




Semarak International Journal of Fundamental and Applied Mathematics

Journal homepage:
<https://semarakilmu.my/index.php/sijfam/index>
ISSN: 3030-5527



Rangkaian Neural Hopfield Diskret Berpandukan Simbolik: Pendekatan berasaskan 3-Satisfiability

Discrete Symbolic Guided Hopfield Neural Networks: A 3-Satisfiability Based Approach

Nur 'Afifah Rusdi¹, Nurshazneem Roslan¹, Nur Izzah Aqilah Amram², Mohd Shareduwan Mohd Kasihmuddin^{2,*}, Nur Ezlin Zamri³, Yunjie Chang⁴, Yueling Guo⁵

¹ Institute of Engineering Mathematics, Universiti Malaysia Perlis, 02600 Arau, Perlis, Malaysia

² School of Mathematical Sciences, Universiti Sains Malaysia, 11800 USM, Penang, Malaysia

³ Department of Mathematics and Statistics, Faculty of Science, Universiti Putra Malaysia, 43400 UPM, Serdang, Selangor, Malaysia

⁴ School of Computer Science and Engineering, Hunan Institute of Technology, 421002 Hengyang, China

⁵ School of Science, Hunan Institute of Technology, 421002 Hengyang, China

ARTICLE INFO

Article history:

Received 15 March 2025

Received in revised form 19 April 2025

Accepted 18 May 2025

Available online 30 June 2025

ABSTRAK

Rangkaian Neural Buatan ialah pendekatan penting dalam kecerdasan buatan kerana keupayaannya mengenal pasti corak tersembunyi dalam data. Rangkaian Neural Hopfield Diskret merupakan varian Rangkaian Neural Buatan yang menggunakan struktur maklum balas penuh serta memori capaian kandungan untuk menyimpan dan mengingat corak. Namun, rangkaian ini sering dianggap sebagai model 'kotak hitam' kerana ketiadaan kawalan simbolik yang jelas terhadap dinamik neuron. Kajian ini mencadangkan pelaksanaan logik 3-Satisfiability sebagai mekanisme kawalan simbolik bagi mempertingkatkan interpretasi dan kecekapan Rangkaian Neural Hopfield Diskret. Logik ini menghadkan setiap klausa kepada tiga literal, di mana setiap literal mewakili satu neuron dalam rangkaian. Dengan penggabungan 3-Satisfiability ke dalam struktur Rangkaian Neural Hopfield Diskret, neuron dapat dimodelkan dengan lebih teratur dan meningkatkan keupayaan sistem dalam melaksanakan pengoptimuman secara sistematik. Prestasi pendekatan ini dinilai melalui fasa pembelajaran dan perolehan untuk memastikan pencapaian neuron akhir yang optimum. Hasil kajian ini diharapkan dapat memperkukuh ketelusan model Rangkaian Neural Buatan dan membentuk asas kepada pembangunan sistem neural yang lebih utuh dan stabil.

Artificial Neural Networks are a significant approach in artificial intelligence due to their ability to identify hidden patterns in data. The Discrete Hopfield Neural Network is a variant of Artificial Neural Networks that utilize a fully connected feedback structure and content-addressable memory to store and recall patterns. However, these networks are often regarded as 'black box' model because of the lack of explicit symbolic control over neuron dynamics. This study proposes the implementation of 3-

* Corresponding author.

E-mail address: shareduwan@usm.my

<https://doi.org/10.37934/sijfam.6.1.2840>

Kata Kunci:

3-Satisfiability; Rangkaian Neural
Hopfield diskret; kawalan simbolik

Keywords:

3 Satisfiability; Discrete Hopfield Neural
Networks; symbolic control

Satisfiability logic as a symbolic control mechanism to enhance the interpretability and efficiency of Discrete Hopfield Neural Networks. This logic restricts each clause to three literals, where each literal represents a neuron in the network. By implementing 3-Satisfiability into the structure of the Discrete Hopfield Neural Network, neurons can be modeled more systematically and the network is able to perform systematic optimization more effectively. The performance of this approach is evaluated through learning and retrieval phases to ensure optimal final neuron achievement. The results of this study are expected to strengthen the transparency of Artificial Neural Network models and lay the foundation for the development of more robust and stable neural systems.

1. Pengenalan

Rangkaian Neural Buatan (RNB) merupakan salah satu pendekatan utama dalam bidang kecerdasan buatan yang diilhamkan daripada cara otak manusia memproses maklumat. RNB terdiri daripada nod-nod atau "neuron" buatan yang saling berhubung, membentuk satu sistem rangkaian yang mampu mengenal pasti serta mempelajari corak tersembunyi dalam data. Berdasarkan keupayaan ini, para penyelidik telah membangunkan pelbagai model pintar berasaskan RNB yang bukan sahaja mampu belajar, tetapi juga menganalisis secara logik dan menyokong proses membuat keputusan. Sebagai model matematik yang fleksibel, RNB telah mencetuskan revolusi dalam pelbagai bidang seperti analisis data perubatan [1], pemrosesan imej [2] dan pembuatan berteknologi tinggi termasuk aplikasi dalam reka bentuk dan pembangunan bahan komposit untuk pesawat, dron dan kapal angkasa [3]. Selain struktur asas RNB, terdapat pelbagai varian RNB yang dibangunkan untuk menyelesaikan masalah khusus dengan lebih berkesan. Salah satu varian tersebut ialah Rangkaian Neural Hopfield Diskret (RNHD), iaitu sejenis rangkaian neural berulang yang terdiri daripada saling berhubung. Setiap output neuron dihantar semula ke semua input neuron lain, menghasilkan struktur maklum balas penuh. Hubungan ini digambarkan melalui berat sinaptik yang mencerminkan keupayaan RNHD untuk belajar dan menyimpan maklumat. Selain itu, RNHD menggunakan mekanisme Memori Boleh Capaian Kandungan (MBCK) untuk menyimpan sejumlah corak secara rawak dan mengambil semula corak tersebut apabila diperlukan. Ini adalah ciri penting dalam proses pengulangan yang bertujuan mendapatkan semula corak yang telah disimpan. Sebagai contoh, dalam kajian Karim *et al.*, [4], berat sinaptik disimpan dalam bentuk matriks untuk digunakan semula dalam fasa perolehan dalam menghasilkan neuron akhir. Dengan menggunakan persamaan medan setempat untuk mengemas kini neuron secara tak segerak, RNHD berpotensi besar dalam menyelesaikan masalah pengoptimuman. Selain itu, struktur ringkasnya yang menyerupai rangkaian neural maklum balas satu lapisan tanpa lapisan tersembunyi turut menjadikan RNHD menarik untuk pelbagai aplikasi [5].

