

แบบจำลองของช่างงานนิวรรค์ สำหรับทำนายเปอร์เซ็นต์ของแข็งของแชมพู



นางสาว วิไลรัตน์ แซ่หยาง

สถาบันวิทยบริการ

จุฬาลงกรณ์มหาวิทยาลัย

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมเคมี ภาควิชาวิศวกรรมเคมี

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2548

ISBN 974-17-5267-9

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

NEURAL NETWORKS MODEL FOR PREDICTION OF SOLID PERCENTAGE OF SHAMPOO



Miss Wilairat Saeyang

สถาบันวิทยบริการ
A Thesis Submitted in Partial Fulfillment of Requirements
for the Degree of Master of Engineering Program in Chemical Engineering
Department of Chemical Engineering

Faculty of Engineering

Chulalongkorn University

Academic Year 2005

ISBN 974-17-5267-9

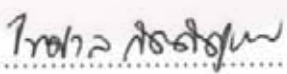
หัวข้อวิทยานิพนธ์ แบบจำลองของหน่วยงานนิรวัล สำหรับทำนายเปอร์เซ็นต์ของแข็งของแอมพู
โดย นางสาว วิไลรัตน์ แซ่หยาง
สาขาวิชา วิศวกรรมเคมี
อาจารย์ที่ปรึกษา รองศาสตราจารย์ ดร. ไพศาล กิตติสุภกร

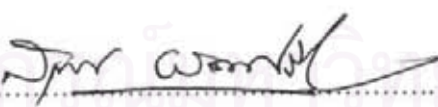
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้นับวิทยานิพนธ์ฉบับนี้เป็น
ส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต


..... คณบดีคณะวิศวกรรมศาสตร์
(ศาสตราจารย์ ดร.ดิเรก ลาวัณย์ศิริ)

คณะกรรมการสอบวิทยานิพนธ์


..... ประธานกรรมการ
(รองศาสตราจารย์ ดร.ธวัชชัย ชรินพานิชกุล)


..... อาจารย์ที่ปรึกษา
(รองศาสตราจารย์ ดร. ไพศาล กิตติสุภกร)


..... กรรมการ
(อาจารย์ ดร.สุพจน์ พัฒนะศรี)


..... กรรมการ
(อาจารย์ ดร.อมรชัย อภรณ์วิชานพ)

วิไลรัตน์ แซ่หยาง : แบบจำลองของข่ายงานนิวรัลสำหรับทำนายเปอร์เซ็นต์ของแข็งของแชมพู.
(NEURAL NETWORKS MODEL FOR PREDICTION OF SOLID PERCENTAGE OF SHAMPOO) อ. ที่ปรึกษา : รศ. ดร. ไพศาล กิตติศุภกร, 116 หน้า. ISBN 974-17-5267-9.

งานวิจัยนี้เป็นการสร้างแบบจำลองข่ายงานนิวรัล สำหรับทำนายเปอร์เซ็นต์ของแข็งและความหนืดของแชมพูในถังผลิตแชมพู ข้อมูลที่ใช้ในการฝึกและทดสอบข่ายงานได้จากการทำการทดลองผลิตแชมพู โดยเปลี่ยนอุณหภูมิของถังผลิตตั้งแต่ 25 – 50 °C, เวลาในการผลิตตั้งแต่ 10 – 35 นาที และอัตราส่วนผสมที่ใช้ของสารเคมีและน้ำเป็น 1 และ 2 ในการออกแบบโครงสร้างข่ายงานนิวรัลใช้การเชื่อมโยงแบบการกระจายความผิดพลาดย้อนกลับ และอัลกอริธึมการเรียนรู้แบบบริเวณเบอกรี-มาร์ควอร์ในการฝึกข่ายงาน เปรียบเทียบผลความแตกต่างระหว่างผลจากการทำนายและผลจากการทดลองโดยใช้ค่าดัชนีเปอร์เซ็นต์ความผิดพลาดกำลังสองเฉลี่ยน้อยสุด (Root Mean Square Percent Error Index: RMSPE) และค่าดัชนีเปอร์เซ็นต์ความผิดพลาดมากที่สุด (Maximum Percent Error Index: MPE) และคัดเลือกข่ายงานโดยใช้ค่าสมรรถนะความถูกต้องในการทำนาย (Accuracy Performance)

ผลจากการจำลองพบว่าข่ายงานนิวรัลแบบการกระจายย้อนกลับ 2 ชั้นซ่อนที่มี 5 โหนดในชั้นซ่อนที่ 1 และ 9 โหนดในชั้นซ่อนที่ 2 สามารถทำนายเปอร์เซ็นต์ของแข็งและความหนืดได้ใกล้เคียงที่สุด ซึ่งค่าดัชนีความผิดพลาด RMSPE และ MPE ของการทำนายเปอร์เซ็นต์ของแข็งมีค่าเท่ากับ 9.71% และ 8.33% ตามลำดับ, ค่าดัชนีความผิดพลาดทั้งสองของการทำนาย ความหนืดมีค่าเท่ากับ 15.73% และ 42.83% ตามลำดับ และสมรรถนะความถูกต้องในการทำนายเป็น 80.85%

สถาบันวิทยบริการ จุฬาลงกรณ์มหาวิทยาลัย

ภาควิชา.....วิศวกรรมเคมี.....ลายมือชื่อนิสิต.....ไพศาล แซ่หยาง.....
สาขาวิชา.....วิศวกรรมเคมี.....ลายมือชื่ออาจารย์ที่ปรึกษา.....ไพศาล กิตติศุภกร.....
ปีการศึกษา.....2548.....ลายมือชื่ออาจารย์ที่ปรึกษาร่วม.....-

4571463121 : MAJOR CHEMICAL ENGINEERING

KEY WORD: NEURAL NETWORK MODEL / PREDICTION/ SOLID PERCENTAGE OF SHAMPOO

WILAIRAT SAEYANG : NEURAL NETWORKS MODEL FOR PREDICTION OF SOLID PERCENTAGE OF SHAMPOO. THESIS ADVISOR : ASSOC.PROF PAISAN KITTISUPAKORN Ph.D., 116 pp. ISBN 974-17-5267 -9.

