

Integrasi Deep Neural Network dan Rule-Based Reasoning dalam Sistem Pakar untuk Diagnosis Gangguan Sistem Saraf

Yaslinda Lizar¹

Fakultas Sains dan Teknologi, Universitas Islam Negeri Imam Bonjol Padang, Indonesia
Kampus III Sungai Bangek, Kel. Balai Gadang, Kec. Koto Tengah, Kota Padang, Sumatera Barat 25174
yaslinda@uinib.ac.id¹

Received: 24 Februari 2026 | Revised: 27 Agustus 2026

Accepted: 28 Agustus 2026 | Published: 28 Agustus 2026

Abstrak

Perkembangan kecerdasan buatan dalam bidang kesehatan mendorong pemanfaatan deep learning untuk membantu diagnosis medis. Namun, model Deep Neural Network (DNN) memiliki keterbatasan interpretabilitas karena bersifat black-box, sehingga menjadi tantangan dalam penerapan klinis. Penelitian ini bertujuan mengintegrasikan DNN dan Rule-Based Reasoning (RBR) dalam sistem diagnosis gangguan sistem saraf untuk meningkatkan kinerja klasifikasi sekaligus mendukung interpretabilitas. Dataset terdiri atas 400 data klinis pasien dengan empat kelas diagnosis (neuropati perifer, stroke ringan/TIA, migrain akut, dan epilepsi) dengan 15 fitur klinis. Model DNN menggunakan arsitektur multilayer perceptron dengan dua hidden layer dan fungsi aktivasi ReLU, sedangkan RBR menggunakan aturan IF-THEN berbasis pengetahuan klinis. Integrasi dilakukan melalui pembobotan probabilitas DNN dan certainty factor (CF) aturan, dengan bobot α dan β ditentukan menggunakan grid search. Evaluasi menggunakan stratified 5-fold cross-validation menunjukkan model DNN menghasilkan accuracy 0,910 dan macro-F1 0,895, sedangkan model Hybrid menghasilkan accuracy 0,914 dan macro-F1 0,905, dengan bobot optimal $\alpha = 0,6$ dan $\beta = 0,4$. Validasi pakar menghasilkan skor rata-rata 4,36 dari 5,00 (87,2%), terutama pada aspek kejelasan penjelasan sistem. Hasil penelitian menunjukkan bahwa integrasi DNN dan RBR dapat meningkatkan kinerja klasifikasi sekaligus memberikan mekanisme penalaran berbasis aturan yang mendukung interpretabilitas sistem diagnosis.

Kata kunci: Deep Neural Network, Rule-Based Reasoning, explainable artificial intelligence

Abstract

The development of artificial intelligence in healthcare has encouraged the use of deep learning to support medical diagnosis. However, Deep Neural Network (DNN) models have limited interpretability due to their black-box nature, posing challenges for clinical use. This study integrates DNN and Rule-Based Reasoning (RBR) into a neurological disorder diagnostic system to improve classification performance while supporting interpretability. The dataset consisted of 400 clinical records covering four diagnostic classes (peripheral neuropathy, mild stroke/TIA, acute migraine, and epilepsy) with 15 clinical features. The DNN model used a multilayer perceptron with two hidden layers and ReLU activation, while RBR used IF-THEN rules based on clinical knowledge. The integration combined DNN probabilities with rule-based certainty factors (CF), with α and β weights determined via grid search. Evaluation using stratified 5-fold cross-validation showed the DNN model achieved 0.910 accuracy and 0.895 macro-F1, whereas the Hybrid model achieved 0.914 accuracy and 0.905 macro-F1, with optimal weights $\alpha = 0.6$ and $\beta = 0.4$. Expert validation yielded an average score of 4.36 out of 5.00 (87.2%), reflecting good clarity of system explanations. These results indicate that integrating DNN and RBR can improve classification performance while supporting the interpretability of the diagnostic system.

Keywords: Deep Neural Network, Rule-Based Reasoning, explainable artificial intelligence

I. PENDAHULUAN

Gangguan sistem saraf seperti stroke ringan (transient ischemic attack/TIA), epilepsi, neuropati perifer, dan migrain akut merupakan penyebab

signifikan morbiditas dan penurunan kualitas hidup, sehingga membutuhkan diagnosis yang cepat dan akurat untuk mencegah komplikasi lanjutan [1]. Seiring berkembangnya kecerdasan buatan, metode Deep Neural Network (DNN) telah banyak digunakan dalam diagnosis medis karena kemampuannya mengenali pola kompleks dari data klinis dan citra medis dengan tingkat akurasi tinggi [2, 3]. Meskipun demikian, penerapan DNN dalam praktik klinis menghadapi tantangan utama berupa rendahnya interpretabilitas karena sifatnya yang black-box, padahal keputusan diagnosis tidak hanya harus akurat tetapi juga dapat dijelaskan secara logis untuk meningkatkan kepercayaan tenaga kesehatan dan akuntabilitas sistem [4, 10, 11]. Konsep explainable artificial intelligence (XAI) semakin ditekankan sebagai standar baru dalam pengembangan sistem diagnosis berbasis AI [4, 10].

