

สำนักหอสมุดกลาง พระจอมเกล้าลาดกระบัง

การปรับปรุงประสิทธิภาพโครงข่ายประสาทเทียมแบบหลายชั้น
ที่ใช้การเรียนรู้แบบแพร่ย้อนกลับ โดยใช้ค่าน้ำหนักแบบหลายเซกเมนต์

IMPROVING THE PERFORMANCE OF MULTI-LAYER BACKPROPAGATION
NEURAL NETWORKS USING MULTI-SEGMENT CONNECTION WEIGHTS



T117078

พงษ์เทพ รักผกาวงศ์
PHONGTHEP RUXPAKAWONG

ฉพ.

พ/56 ก

2553

เลขที่

117078

เลขทะเบียน

วันเดือนปี 23 ส.ค. 2554

b...12319302
i.....

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาตรีบัณฑิต

สาขาวิชาเทคโนโลยีสารสนเทศ

คณะเทคโนโลยีสารสนเทศ

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ.2553

KMITL-2010-IT-D-001-002

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

IMPROVING THE PERFORMANCE OF MULTI-LAYER BACKPROPAGATION
NEURAL NETWORKS USING MULTI-SEGMENT CONNECTION WEIGHTS



A THESIS SUBMITTED IN PARTIAL FULFILLMENT
OF THE REQUIREMENT FOR THE DEGREE OF
DOCTOR OF PHILOSOPHY PROGRAM IN INFORMATION TECHNOLOGY
FACULTY OF INFORMATION TECHNOLOGY
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

2010

KMITL-2010-IT-D-001-002

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2010

FACULTY OF INFORMATION TECHNOLOGY

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

คณะเทคโนโลยีสารสนเทศ
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
ใบรับรองวิทยานิพนธ์

หัวข้อวิทยานิพนธ์ การปรับปรุงประสิทธิภาพโครงข่ายประสาทเทียมแบบหลายชั้น ที่ใช้การเรียนรู้แบบแพร่ย้อนกลับ โดยใช้ค่าน้ำหนักแบบหลายเซกเมนต์
Improving the Performance of Multi-Layer Backpropagation Neural Networks Using Multi-Segment Connection Weights
นักศึกษา นายพงษ์เทพ รักผกาวงศ์
รหัสประจำตัว 47066002
ปริญญา ปรัชญาคุณวุฒิบัณฑิต
สาขาวิชา เทคโนโลยีสารสนเทศ
อาจารย์ที่ปรึกษาวิทยานิพนธ์ รองศาสตราจารย์ ดร.อาริต ธรรมโน

คณะกรรมการสอบวิทยานิพนธ์	ลายมือชื่อ
ศาสตราจารย์ ดร.ชิตชนก เหลือสินทรัพย์ รองศาสตราจารย์ ดร.อาริต ธรรมโน ผู้ช่วยศาสตราจารย์ ดร.ภัทรชัย สถิตโรจน์วงศ์ รองศาสตราจารย์ ดร.วรพจน์ กวีสุระเดช ผู้ช่วยศาสตราจารย์ ดร.พรฤดี เนติโสภากุล	

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

วัน/เดือน/ปี ที่สอบ วันศุกร์ที่ 30 กรกฎาคม 2553 เวลา 10.00 น.

สถานที่สอบ ณ ห้อง 328 ชั้น 3 คณะเทคโนโลยีสารสนเทศ

คณะเทคโนโลยีสารสนเทศที่รับรองแล้ว



(รองศาสตราจารย์ ดร.ฉันทนรินทร์ สถิตวิริยวงศ์)

คณบดีคณะเทคโนโลยีสารสนเทศ

วันที่ 2 เดือน กันยายน พ.ศ. 2553

สำนักทะเบียนและประมวลผล สจล.

วันที่ส่งเล่มวิทยานิพนธ์ วันสมบูรณ์

วันที่ 2 เดือน สิงหาคม พ.ศ. 2553

ลงชื่อ.....

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อวิทยานิพนธ์	การปรับปรุงประสิทธิภาพโครงข่ายประสาทเทียมแบบหลายชั้นที่ใช้การเรียนรู้แบบแพร่ย้อนกลับ โดยใช้ค่าน้ำหนักแบบหลายเซกเมนต์
นักศึกษา	พงษ์เทพ รักศกาวงศ์
รหัสประจำตัว	47066002
ปริญญา	ปรัชญาดุษฎีบัณฑิต
สาขาวิชา	เทคโนโลยีสารสนเทศ
พ.ศ.	2553
อาจารย์ผู้ควบคุมวิทยานิพนธ์	รศ. ดร. อาริต ธรรมโน

บทคัดย่อ

โครงข่ายประสาทเทียมแบบหลายชั้น (Multi-layer neural networks) เป็นโครงข่ายที่นิยมนำไปประยุกต์ใช้กับงานหลายด้าน เช่น การรู้จำอักษร การรู้จำภาพใบหน้า การรู้จำเสียง ซึ่งใช้อัลกอริทึมการเรียนรู้แบบแพร่กระจายย้อนกลับ (Back propagation learning algorithm) โดยการพยายามปรับค่าน้ำหนักภายในโครงข่าย เพื่อให้ผลที่ถูกต้องตามค่าเป้าหมายที่กำหนด และได้มีการพัฒนาโครงข่ายฯ โดยการปรับเปลี่ยน โครงสร้างของโครงข่ายฯ เป็นแบบรีเคอร์เรนต์ (Recurrent Neural Network) เพื่อใช้งานด้านการพยากรณ์ข้อมูล โดยยังคงใช้อัลกอริทึมและค่าน้ำหนักแบบเดิม ซึ่งการพัฒนาดังกล่าวเป็นลักษณะการปรับปรุง โครงสร้างโครงข่ายฯ เพื่อใช้งานกับข้อมูลอีกประเภทหนึ่ง ส่วนในงานวิจัยนี้เป็นการปรับปรุงเพื่อให้ได้ผลที่ถูกต้องมากยิ่งขึ้น โดยปรับส่วนค่าน้ำหนักให้ใช้ค่าน้ำหนักแบบหลายเซกเมนต์ และปรับอัลกอริทึมที่เกี่ยวข้องกับค่าน้ำหนักนั้น ซึ่งสามารถใช้ได้ทั้งแบบป้อนไปข้างหน้า (Feed forward neural network) และแบบรีเคอร์เรนต์ จากการทดลองโดยนำโครงข่ายฯ ประยุกต์ใช้กับการจำแนกข้อมูล (Classification) การประมาณฟังก์ชัน (Function approximation) และการพยากรณ์ (Forecast) การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ให้ผลความถูกต้องมากยิ่งขึ้น และยังมีขนาดของโครงข่ายฯ ที่เล็กกว่าแบบของเดิมในการทดลองกับบางชนิดข้อมูลอีกด้วย

Thesis Title	Improving the Performance of Multi-Layer Backpropagation Neural Networks Using Multi-Segment Connection Weights
Student	Phongthep Ruxpakawong
Student ID.	47066002
Degree	Doctor of Philosophy
Programme	Information Technology
Year	2010
Thesis Advisor	Assoc. Prof. Dr. Arit Thammano

ABSTRACT

Multi-Layer Neural Networks (MLNN) are the most widely used neural network. It is applied to use in several areas such as character recognition, facial image recognition, and voice recognition. Many previous research works have done a lot of improvement over the standard multi-layer neural network. However, those works emphasize mainly on the modification of the neural network structure. In this research, the proposed network improves the original network by replacing the single weight value of the original network with the multi-segment connection weights. Also the backpropagation learning algorithm is adjusted in order to accommodate the above modification. Two types of neural networks are experimented: feed-forward and recurrent neural networks. The problems that the proposed network has been applied to include data classification, function approximation and data forecast. From the experiment results, the proposed network was found to be superior than the other 3 neural networks in terms of accuracy and size of neural network.

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงได้อย่างดี ด้วยความกรุณา จาก รศ.ดร.อาริต ธรรมโน ซึ่งเป็นอาจารย์ที่ปรึกษาวิทยานิพนธ์ ผู้วิจัยรู้สึกซาบซึ้งในความอนุเคราะห์จากท่านและขอกราบขอบพระคุณเป็นอย่างสูง

ขอขอบคุณอาจารย์คณะเทคโนโลยีสารสนเทศทุกท่าน ที่ประสิทธิประสาทวิชาความรู้ พร้อมทั้งคำแนะนำต่างๆ ซึ่งสามารถนำความรู้ที่ได้รับมาช่วยเพิ่มประสิทธิภาพในงานวิจัยนี้ได้เป็นอย่างดี

ขอขอบคุณเจ้าหน้าที่คณะเทคโนโลยีสารสนเทศทุกท่านที่อำนวยความสะดวกด้านเอกสาร และติดต่อประสานงานต่างๆ ซึ่งทำให้การทำงานวิจัยดำเนินไปโดยสะดวก และสำเร็จลุล่วงด้วยดี

ขอขอบคุณเพื่อนๆ พี่ๆ และน้องๆ นักศึกษาทุกท่านที่ให้ความช่วยเหลือ คำแนะนำ พร้อมทั้งช่วยวิเคราะห์ แก้ไขทฤษฎีต่างๆ และเป็นกำลังใจให้งานวิจัยสำเร็จสมบูรณ์ยิ่งขึ้น

ขอขอบคุณบิดา มารดา ผู้ให้กำเนิด ภรรยาอันเป็นที่รัก และลูกๆ ทั้ง 3 คน ที่สนับสนุนให้ศึกษาหาวิชาความรู้ และเป็นกำลังใจให้สามารถทำงานวิทยานิพนธ์นี้จนสำเร็จ

สุดท้ายขอขอบคุณมหาวิทยาลัยราชภัฏพิบูลสงคราม ที่ได้ให้ทุนสนับสนุนการศึกษา และการทำวิทยานิพนธ์ครั้งนี้

คุณค่า คุณงามความดีและประโยชน์อันพึงมีจากวิทยานิพนธ์ฉบับนี้ ผู้วิจัยขอบอบแต่ผู้มีพระคุณทุกท่าน

พงษ์เทพ รักผกาวงศ์

สารบัญ

หน้า

บทคัดย่อภาษาไทย	I
บทคัดย่อภาษาอังกฤษ	II
กิตติกรรมประกาศ.....	III
สารบัญ	IV
สารบัญตาราง	VIII
สารบัญรูป	XII

บทที่ 1 บทนำ	1
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของงานวิจัย.....	2
1.3 ขอบเขตของงานวิจัย	2
1.4 ขั้นตอนการทำวิจัย	2
1.5 ประโยชน์ที่คาดว่าจะได้รับ	2
1.6 โครงสร้างวิทยานิพนธ์.....	3

บทที่ 2 งานวิจัยที่เกี่ยวข้อง.....	4
2.1 โครงข่ายประสาทเทียมแบบแพร่กระจายย้อนกลับ.....	4
2.1.1 ชั้นข้อมูลเข้า (Input Layer).....	4
2.1.2 ชั้นซ่อน (Hidden Layer).....	5
2.1.3 ชั้นข้อมูลออก (Output Layer).....	6
2.1.4 การเรียนรู้แบบแพร่กระจายย้อนกลับ.....	7
2.2 โครงข่ายประสาทเทียมรีเคอร์เรนต์แบบ Jordan (Jordan Recurrent Neural Network).....	8
2.2.1 ชั้นข้อมูลเข้า (Input Layer).....	9
2.2.2 ชั้นซ่อน (Hidden Layer).....	10
2.2.3 ชั้นข้อมูลออก (Output Layer).....	10
2.2.4 การเรียนรู้แบบแพร่กระจายย้อนกลับ	10
2.3 โครงข่ายประสาทเทียมรีเคอร์เรนต์แบบ Elman (Elman Recurrent Neural Network).....	11
2.3.1 ชั้นข้อมูลเข้า (Input Layer).....	11
2.3.2 ชั้นซ่อน (Hidden Layer).....	12

สารบัญ (ต่อ)

หน้า

2.3.3	ชั้นข้อมูลออก (Output Layer).....	12
2.3.4	การเรียนรู้แบบแพร่กระจายย้อนกลับ.....	12
2.4	งานวิจัยที่เกี่ยวข้อง.....	12
2.4.1	A Comparative Study of Recurrent Neural Network Architectures on Learning Temporal Sequences.....	13
2.4.2	Dynamic Properties of Elman and Modified Elman Neural Network.....	14
2.4.3	The Property of PID Elman Neural Network and Its Application in Identification of Hydraulic Unit.....	15
2.4.4	A New Recurrent Neural-Network Architecture for Visual Pattern Recognition.....	16
2.4.5	A fuzzy backpropagation algorithm.....	17
2.4.6	A Neural Multiclassifier System for Object Recognition in Robotic Vision Applications.....	19
2.4.7	การรู้จำลายมือตัวอักษรภาษาไทยแบบออนไลน์.....	19
2.4.8	การรู้จำตัวอักษรภาษาไทยและภาษาอังกฤษโดยใช้เครือข่ายประสาท.....	20
2.4.9	เทคนิคการวิเคราะห์อนุกรมเวลาสำหรับการพยากรณ์ปริมาณผลผลิตผักและผลไม้.....	20
2.5	เทคนิคการพยากรณ์.....	21
2.5.1	ประเภทการพยากรณ์.....	21
2.5.2	การวัดระดับความถูกต้อง.....	22
2.6	ข้อมูลอนุกรมเวลา (Time Series).....	23
2.6.1	ข้อมูลอนุกรมเวลาแบบแนวโน้ม (Trend Time Series).....	23
2.6.2	ข้อมูลอนุกรมเวลาแบบฤดูกาล (Seasonal Time Series).....	24
2.6.3	ข้อมูลอนุกรมเวลาแบบวัฏจักร (Cycle Time Series).....	24
2.6.4	ข้อมูลอนุกรมเวลาแบบผิดปกติ (Irregular).....	25
บทที่ 3 แนวทางการวิจัย.....		26
3.1	การรู้จำของโครงข่ายฯที่ใช้ค่าน้ำหนักแบบเดิม.....	26
3.2	อัลกอริทึมโครงข่ายประสาทเทียมกับการใช้ค่าน้ำหนักแบบหลายเซกเมนต์.....	28

สารบัญ (ต่อ)

หน้า

3.3	การเพิ่มเซกเมนต์ของค่าน้ำหนักในขั้นตอนการสุ่มค่าน้ำหนัก.....	34	
3.4	การเพิ่มเซกเมนต์ของค่าน้ำหนักในระหว่างการเรียนรู้.....	35	
3.5	การลบตำแหน่งอ้างอิงค่าน้ำหนักที่ไม่ได้ใช้ในระหว่างการเรียนรู้.....	40	
3.6	สรุป.....	41	
บทที่ 4 การทดลองและผลการทดลอง.....			43
4.1	ประเภทการจำแนกข้อมูล (Classification).....	43	
4.2	ประเภทการประมาณฟังก์ชัน (Function Approximation).....	48	
4.2.1	ระบบความอลวน แบบ 1 มิติ.....	48	
4.2.2	ระบบความอลวน แบบ 2 มิติ.....	49	
4.2.3	ระบบความอลวน แบบ 3 มิติ.....	50	
4.2.4	ระบบความอลวน แบบ 4 มิติ.....	53	
4.3	ประเภทการพยากรณ์ (Forecast).....	57	
4.4	สรุป.....	60	
บทที่ 5 สรุปผลงานวิจัยและข้อเสนอแนะ.....			61
5.1	สรุปผลงานวิจัย.....	61	
5.2	การนำงานวิจัยไปใช้.....	61	
5.3	ปัญหาที่พบในงานวิจัยนี้.....	61	
5.4	แนวทางการพัฒนาในอนาคต.....	62	
บรรณานุกรม.....			63
ภาคผนวก ก. ผลการทดลองและสถิติผลการทดลอง กับงานการจำแนกข้อมูล.....			66
ภาคผนวก ข. ผลการทดลองและสถิติผลการทดลอง กับงานระบบความอลวน.....			90
ภาคผนวก ค. ผลการทดลองและสถิติผลการทดลอง กับงานการพยากรณ์.....			124
ภาคผนวก ง. ผลงานการตีพิมพ์.....			155
Feedforward Neural Network with Multi-valued Connection Weights.....			156
Dynamic System Identification Using Recurrent Neural Network with Multi-Valued Connection Weight.....			165

สารบัญ (ต่อ)

หน้า

Nonlinear dynamic system identification using recurrent neural network with multi-segment piecewise-linear connection weight	171
ประวัติผู้เขียน	181



VII

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญตาราง

ตารางที่	หน้า
2.1	เปรียบเทียบอัตราความผิดพลาดในการรู้จำลายมือเขียนตัวเลข โดยใช้โครงข่ายแบบต่างๆ ...17
3.1	ผลการคูณ39
4.1	ผลการทดลองของโครงข่ายกับการจำแนกข้อมูล46
4.2	ค่าเฉลี่ยรวมเมื่อใช้จำนวนโหนดที่เท่ากัน ในงานด้านการจำแนกข้อมูล47
4.2	ผลการทดลองของโครงข่ายกับระบบความอลวน55
4.3	ค่าเฉลี่ยรวมเมื่อใช้จำนวนโหนดที่เท่ากัน กับระบบความอลวน56
4.4	ผลการทดลองของโครงข่ายกับการพยากรณ์58
4.4	ค่าเฉลี่ยรวมเมื่อใช้จำนวนโหนดที่เท่ากัน ในงานด้านการพยากรณ์59
ก.1	ผลการทดลองและสถิติของข้อมูล austra โดยใช้ Feed forward NN.67
ก.2	ผลการทดลองและสถิติของข้อมูล balance-scale โดยใช้ Feed forward NN.68
ก.3	ผลการทดลองและสถิติของข้อมูล Breast โดยใช้ Feed forward NN.69
ก.4	ผลการทดลองและสถิติของข้อมูล Diabetes โดยใช้ Feed forward NN.70
ก.5	ผลการทดลองและสถิติของข้อมูล Donat โดยใช้ Feed forward NN.71
ก.6	ผลการทดลองและสถิติของข้อมูล Fan โดยใช้ Feed forward NN.72
ก.7	ผลการทดลองและสถิติของข้อมูล Flower 1 โดยใช้ Feed forward NN.73
ก.8	ผลการทดลองและสถิติของข้อมูล Flower 2 โดยใช้ Feed forward NN.74
ก.9	ผลการทดลองและสถิติของข้อมูล Glass โดยใช้ Feed forward NN.75
ก.10	ผลการทดลองและสถิติของข้อมูล Haberman โดยใช้ Feed forward NN.76
ก.11	ผลการทดลองและสถิติของข้อมูล Image โดยใช้ Feed forward NN.77
ก.12	ผลการทดลองและสถิติของข้อมูล Ionosphere โดยใช้ Feed forward NN.78
ก.13	ผลการทดลองและสถิติของข้อมูล Iris โดยใช้ Feed forward NN.79
ก.14	ผลการทดลองและสถิติของข้อมูล Nine โดยใช้ Feed forward NN.80
ก.15	ผลการทดลองและสถิติของข้อมูล Pima โดยใช้ Feed forward NN.81
ก.16	ผลการทดลองและสถิติของข้อมูล Sawtooth โดยใช้ Feed forward NN.82
ก.17	ผลการทดลองและสถิติของข้อมูล Sigsag โดยใช้ Feed forward NN.83
ก.18	ผลการทดลองและสถิติของข้อมูล Sona โดยใช้ Feed forward NN.84
ก.19	ผลการทดลองและสถิติของข้อมูล Spectf โดยใช้ Feed forward NN.85
ก.20	ผลการทดลองและสถิติของข้อมูล Spiral โดยใช้ Feed forward NN.86
ก.21	ผลการทดลองและสถิติของข้อมูล Vehicle โดยใช้ Feed forward NN.87
ก.22	ผลการทดลองและสถิติของข้อมูล Vowel โดยใช้ Feed forward NN.88

สารบัญตาราง (ต่อ)

ตารางที่	หน้า
ก.23 ผลการทดลองและสถิติของข้อมูล Yeast โดยใช้ Feed forward NN.....	89
ข.1 ผลการทดลองและสถิติของข้อมูล Mackey-Glass โดยใช้ Feed forward NN.....	91
ข.2 ผลการทดลองและสถิติของข้อมูล Mackey-Glass โดยใช้ Elman Recurrent NN.....	92
ข.3 ผลการทดลองและสถิติของข้อมูล Mackey-Glass โดยใช้ Jordan Recurrent NN.....	93
ข.4 ผลการทดลองและสถิติของข้อมูล logistic โดยใช้ Feed forward NN.....	94
ข.5 ผลการทดลองและสถิติของข้อมูล logistic โดยใช้ Elman Recurrent NN.....	95
ข.6 ผลการทดลองและสถิติของข้อมูล logistic โดยใช้ Jordan Recurrent NN.....	96
ข.7 ผลการทดลองและสถิติของข้อมูล henon โดยใช้ Feed forward NN.....	97
ข.8 ผลการทดลองและสถิติของข้อมูล henon โดยใช้ Elman Recurrent NN.....	98
ข.9 ผลการทดลองและสถิติของข้อมูล henon โดยใช้ Jordan Recurrent NN.....	99
ข.10 ผลการทดลองและสถิติของข้อมูล Ikeda โดยใช้ Feed forward NN.....	100
ข.11 ผลการทดลองและสถิติของข้อมูล Ikeda โดยใช้ Elman Recurrent NN.....	101
ข.12 ผลการทดลองและสถิติของข้อมูล Ikeda โดยใช้ Jordan Recurrent NN.....	102
ข.13 ผลการทดลองและสถิติของข้อมูล R?ssler โดยใช้ Feed forward NN.....	103
ข.14 ผลการทดลองและสถิติของข้อมูล R?ssler โดยใช้ Elman Recurrent NN.....	104
ข.15 ผลการทดลองและสถิติของข้อมูล R?ssler โดยใช้ Jordan Recurrent NN.....	105
ข.16 ผลการทดลองและสถิติของข้อมูล ChuaCirc โดยใช้ Feed forward NN.....	106
ข.17 ผลการทดลองและสถิติของข้อมูล ChuaCirc โดยใช้ Elman Recurrent NN.....	107
ข.18 ผลการทดลองและสถิติของข้อมูล ChuaCirc โดยใช้ Jordan Recurrent NN.....	108
ข.19 ผลการทดลองและสถิติของข้อมูล ChuaCircCN โดยใช้ Feed forward NN.....	109
ข.20 ผลการทดลองและสถิติของข้อมูล ChuaCircCN โดยใช้ Elman Recurrent NN.....	110
ข.21 ผลการทดลองและสถิติของข้อมูล ChuaCircCN โดยใช้ Jordan Recurrent NN.....	111
ข.22 ผลการทดลองและสถิติของข้อมูล Lorenz โดยใช้ Feed forward NN.....	112
ข.23 ผลการทดลองและสถิติของข้อมูล Lorenz โดยใช้ Elman Recurrent NN.....	113
ข.24 ผลการทดลองและสถิติของข้อมูล Lorenz โดยใช้ Jordan Recurrent NN.....	114
ข.25 ผลการทดลองและสถิติของข้อมูล Colpitts Oscillator โดยใช้ Feed forward NN.....	115
ข.26 ผลการทดลองและสถิติของข้อมูล Colpitts Oscillator โดยใช้ Elman Recurrent NN.....	116
ข.27 ผลการทดลองและสถิติของข้อมูล Colpitts Oscillator โดยใช้ Jordan Recurrent NN.....	117
ข.28 ผลการทดลองและสถิติของข้อมูล RC chaotic Oscillator โดยใช้ Feed forward NN.....	118
ข.29 ผลการทดลองและสถิติของข้อมูล RC chaotic Oscillator โดยใช้ Elman Recurrent NN.....	119

สารบัญตาราง (ต่อ)

ตารางที่	หน้า
ข.30 ผลการทดลองและสถิติของข้อมูล RC chaotic Oscillator โดยใช้ Jordan Recurrent NN.	120
ข.31 ผลการทดลองและสถิติของข้อมูล Autonomous4DCirc โดยใช้ Feed forward NN.	121
ข.32 ผลการทดลองและสถิติของข้อมูล Autonomous4DCirc โดยใช้ Elman Recurrent NN.....	122
ข.33 ผลการทดลองและสถิติของข้อมูล Autonomous4DCirc โดยใช้ Jordan Recurrent NN.	123
ค.1 ผลการทดลองและสถิติของข้อมูล arge030 โดยใช้ Feed forward NN.	125
ค.2 ผลการทดลองและสถิติของข้อมูล arge030 โดยใช้ Elman Recurrent NN.	126
ค.3 ผลการทดลองและสถิติของข้อมูล arge030 โดยใช้ Jordan Recurrent NN.	127
ค.4 ผลการทดลองและสถิติของข้อมูล ausl006 โดยใช้ Feed forward NN.	128
ค.5 ผลการทดลองและสถิติของข้อมูล ausl006 โดยใช้ Elman Recurrent NN.....	129
ค.6 ผลการทดลองและสถิติของข้อมูล ausl006 โดยใช้ Jordan Recurrent NN.	130
ค.7 ผลการทดลองและสถิติของข้อมูล az510 โดยใช้ Feed forward NN.	131
ค.8 ผลการทดลองและสถิติของข้อมูล az510 โดยใช้ Elman Recurrent NN.....	132
ค.9 ผลการทดลองและสถิติของข้อมูล az510 โดยใช้ Jordan Recurrent NN.	133
ค.10 ผลการทดลองและสถิติของข้อมูล beer โดยใช้ Feed forward NN.	134
ค.11 ผลการทดลองและสถิติของข้อมูล beer โดยใช้ Elman Recurrent NN.	135
ค.12 ผลการทดลองและสถิติของข้อมูล beer โดยใช้ Jordan Recurrent NN.	136
ค.13 ผลการทดลองและสถิติของข้อมูล co522 โดยใช้ Feed forward NN.	137
ค.14 ผลการทดลองและสถิติของข้อมูล co522 โดยใช้ Elman Recurrent NN.	138
ค.15 ผลการทดลองและสถิติของข้อมูล co522 โดยใช้ Jordan Recurrent NN.	139
ค.16 ผลการทดลองและสถิติของข้อมูล dj โดยใช้ Feed forward NN.....	140
ค.17 ผลการทดลองและสถิติของข้อมูล dj โดยใช้ Elman Recurrent NN.	141
ค.18 ผลการทดลองและสถิติของข้อมูล dj โดยใช้ Jordan Recurrent NN.....	142
ค.19 ผลการทดลองและสถิติของข้อมูล pigs โดยใช้ Feed forward NN.	143
ค.20 ผลการทดลองและสถิติของข้อมูล pigs โดยใช้ Elman Recurrent NN.	144
ค.21 ผลการทดลองและสถิติของข้อมูล pigs โดยใช้ Jordan Recurrent NN.	145
ค.22 ผลการทดลองและสถิติของข้อมูล rawsteel โดยใช้ Feed forward NN.....	146
ค.23 ผลการทดลองและสถิติของข้อมูล rawsteel โดยใช้ Elman Recurrent NN.....	147
ค.24 ผลการทดลองและสถิติของข้อมูล rawsteel โดยใช้ Jordan Recurrent NN.....	148
ค.25 ผลการทดลองและสถิติของข้อมูล sp500 โดยใช้ Feed forward NN.	149
ค.26 ผลการทดลองและสถิติของข้อมูล sp500 โดยใช้ Elman Recurrent NN.....	150

สารบัญตาราง (ต่อ)

ตารางที่	หน้า
ก.27 ผลการทดลองและสถิติของข้อมูล sp500 โดยใช้ Jordan Recurrent NN.	151
ก.28 ผลการทดลองและสถิติของข้อมูล sunplus โดยใช้ Feed forward NN.	152
ก.29 ผลการทดลองและสถิติของข้อมูล sunplus โดยใช้ Elman Recurrent NN.	153
ก.30 ผลการทดลองและสถิติของข้อมูล sunplus โดยใช้ Jordan Recurrent NN.	154



สารบัญรูป

รูปที่	หน้า
2.1	แผนภาพโครงข่ายประสาทเทียมแบบแพร่กระจายย้อนกลับ.....4
2.2	กราฟฟังก์ชัน sigmoid6
2.3	โครงข่ายประสาทเทียมรีเคอร์เรนต์แบบ Jordan9
2.4	โครงข่ายประสาทเทียมรีเคอร์เรนต์แบบ Elman.....11
2.5	โครงข่ายประสาทเทียมแบบ Chen and Soo 13
2.6	โครงข่ายประสาทเทียมแบบ Cheng, Qi, and Cai.....14
2.7	โครงข่ายประสาทเทียมแบบ Elman ที่มีคุณสมบัติ PID15
2.8	โครงข่ายประสาทเทียมแบบ Seong-Whan Lee และ Hee-Heon Song16
2.9	ตัวอย่างลายมือเขียนตัวเลขบนซองจดหมาย.....17
2.10	ข้อมูลอนุกรมเวลาแบบแนวโน้ม23
2.11	ข้อมูลอนุกรมเวลาแบบฤดูกาล24
2.12	ข้อมูลอนุกรมเวลาแบบวัฏจักร24
2.13	ข้อมูลอนุกรมเวลาแบบผิดปกติ25
3.1	กราฟแสดงลักษณะข้อมูล mine.....26
3.2	กราฟค่าน้ำหนักแบบค่าเดียว และกราฟค่าน้ำหนักแบบใหม่.....27
3.3	ตัวอย่างกราฟค่าน้ำหนักแบบเซกเมนต์.....28
3.4	ตัวอย่างกราฟค่าน้ำหนักแบบ 2 เซกเมนต์หลังจากผ่านการเรียนรู้.....35
3.5	ตัวอย่างกราฟค่าน้ำหนัก ก่อนและหลังการลบตำแหน่งอ้างอิงค่าน้ำหนัก41
4.1	กราฟแสดงลักษณะข้อมูลที่สร้างขึ้นเอง.....44
4.2	กราฟแสดงลักษณะข้อมูลลวน 1 มิติ.....49
4.3	กราฟแสดงลักษณะข้อมูลลวน 2 มิติ50
4.4	กราฟแสดงลักษณะข้อมูลลวน 3 มิติ52
4.5	กราฟแสดงลักษณะข้อมูลลวน 4 มิติ54

1.2 วัตถุประสงค์ของงานวิจัย

งานวิจัยนี้มีวัตถุประสงค์ เพื่อปรับปรุง โครงข่ายประสาทเทียมที่ใช้อัลกอริทึมการเรียนรู้แบบแพร่กระจายย้อนกลับ ให้สามารถเรียนรู้ข้อมูลที่มีความซับซ้อนมากขึ้น และให้ผลการรู้จำที่ดีขึ้น โดยยังคงความสามารถด้านอื่นๆของโครงข่ายฯไม่ให้ด้อยไปกว่าเดิม

1.3 ขอบเขตของงานวิจัย

1.3.1 ปรับปรุง โครงข่ายประสาทเทียมที่ใช้อัลกอริทึมการเรียนรู้แบบแพร่กระจายย้อนกลับ ให้สามารถรู้จำข้อมูลได้ดีขึ้น

1.3.2 ปรับปรุงอัลกอริทึม โครงข่ายประสาทเทียมรีเคอร์เร้นท์แบบ Elman ซึ่งใช้อัลกอริทึมการเรียนรู้แบบแพร่กระจายย้อนกลับ ให้สามารถพยากรณ์ข้อมูลได้ดีขึ้น

1.3.3 ปรับปรุงอัลกอริทึม โครงข่ายประสาทเทียมรีเคอร์เร้นท์แบบ Jordan ซึ่งใช้อัลกอริทึมการเรียนรู้แบบแพร่กระจายย้อนกลับ ให้สามารถพยากรณ์ข้อมูลได้ดีขึ้น

1.4 ขั้นตอนการทำวิจัย

1.4.1 ศึกษาอัลกอริทึม โครงข่ายประสาทเทียมแบบแพร่กระจายย้อนกลับ

1.4.2 ศึกษาอัลกอริทึม โครงข่ายประสาทเทียมรีเคอร์เร้นท์แบบ Elman

1.4.3 ศึกษาอัลกอริทึม โครงข่ายประสาทเทียมรีเคอร์เร้นท์แบบ Jordan

1.4.4 ออกแบบและพัฒนาอัลกอริทึมของ โครงข่ายฯ ทั้ง 3 แบบข้างต้น ให้สามารถเรียนรู้ และให้ผลที่ดีขึ้น

1.4.5 ทดลองอัลกอริทึมที่ออกแบบใหม่กับข้อมูลประเภทต่างๆ

1.4.6 เปรียบเทียบผลการทดลองของอัลกอริทึมแบบใหม่ กับแบบเดิม

1.5 ประโยชน์ที่คาดว่าจะได้รับ

1.5.1 อัลกอริทึมโครงข่ายประสาทเทียมที่มีพื้นฐานแบบแพร่กระจายย้อนกลับ ที่สามารถให้ผลที่ดีขึ้นกว่าเดิม

1.5.2 สามารถนำ โครงข่ายประสาทเทียมที่ใช้อัลกอริทึมการเรียนรู้แบบแพร่กระจายย้อนกลับ ไปประยุกต์ใช้กับข้อมูลที่มีความซับซ้อนมากขึ้น และได้ผลดียิ่งขึ้น

1.5.3 สามารถนำ โครงข่ายประสาทเทียมรีเคอร์เร้นท์ที่ใช้อัลกอริทึมการเรียนรู้แบบแพร่กระจายย้อนกลับ ไปประยุกต์ใช้กับงานประมาณฟังก์ชัน งานพยากรณ์ข้อมูลที่มีความซับซ้อนมากขึ้น และได้ผลดียิ่งขึ้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1.6 โครงสร้างวิทยานิพนธ์

งานวิทยานิพนธ์ฉบับนี้ แบ่งออกเป็น 5 บท ประกอบด้วย

บทที่ 1 บทนำ กล่าวถึง ความเป็นมาและความสำคัญของปัญหาของโครงข่ายประสาทเทียมที่ใช้อัลกอริทึมการเรียนรู้แบบแพร่กระจายย้อนกลับ อธิบายวัตถุประสงค์ ขอบเขต และขั้นตอนการทำวิจัยในการปรับปรุงโครงข่ายฯ

บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง กล่าวถึง ทฤษฎีและงานวิจัยต่างๆที่เกี่ยวข้องกับโครงข่ายประสาทเทียมที่ใช้อัลกอริทึมการเรียนรู้แบบแพร่กระจายย้อนกลับ ซึ่งเป็นพื้นฐานสำคัญที่นำมาพัฒนา และวิจัยเพิ่มเติม ในงานวิจัยฉบับนี้

บทที่ 3 แนวทางการวิจัย กล่าวถึง งานวิจัยที่ได้ออกแบบ และพัฒนาขึ้น โดยอธิบายถึงส่วนอัลกอริทึมที่ออกแบบเพิ่มเติมจากเดิม ซึ่งเป็นอัลกอริทึมที่ให้ผลที่ดีขึ้นกว่าเดิม

บทที่ 4 การทดลองและผลการทดลอง กล่าวถึง การนำอัลกอริทึมที่ออกแบบใหม่ ไปทดลองกับข้อมูลประเภทต่างๆ เพื่อนำผลมาเปรียบเทียบกับการใช้อัลกอริทึมแบบเดิมว่าได้ผลที่แตกต่างจากเดิมเช่นไร


บทที่ 5 สรุปผลการทดลองและข้อเสนอแนะ เป็นการอภิปรายผลการเปรียบเทียบผลการทดลองที่ได้จากบทที่ 4 และข้อเสนอแนะในการทำวิจัยเพิ่มเติมต่อจากงานวิจัยนี้

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 โครงข่ายประสาทเทียมแบบแพร่กระจายย้อนกลับ

โครงข่ายประสาทเทียมแบบแพร่กระจายย้อนกลับ (Backpropagation Neural Network) เป็นโครงข่ายประสาทเทียมประเภทหนึ่งที่เป็นที่นิยม เพราะสามารถนำไปประยุกต์ใช้ในการรู้จำข้อมูลประเภทต่างๆ ได้เป็นอย่างดี เช่น การรู้จำภาพอักษร การรู้จำเสียง ฯลฯ โดย Han and Kamber (2001) ได้อธิบายเกี่ยวกับโครงข่ายประสาทเทียมแบบแพร่กระจายย้อนกลับ สามารถสรุปได้ดังนี้



รูปที่ 2.1 แผนภาพโครงข่ายประสาทเทียมแบบแพร่กระจายย้อนกลับ

จากรูปที่ 2.1 แสดง โครงสร้างของ โครงข่ายประสาทเทียมแบบแพร่กระจายย้อนกลับ ซึ่งจะมีชั้นข้อมูลเข้า (input layer) เป็นส่วนรับข้อมูลเข้าโครงข่ายฯ ชั้นซ่อน (hidden layer) เป็นชั้นภายในโครงข่ายฯ รับข้อมูลจากชั้นข้อมูลเข้า เพื่อประมวลผลก่อนส่งผลให้ชั้นข้อมูลออก (output layer) ส่วนชั้นสุดท้ายคือชั้นข้อมูลออก จะรับข้อมูลจากชั้นซ่อนมาประมวลผล และส่งเป็นข้อมูลออกหรือผลลัพธ์ออกจากโครงข่ายฯ ซึ่งในเบื้องต้น ผลลัพธ์ที่ออกจากโครงข่ายฯมักจะไม่ถูกต้อง จึงต้องมีการเรียนรู้ ในที่นี้ใช้วิธีการเรียนรู้แบบแพร่กระจายย้อนกลับ (back propagation learning algorithm) เป็นส่วนของการเรียนรู้ของโครงข่ายฯ โดยนำผลของโครงข่ายฯเปรียบเทียบกับค่าเป้าหมาย ซึ่งจะได้เป็นค่าที่ผิดพลาดมาปรับค่าน้ำหนักภายในโครงข่ายฯ เพื่อโครงข่ายจะให้ผลที่ถูกต้องมากยิ่งขึ้น ในการรับข้อมูลในรอบถัดไป ซึ่งรายละเอียดการทำงานของโครงข่ายฯจะได้ อธิบายแต่ละชั้นในรายละเอียดต่อไป

2.1.1 ชั้นข้อมูลเข้า (Input Layer)

โหนดในชั้นข้อมูลเข้า จะคอยรับค่าข้อมูลเข้าโครงข่ายฯ ที่มาจากภายนอกโครงข่ายฯ โดยแต่ละค่าจะมีค่าระหว่าง 0-1 และจำนวนโหนดในชั้นข้อมูลเข้านี้ จะหมายถึงจำนวนคุณลักษณะ

(feature) ของข้อมูลนั้นๆ เช่นถ้าต้องการรู้จำภาพขนาด 5x5 pixels โดยให้แต่ละจุด (pixel) เป็นข้อมูลเข้าให้กับโครงข่ายฯ ดังนั้น โครงข่ายฯจะมีโหนดในชั้นข้อมูลเข้า 25 โหนด เพื่อคอยรับข้อมูลจากภาพ (5x5 pixels) นั้น ซึ่งโดยทั่วไปมักกำหนดให้ จุดสีดำมีค่าเป็น 1 และจุดสีขาวมีค่าเป็น 0 ซึ่งแสดงการรับข้อมูลเข้าโครงข่ายฯ ดังสมการ (2.1)

$$o_i^I = x_i \dots\dots\dots(2.1)$$

o_i^I คือข้อมูลออกของโหนดที่ i ในชั้นข้อมูลเข้า (input layer)

x_i คือข้อมูลเข้าโครงข่ายฯ ซึ่งเป็นคุณลักษณะของข้อมูล (feature) ที่ i

2.1.2 ชั้นซ่อน (Hidden Layer)

ชั้นซ่อนของโครงข่ายฯ เป็นชั้นรับข้อมูลจากชั้นข้อมูลเข้า เพื่อนำมาประมวลผล แล้วส่งให้ชั้นข้อมูลออก (output layer) ซึ่งจำนวนโหนดในชั้นซ่อนนี้ ไม่มีสูตรใดกำหนดแน่นอน อาจจะต้องทดลองโครงข่ายฯ โดยกำหนดจำนวนโหนดหลายๆ ก่อน แล้วจึงค่อยลดจำนวนโหนดลง แต่ยังคงประสิทธิภาพการรู้จำเท่าเดิมหรือดีกว่าเดิม

แต่ละโหนดในชั้นซ่อน จะรับข้อมูลจากทุกโหนดในชั้นข้อมูลเข้า มาคูณกับค่าน้ำหนักของเส้นเชื่อมต่อโหนดนั้นๆ แสดงดังสมการ (2.2) และนำผลรวมนั้นผ่านฟังก์ชันกระตุ้นเพื่อเป็นข้อมูลออกของโหนดนั้นๆ ต่อไป แสดงดังสมการ (2.3)

$$net_j^H = \sum_{i=1}^{N^I} w_{ij}^H o_i^I \dots\dots\dots(2.2)$$

$$o_j^H = f(net_j^H) \dots\dots\dots(2.3)$$

o_i^I คือข้อมูลออกของโหนดที่ i ในชั้นข้อมูลเข้า

w_{ij}^H คือค่าน้ำหนักของเส้นเชื่อมต่อจากโหนดที่ i ในชั้นข้อมูลเข้ามายังโหนดที่ j ใน


ชั้นซ่อน

N^I คือจำนวนโหนดในชั้นข้อมูลเข้า

net_j^H คือผลรวมการคูณค่าโหนดในชั้นข้อมูลเข้า กับค่าน้ำหนักของเส้นเชื่อมต่อมายังโหนดที่ j ในชั้นซ่อน

o_j^H คือข้อมูลออกของโหนดที่ j ในชั้นซ่อน

$f(\cdot)$ เป็นฟังก์ชันกระตุ้น ซึ่งในโครงข่ายฯนี้ ใช้ฟังก์ชัน sigmoid แสดงกราฟ และฟังก์ชันดังรูปที่ 2.2



รูปที่ 2.2 กราฟฟังก์ชัน sigmoid = $\frac{1}{1+e^{-x}}$

2.1.3 ชั้นข้อมูลออก (Output Layer)

ชั้นข้อมูลออก หรือชั้นผลลัพธ์ของโครงข่ายฯ ซึ่งจำนวนโหนดในชั้นนี้ จะขึ้นอยู่กับ การประยุกต์ใช้งานของโครงข่ายฯ เช่นถ้านำไปใช้งานด้านการจำแนกข้อมูล (Classification) จำนวนโหนดในชั้นนี้ก็จะเท่ากับจำนวนคลาส (Class) ของข้อมูลนั้นๆ ซึ่งถ้าข้อมูลออกของโหนดใดในชั้นนี้ มีค่ามากที่สุด จะถือว่าโหนดนั้นเป็น โหนดชนะ และก็จะเป็ค่าตอบของข้อมูลที่เข้ามาในโครงข่ายฯว่าจัดอยู่ในคลาสใด

ถ้านำโครงข่ายฯ ไปประยุกต์ใช้งานด้านการพยากรณ์ จำนวนโหนดก็จะขึ้นอยู่กับ จำนวนค่าที่ต้องการพยากรณ์ เช่น รับข้อมูลหุ้นเข้ามา และต้องการพยากรณ์ข้อมูลหุ้น 3 วันถัดไป ก็ต้องใช้จำนวนโหนด 3 โหนด เพื่อใช้แทนการพยากรณ์วันที่ 1, 2 และ 3 ถัดจากข้อมูลที่รับเข้ามา เป็นต้น

เมื่อกำหนดจำนวนโหนดในชั้นนี้เรียบร้อยแล้ว แต่ละโหนดในชั้นนี้ จะรับข้อมูลมาจากทุกโหนดในชั้นซ่อน นำมาคูณกับค่าน้ำหนักของเส้นเชื่อมโหนดนั้นๆ แสดงดังสมการ (2.4) และนำผลรวมนั้น ผ่านฟังก์ชันกระตุ้น เพื่อเป็นข้อมูลออกของโหนดนั้นๆต่อไป แสดงดังสมการ (2.5)

$$net_j^III = \sum_{i=1}^{N^II} w_{ij}^III o_i^II \dots\dots\dots(2.4)$$

$$o_j^III = f(net_j^III) \dots\dots\dots(2.5)$$

o_i^II คือข้อมูลออกของโหนดที่ i ในชั้นซ่อน

w_{ij}^III คือค่าน้ำหนักของเส้นเชื่อมต่อจากโหนดที่ i ในชั้นซ่อน มายังโหนดที่ j ในชั้น

ข้อมูลออก

N^II คือจำนวนโหนดในชั้นซ่อน

net_j^III คือผลรวมการคูณค่าโหนดในชั้นซ่อน กับค่าน้ำหนักของเส้นเชื่อมต่อมายังโหนดที่ j ในชั้นข้อมูลออก

o_j^m คือข้อมูลออกของโหนดที่ j ในชั้นข้อมูลออก

$f(\cdot)$ เป็นฟังก์ชันกระตุ้น ซึ่งในโครงข่ายนี้ ใช้ฟังก์ชัน sigmoid

สำหรับการประยุกต์โครงข่ายฯ ในการจำแนกข้อมูล (Classification) สามารถนำข้อมูลออกในชั้นข้อมูลออกนี้ ไปสรุปเป็นคำตอบของโครงข่ายฯ โดยหาโหนดที่มีค่ามากที่สุด และให้โหนดนั้นเป็นผู้ชนะ เพื่อเป็นคำตอบของโครงข่าย แสดงดังสมการ (2.6)

$$K = \arg \max(o_k^m : k = 1, 2, \dots, N^m) \dots \dots \dots (2.6)$$

K คือ โหนดที่มีค่ามากที่สุด ซึ่งเป็นคำตอบของโครงข่ายประสาทเทียม

2.1.4 การเรียนรู้แบบแพร่กระจายย้อนกลับ

ผลของโครงข่ายฯ จะนำไปเปรียบเทียบกับค่าเป้าหมาย ที่ป้อนเข้ามาพร้อมกับข้อมูลเข้า ซึ่งทำให้ทราบว่า คำตอบของโครงข่ายฯ มีความผิดพลาด (error) มากน้อยเท่าไร แสดงดังสมการ (2.7)

$$\text{error} = \frac{1}{2} \sum_{i=1}^{N^m} (y_i - o_i^m)^2 \dots \dots \dots (2.7)$$

y_i คือค่าเป้าหมายของโหนดที่ i ในชั้นข้อมูลออก

o_i^m คือข้อมูลออกของโหนดที่ i ในชั้นข้อมูลออก

เมื่อมีข้อผิดพลาดก็ต้องพยายามเรียนรู้ โดยพยายามปรับค่าน้ำหนักต่างๆ ทั้งในชั้นซ่อน และชั้นข้อมูลออก เพื่อเมื่อข้อมูลเข้ามาใหม่จะได้ให้ผลที่ถูกต้องมากยิ่งขึ้น สมการการปรับค่าน้ำหนักในชั้นข้อมูลออก และชั้นซ่อน แสดงดังสมการ (2.8) และ (2.10) ส่วนสมการหาค่าความผิดพลาดของแต่ละค่าน้ำหนักในชั้นข้อมูลออก และชั้นซ่อน แสดงดังสมการ (2.9) และ (2.11)

$$w_{ij}^m(\text{new}) = w_{ij}^m(\text{old}) + \eta \frac{\partial E}{\partial w_{ij}^m} \dots \dots \dots (2.8)$$

$$\frac{\partial E}{\partial w_{ij}^m} = (y_j - o_j^m) o_j^m \cdot (1 - o_j^m) o_i^m \dots \dots \dots (2.9)$$

$$w_{ij}^m(\text{new}) = w_{ij}^m(\text{old}) + \eta \frac{\partial E}{\partial w_{ij}^m} \dots \dots \dots (2.10)$$

$$\frac{\partial E}{\partial w_{ij}^m} = (o_j^m \cdot (1 - o_j^m)) o_i^m \sum_{k=1}^{N^m} (y_k - o_k^m) (o_k^m \cdot (1 - o_k^m)) w_{jk}^m \dots \dots \dots (2.11)$$

η เป็นอัตราการเรียนรู้ของโครงข่ายฯ มีค่าอยู่ระหว่าง 0-1 ซึ่งถ้า η มีค่าน้อย จะทำให้การเรียนรู้ข้อมูลใหม่ช้า แต่ก็ยังคงรู้จำข้อมูลเก่าๆก่อนหน้าได้ แต่ถ้า η มีค่ามากจะทำให้การเรียนรู้ข้อมูลใหม่เร็ว แต่ก็ลืมข้อมูลเก่าเร็วด้วยเช่นกัน โดยทั่วไปกำหนดค่า η มีค่าน้อย เช่น 0.2, 0.1 หรือ 0.05 เพื่อให้โครงข่ายฯ ค่อยๆเรียนรู้ข้อมูลใหม่และยังคงจำข้อมูลเก่าได้ด้วย ซึ่งอาจจะต้องป้อนข้อมูลเข้าในจำนวนรอบที่มากขึ้น

จากการที่โครงข่ายฯเรียนรู้แต่ละข้อมูล และมีการปรับค่าน้ำหนักเพื่อให้ได้ผลที่ผิดพลาดน้อยลงของแต่ละข้อมูล ดังนั้นจึงหาผลรวมความผิดพลาดของแต่ละข้อมูล เพื่อใช้เป็นค่าวัดความผิดพลาดโดยรวมของโครงข่ายฯนั้นๆ โดยหาค่า Mean Squared Error (MSE) แสดงดังสมการ (2.12) หาค่า Root Mean Squared Error (RMSE) แสดงดังสมการ (2.13) หรือหาค่า Mean Absolute Percentage Error (MAPE) แสดงดังสมการ (2.14)

$$MSE = \frac{\sum_{p=1}^P \sum_{i=1}^{N^{III}} (y_i^p - o_i^{pIII})^2}{P \cdot N^{III}} \dots\dots\dots(2.12)$$

$$RMSE = \sqrt{\frac{\sum_{p=1}^P \sum_{i=1}^{N^{III}} (y_i^p - o_i^{pIII})^2}{P \cdot N^{III}}} \dots\dots\dots(2.13)$$

$$MAPE = \frac{\sum_{p=1}^P \sum_{i=1}^{N^{III}} \left| \frac{y_i^p - o_i^{pIII}}{y_i^p} \right|}{P \cdot N^{III}} \dots\dots\dots(2.14)$$


y_i^p คือค่าเป้าหมายของโหนดที่ i ในชั้นข้อมูลออก ของชุดข้อมูลลำดับที่ p
 o_i^{pIII} คือค่าข้อมูลออกของโหนดที่ i ในชั้นข้อมูลออก ของชุดข้อมูลลำดับที่ p
 N^{III} คือจำนวนโหนดในชั้นข้อมูลออก

P คือจำนวนข้อมูลในแต่ละชุด เช่นชุดข้อมูลเรียนรู้ (Training data set) หรือชุดข้อมูลทดสอบ (Testing data set) เป็นต้น

2.2 โครงข่ายประสาทเทียมรีเคอร์เรนต์แบบ Jordan (Jordan Recurrent Neural Network)

โครงข่ายประสาทเทียมรีเคอร์เรนต์ (recurrent neural network)

โครงข่ายฯลักษณะนี้ แบบหนึ่งที่เป็นที่นิยมได้แก่โครงข่ายประสาทเทียมรีเคอร์เรนต์แบบ Jordan ซึ่งตั้งชื่อตามผู้ออกแบบที่ชื่อ Jordan โดย Jordan (1986) ได้ออกแบบโครงข่ายฯแบบ Jordan ซึ่งจะนำข้อมูลที่ออกจากชั้นข้อมูลออก (output layer) นำมาป้อนกลับไปพร้อมกับข้อมูลเข้าชุดใหม่ที่เข้ามาจากภายนอกโครงข่ายฯ ซึ่งข้อมูลที่นำมาป้อนกลับนี้ จะเรียกว่าหน่วยบริบท (context units) แสดงโครงข่ายฯแบบ Jordan ดังรูปที่ 2.3



รูปที่ 2.3 โครงข่ายประสาทเทียมรีเคอร์เรนต์แบบ Jordan

จากรูปที่ 2.3 สามารถอธิบายรายละเอียดแต่ละชั้นในโครงข่ายฯ ได้ดังนี้

2.2.1 ชั้นข้อมูลเข้า (Input Layer)

ในชั้นข้อมูลเข้านี้ ประกอบด้วย 2 หน่วยย่อยคือ หน่วยรับข้อมูลเข้าจากภายนอก (input units) และ หน่วยบริบท (context units) ซึ่งเป็นหน่วยรับข้อมูลป้อนกลับจากภายในโครงข่าย

2.2.1.1 หน่วยรับข้อมูลเข้า (Input Units)

หน่วยรับข้อมูลเข้าจะเป็นหน่วยรับข้อมูลเข้าจากภายนอก ซึ่งจำนวนโหนดจะเท่ากับจำนวนคุณลักษณะ (feature) ของข้อมูลนั้นๆ แสดงดังสมการ (2.15)

$$o_i^1 = x_i \dots\dots\dots(2.15)$$

x_i : คุณลักษณะที่ i ของข้อมูลเข้า

o_i^1 : ข้อมูลออกของโหนดที่ i ในหน่วยรับข้อมูลเข้า

2.2.1.2 หน่วยบริบท (Context Units)

หน่วยบริบทของโครงข่ายฯแบบ Jordan นี้ จะนำข้อมูลมาจากชั้นข้อมูลออก โดยการคัดลอกข้อมูลมาเก็บไว้ในหน่วยบริบทนี้ในลักษณะหนึ่งต่อหนึ่ง แสดงดังสมการ (2.16) ดังนั้นจำนวนโหนดในหน่วยบริบทนี้ จะมีจำนวนเท่ากับจำนวนโหนดในชั้นข้อมูลออก

$$o_i^c = \alpha o_i^{III}(t-1) + (1-\alpha)o_i^c(t-1) \dots\dots\dots(2.16)$$

$o_i^{III}(t-1)$ ข้อมูลออกของโหนดที่ i ในชั้นข้อมูลออกในรอบที่ผ่านมา

$o_i^c(t-1)$ ข้อมูลออกของโหนดที่ i ในหน่วยบริบทในรอบที่ผ่านมา

o_i^c ข้อมูลออกของโหนดที่ i ในหน่วยบริบท

α ค่าพารามิเตอร์ที่ปรับให้ความสำคัญระหว่าง 2 ข้อมูล มีค่าอยู่ระหว่าง 0-1

2.2.2 ชั้นซ่อน (Hidden Layer)

ชั้นซ่อนของโครงข่ายแบบ Jordan โดยหลักๆ แล้วจะเหมือนกับชั้นซ่อนในโครงข่ายแบบแพร่กระจายย้อนกลับ เพียงแต่จะต้องรับข้อมูลในหน่วยบริบทมาประมวลผลเพิ่มเติม แสดงดังสมการ (2.17) และผ่านฟังก์ชันกระตุ้นเหมือนในโครงข่ายแบบแพร่กระจายย้อนกลับแสดงดังสมการ (2.3)

$$net_j^{II} = \sum_{i=1}^{N^I} w_{ij}^{II} o_i^I + \sum_{i=1}^{N^c} w_{ij}^{IIc} o_i^c \dots\dots\dots(2.17)$$

o_i^c คือข้อมูลออกของโหนดที่ i ในหน่วยบริบท

w_{ij}^{IIc} คือค่าน้ำหนักของเส้นเชื่อมต่อจากโหนดที่ i ในหน่วยบริบทมายังโหนดที่ j ใน

ชั้นซ่อน

N^c คือจำนวน โหนดในหน่วยบริบท

2.2.3 ชั้นข้อมูลออก (Output Layer)

ชั้นข้อมูลออกของ โครงข่ายแบบ Jordan นี้ จะเหมือนกับ โครงข่ายแบบแพร่กระจายย้อนกลับ แสดงดังสมการ (2.4) และ (2.5)

2.2.4 การเรียนรู้แบบแพร่กระจายย้อนกลับ

การเรียนรู้ของโครงข่ายแบบ Jordan นี้ ในส่วนหลักๆ จะเหมือนกับโครงข่ายแบบแพร่กระจายย้อนกลับ โดยนำค่าเป้าหมายมาหาค่าความผิดพลาด แสดงดังสมการ (2.7) การปรับค่าน้ำหนักในชั้นข้อมูลออก แสดงดังสมการ (2.8) และ (2.9) การปรับค่าน้ำหนักในชั้นซ่อนที่เชื่อมต่อกับหน่วยรับข้อมูลเข้า แสดงดังสมการ (2.10) และ (2.11)

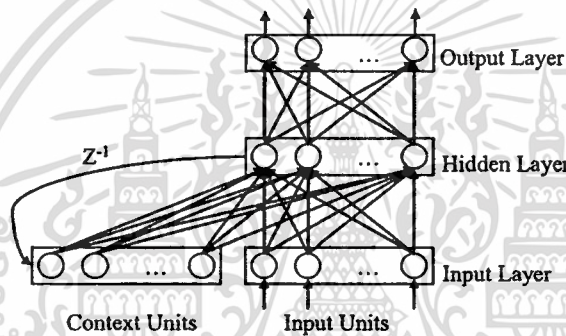
ส่วนค่าน้ำหนักของเส้นเชื่อมต่อระหว่างหน่วยบริบท กับชั้นซ่อน สามารถปรับค่าได้ดังสมการ (2.18) และ (2.19)

$$w_{ij}^{IIc}(new) = w_{ij}^{IIc}(old) + \eta \frac{\partial E}{\partial w_{ij}^{IIc}} \dots\dots\dots(2.18)$$

$$\frac{\partial E}{\partial w_{ij}^{II}} = (o_j^{II} \cdot (1 - o_j^{II})) o_i^c \sum_{k=1}^{N^{III}} (y_k - o_k^{III}) (o_k^{III} \cdot (1 - o_k^{III})) w_{jk}^{III} \dots\dots\dots(2.19)$$

2.3 โครงข่ายประสาทเทียมรีเคอร์เรนต์แบบ Elman (Elman Recurrent Neural Network)

โครงข่ายประสาทเทียมรีเคอร์เรนต์แบบ Elman เป็นโครงข่ายรีเคอร์เรนต์แบบหนึ่งที่เป็นที่นิยม ตั้งชื่อตามผู้ออกแบบที่ชื่อ Elman โดย Elman (1990) ได้ออกแบบโครงข่ายฯโดยนำข้อมูลมาป้อนกลับเหมือนของแบบ Jordan แต่ของแบบ Elman จะนำข้อมูลจากชั้นซ่อน (hidden layer) มาป้อนกลับเป็นหน่วยบริบท (context units) แสดงโครงข่ายฯแบบ Elman ดังรูปที่ 2.4



รูปที่ 2.4 โครงข่ายประสาทเทียมรีเคอร์เรนต์แบบ Elman

โครงสร้างและการทำงานหลักๆของโครงข่ายฯแบบ Elman จะคล้ายๆกับโครงข่ายฯแบบ Jordan ดังอธิบายรายละเอียดแต่ละชั้นในโครงข่ายฯ ได้ดังนี้

2.3.1 ชั้นข้อมูลเข้า (Input Layer)

ในชั้นข้อมูลเข้านี้ ประกอบด้วย 2 หน่วยเหมือนแบบ Jordan กล่าวคือ หน่วยรับข้อมูลเข้าจากภายนอก (input units) และ หน่วยบริบท (context units) ซึ่งเป็นหน่วยรับข้อมูลป้อนกลับจากภายใน

2.3.1.1 หน่วยรับข้อมูลเข้า (Input Units)

หน่วยรับข้อมูลเข้าจะเป็นหน่วยรับข้อมูลเข้าจากภายนอก ซึ่งจำนวนโหนดจะเท่ากับจำนวนคุณลักษณะ (feature) ของข้อมูลนั้นๆ แสดงดังสมการ (2.15) เหมือนแบบ Jordan

2.3.1.2 หน่วยบริบท (Context Units)

หน่วยบริบทของโครงข่ายแบบ Elman นี้ จะต่างจากของแบบ Jordan โดยแบบ Elman จะนำข้อมูลมาจากชั้นซ่อน โดยการคัดลอกข้อมูลมาเก็บไว้ในหน่วยบริบทนี้ในลักษณะหนึ่งต่อหนึ่ง แสดงดังสมการ (2.20) ดังนั้นจำนวนโหนดในหน่วยบริบทนี้ จะมีจำนวนเท่ากับจำนวนโหนดในชั้นซ่อน

$$o_i^c = o_i^h(t-1) \dots\dots\dots(2.20)$$

$o_i^h(t-1)$ ข้อมูลออกของโหนดที่ i ในชั้นซ่อนในรอบที่ผ่านมา

o_i^c ข้อมูลออกของโหนดที่ i ในหน่วยบริบท

2.3.2 ชั้นซ่อน (Hidden Layer)

ชั้นซ่อนของโครงข่ายแบบ Elman จะเหมือนกับชั้นซ่อนในโครงข่ายแบบ Jordan ที่รับข้อมูลมาจากหน่วยรับข้อมูลเข้า และหน่วยบริบท แสดงดังสมการ (2.17) และผ่านฟังก์ชันกระตุ้นเหมือนในโครงข่ายแบบแพร่กระจายย้อนกลับแสดงดังสมการ (2.3)

2.3.3 ชั้นข้อมูลออก (Output Layer)

ชั้นข้อมูลออกของโครงข่ายแบบ Elman นี้ก็เช่นกัน จะเหมือนกับโครงข่ายแบบแพร่กระจายย้อนกลับ และแบบ Jordan แสดงดังสมการ (2.4) และ (2.5)

2.3.4 การเรียนรู้แบบแพร่กระจายย้อนกลับ

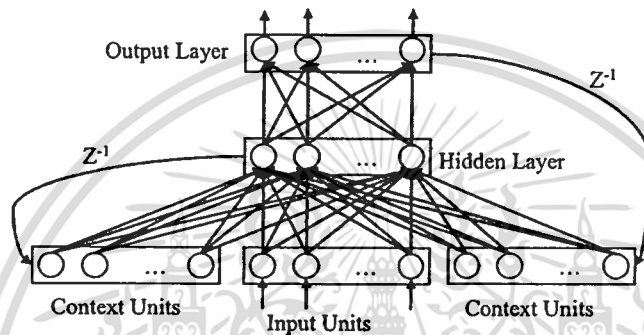
การเรียนรู้ของโครงข่ายแบบ Elman นี้ จะเหมือนกับโครงข่ายแบบแพร่กระจายย้อนกลับ ที่นำค่าเป้าหมายมาหาค่าความผิดพลาด แสดงดังสมการ (2.7) การปรับค่าน้ำหนักในชั้นข้อมูลออก แสดงดังสมการ (2.8) และ (2.9) การปรับค่าน้ำหนักในชั้นซ่อน ที่เชื่อมต่อกับหน่วยรับข้อมูลเข้า แสดงดังสมการ (2.10) และ (2.11) และเหมือนกับแบบ Jordan ที่ปรับค่าน้ำหนักของเส้นเชื่อมต่อระหว่างหน่วยบริบท กับชั้นซ่อน ดังสมการ (2.18) และ (2.19)

2.4 งานวิจัยที่เกี่ยวข้อง

ในหัวข้อที่ผ่านมา ได้อธิบายถึงโครงข่ายประสาทเทียมแบบแพร่กระจายย้อนกลับ ซึ่งถือเป็นต้นแบบโครงข่ายแบบหนึ่ง และได้มีการปรับปรุงเป็นแบบ Jordan และ Elman เพื่อใช้ในงานข้อมูลประเภทรีเคอร์เรนต์ (Recurrent) และได้มีงานวิจัยจำนวนมากที่ยังคง ทั้งแบบแพร่กระจายย้อนกลับ แบบ Jordan และแบบ Elman อีกทั้งยังมีการปรับปรุงโครงสร้างโครงข่ายในลักษณะที่แตกต่างกันไป ดังจะได้อธิบายการปรับปรุงโครงสร้างโครงข่าย ในรายละเอียดต่อไป

2.4.1 A Comparative Study of Recurrent Neural Network Architectures on Learning Temporal Sequences.

งานวิจัยนี้ วิจัยโดย Chen and Soo (1996) ได้รับการตีพิมพ์ใน Proceedings of the IEEE International Conference on Neural Networks. ปี ค.ศ. 1996 หน้า 1945-1950 เป็นการประยุกต์ทั้งของแบบ Elman และแบบ Jordan เข้าด้วยกัน โดยมีหน่วยบริบท (Context Units) ทั้งของแบบ Elman ที่นำข้อมูลมาจากชั้นซ่อน และของแบบ Jordan ที่นำข้อมูลมาจากชั้นข้อมูลออก แสดงดังรูปที่ 2.5



รูปที่ 2.5 โครงข่ายประสาทเทียมแบบ Chen and Soo

การทดลองแบ่งออกเป็น 3 การทดลอง การทดลองที่ 1 ใช้กับข้อมูลของเครื่องสถานะจำกัด (finite state machine) ที่มีข้อมูลเข้า 4 แบบ (0, 0), (0, 1), (1, 0) และ (1, 1) ซึ่งถ้ากำหนดสถานะเริ่มต้นที่แตกต่างกัน แม้ข้อมูลเหมือนกันก็อาจได้สถานะที่แตกต่างกันได้ ในการทดลองกำหนด 4 โหนด, 8 โหนด และ 4 โหนด ให้กับชั้นข้อมูลเข้า ชั้นซ่อน และชั้นข้อมูลออกตามลำดับ สำหรับโครงข่ายรีเคอร์เร้นท์ทั้ง 3 แบบ คือ แบบ Elman, แบบ Jordan และแบบ MSRN ที่เป็นแบบที่นำเสนอใหม่ข้างต้น ซึ่งถ้าไม่ได้กำหนดสถานะเริ่มต้นให้แก่ชั้นข้อมูลออก โครงข่ายแบบ Elman จะไม่สามารถเรียนรู้ได้ โดยโครงข่าย MSRN ก็ให้ผลดีกว่าแบบ Jordan แต่เมื่อได้กำหนดสถานะเริ่มต้นให้กับชั้นข้อมูลออกแล้ว โครงข่ายแบบ Elman ก็ยังสามารถเรียนรู้ได้ แต่ผลของโครงข่ายแบบ MSRN ก็ยังดีกว่าแบบ Elman และแบบ Jordan เช่นเดิม


การทดลองที่ 2 ทดลองกับข้อมูลวัตถุ 8 ชนิด ซึ่งจะระบุได้โดย 3 ข้อมูล แต่ละข้อมูลมี 2 แบบ โดยการป้อนข้อมูลทั้ง 3 แบบตามลำดับให้กับโครงข่าย เพื่อให้โครงข่ายระบุว่าเป็นวัตถุอะไร ซึ่งกำหนดโครงข่ายเป็น 6 โหนด, 4 โหนด และ 8 โหนด สำหรับชั้นข้อมูลเข้า ชั้นซ่อน และชั้นข้อมูลออก จากผลการทดลองโครงสร้างแบบ MSRN ที่ใช้วิธีผู้สอนบังคับ (teacher-forced) ให้ผลดีกว่าแบบอื่นๆอย่างมาก

สำหรับการทดลองที่ 3 ทดลองกับลำดับข้อมูล 4 แบบ คือ 111, 000, 100 และ 110 ซึ่งข้อมูลดังกล่าวจะทำซ้ำกัน 3 ครั้งเป็น 9 หลัก ก่อนป้อนให้กับโครงข่ายฯ คือ 111111111, 000000000, 100100100 หรือ 110110110 เป็นต้น จากการทดลองโครงข่ายฯแบบ MSRN ให้ผลดีที่สุด

โดยสรุปแล้ว ผู้วิจัยพบว่าในหน่วยบริบท (context unit) เป็นที่เก็บลำดับข้อมูลไว้ จึงนำเสนอโครงข่ายฯที่มีหน่วยบริบททั้งแบบของ Elman และแบบ Jordan รวมกัน

2.4.2 Dynamic Properties of Elman and Modified Elman Neural Network.

งานวิจัยนี้ วิจัยโดย Cheng, Qi, and Cai (2002) ได้รับการตีพิมพ์ใน Proceedings of the First International Conference on Machine Learning and Cybernetics หน้า 637-640 และจัดประชุมที่ ปักกิ่ง ประเทศจีน ในปี ค.ศ. 2002 ซึ่งเป็นการประยุกต์ของแบบ Elman โดยหน่วยบริบท (context units) ของแบบ Elman จะป้อนข้อมูลให้กับชั้นซ่อนเท่านั้น แต่ของแบบ Cheng, Qi, and Cai จะป้อนข้อมูลให้กับชั้นข้อมูลออกด้วย แสดงดังรูปที่ 2.6



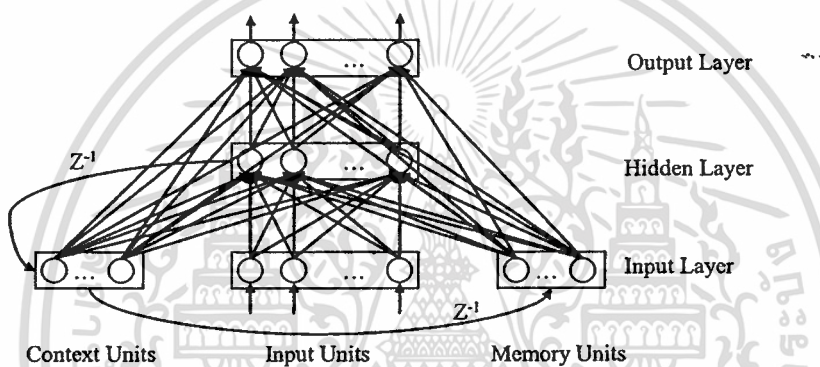
รูปที่ 2.6 โครงข่ายประสาทเทียมแบบ Cheng, Qi, and Cai

ในงานวิจัยได้อธิบายถึงอินทิกรัล (integral), สัดส่วน (proportional) และอนุพันธ์ (derivative) อีกทั้งแสดงโครงสร้างที่นำเสนอใหม่เป็นแบบง่าย โดยแสดงเป็นโหนดเดียวในทุกชั้น และอธิบายการคำนวณอินทิกรัล (integral) คือส่วนหน่วยบริบทและหน่วยข้อมูลเข้าร่วมกันป้อนข้อมูลให้กับชั้นซ่อน และอธิบายการคำนวณสัดส่วน (proportional) คือส่วนบริบท และชั้นซ่อนร่วมกันป้อนข้อมูลให้กับชั้นข้อมูลออก พร้อมทั้งวิเคราะห์สมการเปรียบเทียบกับสมการอนุพันธ์ PID (proportional, integral, derivative) ได้ตรงกัน โดยในส่วน derivative ของโครงสร้างที่นำเสนอใหม่มีค่า 0