This research describes neural network models for the prediction of the solid percentage and viscosity of shampoo in a shampoo production tank. The data used for training and testing the neural network models, have been gathered from experiments with respect to changes in the tank's temperature of 25 – 50 °C, production time of 10 – 35 minutes and mixing compounds with the ratio of chemical components to water of 1 and 2. Backpropagation and Levenberg-Marquardt techniques have been used to train varied neural network architectures and Root Mean Square Percent (RMSP) Error and Maximum Percent (MP) Error Indices have been employed to evaluate the accuracy of the obtained models.

The simulation results show that the multiplayer feed forward neural network model with two hidden layers (5 node in first hidden layer and 9 node in second hidden layer) provide the best prediction of the solid percentage and viscosity. Its RMSP and MP indices of the solid percentage are 9.71 % and 8.83% respectively and those of the viscosity are 15.73% and 42.83% respectively with accuracy performance of 80.85%.

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

Department.....Chemical Engineering..... Student's signature.....
Field of study.....Chemical Engineering..... Advisor's signature.....
Academic year.....2005..... Co-advisor's signature.....

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลงได้โดยได้รับความช่วยเหลือจากหลายฝ่าย ข้าพเจ้าขอขอบพระคุณ รศ. ดร. ไพศาล กิตติศุภกร ที่ได้กรุณาให้คำปรึกษา, แนะนำแนวทางการทำงานวิจัย, แนวทางการแก้ปัญหา, ให้ข้อคิดเห็นต่างๆ, ตลอดจนการตรวจทานแก้ไขวิทยานิพนธ์จนสำเร็จเป็นรูปเล่มที่สมบูรณ์

ข้าพเจ้าขอขอบพระคุณคณะกรรมการสอบวิทยานิพนธ์ทั้ง 3 ท่าน ประกอบด้วย ประธานกรรมการ รศ.ดร.ธวัชชัย ชรินพานิชกุล, กรรมการ ดร.สุพจน์ พัฒนะศรี และ กรรมการ ดร.อมรชัย อภรณ์วิชานพ ซึ่งได้ให้ความสนใจและให้ข้อคิดเห็นที่เป็นประโยชน์เพิ่มเติมทำให้วิทยานิพนธ์ฉบับนี้ มีความสมบูรณ์ยิ่งขึ้น

นอกจากนี้ข้าพเจ้าขอขอบคุณ บริษัท วีร่า อัสสเลย์ จำกัด ที่เอื้อเฟื้อตัวอย่างสำหรับทำการทดลอง, สถานที่, และเครื่องมือต่างๆ ทำให้งานวิจัยของข้าพเจ้าสำเร็จลุล่วงไปได้ด้วยดี และที่ขาดไม่ได้คือ นาย ธวัชชัย องค์กรยา ที่ให้ความช่วยเหลือในการจำลองเครื่องผสมแซมพู

ท้ายที่สุดนี้ข้าพเจ้าขอกราบขอบพระคุณ บิดา-มารดา, น้ำสาว, พี่ชาย, พี่สาว, และเพื่อนๆ ที่คอยช่วยเหลือและให้กำลังใจข้าพเจ้าจนสำเร็จการศึกษา

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

สารบัญ

หน้า

บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญตาราง.....	ฅ
สารบัญภาพ.....	ญ

บทที่

1. บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของการวิจัย.....	2
1.3 ขอบเขตของการวิจัย.....	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	2
1.5 วิธีดำเนินการวิจัย.....	2
2. แคมพู.....	3
2.1 องค์ประกอบของแคมพู.....	3
2.2 ปัจจัยที่มีผลต่อการเกิดปฏิกิริยาเคมี.....	4
2.3 กระบวนการผลิตแคมพู.....	4
3. ทฤษฎีเกี่ยวกับข่ายงานนิวรัล.....	7
3.1 จีวีวิทยาของนิวรัลและแบบจำลองของข่ายงานนิวรัลในยุคแรกๆ.....	7
3.2 แบบจำลองของข่ายงานนิวรัลในปัจจุบัน (Artificial Neural Network).....	9
3.2.1 องค์ประกอบและหน้าที่ของนิวรัล.....	10
3.2.2 พารามิเตอร์ที่มีความสำคัญสำหรับการทำงานของนิวรัล.....	11
3.3 การออกแบบข่ายงานนิวรัล.....	17
3.3.1 ข้อมูลที่ใช้ในการฝึกข่ายงาน (Training Data).....	17
3.3.2 ความรู้เกี่ยวกับการสร้างแบบจำลอง.....	19
3.4 บทสรุป.....	44
4. ขั้นตอนการดำเนินงานวิจัย.....	45
4.1 อุปกรณ์และสารเคมี.....	45
4.2 ขั้นตอนการทดลองการผลิตแคมพู.....	46