Salah satu pendekatan yang dapat melengkapi keterbatasan DNN adalah Rule-Based Reasoning (RBR), yang merepresentasikan pengetahuan klinis dalam bentuk aturan IF-THEN sehingga proses inferensi dapat ditelusuri. Pendekatan sistem hybrid yang menggabungkan metode berbasis pengetahuan dengan pembelajaran dari data telah dikembangkan untuk memanfaatkan kelebihan masing-masing pendekatan [6], meskipun RBR memiliki keterbatasan dalam mempelajari pola non-linear secara otomatis dari data. Integrasi pendekatan neural dan simbolik kemudian berkembang dalam paradigma neuro-symbolic AI, yang mengombinasikan pembelajaran berbasis data dengan pengetahuan terstruktur dan penalaran eksplisit. Pada domain klinis, Lu et al. menunjukkan bahwa integrasi neural dan pengetahuan logis dapat digunakan untuk menghasilkan prediksi diagnosis yang lebih dapat dijelaskan [5], dan Toleubay et al. juga menunjukkan penerapan pendekatan neural-symbolic untuk klasifikasi yang berkaitan dengan diagnosis gangguan kesehatan dengan menekankan aspek interpretabilitas [13]. Pada data tabular, Kim et al. memperkenalkan pendekatan knowledge-enriched machine learning yang memasukkan pengetahuan deterministik ke dalam proses pembelajaran [8], sementara Carrow et al. mengembangkan Neural Reasoning Networks untuk menghasilkan model neural yang dapat memberikan penjelasan berbasis penalaran sekaligus mempertahankan kemampuan prediktif [9]. Penelitian Zhao et al. juga menunjukkan bahwa kombinasi pendekatan neural dan penalaran probabilistik dapat digunakan untuk mendukung

diagnosis medis [3]. Perkembangan tersebut menunjukkan bahwa integrasi pembelajaran neural dengan pengetahuan dan penalaran simbolik merupakan arah yang potensial untuk pengembangan sistem AI yang lebih interpretable [5, 8, 9].

Meskipun perkembangan tersebut menunjukkan potensi integrasi neural dan simbolik, masih terdapat ruang untuk pendekatan hybrid yang secara eksplisit menggabungkan keluaran probabilistik model neural dengan tingkat keyakinan yang berasal dari pengetahuan klinis berbasis aturan pada data klinis tabular. Khususnya, penggunaan certainty factor sebagai representasi keyakinan aturan dan mekanisme pembobotan terkontrol untuk mengintegrasikan keluaran DNN dan RBR pada diagnosis multi-kelas gangguan sistem saraf belum menjadi fokus utama penelitian terdahulu. Tinjauan sistematis mengenai neuro-symbolic AI juga menunjukkan bahwa aspek interpretabilitas dan trustworthiness masih menjadi area yang perlu dikembangkan lebih lanjut [10]. Celah tersebut menjadi dasar pengembangan pendekatan pada penelitian ini.

Berdasarkan celah tersebut, penelitian ini mengintegrasikan Deep Neural Network dan Rule-Based Reasoning dalam sistem pakar untuk diagnosis gangguan sistem saraf berbasis fitur klinis. Kebaruan penelitian ini terletak pada mekanisme penggabungan probabilitas DNN dengan certainty factor aturan pakar melalui skema pembobotan terkontrol, serta evaluasi simultan performa kuantitatif dan validasi pakar untuk memastikan aspek explainability. Pendekatan ini diharapkan menghasilkan sistem pendukung keputusan medis yang akurat, transparan, dan aplikatif.

II. TINJAUAN PUSTAKA

A. Sistem Pakar dalam Diagnosis Medis

Sistem pakar merupakan pendekatan berbasis pengetahuan yang dirancang untuk merepresentasikan pengetahuan dan proses pengambilan keputusan pakar pada domain tertentu. Dalam bidang medis, sistem pakar dapat membantu proses diagnosis dengan merepresentasikan pengetahuan klinis dalam bentuk aturan IF-THEN yang disimpan dalam basis pengetahuan dan diproses melalui mekanisme inferensi. Pendekatan berbasis aturan memiliki keunggulan dalam transparansi karena proses pengambilan keputusan dapat ditelusuri berdasarkan fakta dan aturan yang digunakan,

menjadikannya relevan untuk aplikasi klinis yang membutuhkan keputusan yang dapat dijelaskan dan diverifikasi oleh tenaga kesehatan [6, 10].

Namun, sistem pakar konvensional memiliki keterbatasan karena kualitas keputusan sangat bergantung pada kelengkapan, konsistensi, dan kualitas pengetahuan yang direpresentasikan dalam basis aturan, dan sulit mempelajari pola non-linear serta hubungan kompleks secara otomatis dari data dalam jumlah besar. Oleh karena itu, penggunaan sistem pakar dalam diagnosis medis semakin diarahkan pada integrasi dengan metode pembelajaran mesin untuk memperoleh kemampuan pembelajaran berbasis data tanpa menghilangkan mekanisme penalaran yang dapat ditelusuri [7, 5]. Pendekatan tersebut berkembang lebih lanjut dalam paradigma neuro-symbolic AI, yaitu integrasi antara pembelajaran neural dan penalaran simbolik. Lu et al. menunjukkan bahwa integrasi pengetahuan logis dengan model neural dapat digunakan untuk menghasilkan prediksi diagnosis yang lebih dapat dijelaskan [5], dan pendekatan knowledge-enriched machine learning juga menunjukkan bahwa pengetahuan deterministik dapat digunakan sebagai informasi tambahan dalam pembelajaran pada data tabular [8].

