

การออกแบบและพัฒนาโครงข่ายทฤษฎีฟัซซีเรโซแนนซ์แบบปรับตัวอย่างง่าย ด้วยหลักการกำหนดค่าพารามิเตอร์สอดคล้องหลายค่าแบบปรับปรุงตัวเอง

Design and Development of An Auto Adaptive Multi-Vigilance for Simplified Fuzzy ARTMAP

กรณัทกมล ภูครองหิน¹ เอบบดี เมืองกลาง¹ ปรีชา สมหวัง¹ เต๋น คอกพิมาย¹ ฌัฐพงษ์ วงศ์บัณฑิต¹ และ วิญญะ ฉินยาทุ²

¹สาขาวิศวกรรมเมคคาทรอนิกส์ คณะวิศวกรรมศาสตร์และเทคโนโลยี มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี

²ภาควิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์และสถาปัตยกรรมศาสตร์ มหาวิทยาลัยราชภัฏสวนสุนันทา

Email: krankamon.ph@rmuti.ac.th

บทคัดย่อ

บทความนี้นำเสนอการออกแบบและพัฒนาโครงข่ายทฤษฎีฟัซซีเรโซแนนซ์แบบปรับตัวอย่างง่าย (Simplified Fuzzy ARTMAP, SFAM) ด้วยรูปแบบการกำหนดค่าพารามิเตอร์สอดคล้องหลายค่า (Auto Adaptive Multi-Vigilance) แบบปรับตัวอัตโนมัติ โดยใช้แนวคิดการปรับตัวจากลักษณะความคุ้นชินของมนุษย์ในการจดจำสิ่งต่าง ๆ เพื่อให้รูปแบบการตัดสินใจของโครงข่ายประสาทเทียมมีความยืดหยุ่นและมีประสิทธิภาพมากขึ้น จากรูปแบบสถาปัตยกรรมดั้งเดิมของ SFAM ที่มีการกำหนดพารามิเตอร์สอดคล้องเพียงหนึ่งค่าและเป็นค่าคงที่ ซึ่งค่าพารามิเตอร์สอดคล้องนี้ถูกออกแบบให้ใช้ในการเปรียบเทียบความคล้ายของชุดข้อมูลกับนิวรอลทุกตัวที่ถูกเก็บไว้ในชั้นนำหนักประสาท ส่งผลให้ความยืดหยุ่นในการเรียนรู้ลดน้อยลง จึงเกิดแนวคิดในการออกแบบและพัฒนาสถาปัตยกรรมของโครงข่ายทฤษฎีฟัซซีเรโซแนนซ์แบบปรับตัวอย่างง่ายให้มีความยืดหยุ่นขึ้นด้วยการออกแบบอัลกอริทึมให้สามารถสร้างค่าพารามิเตอร์สอดคล้องได้หลายค่าตามจำนวนของกลุ่มนำหนักประสาท และสามารถปรับปรุงค่าพารามิเตอร์นี้ได้ตามรูปแบบการเรียนรู้ที่โครงข่ายประสาทเทียมได้รับจากชุดข้อมูล โดยทำการทดสอบกับข้อมูลสองรูปแบบ คือ 1.การทดสอบการเรียนรู้ด้วยชุดอินพุตแบบอย่างง่าย และ 2.การทดสอบการเรียนรู้รับอินพุตที่มีความซับซ้อน จากผลการทดสอบแสดงให้เห็นถึงประสิทธิภาพของโครงข่ายประสาทเทียมที่ทำการพัฒนาขึ้น โดยมีเปอร์เซ็นต์ความถูกต้องอยู่ที่ 96.67% และ 95.33% ตามลำดับการทดสอบ ขณะที่โครงข่ายแบบดั้งเดิมมีเปอร์เซ็นต์ความถูกต้องอยู่ที่ 86.67% และ 92.66%

คำสำคัญ: การเรียนรู้ของเครื่อง โครงข่ายทฤษฎีฟัซซีเรโซแนนซ์แบบปรับตัวอย่างง่าย พารามิเตอร์สอดคล้องหลายค่าแบบปรับตัว