Meskipun keupayaan RNHD dalam menangani masalah pengoptimuman diiktiraf, timbul persoalan terhadap kebolehlaksanaannya dalam situasi sebenar. Hal ini disebabkan oleh ketiadaan arahan formal yang mengawal dinamik neuron dalam rangkaian, menjadikan struktur RNHD sukar ditafsir. Walaupun RNHD dilihat cekap dalam mencapai neuron akhir yang optimum, kajian-kajian terdahulu lebih menumpukan kepada hasil akhir tanpa memberi perhatian terhadap cara struktur dalaman dibentuk. Ini menyebabkan RNHD sering berfungsi sebagai model kotak hitam, iaitu sistem yang mekanisme dalamnya tidak difahami dengan jelas. Ini boleh menimbulkan ketidakpastian dalam kalangan penyelidik sama ada aspek yang dioptimumkan benar-benar relevan, atau sebaliknya. Oleh itu, penambahbaikan terhadap struktur dan kawalan RNHD bukan sahaja boleh meningkatkan keupayaannya dalam menyimpan dan mengeluarkan semula corak, malah turut membuka laluan kepada pembangunan model RNB yang lebih telus dan boleh dipercayai. Bagi

mengatasi kelemahan ini, satu pendekatan diperlukan bagi memberi arahan simbolik yang jelas untuk mengawal struktur dan operasi RNHD.

Untuk menangani isu ini, beberapa model telah dibangunkan bagi mewakili neuron dalam RNHD. Romli *et al.*, [20] telah mencadangkan logik 2-Satisfiability (2SAT) dalam RNHD dengan mewakili dua neuron bagi setiap klausa. Keadaan literal dalam 2SAT dirumuskan berdasarkan ciri berlawanan logik tersebut. Logik 2SAT yang dicadangkan kemudiannya dilaksanakan dalam RNHD dengan membandingkan fungsi kos dan fungsi tenaga. Berdasarkan hasil kajian, neuron mampu menghasilkan keadaan neuron yang lebih pelbagai. Dalam perkembangan lain, Chen *et al.*, [19] telah mencadangkan 2SAT Kebarangkalian dalam RNHD dengan mentakrifkan kebarangkalian kepada setiap neuron. Dalam konteks ini, logik diperhatikan dari perspektif set, bukannya logik individu. Oleh sebab kelebihan ini, keadaan akhir neuron boleh dipelbagaikan. Walaupun kedua-dua kajian ini berjaya mewakili neuron dalam RNHD, ruang penyelesaian bagi klausa yang mengandungi dua literal adalah sangat terhad. Oleh itu, terdapat keperluan untuk meningkatkan kapasiti neuron bagi setiap klausa.

Kajian ini mencadangkan penggunaan konsep SAT dengan tertib tinggi sebagai mekanisme kawalan simbolik dalam RNHD. Dalam konteks ini, SAT bertindak sebagai peraturan simbolik yang mengatur dinamik neuron, sekali gus memperkukuh interpretasi serta keupayaan RNHD untuk menyelesaikan masalah pengoptimuman secara lebih tersusun dan boleh dijelaskan. Setakat pengetahuan kami, kajian ini merupakan yang pertama memperkenalkan pelaksanaan SAT dalam RNHD. Dengan penggabungan ini, diharap dapat membuka laluan kepada pembangunan model RNB yang lebih berstruktur dan efisien. Justeru, objektif utama kertas kerja ini adalah seperti berikut:

- i) Memformulasikan satu peraturan logik sistematik tertib tinggi, iaitu 3-Satisfiability. Logik yang dicadangkan ini menghadkan jumlah literal kepada tiga dalam setiap klausa, di mana setiap literal dalam 3-Satisfiability mewakili satu neuron dalam rangkaian.
- ii) Mencadangkan pelaksanaan 3-Satisfiability ke dalam Rangkaian Neural Hopfield Diskret sebagai peraturan simbolik. Dengan menggabungkan peraturan logik yang dicadangkan, setiap neuron dalam RNHD dapat dimodelkan secara lebih teratur dan meningkatkan kecekapan rangkaian dalam melaksanakan logik sistematik tertib tinggi.
- iii) Menilai prestasi 3-Satisfiability dalam RNHD dari segi fasa pembelajaran dan fasa perolehan dengan tujuan mencapai neuron akhir yang optimum.

Bagi memenuhi kesemua objektif yang telah digariskan, perbincangan dimulakan dengan metodologi dalam Seksyen 2 yang merangkumi formulasi 3-Satisfiability serta konsep asas pelaksanaannya dalam RNHD. Seterusnya, Seksyen 3 menghuraikan penyediaan eksperimen yang digunakan dalam kajian ini. Dapatan kajian dan perbincangan diperincikan dalam Seksyen 4. Akhir sekali, Seksyen 5 membentangkan kesimpulan kajian serta cadangan untuk kajian masa hadapan.

2. Metodologi Kajian

Bahagian ini membincangkan metodologi yang dicadangkan untuk pelaksanaan 3-Satisfiability (3SAT) dalam RNHD, merangkumi formulasi peraturan logik bagi 3SAT serta konsep asas pelaksanaan 3SAT dalam RNHD.