ผู้วิจัยจึงสรุปว่า โครงข่ายฯแบบ Elman เป็นฟังก์ชันอินทิกรัล (integral) เพียงอย่างเดียว ส่วนโครงข่ายฯที่ปรับปรุงใหม่นั้น เป็นทั้งแบบอินทิกรัล (integral) และสัดส่วน (proportional) รวมกัน

2.4.3 The Property of PID Elman Neural Network and Its Application in Identification of Hydraulic Unit

งานวิจัยนี้วิจัยโดย Ji และ Qi (2007) ได้รับการตีพิมพ์ใน IEEE International Conference on Control and Automation หน้า 1795-1798 และจัดประชุมวิชาการที่ Guangzhou ประเทศจีน เมื่อวันที่ 30 พฤษภาคม ถึง 1 มิถุนายน พ.ศ. 2550 ในงานวิจัยได้กล่าวถึง การประยุกต์โครงข่ายประสาทเทียมรีเคอร์เรนท์แบบ Elman ให้มีคุณสมบัติสัดส่วน (Proportional) และอินทิกรัล (Integral) แต่ยังไม่มียุทธสมบัติอนุพันธ์ (Derivative) ดังได้อธิบายในหัวข้อ 2.4.2 ดังนั้นในงานวิจัยนี้จึงนำเสนอโครงข่ายที่มีทั้งคุณสมบัติสัดส่วน (Proportional) อินทิกรัล (Integral) และอนุพันธ์ (Derivative) โดยประยุกต์โครงข่ายแบบของ Elman เพิ่มเติม แสดงดังรูปที่ 2.7



รูปที่ 2.7 โครงข่ายประสาทเทียมแบบ Elman ที่มีคุณสมบัติ PID

จากรูปที่ 2.7 พัฒนาเพิ่มเติมจากรูปที่ 2.6 โดยคัดลอกหน่วยบริบทมาเป็นหน่วยความจำ เพื่อป้อนข้อมูลให้กับชั้นซ่อน และชั้นข้อมูลออกในรอบต่อไป

ในการทดลองนำโครงข่ายมาประมาณฟังก์ชัน ดังสมการ (2.21) ซึ่งใช้ข้อมูลเข้าดังสมการ (2.22)

$$y(k + 1) = 0.8y(k) + \frac{1}{y(k)} - 0.5u(k) \dots\dots\dots(2.21)$$

$$u(k) = 0.4 \sin\left(\frac{3\pi k}{14}\right) + 0.6 \sin\left(\frac{2\pi k}{11}\right) \dots\dots\dots(2.22)$$


โดยกำหนดให้ $k = 1$ จนถึง 200 ซึ่งจะได้ 200 ข้อมูล และกำหนดจำนวน โหนดในชั้นซ่อนเท่ากับ 15 โหนด ซึ่งจะกำหนดจำนวน โหนดในหน่วยบริบท และหน่วยความจำให้มีหน่วยละ 15 โหนดไปในตัว ทำการเรียนรู้ 600 รอบ จะได้ค่าเฉลี่ยผิดพลาดยกกำลังสอง (mean square error: MSE) ของโครงข่ายปรับปรุง Elman แบบ PI เท่ากับ 0.006133 และ โครงข่ายที่ปรับปรุง Elman

แบบใหม่ (PID) จะได้ 0.001049 ซึ่งแสดงให้เห็นว่า การปรับปรุง Elman ใหม่ ที่มีคุณสมบัติ PID ดีกว่าแบบ PI ซึ่งไม่มีคุณสมบัติสัดส่วน (Derivative) ดังกล่าวข้างต้น

และยังนำโครงข่ายฯ ทั้ง 2 แบบ มาทดลองกับระบบ electro-hydraulic servo ซึ่งทำการเรียนรู้จำนวน 1000 รอบ โดยรับข้อมูลเข้าปกติจาก servo valve และข้อมูลออกก็คือจากสัญญาณ velocity ของ hydraulic cylinder ซึ่งจากผลการทดลอง โครงข่ายฯ แบบ Elman (PI) ให้ผลผิดพลาดมากกว่าโครงข่ายฯ แบบ Elman (PID) ที่ปรับปรุงขึ้นมาใหม่

2.4.4 A New Recurrent Neural-Network Architecture for Visual Pattern Recognition

งานวิจัยนี้ วิจัยโดย Lee and Song (1997) ได้รับการตีพิมพ์ใน IEEE Transactions on neural networks Vol.8 No.2 เดือนมีนาคม ปี ค.ศ. 1997 หน้า 331-340 ซึ่งเป็นการรู้จักลายมือเขียนตัวเลข โดยปรับปรุงโครงข่ายประสาทเทียมรีเคอร์เรนต์ในส่วนของหน่วยบริบท (context units) โดยหน่วยบริบทจะสำเนาข้อมูลมาจากข้อมูลออกของโครงข่ายเหมือนของแบบ Jordan แต่ต่างกันตรงที่ หน่วยบริบทนี้จะป้อนข้อมูลพร้อมกับ โหนดในชั้นซ่อน เพื่อส่งข้อมูลให้กับชั้นข้อมูลออก แสดงดังรูปที่ 2.8



รูปที่ 2.8 โครงข่ายประสาทเทียมแบบ Seong-Whan Lee และ Hee-Heon Song

ในงานวิจัยนี้ได้ทำการทดลองกับลายมือเขียนตัวเลขบนซองจดหมายจำนวน 6000 ตัวเลข ซึ่งได้มาจากซองจดหมายในที่ทำการไปรษณีย์ต่างๆ ในสหรัฐอเมริกา แบ่งเป็นข้อมูลสำหรับการเรียนรู้ 4000 ข้อมูล และสำหรับการทดสอบ 2000 ข้อมูล แสดงตัวอย่างตัวเลขดังรูปที่ 2.9 และผลการทดลองโดยเปรียบเทียบอัตราผิดพลาดของการรู้จำ ในการใช้โครงข่ายประสาทเทียมแบบต่างๆ แสดงดังตารางที่ 2.1

๐ / 2 3 4 5 6 7 8 9
 ๐ \ 2 3 4 5 6 7 8 9
 ๐ | 2 3 4 5 6 7 8 9
 ๐ | 2 3 4 5 6 7 8 9
 ๐ | 2 3 4 5 6 7 8 9

รูปที่ 2.9 ตัวอย่างลายมือเขียนตัวเลขบนซองจดหมาย

ตารางที่ 2.1 เปรียบเทียบอัตราความผิดพลาดในการรู้จำลายมือเขียน

Method	Feedforward NN	Jordan's RNN	Elman's RNN	Proposed RNN
Training set	0.850%	0.650%	0.625%	0.575%
Testing set	3.7%	3.1%	2.9%	2.7%

2.4.5 A fuzzy backpropagation algorithm

อัลกอริทึมแพร่กระจายย้อนกลับแบบฟัซซีนี้ นำเสนอโดย Stoeva and Nikov (2000) ได้รับการตีพิมพ์ใน Fuzzy Sets and Systems ฉบับที่ 112 หน้า 27-39 ปี ค.ศ. 2000 ซึ่งอัลกอริทึมแพร่กระจายย้อนกลับแบบฟัซซีนี้ จะมีโครงสร้างเหมือนโครงข่ายประสาทเทียมแบบแพร่กระจายย้อนกลับ แต่ใช้สมการที่แตกต่างกัน โดยนำหลักการของฟัซซีมาคำนวณหาค่าของแต่ละโหนดอธิบายการคำนวณในแต่ละชั้นได้ดังนี้

ชั้นข้อมูลเข้า จะรับข้อมูลจากภายนอก (x_j) และส่งเป็นข้อมูลออกของชั้นนี้ โดยไม่ต้องมีการคำนวณใดๆ

ในชั้นซ่อน แต่ละโหนดจะรับข้อมูลมาจากทุกโหนดในชั้นข้อมูลเข้า ซึ่งจะมีค่าน้ำหนักของแต่ละการเชื่อมโยง ($w_{ij}^{(1)}$) และการทำงานของโหนดจะใช้ตัวดำเนินการฟัซซี ดังสมการ (2.23) (2.24)

$$net_i^{(1)} = \bigvee_{G \in P(J)} \left[\left(\bigwedge_{p \in G} a_p^{(0)} \right) \wedge g(G) \right] \dots\dots\dots(2.23)$$

$$a_i^{(1)} = f(net_i^{(1)}) \dots\dots\dots(2.24)$$

$P(J)$ เป็น power set ของโหนดที่เป็นข้อมูลเข้าของโหนด J และ J_{ij} เป็นค่าน้ำหนักของโหนดข้อมูลเข้า j ที่เชื่อมไปยังโหนด i

ฟังก์ชัน $g(\cdot)$ เป็นการหาค่ามากที่สุดของพารามิเตอร์ โดยในที่นี้พารามิเตอร์เป็นเซตของค่าน้ำหนัก ดังนั้นฟังก์ชัน $g(\cdot)$ จะเป็นการหาค่ามากที่สุดของค่าน้ำหนักในเซตนั้นๆ

ตัวดำเนินการ \wedge เป็นการหาค่าน้อยที่สุด และตัวดำเนินการ \vee เป็นการหาค่ามากที่สุด และผ่านฟังก์ชันกระตุ้น แสดงดังสมการ (2.25)

$$f(\text{net}) = \frac{1}{1 + \exp(-4(\text{net} - 0.5))} \dots\dots\dots(2.25)$$

ในชั้นข้อมูลออกจะมีเพียง 1 โหนด โดยจะรับข้อมูลมาจากทุกโหนดในชั้นซ่อน และมีค่าน้ำหนักประจำของแต่ละการเชื่อมโยง ($w_{ij}^{(2)}$) การทำงานของโหนดจะใช้ตัวดำเนินการพีชคณิตสมการ (2.26) (2.27)

$$\text{net}^{(2)} = \bigvee_{G \in P(J)} \left[\left(\bigwedge_{p \in G} a_p^{(1)} \right) \wedge g(G) \right] \dots\dots\dots(2.26)$$

$$a^{(2)} = f(\text{net}^{(2)}) \dots\dots\dots(2.27)$$

เมื่อได้ผลลัพธ์ $a^{(2)}$ แล้วจะเป็นคำตอบของโครงข่ายของข้อมูลนั้นๆ โดยในขั้นตอนการเรียนรู้ จะนำไปเปรียบเทียบกับค่าเป้าหมาย (y^d) เพื่อจะได้ทราบค่าความผิดพลาดของโครงข่ายซึ่งหาได้จากสมการ (2.28) (2.29)

$$\delta^{(2)} = |y^d - a^{(2)}| \dots\dots\dots(2.28)$$

$$\delta_i^{(1)} = |y^d - a_i^{(1)}| \dots\dots\dots(2.29)$$

การปรับค่าน้ำหนักจะปรับตามแต่กรณีดังนี้

กรณี $y^d = a^{(2)}$ ไม่ต้องปรับค่าน้ำหนักใดๆ เพราะให้ผลที่ถูกต้องแล้ว

กรณี $y^d > a^{(2)}$ จะปรับค่าน้ำหนักตามแต่กรณีดังนี้

ถ้า $w_{ij}^{\text{old}} < y^d$ จะปรับค่าน้ำหนักโดย $w_{ij}^{\text{new}} = 1 \wedge (w_{ij}^{\text{old}} + \Delta w_{ij})$

ถ้า $w_{ij}^{\text{old}} \geq y^d$ ไม่ต้องปรับค่าน้ำหนัก โดยใช้ค่าน้ำหนักเดิม

กรณี $y^d < a^{(2)}$ จะปรับค่าน้ำหนักตามแต่กรณีดังนี้

ถ้า $w_{ij}^{\text{old}} > y^d$ จะปรับค่าน้ำหนักโดย $w_{ij}^{\text{new}} = 0 \vee (w_{ij}^{\text{old}} - \Delta w_{ij})$

ถ้า $w_{ij}^{\text{old}} \leq y^d$ ไม่ต้องปรับค่าน้ำหนัก โดยใช้ค่าน้ำหนักเดิม

Δw_{ij} เป็นค่าการปรับน้ำหนักที่ได้จากสมการ $\Delta w_{ij} = \eta \delta_i^{(l)}$

ข้อดีของอัลกอริทึมแพร่กระจายย้อนกลับแบบพีชคณิต สามารถจำแนกได้ดังนี้

1. การปรับค่าน้ำหนักให้เข้าสู่จุดสมดุล ทำได้อย่างรวดเร็ว เป็นผลจากการลดเวลาในการคำนวณ ซึ่งเป็นสิ่งสำคัญมากสำหรับโครงข่ายประสาทเทียมที่มีขนาดใหญ่

2. การปรับค่าน้ำหนักให้ได้ค่าผลลัพธ์ตามเป้าหมายจะ ไม่มีการแกว่งไปมา และจะไม่เข้าจุดสมดุลในระดับโลกอล
3. ไม่ใช้วิธีการของความน่าจะเป็น และไม่ขึ้นกับรูปแบบของข้อมูล
4. ไม่จำเป็นต้องกำหนดค่าเริ่มต้นของน้ำหนักให้แตกต่างกัน

2.4.6 A Neural Multiclassifier System for Object Recognition in Robotic Vision Applications

งานวิจัยนี้ วิจัยโดย Mitzias, Dimitris A. and Basil G. Mertzios. (2004) ได้รับการตีพิมพ์ใน ScienceDirect 36, 3-4 เดือน ตุลาคม-ธันวาคม ปี ค.ศ. 2004 เป็นงานวิจัยทางด้านการพัฒนาความสามารถในการมองเห็นของหุ่นยนต์ โดยใช้ระบบ NEural MUlticlassifier System (NEMUS) ซึ่งเป็นระบบที่ใช้วิธีการจำแนกหลายวิธีร่วมกัน โดยมีการทำงานหลัก 2 ขั้นตอน คือ ขั้นแรกจำแนกจากกลุ่มของคุณลักษณะที่แตกต่างกัน 3 กลุ่ม (คุณลักษณะทางเรขาคณิต, central moment และ การประมาณค่ารูปหลายเหลี่ยม) โดยใช้ Back-propagation neural classifiers แล้วจึงนำผลลัพธ์ที่ได้มาประมวลผลร่วมกัน โดยใช้ Decision Making Network (DM-Net) พบว่าการใช้คุณลักษณะเพียงกลุ่มเดียวจะให้ความถูกต้องสูงสุดเพียง 75.6% แต่หากใช้ร่วมกันจะให้ค่าความถูกต้องสูงสุด 98.3%

2.4.7 การรู้จำลายมือตัวอักษรภาษาไทยแบบออนไลน์

งานวิจัยนี้ วิจัยโดย Sae-Tang and Methaste (2543) เป็นงานวิจัยเกี่ยวกับการรู้จำลายมือตัวอักษรภาษาไทยแบบออนไลน์ โดยใช้เทคนิคเครือข่ายประสาทแบบหลายชั้น (Multi-Layer Perceptron : MLP) และใช้การเรียนรู้ด้วยวิธีแพร่กระจายย้อนกลับ (Backpropagation learning algorithm) งานวิจัยนี้ใช้ตัวอักษรภาษาไทยรวม 75 ตัว แบ่งเป็นพยัญชนะ 44 ตัว สระ 14 ตัว วรรณยุกต์ 5 ตัว สัญลักษณ์ 2 ตัว และตัวเลขไทย 10 ตัว โดยมองถึงปัญหาของภาษาไทย เช่น ช่องว่างระหว่างตัวอักษร ลายเส้นโค้ง กลม และการที่ตัวอักษรมีหัว เป็นต้น จากการจัดวางพยัญชนะ สระ และวรรณยุกต์ร่วมกันทำให้แบ่งระดับของตัวอักษรได้ 4 ระดับ ทั้งนี้ได้มีการวิจัยเกี่ยวกับตัวอักษรเขียนด้วย ทำให้เมื่อนำเข้าข้อมูลแล้วจะมีการประมวลผลเบื้องต้นคือ การตัดส่วนเกินที่เกิดจากการลากเส้นออก และการหาตำแหน่งของการหักมุม ตัวอักษรในแต่ละตัวจะถูกแบ่งออกเป็น 6 ส่วนคือ 3 ส่วนตามแนวตั้งและอีก 3 ส่วนตามแนวนอน โดยแต่ละส่วนจะถูกนำไปคำนวณเพื่อหาอัตราส่วนของพิกเซลสีดำ การประมวลผลจะนำข้อมูลในแต่ละเฟรมมาซ้อนกัน การทดลองจะมีการแบ่งพื้นที่ออกเป็น 3 ส่วน คือ บน กลาง และล่าง ตามตำแหน่งของพยัญชนะ สระ และวรรณยุกต์ จากนั้นให้กลุ่มผู้เข้าทดลองเขียนตัวอักษรและทำการทดสอบการรู้จำ ผลที่ได้สามารถจดจำตัวอักษรได้เป็นอย่างดี

2.4.8 การรู้จำตัวอักษรภาษาไทยและภาษาอังกฤษโดยใช้เครือข่ายประสาท

งานวิจัยนี้ วิจัยโดย ชนิรินทร์ สุนทรระกุล (2543) เป็นงานวิจัยเพื่อรู้จำตัวอักษรจำนวน 94 ตัว แบ่งเป็นพยัญชนะ สระ สัญลักษณ์ และวรรณยุกต์ภาษาไทยรวม 68 ตัว และอักษรภาษาอังกฤษจำนวน 26 ตัว โดยนำเข้าข้อมูลรูปภาพแบบขาวดำ (Bi-Level) ตัวอักษรจะได้จากการสแกนเอกสารที่พิมพ์ด้วยตัวอักษรในแบบ AngsanaUPC, BrowaliaUPC และ CordiaUPC กำหนดให้มีขนาด 16, 22, 36 พิกเซล และเป็นตัวอักษรแบบปกติ วิเคราะห์องค์ประกอบหลัก (Principal Component Analysis: PCA) เพื่อสร้างเมทริกซ์ของความแปรปรวนร่วม (Covariance Matrix) จากข้อมูลภาพที่ได้ ถูกนำไปใช้ในการบีบอัดข้อมูล และการสร้างภาพใบหน้าไอเกน (Eigen Faces) ทำการปรับขนาดภาพให้มีขนาด 64 x 64 พิกเซล เพื่อให้ได้เวกเตอร์ขนาด 4096 สำหรับส่งผ่านขั้นตอนการรู้จำซึ่งเลือกใช้เครือข่ายประสาทเทียมแบบหลายชั้น (Multilayer Neural Network: MLP) หรือเครือข่ายประสาทแบบแพร่กระจายย้อนกลับ (Feed-Forward Backpropagation Neural Network) ซึ่งเป็นเครือข่ายประสาทแบบที่มีผู้สอน (Supervised Learning) ซึ่งกำหนดให้มีชั้นข้อมูลเข้า (input layer), ชั้นซ่อน (hidden layer) จำนวน 1 ชั้น และชั้นข้อมูลออก (output layer) และผลลัพธ์ที่ได้จะเป็นค่ารหัสแอสกี งานวิจัยนี้คำนึงถึงประสิทธิภาพในการรู้จำเท่านั้น

2.4.9 เทคนิคการวิเคราะห์หอนุกรมเวลาสำหรับการพยากรณ์ปริมาณผลผลิตผักและผลไม้

งานวิจัยนี้ วิจัยโดย ศิราภรณ์ วิชัยสินธุ์ และ รวิพิมพ์ ฉวีสุข (2552) ภาควิชาเทคโนโลยีอุตสาหกรรมเกษตร มหาวิทยาลัยเกษตรศาสตร์ โดยงานวิจัยนี้ ศึกษาเปรียบเทียบเทคนิคการวิเคราะห์หอนุกรมเวลาในการพยากรณ์ปริมาณผลผลิตผักและผลไม้ทั้งในระยะสั้น (ล่วงหน้า 1 หน่วยเวลาคือล่วงหน้า 1 ไตรมาสในผลผลิตผัก และล่วงหน้า 1 เดือนในผลผลิตผลไม้) และระยะยาว (ล่วงหน้าหลายหน่วยเวลา) ระหว่างวิธีปรับเรียบทางสถิติ 2 วิธี ได้แก่วิธีปรับให้เรียบแบบโฮลท์และวินเทอร์ที่มีฤดูกาลแบบบวก และวิธีปรับให้เรียบแบบโฮลท์และวินเทอร์ที่มีฤดูกาลแบบคูณ กับแบบจำลองเครือข่ายประสาทเทียมแบบส่งถ่ายข้อมูลย้อนกลับ (Backpropagation neural network: BPN) ผลการวิจัยพบว่าสำหรับวิธีปรับเรียบทางสถิติที่ให้ค่าความคลาดเคลื่อนต่ำที่สุด คือวิธีปรับให้เรียบแบบโฮลท์และวินเทอร์ที่มีฤดูกาลแบบบวก (Holt-Winters' additive seasonal smoothing: Additive HWS) และเมื่อนำแบบจำลองพยากรณ์จาก Additive HWS มาเปรียบเทียบกับแบบจำลอง BPN พบว่าผลการพยากรณ์ปริมาณผลผลิตผักในระยะสั้นนั้นแบบจำลองจากวิธี Additive HWS ให้ค่าความถูกต้องสูงกว่าแบบจำลอง BPN ส่วนผลการพยากรณ์ปริมาณผลผลิตผักในระยะยาวและการพยากรณ์ปริมาณผลผลิตผลไม้ในระยะสั้นและระยะยาวนั้น แบบจำลอง BPN ให้ค่าความถูกต้องของการพยากรณ์สูงกว่าแบบจำลอง Additive HWS อย่างไรก็ตามแบบจำลองทั้ง 2 ประเภทมีแนวโน้มที่จะพยากรณ์ได้สูงกว่าปริมาณผลผลิตจริง โดยที่แบบจำลอง Additive HWS

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

มีแนวโน้มที่จะเกิดความล่าช้าสูงกว่าแบบจำลอง BPN นอกจากนี้ แบบจำลอง BPN มีความสามารถในการพยากรณ์ข้อมูลในระยะยาวได้ดีกว่าระยะสั้น โดยรวมแล้วแบบจำลอง BPN มีความถูกต้องในการนำไปใช้งานในข้อมูลหลายรูปแบบได้ดีกว่าแบบจำลอง Additive HWS

2.5 เทคนิคการพยากรณ์

ตั้งแต่ปี ค.ศ. 1960 เทคนิคการพยากรณ์ได้รับความนิยม และได้รับการพัฒนาไปอย่างมากในเกือบทุกวงการ โดยเฉพาะในวงการธุรกิจ และการเงิน และณัฐพันธ์ เซจรนันท์ (2545) ได้อธิบายเกี่ยวกับการพยากรณ์ไว้หนังสือ การวิเคราะห์เชิงปริมาณทางธุรกิจ สามารถสรุปประเด็นสำคัญได้ดังนี้

2.5.1 ประเภทการพยากรณ์

โดยทั่วไปแล้วการพยากรณ์แบ่งออกเป็น 2 ประเภท คือการพยากรณ์เชิงคุณภาพ (Qualitative Forecasting) และการพยากรณ์เชิงปริมาณ (Quantitative Forecasting)

2.5.1.1 การพยากรณ์เชิงคุณภาพ (Qualitative Forecasting)

การพยากรณ์เชิงคุณภาพเป็นการพยากรณ์ที่อาศัยความรู้ ความสามารถ ประสบการณ์ ความชำนาญ รวมทั้งพิจารณาของผู้พยากรณ์โดยตรง ซึ่งในการเลือกใช้การพยากรณ์เชิงคุณภาพอาจเกิดจาก ผู้ทำการพยากรณ์ไม่ได้เก็บรวบรวมข้อมูลไว้ หรือมีไม่เพียงพอในการพยากรณ์เชิงปริมาณ เป็นต้น การพยากรณ์เชิงคุณภาพมีหลายวิธี ดังนี้

ความคิดเห็นของนักบริหาร (Jury of Executive Opinion)

ความคิดเห็นของนักบริหาร เป็นการระดมความคิดของผู้บริหารระดับสูง ปกติจะมีการใช้แบบจำลองทางสถิติ (Statistic Model) และการพยากรณ์เข้ามาช่วยในการทำ ความเข้าใจ และวิเคราะห์ปัญหา

วิธีเดลไฟ (Delphi Method)

วิธีเดลไฟ เป็นอีกวิธีหนึ่งที่นิยมใช้ โดยมีหลักคือ ค่าของการพยากรณ์จะไม่ใช่มาจากผู้ทำการพยากรณ์ แต่จะมาจากความคิดเห็นที่พ้องกันของบุคคลหลายๆฝ่าย ซึ่งจะไม่ใช่วิธีประชุมแสดงความคิดเห็น แต่จะมีการใช้แบบสอบถามอย่างต่อเนื่อง และมีความเป็นอิสระในการแสดงความคิดเห็น เพื่อป้องกันไม่ให้เกิดความเอนเอียงไปตามผู้เชี่ยวชาญคนใดคนหนึ่ง

วิธีวิจัยตลาด (Market Research)

วิธีวิจัยตลาด เป็นวิธีที่รวมเอาเทคนิคเชิงปริมาณอื่นๆเข้าไว้ใช้ประโยชน์ในด้านการพยากรณ์ เช่น ขนาดโครงสร้าง และขอบเขตของตลาดเป็นต้น ข้อมูลการวิจัยตลาดได้มาจากการส่งแบบสอบถาม การสำรวจทางโทรศัพท์ การอภิปรายกลุ่ม และการสัมภาษณ์ หลังจากนั้นนำจำนวนข้อมูลที่ได้มาทดสอบทางสถิติ เพื่อพิสูจน์สมมติฐานทางการตลาด วิธีการวิจัยตลาดเป็นวิธีที่เสียเวลา และค่าใช้จ่ายสูงที่สุด แต่ผลลัพธ์ก็ค่อนข้างจะถูกต้องแม่นยำที่สุดด้วย

2.5.1.2 การพยากรณ์เชิงปริมาณ (Quantitative Forecasting)

การพยากรณ์เชิงปริมาณ สามารถจำแนกได้เป็น 2 ประเภทใหญ่ๆ ได้ดังนี้

ประเภทที่ 1

การพยากรณ์ที่มีแนวคิดว่าการพฤติกรรมในอดีต สามารถที่จะอธิบาย หรือพยากรณ์สิ่งที่จะเกิดขึ้นในอนาคตได้ นั่นคือการนำข้อมูลในอดีตของตัวแปรที่สนใจเพียงตัวเดียวมาใช้ในการพยากรณ์ เทคนิคการพยากรณ์ที่สนับสนุนการพยากรณ์ในแนวคิดนี้ได้แก่ การพยากรณ์แบบปรับได้ (Adaptive Forecasting) เทคนิคการพยากรณ์แบบทำให้เรียบ (Smoothing techniques) การพยากรณ์โดยใช้ข้อมูลในอดีตที่มีลักษณะเป็นอนุกรมเวลา (Time Series) เป็นต้น

ประเภทที่ 2

การพยากรณ์ที่มีแนวคิดว่าการพฤติกรรมของสิ่งที่ต้องการพยากรณ์อาจขึ้นกับการเปลี่ยนแปลงของสิ่งอื่นๆ ซึ่งมีความสัมพันธ์บางอย่างกับสิ่งที่ต้องการพยากรณ์นั้นๆ ซึ่งโดยรวมแล้วการพยากรณ์ประเภทนี้ ยังคงอยู่บนพื้นฐานของการพยากรณ์ประเภทที่หนึ่ง เพียงแต่มีการพิจารณาตัวแปรอื่นๆร่วมด้วย นอกเหนือจากตัวแปรที่จะทำการพยากรณ์ เช่น การพยากรณ์อัตราแลกเปลี่ยนระหว่างประเทศ อาจมีการพิจารณาถึงปัจจัยต่างๆ ที่เกี่ยวข้องได้แก่ ปริมาณของอุปสงค์และอุปทานต่อเงินตราต่างประเทศ เป็นต้น เทคนิคการพยากรณ์ที่สนับสนุนการพยากรณ์ในแนวคิดนี้ได้แก่ การพยากรณ์ด้วยการวิเคราะห์การถดถอย (Regressive Forecasting) และการพยากรณ์เชิงเศรษฐมิติ (Econometric Forecasting) เป็นต้น

2.5.2 การวัดระดับความถูกต้อง

การวัดระดับความถูกต้องของค่าพยากรณ์ที่ระบบทำนายออกมา (\hat{y}_t) ทำได้โดยการนำไปเปรียบเทียบกับค่าที่เกิดขึ้นจริง (y_t) และหาค่าเฉลี่ยความคลาดเคลื่อนโดยรวมของการพยากรณ์นั้นๆ ซึ่งมีรูปแบบการวัดที่นิยมใช้ดังนี้

Mean Absolute Error: MAE

$$\text{MAE} = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \dots\dots\dots(2.30)$$

Mean Absolute Percentage Error: MAPE

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \dots\dots\dots(2.31)$$

Mean Squared Error: MSE

$$\text{MSE} = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2 \dots\dots\dots(2.32)$$

Root Mean Squared Error: RMSE


$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \dots\dots\dots(2.33)$$

2.6 ข้อมูลอนุกรมเวลา (Time Series)

ข้อมูลอนุกรมเวลา คือ ข้อมูลที่มีลักษณะเกิดขึ้นในช่วงเวลาที่ต่อเนื่องกัน และมีระยะห่างของช่วงเวลาที่เท่ากัน โดยหน่วยเวลาอาจเป็น ปี เดือน วัน ชั่วโมง นาที หรือแม้แต่วินาที เป็นต้น ข้อมูลอนุกรมเวลา แบ่งออกเป็น 4 ลักษณะย่อยได้ดังนี้

2.6.1 ข้อมูลอนุกรมเวลาแบบแนวโน้ม (Trend Time Series)


ข้อมูลอนุกรมเวลาแบบแนวโน้ม คือ ลักษณะการเปลี่ยนแปลงข้อมูลที่มีแนวโน้มเพิ่มขึ้น หรือลดลงอย่างสม่ำเสมอชัดเจน เมื่อเวลาผ่านไประยะหนึ่ง แสดงตัวอย่างดังรูปที่ 2.10



รูปที่ 2.10 ข้อมูลอนุกรมเวลาแบบแนวโน้ม

2.6.2 ข้อมูลอนุกรมเวลาแบบฤดูกาล (Seasonal Time Series)

ข้อมูลอนุกรมเวลาแบบฤดูกาล คือลักษณะการเปลี่ยนแปลงของข้อมูลที่มีรูปแบบซ้ำๆกัน ในแต่ละช่วงเวลาหนึ่งๆ เช่น ทุกๆปี ซึ่งมักพบในข้อมูลที่เป็นแบบรายปี หรือมากกว่า แสดงตัวอย่างดังรูปที่ 2.11



รูปที่ 2.11 ข้อมูลอนุกรมเวลาแบบฤดูกาล

2.6.3 ข้อมูลอนุกรมเวลาแบบวัฏจักร (Cycle Time Series)


ข้อมูลอนุกรมเวลาแบบวัฏจักร คือลักษณะการเปลี่ยนแปลงของข้อมูลที่เกิดขึ้นซ้ำๆกัน คล้ายกับแบบฤดูกาล แต่แบบวัฏจักรนี้ แต่ละช่วงเวลาอาจไม่เท่ากัน เช่น วัฏจักรทางธุรกิจ (Business life cycle) ช่วงระยะฟื้นตัวในแต่ละครั้งอาจใช้เวลานาน้อยต่างกัน แสดงตัวอย่างดังรูปที่ 2.12



รูปที่ 2.12 ข้อมูลอนุกรมเวลาแบบวัฏจักร

2.6.4 ข้อมูลอนุกรมเวลาแบบผิดปกติ (Irregular)

ข้อมูลอนุกรมเวลาแบบผิดปกติ คือลักษณะการเปลี่ยนแปลงข้อมูลที่ผิดปกติไปจากเดิม อาจเนื่องมาจากปัจจัยภายนอกที่ไม่คาดคิด เช่น น้ำท่วม แผ่นดินไหว หรือสงคราม เป็นต้น แสดงตัวอย่างดังรูปที่ 2.13



รูปที่ 2.13 ข้อมูลอนุกรมเวลาแบบผิดปกติ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 3


แนวทางการวิจัย

จากบทที่ผ่านมา ได้อธิบายลักษณะสำคัญของโครงข่ายแบบแพร่กระจายย้อนกลับที่ประกอบด้วยชั้นต่างๆของโครงข่าย สมการที่ใช้คำนวณหาผลลัพธ์จากโครงข่าย และสมการที่ปรับค่าน้ำหนักเพื่อให้ได้ผลที่ถูกต้องตรงตามค่าเป้าหมาย อีกทั้งอธิบายถึงการปรับปรุงโครงสร้างของโครงข่ายเป็นแบบรีเคอร์เรนต์ เช่น โครงข่ายแบบ Jordan และแบบ Elman แต่ยังคงใช้สมการ และค่าน้ำหนักในแบบเดียวกับโครงข่ายแบบแพร่กระจายย้อนกลับ ส่วนในงานวิจัยนี้จะนำเสนอโครงข่ายที่ปรับปรุงค่าน้ำหนักให้มีหลายเซกเมนต์ เพื่อให้ผลที่ถูกต้องตามแต่ข้อมูลที่เข้ามา ซึ่งสามารถประยุกต์ใช้ได้ทั้งแบบแพร่กระจายย้อนกลับ และแบบรีเคอร์เรนต์ ดังจะได้อธิบายรายละเอียดต่อไป

3.1 การรู้จักของโครงข่ายที่ใช้ค่าน้ำหนักแบบเดิม

จากโครงข่ายประสาทเทียมที่ได้อธิบายในบทที่ผ่านมา จะมีค่าน้ำหนักประจำของแต่ละการเชื่อมโยง โหนด เป็นค่าน้ำหนักเพียงค่าเดียว เมื่อมีข้อมูลเข้ามา ก็จะนำมาคูณกับค่าน้ำหนักเพื่อหาผล และเมื่อมีการปรับค่าน้ำหนัก ก็จะปรับค่าน้ำหนักนั้นอีก ซึ่งแสดงว่าค่าน้ำหนักนั้นจะต้องถูกปรับค่าให้เหมาะกับทุกๆข้อมูลที่เข้ามา ซึ่งอาจทำให้ได้ผลลัพธ์ไม่ดีเท่าที่ควร

ตัวอย่างเช่น ข้อมูล nine เป็นข้อมูลที่สร้างขึ้นเพื่อใช้ทดสอบประสิทธิภาพของโมเดลการจำแนกข้อมูล โดยเฉพาะ ซึ่งข้อมูลมีลักษณะพันเกลียวสลับกันอยู่ 4 กลาส ในลักษณะที่ใกล้เคียงกันมาก แสดงดังรูปที่ 3.1




รูปที่ 3.1 กราฟแสดงลักษณะข้อมูล nine

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 3.1 มี 2 คุณลักษณะ (feature) คือ x_1 และ x_2 ใช้ตัวอย่างข้อมูลโดยให้ค่า x_2 คงที่ คือเท่ากับ 0.5 แต่ถ้าค่า x_1 มีค่าเท่ากับ 0.15 ซึ่งข้อมูลคือ (0.5, 0.15) จะอยู่ในคลาส 4 แต่ถ้าค่า x_1 มีค่าเท่ากับ 0.2 ซึ่งข้อมูลคือ (0.5, 0.2) จะอยู่ในคลาส 3 ดังจะเห็นได้ว่า ค่า x_1 มีค่าเปลี่ยนไปเพียง 0.05 ค่าเป้าหมายหรือคลาสก็จะเปลี่ยนไปด้วย ซึ่งจากรูปยังแสดงให้เห็นอีกว่า ข้อมูลยังมีหลายช่วงที่มีลักษณะดังกล่าวข้างต้น

จากข้อมูล nine ข้างต้น เมื่อนำไปทดสอบโครงข่ายประสาทเทียมแบบแพร่กระจายย้อนกลับที่ใช้ค่าน้ำหนักเพียงค่าเดียว ก็จะทำให้ค่าน้ำหนักเพียงค่าเดียวในแต่ละการเชื่อมโหนดนั้น จะต้องถูกปรับไปมา เพื่อให้ผลลัพธ์ตรงตามค่าเป้าหมายหรือคลาสนั้นๆ อยู่เสมอ ดังจากการทดลอง ได้ความถูกต้อง 63.6%

ในงานวิจัยนี้จึงมีแนวคิดว่าจะเพิ่มประสิทธิภาพของโครงข่ายฯ ให้มากขึ้น ซึ่งจากการทดลอง การสังเกตข้อมูล และความเข้าใจในอัลกอริทึมแบบแพร่กระจายย้อนกลับ จึงเห็นว่าควรปรับค่าน้ำหนักของแต่ละเส้นเชื่อมโหนดนั้น ให้มีหลายเซกเมนต์ได้ โดยการเลือกใช้ให้เหมาะสมกับค่าข้อมูลเข้าหนึ่งๆ เพื่อให้ผลที่ถูกต้อง ตามที่แต่ละข้อมูลเข้าได้มากยิ่งขึ้น



รูปที่ 3.2 กราฟค่าน้ำหนักแบบค่าเดียว และกราฟค่าน้ำหนักแบบใหม่

จากรูปที่ 3.2(ก) แสดงกราฟค่าน้ำหนักแบบค่าเดียว ซึ่งเมื่อมีค่าข้อมูลเข้า x ใดๆ ก็จะใช้ค่าน้ำหนัก 0.2 ในการคำนวณของโครงข่ายฯ แต่จากรูปที่ 3.2(ข) แสดงค่าน้ำหนักแบบเซกเมนต์ซึ่งค่าน้ำหนักจะแปรผันตามค่าข้อมูลเข้า x เช่น $x = 0$ จะใช้ค่าน้ำหนัก -0.5 แต่ถ้า $x = 1$ จะใช้ค่าน้ำหนัก 0.8 ในการคำนวณของโครงข่ายฯ เป็นต้น

เพื่อให้เข้าใจการประยุกต์ใช้ค่าน้ำหนักหลายเซกเมนต์ กับโครงข่ายฯ แบบเดิม จึงจะอธิบายการใช้ค่าน้ำหนักเซกเมนต์ร่วมกับอัลกอริทึมของโครงข่ายฯ ทั้ง 3 แบบ คือแบบแพร่กระจายย้อนกลับ แบบ Jordan และแบบ Elman ไปพร้อมๆ กัน ดังรายละเอียดในหัวข้อถัดไป

3.2 อัลกอริทึมโครงข่ายประสาทเทียมกับการใช้ค่าน้ำหนักแบบหลายเซกเมนต์


- ก) กำหนดจำนวน โหนดในชั้นซ่อน
- ข) ปรับค่าข้อมูลเข้าให้อยู่ในช่วง (0, 1)
- ค) สุ่มค่าน้ำหนักให้แต่ละเส้นเชื่อมโยงโหนด

โดยการสุ่มตัวเลขใดๆที่อยู่ในช่วง (-1, 1) ไม่ซ้ำกัน จำนวน 2 ค่า เพื่อใช้เป็นค่าน้ำหนักอ้างอิง 2 จุด ที่ครอบคลุมตลอดช่วงข้อมูล เช่น ข้อมูลเข้าถูกปรับให้อยู่ในช่วง (0, 1) ตามขั้นตอน ข) ดังนั้นค่าน้ำหนักที่สุ่มมา ก็ต้องให้ใช้ได้ครอบคลุมตลอดช่วง (0, 1) เป็นต้น

จากที่ ค่าข้อมูลเข้าของแต่ละเส้นเชื่อมโยงจะอยู่ในช่วง (0, 1) ซึ่งเป็นไปตามขั้นตอน ข) นั้น ในที่นี้จะเรียกว่า 1 เซกเมนต์ (segment) ใน 1 เซกเมนต์นี้ จะมีจุดอ้างอิง 2 จุด (points) คือ ค่าที่น้อยที่สุดของเซกเมนต์ หรือขอบเขตล่างของเซกเมนต์ (คือ 0) และค่ามากที่สุดของเซกเมนต์ หรือขอบเขตบนของเซกเมนต์ (คือ 1) ดังนั้น ค่าที่สุ่มมา 2 ค่า ค่าหนึ่งจะกำหนดเป็นค่าน้ำหนักสำหรับค่าน้อยที่สุดของเซกเมนต์ และอีกค่าหนึ่ง จะเป็นค่าน้ำหนักสำหรับค่ามากที่สุดของเซกเมนต์

ตัวอย่างเช่น สุ่มค่ามาได้ 2 ค่า คือ -0.5 และ 0.8 กำหนดให้ -0.5 เป็นค่าน้ำหนักของขอบเขตล่างของเซกเมนต์ คือ $w(0) = -0.5$ และกำหนดให้ 0.8 เป็นค่าน้ำหนักของขอบเขตบนของเซกเมนต์ คือ $w(1) = 0.8$ ซึ่งจากการกำหนดค่าดังกล่าว แสดงกราฟค่าน้ำหนักได้ดังรูปที่ 3.3(ก)

อีกตัวอย่างเช่น สุ่มค่ามาได้ 2 ค่า คือ 0.9 และ -0.45 กำหนดให้ 0.9 เป็นค่าน้ำหนักของขอบเขตล่างของเซกเมนต์ คือ $w(0) = 0.9$ และกำหนดให้ -0.45 เป็นค่าน้ำหนักของขอบเขตบนของเซกเมนต์ คือ $w(1) = -0.45$ ซึ่งจากการกำหนดค่าดังกล่าว แสดงกราฟค่าน้ำหนักได้ดังรูปที่ 3.3(ข)



รูปที่ 3.3 ตัวอย่างกราฟค่าน้ำหนักแบบเซกเมนต์

จากรูปที่ 3.3 ตัวอย่างกราฟค่าน้ำหนักแบบเซกเมนต์ ที่ค่าน้ำหนักแปรผันตามข้อมูลเข้า ซึ่งแต่ละกราฟกำหนดจุดอ้างอิงค่าน้ำหนักไว้เพียง 2 จุด ถ้าข้อมูลเข้า (x) มีค่า 0 หรือ 1 ก็จะทราบค่าน้ำหนักได้ทันที เช่น จากรูปที่ 3.3(ก) ถ้าข้อมูลเข้าเป็น 0 ก็จะได้ค่าน้ำหนักคือ -0.5 และถ้าข้อมูลเข้าเป็น 1 ก็จะได้ค่าน้ำหนักคือ 0.8 ตามค่าน้ำหนักที่สุ่ม และกำหนดไว้ เป็นต้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

แต่ถ้าข้อมูลเข้าเป็นค่าใดๆ ที่ไม่ได้กำหนดค่าน้ำหนักไว้ ก็สามารถหาค่าน้ำหนักจากจุดอ้างอิงค่าน้ำหนักใกล้เคียงได้ ดังสมการ (3.1)

$$w(x) = w(L) + \frac{x-L}{U-L}(w(U)-w(L)) \dots\dots\dots(3.1)$$

L คือขอบเขตล่าง และ U คือขอบเขตบนของเซกเมนต์ ที่ค่า x มีค่าอยู่ในเซกเมนต์นั้น ตัวอย่างจากรูปที่ 3.3(ก) เมื่อต้องการหาค่าน้ำหนักของ $x = 0.2$ ซึ่งกำหนดค่าน้ำหนักไว้เพียง $w(0) = -0.5$ และ $w(1) = 0.8$ จากการกำหนดดังกล่าว ก็จะทราบว่าขอบเขตล่างคือ $L = 0$ และขอบเขตบนคือ $U = 1$ ดังนั้นแทนค่าในสมการ (3.1) ได้ดังนี้

$$w(0.2) = -0.5 + \frac{0.2-0}{1-0}(0.8-(-0.5)) = -0.24$$

ดังนั้น $w(x=0.2) = -0.24$

ง) ชั้นข้อมูลเข้า ประกอบด้วยหน่วยข้อมูลเข้า และหน่วยบริบท

ง.1) หน่วยข้อมูลเข้า รับข้อมูลเข้ามาจากภายนอก

$$o_i^I = x_i \dots\dots\dots(3.2)$$

ง.2) หน่วยบริบท เป็นหน่วยป้อนข้อมูลกลับจากภายในโครงข่ายฯ ซึ่งจะแตกต่างกันในแต่ละแบบของโครงข่ายฯ โดยโครงข่ายแบบ Elman จะป้อนกลับมาจากชั้นซ่อนแสดงดังสมการ (3.3) โครงข่ายแบบ Jordan จะป้อนกลับมาจากชั้นข้อมูลออกแสดงดังสมการ (3.4) ดังนั้น จำนวนโหนดในชั้นบริบท (N^c) ของโครงข่ายฯแบบ Elman จะเท่ากับจำนวนโหนดในชั้นซ่อน ($N^c=N^H$) และของแบบ Jordan จะเท่ากับจำนวนโหนดในชั้นข้อมูลออก ($N^c=N^O$)

$$o_i^c = o_i^H(t-1) \dots\dots\dots(3.3)$$

$$o_i^c = o_i^O(t-1) \dots\dots\dots(3.4)$$

แต่สำหรับ โครงข่ายฯแบบแพร่กระจายย้อนกลับจะไม่มีส่วนบริบท ดังนั้นไม่ต้องดำเนินการใดๆในชั้นตอนนี้ ซึ่งจะทำให้จำนวนโหนดในหน่วยบริบท (N^c) ของโครงข่ายฯแบบแพร่กระจายย้อนกลับเท่ากับ 0 ($N^c=0$) ไปโดยปริยาย

จ) ชั้นซ่อน จะประมวลผลข้อมูลที่เข้ามาจากหน่วยข้อมูลเข้า และหน่วยบริบท แสดงดังสมการ (3.5) และ (3.6)

$$o_j^H = f(\text{net}_j^H) \dots\dots\dots(3.5)$$

$$\text{net}_j^{\text{II}} = \sum_{i=1}^{N^{\text{I}}} w_{ij}^{\text{II}}(o_i^{\text{I}})o_i^{\text{I}} + \sum_{i=1}^{N^{\text{c}}} w_{ij}^{\text{IIc}}(o_i^{\text{c}})o_i^{\text{c}} \dots\dots\dots(3.6)$$

$f(\cdot)$ ฟังก์ชันกระตุ้น ในที่นี้ใช้ฟังก์ชัน sigmoid ตลอดโครงข่ายฯ

$w_{ij}^{\text{II}}, w_{ij}^{\text{IIc}}$ เป็นค่าน้ำหนักที่แปรผันตามข้อมูลเข้า หากทำได้ดังสมการ (3.1)

แต่สำหรับโครงข่ายฯแบบแพร่กระจายย้อนกลับ ไม่มีหน่วยบริบท ($N^{\text{c}}=0$) ดังนั้นในพจน์หลังของสมการ (3.6) จะมีค่าเป็น 0 ซึ่งสามารถเขียนใหม่ได้ดังสมการ (3.7)

$$\text{net}_j^{\text{II}} = \sum_{i=1}^{N^{\text{I}}} w_{ij}^{\text{II}}(o_i^{\text{I}})o_i^{\text{I}} \dots\dots\dots(3.7)$$

กล่าวโดยสรุปคือ สำหรับโครงข่ายฯแบบ Jordan และแบบ Elman ใช้สมการ (3.5) และ (3.6) แต่สำหรับโครงข่ายฯแบบแพร่กระจายย้อนกลับใช้สมการ (3.5) และ (3.7)

ฉ) ชั้นข้อมูลออก จะประมวลผลข้อมูลที่เข้ามาจากชั้นซ่อน แสดงดังสมการ (3.8) และ (3.9)

$$o_j^{\text{III}} = f(\text{net}_j^{\text{III}}) \dots\dots\dots(3.8)$$

$$\text{net}_j^{\text{III}} = \sum_{i=1}^{N^{\text{II}}} w_{ij}^{\text{III}}(o_i^{\text{II}})o_i^{\text{II}} \dots\dots\dots(3.9)$$

w_{ij}^{III} เป็นค่าน้ำหนักที่แปรผันตามข้อมูลเข้า หากทำได้ดังสมการ (3.1)

ช) เปรียบเทียบผลกับค่าเป้าหมาย เพื่อหาค่าความผิดพลาด

$$\text{error} = \frac{1}{2} \sum_{i=1}^{N^{\text{III}}} (y_i - o_i^{\text{III}})^2 \dots\dots\dots(3.10)$$

y_i คือค่าเป้าหมายของโหนดที่ i ในชั้นข้อมูลออก

ซ) ปรับค่าน้ำหนักในชั้นข้อมูลออก โดยปรับที่ขอบเขตล่างและขอบเขตบนของเซกเมนต์ในอัตราส่วนความใกล้เคียงของค่าข้อมูลเข้า

สมการปรับค่าน้ำหนักในขอบเขตล่างแสดงดังสมการ (3.11) (3.13) (3.15) (3.16) (3.17) และ (3.18)

สมการปรับค่าน้ำหนักในขอบเขตบนแสดงดังสมการ (3.12) (3.14) (3.15) (3.16) (3.17) และ (3.19)

$$w_{ij}^{\text{III}}(L)^{\text{new}} = w_{ij}^{\text{III}}(L)^{\text{old}} + \eta \left[\frac{\partial E}{\partial w_{ij}^{\text{III}}(L)} \right] \dots\dots\dots(3.11)$$

$$w_{ij}^{III}(U)^{new} = w_{ij}^{III}(U)^{old} + \eta \left[\frac{\partial E}{\partial w_{ij}^{III}(U)} \right] \dots\dots\dots(3.12)$$

$$\left[\frac{\partial E}{\partial w_{ij}^{III}(L)} \right] = \left[\frac{\partial E}{\partial o_j^{III}} \right] \left[\frac{\partial o_j^{III}}{\partial net_j^{III}} \right] \left[\frac{\partial net_j^{III}}{\partial w_{ij}^{III}(o_i^{II})} \right] \left[\frac{\partial w_{ij}^{III}(o_i^{II})}{\partial w_{ij}^{III}(L)} \right] \dots\dots\dots(3.13)$$

$$\left[\frac{\partial E}{\partial w_{ij}^{III}(U)} \right] = \left[\frac{\partial E}{\partial o_j^{III}} \right] \left[\frac{\partial o_j^{III}}{\partial net_j^{III}} \right] \left[\frac{\partial net_j^{III}}{\partial w_{ij}^{III}(o_i^{II})} \right] \left[\frac{\partial w_{ij}^{III}(o_i^{II})}{\partial w_{ij}^{III}(U)} \right] \dots\dots\dots(3.14)$$

$$\left[\frac{\partial E}{\partial o_j^{III}} \right] = y_j - o_j^{III} \dots\dots\dots(3.15)$$

$$\left[\frac{\partial o_j^{III}}{\partial net_j^{III}} \right] = o_j^{III} (1 - o_j^{III}) \dots\dots\dots(3.16)$$

$$\left[\frac{\partial net_j^{III}}{\partial w_{ij}^{III}(o_i^{II})} \right] = o_i^{II} \dots\dots\dots(3.17)$$

$$\left[\frac{\partial w_{ij}^{III}(o_i^{II})}{\partial w_{ij}^{III}(L)} \right] = \frac{U - o_i^{II}}{U - L} \dots\dots\dots(3.18)$$

$$\left[\frac{\partial w_{ij}^{III}(o_i^{II})}{\partial w_{ij}^{III}(U)} \right] = \frac{o_i^{II} - L}{U - L} \dots\dots\dots(3.19)$$

๓ อัตรการเรียนรู้ของโครงข่ายฯ

ฉ) ปรับค่าน้ำหนักในชั้นซ่อน ที่เชื่อมโยงกับหน่วยข้อมูลเข้า โดยปรับที่ขอบเขตล่างและขอบเขตบนของเซกเมนต์ในอัตราส่วนความใกล้เคียงของค่าข้อมูลเข้า

สมการปรับค่าน้ำหนักในขอบเขตล่างแสดงดังสมการ (3.20) (3.22) (3.24) (3.25) (3.26) และ (3.27)

สมการปรับค่าน้ำหนักในขอบเขตบนแสดงดังสมการ (3.21) (3.23) (3.24) (3.25) (3.26) และ (3.28)

$$w_{ij}^{II}(L)^{new} = w_{ij}^{II}(L)^{old} + \eta \left[\frac{\partial E}{\partial w_{ij}^{II}(L)} \right] \dots\dots\dots(3.20)$$

$$w_{ij}^{II}(U)^{new} = w_{ij}^{II}(U)^{old} + \eta \left[\frac{\partial E}{\partial w_{ij}^{II}(U)} \right] \dots\dots\dots(3.21)$$

$$\left[\frac{\partial E}{\partial w_{ij}^{II}(L)} \right] = \left[\frac{\partial E}{\partial o_j^{II}} \right] \left[\frac{\partial o_j^{II}}{\partial net_j^{II}} \right] \left[\frac{\partial net_j^{II}}{\partial w_{ij}^{II}(o_i^I)} \right] \left[\frac{\partial w_{ij}^{II}(o_i^I)}{\partial w_{ij}^{II}(L)} \right] \dots\dots\dots(3.22)$$

$$\left[\frac{\partial E}{\partial w_{ij}^{II}(U)} \right] = \left[\frac{\partial E}{\partial o_j^{II}} \right] \left[\frac{\partial o_j^{II}}{\partial net_j^{II}} \right] \left[\frac{\partial net_j^{II}}{\partial w_{ij}^{II}(o_i^I)} \right] \left[\frac{\partial w_{ij}^{II}(o_i^I)}{\partial w_{ij}^{II}(U)} \right] \dots\dots\dots(3.23)$$

$$\left[\frac{\partial E}{\partial o_j^{II}} \right] = \sum_{k=1}^{N^{III}} (y_k - o_k^{III})(o_k^{III}(1 - o_k^{III}))w_{jk}^{III} \dots\dots\dots(3.24)$$

$$\left[\frac{\partial o_j^{II}}{\partial net_j^{II}} \right] = o_j^{II}(1 - o_j^{II}) \dots\dots\dots(3.25)$$

$$\left[\frac{\partial net_j^{II}}{\partial w_{ij}^{II}(o_i^I)} \right] = o_i^I \dots\dots\dots(3.26)$$

$$\left[\frac{\partial w_{ij}^{II}(o_i^I)}{\partial w_{ij}^{II}(L)} \right] = \frac{U - o_i^I}{U - L} \dots\dots\dots(3.27)$$

$$\left[\frac{\partial w_{ij}^{II}(o_i^I)}{\partial w_{ij}^{II}(U)} \right] = \frac{o_i^I - L}{U - L} \dots\dots\dots(3.28)$$

ญ) ปรับค่าน้ำหนักในชั้นซ่อน ที่เชื่อมโยงกับหน่วยบริบท โดยปรับที่ขอบเขตล่างและขอบเขตบนของเซกเมนต์ในอัตราส่วนความใกล้เคียงของค่าข้อมูลเข้า

โดยหน่วยบริบทจะมีเฉพาะในโครงข่ายแบบ Jordan และแบบ Elman ดังนั้นสำหรับโครงข่ายแบบแพร่กระจายย้อนกลับ ซึ่งไม่มีหน่วยบริบทก็ข้ามขั้นตอนนี้ไปได้

สมการปรับค่าน้ำหนักในขอบเขตล่างแสดงดังสมการ (3.29) (3.31) (3.24) (3.25) (3.33) และ (3.34)

สมการปรับค่าน้ำหนักในขอบเขตบนแสดงดังสมการ (3.30) (3.32) (3.24) (3.25) (3.33) และ (3.35)

$$w_{ij}^{IIc}(L)^{new} = w_{ij}^{IIc}(L)^{old} + \eta \left[\frac{\partial E}{\partial w_{ij}^{IIc}(L)} \right] \dots\dots\dots(3.29)$$

$$w_{ij}^{IIc}(U)^{new} = w_{ij}^{IIc}(U)^{old} + \eta \left[\frac{\partial E}{\partial w_{ij}^{IIc}(U)} \right] \dots\dots\dots(3.30)$$

$$\left[\frac{\partial E}{\partial w_{ij}^{IIc}(L)} \right] = \left[\frac{\partial E}{\partial o_j^{II}} \right] \left[\frac{\partial o_j^{II}}{\partial net_j^{II}} \right] \left[\frac{\partial net_j^{II}}{\partial w_{ij}^{IIc}(o_i^c)} \right] \left[\frac{\partial w_{ij}^{IIc}(o_i^c)}{\partial w_{ij}^{IIc}(L)} \right] \dots\dots\dots(3.31)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\left[\frac{\partial E}{\partial w_{ij}^{lc}(U)} \right] = \left[\frac{\partial E}{\partial o_j^H} \right] \left[\frac{\partial o_j^H}{\partial net_j^H} \right] \left[\frac{\partial net_j^H}{\partial w_{ij}^{lc}(o_i^c)} \right] \left[\frac{\partial w_{ij}^{lc}(o_i^c)}{\partial w_{ij}^{lc}(U)} \right] \dots\dots\dots(3.32)$$

$$\left[\frac{\partial net_j^H}{\partial w_{ij}^H(o_i^c)} \right] = o_i^c \dots\dots\dots(3.33)$$

$$\left[\frac{\partial w_{ij}^H(o_i^c)}{\partial w_{ij}^H(L)} \right] = \frac{U - o_i^c}{U - L} \dots\dots\dots(3.34)$$

$$\left[\frac{\partial w_{ij}^H(o_i^c)}{\partial w_{ij}^H(U)} \right] = \frac{o_i^c - L}{U - L} \dots\dots\dots(3.35)$$

ฎ) ป้อนข้อมูลใหม่ และทำขั้นตอน ง) - ฉ) จนครบทุกข้อมูลนั้นๆ เช่น ชุดข้อมูลการเรียนรู้ (training data set) หรือชุดข้อมูลทดสอบ (testing data set) เป็นต้น เมื่อครบข้อมูลชุดหนึ่งๆแล้ว นับเพิ่มอีก 1 รอบข้อมูล เช่นถ้าเป็นการเรียนรู้ข้อมูล นับเพิ่ม 1 รอบการเรียนรู้

ฏ) หาผลผิดพลาดโดยรวมของโครงข่ายฯ แสดงดังสมการ (3.36)-(3.38)

กรณีอยู่ในขั้นตอนการเรียนรู้ของโครงข่ายฯ ถ้าค่าความผิดพลาดโดยรวมของโครงข่ายฯยังมีค่าที่สูงอยู่ หรือยังไม่อยู่ในระดับที่ยอมรับ ก็สามารให้โครงข่ายฯเรียนรู้ข้อมูลชุดนั้นใหม่ได้ โดยทำตามขั้นตอน ง)-ฎ) อีก จนกว่าจะได้ค่าความผิดพลาดโดยรวมของโครงข่ายฯเป็นที่ยอมรับ หรือจนกว่าจะครบจำนวนรอบการเรียนรู้ ตามที่ได้กำหนดไว้ เช่น 100 รอบการเรียนรู้ เป็นต้น

กรณีวัดประสิทธิภาพของโครงข่ายฯ คือการนำชุดข้อมูลทดสอบ (testing data set) ป้อนเข้าโครงข่ายฯ โดยทำตามขั้นตอน ง)-ฉ) จนครบทุกข้อมูล และหาค่าความผิดพลาดโดยรวมของโครงข่ายฯ ดังสมการ (3.36) หรือ (3.37) หรือ (3.38)

$$MSE = \frac{\sum_{p=1}^P \sum_{i=1}^{N^{III}} (y_i^p - o_i^{pIII})^2}{P \cdot N^{III}} \dots\dots\dots(3.36)$$

$$RMSE = \sqrt{\frac{\sum_{p=1}^P \sum_{i=1}^{N^{III}} (y_i^p - o_i^{pIII})^2}{P \cdot N^{III}}} \dots\dots\dots(3.37)$$

$$MAPE = \frac{\sum_{p=1}^P \sum_{i=1}^{N^{III}} \left| \frac{y_i^p - o_i^{pIII}}{y_i^p} \right|}{P \cdot N^{III}} \dots\dots\dots(3.38)$$

y_i^p คือค่าเป้าหมายของโหนดที่ i ในชั้นข้อมูลออก ของชุดข้อมูลลำดับที่ p

o_i^{pIII} คือค่าข้อมูลออกของโหนดที่ i ในชั้นข้อมูลออก ของชุดข้อมูลลำดับที่ p

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

N''' คือจำนวนโหนดในชั้นข้อมูลออก

P จำนวนข้อมูลในแต่ละชุด เช่น ชุดข้อมูลเรียนรู้ (Training data) ชุดข้อมูลทดสอบ (Testing data) เป็นต้น

ฐ) การนำโครงข่ายฯ ไปใช้งานโดยป้อนข้อมูลเข้า และทำขั้นตอน ง) – ฉ) ซึ่งจะให้ผลของโครงข่ายฯ ในชั้นข้อมูลออก ตามที่โครงข่ายฯ ได้เคยเรียนรู้มา

จากอัลกอริทึมข้างต้น เป็นการทำงานของโครงข่ายฯ ที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์ ซึ่งค่าน้ำหนักจะแปรผันตามข้อมูลเข้า โดยแต่ละค่าน้ำหนักมีเพียงเซกเมนต์เดียว กล่าวคือมีจุดอ้างอิงค่าน้ำหนักเพียง 2 ค่า ที่ครอบคลุมข้อมูลเข้าทั้งหมด $[0, 1]$ ในหัวข้อถัดไปจะเป็นการเพิ่มเซกเมนต์ให้มากขึ้นตั้งแต่ขั้นตอนการสุ่มค่าน้ำหนัก ส่วนการเพิ่มเซกเมนต์ในระหว่างการเรียนรู้จะอธิบายเป็นอีกหัวข้อ ในหัวข้อถัดไป

3.3 การเพิ่มเซกเมนต์ของค่าน้ำหนักในขั้นตอนการสุ่มค่าน้ำหนัก

ค่าน้ำหนักแบบเซกเมนต์ จะมีเซกเมนต์ที่ครอบคลุมค่าข้อมูลเข้าช่วงหนึ่งๆ ซึ่งจากอัลกอริทึมในหัวข้อ 3.2 ขั้นตอน ก) อธิบายการสุ่มค่าน้ำหนักที่กำหนดเซกเมนต์เพียงเซกเมนต์เดียว โดยมองว่าค่าน้ำหนักในแต่ละการเชื่อม โหนดมีทิศทางไปในทางเดียวกัน เช่น จากรูปที่ 3.3(ก) ข้อมูลมีค่าน้อยก็จะใช้ค่าน้ำหนักน้อย ข้อมูลมีค่ามากก็จะใช้ค่าน้ำหนักมาก ส่วนจากรูปที่ 3.3(ข) ข้อมูลที่มีค่าน้อยจะใช้ค่าน้ำหนักมาก ข้อมูลที่มีค่ามากก็จะใช้ค่าน้ำหนักน้อย ซึ่งทั้ง 2 แบบแสดงค่าน้ำหนักแปรผันตามข้อมูลไปในทิศทางเดียวกันตลอดช่วงข้อมูล ไม่ทางใด ก็ทางหนึ่ง

แต่ถ้าค่าน้ำหนักไม่แปรผันตามข้อมูลในทิศทางเดียวกันตลอดช่วงข้อมูล ก็อาจกำหนดเป็นหลายเซกเมนต์ โดยการกำหนดเพิ่มจุดอ้างอิงค่าน้ำหนัก ซึ่งในหัวข้อนี้เป็นการเพิ่มจุดอ้างอิงในขั้นตอนการสุ่มค่าน้ำหนัก ดังนั้นจากอัลกอริทึมในหัวข้อ 3.2 หลังจากทำขั้นตอน ก) เสร็จแล้วสามารถเพิ่มจุดอ้างอิงค่าน้ำหนักเพิ่มเติม ดังสมการ (3.39)

$$w(p) = w(L) + \frac{p-L}{U-L} (w(U) - w(L)) \dots\dots\dots(3.39)$$


p ตำแหน่งหรือค่าข้อมูลเข้าที่ต้องการเพิ่มเป็นจุดอ้างอิง

L คือขอบเขตล่าง และ U คือขอบเขตบนของเซกเมนต์ ที่ p มีค่าอยู่ในเซกเมนต์นั้น

ตัวอย่างเช่น จากรูปที่ 3.3(ก) เพิ่มจุดอ้างอิงที่ค่าข้อมูลเข้า 0.5 แทนค่าในสมการ (3.39) ได้ดังนี้

$$w(0.5) = -0.5 + \frac{0.5-0}{1-0} (0.8 - (-0.5)) = 0.15$$

ดังนั้น $w(0) = -0.5$, $w(0.5) = 0.15$, $w(1) = 0.8$ และแม้หลังจากกำหนดจุดอ้างอิงดังกล่าวแล้ว กราฟค่าน้ำหนักก็ยังคงเป็นเหมือน รูปที่ 3.3(ก) แต่เมื่อผ่านขั้นตอนการเรียนรู้ กราฟค่าน้ำหนักอาจมีลักษณะเปลี่ยนไป แสดงดังตัวอย่างในรูปที่ 3.4



รูปที่ 3.4 ตัวอย่างกราฟค่าน้ำหนักแบบ 2 เซกเมนต์หลังจากผ่านการเรียนรู้

จากรูปที่ 3.4 แสดงกราฟค่าน้ำหนัก 2 เซกเมนต์ ในเซกเมนต์แรกค่าน้ำหนักจะครอบคลุมช่วงข้อมูล $[0, 0.5]$ และเซกเมนต์ที่สองค่าน้ำหนักจะครอบคลุมช่วงข้อมูล $[0.5, 1]$ ซึ่งแต่ละเซกเมนต์สามารถปรับค่าน้ำหนักได้เป็นอิสระต่อกัน เพื่อให้ได้ผลลัพธ์ของโครงข่ายที่ดีที่สุดตามค่าเป้าหมายที่ป้อนเข้ามา

3.4 การเพิ่มเซกเมนต์ของค่าน้ำหนักในระหว่างการเรียนรู้

ในเบื้องต้นยังไม่รู้ว่าค่าน้ำหนักควรเป็นเท่าไร จึงกำหนดค่าโดยการสุ่มให้มีเพียงเซกเมนต์เดียวก่อน แล้วอัลกอริทึมของโครงข่ายก็จะพยายามปรับค่าน้ำหนักนั้นให้เหมาะกับทุกๆ ข้อมูล เพื่อให้ผลถูกต้อง โดยใช้การคำนวณผลต่างของค่าความผิดพลาดกับค่าน้ำหนักนั้นๆ ($\delta = \frac{\partial E}{\partial w}$) ดังนั้นค่าน้ำหนักก็จะถูกเปลี่ยนไป เพื่อเมื่อข้อมูลใหม่เข้ามา ก็จะใช้ค่าน้ำหนักใหม่นั้น และให้ผลของโครงข่ายที่ถูกต้องต่อไป

แต่ถ้าข้อมูลมีความซับซ้อน เช่น ข้อมูลที่ใกล้เคียงกัน แต่มีคำตอบที่ต่างกัน โครงข่ายก็จะต้องพยายามปรับค่าน้ำหนักไปมา เพื่อให้ผลของโครงข่ายตรงคำตอบของข้อมูลนั้นๆ การปรับค่าน้ำหนักไปมา ย่อมไม่เป็นผลดีกับโครงข่าย เช่นการปรับค่าน้ำหนักให้มากขึ้นเพื่อให้ข้อมูลหนึ่งถูกต้อง แต่ก็ต้องมาปรับค่าน้ำหนักลงเพื่อให้อีกข้อมูลหนึ่งได้ผลถูกต้อง พอสุดท้ายให้คำตอบที่ถูกต้องได้เพียงข้อมูลเดียว หรืออาจผิดพลาดทุกคำตอบก็ได้

ในงานวิจัยนี้จึงมีแนวความคิดว่า ถ้าเพิ่มเซกเมนต์เป็นช่วงๆ เพื่อค่าน้ำหนักจะถูกปรับเฉพาะช่วงข้อมูลๆ นั้น ส่วนช่วงข้อมูลอื่นๆ ก็ยังคงให้ค่าน้ำหนักตามเดิม การให้คำตอบของโครงข่ายสำหรับข้อมูลช่วงนั้นก็มักจะยังคงถูกต้องเหมือนเดิม

อัลกอริทึมการเพิ่มเซกเมนต์ในระหว่างการเรียนรู้ของโครงข่ายฯนี้ จะเป็นขั้นตอนที่เพิ่มเติมในอัลกอริทึมหลัก ตามที่ได้อธิบายไว้ในหัวข้อ 3.2 ดังนั้น อัลกอริทึมการเพิ่มเซกเมนต์นี้ จะอธิบายเฉพาะส่วนที่เพิ่มเติม ดังนี้

ก) มีขั้นตอนเพิ่มเติมคือ กำหนดจำนวนเซกเมนต์ที่จะถูกแบ่งได้มากที่สุด กำหนดเป็นตัวแปร Φ ซึ่งในแต่ละเส้นเชื่อมโยงนั้น ค่าน้ำหนักอาจถูกเพิ่มเซกเมนต์มากน้อยต่างกัน แต่จะต้องไม่เกินจำนวนเซกเมนต์ (Φ) ที่กำหนดนี้

ทำตามขั้นตอน ข) - ฉ) ตามปกติ

ฎ) ในขั้นตอนนี้เป็นการป้อนข้อมูลให้ครบทุกข้อมูลในชุดข้อมูลหนึ่งๆ เมื่อครบทุกข้อมูลในชุดหนึ่งๆแล้ว ในขั้นตอนนี้จึงสามารถทำขั้นตอนการเพิ่มเซกเมนต์ได้ โดยให้ทำการตรวจสอบเส้นเชื่อมโยงค่าน้ำหนักแต่ละเส้นว่าจะต้องเพิ่มเซกเมนต์หรือไม่ ดังมีรายละเอียดดังนี้

ฎ.ิ) ในแต่ละเส้นเชื่อมโยงค่าน้ำหนัก พิจารณาว่าขณะนี้มียังจำนวนเซกเมนต์เท่าไร กำหนดเป็น Q