Abstract

This paper presents the design and development of a Simplified Fuzzy Resonance Theory (SFAM) with an auto-adaptive multi-vigilance parameter. Using the concept of adaptation from human familiarity in recognizing things to make a decision of patterns of the artificial neural network more flexible and efficient. Based on the

original SFAM architecture that has only one vigilance parameter is defined and it is not adaptive. This vigilance parameter was designed to compare the similarity of the dataset to winner neurons stored in the neural weight layer, causing the flexibility in the model of the artificial neural network to decrease. Therefore, an idea was born to design and develop the architecture of a simple adaptive fuzzy resonance theory neural network to be more flexible by designing an algorithm that can generate multiple vigilance parameters based on the number of nervous weight neural and this parameter can be adapted according to the learning process that the neural network receives from the dataset. Two types of datasets were tested including 1. simple input dataset and 2. complex input dataset. The test results show that the efficiency of the purpose neural network has an accuracy percentage of 96.67% and 95.33% respectively. While traditional networks have accuracy percentages of 86.67% and 92.66%.

Keywords: Machine Learning, SFAM, Auto Adaptive Multi Vigilance

1. บทนำ

ในปัจจุบันด้วยการพัฒนาอย่างต่อเนื่องในกลุ่มงานวิจัยทางด้านปัญญาประดิษฐ์ส่งผลให้เกิดการสร้างนวัตกรรมใหม่ สิ่งประดิษฐ์ใหม่จนไปถึงแนวคิดต่าง ๆ ที่ทำงานได้อย่างชาญฉลาด[1] เช่นงานทางด้านการเรียนรู้เชิงลึก (Deep learning) ซึ่งถูกนำมาใช้อย่างกว้างขวางร่วมกับการประมวลผลภาพดิจิทัล[2] แต่หากกล่าวถึงองค์ความรู้ต้นแบบที่ถูกนำมาพัฒนาต่อยอดจนกลายเป็นการเรียนรู้เชิงลึกในปัจจุบันย่อมเป็นที่รู้จักกันดีในชื่อของการเรียนรู้ของเครื่อง (Machine learning)[3] ซึ่งหากไม่พูดถึงจุดด้อยในกระบวนการหาลักษณะเด่นของชุดข้อมูลแล้ว การเรียนรู้ของเครื่องก็ยังคงเป็นเครื่องมือในการเรียนรู้และจดจำข้อมูลได้อย่างมีประสิทธิภาพ แต่รูปแบบการเรียนรู้รวมถึงลักษณะในการทำงานแตกต่างกันตามรูปแบบของระเบียบวิธีการที่เลือกใช้ใช้งาน ในบทความนี้เลือกใช้โครงข่ายทฤษฎีฟัซซีเรโซแนนซ์แบบปรับตัวอย่างง่าย[4] เป็นต้นแบบการพัฒนา ด้วยข้อดีของโครงข่ายชนิดนี้มีประสิทธิภาพในการเรียนรู้ที่ดี สามารถเรียนรู้ได้อย่างต่อเนื่องเมื่อมีชุดข้อมูลใหม่ถูกป้อนเข้า

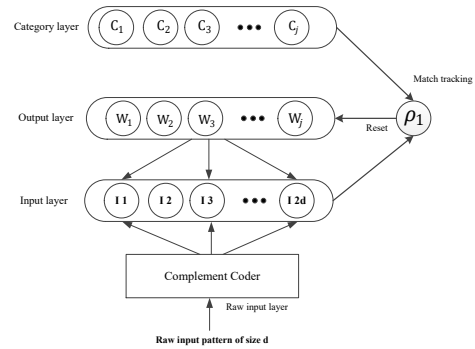
มาโดยไม่จำเป็นที่จะต้องทำการสอนโครงข่ายใหม่ทั้งหมดตั้งแต่ต้น ทำให้ผู้ใช้งานไม่ต้องกังวลถึงการจัดเก็บชุดข้อมูล หรือชุดข้อมูลสูญหาย แต่รูปแบบการทำงานของโครงข่ายชนิดนี้ยังขาดความยืดหยุ่น อันเนื่องมาจากการมีค่าพารามิเตอร์สอดคล้องเพียงตัวเดียวที่ทำหน้าที่ในการพิจารณาความคล้ายของนิเวศผู้ชนะกับค่าน้ำหนักประสาทที่โครงข่ายได้เรียนรู้ไว้แล้วและต้องใช้ค่าเดียวกันกับทุกกลุ่มน้ำหนักประสาท ซึ่งพารามิเตอร์สอดคล้องนี้ทำหน้าที่คล้ายกับความคุ้นชินของมนุษย์แต่ไม่สามารถปรับปรุงตัวเองให้เพิ่มขึ้นหรือลดลงได้