2.1 Formula Peraturan Logik 3 Satisfiability (3SAT)

Menurut Mansor *et al.*, [6], 3SAT dikenali sebagai peraturan logik yang bersifat sistematik di mana setiap klausa mengandungi tiga literal yang dinyatakan dalam Bentuk Normal Konjunktif (BNK). Semua klausa dihubungkan dengan operator logik DAN ($\wedge$) manakala literal dalam setiap klausa dihubungkan dengan operator logik ATAU ($\vee$). Komponen asas bagi formulasi peraturan logik ini diperincikan seperti berikut:

- i) Satu set yang terdiri daripada n literal, $q_1, q_2, q_3, \dots, q_n$ di mana setiap literal mewakili sama ada literal positif (q_i) atau literal negatif ($\neg q_i$) yang membawa maksud nilai BENAR atau PALSU, dengan $q_i \in \{1, -1\}$.
- ii) Terdiri daripada konjungsi sebanyak m klausa tetap, $Q_m^{(k)}$ yang dihubungkan dengan operator logik DAN ($\wedge$) membentuk $P_{3SAT} = Q_1^{(k)} \wedge Q_2^{(k)} \wedge \dots \wedge Q_m^{(k)}$, di mana k merujuk kepada peringkat klausa tersebut.
- iii) Setiap klausa $Q_m^{(k)}$ merupakan satu disjungsi literal di mana semua literal dihubungkan dengan operator logik ATAU ($\vee$).

Dengan merujuk kepada komponen di atas, konsep asas peraturan logik bagi 3SAT (P_{3SAT}) ditunjukkan dalam Persamaan (1) – (2). Setiap klausa dihubungkan dengan operator logik DAN ($\wedge$) dan mengandungi tepat tiga literal di mana nilai $k=3$.

$$P_{3SAT} = \bigwedge_{i=1}^m Q_i^{(k=3)}, \quad (1)$$

$$P_{3SAT} = Q_1^{(k=3)} \wedge Q_2^{(k=3)} \wedge Q_3^{(k=3)} \wedge \dots \wedge Q_m^{(k=3)}. \quad (2)$$

Sebagai contoh, bilangan klausa yang ditetapkan adalah $m=3$. Oleh yang demikian, contoh struktur peraturan logik bagi P_{3SAT} adalah seperti yang ditunjukkan dalam Persamaan (3), di mana setiap literal dalam P_{3SAT} adalah unik dan mewakili sama ada literal positif atau literal negatif. Tiada syarat khusus ditetapkan bagi pembahagian antara literal positif atau literal negatif dalam P_{3SAT} .

$$P_{3SAT} = (q_1 \vee \neg q_2 \vee \neg q_3) \wedge (q_4 \vee q_5 \vee \neg q_6) \wedge (q_7 \vee q_8 \vee q_9). \quad (3)$$

Berdasarkan Persamaan (3), setiap literal membawa nilai bipolar $q_i \in \{1, -1\}$ mewakili nilai BENAR atau PALSU. Sekiranya struktur peraturan logik bagi P_{3SAT} memberikan nilai $P_{3SAT} = 1$, ini menunjukkan bahawa setiap klausa dalam P_{3SAT} adalah BENAR. Sebaliknya jika $P_{3SAT} = -1$, ini menunjukkan terdapat klausa PALSU dalam P_{3SAT} . Dalam kajian ini, peraturan logik bagi P_{3SAT} akan bertindak sebagai peraturan simbolik untuk mewakili neuron-neuron dalam RNHD. Bahagian seterusnya akan menerangkan proses pelaksanaan P_{3SAT} yang terlibat dalam RNHD.

2.2 3 Satisfiability dalam RNHD

Bahagian ini membincangkan konsep asas pelaksanaan P_{3SAT} dalam RNHD. Berdasarkan konsep yang diperkenalkan oleh Abdullah [7], peraturan logik P_{3SAT} dimasukkan ke dalam RNHD dengan menetapkan setiap literal kepada nilai bipolar 1 atau -1 . Proses pelaksanaan dalam RNHD terdiri daripada dua fasa utama, iaitu fasa pembelajaran dan fasa perolehan. Dalam fasa pembelajaran, objektif utamanya adalah untuk meminimumkan ketidakselarasan dalam peraturan logik yang seterusnya meminimumkan fungsi kos. Dengan menggunakan keadah Wan Abdullah (Kaedah WA) [7], formulasi fungsi kos bagi P_{3SAT} , $(E_{P_{3SAT}})$ adalah seperti yang ditunjukkan dalam Persamaan (4):

$$E_{P_{3SAT}} = \sum_{i=1}^n \prod_{j=1}^3 Z_{ij}, \quad (4)$$

di mana n merujuk kepada jumlah klausa dalam P_{3SAT} . Ketidakselarasan bagi setiap klausa dalam P_{3SAT} diwakili oleh Z_{ij} seperti yang ditunjukkan dalam Persamaan (5):

$$Z_{ij} = \begin{cases} \frac{1}{2}(1 - S_q), & \text{jika } \neg q \\ \frac{1}{2}(1 + S_q), & \text{jika } q \end{cases}. \quad (5)$$

Berdasarkan Persamaan (5), q mewakili literal di dalam P_{3SAT} di mana $q \in \{q_i, q_j, q_k\}$. Menurut Azizan *et al.*, [8], ketidakselarasan logik adalah berkadar terus dengan fungsi kos peraturan logik. Dalam konteks ini, semakin tinggi ketidakselarasan dalam peraturan logik P_{3SAT} , semakin tinggi nilai $E_{P_{3SAT}}$. Oleh yang demikian, sekiranya fungsi kos adalah sifar ($E_{P_{3SAT}} = 0$), ini menunjukkan bahawa ketidakselarasan logik dalam P_{3SAT} telah diminimumkan dan semua klausa dalam P_{3SAT} telah dipenuhi. Bagi meminimumkan ketidakselarasan logik dalam P_{3SAT} , kaedah Carian Menyeluruh (CM) seperti Abdeen *et al.*, [9] dan Manoharam *et al.*, [10] akan digunakan untuk mendapatkan interpretasi penuh bagi P_{3SAT} .