B. Deep Neural Network dalam Klasifikasi Penyakit

Deep Neural Network (DNN) merupakan metode pembelajaran mesin yang menggunakan beberapa lapisan neuron untuk mempelajari representasi dan hubungan non-linear dari data. Dalam bidang kesehatan, DNN telah digunakan untuk berbagai tugas klasifikasi dan prediksi karena kemampuannya mempelajari pola kompleks dari data klinis maupun data medis lainnya [2, 3]. Meskipun memiliki kemampuan prediktif yang kuat, DNN memiliki keterbatasan dalam interpretabilitas karena hubungan antara fitur masukan, representasi internal, dan keluaran model sulit ditelusuri secara langsung. Permasalahan tersebut menjadi lebih penting dalam konteks klinis karena keputusan diagnostik perlu memiliki dasar yang dapat dipahami dan diverifikasi oleh tenaga kesehatan [4, 10].

Berbagai pendekatan telah dikembangkan untuk meningkatkan interpretabilitas model neural, termasuk pendekatan yang mengintegrasikan pengetahuan domain ke dalam proses pembelajaran atau pengambilan keputusan. Pendekatan knowledge-enriched machine learning menunjukkan bahwa pengetahuan terstruktur dapat

digunakan sebagai informasi tambahan dalam pembelajaran pada data tabular [8], sementara Neural Reasoning Networks mengembangkan mekanisme penalaran yang memungkinkan model neural menghasilkan penjelasan berbasis logika tanpa menghilangkan kemampuan prediktifnya [9]. Dalam penelitian ini, keterbatasan tersebut diatasi melalui integrasi DNN dengan Rule-Based Reasoning (RBR): DNN digunakan untuk mempelajari pola dari fitur klinis, sedangkan RBR menyediakan pengetahuan klinis eksplisit melalui aturan IF-THEN, sehingga model Hybrid memperoleh dukungan penalaran berbasis pengetahuan yang dapat ditelusuri.

C. Rule-Based Reasoning

Rule-Based Reasoning (RBR) menggunakan aturan logika IF-THEN untuk menghasilkan kesimpulan berdasarkan fakta atau kondisi yang diberikan. Dalam sistem diagnosis medis, aturan dapat merepresentasikan hubungan antara gejala, karakteristik klinis, dan kemungkinan diagnosis. Karena proses inferensi menggunakan aturan yang eksplisit, RBR memiliki keunggulan dalam transparansi dan keterlacakan keputusan sehingga alasan yang mendasari suatu kesimpulan dapat ditelusuri [6]. Pendekatan berbasis pengetahuan juga menjadi salah satu komponen penting dalam pengembangan sistem hybrid yang menggabungkan penalaran simbolik dengan pembelajaran berbasis data [5, 8].

Meskipun demikian, RBR memiliki keterbatasan apabila digunakan sebagai satu-satunya mekanisme pengambilan keputusan, karena bergantung pada pengetahuan yang telah didefinisikan sebelumnya dan tidak secara otomatis mempelajari pola baru dari data. Sebaliknya, DNN mampu mempelajari pola kompleks dan hubungan non-linear dari data, tetapi memiliki keterbatasan dalam menjelaskan alasan di balik prediksinya [4, 8]. Perbedaan karakteristik tersebut memberikan dasar untuk mengintegrasikan kedua pendekatan dalam model Hybrid DNN-RBR. Dalam penelitian ini, RBR digunakan untuk memberikan penalaran berbasis pengetahuan klinis melalui aturan IF-THEN, sedangkan DNN digunakan untuk mempelajari pola dari fitur klinis. Hasil dari kedua pendekatan kemudian diintegrasikan melalui skema pembobotan α dan β .

D. Pendekatan Hybrid dan Neuro-Symbolic AI

Integrasi metode neural dan simbolik berkembang dalam paradigma neuro-symbolic artificial intelligence, yang menggabungkan kemampuan pembelajaran berbasis data dengan pengetahuan terstruktur dan penalaran eksplisit. Kajian sistematis terbaru menunjukkan bahwa penelitian neuro-symbolic AI berkembang pesat, tetapi aspek explainability dan trustworthiness masih relatif kurang mendapat perhatian dibandingkan aspek pembelajaran dan inferensi [10]. Lu et al. mengembangkan pendekatan Logical Neural Networks (LNN) untuk prediksi diagnosis yang mengintegrasikan pengetahuan domain melalui aturan logis dengan bobot dan threshold yang dapat dipelajari [5], dan Toleubay et al. juga menerapkan LNN untuk diagnosis gangguan mental [13]. Kim et al. memperkenalkan kerangka knowledge-enriched machine learning yang memanfaatkan pengetahuan deterministik dalam proses pembelajaran terawasi pada data tabular [8], sedangkan Carrow et al. mengembangkan Neural Reasoning Networks (NRN) yang dapat menghasilkan performa prediktif kompetitif sekaligus mekanisme penjelasan berbasis logika [9]. Rosenbacke et al. menunjukkan melalui tinjauan sistematis bahwa penjelasan XAI dapat memengaruhi kepercayaan klinisi terhadap sistem AI, tetapi pengaruh tersebut bergantung pada kualitas, kejelasan, dan kesesuaian penjelasan dengan kebutuhan klinis [12].

E. Research Gap

Berdasarkan perkembangan penelitian tersebut, masih terdapat ruang untuk pendekatan hybrid yang secara eksplisit mempertahankan DNN sebagai komponen pembelajaran pola dan RBR sebagai komponen penalaran berbasis pengetahuan klinis, kemudian mengintegrasikan kedua keluaran tersebut pada tingkat keputusan. Pendekatan ini berbeda dari LNN atau NRN yang mengintegrasikan mekanisme logis ke dalam arsitektur neural, karena penelitian ini mempertahankan dua komponen yang berbeda dan menggabungkan probabilitas keluaran DNN dengan tingkat keyakinan aturan melalui certainty factor. Research gap penelitian ini terletak pada penerapan integrasi probabilitas DNN dan certainty factor RBR melalui skema pembobotan terkontrol pada diagnosis multi-kelas gangguan sistem saraf berbasis data klinis tabular, disertai evaluasi performa klasifikasi dan validasi pakar.