จึงเกิดแนวคิดให้คณะวิจัยทำการพัฒนาโครงข่ายทฤษฎีฟิชเชอร์โซเนนซ์แบบปรับตัวอย่างง่ายให้มีรูปแบบการทำงานที่ยืดหยุ่นมากขึ้นและมีประสิทธิภาพที่ดีขึ้น จากแนวคิดในการปรับปรุงให้พารามิเตอร์สอดคล้องนั้นทำงานเปรียบเสมือนความคุ้นชินของมนุษย์ เมื่อเจอข้อมูลในกลุ่มที่เคยเรียนรู้แล้ว อัลกอริทึมจะปรับให้ความคุ้นชินนี้มีค่ามากขึ้น ซึ่งหมายถึงเงื่อนไขที่ใช้งานการตรวจสอบความคล้ายมีค่าลดลง (ค่าพารามิเตอร์สอดคล้องมีค่าลดลง) และเมื่อโครงข่ายได้พบกันข้อมูลชุดใหม่ หรือมีการสร้างน้ำหนักประสาทค่าใหม่ อัลกอริทึมที่ออกแบบจะปรับความคุ้นชินให้มีย่านของค่าพารามิเตอร์สอดคล้องมีค่ามากขึ้น) และยังทำการพัฒนาให้โครงข่ายประสาทเทียมมีจำนวนพารามิเตอร์สอดคล้องที่ใช้เปรียบเทียบเฉพาะในกลุ่มของตัวเองเพื่อเพิ่มความยืดหยุ่นในการทำงานและไม่ส่งผลกระทบต่อการทำงานเปรียบเทียบกับค่าน้ำหนักประสาทกลุ่มอื่น ๆ ในกรณีที่ค่าพารามิเตอร์สอดคล้องมีการปรับปรุงตัวเอง

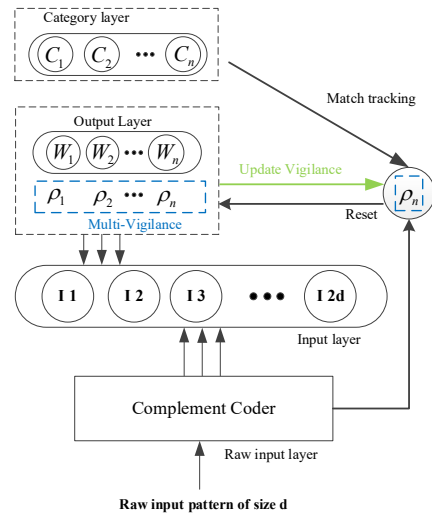
2. การออกแบบทฤษฎีฟิชเชอร์โซเนนซ์แบบปรับตัวอย่างง่ายด้วยหลักการกำหนดค่าพารามิเตอร์สอดคล้องหลายค่าแบบปรับปรุงตัวเอง