Seterusnya, dengan menggunakan Kaedah WA, nilai berat sinaptik $W_i^{(1)}$, $W_{ij}^{(2)}$ and $W_{ijk}^{(3)}$ dapat diperoleh dengan membandingkan secara langsung $E_{P_{3SAT}}$ dengan fungsi tenaga Lyapunov ($H_{P_{3SAT}}$) bagi RNHD. Persamaan (6) menunjukkan fungsi tenaga Lyapunov bagi RNHD:

$$H_{P_{3SAT}} = -\frac{1}{3} \sum_{i=1, j=1, k=1, \substack{i \neq j, j \neq i, k \neq i, \\ i \neq k, j \neq k, k \neq j}}^N \sum_{j=1}^N \sum_{k=1}^N W_{ijk}^{(3)} S_i S_j S_k - \frac{1}{2} \sum_{i=1, j=1, \substack{i \neq j, j \neq i}}^N \sum_{j=1}^N W_{ij}^{(2)} S_i S_j - \sum_{i=1}^N W_i^{(1)} S_i. \quad (6)$$

Berdasarkan Persamaan (6), N merujuk kepada bilangan neuron dalam rangkaian, manakala S_i , S_j dan S_k mewakili keadaan neuron bagi unit i , j dan k yang membawa nilai bipolar 1 atau -1 . Nilai berat sinaptik disimpan dalam MBCK bagi membolehkan RNHD menggunakan semula nilai

tersebut dalam pengiraan medan setempat. Dalam konteks ini, sambungan neuron optimum merujuk kepada nilai berat sinaptik.

Dalam fasa perolehan, objektif utama adalah untuk menghasilkan keadaan neuron akhir yang optimum. Bagi mencapai matlamat ini, dengan menggunakan Persamaan (7), pengiraan medan setempat (h_i) bagi RNHD dilakukan dengan menggunakan nilai berat sinaptik yang disimpan dalam MBCK:

$$h_i = \sum_{j=1, j \neq i, j \neq k}^N w_{ijk}^{(3)} S_j S_k + \sum_{j=1, j \neq i}^N w_{ij}^{(2)} S_j + w_i^{(1)}. \quad (7)$$

Keadaan neuron akhir (S_i^f) diperoleh dengan menggunakan fungsi pengaktifan yang berfungsi menukarkan nilai h_i kepada nilai bipolar 1 atau -1 , seperti yang ditunjukkan dalam Persamaan (8):

$$S_i^f = \begin{cases} 1, & \tanh(h_i) \geq 0 \\ -1, & \text{sebaliknya} \end{cases}. \quad (8)$$

Berdasarkan Persamaan (8), Fungsi Pengaktifan Tangen Hiperbolik (FPTH) diperkenalkan oleh Mansor & Sathasivam [11] ditakrifkan seperti dalam Persamaan (9):

$$\tanh(h_i) = \frac{e^{h_i} - e^{-h_i}}{e^{h_i} + e^{-h_i}}. \quad (9)$$

Akhir sekali, kualiti S_i^f yang diperoleh akan dinilai berdasarkan Persamaan (10) yang diberikan di bawah:

$$\left| H_{P_{3SAT}} - H_{P_{3SAT}}^{\min} \right| \leq Tol. \quad (10)$$

Berdasarkan Persamaan (10), Tol adalah nilai pratentu, manakala $H_{P_{3SAT}}$ merujuk kepada tenaga akhir rangkaian dan $H_{P_{3SAT}}^{\min}$ ialah tenaga minimum. Tenaga minimum ini dirumuskan seperti dalam Persamaan (11) di mana λ merupakan jumlah bilangan kluasa dalam P_{3SAT} :

$$H_{P_{3SAT}}^{\min} = -\frac{\lambda}{8}. \quad (11)$$

Merujuk kepada Persamaan (10), sekiranya perbezaan antara nilai tenaga adalah kurang daripada nilai Tol , maka S_i^f yang diperoleh diklasifikasikan sebagai mencapai tenaga minimum global. Jika tidak, S_i^f dianggap terperangkap dalam tenaga minimum setempat. Menurut Sathasivam [12], nilai Tol ditetapkan kepada 0.001 bagi mengurangkan ralat dalam keadaan neuron. Dalam konteks ini, adalah penting untuk S_i^f mencapai tenaga minimum global kerana ini membuktikan bahawa peraturan logik P_{3SAT} adalah selaras dan dipenuhi sepenuhnya.

3. Penyediaan Eksperimen

Bagi menilai pencapaian P_{3SAT} dalam RNHD, bahagian ini membincangkan proses ujikaji yang telah direka bentuk, merangkumi penjelasan mengenai platform simulasi, penetapan parameter, serta metrik prestasi yang digunakan. Eksperimen ini dijalankan pada sebuah komputer peribadi dengan pemproses Intel Core i5 menggunakan perisian sumber terbuka Dev C++ (Versi 5.11). Bagi mengelakkan sebarang kecenderungan atau berat sebelah dalam menganalisis keputusan, eksperimen ini dilakukan dengan menggunakan penyusun dan penetapan parameter yang sama. Set data simulasi dihasilkan secara rawak dengan menetapkan representasi bipolar $\{-1,1\}$ pada keadaan neuron. Penetapan parameter bagi P_{3SAT} dalam RNHD sepanjang kajian ini ditunjukkan dalam Jadual 1.