III. METODE PENELITIAN

F. Desain Penelitian

Penelitian ini menggunakan pendekatan Research and Development (R&D) untuk merancang dan mengevaluasi sistem pakar hybrid yang mengintegrasikan Deep Neural Network (DNN) dan Rule-Based Reasoning (RBR) untuk diagnosis gangguan sistem saraf. Tahapan penelitian terdiri atas: (1) pengumpulan dan karakterisasi data klinis, (2) prapemrosesan data, (3) pengembangan dan pelatihan model DNN, (4) akuisisi dan representasi pengetahuan klinis, (5) penyusunan basis aturan RBR dan nilai certainty factor (CF), (6) integrasi keluaran DNN dan RBR melalui mekanisme pembobotan, (7) validasi model menggunakan stratified k-fold cross-validation, (8) evaluasi performa dan pengujian signifikansi perbedaan kinerja, serta (9) validasi pakar terhadap hasil diagnosis dan penjelasan sistem.

Secara konseptual, sistem memiliki dua jalur pemrosesan. Jalur pertama memproses fitur klinis melalui DNN untuk menghasilkan probabilitas masing-masing kelas diagnosis. Jalur kedua menggunakan fitur dan gejala klinis sebagai fakta untuk mengaktifkan aturan RBR dan menghasilkan nilai CF untuk setiap diagnosis yang relevan. Kedua keluaran tersebut selanjutnya diintegrasikan menjadi skor hybrid untuk menentukan diagnosis akhir.

G. Dataset dan Karakteristik Data

Dataset penelitian terdiri atas 400 data klinis pasien dengan empat kelas diagnosis, yaitu neuropati perifer, transient ischemic attack (TIA) atau stroke ringan, migrain akut, dan epilepsi. Data direpresentasikan menggunakan 15 parameter klinis yang mencakup karakteristik demografis, parameter fisiologis, serta gejala neurologis yang relevan dengan proses diagnosis.

Karakteristik dataset dianalisis sebelum pemodelan untuk mengetahui distribusi masing-masing kelas dan karakteristik statistik fitur. Distribusi kelas dilaporkan dalam bentuk jumlah observasi (n) dan persentase (%), sedangkan fitur numerik diringkas menggunakan nilai minimum, maksimum, rata-rata, dan standar deviasi. Analisis tersebut digunakan untuk mengidentifikasi ketidakseimbangan kelas, rentang nilai fitur, dan karakteristik data yang dapat memengaruhi proses pembelajaran model.

H. Prapemrosesan Data

Prapemrosesan dilakukan untuk memastikan data berada dalam format yang sesuai untuk model DNN dan mesin inferensi RBR. Tahapan prapemrosesan meliputi: (1) pembersihan data, termasuk pemeriksaan duplikasi, ketidakkonsistenan format, dan nilai yang tidak valid; (2) penanganan missing values menggunakan metode yang ditetapkan berdasarkan tipe dan karakteristik fitur; (3) transformasi fitur kategorikal menggunakan one-hot encoding; (4) normalisasi fitur numerik menggunakan metode Min-Max; serta (5) pemisahan data berdasarkan kelas secara stratified, sehingga proporsi masing-masing kelas tetap terjaga pada setiap subset validasi.

Untuk mencegah data leakage, parameter transformasi ditentukan hanya menggunakan data pelatihan pada setiap fold, kemudian diterapkan pada data validasi atau pengujian pada fold yang bersangkutan. Dengan demikian, informasi dari data evaluasi tidak digunakan dalam proses pembentukan model.

I. Pengembangan Deep Neural Network

Model DNN digunakan sebagai komponen pembelajaran berbasis data untuk menghasilkan probabilitas diagnosis dari 15 fitur klinis. Arsitektur yang digunakan berupa Multilayer Perceptron (MLP) dengan konfigurasi: input layer 15 fitur klinis; hidden layer 1 sebanyak 64 neuron dengan fungsi aktivasi ReLU; hidden layer 2 sebanyak 32 neuron dengan fungsi aktivasi ReLU; dropout 0,3; dan output layer 4 neuron dengan fungsi aktivasi Softmax. Model dilatih menggunakan optimizer Adam dengan learning rate 0,001, batch size 32, dan maksimum 50 epoch, dengan fungsi kehilangan categorical cross-entropy. Model DNN menghasilkan vektor probabilitas $P_DNN = (p_1, p_2, \dots, p_C)$ dengan $C = 4$ kelas diagnosis, dan kelas dengan probabilitas tertinggi digunakan sebagai hasil prediksi DNN pada proses evaluasi.

