



Arsitektur Komputasi Kognitif Berbasis Penalaran Neuro-Simbolik untuk Manajemen Sumber Daya *Multicore*

Mohamad Ali Wardana¹, Andi Patappari²

Program Studi Teknik Informatika, Universitas Lamappapoleonro¹

Program Studi Sistem Informasi, Universitas Lamappapoleonro²

Jl. Salotungo No. 62, Watansoppeng, Soppeng, Sulawesi Selatan, Indonesia^{1,2}

aliwardana@unipol.ac.id^{*1}, andi.patappari@unipol.ac.id²

Kata Kunci :

Komputasi kognitif;
Multicore;
Penalaran neuro-simbolik;
Manajemen sumber daya;
Machine learning

ABSTRAK

Penelitian ini mengembangkan arsitektur komputasi kognitif neuro-simbolik untuk rekomendasi pengelolaan sumber daya multicore. Sebanyak 5.000 observasi gabungan pengukuran dan simulasi yang dinyatakan telah divalidasi pakar dianalisis menggunakan pembagian terstratifikasi 70:15:15. Arsitektur mengintegrasikan multilayer perceptron, aturan simbolik terpelajar, dan pemeriksaan kelayakan tindakan. Evaluasi menunjukkan Random Forest memiliki Macro-F1 tertinggi (87,29%), sedangkan fusi neuro-simbolik menghasilkan 78,92% dan meningkat menjadi 79,06% setelah pemeriksaan aturan, dengan akurasi 90,27%. Penalaran simbolik meningkatkan sensitivitas beberapa tindakan minoritas, tetapi menimbulkan kompromi kesalahan pada kelas lainnya. Temuan menunjukkan manfaat integrasi penalaran yang dapat ditelusuri, sekaligus menegaskan bahwa keunggulan prediktif dan efisiensi operasional belum otomatis diperoleh dari fusi model. Evaluasi prospektif penjadwalan diperlukan untuk mengukur dampak aktual pada latensi dan throughput.

Keywords:

Cognitive computing;
Multicore;
Neuro-symbolic reasoning;
Resource management;
Machine learning

ABSTRACT

This study develops a neuro-symbolic cognitive computing architecture for multicore resource-management recommendations. A total of 5,000 observations combining measurements and simulation, reported as expert-validated, were examined using a stratified 70:15:15 train-validation-test split. The architecture integrates a multilayer perceptron, learned symbolic rules, and action-feasibility checks. Random Forest achieved the highest macro-F1 (87.29%), while neuro-symbolic fusion reached 78.92%, improving to 79.06% with feasibility checks and 90.27% accuracy. Symbolic reasoning improved sensitivity for selected minority actions but introduced trade-offs across classes. These findings demonstrate the value of traceable reasoning while showing that hybridization does not automatically outperform strong predictive baselines. Prospective scheduling experiments are needed to quantify actual improvements in latency and throughput.

---Jurnal JISTI @2026---

PENDAHULUAN

Peningkatan jumlah inti pemrosesan dalam sistem multicore memperluas kapasitas komputasi paralel, tetapi tidak serta-merta menjamin kinerja yang stabil. Banyaknya tugas yang dapat berjalan bersamaan memunculkan persaingan pada cache, memori, jalur interkoneksi, serta antrian eksekusi. Dalam sistem yang melayani beban heterogen, keputusan menambah inti aktif, mengubah prioritas, atau memindahkan proses perlu mempertimbangkan keterbatasan sumber daya dan karakter tugas. Meunier et al. (2024) menegaskan bahwa interferensi antartugas pada multicore memengaruhi prediktabilitas waktu eksekusi, sedangkan Vesilo (2024) menunjukkan relevansi strategi alokasi core terhadap waktu penyelesaian total.



Pendekatan penjadwalan konvensional menawarkan implementasi yang relatif sederhana, tetapi kebijakan tetap cenderung kesulitan merespons variasi beban yang berubah cepat. Pengalokasian berlebih dapat memperbesar konsumsi daya dan overhead, sementara pengalokasian yang kurang memadai meningkatkan waktu tunggu. Friebe et al. (2025) memodelkan pemilihan jumlah core sebagai keputusan adaptif pada tugas paralel dengan batas tenggat. Di ranah komputasi terdistribusi, Devi et al. (2024), Rathee dan Dalal (2025), serta Sanjalawe et al. (2025) juga mengidentifikasi kebutuhan penyeimbangan beban serta pengelolaan energi yang semakin adaptif. Walaupun konteks cloud tidak identik dengan multicore pada satu perangkat, persoalan alokasi sumber daya dan kompromi kualitas layanan memperlihatkan kesamaan prinsip.