บทที่	หน้า
4.3 ขั้นตอนการทดลองข่ายงานนิเวรัลสำหรับสร้างแบบจำลอง.....	50
4.3.1 การแบ่งข้อมูล.....	50
4.3.2 การออกแบบโครงสร้างข่ายงานนิเวรัล.....	50
4.3.3 การคัดเลือกข่ายงาน.....	54
4.4 สรุปขั้นตอนการดำเนินงานวิจัย.....	54
4.4.1 ขั้นตอนการทดลองผลิตแซมพู.....	54
4.4.2 ขั้นตอนการศึกษาแบบจำลองข่ายงานนิเวรัล.....	55
4.4.3 ขั้นตอนการเปรียบเทียบผลการทำนาย.....	55
5. ผลการจำลองและวิเคราะห์ผลงานวิจัย.....	56
5.1 ผลการฝึกข่ายงานและการคัดเลือกข่ายงาน.....	56
5.1.1 ผลการฝึกข่ายงานนิเวรัลแบบ 1 ชั้นซ่อน (Single Hidden Layer).....	56
5.1.2 ผลการฝึกข่ายงานนิเวรัลแบบ 2 ชั้นซ่อน (Two Hidden Layer).....	56
5.2 การเปรียบเทียบผลการทำนายจากค่าดัชนี RMSP และ MP.....	67
5.3 การเลือกแบบจำลองจากประสิทธิภาพในการทำนาย.....	67
6. สรุปผลงานวิจัย.....	69
6.1 สรุปผลงานวิจัย.....	69
6.1.1 สรุปผลการทำนายเปอร์เซ็นต์ของแข็ง.....	70
6.1.2 สรุปผลการทำนายความหนืด.....	70
6.1.3 สรุปผลการคัดเลือกข่ายงาน.....	70
6.2 บทสรุป.....	71
รายการอ้างอิง.....	72
ภาคผนวก.....	75
ภาคผนวก ก. ผลการทำนายของข่ายงานนิเวรัล.....	76
ภาคผนวก ข. ค่าดัชนี RMSP, MP และสมรรถนะความถูกต้องในการทำนาย (Accuracy Performance) ของข่ายงานนิเวรัล.....	109
ประวัติผู้เขียนวิทยานิพนธ์.....	116

สารบัญตาราง

ตาราง	หน้า
4.1 แสดงผลการทดลองผลิตแชมพู.....	48
4.2 แสดงจำนวนขายงานทั้งหมด.....	51
5.1 แสดงช่วงดัชนีความผิดพลาด RSMP, MP และสมรรถนะความถูกต้องของขายงาน 1 ชั้นช้อน 5 ขายงาน และ 2 ชั้นช้อน 5 ขายงานที่มีค่าความผิดพลาดต่ำสุด.....	68
ก.1 แสดงผลการทำนายของขายงานทั้งหมด 162 ขายงาน.....	76
ข.1 แสดงช่วงดัชนีความผิดพลาด RSMP, MP และสมรรถนะความถูกต้องของขายงาน 162 ขายงาน.....	109



สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

สารบัญภาพ

ภาพประกอบ	หน้า
2.1 แสดงการผลิตแชนพู.....	5
3.1 โครงสร้างของเซลล์ประสาท (neural).....	8
3.2 แบบจำลองการทำงานของนิวรัลเสนอโดย McCulloch และ Pitts.....	9
3.3 หน้าที่และการทำงานของนิวรัล.....	10
3.4 ฟังก์ชันมูลฐาน.....	12
3.5 พื้นฐานการออกแบบข่ายงานนิวรัล.....	17
3.6 โครงสร้างพื้นฐานของข่ายงานนิวรัลที่แสดงการเชื่อมโยงแบบต่างๆ.....	21
3.7 การเรียนรู้ข่ายงานนิวรัลในการปรับค่าน้ำหนัก.....	23
3.8 แสดงแบบจำลองนิวรัลในชั้นที่ 1.....	25
3.9 แสดงการปรับน้ำหนักสำหรับอัลกอริทึมการกระจายความผิดพลาดย้อนกลับ.....	29
3.10 แสดงขั้นตอนการเรียนรู้ของข่ายงานนิวรัล.....	32
3.11 การเรียนรู้ของข่ายงานนิวรัลในการปรับค่าน้ำหนักแบบไม่มีการชี้แนะ.....	37
3.12 ข่ายงานนิวรัลสามารถจำแนกเป็นแบบมีการชี้แนะและไม่มีการชี้แนะ.....	37
3.13 แบบจำลองแบบไม่กลับกระแส.....	39
3.14 แบบจำลองแบบกลับกระแส.....	40
3.15 ข่ายงานมีการประมาณค่าระหว่างเส้นอย่างเหมาะสม.....	42
3.16 ข่ายงานมีการประมาณค่าระหว่างเส้นอย่างเหมาะสม.....	42
3.17 ข่ายงานมีการแบ่งประเภทผิดเนื่องจากมีการประมาณค่าระหว่างเส้นมากเกินไป.....	43
3.18 ความผิดพลาดเฉพาะที่ (local minima).....	43
4.1 แสดงถึงผสมกวนแชนพู.....	45
4.2 แสดงการเทส่วนผสมแชนพูลงในถังผสม.....	46
4.3 แสดงการเทน้ำลงในถังผสม.....	46
4.4 แสดงการกวนผสมแชนพู.....	47
4.5 แสดงแชนพูที่ตั้งทิ้งไว้จนฟองอากาศหมดไป.....	47
4.6 แสดงโครงสร้างของข่ายงานนิวรัลที่มี 1 ชั้นซ่อน.....	52
4.7 แสดงโครงสร้างของข่ายงานนิวรัลที่มี 2 ชั้นซ่อน.....	52
4.8 แสดงขั้นตอนของโปรแกรมในการหาแบบจำลอง.....	53
5.1 ผลการทำนายเปอร์เซ็นต์ของแข็งโดยใช้ข่ายงานนิวรัลแบบ 1 ชั้นซ่อน Model Log 3.....	57
5.2 ผลการทำนายเปอร์เซ็นต์ของแข็งโดยใช้ข่ายงานนิวรัลแบบ 1 ชั้นซ่อน Model Log 15.....	57

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

บริษัทแห่งหนึ่งดำเนินการผลิตผลิตภัณฑ์ทำความสะอาดร่างกายและบำรุงผิว เช่น แชมพู ครีมบำรุงผิว ฯลฯ เป็นธุรกิจขนาดกลางและย่อม (SMEs) ที่เดิมนั้นพัฒนามาจากอุตสาหกรรมในครอบครัว ลักษณะของการดำเนินธุรกิจมีอยู่ 2 ลักษณะ คือผลิตโดยใช้สูตรของบริษัทแล้วส่งผลิตภัณฑ์ให้กับลูกค้าที่ต้องการ และรับจ้างผลิตสินค้าโดยใช้สูตรเฉพาะของลูกค้า ในงานวิจัยนี้จะทำการศึกษาในส่วนเฉพาะการผลิตแชมพู