Jadual 1

Penetapan parameter bagi P_{3SAT} dalam RNHD

Penetapan	Nilai Parameter
Bilangan neuron, (NN)	$9 \leq NN \leq 180$
Gabungan neuron, (C)	100 [13]
Bilangan percubaan, (NT)	100 [14]
Bilangan pembelajaran, (NH)	100 [14]

Prestasi P_{3SAT} dianalisis berdasarkan metrik prestasi yang meliputi ralat pembelajaran dan ralat pengujian menggunakan Punca Min Ralat Kuasa Dua ($PMRK$), kualiti neuron akhir dalam mencapai penyelesaian minimum global menggunakan Nisbah Global Minima (N_G), serta pengiraan indeks kesamaan yang rendah menggunakan Jaccard (J_{IK}). Objektif fasa pembelajaran adalah untuk menguji keupayaan P_{3SAT} dalam RNHD untuk meminimumkan $E_{P_{3SAT}}$. $PMRK_{belajar}$ menilai keupayaan P_{3SAT} dalam memperoleh interpretasi penuh. Bagi mengenal pasti kewujudan ralat pembelajaran, $PMRK_{belajar}$ dikira berdasarkan perbezaan antara kecergasan neuron semasa (f_i) dan kecergasan maksimum (f_{NC}). Oleh itu, $PMRK_{belajar}$ dirumuskan seperti berikut:

$$PMRK_{belajar} = \sum_{i=1}^{NH} \sqrt{\frac{(f_{NC} - f_i)^2}{NH}}. \quad (12)$$

Dalam fasa perolehan, ukuran prestasi $PMRK_{ujian}$ digunakan untuk menilai kualiti keadaan akhir neuron yang diperoleh, seperti ditunjukkan dalam Persamaan (13). Ralat sifar bagi $PMRK_{ujian}$ menunjukkan fungsi kos berjaya diminimumkan semasa fasa pembelajaran sekali gus menghasilkan penyelesaian global.

$$PMRK_{ujian} = \sum_{i=1}^{\alpha} \sqrt{\frac{(N_{TS} - N_{GS})^2}{\alpha}}. \quad (13)$$

Selain itu, bagi memastikan kestabilan keadaan akhir neuron dan pencapaian tenaga minimum, prestasi P_{3SAT} dalam RNHD dinilai menggunakan N_G . Nilai N_G menunjukkan keupayaan P_{3SAT} mencapai tenaga minima global dengan formula N_G seperti yang dinyatakan dalam Persamaan (14):

$$N_G = \frac{1}{\alpha} \sum_{i=1}^{\alpha} N_{GS}. \quad (14)$$

Untuk menilai kualiti keadaan akhir neuron, analisis indeks kesamaan dilakukan dengan membandingkan keadaan akhir neuron rangkaian terhadap keadaan neuron penanda aras. Merujuk kepada Rusdi *et al.*, [15] indeks kesamaan J_{IK} dikira menggunakan Persamaan (15) bagi mengukur kesamaan nilai positif terhadap keadaan neuron penanda aras.

$$J_{IK} = \frac{a}{a+b+c}. \quad (15)$$

Julat nilai J_{IK} adalah (0,1) di mana nilai yang rendah menunjukkan ketidaksamaan yang tinggi antara keadaan akhir neuron dan neuron penanda aras. Jadual 2 menyenaraikan parameter yang berkaitan dengan semua metrik prestasi yang dinilai.

Jadual 2

Senarai parameter yang digunakan dalam peyediaan eksperimen


Parameter	Definisi
NC	Bilangan klausa
f_{NC}	Kecergasan maksimum yang diperolehi berdasarkan NC
f_i	Kecergasan semasa yang diperolehi
N_{TS}	Bilangan jumlah penyelesaian
N_{GS}	Bilangan penyelesaian Global Minima
α	$NT \cdot C$

Oleh itu, nilai J_{IK} yang rendah menunjukkan tahap kepelbagaian neuron yang tinggi dari segi keadaan neuron positif.

4. Dapatan Kajian dan Perbincangan

Seksyen ini membincangkan pencapaian P_{3SAT} dalam RNHD dari aspek ralat pembelajaran menggunakan $PMRK_{belajar}$, ralat pengujian menggunakan $PMRK_{ujian}$, kualiti neuron akhir untuk mencapai penyelesaian minima global menggunakan N_G dan pengiraan indeks kesamaan yang rendah menggunakan J_{IK} . Dalam fasa pembelajaran, tujuan utama adalah untuk menilai kecekapan pendekatan CM dalam mendapatkan interpretasi penuh (iaitu bilangan klausa yang dipenuhi secara maksimum) bagi P_{3SAT} dalam usaha meminimumkan fungsi kos rangkaian. Memandangkan kajian ini merupakan percubaan pertama dalam melaksanakan SAT ke dalam RNHD, hanya pendekatan CM yang digunakan sebagai algoritma pembelajaran dalam mencari interpretasi penuh untuk P_{3SAT} . Dalam simulasi ini, proses akan dihentikan sama ada apabila bilangan klausa yang dipenuhi secara maksimum telah dicapai atau apabila bilangan pengulangan melebihi jumlah pengulangan yang

ditetapkan. Prestasi P_{3SAT} dalam memperoleh nilai $PMRK_{belajar}$ ditunjukkan dalam Rajah 1. Berdasarkan rajah tersebut, dapat diperhatikan bahawa apabila bilangan neuron meningkat, nilai $PMRK_{belajar}$ juga cenderung untuk meningkat. Dalam konteks ini, nilai ralat yang lebih tinggi menunjukkan peratusan klausa yang tidak dipenuhi juga adalah tinggi [16]. Salah satu faktor utama yang menyumbang kepada prestasi ini ialah sifat kaedah CM yang bergantung kepada pendekatan cuba dan jaya untuk mendapatkan interpretasi yang penuh berdasarkan peraturan logik. Apabila kerumitan rangkaian meningkat dengan bilangan neuron yang lebih tinggi, CM menghadapi kesukaran untuk mencari interpretasi penuh bg peraturan logik tersebut. Ini kerana CM meneroka semua kemungkinan kombinasi klausa, dan apabila ruang carian menjadi semakin besar, proses ini menjadi lebih rumit dan memakan masa.