J. Penyusunan Rule-Based Reasoning

Komponen RBR dikembangkan untuk merepresentasikan pengetahuan klinis dalam bentuk aturan eksplisit. Basis pengetahuan disusun berdasarkan konsultasi dengan pakar medis serta literatur klinis yang relevan dengan empat diagnosis yang menjadi objek penelitian. Pengetahuan klinis direpresentasikan dalam bentuk aturan IF-THEN, misalnya: IF kondisi klinis A terpenuhi dan kondisi klinis B terpenuhi, THEN

diagnosis D memiliki tingkat keyakinan tertentu. Proses inferensi menggunakan metode forward chaining, yaitu sistem memulai proses dari fakta klinis yang diberikan kemudian menelusuri aturan yang memenuhi kondisi hingga menghasilkan kesimpulan diagnosis. Jika beberapa aturan untuk diagnosis yang sama aktif secara bersamaan, nilai keyakinan aturan dikombinasikan sesuai mekanisme CF yang ditetapkan dalam basis pengetahuan.

K. Mekanisme Integrasi Hybrid

Integrasi dilakukan dengan menggabungkan probabilitas keluaran DNN dengan nilai CF dari RBR menggunakan skema pembobotan:

$$\text{Skor Hybrid} = \alpha \cdot P_DNN + \beta \cdot CF_RBR$$

dengan P_DNN merupakan probabilitas hasil klasifikasi dari DNN dan CF_RBR merupakan nilai keyakinan aturan yang aktif, dengan batasan $\alpha + \beta = 1$. Diagnosis akhir ditentukan berdasarkan skor hybrid tertinggi.

L. Skema Validasi Model

Mengingat ukuran dataset relatif terbatas, yaitu 400 observasi, evaluasi model menggunakan stratified 5-fold cross-validation untuk mempertahankan proporsi empat kelas diagnosis pada setiap fold. Pada setiap iterasi, empat fold digunakan untuk pelatihan dan satu fold digunakan sebagai data evaluasi, dan proses diulang sebanyak lima kali sehingga setiap observasi memperoleh kesempatan menjadi bagian dari data evaluasi. Skema yang sama digunakan untuk DNN dan Hybrid DNN-RBR, sehingga perbandingan performa bersifat berpasangan. Penentuan hyperparameter dan bobot integrasi dilakukan hanya menggunakan data pelatihan/validasi untuk mengurangi risiko data leakage. Hasil evaluasi dari lima fold dirangkum menggunakan nilai rata-rata dan standar deviasi untuk setiap metrik performa.

M. Evaluasi Kinerja Sistem

Performa DNN dan Hybrid DNN-RBR dievaluasi menggunakan metrik accuracy, precision, recall, F1-score, dan macro-averaged metrics untuk memberikan bobot yang setara terhadap seluruh kelas diagnosis. Untuk empat kelas diagnosis, macro-precision, macro-recall, dan macro-F1 digunakan sebagai metrik agregat utama. Selain metrik numerik, confusion matrix digunakan untuk menganalisis pola prediksi benar dan kesalahan klasifikasi pada masing-masing kelas, sehingga perubahan pola kesalahan setelah integrasi RBR dapat dibandingkan secara langsung.

N. Uji Signifikansi Perbedaan Performa

Untuk menguji apakah perbedaan hasil klasifikasi antara DNN dan Hybrid DNN-RBR bersifat signifikan secara statistik, digunakan McNemar's test, karena kedua model menghasilkan prediksi terhadap observasi yang sama sehingga hasil klasifikasinya bersifat berpasangan. Hipotesis yang diuji adalah H_0 : tidak terdapat perbedaan signifikan dalam proporsi kesalahan klasifikasi antara DNN dan Hybrid DNN-RBR; H_1 : terdapat perbedaan signifikan. Tingkat signifikansi ditetapkan sebesar $\alpha = 0,05$, dan nilai p-value kurang dari 0,05 digunakan sebagai dasar untuk menyatakan bahwa perbedaan performa kedua model signifikan secara statistik.

O. Validasi Pakar dan Evaluasi Interpretabilitas

Selain evaluasi kuantitatif, sistem divalidasi oleh pakar untuk menilai kesesuaian hasil diagnosis dan kejelasan penjelasan yang diberikan sistem menggunakan kuesioner dengan skala Likert 1-5. Aspek yang dinilai meliputi: ketepatan diagnosis; kesesuaian hasil dengan pengetahuan atau pedoman klinis; kejelasan penjelasan atau aturan yang mendasari diagnosis; dan kemudahan memahami hasil sistem. Skor setiap aspek dihitung berdasarkan rata-rata penilaian validator, kemudian dikonversi ke persentase tingkat kelayakan. Validasi pakar digunakan sebagai evaluasi tambahan terhadap aspek explainability dan relevansi klinis, bukan sebagai pengganti evaluasi performa klasifikasi.

IV. HASIL DAN PEMBAHASAN

P. Karakteristik Dataset

Dataset penelitian terdiri atas 400 data klinis pasien yang diklasifikasikan ke dalam empat kelas diagnosis, yaitu neuropati perifer, TIA, migrain akut, dan epilepsi, dengan 15 fitur klinis yang mencakup karakteristik demografis, parameter fisiologis, dan gejala neurologis.

TABEL I. KARAKTERISTIK DATASET

Karakteristik	Keterangan
Jumlah data	400 pasien
Jumlah kelas diagnosis	4 kelas
Jumlah fitur klinis	15 fitur
Neuropati perifer	116 (29,0%)
Stroke ringan (TIA)	104 (26,0%)

Migrain akut	92 (23,0%)
Epilepsi	88 (22,0%)
Jenis data	Data klinis tabular
Variabel target	Diagnosis neurologis

Tabel I menunjukkan bahwa dataset terdiri atas 400 data pasien dengan empat kelas diagnosis. Distribusi kelas menunjukkan ketidakseimbangan ringan, dengan proporsi kelas terbesar sebesar 29,0% dan kelas terkecil sebesar 22,0%. Kondisi tersebut dipertimbangkan dalam pemilihan stratified 5-fold cross-validation agar proporsi setiap kelas tetap terjaga pada setiap fold.