แชมพูเป็นสิ่งจำเป็นในชีวิตประจำวันของมนุษย์ เพื่อใช้ชำระล้างคราบไขมัน ละออง เหงื่อไคล และสิ่งสกปรกออกจากเส้นผมและหนังศีรษะ ซึ่งปัจจุบันมีการแข่งขันทางการตลาดสูงมาก โดยเฉพาะในประเทศไทยมีแชมพูมากกว่า 200 ชนิดจาก 75 บริษัท ทั้งบริษัทขนาดใหญ่ บริษัทขนาดกลางและขนาดย่อม (SMEs), และกลุ่มชุมชน (ในรูปแบบของสินค้าหนึ่งตำบลหนึ่งผลิตภัณฑ์) ที่ทางรัฐบาลให้การสนับสนุน จึงทำให้ทางผู้ผลิตจะต้องมีการพัฒนาคุณภาพผลิตภัณฑ์และกระบวนการผลิตอยู่ตลอดเวลา เพื่อให้ผลิตภัณฑ์ของตนสามารถแข่งขันในตลาดได้

จากข้อมูลเบื้องต้นที่ได้จากบริษัทผู้ผลิตแชมพู และปัจจัยที่มีผลต่อการเกิดปฏิกิริยาเคมีในการผลิตแชมพู พบว่าบริษัทนี้ยังไม่มีการนำความรู้ในเรื่องดังกล่าวไปพัฒนาปรับปรุงกระบวนการผลิต ซึ่งอาจเนื่องมาจากบริษัทเป็นอุตสาหกรรมขนาดกลางและย่อม (SMEs) และขาดบุคลากรที่มีความรู้ทางด้านวิชาการและงบประมาณสำหรับทำการศึกษา ดังนั้นการศึกษาและสร้างแบบจำลองโดยใช้ข่ายงานนิวรัลในงานวิจัยนี้ จะช่วยให้ทางบริษัทนำผลการศึกษาและแบบจำลองไปประยุกต์ใช้ในการพัฒนาการผลิตและเพิ่มคุณภาพของผลิตภัณฑ์ได้

นอกจากนี้ทางบริษัทยังสามารถนำผลการศึกษาและแบบจำลองข่ายงานนิวรัลที่ได้ไปขยายต่อในด้านการออกแบบทางวิศวกรรมเคมีของหน่วยการผสม (Mixing Units) และการออกแบบควบคุมกระบวนการผลิต (Process Control) เพื่อให้กระบวนการมีประสิทธิภาพมากขึ้น คือได้ผลิตภัณฑ์ที่มีปริมาณและคุณภาพตามที่ต้องการ และมีต้นทุนการผลิตต่ำ

1.2 วัตถุประสงค์ของการวิจัย

เพื่อสร้างแบบจำลองนิวัตสำหรับทำนายเปอร์เซ็นต์ของแข็งของแฉมพู

1.3 ขอบเขตของการวิจัย

กระบวนการผลิตแฉมพูที่ใช้เป็นขอบเขตงานวิจัยคือ ถึงผสมแบบไม่ต่อเนื่อง (Batch) ซึ่งต้องการทำนายเปอร์เซ็นต์ของแข็งของแฉมพู โดยทำการทดลองวัดค่าเปอร์เซ็นต์ของแข็ง (percent solid) ที่อัตราส่วนผสม, เวลาผสม, และอุณหภูมิ ต่างๆ ซึ่งใช้เทคนิคการเรียนรู้แบบการกระจายย้อนกลับเป็นตัวสร้างข่ายงานนิวัต

1.4 ประโยชน์ที่คาดว่าจะได้รับ

- สามารถจำลองข่ายงานนิวัตเพื่อทำนายเปอร์เซ็นต์ของแข็งของแฉมพู
- บริษัทสามารถนำแบบจำลองไปใช้ในการพัฒนาคุณภาพของผลิตภัณฑ์แฉมพูได้

1.5 วิธีดำเนินการวิจัย

แนวทางการดำเนินการวิจัยแบ่งออกเป็นขั้นตอนดังนี้

ก. ศึกษาคุณภาพของผลิตภัณฑ์แฉมพู โดยทำการทดลองและเก็บข้อมูลค่าเปอร์เซ็นต์ของแข็งของแฉมพู (percent solid) ที่อุณหภูมิ, ความเป็นกรด-ด่าง (pH), และค่าความหนืดต่างๆ จำนวน 72 ข้อมูล

ข. แบ่งข้อมูลออกเป็น 3 ชุดในอัตราส่วน 70:20:10

ค. สร้างแบบจำลองข่ายงานนิวัตโดยใช้ข้อมูลชุดที่ 1 ในการฝึกข่ายงานนิวัต

ง. ทดสอบความสามารถของแบบจำลองโดยใช้ข้อมูลชุดที่ 2

จ. ทดสอบสมรรถนะความถูกต้องในการทำนายของข่ายงานและวิเคราะห์ผลโดยใช้ข้อมูลชุดที่ 3

ฉ. จัดทำรายงานวิทยานิพนธ์

บทที่ 2

แชมพู

2.1 องค์ประกอบของแชมพู

ผลิตภัณฑ์ที่สามารถชำระล้างคราบไขมัน ลู่นละออง เหงื่อไคล และสิ่งสกปรกออกจากเส้นผมและหนังศีรษะได้คือ แชมพู ซึ่งตามความหมายของทางเครื่องสำอางค์หมายถึง ผลิตภัณฑ์ที่เตรียมขึ้นในรูปของเหลว ของแข็ง หรือลักษณะผง และใช้ตามที่ระบุบนฉลากโดยไม่เป็นอันตรายต่อผู้ใช้