การออกแบบสถาปัตยกรรมของทฤษฎีฟิชเชอร์โซเนนซ์แบบปรับตัวอย่างง่ายที่สามารถสร้างค่าพารามิเตอร์สอดคล้องได้เองตามจำนวนของกลุ่มข้อมูลที่ได้รับการเรียนรู้และสามารถปรับปรุงตัวเองให้มีความเหมาะสมกับลักษณะของข้อมูลที่ได้เรียนรู้แล้วยังคงใช้โครงสร้างของสถาปัตยกรรมเดิมแต่อัลกอริทึมในการทำงานนั้นจะแตกต่างออกไป จากหลักแนวคิดเกี่ยวกับความคุ้นชินของการรับรู้ข้อมูลที่ว่า เมื่อมีข้อมูลใหม่เข้ามาอัลกอริทึมจะใช้เงื่อนไขในการตรวจสอบที่สูงเนื่องจากยังไม่เคยพบข้อมูลในลักษณะนี้ และในกรณีที่ข้อมูลที่ถูกรับเข้ามานั้น โครงข่ายเคยได้เรียนรู้ไว้แล้วแม้จะมีความแตกต่างแต่ถ้าอยู่ในกลุ่มเดียวกัน อัลกอริทึมก็จะทำการลดเงื่อนไขในการตรวจสอบลงเปรียบเสมือนว่าเมื่อเจอข้อมูลกลุ่มเดิมบ่อยขึ้นความคุ้นชินระหว่างโครงข่ายกับข้อมูลก็จะเพิ่มขึ้น และใช้แนวคิดในการสร้างพารามิเตอร์สอดคล้องประจำกลุ่มน้ำหนักประสาทเพื่อให้โครงข่ายประสาทเทียมมีความยืดหยุ่น เมื่อน้ำหนักประสาทหรือนิวรอนมีจำนวนมากขึ้นค่าพารามิเตอร์สอดคล้องก็จะเพิ่มขึ้นตามไปด้วย เพื่อให้มั่นใจว่าการเพิ่มขึ้นหรือลดลงของความคุ้นชินจะไม่ส่งผลกระทบต่อการทำงานในกลุ่มอื่น ๆ โดยรูปที่ 1 แสดงแผนภาพ

สถาปัตยกรรมของโครงข่ายประสาทเทียมแบบดั้งเดิม และโครงข่ายประสาทเทียมที่นำเสนอในงานวิจัยนี้แสดงในรูปที่ 2



รูปที่ 1 สถาปัตยกรรมของทฤษฎีฟิชเชอร์โซเนนซ์แบบปรับตัวอย่างง่ายแบบดั้งเดิม



รูปที่ 2 สถาปัตยกรรมของทฤษฎีฟิชเชอร์โซเนนซ์แบบปรับตัวอย่างง่ายแบบค่าพารามิเตอร์สอดคล้องหลายค่าแบบปรับปรุงตัวเอง

โดยรูปแบบการเรียนรู้ การคำนวณรวมไปถึงการตัดสินใจของโครงข่ายประสาทเทียมแสดงได้ดังสมการต่อไปนี้

1) จัดเตรียมอินพุตเพื่อใช้ในการคำนวณหาฟังก์ชันการกระตุ้นและนิเวศผู้ชนะ โดยใช้สมการที่ 1 เมื่อ \bar{a} คือ อินพุต และ \bar{a}^c คือ เวกเตอร์ค่าคอมพลิเมนต์ของอินพุตที่มีจำนวนเท่ากับ d

$$I_i = (\bar{a}, \bar{a}^c) = (a_1, a_2, a_3, \dots, a_d, 1-a_1, 1-a_2, 1-a_3, \dots, 1-a_d) \quad (1)$$

ในกรณีที่อินพุต I_i เป็นอินพุตแรกที่ได้รับการเรียนรู้จะถูกกำหนดให้เป็นค่าน้ำหนักประสาทตัวแรกพร้อมกับทำการกำหนดค่าพารามิเตอร์สอดคล้องประจำกลุ่ม

2) คำนวณค่าฟังก์ชันการกระตุ้น (Activation function) โดยใช้สมการที่ 2

$$T_n(I_i) = \frac{|I \wedge W_n|}{\alpha + |W_n|} \quad (2)$$

- เมื่อ W_n คือ ค่าน้ำหนักประสาทประจำกลุ่ม
 n คือ จำนวนของนิวรอนในชั้นน้ำหนักประสาท
 I คือ อินพุต, α คือ ค่าคงที่มีค่าเข้าใกล้ศูนย์
 $T_n(I_i)$ คือ ฟังก์ชันการกระตุ้นของอินพุต
 3) จากนั้นทำการหาค่าของฟังก์ชันการกระตุ้นโดยใช้สมการที่ 3