Rajah 1. $PMRK_{belajar}$ bagi P_{3SAT}


Walaubagaimanapun, nilai $PMRK_{belajar}$ didapati paling rendah apabila bilangan neuron adalah kecil, khususnya apabila $NN < 40$. Hasil ini berpunca daripada kelebihan logik tertib ketiga yang mengandungi lebih banyak literal dalam setiap klausa, sekali gus meningkatkan peluang untuk mendapatkan interpretasi penuh [17]. Pemerhatian ini menunjukkan bahawa logik tertib tinggi meningkatkan kebarangkalian memperoleh interpretasi penuh. Sebagai contoh, dalam peraturan logik P_{3SAT} , terdapat lapan kemungkinan kombinasi klausa, di mana tujuh daripadanya adalah BENAR. Ini menunjukkan peratusan kombinasi BENAR yang lebih tinggi dalam P_{3SAT} ini meningkatkan lagi kebarangkalian untuk mencapai bilangan klausa yang dipenuhi secara maksimum. Selain itu, apabila bilangan neuron meningkat, nilai $PMRK_{belajar}$ juga meningkat secara konsisten tanpa turun naik. Corak ini mencerminkan sifat sistematik dalam formulasi SAT, di mana bilangan literal dalam setiap klausa adalah tetap dan terhad [18]. Dalam konteks ini, mendapatkan bilangan klausa yang dipenuhi secara maksimum adalah penting untuk meminimumkan ketidakselarasan dalam peraturan logik yang seterusnya meminimumkan fungsi kos. Ini memastikan bahawa berat sinaptik yang optimum dapat diperoleh dan disimpan dalam MBCK untuk digunakan semula dalam fasa perolehan. Oleh itu, dapat disimpulkan bahawa RNHD yang menggunakan peraturan logik P_{3SAT} menunjukkan keupayaan pembelajaran terbaik serta mencapai fasa pembelajaran yang optimum dengan berat sinaptik yang optimum.

Dalam fasa perolehan, nilai berat sinaptik yang diperoleh dalam fasa pembelajarkan akan digunakan untuk mengemaskini keadaan neuron melalui persamaan medan setempat bagi mendapatkan neuron akhir. Oleh itu, analisis dilaksanakan untuk menilai tingkah laku 3SAT

berdasarkan berat sinaptik yang diperoleh. Prestasi P_{3SAT} dalam memperoleh nilai $PMRK_{ujian}$ ditunjukkan dalam Rajah 2. Dalam hal ini, ralat pengujian yang rendah menunjukkan kecekapan model dalam mengenal pasti penyelesaian minima global berbanding penyelesaian minima setempat [4]. Di samping itu, nilai $PMRK_{ujian}$ yang diperoleh dalam fasa perolehan mempunyai hubungan dengan ralat yang diperoleh dalam fasa pembelajaran. Secara ringkasnya, apabila $PMRK_{belajar}$ meningkat disebabkan oleh kesukaran untuk mendapatkan interpretasi penuh, ini seterusnya membawa kepada peningkatan dalam nilai $PMRK_{ujian}$ [19]. Dalam hal ini, keupayaan untuk mencapai ralat pengujian yang rendah menunjukkan keberkesanan model dalam memperoleh penyelesaian minima global, sekali gus memastikan sifat penumpuan DHNN. Keberkesanan ini boleh diukur melalui N_G .




Rajah 2. $PMRK_{ujian}$ bagi P_{3SAT}



Rajah 3. N_G bagi P_{3SAT}

Rajah 3 menunjukkan prestasi P_{3SAT} dalam mencapai penyelesaian global. Berdasarkan rajah tersebut, dapat diperhatikan bahawa nilai N_G yang terhasil mempunyai hubungan dengan nilai $PMRK_{ujian}$. Sebagai contoh, berdasarkan Rajah 2, dapat dilihat bahawa $PMRK_{ujian}$ mampu mencapai nilai ralat 0.0000 bagi $NN < 65$. Ini menunjukkan dalam julat nilai tersebut, CM mampu mencapai interpretasi penuh untuk P_{3SAT} yang membawa kepada $E_{P_{3SAT}} = 0$, seterusnya menghasilkan berat sinaptik yang optimum. Secara tidak langsung, ini telah meningkatkan potensi neuron untuk

menumpu kepada penyelesaian global. Ini dapat disokong dengan pencapaian P_{3SAT} dalam mencapai $N_G = 1$ untuk julat nilai $NN < 65$. Namun begitu, apabila nilai $PMRK_{ujian}$ semakin meningkat, boleh dilihat kualiti neuron akhir yang menumpu ke arah penyelesaian global semakin menurun. Hal ini adalah disebabkan apabila CM tidak mampu mencapai interpretasi penuh dalam fasa pembelajaran, ia membawakan kepada nilai berat sinaptik yang tidak optimum disimpan di dalam MBCK. Jadi, penggunaan nilai berat sinaptik yang tidak optimum digunakan untuk mengemaskini keadaan neuron menyebabkan neuron akhir tidak menumpu ke arah penyelesaian global.



Rajah 4. J_{IK} bagi P_{3SAT}

Dalam hal ini, mencapai penyelesaian global adalah penting untuk menilai kualiti neuron akhir dalam konteks indeks kesamaan. Hal ini kerana, indeks kesamaan hanya boleh dikira bagi neuron yang mencapai penyelesaian minima global [14]. Tanpa penyelesaian global, kualiti keadaan neuron tersebut kekal tidak pasti. Dalam konteks ini, kualiti neuron akhir yang diperoleh boleh dinilai menggunakan indeks kesamaan yang mengukur tahap kesamaan atau perbezaan antara keadaan neuron dan penanda aras. Rajah 4 menunjukkan prestasi P_{3SAT} dalam memperoleh nilai indeks kesamaan J_{IK} . Dalam konteks nilai J_{IK} , nilai yang lebih kecil menunjukkan tahap perbezaan yang tinggi antara keadaan neuron akhir yang diperoleh dan keadaan penanda aras. Keadaan penanda aras merujuk kepada keadaan neuron rujukan yang mewakili penyelesaian ideal atau jangkaan, yang berfungsi sebagai tanda aras untuk menilai sejauh mana keadaan neuron akhir mencerminkan peraturan logik. Berdasarkan Rajah 4, P_{3SAT} memperoleh nilai J_{IK} dalam julai nilai antara 0.53 dan 0.57. Nilai Jaccard yang rendah ini menunjukkan bahawa keadaan neuron akhir yang diperoleh oleh P_{3SAT} mempunyai tahap perbezaan yang tinggi apabila dibandingkan dengan keadaan penanda aras. Tahap perbezaan yang tinggi ini menandakan penyelesaian yang tidak mengalami penyuaian melampau. Sebaliknya, penyuaian melampau berlaku apabila semua keadaan neuron akhir yang diperoleh sepadan sepenuhnya dengan keadaan penanda aras seterusnya mengehadkan keupayaan logik untuk menangani aplikasi dunia sebenar.