ถ้า $Q = \Phi$ แสดงว่าค่าน้ำหนักถูกแบ่งเซกเมนต์ไว้มากตามจำนวนที่กำหนดแล้ว ไม่สามารถเพิ่มเซกเมนต์ในเส้นเชื่อมโยงนี้ได้อีก ก็หยุดการพิจารณาการเพิ่มเซกเมนต์สำหรับเส้นเชื่อมโยงค่าน้ำหนักเส้นนี้

ถ้า $Q < \Phi$ แสดงว่าค่าน้ำหนักถูกแบ่งเซกเมนต์น้อยกว่าที่กำหนด ยังสามารถเพิ่มเซกเมนต์ได้ (ถ้าจำเป็น) จึงต้องพิจารณาขั้นตอนต่อไป

ฎ.ii) หาผลรวมการปรับค่า เฉพาะการปรับค่าเพิ่มขึ้น และเฉพาะการปรับค่าลดลง

ในเบื้องต้น ขอทบทวนก่อนว่า ทำไมต้องเพิ่มเซกเมนต์ เพิ่มเซกเมนต์เพื่ออะไร ซึ่งควรเพิ่มเซกเมนต์ก็เพราะว่า ภายในเซกเมนต์นั้นมีการปรับค่าน้ำหนักเพิ่มขึ้น-ลดลง จนยากจะเกิดจุดสมดุลที่ทำให้ได้ผลลัพธ์ที่ดีที่สุด ดังนั้นเพื่อเป็นการช่วยโครงข่ายฯ จึงควรเพิ่มเซกเมนต์ในตำแหน่งที่เหมาะสม เพื่อจะทำให้เซกเมนต์ย่อยที่แบ่งเพิ่มขึ้นมานั้น ปรับค่าน้ำหนักให้ได้สมดุล คือได้ผลลัพธ์ที่ดีได้โดยเร็ว

จากแนวความคิดการเพิ่มเซกเมนต์ข้างต้น จึงต้องพิจารณาว่าเซกเมนต์ได้มีการปรับค่าน้ำหนักขึ้น-ลง ในสัดส่วนใกล้เคียงกันบ้างหรือไม่

ดังนั้น ก่อนอื่นจึงต้องรวบรวมการปรับค่าน้ำหนักในการเรียนรู้ของแต่ละข้อมูล และจัดว่าการปรับค่าน้ำหนักใดเป็นการปรับเพิ่มขึ้น การปรับค่าน้ำหนักใดเป็นการปรับลดลง

จากสมการปรับค่าน้ำหนัก (3.11) (3.12) (3.20) (3.21) (3.29) และ (3.30) จะมีสมการเชิงอนุพันธ์ $\left[\frac{\partial E}{\partial w(\cdot)} \right]$ หรือเขียนใหม่เป็น $\Delta w(\cdot)$ ที่หาผลต่างของค่าน้ำหนักที่ทำให้เกิดความผิดพลาด รวมอยู่ในสมการด้วย ซึ่งค่า $\Delta w(\cdot)$ นี้จะเป็นค่าที่คอยปรับค่าน้ำหนักให้เพิ่มขึ้น หรือลดลง ที่ทำให้ผลลัพธ์ดีขึ้น

เมื่อทราบว่า ค่า $\Delta w(\cdot)$ นี้ เป็นค่าที่คอยปรับค่าน้ำหนักให้เพิ่มขึ้น หรือลดลง แต่การปรับค่าน้ำหนักจริงๆนั้นจะปรับที่ขอบเขตล่าง และขอบเขตบนของเซกเมนต์ในอัตราส่วนความใกล้เคียง-ไกลของข้อมูลกับขอบเขตล่าง-บนด้วย ซึ่งเขียนเป็นสมการได้ดังสมการ (3.40) (3.41)

$$\Delta L = \Delta w(x) \left[\frac{U-x}{U-L} \right] \dots\dots\dots(3.40)$$

$$\Delta U = \Delta w(x) \left[\frac{x-L}{U-L} \right] \dots\dots\dots(3.41)$$

ΔL คือค่าที่ใช้ปรับ (เพิ่มขึ้น หรือลดลง) สำหรับขอบเขตล่าง

ΔU คือค่าที่ใช้ปรับ (เพิ่มขึ้นหรือลดลง) สำหรับขอบเขตบน

ดังนั้น ที่ขอบเขตล่าง หาผลรวมเฉพาะค่าที่ปรับให้เพิ่มขึ้น ได้ดังสมการ (3.42) และเฉพาะค่าที่ปรับให้ลดลง ได้ดังสมการ (3.43)

$$\Delta L^+ = \sum_{\forall \Delta L: \Delta L > 0} \Delta L \dots\dots\dots(3.42)$$

$$\Delta L^- = \sum_{\forall \Delta L: \Delta L < 0} |\Delta L| \dots\dots\dots(3.43)$$

ที่ขอบเขตบน หาผลรวมเฉพาะค่าที่ปรับให้เพิ่มขึ้น ได้ดังสมการ (3.44) และเฉพาะค่าที่ปรับให้ลดลง ได้ดังสมการ (3.45)

$$\Delta U^+ = \sum_{\forall \Delta U: \Delta U > 0} \Delta U \dots\dots\dots(3.44)$$

$$\Delta U^- = \sum_{\forall \Delta U: \Delta U < 0} \Delta U \dots\dots\dots(3.45)$$

ฎ.iii) หาอัตราส่วนระหว่างการปรับค่าขึ้น-ลง

การหาอัตราส่วนระหว่างการปรับค่าขึ้น-ลง จะต้องรวมผลกระทบที่เกิดกับขอบเขตนั่นๆก่อน โดยในแต่ละเซกเมนต์จะมีเซกเมนต์ข้างเคียง ซึ่งขอบเขตล่าง (L) ของเซกเมนต์หนึ่ง จะเป็นขอบเขตบน (U) ของอีกเซกเมนต์หนึ่ง และเช่นเดียวกัน ขอบเขตบนของเซกเมนต์หนึ่งจะเป็นขอบเขตล่างของอีกเซกเมนต์หนึ่งด้วยเช่นกัน ดังนั้น ต้องรวมผลรวมผลกระทบที่เกิดจากขอบเขตนั่นๆ ที่เกิดจากเซกเมนต์ใกล้เคียงด้วย

หาอัตราส่วนขอบเขตล่าง

โดยหาผลรวมขอบเขตล่าง กับขอบเขตบนของเซกเมนต์ที่ใกล้เคียง ดังสมการ (3.46)

(3.47) และหาอัตราส่วนระหว่างการปรับค่าขึ้น-ลง ดังสมการ (3.48)

$$P_i^{L+} = \Delta L_i^+ + \Delta U_{i-1}^+ \dots\dots\dots(3.46)$$

$$P_i^{L-} = \Delta L_i^- + \Delta U_{i-1}^- \dots\dots\dots(3.47)$$

$$P_i^{L\ddagger} = \frac{P_i^{L+} - P_i^{L-}}{\max(P_i^{L+}, P_i^{L-})} \dots\dots\dots(3.48)$$

P_i^{L+} ผลรวมขอบเขตล่างที่ปรับค่าเพิ่มขึ้น ของเซกเมนต์ที่ i

P_i^{L-} ผลรวมขอบเขตล่างที่ปรับค่าลดลง ของเซกเมนต์ที่ i

ΔL_i^+ ผลรวมที่ปรับค่าเพิ่มขึ้นของขอบเขตล่าง ของเซกเมนต์ที่ i

ΔL_i^- ผลรวมที่ปรับค่าลดลงของขอบเขตล่าง ของเซกเมนต์ที่ i

ΔU_{i-1}^+ ผลรวมที่ปรับค่าเพิ่มขึ้น ของขอบเขตบน ของเซกเมนต์ที่ $i-1$ ในกรณีที่ $i = 1$ (เป็นเซกเมนต์แรก) กำหนดให้ค่า ΔU_{i-1}^+ เท่ากับ 0

ΔU_{i-1}^- ผลรวมที่ปรับค่าลดลง ของขอบเขตบน ของเซกเมนต์ที่ $i-1$ ในกรณีที่ $i = 1$ (เป็นเซกเมนต์แรก) กำหนดให้ค่า ΔU_{i-1}^- เท่ากับ 0

$P_i^{L\ddagger}$ อัตราการปรับค่า (เพิ่มขึ้นหรือลดลง) ของขอบเขตล่าง ของเซกเมนต์ที่ i

ถ้า $P_i^{L\ddagger} > 0$ แสดงว่า มีการปรับค่าเพิ่มขึ้น มากกว่า การปรับค่าลดลง

ถ้า $P_i^{L\ddagger} < 0$ แสดงว่า มีการปรับค่าลดลง มากกว่า การปรับค่าเพิ่มขึ้น

หาอัตราส่วนขอบเขตบน

การหาอัตราส่วนการปรับค่าของขอบเขตบน จะมีหลักการเหมือนกับขอบเขตล่าง โดยหาผลรวมขอบเขตล่างที่ใกล้เคียง ดังสมการ (3.49) (3.50) และหาอัตราส่วนระหว่างการปรับค่าขึ้น-ลง ดังสมการ (3.51)

$$P_i^{U+} = \Delta U_i^+ + \Delta L_{i+1}^+ \dots\dots\dots(3.49)$$

$$P_i^{U-} = \Delta U_i^- + \Delta L_{i+1}^- \dots\dots\dots(3.50)$$

$$P_i^{U\ddagger} = \frac{P_i^{U+} - P_i^{U-}}{\max(P_i^{U+}, P_i^{U-})} \dots\dots\dots(3.51)$$

P_i^{U+} ผลรวมขอบเขตบนที่ปรับค่าเพิ่มขึ้น ของเซกเมนต์ที่ i

P_i^{U-} ผลรวมขอบเขตบนที่ปรับค่าลดลง ของเซกเมนต์ที่ i

ΔU_i^+ ผลรวมที่ปรับค่าเพิ่มขึ้น ของขอบเขตบน ของเซกเมนต์ที่ i

ΔU_i^- ผลรวมที่ปรับค่าลดลง ของขอบเขตบน ของเซกเมนต์ที่ i

ΔL_{i+1}^+ ผลรวมที่ปรับค่าเพิ่มขึ้น ของขอบเขตล่าง ของเซกเมนต์ที่ $i + 1$ กรณีที่ $i = Q$ (เป็นเซกเมนต์สุดท้าย) กำหนดให้ค่า ΔL_{i+1}^+ เท่ากับ 0

ΔL_{i+1}^- ผลรวมที่ปรับค่าลดลง ของขอบเขตล่าง ของเซกเมนต์ที่ $i + 1$ กรณีที่ $i = Q$ (เป็นเซกเมนต์สุดท้าย) กำหนดให้ค่า ΔL_{i+1}^- เท่ากับ 0

$P_i^{U\pm}$ อัตราการปรับค่า (เพิ่มขึ้นหรือลดลง) ของขอบเขตบน ของเซกเมนต์ที่ i

ถ้า $P_i^{U\pm} > 0$ แสดงว่า มีการปรับค่าเพิ่มขึ้น มากกว่า การปรับค่าลดลง

ถ้า $P_i^{U\pm} < 0$ แสดงว่า มีการปรับค่าลดลง มากกว่า การปรับค่าเพิ่มขึ้น

ฎ.iv) เปรียบเทียบการปรับค่าของขอบเขตล่าง-บนว่ามีปรับค่า (ขึ้นหรือลง) ไปในทางเดียวกันหรือไม่ แสดงดังสมการ (3.52)

$$\bar{P}_i = P_i^{L\pm} \cdot P_i^{U\pm} \dots\dots\dots(3.52)$$

\bar{P}_i อัตราส่วนเปรียบเทียบการปรับค่า ระหว่างขอบเขตล่างและขอบเขตบน ของเซกเมนต์ที่ i

ในที่นี้ พิจารณาแนวทางการปรับค่าเพิ่มขึ้น (ค่าบวก) และแนวทางการปรับค่าลดลง (ค่าลบ) ดังนั้นแสดงผลคูณ ได้ดังตารางที่ 3.1

ตารางที่ 3.1 ผลการคูณ

ค่าที่ 1	ค่าที่ 2	ผลการคูณ
+	+	+
+	-	-
-	+	-
-	-	+

หมายเหตุ : + แทนค่าใดๆที่เป็นค่าบวก และ - แทนค่าใดๆที่เป็นค่าลบ

จากสมการ (3.52) และผลการคูณดังตารางที่ 3.1 สามารถสรุปได้ดังนี้

ถ้า $\bar{P}_i > 0$ แสดงว่า แนวทางการปรับค่าของขอบเขตล่าง และขอบเขตบนเป็นไปในแนวทางเดียวกัน

ถ้า $\bar{P}_i < 0$ แสดงว่า แนวทางการปรับค่าของขอบเขตล่าง และขอบเขตบนไม่เป็นไปในแนวทางเดียวกัน

กำหนด ε เป็นค่าอัตราความแตกต่างที่ควรเพิ่มเซกเมนต์

ถ้า $\bar{P}_i < -\varepsilon$ แสดงว่าควรเพิ่มเซกเมนต์

ข้อพิจารณาเพิ่มเติมสำหรับการเพิ่มเซกเมนต์คือ การเพิ่มเซกเมนต์จะต้องไม่เกินจำนวนเซกเมนต์ที่กำหนด ดังนั้นควรเลือกเซกเมนต์ที่ P มีค่าน้อยที่สุดก่อน (ซึ่งแสดงว่ามีความแตกต่างในการปรับค่ามาก) และเมื่อเพิ่มเซกเมนต์แล้ว ยังไม่เกินจำนวนเซกเมนต์ที่กำหนด จึงเลือก P ที่มีค่าน้อยลำดับถัดมา

ฎ.๖) การเพิ่มเซกเมนต์ ณ ตำแหน่งที่เหมาะสม

แนวคิดเกี่ยวกับตำแหน่งที่ควรเพิ่มเซกเมนต์นี้ คือ จะต้องเป็นจุดแบ่งเซกเมนต์ที่แยกการปรับค่าเพิ่มขึ้น และการปรับค่าลดลงออกจากกัน เพื่อหลีกเลี่ยงการปรับค่าเพิ่มขึ้น และการปรับค่าลดลงในเซกเมนต์เดียวกันให้มากที่สุด สำหรับการเรียนรู้ในรอบต่อไป

ในเบื้องต้น จึงหาค่าเฉลี่ยของข้อมูลเข้าที่อยู่ในเซกเมนต์ที่ i ($L_i < x < U_i$) เฉพาะที่ปรับค่าน้ำหนักเพิ่มขึ้น (\bar{x}_i^+) ดังสมการ (3.53) และเฉพาะที่ปรับค่าน้ำหนักลดลง (\bar{x}_i^-) ดังสมการ (3.54) จากนั้นหาค่าตำแหน่งที่ควรเพิ่มเซกเมนต์ (\bar{x}) ดังสมการ (3.55)

$$\bar{x}_i^+ = \frac{\sum_{\forall x: (\Delta w(x) > 0) \wedge (L_i < x < U_i)} x}{\sum_{\forall x: (\Delta w(x) > 0) \wedge (L_i < x < U_i)} 1} \dots\dots\dots (3.53)$$

$$\bar{x}_i^- = \frac{\sum_{\forall x: (\Delta w(x) < 0) \wedge (L_i < x < U_i)} x}{\sum_{\forall x: (\Delta w(x) < 0) \wedge (L_i < x < U_i)} 1} \dots\dots\dots (3.54)$$

$$sp = \frac{\bar{x}_i^+ + \bar{x}_i^-}{2} \dots\dots\dots (3.55)$$

\bar{x}_i^+ เป็นค่าเฉลี่ยของข้อมูลเข้า เฉพาะที่มีการปรับค่าน้ำหนักเพิ่มขึ้น ในเซกเมนต์ที่ i

\bar{x}_i^- เป็นค่าเฉลี่ยของข้อมูลเข้า เฉพาะที่มีการปรับค่าน้ำหนักลดลง ในเซกเมนต์ที่ i

sp เป็นค่าเฉลี่ยของข้อมูลเข้าที่ควรเพิ่มเซกเมนต์

เพิ่มค่า sp เป็นจุดอ้างอิงค่าน้ำหนัก และหาค่าน้ำหนักของ sp ได้ดังสมการ (3.1)

ทำตามขั้นตอน ฎ) ตามปกติ

3.5 การลบตำแหน่งอ้างอิงค่าน้ำหนักที่ไม่ได้ใช้ในระหว่างการเรียนรู้

ในกรณีที่เซกเมนต์ใดๆ ไม่เคยใช้ กล่าวคือ ไม่มีค่าข้อมูลเข้าใดๆ ที่อยู่ในเซกเมนต์นั้นๆ เลย ซึ่งถ้าเซกเมนต์ใดไม่มีประโยชน์ ก็สามารถลบเซกเมนต์นั้นออกไปได้ เพื่อรักษาสิทธิในการเพิ่มเซกเมนต์ ณ ตำแหน่งที่จำเป็นอื่นๆ โดยยังคงจำนวนเซกเมนต์ไม่เกินที่กำหนดไว้เช่นเดิม

จากอัลกอริทึมการเพิ่มเซกเมนต์ สามารถพิจารณาการลบเซกเมนต์ควบคู่ไปด้วย ดังนี้
 ฎ.vi) พิจารณาการลบตำแหน่งอ้างอิงค่าน้ำหนัก โดยพิจารณาจำนวนการใช้เซกเมนต์ และ
 เซกเมนต์ใกล้เคียง ดังสมการ (3.56)


$$R_i = \sum_{\forall x: L_i < x < U_i} 1 \dots\dots\dots(3.56)$$

R_i จำนวนครั้งที่ใช้เซกเมนต์ที่ i

ถ้า $R_i = 0$ และ $R_{i-1} = 0$ แสดงว่า ขอบเขตล่างไม่เคยใช้ สามารถลบตำแหน่งอ้างอิงค่าน้ำหนักที่เป็นขอบเขตล่างออกได้

ถ้า $R_i = 0$ และ $R_{i+1} = 0$ แสดงว่า ขอบเขตบนไม่เคยใช้ สามารถลบตำแหน่งอ้างอิงค่าน้ำหนักที่เป็นขอบเขตบนออกได้

แสดงตัวอย่างกราฟค่าน้ำหนัก ก่อนและหลังการลบตำแหน่งอ้างอิงค่าน้ำหนักได้ดังรูปที่ 3.5



รูปที่ 3.5 ตัวอย่างกราฟค่าน้ำหนัก ก่อนและหลังการลบตำแหน่งอ้างอิงค่าน้ำหนัก

3.6 สรุป

ในบทนี้ได้กล่าวถึง โครงข่ายประสาทเทียมแบบแพร่กระจายย้อนกลับ โดยใช้ค่าน้ำหนักแบบหลายเซกเมนต์ การเพิ่มเซกเมนต์ในขั้นตอนการสุ่มค่าน้ำหนัก การเพิ่มเซกเมนต์ในระหว่าง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การเรียนรู้ และการลบตำแหน่งอ้างอิงค่าน้ำหนักที่ไม่ได้ใช้ในระหว่างการเรียนรู้ ในบทถัดไป จะกล่าวถึง การนำโครงข่ายประสาทเทียมแบบแพร่กระจายย้อนกลับโดยใช้อ่านน้ำหนักแบบหลายเซกเมนต์นี้ ไปใช้ทดลองกับงานทางด้านการจำแนกข้อมูล การประมาณฟังก์ชัน และการพยากรณ์ เพื่อเปรียบเทียบประสิทธิภาพของโครงข่ายแบบใหม่กับแบบเดิม ดังจะได้แสดงรายละเอียดต่อไป



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 4

การทดลองและผลการทดลอง

ในบทที่ผ่านมาได้อธิบายถึงอัลกอริทึมของโครงข่ายประสาทเทียม โดยใช้ค่าน้ำหนักแบบหลายเซกเมนต์ ในบทนี้จะนำอัลกอริทึมดังกล่าวมาทดลองกับข้อมูลแบบต่างๆ เพื่อเปรียบเทียบผลระหว่างโครงข่ายที่ใช้ค่าน้ำหนักค่าเดียว กับค่าน้ำหนักแบบใหม่ที่น่าเสนอ โดยทดลองโครงข่ายในการจำแนกข้อมูล (Classification) การประมาณฟังก์ชัน (Function Approximation) และการพยากรณ์ (Forecast)

4.1 ประเภทการจำแนกข้อมูล (Classification)

การจำแนกข้อมูล เป็นการจัดข้อมูลให้อยู่ในกลุ่มต่างๆ ตามที่ได้จัดกลุ่มไว้แล้ว โดยลักษณะของข้อมูลประเภทนี้จะไม่มีลำดับข้อมูล แต่ละข้อมูลไม่มีความเกี่ยวข้องกัน ดังนั้นในการทดลองกับข้อมูลประเภทนี้จะใช้โครงข่ายแบบแพร่กระจายย้อนกลับ เพียง โครงสร้างเดียว แต่กำหนดจำนวนโหนดในชั้นซ่อนที่แตกต่างกัน ตั้งแต่ 1 โหนดจนถึง 50 โหนด และกำหนดค่าน้ำหนักเป็นแบบค่าเดียว แบบเซกเมนต์เพียง 1 เซกเมนต์ และแบบเซกเมนต์แบบแบ่งเพิ่มได้ในระหว่างเรียนรู้โดยกำหนดให้สามารถแบ่งได้มากที่สุด 2, 5, 10, 15 และ 20 เซกเมนต์ โดยทำการทดลองแต่ละแบบอย่างน้อย 5 ผลการทดลอง และเปรียบเทียบผลที่ดีที่สุดของแต่ละแบบ

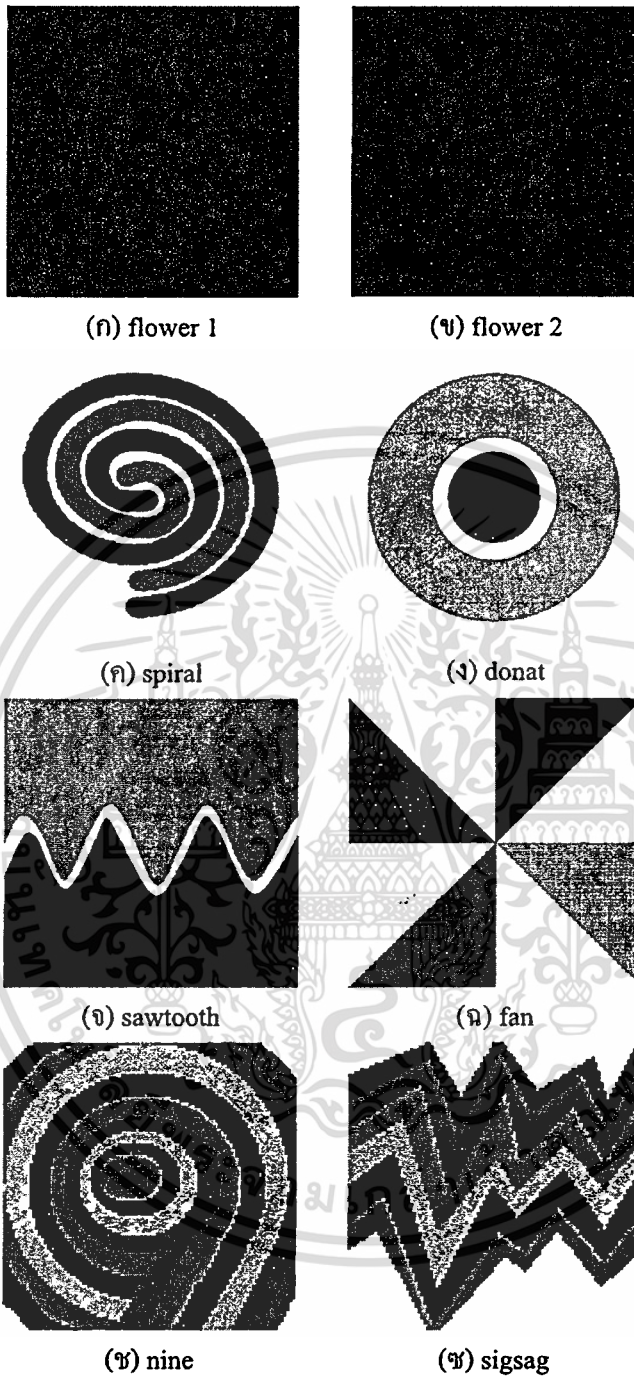
ข้อมูลที่นำมาใช้ในการทดลอง แบ่งเป็นข้อมูลที่สร้างขึ้นเอง (Artificial data sets) 8 ชุดข้อมูล ซึ่งออกแบบมาเพื่อใช้ทดสอบการจำแนกข้อมูล โดยเฉพาะ และข้อมูลที่เก็บมาจริง (Real-life data sets) 15 ชุดข้อมูล

ข้อมูลที่สร้างขึ้นเอง ได้แก่ Flower1, Flower2, Spiral, Donat, Sawtooth, Fan, Nine และ Sigsag ซึ่งตั้งชื่อตามลักษณะข้อมูล แสดงดังรูปที่ 4.1

ข้อมูลที่สร้างขึ้นเองนั้น แต่ละข้อมูลมี 2 คุณลักษณะ (feature) ซึ่งสำหรับข้อมูล Sigsag มี 5 คลาส ส่วนข้อมูล Fan และ Nine มี 4 คลาส สำหรับข้อมูล Flower1, Flower2, Spiral, Donat และ Sawtooth แต่ละข้อมูลมี 2 คลาส

ข้อมูล sigsag จะมี 1882 ข้อมูลที่ใช้สำหรับในการเรียนรู้ และอีก 4231 ข้อมูลที่ใช้สำหรับการทดสอบ คิดเป็นอัตราส่วน 30-70 (เรียนรู้-ทดสอบ) ของข้อมูลทั้งหมด

ส่วนข้อมูล Flower1, Flower2, Spiral, Donat, Sawtooth, Fan และ Nine จะมี 2000 ข้อมูลที่ใช้สำหรับในการเรียนรู้ และอีก 2000 ข้อมูลที่ใช้สำหรับการทดสอบ คิดเป็นอัตราส่วน 50-50 (เรียนรู้-ทดสอบ) ของข้อมูลทั้งหมด



รูปที่ 4.1 กราฟแสดงลักษณะข้อมูลที่สร้างขึ้นเอง

ข้อมูลที่เก็บมาจริง (Real-life data sets) ได้แก่ austra, balance-scale, breast, diabetes, glass, haberman, image, ionosphere, iris, pima, sona, spectF, vehicle, vowel และ yeast โดยนำมาจาก UCI Machine Learning Repository ซึ่งเป็นแหล่งรวบรวมข้อมูลหลายประเภทที่สามารถนำมาใช้ศึกษาค้นคว้าและทำการทดลองได้เป็นอย่างดี

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ข้อมูล *austra* มีคุณลักษณะ 14 คุณลักษณะ ซึ่งแบ่งเป็น 2 คลาส และใช้ข้อมูล 414 ข้อมูลในการเรียนรู้ และอีก 276 ข้อมูลในการทดสอบ คิดเป็น 60-40 (เรียนรู้-ทดสอบ) ของข้อมูลทั้งหมด

ข้อมูล *balance-scale* มีคุณลักษณะ 4 คุณลักษณะ ซึ่งแบ่งเป็น 3 คลาส และใช้ข้อมูล 375 ข้อมูลในการเรียนรู้ และอีก 250 ข้อมูลในการทดสอบ คิดเป็น 60-40 ของข้อมูลทั้งหมด

ข้อมูล *breast* มีคุณลักษณะ 7 คุณลักษณะ ซึ่งแบ่งเป็น 2 คลาส และใช้ข้อมูล 420 ข้อมูลในการเรียนรู้ และอีก 279 ข้อมูลในการทดสอบ คิดเป็น 60-40 ของข้อมูลทั้งหมด

ข้อมูล *diabetes* มีคุณลักษณะ 8 คุณลักษณะ ซึ่งแบ่งเป็น 2 คลาส และใช้ข้อมูล 461 ข้อมูลในการเรียนรู้ และอีก 307 ข้อมูลในการทดสอบ คิดเป็น 60-40 ของข้อมูลทั้งหมด

ข้อมูล *glass* มีคุณลักษณะ 9 คุณลักษณะ ซึ่งแบ่งเป็น 7 คลาส และใช้ข้อมูล 131 ข้อมูลในการเรียนรู้ และอีก 83 ข้อมูลในการทดสอบ คิดเป็น 60-40 ของข้อมูลทั้งหมด

ข้อมูล *haberman* มีคุณลักษณะ 3 คุณลักษณะ ซึ่งแบ่งเป็น 2 คลาส และใช้ข้อมูล 184 ข้อมูลในการเรียนรู้ และอีก 122 ข้อมูลในการทดสอบ คิดเป็น 60-40 ของข้อมูลทั้งหมด

ข้อมูล *image* มีคุณลักษณะ 19 คุณลักษณะที่จะนำไปเป็นข้อมูลในการจำแนกคลาส (class) ซึ่งมีทั้งหมด 7 คลาส ในการทดลองใช้ตัวอย่าง 210 ข้อมูลในการเรียนรู้ และอีก 2100 ข้อมูลในการทดสอบ คิดเป็น 10%-90% (เรียนรู้-ทดสอบ) ของข้อมูลทั้งหมด

ข้อมูล *ionosphere* มีคุณลักษณะ 34 คุณลักษณะ ซึ่งแบ่งเป็น 2 คลาส และใช้ข้อมูล 212 ข้อมูลในการเรียนรู้ และอีก 139 ข้อมูลในการทดสอบ คิดเป็น 60-40 ของข้อมูลทั้งหมด

ข้อมูล *iris* เป็นที่นิยมในการทดลองการจำแนกข้อมูล (classification) เพราะมีข้อมูลไม่มากนัก และศึกษาทำความเข้าใจในเบื้องต้นได้ง่าย โดยข้อมูลประกอบด้วย ความกว้าง-ยาวของก้านดอกและความกว้าง-ยาวของกลีบดอก รวมเป็น 4 คุณลักษณะของข้อมูลดอกไม้ดอกหนึ่งๆ ที่จะจัดว่าดอกไม้ชิ้นนั้นจัดอยู่ในสายพันธุ์ใดใน 3 สายพันธุ์ (*iris-setosa*, *iris-versicolor*, และ *iris-virginica*) ในการทดลองใช้ 90 ข้อมูลในการเรียนรู้ และอีก 60 ข้อมูลในการทดสอบ คิดเป็น 60-40 ของข้อมูลทั้งหมด

ข้อมูล *pima* มีคุณลักษณะ 8 คุณลักษณะ ซึ่งแบ่งเป็น 2 คลาส และใช้ข้อมูล 460 ข้อมูลในการเรียนรู้ และอีก 308 ข้อมูลในการทดสอบ คิดเป็น 60-40 ของข้อมูลทั้งหมด

ข้อมูล *sonar* มีคุณลักษณะ 60 คุณลักษณะ ซึ่งแบ่งเป็น 2 คลาส และใช้ข้อมูล 125 ข้อมูลในการเรียนรู้ และอีก 83 ข้อมูลในการทดสอบ คิดเป็น 60-40 ของข้อมูลทั้งหมด

ข้อมูล *spectf* มีคุณลักษณะ 44 คุณลักษณะ ซึ่งแบ่งเป็น 2 คลาส และใช้ข้อมูล 80 ข้อมูลในการเรียนรู้ และอีก 269 ข้อมูลในการทดสอบ คิดเป็น 23-77 (เรียนรู้-ทดสอบ) ของข้อมูลทั้งหมด

ข้อมูล *vehicle* มีคุณลักษณะ 18 คุณลักษณะ ซึ่งแบ่งเป็น 4 คลาส และใช้ข้อมูล 506 ข้อมูลในการเรียนรู้ และอีก 340 ข้อมูลในการทดสอบ คิดเป็น 60-40 ของข้อมูลทั้งหมด

ข้อมูล vowel มีคุณลักษณะ 10 คุณลักษณะ ซึ่งแบ่งเป็น 10 คลาส และใช้ข้อมูล 528 ข้อมูลในการเรียนรู้ และอีก 462 ข้อมูลในการทดสอบ คิดเป็น 54-46 (เรียนรู้,ทดสอบ) ของข้อมูลทั้งหมด

ข้อมูล yeast มีคุณลักษณะ 8 คุณลักษณะ ซึ่งแบ่งเป็น 10 คลาส และใช้ข้อมูล 890 ข้อมูลในการเรียนรู้ และอีก 594 ข้อมูลในการทดสอบ คิดเป็น 60-40 ของข้อมูลทั้งหมด

ตารางที่ 4.1 ผลการทดลองของโครงข่ายกับการจำแนกข้อมูล

ชื่อชุดข้อมูล	จำนวนคุณลักษณะ	จำนวนคลาส	ค่าน้ำหนักแบบค่าเดียว		ค่าน้ำหนักแบบเซกเมนต์		
			ค่าความผิดพลาด (%)	M	ค่าความผิดพลาด (%)	M	S
Austra	14	2	12.68	1	11.23	13	2
Balance-scale	4	3	4	13	0.8	1	20
Breast	7	2	3.23	6	2.51	7	5
Diabetes	8	2	22.8	6	20.2	21	10
Donat	2	2	0	3 [†]	0	1 [†]	1
Fan	2	4	0	2 [†]	0	3 [†]	1
Flower 1	2	2	2.5	25	1.15	30	10
Flower 2	2	2	3	40	0.95	46	15
Glass	9	7	25.3	4	18.07	11	5
Haberman	3	2	22.95	4	19.67	3	5
Image	19	7	7.81	5	5.57	21	5
Ionosphere	34	2	5.04	3	3.6	37	5
Iris	4	3	0	1 [†]	0	1 [†]	1
Nine	2	4	36.4	16	20.7	3	10
Pima	8	2	21.1	16	0	16	1
Sawtooth	2	2	4.15	10	0	9	5
Sigsag	2	5	34.34	10	5.65	36 [†]	10
Sona	60	2	13.25	7 [†]	8.43	21 [†]	2
Spectf	44	2	14.87	1	5.58	1	15
Spiral	2	2	18.0	21	0.65	43	10
Vehicle	18	4	18.24	44	16.18	40	1
Vowel	10	10	42.21	31	39.39	36	2
Yeast	8	10	36.87	45	35.19	48	1

M จำนวนโหนดในชั้นซ่อน S จำนวนเซกเมนต์มากที่สุดที่สามารถแบ่งได้

[†] มีโครงข่ายที่ใช้จำนวนโหนดในชั้นซ่อนต่างกัน แต่ให้ผลค่าผิดพลาดน้อยที่สุดเท่ากัน ในที่นี้เลือกแสดงจำนวนโหนดน้อยที่สุด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ในการทดลองป้อนข้อมูลที่ใช้การเรียนรู้ เพื่อให้โครงข่ายการเรียนรู้เป็นจำนวน 50 รอบ และ นำโครงข่ายมาทดสอบกับข้อมูลทดสอบ และหาผลผิดพลาดจากโครงข่าย

ในงานวิจัยนี้ ผลการทดลองถูกแสดงออกเป็น 2 รูปแบบ คือ

1) ผลการทดลองที่ดีที่สุดจาก Feed forward NN (FNN) ซึ่งผลการทดลองที่ดีที่สุดของโครงข่าย (เลือกแสดงค่าผิดพลาดที่น้อยที่สุด กรณีมีค่าความผิดพลาดน้อยที่สุดเท่ากัน จะเลือกโครงข่ายที่ใช้จำนวนโหนดในชั้นซ่อนน้อยที่สุด) แสดงดังตารางที่ 4.1

2) ผลการทดลองเปรียบเทียบ ในกรณีที่มีการใช้จำนวนโหนดในชั้นซ่อนที่เท่ากัน สำหรับรายละเอียดการทดลอง เพื่อเปรียบเทียบในจำนวนโหนดที่เท่ากันนี้ มีจำนวน 23 ตาราง จึงได้นำแสดงในตาราง ก.1-ก.23 ในภาคผนวก ก. และแสดงสรุปค่าเฉลี่ยทุกแบบ (1-50 โหนด) ของแต่ละข้อมูล ดังตารางที่ 4.2

จากตารางที่ 4.1 แสดงผลการทดลองซึ่งเปรียบเทียบระหว่างโครงข่ายที่ใช้ค่าน้ำหนักแบบค่าเดียว กับโครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์ ซึ่งจะเห็นว่า การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ ได้ผลค่าความผิดพลาดน้อยกว่า การใช้ค่าน้ำหนักแบบค่าเดียว

ตารางที่ 4.2 ค่าเฉลี่ยรวมเมื่อใช้จำนวนโหนดที่เท่ากัน ในงานด้านการจำแนกข้อมูล

ข้อมูล	Feed forward NN		ข้อมูล	Feed forward NN	
	reduce (%)	num		reduce (%)	num
Austra	-1.45	50	Iris*	0	0
Balance-scale	-0.40	30	Nine	-16.13	50
Breast	-0.36	33	Pima	0.32	7
Diabetes	-0.82	43	Sawtooth	-4.30	50
Donat	0	2	Sigsag	-30.71	50
Fan	-0.1	48	Sona	-3.62	49
Flower 1	-1.23	50	Spectf	-4.46	50
Flower 2	-2.45	50	Spiral	-18.13	50
Glass	-9.64	50	Vehicle	-2.64	49
Haberman	-1.64	47	Vowel	-4.54	50
Image	-2.19	50	Yeast	-2.11	48
Ionosphere	-1.44	36			

reduce –ค่าเฉลี่ยรวมทุกแบบ (1-50 โหนด) ที่ให้ค่าผิดพลาดลดลง เมื่อใช้ค่าน้ำหนักแบบหลายเซกเมนต์

ค่าลบ หมายถึง โดยเฉลี่ยจาก 50 แบบ (1-50 โหนด) โครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์ให้ผลค่าผิดพลาดลดลง (%)

ค่าบวก หมายถึง โดยเฉลี่ยจาก 50 แบบ (1-50 โหนด) โครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์ให้ผลค่าผิดพลาดมากขึ้น (%)

num –จำนวนแบบ (1-50 โหนด) เมื่อใช้ค่าน้ำหนักแบบหลายเซกเมนต์ที่ให้ค่าผิดพลาดน้อยกว่าการใช้ค่าน้ำหนักเพียงค่าเดียว

* ข้อมูล iris ให้ผลผิดพลาด 0.0% ทุกการทดลอง

จากตารางที่ 4.2 แสดงให้เห็นว่าโครงข่าย Feed forward เมื่อเปรียบเทียบการใช้จำนวน โหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ จะให้ผลค่าผิดพลาดลดลง เมื่อใช้ กับข้อมูล Sigsag, Spiral และ Nine โดยคิดเป็นค่าเฉลี่ย 30.71%, 18.13% และ 16.13% ตามลำดับ สำหรับข้อมูลอื่นๆ ให้ผลค่าผิดพลาดลดลง โดยเฉลี่ย 0-10% แต่สำหรับข้อมูล pima ที่โดยเฉลี่ยทุก แบบ (1-50 โหนด) ให้ผลผิดพลาดไม่ลดลง

4.2 ประเภทการประมาณฟังก์ชัน (Function Approximation)

การประมาณฟังก์ชัน เป็นลักษณะการสร้างแบบจำลอง เลียนแบบฟังก์ชันอื่นๆ เพื่อนำ แบบจำลองนั้น ไปใช้ศึกษาหรือทดลอง แทนการใช้ฟังก์ชันจริง ในที่นี้ ยกตัวอย่างระบบความอลวน (Chaotic systems) เป็นระบบที่ตัวแปรหนึ่งขึ้นกับตัวแปรอื่นๆทั้งจากอดีตหรือปัจจุบัน ซึ่งทำให้ยุ่งเหยิงยากแก่การหาคำตอบ จึงนำมาใช้ทดสอบประมาณการฟังก์ชันในงานวิจัยนี้

ระบบความอลวนที่นำมาใช้ในการทดลองมี 11 ระบบ แบ่งเป็น 1 มิติ (จำนวน 2 ระบบ), 2 มิติ (จำนวน 2 ระบบ), 3 มิติ (จำนวน 6 ระบบ) และ 4 มิติ (จำนวน 1 ระบบ)

4.2.1 ระบบความอลวน แบบ 1 มิติ

ระบบความอลวน แบบ 1 มิติ คือจะมีข้อมูลเข้าระบบ 1 ค่า และระบบจะให้ข้อมูล ออก 1 ค่า สมการที่นำมาใช้ทดสอบคือ Mackey-Glass และ Logistic map

4.2.1.1 Mackey-Glass

สมการ Mackey-Glass แสดงดังสมการ (4.1) แสดงกราฟดังรูปที่ 4.2 (ก)

$$\frac{dx(t)}{dt} = \frac{ax(t-\tau)}{1+x^\theta(t-\tau)} - bx \dots\dots\dots(4.1)$$


โดยกำหนดให้ $a = 2$, $b = 0.1$, และ $\tau = 17$

4.2.1.2 Logistic map

สมการ Logistic map แสดงดังสมการ (4.2) แสดงกราฟดังรูปที่ 4.2 (ข)

$$\frac{dx(t)}{dt} = ax(1-x) \dots\dots\dots(4.2)$$

โดยกำหนดให้ $a = 4$



รูปที่ 4.2 กราฟแสดงลักษณะข้อมูลลวน 1 มิติ

4.2.2 ระบบความอลวน แบบ 2 มิติ

ระบบความอลวน แบบ 2 มิติ คือจะมีข้อมูลเข้าระบบ 2 ค่า และระบบจะให้ข้อมูลออก 2 ค่า สมการที่นำมาใช้ทดสอบคือ Hénon map และ Ikeda map

4.2.2.1 Hénon map

สมการ Hénon map แสดงดังสมการ (4.3) และ (4.4) แสดงกราฟดังรูปที่ 4.3 (ก)

$$\frac{dx(t)}{dt} = 1 - ax^2 + y \dots\dots\dots(4.3)$$

$$\frac{dy(t)}{dt} = bx \dots\dots\dots(4.4)$$

โดยกำหนดให้ $a = 1.4$ และ $b = 0.3$


4.2.2.2 Ikeda map

สมการ Ikeda map แสดงดังสมการ (4.5) และ (4.6) แสดงกราฟดังรูปที่ 4.3 (ข)

$$\frac{dx(t)}{dt} = 1 + \mu(x \cos(t) - y \sin(t)) \dots\dots\dots(4.5)$$

$$\frac{dy(t)}{dt} = \mu(x \sin(t) + y \cos(t)) \dots\dots\dots(4.6)$$

โดยกำหนดให้ $\mu = 0.9$



รูปที่ 4.3 กราฟแสดงลักษณะข้อมูลลวน 2 มิติ

4.2.3 ระบบความอลวน แบบ 3 มิติ

ระบบความอลวน แบบ 3 มิติ คือจะมีข้อมูลเข้าระบบ 3 ค่า และระบบจะให้ข้อมูลออก 3 ค่า สมการที่นำมาใช้ทดสอบคือ Rössler attractor, Chua's autonomous circuit, Chua's circuit, Lorenz chaotic system, Colpitts Oscillator, และ RC chaotic oscillator

4.2.3.1 Rössler attractor

สมการ Rössler attractor แสดงดังสมการ (4.7) (4.8) และ (4.9) แสดงกราฟดังรูปที่

4.4 (ก)

$$\frac{dx(t)}{dt} = -y - z \dots\dots\dots(4.7)$$

$$\frac{dy(t)}{dt} = x + ay \dots\dots\dots(4.8)$$

$$\frac{dz(t)}{dt} = b + z(x - c) \dots\dots\dots(4.9)$$

โดยกำหนดให้ $a = 0.2$, $b = 0.4$ และ $c = 5.7$

4.2.3.2 Chua's autonomous circuit

สมการ Rössler attractor แสดงดังสมการ (4.10) (4.11) และ (4.12) แสดงกราฟดังรูป

ที่ 4.4 (ข)

$$\frac{dx(t)}{dt} = \alpha(-x + h(x)) \dots\dots\dots(4.10)$$

$$\frac{dy(t)}{dt} = x - y + z \dots\dots\dots(4.11)$$

$$\frac{dz(t)}{dt} = -\beta y \dots\dots\dots(4.12)$$

โดยกำหนดให้ $h(x) = bx + 0.5(a - b)(|x + 1| - |x - 1|)$, $\alpha = 10$, $\beta = 15$, $a = -1.3$, และ $b = -0.7$

4.2.3.3 Chua's circuit

สมการ Chua's circuit แสดงดังสมการ (4.13) (4.14) และ (4.15) แสดงกราฟดังรูปที่

4.4 (ก)

$$\frac{dx(t)}{dt} = \alpha(-x + h(x)) \dots\dots\dots(4.13)$$

$$\frac{dy(t)}{dt} = x - y + z \dots\dots\dots(4.14)$$

$$\frac{dz(t)}{dt} = -\beta y \dots\dots\dots(4.15)$$

โดยกำหนดให้ $h(x) = ax + bx^3$, $\alpha = 8.85$, $\beta = 15$, $a = -1.3$, และ $b = 0.07$

4.2.3.4 Lorenz chaotic system

สมการ Lorenz chaotic system แสดงดังสมการ (4.16) (4.17) และ (4.18) แสดงกราฟ

ดังรูปที่ 4.4 (ง)

$$\frac{dx(t)}{dt} = \sigma(y - x) \dots\dots\dots(4.16)$$

$$\frac{dy(t)}{dt} = rx - y - xz \dots\dots\dots(4.17)$$

$$\frac{dz(t)}{dt} = xy - bz \dots\dots\dots(4.18)$$

โดยกำหนดให้ $\sigma = 16$, $r = 45.92$, และ $b = 4$

4.2.3.5 Colpitts Oscillator

สมการ Colpitts Oscillator แสดงดังสมการ (4.19) (4.20) และ (4.21) แสดงกราฟดัง

รูปที่ 4.4 (จ)

$$\frac{dx(t)}{dt} = z - \beta \cdot f(y) \dots\dots\dots(4.19)$$

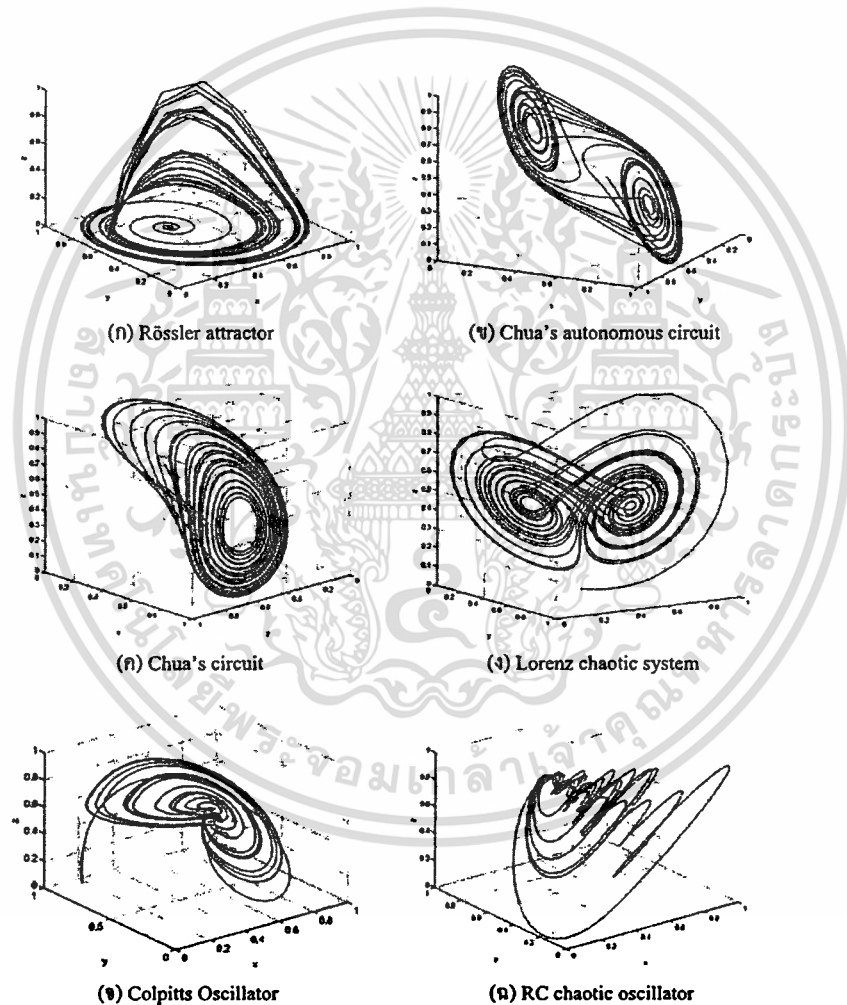
$$\frac{dy(t)}{dt} = \alpha(-r(y+\varphi) - z - f(y)) \dots\dots\dots(4.20)$$

$$\frac{dz(t)}{dt} = \delta(-x + y + \varepsilon) - \rho z \dots\dots\dots(4.21)$$

โดยกำหนดให้

$$f(y) = \begin{cases} 0 & ; y \leq 1 \\ y-1 & ; \text{otherwise} \end{cases}$$

$\alpha = 1$, $\beta = 200$, $\varphi = -20/3$, $\delta = 5.5$, $\varepsilon = 20/3$, $\rho = 2$, และ $r = 0.25$



รูปที่ 4.4 กราฟแสดงลักษณะข้อมูลลวน 3 มิติ

4.2.3.6 RC chaotic oscillator

สมการ RC chaotic oscillator แสดงดังสมการ (4.22) (4.23) และ (4.24) แสดงกราฟ

ดังรูปที่ 4.4 (ฉ)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\frac{dx(t)}{dt} = k \cdot m(x-z) - x \dots\dots\dots(4.22)$$

$$\frac{dy(t)}{dt} = k \cdot n \cdot f(y,z) \dots\dots\dots(4.23)$$

$$\frac{dz(t)}{dt} = k \cdot m(x-z) - k \cdot n \cdot f(y,z) \dots\dots\dots(4.24)$$

โดยกำหนดให้

$$f(y,z) = \begin{cases} z - y & ; z - y \leq 1 \\ 1 & ; \text{otherwise} \end{cases}$$

$$k = 2, m = 11, \text{ และ } n = 0.9$$

4.2.4 ระบบความอลวน แบบ 4 มิติ

ระบบความอลวน แบบ 4 มิติ ก็จะมีข้อมูลเข้าระบบ 4 ค่า และระบบจะให้ข้อมูลออก 4 ค่า สมการที่นำมาใช้ทดสอบ Four dimensional autonomous chaotic circuit

4.2.4.1 Four dimensional autonomous chaotic circuit

สมการ Four dimensional autonomous chaotic circuit แสดงดังสมการ (4.25) (4.26)

(4.27) และ (4.28) แสดงกราฟดังรูปที่ 4.5

$$\frac{dx(t)}{dt} = \delta(x + \varphi y) - z - f(1,x) \dots\dots\dots(4.25)$$

$$\frac{dy(t)}{dt} = \beta \cdot (\delta(x + \varphi y) - w - \varphi f(2,y)) \dots\dots\dots(4.26)$$


$$\frac{dz(t)}{dt} = x \dots\dots\dots(4.27)$$

$$\frac{dw(t)}{dt} = \alpha y \dots\dots\dots(4.28)$$

โดยกำหนดให้

$$f(k,x) = \frac{0.5(|x-1| + x - 1)}{\varepsilon_k}$$

$$\alpha = 2, \varphi = 3, \delta = 0.27, \varepsilon_1 = 0.8, \text{ และ } \varepsilon_2 = 0.2$$



รูปที่ 4.5 กราฟแสดงลักษณะข้อมูลลวน 4 มิติ

จากระบบความอลวนที่มักมีการอ้างอิงข้อมูลในอดีต ดังนั้นการประมาณการฟังก์ชันนี้ จะใช้โครงข่ายรีเคอร์เรนต์ (Recurrent Neural Network) ในการประมาณการฟังก์ชัน โดยใช้ทั้งแบบ Jordan และ Elman แต่เพื่อเป็นการทดสอบการใช้ค่าน้ำหนักแบบหลายเซกเมนต์ว่าจะดีกว่าการใช้ค่าน้ำหนักแบบค่าเดียวหรือไม่ จึงเพิ่มการทดลองโดยใช้โครงข่ายแบบแพร่กระจายย้อนกลับ (Backpropagation Neural Network: BPNN) ด้วย ซึ่งในการทดลองจะกำหนดจำนวนโหนดในชั้นซ่อนตั้งแต่แบบ 1 โหนด จนถึง 50 โหนด แต่ละแบบใช้ค่าน้ำหนักแบบค่าเดียว และแบบหลายเซกเมนต์ที่แตกต่างกันไป โดยกำหนดให้มีเพียง 1 เซกเมนต์ตลอดการเรียนรู้ หรือสามารถแบ่งได้ 2, 5, 10, 15, 20 เซกเมนต์ ในระหว่างการเรียนรู้ ซึ่งหมายรวมถึง การลบเซกเมนต์ที่ไม่ได้ใช้ระหว่างการเรียนรู้ด้วย

ในการทดลองต้องนำฟังก์ชันข้างต้น กำหนดค่าเริ่มต้น และหาค่าต่อเนื่อง 2000 ข้อมูล โดยแบ่งเป็น 1000 ข้อมูลแรกใช้ในการเรียนรู้ และอีก 1000 ข้อมูลที่เหลือใช้ในการทดสอบ โดยทดลองโครงข่ายแต่ละแบบไม่น้อยกว่า 5 การทดลอง แต่ละการทดลอง จะหยุดเรียนรู้เมื่อ RMSE น้อยกว่า 0.02 หรือจนครบ 1000 รอบ และนำไปทดสอบกับข้อมูลทดสอบเพื่อหาค่า RMSE

ในงานวิจัยนี้ ผลการทดลองถูกแสดงออกเป็น 2 รูปแบบ คือ

1) ผลการทดลองที่ดีที่สุดจากทั้ง 3 โมเดล (Feed forward NN (FNN), Elman Recurrent NN (ERNN) และ Jordan Recurrent NN (JRNN)) ซึ่งแสดงผลการทดลองที่ดีที่สุดของแต่ละโครงข่าย (เลือกแสดงค่าน้อยที่สุดของ RMSE กรณีมีค่า RMSE น้อยที่สุดเท่ากัน จะเลือกโครงข่ายที่ใช้จำนวนโหนดในชั้นซ่อนน้อยที่สุด) ดังตารางที่ 4.3

2) ผลการทดลองเปรียบเทียบของทั้ง 3 โมเดล ในกรณีที่มีการใช้จำนวนโหนดในชั้นซ่อนที่เท่ากัน สำหรับรายละเอียดการทดลอง เพื่อเปรียบเทียบในจำนวนโหนดที่เท่ากันนี้ มีจำนวน 33 ตาราง จึงได้นำแสดงในตาราง ข.1-ข.33 ในภาคผนวก ข. และได้รวบรวมค่าเฉลี่ยเปอร์เซ็นต์เปรียบเทียบผลการทดลองในการใช้จำนวนโหนดที่เท่ากัน แสดงไว้ในตารางที่ 4.4

ตารางที่ 4.3 ผลการทดลองของโครงข่ายกับระบบความอลวน

ระบบความอลวน (Chaotic Systems)	ชนิดโครงข่าย	ค่าน้ำหนักแบบค่าเดียว		ค่าน้ำหนักแบบหลายเซกเมนต์		
		RMSE	M	RMSE	M	S
Mackey-Glass	FNN	0.03568	4	0.02787	4	10
	Elman	0.01208	26	0.00871	29	15
	Jordan	0.03068	3	0.01567	3	20
logistic	FNN	0.04147	38	0.00378	48	10
	Elman	0.02515	30	0.01497	3	10
	Jordan	0.03671	30	0.0041	49	15
henon	FNN	0.02722	19	0.00432	50	10
	Elman	0.01455	32	0.00987	12	20
	Jordan	0.0223	9	0.00418	50	20
Ikeda	FNN	0.03318	24	0.00917	47	10
	Elman	0.02245	13	0.01926	26	1
	Jordan	0.05593	19	0.00911	49	15
Rössler	FNN	0.02098	14	0.00786	50	2
	Elman	0.01443	4	0.0077	34	15
	Jordan	0.02074	12	0.00818	43	20
Chua's autonomous circuit (ChuaCirc)	FNN	0.02164	7	0.00936	46	2
	Elman	0.01484	36	0.00995	49	20
	Jordan	0.02128	4	0.00985	49	15
Chua's circuit with a cubic nonlinearity (ChuaCircCN)	FNN	0.02269	8	0.01071	47	2
	Elman	0.01408	12	0.00945	49	20
	Jordan	0.02203	12	0.01023	48	15
Lorenz	FNN	0.02132	7	0.01291	4	2
	Elman	0.0152	20	0.01358	8	2
	Jordan	0.0166	9	0.01249	45	1
Colpitts Oscillator	FNN	0.01863	6	0.01009	50	2
	Elman	0.01208	5	0.00975	18	20
	Jordan	0.01858	16	0.0108	46	15
RC chaotic Oscillator	FNN	0.02064	10	0.00778	14	2
	Elman	0.00939	30	0.01036	49	15
	Jordan	0.01695	45	0.01051	41	20
Autonomous4DCirc	FNN	0.02365	9	0.01618	50	2
	Elman	0.02086	4	0.01607	43	1
	Jordan	0.02346	14	0.01603	44	1

M จำนวนโหนดในชั้นซ่อน S จำนวนเซกเมนต์มากที่สุดที่สามารถแบ่งได้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางที่ 4.3 แสดงผลการทดลองของโครงข่ายแบบแพร่กระจายย้อนกลับ โครงข่ายแบบ Elman โครงข่ายแบบ Jordan และการปรับปรุงโครงข่าย โดยใช้ค่าน้ำหนักแบบหลายเซกเมนต์ ของทั้ง 3 แบบ ซึ่งผลการทดลองแสดงให้เห็นว่า การใช้วิธีการปรับปรุงโครงข่าย ให้ผลที่ดีกว่าแบบเดิม ที่ใช้ค่าน้ำหนักเพียงค่าเดียว และหลายผลการทดลองยังมีโครงสร้างโครงข่ายที่เล็กกว่า โดยดูได้จากจำนวนโหนดในชั้นซ่อนที่มีจำนวนน้อยกว่า เช่น ฟังก์ชัน logistic ในการทดลอง โดยใช้โครงข่ายแบบแพร่กระจายย้อนกลับ (BPNN) ที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์ จะมีจำนวนโหนดในชั้นซ่อน 15 โหนดและได้ผล RMSE= 0.015 แต่ถ้าเป็นแบบใช้ค่าน้ำหนักแบบค่าเดียว จะใช้จำนวนโหนดในชั้นซ่อนถึง 38 โหนด และได้ผล RMSE เพียง 0.0415 ซึ่งแสดงว่าโครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์นี้ มีขนาดโครงข่ายที่เล็กกว่า และยังให้ผลที่ดีกว่าอีกด้วย

ตารางที่ 4.4 ค่าเฉลี่ยรวมเมื่อใช้จำนวนโหนดที่เท่ากัน กับระบบความอลวน

ข้อมูล	Feed forward NN		Elman RNN		Jordan RNN	
	reduce (%)	num	reduce (%)	num	reduce (%)	num
Mackey-Glass	-22.66	50	-29.58	49	-45.97	49
logistic	-71.67	50	-29.39	50	-78.42	50
henon	-47.05	50	-8.23	44	-47.79	50
Ikeda	-75.17	50	-11.28	38	-65.85	49
Rössler	-15.10	49	-35.10	48	-17.28	50
Chua's autonomous circuit (ChuaCirc)	-33.86	49	-61.62	49	-36.71	49
Chua's circuit with a cubic nonlinearity (ChuaCircCN)	-20.61	49	-38.6	40	-27.26	49
Lorenz	-15.01	46	-16.67	39	-17.57	49
Colpitts Oscillator	-21.46	49	-23.71	47	-23.55	49
RC chaotic Oscillator	-36.44	50	-24.16	48	-34.98	50
Autonomous4DCirc	-20.45	48	-16.71	47	-17.67	47

reduce –ค่าเฉลี่ยรวมทุกแบบ (1-50 โหนด) ที่ให้ค่าผิดพลาดลดลง เมื่อใช้ค่าน้ำหนักแบบหลายเซกเมนต์

ค่าลบ หมายถึง โดยเฉลี่ยจาก 50 แบบ (1-50 โหนด) โครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์ให้ผลค่าผิดพลาดลดลง (%)

ค่าบวก หมายถึง โดยเฉลี่ยจาก 50 แบบ (1-50 โหนด) โครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์ให้ผลค่าผิดพลาดมากขึ้น (%)

num –จำนวนแบบ (1-50 โหนด) เมื่อใช้ค่าน้ำหนักแบบหลายเซกเมนต์ที่ให้ค่าผิดพลาดน้อยกว่าการใช้ค่าน้ำหนักเพียงค่าเดียว

จากตารางที่ 4.4 แสดงค่า reduce เป็นค่าลบทุกข้อมูล ซึ่งแสดงให้เห็นว่าการใช้โครงข่ายฯที่ใช้ค่าน้ำหนักแบบเซกเมนต์จะให้ค่าความผิดพลาดลดลงกว่าการใช้ค่าน้ำหนักเพียงค่าเดียวในทุกๆ ข้อมูล ทุกๆแบบ โครงข่ายฯ

4.3 ประเภทการพยากรณ์ (Forecast)

การพยากรณ์เป็นการทำนายข้อมูลในอนาคต โดยนำข้อมูลอดีตและปัจจุบันมาพิจารณา แล้วทำนายว่าข้อมูลในอนาคตจะเป็นอย่างไร เช่น ข้อมูลการซื้อขายหุ้นในตลาดหลักทรัพย์ตลอด 6 เดือนที่ผ่านมา แล้วทำนายว่าวันพรุ่งนี้ สัปดาห์หน้า หรือเดือนหน้า การซื้อขายหุ้นนั้นจะเป็นอย่างไร เป็นต้น

จากการพยากรณ์ที่ต้องนำข้อมูลอดีตมาพิจารณา ดังนั้น การทดลองจึงเหมือนการประมาณฟังก์ชัน ที่ใช้โครงข่ายรีเคอร์เร้นท์ทั้งแบบ Jordan และ Elman และเพื่อการศึกษาการใช้ค่าน้ำหนักแบบหลายเซกเมนต์เพิ่มเติม จึงเพิ่มการทดลองแบบแพร่กระจายย้อนกลับด้วย โดยการทดลองกำหนดโหนดในชั้นซ่อน 1 โหนด จนถึง 50 โหนด และกำหนดค่าน้ำหนักแบบค่าเดียว และแบบหลายเซกเมนต์ที่แตกต่างกันออกไป โดยกำหนดให้มีเพียง 1 เซกเมนต์ตลอดการเรียนรู้ หรือสามารถแบ่งได้ 2, 5, 10, 15, 20 เซกเมนต์ ในระหว่างการเรียนรู้ ซึ่งหมายรวมถึง การลบเซกเมนต์ที่ไม่ได้ใช้ในระหว่างการเรียนรู้ด้วย

ในที่นี้เลือกนำข้อมูลมาจาก Time Series Data Library ซึ่งรวบรวมข้อมูลอนุกรมเวลา (Time Series) หลายแบบ และจาก Forecasting: Methods and Applications เป็นชื่อเดียวกับชื่อหนังสือ ซึ่งได้รวบรวมข้อมูลที่ใช้ประกอบการทดลองตามบทต่างๆ ในหนังสือ โดยในที่นี้ได้เลือกและนำข้อมูลมาทดลองหาผล โดยการทดลองโครงข่ายฯแต่ละแบบไม่น้อยกว่า 5 การทดลอง แต่ละการทดลองจะหยุดเรียนรู้เมื่อ RMSE น้อยกว่า 0.05 หรือจนครบ 1000 รอบ และนำไปทดสอบกับข้อมูลทดสอบเพื่อหาค่า RMSE

ในงานวิจัยนี้ ผลการทดลองถูกแสดงออกเป็น 2 รูปแบบ คือ

1) ผลการทดลองที่ดีที่สุดจากทั้ง 3 โมเดล (Feed forward NN (FNN), Elman Recurrent NN (ERNN) และ Jordan Recurrent NN (JRNN)) ซึ่งแสดงผลการทดลองที่ดีที่สุดของแต่ละ โครงข่าย (เลือกแสดงค่าน้อยที่สุดของ RMSE กรณีมีค่า RMSE น้อยที่สุดเท่ากัน จะเลือกโครงข่ายที่ใช้จำนวนโหนดในชั้นซ่อนน้อยที่สุด) ดังตารางที่ 4.5

2) ผลการทดลองเปรียบเทียบของทั้ง 3 โมเดล ในกรณีที่มีการใช้จำนวนโหนดในชั้นซ่อนที่เท่ากัน สำหรับรายละเอียดการทดลอง เพื่อเปรียบเทียบในจำนวนโหนดที่เท่ากันนี้ มีจำนวน 30 ตาราง จึงได้นำแสดงในตาราง ค.1-ค.30 ในภาคผนวก ค. และได้รวบรวมค่าเฉลี่ยเปอร์เซ็นต์เปรียบเทียบผลการทดลองในการใช้จำนวนโหนดที่เท่ากัน แสดงไว้ในตารางที่ 4.6

ตารางที่ 4.5 ผลการทดลองของโครงข่ายกับการพยากรณ์

ข้อมูล	จำนวนข้อมูล		ชนิดโครงข่าย	ค่าน้ำหนักแบบค่าเดียว		ค่าน้ำหนักแบบหลายเซกเมนต์		
	เรียนรู้ (60%)	ทดสอบ(40%)		RMSE	M	RMSE	M	S
arge030	920	613	FNN	0.1107	2	0.011074	8	1
			Elman	0.11092	7	0.11035	1	2
			Jordan	0.11069	2	0.11051	4	20
ausl006	568	379	FNN	0.09262	1	0.09089	3	5
			Elman	0.08898	2	0.08855	3	2
			Jordan	0.09239	1	0.09054	3	10
az510	860	575	FNN	0.08689	5	0.08626	2	10
			Elman	0.08598	2	0.08581	2	10
			Jordan	0.08662	3	0.08641	2	10
beer	284	191	FNN	0.1274	14	0.12844	12	5
			Elman	0.11819	37	0.09472	43	10
			Jordan	0.1275	20	0.12531	6	2
co522	875	583	FNN	0.07602	4	0.0756	24	1
			Elman	0.07338	2	0.07326	3	20
			Jordan	0.076	3	0.07458	5	1
dj	174	117	FNN	0.05289	3	0.05131	6	20
			Elman	0.05187	2	0.05138	2	2
			Jordan	0.0531	3	0.05066	2	2
pigs	112	75	FNN	0.11413	4	0.11214	47	15
			Elman	0.10239	4	0.09818	14	10
			Jordan	0.11342	1	0.11056	9	1
rawsteel	272	182	FNN	0.09372	3	0.09033	3	20
			Elman	0.09056	4	0.088	4	2
			Jordan	0.09463	3	0.09042	3	2
sp500	920	613	FNN	0.04277	20	0.0385	4	10
			Elman	0.07417	14	0.04684	27	2
			Jordan	0.03737	12	0.03382	9	10
sunsplus	1643	1095	FNN	0.06753	2	0.06712	34	2
			Elman	0.06444	3	0.06508	3	2
			Jordan	0.0688	2	0.06491	43	20

M จำนวนโหนดในชั้นซ่อน S จำนวนเซกเมนต์มากที่สุดที่สามารถแบ่งได้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางที่ 4.5 แสดงผลการทดลองของโครงข่ายแบบแพร่กระจายย้อนกลับ โครงข่ายแบบ Elman โครงข่ายแบบ Jordan และการปรับปรุงโครงข่ายโดยใช้ค่าน้ำหนักแบบหลายเซกเมนต์ของทั้ง 3 แบบ ซึ่งผลการทดลองแสดงให้เห็นว่า การใช้ค่าน้ำหนักแบบเดิม และแบบหลายเซกเมนต์ให้ผลที่ไม่แตกต่างกันมากนัก (± 0.001) แต่เมื่อดูขนาดของโครงข่ายแล้ว โดยดูจากจำนวนโหนดในชั้นซ่อน จะเห็นได้ว่า โครงข่ายแบบที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์นั้น โดยส่วนใหญ่จะมีขนาดเล็กกว่า กล่าวคือใช้จำนวนโหนดในชั้นซ่อนน้อยกว่า เช่น ข้อมูล arge030 ในโครงข่ายแบบรีเคอร์เรนท์แบบ Elman (Elman NN) ที่ใช้ค่าน้ำหนักแบบค่าเดียว จะมีจำนวนโหนดในชั้นซ่อน 7 โหนด แต่ถ้าใช้ค่าน้ำหนักแบบเซกเมนต์ จะมีจำนวนโหนดในชั้นซ่อน 1 โหนด แม้ให้ผลที่ต่างกันเพียง 0.00057 แต่การใช้โครงข่ายที่เล็กกว่า ย่อมได้เปรียบกว่าในหลายด้าน เช่น การคำนวณหาผลที่เร็วกว่า เป็นต้น

ตารางที่ 4.6 ค่าเฉลี่ยรวมเมื่อใช้จำนวนโหนดที่เท่ากัน ในงานด้านการพยากรณ์

ข้อมูล	Feed forward NN		Elman RNN		Jordan RNN	
	reduce (%)	num	reduce (%)	num	reduce (%)	num
arge030	-0.27	28	0.39	11	-0.27	25
aus1006	-0.18	34	0.53	15	-0.58	37
az510	-2.10	41	0.93	9	-1.53	40
beer	0.7	16	-0.69	32	0.84	10
co522	-1.41	40	1.50	7	-0.56	41
dj	-7.51	47	-1.2	31	-8.40	50
pigs	-12.28	46	-7.42	36	-11.30	45
rawsteel	-0.79	30	-0.79	32	-2.43	35
sp500	25.50	15	-5.05	28	27.10	8
sunsplus	-11.66	47	-0.21	26	-12.08	49

reduce – ค่าเฉลี่ยรวมทุกแบบ (1-50 โหนด) ที่ให้ค่าผิดพลาดลดลง เมื่อใช้ค่าน้ำหนักแบบหลายเซกเมนต์