$$T_k(I_i) = \max T_n(I_i) \quad (3)$$

- 4) คำนวณฟังก์ชันความคล้ายโดยใช้สมการที่ 4

$$MF(I_i) = \frac{|I_i \wedge W_n|}{|I_i|} \quad (4)$$

ตรวจสอบเงื่อนไขการเรโซแนนซ์หรือตรวจสอบความคล้ายโดยใช้สมการที่ 5 ในกรณีที่การตรวจสอบไม่ผ่านเงื่อนไข โครงข่ายจะทำการรีเซ็ตตัวเองเพื่อหาค่าของฟังก์ชันตัวใหม่ และทำการตรวจสอบเงื่อนไขอีกครั้ง จากนั้นจะทำการปรับปรุงค่าน้ำหนักประสาทในชั้นหลักโดยใช้สมการที่ 6 และหากไม่ผ่านเงื่อนไขใดเลยโครงข่ายจะทำการสร้างน้ำหนักประสาทกลุ่มใหม่ขึ้นมาแทน

$$MF(I_i) > \rho_n \quad (5)$$

$$W_n^{new} = \beta(I \wedge W_n^{old}) + (1 - \beta)W_n^{old} \quad (6)$$

- เมื่อ W_n^{new} คือ ค่าน้ำหนักประสาทที่ทำการปรับปรุง
 W_n^{old} คือ ค่าน้ำหนักประสาทเดิม, β คือ ค่าคงที่
 ρ_n คือ ค่าพารามิเตอร์สอดคล้องประจำกลุ่มน้ำหนักประสาท n

ในงานวิจัยนี้ผู้วิจัยได้ทำการปรับปรุงอัลกอริทึมของโครงข่ายเพื่อให้สามารถทำงานได้ตามที่ได้นำเสนอแนวคิดไว้ โดยเมื่อมีการปรับปรุงน้ำหนักประสาท(ความคุ้นชินเพิ่มมากขึ้น) ค่าพารามิเตอร์สอดคล้องจะทำการปรับตัวเองให้ลดลง โดยใช้สมการที่ 7

$$\rho_n^{new} = (1 - \Delta)\rho_n^{old} \quad (7)$$

เมื่อมีการสร้างน้ำหนักประสาทค่าใหม่(นิวรอนกลุ่มใหม่) ค่าพารามิเตอร์สอดคล้องจะถูกปรับให้สูงขึ้นโดยใช้สมการที่ 8

$$\rho_n^{new} = (1 + \Delta)\rho_n^{old} \quad (8)$$

- เมื่อ Δ คือ ค่าคงที่มีค่าระหว่าง 0 ถึง 1

โดยกระบวนการหาค่าตอบของโครงข่ายประสาทเทียมนั้นสามารถทำได้โดยการคำนวณหาค่าฟังก์ชันการกระตุ้น โดยใช้สมการที่ 2 จากนั้นหาค่าของฟังก์ชัน โดยใช้สมการที่ 3 ซึ่งหาค่าของฟังก์ชันจะเชื่อมโยงกันกับชั้นการระบุกลุ่มข้อมูล (Category layer) และใช้เป็นคำตอบของโครงข่ายประสาทเทียม

3. การเตรียมข้อมูลในการทดสอบโครงข่ายประสาทเทียม

ในการทดสอบประสิทธิภาพการทำงานของโครงข่ายประสาทเทียมนั้นจะทำการทดสอบกับชุดข้อมูลสองรูปแบบ คือ 1. ข้อมูลในรูปแบบอย่างง่าย และ 2. ข้อมูลที่มีความซับซ้อน โดยข้อมูลในกลุ่มที่ 2 ได้มาจากกระบวนการสกัดคุณลักษณะเด่นจากโครงข่ายประสาทเทียมแบบคอนโวลูชัน ซึ่งเป็นที่นิยมในปัจจุบันในงานรู้จำรูปภาพหรือจำแนกรูปภาพ

3.1 การเตรียมชุดข้อมูลทดสอบแบบอย่างง่าย

ในการทดสอบกับข้อมูลแบบอย่างง่าย ค่าของอินพุตจะถูกกำหนดไว้ให้เป็น 0 และ 1 เท่านั้น โดยทำการแบ่งกลุ่มชุดข้อมูลออกเป็น 3 กลุ่ม มีข้อมูลกลุ่มละ 4 ชุดข้อมูล ดังแสดงในตารางที่ 1