แชมพูประกอบไปด้วยสารเคมีที่ทำหน้าที่หลักอย่างน้อย 3 ส่วนคือ

1. สารลดแรงตึงผิว (Primary Surfactants) ทำหน้าที่ทำความสะอาดเส้นผมและหนังศีรษะ โดยสารลดแรงตึงผิวหลักที่ใช้เป็นสารหลักในสูตรแชมพูมีดังนี้

1.1 สารชำระล้างประจุลบ (Anionic detergents) เป็นสารที่มีคุณสมบัติดีกว่าชนิดอื่นคือสามารถทำความสะอาดได้ดี เกิดฟองรวดเร็วและปริมาณฟองมาก ราคาถูกจึงนิยมใช้เป็นสารหลัก ซึ่งแบ่งออกเป็นกลุ่มแฟตตีแอซิดโซป (Fatty acid soap), อัลคิลซัลเฟต (Alkyl sulfate), อัลคิลอีเทอร์ซัลเฟต (Alkyl ether sulfate), อัลคิลเบนซีนซัลโฟเนต (Alkyl benzene sulfonate), อัลฟาโอลีฟินซัลโฟเนต (α -olefin sulfonates), และอัลคิลฟอสเฟต (Alkyl phosphate)

1.2 สารชำระล้างประจุบวก (Cationic detergents) สารกลุ่มนี้มีอำนาจชำระล้างและการเกิดฟองน้อยกว่าชนิดประจุลบ ทั้งยังมีข้อเสียคือทำให้เกิดการระคายเคืองต่อตาและผิวหนัง อย่างไรก็ตามเนื่องจากสารชำระล้างชนิดนี้นิยมนำมาใช้เป็นสารช่วยปรับสภาพเส้นผมไม่ให้มีประจุลบมากเกินไป ซึ่งจะทำให้เส้นผมหวีง่ายและไม่ยุ่งเหยิง

1.3 สารชำระล้างชนิดไม่มีประจุ (Nonionic detergents) สารกลุ่มนี้มีอำนาจการชำระล้างมากเหมาะที่จะเป็นสารหลักในแชมพู แต่ให้ฟองไม่มากเท่าที่ควรทำให้ผู้ใช้ไม่ชอบจึงนิยมใช้ปรุงแต่งในสูตรเพื่อช่วยการละลายและเพิ่มการชำระล้างของแชมพู

2. สารช่วยลดแรงตึงผิว (Auxiliary Surfactants) ได้แก่สารช่วยเสริมสมบัติของสารลดแรงตึงผิวหลักที่ขาดไปบางประการ เช่น ช่วยเพิ่มฟอง ช่วยเพิ่มอำนาจการชำระล้างหรือช่วยปรับสภาพเส้นผมไม่ให้แห้งหยาบเป็นต้น สารในกลุ่มนี้คือ เซกเอนดารีอัลคิลซัลเฟต (Secondary alkyl sulfate), โมโนกลีเซอไลด์ซัลเฟต (Monoglyceride sulfate), อัลคิลซัลโฟเนต

(Alkyl sulfonate), อัลคิลซัลโฟซัลซิเนต (Alkyl sulfosuccinates), แฟตตีเอซิดคอนเดนเซชันโพรดัก (Fatty acid condensation product), แฟตตีเอซิดอัลคานอลไนด์ (Fatty acid alkanolonide), แอมโฟเทอริกเซอแฟกแทน (Amphoteric surfactants), แคทไอออนิกเซอแฟกแทน (Cationic surfactants), นอนไอออนิกเซอแฟกแทน (Nonionic surfactants), เอมีนออกไซด์ (Amine oxides)

3. สารปรุงแต่งผลิตภัณฑ์แชมพู (Shampoo additives) เป็นสารที่ช่วยปรุงแต่งให้ผลิตภัณฑ์แชมพูมีคุณสมบัติตามรูปแบบที่ต้องการ หรือช่วยเสริมความคงสภาพ, ความสวยงาม, และสีของผลิตภัณฑ์ เช่น สารแต่งสี, สารแต่งกลิ่น, สารทำให้ใส, สารช่วยทำให้แชมพูขึ้น (หนืด), สารช่วยทำให้ทึบแสง, สารปรับสภาพเส้นผมโดยการเคลือบมัน, สารขจัดรังแค, สารกันเสีย เป็นต้น

2.2 ปัจจัยที่มีผลต่อการเกิดปฏิกิริยาเคมี


ปฏิกิริยาเคมีโดยทั่วไปที่เกิดขึ้นจะมีการสลายพันธะของตัวทำปฏิกิริยา (2 ชนิดขึ้นไป) และสร้างพันธะใหม่ของผลิตภัณฑ์ ซึ่งในบางปฏิกิริยาสามารถเกิดปฏิกิริยาได้ดีในสภาวะอุณหภูมิและความดันบรรยากาศปกติ แต่ก็มีบางปฏิกิริยาที่ในสภาวะดังกล่าวสามารถเกิดขึ้นได้แต่ใช้ระยะเวลาานาน ดังนั้นในปัจจุบันจึงได้มีการศึกษาหาสภาวะและปัจจัยด้านอื่นๆที่เหมาะสมของแต่ละปฏิกิริยาเพื่อให้ปฏิกิริยานั้นสามารถเกิดได้ดีขึ้น ส่งผลให้ได้ผลิตภัณฑ์ที่มีปริมาณมากและได้คุณภาพตามที่ต้องการ ซึ่งปัจจัยที่มีผลต่อการเกิดปฏิกิริยาเคมีมีดังต่อไปนี้

1. ความเข้มข้นของสาร
2. อุณหภูมิ
3. ความดัน
4. ตัวเร่งปฏิกิริยา
5. ระยะเวลาที่ใช้ในการทำปฏิกิริยา
6. การกวนผสม