Machine Learning (ML) menyediakan kemampuan mempelajari hubungan nonlinier antara kondisi pemrosesan dan tindakan pengelolaan sumber daya. Kajian Zhou, Tian, et al. (2024) menguraikan penggunaan pembelajaran penguatan untuk penjadwalan sumber daya, sedangkan Hou et al. (2024) merangkum peluang pengurangan konsumsi energi melalui pengambilan keputusan berbasis data. Feng dan Ding (2025) menekankan bahwa ramalan beban komputasi dapat mendukung pengelolaan sumber daya secara proaktif. Xiu et al. (2023) mengembangkan adaptasi penjadwalan berbasis meta-reinforcement learning, sementara Zhou, Yang, et al. (2024) pada lingkungan edge meninjau hubungan antara keseimbangan beban dan energi. Kendati demikian, pembelajaran berbasis data tidak menjamin bahwa setiap rekomendasi memenuhi aturan operasional yang dapat dijelaskan.

Keterbatasan tersebut menempatkan penalaran simbolik sebagai komponen yang dapat melengkapi sistem pembelajaran. Pendekatan neuro-simbolik menggabungkan kemampuan neural untuk mengenali pola dengan aturan logis yang transparan. Marra et al. (2024) menguraikan berbagai dimensi integrasi pembelajaran dan penalaran; Bhuyan et al. (2024) serta Nawaz et al. (2025) menekankan interpretabilitas dan keterlacakan keputusan. Lu et al. (2024) memperlihatkan pentingnya reliabilitas pendekatan neuro-simbolik pada lingkungan komputasi terkoneksi. Integrasi demikian relevan ketika tindakan pengelolaan CPU harus tetap sesuai dengan batas jumlah core dan kondisi sumber daya.

Penelitian neurosimbolik menunjukkan alternatif mekanisme integrasi. Cunnington et al. (2023) menggabungkan pembelajaran saraf dan induksi logika yang dapat ditafsirkan; Giunchiglia et al. (2024) mengintegrasikan persyaratan logis pada keluaran model; Derkinderen et al. (2024) meninjau semantik penalaran probabilistik, dan Gao et al. (2024) mengembangkan pembelajaran aturan yang terdiferensiasi. Di sisi lain, Acharya et al. (2024) memetakan kontribusi penalaran neuro-simbolik dalam reinforcement learning dan perencanaan; Wu et al. (2024) serta Pfanschilling et al. (2025) menggarisbawahi alternatif pemodelan logika untuk rekomendasi dan penalaran probabilistik. Ragam pendekatan ini memperlihatkan peluang untuk mendesain sistem yang memisahkan penilaian probabilistik dari pemeriksaan kelayakan keputusan.

Berdasarkan sintesis pustaka, penelitian penjadwalan berbasis ML umumnya menitikberatkan kualitas kebijakan atau efisiensi, sedangkan literatur neuro-simbolik lebih luas menekankan integrasi pengetahuan dan pembelajaran. Ruang pengembangan yang dituju artikel ini adalah arsitektur keputusan pengelolaan multicore yang memadukan prediksi neural, penalaran aturan kontekstual, dan pengendalian kelayakan tindakan secara eksplisit. Penempatan fokus tersebut tidak berarti belum pernah terdapat pendekatan hibrida sejenis; kontribusi penelitian dibatasi pada rancangan dan pengujian konfigurasi yang dinyatakan dalam artikel. Prinsip kehati-hatian ini sejalan dengan perhatian Kapoor dan Narayanan (2023) terhadap risiko evaluasi terlalu optimistis akibat kebocoran informasi.

Penelitian menggunakan 5.000 observasi kondisi multicore yang menurut keterangan peneliti berasal dari kombinasi pengukuran langsung dan simulasi serta telah melalui validasi pakar. Data memuat indikator arsitektur dan beban sistem, tiga skor penalaran simbolik, serta lima tindakan rujukan.



Tujuan penelitian ialah (1) merancang arsitektur Neuro-Symbolic Cognitive Architecture for Resource Management (NS-CARM); (2) menguji kemampuan komponen neural, simbolik, dan fusi terhadap rekomendasi tindakan; dan (3) menganalisis kompromi antara akurasi, keterwakilan kelas minoritas, dan konsistensi aturan tindakan. Kebaruan yang diusulkan bersifat integrasi arsitektural dan evaluatif, bukan klaim penciptaan algoritma pembelajaran baru.