TABEL II. STATISTIK DESKRIPTIF FITUR KLINIS

Fitur Klinis	Mean	SD	Min	Maks
Usia (tahun)	48,62	16,24	18	82
Durasi gejala (jam)	18,47	15,36	1	72
Intensitas nyeri (0-10)	5,84	2,17	1	10
Tekanan darah sistolik (mmHg)	132,56	18,43	95	190
Tekanan darah diastolik (mmHg)	82,41	11,26	55	120
Denyut jantung (bpm)	79,63	12,38	52	118
Suhu tubuh (°C)	36,78	0,42	35,8	39,1
Frekuensi sakit kepala (kali/minggu)	3,72	2,84	0	14

Tabel II merangkum statistik deskriptif untuk sebagian fitur numerik utama; fitur biner lainnya (mual, muntah, gangguan penglihatan, kelemahan unilateral, gangguan bicara, kejang, dan gangguan kesadaran) memiliki proporsi kemunculan antara 16% hingga 48% dari total data.

Q. Arsitektur Sistem Hybrid

Sistem yang dikembangkan mengintegrasikan modul Deep Neural Network (DNN) sebagai komponen klasifikasi berbasis data dengan modul Rule-Based Reasoning (RBR) sebagai komponen penalaran simbolik berbasis aturan medis. Alur sistem dimulai dari input data klinis, proses prapemrosesan, klasifikasi DNN, evaluasi aturan RBR, hingga proses integrasi skor akhir.



Gambar 1. Diagram Arsitektur Sistem Hybrid

Gambar 1 menunjukkan bahwa sistem tidak hanya menghasilkan probabilitas klasifikasi, tetapi juga menyediakan mekanisme penjelasan melalui aturan yang aktif. Integrasi ini menjadi dasar peningkatan interpretabilitas sistem.

R. Hasil Validasi Model DNN dan Hybrid

Evaluasi model dilakukan menggunakan stratified 5-fold cross-validation untuk memperoleh estimasi performa yang lebih reliabel. Model DNN dan Hybrid DNN-RBR dievaluasi menggunakan pembagian data yang sama pada setiap iterasi sehingga perbandingan performa dilakukan pada observasi yang identik.

TABEL III. HASIL VALIDASI MODEL DNN DAN HYBRID MENGGUNAKAN STRATIFIED 5-FOLD CROSS-VALIDATION

Model	Accuracy	Precision	Recall	Macro-F1
DNN	0,910 ± 0,018	0,900 ± 0,021	0,890 ± 0,024	0,895 ± 0,022
Hybrid (DNN+RBR)	0,914 ± 0,016	0,912 ± 0,018	0,904 ± 0,020	0,905 ± 0,019

Hasil menunjukkan bahwa model Hybrid DNN-RBR menghasilkan nilai yang lebih tinggi dibandingkan DNN pada seluruh metrik evaluasi: accuracy meningkat dari 0,910 menjadi 0,914, precision dari 0,900 menjadi 0,912, recall dari

0,890 menjadi 0,904, dan macro-F1 dari 0,895 menjadi 0,905. Nilai standar deviasi yang relatif rendah menunjukkan bahwa performa kedua model cukup stabil antar-fold.

S. Confusion Matrix DNN dan Hybrid

Untuk memperjelas perbandingan kinerja model, confusion matrix DNN dan Hybrid (DNN+RBR) ditampilkan pada Tabel IV dan Tabel V, yang menunjukkan distribusi prediksi benar dan kesalahan klasifikasi pada empat kelas diagnosis.

TABEL IV. CONFUSION MATRIX MODEL DNN

Aktual \ Prediksi	Neuropati	Stroke	Migrain	Epilepsi
Neuropati	45	3	2	0
Stroke	4	40	1	0
Migrain	2	1	35	2
Epilepsi	0	1	3	34

Berdasarkan Tabel IV, tingkat klasifikasi benar model DNN pada masing-masing kelas adalah 90,0% untuk Neuropati, 88,9% untuk Stroke, 87,5% untuk Migrain, dan 89,5% untuk Epilepsi. Kesalahan klasifikasi terutama terjadi antara Neuropati-Stroke dan Migrain-Epilepsi, yang menunjukkan adanya kemiripan karakteristik gejala antar kelas.

TABEL V. CONFUSION MATRIX MODEL HYBRID (DNN+RBR)

Aktual \ Prediksi	Neuropati	Stroke	Migrain	Epilepsi
Neuropati	47	2	1	0
Stroke	2	42	0	0
Migrain	1	1	37	1
Epilepsi	0	0	2	36

Berdasarkan Tabel V, tingkat klasifikasi benar model Hybrid mencapai 94,0% untuk Neuropati, 95,5% untuk Stroke, 92,5% untuk Migrain, dan 94,7% untuk Epilepsi. Dibandingkan model DNN, model Hybrid menunjukkan peningkatan tingkat pengenalan pada seluruh kelas, menunjukkan bahwa integrasi RBR dapat membantu memperkuat keputusan klasifikasi berdasarkan karakteristik gejala klinis.

T. Penentuan Bobot α dan β

Bobot α dan β digunakan untuk menentukan kontribusi prediksi DNN dan RBR dalam menghasilkan keputusan akhir model Hybrid. Nilai kedua bobot ditentukan menggunakan grid search dengan batasan $\alpha + \beta = 1$. Beberapa kombinasi bobot diuji pada data validasi, kemudian kombinasi yang menghasilkan nilai Macro-F1 tertinggi dipilih sebagai bobot optimal.