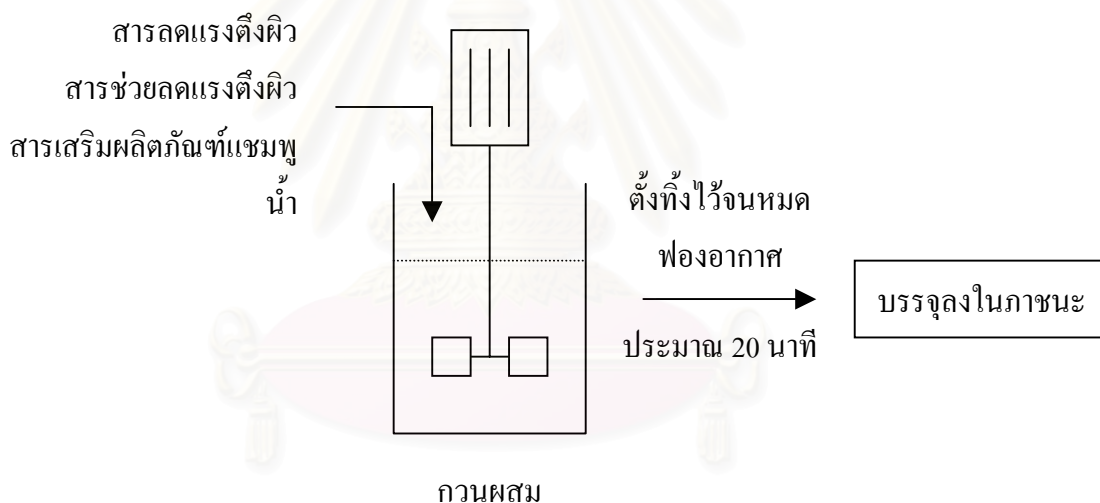
อุณหภูมิเป็นปัจจัยหนึ่งที่มีผลต่อการเกิดปฏิกิริยาเคมี ซึ่งส่วนใหญ่จะพบว่าถ้าเพิ่มอุณหภูมิในระหว่างเกิดปฏิกิริยาจะทำให้สามารถเกิดได้เร็วยิ่งขึ้น เนื่องจากโมเลกุลของสารเคมีที่ทำปฏิกิริยากันมีพลังงานจลน์ที่สูงขึ้นทำให้มีโอกาสชนกันระหว่างโมเลกุลได้มากขึ้น

2.3 กระบวนการผลิตแชมพู

กระบวนการผลิตแชมพูประกอบด้วย การนำสารเคมีทั้ง 3 ชนิด คือ สารลดแรงตึงผิว, สารช่วยลดแรงตึงผิว, และสารปรุงแต่งผลิตภัณฑ์มาทำปฏิกิริยา



ลักษณะของการผลิตแชมพูโดยทั่วไป จะมีอัตราส่วนของสารลดแรงตึงผิว (Primary Surfactant) และสารช่วยลดแรงตึง (Auxiliary Surfactant) ประมาณ 40 เปอร์เซ็นต์ และ 3-5 เปอร์เซ็นต์ตามลำดับ โดยอัตราส่วนของสารปรุงแต่งผลิตภัณฑ์แชมพู (Additive) จะมีอัตราส่วนแตกต่างกันขึ้นอยู่กับลักษณะของผลิตภัณฑ์แชมพู



ใช้เวลาประมาณ 20 นาที

รูปที่ 2.1 แสดงการผลิตแชมพู

สารเคมีทั้ง 3 ชนิด และน้ำ จะผสมลงในถังปฏิกิริยา (Reactor) โดยใช้พลังงานกลจากมอเตอร์ในการกวนผสม (Mixing) เพื่อทำให้เกิดปฏิกิริยาเคมีและใช้เวลาประมาณ 20 นาที ทำการทดสอบคุณภาพของผลิตภัณฑ์โดยจะทำการทดสอบ 3 ค่า คือ ค่าความเป็นกรด-ด่าง (pH), ค่าความหนืด (Viscosity), และค่าเปอร์เซ็นต์ของแข็ง (% Solid) จนได้ตามเกณฑ์มาตรฐานของผลิตภัณฑ์ หลังจากนั้นจะนำมาตั้งทิ้งไว้ที่อุณหภูมิห้องเพื่อให้ฟองอากาศที่เกิดขึ้นในระหว่างการผสมหมดไปโดยจะต้องตั้งทิ้งไว้ประมาณ 20 นาที ก่อนที่จะบรรจุในภาชนะต่อไป

เนื่องจากพฤติกรรมของกระบวนการผลิตแชมพูไม่เป็นเชิงเส้น ในงานวิจัยนี้จึง
เลือกใช้ข่ายงานนิวรัลเพื่อสร้างแบบจำลองการผลิตแชมพู โดยทฤษฎีเกี่ยวกับข่ายงานนิวรัลได้กล่าว
ไว้ในบทที่ 3



สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

บทที่ 3

ทฤษฎีเกี่ยวกับข่ายงานนิวรัล

บทนี้จะกล่าวถึงทฤษฎีเกี่ยวกับข่ายงานนิวรัล โดยแบ่งหัวข้อเป็นดังนี้คือ หัวข้อ 3.1 จะกล่าวถึงชีววิทยาของนิวรัลและแบบจำลองของข่ายงานนิวรัลในยุคแรกๆว่ามีแนวคิดของข่ายงานนิวรัลมาจากสิ่งใด หัวข้อ 3.2 จะกล่าวถึงแบบจำลองนิวรัลที่ใช้ในปัจจุบัน และในหัวข้อ 3.3 กล่าวถึงการออกแบบข่ายงานนิวรัลซึ่งต้องมียุคประกอบพื้นฐานคือ ข้อมูลที่ใช้ในการฝึกข่ายงาน และความรู้เกี่ยวกับการสร้างแบบจำลอง ซึ่งข้อมูลที่ใช้ในการฝึกข่ายงานนิวรัลจะใช้ข้อมูลจำนวนมากและต้องมีความแตกต่างกันของข้อมูล โดยจะต้องมีการจัดเตรียมข้อมูลที่ดี ส่วนความรู้กระบวนการที่จะสร้างแบบจำลอง เป็นเครื่องมือหลักคั่นในแต่ละขั้นตอนของการสร้างแบบจำลองให้สำเร็จ โดยจะอธิบายถึงวิธีการสร้างแบบจำลองเริ่มตั้งแต่โครงสร้างของ แบบจำลอง, การจำแนก, และการเรียนรู้