METODE PENELITIAN

Penelitian menerapkan pendekatan kuantitatif eksperimental untuk memodelkan rekomendasi keputusan pada sistem multicore. Unit analisis berupa satu keadaan pengujian yang direpresentasikan oleh variabel beban kerja, karakteristik CPU, utilisasi memori, indikator performa, tiga skor simbolik, serta label rekomendasi tindakan. Alur penelitian meliputi pemetaan variabel, prapemrosesan, pembelajaran neural, induksi aturan simbolik, fusi keputusan, pemeriksaan kelayakan, dan evaluasi pada data uji terpisah sebagaimana Gambar 1.



Gambar 1. Arsitektur NS-CARM untuk rekomendasi pengelolaan sumber daya multicore

Sumber: Hasil rancangan dan pengolahan data peneliti (2026).

a. Dataset, variabel dan pembagian data

Dataset penelitian memuat 5.000 observasi dan 24 kolom asli, yang terdiri atas identitas pengujian, 22 prediktor, dan satu label rekomendasi. Menurut keterangan peneliti, seluruh data telah melalui pemeriksaan pakar. Lima kategori tindakan adalah *balanced_scheduling*, *boost_priority*, *scale_out_cores*, *memory_aware_placement*, dan *consolidate_cores*. Variabel identitas pengujian tidak digunakan sebagai prediktor, dan indikator hasil turunan yang dibuat pada tahap audit tidak diikutsertakan agar model hanya memakai variabel penelitian asli. Pemisahan terstratifikasi secara acak dengan seed 42 menghasilkan 3.500 data latih (70%), 750 validasi (15%), dan 750 uji (15%). Transformasi dan standardisasi dipelajari hanya dari data latih.

Tabel 1. Ringkasan Kelompok Variabel Dataset

Kelompok variabel	Contoh atribut	Peran
Arsitektur & status	core_count, active_cores, os_type	Kapasitas perangkat
Beban dan proses	workload_type, task_priority, run_queue_length	Konteks komputasi
Kinerja operasional	cpu_utilization_pct, memory_utilization_pct, observed_latency_ms	Kondisi observasi
Penalaran simbolik	urgency, memory pressure, thermal pressure	Masukan komponen simbolik
Keputusan	recommended_action (lima kelas)	Label rujukan

Sumber: Dataset penelitian (2026).

b. Arsitektur neural dan penalaran simbolik

Komponen neural menggunakan multilayer perceptron (MLP) dengan dua lapisan tersembunyi berukuran 64 dan 32 neuron. Masukannya adalah 17 variabel numerik non-simbolik dan dua variabel kategorikal setelah encoding. Pelatihan memakai early stopping dan jumlah iterasi maksimum 300. Sebagai pembanding digunakan Random Forest dengan 250 pohon dan minimal dua sampel per daun, serta baseline kelas mayoritas. Komponen simbolik diwujudkan sebagai pohon keputusan yang dilatih



hanya dari tiga skor simbolik (kedalaman maksimum enam; minimal 16 sampel per daun). Pohon ini merupakan aturan yang diinduksi dari data, bukan pengganti dokumentasi aturan pakar, sehingga setiap lintasan dapat ditelusuri melalui ambang kondisi.

Distribusi probabilitas model neural $pN(a|x)$ dan model simbolik $pS(a|x)$ digabung dengan bobot α yang dipilih pada data validasi melalui penelusuran nilai 0,0–1,0 pada interval 0,1 untuk memaksimalkan Macro-F1. Dalam eksperimen diperoleh $\alpha = 0,6$. Keluaran fusi dihitung dengan Persamaan (1):

$$pF(a|x) = \alpha pN(a|x) + (1 - \alpha) pS(a|x). \quad (1)$$

Lapisan kelayakan kemudian menonaktifkan rekomendasi `consolidate_cores` ketika hanya satu core aktif dan `scale_out_cores` ketika seluruh core sudah aktif. Tindakan akhir dipilih dari skor fusi terbesar yang lolos pemeriksaan; apabila tidak ada tindakan yang lolos, probabilitas asal dipertahankan sebagai fallback. Pemeriksaan ini merepresentasikan dua batas operasional terukur, bukan seluruh spektrum kebijakan scheduler. Arsitektur memiliki kanal umpan balik sebagai rancangan, tetapi eksperimen dataset saat ini mengevaluasi rekomendasi offline, bukan pembelajaran kebijakan online.