ตารางที่ 1 ชุดข้อมูลที่ใช้ในการทดสอบแบบอย่างง่าย

ลำดับที่	อินพุต										กลุ่ม
1	1	1	1	1	1	0	0	0	0	0	1
2	1	1	1	1	0	0	0	0	0	0	1
3	1	1	1	0	0	0	0	0	0	0	1
4	1	1	0	0	0	0	0	0	0	0	1
5	0	0	0	0	0	1	1	1	1	1	2
6	0	0	0	0	0	0	1	1	1	1	2
7	0	0	0	0	0	0	0	1	1	1	2
8	0	0	0	0	0	0	0	0	1	1	2
9	0	0	1	1	1	1	1	1	0	0	3
10	0	0	0	1	1	1	1	0	0	0	3
11	1	1	1	0	0	0	0	1	1	1	3
12	1	1	0	0	0	0	0	0	1	1	3

จากข้อมูลที่แสดงในตารางที่ 1 เป็นชุดข้อมูลที่ใช้ในการเรียนรู้ของโครงข่ายประสาทเทียม ในการทดสอบจะทำการทดสอบกับข้อมูลที่เคยเรียนรู้มาแล้วและข้อมูลชุดใหม่ที่ไม่เคยเรียนรู้และแสดงผลการทดสอบในหัวข้อต่อไป

3.2 การเตรียมชุดข้อมูลทดสอบที่มีความซับซ้อน

ชุดข้อมูลที่ใช้ในการทดสอบนี้ได้มาจากกระบวนการสกัดคุณลักษณะเด่นด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน[5] ซึ่งกลุ่มของข้อมูลนั้นเป็นรูปภาพของโรคที่เกิดขึ้นบนใบองุ่น ทั้งหมด 3 โรค คือ Downey, Rust และ Scab ใช้ตัวอย่างรูปภาพกลุ่มละ 50 ภาพ รวมทั้งหมด 150 ภาพ โดยรูปแบบการสกัดลักษณะเด่นแสดงในรูปภาพที่ 3



รูปที่ 3 การสกัดคุณลักษณะเด่นด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน

4. ผลการทดสอบ

ในกระบวนการทดสอบประสิทธิภาพของโครงข่ายประสาทเทียมที่พัฒนาขึ้นนั้นจะทำการทดสอบกับชุดข้อมูลที่เคยได้เรียนรู้แล้วและชุดข้อมูลใหม่ที่โครงข่ายประสาทเทียมไม่เคยเรียนรู้ พร้อมทำการเปรียบเทียบกับโครงข่ายแบบดั้งเดิม ดังแสดงในตารางที่ 2 และ 3

ตารางที่ 2 ผลการทดสอบกับอินพุตแบบอย่างง่าย

พารามิเตอร์ (เริ่มต้น)	SFAM (ดั้งเดิม)		SFAM Adaptive Multi-Vigilance	
	ความถูกต้อง(%)		ความถูกต้อง(%)	
ρ_n	เคยสอนแล้ว	ข้อมูลใหม่	เคยสอนแล้ว	ข้อมูลใหม่
0.10	100	100	100	100
0.20	100	100	100	100
0.50	100	100	100	100
0.70	100	83.33	100	100
0.90	100	50.00	100	83.33

ตารางที่ 3 ผลการทดสอบกับอินพุตแบบอย่างง่าย กำหนด ρ_n เริ่มต้นเท่ากับ 0.7

ชนิดโรค	SFAM (ดั้งเดิม)		SFAM Adaptive Multi-Vigilance	
	ความถูกต้อง(%)		ความถูกต้อง(%)	
	เคยสอนแล้ว	ข้อมูลใหม่	เคยสอนแล้ว	ข้อมูลใหม่
Downey	100	90	100	96
Rust	100	96	100	96
Scab	100	92	100	94