ค่าลบ หมายถึง โดยเฉลี่ยจาก 50 แบบ (1-50 โหนด) โครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์ให้ผลค่าผิดพลาดลดลง (%)

ค่าบวก หมายถึง โดยเฉลี่ยจาก 50 แบบ (1-50 โหนด) โครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์ให้ผลค่าผิดพลาดมากขึ้น (%)

num – จำนวนแบบ (1-50 โหนด) เมื่อใช้ค่าน้ำหนักแบบหลายเซกเมนต์ที่ให้ค่าผิดพลาดน้อยกว่าการใช้ค่าน้ำหนักเพียงค่าเดียว

จากตารางที่ 4.6 แสดงให้เห็นว่า การใช้โครงข่ายแบบใช้ค่าน้ำหนักแบบหลายเซกเมนต์ให้ผลค่าผิดพลาดลดลง 22 แบบการทดลอง จากการทดลองทั้งหมด 30 แบบการทดลอง สามารถอธิบายรายละเอียดที่น่าสนใจได้ดังนี้

1. ข้อมูล dj, pigs, rawsteel และ sunsplus รวม 3 ข้อมูล ที่ทุกโครงข่าย (แบบ Feed forward, แบบ Elman, แบบ Jordan) เมื่อใช้ค่าน้ำหนักแบบหลายเซกเมนต์จะให้ผลผิดพลาดลดลงทุกโครงข่าย
2. ข้อมูล beer และ sp500 เมื่อใช้โครงข่ายแบบ Feed forward NN และ Jordan RNN โดยใช้ค่าน้ำหนักแบบหลายเซกเมนต์จะไม่ทำให้ผลค่าผิดพลาดลดลง
3. ข้อมูล arge030, ausl006, az510 และ co522 เมื่อใช้โครงข่ายแบบ Elman RNN โดยใช้ค่าน้ำหนักแบบหลายเซกเมนต์จะไม่ทำให้ผลค่าผิดพลาดลดลง
4. ในภาพรวมการใช้โครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์ ไม่ทำให้ค่าผิดพลาดลดลง

4.4 สรุป

จากการทดลองโครงข่ายแบบแพร่กระจายย้อนกลับ โครงข่ายแบบ Elman และโครงข่ายแบบ Jordan โดยเปรียบเทียบแบบที่ใช้ค่าน้ำหนักเพียงค่าเดียว กับแบบที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์ โดยทดลองกับงานทางด้านกรจำแนกข้อมูล จำนวน 23 ข้อมูล การประมาณฟังก์ชัน จำนวน 11 ฟังก์ชัน และการพยากรณ์ จำนวน 10 ข้อมูล

ในงานด้านการจำแนกข้อมูล โครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์จะให้ผลค่าผิดพลาดลดลง 21 ข้อมูล โดยเฉลี่ยประมาณ 0-30% ให้ผลผิดพลาด 0.0% เท่ากับแบบที่ใช้ค่าน้ำหนักเพียงค่าเดียว 1 ข้อมูล และให้ผลค่าผิดพลาดไม่ลดลง 1 ข้อมูล

ในงานด้านการประมาณฟังก์ชัน โครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์จะให้ผลค่าผิดพลาดลดลงทุกข้อมูล

ในงานด้านการพยากรณ์ โครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์จะให้ผลค่าผิดพลาดลดลง 22 แบบการทดลอง จากการทดลองทั้งหมด 30 แบบการทดลอง มีเพียง 3 ข้อมูลที่การทดลองกับ 3 โครงข่าย (แบบ Feed forward, แบบ Elman และแบบ Jordan) เมื่อใช้ค่าน้ำหนักแบบหลายเซกเมนต์ ให้ผลค่าผิดพลาดลดลงทุกโครงข่าย แต่โดยภาพรวมการใช้โครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์กับงานด้านการพยากรณ์ ไม่ทำให้ค่าผิดพลาดลดลง

บทที่ 5

สรุปผลงานวิจัยและข้อเสนอแนะ

5.1 สรุปผลงานวิจัย

งานวิจัยนี้ได้ปรับปรุงโครงข่ายแบบแพร่กระจายย้อนกลับ โครงข่ายแบบ Elman และโครงข่ายแบบ Jordan ที่ปกติจะใช้ค่าน้ำหนักเพียงค่าเดียว มาเป็นการใช้ค่าน้ำหนักแบบหลายเซกเมนต์ โดยนำมาทดลองกับงานด้านการจำแนกข้อมูล จำนวน 23 ข้อมูล ซึ่งแบ่งเป็น ข้อมูลที่สร้างขึ้นเอง 8 ข้อมูล และข้อมูลที่เกิดขึ้นจริง 15 ข้อมูล งานด้านการประมาณฟังก์ชัน จำนวน 11 ฟังก์ชัน โดยใช้ chaotic function ทั้ง 11 ฟังก์ชัน และงานด้านการพยากรณ์ จำนวน 10 ข้อมูล

จากการทดลอง โครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์ จะให้ผลการทดลองที่ดีกว่าแบบที่ใช้ค่าน้ำหนักเพียงค่าเดียว พร้อมทั้งโครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์นั้น ยังมีขนาดโครงข่ายที่เล็กกว่า โดยดูได้จากจำนวนโหนดในชั้นช่อนที่น้อยกว่า แบบที่ใช้ค่าน้ำหนักเพียงค่าเดียวอีกด้วย

5.2 การนำงานวิจัยไปใช้

การนำงานวิจัยนี้ไปใช้ เป็นเหมือนการนำโครงข่ายประสาทเทียมไปใช้ทั่วไป เช่นการรู้จำภาพอักษร การรู้จำใบหน้า การประมาณฟังก์ชัน การพยากรณ์หุ้น การพยากรณ์ผลผลิตข้าว เป็นต้น โดยการศึกษาการนำไปใช้เหมือนการศึกษานำโครงข่ายประสาทเทียมแบบเดิมไปใช้ เช่นการกำหนดข้อมูลเข้า การกำหนดจำนวนโหนดในชั้นช่อน การกำหนดข้อมูลออก และมีเพิ่มเติมคือการกำหนดจำนวนการแบ่งเซกเมนต์มากที่สุด ซึ่งในเบื้องต้นควรกำหนดเป็น 1 เซกเมนต์ แล้วจึงค่อยเพิ่มจำนวนเซกเมนต์เพื่อดูประสิทธิภาพของโครงข่ายที่เพิ่มขึ้น

โดยภาพรวมการนำโครงข่ายที่ปรับปรุงนี้ไปใช้ เหมือนการนำโครงข่ายประสาทเทียมแบบเดิมไปใช้ เพราะภาพรวมภายนอกของโครงข่ายที่เหมือนกัน แต่เป็นการปรับปรุงอัลกอริทึมภายในโครงข่าย ทำให้สะดวกในการศึกษานำไปใช้ทั่วไปได้เป็นอย่างดี

5.3 ปัญหาที่พบในงานวิจัยนี้

จากงานวิจัยนี้ ที่ได้ปรับปรุงโครงข่าย ให้ใช้ค่าน้ำหนักแบบหลายเซกเมนต์ อีกทั้งยังพัฒนาให้สามารถแบ่งเซกเมนต์ได้ ในขณะที่เรารู้จักด้วยนั้น ในการทดลองพบว่า การแบ่งเซกเมนต์ที่มากเกินไป จะทำให้โครงข่ายรู้จักเฉพาะข้อมูลที่เรียนรู้ (over fit) ซึ่งไม่เป็นผลดีกับโครงข่าย

เพราะเมื่อนำโครงข่ายฯ ไปทดสอบกับข้อมูลทดสอบ ซึ่งเป็นเพียงข้อมูลที่มีรูปแบบใกล้เคียงกับข้อมูลที่เรียนรู้ จะทำให้โครงข่ายฯ ให้ผลไม่ถูกต้อง เพราะเป็นข้อมูลที่ไม่ตรงตามรูปแบบที่โครงข่ายฯ ได้เรียนรู้มา

ในการทดลอง จึงต้องกำหนดการแบ่งจำนวนเซกเมนต์มากที่สุดไว้หลายแบบ คือ 1, 2, 5, 10, 15 และ 20 เซกเมนต์ ในแต่ละการทดลองกับจำนวนโหนดในชั้นซ่อน กล่าวคือ จำนวนโหนด 1 โหนด ถึง 50 โหนด ซึ่งทำให้ต้องทำการทดลองจำนวน 50×6 การทดลอง ในแต่ละข้อมูล

5.4 แนวทางการพัฒนาในอนาคต

จากปัญหาที่พบในงานวิจัยหลักๆ คือ การแบ่งจำนวนเซกเมนต์ที่มากจนเกินไป ดังนั้น แนวทางการพัฒนาต่อจากงานวิจัยนี้ คือ การพัฒนาอัลกอริทึมที่ไม่ให้มีการแบ่งเซกเมนต์มากเกินไปจนความจำเป็น หรือการลดเซกเมนต์ที่มีความใกล้เคียงกัน เป็นต้น



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บรรณานุกรม

- กัลยา วานิชบัญชา. 2542. การวิเคราะห์สถิติ: สถิติเพื่อการตัดสินใจ. พิมพ์ครั้งที่ 4. กรุงเทพฯ: โรงพิมพ์แห่งจุฬาลงกรณ์มหาวิทยาลัย.
- ฉัตรฐพันธ์ เขจรนันท์. 2545. การวิเคราะห์เชิงปริมาณทางธุรกิจ. กรุงเทพฯ: ธรรมกลการพิมพ์.
- ศิริภรณ์ วิชัยสินธุ์ และรวีพิมพ์ นวีสุข. 2552. เทคนิคการวิเคราะห์อนุกรมเวลาสำหรับการพยากรณ์ปริมาณผลผลิตผักและผลไม้. [ออนไลน์]. เข้าถึงได้จาก : http://www.siamzip.com/tlog/components/com_booklibrary/ebooks/FB4_3.pdf.
- Arbach, L., Reinhardt, J. M., Bennett, D. L., and Fallouh, G. 2003. "Mammographic Masses Classification: Comparison Between Backpropagation Neural Network (BNN), K Nearest Neighbors (KNN), and Human Readers." pp. 1441-1444. In: **Proceedings of the Canadian Conference on Electrical and Computer Engineering.**
- Arbach, L., Stolpen, A., and Reinhardt, J. M.: 2004. "Classification of Breast MRI Lesions Using a Backpropagation Neural Network (BNN)." pp. 253-256. In: **Proceedings of the IEEE International Symposium on Biomedical Imaging: Nano to Macro.**
- Asuncion, A., and Newman, D. J.: 2007. **UCI Machine Learning Repository.** Available: <http://www.ics.uci.edu/~mlern/MLRepository.html>. University of California, School of Information and Computer Science.
- Bowerman, B.L. and O'Connell, R.T. 1993. **Forecasting and Time Series: An Applied Approach.** Belmont, CA: Duxbury Press.
- Box, G.E.P. and Jenkins, F.M. 1976. **Time Series Analysis: Forecasting and Control.** 2nd ed. Oakland, CA: Holden-Day.
- Chen, T. B. and Soo, V. W. 1996. "A comparative study of recurrent neural network architectures on learning temporal sequences," pp. 1945-1950. in **Proceedings of the IEEE International Conference on Neural Networks.**
- Cheng, Y. C., Qi, W. M., and Cai, W. Y. 2002. "Dynamic properties of Elman and modified Elman neural network," pp. 637-640. in **Proceedings of the First International Conference on Machine Learning and Cybernetics.**
- Danaher, S., Herries, G., Selige, T., and Mac Suirtan, M. 1997. "A Comparison of the Characterisation of Agricultural Land Using Singular Value Decomposition and Neural Networks." in **Neurocomputation in Remote Sensing Data Analysis.**

- Elman, J. L. 1990. "Finding structure in time," *Cognitive Science*. 14:179–211.
- Fisher, R. A. 1936. "The Use of Multiple Measurements in Taxonomic Problems." *Annual Eugenics*. Vol. 7:179-188.
- Go, J., Han, G., Kim, H., Lee, C.: 2001. "Multigradient: A New Neural Network Learning Algorithm for Pattern Classification." in *IEEE Transactions on Geoscience and Remote Sensing*. 39(5):986-993.
- Grip, H., Öhberg, F., Wiklund, U., Sterner, Y., Karlsson, J. S., and Gerdle, B. 2003. "Classification of Neck Movement Patterns Related to Whiplash-Associated Disorders Using Neural Networks." *IEEE Transactions on Information Technology in Biomedicine*. 7(4): 412-418.
- Han, J., and Kamber, M. 2001. *Data Mining: Concepts and Techniques*. Academic Press
- Haykin, S. 1994. *Neural Network: A Comprehensive Foundation*. New York: Macmillan College.
- Ji, Q.L., Qi, W.M. 2007. "The property of PID Elman neural network and its application in identification of hydraulic unit," pp. 1795–1798. In: *Proceedings of the 2007 IEEE international conference on control and automation*.
- Jordan, M. I. 1986. "Attractor dynamics and parallelism in a connectionist sequential machine," pp.531–546. in: *Proceedings of the Eighth Annual Conference of the Cognitive Science Society*.
- Lee, J., Weger, R. C., Sengupta, S. K., and Welch, R. M. 1990. "A Neural Network Approach to Cloud Classification." *IEEE Transactions on Geoscience and Remote Sensing*. 28(5): 846-855.
- Lee, S. and Song, H. 1997. "A new recurrent neural network architecture for visual pattern recognition," *IEEE Transactions on Neural Networks*. 8(2): 331–340.
- Makridakis, S., Wheelwright, S.C., and Hyndman, R.J. 2008. *Forecasting: Methods and Applications*. [online]. Available : <http://www.robjhyndman.com/forecasting/>
- Mitzias, Dimitris A. and Basil G. Mertzios. 2004, October-December. "A Neural Multiclassifier System for Object Recognition in Robotic Vision Applications." *ScienceDirect*. 36(3-4) :315-330.

- Quinlan, J. R. 1994. "Comparing Connectionist and Symbolic Learning Methods." pp.445-456. In: **Proceedings of a Workshop on Computational Learning Theory and Natural Learning Systems.**
- Rimer, M., Anderson, T., and Martinez, T. R. 2001. "Improving Backpropagation Ensembles through Lazy Training." pp.2007-2112. In: **Proceedings of the IEEE International Joint Conference on Neural Networks.**
- Rimer, M., and Martinez, T. 2004. "Softprop: Softmax Neural Network Backpropagation Learning." pp.979-983. In: **Proceedings of the 2004 IEEE International Joint Conference on Neural Networks.**
- Rumatir, G.W. 1995. "A Hybrid Statistical and Feedforward Network Model for Forecasting with a Limited Amount of Data: Average Monthly Water Demand Time-Series." Thesis, Royal Melbourne Institute of Technology.
- Russell, S., and Norvig, P. 1995. **Artificial Intelligence: A Modern Approach.** Prentice Hall.
- Sarkar, M., and Yegnanarayana, B. 1997. "Incorporation of Fuzzy Classification Properties into Backpropagation Learning Algorithm." pp.1701-1706. In: **Proceedings of the Sixth IEEE International Conference on Fuzzy Systems.**
- Shavlik, J. W., Mooney, R. J., and Towell, G. G. 1991. "Symbolic and Neural Learning Algorithms: An Experimental Comparison." **Machine Learning.** 6(2):111-143.
- Stoeva, S., and Nikov, S., 2000. "A fuzzy backpropagation algorithm. Fuzzy Set and Systems." 112(1):27-39.

ภาคผนวก ก.

ผลการทดลองและสถิติผลการทดลอง กับงานการจำแนกข้อมูล



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ก.11 ผลการทดลองและสถิติของข้อมูล Image โดยใช้ Feed forward NN.

Table with columns for Feed forward NN (FNN) and Feed forward NN (MSFNN) metrics across 50 iterations. Includes sub-columns for max, min, mean, and SD, and a final re(%) column.

H-จำนวนโหนดในชั้นซ่อน, min-ค่าผิดพลาดน้อยที่สุดจากการทดลอง 5 ครั้ง, 1, 2, 3, 4, 5-ผลการทดลองครั้งที่ 1, 2, 3, 4, 5 โดยคิดเป็นเปอร์เซ็นต์ที่โครงข่ายให้ผลผิดพลาด, SD-ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง, A-ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด), B-ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด), C-ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด), re -reduce เปอร์เซ็นต์ที่โครงข่ายให้ผลผิดพลาดลดลง โดยหาได้จาก mean_FNN/mean_MS, max-ค่าผิดพลาดมากที่สุดจากการทดลอง 5 ครั้ง, mean-ค่าเฉลี่ยของค่าความผิดพลาดจากการทดลอง 5 ครั้ง

ผลการทดลองจากตารางที่ ก.11 แสดงให้เห็นว่า เมื่อมีการใช้จำนวนโหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลงทุกแบบ (จำนวนโหนดที่เท่ากันในชั้นซ่อน) โดยถ้าคิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลงโดยเฉลี่ย 2.19% โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 7.81% เมื่อใช้จำนวนโหนดในชั้นซ่อน 5 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์คือ 5.57% เมื่อใช้จำนวนโหนดในชั้นซ่อน 21 โหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ก.13 ผลการทดลองและสถิติของข้อมูล Iris โดยใช้ Feed forward NN.

H	Feed forward NN แบบใช้ค่าน้ำหนักเพียงค่าเดียว (FNN)				Feed forward NN แบบใช้ค่าน้ำหนักแบบหลายเซกเมนต์ (MSFNN)				re(%)			
	1	2	3	4	5	max	min	mean		SD		
1	0	0	0	0	0	0	0	0	0.0000	0		
2	0	0	0	0	0	0	0	0	0.0000	0		
3	0	0	0	0	0	0	0	0	0.0000	0		
4	0	0	0	0	0	0	0	0	0.0000	0		
5	0	0	0	0	0	0	0	0	0.0000	0		
6	0	0	0	0	0	0	0	0	0.0000	0		
7	0	0	0	0	0	0	0	0	0.0000	0		
8	0	0	0	0	0	0	0	0	0.0000	0		
9	0	0	0	0	0	0	0	0	0.0000	0		
10	0	0	0	0	0	0	0	0	0.0000	0		
11	0	0	0	0	0	0	0	0	0.0000	0		
12	0	0	0	0	0	0	0	0	0.0000	0		
13	0	0	0	0	0	0	0	0	0.0000	0		
14	0	0	0	0	0	0	0	0	0.0000	0		
15	0	0	0	0	0	0	0	0	0.0000	0		
16	0	0	0	0	0	0	0	0	0.0000	0		
17	0	0	0	0	0	0	0	0	0.0000	0		
18	0	0	0	0	0	0	0	0	0.0000	0		
19	0	0	0	0	0	0	0	0	0.0000	0		
20	0	0	0	0	0	0	0	0	0.0000	0		
21	0	0	0	0	0	0	0	0	0.0000	0		
22	0	0	0	0	0	0	0	0	0.0000	0		
23	0	0	0	0	0	0	0	0	0.0000	0		
24	0	0	0	0	0	0	0	0	0.0000	0		
25	0	0	0	0	0	0	0	0	0.0000	0		
26	0	0	0	0	0	0	0	0	0.0000	0		
27	0	0	0	0	0	0	0	0	0.0000	0		
28	0	0	0	0	0	0	0	0	0.0000	0		
29	0	0	0	0	0	0	0	0	0.0000	0		
30	0	0	0	0	0	0	0	0	0.0000	0		
31	0	0	0	0	0	0	0	0	0.0000	0		
32	0	0	0	0	0	0	0	0	0.0000	0		
33	0	0	0	0	0	0	0	0	0.0000	0		
34	0	0	0	0	0	0	0	0	0.0000	0		
35	0	0	0	0	0	0	0	0	0.0000	0		
36	0	0	0	0	0	0	0	0	0.0000	0		
37	0	0	0	0	0	0	0	0	0.0000	0		
38	0	0	0	0	0	0	0	0	0.0000	0		
39	0	0	0	0	0	0	0	0	0.0000	0		
40	0	0	0	0	0	0	0	0	0.0000	0		
41	0	0	0	0	0	0	0	0	0.0000	0		
42	0	0	0	0	0	0	0	0	0.0000	0		
43	0	0	0	0	0	0	0	0	0.0000	0		
44	0	0	0	0	0	0	0	0	0.0000	0		
45	0	0	0	0	0	0	0	0	0.0000	0		
46	0	0	0	0	0	0	0	0	0.0000	0		
47	0	0	0	0	0	0	0	0	0.0000	0		
48	0	0	0	0	0	0	0	0	0.0000	0		
49	0	0	0	0	0	0	0	0	0.0000	0		
50	0	0	0	0	0	0	0	0	0.0000	0		
		A=0.00	B=0.00	C=0.00	C=0.0000			A=0.00	B=0.00	C=0.00	C=0.0000	C=0.00

H-จำนวนโหนดในชั้นซ่อน

max-ค่าผิดพลาดมากที่สุดจากการทดลอง 5 ครั้ง

mnk-ค่าผิดพลาดน้อยที่สุดจากการทดลอง 5 ครั้ง

mean-ค่าเฉลี่ยของค่าความผิดพลาดจากการทดลอง 5 ครั้ง

1, 2, 3, 4, 5-ผลการทดลองครั้งที่ 1, 2, 3, 4, 5 โดยคิดเป็นเปอร์เซ็นต์ที่โครงข่ายให้ผลผิดพลาด

A-ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)

SD-ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง

B-ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)

B-ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)

C-ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด)

re-reduce เปอร์เซ็นต์ที่โครงข่ายให้ผลผิดพลาดลดลง โดยหาได้จาก $\frac{\text{mean}_{\text{MSFNN}} - \text{mean}_{\text{FNN}}}{\text{mean}_{\text{FNN}}}$

ผลการทดลองจากตารางที่ ก.13 แสดงให้เห็นว่า เมื่อมีการใช้จำนวนโหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดเท่ากับการใช้ค่าน้ำหนักเพียงค่าเดียวทุกแบบ (จำนวนโหนดที่เท่ากันในชั้นซ่อน) คือ 0.0% โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 0.0% เมื่อใช้จำนวนโหนดในชั้นซ่อนตั้งแต่ 1 โหนดขึ้นไป และผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์คือ 0.0% เมื่อใช้จำนวนโหนดในชั้นซ่อนตั้งแต่ 1 โหนดขึ้นไป เช่นกัน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ก.19 ผลการทดลองและสถิติของข้อมูล Spectf โดยใช้ Feed forward NN.

Table with 2 main sections: Feed forward NN แบบใช้ค่าน้ำหนักเพียงค่าเดียว (FNN) and Feed forward NN แบบใช้ค่าน้ำหนักแบบหลายเซกเมนต์ (MSFNN). Each section has columns for H, 1-5, max, min, mean, SD, and re(%).

H-จำนวนโหนดในชั้นซ่อน max-ค่าผิดพลาดมากที่สุดจากการทดลอง 5 ครั้ง
min-ค่าผิดพลาดน้อยที่สุดจากการทดลอง 5 ครั้ง mean-ค่าเฉลี่ยของค่าความผิดพลาดจากการทดลอง 5 ครั้ง
SD-ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง A-ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
B-ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด) C-ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด)
re-reduce เปอร์เซ็นต์ที่โครงข่ายฯให้ผลผิดพลาดลดลง โดยหาได้จาก meanMSFNN/meanFNN

ผลการทดลองจากตารางที่ ก.19 แสดงให้เห็นว่า เมื่อมีการใช้จำนวนโหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายฯให้ผลผิดพลาดลดลงทุกแบบ (จำนวนโหนดที่เท่ากันในชั้นซ่อน) โดยถ้าคิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายฯให้ผลผิดพลาดลดลงโดยเฉลี่ย 4.46% โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายฯที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 14.87% เมื่อใช้จำนวนโหนดในชั้นซ่อน 1 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายฯที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์คือ 5.58% เมื่อใช้จำนวนโหนดในชั้นซ่อน 1 โหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก ข.

ผลการทดลองและสถิติผลการทดลอง กับงานระบบความอดวน



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ข.3 ผลการทดลองและสถิติของข้อมูล Mackey-Glass โดยใช้ Jordan Recurrent NN.

Table with columns for Jordan Recurrent NN แบบใช้ค่าน้ำหนักเพียงค่าเดียว (JRNN) and Jordan Recurrent NN แบบใช้ค่าน้ำหนักแบบเชกเมนต์ (MSJRNN). Rows 1-500 show parameters like 1, 2, 3, 4, 5, max, min, mean, SD and resulting re(%) values.

H -จำนวนโหนดในชั้นซ่อน
min -ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง
max -ค่าผิดพลาด (RMSE) มากที่สุดจากการทดลอง 5 ครั้ง
mean -ค่าเฉลี่ยของค่าความผิดพลาด (RMSE) จากการทดลอง 5 ครั้ง
SD -ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง
A -ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
B -ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
C -ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด)
re -reduce เมื่อใช้ค่าที่โครงข่ายให้ผลผิดพลาดลดลง โดยหาได้จาก (meanMSJRNN-meanJRNN)/meanJRNN*100

ผลการทดลองจากรายการที่ ข.3 แสดงให้เห็นว่า เมื่อมีการใช้จำนวนโหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเชกเมนต์ทำให้โครงข่ายฯให้ผลผิดพลาดลดลง 49 แบบ (จำนวนโหนดที่เท่ากัน 3-5 โหนด) โดยถ้าคิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนักแบบหลายเชกเมนต์ทำให้โครงข่ายฯให้ผลผิดพลาดลดลงโดยเฉลี่ย 45.97% โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายฯที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 0.03068 เมื่อใช้จำนวนโหนดในชั้นซ่อน 3 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายฯที่ใช้ค่าน้ำหนักแบบหลายเชกเมนต์คือ 0.01567 เมื่อใช้จำนวนโหนดในชั้นซ่อน 3 โหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับกรใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ข.4 ผลการทดลองและสถิติของข้อมูล logistic โดยใช้ Feed forward NN.

Table with 3 main columns: Feed forward NN แบบใช้ค่าน้ำหนักเพียงค่าเดียว (FNN), Feed forward NN แบบใช้ค่าน้ำหนักแบบหลายเซกเมนต์ (MSFNN), and re(%). Each column contains 11 sub-columns for parameters 1-5, max, min, mean, SD, and re(%). Rows 1-50 show numerical results for each configuration.

H -จำนวนโหนดในชั้นซ่อน max -ค่าผิดพลาด (RMSE) มากที่สุดจากการทดลอง 5 ครั้ง
min -ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง mean -ค่าเฉลี่ยของค่าความผิดพลาด (RMSE) จากการทดลอง 5 ครั้ง
1, 2, 3, 4, 5 -ผลการทดลองครั้งที่ 1, 2, 3, 4, 5 โดยเรียงจากโครงข่ายให้ผลผิดพลาด (RMSE)
SD -ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง A -ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
B -ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด) C -ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด)
re -reduce เปอร์เซนต์ที่โครงข่ายให้ผลผิดพลาดลดลง โดยหาได้จาก (meanMSFNN-meanFNN)/meanFNN*100

ผลการทดลองจากตารางที่ ข.4 แสดงให้เห็นว่า เมื่อมีการใช้จำนวนโหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลงทุกแบบ (จำนวนโหนดที่เท่ากันในชั้นซ่อน) โดยถ้ามคิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลงโดยเฉลี่ย 71.67% โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 0.04147 เมื่อใช้จำนวนโหนดในชั้นซ่อน 38 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์คือ 0.00378 เมื่อใช้จำนวนโหนดในชั้นซ่อน 48 โหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ข.9 ผลการทดลองและสถิติของข้อมูล henon โดยใช้ Jordan Recurrent NN.

Table with 14 columns: H, 1, 2, 3, 4, 5, max, min, mean, SD for Jordan Recurrent NN and 1, 2, 3, 4, 5, max, min, mean, SD for Jordan Recurrent NN แบบใช้ค่าน้ำหนักแบบเวกเมนต์ (MSJRNN), and re(%). Rows 1-500 show detailed data points and statistical values for each iteration.

H -จำนวนโหนดในชั้นซ่อน

min -ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง

1, 2, 3, 4, 5 -ผลการทดลองครั้งที่ 1, 2, 3, 4, 5 โดยคิดจากที่โครงสร้างโหนดผิดพลาด (RMSE)

SD -ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง

A -ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)

B -ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)

C -ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด)

re -reduce เปรอเซ็นต์ที่โครงสร้างโหนดผิดพลาดลดลง โดยหาได้จาก (mean_{MSJRNN}-mean_{JRNN})/mean_{JRNN}*100

max -ค่าผิดพลาด (RMSE) มากที่สุดจากการทดลอง 5 ครั้ง

mean -ค่าเฉลี่ยของค่าความผิดพลาด (RMSE) จากการทดลอง 5 ครั้ง

(RMSE)

A -ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)

B -ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)

C -ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด)

ผลการทดลองจากตารางที่ ข.9 แสดงให้เห็นว่า เมื่อมีการใช้จำนวนโหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลงทุกแบบ (จำนวนโหนดที่เท่ากันในชั้นซ่อน) โดยถ้าคิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลงโดยเฉลี่ย 46.79% โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 0.0223 เมื่อใช้จำนวนโหนดในชั้นซ่อน 9 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์คือ 0.00418 เมื่อใช้จำนวนโหนดในชั้นซ่อน 50 โหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นอนุญาติให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ข.11 ผลการทดลองและสถิติของข้อมูล Ikeda โดยใช้ Elman Recurrent NN.

Table with 2 main columns: Elman Recurrent NN แบบใช้ค่าน้ำหนักแบบค่าเดิม (ERNN) and Elman Recurrent NN แบบใช้ค่าน้ำหนักแบบชกนบ (MSERNN). Each column contains 15 sub-columns: 1, 2, 3, 4, 5, max, min, mean, SD, re(%). The table lists 50 rows of data points.

H - จำนวนโหนดในชั้นซ่อน max - ค่าผิดพลาด (RMSE) มากที่สุดจากการทดลอง 5 ครั้ง
min - ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง
mean - ค่าเฉลี่ยของค่าความผิดพลาด (RMSE) จากการทดลอง 5 ครั้ง
1, 2, 3, 4, 5 - ผลการทดลองครั้งที่ 1, 2, 3, 4, 5 โดยคิดจากที่โครงข่ายให้ผลผิดพลาด (RMSE)
SD - ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง A - ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
B - ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด) C - ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด)
re - reduce เปอร์เซ็นต์ที่โครงข่ายให้ผลผิดพลาดลดลง โดยหาได้จาก (meanMSERNN - meanERNN) / meanERNN * 100

ผลการทดลองจากการตารางที่ ข.11 แสดงให้เห็นว่า เมื่อมีการใช้จำนวนโหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลง 38 แบบ (จำนวนโหนดที่เท่ากันในชั้นซ่อน) โดยถ้าคิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลงโดยเฉลี่ย 11.28% โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 0.02245 เมื่อใช้จำนวนโหนดในชั้นซ่อน 13 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์คือ 0.01926 เมื่อใช้จำนวนโหนดในชั้นซ่อน 26 โหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ข.14 ผลการทดลองและสถิติของข้อมูล Rössler โดยใช้ Elman Recurrent NN.

Table with 2 main sections: Elman Recurrent NN แบบใช้ค่าน้ำหนักเพียงค่าเดียว (ERNN) and Elman Recurrent NN แบบใช้ค่าน้ำหนักแบบแยกกัน (MSERNN). Each section contains columns for iterations 1-5, min, max, mean, SD, and re(%).

H-จำนวนโหนดในชั้นซ่อน max-ค่าผิดพลาด (RMSE) มากที่สุดจากการทดลอง 5 ครั้ง min-ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง mean-ค่าเฉลี่ยของค่าความผิดพลาด (RMSE) จากการทดลอง 5 ครั้ง SD-ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง A-ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด) B-ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด) C-ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด) re-reduce เปรอเซ็นต์ที่โครงข่ายให้ผลผิดพลาดลดลง โดยหาได้จาก (meanMSERNN-meanERNN)/meanERNN*100

ผลการทดลองจากตารางที่ ข.14 แสดงให้เห็นว่า เมื่อมีการใช้จำนวน โหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลง 48 แบบ (จำนวนโหนดที่เท่ากันในชั้นซ่อน) โดยถ้าคิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลงโดยเฉลี่ย 35.10% โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 0.01443 เมื่อใช้จำนวนโหนดในชั้นซ่อน 4 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์คือ 0.0077 เมื่อใช้จำนวนโหนดในชั้นซ่อน 34 โหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นิยามให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ข.15 ผลการทดลองและสถิติของข้อมูล Rössler โคโยใช้ Jordan Recurrent NN.

Table with 3 main sections: Jordan Recurrent NN summary statistics (columns 1-6), Jordan Recurrent NN parameter values (columns 7-11), and re(%) (column 12). Rows 1-500 contain numerical data for various parameters and iterations.

H-จำนวนโหนดในชั้นซ่อน max-ค่าผิดพลาด (RMSE) มากที่สุดจากการทดลอง 5 ครั้ง
min-ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง mean-ค่าเฉลี่ยของค่าความผิดพลาด (RMSE) จากการทดลอง 5 ครั้ง
1, 2, 3, 4, 5-ผลจากการทดลองครั้งที่ 1, 2, 3, 4, 5 โดยคิดจากที่โครงข่ายให้ผลผิดพลาด (RMSE)
SD-ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง A-ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
B-ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด) C-ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด)
re-reduce เปอร์เซ็นต์โครงข่ายให้ผลผิดพลาดลดลง โดยหาได้จาก (mean_MSRNN - mean_JRNN) / mean_JRNN * 100

ผลการทดลองจากตารางที่ ข.15 แสดงให้เห็นว่า เมื่อมีการใช้จำนวน โหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลงทุกแบบ (จำนวนโหนดที่เท่ากันในชั้นซ่อน) โดยถ้าคิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลงโดยเฉลี่ย 17.28% โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 0.02074 เมื่อใช้จำนวน โหนดในชั้นซ่อน 12 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์คือ 0.00818 เมื่อใช้จำนวน โหนดในชั้นซ่อน 43 โหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ข.16 ผลการทดลองและสถิติของข้อมูล ChuaCirc โดยใช้ Feed forward NN.

Table with columns: Feed forward NN แบบใช้ค่าน้ำหนักแบบค่าเดิม (FNN) and Feed forward NN แบบใช้ค่าน้ำหนักแบบขนาน (MSFNN). Rows include numerical data for 50 iterations and statistical values like max, min, mean, SD, and re(%).

H-จำนวนโหนดในชั้นซ่อน max-ค่าผิดพลาด (RMSE) มากที่สุดจากการทดลอง 5 ครั้ง
min-ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง
mean-ค่าเฉลี่ยของค่าความผิดพลาด (RMSE) จากการทดลอง 5 ครั้ง
SD-ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง
A-ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
B-ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
C-ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด)
re-reduce ค่าเฉลี่ยข้อผิดพลาดจากผลคูณของผลคูณโดยหาได้จาก ((meanMSFNN-meanFNN)/meanFNN)*100

ผลการทดลองจากรางที่ ข.16 แสดงให้เห็นว่า เมื่อมีการใช้จำนวนโหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลง 49 แบบ (จำนวนโหนดที่เท่ากันในชั้นซ่อน) โดยถ้าคิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลงโดยเฉลี่ย 33.86% โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 0.02164 เมื่อใช้จำนวนโหนดในชั้นซ่อน 7 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์คือ 0.00936 เมื่อใช้จำนวนโหนดในชั้นซ่อน 46 โหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ข.17 ผลการทดลองและสถิติของข้อมูล ChuaCirc โดยใช้ Elman Recurrent NN.

Table with 21 columns: H, 1, 2, 3, 4, 5, max, min, mean, SD, 1, 2, 3, 4, 5, max, min, mean, SD, re(%). It contains experimental data for 50 trials, showing various performance metrics for Elman Recurrent NN models.

H - จำนวนโหนดในชั้นซ่อน max - ค่าผิดพลาด (RMSE) มากที่สุดจากการทดลอง 5 ครั้ง
min - ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง mean - ค่าเฉลี่ยของความผิดพลาด (RMSE) จากการทดลอง 5 ครั้ง
1, 2, 3, 4, 5 - ผลการทดลองครั้งที่ 1, 2, 3, 4, 5 โดยตัดจากโครงข่ายโหนดผิดพลาด (RMSE) A - ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
SD - ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง B - ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
re - reduce ผลลัพธ์ที่โครงข่ายโหนดผิดพลาดลดลง โดยหาได้จาก (mean_MSE_50 - mean_ERNN) / (mean_ERNN * 100)

ผลการทดลองจากตารางที่ ข.17 แสดงให้เห็นว่า เมื่อมีการใช้จำนวนโหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายฯ ให้ผลผิดพลาดลดลง 49 แบบ (จำนวนโหนดที่เท่ากันในชั้นซ่อน) โดยถ้าคิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายฯ ให้ผลผิดพลาดลดลงโดยเฉลี่ย 61.62% โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายฯที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 0.01484 เมื่อใช้จำนวนโหนดในชั้นซ่อน 36 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายฯที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์คือ 0.00995 เมื่อใช้จำนวนโหนดในชั้นซ่อน 49 โหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ข.18 ผลการทดลองและสถิติของข้อมูล ChuaCirc โดยใช้ Jordan Recurrent NN.

Table with 15 columns: H, J1, J2, J3, J4, J5, max, min, mean, SD for Jordan Recurrent NN (JRNN), and corresponding columns for Jordan Recurrent NN แบบใช้ค่าน้ำหนักแบบผสมกัน (MSJRNN) plus a re(%) column. Rows 1-50 show numerical data for various iterations.

H -จำนวนโหนดในชั้นซ่อน max -ค่าผิดพลาด (RMSE) มากที่สุดจากการทดลอง 5 ครั้ง
min -ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง mean -ค่าเฉลี่ยของความผิดพลาด (RMSE) จากการทดลอง 5 ครั้ง
SD -ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง A -ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
B -ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด) C -ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด)
re -reduce แปลงเป็นค่าที่ตรงข้ามให้ผลผิดพลาดลดลง โดยหาได้จาก (meanMSJRNN-meanJRNN)/meanJRNN*100

ผลการทดลองจากตารางที่ ข.18 แสดงให้เห็นว่า เมื่อมีการใช้จำนวน โหนดที่เท่ากัน ในชั้น
ซ่อน การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายฯ ให้ผลผิดพลาดลดลง 49 แบบ (จำนวน
โหนดที่เท่ากัน ในชั้นซ่อน) โดยถ้าคิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนัก
แบบหลายเซกเมนต์ทำให้โครงข่ายฯ ให้ผลผิดพลาดลดลงโดยเฉลี่ย 36.71% โดยผลผิดพลาดที่น้อย
ที่สุดของโครงข่ายฯที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 0.02128 เมื่อใช้จำนวน โหนดในชั้นซ่อน 4
โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายฯที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์คือ 0.00985
เมื่อใช้จำนวน โหนดในชั้นซ่อน 49 โหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ข.19 ผลการทดลองและสถิติของข้อมูล ChuaCircCN โดยใช้ Feed forward NN.

Table with 25 columns: Feed forward NN parameters (1-5, min, max, mean, SD) and Feed forward NN output parameters (1-5, min, max, mean, SD, re(%)). Rows 1-50 show numerical data for each parameter.

H - จำนวนโหนดในชั้นซ่อน max - ค่าผิดพลาด (RMSE) มากที่สุดจากการทดลอง 5 ครั้ง
min - ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง
mean - ค่าเฉลี่ยของค่าความผิดพลาด (RMSE) จากการทดลอง 5 ครั้ง
SD - ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง
A - ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
B - ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
C - ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด)
re - reduce เปอร์เซ็นต์ที่โครงข่ายให้ผลผิดพลาดลดลง โดยหาได้จาก (mean_FNNn - mean_FNNn) / mean_FNNn * 100

ผลการทดลองจากตารางที่ ข.19 แสดงให้เห็นว่า เมื่อมีการใช้จำนวน โหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลง 49 แบบ (จำนวนโหนดที่เท่ากัน ในชั้นซ่อน) โดยถ้าคิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลงโดยเฉลี่ย 20.61% โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 0.02269 เมื่อใช้จำนวน โหนดในชั้นซ่อน 8 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์คือ 0.0107 เมื่อใช้จำนวน โหนดในชั้นซ่อน 47 โหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ข.24 ผลการทดลองและสถิติของข้อมูล Lorenz โดยใช้ Jordan Recurrent NN.

Table with 19 columns: H, Jordan Recurrent NN (5 sub-columns: 1-5, max, min, mean, SD), Jordan Recurrent NN แบบใช้ค่าน้ำหนักแบบเชกเมนต์ (MSJRN) (5 sub-columns: 1-5, min, mean, SD), and re(%). It contains 50 rows of numerical data.

H – จำนวนโหนดในชั้นซ่อน min – ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง max – ค่าผิดพลาด (RMSE) มากที่สุดจากการทดลอง 5 ครั้ง mean – ค่าเฉลี่ยของค่าความผิดพลาด (RMSE) จากการทดลอง 5 ครั้ง SD – ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง A – ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบน (1-50 โหนด) B – ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบน (1-50 โหนด) C – ค่าเฉลี่ยจากการทดลอง 50 แบน (1-50 โหนด) re – reduce เปอร์เซ็นต์ที่โครงข่ายฯ ให้ผลผิดพลาดลดลง โดยหาได้จาก $(\text{mean}_{MSJRN} - \text{mean}_{JRN}) / \text{mean}_{JRN} * 100$

ผลการทดลองจากตารางที่ ข.24 แสดงให้เห็นว่า เมื่อมีการใช้จำนวนโหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเชกเมนต์ทำให้โครงข่ายฯ ให้ผลผิดพลาดลดลง 49 แบน (จำนวนโหนดที่เท่ากันในชั้นซ่อน) โดยถ้าคิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนักแบบหลายเชกเมนต์ทำให้โครงข่ายฯ ให้ผลผิดพลาดลดลงโดยเฉลี่ย 17.57% โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายฯ ที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 0.0166 เมื่อใช้จำนวนโหนดในชั้นซ่อน 9 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายฯ ที่ใช้ค่าน้ำหนักแบบหลายเชกเมนต์คือ 0.01249 เมื่อใช้จำนวนโหนดในชั้นซ่อน 45 โหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นับผูกพันให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ข.27 ผลการทดลองและสถิติของข้อมูล Colpitts Oscillator โดยใช้ Jordan Recurrent NN.

Table with 15 columns for Jordan Recurrent NN and MSJRN. Columns include H, 1-5, max, min, mean, SD, and re(%). Rows 1-50 show data points with values ranging from 0.0000 to 0.13156. A summary row at the bottom shows A=0.132, B=0.01858, C=0.020, C=0.001.

H –จำนวนโหนดในชั้นซ่อน max –ค่าผิดพลาด (RMSE) มากที่สุดจากการทดลอง 5 ครั้ง
1, 2, 3, 4, 5 –ผลการทดลองครั้งที่ 1, 2, 3, 4, 5 โดยคิดจากที่โครงข่ายให้ผลผิดพลาด (RMSE) mean –ค่าเฉลี่ยของค่าความผิดพลาด (RMSE) จากการทดลอง 5 ครั้ง
SD –ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง A –ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
B –ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด) C –ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด)
re -reduce เปอร์เซ็นต์ที่โครงข่ายให้ผลผิดพลาดลดลง โดยหาได้จาก (mean_{MSJRN}-mean_{JRN})/mean_{JRN}*100

ผลการทดลองจากตารางที่ ข.27 แสดงให้เห็นว่า เมื่อมีการใช้จำนวน โหนดที่เท่ากัน ในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลง 49 แบบ (จำนวนโหนดที่เท่ากัน ในชั้นซ่อน) โดยถ้าคิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลงโดยเฉลี่ย 23.55% โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 0.01858 เมื่อใช้จำนวน โหนดในชั้นซ่อน 16 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์คือ 0.0108 เมื่อใช้จำนวน โหนดในชั้นซ่อน 46 โหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ข.30 ผลการทดลองและสถิติของข้อมูล RC chaotic Oscillator โดยใช้ Jordan Recurrent NN.

Table with columns for Jordan Recurrent NN and Jordan Recurrent NN แบบใช้ค่าน้ำหนักแบบเมทริกซ์ (MSJRNN). Includes sub-columns for H, 1, 2, 3, 4, 5, max, min, mean, SD, and re(%).

H -จำนวนโหนดในชั้นซ่อน max -ค่าผิดพลาด (RMSE) มากที่สุดจากการทดลอง 5 ครั้ง
min -ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง mean -ค่าเฉลี่ยของค่าความผิดพลาด (RMSE) จากการทดลอง 5 ครั้ง
SD -ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง A -ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
B -ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด) C -ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด)
re -reduce เปรอเซ็นต์ที่โครงข่ายให้ผลผิดพลาดลดลง โดยหาได้จาก (meanMSJRNN-meanJRNN)/meanJRNN*100

ผลการทดลองจากตารางที่ ข.30 แสดงให้เห็นว่า เมื่อมีการใช้จำนวน โหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลงทุกแบบ (จำนวน โหนดที่เท่ากันในชั้นซ่อน) โดยถ้าคิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลงโดยเฉลี่ย 34.98% โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 0.01695 เมื่อใช้จำนวน โหนดในชั้นซ่อน 45 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์คือ 0.01051 เมื่อใช้จำนวน โหนดในชั้นซ่อน 41 โหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ข.32 ผลการทดลองและสถิติของข้อมูล Autonomous4DCirc โดยใช้ Elman Recurrent NN.

Table with columns: Elman Recurrent NN แบบใช้ค่าน้ำหนักแบบเต็มตัว (ERNN) and Elman Recurrent NN แบบใช้ค่าน้ำหนักแบบเซกเมนต์ (MSERNN). Rows 1-500 show various numerical values for parameters like max, min, mean, SD, and re(%).

H -จำนวนโหนดในชั้นซ่อน min -ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง mean -ค่าเฉลี่ยของค่าความผิดพลาด (RMSE) จากการทดลอง 5 ครั้ง SD -ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง re -reduce เปอร์เซ็นต์ที่โครงข่ายให้ผลผิดพลาดลดลง โดยหาได้จาก (meanMSERNN - meanERNN) / meanERNN * 100

ผลการทดลองจากตารางที่ ข.32 แสดงให้เห็นว่า เมื่อมีการใช้จำนวนโหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลง 47 แบบ (จำนวนโหนดที่เท่ากันในชั้นซ่อน) โดยถ้าคิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลงโดยเฉลี่ย 16.71% โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 0.02086 เมื่อใช้จำนวนโหนดในชั้นซ่อน 4 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์คือ 0.01607 เมื่อใช้จำนวนโหนดในชั้นซ่อน 43 โหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ข.33 ผลการทดลองและสถิติของข้อมูล Autonomous4DCirc โดยใช้ Jordan Recurrent NN.

Table with 3 main columns: Jordan Recurrent NN แบบใช้ค่าน้ำหนักเพิ่มค่าตัว (JRNN), Jordan Recurrent NN แบบใช้ค่าน้ำหนักแบบชนวน (MSJRNN), and re(%). Each sub-column contains 11 metrics: 1, 2, 3, 4, 5, max, min, mean, SD, and re(%).

H -จำนวนโหนดในชั้นซ่อน max -ค่าผิดพลาด (RMSE) มากที่สุดจากการทดลอง 5 ครั้ง
m1 -ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง mean -ค่าเฉลี่ยของค่าความผิดพลาด (RMSE) จากการทดลอง 5 ครั้ง
1, 2, 3, 4, 5 -ผลการทดลองครั้งที่ 1, 2, 3, 4, 5 โดยจัดจากที่ตรงข้ามให้ผลผิดพลาดมากที่สุด
SD -ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง A -ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
B -ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด) C -ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด)
re -reduce เปรอเซ็นต์ที่ตรงข้ามให้ผลผิดพลาดลดลง โดยหาได้จาก (meanMSJRNN-meanJRNN)/meanJRNN*100

ผลการทดลองจากตารางที่ ข.33 แสดงให้เห็นว่า เมื่อมีการใช้จำนวนโหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลง 47 แบบ (จำนวนโหนดที่เท่ากันในชั้นซ่อน) โดยถ้าคิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลงโดยเฉลี่ย 17.67% โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 0.02346 เมื่อใช้จำนวนโหนดในชั้นซ่อน 14 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์คือ 0.01603 เมื่อใช้จำนวนโหนดในชั้นซ่อน 44 โหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาคผนวก ก.
ผลการทดลองและสถิติผลการทดลอง กับงานการพยากรณ์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ก.2 ผลการทดลองและสถิติของข้อมูล arge030 โดยใช้ Elman Recurrent NN.

Table with 2 main sections: Elman Recurrent NN. แบบใช้ค่าน้ำหนักเพิ่มค่าเดิม (ERNN) and Elman Recurrent NN. แบบใช้ค่าน้ำหนักแบบขมกมนต์ (MSERNN). Each section has columns for iterations 1-5, max, min, mean, SD, and re(%).

H -จำนวนโหนดในชั้นซ่อน min -ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง SD -ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง re -reduce เปรอ์เซ็นต์ที่โครงข่ายให้ผลผิดพลาดลดลง โดยหาได้จาก (mean_MSERNN-mean_ERNN)/mean_ERNN*100

ผลการทดลองจากตารางที่ ก.2 แสดงให้เห็นว่า เมื่อมีการใช้จำนวนโหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลง 11 แบบ (จำนวนโหนดที่เท่ากันในชั้นซ่อน) โดยถ้าคิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดไม่ลดลง โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 0.11092 เมื่อใช้จำนวนโหนดในชั้นซ่อน 7 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์คือ 0.11035 เมื่อใช้จำนวนโหนดในชั้นซ่อน 1 โหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ก.4 ผลการทดลองและสถิติของข้อมูล ausl006 โดยใช้ Feed forward NN.

Table with 3 main sections: Feed forward NN แบบใช้ค่าน้ำหนักเพียงค่าเดียว (FNN), Feed forward NN แบบใช้ค่าน้ำหนักแบบเซกเมนต์ (MSFNN), and a summary row with statistical labels like H, min, max, SD, A, B, C.

H - จำนวนโหนดในชั้นซ่อน min - ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง max - ค่าผิดพลาด (RMSE) มากที่สุดจากการทดลอง 5 ครั้ง 1, 2, 3, 4, 5 - ผลการทดลองครั้งที่ 1, 2, 3, 4, 5 โดยคิดจากที่โครงข่ายโหนดผิดพลาด (RMSE) mean - ค่าเฉลี่ยของค่าความผิดพลาด (RMSE) จากทดลอง 5 ครั้ง SD - ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง A - ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด) B - ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด) C - ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด) re - ค่ารวมแปรผันที่โครงข่ายโหนดผิดพลาดลดลง โดยหาได้จาก $(\text{mean}_{\text{MSFNN}} - \text{mean}_{\text{FNN}}) / \text{mean}_{\text{FNN}} \times 100$

ผลการทดลองจากตารางที่ ก.4 แสดงให้เห็นว่า เมื่อมีการใช้จำนวนโหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายฯ ให้ผลผิดพลาดลดลง 34 แบบ (จำนวนโหนดที่เท่ากันในชั้นซ่อน) โดยถ้าคิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายฯ ให้ผลผิดพลาดลดลงโดยเฉลี่ย 0.18% โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายฯ ที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 0.09262 เมื่อใช้จำนวนโหนดในชั้นซ่อน 1 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายฯ ที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์คือ 0.09089 เมื่อใช้จำนวนโหนดในชั้นซ่อน 3 โหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ค.6 ผลการทดลองและสถิติของข้อมูล aus1006 โดยใช้ Jordan Recurrent NN.

Table with 17 columns: H, 1-5 (JRNN), max, min, mean, SD, 1-5 (MSJRNN), max, min, mean, SD, re(%). Rows 1-500 show experimental results for various hidden layer sizes (H) and iterations (1-5).

H -จำนวนโหนดในชั้นซ่อน

min -ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง

1, 2, 3, 4, 5 -ผลการทดลองครั้งที่ 1, 2, 3, 4, 5 โดยคิดจากที่โครงข่ายให้ผลผิดพลาด (RMSE)

SD -ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง

A -ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)

B -ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)

C -ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด)

re -reduce เปอร์เซ็นต์ที่โครงข่ายให้ผลผิดพลาดลดลง โดยหาได้จาก (meanMSJRNN-meanJRNN)/meanJRNN*100

max -ค่าผิดพลาด (RMSE) มากที่สุดจากการทดลอง 5 ครั้ง

mean -ค่าเฉลี่ยของค่าความผิดพลาด (RMSE) จากการทดลอง 5 ครั้ง

SD -ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง

A -ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)

B -ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)

C -ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด)

ผลการทดลองจากตารางที่ ค.6 แสดงให้เห็นว่า เมื่อมีการใช้จำนวนโหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลง 37 แบบ (จำนวนโหนดที่เท่ากันในชั้นซ่อน) โดยถ้าคิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลงโดยเฉลี่ย 0.58% โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 0.09239 เมื่อใช้จำนวนโหนดในชั้นซ่อน 1 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์คือ 0.09054 เมื่อใช้จำนวนโหนดในชั้นซ่อน 3 โหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ค.8 ผลการทดลองและสถิติของข้อมูล az510 โดยใช้ Elman Recurrent NN.

Table with 15 columns and 50 rows. Columns include 'Elman Recurrent NN. แบบใช้ค่าน้ำหนักฟังก์ชันค่าเดียว (ERNN)' and 'Elman Recurrent NN. แบบใช้ค่าน้ำหนักแบบเชิงเส้น (MSERNN)'. Rows contain numerical data for various parameters like H, min, max, SD, and re-%.

H-จำนวนโหนดในชั้นซ่อน
min-ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง
max-ค่าผิดพลาด (RMSE) มากที่สุดจากการทดลอง 5 ครั้ง
mean-ค่าเฉลี่ยของค่าความผิดพลาด (RMSE) จากการทดลอง 5 ครั้ง
SD-ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง
A-ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
B-ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
C-ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด)
re-reduce เปอร์เซนต์ที่โครงข่ายให้ผลผิดพลาดลดลง โดยหาได้จาก (meanMSERNN-meanERNN)/meanERNN*100

ผลการทดลองจากตารางที่ ค.8 แสดงให้เห็นว่า เมื่อมีการใช้จำนวนโหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเชิงเส้นทำให้โครงข่ายให้ผลผิดพลาดลดลง 9 แบบ (จำนวนโหนดที่เท่ากันในชั้นซ่อน) โดยถ้าคิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนักแบบหลายเชิงเส้นทำให้โครงข่ายให้ผลผิดพลาดไม่ลดลง โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักเท่ากันค่าเดียว คือ 0.08598 เมื่อใช้จำนวนโหนดในชั้นซ่อน 2 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเชิงเส้นคือ 0.08581 เมื่อใช้จำนวนโหนดในชั้นซ่อน 2 โหนด

เอกสารนี้เป็นเอกสารที่แสวงหาสำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ค.10 ผลการทดลองและสถิติของข้อมูล beer โดยใช้ Feed forward NN.

Feed forward NN. แบบใช้ค่าน้ำหนักแบบค่าเต็ม (FNN)										Feed forward NN. แบบใช้ค่าน้ำหนักแบบเซกเมนต์ (MSFNN)									
H	1	2	3	4	5	max	min	mean	SD	1	2	3	4	5	max	min	mean	SD	re(%)
1	0.132790	0.127650	0.127770	0.127870	0.129430	0.13279	0.12765	0.1279	0.002	0.130750	0.130530	0.131920	0.132630	0.129970	0.13263	0.12997	0.1308	0.001	2.25
2	0.129010	0.132560	0.129030	0.129570	0.132340	0.13256	0.12901	0.1296	0.002	0.132340	0.128620	0.131380	0.131170	0.131790	0.13234	0.12862	0.1314	0.001	1.40
3	0.130530	0.132570	0.131940	0.132410	0.1286	0.13257	0.1286	0.1319	0.002	0.128550	0.128650	0.128460	0.128490	0.128570	0.12865	0.12846	0.1286	0.000	-2.57
4	0.132270	0.128310	0.128180	0.128720	0.131820	0.13227	0.12818	0.1287	0.002	0.128690	0.128470	0.128570	0.128470	0.128470	0.12869	0.12847	0.1285	0.000	-0.19
5	0.132340	0.130530	0.139750	0.130630	0.131820	0.13975	0.13053	0.1318	0.004	0.128730	0.128640	0.128490	0.128540	0.128690	0.12873	0.12849	0.1286	0.000	-2.41
6	0.127510	0.130870	0.127870	0.131960	0.127780	0.13196	0.12751	0.1279	0.002	0.128570	0.128680	0.128850	0.128640	0.128690	0.12885	0.12857	0.1287	0.000	0.63
7	0.129010	0.131950	0.130640	0.128020	0.127530	0.13195	0.12753	0.1290	0.002	0.131650	0.130740	0.128620	0.128940	0.128860	0.13165	0.12862	0.1289	0.001	-0.05
8	0.131820	0.129010	0.130870	0.127510	0.1323	0.1323	0.12751	0.1309	0.002	0.132370	0.129030	0.129010	0.132250	0.129410	0.13237	0.12901	0.1294	0.002	-1.12
9	0.131120	0.1277	0.128310	0.128260	0.127530	0.13112	0.12753	0.1283	0.001	0.129530	0.128570	0.128460	0.1292	0.1292	0.12953	0.12846	0.1292	0.000	0.73
10	0.127920	0.130070	0.131720	0.131820	0.131820	0.13182	0.12792	0.1317	0.002	0.128950	0.1286	0.129010	0.1286	0.128680	0.12901	0.1286	0.1287	0.000	-2.31
11	0.130070	0.127670	0.127780	0.128110	0.127920	0.13007	0.12767	0.1279	0.001	0.128770	0.128740	0.128740	0.128770	0.128940	0.12894	0.12874	0.1288	0.000	0.66
12	0.129010	0.1288	0.131720	0.127820	0.128020	0.13172	0.12782	0.1288	0.002	0.128670	0.128750	0.128560	0.128670	0.128440	0.12875	0.12844	0.1287	0.000	-0.10
13	0.127670	0.129260	0.131950	0.128570	0.129890	0.13195	0.12767	0.1293	0.002	0.1287	0.129030	0.128840	0.1287	0.128760	0.12903	0.1287	0.1288	0.000	-0.39
14	0.130380	0.1274	0.1311	0.127550	0.139750	0.13975	0.1274	0.1304	0.005	0.128940	0.129230	0.129580	0.128890	0.129580	0.12958	0.12889	0.1292	0.000	-0.88
15	0.130490	0.1277	0.127550	0.131260	0.131380	0.13138	0.12755	0.1305	0.002	0.129410	0.1293	0.129560	0.128850	0.129410	0.12956	0.12885	0.1294	0.000	-0.83
16	0.128020	0.127670	0.130530	0.129010	0.127650	0.13053	0.12765	0.1280	0.001	0.128850	0.128650	0.129450	0.129490	0.129490	0.12949	0.12865	0.1295	0.000	1.12
17	0.127730	0.1288	0.127980	0.127450	0.128760	0.12876	0.12745	0.1280	0.001	0.132070	0.129060	0.128780	0.132070	0.129390	0.13207	0.12878	0.1294	0.002	1.10
18	0.129430	0.128760	0.127730	0.129890	0.127870	0.12989	0.12773	0.1288	0.001	0.129620	0.129330	0.129150	0.129550	0.130470	0.13047	0.12915	0.1296	0.001	0.61
19	0.128720	0.130490	0.128280	0.130530	0.127770	0.13053	0.12777	0.1287	0.001	0.128850	0.129410	0.1295	0.1295	0.129410	0.1295	0.12885	0.1294	0.000	0.54
20	0.131210	0.132340	0.127730	0.127820	0.128770	0.13234	0.12773	0.1288	0.002	0.129390	0.129390	0.129430	0.129430	0.129430	0.12943	0.12939	0.1294	0.000	0.51
21	0.127630	0.130840	0.127770	0.128260	0.131950	0.13195	0.12763	0.1283	0.002	0.129240	0.129750	0.1404	0.129530	0.128710	0.1404	0.12871	0.1295	0.005	0.99
22	0.1288	0.131120	0.130790	0.130990	0.128110	0.13112	0.12811	0.1308	0.001	0.128770	0.129510	0.129290	0.129850	0.1299	0.1299	0.12929	0.1296	0.000	-0.90
23	0.130870	0.127920	0.131120	0.131210	0.128830	0.13121	0.12792	0.1309	0.002	0.1297	0.1297	0.129770	0.129210	0.129660	0.12977	0.12921	0.1297	0.000	-0.89
24	0.128280	0.130690	0.130630	0.127730	0.127780	0.13069	0.12773	0.1283	0.002	0.131980	0.130370	0.129290	0.129990	0.1294	0.13198	0.12929	0.1300	0.001	1.33
25	0.128540	0.130830	0.130530	0.130490	0.127480	0.13083	0.12748	0.1305	0.001	0.130180	0.129720	0.1295	0.129160	0.129350	0.13015	0.12916	0.1295	0.000	-0.76
26	0.127650	0.131720	0.128510	0.130870	0.127510	0.13172	0.12751	0.1285	0.002	0.129280	0.129620	0.129610	0.129870	0.129490	0.12987	0.12949	0.1296	0.000	0.86
27	0.130830	0.127980	0.128540	0.131720	0.130790	0.13172	0.12798	0.1308	0.002	0.130890	0.131620	0.129880	0.1301	0.130030	0.13162	0.12988	0.1301	0.001	-0.53
28	0.130630	0.127630	0.130070	0.129110	0.128720	0.13063	0.12763	0.1291	0.001	0.129580	0.129580	0.129610	0.129620	0.129580	0.12962	0.12958	0.1296	0.000	0.36
29	0.131210	0.131210	0.130520	0.127920	0.130380	0.13121	0.12792	0.1304	0.002	0.130240	0.129970	0.130430	0.130240	0.130730	0.13073	0.12997	0.1302	0.000	-0.11
30	0.128770	0.1288	0.130530	0.129260	0.130490	0.13053	0.12877	0.1293	0.001	0.129950	0.130460	0.130070	0.130460	0.130190	0.13046	0.12995	0.1302	0.000	0.72
31	0.128050	0.127770	0.132340	0.128280	0.130440	0.13234	0.12777	0.1281	0.002	0.1302	0.129680	0.130920	0.129340	0.130510	0.13092	0.12934	0.1302	0.001	1.68
32	0.1302	0.128210	0.128180	0.130280	0.130440	0.13044	0.12818	0.1302	0.001	0.130210	0.130030	0.129680	0.130730	0.1301	0.13073	0.12968	0.1301	0.000	-0.08
33	0.128770	0.130640	0.128020	0.128950	0.130410	0.13064	0.12802	0.1290	0.001	0.129270	0.130820	0.130120	0.1306	0.130120	0.13082	0.12927	0.1301	0.001	0.91
34	0.130640	0.127550	0.127490	0.128260	0.129010	0.13064	0.12749	0.1283	0.001	0.130330	0.130240	0.130560	0.130050	0.130330	0.13056	0.13005	0.1303	0.000	1.61
35	0.130070	0.129890	0.127530	0.130530	0.128280	0.13053	0.12753	0.1299	0.001	0.130680	0.130440	0.130680	0.130440	0.130440	0.13068	0.13044	0.1304	0.000	0.42
36	0.127670	0.128180	0.1302	0.128540	0.128260	0.1302	0.12767	0.1283	0.001	0.129210	0.130340	0.130150	0.130150	0.130340	0.13034	0.12921	0.1302	0.000	1.47
37	0.1302	0.128570	0.128110	0.128690	0.128180	0.1302	0.12811	0.1286	0.001	0.130610	0.130230	0.130230	0.130430	0.130380	0.13061	0.13023	0.1304	0.000	1.41
38	0.131260	0.128210	0.128310	0.130490	0.128840	0.13126	0.12821	0.1288	0.001	0.1314	0.130440	0.1304	0.131370	0.131	0.1314	0.1304	0.1310	0.000	1.68
39	0.130320	0.130640	0.128720	0.1311	0.128830	0.1311	0.12872	0.1303	0.001	0.129470	0.1308	0.130610	0.130350	0.130750	0.1308	0.12947	0.1306	0.001	0.22
40	0.130420	0.1288	0.130640	0.129850	0.127870	0.13064	0.12787	0.1299	0.001	0.130930	0.1309	0.131520	0.130720	0.131890	0.13189	0.13072	0.1309	0.000	0.83
41	0.127980	0.139750	0.128830	0.130630	0.128310	0.13975	0.12798	0.1288	0.005	0.131170	0.131660	0.130790	0.131060	0.130790	0.13166	0.13079	0.1311	0.000	1.73
42	0.128510	0.128540	0.131950	0.131260	0.1277	0.13195	0.1277	0.1285	0.002	0.131590	0.131370	0.131020	0.131020	0.131540	0.13159	0.13102	0.1314	0.000	2.20
43	0.1286	0.129750	0.129110	0.129110	0.129790	0.12979	0.1286	0.1291	0.001	0.1316	0.1313	0.131340	0.131340	0.130990	0.1316	0.13099	0.1313	0.000	1.73
44	0.128930	0.128760	0.130020	0.128850	0.128260	0.13002	0.12826	0.1289	0.001	0.129180	0.131360	0.131460	0.131160	0.130730	0.13146	0.12918	0.1312	0.001	1.79
45	0.128830	0.128020	0.131120	0.129990	0.128920	0.13112	0.12802	0.1289	0.001	0.131210	0.131210	0.131890	0.129260	0.1315	0.13189	0.12926	0.1312	0.001	1.78
46	0.129890	0.130530	0.130990	0.128950	0.130410	0.13099	0.12895	0.1304	0.001	0.129310	0.1313	0.131330	0.131460	0.130780	0.13146	0.12931	0.1313	0.001	0.68
47	0.1297	0.129110	0.129050	0.130160	0.128950	0.13016	0.12895	0.1291	0.001	0.131340	0.131530	0.131710	0.131530	0.131150	0.13171	0.13115	0.1315	0.000	1.87
48	0.129010	0.129260	0.131260	0.128770	0.131260	0.13126	0.12877	0.1290	0.001	0.131490	0.1316	0.131330	0.131470	0.1316	0.1316	0.13133	0.1315	0.000	1.92
49	0.129010	0.129810	0.128540	0.129440	0.127650	0.12981	0.12765	0.1290	0.001	0.1316	0.131620	0.132030	0.132030	0.132070	0.13207	0.1316	0.1320	0.000	2.34
50	0.130870	0.128210	0.130990	0.1286	0.127530	0.13099	0.12753	0.1286	0.002	0.131740	0.131650	0.131760	0.131650	0.131720	0.13176	0.13165	0.1317	0.000	2.43
A=0.140 B=0.12740 C=0.129 C=0.001																			

H -จำนวนโหนดในชั้นซ่อน max -ค่าผิดพลาด (RMSE

ตารางที่ ค.11 ผลการทดลองและสถิติของข้อมูล beer โดยใช้ Elman Recurrent NN.