c. Protokol evaluasi dan studi ablasi

Perbandingan menggunakan label rujukan yang sama pada 750 observasi uji dan metrik accuracy, Macro-F1, balanced accuracy, recall per kelas, serta confusion matrix. Bobot fusi dipilih hanya dari 750 observasi validasi. Studi ablasi membandingkan MLP tanpa skor simbolik, pohon aturan simbolik saja, MLP dengan skor simbolik sebagai fitur, fusi MLP–simbolik, serta fusi yang ditambah pemeriksaan kelayakan. Pengujian dilakukan pada satu pembagian terstratifikasi; karena tidak tersedia pembagian kelompok perangkat atau skenario pada berkas ini, angka performa merupakan estimasi internal dan tidak ditafsirkan sebagai generalisasi lintas perangkat. Demikian pula, latency dan throughput pada berkas merupakan keadaan teramati sebelum keputusan, bukan pengukuran setelah rekomendasi dijalankan.

HASIL DAN PEMBAHASAN

1. Karakteristik dataset dan distribusi tindakan

Seluruh 5.000 observasi memiliki identitas unik dan nilai lengkap pada variabel asli. Dataset mencakup perangkat dengan 4, 8, 16, dan 32 core, lima jenis beban kerja, serta tiga jenis sistem operasi. Rata-rata utilisasi CPU tercatat 60,04% dan penggunaan memori 60,92%. Rerata latensi teramati sebesar 171,50 ms dan throughput 5.867,28 operasi per detik; ukuran tersebut mendeskripsikan kondisi dataset, bukan akibat penggunaan arsitektur NS-CARM. Distribusi label menunjukkan dominasi tindakan penjadwalan berimbang, sehingga akurasi agregat berisiko menutupi kegagalan mendeteksi tindakan yang jarang muncul.

Tabel 2. Distribusi Lima Kelas Rekomendasi Multicore

Tindakan rekomendasi	Jumlah	Persentase
balanced_scheduling	3566	71,32%
boost_priority	571	11,42%
scale_out_cores	432	8,64%
memory_aware_placement	329	6,58%
consolidate_cores	102	2,04%
Total	5000	100,00%

Sumber: Pengolahan dataset penelitian menggunakan Python (2026).

Sebanyak 3.566 observasi (71,32%) merekomendasikan `balanced_scheduling`, sedangkan `consolidate_cores` hanya 102 observasi (2,04%). Jumlah ini penting karena kinerja sangat baik pada kelas dominan masih dapat beriringan dengan recall rendah pada kelas minoritas. Oleh sebab itu,



Macro-F1 dan balanced accuracy diposisikan sebagai ukuran pembanding utama, didukung analisis kesalahan per kelas.

2. Kinerja model dasar dan arsitektur neuro-simbolik


Pengujian 750 observasi mempertahankan komposisi kelas melalui stratifikasi. Baseline mayoritas menghasilkan accuracy 71,33%, tetapi Macro-F1 hanya 16,65% karena tidak mengidentifikasi empat kelas lainnya. Random Forest mencapai accuracy 92,00% dan Macro-F1 87,29%, menjadi pembanding prediktif terbaik pada percobaan ini. MLP tanpa skor simbolik mencatat accuracy 87,60% dan Macro-F1 73,78%, sedangkan model aturan simbolik mencapai accuracy 73,87% dan Macro-F1 68,18%. Hasil tersebut memperlihatkan bahwa baik pembelajaran pola maupun penalaran aturan memiliki kekuatan dan kelemahan berbeda.

Tabel 3. Perbandingan Performa Model pada Data Uji Independen (n=750)

Model	Akurasi	Macro-F1	Balanced acc.
Kelas mayoritas	71,33%	16,65%	20,00%
Random Forest	92,00%	87,29%	86,50%
MLP tanpa skor simbolik	87,60%	73,78%	71,21%
Aturan simbolik terinduksi	73,87%	68,18%	90,00%
NS-CARM (fusi)	89,47%	78,92%	83,42%
NS-CARM + aturan kelayakan	90,27%	79,06%	82,35%

Sumber: Implementasi model dan evaluasi holdout menggunakan Python/Scikit-learn (2026).