5. สรุป

ในงานวิจัยนี้นำเสนอโครงข่ายทฤษฎีพีซีซีเรโซแนนซ์แบบปรับตัวอย่างง่ายที่มีการพัฒนากระบวนการเรียนรู้ด้วยหลักการปรับตัวของพารามิเตอร์สอดส่องให้มีความเหมาะสมกับรูปแบบของชุดข้อมูลที่ถูกป้อนเข้ามาและเพิ่มความยืดหยุ่นของโครงข่ายด้วยหลักการกำหนดค่าพารามิเตอร์สอดส่องแบบหลายค่าเพื่อให้ง่ายต่อการปรับค่าพารามิเตอร์สอดส่องประจำกลุ่มน้ำหนักประสาทไม่ส่งผลกระทบต่อการเรียนรู้ในกลุ่มอื่น ๆ โดยทำการทดสอบกับข้อมูล 2 รูปแบบ คือกลุ่มข้อมูลในรูปแบบอย่างง่าย และข้อมูลที่มีรูปแบบซับซ้อน จากผลการทดสอบในตารางที่ 2 และตารางที่ 3 โครงข่ายทั้งสองรูปแบบสามารถให้คำตอบที่ถูกต้อง 100% กับชุดข้อมูลที่เคยเรียนรู้มาแล้ว และในกรณีทดสอบกับข้อมูลใหม่ที่ไม่เคยเรียนรู้ โครงข่ายประสาทเทียมที่นำเสนอมีเปอร์เซ็นต์ความ

ถูกต้องเฉลี่ยที่สูงกว่า โดยมีค่าเท่ากับ 96.67% ในขณะที่โครงข่ายแบบดั้งเดิมมีความถูกต้องเฉลี่ยอยู่ที่ 86.67% สำหรับชุดข้อมูลอย่างง่าย เมื่อทำการทดสอบกับชุดข้อมูลที่มีความซับซ้อน โครงข่ายที่นำเสนอสามารถให้ประสิทธิภาพที่ดีกว่าเช่นกัน โดยมีเปอร์เซ็นต์ความถูกต้องเฉลี่ยที่ 95.33% และโครงข่ายแบบดั้งเดิมมีเปอร์เซ็นต์ความถูกต้องเฉลี่ยที่ 92.66% โดยเมื่อค่าเริ่มต้นของพารามิเตอร์สอดส่องเพิ่มขึ้นจะแสดงถึงเงื่อนไขการตรวจสอบความคล้ายที่สูงขึ้นทำให้โครงข่ายแบบดั้งเดิมที่ไม่มีการปรับค่าพารามิเตอร์สอดส่องไม่สามารถให้คำตอบที่ถูกต้องได้เนื่องจากไม่ผ่านเงื่อนไขตรวจสอบความคล้าย ในขณะที่โครงข่ายประสาทเทียมที่นำเสนอในบทความนี้มีการปรับค่าพารามิเตอร์สอดส่องให้ลดลงเมื่อมีการปรับค่าน้ำหนักประสาทในแต่ละกลุ่มหรือเพิ่มขึ้นเมื่อมีการสร้างค่าน้ำหนักประสาทค่าใหม่ จึงส่งผลให้โครงข่ายสามารถให้คำตอบได้อย่างถูกต้องมากขึ้น

เอกสารอ้างอิง

- [1] F. Y. Wang, "AI and Intelligent Vehicles Future Challenge (IVFC) in China: From cognitive intelligence to parallel intelligence," *2017 ITU Kaleidoscope: Challenges for a Data-Driven Society (ITU K)*, pp. 1-2, 2017.
- [2] M. T. Islam, B. M. N. Karim Siddique, S. Rahman and T. Jabid, "Image Recognition with Deep Learning," *2018 International Conference on Intelligent Informatics and Biomedical Sciences (ICIIBMS)*, pp. 106-110, 2018.
- [3] S. Le Moan and D. Bailey, "Comparison of machine learning-based feature pooling strategies for colour image fidelity assessment," *2017 International Conference on Image and Vision Computing New Zealand (IVCNZ)*, pp. 1-5, 2017.
- [4] K. Phookronghin, A. Srikaew, K. Attakitmongkol and P. Kumsawat, "2 Level Simplified Fuzzy ARTMAP for Grape Leaf Disease System Using Color Imagery and Gray Level Co-Occurrence Matrix," *2018 International Electrical Engineering Congress (IEECON)*, pp. 1-4, 2018.
- [5] E. David, P. Ungureanu and L. Goras, "On the Feature Extraction Performances of CNN Gabor-Type Filters in Texture Recognition Applications," *2006 10th International Workshop on Cellular Neural Networks and Their Applications, Istanbul, Turkey*, pp. 1-6, 2006.