การจำแนกข่ายงานนิวรัล จะแบ่งเป็น 2 ประเภท คือ ข่ายงานนิวรัลแบบมีการชี้นำ และข่ายงานนิวรัลแบบไม่มีการชี้นำ วิธีการฝึกข่ายงานและปัญหาที่พบในการฝึกข่ายงานในบทนี้ เน้นการเรียนรู้ไปที่อัลกอริธึมแบบการกระจายความผิดพลาดย้อนกลับชนิด รีเวนเบอร์เกอร์-มาร์ควอร์ (Levenberg-Marquardt) เนื่องจากเป็นอัลกอริธึมที่ใช้สำหรับงานวิจัยในครั้งนี้


3.1 ชีววิทยาของนิวรอนและแบบจำลองของข่ายงานนิวรอนในยุคแรกๆ

ระบบประสาทของมนุษย์ได้รับสัญญาณอินพุตจากหลายแหล่ง และกระบวนการทำงานของระบบประสาทจะทำหน้าที่ในการแปลงสัญญาณอินพุตให้เป็นสัญญาณการตอบสนองที่เหมาะสม โดยจะมีนิวรัลเป็นล้านๆ นิวรัลเชื่อมต่อกันที่เรียกว่าข่ายงานนิวรัล (neural network) เพื่อสร้างสัญญาณตอบสนองหรือพฤติกรรมต่างๆในการดำเนินชีวิตประจำวันของมนุษย์ ดังนั้นมีผู้วิจัยและพัฒนาแบบจำลองได้แนวคิดสำหรับข่ายงานนิวรัลซึ่งมีพื้นฐานมาจากการเลียนแบบโครงสร้างระบบประสาทของมนุษย์ (human neurons system) นั่นคือระบบประสาทของมนุษย์ ประกอบด้วยกลุ่มของนิวรัลประมาณ 10^{11} เซล โดยสามารถติดต่อกับนิวรัลอื่นๆ ด้วยแอกซอน (axon) และซินแนปส์ (synapses) ซึ่งมีความหนาแน่นของซินแนปส์ประมาณ 10^4 หน่วยต่อนิวรัล ข้อสมมติฐานเกี่ยวกับแบบจำลองของระบบประสาทคือ นิวรัลจะทำการติดต่อกันโดยอาศัยการกระตุ้นทางไฟฟ้า (electrical impulse) แต่การทำงานของนิวรัลนั้นเกิดจากกระบวนการทางชีวเคมี ช่วงเวลาในการประมวลผลของนิวรัล (neuron switch time) จะมีค่าน้อยกว่าหนึ่งในพันวินาที

ซึ่งน้อยกว่าช่วงเวลาที่กระแสไฟฟ้าวิ่งผ่านคอมพิวเตอร์ถึงหนึ่งล้านเท่า และนิวรัลยังสามารถเชื่อมโยงกันได้ไวกว่าซูเปอร์คอมพิวเตอร์ในปัจจุบันถึงหนึ่งพันเท่า

ในทางชีววิทยานิวรัลมีองค์ประกอบ 3 ส่วนดังแสดงในรูปที่ 3.1

- 1) เดนไดรท์ (dendrite) ที่แตกแขนงออกจากตัวเซลล์เพื่อรับสัญญาณจากแอกซอนของนิวรัลตัวอื่นเข้ามาและส่งต่อมายังเซลล์นิวรัล
- 2) เซลล์นิวรัล (cell body) ทำหน้าที่รวบรวมสัญญาณจากเดนไดรท์และส่งไปให้แก่แอกซอน
- 3) แอกซอน (axon) ทำหน้าที่นำสัญญาณที่ออกจากเซลล์นิวรัลส่งไปยังเดนไดรท์ของนิวรัลอื่นๆ



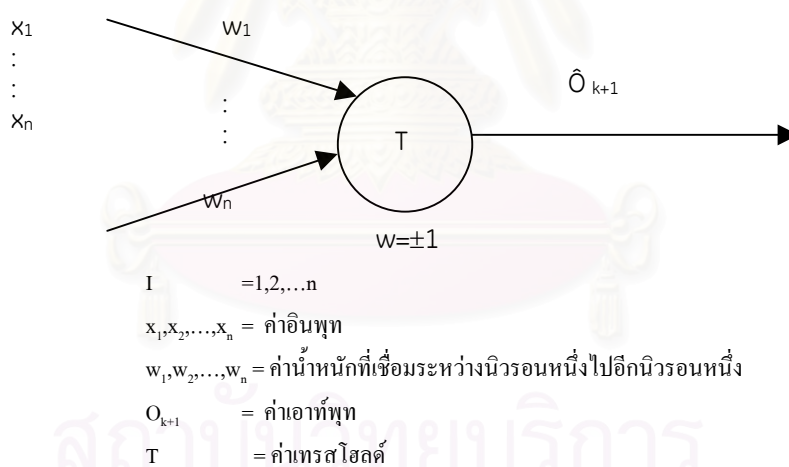
รูปที่ 3.1 โครงสร้างของเซลล์ประสาท (neural)