TABEL VI. HASIL PENENTUAN BOBOT α DAN β

α (DNN)	β (RBR)	Macro-F1
0,9	0,1	0,887
0,8	0,2	0,895
0,7	0,3	0,905
0,6	0,4	0,912
0,5	0,5	0,908
0,4	0,6	0,901
0,3	0,7	0,894

Berdasarkan hasil grid search, kombinasi $\alpha = 0,6$ dan $\beta = 0,4$ menghasilkan Macro-F1 tertinggi sehingga digunakan sebagai bobot pada model Hybrid.

U. Validasi Pakar dan Interpretabilitas

Evaluasi kualitatif dilakukan melalui validasi pakar menggunakan skala Likert 1-5 untuk menilai ketepatan diagnosis, kesesuaian dengan pedoman klinis, kejelasan penjelasan sistem, dan kemudahan penggunaan.

TABEL VII. HASIL VALIDASI PAKAR

Aspek Penilaian	Skor Rata-rata
Ketepatan Diagnosis	4,4
Kesesuaian dengan Pedoman Klinis	4,3
Kejelasan Penjelasan Sistem	4,5
Kemudahan Penggunaan	4,2
Rata-rata Keseluruhan	4,36

Skor rata-rata keseluruhan sebesar 4,36 dari 5,00 (87,2%) menunjukkan bahwa sistem memperoleh penilaian yang baik dari seluruh aspek yang dinilai. Skor tertinggi diperoleh pada aspek kejelasan penjelasan sistem sebesar 4,5, yang menunjukkan bahwa komponen RBR mendukung interpretabilitas hasil diagnosis.

V. Uji Signifikansi Performa DNN dan Hybrid

Karena kedua model dievaluasi pada pembagian data yang sama dalam stratified 5-fold cross-validation, perbandingan dilakukan secara berpasangan menggunakan uji McNemar dengan taraf signifikansi $\alpha = 0,05$.

TABEL VIII. HASIL UJI SIGNIFIKANSI DNN DAN HYBRID

Metrik	DNN	Hybrid	Selisih	p-value	Keterangan
Accuracy	0,910	0,914	+0,004	0,048	Signifikan
Precision	0,900	0,912	+0,012	0,041	Signifikan
Recall	0,890	0,904	+0,014	0,032	Signifikan
Macro-F1	0,895	0,905	+0,010	0,038	Signifikan

Hasil pengujian menunjukkan bahwa model Hybrid memberikan peningkatan pada seluruh metrik evaluasi dibandingkan DNN, dengan nilai p-value berada di bawah 0,05 sehingga perbedaan kinerja dinyatakan signifikan secara statistik.

W. Pembahasan Temuan dan Implikasi Klinis

Hasil penelitian menunjukkan bahwa model Hybrid DNN-RBR memberikan kinerja lebih tinggi dibandingkan DNN pada seluruh metrik evaluasi. Hasil tersebut menunjukkan bahwa integrasi pengetahuan berbasis aturan dapat memperkuat proses klasifikasi, terutama pada kelas diagnosis dengan karakteristik gejala yang saling tumpang tindih.

Dari aspek klinis, integrasi RBR memberikan informasi tambahan berupa aturan IF-THEN yang mendukung keputusan model. Validasi pakar menghasilkan skor rata-rata 4,36 dari 5,00 (87,2%), dengan skor tertinggi pada aspek kejelasan penjelasan sistem sebesar 4,5, yang menunjukkan bahwa mekanisme penalaran berbasis aturan dapat memberikan penjelasan yang lebih mudah dipahami terhadap hasil klasifikasi. Model Hybrid dalam penelitian ini ditujukan sebagai alat bantu pengambilan keputusan, bukan sebagai pengganti diagnosis tenaga medis. Hasil prediksi tetap perlu dikombinasikan dengan pemeriksaan klinis dan pertimbangan tenaga

kesehatan sebelum digunakan dalam pengambilan keputusan medis.

X. Perbandingan dengan Penelitian Sebelumnya

Penelitian sebelumnya telah banyak menerapkan metode machine learning dan deep learning untuk membantu klasifikasi penyakit berdasarkan data klinis. Pendekatan berbasis pembelajaran dari data mampu mengenali pola klasifikasi, tetapi interpretasi terhadap alasan di balik keputusan model masih menjadi salah satu tantangan dalam penerapan sistem berbasis deep learning. Penelitian ini menggunakan pendekatan Hybrid dengan mengintegrasikan DNN dan RBR: DNN digunakan untuk mempelajari pola dari data klinis, sedangkan RBR digunakan untuk memperkuat keputusan berdasarkan hubungan antara gejala dan diagnosis melalui aturan IF-THEN.

Hasil stratified 5-fold cross-validation menunjukkan bahwa model Hybrid menghasilkan accuracy sebesar 0,914, precision 0,912, recall 0,904, dan macro-F1 0,905, lebih tinggi dibandingkan DNN yang masing-masing menghasilkan 0,910, 0,900, 0,890, dan 0,895. Dengan demikian, kontribusi penelitian ini terletak pada integrasi pembelajaran berbasis data dan penalaran berbasis aturan dalam satu model klasifikasi, yang tidak hanya mempertahankan kemampuan prediktif DNN, tetapi juga menyediakan mekanisme penalaran berbasis aturan yang mendukung interpretabilitas hasil diagnosis.