Elman Recurrent NN. แบบไร้ค่าน้ำหนักเชื่อมค่าสุมา (ERNN)										Elman Recurrent NN. แบบไร้ค่าน้ำหนักแบบเซกเมนต์ (MSERNN)										re(%)
H	1	2	3	4	5	max	min	mean	SD	1	2	3	4	5	max	min	mean	SD		
1	0.131360	0.131350	0.131360	0.131360	0.1288	0.13136	0.1288	0.1314	0.001	0.12763	0.127610	0.127610	0.128580	0.127870	0.127720	0.12858	0.12761	0.1277	0.000	-2.77
2	0.127880	0.12811	0.1279	0.127880	0.127450	0.12811	0.12745	0.1279	0.000	0.12904	0.128460	0.127470	0.12919	0.128	0.12919	0.12747	0.1285	0.001	0.45	
3	0.127450	0.1307	0.127690	0.130820	0.131050	0.13105	0.12745	0.1307	0.002	0.12772	0.127290	0.126940	0.127720	0.128160	0.12816	0.12694	0.1277	0.000	-2.28	
4	0.127030	0.12711	0.126710	0.127030	0.127120	0.12712	0.12671	0.1270	0.000	0.12707	0.127070	0.137670	0.141360	0.130710	0.14136	0.12707	0.1307	0.006	2.90	
5	0.130750	0.12727	0.126990	0.130780	0.126940	0.13078	0.12694	0.1273	0.002	0.12738	0.127080	0.126850	0.127090	0.127090	0.12738	0.12685	0.1271	0.000	-0.14	
6	0.126760	0.12696	0.1267	0.1267	0.1267	0.12696	0.1267	0.1267	0.000	0.12717	0.128480	0.127160	0.129040	0.127160	0.12904	0.12716	0.1272	0.001	0.37	
7	0.127190	0.126110	0.12711	0.1311	0.12611	0.1311	0.12611	0.1271	0.002	0.12641	0.126270	0.127430	0.126270	0.128250	0.12825	0.12627	0.1264	0.001	-0.55	
8	0.1262	0.1255	0.1262	0.1255	0.1255	0.1262	0.1255	0.1255	0.000	0.13018	0.127590	0.128650	0.1307	0.1267	0.1307	0.1267	0.1287	0.002	2.51	
9	0.125540	0.126510	0.130180	0.127180	0.122880	0.13018	0.12288	0.1265	0.003	0.12719	0.125940	0.127140	0.124420	0.127880	0.12788	0.12442	0.1271	0.001	0.50	
10	0.125910	0.125910	0.12571	0.1258	0.125770	0.12591	0.12571	0.1258	0.000	0.1294	0.126880	0.126510	0.127780	0.126070	0.1294	0.12607	0.1269	0.001	0.86	
110	0.126140	0.125310	0.126430	0.125570	0.126350	0.12643	0.12531	0.1261	0.000	0.13037	0.127820	0.127540	0.12822	0.1295	0.13037	0.12754	0.1282	0.001	1.65	
12	0.1252	0.1252	0.125680	0.12568	0.1252	0.12568	0.1252	0.1252	0.000	0.12631	0.126310	0.126830	0.125210	0.126310	0.12683	0.12521	0.1263	0.001	0.89	
130	0.126390	0.125690	0.126390	0.127370	0.123480	0.12737	0.12348	0.1264	0.001	0.12804	0.1274	0.126450	0.126450	0.122740	0.12804	0.12274	0.1274	0.001	0.05	
140	0.123320	0.12332	0.1251	0.12332	0.1251	0.1251	0.12332	0.1233	0.001	0.12695	0.126190	0.126950	0.126950	0.1269	0.12695	0.12619	0.1270	0.000	2.94	
150	0.125750	0.125420	0.122730	0.125190	0.125750	0.12575	0.12273	0.1254	0.001	0.128760	0.126620	0.126160	0.127160	0.128020	0.12876	0.12616	0.1272	0.001	1.39	
160	0.125150	0.12279	0.1242	0.122790	0.125150	0.12515	0.12279	0.1242	0.001	0.1246	0.126090	0.1249	0.1246	0.124480	0.12609	0.12448	0.1246	0.001	0.32	
17	0.124	0.125380	0.125440	0.125440	0.125440	0.12544	0.124	0.1254	0.001	0.12341	0.123770	0.123770	0.122790	0.123770	0.12377	0.12279	0.1237	0.000	-1.33	
180	0.125150	0.125090	0.124390	0.125090	0.125150	0.12515	0.12439	0.1251	0.000	0.121320	0.126630	0.127330	0.124	0.127330	0.12733	0.12132	0.1266	0.003	1.23	
190	0.125370	0.123980	0.125850	0.125750	0.125390	0.12585	0.12398	0.1254	0.001	0.12475	0.120640	0.124090	0.115450	0.127650	0.12765	0.11545	0.1241	0.005	-1.04	
200	0.123650	0.123650	0.125230	0.123990	0.125260	0.12526	0.12365	0.1240	0.001	0.12341	0.121530	0.123180	0.123180	0.123410	0.12341	0.12153	0.1232	0.001	-0.65	
21	0.1249	0.125340	0.125480	0.124470	0.125560	0.12556	0.12447	0.1253	0.000	0.13194	0.123130	0.126880	0.123130	0.128470	0.13194	0.12313	0.1269	0.004	1.23	
220	0.124240	0.124610	0.124610	0.124860	0.124610	0.12486	0.12424	0.1246	0.000	0.125290	0.121820	0.124590	0.121780	0.123850	0.12529	0.12178	0.1239	0.002	-0.61	
230	0.126350	0.125810	0.124410	0.124410	0.125410	0.12635	0.12441	0.1254	0.001	0.120930	0.123220	0.121760	0.124970	0.124010	0.12497	0.12093	0.1232	0.002	-1.75	
240	0.12384	0.1241	0.1241	0.123840	0.125010	0.12501	0.12384	0.1241	0.000	0.121880	0.122320	0.121220	0.122710	0.121220	0.12271	0.12122	0.1219	0.001	-1.79	
250	0.126650	0.127020	0.12618	0.125	0.126180	0.12702	0.125	0.1262	0.001	0.126070	0.128030	0.124840	0.123950	0.123	0.12803	0.123	0.1248	0.002	-1.06	
260	0.124030	0.124030	0.124030	0.123260	0.123260	0.12403	0.12326	0.1240	0.000	0.1253	0.125150	0.12320	0.123330	0.118060	0.1253	0.11806	0.1233	0.003	-0.56	
270	0.125250	0.125510	0.125970	0.123740	0.124960	0.12597	0.12374	0.1253	0.001	0.126270	0.126140	0.123090	0.127380	0.126270	0.12738	0.12309	0.1263	0.002	0.81	
280	0.125640	0.125040	0.125670	0.123420	0.123420	0.12567	0.12342	0.1250	0.001	0.125520	0.128490	0.122180	0.123710	0.122070	0.12849	0.12207	0.1237	0.003	-1.06	
290	0.124440	0.125050	0.126070	0.125780	0.124550	0.12607	0.12444	0.1251	0.001	0.133390	0.124960	0.124960	0.1188	0.124860	0.13339	0.1188	0.1250	0.005	-0.07	
300	0.12478	0.1247	0.123260	0.1256	0.124780	0.1256	0.12326	0.1248	0.001	0.124360	0.124220	0.123870	0.1188	0.123870	0.12436	0.1188	0.1239	0.002	-0.73	
310	0.127390	0.124160	0.127940	0.126010	0.123440	0.12794	0.12344	0.12344	0.002	0.125220	0.123920	0.122660	0.125420	0.123920	0.12542	0.12266	0.1239	0.001	-1.66	
320	0.126650	0.123950	0.123830	0.127060	0.125930	0.12706	0.12383	0.1259	0.002	0.12325	0.125	0.126970	0.124940	0.122780	0.12697	0.12278	0.1249	0.002	-0.79	
330	0.128240	0.124280	0.127490	0.124960	0.124980	0.12749	0.12428	0.1250	0.002	0.125020	0.123620	0.125390	0.122860	0.125110	0.12539	0.12286	0.1250	0.001	0.03	
340	0.126840	0.123050	0.122340	0.127890	0.127890	0.12789	0.12234	0.1268	0.003	0.1236	0.124690	0.121970	0.124440	0.123550	0.12469	0.12197	0.1236	0.001	-2.55	
350	0.125430	0.123110	0.1238	0.123980	0.123110	0.12543	0.12311	0.1238	0.001	0.119760	0.120180	0.119950	0.120180	0.120180	0.12018	0.11976	0.1202	0.000	-2.92	
360	0.123180	0.126890	0.126440	0.125530	0.128320	0.12644	0.12318	0.1264	0.002	0.122280	0.1159	0.121330	0.122280	0.121330	0.12228	0.1159	0.1213	0.003	-4.04	
37	0.124	0.124160	0.122880	0.118190	0.122880	0.12416	0.11819	0.1229	0.002	0.123930	0.1229	0.123160	0.1202	0.122360	0.12393	0.1202	0.1229	0.001	0.02	
380	0.125860	0.127470	0.125860	0.126950	0.1238	0.12747	0.1238	0.1259	0.001	0.122480	0.120630	0.117040	0.116170	0.1252	0.1252	0.11617	0.1206	0.004	-4.16	
390	0.125190	0.126180	0.125050	0.124390	0.123320	0.12618	0.12332	0.1251	0.001	0.122230	0.117110	0.122430	0.122430	0.121160	0.12243	0.12116	0.1222	0.002	-2.26	
400	0.124980	0.124230	0.126650	0.126350	0.126650	0.12665	0.12423	0.1264	0.001	0.124820	0.124620	0.123320	0.123320	0.123310	0.12482	0.12331	0.1233	0.001	-2.40	
410	0.121550	0.123180	0.118390	0.122790	0.123420	0.12342	0.11839	0.1228	0.002	0.122160	0.128190	0.125970	0.125970	0.128190	0.12597	0.12216	0.1260	0.002	2.59	
42	0.1246	0.126330	0.1247	0.126230	0.126330	0.12633	0.1246	0.1246	0.001	0.114160	0.1213	0.1246	0.1245	0.120740	0.1246	0.11416	0.1213	0.004	-3.91	
430	0.123650	0.122790	0.126180	0.123760	0.123260	0.12618	0.12279	0.1237	0.001	0.124220	0.115770	0.118610	0.094720	0.124030	0.12422	0.09472	0.1186	0.012	-4.08	
440	0.126770	0.126770	0.123420	0.12543	0.125	0.12677	0.12342	0.1254	0.001	0.115730	0.115730	0.118720	0.122570	0.115730	0.12257	0.11573	0.1157	0.005	-2.70	
450	0.124030	0.124280	0.126840	0.123650	0.123950	0.12684	0.12365	0.1240	0.001	0.12020	0.122940	0.117360	0.120650	0.1158	0.12294	0.1158	0.1202	0.003	-3.09	
460	0.125530	0.126870	0.124240	0.124960	0.124780	0.12687	0.12424	0.1250	0.001	0.126530	0.124390	0.11518	0.124	0.128170	0.12653	0.11518	0.1244	0.005	-0.46	
47	0.1225	0.124570	0.126010	0.125480	0.124780	0.12601	0.1225	0.1248	0.001	0.115670	0.124140	0.123070	0.121410	0.111680	0.12414	0.11168	0.1214	0.005	-2.70	
480	0.125950	0.125040	0.125050	0.120500	0.122730	0.12595	0.12050	0.12503	0.002	0.12024	0.1224	0.125830	0.123330	0.116270	0.12583	0.11627	0.1224	0.004	-2.11	
490	0.127890	0.125250	0.125530	0.123420	0.122730	0.12789	0.12273	0.1253	0.002	0.121610	0.122450	0.115710	0.118930	0.115660	0.12245	0.11566	0.1189	0.003	-5.05	
50	0.1256	0.12538	0.1249	0.1247	0.119910	0.1256	0.11991	0.1249	0.002	0.121360	0.122540	0.122090	0.124540	0.122640	0.12454	0.12136	0.1225	0.001	-1.89	

H -จำนวนโหนดในชั้นซ่อน
 max -ค่าผิดพลาด (RMSE) มากที่สุดจากการทดลอง 5 ครั้ง
 min -ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง
 mean -ค่าเฉลี่ยของค่าความผิดพลาด (RMSE) จากการทดลอง 5 ครั้ง
 SD -ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง
 A -ค่าความผิดพลาดมากที่สุดจากการทดลอง 5

ตารางที่ ค.12 ผลการทดลองและสถิติของข้อมูล beer โดยใช้ Jordan Recurrent NN.

Jordan Recurrent NN, แบบใช้ค่าน้ำหนักเพียงค่าเดียว (JRNN)										Jordan Recurrent NN, แบบใช้ค่าน้ำหนักแบบแยกแยะ (MSJRNN)										rel(%)
H	1	2	3	4	5	max	min	mean	SD	1	2	3	4	5	max	min	mean	SD		
1	0.130510	0.131630	0.132750	0.127550	0.128480	0.132750	0.127550	0.130500	0.0020	0.128640	0.129620	0.128820	0.128720	0.128640	0.129620	0.128640	0.128700	0.0020	-1.37	
2	0.132310	0.128680	0.128950	0.131630	0.129060	0.132310	0.128680	0.129100	0.0020	0.126970	0.128820	0.128360	0.128700	0.128820	0.128820	0.126970	0.128700	0.0010	-0.28	
3	0.128710	0.130950	0.128570	0.129150	0.128680	0.130950	0.128570	0.128700	0.0010	0.128700	0.128740	0.126330	0.128700	0.129040	0.129040	0.126330	0.128700	0.0010	-0.01	
4	0.130750	0.128070	0.128270	0.132030	0.127860	0.132030	0.127860	0.128300	0.0020	0.128550	0.128630	0.128420	0.128420	0.128530	0.128630	0.128420	0.128500	0.0020	0.20	
5	0.128640	0.132030	0.130950	0.130590	0.132090	0.132090	0.128640	0.131000	0.0010	0.128470	0.128490	0.128460	0.127850	0.128710	0.128710	0.127850	0.128500	0.0000	-1.89	
6	0.127960	0.132030	0.128050	0.130730	0.128890	0.132030	0.127960	0.128900	0.0020	0.128670	0.128340	0.125310	0.128600	0.128670	0.128670	0.125310	0.128600	0.0010	-0.22	
7	0.128670	0.128190	0.127550	0.127520	0.130750	0.130750	0.128670	0.127520	0.0010	0.128540	0.128960	0.128940	0.128830	0.128320	0.128960	0.128320	0.128800	0.0010	0.50	
8	0.127520	0.128420	0.131990	0.130750	0.128840	0.131990	0.127520	0.128800	0.0020	0.128440	0.128300	0.128460	0.128300	0.128460	0.128460	0.128300	0.128400	0.0000	-0.31	
9	0.127890	0.128080	0.131700	0.127960	0.128190	0.131700	0.127890	0.128100	0.0020	0.129120	0.128940	0.129140	0.128920	0.129020	0.129140	0.128920	0.129000	0.0000	0.73	
10	0.128420	0.130150	0.127550	0.127980	0.132750	0.132750	0.128420	0.127550	0.0020	0.128940	0.128940	0.128760	0.129000	0.129000	0.128760	0.129000	0.128760	0.0000	0.40	
11	0.127550	0.127560	0.127620	0.127520	0.127670	0.127670	0.127550	0.127600	0.0000	0.128890	0.128950	0.128490	0.128750	0.128800	0.128950	0.128800	0.128800	0.0000	0.97	
12	0.131630	0.128420	0.130090	0.127660	0.127960	0.131630	0.128420	0.127660	0.0020	0.128950	0.128700	0.129310	0.129310	0.128540	0.129310	0.128540	0.129000	0.0000	0.41	
13	0.130950	0.127520	0.131240	0.131650	0.127990	0.131650	0.127520	0.131000	0.0020	0.128550	0.128710	0.128710	0.129030	0.128470	0.129030	0.128470	0.128700	0.0000	-1.71	
14	0.128670	0.127660	0.131310	0.128270	0.131550	0.131550	0.128670	0.128700	0.0020	0.129010	0.128960	0.129330	0.129010	0.129190	0.129330	0.128960	0.129000	0.0000	0.26	
15	0.127850	0.131360	0.130090	0.127760	0.132750	0.132750	0.127850	0.130100	0.0020	0.128760	0.128870	0.128870	0.128760	0.129180	0.129180	0.128760	0.128900	0.0000	-0.94	
16	0.130750	0.132030	0.129770	0.127520	0.128440	0.132030	0.129770	0.129800	0.0020	0.129010	0.129290	0.128900	0.129410	0.129220	0.129410	0.128900	0.129200	0.0000	-0.42	
17	0.128080	0.128680	0.127550	0.128190	0.127620	0.128680	0.128080	0.127550	0.0000	0.129470	0.127890	0.129380	0.129760	0.129760	0.129380	0.129760	0.129500	0.0010	1.09	
18	0.127890	0.128190	0.128190	0.127880	0.131070	0.131070	0.127890	0.128200	0.0010	0.129660	0.129520	0.129160	0.129520	0.129500	0.129660	0.129160	0.129500	0.0000	1.04	
19	0.127520	0.130590	0.130450	0.127550	0.128470	0.130590	0.127520	0.128500	0.0020	0.129320	0.128880	0.128780	0.129350	0.129350	0.128880	0.129350	0.128780	0.0000	0.66	
20	0.130750	0.127960	0.139210	0.128150	0.127500	0.139210	0.130750	0.127500	0.0005	0.129380	0.129390	0.128890	0.129390	0.129440	0.129440	0.128890	0.129400	0.0000	0.97	
21	0.130390	0.127550	0.128110	0.130750	0.128050	0.130750	0.127550	0.128100	0.0010	0.129460	0.129450	0.129450	0.129320	0.129500	0.129500	0.129320	0.129500	0.0000	1.05	
22	0.128420	0.127880	0.130750	0.130750	0.127620	0.130750	0.128420	0.127620	0.0020	0.129520	0.129600	0.129540	0.129600	0.129650	0.129650	0.129520	0.129600	0.0000	0.92	
23	0.128680	0.130730	0.127550	0.127880	0.130950	0.130950	0.128680	0.127550	0.0020	0.129730	0.129550	0.129020	0.129630	0.129390	0.129730	0.129550	0.129390	0.0000	0.68	
24	0.127860	0.131070	0.127860	0.128270	0.130790	0.131070	0.127860	0.128300	0.0020	0.129370	0.128980	0.129340	0.129620	0.129480	0.129620	0.128980	0.129400	0.0000	0.86	
25	0.128570	0.127880	0.132030	0.127760	0.128190	0.132030	0.128570	0.128200	0.0020	0.129520	0.128810	0.129500	0.129510	0.129520	0.129520	0.128810	0.129500	0.0000	1.03	
26	0.127960	0.138570	0.128480	0.128420	0.130660	0.138570	0.127960	0.128500	0.0040	0.129530	0.129860	0.129540	0.129860	0.129530	0.129860	0.129530	0.129860	0.0000	0.83	
27	0.130510	0.130190	0.128680	0.132750	0.128070	0.132750	0.130510	0.130200	0.0020	0.130340	0.129660	0.129580	0.129580	0.130040	0.130340	0.129580	0.129700	0.0000	-0.41	
28	0.130590	0.128070	0.128420	0.128050	0.130790	0.130790	0.130590	0.128050	0.0010	0.129830	0.129650	0.129830	0.129650	0.129790	0.129830	0.129650	0.129800	0.0000	1.07	
29	0.128420	0.130450	0.128440	0.128110	0.130750	0.130750	0.128420	0.128400	0.0010	0.130150	0.129890	0.129870	0.130190	0.129920	0.130190	0.129890	0.130100	0.0000	1.19	
30	0.128050	0.130450	0.128650	0.128640	0.128420	0.130450	0.128050	0.128600	0.0010	0.130140	0.130140	0.130050	0.130020	0.129810	0.130050	0.129810	0.130100	0.0000	1.17	
31	0.128070	0.128190	0.128470	0.127570	0.130190	0.130190	0.128070	0.127570	0.0010	0.130040	0.130050	0.130040	0.130240	0.130550	0.130050	0.130040	0.130100	0.0000	1.45	
32	0.127520	0.127880	0.128290	0.130950	0.130150	0.130950	0.127520	0.128100	0.0010	0.131260	0.132040	0.130400	0.130100	0.131630	0.132040	0.130400	0.130100	0.0010	2.51	
33	0.130380	0.127850	0.130390	0.128190	0.128070	0.130390	0.130380	0.127850	0.0010	0.130020	0.130020	0.129870	0.130120	0.130120	0.130020	0.129870	0.130100	0.0000	1.43	
34	0.128950	0.130410	0.130510	0.128890	0.128640	0.130510	0.128950	0.128640	0.0001	0.130350	0.130460	0.129990	0.130140	0.130460	0.130460	0.129990	0.130400	0.0000	1.09	
35	0.130390	0.129990	0.130380	0.128810	0.128570	0.130390	0.130390	0.128570	0.0001	0.130100	0.130310	0.130100	0.130430	0.130100	0.130430	0.130100	0.130100	0.0000	0.08	
36	0.128950	0.130750	0.128890	0.128650	0.127980	0.130750	0.128950	0.128890	0.0010	0.130540	0.130540	0.130180	0.130400	0.130400	0.130540	0.130180	0.130400	0.0000	1.16	
37	0.130290	0.130150	0.129990	0.128440	0.130260	0.130290	0.130290	0.130260	0.0001	0.130390	0.130440	0.130610	0.130610	0.130260	0.130610	0.130260	0.130400	0.0000	0.22	
38	0.129990	0.130750	0.128670	0.129800	0.130090	0.130750	0.129990	0.130090	0.0010	0.130180	0.130050	0.130610	0.130050	0.129210	0.130610	0.129210	0.130050	0.0010	0.39	
39	0.130370	0.128670	0.128700	0.129910	0.129910	0.130370	0.130370	0.128670	0.0010	0.130080	0.130750	0.130750	0.130620	0.130080	0.130080	0.130620	0.130080	0.0000	0.65	
40	0.128850	0.128050	0.129950	0.128850	0.128470	0.129950	0.128850	0.128050	0.0010	0.130850	0.128300	0.130550	0.130670	0.130090	0.130090	0.128300	0.130070	0.0010	1.41	
41	0.128950	0.128680	0.128650	0.130090	0.128480	0.130090	0.128950	0.128480	0.0010	0.130930	0.129640	0.130370	0.130930	0.129230	0.130930	0.129230	0.130400	0.0010	1.31	
42	0.128680	0.129900	0.129900	0.127550	0.129770	0.129900	0.128680	0.129770	0.0010	0.131620	0.129250	0.130600	0.130950	0.131820	0.131820	0.129250	0.131000	0.0010	0.91	
43	0.130380	0.128290	0.128840	0.132030	0.129770	0.132030	0.130380	0.129770	0.0010	0.130860	0.131070	0.130860	0.131070	0.130680	0.131070	0.130680	0.130780	0.0000	0.84	
44	0.130060	0.128110	0.129800	0.127550	0.130190	0.130190	0.130060	0.129800	0.0010	0.130880	0.130880	0.131150	0.130780	0.130890	0.131150	0.130780	0.130890	0.0000	0.83	
45	0.128940	0.128680	0.128050	0.127960	0.130210	0.130210	0.128940	0.127960	0.0010	0.130830	0.131080	0.131180	0.128820	0.130830	0.131180	0.128820	0.130080	0.0010	1.67	
46	0.130390	0.128650	0.127520	0.129660	0.129710	0.130390	0.130390	0.127520	0.0010	0.131570	0.131360	0.131640	0.131260	0.131260	0.131640	0.131260	0.131400	0.0000	1.31	
47	0.127520	0.129220	0.127620	0.128440	0.127960	0.129220	0.127520	0.128440	0.0010	0.131430	0.131410	0.131650	0.131430	0.131430	0.131650	0.131430	0.131400	0.0000	2.71	
48	0.127890	0.132030	0.129770	0.130340	0.138370	0.138370	0.127890	0.130340	0.0040	0.131000	0.129300	0.131310	0.131000	0.131310	0.131310	0.129300	0.131000	0.0010		

ตารางที่ ค.13 ผลการทดลองและสถิติของข้อมูล co522 โดยใช้ Feed forward NN.

Table with 30 rows and 15 columns. Columns include Feed forward NN. แบบใช้จำนวนฟังก์ชันค่าเดียว (FNN) and Feed forward NN. แบบใช้จำนวนฟังก์ชันเชิงเส้น (MSFNN). Headers include H, 1, 2, 3, 4, 5, max, min, mean, SD, and re(%). The table contains numerical data for various parameters across 30 trials.

H -จำนวนโหนดในชั้นซ่อน max-ค่าผิดพลาด (RMSE) มากที่สุดจากการทดลอง 5 ครั้ง
min -ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง mean -ค่าเฉลี่ยของค่าผิดพลาด (RMSE) จากการทดลอง 5 ครั้ง
1, 2, 3, 4, 5 -ผลการทดลองครั้งที่ 1, 2, 3, 4, 5 โดยติดจากโปรแกรมให้ผลผิดพลาด (RMSE)
SD -ค่าเบี่ยงเบนมาตรฐานของค่าผิดพลาดจากการทดลอง 5 ครั้ง A -ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
B -ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด) C -ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด)
re -reduce เปอร์เซ็นต์ที่โครงข่ายให้ผลผิดพลาดลดลง โดยหาได้จาก (mean_{MSFNN} - mean_{FNN}) / mean_{FNN} * 100

ผลการทดลองจากตารางที่ ค.13 แสดงให้เห็นว่า เมื่อมีการใช้จำนวนโหนดที่เท่ากัน ในชั้นซ่อน การใช้จำนวนฟังก์ชันเชิงเส้นทำให้โครงข่ายให้ผลผิดพลาดลดลง 40 แบบ (จำนวนโหนดที่เท่ากัน ในชั้นซ่อน) โดยถ้าคิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้จำนวนฟังก์ชันเชิงเส้นทำให้โครงข่ายให้ผลผิดพลาดลดลงโดยเฉลี่ย 1.41% โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้จำนวนฟังก์ชันเชิงเส้นค่าเดียว คือ 0.07602 เมื่อใช้จำนวนโหนดในชั้นซ่อน 4 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้จำนวนฟังก์ชันเชิงเส้นค่าเดียวคือ 0.07560 เมื่อใช้จำนวนโหนดในชั้นซ่อน 24 โหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ค.14 ผลการทดลองและสถิติของข้อมูล co522 โดยใช้ Elman Recurrent NN.

Table with 4 main columns: ERNN (max, min, mean, SD) and MSERNN (1, 2, 3, 4, 5, max, min, mean, SD) and a final re(%) column. It contains 50 rows of numerical data representing model performance metrics.

H -จำนวนโหนดในชั้นซ่อน
min -ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง
max -ค่าผิดพลาด (RMSE) มากที่สุดจากการทดลอง 5 ครั้ง
mean -ค่าเฉลี่ยของค่าความผิดพลาด (RMSE) จากการทดลอง 5 ครั้ง
SD -ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง
A -ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
B -ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
C -ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด)
re -reduce เปอร์เซ็นต์ที่โครงข่ายให้ผลผิดพลาดลดลง โดยหาได้จาก (mean_MSERNN - mean_ERNN) / mean_ERNN * 100

ผลการทดลองจากตารางที่ ค.14 แสดงให้เห็นว่า เมื่อมีการใช้จำนวนโหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลง 7 แบบ (จำนวนโหนดที่เท่ากันในชั้นซ่อน) โดยถ้าคิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดไม่ลดลง โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 0.07338 เมื่อใช้จำนวนโหนดในชั้นซ่อน 2 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์คือ 0.07326 เมื่อใช้จำนวนโหนดในชั้นซ่อน 3 โหนด

เอกสารนี้เป็นเอกสารที่สวามิภักดิ์สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ค.15 ผลการทดลองและสถิติของข้อมูล co522 โดยใช้ Jordan Recurrent NN.

Jordan Recurrent NN, แบบใช้ค่าน้ำหนักแบบค่าเดียว (JRNN)										Jordan Recurrent NN, แบบใช้ค่าน้ำหนักแบบเซกเมนต์ (MSJRNN)										
H	1	2	3	4	max	min	mean	SD		1	2	3	4	5	max	min	mean	SD	re(%)	
1	0.07618	0.08108	0.07899	0.08052	0.07638	0.08108	0.07618	0.0790	0.002	0.07598	0.07617	0.07604	0.07604	0.07577	0.07617	0.07577	0.0760	0.000	-3.73	
2	0.07604	0.07811	0.08097	0.07946	0.07625	0.08097	0.07604	0.0781	0.002	0.07644	0.07547	0.07606	0.0764	0.07563	0.07644	0.07547	0.0761	0.000	-2.62	
3	0.08096	0.076	0.07898	0.0782	0.0782	0.08096	0.076	0.0782	0.002	0.0751	0.07633	0.07586	0.07646	0.07695	0.07695	0.0751	0.0763	0.001	-2.39	
4	0.08096	0.0767	0.07704	0.07615	0.07823	0.08096	0.07615	0.0770	0.002	0.07648	0.0781	0.07591	0.07661	0.07656	0.0781	0.07591	0.0766	0.001	-0.62	
5	0.07936	0.07618	0.07893	0.07921	0.07738	0.07936	0.07618	0.0789	0.001	0.07832	0.07837	0.07458	0.07768	0.07604	0.07837	0.07458	0.0777	0.002	-1.58	
6	0.08153	0.07936	0.07606	0.0771	0.07622	0.08153	0.07606	0.0771	0.002	0.07839	0.07685	0.07617	0.07621	0.07839	0.07839	0.07617	0.0769	0.001	-0.32	
7	0.07865	0.07631	0.07615	0.07615	0.07853	0.07865	0.07615	0.0763	0.001	0.07626	0.07613	0.07606	0.07627	0.07634	0.07634	0.07606	0.0763	0.000	-0.07	
8	0.0785	0.07605	0.0771	0.07605	0.07621	0.0785	0.07605	0.0762	0.001	0.0763	0.07799	0.07641	0.07618	0.07715	0.07799	0.07618	0.0764	0.001	0.26	
9	0.07636	0.07701	0.07762	0.07707	0.07691	0.07762	0.07636	0.0770	0.000	0.07614	0.07606	0.07625	0.07613	0.0759	0.07625	0.0759	0.0761	0.000	-1.14	
10	0.07625	0.07613	0.07632	0.07606	0.07635	0.07625	0.07606	0.0763	0.000	0.07634	0.07608	0.07581	0.07639	0.07618	0.07639	0.07581	0.0762	0.000	-0.09	
11	0.07924	0.07606	0.07628	0.07921	0.07641	0.07924	0.07606	0.0764	0.002	0.07633	0.07622	0.0763	0.07622	0.07589	0.07633	0.07589	0.0762	0.000	-0.25	
12	0.07643	0.07643	0.07823	0.07638	0.07891	0.07891	0.07638	0.0764	0.001	0.07492	0.07627	0.07688	0.07597	0.07678	0.07688	0.07492	0.0763	0.001	-0.21	
13	0.07625	0.07899	0.0771	0.07786	0.07738	0.07899	0.07625	0.0774	0.001	0.07621	0.0764	0.0765	0.0772	0.0774	0.0774	0.07621	0.0765	0.001	-1.14	
14	0.07885	0.07643	0.07938	0.07615	0.07701	0.07938	0.07615	0.0770	0.001	0.07591	0.07635	0.07635	0.07634	0.07593	0.07635	0.07591	0.0763	0.000	-0.87	
15	0.08114	0.07663	0.07618	0.07668	0.08004	0.08114	0.07618	0.0767	0.002	0.07652	0.07633	0.07674	0.07692	0.07647	0.07692	0.07633	0.0765	0.000	-0.21	
16	0.07638	0.0766	0.07663	0.07656	0.08101	0.08101	0.07638	0.0766	0.002	0.07656	0.07664	0.07613	0.07657	0.07671	0.07671	0.07613	0.0766	0.000	-0.04	
17	0.07701	0.07923	0.07738	0.07668	0.08114	0.08114	0.07668	0.0774	0.002	0.07658	0.07625	0.07654	0.07647	0.07648	0.07658	0.07625	0.0765	0.000	-1.16	
18	0.07898	0.07605	0.07938	0.0764	0.07643	0.07938	0.07605	0.0776	0.001	0.07653	0.07654	0.07661	0.07658	0.07653	0.07661	0.07653	0.0765	0.000	-1.42	
19	0.07936	0.07946	0.07893	0.08468	0.08097	0.08468	0.07893	0.0795	0.002	0.0779	0.07775	0.07722	0.07661	0.07666	0.0779	0.07661	0.0772	0.001	-2.82	
20	0.07747	0.07921	0.07738	0.08096	0.07668	0.08096	0.07668	0.0775	0.002	0.07737	0.07668	0.07818	0.07679	0.07762	0.07818	0.07668	0.0774	0.001	-0.13	
21	0.07747	0.07715	0.08098	0.07893	0.07663	0.08098	0.07663	0.0775	0.002	0.07893	0.07663	0.07713	0.07721	0.07696	0.07893	0.07663	0.0771	0.001	-0.44	
22	0.07707	0.07924	0.08112	0.07709	0.07704	0.08112	0.07704	0.0771	0.002	0.07684	0.07665	0.07645	0.07678	0.07666	0.07684	0.07645	0.0767	0.000	-0.56	
23	0.08004	0.07691	0.07924	0.07979	0.07638	0.08004	0.07638	0.0792	0.002	0.07666	0.0769	0.077	0.07664	0.07703	0.07703	0.07666	0.0769	0.000	-2.95	
24	0.07734	0.08096	0.07701	0.07693	0.07747	0.08096	0.07693	0.0773	0.002	0.07681	0.0769	0.07629	0.07683	0.07699	0.07699	0.07629	0.0768	0.000	-0.66	
25	0.07698	0.08153	0.0771	0.07613	0.08096	0.08153	0.07613	0.0771	0.003	0.07679	0.07688	0.07693	0.07706	0.07681	0.07706	0.07679	0.0769	0.000	-0.29	
26	0.07709	0.07715	0.07698	0.08106	0.08002	0.08106	0.07698	0.0772	0.002	0.07783	0.07714	0.07682	0.07699	0.07703	0.07783	0.07682	0.0770	0.000	-0.16	
27	0.07621	0.07734	0.07823	0.07668	0.07723	0.07823	0.07621	0.0772	0.001	0.07799	0.07689	0.07772	0.07704	0.07714	0.07799	0.07689	0.0771	0.000	-0.12	
28	0.07701	0.07701	0.08098	0.08112	0.08108	0.08112	0.07701	0.0810	0.002	0.07688	0.07704	0.07736	0.07683	0.07768	0.07836	0.07688	0.0774	0.001	-4.47	
29	0.07615	0.07693	0.07738	0.07709	0.08071	0.08071	0.07615	0.0771	0.002	0.07722	0.0779	0.07703	0.07713	0.07912	0.07912	0.07703	0.0772	0.001	0.17	
30	0.07723	0.08136	0.0773	0.07613	0.08052	0.08136	0.07613	0.0773	0.002	0.07616	0.07725	0.07715	0.07681	0.07709	0.07725	0.07616	0.0771	0.000	-0.27	
31	0.08103	0.08098	0.07734	0.0753	0.08052	0.08103	0.07734	0.0805	0.002	0.07723	0.07631	0.07729	0.07742	0.07706	0.07742	0.07631	0.0772	0.000	-4.10	
32	0.07734	0.07738	0.07747	0.07946	0.08098	0.08098	0.07734	0.0775	0.002	0.07702	0.07673	0.07617	0.07711	0.07708	0.07711	0.07617	0.0770	0.000	-0.57	
33	0.07698	0.07604	0.07936	0.07747	0.07938	0.07938	0.07604	0.0775	0.001	0.077	0.07664	0.07738	0.07729	0.07639	0.07738	0.07639	0.0770	0.000	-0.61	
34	0.07738	0.07638	0.07656	0.07615	0.07979	0.07979	0.07615	0.0766	0.001	0.07739	0.07762	0.07727	0.07799	0.07721	0.07799	0.07721	0.0774	0.000	1.08	
35	0.08151	0.08108	0.07762	0.07615	0.08171	0.08171	0.07615	0.0811	0.003	0.07678	0.07713	0.07746	0.07651	0.07737	0.07746	0.07651	0.0771	0.000	-4.87	
36	0.08097	0.07715	0.082	0.07698	0.07898	0.082	0.07698	0.0790	0.002	0.0772	0.07966	0.07753	0.07793	0.07992	0.07992	0.0772	0.0779	0.001	-1.33	
37	0.07899	0.07747	0.08112	0.08108	0.08225	0.08225	0.07747	0.0811	0.002	0.08074	0.07814	0.07739	0.0772	0.07744	0.08074	0.0772	0.0774	0.001	-4.49	
38	0.07638	0.08096	0.08189	0.07656	0.07701	0.08189	0.07638	0.0770	0.003	0.07715	0.0764	0.07724	0.07688	0.07712	0.07724	0.0764	0.0771	0.000	0.14	
39	0.0779	0.07777	0.07813	0.08276	0.07747	0.08276	0.07747	0.0779	0.002	0.07768	0.07842	0.07816	0.0781	0.07761	0.07842	0.07761	0.0781	0.000	0.26	
40	0.07794	0.0777	0.08291	0.07738	0.0764	0.08291	0.07738	0.0777	0.002	0.07732	0.08028	0.07762	0.07778	0.07807	0.08028	0.07732	0.0778	0.001	0.10	
41	0.07636	0.07979	0.08153	0.07622	0.07638	0.08153	0.07622	0.0764	0.002	0.07756	0.07788	0.07761	0.07748	0.07779	0.07788	0.07748	0.0776	0.000	1.61	
42	0.07787	0.08004	0.07786	0.07803	0.07979	0.08004	0.07786	0.0780	0.001	0.07686	0.07767	0.07786	0.07791	0.07786	0.07791	0.07686	0.0779	0.000	-0.22	
43	0.07899	0.07823	0.07663	0.07806	0.07605	0.07899	0.07605	0.0781	0.001	0.07775	0.07765	0.07988	0.08093	0.08104	0.08104	0.07765	0.0799	0.002	2.33	
44	0.07817	0.08223	0.07821	0.07747	0.0833	0.0833	0.07747	0.0782	0.003	0.07767	0.07715	0.07814	0.0777	0.07802	0.07814	0.07715	0.0777	0.000	-0.65	
45	0.08514	0.07825	0.08234	0.08234	0.07839	0.08514	0.07825	0.0823	0.003	0.0773	0.07957	0.07843	0.07911	0.07823	0.07957	0.0773	0.0784	0.001	-4.75	
46	0.08388	0.07723	0.08108	0.07923	0.07924	0.08388	0.07723	0.0792	0.002	0.07864	0.08163	0.07754	0.08163	0.07788	0.08163	0.07754	0.0786	0.002	-0.76	
47	0.0842	0.07817	0.07621	0.07883	0.07883	0.0842	0.07621	0.0788	0.003	0.07831	0.07771	0.07792	0.07847	0.07832	0.07847	0.07771	0.0783	0.000	-0.66	
48	0.07841	0.07638	0.07885	0.08454	0.07618	0.08454	0.07618	0.0784	0.003	0.0777	0.07811	0.07799	0.07788	0.07794	0.07811	0.0777	0.0780	0.000	-0.55	
49	0.08516	0.08485	0.07857	0.08533	0.0786	0.08533	0.07857	0.0849	0.004	0.07708	0.07802	0.07709	0.07798	0.07856	0.07856	0.07708	0.0780	0.001	-8.10	
50	0.07701	0.07923	0.07691	0.07606	0.07693	0.07923	0.07606	0.0769	0.001	0.07686	0.07824	0.07797	0.07688	0.07804	0.07866	0.07688	0.0780	0.001	1.44	
				A=0.085	B=0.0760	C=0.077	C=0.002							A=0.082	B=0.07458	C=0.077	C=0.000	C=-0.56		

H –จำนวนโหนดในชั้นซ่อน

min –ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง

1, 2, 3, 4, 5 –ผลการทดลองครั้งที่ 1, 2, 3, 4, 5 โดยคิดจากที่โครงข่ายให้ผลผิดพลาดลดลง

SD –ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง

ตารางที่ ค.16 ผลการทดลองและสถิติของข้อมูล dj โดยใช้ Feed forward NN.

H	Feed forward NN. แบบใช้ค่าน้ำหนักแบบค่าเต็ม (FNN)								Feed forward NN. แบบใช้ค่าน้ำหนักแบบเชกเมนต์ (MSFNN)								re(%)		
	1	2	3	4	5	max	min	mean	SD	1	2	3	4	5	max	min		mean	SD
1	0.06474	0.05689	0.0534	0.05308	0.05694	0.06474	0.05308	0.0569	0.005	0.0531	0.05311	0.05292	0.05282	0.05291	0.05311	0.05282	0.0529	0.000	-6.98
2	0.06692	0.05472	0.06437	0.06093	0.05335	0.06692	0.05335	0.0609	0.006	0.05215	0.05282	0.05276	0.05233	0.05276	0.05282	0.05215	0.0528	0.000	-13.41
3	0.05289	0.05446	0.05676	0.05308	0.05701	0.05701	0.05289	0.0545	0.002	0.05403	0.05379	0.05395	0.05168	0.05161	0.05403	0.05161	0.0538	0.001	-1.23
4	0.05443	0.05443	0.05335	0.05788	0.06032	0.06032	0.05335	0.0544	0.003	0.0528	0.05215	0.05516	0.05363	0.05263	0.05516	0.05215	0.0528	0.001	-2.99
5	0.06504	0.05916	0.05446	0.05567	0.05496	0.06504	0.05446	0.0557	0.004	0.05278	0.05241	0.05247	0.05145	0.05385	0.05385	0.05145	0.0525	0.001	-5.75
6	0.06236	0.0671	0.05737	0.05701	0.06189	0.0671	0.05701	0.0619	0.004	0.05227	0.05131	0.05284	0.05226	0.05268	0.05284	0.05131	0.0523	0.001	-15.54
7	0.05362	0.05536	0.05362	0.05308	0.05755	0.05755	0.05308	0.0536	0.002	0.05217	0.054	0.05267	0.0528	0.05278	0.054	0.05217	0.0528	0.001	-1.57
8	0.05496	0.05397	0.05867	0.06092	0.06634	0.06634	0.05397	0.0587	0.005	0.05279	0.05314	0.05407	0.05284	0.05408	0.05408	0.05279	0.0531	0.001	-9.43
9	0.05676	0.05567	0.05755	0.05568	0.06475	0.06475	0.05567	0.0568	0.004	0.05297	0.05289	0.0533	0.05411	0.05287	0.05411	0.05287	0.0530	0.001	-6.68
10	0.05755	0.05846	0.05689	0.056	0.06032	0.06032	0.056	0.0576	0.002	0.05332	0.05437	0.05355	0.05436	0.05359	0.05437	0.05332	0.0536	0.000	-6.88
11	0.05904	0.05397	0.05568	0.056	0.05496	0.05904	0.05397	0.0557	0.002	0.05264	0.05313	0.05352	0.05297	0.05281	0.05352	0.05264	0.0530	0.000	-4.87
12	0.05446	0.06437	0.05916	0.05689	0.05651	0.06437	0.05446	0.0569	0.004	0.05441	0.0542	0.05432	0.05462	0.05463	0.05463	0.0542	0.0544	0.000	-4.36
13	0.06504	0.05701	0.0671	0.05676	0.06092	0.0671	0.05676	0.0609	0.005	0.05524	0.05307	0.05343	0.05464	0.05485	0.05524	0.05307	0.0546	0.001	-10.31
14	0.05545	0.06164	0.0534	0.05737	0.06181	0.06181	0.0534	0.0574	0.004	0.05325	0.05458	0.05299	0.05329	0.05317	0.05458	0.05299	0.0533	0.001	-7.18
15	0.0687	0.06236	0.056	0.06413	0.05472	0.0687	0.05472	0.0624	0.006	0.05516	0.05399	0.05493	0.05483	0.05448	0.05516	0.05399	0.0548	0.000	-12.08
16	0.06152	0.05714	0.06152	0.05894	0.05846	0.06152	0.05894	0.0585	0.002	0.05314	0.0532	0.05181	0.05322	0.05322	0.05322	0.05181	0.0532	0.001	-9.00
17	0.06475	0.05903	0.06504	0.06692	0.05496	0.06692	0.05496	0.0648	0.005	0.05473	0.05321	0.0551	0.05493	0.054	0.0551	0.05321	0.0547	0.001	-15.47
18	0.06152	0.05737	0.05774	0.06189	0.05782	0.06189	0.05737	0.0578	0.002	0.05381	0.05409	0.05301	0.05496	0.05437	0.05496	0.05301	0.0541	0.001	-6.45
19	0.06118	0.05788	0.06564	0.06477	0.05309	0.06564	0.05309	0.0612	0.005	0.0534	0.05248	0.05428	0.05272	0.05342	0.05428	0.05248	0.0534	0.001	-12.72
20	0.05903	0.06181	0.0671	0.06235	0.063	0.0671	0.05903	0.0624	0.003	0.05427	0.05416	0.05316	0.05424	0.05484	0.05484	0.05316	0.0542	0.001	-13.01
21	0.06152	0.05714	0.05786	0.06564	0.05776	0.06564	0.05714	0.0579	0.004	0.05512	0.05539	0.05426	0.05346	0.0549	0.05539	0.05346	0.0549	0.001	-5.12
22	0.05651	0.06148	0.05846	0.05545	0.06196	0.06196	0.05545	0.0585	0.003	0.05407	0.05517	0.05394	0.0543	0.05447	0.05517	0.05394	0.0543	0.000	-7.12
23	0.05815	0.05827	0.05755	0.05362	0.06109	0.06109	0.05362	0.0582	0.003	0.05081	0.05539	0.05613	0.05629	0.05483	0.05629	0.05483	0.0558	0.001	-4.02
24	0.05988	0.06032	0.05903	0.06564	0.05867	0.06564	0.05867	0.0599	0.003	0.05602	0.05573	0.05605	0.05608	0.05606	0.05608	0.05573	0.0561	0.000	-6.40
25	0.05676	0.05916	0.06152	0.05867	0.06564	0.06564	0.05867	0.0592	0.003	0.05584	0.05619	0.05491	0.05443	0.05432	0.05619	0.05432	0.0549	0.001	-7.18
26	0.06475	0.05916	0.05701	0.06666	0.05904	0.06666	0.05701	0.0592	0.004	0.0558	0.05489	0.05513	0.05454	0.05597	0.05597	0.05454	0.0551	0.001	-6.81
27	0.06093	0.06475	0.06092	0.06148	0.063	0.06475	0.06092	0.0615	0.002	0.05624	0.05419	0.05531	0.05618	0.05609	0.05624	0.05419	0.0561	0.001	-8.77
28	0.06504	0.06692	0.05904	0.06148	0.06152	0.06692	0.05904	0.0615	0.003	0.05553	0.05599	0.05824	0.05569	0.05419	0.05624	0.05419	0.0567	0.001	-9.48
29	0.06413	0.06474	0.06032	0.06093	0.06692	0.06692	0.06032	0.0641	0.003	0.05541	0.0572	0.05563	0.05714	0.05462	0.0572	0.05462	0.0556	0.001	-13.25
30	0.06181	0.06456	0.06118	0.06456	0.06088	0.06456	0.06088	0.0618	0.002	0.05629	0.05463	0.05664	0.05663	0.05532	0.05664	0.05463	0.0563	0.001	-8.93
31	0.05903	0.06235	0.06088	0.063	0.06431	0.06431	0.05903	0.0624	0.002	0.05581	0.0537	0.05683	0.05652	0.0567	0.05683	0.0537	0.0565	0.001	-9.35
32	0.06477	0.06503	0.06164	0.05362	0.06189	0.06503	0.05362	0.0619	0.005	0.05722	0.05688	0.05718	0.05614	0.0568	0.05722	0.05614	0.0569	0.000	-8.10
33	0.06475	0.0687	0.06504	0.0671	0.05714	0.0687	0.05714	0.0650	0.004	0.05686	0.05685	0.05594	0.05715	0.05431	0.05715	0.05431	0.0569	0.001	-12.59
34	0.06196	0.05788	0.06474	0.06477	0.06634	0.06634	0.05788	0.0647	0.003	0.05696	0.05585	0.05838	0.05703	0.0564	0.05703	0.05585	0.0564	0.000	-12.88
35	0.0687	0.06475	0.06236	0.06666	0.06189	0.0687	0.06189	0.0648	0.003	0.05722	0.05702	0.05712	0.0569	0.05644	0.05722	0.05644	0.0570	0.000	-11.94
36	0.05846	0.05443	0.06093	0.06477	0.05568	0.06477	0.05443	0.0589	0.004	0.05471	0.05709	0.05704	0.05693	0.05555	0.05709	0.05471	0.0569	0.001	-0.02
37	0.06634	0.05651	0.05846	0.06503	0.06564	0.06634	0.05651	0.0650	0.005	0.05757	0.05728	0.05736	0.05728	0.05706	0.05757	0.05706	0.0573	0.000	-11.92
38	0.06882	0.0687	0.06437	0.05567	0.06431	0.06882	0.05567	0.0644	0.005	0.05521	0.05678	0.05728	0.05476	0.05717	0.05728	0.05476	0.0568	0.001	-11.79
39	0.06692	0.06486	0.06181	0.05362	0.05689	0.06692	0.05362	0.0618	0.006	0.05741	0.05674	0.05697	0.05693	0.05709	0.05741	0.05674	0.0570	0.001	-7.83
40	0.06152	0.05846	0.06666	0.06477	0.06838	0.06838	0.05846	0.0648	0.004	0.05751	0.05789	0.05691	0.05757	0.05696	0.05789	0.05691	0.0575	0.000	-11.21
41	0.06196	0.06148	0.05651	0.06503	0.06431	0.06503	0.05651	0.0620	0.003	0.05804	0.05768	0.05763	0.05901	0.05766	0.05901	0.05763	0.0577	0.001	-6.91
42	0.06148	0.06413	0.05889	0.06689	0.05651	0.06689	0.05651	0.0615	0.005	0.05611	0.05772	0.05497	0.05774	0.05777	0.05777	0.05497	0.0577	0.001	-6.12
43	0.05545	0.05472	0.05567	0.05788	0.06634	0.06634	0.05472	0.0557	0.005	0.05323	0.05802	0.05859	0.05336	0.05784	0.05859	0.05323	0.0578	0.003	3.90
44	0.06503	0.05694	0.06564	0.05788	0.0689	0.0689	0.05694	0.0650	0.005	0.05816	0.05876	0.05915	0.05797	0.05947	0.05947	0.05797	0.0588	0.001	-9.64
45	0.06431	0.05472	0.05496	0.05676	0.07216	0.07216	0.05472	0.0568	0.008	0.06072	0.06072	0.05765	0.06007	0.05964	0.06072	0.05765	0.0601	0.001	5.83
46	0.06093	0.06118	0.07913	0.06164	0.05714	0.07913	0.05714	0.0612	0.009	0.05907	0.05836	0.05814	0.05788	0.05836	0.05907	0.05788	0.0584	0.000	-4.61
47	0.05867	0.07046	0.05335	0.05737	0.07421	0.07421	0.05335	0.0587	0.009	0.05941	0.06196	0.06042	0.06087	0.05702	0.06196	0.05702	0.0604	0.002	2.98
48	0.07254	0.07168	0.06148	0.06236	0.06503	0.07254	0.06148	0.0650	0.005	0.05874	0.05802	0.05874	0.0542	0.05874	0.05874				

ตารางที่ ก.17 ผลการทดลองและสถิติของข้อมูล dj โดยใช้ Elman Recurrent NN.

Table with 2 main sections: Elman Recurrent NN. แบบใช้ค่าน้ำหนักทั้งหมดค่าเดียว (ERNN) and Elman Recurrent NN. แบบใช้ค่าน้ำหนักแบบแยกแอมป์ (MSERNN). Each section contains columns for iterations (1-5) and statistical metrics (max, min, mean, SD, re(%)).

H - จำนวนโหนดในชั้นซ่อน
min - ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง
max - ค่าผิดพลาด (RMSE) มากที่สุดจากการทดลอง 5 ครั้ง
mean - ค่าเฉลี่ยของค่าความผิดพลาด (RMSE) จากการทดลอง 5 ครั้ง
SD - ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง
A - ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
B - ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
C - ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด)
re - reduce เปอร์เซนต์ที่โครงข่ายให้ผลผิดพลาดลดลง โดยหาได้จาก (mean_MSERNN - mean_ERNN) / mean_ERNN * 100

ผลการทดลองจากตารางที่ ก.17 แสดงให้เห็นว่า เมื่อมีการใช้จำนวนโหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลง 31 แบบ (จำนวนโหนดที่เท่ากันในชั้นซ่อน) โดยถ้าคิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลงโดยเฉลี่ย 1.20% โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 0.05187 เมื่อใช้จำนวนโหนดในชั้นซ่อน 2 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์คือ 0.05138 เมื่อใช้จำนวนโหนดในชั้นซ่อน 2 โหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ก.18 ผลการทดลองและสถิติของข้อมูล dj โดยใช้ Jordan Recurrent NN.

H	Jordan Recurrent NN. แบบใช้ค่าน้ำหนักเพียงค่าเดียว (JRNN)									Jordan Recurrent NN. แบบใช้ค่าน้ำหนักแบบแยกเมมด (MSJRNN)									re(%)	
	1	2	3	4	5	max	min	mean	SD	1	2	3	4	5	max	min	mean	SD		
1	0.06063	0.05356	0.07096	0.05538	0.07217	0.07217	0.05356	0.0606	0.009	0.05153	0.05439	0.05227	0.05183	0.05301	0.05439	0.05153	0.0523	0.001	-13.79	
2	0.06403	0.05529	0.05781	0.06966	0.05449	0.06966	0.05449	0.0578	0.006	0.05066	0.05288	0.05142	0.05349	0.05367	0.05367	0.05066	0.0529	0.001	-8.53	
3	0.06006	0.05654	0.05692	0.0531	0.06513	0.06513	0.0531	0.0569	0.005	0.0529	0.05193	0.05223	0.05294	0.05223	0.05294	0.05193	0.0522	0.000	-8.24	
4	0.05536	0.06081	0.05324	0.05483	0.05314	0.06081	0.05314	0.0548	0.003	0.05283	0.05259	0.05211	0.05255	0.05343	0.05343	0.05211	0.0526	0.000	-4.09	
5	0.055	0.0638	0.05455	0.05692	0.07207	0.07207	0.05455	0.0569	0.007	0.05257	0.05207	0.05275	0.05209	0.05204	0.05275	0.05204	0.0521	0.000	-8.49	
6	0.05466	0.05337	0.05314	0.05499	0.06231	0.06231	0.05314	0.0547	0.004	0.05411	0.05425	0.05263	0.05266	0.05411	0.05425	0.05263	0.0541	0.001	-1.01	
7	0.05536	0.05782	0.05647	0.05782	0.05538	0.05782	0.05536	0.0565	0.001	0.05364	0.05376	0.05273	0.05326	0.05364	0.05376	0.05273	0.0536	0.000	-5.01	
8	0.07579	0.05586	0.06887	0.05356	0.06143	0.07579	0.05356	0.0614	0.009	0.0527	0.05287	0.05221	0.0524	0.05105	0.05287	0.05105	0.0524	0.001	-14.70	
9	0.05361	0.07207	0.05361	0.05527	0.05567	0.07207	0.05361	0.0553	0.008	0.05079	0.05327	0.05349	0.05293	0.0529	0.05349	0.05079	0.0529	0.001	-4.23	
10	0.05956	0.05608	0.05619	0.07217	0.0638	0.07217	0.05608	0.0596	0.007	0.05385	0.05285	0.05416	0.05352	0.05444	0.05444	0.05285	0.0539	0.001	-9.59	
11	0.06094	0.05477	0.06685	0.0559	0.05647	0.06685	0.05477	0.0585	0.005	0.05445	0.05452	0.05289	0.0527	0.05386	0.05452	0.0527	0.0539	0.001	-6.52	
12	0.05408	0.05608	0.06279	0.06513	0.05432	0.06513	0.05408	0.0561	0.005	0.05281	0.05287	0.05303	0.05288	0.05272	0.05303	0.05272	0.0529	0.000	-5.72	
13	0.05689	0.05482	0.05795	0.05411	0.05419	0.05795	0.05411	0.0548	0.002	0.0546	0.05326	0.05391	0.05446	0.0526	0.0546	0.0526	0.0539	0.001	-1.66	
14	0.05963	0.05497	0.06132	0.0548	0.05576	0.06132	0.0548	0.0558	0.003	0.05315	0.05272	0.05258	0.05315	0.05299	0.05315	0.05258	0.0530	0.000	-4.97	
15	0.05477	0.05608	0.05586	0.05781	0.06231	0.06231	0.05477	0.0561	0.003	0.05326	0.05341	0.05456	0.05372	0.05342	0.05456	0.05326	0.0534	0.001	-4.74	
16	0.05689	0.05656	0.05482	0.05647	0.05477	0.05689	0.05477	0.0565	0.001	0.05419	0.05461	0.05388	0.05531	0.05493	0.05531	0.05388	0.0546	0.001	-3.29	
17	0.05654	0.05721	0.05529	0.05806	0.05337	0.05806	0.05337	0.0565	0.002	0.05321	0.05335	0.05387	0.05297	0.05337	0.05387	0.05297	0.0534	0.000	-5.64	
18	0.05538	0.05895	0.05781	0.05548	0.05591	0.05895	0.05538	0.0559	0.002	0.05158	0.05364	0.05353	0.05447	0.05375	0.05447	0.05158	0.0536	0.001	-4.06	
19	0.05911	0.05411	0.05911	0.06132	0.06094	0.06132	0.05411	0.0591	0.003	0.05393	0.05628	0.05524	0.05333	0.05502	0.05528	0.05333	0.0550	0.001	-6.92	
20	0.05576	0.06081	0.05643	0.05795	0.05795	0.05576	0.0564	0.001	0.05449	0.05429	0.05485	0.05427	0.05369	0.05485	0.05369	0.0543	0.000	-3.79		
21	0.05654	0.0548	0.05654	0.05692	0.06347	0.06347	0.0548	0.0565	0.003	0.05459	0.05513	0.05472	0.05456	0.05535	0.05535	0.05456	0.0547	0.000	-3.22	
22	0.05782	0.05356	0.05782	0.05925	0.05789	0.05925	0.05356	0.0578	0.002	0.05413	0.05566	0.05595	0.0537	0.05478	0.05595	0.0537	0.0548	0.001	-5.26	
23	0.05810	0.05781	0.08457	0.05967	0.05858	0.08457	0.05781	0.0586	0.012	0.05523	0.05432	0.05434	0.05438	0.05422	0.05523	0.05422	0.0543	0.000	-7.24	
24	0.06081	0.07099	0.06063	0.05781	0.05963	0.07099	0.05781	0.0606	0.005	0.05367	0.05525	0.0536	0.05552	0.05498	0.05552	0.05367	0.0550	0.001	-9.32	
25	0.06006	0.06003	0.07096	0.05795	0.05647	0.07096	0.05647	0.0600	0.006	0.05545	0.05511	0.05569	0.05522	0.05467	0.05569	0.05467	0.0552	0.000	-8.01	
26	0.06106	0.06233	0.06143	0.05956	0.06966	0.06966	0.05956	0.0614	0.004	0.05512	0.05459	0.05476	0.05512	0.05492	0.05512	0.05459	0.0549	0.000	-10.80	
27	0.0548	0.05361	0.06081	0.06081	0.06106	0.06106	0.05361	0.0608	0.004	0.05529	0.05628	0.05575	0.05530	0.05629	0.05629	0.05529	0.0558	0.002	-8.32	
28	0.06063	0.06094	0.05337	0.06259	0.06452	0.06452	0.05337	0.0609	0.004	0.05617	0.05617	0.05388	0.05663	0.05617	0.05663	0.05538	0.0562	0.000	-7.83	
29	0.05310	0.05911	0.06403	0.05482	0.05956	0.06403	0.05310	0.0591	0.004	0.05574	0.05549	0.05604	0.05512	0.0541	0.05604	0.0541	0.0565	0.001	-6.12	
30	0.05482	0.07099	0.05608	0.05643	0.06403	0.07099	0.05482	0.0564	0.007	0.05631	0.05364	0.05456	0.05528	0.05626	0.05631	0.05364	0.0553	0.001	-2.04	
31	0.05449	0.07207	0.06132	0.06685	0.05337	0.07207	0.05337	0.0613	0.008	0.05626	0.05637	0.05662	0.05564	0.05572	0.05662	0.05564	0.0563	0.000	-8.25	
32	0.06279	0.06513	0.07099	0.05477	0.05455	0.07099	0.05455	0.0628	0.007	0.05524	0.0553	0.05604	0.05635	0.05647	0.05647	0.05524	0.0560	0.001	-10.75	
33	0.0638	0.06006	0.06571	0.06231	0.05643	0.06571	0.05643	0.0628	0.004	0.05347	0.05615	0.05537	0.05524	0.05545	0.05615	0.05347	0.0564	0.001	-11.14	
34	0.08457	0.05619	0.06791	0.06966	0.06279	0.08457	0.05619	0.0679	0.011	0.05699	0.05697	0.05607	0.05688	0.05703	0.05703	0.05607	0.0570	0.000	-16.11	
35	0.07217	0.05782	0.08457	0.0655	0.06347	0.08457	0.05782	0.0655	0.010	0.05708	0.05714	0.05629	0.05393	0.05687	0.05714	0.05393	0.0569	0.001	-13.18	
36	0.06550	0.06364	0.06966	0.07217	0.06787	0.07217	0.06364	0.0679	0.003	0.05624	0.05703	0.05647	0.05809	0.05687	0.05703	0.05609	0.0565	0.000	-16.80	
37	0.06362	0.06519	0.05619	0.06519	0.05886	0.06519	0.05619	0.0636	0.005	0.05388	0.05722	0.05546	0.0566	0.057	0.05722	0.05388	0.0566	0.001	-11.03	
38	0.06862	0.06452	0.05477	0.06816	0.05477	0.06862	0.05477	0.0645	0.007	0.05614	0.05745	0.05462	0.05324	0.05733	0.05745	0.05324	0.0561	0.002	-12.99	
39	0.06259	0.05536	0.05482	0.08457	0.05795	0.08457	0.05482	0.0580	0.012	0.05765	0.05645	0.05737	0.05348	0.05745	0.05765	0.05348	0.0574	0.002	-1.00	
40	0.08457	0.06887	0.06231	0.06513	0.06132	0.08457	0.06132	0.0651	0.009	0.05682	0.05648	0.05741	0.05722	0.05617	0.05741	0.05617	0.0568	0.001	-12.76	
41	0.06685	0.071	0.06003	0.06791	0.06748	0.071	0.06003	0.0675	0.004	0.0572	0.05755	0.05794	0.05717	0.05813	0.05717	0.0576	0.000	-14.72		
42	0.06513	0.07087	0.05781	0.06966	0.06791	0.07087	0.05781	0.0679	0.005	0.05797	0.05787	0.0579	0.05724	0.05797	0.05797	0.05724	0.0579	0.000	-14.74	
43	0.06887	0.06364	0.05408	0.06063	0.06362	0.06887	0.05408	0.0636	0.005	0.05803	0.05769	0.05726	0.05721	0.05723	0.05803	0.05721	0.0573	0.000	-10.00	
44	0.07207	0.06006	0.07447	0.05629	0.06791	0.07447	0.05629	0.0679	0.008	0.05445	0.05815	0.05735	0.05782	0.05724	0.05815	0.05445	0.0574	0.001	-15.55	
45	0.07306	0.07531	0.05411	0.06063	0.07099	0.07531	0.05411	0.0710	0.009	0.05787	0.05885	0.05825	0.05835	0.05852	0.05885	0.05787	0.0584	0.001	-17.81	
46	0.06966	0.06347	0.07132	0.07378	0.06403	0.07378	0.06347	0.0697	0.005	0.06379	0.06091	0.05893	0.058	0.0652	0.0652	0.058	0.0609	0.003	-12.56	
47	0.07311	0.06966	0.07466	0.07481	0.07369	0.07481	0.06966	0.0737	0.002	0.05396	0.05238	0.05369	0.0587	0.0591	0.0591	0.05238	0.0540	0.003	-26.77	
48	0.07579	0.07979	0.06143	0.07644	0.07096	0.07979	0.06143	0.0758	0.007	0.05894	0.05776	0.05964	0.06136	0.06142	0.05776	0.0596	0.002	-21.31		
49	0.05782	0.07217	0.06887	0.07628	0.0781	0.0781	0.05782	0.0722	0.008	0.05784	0.05816	0.05891	0.05383	0.05863	0.05891	0.05383	0.0582	0.002	-19.41	
50	0.07313	0.05911	0.07096	0.0726	0.06452	0.07313	0.05911	0.0710	0.006	0.05904	0.06024	0.05918	0.05954	0.05792	0.06024	0.05792	0.0592	0.001	-16.60	
A=0.085B=0.05310C=0.060C=0.005										A=0.065B=0.05066C=0.055C=0.001										C=-8.40

H - จำนวนโหนดในชั้นซ่อน
 max - ค่าผิดพลาด (RMSE) มากที่สุดจากการทดลอง 5 ครั้ง
 min - ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง
 mean - ค่าเฉลี่ยของค่าความผิดพลาด (RMSE) จากการทดลอง 5 ครั้ง
 SD - ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง
 A - ค่าความผิดพลาดมากที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
 B - ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
 C - ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด)
 re - reduce เปอร์เซนต์ที่โครงข่ายให้ผลผิดพลาดลดลง โดยหาได้จาก $(mean_{MSJRNN} - mean_{JRNN}) / mean_{JRNN} * 100$

ผลการทดลองจากตารางที่ ก.18 แสดงให้เห็นว่า เมื่อมีการใช้จำนวนโหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลงทุกแบบ (จำนวนโหนดที่เท่ากันในชั้นซ่อน) โดยถ้าวัดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลงโดยเฉลี่ย 8.40% โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 0.05310 เมื่อใช้จำนวนโหนดในชั้นซ่อน 3 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์คือ 0.05066 เมื่อใช้จำนวนโหนดในชั้นซ่อน 2 โหนด

ตารางที่ ค.19 ผลการทดลองและสถิติของข้อมูล pigs โดยใช้ Feed forward NN.

Feed forward NN. แบบใช้ค่าน้ำหนักแบบค่าเฉลี่ย (FNN)										Feed forward NN. แบบใช้ค่าน้ำหนักแบบเซกเมนต์ (MSFNN)									
H	1	2	3	4	5	max	min	mean	SD	1	2	3	4	5	max	min	mean	SD	re(%)
1	0.13637	0.14825	0.12748	0.14065	0.1313	0.14825	0.12748	0.1364	0.008	0.11815	0.1133	0.11815	0.11344	0.11346	0.11815	0.1133	0.1135	0.003	-16.80
2	0.11799	0.1446	0.11638	0.15726	0.11611	0.15726	0.11611	0.1180	0.019	0.11289	0.11828	0.11826	0.11822	0.11822	0.11828	0.11289	0.1182	0.002	0.19
3	0.13458	0.11571	0.14931	0.13494	0.12769	0.14931	0.11571	0.1346	0.012	0.11828	0.11829	0.11414	0.11768	0.11368	0.11829	0.11368	0.1177	0.002	-12.56
4	0.11799	0.11413	0.11805	0.15969	0.13458	0.15969	0.11413	0.1181	0.019	0.11616	0.11832	0.11841	0.11841	0.11411	0.11841	0.11411	0.1183	0.002	0.23
5	0.13637	0.11646	0.14352	0.12484	0.11465	0.14352	0.11465	0.1248	0.013	0.11859	0.11853	0.11845	0.11418	0.11845	0.11859	0.11418	0.1185	0.002	-5.12
6	0.11515	0.14267	0.1212	0.1366	0.15852	0.15852	0.11515	0.1366	0.017	0.1143	0.11868	0.11868	0.11499	0.11756	0.11868	0.1143	0.1176	0.002	-13.94
7	0.14922	0.11611	0.16229	0.14475	0.14065	0.16229	0.11611	0.1483	0.017	0.11916	0.11977	0.12006	0.11913	0.11556	0.12006	0.11556	0.1192	0.002	-19.62
8	0.12806	0.11881	0.15678	0.12026	0.12117	0.15678	0.11881	0.1212	0.016	0.11956	0.11878	0.11877	0.11654	0.11923	0.11956	0.11654	0.1188	0.001	-1.97
9	0.1366	0.1227	0.1217	0.12484	0.12181	0.1366	0.1217	0.1227	0.006	0.12144	0.12002	0.12002	0.12038	0.12038	0.12144	0.12002	0.1204	0.001	-1.89
10	0.1212	0.15677	0.12393	0.16842	0.12196	0.16842	0.1212	0.1239	0.022	0.11868	0.11714	0.11751	0.11685	0.11602	0.11868	0.11602	0.1171	0.001	-5.48
11	0.16644	0.1446	0.14595	0.13385	0.12484	0.16644	0.12484	0.1446	0.016	0.11707	0.11877	0.11937	0.11601	0.11877	0.11937	0.11601	0.1188	0.001	-17.86
12	0.12293	0.12635	0.11611	0.12467	0.11571	0.12635	0.11571	0.1229	0.005	0.12278	0.11777	0.11388	0.12388	0.1231	0.12388	0.11388	0.1228	0.004	-0.12
13	0.12769	0.15275	0.12806	0.15969	0.1212	0.15969	0.1212	0.1281	0.017	0.11752	0.1213	0.11993	0.1185	0.12033	0.1213	0.11752	0.1199	0.002	-6.35
14	0.15027	0.17475	0.14212	0.12484	0.12769	0.17475	0.12484	0.1421	0.020	0.12014	0.13397	0.12154	0.12609	0.11931	0.13397	0.11931	0.1215	0.006	-14.48
15	0.1313	0.16514	0.12806	0.1313	0.16197	0.16514	0.12806	0.1313	0.018	0.11953	0.11526	0.11812	0.11567	0.11871	0.11953	0.11526	0.1181	0.002	-10.04
16	0.13494	0.15432	0.16965	0.14267	0.15541	0.16965	0.13494	0.1543	0.013	0.11942	0.11964	0.11326	0.11964	0.11542	0.11964	0.11326	0.1194	0.003	-22.62
17	0.11515	0.12726	0.1446	0.14597	0.12769	0.14597	0.11515	0.1277	0.013	0.1198	0.12027	0.1199	0.12026	0.12027	0.12027	0.1198	0.1203	0.000	-5.82
18	0.13202	0.12748	0.14825	0.15852	0.11646	0.15852	0.11646	0.1320	0.017	0.12044	0.12154	0.11601	0.12053	0.11866	0.12154	0.11601	0.1204	0.002	-8.77
19	0.13385	0.1313	0.18324	0.16229	0.13496	0.18324	0.1313	0.1350	0.023	0.11942	0.11727	0.12105	0.12007	0.12105	0.12105	0.11727	0.1201	0.002	-11.03
20	0.13333	0.13333	0.16965	0.14065	0.11881	0.16965	0.11881	0.1333	0.019	0.12138	0.12916	0.12006	0.1333	0.11984	0.1333	0.11984	0.1214	0.006	-8.96
21	0.14212	0.13494	0.1447	0.14352	0.14267	0.1447	0.13494	0.1427	0.004	0.12027	0.12002	0.11931	0.11665	0.12005	0.12027	0.11665	0.1200	0.002	-15.88
22	0.13764	0.13385	0.13458	0.13791	0.14825	0.13385	0.1376	0.006	0.12111	0.12462	0.1203	0.12063	0.12106	0.12462	0.1203	0.1211	0.002	-12.05	
23	0.14922	0.13637	0.11611	0.12484	0.13496	0.14922	0.11611	0.1350	0.013	0.12632	0.12235	0.12083	0.12632	0.13035	0.12083	0.12632	0.1263	0.004	-6.40
24	0.14211	0.14057	0.13494	0.1366	0.1366	0.14211	0.13494	0.1366	0.003	0.12387	0.11341	0.12446	0.12449	0.1245	0.1245	0.11341	0.1245	0.005	-8.89
25	0.12726	0.15027	0.16229	0.13496	0.11881	0.16229	0.11881	0.1350	0.018	0.12283	0.12123	0.12105	0.12211	0.12462	0.12462	0.12105	0.1222	0.001	-9.45
26	0.17147	0.14212	0.15834	0.13764	0.14922	0.17147	0.13764	0.1492	0.014	0.12248	0.13242	0.12126	0.13082	0.12499	0.13242	0.12126	0.1250	0.005	-16.24
27	0.14768	0.14267	0.14352	0.15319	0.14595	0.15319	0.14267	0.1460	0.004	0.11966	0.11927	0.12454	0.12085	0.11855	0.12454	0.11855	0.1197	0.002	-18.01
28	0.15678	0.12726	0.14597	0.1447	0.12748	0.15678	0.12726	0.1447	0.013	0.11932	0.12292	0.12155	0.12399	0.12406	0.12406	0.11932	0.1229	0.002	-15.05
29	0.14267	0.14987	0.14858	0.15226	0.11638	0.15226	0.11638	0.1486	0.015	0.13222	0.11994	0.12911	0.13355	0.12502	0.13355	0.11994	0.1291	0.006	-13.10
30	0.1446	0.13385	0.14825	0.15432	0.11465	0.15432	0.11465	0.1446	0.016	0.11857	0.12384	0.12384	0.11768	0.12396	0.12396	0.11768	0.1238	0.003	-14.36
31	0.15027	0.16068	0.15891	0.17475	0.15235	0.17475	0.15027	0.1589	0.010	0.12592	0.1242	0.1242	0.12296	0.12147	0.12592	0.12147	0.1242	0.002	-21.84
32	0.14922	0.14931	0.16965	0.15324	0.15249	0.16965	0.14922	0.1524	0.009	0.11897	0.12382	0.12352	0.12034	0.12133	0.12382	0.11897	0.1213	0.002	-20.39
33	0.15677	0.15275	0.14065	0.15677	0.16644	0.15677	0.14065	0.1568	0.009	0.12619	0.11953	0.12141	0.12343	0.12388	0.12619	0.11953	0.1234	0.003	-21.27
34	0.13496	0.13333	0.17147	0.1447	0.14724	0.17147	0.13333	0.1447	0.015	0.12701	0.11925	0.12838	0.135	0.135	0.135	0.11925	0.1284	0.007	-11.28
35	0.16514	0.18324	0.14724	0.14352	0.11611	0.18324	0.11611	0.1472	0.025	0.12753	0.12791	0.13268	0.13453	0.13316	0.13453	0.12753	0.1327	0.003	-9.89
36	0.15514	0.14212	0.13385	0.15275	0.15541	0.15541	0.13385	0.1528	0.010	0.13402	0.12926	0.12651	0.12825	0.12796	0.13402	0.12651	0.1283	0.003	-16.04
37	0.15834	0.14724	0.17147	0.1313	0.16644	0.17147	0.1313	0.1583	0.016	0.13481	0.13531	0.13531	0.12512	0.12819	0.13531	0.12512	0.1348	0.005	-14.86
38	0.15678	0.12806	0.13637	0.11423	0.17147	0.17147	0.11423	0.1364	0.023	0.12496	0.12803	0.1299	0.12828	0.11258	0.1299	0.11258	0.1280	0.007	-6.12
39	0.16514	0.15726	0.16842	0.14595	0.16965	0.16965	0.14595	0.1651	0.010	0.12876	0.12506	0.12905	0.12902	0.131	0.131	0.12506	0.1290	0.002	-21.87
40	0.1593	0.13494	0.11571	0.16514	0.1217	0.16514	0.11571	0.1349	0.022	0.1352	0.12927	0.13899	0.13362	0.13817	0.13899	0.12927	0.1352	0.004	0.19
41	0.1212	0.16514	0.15541	0.15852	0.15432	0.16514	0.1212	0.1554	0.017	0.12939	0.11275	0.12711	0.12952	0.12939	0.12952	0.11275	0.1294	0.007	-16.74
42	0.13764	0.15834	0.1636	0.15969	0.16631	0.16631	0.13764	0.1597	0.011	0.12683	0.12805	0.12683	0.13038	0.11231	0.13038	0.11231	0.1268	0.007	-20.58
43	0.16842	0.11443	0.1755	0.14212	0.16229	0.1755	0.11443	0.1623	0.025	0.12169	0.13198	0.13618	0.13198	0.13195	0.13618	0.12169	0.1320	0.005	-18.68
44	0.11571	0.16631	0.16965	0.16644	0.15432	0.16965	0.11571	0.1663	0.022	0.13835	0.12914	0.13889	0.14171	0.13943	0.14171	0.12914	0.1389	0.005	-16.49
45	0.17475	0.15027	0.12726	0.15677	0.11646	0.17475	0.11646	0.1503	0.023	0.13201	0.13347	0.13197	0.12905	0.13144	0.13347	0.12905	0.1320	0.002	-12.18
46	0.11881	0.16631	0.18324	0.17475	0.11515	0.18324	0.11515	0.1663	0.032	0.13106	0.13367	0.13106	0.13273	0.13354	0.13367	0.13106	0.1327	0.001	-20.19
47	0.1823	0.17919	0.1217	0.1447	0.11465	0.1823	0.11465	0.1447	0.031	0.13522	0.11913	0.11214	0.12677	0.13353	0.13522	0.11214	0.1268	0.010	-12.39
48	0.12806	0.11419	0.18324	0.13764	0.14597	0.18324	0.11419	0.1376	0.026	0.13271	0.13416	0.13248	0.13416	0.13431	0.13431	0.1			

ตารางที่ ค.20 ผลการทดลองและสถิติของข้อมูล pigs โดยใช้ Elman Recurrent NN.