NS-CARM menggabungkan probabilitas neural dan aturan terinduksi dengan bobot validasi $\alpha = 0,6$. Fusi menghasilkan accuracy 89,47%, Macro-F1 78,92%, dan balanced accuracy 83,42%. Penambahan pemeriksaan kelayakan menaikkan accuracy menjadi 90,27% dan Macro-F1 menjadi 79,06%, tetapi balanced accuracy menurun menjadi 82,35%. Secara substantif, hasil ini tidak mendukung klaim bahwa kombinasi neuro-simbolik otomatis melampaui Random Forest: selisih Macro-F1 terhadap Random Forest masih 8,23 poin persentase. Kontribusinya lebih tepat dibaca sebagai arsitektur yang menambahkan struktur pemeriksaan keputusan yang eksplisit.



Gambar 2. Perbandingan akurasi dan Macro-F1 model pada data uji

Sumber: Hasil rancangan dan pengolahan data peneliti menggunakan Python (2026).

3. Analisis kelas minoritas dan kesalahan klasifikasi

Pada data uji terdapat 535 observasi balanced_scheduling, 86 boost_priority, 64 scale_out_cores, 50 memory_aware_placement, dan 15 consolidate_cores. Random Forest mencatat recall 94,58% pada balanced_scheduling dan 96,88% pada scale_out_cores, namun recall memory_aware_placement hanya 66,00%. Model aturan simbolik menghasilkan recall 100% untuk boost_priority dan




memory_aware_placement, tetapi recall kelas dominan menurun menjadi 64,49%, yang mencerminkan kecondongan model berbobot kelas dalam meningkatkan sensitivitas kelompok tertentu.

Tabel 4. Recall dan F1 Per Kelas pada Pengujian 750 Observasi

Kelas	Recall RF	Recall NS-CARM	F1 NS-CARM
Balanced scheduling	94.6%	91.2%	93.2%
Boost priority	88.4%	98.8%	91.4%
Consolidate cores	86.7%	53.3%	45.7%
Memory-aware placement	66.0%	84.0%	79.2%
Scale out cores	96.9%	84.4%	85.7%

Sumber: Confusion matrix hasil evaluasi model menggunakan Python (2026).

Model NS-CARM dengan kelayakan memperoleh recall 98,84% untuk boost_priority dan 84,00% untuk memory_aware_placement, tetapi hanya 53,33% untuk consolidate_cores. Dua kelas terakhir menunjukkan bahwa sebagian tindakan dapat dikenali baik oleh aturan, sementara tindakan yang membutuhkan kompromi antara pengurangan core dan beban sistem tetap sulit dipelajari. Confusion matrix pada Gambar 3 memperlihatkan 47 pengamatan balanced_scheduling dialihkan ke kelas lain; sebagian kesalahan juga terjadi antara balanced_scheduling dan memory_aware_placement. Interpretasi ini menegaskan pentingnya memeriksa kesalahan spesifik tindakan, bukan hanya nilai rata-rata.



Gambar 3. Confusion matrix NS-CARM dengan pemeriksaan kelayakan (aktual × prediksi)

Sumber: Hasil rancangan dan pengolahan data peneliti menggunakan Python (2026).

4. Analisis ablation dan kontribusi penalaran simbolik

Studi ablasi memisahkan pengaruh informasi simbolik sebagai fitur, sebagai model aturan, dan sebagai lapisan pemilihan tindakan. Menambahkan tiga skor simbolik langsung ke MLP menghasilkan Macro-F1 77,08%, lebih tinggi 3,30 poin dibandingkan MLP tanpa skor simbolik (73,78%). Integrasi probabilitas MLP dan pohon aturan menaikkan Macro-F1 menjadi 78,92%; penambahan aturan kelayakan meningkatkan lagi menjadi 79,06%. Dengan demikian, pengayaan representasi dan integrasi aturan berkontribusi pada peningkatan performa relatif terhadap MLP dasar, tetapi besarnya peningkatan bersifat moderat dan belum mengungguli ensemble pohon sebagai baseline kuat.

Tabel 5. Ablation Study Modul Penalaran Neuro-Simbolik

Konfigurasi ablasi	Accuracy	Macro-F1
A0: MLP (tanpa skor simbolik)	87,60%	73,78%
A1: MLP + tiga skor simbolik	88,53%	77,08%
A2: MLP + pohon aturan (fusi)	89,47%	78,92%
A3: Fusi + pemeriksaan kelayakan	90,27%	79,06%

Sumber: Hasil eksperimen ablasi data uji menggunakan Python (2026).