5. Kesimpulan

Memandangkan sifat semula jadi model RNHD sedia ada, kajian ini bertujuan untuk meningkatkan kebolehfahaman model tersebut dengan memperkenalkan peraturan simbolik sebagai bahasa untuk mengawal neuron dalam RNHD untuk meningkatkan kebolehgunaannya dalam

menyelesaikan masalah pengelasan dunia sebenar. Sehubungan itu, kami memperkenalkan satu peraturan logik baharu yang dikenali sebagai P_{3SAT} ke dalam rangka kerja RNHD. P_{3SAT} ini menghadkan bilangan literal dalam setiap klausa serta menggabungkan taburan rawak literal positif dan negatif. Pelaksanaan P_{3SAT} ke dalam RNHD telah membawa kepada peningkatan prestasi keseluruhan model khususnya dalam mencapai lebih banyak penyelesaian minimum global. Selain itu, nilai J_{IK} yang rendah menunjukkan tahap kesamaan yang rendah antara keadaan neuron akhir dengan keadaan penanda aras serta membantu mengelakkan model daripada penyuaian melampau.

Walau bagaimanapun, kajian ini mempunyai beberapa keterbatasan yang boleh diperbaiki dalam kajian akan datang. Pertama, walaupun logik peringkat tinggi mampu mencapai lebih banyak penyelesaian minimum global, struktur P_{3SAT} dengan bilangan literal yang terhad dalam setiap klausa boleh ditambah baik dengan meneroka logik secara tidak sistematik yang lebih fleksibel. Ini boleh dilaksanakan dengan tidak menghadkan jumlah literal dalam setiap klausa. Dalam konteks ini, setiap klausa boleh mempunyai satu, dua atau tiga literals. Kepelbagaian literals dalam setiap klausa akan membawa kepada penghasilan nilai berat sinaptik yang pelbagai seterusnya menghasilkan kepelbagaian yang lebih tinggi dalam neuron akhir yang diperoleh. Kedua, struktur P_{3SAT} yang digunakan pada masa ini hanya mengambil kira taburan rawak literal positif dan negatif. Namun begitu, SAT lebih banyak menghasilkan bilangan literal positif menjadikan pengaruh literal negatif kurang jelas. Oleh itu, kajian masa hadapan boleh menumpukan kepada penerokaan kesan literal negatif terhadap tingkah laku neuron dalam RNHD. Ini dapat dilaksanakan dengan menetapkan bilangan literal negatif untuk jumlah klausa yang digunakan. Dalam konteks ini, pelaksanaan algoritma akan memudahkan proses bagi memperoleh jumlah literal negatif yang optimum untuk jumlah klausa yang ada. Selain itu, dapatan kajian menunjukkan bahawa kaedah CM menjadi kurang efisien apabila bilangan neuron meningkat, disebabkan oleh ruang carian yang lebih besar dan peningkatan kerumitan seterusnya membawa kepada penurunan prestasi. Justeru, kajian akan datang boleh menumpukan kepada pelaksanaan algoritma metaheuristik sebagai mekanisme pembelajaran untuk meningkatkan proses pencarian interpretasi penuh bagi logik tersebut. Dengan pelaksanaan algoritma ini dalam fasa pembelajaran, ia dapat meningkatkan peluang dan memudahkan model ini untuk mencapai interpretasi penuh. Dalam konteks ini, mencapai interpretasi penuh adalah penting bagi memastikan nilai berat sinaptik yg dihasilkan adalah optimum sekali gus meningkatkan peluang untuk memperoleh neuron akhir yang lebih optimum. Hal ini kerana, berat sinaptik ini akan digunakan untuk mengemaskini keadaan neuron bagi memperoleh neuron akhir yang optimum. Oleh itu, penambakan melalui pelaksanaan algoritma metaheuristik dalam fasa pembelajaran adalah berkesan untuk menangani keterbatasan kaedah CM.

Penghargaan

Kajian ini tidak dibiayai melalui sebarang bentuk geran penyelidikan.

Rujukan

- [1] Si, Tapas, Jayri Bagchi, and P ricles BC Miranda. "Artificial neural network training using metaheuristics for medical data classification: an experimental study." *Expert Systems with Applications* 193 (2022): 116423. <https://doi.org/10.1016/j.eswa.2021.116423>
- [2] Azgomi, Hossein, Fatemeh Roshannia Haredasht, and Mohammad Reza Safari Motlagh. "Diagnosis of some apple fruit diseases by using image processing and artificial neural network." *Food Control* 145 (2023): 109484. <https://doi.org/10.1016/j.foodcont.2022.109484>
- [3] Ghimire, Ritesh, and Asokan Raji. "Use of artificial intelligence in design, development, additive manufacturing, and certification of multifunctional composites for aircraft, drones, and spacecraft." *Applied Sciences* 14, no. 3 (2024): 1187. <https://doi.org/10.3390/app14031187>