H	Elman Recurrent NN. แบบไร้ค่าน้ำหนักเบี่ยงค่าเดิม (ERNN)										Elman Recurrent NN. แบบไร้ค่าน้ำหนักแบบเซกเมนต์ (MSERNN)										re(%)
	1	2	3	4	5	max	min	mean	SD		1	2	3	4	5	max	min	mean	SD		
1	0.10344	0.10354	0.11019	0.10992	0.10359	0.11019	0.10344	0.1036	0.004	0.1071	0.10126	0.10147	0.10191	0.10143	0.1071	0.10126	0.1015	0.003	-2.05		
2	0.10285	0.10305	0.10315	0.10259	0.10305	0.10315	0.10259	0.1031	0.000	0.10678	0.10887	0.10863	0.10211	0.10168	0.10887	0.10168	0.1068	0.003	3.62		
3	0.11167	0.11167	0.11173	0.10336	0.10457	0.11173	0.10336	0.1117	0.004	0.10882	0.10259	0.10413	0.10159	0.10163	0.10882	0.10159	0.1026	0.003	-8.13		
4	0.10239	0.10293	0.10293	0.10266	0.10293	0.10293	0.10239	0.1029	0.000	0.10913	0.10913	0.10935	0.10219	0.10135	0.10935	0.10135	0.1091	0.004	6.02		
5	0.11158	0.10977	0.11177	0.10435	0.10375	0.11177	0.10375	0.1098	0.006	0.10882	0.11009	0.10377	0.10237	0.10031	0.11009	0.10031	0.1038	0.004	-5.47		
6	0.10319	0.10319	0.1034	0.10319	0.1034	0.1034	0.10319	0.1032	0.000	0.11033	0.10152	0.10878	0.11035	0.10961	0.11035	0.10152	0.1096	0.004	6.22		
7	0.11175	0.11361	0.10578	0.10357	0.11152	0.11361	0.10357	0.1115	0.004	0.10953	0.10972	0.10358	0.10848	0.10939	0.10972	0.10358	0.1094	0.003	-1.91		
8	0.10542	0.10381	0.10381	0.10381	0.10495	0.10542	0.10381	0.1038	0.001	0.10875	0.10856	0.10835	0.11008	0.10987	0.11008	0.10835	0.1088	0.001	4.76		
9	0.11276	0.10294	0.10960	0.10935	0.10935	0.11276	0.10294	0.1094	0.004	0.10113	0.10558	0.10558	0.10559	0.10221	0.10559	0.10113	0.1056	0.002	-3.45		
10	0.10526	0.10657	0.10647	0.10647	0.10482	0.10657	0.10482	0.1065	0.001	0.10965	0.10823	0.11186	0.10742	0.10773	0.11186	0.10742	0.1082	0.002	1.65		
11	0.11080	0.11620	0.10808	0.10882	0.1116	0.11620	0.10808	0.1109	0.002	0.10572	0.09886	0.10703	0.10846	0.10114	0.10846	0.09886	0.1057	0.004	-4.64		
12	0.10754	0.10712	0.10712	0.10712	0.105	0.10754	0.105	0.1071	0.001	0.13053	0.10991	0.12047	0.10851	0.10555	0.13053	0.10555	0.1099	0.010	2.60		
13	0.1081	0.10967	0.11169	0.10742	0.11288	0.11288	0.10742	0.1097	0.002	0.11632	0.10777	0.13242	0.127	0.10568	0.13242	0.10568	0.1163	0.012	6.06		
14	0.10585	0.10824	0.10903	0.10933	0.10496	0.10903	0.10496	0.1082	0.002	0.108	0.11732	0.10826	0.09818	0.10855	0.11732	0.09818	0.1083	0.007	0.02		
15	0.1142	0.10989	0.11342	0.11095	0.10605	0.1142	0.10605	0.1110	0.003	0.10644	0.10605	0.10859	0.10738	0.10682	0.10859	0.10605	0.1068	0.001	-3.72		
16	0.11373	0.10992	0.11242	0.10896	0.10944	0.11373	0.10896	0.1099	0.002	0.10837	0.11053	0.10804	0.11228	0.10538	0.11228	0.10538	0.1084	0.003	-1.41		
17	0.11206	0.11362	0.12135	0.12135	0.11846	0.12135	0.11206	0.1185	0.004	0.11236	0.09918	0.10663	0.10895	0.12949	0.10895	0.09918	0.1090	0.012	-8.03		
18	0.11011	0.11416	0.11287	0.10868	0.11407	0.11416	0.10868	0.1129	0.002	0.10863	0.10706	0.10059	0.12048	0.10376	0.12048	0.10059	0.1071	0.008	-5.15		
19	0.11626	0.1177	0.11577	0.12788	0.12453	0.12788	0.11577	0.1177	0.005	0.10327	0.10804	0.108	0.10721	0.10579	0.10804	0.10327	0.1072	0.002	-8.91		
20	0.11302	0.11519	0.11519	0.11519	0.11502	0.11519	0.11302	0.1150	0.002	0.11819	0.10491	0.10252	0.10982	0.10841	0.11819	0.10252	0.1084	0.006	-5.75		
21	0.11615	0.11843	0.11721	0.11721	0.1178	0.11843	0.11615	0.1172	0.001	0.10752	0.11066	0.11146	0.10353	0.1067	0.11146	0.10353	0.1075	0.003	-8.27		
22	0.11863	0.11863	0.11173	0.12008	0.11863	0.12008	0.11173	0.1186	0.003	0.10808	0.10121	0.10898	0.10092	0.1095	0.1095	0.10092	0.1081	0.004	-8.89		
23	0.12203	0.1208	0.12081	0.13431	0.12081	0.13431	0.1208	0.1208	0.006	0.10693	0.1115	0.10109	0.11011	0.11833	0.11833	0.10109	0.1101	0.006	-8.86		
24	0.11979	0.10977	0.1203	0.1203	0.12444	0.12444	0.10977	0.1203	0.005	0.10264	0.10623	0.10693	0.10835	0.10144	0.10835	0.10144	0.1062	0.003	-11.70		
25	0.12132	0.12676	0.12107	0.12225	0.12132	0.12676	0.12107	0.1213	0.002	0.10572	0.11448	0.10816	0.10442	0.10207	0.11448	0.10207	0.1082	0.005	-10.85		
26	0.1242	0.11788	0.12127	0.1195	0.12127	0.1242	0.11788	0.1213	0.005	0.10921	0.10695	0.11183	0.1049	0.11425	0.11425	0.10281	0.1070	0.005	-11.81		
27	0.12477	0.11664	0.12477	0.13433	0.12199	0.13433	0.11664	0.1248	0.006	0.11558	0.12654	0.10773	0.10715	0.12478	0.12654	0.10715	0.1156	0.009	-7.37		
28	0.12795	0.12795	0.10987	0.12391	0.12632	0.12795	0.10987	0.1263	0.008	0.10105	0.10401	0.1015	0.10798	0.10666	0.10798	0.1015	0.1040	0.003	-17.66		
29	0.12866	0.12803	0.12437	0.12792	0.12803	0.12866	0.12437	0.1280	0.002	0.11392	0.10069	0.109	0.11133	0.10138	0.109	0.10069	0.1090	0.006	-14.86		
30	0.11329	0.13338	0.13634	0.13775	0.13241	0.13775	0.11329	0.1334	0.010	0.10922	0.10137	0.10402	0.10777	0.10755	0.10922	0.10137	0.1076	0.003	-19.37		
31	0.13547	0.1402	0.13757	0.13547	0.13637	0.13757	0.13547	0.1376	0.018	0.10186	0.1289	0.13273	0.1068	0.13048	0.13273	0.10186	0.1289	0.015	-6.30		
32	0.14329	0.14439	0.17028	0.13617	0.14292	0.17028	0.13617	0.1433	0.013	0.10988	0.12068	0.12354	0.12745	0.1205	0.12745	0.10988	0.1207	0.007	-15.78		
33	0.14615	0.14615	0.14296	0.17351	0.12477	0.17351	0.14296	0.1462	0.017	0.11032	0.12933	0.11843	0.12239	0.1215	0.12933	0.11032	0.1215	0.007	-16.87		
34	0.14212	0.18264	0.12965	0.14296	0.1564	0.18264	0.12965	0.1430	0.020	0.1104	0.10249	0.13094	0.1182	0.13094	0.13094	0.1182	0.1309	0.013	-17.32		
35	0.14357	0.13529	0.10381	0.13898	0.17917	0.13898	0.10381	0.1390	0.027	0.1216	0.1073	0.11856	0.1059	0.1079	0.1216	0.1059	0.1079	0.007	-22.36		
36	0.18453	0.1443	0.10896	0.12437	0.16085	0.1443	0.10896	0.1443	0.030	0.14725	0.11176	0.12814	0.1433	0.12713	0.14725	0.11176	0.1281	0.014	-11.20		
37	0.15035	0.17625	0.12132	0.14	0.13639	0.17625	0.12132	0.1400	0.020	0.10502	0.1183	0.10449	0.11035	0.10654	0.1183	0.10449	0.1065	0.006	-23.90		
38	0.1865	0.12913	0.17761	0.11863	0.10357	0.1865	0.10357	0.1291	0.037	0.10865	0.10903	0.10593	0.10903	0.10276	0.10903	0.10276	0.1087	0.003	-15.86		
39	0.15397	0.16762	0.10808	0.12107	0.16594	0.16762	0.10808	0.1540	0.027	0.11313	0.10334	0.12764	0.11317	0.1177	0.12764	0.10334	0.1132	0.009	-26.50		
40	0.17937	0.13612	0.18609	0.15623	0.18354	0.18609	0.13612	0.1794	0.022	0.1033	0.11227	0.11617	0.12407	0.12337	0.12407	0.1033	0.1162	0.009	-35.23		
41	0.15896	0.13549	0.1471	0.13549	0.1687	0.1687	0.13549	0.1471	0.015	0.12119	0.11866	0.13017	0.09955	0.1291	0.13017	0.09955	0.1212	0.013	-17.61		
42	0.11072	0.15958	0.1825	0.16121	0.1195	0.1825	0.11072	0.1596	0.032	0.12061	0.12386	0.11275	0.12543	0.11179	0.12543	0.11179	0.1206	0.006	-24.42		
43	0.18356	0.11664	0.11173	0.14329	0.11721	0.18356	0.11173	0.1172	0.030	0.11328	0.14013	0.12175	0.17136	0.1227	0.17136	0.11328	0.1227	0.023	4.68		
44	0.10482	0.16762	0.1177	0.10496	0.10868	0.16762	0.10482	0.1087	0.027	0.1227	0.12295	0.10252	0.12204	0.12295	0.10252	0.1227	0.009	12.90			
45	0.10336	0.11502	0.11615	0.1208	0.14296	0.11502	0.10336	0.1162	0.015	0.12175	0.12621	0.12214	0.11607	0.10458	0.12621	0.10458	0.1218	0.008	4.82		
46	0.14296	0.11323	0.11863	0.15067	0.10605	0.15067	0.10605	0.1186	0.019	0.10718	0.12209	0.13526	0.10695	0.13068	0.13526	0.10695	0.1221	0.013	2.92		
47	0.11206	0.1865	0.11721	0.13338	0.10605	0.1865	0.10605	0.1172	0.033	0.12422	0.14549	0.14549	0.15306	0.13453	0.15306	0.12422	0.1455	0.011	24.13		
48	0.10808	0.21871	0.13338	0.13757	0.12081	0.21871	0.10808	0.1334	0.043	0.12507	0.12274	0.12255	0.11565	0.11389	0.12507	0.11					

ตารางที่ ค.21 ผลการทดลองและสถิติของข้อมูล pigs โดยใช้ Jordan Recurrent NN.

Jordan Recurrent NN. แบบใช้ค่าน้ำหนักเพียงค่าเดียว (JRNN)										Jordan Recurrent NN. แบบใช้ค่าน้ำหนักแบบเซกเมนต์ (MSJRNN)										
H	1	2	3	4	5	max	min	mean	SD	1	2	3	4	5	max	min	mean	SD	re(%)	
1	0.114150	0.113860	0.113420	0.113460	0.117840	0.11342	0.11342	0.11399	0.002	0.118130	0.118000	0.118000	0.118300	0.118170	0.118300	0.118000	0.118100	0.000	3.75	
2	0.113580	0.114950	0.174180	0.113850	0.118470	0.11358	0.11358	0.11550	0.026	0.112700	0.118000	0.114000	0.114390	0.117980	0.111800	0.112700	0.114400	0.002	-0.49	
3	0.125160	0.115460	0.117980	0.118400	0.125160	0.12516	0.11546	0.11840	0.004	0.118010	0.113000	0.118000	0.118320	0.113950	0.118320	0.111000	0.118000	0.003	-0.34	
4	0.114180	0.114490	0.113460	0.116820	0.173980	0.11418	0.11346	0.11445	0.027	0.118360	0.115000	0.118000	0.113910	0.113420	0.118360	0.113420	0.115000	0.002	0.45	
5	0.133130	0.115460	0.116530	0.118620	0.116230	0.13313	0.11546	0.11653	0.007	0.119310	0.114000	0.114000	0.118220	0.118520	0.119310	0.114000	0.118200	0.003	1.45	
6	0.115250	0.115800	0.119110	0.166840	0.130550	0.11525	0.11525	0.11911	0.022	0.118600	0.119000	0.118000	0.118670	0.116650	0.111900	0.116650	0.118600	0.001	-0.43	
7	0.115420	0.150540	0.138620	0.117750	0.120270	0.11542	0.11542	0.12003	0.015	0.114750	0.115000	0.116000	0.115440	0.112850	0.111600	0.112850	0.115000	0.001	-4.38	
8	0.120610	0.121340	0.117460	0.130370	0.127810	0.12061	0.11746	0.12134	0.005	0.114630	0.119000	0.116000	0.116540	0.120530	0.120530	0.114630	0.116500	0.002	-3.96	
9	0.134420	0.144480	0.165320	0.121620	0.115250	0.13442	0.11525	0.13444	0.020	0.118600	0.121000	0.119000	0.116410	0.110560	0.121000	0.110560	0.118600	0.004	-11.77	
10	0.120610	0.121940	0.122430	0.156370	0.121490	0.12061	0.12061	0.12190	0.016	0.120770	0.113000	0.112000	0.121040	0.114620	0.121040	0.113000	0.120000	0.004	-1.59	
11	0.114690	0.125120	0.122400	0.125070	0.115420	0.11469	0.11469	0.12240	0.005	0.116780	0.121000	0.121000	0.118810	0.117590	0.121000	0.117590	0.118800	0.002	-2.93	
12	0.125760	0.123400	0.180070	0.124860	0.145190	0.12576	0.12340	0.12580	0.024	0.117910	0.119000	0.116000	0.117230	0.119000	0.119000	0.117910	0.117900	0.001	-6.24	
13	0.123710	0.116230	0.163520	0.123910	0.122220	0.12371	0.11623	0.12370	0.019	0.117390	0.112000	0.116000	0.122390	0.120350	0.122390	0.116000	0.120000	0.003	-3.00	
14	0.153540	0.118080	0.127960	0.122400	0.145190	0.15354	0.11808	0.12800	0.015	0.121300	0.123000	0.119000	0.119140	0.122570	0.123000	0.121300	0.121300	0.002	-5.20	
15	0.165560	0.130060	0.125160	0.127810	0.162490	0.16556	0.12516	0.13001	0.020	0.117320	0.119000	0.116000	0.117750	0.119290	0.119290	0.116000	0.117500	0.001	-9.66	
16	0.128280	0.122220	0.125120	0.125120	0.165560	0.12828	0.12222	0.12510	0.018	0.119730	0.117000	0.119000	0.120340	0.119740	0.120340	0.117000	0.119700	0.001	-4.31	
17	0.164100	0.127080	0.128900	0.127170	0.127960	0.16410	0.12708	0.12800	0.016	0.122900	0.119000	0.123000	0.115540	0.116540	0.123000	0.115540	0.119000	0.003	-7.00	
18	0.117460	0.118080	0.135180	0.130370	0.162310	0.11746	0.13040	0.018	0.122150	0.121000	0.120000	0.123350	0.125690	0.125690	0.120000	0.122200	0.122200	0.002	-6.31	
19	0.130680	0.135290	0.131310	0.130550	0.128280	0.13068	0.12828	0.13007	0.003	0.121150	0.116000	0.120000	0.120900	0.116550	0.121150	0.116000	0.120000	0.002	-8.17	
20	0.130680	0.163520	0.180070	0.174180	0.121620	0.13068	0.12162	0.16350	0.026	0.117520	0.116000	0.119000	0.113760	0.117310	0.119000	0.113760	0.117300	0.002	-28.26	
21	0.160750	0.134420	0.139350	0.117460	0.142430	0.16075	0.13940	0.016	0.120720	0.118000	0.124000	0.117830	0.120420	0.124000	0.120420	0.117830	0.120400	0.003	-13.58	
22	0.133130	0.136340	0.121620	0.144480	0.143180	0.13313	0.12162	0.13630	0.009	0.120550	0.113000	0.119000	0.119390	0.119390	0.120550	0.113000	0.119400	0.003	-12.43	
23	0.174180	0.138620	0.116230	0.115420	0.114180	0.17418	0.11418	0.11620	0.026	0.121890	0.122000	0.122000	0.120420	0.120420	0.122000	0.120420	0.121900	0.001	4.87	
24	0.142430	0.159230	0.116230	0.155300	0.127810	0.14243	0.11623	0.14240	0.018	0.123790	0.123000	0.124000	0.120750	0.124180	0.124180	0.120750	0.123800	0.001	-13.09	
25	0.163160	0.153570	0.123400	0.139350	0.114690	0.16316	0.11469	0.13940	0.020	0.120990	0.122000	0.121000	0.113870	0.124280	0.124280	0.113870	0.121000	0.004	-13.17	
26	0.138620	0.143190	0.146690	0.127080	0.158950	0.13862	0.12708	0.14320	0.012	0.118020	0.122000	0.119000	0.123320	0.123320	0.123320	0.118020	0.122000	0.002	-14.80	
27	0.125160	0.139350	0.155300	0.115250	0.145190	0.12516	0.11525	0.13940	0.016	0.120920	0.124000	0.121000	0.125490	0.121430	0.125490	0.120920	0.121400	0.002	-12.86	
28	0.166840	0.162310	0.164100	0.156370	0.153570	0.16684	0.15357	0.16230	0.006	0.118340	0.123000	0.121000	0.122830	0.123050	0.123050	0.118340	0.122800	0.002	-24.32	
29	0.147300	0.145580	0.130680	0.113580	0.145610	0.14730	0.11358	0.14560	0.015	0.123200	0.126000	0.123000	0.120220	0.125020	0.126000	0.123200	0.123200	0.002	-15.37	
30	0.164100	0.147340	0.144480	0.158950	0.162310	0.16410	0.14448	0.15900	0.009	0.124810	0.124000	0.124000	0.124140	0.124140	0.124140	0.124000	0.124100	0.000	-21.93	
31	0.164100	0.165810	0.165320	0.144480	0.163160	0.16410	0.14448	0.16410	0.009	0.124390	0.124000	0.122000	0.123910	0.122290	0.124390	0.122000	0.123900	0.001	-24.49	
32	0.173980	0.145190	0.127170	0.113490	0.166210	0.17398	0.11349	0.14520	0.025	0.125110	0.121000	0.123000	0.125110	0.123390	0.125110	0.121000	0.123400	0.002	-15.01	
33	0.163160	0.150540	0.165320	0.162310	0.145580	0.16316	0.14558	0.16230	0.009	0.129790	0.127000	0.129000	0.120890	0.126500	0.129790	0.120890	0.127000	0.003	-21.75	
34	0.156220	0.156370	0.159570	0.155300	0.115250	0.15622	0.11525	0.15620	0.019	0.124360	0.127000	0.128000	0.127310	0.123170	0.128000	0.123170	0.127000	0.002	-18.70	
35	0.154400	0.146020	0.127810	0.153540	0.153540	0.15440	0.12781	0.15350	0.011	0.130650	0.127000	0.134000	0.126870	0.125550	0.134000	0.125550	0.127000	0.003	-17.29	
36	0.127080	0.128280	0.150540	0.130550	0.159230	0.12708	0.12708	0.13060	0.015	0.126630	0.127000	0.120000	0.124670	0.120270	0.127000	0.120270	0.124700	0.003	-4.50	
37	0.113580	0.156370	0.138620	0.125160	0.158450	0.11358	0.13860	0.019	0.128780	0.128000	0.127000	0.128470	0.128460	0.128780	0.127000	0.128500	0.001	-7.33		
38	0.166210	0.165090	0.115420	0.159570	0.138620	0.16621	0.11542	0.15960	0.022	0.128710	0.125000	0.126000	0.132840	0.128440	0.132840	0.125000	0.128400	0.003	-19.51	
39	0.142430	0.128280	0.160750	0.163160	0.156220	0.14243	0.12828	0.15620	0.015	0.119980	0.123000	0.129000	0.126340	0.119340	0.129000	0.119340	0.123000	0.004	-21.26	
40	0.130550	0.158450	0.159570	0.145580	0.133130	0.13055	0.13055	0.14560	0.014	0.129800	0.129000	0.130000	0.129800	0.126500	0.130000	0.126500	0.129800	0.001	-10.84	
41	0.135180	0.159230	0.163000	0.159570	0.158950	0.13518	0.15920	0.011	0.130350	0.130000	0.122000	0.119580	0.130970	0.130970	0.119580	0.130000	0.005	-18.36		
42	0.165810	0.127960	0.135180	0.166840	0.130370	0.16581	0.12796	0.13520	0.019	0.126570	0.131000	0.112000	0.120880	0.127290	0.131000	0.112000	0.126600	0.007	-6.37	
43	0.174180	0.169070	0.165090	0.114690	0.127170	0.17418	0.11469	0.16510	0.027	0.126300	0.128000	0.119000	0.127470	0.131410	0.131410	0.119000	0.127500	0.005	-22.79	
44	0.150540	0.113580	0.146020	0.165810	0.125160	0.15054	0.11358	0.14600	0.021	0.132070	0.133000	0.131000	0.128550	0.128550	0.133000	0.128550	0.131000	0.002	-10.29	
45	0.175910	0.162490	0.146020	0.114690	0.165320	0.17591	0.11469	0.16250	0.024	0.128810	0.133000	0.131000	0.134760	0.135000	0.135000	0.128810	0.133000	0.003	-18.15	
46	0.127080	0.173980	0.134420	0.180070	0.186510	0.12708	0.17400	0.028	0.119960	0.132000	0.125000	0.123730	0.129000	0.132000	0.119960	0.125000	0.005	-28.15		
47	0.158950	0.127080	0.120610	0.115460	0.163520	0.15895	0.11546	0.12710	0.022	0.125610	0.133000	0.133000	0.128420	0.133000	0.133000	0.125610	0.133000	0.003	4.66	
48	0.139350	0.183430	0.179050	0.165560	0.176310	0.13935	0.13935	0.17630	0.018	0.129580	0.135000	0.135000	0.129640	0.137000	0.137000	0.129580	0.135000	0.003	-23.43	
49	0.164100	0.165810	0.118080	0.185910	0.175390	0.16410	0.11808	0.16580	0.026	0.129970	0.121000	0.135000	0.133370	0.132000	0.135000	0.121000	0.132000	0.005	-20.3	

ตารางที่ ก.22 ผลการทดลองและสถิติของข้อมูล rawsteel โดยใช้ Feed forward NN.

H	Feed forward NN. แบบใช้ค่าน้ำหนักแบบค่าเต็ม (FNN)							Feed forward NN. แบบใช้ค่าน้ำหนักแบบเซกเมนต์ (MSFNN)							re(%)					
	1	2	3	4	5	max	min	mean	SD	1	2	3	4	5		max	min	mean	SD	
1	0.1117	0.10235	0.1103	0.1064	0.10886	0.11117	0.10235	0.1090	0.004	0.09444	0.09444	0.09444	0.09444	0.09447	0.09452	0.09452	0.09444	0.0944	0.000	-13.33
2	0.09494	0.10661	0.11096	0.10418	0.11772	0.11772	0.09494	0.1066	0.008	0.09429	0.09487	0.09188	0.09406	0.09471	0.09487	0.09188	0.0943	0.001	0.001	-11.56
3	0.0963	0.09372	0.09372	0.10386	0.111	0.111	0.09372	0.0963	0.008	0.09288	0.09033	0.09351	0.09351	0.09312	0.09351	0.09033	0.0931	0.001	0.001	-3.30
4	0.10234	0.11117	0.11716	0.10897	0.09999	0.11716	0.09999	0.1090	0.007	0.09601	0.0918	0.09641	0.09477	0.09489	0.09641	0.0918	0.0949	0.002	0.002	-12.92
5	0.09974	0.10711	0.10896	0.10211	0.11837	0.11837	0.09974	0.1071	0.007	0.09694	0.09907	0.09907	0.09781	0.09683	0.09907	0.09683	0.0978	0.001	0.001	-8.68
6	0.09886	0.10724	0.09569	0.11968	0.10212	0.11968	0.09569	0.1021	0.009	0.09888	0.09545	0.09558	0.09545	0.09911	0.09911	0.09545	0.0956	0.002	0.002	-6.40
7	0.10534	0.1064	0.09886	0.09494	0.09999	0.1064	0.09494	0.1000	0.005	0.09497	0.09715	0.09267	0.10056	0.09497	0.10056	0.09267	0.0950	0.003	0.003	-5.02
8	0.09937	0.11772	0.09886	0.10438	0.10534	0.11772	0.09886	0.1044	0.008	0.10088	0.1003	0.09544	0.09923	0.09577	0.10088	0.09544	0.0992	0.003	0.003	-4.93
9	0.10418	0.10419	0.11837	0.10418	0.10211	0.11837	0.10211	0.1042	0.007	0.09917	0.09916	0.09678	0.10296	0.09666	0.10296	0.09666	0.0992	0.003	0.003	-4.82
10	0.10251	0.10251	0.11148	0.1088	0.11651	0.11651	0.10251	0.1088	0.006	0.09717	0.10168	0.10932	0.10189	0.10168	0.10932	0.09717	0.1017	0.004	0.004	-6.54
11	0.10234	0.10627	0.11161	0.09557	0.11117	0.11161	0.09557	0.1063	0.007	0.09747	0.10012	0.09568	0.09829	0.0977	0.10012	0.09568	0.0977	0.002	0.002	-8.06
12	0.10374	0.10589	0.10235	0.1088	0.10703	0.1088	0.10235	0.1059	0.003	0.10169	0.10055	0.09839	0.10131	0.09838	0.10169	0.09838	0.1006	0.002	0.002	-5.04
13	0.10720	0.11013	0.10557	0.10572	0.10573	0.11013	0.10557	0.1057	0.002	0.10019	0.1063	0.10128	0.10693	0.10635	0.10693	0.10019	0.1063	0.003	0.003	0.55
14	0.1081	0.10661	0.10631	0.10573	0.11968	0.11968	0.10573	0.1066	0.006	0.10322	0.10179	0.10236	0.10444	0.09901	0.10444	0.09901	0.1024	0.002	0.002	-3.99
15	0.10711	0.11211	0.1077	0.10572	0.10527	0.11211	0.10527	0.1071	0.003	0.10336	0.10272	0.10228	0.0991	0.1026	0.10336	0.0991	0.1026	0.002	0.002	-4.21
16	0.10901	0.10923	0.10724	0.10724	0.11097	0.11097	0.10724	0.1090	0.002	0.10342	0.10342	0.10473	0.10342	0.10276	0.10473	0.10276	0.1034	0.001	0.001	-5.13
17	0.10703	0.10703	0.11148	0.11716	0.1064	0.11716	0.1064	0.1070	0.005	0.1029	0.10427	0.10077	0.10427	0.10092	0.10427	0.10077	0.1029	0.002	0.002	-3.86
18	0.10832	0.11013	0.111	0.11142	0.10374	0.11142	0.10374	0.1101	0.003	0.10741	0.10483	0.10506	0.10506	0.10506	0.10741	0.10483	0.1051	0.001	0.001	-4.60
19	0.10759	0.10759	0.10912	0.10557	0.11083	0.11083	0.10557	0.1076	0.002	0.10696	0.10647	0.10696	0.10307	0.10681	0.10696	0.10307	0.1068	0.002	0.002	-0.72
20	0.10703	0.10897	0.1211	0.11053	0.10631	0.1211	0.10631	0.1090	0.006	0.10465	0.10665	0.10426	0.1075	0.10464	0.1075	0.10426	0.1047	0.001	0.001	-3.96
21	0.10832	0.09569	0.10534	0.11096	0.11022	0.1096	0.09569	0.1083	0.006	0.10763	0.10391	0.10532	0.10786	0.10786	0.10786	0.10391	0.1076	0.002	0.002	-0.64
22	0.09937	0.11138	0.11837	0.10912	0.10631	0.11837	0.09937	0.1091	0.007	0.10847	0.09939	0.10572	0.10838	0.10838	0.10947	0.09939	0.1084	0.004	0.004	-0.68
23	0.11188	0.10912	0.10639	0.11695	0.10910	0.11695	0.10639	0.1091	0.004	0.10869	0.10959	0.10869	0.10437	0.10571	0.10959	0.10437	0.1087	0.002	0.002	-0.39
24	0.1103	0.1211	0.1088	0.1109	0.10724	0.1211	0.10724	0.1103	0.005	0.10874	0.10958	0.09985	0.11153	0.11503	0.11503	0.09985	0.1096	0.006	0.006	-0.65
25	0.10874	0.11148	0.10374	0.11968	0.09557	0.11968	0.09557	0.1087	0.009	0.10584	0.10884	0.10584	0.10884	0.10884	0.10884	0.10584	0.1058	0.002	0.002	-2.67
26	0.10874	0.11083	0.1117	0.11651	0.11901	0.11901	0.10874	0.1117	0.004	0.10599	0.10903	0.10903	0.10918	0.10599	0.10918	0.10599	0.1090	0.002	0.002	-2.39
27	0.11607	0.11096	0.11117	0.09557	0.10251	0.11607	0.09557	0.1110	0.008	0.10962	0.10647	0.10962	0.10981	0.10962	0.10981	0.10962	0.10981	0.004	0.004	-1.21
28	0.10418	0.10703	0.11968	0.10527	0.12592	0.12592	0.10418	0.1070	0.010	0.10329	0.10909	0.10360	0.11022	0.11018	0.11036	0.10329	0.1102	0.003	0.003	2.94
29	0.12175	0.10711	0.11278	0.10211	0.09494	0.12175	0.09494	0.1071	0.010	0.11085	0.11217	0.11399	0.10791	0.11196	0.11399	0.10791	0.1120	0.002	0.002	4.53
30	0.11772	0.11083	0.10759	0.10631	0.10912	0.11772	0.10631	0.1091	0.004	0.10222	0.10049	0.11315	0.11258	0.11175	0.11315	0.10049	0.1118	0.006	0.006	2.41
31	0.10896	0.11651	0.11138	0.11905	0.10711	0.11905	0.10711	0.1114	0.005	0.11413	0.11427	0.11414	0.11209	0.11335	0.11427	0.11414	0.1134	0.001	0.001	1.77
32	0.11097	0.10724	0.12315	0.1138	0.1211	0.12315	0.10724	0.1114	0.007	0.11014	0.10314	0.1089	0.11235	0.11191	0.11235	0.10314	0.1101	0.004	0.004	-1.11
33	0.11837	0.10832	0.10912	0.11716	0.1088	0.11837	0.10832	0.1091	0.005	0.11301	0.11161	0.11273	0.11221	0.11214	0.11301	0.11161	0.1122	0.001	0.001	2.83
34	0.11161	0.11278	0.11769	0.10896	0.10573	0.11769	0.10573	0.1116	0.004	0.11211	0.11211	0.1121	0.11065	0.1121	0.11211	0.11065	0.1121	0.001	0.001	0.44
35	0.09886	0.12495	0.11757	0.11018	0.12495	0.09886	0.11757	0.1114	0.010	0.11286	0.10903	0.11286	0.10413	0.11047	0.11286	0.10413	0.1105	0.004	0.004	-0.85
36	0.10832	0.11968	0.10374	0.12175	0.11278	0.12175	0.10374	0.1128	0.008	0.11812	0.11627	0.11109	0.11152	0.11437	0.11812	0.11109	0.1144	0.003	0.003	1.41
37	0.12054	0.11196	0.111	0.1117	0.11018	0.12054	0.11018	0.1117	0.004	0.11861	0.1043	0.11132	0.11314	0.11869	0.11869	0.1043	0.1131	0.006	0.006	1.29
38	0.10235	0.1117	0.09557	0.10534	0.11013	0.1117	0.09557	0.1053	0.006	0.11374	0.11331	0.11417	0.11231	0.11271	0.11417	0.11231	0.1133	0.001	0.001	7.57
39	0.11053	0.12605	0.10711	0.11837	0.10418	0.12605	0.10418	0.1105	0.009	0.11442	0.11236	0.11368	0.11382	0.11348	0.11442	0.11236	0.1137	0.001	0.001	2.85
40	0.11097	0.1077	0.10703	0.10874	0.09569	0.11097	0.09569	0.1077	0.006	0.11531	0.1148	0.11418	0.11481	0.1148	0.11531	0.11481	0.1148	0.000	0.000	6.59
41	0.11211	0.12271	0.11278	0.11858	0.1269	0.1269	0.11211	0.1186	0.006	0.11455	0.11548	0.1153	0.11003	0.11428	0.11548	0.11003	0.1146	0.002	0.002	-3.40
42	0.1103	0.12175	0.11097	0.10703	0.12592	0.12592	0.1103	0.1110	0.008	0.11551	0.11545	0.11586	0.11598	0.11433	0.11598	0.11433	0.1155	0.001	0.001	4.09
43	0.11275	0.1077	0.09569	0.11013	0.111	0.11275	0.09569	0.1101	0.007	0.1068	0.11704	0.11704	0.11253	0.11704	0.11704	0.1068	0.1170	0.005	0.005	6.27
44	0.12592	0.10527	0.11187	0.12560	0.10235	0.12592	0.10235	0.1119	0.011	0.11842	0.11624	0.11842	0.11517	0.11595	0.11842	0.11517	0.1162	0.001	0.001	3.91
45	0.10557	0.11544	0.12914	0.13368	0.11326	0.13368	0.10557	0.1154	0.012	0.11959	0.11444	0.11711	0.11607	0.11491	0.11959	0.11444	0.1161	0.002	0.002	0.55
46	0.1103	0.10759	0.1211	0.11292	0.11253	0.1211	0.10759	0.1125	0.005	0.11515	0.12047	0.11344	0.10652	0.11804	0.12047	0.10652	0.1152	0.005	0.005	2.33
47	0.10251	0.09999	0.11053	0.10534	0.11083	0.11083	0.09999	0.1053	0.005	0.12293	0.11124	0.11696	0.12136	0.12293	0.12293	0.11124	0.1214	0.005	0.005	15.21
48	0.1318	0.13017	0.12808	0.1211	0.11395	0.1318	0.1211	0.1281	0.013	0.11469	0.11779	0.11947	0.11632	0.11739	0.11947	0.11632	0.1174	0.002	0.002	-8.35
49	0.11467	0.09999	0.10211	0.11689	0.11651	0.11689	0.09999	0.1147	0.008	0.1152	0.11646	0.11527	0.11378	0.11741	0.11741	0.11378	0.1153	0.001	0.001	0.52
50	0.11461	0.12592	0.10901	0.10724	0.11018	0.12592	0.10724	0.1102	0.008	0.11684	0.11361	0.11981	0.11677	0.11366	0.11981	0.11361	0.1166	0.003	0.003	5.86
A=0.134 B=0.09372 C=0.109 C=0.006																				
A=0.123 B=0.09033 C=0.109 C=0.00																				

ตารางที่ ก.23 ผลการทดลองและสถิติของข้อมูล rawsteel โดยใช้ Elman Recurrent NN.

Elman Recurrent NN, แบบใช้ค่าน้ำหนักเพิ่มค่าเดิม (ERNN)										Elman Recurrent NN, แบบใช้ค่าน้ำหนักแบบเซกเมนต์ (MSERNN)										re(%)
H	1	2	3	4	5	max	min	mean	SD	1	2	3	4	5	max	min	mean	SD		
1	0.116430	0.103560	0.092560	0.108180	0.100410	0.116430	0.092560	0.1036	0.009	0.09318	0.09333	0.09197	0.09336	0.0926	0.09336	0.09197	0.0932	0.001	-10.02	
2	0.091780	0.091310	0.091780	0.093610	0.090810	0.093610	0.090810	0.0918	0.001	0.08804	0.08804	0.08804	0.09106	0.09106	0.09106	0.08804	0.0880	0.002	-4.07	
3	0.100510	0.099240	0.096760	0.098890	0.097720	0.100510	0.096760	0.0989	0.001	0.09071	0.09419	0.09381	0.08898	0.09216	0.09419	0.08898	0.0922	0.002	-6.81	
4	0.093790	0.090560	0.090790	0.091210	0.090790	0.093790	0.090560	0.0908	0.001	0.09477	0.09381	0.088	0.09087	0.09381	0.09477	0.088	0.0938	0.003	3.33	
5	0.099320	0.093110	0.099120	0.095180	0.095010	0.099320	0.093110	0.0952	0.003	0.09508	0.091	0.09489	0.0948	0.09485	0.09508	0.091	0.0949	0.002	-0.35	
6	0.094560	0.094560	0.091620	0.090660	0.094560	0.094560	0.090660	0.0946	0.002	0.09294	0.09294	0.09295	0.088750	0.09241	0.09295	0.08875	0.0929	0.002	-1.71	
7	0.098250	0.098190	0.096650	0.098190	0.094960	0.098250	0.094960	0.0982	0.001	0.09861	0.09072	0.09494	0.096120	0.090790	0.09861	0.09072	0.0949	0.003	-3.31	
8	0.093410	0.095480	0.0959	0.096340	0.092980	0.096340	0.092980	0.0955	0.002	0.09956	0.095430	0.099940	0.100460	0.100250	0.100460	0.09543	0.0999	0.002	4.67	
9	0.105370	0.098290	0.097720	0.099770	0.098620	0.105370	0.097720	0.0986	0.003	0.09969	0.097790	0.094170	0.098680	0.096690	0.09969	0.09417	0.0978	0.002	-0.84	
10	0.0976	0.0963	0.097180	0.096610	0.0976	0.0976	0.0963	0.0972	0.001	0.09384	0.098660	0.098720	0.093840	0.098080	0.09872	0.09384	0.0981	0.003	0.93	
11	0.107090	0.099990	0.105370	0.099260	0.103530	0.107090	0.099260	0.1035	0.003	0.09961	0.097920	0.094050	0.096980	0.098950	0.09961	0.09405	0.0979	0.002	-5.42	
12	0.098160	0.098160	0.098450	0.098160	0.097860	0.098160	0.097860	0.0985	0.000	0.09875	0.093540	0.094060	0.0982	0.093540	0.09875	0.09354	0.0941	0.003	-4.18	
13	0.10041	0.101	0.099670	0.10637	0.101	0.10637	0.09967	0.1010	0.003	0.12847	0.102710	0.106610	0.099890	0.107030	0.12847	0.09989	0.1066	0.011	5.55	
14	0.09676	0.0988	0.098620	0.094240	0.09676	0.0988	0.09424	0.0968	0.002	0.10263	0.100460	0.102570	0.102430	0.100480	0.10263	0.10046	0.1024	0.011	5.86	
15	0.106970	0.105090	0.101030	0.101690	0.0995	0.106970	0.0995	0.1017	0.003	0.10557	0.106160	0.1014	0.100850	0.100720	0.106160	0.10072	0.1014	0.003	-0.29	
16	0.0982	0.094270	0.099420	0.099960	0.099420	0.099960	0.094270	0.0994	0.002	0.09962	0.104950	0.103250	0.107370	0.106610	0.107370	0.09962	0.1050	0.003	5.56	
17	0.102830	0.100510	0.103470	0.1094	0.10941	0.102830	0.100510	0.1035	0.004	0.11004	0.1068	0.102330	0.110190	0.105070	0.110190	0.10233	0.1068	0.003	3.22	
18	0.096050	0.099530	0.102930	0.099030	0.101840	0.102930	0.099030	0.0995	0.003	0.09868	0.098520	0.103180	0.099390	0.098520	0.103180	0.09852	0.0987	0.002	-0.85	
19	0.1028	0.102770	0.106880	0.099740	0.102020	0.106880	0.099740	0.1028	0.003	0.10092	0.102260	0.1034	0.105380	0.092250	0.105380	0.09225	0.1023	0.005	-0.50	
20	0.103510	0.103980	0.094290	0.1011	0.104250	0.103510	0.094290	0.1035	0.004	0.10051	0.099550	0.102180	0.097170	0.099330	0.102180	0.09717	0.0996	0.002	-3.83	
21	0.103040	0.109460	0.1074	0.1043	0.108430	0.109460	0.10430	0.1074	0.003	0.10698	0.106610	0.099640	0.098420	0.111770	0.111770	0.09842	0.1066	0.006	-0.74	
22	0.10356	0.1039	0.10865	0.0949	0.108890	0.10356	0.0949	0.1039	0.006	0.11123	0.104660	0.101180	0.103640	0.102270	0.111230	0.10118	0.1036	0.004	-2.25	
23	0.112220	0.111120	0.105980	0.108130	0.108750	0.112220	0.105980	0.1088	0.002	0.10287	0.106820	0.105930	0.104670	0.105880	0.106820	0.10287	0.1059	0.002	-2.64	
24	0.1105	0.1106	0.109310	0.108180	0.1105	0.1106	0.108180	0.1105	0.001	0.10727	0.110260	0.107270	0.105680	0.107160	0.110260	0.10568	0.1073	0.002	-2.92	
25	0.1104	0.1115	0.104480	0.103920	0.10675	0.1115	0.103920	0.1068	0.003	0.10781	0.108740	0.108390	0.109930	0.109950	0.109950	0.107610	0.1087	0.001	1.86	
26	0.114150	0.111180	0.113	0.106780	0.113	0.114150	0.106780	0.1130	0.003	0.10997	0.102740	0.108930	0.109270	0.104960	0.109970	0.102740	0.1089	0.003	-3.60	
27	0.114150	0.107620	0.106750	0.110180	0.106350	0.114150	0.106350	0.1076	0.003	0.10399	0.109290	0.107220	0.111990	0.104590	0.111990	0.10399	0.1072	0.003	-0.37	
28	0.1075	0.109330	0.115240	0.115240	0.115940	0.115940	0.1075	0.1152	0.004	0.11016	0.104170	0.109930	0.097580	0.107240	0.110160	0.09758	0.1072	0.005	-6.94	
29	0.119660	0.1166	0.11660	0.116050	0.113400	0.119660	0.11660	0.1166	0.003	0.10773	0.108210	0.105320	0.103430	0.107970	0.108210	0.103430	0.1073	0.002	-7.98	
30	0.125290	0.106830	0.117810	0.121270	0.121270	0.125290	0.106830	0.1213	0.007	0.11133	0.117080	0.109430	0.102610	0.105870	0.117080	0.102610	0.1094	0.006	-9.76	
31	0.116430	0.126010	0.096050	0.120090	0.120090	0.126010	0.096050	0.1201	0.012	0.10778	0.112	0.099850	0.106250	0.120840	0.120840	0.099850	0.1078	0.008	-10.25	
32	0.123290	0.120890	0.118660	0.123290	0.124290	0.123290	0.118660	0.1233	0.002	0.117820	0.112290	0.11	0.122610	0.1344	0.1344	0.11	0.1178	0.010	-4.44	
33	0.120880	0.094270	0.120880	0.109330	0.122250	0.122250	0.094270	0.1209	0.012	0.113630	0.111570	0.107580	0.107580	0.114660	0.114660	0.107580	0.1116	0.003	-7.70	
34	0.125720	0.1252	0.109770	0.1252	0.114420	0.125720	0.109770	0.1252	0.008	0.137110	0.097190	0.122380	0.105740	0.116020	0.137110	0.097190	0.1160	0.015	-7.33	
35	0.108630	0.111180	0.123620	0.094240	0.108150	0.123620	0.094240	0.1086	0.010	0.111790	0.116520	0.105390	0.097950	0.112540	0.116520	0.097950	0.1118	0.007	2.91	
36	0.1256	0.1256	0.122530	0.117440	0.126340	0.126340	0.117440	0.1256	0.004	0.10816	0.116840	0.0973	0.110140	0.111230	0.116840	0.0973	0.1101	0.007	-12.31	
37	0.1075	0.101030	0.108150	0.126640	0.099740	0.126640	0.099740	0.1075	0.011	0.109550	0.131020	0.108340	0.116470	0.120030	0.131020	0.108340	0.1165	0.009	8.34	
38	0.117810	0.123620	0.125260	0.111180	0.131510	0.131510	0.111180	0.1236	0.008	0.119590	0.143250	0.104840	0.1072	0.143250	0.143250	0.104840	0.1196	0.015	-3.26	
39	0.103920	0.109310	0.1011	0.094240	0.139330	0.139330	0.094240	0.1039	0.017	0.122620	0.105970	0.122620	0.119840	0.104870	0.122620	0.104870	0.1198	0.009	15.32	
40	0.114170	0.0995	0.137790	0.103040	0.110880	0.137790	0.0995	0.1109	0.015	0.133330	0.149260	0.118900	0.115580	0.116520	0.149260	0.111890	0.1165	0.016	5.09	
41	0.108630	0.118660	0.120090	0.0963	0.111710	0.120090	0.0963	0.1117	0.010	0.114670	0.120680	0.100950	0.100190	0.118760	0.120680	0.100190	0.1147	0.010	2.65	
42	0.101030	0.094270	0.141280	0.104480	0.1075	0.141280	0.094270	0.1045	0.018	0.100040	0.117330	0.125470	0.122940	0.115150	0.125470	0.100040	0.1173	0.010	12.30	
43	0.154090	0.117660	0.147470	0.115330	0.090810	0.154090	0.090810	0.1177	0.026	0.102340	0.121050	0.1269	0.125320	0.1274	0.1269	0.102340	0.1211	0.010	2.88	
44	0.1043	0.109770	0.117440	0.141020	0.123710	0.141020	0.1043	0.1174	0.014	0.115330	0.114680	0.148060	0.155610	0.110750	0.155610	0.110750	0.1153	0.021	-1.80	
45	0.117810	0.1192	0.093110	0.090660	0.110690	0.1192	0.090660	0.1107	0.014	0.110350	0.105740	0.112990	0.132090	0.096430	0.132090	0.096430	0.1104	0.013	-0.31	
46	0.109770	0.108150	0.096760	0.096610	0.157840	0.157840	0.096610	0.1082	0.025	0.109210	0.109450	0.125170	0.124420	0.119530	0.125170	0.109210	0.1195	0.008	10.52	
47	0.108630	0.120090	0.144470	0.145510	0.0995	0.145510	0.0995	0.1201	0.021	0.111980	0.109830	0.105860	0.109030	0.110060	0.111980	0.105860	0.1098	0.002	-8.54	
48	0.132750	0.098160	0.136260	0.151430	0.149560	0.151430	0.098160	0.1363	0.021	0.105870	0.109080	0.118170	0.122070	0.1115	0.122070	0.105870	0.1115	0.007	-18.17	
49	0.097860	0.098160	0.099990	0.102660	0.109330	0.109330	0.097860	0.1000	0.005	0.106950	0.095950	0.119170	0.100110	0.105950	0.119170	0.095950	0.1060	0.009	5.96	
50	0.108130	0.109310	0.099260	0.0949	0.0982	0.109310	0.0949	0.0993	0.006	0.113190	0.0987	0.112090	0.104970	0.091690	0.113190	0.091690	0.1050	0.009	5.75	

H - จำนวนโหนดในชั้นซ่อน
 max - ค่าผิดพลาด (RMSE) มากที่สุดจากการทดลอง 5 ครั้ง

ตารางที่ ค.24 ผลการทดลองและสถิติของข้อมูล rawsteel โดยใช้ Jordan Recurrent NN.

Jordan Recurrent NN. แบบใช้ค่าน้ำหนักเพียงค่าเดียว (JRNN)										Jordan Recurrent NN. แบบใช้ค่าน้ำหนักแบบแยกกัน (MSJRNN)										
H	1	2	3	4	5	max	min	mean	SD	1	2	3	4	5	max	min	mean	SD	re(%)	
1	0.09717	0.10427	0.10907	0.1027	0.11644	0.11644	0.09717	0.1043	0.007	0.09466	0.09451	0.09454	0.09454	0.09468	0.09468	0.09451	0.0945	0.004	-9.33	
2	0.09868	0.11182	0.11031	0.09608	0.12128	0.12128	0.09608	0.1103	0.010	0.09319	0.09172	0.09469	0.09424	0.09383	0.09469	0.09172	0.0938	0.001	-14.94	
3	0.0989	0.10254	0.09463	0.10182	0.10875	0.10875	0.09463	0.1018	0.005	0.09483	0.09498	0.09042	0.09498	0.09487	0.09498	0.09042	0.0949	0.002	-6.83	
4	0.0963	0.1052	0.09866	0.11158	0.09785	0.11158	0.0963	0.0987	0.006	0.09319	0.09524	0.09327	0.09338	0.09524	0.09524	0.09319	0.0934	0.001	-5.35	
5	0.10693	0.1112	0.10529	0.10641	0.10438	0.1112	0.10438	0.1064	0.003	0.09293	0.09275	0.09091	0.09495	0.09495	0.09495	0.09091	0.0929	0.002	-12.67	
6	0.10046	0.09578	0.12473	0.11353	0.1143	0.12473	0.09578	0.1135	0.012	0.09547	0.09547	0.09547	0.09547	0.09109	0.09547	0.09109	0.0955	0.002	-15.91	
7	0.10285	0.09648	0.11022	0.10044	0.11033	0.11033	0.09648	0.1029	0.006	0.09422	0.09955	0.09524	0.10033	0.09757	0.10033	0.09422	0.0976	0.003	-5.13	
8	0.0989	0.12284	0.1118	0.10033	0.11766	0.12284	0.0989	0.1118	0.011	0.09876	0.09886	0.10102	0.09935	0.09885	0.10102	0.09876	0.0989	0.001	-11.57	
9	0.11182	0.10673	0.10535	0.10872	0.10354	0.11182	0.10354	0.1067	0.003	0.09663	0.09667	0.095	0.0967	0.095	0.0967	0.095	0.0966	0.001	-9.46	
10	0.11238	0.09564	0.1051	0.10872	0.10718	0.11238	0.09564	0.1072	0.006	0.09888	0.09888	0.0989	0.09952	0.09547	0.09952	0.09547	0.0989	0.002	-7.74	
11	0.09648	0.09473	0.10903	0.1118	0.10518	0.1118	0.09473	0.1052	0.008	0.10067	0.1003	0.09772	0.10067	0.10018	0.10067	0.09772	0.1003	0.001	-4.64	
12	0.11644	0.11001	0.10912	0.1052	0.10586	0.11644	0.1052	0.1091	0.004	0.09829	0.09829	0.09829	0.0977	0.09836	0.09836	0.0977	0.0983	0.000	-9.92	
13	0.10869	0.1118	0.11033	0.0989	0.11001	0.1118	0.0989	0.1100	0.005	0.09858	0.10386	0.10385	0.10238	0.09771	0.10386	0.09771	0.1024	0.003	-6.94	
14	0.10701	0.11281	0.10667	0.11176	0.10667	0.11281	0.10667	0.1070	0.003	0.10451	0.10144	0.09859	0.10341	0.10451	0.10451	0.09859	0.1034	0.003	-3.36	
15	0.12284	0.10783	0.10586	0.10718	0.10821	0.12284	0.10586	0.1078	0.007	0.0992	0.10245	0.10245	0.10254	0.10254	0.10254	0.0992	0.1025	0.001	-4.99	
16	0.11021	0.10635	0.11003	0.1112	0.10739	0.1112	0.10635	0.1100	0.002	0.10266	0.10001	0.10275	0.10266	0.10275	0.10275	0.10001	0.1027	0.001	-6.70	
17	0.10641	0.10826	0.10655	0.10518	0.10759	0.10826	0.10518	0.1066	0.001	0.1042	0.10017	0.10106	0.10411	0.1042	0.1042	0.10017	0.1041	0.002	-2.29	
18	0.11353	0.10669	0.10628	0.10869	0.10933	0.11353	0.10628	0.1087	0.003	0.0989	0.10557	0.10198	0.1056	0.10453	0.1056	0.0989	0.1045	0.003	-3.83	
19	0.10698	0.10837	0.10693	0.0963	0.10986	0.10698	0.0963	0.1070	0.005	0.10307	0.10308	0.10655	0.1059	0.10307	0.10655	0.10307	0.1031	0.002	-3.65	
20	0.10903	0.10667	0.11277	0.11321	0.10998	0.11321	0.10667	0.1100	0.003	0.10191	0.10744	0.10744	0.1073	0.10694	0.10744	0.10191	0.1073	0.002	-2.44	
21	0.11358	0.10628	0.11208	0.11022	0.10885	0.11358	0.10628	0.1102	0.003	0.10776	0.10776	0.10756	0.10754	0.10559	0.10776	0.10559	0.1076	0.001	-2.41	
22	0.10837	0.11766	0.11321	0.10718	0.10628	0.11766	0.10628	0.1084	0.005	0.10577	0.1061	0.10577	0.10835	0.10967	0.10967	0.10577	0.1061	0.002	-2.09	
23	0.10641	0.10907	0.11182	0.10929	0.09648	0.11182	0.09648	0.1091	0.006	0.1076	0.10864	0.1076	0.10846	0.1076	0.10864	0.1076	0.1076	0.001	-1.35	
24	0.10635	0.11176	0.11299	0.11031	0.10885	0.11176	0.10635	0.1103	0.002	0.10549	0.10527	0.10527	0.10527	0.1068	0.1068	0.10527	0.1053	0.001	-4.57	
25	0.12473	0.10869	0.10929	0.10872	0.11062	0.12473	0.10869	0.1093	0.007	0.10624	0.10908	0.10591	0.10908	0.10591	0.10908	0.10591	0.1062	0.002	-2.79	
26	0.11326	0.11001	0.11299	0.11069	0.11001	0.11326	0.11001	0.1107	0.001	0.10805	0.10464	0.09968	0.10804	0.10754	0.10805	0.09968	0.1075	0.004	-2.85	
27	0.11155	0.11311	0.11131	0.1109	0.10907	0.11311	0.10907	0.1112	0.001	0.11049	0.11049	0.10663	0.10922	0.11089	0.11089	0.10663	0.1105	0.002	-0.59	
28	0.11338	0.10354	0.1112	0.10046	0.11238	0.11338	0.10046	0.1112	0.006	0.10966	0.11294	0.11104	0.11104	0.10967	0.11294	0.10966	0.1110	0.001	-0.14	
29	0.10518	0.11580	0.11326	0.11281	0.11326	0.11580	0.11281	0.11326	0.003	0.11081	0.11141	0.11141	0.11009	0.11009	0.11141	0.11009	0.1108	0.005	-1.77	
30	0.1118	0.11176	0.11069	0.12214	0.11481	0.12214	0.11069	0.1118	0.005	0.11154	0.11009	0.10608	0.11154	0.11154	0.11154	0.10608	0.1115	0.002	-0.23	
31	0.1052	0.1143	0.09578	0.10354	0.11208	0.1143	0.09578	0.1052	0.007	0.11351	0.11163	0.11217	0.1108	0.11346	0.11351	0.1108	0.1122	0.001	6.63	
32	0.11889	0.10912	0.10875	0.1112	0.11212	0.11889	0.10875	0.1111	0.004	0.11335	0.11283	0.11381	0.11403	0.1132	0.11403	0.1132	0.1134	0.001	2.01	
33	0.10903	0.12358	0.11188	0.10693	0.11644	0.12358	0.10693	0.1119	0.007	0.11263	0.11436	0.11059	0.11580	0.11237	0.11436	0.11059	0.1124	0.001	0.44	
34	0.09483	0.11580	0.11238	0.11176	0.10464	0.11580	0.09483	0.1116	0.008	0.11128	0.11083	0.11084	0.10984	0.11298	0.11298	0.10984	0.1108	0.001	-0.66	
35	0.10903	0.12284	0.11766	0.10929	0.09608	0.12284	0.09608	0.1138	0.010	0.11205	0.11227	0.10382	0.11227	0.11152	0.11227	0.10382	0.1121	0.004	2.53	
36	0.11182	0.11007	0.11243	0.11262	0.1109	0.11262	0.11007	0.1118	0.001	0.11378	0.11441	0.11378	0.11421	0.1161	0.11441	0.1161	0.1138	0.001	1.75	
37	0.11580	0.11353	0.10667	0.11321	0.11281	0.11580	0.10667	0.1128	0.003	0.11187	0.11253	0.1133	0.11346	0.11353	0.11353	0.11187	0.1133	0.001	0.43	
38	0.1138	0.12089	0.11031	0.09578	0.12256	0.12089	0.09578	0.1138	0.011	0.11354	0.11244	0.11546	0.11208	0.1135	0.11546	0.1135	0.1124	0.002	-1.20	
39	0.11172	0.12491	0.1141	0.10641	0.1213	0.12491	0.10641	0.1141	0.007	0.11572	0.10842	0.10882	0.11636	0.10832	0.11636	0.10842	0.1098	0.004	-3.75	
40	0.12128	0.12463	0.12521	0.12636	0.1281	0.12636	0.1281	0.1246	0.006	0.11481	0.11561	0.1154	0.11481	0.10554	0.11561	0.10554	0.1148	0.004	-7.88	
41	0.11172	0.10693	0.1109	0.10046	0.12128	0.11172	0.10046	0.1109	0.008	0.11405	0.11734	0.10462	0.11369	0.1145	0.11734	0.10462	0.1141	0.005	2.84	
42	0.12658	0.11033	0.12505	0.11416	0.11216	0.12658	0.11033	0.1142	0.008	0.11367	0.11951	0.11469	0.11455	0.11427	0.11951	0.11367	0.1146	0.002	0.34	
43	0.10875	0.11069	0.11208	0.12473	0.11033	0.12473	0.10875	0.1107	0.006	0.11333	0.11371	0.10955	0.11349	0.11226	0.11371	0.10955	0.1133	0.002	2.39	
44	0.1124	0.12128	0.0963	0.10869	0.12284	0.12128	0.0963	0.1124	0.011	0.1137	0.11424	0.10651	0.1151	0.10564	0.1161	0.10564	0.1137	0.005	1.16	
45	0.10518	0.1052	0.10667	0.11644	0.09717	0.11644	0.09717	0.1052	0.007	0.11453	0.117	0.11556	0.11348	0.11391	0.117	0.11348	0.1145	0.001	8.87	
46	0.12868	0.09608	0.12849	0.12695	0.11580	0.12868	0.09608	0.1270	0.014	0.11974	0.10752	0.1164	0.12006	0.11453	0.12006	0.10752	0.1164	0.005	-8.31	
47	0.11326	0.09564	0.11338	0.10759	0.1141	0.1141	0.09564	0.1124	0.008	0.11725	0.11464	0.11502	0.12026	0.1178	0.12026	0.11464	0.1173	0.002	4.33	
48	0.10354	0.11129	0.10885	0.10718	0.09717	0.11129	0.09717	0.1072	0.005	0.12078	0.12029	0.11911	0.11455	0.12078	0.12078	0.11455	0.1203	0.003		

ตารางที่ ค.25 ผลการทดลองและสถิติของข้อมูล sp500 โดยใช้ Feed forward NN.

Feed forward NN. แบบใช้ค่าน้ำหนักแบบค่าเต็ม (FNN)										Feed forward NN. แบบใช้ค่าน้ำหนักแบบทศนิยม (MSFNN)									
H	1	2	3	4	5	max	min	mean	SD	1	2	3	4	5	max	min	mean	SD	re(%)
1	0.22424	0.29328	0.30505	0.18529	0.18427	0.30505	0.18427	0.2242	0.058	0.09593	0.0974	0.09349	0.09999	0.0921	0.09999	0.0921	0.0959	0.003	-57.22
2	0.21606	0.18974	0.18783	0.18213	0.21111	0.21606	0.18213	0.1897	0.015	0.09472	0.0808	0.09515	0.09565	0.07656	0.09565	0.07656	0.0947	0.009	-50.08
3	0.20018	0.28576	0.21003	0.20099	0.18677	0.28576	0.18677	0.2010	0.039	0.09702	0.0955	0.0958	0.09837	0.09659	0.09837	0.0955	0.0966	0.001	-51.94
4	0.07756	0.07756	0.14358	0.13812	0.09903	0.14358	0.07756	0.0990	0.032	0.08487	0.07222	0.09965	0.06957	0.0385	0.09965	0.0385	0.0722	0.023	-27.07
5	0.07247	0.10774	0.10011	0.07577	0.07453	0.10774	0.07247	0.0758	0.017	0.06433	0.06488	0.0717	0.06484	0.06826	0.0717	0.06433	0.0649	0.003	-14.37
6	0.09903	0.09903	0.08918	0.10011	0.10506	0.10506	0.08918	0.0990	0.006	0.06219	0.09717	0.09717	0.05787	0.08809	0.09717	0.05787	0.0881	0.019	-11.05
7	0.12887	0.07874	0.07113	0.12657	0.10049	0.12887	0.07113	0.1005	0.027	0.09108	0.08795	0.05592	0.08224	0.05592	0.09108	0.05592	0.0822	0.017	-18.16
8	0.08079	0.09662	0.08999	0.07429	0.07453	0.09662	0.07429	0.0808	0.010	0.03991	0.07546	0.054	0.07738	0.0591	0.07738	0.03991	0.0591	0.016	-26.85
9	0.09662	0.07808	0.09412	0.08918	0.07372	0.09662	0.07372	0.0892	0.010	0.06392	0.09199	0.04703	0.06392	0.07589	0.09199	0.04703	0.0639	0.017	-28.32
10	0.10011	0.08918	0.08041	0.13764	0.09662	0.13764	0.08041	0.0966	0.022	0.07418	0.07418	0.0747	0.07752	0.0747	0.07752	0.0747	0.0747	0.001	-22.69
11	0.07113	0.13473	0.07016	0.08918	0.08079	0.13473	0.07016	0.0808	0.027	0.09781	0.08034	0.09938	0.06667	0.08034	0.09938	0.06667	0.0803	0.014	-0.56
12	0.07008	0.08918	0.07314	0.09662	0.08071	0.09662	0.07008	0.0807	0.011	0.09961	0.08077	0.06076	0.08116	0.08116	0.09961	0.06076	0.0812	0.014	0.56
13	0.11044	0.09903	0.09903	0.07874	0.08918	0.11044	0.07874	0.0990	0.012	0.09232	0.09166	0.08509	0.05038	0.08509	0.09232	0.05038	0.0851	0.017	-14.08
14	0.09587	0.10011	0.07694	0.08071	0.10506	0.10506	0.07694	0.0959	0.012	0.07776	0.08601	0.09095	0.09321	0.09606	0.09606	0.0776	0.0910	0.007	-5.13
15	0.07113	0.07874	0.07429	0.07577	0.07247	0.07874	0.07113	0.0743	0.003	0.08872	0.08885	0.098	0.09067	0.09833	0.09833	0.08872	0.0907	0.005	22.05
16	0.08071	0.05839	0.08999	0.07577	0.05057	0.08999	0.05057	0.0758	0.016	0.06207	0.06207	0.09403	0.09002	0.0939	0.09403	0.06207	0.0900	0.017	18.81
17	0.08918	0.09662	0.08918	0.10011	0.05648	0.10011	0.05648	0.0892	0.017	0.07616	0.0748	0.08576	0.08386	0.09113	0.09913	0.0748	0.0839	0.010	-5.97
18	0.07874	0.08918	0.0693	0.04791	0.06342	0.08918	0.04791	0.0693	0.016	0.08666	0.09159	0.07719	0.09758	0.0957	0.09758	0.07719	0.0916	0.008	32.16
19	0.10506	0.05044	0.07113	0.04658	0.05815	0.10506	0.04658	0.0582	0.024	0.09403	0.09412	0.08699	0.09374	0.09592	0.09592	0.08699	0.0940	0.003	61.70
20	0.05648	0.07016	0.07314	0.04277	0.06343	0.07314	0.04277	0.0634	0.012	0.05434	0.04654	0.05434	0.08662	0.08662	0.08662	0.04654	0.0543	0.019	-14.33
21	0.0686	0.04815	0.09412	0.04837	0.04356	0.09412	0.04356	0.0484	0.021	0.08585	0.0912	0.09458	0.09827	0.0843	0.09827	0.0843	0.0912	0.006	88.55
22	0.07874	0.05257	0.10011	0.09412	0.06577	0.10011	0.05257	0.0787	0.020	0.09799	0.09713	0.09343	0.09505	0.07748	0.09799	0.07748	0.0951	0.008	20.71
23	0.07113	0.07372	0.05379	0.09662	0.09903	0.09903	0.05379	0.0737	0.019	0.09592	0.09154	0.05328	0.09149	0.0968	0.0968	0.05328	0.0915	0.018	24.17
24	0.07016	0.04397	0.07016	0.04791	0.08918	0.08918	0.04397	0.0702	0.019	0.08861	0.09214	0.09404	0.09404	0.09434	0.09434	0.08861	0.0940	0.002	34.04
25	0.0483	0.07577	0.07808	0.08999	0.09662	0.09662	0.0483	0.0781	0.019	0.09862	0.09314	0.09704	0.09682	0.09759	0.09862	0.09314	0.0970	0.002	24.28
26	0.07429	0.08364	0.08999	0.05648	0.0483	0.08999	0.0483	0.0743	0.018	0.09603	0.09212	0.09367	0.09581	0.09305	0.09603	0.09212	0.0937	0.002	26.09
27	0.08918	0.05815	0.04837	0.06834	0.07429	0.08918	0.04837	0.0683	0.016	0.09882	0.09191	0.06489	0.09656	0.09191	0.09882	0.06489	0.0919	0.014	34.49
28	0.04815	0.04397	0.0686	0.0686	0.04487	0.0686	0.04397	0.0482	0.013	0.09842	0.09819	0.09833	0.1027	0.09553	0.1027	0.09553	0.0983	0.003	104.22
29	0.09903	0.06343	0.07314	0.05379	0.09662	0.09903	0.05379	0.0731	0.020	0.09886	0.09492	0.09859	0.09886	0.09935	0.09935	0.09492	0.0989	0.002	35.17
30	0.06342	0.05789	0.05789	0.08918	0.09903	0.09903	0.05789	0.0634	0.019	0.09553	0.09612	0.0911	0.09144	0.09301	0.09612	0.0911	0.0930	0.002	46.66
31	0.06505	0.06758	0.07453	0.0628	0.0693	0.07453	0.0628	0.0676	0.004	0.07252	0.09706	0.0484	0.08844	0.09081	0.09706	0.0484	0.0884	0.020	30.87
32	0.07372	0.06769	0.07429	0.05789	0.06834	0.07429	0.05789	0.0683	0.007	0.07343	0.09973	0.09884	0.09805	0.0939	0.09973	0.07343	0.0981	0.011	43.47
33	0.10506	0.08918	0.06543	0.06577	0.07247	0.10506	0.06543	0.0725	0.017	0.09852	0.09053	0.0767	0.07986	0.09053	0.09852	0.0767	0.0905	0.009	24.92
34	0.06769	0.07008	0.05044	0.10011	0.06342	0.10011	0.05044	0.0677	0.018	0.09151	0.09151	0.07528	0.07528	0.09466	0.09466	0.07528	0.0915	0.010	35.19
35	0.09662	0.07429	0.07453	0.06577	0.09903	0.09903	0.06577	0.0745	0.015	0.09493	0.09236	0.09273	0.09832	0.09687	0.09832	0.09236	0.0949	0.003	27.37
36	0.05057	0.04773	0.05369	0.06343	0.06505	0.06505	0.04773	0.0537	0.008	0.09842	0.09306	0.07728	0.09757	0.09757	0.09842	0.07728	0.0976	0.009	81.73
37	0.09903	0.05789	0.04857	0.05044	0.04414	0.09903	0.04414	0.0504	0.022	0.09219	0.08348	0.09125	0.08348	0.091	0.09219	0.08348	0.0910	0.004	80.41
38	0.10506	0.06577	0.06343	0.0538	0.06505	0.10506	0.0538	0.0651	0.020	0.09383	0.09736	0.09508	0.09383	0.08145	0.09736	0.08145	0.0938	0.006	44.24
39	0.05044	0.04990	0.04658	0.04414	0.06555	0.06555	0.04414	0.0500	0.008	0.09477	0.09121	0.09238	0.09158	0.09493	0.09493	0.09121	0.0924	0.002	84.91
40	0.09662	0.09662	0.07429	0.06423	0.04287	0.09662	0.04287	0.0743	0.023	0.08727	0.07072	0.09073	0.09625	0.09168	0.09625	0.07072	0.0907	0.010	22.13
41	0.07808	0.09662	0.07372	0.04857	0.06543	0.09662	0.04857	0.0737	0.018	0.06677	0.09741	0.09871	0.0926	0.0952	0.09871	0.06677	0.0952	0.013	29.14
42	0.04773	0.05315	0.09903	0.05257	0.05789	0.09903	0.04773	0.0532	0.021	0.09733	0.09409	0.0936	0.09059	0.09409	0.09733	0.09059	0.0941	0.002	77.03
43	0.04815	0.0483	0.09412	0.04791	0.08999	0.09412	0.04791	0.0483	0.024	0.09924	0.0938	0.0978	0.09869	0.09151	0.09924	0.09151	0.0978	0.003	102.48
44	0.0628	0.08079	0.10506	0.08079	0.09662	0.10506	0.0628	0.0808	0.016	0.09093	0.09377	0.09213	0.09093	0.09093	0.09377	0.09093	0.0909	0.001	12.55
45	0.05379	0.07577	0.09903	0.04815	0.09412	0.09903	0.04815	0.0758	0.023	0.09667	0.09331	0.0878	0.0878	0.09781	0.09781	0.0878	0.0933	0.005	23.15
46	0.0538	0.04791	0.05815	0.06423	0.04773	0.06423	0.04773	0.0538	0.007	0.09814	0.0984	0.091	0.08607	0.09429	0.0984	0.08607	0.0943	0.005	75.26
47	0.0633	0.04791	0.05648	0.08918	0.04791	0.08918	0.04791	0.0565	0.017	0.09856	0.0911	0.09612	0.09354	0.09198	0.09856	0.0911	0.0935	0.003	65.62
48	0.06423	0.04279	0.08079	0.05257	0.07314	0.08079	0.04279	0.0642	0.015	0.09928	0.09083	0.0909	0.0983	0.0905					

ตารางที่ ก.26 ผลการทดลองและสถิติของข้อมูล sp500 โดยใช้ Elman Recurrent NN.