Hasil ini dapat dikaitkan dengan pemisahan peran komponen neuro-simbolik yang dibahas Cunningham et al. (2023) dan Giunchiglia et al. (2024): prediksi probabilistik mempelajari pola, sementara struktur simbolik menambahkan jejak keputusan dan kemungkinan pembatasan. DeLong et al. (2025) dan Lee et al. (2025) menekankan bahwa konsep atau aturan dapat meningkatkan keterpahaman keluaran model, tetapi manfaat tersebut perlu dibedakan dari kenaikan akurasi. Pada eksperimen ini, interpretabilitas operasional didukung oleh lintasan aturan pohon yang dapat ditelusuri dan dua pengaman kelayakan yang didefinisikan eksplisit.

5. Konsistensi tindakan dan dampak pemeriksaan kelayakan

Pemeriksaan kelayakan pada tahap fusi bertujuan menolak dua tindakan yang tidak konsisten dengan kapasitas core: mengonsolidasikan core ketika hanya satu core yang aktif, atau menambah core ketika semua core telah diaktifkan. Perubahan skor klasifikasi setelah penerapan pemeriksaan tersebut menunjukkan bahwa lapisan simbolik tidak selalu netral terhadap kesesuaian dengan label rujukan. Penurunan balanced accuracy dari 83,42% menjadi 82,35% memperlihatkan kompromi: beberapa keputusan menjadi lebih konsisten menurut batas operasional, namun kesalahan pada kelas tertentu dapat meningkat. Karena aturan dalam penelitian ini hanya mencakup dua pembatas, istilah kelayakan harus dipahami secara terbatas dan bukan sebagai jaminan kebenaran seluruh kebijakan penjadwalan.

6. Implikasi pada pengelolaan sumber daya multicore

Rekomendasi tindakan mencerminkan pengelolaan operasional yang berbeda: `balanced_scheduling` menjaga distribusi beban, `boost_priority` menanggapi urgensi, `scale_out_cores` merespons kebutuhan kapasitas, `memory_aware_placement` mempertimbangkan tekanan memori, dan `consolidate_cores` berpotensi mengurangi penggunaan core yang tidak diperlukan. Namun, nilai throughput, daya, dan latensi dalam dataset merupakan variabel kondisi yang dicatat pada saat pengamatan. Tanpa pengukuran terpasang setelah tindakan yang dipilih diterapkan, penelitian ini belum menghitung rasio percepatan (speedup), penurunan konsumsi energi, maupun perubahan throughput akibat NS-CARM. Hasil yang dapat dipertanggungjawabkan pada tahap ini adalah mutu rekomendasi tindakan berdasarkan label yang telah ditetapkan.

Konteks hasil ini sejalan dengan penelitian Friebe et al. (2025) dan Vesilo (2024) yang menunjukkan pentingnya mendefinisikan konsekuensi operasional alokasi core, serta Zhou, Tian, et al. (2024) dan Hou et al. (2024) mengenai trade-off biaya keputusan. Dalam pengembangan selanjutnya, mekanisme umpan balik NS-CARM perlu dijalankan pada perangkat multicore sehingga rekomendasi, tindakan yang dieksekusi, dan hasil kinerja pascatindakan dapat dihubungkan secara kausal. Penelitian masa depan juga perlu memisahkan kelompok perangkat atau skenario simulasi pada evaluasi untuk menilai robustnes lintas lingkungan sebagaimana diingatkan Kapoor dan Narayanan (2023).

7. Pembahasan kontribusi dan keterbatasan penelitian

Kontribusi utama penelitian terletak pada rancangan alur NS-CARM yang menghubungkan pembelajaran neural, aturan yang diturunkan dari indikator pengetahuan, fusi probabilistik, serta pemeriksaan tindakan. Melalui eksperimen dan ablasi, setiap modul memiliki hasil yang dapat diuji secara terpisah. Hasil tidak memperlihatkan dominasi prediktif NS-CARM atas Random Forest, namun mengungkap kompromi yang penting bagi arsitektur keputusan: tambahan struktur penalaran dapat membantu beberapa kelas minoritas dan memperjelas batas tindakan, dengan biaya kesalahan pada kelompok lainnya. Prinsip integrasi dan ketegangan antara interpretabilitas dan kinerja telah dibahas oleh Marra et al. (2024), Lu et al. (2024), dan Nawaz et al. (2025); eksperimen ini menempatkannya secara khusus pada pilihan tindakan multicore.