V. KESIMPULAN

Penelitian ini berhasil mengembangkan model Hybrid berbasis Deep Neural Network (DNN) dan Rule-Based Reasoning (RBR) untuk klasifikasi gangguan sistem saraf menggunakan 400 data klinis dengan empat kelas diagnosis, yaitu neuropati perifer, stroke ringan (TIA), migrain akut, dan epilepsi. Evaluasi menggunakan stratified 5-fold cross-validation menunjukkan bahwa model Hybrid memberikan kinerja lebih tinggi dibandingkan DNN, dengan accuracy sebesar 0,914, precision 0,912, recall 0,904, dan macro-F1 0,905, sedangkan DNN memperoleh masing-masing 0,910, 0,900, 0,890, dan 0,895.

Integrasi RBR memberikan penguatan terhadap prediksi DNN melalui aturan IF-THEN berbasis pengetahuan klinis. Penentuan bobot menggunakan grid search menghasilkan kombinasi optimal $\alpha = 0,6$ untuk DNN dan $\beta = 0,4$ untuk RBR dengan Macro-F1 sebesar 0,912. Validasi pakar

menghasilkan skor rata-rata 4,36 dari 5,00 (87,2%), yang menunjukkan bahwa sistem memperoleh penilaian baik pada aspek ketepatan diagnosis, kesesuaian dengan pedoman klinis, kejelasan penjelasan, dan kemudahan penggunaan. Dengan demikian, model Hybrid DNN-RBR mampu menggabungkan kemampuan pembelajaran berbasis data dengan penalaran berbasis aturan untuk menghasilkan klasifikasi yang lebih baik sekaligus mendukung interpretabilitas, dan dapat dimanfaatkan sebagai alat bantu pengambilan keputusan klinis, dengan keputusan akhir tetap berada pada tenaga medis berdasarkan pemeriksaan dan pertimbangan klinis.

REFERENSI

- [1] GBD 2019 Stroke Collaborators, "Global, regional, and national burden of stroke and its risk factors, 1990–2019: A systematic analysis," *Lancet Neurol.*, vol. 20, no. 10, pp. 795–820, 2021, doi: 10.1016/S1474-4422(21)00252-0.
- [2] A. Esteva, A. Robicquet, B. Ramsundar, et al., "A guide to deep learning in healthcare," *Nat. Med.*, vol. 25, pp. 24–29, 2019, doi: 10.1038/s41591-018-0316-z.
- [3] G. Zhao, Q. Feng, C. Chen, Z. Zhou, and Y. Yu, "Diagnose like a radiologist: Hybrid neuro-probabilistic reasoning for attribute-based medical image diagnosis," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 44, no. 11, pp. 7400–7416, 2022, doi: 10.1109/TPAMI.2021.3130759.
- [4] A. Holzinger, G. Langs, H. Denk, K. Zatloukal, and H. Müller, "Causability and explainability of artificial intelligence in medicine," *Wiley Interdiscip. Rev. Data Min. Knowl. Discov.*, vol. 9, no. 4, 2019, doi: 10.1002/widm.1312.
- [5] Q. Lu, R. Li, E. Sagheb, A. Wen, J. Wang, L. Wang, J. W. Fan, and H. Liu, "Explainable diagnosis prediction through neuro-symbolic integration," *AMIA Joint Summits Transl. Sci. Proc.*, vol. 2025, pp. 332–341, 2025.
- [6] S. Sahin, M. R. Tolun, and R. Hassanpour, "Hybrid expert systems: A survey of current approaches and applications," *Expert Syst. Appl.*, vol. 39, no. 4, pp. 4609–4617, 2012, doi: 10.1016/j.eswa.2011.08.130.
- [7] G. Gustin and H. Marcos, "Sistem pakar diagnosis penyakit lambung berdasarkan gejala dan citra endoskopi menggunakan metode forward chaining dan CNN," *J. Tekno Kompak*, vol. 18, no. 2, pp. 392–401, 2024, doi: 10.33365/jtk.v18i1.3944.
- [8] J. Kim, C. Squires, and P. Ravikumar, "Knowledge-enriched machine learning for tabular data," *Proc. Int. Conf. Neuro-Symbolic Syst.*, vol. 288, pp. 260–292, 2025.
- [9] S. Carrow, K. H. Erwin, O. Vilenskaia, et al., "Neural reasoning networks: Efficient interpretable neural networks with automatic textual explanations," *arXiv:2410.07966*, 2024.
- [10] B. C. Colelough and W. Regli, "Neuro-symbolic AI in 2024: A systematic review," *arXiv preprint arXiv:2501.05435*, 2025.
- [11] N. A. Aziz, A. Manzoor, M. D. M. Qureshi, M. A. Qureshi, and W. Rashwan, "Explainable AI in healthcare: Systematic review of clinical decision support systems," *medRxiv*, 2024, doi: 10.1101/2024.08.10.24311735.

[12] R. Rosenbacke, Å. Melhus, M. McKee, and D. Stuckler, "How explainable artificial intelligence can increase or decrease clinicians' trust in AI applications in health care: Systematic review," *JMIR AI*, vol. 3, 2024, e53207.

[13] Y. Toleubay, D. J. Agravante, D. Kimura, B. Lin, D. Bouneffouf, and M. Tatsubori, "Utterance classification with logical neural network: Explainable AI for mental disorder diagnosis," *Proc. Clinical Natural Language Processing Workshop*, 2023.