Elman Recurrent NN. แบบใช้ค่าน้ำหนักแบบค่าเดิม (ERNN)										Elman Recurrent NN. แบบใช้ค่าน้ำหนักแบบเชกเมนต์ (MSERNN)										re(%)
H	1	2	3	4	5	max	min	mean	SD	1	2	3	4	5	max	min	mean	SD		
1	0.28256	0.28607	0.28695	0.28203	0.28773	0.28203	0.2861	0.003	0.10029	0.10286	0.08654	0.10362	0.10266	0.10362	0.08654	0.1027	0.007	0.007	-64.11	
2	0.11604	0.11572	0.11365	0.1176	0.13109	0.13109	0.11365	0.1160	0.007	0.10931	0.10927	0.10039	0.11036	0.10458	0.11036	0.10039	0.1093	0.004	0.004	-5.83
3	0.13943	0.19417	0.15289	0.24799	0.18464	0.24799	0.13943	0.1846	0.042	0.10147	0.10098	0.10649	0.10912	0.1051	0.10912	0.10098	0.1051	0.003	0.003	-43.08
4	0.10888	0.10077	0.10077	0.10888	0.10888	0.10888	0.10077	0.1089	0.004	0.10558	0.13301	0.10204	0.10223	0.09181	0.13301	0.09181	0.1022	0.015	0.015	-6.11
5	0.17977	0.08595	0.09351	0.13646	0.08103	0.17977	0.08103	0.0935	0.042	0.08809	0.0685	0.10988	0.05078	0.10994	0.10994	0.05078	0.0881	0.026	0.026	-5.80
6	0.10308	0.09091	0.09091	0.10027	0.09091	0.10308	0.09091	0.0909	0.006	0.10748	0.10682	0.10348	0.10985	0.10992	0.10992	0.10348	0.1075	0.003	0.003	18.23
7	0.12925	0.09468	0.12925	0.11195	0.13975	0.13975	0.09468	0.1293	0.018	0.07681	0.10856	0.1003	0.10821	0.1003	0.10856	0.07681	0.1003	0.013	0.013	-22.40
8	0.09495	0.09716	0.09716	0.0954	0.09716	0.09716	0.09495	0.0972	0.001	0.10974	0.10785	0.10215	0.10792	0.10517	0.10974	0.10215	0.1079	0.003	0.003	11.00
9	0.12358	0.13291	0.1513	0.1001	0.13714	0.1513	0.1001	0.1329	0.019	0.10822	0.10822	0.10791	0.10888	0.10111	0.10888	0.10111	0.1082	0.003	0.003	-18.58
10	0.09295	0.09188	0.09374	0.09424	0.09374	0.09424	0.09188	0.0937	0.001	0.10641	0.10242	0.10207	0.12707	0.10951	0.12707	0.10207	0.1064	0.010	0.010	13.52
11	0.0976	0.16291	0.11614	0.13266	0.1072	0.16291	0.0976	0.1161	0.026	0.12019	0.15086	0.10398	0.10097	0.08838	0.15086	0.08838	0.1040	0.024	0.024	-10.47
12	0.09563	0.09676	0.09563	0.09897	0.09563	0.09897	0.09563	0.0956	0.001	0.10784	0.10312	0.10661	0.10191	0.10503	0.10784	0.10191	0.1050	0.002	0.002	9.83
13	0.10698	0.101	0.12592	0.101	0.101	0.12592	0.101	0.1010	0.011	0.10645	0.08893	0.08051	0.10078	0.10078	0.08051	0.1008	0.008	0.011	0.011	-0.22
14	0.09302	0.09559	0.07417	0.09302	0.09559	0.07417	0.0930	0.011	0.10019	0.10208	0.10549	0.12074	0.10602	0.12074	0.10019	0.1055	0.008	0.008	13.41	
15	0.10561	0.10418	0.08507	0.10418	0.12418	0.12418	0.08507	0.1042	0.014	0.09533	0.10419	0.10321	0.10491	0.10815	0.10815	0.09533	0.1042	0.005	0.005	0.01
16	0.09511	0.10016	0.09875	0.08733	0.09363	0.10016	0.08733	0.0951	0.005	0.10179	0.08402	0.1077	0.07642	0.10209	0.1077	0.07642	0.1018	0.013	0.013	7.02
17	0.1139	0.11863	0.13459	0.11863	0.1343	0.13459	0.1139	0.1186	0.010	0.11755	0.10246	0.10246	0.10125	0.15186	0.15186	0.10125	0.1025	0.022	0.022	-13.63
18	0.09618	0.10409	0.09709	0.10218	0.10407	0.10409	0.09618	0.1022	0.004	0.12579	0.11512	0.10185	0.10665	0.10783	0.12579	0.10185	0.1107	0.009	0.009	8.29
19	0.09904	0.10032	0.13277	0.13918	0.09275	0.13918	0.09275	0.1003	0.021	0.10675	0.10369	0.10858	0.1175	0.10032	0.1175	0.10032	0.1068	0.006	0.006	6.41
20	0.09396	0.09935	0.09494	0.10266	0.08708	0.10266	0.08708	0.0949	0.006	0.10262	0.11014	0.10888	0.12671	0.11599	0.12671	0.10262	0.1101	0.009	0.009	16.01
21	0.11968	0.11211	0.13281	0.11721	0.08819	0.13281	0.08819	0.1172	0.016	0.11846	0.08461	0.10165	0.10808	0.12361	0.12361	0.08461	0.1081	0.015	0.015	-7.79
22	0.07638	0.09339	0.11175	0.10767	0.09767	0.11175	0.07638	0.0977	0.014	0.08001	0.11251	0.11251	0.08759	0.10336	0.11251	0.08001	0.1034	0.015	0.015	5.83
23	0.11512	0.12694	0.09215	0.10704	0.13329	0.13329	0.09215	0.1151	0.016	0.10557	0.12066	0.10471	0.10038	0.10297	0.12066	0.10038	0.1047	0.008	0.008	-9.04
24	0.09351	0.1194	0.11013	0.12628	0.1273	0.1273	0.09351	0.1194	0.014	0.13105	0.10321	0.15021	0.10581	0.10818	0.15021	0.10321	0.1082	0.020	0.020	-9.40
25	0.14829	0.15034	0.12280	0.12751	0.12617	0.15034	0.12288	0.1275	0.013	0.10355	0.10108	0.10891	0.10108	0.10407	0.10891	0.10108	0.1036	0.003	0.003	-18.79
26	0.12369	0.08103	0.1072	0.12324	0.13013	0.13013	0.08103	0.1232	0.020	0.13429	0.14628	0.1304	0.1349	0.10248	0.14628	0.10248	0.1304	0.018	0.018	5.81
27	0.12354	0.15465	0.14825	0.15769	0.15253	0.15769	0.12354	0.1525	0.014	0.04684	0.10867	0.10975	0.10424	0.10542	0.10975	0.04684	0.1054	0.027	0.027	-30.89
28	0.12373	0.09068	0.13021	0.08892	0.10162	0.13021	0.08892	0.1016	0.019	0.10571	0.07354	0.1005	0.10049	0.1005	0.10571	0.07354	0.1005	0.013	0.013	-1.10
29	0.14222	0.12576	0.12426	0.12628	0.18048	0.18048	0.12426	0.1263	0.024	0.13429	0.13407	0.10445	0.1055	0.13765	0.13765	0.10445	0.1341	0.017	0.017	6.17
30	0.12991	0.12945	0.11086	0.12466	0.09373	0.12991	0.09373	0.1247	0.015	0.15642	0.10176	0.14836	0.13716	0.11982	0.15642	0.10176	0.1372	0.022	0.022	10.03
31	0.10695	0.12420	0.12369	0.08733	0.17007	0.17007	0.08733	0.1237	0.033	0.10448	0.14068	0.10116	0.10798	0.14146	0.14146	0.10116	0.1080	0.020	0.020	-12.70
32	0.13504	0.11317	0.13801	0.12426	0.13401	0.13801	0.11317	0.1340	0.010	0.10265	0.1569	0.1086	0.15908	0.1569	0.15908	0.10265	0.1569	0.029	0.029	17.08
33	0.12369	0.08892	0.12594	0.17977	0.12354	0.17977	0.08892	0.1237	0.033	0.10646	0.10484	0.10964	0.10849	0.10828	0.10964	0.10484	0.1083	0.002	0.002	-12.46
34	0.12511	0.13266	0.14859	0.18453	0.19731	0.19731	0.12511	0.1486	0.032	0.14629	0.10357	0.10307	0.10307	0.14879	0.14879	0.10307	0.1036	0.024	0.024	-30.30
35	0.12426	0.14220	0.17955	0.16955	0.07638	0.17955	0.07638	0.1422	0.041	0.13721	0.11406	0.10777	0.12491	0.12272	0.13721	0.10777	0.1227	0.011	0.011	-13.71
36	0.1351	0.12703	0.12682	0.18441	0.13088	0.18441	0.12682	0.1309	0.025	0.11667	0.10666	0.10189	0.11043	0.14645	0.14645	0.10189	0.1104	0.018	0.018	-15.63
37	0.08673	0.09275	0.09617	0.11863	0.12511	0.12511	0.08673	0.0962	0.017	0.14133	0.15248	0.12688	0.10697	0.1092	0.15248	0.10697	0.1269	0.020	0.020	31.93
38	0.16544	0.18672	0.20024	0.12733	0.13014	0.20024	0.12733	0.1654	0.033	0.10933	0.10346	0.10972	0.10421	0.10682	0.10972	0.10346	0.1068	0.003	0.003	-35.43
39	0.08891	0.08673	0.09396	0.16714	0.09904	0.16714	0.08673	0.0940	0.034	0.10914	0.15455	0.10323	0.12386	0.12234	0.15455	0.10323	0.1223	0.020	0.020	30.20
40	0.11963	0.18489	0.08103	0.08610	0.19932	0.19932	0.08103	0.1196	0.055	0.1062	0.12538	0.12439	0.14337	0.14956	0.14956	0.1062	0.1254	0.017	0.017	4.81
41	0.18048	0.10695	0.14733	0.16707	0.09904	0.18048	0.09904	0.1473	0.036	0.14427	0.10444	0.10045	0.10558	0.12783	0.14427	0.10045	0.1056	0.019	0.019	-28.34
42	0.09396	0.11782	0.09068	0.1871	0.12617	0.1871	0.09068	0.1178	0.038	0.10542	0.10725	0.10587	0.10802	0.14565	0.14565	0.10542	0.1073	0.017	0.017	-8.97
43	0.09468	0.08726	0.08733	0.09373	0.11086	0.11086	0.08726	0.0937	0.010	0.10301	0.11572	0.10833	0.10073	0.10286	0.11572	0.10073	0.1030	0.006	0.006	9.90
44	0.07638	0.09904	0.12682	0.28563	0.08819	0.28563	0.07638	0.0990	0.086	0.10682	0.13625	0.13495	0.10906	0.14398	0.14398	0.10682	0.1350	0.017	0.017	36.26
45	0.14222	0.17977	0.08681	0.12694	0.12628	0.17977	0.08681	0.1269	0.033	0.10183	0.1065	0.10585	0.11664	0.10332	0.11664	0.10183	0.1059	0.006	0.006	-16.61
46	0.0976	0.11863	0.1139	0.08733	0.11013	0.11863	0.08733	0.1101	0.013	0.10918	0.10327	0.1024	0.10045	0.10756	0.10918					

ตารางที่ ค.27 ผลการทดลองและสถิติของข้อมูล sp500 โดยใช้ Jordan Recurrent NN.

Jordan Recurrent NN. แบบใช้ค่าน้ำหนักฟังก์ชันค่าเดียว (JRNN)										Jordan Recurrent NN. แบบใช้ค่าน้ำหนักแบบเซกเมนต์ (MSJRNN)									
H	1	2	3	4	5	max	min	mean	SD	1	2	3	4	5	max	min	mean	SD	re(%)
1	0.21865	0.22069	0.19933	0.30515	0.20737	0.30515	0.19933	0.2187	0.043	0.0934	0.09514	0.09601	0.09426	0.09037	0.09601	0.09037	0.0943	0.002	-56.89
2	0.17072	0.17785	0.15625	0.15933	0.14083	0.17785	0.14083	0.1593	0.014	0.09848	0.07885	0.07306	0.05059	0.0625	0.09848	0.05059	0.0731	0.018	-54.15
3	0.14389	0.13845	0.28391	0.16473	0.13453	0.28391	0.13453	0.1439	0.063	0.0965	0.07688	0.09919	0.09311	0.0886	0.09919	0.07688	0.0931	0.009	-35.29
4	0.10045	0.1519	0.10589	0.10841	0.13149	0.1519	0.10045	0.1084	0.022	0.03922	0.06769	0.06323	0.0976	0.03922	0.0976	0.03922	0.0632	0.024	-41.68
5	0.10386	0.12981	0.13619	0.13413	0.14334	0.14334	0.10388	0.1341	0.015	0.05497	0.03867	0.06411	0.07262	0.03867	0.07262	0.03867	0.0550	0.015	-59.02
6	0.13482	0.11473	0.13073	0.12785	0.1211	0.13482	0.11473	0.1279	0.008	0.05938	0.05938	0.06464	0.05938	0.05938	0.06464	0.05938	0.0594	0.002	-53.55
7	0.05728	0.04793	0.11899	0.06629	0.10145	0.11899	0.04793	0.0663	0.030	0.0753	0.09711	0.09095	0.09408	0.09685	0.09711	0.0753	0.0941	0.009	41.92
8	0.09146	0.05573	0.04832	0.08392	0.12904	0.12904	0.04832	0.0839	0.032	0.05457	0.05457	0.09055	0.09372	0.09372	0.09372	0.05457	0.0906	0.021	7.90
9	0.10014	0.13515	0.07524	0.13721	0.1286	0.13721	0.07524	0.1286	0.027	0.0748	0.08468	0.03382	0.08468	0.06396	0.08468	0.03382	0.0748	0.021	-41.84
10	0.12233	0.05183	0.07374	0.12661	0.06486	0.12661	0.05183	0.0737	0.034	0.07558	0.09029	0.03629	0.07403	0.09289	0.09289	0.03629	0.0756	0.023	2.50
11	0.07313	0.07477	0.12535	0.10191	0.11787	0.12535	0.07313	0.1019	0.024	0.06687	0.09175	0.09967	0.09581	0.09581	0.09967	0.06687	0.0958	0.013	-5.99
12	0.07037	0.05105	0.03737	0.04848	0.09612	0.09612	0.03737	0.0511	0.023	0.08167	0.09609	0.08076	0.09999	0.05218	0.09999	0.05218	0.0817	0.019	59.98
13	0.04848	0.07053	0.08366	0.06175	0.11694	0.11694	0.04848	0.0705	0.026	0.08745	0.07733	0.08465	0.09018	0.04862	0.09018	0.04862	0.0847	0.017	20.02
14	0.06628	0.06492	0.06539	0.06628	0.06791	0.06791	0.06492	0.0663	0.001	0.07771	0.07942	0.06083	0.07942	0.07771	0.07942	0.06083	0.0777	0.008	17.25
15	0.09612	0.04827	0.06175	0.04827	0.04941	0.09612	0.04827	0.0494	0.021	0.09066	0.06842	0.09443	0.06891	0.09066	0.09443	0.06842	0.0907	0.013	83.49
16	0.07037	0.08678	0.11202	0.0482	0.05563	0.11202	0.0482	0.0704	0.026	0.0762	0.06361	0.0762	0.09819	0.06361	0.09819	0.06361	0.0762	0.014	8.28
17	0.04941	0.07528	0.10216	0.06628	0.08875	0.10216	0.04941	0.0753	0.020	0.0742	0.05622	0.09499	0.09994	0.09994	0.09994	0.05622	0.0950	0.019	26.18
18	0.05105	0.07374	0.09332	0.04848	0.07374	0.09332	0.04848	0.0737	0.019	0.09291	0.09973	0.08411	0.09026	0.09291	0.09973	0.08411	0.0929	0.006	26.00
19	0.04855	0.05074	0.07313	0.10246	0.07037	0.10246	0.04855	0.0704	0.022	0.09522	0.08097	0.09648	0.098	0.09264	0.098	0.08097	0.0952	0.007	35.31
20	0.09818	0.10216	0.03825	0.07528	0.07037	0.10216	0.03825	0.0753	0.026	0.09228	0.09822	0.0948	0.04675	0.09736	0.09822	0.04675	0.0948	0.022	25.93
21	0.09391	0.07528	0.08392	0.09699	0.06613	0.09699	0.06613	0.0839	0.013	0.09656	0.09253	0.08226	0.09207	0.09207	0.09656	0.08226	0.0921	0.005	9.71
22	0.07915	0.07053	0.03825	0.08392	0.09699	0.09699	0.03825	0.0792	0.022	0.07607	0.09063	0.06632	0.09902	0.09964	0.09964	0.07607	0.0963	0.010	21.69
23	0.07530	0.08875	0.03747	0.08068	0.07524	0.08875	0.03747	0.0775	0.020	0.09642	0.08963	0.08416	0.09596	0.08416	0.09642	0.08416	0.0896	0.006	15.61
24	0.08013	0.05728	0.04941	0.08879	0.04933	0.08879	0.04933	0.0573	0.018	0.04353	0.0911	0.09355	0.09939	0.09355	0.09939	0.04353	0.0936	0.023	63.32
25	0.04793	0.06835	0.05563	0.09517	0.07915	0.09517	0.04793	0.0684	0.019	0.09908	0.09573	0.09908	0.09456	0.0669	0.09908	0.0669	0.0957	0.014	40.06
26	0.05183	0.04689	0.07530	0.05563	0.08879	0.08879	0.05563	0.0556	0.018	0.09557	0.09089	0.09219	0.09941	0.09941	0.09941	0.09089	0.0956	0.004	71.80
27	0.05408	0.04827	0.08401	0.04832	0.05183	0.08401	0.04827	0.0518	0.015	0.09259	0.0993	0.03934	0.09259	0.09403	0.0993	0.03934	0.0926	0.025	78.64
28	0.06492	0.07915	0.07513	0.04848	0.08621	0.08621	0.04848	0.0751	0.015	0.07938	0.09934	0.09618	0.06533	0.09847	0.09934	0.06533	0.0962	0.015	28.02
29	0.05573	0.10063	0.07697	0.06835	0.07442	0.10063	0.05573	0.0744	0.016	0.09384	0.09196	0.09147	0.09335	0.09867	0.09867	0.09147	0.0934	0.003	25.44
30	0.04832	0.04689	0.08089	0.03739	0.05342	0.08089	0.03739	0.0483	0.016	0.09541	0.09883	0.09584	0.09584	0.06572	0.09883	0.06572	0.0958	0.014	98.34
31	0.05728	0.08678	0.06124	0.08879	0.08401	0.08879	0.06124	0.0840	0.015	0.09327	0.06319	0.09147	0.0976	0.09362	0.0976	0.06319	0.0933	0.014	11.02
32	0.05105	0.04827	0.05342	0.04625	0.09612	0.04625	0.0511	0.021	0.09345	0.09547	0.09356	0.09781	0.06153	0.09781	0.06153	0.0936	0.015	83.27	
33	0.08678	0.07111	0.06107	0.04689	0.06885	0.08678	0.04689	0.0689	0.015	0.0985	0.07991	0.09894	0.0985	0.09741	0.09894	0.07991	0.0985	0.008	43.06
34	0.07915	0.07778	0.07053	0.07069	0.07053	0.07915	0.07053	0.0707	0.004	0.09578	0.09009	0.09725	0.09009	0.09508	0.09725	0.09009	0.0951	0.003	34.50
35	0.05927	0.06166	0.06299	0.04488	0.05053	0.06299	0.04488	0.0593	0.007	0.09281	0.09829	0.09273	0.09281	0.09668	0.09829	0.09273	0.0928	0.003	56.59
36	0.08068	0.04625	0.05728	0.04855	0.08068	0.04625	0.0570	0.014	0.014	0.0873	0.09293	0.0873	0.0873	0.09543	0.09543	0.0873	0.0873	0.004	53.16
37	0.06492	0.07530	0.09391	0.07442	0.05203	0.09391	0.05203	0.0744	0.015	0.09209	0.08979	0.08387	0.09701	0.09083	0.09701	0.08387	0.0908	0.005	22.05
38	0.08068	0.07173	0.06474	0.09818	0.04625	0.09818	0.04625	0.0717	0.019	0.095	0.09972	0.09337	0.095	0.0848	0.09972	0.0848	0.0950	0.005	32.44
39	0.04827	0.05067	0.08621	0.08089	0.04827	0.08621	0.04827	0.0507	0.019	0.09718	0.08439	0.08175	0.09241	0.09621	0.09718	0.08175	0.0924	0.007	82.38
40	0.09612	0.04933	0.05378	0.06107	0.07259	0.09612	0.04933	0.0611	0.019	0.09508	0.09508	0.09181	0.09854	0.09667	0.09854	0.09181	0.0951	0.002	55.69
41	0.06808	0.06539	0.05067	0.05074	0.06808	0.05067	0.0507	0.009	0.009	0.09968	0.09083	0.09338	0.09754	0.09988	0.09988	0.09083	0.0975	0.004	92.23
42	0.08089	0.07928	0.03861	0.05105	0.08089	0.03861	0.0528	0.019	0.019	0.08514	0.09046	0.09573	0.08916	0.08916	0.09573	0.08514	0.0892	0.004	68.83
43	0.05488	0.09729	0.08068	0.09391	0.05342	0.09729	0.05342	0.0807	0.021	0.09198	0.09881	0.09111	0.08887	0.09111	0.09881	0.08887	0.0911	0.004	12.93
44	0.06175	0.07513	0.07442	0.10246	0.05139	0.10246	0.05139	0.0744	0.019	0.09579	0.08437	0.0928	0.09053	0.09579	0.09579	0.08437	0.0928	0.005	24.70
45	0.08875	0.07442	0.11642	0.08538	0.08401	0.11642	0.07442	0.0854	0.016	0.09118	0.09769	0.08558	0.08046	0.09603	0.09769	0.08046	0.0912	0.007	6.79
46	0.05383	0.05383	0.08712	0.04625	0.05359	0.08712	0.04625	0.0538	0.016	0.09668	0.06729	0.08331	0.08331	0.09273	0.09668	0.08331	0.0927	0.007	72.26
47	0.05363	0.05203	0.09818	0.08366	0.05447	0.09818	0.05203	0.0545	0.021	0.09217	0.09944	0.09668	0.09826	0.09647	0.09944	0.09217	0.0967	0.003	77.49
48	0.06474	0.05563	0.06539	0.04793	0.08875	0.08875	0.04793	0.0647	0.015	0.09354	0.09449	0.09156	0.0934						

ตารางที่ ค.28 ผลการทดลองและสถิติของข้อมูล sunplus โดยใช้ Feed forward NN.

Feed forward NN. แบบใช้ค่าน้ำหนักเพียงค่าเดียว (FNN)								Feed forward NN. แบบใช้ค่าน้ำหนักแบบแยกแยะ (MSFNN)											
H	1	2	3	4	5	max	min	mean	SD	1	2	3	4	5	max	min	mean	SD	re(%)
1	0.07689	0.07778	0.08335	0.08387	0.07579	0.08387	0.07579	0.0778	0.004	0.0684	0.07251	0.07345	0.0712	0.07168	0.07345	0.0684	0.0717	0.002	-7.84
2	0.08106	0.06753	0.06899	0.07606	0.06852	0.08106	0.06753	0.0690	0.006	0.06912	0.06845	0.06915	0.06741	0.06846	0.06915	0.06741	0.0685	0.001	-0.77
3	0.06851	0.09978	0.07899	0.06851	0.08802	0.09978	0.06851	0.0790	0.013	0.06893	0.06929	0.06735	0.06927	0.06851	0.06929	0.06735	0.0689	0.001	-12.74
4	0.06852	0.07046	0.08464	0.06907	0.06907	0.08464	0.06852	0.0691	0.007	0.06743	0.06863	0.06935	0.06947	0.06959	0.06959	0.06743	0.0694	0.001	0.41
5	0.08406	0.07727	0.07997	0.07811	0.08802	0.08802	0.07727	0.0800	0.004	0.06928	0.0702	0.06848	0.07105	0.07125	0.07125	0.06848	0.0702	0.001	-12.22
6	0.0825	0.08015	0.08301	0.08517	0.07865	0.08517	0.07865	0.0825	0.003	0.06965	0.07025	0.07059	0.06859	0.06926	0.07059	0.06859	0.0697	0.001	-15.58
7	0.06907	0.07997	0.08266	0.06942	0.07285	0.08266	0.06907	0.0729	0.006	0.06937	0.06822	0.07108	0.06884	0.06919	0.07108	0.06822	0.0692	0.001	-5.02
8	0.0717	0.07816	0.08392	0.07286	0.07579	0.08392	0.0717	0.0758	0.005	0.06891	0.06927	0.06961	0.06767	0.06813	0.06961	0.06767	0.0689	0.001	-9.08
9	0.07865	0.08778	0.07055	0.08789	0.07055	0.08789	0.07055	0.0787	0.009	0.06874	0.06811	0.06894	0.06926	0.06876	0.06926	0.06811	0.0688	0.001	-12.57
10	0.07816	0.06851	0.07065	0.0732	0.07197	0.07816	0.06851	0.0720	0.004	0.07006	0.07027	0.06903	0.06977	0.06889	0.07027	0.06889	0.0698	0.001	-3.06
11	0.07491	0.07272	0.08015	0.08778	0.07222	0.08778	0.07222	0.0749	0.007	0.06824	0.06877	0.0687	0.06937	0.07257	0.07257	0.06824	0.0688	0.002	-8.20
12	0.07606	0.07165	0.07096	0.08274	0.06907	0.08274	0.06907	0.0717	0.005	0.06884	0.07097	0.06868	0.06906	0.0689	0.07097	0.06868	0.0689	0.001	-3.84
13	0.07841	0.08644	0.07096	0.07816	0.07319	0.08644	0.07096	0.0782	0.006	0.06986	0.07011	0.07071	0.06959	0.07092	0.07092	0.06959	0.0701	0.001	-10.30
14	0.0755	0.07773	0.08015	0.0825	0.08852	0.0825	0.0755	0.0777	0.005	0.07247	0.06917	0.06786	0.07327	0.06966	0.07327	0.06786	0.0700	0.002	-10.00
15	0.07285	0.07727	0.07285	0.08209	0.07413	0.08209	0.07285	0.0741	0.004	0.07195	0.06893	0.06856	0.06911	0.07021	0.07195	0.06856	0.0691	0.001	-6.77
16	0.08081	0.07822	0.07644	0.0766	0.08789	0.07644	0.08081	0.0782	0.005	0.06938	0.06854	0.07018	0.06857	0.07039	0.07039	0.06854	0.0694	0.001	-11.30
17	0.07579	0.07816	0.06851	0.07606	0.07319	0.07816	0.06851	0.0758	0.004	0.07092	0.0709	0.06862	0.06825	0.06973	0.07092	0.06825	0.0697	0.001	-8.00
18	0.08387	0.07555	0.08805	0.08507	0.0717	0.08805	0.0717	0.0839	0.007	0.06757	0.06928	0.06888	0.07051	0.06981	0.07051	0.06757	0.0693	0.001	-17.40
19	0.06851	0.08406	0.08301	0.0732	0.08067	0.08406	0.06851	0.0807	0.006	0.06938	0.06874	0.07364	0.07061	0.07143	0.07364	0.06874	0.0706	0.002	-12.47
20	0.07899	0.06907	0.08275	0.07865	0.08015	0.08275	0.06907	0.0790	0.005	0.0695	0.06864	0.06896	0.06837	0.06926	0.0695	0.06837	0.0690	0.000	-12.70
21	0.07579	0.08209	0.08149	0.08789	0.07881	0.08789	0.07579	0.0815	0.004	0.06967	0.06845	0.07034	0.07334	0.07449	0.07449	0.06845	0.0703	0.003	-13.68
22	0.06841	0.07811	0.06763	0.07689	0.07997	0.07689	0.06763	0.0769	0.006	0.07038	0.06933	0.06706	0.06823	0.06855	0.07038	0.06823	0.0693	0.001	-9.83
23	0.07872	0.08376	0.07706	0.07606	0.07727	0.08376	0.07706	0.0773	0.003	0.0676	0.07015	0.07552	0.07563	0.07112	0.07563	0.0676	0.0711	0.004	-7.96
24	0.07474	0.08392	0.07822	0.06907	0.0717	0.08392	0.06907	0.0747	0.006	0.06937	0.06804	0.07011	0.06886	0.07287	0.07287	0.06804	0.0694	0.002	-7.18
25	0.07976	0.07474	0.06942	0.08517	0.06851	0.08517	0.06942	0.0747	0.007	0.07048	0.07016	0.06977	0.07054	0.06792	0.07054	0.06792	0.0702	0.001	-6.13
26	0.08805	0.08067	0.07788	0.09978	0.07606	0.09978	0.08067	0.0878	0.009	0.07176	0.07023	0.07347	0.07268	0.07017	0.07347	0.07017	0.0718	0.001	-18.25
27	0.08464	0.08209	0.07773	0.08335	0.08517	0.08209	0.07773	0.0834	0.003	0.06894	0.06984	0.06825	0.06772	0.06984	0.06984	0.06772	0.0689	0.001	-17.29
28	0.07816	0.08106	0.08106	0.08789	0.08106	0.08789	0.07816	0.0811	0.003	0.06892	0.06968	0.07078	0.06773	0.06968	0.07078	0.06773	0.0689	0.001	-14.04
29	0.07865	0.08106	0.0788	0.08106	0.06907	0.08106	0.06907	0.0788	0.005	0.07724	0.07446	0.06827	0.06973	0.06858	0.07724	0.06827	0.0697	0.004	-11.51
30	0.08136	0.08464	0.08644	0.08507	0.0788	0.08644	0.0788	0.0846	0.003	0.06838	0.07006	0.06746	0.06992	0.06878	0.07006	0.06746	0.0688	0.001	-18.74
31	0.06851	0.08106	0.07644	0.07865	0.08599	0.08599	0.06851	0.0769	0.006	0.0757	0.06978	0.06796	0.07502	0.07223	0.0757	0.06796	0.0722	0.003	-6.06
32	0.07811	0.07689	0.06942	0.07727	0.08392	0.08392	0.06942	0.0773	0.005	0.06968	0.07788	0.07791	0.07946	0.06995	0.07946	0.06968	0.0779	0.005	0.79
33	0.07778	0.08802	0.07822	0.09978	0.08136	0.09978	0.07778	0.0814	0.009	0.07647	0.07355	0.07726	0.06847	0.07782	0.07782	0.06847	0.0765	0.004	-8.01
34	0.07096	0.0788	0.07881	0.08106	0.08517	0.08517	0.07096	0.0788	0.005	0.06712	0.06759	0.06963	0.06953	0.0689	0.06963	0.06712	0.0689	0.001	-12.57
35	0.07997	0.08272	0.0825	0.08015	0.06852	0.08272	0.06852	0.0802	0.006	0.07786	0.07046	0.07766	0.07817	0.06928	0.07817	0.06928	0.0777	0.004	-3.11
36	0.08136	0.08644	0.07555	0.07096	0.08274	0.08644	0.07096	0.0814	0.006	0.07647	0.07517	0.06949	0.0705	0.07173	0.07647	0.06949	0.0717	0.003	-11.84
37	0.08149	0.08272	0.08569	0.07644	0.07555	0.08569	0.07555	0.0815	0.004	0.07173	0.07292	0.06849	0.0717	0.07734	0.07734	0.06849	0.0717	0.003	-11.98
38	0.08576	0.08737	0.08387	0.08209	0.08266	0.08737	0.08209	0.0839	0.002	0.06821	0.06953	0.06816	0.06858	0.07018	0.07018	0.06816	0.0685	0.001	-18.23
39	0.06758	0.0825	0.08805	0.08392	0.08406	0.08805	0.06758	0.0839	0.008	0.0668	0.0689	0.06938	0.07933	0.07775	0.07933	0.0668	0.0694	0.005	-17.33
40	0.08406	0.08301	0.07644	0.08507	0.08335	0.08507	0.07644	0.0834	0.003	0.06894	0.0694	0.07245	0.06711	0.06819	0.07245	0.06711	0.0689	0.002	-17.29
41	0.0818	0.07778	0.08331	0.08778	0.08841	0.08841	0.07778	0.0833	0.004	0.07016	0.07037	0.0693	0.06972	0.06926	0.07037	0.06926	0.0697	0.000	-16.31
42	0.08067	0.08902	0.07727	0.08392	0.08274	0.08902	0.07727	0.0827	0.004	0.06898	0.07106	0.06861	0.06939	0.07086	0.07106	0.06861	0.0694	0.001	-16.13
43	0.08335	0.0818	0.08569	0.08136	0.08272	0.08136	0.08335	0.0818	0.002	0.07087	0.06747	0.0683	0.0686	0.06795	0.07087	0.06747	0.0683	0.001	-18.06
44	0.08902	0.0818	0.08464	0.07822	0.08331	0.08902	0.07822	0.0833	0.004	0.06894	0.06878	0.06818	0.06884	0.06859	0.06894	0.06818	0.0688	0.000	-17.44
45	0.08644	0.08106	0.08464	0.08569	0.0901	0.0901	0.08106	0.0857	0.003	0.08072	0.06991	0.07961	0.07876	0.07016	0.08072	0.06991	0.0788	0.005	-8.09
46	0.07899	0.07222	0.07474	0.0912	0.09482	0.09482	0.07222	0.0879	0.010	0.06754	0.08219	0.07762	0.0807	0.07998	0.08219	0.06754	0.0800	0.006	-9.00
47	0.07222	0.08272	0.08387	0.08266	0.06907	0.08387	0.06907	0.0827	0.007	0.06895	0.06901	0.06898	0.06945	0.06987	0.06987	0.06895	0.0690	0.000	-16.51
48	0.08149	0.07065	0.07644	0.08517	0.08517	0.07065	0.07065	0.0790	0.011	0.0705	0.06874	0.06836	0.06966	0.07099	0.07099	0.06836	0.0697	0.001	-11.81
49	0.07065	0.0755	0.07644	0.08517	0.08517	0.07065	0.0764	0.006	0.06986	0.0843	0.08358	0.08399	0.08374	0.0843	0.06986	0.0837	0.006	9.55	
50	0.07055	0.08902	0.08301	0.08802	0.0911	0.0911	0.07055	0.0880	0.008	0.06917	0.07049	0.07335	0.07114	0.07923	0.07923	0.06917	0.0711	0.004	-19.18

H -จำนวนโหนดในชั้นซ่อน
 min -ค่าผิดพลาด (RMSE) น้อยที่สุดจากการทดลอง 5 ครั้ง
 1, 2, 3, 4, 5 -ผลการทดลองครั้งที่ 1, 2, 3, 4, 5 โดยคิดจากที่โครงข่ายให้ผลผิดพลาด (RMSE)
 SD -ค่าเบี่ยงเบนมาตรฐานของค่าความผิดพลาดจากการทดลอง 5 ครั้ง
 B -ค่าความผิดพลาดน้อยที่สุดจากการทดลอง 50 แบบ (1-50 โหนด)
 C -ค่าเฉลี่ยจากการทดลอง 50 แบบ (1-50 โหนด)
 re -reduce เปอร์เซ็นต์ที่โครงข่ายให้ผลผิดพลาดลดลง โดยหาได้จาก $\frac{\max_{\text{MSFNN}} - \text{mean}_{\text{FNN}}}{\text{mean}_{\text{FNN}}} * 100$
 max -ค่าผิดพลาด (RMSE) มากที่สุดจากการทดลอง 5 ครั้ง
 mean -ค่าเฉลี่ยของค่าความผิดพลาด (RMSE) จากการทดลอง 5 ครั้ง

ผลการทดลองจากตารางที่ ค.28 แสดงให้เห็นว่า เมื่อมีการใช้จำนวนโหนดที่เท่ากันในชั้นซ่อน การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลง 47 แบบ (จำนวนโหนดที่เท่ากันในชั้นซ่อน) โดยถ้คิดเป็นค่าเฉลี่ยจากทุกแบบการทดลองแล้ว การใช้ค่าน้ำหนักแบบหลายเซกเมนต์ทำให้โครงข่ายให้ผลผิดพลาดลดลงโดยเฉลี่ย 11.66% โดยผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักเพียงค่าเดียว คือ 0.06753 เมื่อใช้จำนวนโหนดในชั้นซ่อน 2 โหนด และผลผิดพลาดที่น้อยที่สุดของโครงข่ายที่ใช้ค่าน้ำหนักแบบหลายเซกเมนต์คือ 0.06712 เมื่อใช้จำนวนโหนดในชั้นซ่อน 34 โหนด

ตารางที่ ค.29 ผลการทดลองและสถิติของข้อมูล sunplus โดยใช้ Elman Recurrent NN.

Elman Recurrent NN. แบบใช้ค่าพารามิเตอร์ค่าเดิม (ERNN)										Elman Recurrent NN. แบบใช้ค่าพารามิเตอร์แบบเซกเมนต์ (MSERNN)										re(%)
H	1	2	3	4	5	max	min	mean	SD	1	2	3	4	5	max	min	mean	SD		
1	0.078250	0.073410	0.067890	0.075550	0.075550	0.078250	0.067890	0.0756	0.004	0.067350	0.065950	0.066140	0.066990	0.067460	0.066990	0.065950	0.0674	0.002	-10.85	
2	0.065340	0.065370	0.065370	0.065340	0.065370	0.065370	0.065340	0.0654	0.000	0.065440	0.067020	0.065960	0.067650	0.0674	0.067650	0.06544	0.0670	0.001	2.52	
3	0.064444	0.0662	0.073010	0.068950	0.066550	0.073010	0.064444	0.0666	0.003	0.065910	0.067330	0.065080	0.065870	0.066950	0.067330	0.06508	0.0659	0.001	-0.96	
4	0.065340	0.065370	0.065370	0.065570	0.065570	0.065570	0.065340	0.0654	0.000	0.067940	0.066070	0.066610	0.0665310	0.068590	0.068590	0.06531	0.0666	0.001	1.90	
5	0.071460	0.066960	0.071890	0.066260	0.072520	0.072520	0.066260	0.0715	0.003	0.071510	0.066920	0.069040	0.076320	0.068780	0.076320	0.06692	0.0690	0.004	-3.39	
6	0.065970	0.065970	0.065970	0.065970	0.065860	0.065970	0.065860	0.0660	0.000	0.067490	0.067450	0.067440	0.066690	0.065990	0.067490	0.06599	0.0674	0.001	2.23	
7	0.069170	0.066910	0.071960	0.066070	0.071520	0.071960	0.066070	0.0692	0.003	0.070070	0.070580	0.069630	0.069280	0.066550	0.070580	0.06655	0.0696	0.002	0.67	
8	0.066570	0.066570	0.065840	0.066020	0.066470	0.066570	0.065840	0.0665	0.000	0.06930	0.071660	0.068340	0.066090	0.067940	0.071660	0.06609	0.0683	0.002	2.81	
9	0.068350	0.069790	0.068810	0.067350	0.068190	0.069790	0.067350	0.0684	0.001	0.067440	0.067380	0.069230	0.066570	0.067250	0.069230	0.06657	0.0674	0.001	-1.42	
10	0.065930	0.065930	0.066440	0.066490	0.065930	0.066490	0.065930	0.0659	0.000	0.068490	0.068120	0.066790	0.069480	0.0674	0.069480	0.06679	0.0681	0.001	3.32	
11	0.065970	0.070500	0.068840	0.065970	0.0730	0.0730	0.065970	0.0688	0.003	0.068950	0.069690	0.068980	0.06750	0.068870	0.069690	0.06750	0.0690	0.001	0.16	
12	0.067020	0.066940	0.066030	0.066680	0.067020	0.067020	0.066030	0.0669	0.000	0.066280	0.069590	0.068850	0.068950	0.068810	0.069590	0.06628	0.0689	0.001	2.85	
13	0.066260	0.07	0.069180	0.067630	0.0725	0.0725	0.066260	0.0692	0.002	0.070170	0.069790	0.070240	0.069740	0.067020	0.070240	0.06702	0.0698	0.001	0.88	
14	0.067260	0.067490	0.067390	0.066220	0.067490	0.067490	0.066220	0.0674	0.001	0.067010	0.072820	0.070410	0.070740	0.072	0.072820	0.06701	0.0707	0.002	4.97	
15	0.068970	0.070280	0.069130	0.072350	0.076920	0.076920	0.068970	0.0703	0.003	0.075630	0.072080	0.071540	0.071770	0.068570	0.075630	0.06857	0.0718	0.003	2.12	
16	0.067220	0.068030	0.067690	0.067310	0.066820	0.068030	0.066820	0.0673	0.000	0.07130	0.072840	0.070090	0.068270	0.070480	0.072840	0.06827	0.0705	0.002	4.71	
17	0.074880	0.068090	0.067360	0.070270	0.070130	0.074880	0.067360	0.0701	0.003	0.071460	0.068220	0.069130	0.071970	0.071910	0.071970	0.06822	0.0715	0.002	1.90	
18	0.069010	0.067890	0.068120	0.070170	0.068280	0.070170	0.067890	0.0683	0.001	0.072510	0.069350	0.069340	0.071880	0.068680	0.072510	0.06868	0.0694	0.002	1.57	
19	0.071720	0.069860	0.074950	0.079260	0.075140	0.079260	0.069860	0.0750	0.004	0.069040	0.068590	0.068680	0.067740	0.06760	0.069040	0.06760	0.0686	0.001	-8.49	
20	0.067940	0.0692	0.069070	0.070010	0.068260	0.070010	0.067940	0.0691	0.001	0.072410	0.075410	0.083310	0.067590	0.080320	0.083310	0.06759	0.0754	0.006	9.18	
21	0.072750	0.079110	0.069810	0.075110	0.0788	0.079110	0.069810	0.0751	0.004	0.070630	0.070610	0.066520	0.068040	0.070350	0.070630	0.06652	0.0704	0.002	-6.34	
22	0.07230	0.068180	0.070330	0.070550	0.072260	0.07230	0.068180	0.0706	0.002	0.070960	0.069820	0.069960	0.073070	0.070390	0.073070	0.06982	0.0704	0.001	-0.23	
23	0.072370	0.078380	0.073380	0.074890	0.076140	0.078380	0.073380	0.07237	0.002	0.075560	0.076740	0.069140	0.074040	0.067160	0.076740	0.06716	0.0740	0.004	-1.13	
24	0.072020	0.072730	0.0736	0.070590	0.072870	0.0736	0.070590	0.0727	0.001	0.075340	0.072340	0.070690	0.070470	0.0684	0.075340	0.0684	0.0707	0.003	-2.80	
25	0.072080	0.072760	0.075960	0.077010	0.072760	0.077010	0.072080	0.0728	0.002	0.068260	0.070340	0.069880	0.07010	0.070340	0.070340	0.06826	0.0701	0.001	-3.66	
26	0.071890	0.072050	0.076810	0.072050	0.076810	0.076810	0.071890	0.0721	0.003	0.071860	0.069440	0.067990	0.068980	0.070350	0.071860	0.06799	0.0694	0.001	-3.62	
27	0.071680	0.087550	0.083120	0.072080	0.075560	0.087550	0.071680	0.0756	0.007	0.075870	0.0734	0.066880	0.069270	0.069060	0.075870	0.06688	0.0693	0.004	-8.32	
28	0.072520	0.072520	0.072330	0.076	0.074620	0.076	0.072330	0.0725	0.002	0.071320	0.072080	0.069760	0.073340	0.075030	0.075030	0.06976	0.0721	0.002	-0.61	
29	0.076220	0.0759	0.073140	0.0726	0.072450	0.076220	0.072450	0.0731	0.002	0.067480	0.069160	0.074160	0.067830	0.075290	0.075290	0.06748	0.0692	0.004	-5.44	
30	0.083250	0.0836	0.0756	0.073830	0.073830	0.0836	0.073830	0.0756	0.005	0.080440	0.0694	0.076580	0.071740	0.079150	0.080440	0.0694	0.0766	0.005	1.30	
31	0.0752	0.0754	0.084670	0.077950	0.073320	0.084670	0.073320	0.0754	0.004	0.074710	0.081760	0.071370	0.08110	0.06980	0.081760	0.06980	0.0747	0.005	-0.92	
32	0.078440	0.075470	0.080270	0.0743	0.075270	0.080270	0.0743	0.0755	0.003	0.071110	0.071390	0.071390	0.069340	0.074570	0.074570	0.06934	0.0714	0.002	-5.41	
33	0.083710	0.080120	0.073410	0.087350	0.085640	0.087350	0.073410	0.0837	0.006	0.071090	0.069980	0.077360	0.080260	0.074	0.080260	0.06998	0.0740	0.004	-11.60	
34	0.076590	0.075860	0.083390	0.0797	0.083520	0.083520	0.075860	0.0797	0.004	0.07030	0.071810	0.079480	0.074740	0.071980	0.079480	0.07030	0.0720	0.004	-9.69	
35	0.075440	0.084190	0.084470	0.078250	0.085560	0.085560	0.075440	0.0842	0.004	0.081840	0.082480	0.068950	0.070170	0.074350	0.082480	0.06895	0.0744	0.006	-11.89	
36	0.083120	0.084980	0.074340	0.075850	0.077070	0.084980	0.074340	0.0771	0.005	0.08260	0.078680	0.075130	0.071110	0.081330	0.08260	0.07111	0.0787	0.005	2.09	
37	0.0726	0.071680	0.0719	0.084430	0.077510	0.084430	0.071680	0.0726	0.005	0.072460	0.07380	0.072930	0.071640	0.069490	0.07380	0.06949	0.0725	0.002	-0.19	
38	0.086380	0.089420	0.082090	0.08630	0.080960	0.089420	0.080960	0.0863	0.003	0.086760	0.072960	0.077590	0.077870	0.07130	0.086760	0.07130	0.0776	0.006	-10.09	
39	0.071990	0.073460	0.083120	0.071720	0.0844	0.0844	0.071720	0.0735	0.006	0.074480	0.071350	0.084360	0.075770	0.09570	0.09570	0.07135	0.0758	0.010	3.14	
40	0.091760	0.091450	0.083460	0.080180	0.068090	0.091760	0.068090	0.0835	0.010	0.131390	0.073870	0.080090	0.097760	0.071380	0.131390	0.07138	0.0809	0.025	-3.07	
41	0.071720	0.0838	0.0838	0.072520	0.072050	0.0838	0.071720	0.0725	0.006	0.071380	0.081060	0.131990	0.124950	0.072820	0.131990	0.07138	0.0811	0.030	11.78	
42	0.072050	0.080960	0.072330	0.090010	0.082160	0.090010	0.072050	0.0810	0.008	0.069170	0.071870	0.073030	0.069980	0.073760	0.073760	0.06917	0.0719	0.002	-11.23	
43	0.070330	0.113320	0.07730	0.0719	0.072520	0.113320	0.070330	0.0725	0.018	0.112220	0.076060	0.07350	0.11030	0.091980	0.112220	0.07350	0.0920	0.018	26.83	
44	0.072330	0.076590	0.07430	0.072020	0.072520	0.076590	0.072020	0.0725	0.002	0.075540	0.073520	0.078610	0.072180	0.072680	0.078610	0.07218	0.0735	0.003	1.38	
45	0.0850	0.067890	0.07390	0.106190	0.092210	0.106190	0.067890	0.0850	0.015	0.089410	0.071950	0.071870	0.074130	0.084180	0.089410	0.07187	0.0741	0.008	-12.79	
46	0.066960	0.066220	0.071680	0.078250	0.071890	0.078250	0.066220	0.0717	0.005	0.079420	0.076830									

ตารางที่ ก.30 ผลการทดลองและสถิติของข้อมูล sunplus โดยใช้ Jordan Recurrent NN.

Jordan Recurrent NN. แบบใช้ค่าน้ำหนักเพียงค่าเดียว (JRNN)										Jordan Recurrent NN. แบบใช้ค่าน้ำหนักแบบแยกแยะ (MSJRNN)										re(%)
H	1	2	3	4	5	max	min	mean	SD	1	2	3	4	5	max	min	mean	SD		
1	0.07679	0.08236	0.07818	0.08076	0.07789	0.08236	0.07679	0.0782	0.002	0.06944	0.06879	0.06817	0.0724	0.06951	0.0724	0.06817	0.0694	0.002	-11.18	
2	0.07183	0.0699	0.07446	0.06944	0.0688	0.07446	0.0688	0.0699	0.002	0.06952	0.06787	0.06838	0.06774	0.06865	0.06952	0.06774	0.0684	0.001	-2.17	
3	0.07195	0.07129	0.07406	0.06944	0.06892	0.07406	0.06892	0.0713	0.002	0.06838	0.06737	0.06872	0.06804	0.0683	0.06872	0.06737	0.0683	0.001	-4.19	
4	0.0828	0.08151	0.08094	0.07322	0.07458	0.0828	0.07322	0.0809	0.004	0.06849	0.06884	0.06961	0.06939	0.06845	0.06961	0.06845	0.0688	0.001	-14.95	
5	0.07044	0.06893	0.07343	0.07343	0.07185	0.07343	0.06893	0.0719	0.002	0.06963	0.07048	0.06956	0.07021	0.06821	0.07048	0.06821	0.0696	0.001	-3.09	
6	0.08587	0.08351	0.07524	0.08777	0.07212	0.08777	0.07212	0.0835	0.007	0.06862	0.06868	0.06892	0.06654	0.06768	0.06892	0.06654	0.0686	0.001	-17.83	
7	0.06963	0.07504	0.0702	0.07148	0.07503	0.07504	0.06963	0.0715	0.003	0.07059	0.06812	0.06917	0.06886	0.07101	0.07101	0.06812	0.0692	0.001	-3.23	
8	0.07259	0.07169	0.0722	0.07514	0.07331	0.07514	0.07169	0.0726	0.001	0.0698	0.06926	0.07022	0.06985	0.0692	0.07022	0.0692	0.0698	0.000	-3.84	
9	0.07547	0.07031	0.07544	0.07046	0.07184	0.07547	0.07031	0.0718	0.003	0.06838	0.06909	0.06727	0.07137	0.07055	0.07137	0.06727	0.0691	0.002	-3.83	
10	0.08777	0.08049	0.06898	0.08332	0.07446	0.08777	0.06898	0.0805	0.007	0.06944	0.06917	0.06822	0.06861	0.07007	0.07007	0.06822	0.0692	0.001	-14.06	
11	0.08096	0.08056	0.07136	0.08049	0.07222	0.08096	0.07136	0.0805	0.005	0.07353	0.07353	0.06832	0.06944	0.06908	0.07353	0.06832	0.0694	0.003	-13.73	
12	0.06963	0.07692	0.07249	0.07495	0.06893	0.07692	0.06893	0.0725	0.003	0.06875	0.06731	0.06986	0.06804	0.06928	0.06986	0.06731	0.0688	0.001	-5.16	
13	0.07169	0.0722	0.07276	0.07346	0.07362	0.0722	0.07362	0.0723	0.001	0.0695	0.0735	0.07324	0.07427	0.06955	0.07427	0.0695	0.0732	0.002	1.27	
14	0.07603	0.07677	0.07557	0.0813	0.0733	0.0813	0.0733	0.0760	0.003	0.07009	0.06791	0.07096	0.0705	0.06843	0.07096	0.06791	0.0701	0.001	-7.81	
15	0.07966	0.07389	0.0799	0.07343	0.08127	0.08127	0.07343	0.0797	0.004	0.06654	0.06674	0.06801	0.0673	0.06737	0.06801	0.06654	0.0673	0.001	-15.52	
16	0.07856	0.07628	0.07322	0.07724	0.08151	0.07628	0.08151	0.07322	0.003	0.07242	0.074	0.07331	0.07445	0.07485	0.07485	0.07242	0.0740	0.001	-4.19	
17	0.07180	0.08236	0.07701	0.08084	0.08929	0.08929	0.07701	0.0808	0.005	0.07095	0.06946	0.07063	0.07064	0.06755	0.07095	0.06755	0.0706	0.001	-12.63	
18	0.07249	0.07941	0.07455	0.07249	0.07591	0.07941	0.07249	0.0746	0.003	0.07034	0.06705	0.06886	0.07216	0.06916	0.07216	0.06705	0.0692	0.002	-7.23	
19	0.08588	0.0878	0.07462	0.07136	0.08127	0.0878	0.07136	0.0813	0.007	0.06921	0.06827	0.06742	0.06896	0.06709	0.06921	0.06709	0.0683	0.001	-16.00	
20	0.07839	0.07502	0.07984	0.07692	0.07495	0.07839	0.07495	0.0769	0.002	0.07005	0.07395	0.07205	0.06893	0.06875	0.07395	0.06875	0.0701	0.002	-8.93	
21	0.08324	0.07708	0.07818	0.06963	0.07458	0.08324	0.06963	0.0771	0.005	0.07079	0.069	0.06974	0.06912	0.0667	0.07079	0.0667	0.0691	0.002	-10.33	
22	0.07941	0.07782	0.07498	0.07136	0.07343	0.07941	0.07136	0.0750	0.003	0.06799	0.068	0.06938	0.07076	0.06994	0.07076	0.06799	0.0694	0.001	-7.51	
23	0.0851	0.08787	0.07169	0.07893	0.08433	0.08787	0.07169	0.0843	0.006	0.06798	0.06813	0.06883	0.06774	0.0682	0.06883	0.06774	0.0681	0.000	-19.21	
24	0.06944	0.07446	0.06895	0.07941	0.07966	0.07966	0.06895	0.0745	0.005	0.06908	0.06807	0.06855	0.06784	0.06579	0.06908	0.06579	0.0681	0.001	-8.58	
25	0.08587	0.08096	0.07649	0.08455	0.07446	0.08587	0.07446	0.0810	0.005	0.06667	0.06937	0.06954	0.06829	0.06983	0.06983	0.06667	0.0694	0.001	-14.32	
26	0.0829	0.07458	0.08929	0.08076	0.07249	0.0829	0.07249	0.0808	0.007	0.06704	0.06633	0.06744	0.06788	0.06944	0.06944	0.06633	0.0674	0.001	-16.49	
27	0.07856	0.07169	0.08076	0.08433	0.07789	0.08433	0.07169	0.0786	0.005	0.06735	0.06979	0.06684	0.07035	0.06703	0.07035	0.06684	0.0674	0.002	-14.27	
28	0.07701	0.07679	0.07782	0.07959	0.07737	0.07959	0.07679	0.0774	0.001	0.06973	0.06831	0.0673	0.0692	0.06619	0.06973	0.06619	0.0683	0.001	-11.71	
29	0.08447	0.06893	0.08056	0.0829	0.08127	0.08447	0.06893	0.0813	0.006	0.06684	0.07037	0.06747	0.06921	0.06715	0.07037	0.06715	0.0684	0.001	-15.84	
30	0.07462	0.06963	0.07902	0.07458	0.08304	0.08304	0.06963	0.0746	0.005	0.0691	0.07535	0.06733	0.06736	0.07012	0.07535	0.06733	0.0691	0.003	-7.40	
31	0.08151	0.08476	0.07893	0.0828	0.07446	0.08476	0.07446	0.0815	0.004	0.06815	0.0689	0.06837	0.06752	0.06918	0.06918	0.06752	0.0684	0.001	-16.12	
32	0.08587	0.07941	0.08076	0.0829	0.07896	0.08587	0.07896	0.0858	0.003	0.06761	0.06844	0.07021	0.07543	0.07048	0.07543	0.06761	0.0702	0.003	-13.06	
33	0.08447	0.08096	0.07966	0.08151	0.08777	0.08777	0.07966	0.0815	0.003	0.06735	0.07111	0.0692	0.07467	0.07552	0.07552	0.06735	0.0711	0.003	-12.76	
34	0.08236	0.07679	0.08177	0.07343	0.09025	0.09025	0.07343	0.0818	0.006	0.06945	0.06747	0.07527	0.07042	0.0776	0.0776	0.06747	0.0704	0.004	-13.88	
35	0.07322	0.09025	0.08588	0.08777	0.07701	0.09025	0.07322	0.0859	0.007	0.06866	0.07487	0.07749	0.06941	0.0691	0.07749	0.06866	0.0694	0.004	-19.18	
36	0.08351	0.07737	0.07169	0.07896	0.07679	0.08351	0.07169	0.0774	0.004	0.06992	0.06995	0.06857	0.06835	0.07012	0.07012	0.06835	0.0699	0.001	-9.63	
37	0.0851	0.08793	0.08304	0.0829	0.08094	0.08793	0.08094	0.0830	0.003	0.06865	0.06927	0.06973	0.06722	0.07056	0.07056	0.06722	0.0683	0.001	-16.58	
38	0.08332	0.08332	0.08298	0.08587	0.07495	0.08332	0.07495	0.0833	0.004	0.06513	0.06753	0.06696	0.06808	0.0675	0.06808	0.06513	0.0675	0.001	-18.99	
39	0.0799	0.08351	0.07212	0.07969	0.08253	0.08351	0.07212	0.0799	0.004	0.06742	0.07941	0.07886	0.06663	0.06823	0.07941	0.06663	0.0682	0.006	-14.61	
40	0.07966	0.08351	0.09025	0.08056	0.08929	0.09025	0.07966	0.0835	0.005	0.07184	0.07612	0.06931	0.07873	0.0761	0.07873	0.06931	0.0761	0.004	-8.87	
41	0.08724	0.08591	0.08351	0.07249	0.08854	0.08591	0.07249	0.0885	0.006	0.06866	0.07096	0.06802	0.07898	0.07876	0.07898	0.06802	0.0710	0.005	-17.40	
42	0.08096	0.09263	0.07718	0.08049	0.08077	0.09263	0.07718	0.0808	0.006	0.06708	0.07354	0.07118	0.06952	0.07776	0.07776	0.06708	0.0712	0.004	-11.87	
43	0.08660	0.08772	0.07169	0.08056	0.08447	0.08660	0.07169	0.0845	0.007	0.06854	0.06741	0.06595	0.06979	0.06491	0.06979	0.06491	0.0674	0.002	-20.20	
44	0.0799	0.0878	0.08177	0.07969	0.06944	0.0878	0.06944	0.0799	0.007	0.07271	0.07709	0.06994	0.06987	0.0781	0.0781	0.06994	0.0727	0.004	-9.00	
45	0.08332	0.09025	0.07343	0.07322	0.08433	0.09025	0.07322	0.0833	0.007	0.06776	0.06993	0.08249	0.08249	0.08115	0.08249	0.06776	0.0812	0.007	-2.60	
46	0.07893	0.07692	0.08929	0.09025	0.0828	0.09025	0.07692	0.0828	0.006	0.08033	0.07101	0.07235	0.08139	0.08099	0.08139	0.07101	0.0803	0.005	-2.98	
47	0.08298	0.08904	0.08833	0.08792	0.0874	0.08904	0.08298	0.0879	0.002	0.06992	0.06957	0.06829	0.07103	0.06831	0.07103	0.06829	0.0696	0.001	-20.87	
48	0.07856	0.07620	0.07446	0.08800	0.07180	0.08800	0.07180	0.0746	0.006	0.06793	0.06891	0.06956	0.06906							



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Feedforward Neural Network with Multi-valued Connection Weights

Arit Thammano and Phongthep Ruxpakawong

Computational Intelligence Laboratory, Faculty of Information Technology,
King Mongkut's Institute of Technology Ladkrabang, 10520 Bangkok Thailand
arit@it.kmitl.ac.th, thep@psru.ac.th

Abstract. This paper introduces a new concept of the connection weight to the multi-layer feedforward neural network. The architecture of the proposed approach is the same as that of the original multi-layer feedforward neural network. However, the weight of each connection is multi-valued, depending on the value of the input data involved. The backpropagation learning algorithm was also modified to suit the proposed concept. This proposed model has been benchmarked against the original feedforward neural network and the radial basis function network. The results on six benchmark problems are very encouraging.

Keywords: Feedforward Neural Network, Learning algorithm, Data mining, Classification.

1 Introduction

Classification is the process of finding a set of models that describe and distinguish data classes or concepts, for the purpose of being able to use the model to predict the class of objects whose class label is unknown [1]. A variety of techniques have been applied to deal with the classification problems, such as artificial neural networks, a decision tree, and statistical methods. However, many previous research works [2, 3, 4, 5, 6] show that neural network classifiers have better performance, lower classification error rate, and more robust to noise than other classification methods. Among a number of neural network classifiers, the multi-layer feedforward neural network with backpropagation learning algorithm, often called backpropagation neural network, is the most widely used model. Arbach et al. [7] used the backpropagation neural network to classify mammographic masses. The classification performance was measured by computing the sensitivity, specificity, and area under the receiver operating characteristic (ROC) curves. The results showed that the backpropagation neural network performance was slightly better than the expert radiologists, and significantly better than the residents. Grip et al. [8] used the backpropagation neural network to classify neck movement patterns related to Whiplash-associated disorders. The backpropagation neural network with six hidden nodes achieved a predictivity of 0.89, a sensitivity of 0.90, and a specificity of 0.88, which are very promising results. Another research work by Arbach et al. [9] used the

W. Yu, H. He, and N. Zhang (Eds.): ISSN 2009, Part I, LNCS 5551, pp. 229–237, 2009.
© Springer-Verlag Berlin Heidelberg 2009

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

backpropagation neural network for classification of breast MRI lesions. The results illustrated the promise of using the backpropagation neural network as a physician's assistant for breast MRI classification.

Even though the backpropagation neural network has been responsible for numerous successes, it is not without disadvantage. The backpropagation neural network suffers from shortcomings, such as slow convergence rate and easily being trapped in a local minimum [10]. Numerous algorithms that improve on the backpropagation learning algorithm have been proposed. In [11], Sarkar and Yegnanarayana proposed a method of embedding fuzzy objective functions into the original backpropagation learning algorithm. Rimer and Martinez [12] combined the standard backpropagation learning algorithm with lazy training [13]. The combined approach achieved higher accuracy and more robust solutions than either standard backpropagation or lazy training alone.

This paper introduces a new concept of the connection weight to the original multi-layer feedforward neural network. Typically, each connection weight of the multi-layer feedforward neural network is a single real number. However, in this paper the weight of each connection is multi-valued, depending on the value of the input data involved. The performance of the proposed approach is evaluated against the original multi-layer feedforward neural network and the radial basis function network.

This paper is divided into 4 sections. Following this introduction, section 2 presents the architecture of the proposed approach and its learning algorithm. A brief description of the experimental data and the experimental results are given in section 3. Finally, section 4 is the conclusions.

2 The Proposed Approach

In this paper, the three-layer feedforward neural network is used to demonstrate how the proposed approach works. The architecture of the three-layer feedforward neural network is shown in Figure 1. The first layer is the input layer, which consists of N nodes. Each node represents a feature component of the input data. The second layer is the hidden layer. The nodes in the hidden layer are fully connected to the nodes in the input layer and the output layer. The third layer is the output layer. Each node in the output layer represents a class. In this paper, the input vector is denoted by $X = (x_1, x_2, \dots, x_i, \dots, x_N)$, where N is the number of features in X . Once the network receives the input and its associated target output (X, Y) , the training process will begin. The detailed procedure of the proposed approach is as follows:

- a. Define the number of nodes in the hidden layer.
- b. Normalize the input data to a value between $[0, 1]$. Divide the normalized input data range into S segments by specifying the point(s) where the segments will be split, called the splitting point(s). Then, initialize all weight values of each connection, w_{ij} and w_{jk} , with random numbers between -1 and 1 .




Fig. 1. Architecture of the three-layer feedforward neural network

For example, in Figure 2 the splitting point is at 0.5; as a result, x_i and O_j are divided into 2 equal segments ($S = 2$). The first segment (s_1) covers the range between 0 and 0.5 while the second segment (s_2) covers the range between 0.5 and 1. Then, for each connection, randomly pick $S+1$ numbers between -1 and 1. In Figure 2.1, three numbers - 0.55, -0.05, and -0.7 - are randomly picked and assigned to be the weights at the points where $x_i = 0$, $x_i = 0.5$, and $x_i = 1$ respectively - $w_{ij}(0)$, $w_{ij}(0.5)$, and $w_{ij}(1)$.




Fig. 2. Example of the new connection weights

c. Calculate the output of each hidden node (O_j) as follows:

$$O_j = f(\text{net}_j). \tag{1}$$

$$\text{net}_j = \sum_{i=1}^N x_i w_{ij}(x_i). \quad (2)$$

$$w_{ij}(x_i) = w_{ij}(L_i) + \frac{(x_i - L_i)}{(U_i - L_i)} (w_{ij}(U_i) - w_{ij}(L_i)). \quad (3)$$

where $f(\bullet)$ is the activation function. In this paper, the sigmoid function is used as the activation function in both the hidden layer and the output layer.