- [4] Karim, Syed Anayet, Nur Ezlin Zamri, Alyaa Alway, Mohd Shareduwan Mohd Kasihmuddin, Ahmad Izani Md Ismail, Mohd Asyraf Mansor, and Nik Fathihah Abu Hassan. "Random satisfiability: A higher-order logical approach in discrete Hopfield Neural Network." *IEEE Access* 9 (2021): 50831-50845. <https://doi.org/10.1109/ACCESS.2021.3068998>
- [5] Rusdi, Nur' Afifah, Mohd Shareduwan Mohd Kasihmuddin, Nurul Atiqah Romli, Gaeithry Manoharam, and Mohd Asyraf Mansor. "Multi-unit discrete hopfield neural network for higher order supervised learning through logic mining: Optimal performance design and attribute selection." *Journal of King Saud University-Computer and Information Sciences* 35, no. 5 (2023): 101554. <https://doi.org/10.1016/j.jksuci.2023.101554>
- [6] Mansor, M. A., M. S. M. Kasihmuddin, and S. Sathasivam. "Artificial Immune System Paradigm in the Hopfield Network for 3-Satisfiability Problem." *Pertanika Journal of Science & Technology* 25, no. 4 (2017).
- [7] Abdullah, Wan Ahmad Tajuddin Wan. "Logic programming on a neural network." *International journal of intelligent systems* 7, no. 6 (1992): 513-519. <https://doi.org/10.1002/int.4550070604>
- [8] Azizan, Farah Liyana, Saratha Sathasivam, Majid Khan Majahar Ali, Nurshazneem Roslan, and Caicai Feng. "Hybridised Network of Fuzzy Logic and a Genetic Algorithm in Solving 3-Satisfiability Hopfield Neural Networks." *Axioms* 12, no. 3 (2023): 250. <https://doi.org/10.3390/axioms12030250>
- [9] Abdeen, Suad, Mohd Shareduwan Mohd Kasihmuddin, Nur Ezlin Zamri, Gaeithry Manoharam, Mohd Asyraf Mansor, and Nada Alshehri. "S-type random k satisfiability logic in discrete hopfield neural network using probability distribution: Performance optimization and analysis." *Mathematics* 11, no. 4 (2023): 984. <https://doi.org/10.3390/math11040984>
- [10] Manoharam, Gaeithry, Azleena Mohd Kassim, Suad Abdeen, Mohd Shareduwan Mohd Kasihmuddin, Nur' Afifah Rusdi, Nurul Atiqah Romli, and Mohd Asyraf Mansor. "Special major 1, 3 satisfiability logic in discrete Hopfield neural networks." *AIMS Mathematics* 9, no. 5 (2024): 12090-12127. <https://doi.org/10.3934/math.2024591>
- [11] Mansor, Mohd Asyraf, and Saratha Sathasivam. "Accelerating activation function for 3-satisfiability logic programming." *International Journal of Intelligent Systems and Applications* 8, no. 10 (2016): 44. <https://doi.org/10.5815/ijisa.2016.10.05>
- [12] Sathasivam, Saratha. "Upgrading logic programming in Hopfield network." *Sains Malaysiana* 39, no. 1 (2010): 115-118.
- [13] Gao, Yuan, Yueling Guo, Nurul Atiqah Romli, Mohd Shareduwan Mohd Kasihmuddin, Weixiang Chen, Mohd Asyraf Mansor, and Ju Chen. "GRAN3SAT: Creating flexible higher-order logic satisfiability in the discrete hopfield neural network." *Mathematics* 10, no. 11 (2022): 1899. <https://doi.org/10.3390/math10111899>
- [14] Roslan, Nurshazneem, Saratha Sathasivam, and Farah Liyana Azizan. "Conditional random k satisfiability modeling for k= 1, 2 (CRAN2SAT) with non-monotonic Smish activation function in discrete Hopfield neural network." *AIMS Mathematics* 9, no. 2 (2024): 3911-3956. <https://doi.org/10.3934/math.2024193>
- [15] Rusdi, Nur' Afifah, Nur Ezlin Zamri, Mohd Shareduwan Mohd Kasihmuddin, Nurul Atiqah, Gaeithry Manoharam Romli, Suad Abdeen, and Mohd Asyraf Mansor. "Synergizing intelligence and knowledge discovery: Hybrid black hole algorithm for optimizing discrete Hopfield neural network with negative based systematic satisfiability." *AIMS Mathematics* 9, no. 11 (2024): 29820-29882. <https://doi.org/10.3934/math.20241444>
- [16] Zamri, Nur Ezlin, Siti Aishah Azhar, Mohd Asyraf Mansor, Alyaa Alway, and Mohd Shareduwan Mohd Kasihmuddin. "Weighted random k satisfiability for k= 1, 2 (r2SAT) in discrete hopfield neural network." *Applied Soft Computing* 126 (2022): 109312. <https://doi.org/10.1016/j.asoc.2022.109312>
- [17] Kasihmuddin, Mohd Shareduwan Mohd, Mohd Asyraf Mansor, and Saratha Sathasivam. "Hybrid Genetic Algorithm in the Hopfield Network for Logic Satisfiability Problem." *Pertanika Journal of Science & Technology* 25, no. 1 (2017).
- [18] Sathasivam, Saratha, Mohd Asyraf Mansor, Ahmad Izani Md Ismail, Siti Zulaikha Mohd Jamaludin, Mohd Shareduwan Mohd Kasihmuddin, and Mustafa Mamat. "Novel random k satisfiability for k≤ 2 in hopfield neural network." *Sains Malaysiana* 49, no. 11 (2020): 2847-2857. <https://doi.org/10.17576/jsm-2020-4911-23>
- [19] Chen, Ju, Mohd Shareduwan Mohd Kasihmuddin, Yuan Gao, Yueling Guo, Mohd Asyraf Mansor, Nurul Atiqah Romli, Weixiang Chen, and Chengfeng Zheng. "PRO2SAT: Systematic probabilistic satisfiability logic in discrete hopfield neural network." *Advances in Engineering Software* 175 (2023): 103355. <https://doi.org/10.1016/j.advengsoft.2022.103355>
- [20] Romli, Nurul Atiqah, Nur Fariha Syaquina Zulkepli, Mohd Shareduwan Mohd Kasihmuddin, Nur Ezlin Zamri, Nur' Afifah Rusdi, Gaeithry Manoharam, Mohd Asyraf Mansor, Siti Zulaikha Mohd Jamaludin, and Amierah Abdul Malik. "Unsupervised logic mining with a binary clonal selection algorithm in multi-unit discrete Hopfield neural networks via weighted systematic 2 satisfiability." *AIMS Mathematics* 9, no. 8 (2024): 22321-22365. <https://doi.org/10.3934/math.20241087>