Keterbatasan utama meliputi penggunaan satu pemisahan latih-validasi-uji, ketiadaan identitas kelompok perangkat dalam berkas analisis, belum adanya pengujian implementasi pascatindakan, serta



kemungkinan kedekatan struktural antara skor simbolik dan label rujukan. Status validasi pakar atas dataset berasal dari keterangan peneliti, sedangkan protokol kesepakatan antarpakar tidak dihitung ulang dalam analisis ini. Karena itu, performa yang dilaporkan merupakan hasil evaluasi offline pada label rekomendasi, bukan bukti efisiensi eksekusi CPU aktual. Pelaporan batasan ini dimaksudkan untuk menjaga cakupan kesimpulan sesuai bukti dan membuka jalur pengembangan eksperimen yang lebih ketat.

SIMPULAN DAN SARAN

Penelitian ini mengembangkan arsitektur komputasi kognitif NS-CARM berbasis penalaran neuro-simbolik untuk rekomendasi pengelolaan sumber daya multicore melalui integrasi MLP, pohon aturan terinduksi, fusi probabilistik, dan pemeriksaan kelayakan tindakan. Evaluasi pada 5.000 observasi yang dinyatakan telah divalidasi pakar, dengan 750 data uji independen, menghasilkan accuracy 90,27% dan Macro-F1 79,06% pada arsitektur dengan pemeriksaan kelayakan; hasil ini lebih baik daripada MLP tanpa skor simbolik (Macro-F1 73,78%), tetapi masih berada di bawah Random Forest (87,29%). Integrasi simbolik memberi jalur penalaran yang lebih mudah ditelusuri serta membantu pengenalan beberapa kelas minoritas, walaupun tidak menghilangkan kompromi kesalahan antartindakan. Dengan demikian, kontribusi penelitian terutama berupa arsitektur keputusan hibrida yang dapat dievaluasi secara modular, bukan pembuktian peningkatan throughput atau penghematan energi pada perangkat. Penelitian lanjutan disarankan menggunakan pengujian lintas perangkat yang terkelompok dan eksperimen penerapan tindakan secara langsung untuk menilai pengaruh aktual terhadap latensi, throughput, daya, dan overhead penjadwalan.

DAFTAR PUSTAKA

- Acharya, K., Raza, W., Dourado, C., Velasquez, A., & Song, H. H. (2024). Neurosymbolic reinforcement learning and planning: A survey. *IEEE Transactions on Artificial Intelligence*, 5(5), 1939–1953. <https://doi.org/10.1109/TAI.2023.3311428>
- Bhuyan, B. P., Ramdane-Cherif, A., Tomar, R. K., & Singh, T. P. (2024). Neuro-symbolic artificial intelligence: A survey. *Neural Computing and Applications*, 36, 12809–12844. <https://doi.org/10.1007/s00521-024-09960-z>
- Cunnington, D., Law, M., Lobo, J., & Russo, A. (2023). FFNSL: Feed-Forward Neural-Symbolic Learner. *Machine Learning*, 112, 515–569. <https://doi.org/10.1007/s10994-022-06278-6>
- DeLong, L. N., Mir, R. F., & Fleuriot, J. D. (2025). Neurosymbolic AI for reasoning over knowledge graphs: A survey. *IEEE Transactions on Neural Networks and Learning Systems*, 36(5), 7822–7842. <https://doi.org/10.1109/TNNLS.2024.3420218>
- Derkinderen, V., Manhaeve, R., Zuidberg Dos Martires, P., & De Raedt, L. (2024). Semirings for probabilistic and neuro-symbolic logic programming. *International Journal of Approximate Reasoning*, 171, 109130. <https://doi.org/10.1016/j.ijar.2024.109130>
- Devi, N., Dalal, S., Solanki, K., Dalal, S., Lilhore, U. K., Simaiya, S., & Nuristani, N. (2024). A systematic literature review for load balancing and task scheduling techniques in cloud computing. *Artificial Intelligence Review*, 57, Article 276. <https://doi.org/10.1007/s10462-024-10925-w>
- Feng, B., & Ding, Z. (2025). Application-oriented cloud workload prediction: A survey and new perspectives. *Tsinghua Science and Technology*, 30(1), 34–54. <https://doi.org/10.26599/TST.2024.9010024>