N is the total number of nodes in the input layer.

L_i is a lower bound of the segment that x_i falls into.

U_i is an upper bound of the segment that x_i falls into.

d. Calculate the output of each output node (O_k) as follows:

$$O_k = f(\text{net}_k). \quad (4)$$

$$\text{net}_k = \sum_{j=1}^M O_j w_{jk}(O_j). \quad (5)$$

$$w_{jk}(O_j) = w_{jk}(L_j) + \frac{(O_j - L_j)}{(U_j - L_j)} (w_{jk}(U_j) - w_{jk}(L_j)). \quad (6)$$

where M is the total number of nodes in the hidden layer.

L_j is a lower bound of the segment that O_j falls into.

U_j is an upper bound of the segment that O_j falls into.

e. Compare the desired output (Y) with the actual output (O_k) and determine the error at the output layer by

$$E = \frac{1}{2} \sum_{k=1}^C (y_k - O_k)^2. \quad (7)$$

f. Update the connection weights between the hidden layer and the output layer by using the equation

$$w_{jk}^{\text{new}}(L_j) = w_{jk}^{\text{old}}(L_j) + \eta \left(\frac{\partial E}{\partial w_{jk}(O_j)} \right) \left(\frac{(U_j - O_j)}{(U_j - L_j)} \right). \quad (8)$$

$$w_{jk}^{\text{new}}(U_j) = w_{jk}^{\text{old}}(U_j) + \eta \left(\frac{\partial E}{\partial w_{jk}(O_j)} \right) \left(\frac{(O_j - L_j)}{(U_j - L_j)} \right). \quad (9)$$

$$\frac{\partial E}{\partial w_{jk}(O_j)} = (y_k - O_k)(O_k(1 - O_k))O_j. \quad (10)$$

where η is the learning rate, which has a value between 0 and 1.

- g. Update the connection weights between the input layer and the hidden layer by using the equation

$$w_{ij}^{new}(L_i) = w_{ij}^{old}(L_i) + \eta \left(\frac{\partial E}{\partial w_{ij}(x_i)} \right) \left(\frac{(U_i - x_i)}{(U_i - L_i)} \right). \quad (11)$$

$$w_{ij}^{new}(U_i) = w_{ij}^{old}(U_i) + \eta \left(\frac{\partial E}{\partial w_{ij}(x_i)} \right) \left(\frac{(x_i - L_i)}{(U_i - L_i)} \right). \quad (12)$$

$$\frac{\partial E}{\partial w_{ij}(x_i)} = (O_j(1 - O_j)) x_i \sum_{k=1}^C (y_k - O_k)(O_k(1 - O_k)) w_{jk}. \quad (13)$$

- h. Repeat steps c through g for all remaining input patterns in the training data set.
i. Repeat steps c through h until a predetermined number of iteration is reached or the root mean square error reaches an acceptable level.

During testing, each testing vector is applied in turn and its class is predicted. The class whose output node returns the maximum output value is the result of the prediction.

$$K = \arg \max \{O_k : k = 1, 2, \dots, C\}. \quad (14)$$

3 Experimental Results

To test the performance of the proposed approach, the experiments were conducted on 4 artificial data sets and 2 real-life data sets. The four artificial data sets are called Fan, Flower 1, Flower 2, and Sawtooth. The names imply the shape of the classes. Fan data has 4 classes, while the other three have 2 classes. In each of the four data sets, the 4,000 data points in the database were randomly divided into a training set of 2,000 data points and a testing set of 2,000 data points.

The two real-life data sets are the iris data and the image segmentation data. The iris data [14] has been widely used in the classification problem. The sepal length, sepal width, petal length, and petal width of 150 iris flowers from 3 species (*Iris-setosa*, *Iris-versicolor*, and *Iris-virginica*) are measured in centimeters, and are used as the input of the problem. The training set contains 90 records, while the testing set contains 60 records.

The image segmentation data was retrieved from the UCI machine learning database repository [15]. Nineteen continuous attributes are used to predict the output class. There are 7 classes (brick face = 1, sky = 2, foliage = 3, cement = 4, window = 5, path = 6, and grass = 7) with 330 examples per class. In this paper, the training set contains 210 examples, while the testing set contains 2,100 examples.




Fig. 3. Fan




Fig. 4. Flower 1




Fig. 5. Flower 2

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




Fig. 6. Sawtooth

Results of the experiments are shown in Table 1. For Fan data (data set 1), the proposed approach and the radial basis function network (RBFN) win out by a small margin over the multi-layer feedforward neural network (MFNN). The proposed approach and the RBFN achieve a perfect accuracy (100%) while the MFNN misses only 5 out of 2,000 patterns.

For Flower 1, Flower 2, and Sawtooth, the proposed approach outperforms the MFNN by a wide margin. However, the performance of the proposed approach is only slightly better than that of the RBFN. The training parameters of the proposed approach are $M = 18$ and $S = 10$ for Flower 1, $M = 13$ and $S = 10$ for Flower 2, and $M = 2$ and $S = 10$ for Sawtooth. The best prediction performance of MFNN are obtained from the networks with $M = 23$ for Flower 1, $M = 29$ for Flower 2, and $M = 18$ for Sawtooth. The best prediction performance of RBFN are obtained from the networks with 93 hidden nodes for Flower 1, 89 hidden nodes for Flower 2, and 91 hidden nodes for Sawtooth.

For the iris data (data set 5), all three methods – the MFNN, the RBFN, and the proposed approach – achieve a perfect accuracy (100%). These best prediction performances are obtained from the MFNN with 10 nodes in the hidden layer, from the RBFN with 32 hidden nodes, and from the proposed approach with 2 hidden nodes and $S = 1$.

For the image data (data set 6), the proposed approach produces 102 misclassifications out of a total of 2,100 examples; this corresponds to an accuracy of 95.14%. The number of nodes in the hidden layer is 11 and S is 10. On the other hand, the MFNN with 14 hidden nodes produces 137 misclassifications, and the RBFN with 70 hidden nodes produces 109 misclassifications.

4 Conclusions

This paper introduces an improvement on the multi-layer feedforward neural network. In the proposed approach, the weight of each connection in the multi-layer feedforward neural network is modified. To test the performance, the proposed approach, the

original feedforward neural network, and the radial basis function network were used to classify six benchmark problems. With respect to the classification accuracy, the proposed approach is found to be far superior to the original feedforward neural network, and marginally better than the radial basis function network. In addition, the size of the proposed network is much smaller than the sizes of the other two methods.

Table 1. Experimental results

Data Set	Accuracy (%)		
	Feedforward Neural Network	Radial Basis Function Network	Proposed Approach
1. Fan	99.75	100.0	100.0
2. Flower 1	95.35	97.40	99.35
3. Flower 2	95.40	98.25	99.45
4. Sawtooth	95.90	99.80	100.0
5. Iris	100.0	100.0	100.0
6. Image	93.48	94.81	95.14

References

1. Han, J., Kamber, M.: *Data Mining: Concepts and Techniques*. Morgan Kaufmann, San Manteo (2001)
2. Quinlan, J.R.: *Comparing Connectionist and Symbolic Learning Methods*. In: *Workshop on Computational Learning Theory and Natural Learning Systems*, pp. 445–456. MIT Press, Cambridge (1994)
3. Russell, S., Norvig, P.: *Artificial Intelligence: A Modern Approach*. Prentice Hall, New Jersey (1995)
4. Shavlik, J.W., Mooney, R.J., Towell, G.G.: *Symbolic and Neural Learning Algorithms: An Experimental Comparison*. *Machine Learning* 6, 111–143 (1991)
5. Danaher, S., Herries, G., Selige, T., Mac Surtan, M.: *A Comparison of the Characterisation of Agricultural Land Using Singular Value Decomposition and Neural Networks*. In: *Neurocomputation in Remote Sensing Data Analysis*. Springer, Heidelberg (1997)
6. Lee, J., Weger, R.C., Sengupta, S.K., Welch, R.M.: *A Neural Network Approach to Cloud Classification*. *IEEE Transactions on Geoscience and Remote Sensing* 28, 846–855 (1990)
7. Arbach, L., Reinhardt, J.M., Bennett, D.L., Fallouh, G.: *Mammographic Masses Classification: Comparison Between Backpropagation Neural Network (BNN), K Nearest Neighbors (KNN), and Human Readers*. In: *Canadian Conference on Electrical and Computer Engineering*, pp. 1441–1444. IEEE Press, New York (2003)
8. Grip, H., Öhberg, F., Wiklund, U., Sterner, Y., Karlsson, J.S., Gerdle, B.: *Classification of Neck Movement Patterns Related to Whiplash-Associated Disorders Using Neural Networks*. *IEEE Transactions on Information Technology in Biomedicine* 7, 412–418 (2003)
9. Arbach, L., Stolpen, A., Reinhardt, J.M.: *Classification of Breast MRI Lesions Using a Backpropagation Neural Network (BNN)*. In: *IEEE International Symposium on Biomedical Imaging: Nano to Macro*, pp. 253–256. IEEE Press, New York (2004)
10. Go, J., Han, G., Kim, H., Lee, C.: *Multigradient: A New Neural Network Learning Algorithm for Pattern Classification*. *IEEE Transactions on Geoscience and Remote Sensing* 39, 986–993 (2001)

11. Sarkar, M., Yegnanarayana, B.: Incorporation of Fuzzy Classification Properties into Backpropagation Learning Algorithm. In: Sixth IEEE International Conference on Fuzzy Systems, pp. 1701–1706. IEEE Press, New York (1997)
12. Rimer, M., Martinez, T.: Softprop: Softmax Neural Network Backpropagation Learning. In: 2004 IEEE International Joint Conference on Neural Networks, pp. 979–983. IEEE Press, New York (2004)
13. Rimer, M., Anderson, T., Martinez, T.R.: Improving Backpropagation Ensembles through Lazy Training. In: IEEE International Joint Conference on Neural Networks, pp. 2007–2112. IEEE Press, New York (2001)
14. Fisher, R.A.: The Use of Multiple Measurements in Taxonomic Problems. *Annual Eugenics* 7, 179–188 (1936)
15. Asuncion, A., Newman, D.J.: UCI Machine Learning Repository, <http://www.ics.uci.edu/~mllearn/MLRepository.html>



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Dynamic System Identification Using Recurrent Neural Network with Multi-Valued Connection Weight

Arit Thammano and Phongthep Ruxpakawong

Abstract—This paper introduces a new concept of the connection weight to the standard recurrent neural networks – Elman and Jordan networks. The architecture of the modified networks is the same as that of the original recurrent neural networks. However, in the modified networks the weight of each connection is multi-valued, depending on the value of the input data involved. The backpropagation learning algorithm is also modified to suit the proposed concept. The modified networks have been benchmarked against their original counterparts. The results on eleven benchmark problems are very encouraging.

I. INTRODUCTION

NEURAL NETWORKS have long been applied successfully to the identification of complex nonlinear system. Even though neural networks have satisfactorily solved most of these problems, they generally require a large number of input neurons and necessitate a long computation time. For a structure point of view, there are two main types of neural networks: feedforward and recurrent neural networks. A connection in a feedforward neural network (FNN) is unidirectional, which only allows the information to flow from input neurons to output neurons. In a recurrent neural network (RNN), however, there are both the feedforward and feedback connections, which allow the information to flow from input neurons to output neurons and vice versa.

Typically, the feedforward neural networks trained with backpropagation learning algorithm have been widely used for nonlinear system identification. However, since the feedforward neural networks lack the ability to retain information about the infinite past [1], their performances in identifying nonlinear dynamical system will not be as good as those of the recurrent neural networks. Many previous research works, such as [2, 3, 4], show that RNNs are more suitable than FNNs for representing nonlinear dynamical system. Pham and Karaboga [5] further improve the performances of Elman and Jordan recurrent neural networks for dynamic system identification by training such networks using genetic algorithms.

This paper introduces a new concept of the connection weight to the original recurrent neural networks. Typically, each connection weight of the recurrent neural network is a

single real number. However, in this paper the weight of each feedforward connection is multi-valued, depending on the value of the input data involved. The performance of the proposed approach is evaluated against the 2 most common recurrent neural networks: Elman and Jordan networks.

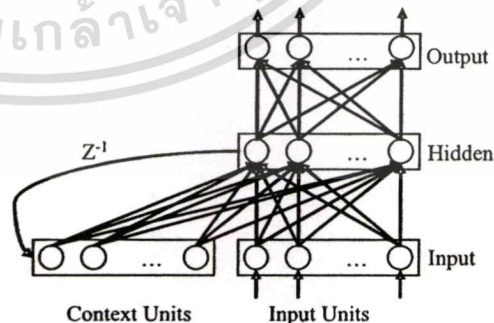
This paper is divided into 5 sections. Following this introduction, section 2 briefly explains the background of recurrent neural networks. Section 3 presents the proposed approach and its learning algorithm. The experimental results are given in section 4. Finally, section 5 is the conclusion.

II. RECURRENT NEURAL NETWORK

Recurrent neural network (RNN) is a kind of neural network with feedback connections. Two of the well-known RNNs are Elman and Jordan networks.

Elman network [6] is a neural network with three layers of neurons. The first layer is the input layer which consists of two groups of neurons: the internal input neurons and the external input neurons. The internal input neurons, also called the context units, takes in the outputs of neurons in the hidden layer as shown in Fig. 1(a). Both the outputs of the context units and the external input units are fed to the neurons in the hidden layer, and then the outputs of the hidden neurons are fed forward to activate the output neurons.

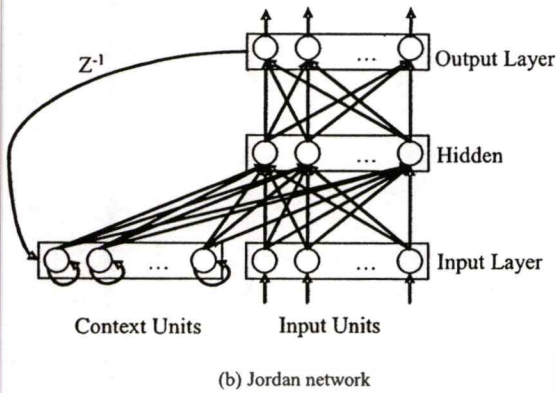
Jordan network [7] also has three layers. The main difference from Elman network is that the context units take inputs from the outputs of neurons in the output layer as shown in Fig. 1(b).



(a) Elman network

A. Thammano is with the Faculty of Information Technology, King Mongkut's Institute of Technology Ladkrabang, Bangkok, 10520 Thailand (e-mail: arit@it.kmitl.ac.th).

P. Ruxpakawong is a Ph.D. student at the Faculty of Information Technology, King Mongkut's Institute of Technology Ladkrabang, Bangkok, 10520 Thailand (e-mail: thep@psru.ac.th).



(b) Jordan network

Fig. 1. Well-known recurrent neural networks

Basically, both Elman and Jordan networks can be trained in the same way as feedforward neural networks by means of the backpropagation learning algorithm. During the training phase, the error is propagated backward from the output layer to adjust the weights of all feedforward connections. However, the weights of the feedback connections must be kept constant, and are not subject to any adjustment.

Besides the Elman and Jordan networks, various models that improve on the original Elman and Jordan networks have been proposed. Cheng, Qi, and Cai [8] improve the dynamic characteristics and convergence speed of the original Elman network by adding feedforward connections between the context nodes and the output nodes (Fig. 2). Chen and Soo [9] proposed a recurrent neural network which has two kinds of context units as shown in Fig. 3. The first group of context units stores the feedback from the outputs of the hidden layer while the second group stores the feedback of the output layer.

III. THE PROPOSED APPROACH

A new concept of the connection weight proposed in this paper is applied to both the original Elman and Jordan recurrent neural networks. As mentioned in section II, the recurrent neural network consists of three layers. The first layer is the input layer which consists of two groups of




Fig. 2. Cheng, Qi, and Cai's recurrent neural network




Fig. 3. Chen and Soo's recurrent neural network

neurons: the internal input neurons and the external input neurons. The number of internal input neurons is equal to the number of neurons in the hidden layer in the case of Elman network and equal to the number of neurons in the output layer in the case of Jordan network. The number of external input neurons is equal to the number of feature components of the input data. The second layer is the hidden layer. The nodes in the hidden layer are fully connected to the nodes in the input layer and the output layer. The third layer is the output layer.

Once the network receives the input and its associated target output (X, Y), the training process will begin. In this paper, the input vector is denoted by $X = (x_1, x_2, \dots, x_i, \dots, x_N)$, where N is the number of features in X; the target output is denoted by $Y = (y_1, y_2, \dots, y_k, \dots, y_C)$, where C is the number of output nodes. The detail procedure of the training process is as follows:

- a. Define the number of nodes in the hidden layer.
- b. Normalize the input data to a value between [0, 1].
- c. Initialize the weights of all feedforward connections. In this paper, the weight of each feedforward connection is multi-valued, depending on the value of the input data involved. Therefore, the values of the weights w_{ij} , w_{j} , and w_{jk} depend on the values of x_i , O_i , and O_j respectively. The following are the initialization method:
 - c.1. Divide the input data range into S segments by specifying S-1 points, called the splitting points, where the segments will be split.
 - c.2. For each feedforward connection (w_{ij} , w_{j} , and w_{jk}), randomly pick S+1 numbers between -1 and 1 and assign them to be the weights at the splitting point(s) and at the opposite ends of the range (0 and 1).

For example, in Fig. 4(b) the input data range is split into 2 segments where the splitting point is at 0.5. Therefore, there are 3 points in the range of 0 to 1 that have to be initialized, which are $w_{jk}(O_j = 0)$, $w_{jk}(O_j = 0.5)$, and $w_{jk}(O_j = 1)$. For this specific jk connection in Fig. 4(b), -0.25, 0.25, and 0.75 are randomly picked and assigned to be the weights at the points where $O_j = 0$, $O_j = 0.5$, and $O_j = 1$ respectively.




Fig. 4. Example of the proposed connection weights

d. Make a copy of the output from the previous time step to form the context layer. For Elman network, the group of context units is a copy of the hidden layer's previous activations. For Jordan network, the group of context units is a copy of the output layer. Therefore, the number of context units of Elman network is equal to the number of nodes in the hidden layer. For Jordan network, the number of context units is equal to the number of nodes in the output layer.

$$O_r = \begin{cases} O_j & \text{for Elman network} \\ O_k & \text{for Jordan network} \end{cases} \quad (1)$$

where $r = 1, 2, 3, \dots, R$. R is the total number of context nodes.

$j = 1, 2, 3, \dots, M$. M is the total number of nodes in the hidden layer.

$k = 1, 2, 3, \dots, C$. C is the total number of nodes in the output layer.

e. Calculate the output of each hidden node (O_j) as follows:

$$O_j = f(\text{net}_j) \quad (2)$$

$$\text{net}_j = \sum_{i=1}^N x_i w_{ij}(x_i) + \sum_{r=1}^R O_r w_{rj}(O_r) \quad (3)$$

$$w_{ij}(x_i) = w_{ij}(L_i) + \frac{x_i - L_i}{U_i - L_i} (w_{ij}(U_i) - w_{ij}(L_i)) \quad (4)$$

$$w_{rj}(O_r) = w_{rj}(L_r) + \frac{O_r - L_r}{U_r - L_r} (w_{rj}(U_r) - w_{rj}(L_r)) \quad (5)$$

where $f(\bullet)$ is the activation function. In this paper, the sigmoid function is used as the activation function in both the hidden layer and the output layer.

N is the total number of external input nodes.
 R is the total number of context nodes.
 L_i is a lower bound of the segment that x_i falls into.
 U_i is an upper bound of the segment that x_i falls into.
 L_r is a lower bound of the segment that O_r falls into.
 U_r is an upper bound of the segment that O_r falls into.

f. Calculate the output of each output node (O_k) as follows:

$$O_k = f(\text{net}_k) \quad (6)$$

$$\text{net}_k = \sum_{j=1}^M O_j w_{jk}(O_j) \quad (7)$$

$$w_{jk}(O_j) = w_{jk}(L_j) + \frac{O_j - L_j}{U_j - L_j} (w_{jk}(U_j) - w_{jk}(L_j)) \quad (8)$$

where M is the total number of nodes in the hidden layer.
 L_j is a lower bound of the segment that O_j falls into.
 U_j is an upper bound of the segment that O_j falls into.

g. Compare the desired output (y_k) with the actual output (O_k) and determine the error at the output layer by

$$E = \frac{1}{2} \sum_{k=1}^C (y_k - O_k)^2 \quad (9)$$

where C is the total number of nodes in the output layer.

h. Update the connection weights between the hidden layer and the output layer by using the equations

$$w_{jk}^{\text{new}}(L_j) = w_{jk}^{\text{old}}(L_j) + \eta \left[\frac{\partial E}{\partial w_{jk}(O_j)} \right] \left[\frac{U_j - O_j}{U_j - L_j} \right] \quad (10)$$

$$w_{jk}^{\text{new}}(U_j) = w_{jk}^{\text{old}}(U_j) + \eta \left[\frac{\partial E}{\partial w_{jk}(O_j)} \right] \left[\frac{O_j - L_j}{U_j - L_j} \right] \quad (11)$$

$$\frac{\partial E}{\partial w_{jk}(O_j)} = (y_k - O_k)(O_k(1 - O_k))O_j \quad (12)$$

where η is the learning rate, which has a value between 0 and 1.

i. Update the connection weights between the group of external input units and the hidden layer by using the equations

$$w_{ij}^{\text{new}}(L_i) = w_{ij}^{\text{old}}(L_i) + \eta \left[\frac{\partial E}{\partial w_{ij}(x_i)} \right] \left[\frac{U_i - x_i}{U_i - L_i} \right] \quad (13)$$

$$w_{ij}^{\text{new}}(U_i) = w_{ij}^{\text{old}}(U_i) + \eta \left[\frac{\partial E}{\partial w_{ij}(x_i)} \right] \left[\frac{x_i - L_i}{U_i - L_i} \right] \quad (14)$$

$$\frac{\partial E}{\partial w_{ij}(x_i)} = (O_j(1-O_j))x_i \sum_{k=1}^C (y_k - O_k)(O_k(1-O_k))w_{jk} \quad (15)$$

- j. Update the connection weights between the group of context units and the hidden layer by using the equations

$$w_{rj}^{\text{new}}(L_r) = w_{rj}^{\text{old}}(L_r) + \eta \left[\frac{\partial E}{\partial w_{rj}(O_r)} \right] \left[\frac{U_r - O_r}{U_r - L_r} \right] \quad (16)$$

$$w_{rj}^{\text{new}}(U_r) = w_{rj}^{\text{old}}(U_r) + \eta \left[\frac{\partial E}{\partial w_{rj}(O_r)} \right] \left[\frac{O_r - L_r}{U_r - L_r} \right] \quad (17)$$

$$\frac{\partial E}{\partial w_{rj}(O_r)} = (O_j(1-O_j))O_r \sum_{k=1}^C (y_k - O_k)(O_k(1-O_k))w_{jk} \quad (18)$$

where L_r is a lower bound of the segment that O_r falls into.

U_r is an upper bound of the segment that O_r falls into.

- k. Repeat steps d through j for all remaining input patterns in the training data set.
l. Repeat steps d through k until a predetermined number of iteration is reached or the error is within the acceptable range.

IV. EXPERIMENTAL RESULTS

In this paper, the proposed approach is applied to both the original Elman and Jordan networks. The performance of the modified networks in identifying chaotic dynamical systems are evaluated and compared to the original versions of the Elman and Jordan networks. To test the performance, all four networks were used to model 11 chaotic dynamical systems, which consist of two one-dimensional, two two-dimensional, and seven three-dimensional dynamical systems. The differential equations of the eleven chaotic systems used in this paper are as follows:

- 1) One-dimensional chaotic systems

- a. Mackey-Glass function

$$\frac{dx(t)}{dt} = \frac{ax(t-\tau)}{1+x^{10}(t-\tau)} - bx \quad (19)$$

where $a = 2$, $b = 0.1$, and $\tau = 17$.

- b. Logistic map

$$\frac{dx(t)}{dt} = ax(1-x) \quad (20)$$

where $a = 4$.

- 2) Two-dimensional chaotic systems

- c. Hénon map

$$\frac{dx(t)}{dt} = 1 - ax^2 + y \quad (21)$$

$$\frac{dy(t)}{dt} = bx \quad (22)$$

where $a = 1.4$, $b = 0.3$.

- d. Ikeda map

$$\frac{dx(t)}{dt} = 1 + \mu(x \cos(t) - y \sin(t)) \quad (23)$$

$$\frac{dy(t)}{dt} = \mu(x \sin(t) + y \cos(t)) \quad (24)$$

where $\mu = 0.9$.

- 3) Three-dimensional chaotic systems

- e. Rössler attractor

$$\frac{dx(t)}{dt} = -y - z \quad (25)$$

$$\frac{dy(t)}{dt} = x + ay \quad (26)$$

$$\frac{dz(t)}{dt} = b + z(x - c) \quad (27)$$

where $a = 0.2$, $b = 0.4$, and $c = 5.7$.

- f. Chua's autonomous circuit

$$\frac{dx(t)}{dt} = \alpha(-x + h(x)) \quad (28)$$

$$\frac{dy(t)}{dt} = x - y + z \quad (29)$$

$$\frac{dz(t)}{dt} = -\beta y \quad (30)$$

where $h(x) = bx + 0.5(a-b)(|x+1| - |x-1|)$, $\alpha = 10$, $\beta = 15$, $a = -1.3$, and $b = -0.7$.

- g. Chua's circuit with a cubic nonlinearity

$$\frac{dx(t)}{dt} = \alpha(-x + h(x)) \quad (31)$$

$$\frac{dy(t)}{dt} = x - y + z \quad (32)$$

$$\frac{dz(t)}{dt} = -\beta y \quad (33)$$

where $h(x) = ax + bx^3$, $\alpha = 8.85$, $\beta = 15$, $a = -1.3$, and $b = 0.07$.

- h. Lorenz chaotic system

$$\frac{dx(t)}{dt} = \sigma(y - x) \quad (34)$$

$$\frac{dy(t)}{dt} = rx - y - xz \quad (35)$$

$$\frac{dz(t)}{dt} = xy - bz \quad (36)$$

where $\sigma = 16$, $r = 45.92$, and $b = 4$.

i. Mobius strip

$$x(u, v) = (1 + \frac{1}{2}v \cos \frac{1}{2}u) \cos u \quad (37)$$

$$y(u, v) = (1 + \frac{1}{2}v \cos \frac{1}{2}u) \sin u \quad (38)$$

$$z(u, v) = \frac{1}{2}v \sin \frac{1}{2}u \quad (39)$$

where $0 \leq u < 2\pi$ and $-1 \leq v \leq 1$.

j. Colpitts Oscillator

$$\frac{dx(t)}{dt} = z - \beta \cdot f(y) \quad (40)$$

$$\frac{dy(t)}{dt} = \alpha(-r(y + \varphi) - z - f(y)) \quad (41)$$

$$\frac{dz(t)}{dt} = \delta(-x + y + \varepsilon) - \rho z \quad (42)$$

$$f(y) = \begin{cases} 0 & ; y \leq 1 \\ y-1 & ; \text{otherwise} \end{cases}$$

where $\alpha = 1$, $\beta = 200$, $\varphi = -20/3$, $\delta = 5.5$, $\varepsilon = 20/3$, $\rho = 2$, and $r = 0.25$.

k. RC chaotic oscillator

$$\frac{dx(t)}{dt} = k \cdot m(x - z) - x \quad (43)$$

$$\frac{dy(t)}{dt} = k \cdot n \cdot f(y, z) \quad (44)$$

$$\frac{dz(t)}{dt} = k \cdot m(x - z) - k \cdot n \cdot f(y, z) \quad (45)$$

$$f(y, z) = \begin{cases} z - y & ; z - y \leq 1 \\ 1 & ; \text{otherwise} \end{cases}$$

where $k = 2$, $m = 11$, and $n = 0.9$.

One thousand data points were sampled from each chaotic system. The first 400 data points of the series were used as a training data, while the remaining 600 were used as a testing data.

Since the efficiency of the artificial neural networks depends highly on the user's ability to specify appropriate neural network parameters, a very important parameter of all four models, which is the number of hidden neurons, is varied from 1 to 30 hidden nodes in order to get the best out of the four models.

Results of the experiments are shown in Table 1. Table 1 illustrates the best results (minimum RMSE) of Elman network, Jordan network, the modified Elman network, and the modified Jordan network. Experimental results show that both modified networks, the ones with multi-valued connection weights, are far superior to their original counterparts.

V. CONCLUSION

This paper applies a new concept of the connection weight to a recurrent neural network. Unlike the connection weights of the original recurrent neural network, the weight of each connection in this proposed approach is multi-valued, depending on the value of the input data involved.

TABLE I
EXPERIMENTAL RESULTS

Chaotic function	Elman Network		Jordan Network		Modified Elman Network			Modified Jordan Network		
	RMSE	M	RMSE	M	RMSE	M	S	RMSE	M	S
Mackey-Glass	0.0160	21	0.0367	22	0.0094	19	2	0.0260	5	10
Logistic	0.0376	24	0.0443	30	0.0178	11	10	0.0141	23	10
Hénon	0.0219	11	0.0294	4	0.0111	15	10	0.0134	25	10
Ikeda	0.0303	28	0.0677	26	0.0266	23	1	0.0264	20	10
Rössler	0.0186	13	0.0241	6	0.0098	18	2	0.0120	26	10
Chua's autonomous circuit	0.0238	4	0.0231	9	0.0140	10	1	0.0154	28	2
Chua's circuit with a cubic nonlinearity	0.0192	12	0.0272	10	0.0142	25	2	0.0169	29	2
Lorenz	0.0088	18	0.0153	11	0.0072	25	1	0.0089	16	2
Mobius	0.0173	28	0.0268	9	0.0142	29	10	0.0123	19	2
Colpitts Oscillator	0.0231	14	0.0286	7	0.0150	20	1	0.0151	28	2
RC chaotic oscillator	0.0112	21	0.0218	4	0.0084	30	2	0.0094	21	2

Note: M is the total number of nodes in the hidden layer.

S is the number of segments into which the input data range is divided.

The performance of the proposed approach is evaluated against the original Elman and Jordan recurrent neural networks. All the compared models were used to approximate 11 chaotic functions. The experimental results show that the proposed approach outperforms the original Elman and Jordan networks by a wide margin.

REFERENCES

- [1] S. S. Rao and B. Kumthekar, "A composite neural architecture and algorithm for nonlinear system identification," in *Proceedings of the 1995 Artificial Neural Networks in Engineering Conference (ANNIE' 95)*, 1995, pp. 77 – 84.
- [2] H. Lee and Y. Park, "nonlinear system identification using recurrent networks," in *Proceedings of the 1991 IEEE International Joint Conference on Neural Networks*, 1991, pp. 2410 – 2415.
- [3] D. Karaboga and A. Kalinli, "Training recurrent neural networks for dynamic system identification using parallel tabu search algorithm," in *Proceedings of the 12th IEEE International Symposium on Intelligent Control*, 1997, pp. 113 – 117.
- [4] W. Yu, "Nonlinear system identification using discrete-time recurrent neural networks with stable learning algorithms," *Information Sciences*, vol. 158, 2004, pp. 131 – 147.
- [5] D. T. Pham and D. Karaboga, "Training Elman and Jordan networks for system identification using genetic algorithms," *Artificial Intelligence in Engineering*, vol. 13, no. 2, Elsevier, 1999, pp. 107 – 117.
- [6] J. L. Elman, "Finding structure in time," *Cognitive Science*, vol. 14, 1990, pp. 179 – 211.
- [7] M. I. Jordan, "Attractor dynamics and parallelism in a connectionist sequential machine," in *Proceedings of the Eighth Annual Conference of the Cognitive Science Society*, 1986, pp. 531 – 546.
- [8] Y. C. Cheng, W. M. Qi, and W. Y. Cai, "Dynamic properties of Elman and modified Elman neural network," in *Proceedings of the First International Conference on Machine Learning and Cybernetics*, Beijing, China, 2002, pp. 637 – 640.
- [9] T. B. Chen and V. W. Soo, "A comparative study of recurrent neural network architectures on learning temporal sequences," in *Proceedings of the IEEE International Conference on Neural Networks*, 1996, pp. 1945 – 1950.
- [10] C. Bogdan, *Chaotic Generators Demo*. Available: <http://www.mathworks.com/matlabcentral/fileexchange/8382>.

Nonlinear dynamic system identification using recurrent neural network with multi-segment piecewise-linear connection weight

Arit Thammano · Phongthep Ruxpakawong

Received: 15 July 2009 / Accepted: 19 April 2010
© Springer-Verlag 2010

Abstract This paper introduces a new concept of the connection weight to the standard recurrent neural networks—Elman and Jordan networks. The architecture of the modified networks is the same as that of the original recurrent neural networks. However, unlike the original recurrent neural networks whose connection weight is a single real number, in the modified networks the weight of each connection is multi-valued, depending on the value of the input data involved. The backpropagation learning algorithm is also modified to suit the proposed concept. The modified networks have been benchmarked against the feedforward neural network and the original recurrent neural networks. The experimental results on twelve benchmark problems show that the modified networks are clearly superior to the other three methods.

Keywords Recurrent neural network · Nonlinear dynamic system · Identification

1 Introduction

Neural networks have long been applied successfully to the identification of complex nonlinear system. Even though neural networks have satisfactorily solved most of these problems, they generally require a large number of input neurons and necessitate a long computation time. From a structure

point of view, there are two main types of neural networks: feedforward and recurrent neural networks. A connection in a feedforward neural network (FNN) is unidirectional, which only allows the information to flow from input neurons to output neurons. In a recurrent neural network (RNN), however, there are both the feedforward and feedback connections, which allow the information to flow from input neurons to output neurons and vice versa.

Typically, the feedforward neural networks trained with backpropagation learning algorithm have been widely used for nonlinear system identification. However, since the feedforward neural networks lack the ability to retain information about the infinite past [1], their performance in identifying nonlinear dynamical system is not as good as those of the recurrent neural networks. Many previous research works, such as [2–4], show that RNNs are more suitable than FNNs for representing nonlinear dynamical system. Pham and Karaboga [5] further improve the performances of Elman and Jordan recurrent neural networks for dynamic system identification by training such networks using genetic algorithms (GAs). The results show that GAs are successful in training the Elman recurrent neural network but not the Jordan network. Yu et al. [6] state that the evolutionary algorithms (EAs), which are designed specifically for the stationary optimization problems, may no longer be efficient in dynamic environments. They, therefore, apply immigrants schemes to GA to maintain the diversity of the population throughout the run.

This paper introduces a new concept of the connection weight to the original recurrent neural networks. Typically, each connection weight of the recurrent neural network is a single real number. However, in this paper the weight of each feedforward connection is multi-valued, depending on the value of the input data involved. The performance of the proposed approach is evaluated against the feedforward

A. Thammano (✉) · P. Ruxpakawong
Computational Intelligence Laboratory,
Faculty of Information Technology,
King Mongkut's Institute of Technology Ladkrabang,
Bangkok 10520, Thailand
e-mail: arit@it.kmitl.ac.th

P. Ruxpakawong
e-mail: thep@psru.ac.th

neural network and the two most common recurrent neural networks: Elman and Jordan networks.

This paper is divided into five sections. Following this introduction, Sect. 2 briefly explains the background of recurrent neural networks. Section 3 presents the proposed approach and its learning algorithm. The experimental results are given in Sect. 4. Finally, Sect. 5 is the conclusion.

2 Recurrent neural network

Recurrent neural network (RNN) is a kind of neural network with feedback connections. The existence of these feedback connections gives RNN a big advantage over FNN when it comes to identifying and controlling dynamical systems. Two of the well-known RNNs are Elman and Jordan networks.

Elman network [7] is a neural network with three layers of neurons. The first layer is the input layer which consists of two groups of neurons: the internal input neurons and the external input neurons. The internal input neurons, also called the context units, take in the outputs of neurons in the hidden layer as shown in Fig. 1a. Both the outputs of the context units and the external input units are fed to the neurons in the hidden layer, and then the outputs of the hidden neurons are fed forward to activate the output neurons.




Fig. 1 Well-known recurrent neural networks. a Elman network, b Jordan network

$$O_r^t = O_j^{t-1} \tag{1}$$

$$net_j^t = \sum_{i=1}^N x_i^t w_{ij} + \sum_{r=1}^R O_r^t w_{rj} \tag{2}$$

$$O_j^t = f(net_j^t) \tag{3}$$

$$net_k^t = \sum_{j=1}^M O_j^t w_{jk} \tag{4}$$

$$O_k^t = f(net_k^t) \tag{5}$$

where O_r^t is the output of the context node r at time t . O_j^t and O_j^{t-1} are the outputs of the hidden node j at time t and $t - 1$, respectively. O_k^t is the output of the output node k at time t . w_{ij} is the weight of the connection that connects the external input node i to the hidden node j . w_{rj} is the weight of the connection that connects the context node r to the hidden node j . w_{jk} is the weight of the connection that connects node j in the hidden layer to node k in the output layer. N is the total number of external input nodes. R is the total number of context nodes. M is the total number of nodes in the hidden layer. $f(\bullet)$ is the activation function.

Jordan network [8] also has three layers. The main different from Elman network is that the context units take inputs from the outputs of neurons in the output layer as shown in Fig. 1b.

$$O_r^t = O_k^{t-1} \tag{6}$$

Basically, both Elman and Jordan networks can be trained in the same way as feedforward neural networks by means of the backpropagation learning algorithm. During the training phase, the error is propagated backward from the output layer to adjust the weights of all feedforward connections. However, the weights of the feedback connections must be kept constant, and are not subject to any adjustment.

Cheng et al. [9] suggested that Elman network inherently has only integral (I) dynamic properties, which will result in slow dynamic response and poor convergence speed. Various models that improve on the original Elman and Jordan networks have been proposed. Gao et al. [10] improve the dynamic characteristics and convergence speed of the original Elman network by adding feedforward connections between the context nodes and the output nodes (Fig. 2). This modification provides the modified Elman neural network with the proportional (P) and integral (I) properties, which make this modified Elman network to have a better dynamic response than the original Elman network. Chen and Soo [11] proposed a recurrent neural network which has two kinds of context units as shown in Fig. 3. The first group of context units stores the feedback from the outputs of the hidden layer while the second group stores the feedback of the output layer. Ji and Qi [12] proposed Proportional-Integral-Derivative (PID) Elman neural network (Fig. 4).




Fig. 2 Gao, Gao, and Ovaska's recurrent neural network




Fig. 3 Chen and Soo's recurrent neural network




Fig. 4 Ji and Qi's recurrent neural network

In comparison to PI Elman network proposed by Gao, Gao, and Ovaska, this PID Elman network has an additional group of context units called memory layer. The outputs of the context units are fed to the memory units through the unit delays. Based on the experimental results, the proposed PID Elman network performs better than PI Elman network both in terms of the identification accuracy and the convergence speed.

3 The proposed approach

A new concept of the connection weight proposed in this paper is applied to both the original Elman and Jordan recurrent neural networks. As mentioned in Sect. 2, the recurrent neural network consists of three layers. The first layer is the input layer which consists of two groups of neurons: the internal input neurons and the external input neurons. The number of internal input neurons is equal to the number of neurons in the hidden layer in the case of Elman network and equal

to the number of neurons in the output layer in the case of Jordan network. The number of external input neurons is equal to the number of feature components of the input data. The second layer is the hidden layer. The nodes in the hidden layer are fully connected to the nodes in the input layer and the output layer. The third layer is the output layer.

Once the network receives the input and its associated target output (X, Y) , the training process will begin. In this paper, the input vector is denoted by $X = (x_1^t, x_2^t, \dots, x_i^t, \dots, x_N^t)$, where N is the number of features in X ; the target output is denoted by $Y = (y_1^t, y_2^t, \dots, y_k^t, \dots, y_C^t)$, where C is the number of output nodes. The detail procedure of the training process is as follows:

- (1) Normalize the input data to a value between $[0, 1]$.
- (2) Define the number of nodes in the hidden layer (M) and the maximum number of segments into which the input data range can be divided (MAXSEGMENTS).
- (3) Initialize the weights of all feedforward connections— w_{ij} , w_{rj} , and w_{jk} . In this research, the weight of each feedforward connection is multi-valued, depending on the value of the input data involved. Therefore, the values of the weights w_{ij} , w_{rj} , and w_{jk} depend on the values of x_i^t , O_r^t , and O_j^t , respectively. To initialize the weight of each feedforward connection (w_{ij} , w_{rj} , and w_{jk}), randomly pick 2 numbers between -1 and 1 and let them be the weights at the opposite ends of the input data range (0 and 1).

Considering the ij connection, for example, the weight initialization is performed at the following two points: $w_{ij}(x_i^t = 0)$ and $w_{ij}(x_i^t = 1)$. For the specific ij connection in Fig. 5a, $w_{ij}(x_i^t = 0) = 0.6$ and $w_{ij}(x_i^t = 1) = -0.7$. In Fig. 5b, 0.35 and 0.85 are randomly picked and assigned to be the weights at the points where $O_r^t = 0$ and $O_r^t = 1$, respectively. In Fig. 5c, -0.25 and 0.75 are randomly picked and assigned to be the weights at the points where $O_j^t = 0$ and $O_j^t = 1$, respectively. It is also important to note that at this initialization step all the connection weights consist of only one segment.

- (4) Make a copy of the output from the last time step to form the group of context units. For Elman network, the group of context units is a copy of the hidden layer's previous activations. For Jordan network, the group of context units is a copy of the output layer. Therefore, the number of context units of Elman network is equal to the number of nodes in the hidden layer. For Jordan network, the number of context units is equal to the number of nodes in the output layer.

$$O_r^t = \begin{cases} O_j^{t-1} & \text{for Elman network} \\ O_k^{t-1} & \text{for Jordan network} \end{cases} \quad (7)$$




Fig. 5 Example of the weight initialization

where $r = 1, 2, 3, \dots, R$. R is the total number of context nodes. $j = 1, 2, 3, \dots, M$. M is the total number of nodes in the hidden layer. $k = 1, 2, 3, \dots, C$. C is the total number of nodes in the output layer.

- (5) Calculate the output of each hidden node (O_j^t) as follows:

$$O_j^t = f(\text{net}_j^t) \tag{8}$$

$$\text{net}_j^t = \sum_{i=1}^N x_i^t w_{ij}(x_i^t) + \sum_{r=1}^R O_r^t w_{rj}(O_r^t) \tag{9}$$

$$w_{ij}(x_i^t) = w_{ij}(L_s) + \frac{x_i^t - L_s}{U_s - L_s} \times (w_{ij}(U_s) - w_{ij}(L_s)) \tag{10}$$

$$w_{rj}(O_r^t) = w_{rj}(L_s) + \frac{O_r^t - L_s}{U_s - L_s} \times (w_{rj}(U_s) - w_{rj}(L_s)) \tag{11}$$

where $f(\bullet)$ is the activation function. In this research, the sigmoid function is used as the activation function in both the hidden layer and the output layer. N is the total number of external input nodes. R is the total number of context nodes. s is the segment that

the input x_i^t or O_r^t falls into. L_s is a lower bound of the s th segment. U_s is an upper bound of the s th segment. $w_{ij}(L_s)$ is the weight of the ij connection at the lower bound of the s th segment that x_i^t falls into. $w_{ij}(U_s)$ is the weight of the ij connection at the upper bound of the s th segment that x_i^t falls into. $w_{rj}(L_s)$ is the weight of the rj connection at the lower bound of the s th segment that O_r^t falls into. $w_{rj}(U_s)$ is the weight of the rj connection at the upper bound of the s th segment that O_r^t falls into.

- (6) Calculate the output of each output node (O_k^t) as follows:

$$O_k^t = f(\text{net}_k^t) \tag{12}$$

$$\text{net}_k^t = \sum_{j=1}^M O_j^t w_{jk}(O_j^t) \tag{13}$$

$$w_{jk}(O_j^t) = w_{jk}(L_s) + \frac{O_j^t - L_s}{U_s - L_s} \times (w_{jk}(U_s) - w_{jk}(L_s)) \tag{14}$$

where M is the total number of nodes in the hidden layer. $w_{jk}(L_s)$ is the weight of the jk connection at the lower bound of the s th segment that O_j^t falls into. $w_{jk}(U_s)$ is the weight of the jk connection at the upper bound of the s th segment that O_j^t falls into.

- (7) Compare the desired output (y_k^t) with the actual output (O_k^t) and determine the error at the output layer by

$$E = \frac{1}{2} \sum_{k=1}^C (y_k^t - O_k^t)^2 \tag{15}$$

where C is the total number of nodes in the output layer.

- (8) Update the connection weights between the hidden layer and the output layer by using the equations

$$w_{jk}^{\text{new}}(L_s) = w_{jk}^{\text{old}}(L_s) + \eta \Delta_{jk} L_s \tag{16}$$

$$w_{jk}^{\text{new}}(U_s) = w_{jk}^{\text{old}}(U_s) + \eta \Delta_{jk} U_s \tag{17}$$

$$\Delta_{jk} L_s = \left[\frac{\partial E}{\partial w_{jk}(O_j^t)} \right] \left[\frac{U_s - O_j^t}{U_s - L_s} \right] \tag{18}$$

$$\Delta_{jk} U_s = \left[\frac{\partial E}{\partial w_{jk}(O_j^t)} \right] \left[\frac{O_j^t - L_s}{U_s - L_s} \right] \tag{19}$$

$$\frac{\partial E}{\partial w_{jk}(O_j^t)} = (y_k^t - O_k^t)(O_k^t(1 - O_k^t))O_j^t \tag{20}$$

where η is the learning rate, which has a value between 0 and 1.

- (9) Update the connection weights between the group of external input units and the hidden layer by using the equations

$$w_{ij}^{new}(L_s) = w_{ij}^{old}(L_s) + \eta \Delta_{ij} L_s \tag{21}$$

$$w_{ij}^{new}(U_s) = w_{ij}^{old}(U_s) + \eta \Delta_{ij} U_s \tag{22}$$

$$\Delta_{ij} L_s = \left[\frac{\partial E}{\partial w_{ij}(x_i^t)} \right] \left[\frac{U_s - x_i^t}{U_s - L_s} \right] \tag{23}$$

$$\Delta_{ij} U_s = \left[\frac{\partial E}{\partial w_{ij}(x_i^t)} \right] \left[\frac{x_i^t - L_s}{U_s - L_s} \right] \tag{24}$$

$$\frac{\partial E}{\partial w_{ij}(x_i^t)} = (O_j^t(1 - O_j^t))x_i^t \times \sum_{k=1}^C (y_k^t - O_k^t)(O_k^t(1 - O_k^t))w_{jk} \tag{25}$$

- (10) Update the connection weights between the group of context units and the hidden layer by using the equations

$$w_{rj}^{new}(L_s) = w_{rj}^{old}(L_s) + \eta \Delta_{rj} L_s \tag{26}$$

$$w_{rj}^{new}(U_s) = w_{rj}^{old}(U_s) + \eta \Delta_{rj} U_s \tag{27}$$

$$\Delta_{rj} L_s = \left[\frac{\partial E}{\partial w_{rj}(O_r^t)} \right] \left[\frac{U_s - O_r^t}{U_s - L_s} \right] \tag{28}$$

$$\Delta_{rj} U_s = \left[\frac{\partial E}{\partial w_{rj}(O_r^t)} \right] \left[\frac{O_r^t - L_s}{U_s - L_s} \right] \tag{29}$$

$$\frac{\partial E}{\partial w_{rj}(O_r^t)} = (O_j^t(1 - O_j^t))O_r^t \times \sum_{k=1}^C (y_k^t - O_k^t)(O_k^t(1 - O_k^t))w_{jk} \tag{30}$$

- (11) Repeat steps 4 through 10 for all remaining input patterns in the training data set.
- (12) Evaluate the weight updates occurred at the lower bound and the upper bound of each s th segment in the last training iteration whether the lower bound and the upper bound were updated in the same direction. If they were updated in different directions, the s th segment must be split into two separate segments in order to allow both end of the segment to be entirely independent of one another. For example, in Fig. 6 the lower bound of the s th segment was updated in the positive direction, while the upper bound was updated




Fig. 6 An example of the case that the lower bound and the upper bound of the s th segment were updated in different directions

in the negative direction. The number of segments into which the input data range may be split cannot exceed MAXSEGMENTS. Therefore, if the number of segments into which the input data range is split is already equal to MAXSEGMENTS, skip this step and go to step 13. However if the number of segments is less than MAXSEGMENTS, perform the splitting procedure as follows:

- a. For each segment of the ij , rj , and jk connections, combine all positive $\Delta \bullet L_s$ together, all negative $\Delta \bullet L_s$ together, all positive $\Delta \bullet U_s$ together, and all negative $\Delta \bullet U_s$ together.

$$\Delta \bullet L_s^+ = \sum_{\forall \Delta \bullet L_s: \Delta \bullet L_s > 0} (\Delta \bullet L_s) \tag{31}$$

$$\Delta \bullet L_s^- = \sum_{\forall \Delta \bullet L_s: \Delta \bullet L_s < 0} |\Delta \bullet L_s| \tag{32}$$

$$\Delta \bullet U_s^+ = \sum_{\forall \Delta \bullet U_s: \Delta \bullet U_s > 0} (\Delta \bullet U_s) \tag{33}$$

$$\Delta \bullet U_s^- = \sum_{\forall \Delta \bullet U_s: \Delta \bullet U_s < 0} |\Delta \bullet U_s| \tag{34}$$

- b. Since the lower bound of the s th segment and the upper bound of the $(s - 1)$ th segment are the same point, combine the weight update value at the lower bound of the s th segment with the weight update value at the upper bound of the $(s - 1)$ th segment by using the Eqs. (35) and (36). Similarly, combine the weight update value at the upper bound of the s th segment with the weight update value at the lower bound of the $(s + 1)$ th segment by using the Eqs. (37) and (38).

$$P_s^{L^+} = \Delta \bullet L_s^+ + \Delta \bullet U_{s-1}^+ \tag{35}$$

$$P_s^{L^-} = \Delta \bullet L_s^- + \Delta \bullet U_{s-1}^- \tag{36}$$

$$P_s^{U^+} = \Delta \bullet U_s^+ + \Delta \bullet L_{s+1}^+ \tag{37}$$

$$P_s^{U^-} = \Delta \bullet U_s^- + \Delta \bullet L_{s+1}^- \tag{38}$$

- c. Compare the direction of the weight updates occurred at the lower bound with that occurred at

the upper bound of each s th segment.

$$P_s^L = \frac{P_s^{L+} - P_s^{L-}}{\max(P_s^{L+}, P_s^{L-})} \quad (39)$$

$$P_s^U = \frac{P_s^{U+} - P_s^{U-}}{\max(P_s^{U+}, P_s^{U-})} \quad (40)$$

$$P_s = P_s^L \cdot P_s^U \quad (41)$$

“ $P_s > 0$ ” means that both the lower bound and the upper bound of the s th segment were updated in the same direction. On the other hand, “ $P_s < 0$ ” means that they were updated in different directions.

Therefore, if P_s is greater than 0, skip this step and go to step 13. However, if P_s is less than 0, the s th segment will be split into two separate segments.

- d. Determine the splitting point (sp) for the s th segment whose P_s value is less than 0.

$$\bar{I}_s^+ = \frac{\sum_{I: (L_s \leq I \leq U_s) \wedge (\Delta w_{\bullet}(I) > 0)} I}{\sum_{I: (L_s \leq I \leq U_s) \wedge (\Delta w_{\bullet}(I) > 0)} 1} \quad (42)$$

$$\bar{I}_s^- = \frac{\sum_{I: (L_s \leq I \leq U_s) \wedge (\Delta w_{\bullet}(I) < 0)} I}{\sum_{I: (L_s \leq I \leq U_s) \wedge (\Delta w_{\bullet}(I) < 0)} 1} \quad (43)$$

$$sp = \frac{\bar{I}_s^+ + \bar{I}_s^-}{2} \quad (44)$$

where $\Delta w_{\bullet}(I) = \frac{\partial E}{\partial w_{\bullet}(I)}$

The variable I represents the input x_i^t , O_r^t , or O_j^t . Equations (42), (43), and (44) are used to determine the splitting point for the s th segment of the ij , rj , and jk connections. For the s th segment of the ij connection, $I = x_i^t$ and $\bullet = ij$. For the s th segment of the rj connection, $I = O_r^t$ and $\bullet = rj$. For the s th segment of the jk connection, $I = O_j^t$ and $\bullet = jk$.

- (13) Merge the unused segments. Any two segments will be joined together if (1) they are adjacent to each other and (2) they were not used in the last training iteration.
- (14) Repeat steps 4 through 13 until a predetermined number of iteration is reached or the error is within the acceptable range. Figure 7 is an example of a connection weight before and after the training process.

4 Experimental results

In this paper, the proposed approach is applied to both the original Elman and Jordan networks. The performance of the modified networks in identifying chaotic dynamical systems is evaluated and compared to the feedforward neural network and the original versions of the Elman and Jordan networks. To test the performance, all five networks were used to model 12 chaotic dynamical systems [13], which consist of two one-dimensional, two two-dimensional, seven three-dimensional,




Fig. 7 Example of a connection weight a before and b after the training process

and one four-dimensional dynamical systems. The differential equations of the twelve chaotic systems used in this paper are as follows:

(1) One-dimensional chaotic systems

- a. Mackey–Glass function

$$\frac{dx(t)}{dt} = \frac{ax(t - \tau)}{1 + x^{10}(t - \tau)} - bx \quad (45)$$

where $a = 2$, $b = 0.1$, and $\tau = 17$.

- b. Logistic map

$$\frac{dx(t)}{dt} = ax(1 - x) \quad (46)$$

where $a = 4$.

(2) Two-dimensional chaotic systems

- c. Hénon map

$$\frac{dx(t)}{dt} = 1 - ax^2 + y \quad (47)$$

$$\frac{dy(t)}{dt} = bx \quad (48)$$

where $a = 1.4$, $b = 0.3$.

- d. Ikeda map

$$\frac{dx(t)}{dt} = 1 + \mu(x \cos(t) - y \sin(t)) \quad (49)$$

$$\frac{dy(t)}{dt} = \mu(x \sin(t) + y \cos(t)) \quad (50)$$

where $\mu = 0.9$.

(3) Three-dimensional chaotic systems

e. Rössler attractor

$$\frac{dx(t)}{dt} = -y - z \tag{51}$$

$$\frac{dy(t)}{dt} = x + ay \tag{52}$$

$$\frac{dz(t)}{dt} = b + z(x - c) \tag{53}$$

where $a = 0.2, b = 0.4,$ and $c = 5.7.$

f. Chua's autonomous circuit

$$\frac{dx(t)}{dt} = \alpha(-x + h(x)) \tag{54}$$

$$\frac{dy(t)}{dt} = x - y + z \tag{55}$$

$$\frac{dz(t)}{dt} = -\beta y \tag{56}$$

where $h(x) = bx + 0.5(a - b)(|x + 1| - |x - 1|),$
 $\alpha = 10, \beta = 15, a = -1.3,$ and $b = -0.7.$

g. Chua's circuit with a cubic nonlinearity

$$\frac{dx(t)}{dt} = \alpha(-x + h(x)) \tag{57}$$

$$\frac{dy(t)}{dt} = x - y + z \tag{58}$$

$$\frac{dz(t)}{dt} = -\beta y \tag{59}$$

where $h(x) = ax + bx^3, \alpha = 8.85, \beta = 15,$
 $a = -1.3,$ and $b = 0.07.$

h. Lorenz chaotic system

$$\frac{dx(t)}{dt} = \sigma(y - x) \tag{60}$$

$$\frac{dy(t)}{dt} = rx - y - xz \tag{61}$$

$$\frac{dz(t)}{dt} = xy - bz \tag{62}$$

where $\sigma = 16, r = 45.92,$ and $b = 4.$

i. Colpitts oscillator

$$\frac{dx(t)}{dt} = z - \beta \cdot f(y) \tag{63}$$

$$\frac{dy(t)}{dt} = \alpha(-r(y + \varphi) - z - f(y)) \tag{64}$$

$$\frac{dz(t)}{dt} = \delta(-x + y + \varepsilon) - \rho z \tag{65}$$

where

$$f(y) = \begin{cases} 0; & y \leq 1 \\ y - 1; & \text{otherwise} \end{cases}$$

$\alpha = 1, \beta = 200, \varphi = -20/3, \delta = 5.5, \varepsilon = 20/3,$
 $\rho = 2,$ and $r = 0.25.$

j. RC chaotic oscillator

$$\frac{dx(t)}{dt} = k \cdot m(x - z) - x \tag{66}$$

$$\frac{dy(t)}{dt} = k \cdot n \cdot f(y, z) \tag{67}$$

$$\frac{dz(t)}{dt} = k \cdot m(x - z) - k \cdot n \cdot f(y, z) \tag{68}$$

where

$$f(y, z) = \begin{cases} z - y; & z - y \leq 1 \\ 1; & \text{otherwise} \end{cases}$$

$k = 2, m = 11,$ and $n = 0.9.$

k. Third order RC ladder phase shift oscillator

$$\frac{dx(t)}{dt} = -2x + y + f(z) \tag{69}$$

$$\frac{dy(t)}{dt} = x - 2y + z \tag{70}$$

$$\frac{dz(t)}{dt} = y - z \tag{71}$$

where

$$f(z) = \begin{cases} m_b \cdot z + m_b - m_a; & z < -1 \\ m_a \cdot z; & -1 \leq z \leq 1 \\ m_b \cdot z - m_b + m_a; & \text{otherwise} \end{cases}$$

$m_a = -33.03, m_b = 250, x(t = 0) = 3,$
 $y(t = 0) = 0,$ and $z(t = 0) = -1.$

(4) Four-dimensional chaotic system

1. Four-dimensional autonomous chaotic circuit

$$\frac{dx(t)}{dt} = \delta \cdot (x + \gamma \cdot y) - z - f_{d1}(x) \tag{72}$$

$$\frac{dy(t)}{dt} = \beta \cdot (\delta \cdot (x + \gamma \cdot y) - w - \gamma \cdot f_{d2}(y)) \tag{73}$$

$$\frac{dz(t)}{dt} = x \tag{74}$$

$$\frac{dw(t)}{dt} = \alpha \cdot y \tag{75}$$

where

$$f_{dk}(x) = \frac{0.5 \cdot (|x - 1| + x - 1)}{\varepsilon_k}; \quad k = 1, 2$$

$\alpha = 2, \beta = 0.17, \gamma = 3, \delta = 0.27, \varepsilon_1 = 0.8,$
 $\varepsilon_2 = 0.2, x(t = 0) = 0.1, y(t = 0) = 0,$
 $z(t = 0) = 0,$ and $w(t = 0) = 0.$

Two thousand data points were sampled from each chaotic system. The first 1,000 data points of the series were used as a training data, while the remaining 1,000 were used as a testing data.

Since the efficiency of the artificial neural networks depends highly on the user's ability to specify appropriate

Table 1 Experimental results: RMSE of the tested models

Chaotic function	Feedforward network		Elman network		Jordan network		Modified Elman network			Modified Jordan network		
	RMSE	<i>M</i>	RMSE	<i>M</i>	RMSE	<i>M</i>	RMSE	<i>M</i>	<i>S</i>	RMSE	<i>M</i>	<i>S</i>
Mackey–Glass	0.0357	8	0.0163	8	0.0307	3	0.0116	41	1–15	0.0157	3	20–20
Logistic	0.0415	38	0.0251	30	0.0367	30	0.0166	3	1–10	0.0112	49	1–15
Hénon	0.0272	50	0.0193	48	0.0223	48	0.0160	34	1–20	0.0098	50	1–20
Ikeda	0.0797	37	0.0225	42	0.0559	19	0.0193	26	1–1	0.0162	49	1–15
Rössler	0.0210	14	0.0189	12	0.0208	12	0.0114	36	1–15	0.0158	43	1–20
Chua's autonomous circuit	0.0216	7	0.0246	5	0.0213	8	0.0115	49	1–20	0.0143	49	1–15
Chua's circuit with a cubic nonlinearity	0.0227	18	0.0209	6	0.0220	12	0.0153	47	1–20	0.0162	48	1–15
Lorenz	0.0213	7	0.0157	18	0.0166	9	0.0136	8	1–2	0.0144	14	1–1
Colpitts oscillator	0.0186	37	0.0169	8	0.0186	36	0.0135	45	1–20	0.0139	49	1–15
RC chaotic oscillator	0.0206	10	0.0128	7	0.0196	6	0.0114	50	1–15	0.0123	45	1–20
Third order RC ladder phase shift oscillator	0.0205	13	0.0182	9	0.0207	34	0.0204	42	1–20	0.0187	50	1–15
Four dimensional autonomous chaotic circuit	0.0237	14	0.0232	20	0.0235	14	0.0202	6	1–1	0.0199	11	1–1

M total number of nodes in the hidden layer. *S* number of segments into which the input data range is divided

neural network parameters, a very important parameter of all five models, which is the number of hidden neurons, is varied from 1 to 50 hidden nodes in order to get the best out of the five models. The training process is terminated when either of the following two conditions holds: (1) the root mean square error (RMSE) is less than 0.02, or (2) the number of training epochs reaches 1,000.

Results of the experiments are shown in Tables 1 and 2. Table 1 illustrates the best results (minimum RMSE) of the feedforward neural network, Elman network, Jordan network, the modified Elman network, and the modified Jordan network. In the modified networks, each weight is divided into different number of segments. Some have many segments while others have only a few. The variable *S* in Table 1 is in the format of two numbers separated by dash. The first number is the minimum number of segments. The second number is the maximum number of segments. The following summarizes the percentage of improvement in RMSE of the modified networks over both their original counterparts and the feedforward neural network:

- The performance of the modified Elman network is better than the performance of the feedforward neural network by 75.78, 67.51, 60.00, 46.76, 45.71, 44.66, 41.18, 36.15, 32.60, 27.42, 14.77, and 0.49% for Ikeda, Mackey–Glass, Logistic, Chua's autonomous circuit, Rössler, RC chaotic oscillator, Hénon, Lorenz, Chua's circuit with a cubic nonlinearity, Colpitts oscillator, Four dimensional autonomous chaotic circuit, and Third order RC ladder phase shift oscillator, respectively.

- The performance of the modified Elman network is better than the performance of the Elman network by 53.25, 39.68, 33.86, 28.83, 26.79, 20.12, 17.10, 14.22, 13.38, 12.93, 10.94, and –12.09% for Chua's autonomous circuit, Rössler, Logistic, Mackey–Glass, Chua's circuit with a cubic nonlinearity, Colpitts oscillator, Hénon, Lorenz, Four dimensional autonomous chaotic circuit, RC chaotic oscillator, and Third order RC ladder phase shift oscillator, respectively.
- The performance of the modified Jordan network is better than the performance of the feedforward neural network by 79.67, 73.01, 63.97, 56.02, 40.29, 33.80, 32.39, 28.63, 25.27, 24.76, 16.03, and 8.78% for Ikeda, Logistic, Hénon, Mackey–Glass, RC chaotic oscillator, Chua's autonomous circuit, Lorenz, Chua's circuit with a cubic nonlinearity, Colpitts oscillator, Rössler, Four dimensional autonomous chaotic circuit, and Third order RC ladder phase shift oscillator, respectively.
- The performance of the modified Jordan network is better than the performance of the Jordan network by 71.02, 69.48, 56.05, 48.86, 37.24, 32.86, 26.36, 25.27, 24.04, 15.32, 13.25, and 9.66% for Ikeda, Logistic, Hénon, Mackey–Glass, RC chaotic oscillator, Chua's autonomous circuit, Chua's circuit with a cubic nonlinearity, Colpitts oscillator, Rössler, Four dimensional autonomous chaotic circuit, Lorenz, and Third order RC ladder phase shift oscillator, respectively.

Table 2 illustrates the number of iterations and the training time each model requires to reach the stopping criteria. With

Table 2 Experimental results: the number of iterations the tested models require to reach the stopping criteria

Chaotic function	Number of training epochs				
	Feedforward network	Elman network	Jordan network	Modified Elman network	Modified Jordan network
Mackey–Glass	1,000 (00-05-37)	785 (00-03-57)	1,000 (00-05-09)	6 (00-03-17)	564 (00-03-12)
Logistic	1,000 (00-12-28)	1,000 (02-24-29)	1,000 (00-16-38)	48 (00-00-12)	11 (00-00-16)
Hénon	1,000 (00-28-59)	309 (01-53-10)	1,000 (00-43-31)	12 (00-02-53)	10 (00-00-39)
Ikeda	1,000 (00-23-50)	1,000 (04-47-37)	1,000 (00-19-21)	904 (01-30-36)	12 (00-00-41)
Rössler	927 (00-12-45)	384 (00-07-41)	820 (00-12-22)	11 (00-02-51)	12 (00-00-52)
Chua's autonomous circuit	328 (00-02-31)	104 (00-00-28)	199 (00-02-23)	6 (00-05-13)	8 (00-00-54)
Chua's circuit with a cubic nonlinearity	1,000 (00-18-14)	628 (00-07-58)	971 (00-17-36)	6 (00-05-01)	8 (00-00-55)
Lorenz	282 (00-02-24)	119 (00-04-04)	838 (00-05-39)	137 (00-01-42)	288 (00-03-57)
Colpitts oscillator	978 (00-33-22)	922 (00-17-11)	872 (00-44-38)	8 (00-04-30)	9 (00-00-51)
RC chaotic oscillator	270 (00-02-33)	481 (00-04-20)	301 (00-03-09)	10 (00-05-13)	12 (00-00-57)
Third order RC ladder phase shift oscillator	783 (00-06-42)	314 (00-04-08)	882 (00-23-41)	10 (00-03-57)	8 (00-00-47)
Four dimensional autonomous chaotic circuit	1,000 (00-19-33)	219 (00-19-22)	1,000 (00-24-10)	459 (00-06-57)	410 (00-10-13)

The figures in brackets, which are in the format of HH-MM-SS, indicate the time used in training the models
The machines used in the experiments are Pentium IV 3.0 GHz PCs with 512 MB of RAM, running Window XP

the modified networks, the training is significantly faster than their original counterparts. Even though the training time per epoch is longer for the modified networks, the total training time of the modified networks is lower due to their ability to learn every dynamical system within a small number of training iterations.

In summary, experimental results from Tables 1 and 2 show that both modified networks, the ones with multi-segment piecewise-linear connection weights, are far superior to both their original counterparts and the feedforward neural network.

5 Conclusion

This paper applies a new concept of the connection weight to the standard Elman and Jordan recurrent neural networks. Unlike the connection weights of the original recurrent neural networks, the weight of each connection in this proposed approach is multi-valued, depending on the value of the input data involved. The performance of the modified networks is evaluated against the feedforward neural network and the original Elman and Jordan recurrent neural networks. All the compared models were used to approximate 12 chaotic functions. The experimental results show that the modified networks outperform the other three networks by a wide margin.

References

1. Rao SS, Kumthekar B (1995) A composite neural architecture and algorithm for nonlinear system identification. In: Proceedings of the 1995 artificial neural networks in engineering conference (ANNIE' 95), pp 77–84
2. Lee H, Park Y (1991) Nonlinear system identification using recurrent networks. In: Proceedings of the 1991 IEEE international joint conference on neural networks, pp 2410–2415
3. Karaboga D, Kalinli A (1997) Training recurrent neural networks for dynamic system identification using parallel tabu search algorithm. In: Proceedings of the 12th IEEE international symposium on intelligent control, pp 113–117
4. Yu W (2004) Nonlinear system identification using discrete-time recurrent neural networks with stable learning algorithms. *Inf Sci* 158:131–147
5. Pham DT, Karaboga D (1999) Training Elman and Jordan networks for system identification using genetic algorithms. *Artificial Intelligence in Engineering* 13, no 2, Elsevier, Amsterdam, pp 107–117
6. Yu X, Tang K, Chen T, Yao X (2009) Empirical analysis of evolutionary algorithms with immigrants schemes for dynamic optimization. *Memetic Computing*, vol 1, no 1, Springer, Berlin, pp 3–24
7. Elman JL (1990) Finding structure in time. *Cognitive Science* 14:179–211
8. Jordan MI (1986) Attractor dynamics and parallelism in a connectionist sequential machine. In: Proceedings of the eighth annual conference of the cognitive science society, pp 531–546
9. Cheng YC, Qi WM, Cai WY (2002) Dynamic properties of Elman and modified Elman neural network. In: Proceedings of the first international conference on machine learning and cybernetics, pp 637–640
10. Gao XZ, Gao XM, Ovaska SJ (1996) A modified Elman neural network model with application to dynamical systems identification.

- In: Proceedings of the IEEE international conference on systems, man, and cybernetics, pp 1376–1381
11. Chen TB, Soo VW (1996) A comparative study of recurrent neural network architectures on learning temporal sequences. In: Proceedings of the IEEE international conference on neural networks, pp 1945–1950
 12. Ji QL, Qi WM (2007) The property of PID Elman neural network and its application in identification of hydraulic unit. In: Proceedings of the 2007 IEEE international conference on control and automation, pp 1795–1798
 13. Bogdan C (Online) Chaotic Generators Demo. Available at <http://www.mathworks.com/matlabcentral/fileexchange/8382>



ประวัติผู้เขียน

ชื่อ-นามสกุล นายพงษ์เทพ รักผกาวงศ์
วัน เดือน ปีเกิด 2 พฤษภาคม 2513 ที่จังหวัดพิษณุโลก
ที่อยู่ 66 หอศิลป์พฤษภรณ์(101) ต.ในเมือง อ.เมือง จ.พิษณุโลก 65000
ประวัติการศึกษา พ.ศ. 2537 วิทยาศาสตรบัณฑิต (วิทยาการคอมพิวเตอร์)
มหาวิทยาลัยกรุงเทพ
พ.ศ. 2545 วิทยาศาสตรมหาบัณฑิต (เทคโนโลยีสารสนเทศ)
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
ประสบการณ์การทำงาน
พ.ศ. 2540-ปัจจุบัน ตำแหน่งอาจารย์ สถาบันราชภัฏพิบูลสงคราม ปัจจุบันเปลี่ยนเป็น
มหาวิทยาลัยราชภัฏพิบูลสงคราม



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้