- Friebe, A., Marchetti-Spaccamela, A., Cucinotta, T., Papadopoulos, A. V., Nolte, T., & Baruah, S. (2025). Resource management for stochastic parallel synchronous tasks: Bandits to the rescue. *Real-Time Systems*, 61, 359–402. <https://doi.org/10.1007/s11241-025-09454-8>
- Gao, K., Inoue, K., Cao, Y., & Wang, H. (2024). A differentiable first-order rule learner for inductive logic programming. *Artificial Intelligence*, 331, 104108. <https://doi.org/10.1016/j.artint.2024.104108>
- Giunchiglia, E., Tatomir, A., Stoian, M. C., & Lukasiewicz, T. (2024). CCN+: A neuro-symbolic framework for deep learning with requirements. *International Journal of Approximate Reasoning*, 171, 109124. <https://doi.org/10.1016/j.ijar.2024.109124>
- Hou, H., Agos Jawaddi, S. N., & Ismail, A. (2024). Energy efficient task scheduling based on deep reinforcement learning in cloud environment: A specialized review. *Future Generation Computer Systems*, 151, 214–231. <https://doi.org/10.1016/j.future.2023.10.002>
- Kapoor, S., & Narayanan, A. (2023). Leakage and the reproducibility crisis in machine-learning-based science. *Patterns*, 4(9), 100804. <https://doi.org/10.1016/j.patter.2023.100804>
- Lee, J. H., Lanza, S., & Wermter, S. (2025). From neural activations to concepts: A survey on explaining concepts in neural networks. *Neurosymbolic Artificial Intelligence*, 1, 1–10. <https://doi.org/10.3233/NAI-240743>
- Lu, Z., Afridi, I., Kang, H. J., Ruchkin, I., & Zheng, X. (2024). Surveying neuro-symbolic approaches for reliable artificial intelligence of things. *Journal of Reliable Intelligent Environments*, 10(3), 257–279. <https://doi.org/10.1007/s40860-024-00231-1>
- Marra, G., Dumančić, S., Manhaeve, R., & De Raedt, L. (2024). From statistical relational to neurosymbolic artificial intelligence: A survey. *Artificial Intelligence*, 328, 104062. <https://doi.org/10.1016/j.artint.2023.104062>
- Meunier, R., Carle, T., & Monteil, T. (2024). Multi-core interference over-estimation reduction by static scheduling of multi-phase tasks. *Real-Time Systems*, 60, 665–703. <https://doi.org/10.1007/s11241-024-09427-3>
- Nawaz, U., Anees-ur-Rahaman, M., & Saeed, Z. (2025). A review of neuro-symbolic AI integrating reasoning and learning for advanced cognitive systems. *Intelligent Systems with Applications*, 26, 200541. <https://doi.org/10.1016/j.iswa.2025.200541>
- Pfanschilling, V., Shindo, H., Dhami, D. S., & Kersting, K. (2025). NeST: The neuro-symbolic transpiler. *International Journal of Approximate Reasoning*, 179, 109369. <https://doi.org/10.1016/j.ijar.2025.109369>
- Rathee, A., & Dalal, S. (2025). A systematic literature review of machine learning-based resource allocation techniques in cloud computing. *Computing*, 107. <https://doi.org/10.1007/s00607-025-01526-8>
- Sanjalawe, Y., Al-E'mari, S., Fraihat, S., & Makhadmeh, S. (2025). AI-driven job scheduling in cloud computing: A comprehensive review. *Artificial Intelligence Review*, 58, Article 197. <https://doi.org/10.1007/s10462-025-11208-8>
- Vesilo, R. (2024). Core allocation to minimize total flow time in a multicore system in the presence of a processing time constraint. *Queueing Systems*, 108, 475–577. <https://doi.org/10.1007/s11134-024-09923-0>



-
- Wu, M., Chen, B., Zhu, S., Zheng, B., Peng, W., & Zhang, M. (2024). Neuro-symbolic recommendation model based on logic query. *Knowledge-Based Systems*, 284, 111311. <https://doi.org/10.1016/j.knosys.2023.111311>
- Xiu, X., Li, J., Long, Y., & Wu, W. (2023). MRLCC: An adaptive cloud task scheduling method based on meta reinforcement learning. *Journal of Cloud Computing*, 12, Article 75. <https://doi.org/10.1186/s13677-023-00440-8>
- Zhou, G., Tian, W., Buyya, R., & Song, L. (2024). Deep reinforcement learning-based methods for resource scheduling in cloud computing: A review and future directions. *Artificial Intelligence Review*, 57, Article 124. <https://doi.org/10.1007/s10462-024-10756-9>
- Zhou, X., Yang, J., Li, Y., Li, S., & Su, Z. (2024). Deep reinforcement learning-based resource scheduling for energy optimization and load balancing in SDN-driven edge computing. *Computer Communications*, 226–227, 107925. <https://doi.org/10.1016/j.comcom.2024.107925>