สำหรับซินแนปส์นั้นเป็นรอยต่อระหว่างแอกซอนของนิวรัลหนึ่ง กับเดนไดรท์ของนิวรัลอื่น ๆ นั่นคือ เดนไดรท์จะรับสัญญาณจากแอกซอนของนิวรัลอื่นเข้ามาและส่งต่อให้เซลล์นิวรัล เซลล์นิวรัลจะรวมสัญญาณที่ได้ส่งต่อไปให้แอกซอนจนถึงรอยต่อซินแนปส์ โดยแอกซอนจะนำสัญญาณผ่านไปตามลำดับของคลื่นกระแสไฟฟ้า ซึ่งขึ้นกับค่าแรงดันต่างศักย์ของนิวรัลและเนื้อเยื่อของนิวรัล (membrane) ที่สร้างแรงดันต่างศักย์กระจายผ่านแอกซอนไปจนถึงรอยต่อซินแนปส์ จากแนวคิดพื้นฐานดังกล่าวนี้มีนักวิจัยได้ใจที่จะศึกษากลไกและโครงสร้างของระบบประสาทของมนุษย์ซึ่งนำไปสู่การพัฒนาแบบจำลองสำหรับการแก้ปัญหาที่ซับซ้อน หรือที่ไม่เป็นเชิงเส้นได้ โดยเริ่มต้นจากในปี ค.ศ. 1943 แมคคัลลอคย (McCulloch) และ พิต (Pitts) ได้เป็นผู้ริเริ่มในการจำลองลักษณะการทำงานของเซลล์ประสาทสมองโดยใช้สมการคณิตศาสตร์อย่างง่าย ซึ่งมีข้อจำกัดคือ สามารถจัดการเฉพาะกับปัญหาที่เป็นลักษณะทางตรรกศาสตร์อย่างง่าย เช่น ปัญหาทางตรรกศาสตร์ NOR, OR, และ AND เป็นต้น และจากจุดเริ่มต้นนี้ได้มีการพัฒนาแบบจำลองดังกล่าวจนเป็นที่ยอมรับและนิยมใช้กันอย่างแพร่หลายในเวลาต่อมา ดังแสดงในรูปที่ 3.2 เป็นการ

เสนอโครงสร้างข่ายงานนิเวศของแมคคัลลอยและพิต โดยอยู่ในรูปแบบจำลองการคำนวณโดยการสร้างตรรกะไธลด์ (threshold logic) อย่างง่ายๆ แต่แบบจำลองมีข้อจำกัดคือ ค่าอินพุตและเอาต์พุตเป็น 0 กับ 1 เท่านั้น และค่าน้ำหนักถูกกำหนดให้มีค่าคงที่รวมทั้งนิเวศมีเพียงหน่วยเดียวเท่านั้นทำให้ไม่มีการติดต่อกันระหว่างนิเวศหน่วยอื่น สัญญาณที่ออกจากนิเวศนั้นได้ถูกกำหนดเงื่อนไขดังสมการที่ 3.1

$$O_{k+1} = \begin{cases} 1 & \text{if } \sum_{i=1}^n w_i x_{ik} \geq T \\ 0 & \text{if } \sum_{i=1}^n w_i x_{ik} < T \end{cases} \quad \text{สมการที่ 3.1}$$

และในปี ค.ศ 1958 โรเซนบลัด (Rosenblatt) ได้เสนอแบบจำลองเปอร์เซปตรอน ซึ่งเป็นแบบจำลองข่ายงานแบบตัดสินใจเพื่อแยกข้อมูล 2 ระดับออกจากกัน ต่อมาใน ค.ศ. 1969 มินท์สกาย (Minsky) และ แพพเพอร์ท (Papert) ทำการพิสูจน์คุณสมบัติของเปอร์เซปตรอน และชี้ให้เห็นถึงข้อจำกัดของ แบบจำลองนี้ซึ่งสามารถแก้ปัญหา เฉพาะระบบที่เป็นเชิงเส้นเท่านั้น




รูปที่ 3.2 แบบจำลองการทำงานของนิเวศเสนอ โดย McCulloch และ Pitts

3.2 แบบจำลองของข่ายงานนิเวศในปัจจุบัน (Artificial Neural Network)

แบบจำลองของข่ายงานนิเวศในปัจจุบันประกอบด้วยชั้นของนิเวศและส่วนเชื่อมโยงระหว่างนิเวศหนึ่งไปสู่นิเวศหนึ่งเรียกว่าน้ำหนัก (weight) อินพุตของนิเวศจะถูกนำมารวมกันโดยฟังก์ชันมูลฐาน (basis function) และส่งเอาต์พุตที่ออกจากฟังก์ชันมูลฐานไปแปลงด้วยฟังก์ชันกระตุ้น (activation function) ซึ่งจะได้เอาต์พุตของนิเวศ และส่งเอาต์พุตของ

นิวรัลนี้ไปเป็นอินพุทของนิวรัลในชั้นถัดไป ดังนั้นองค์ประกอบและหน้าที่ของนิวรัลที่เลียนแบบการทำงานของระบบประสาทมนุษย์จะมีดังต่อไปนี้



รูปที่ 3.3 หน้าที่และการทำงานของนิวรัล

3.2.1 องค์ประกอบและหน้าที่ของนิวรัล

องค์ประกอบของนิวรัลประกอบด้วย 3 ส่วนที่สำคัญคือ

1. หน่วยประมวลผล (processing elements) เรียกว่า node
2. การเชื่อมต่อแบบซินแนปส์ (synaptic connection) เป็นส่วนเชื่อมต่อระหว่างนิวรัลในแต่ละชั้นสำหรับการส่งข้อมูลที่ประมวลผลได้จากนิวรัลหนึ่ง ไปยังอีก นิวรัลหนึ่ง
3. ค่าน้ำหนัก (weight) และค่าไบแอส (bias) ทำหน้าที่ในการขยายหรือลดขนาดของสัญญาณที่เข้าสู่นิวรัล โดยผ่านการเชื่อมต่อแบบซินแนปส์

ข่ายงานนิวรัลแต่ละนิวรัล จะมีการเชื่อมโยงระหว่างชั้นจากนิวรัลหนึ่ง ไปสู่อีก นิวรัลหนึ่ง โดยใช้ค่าน้ำหนัก และในนิวรัลหนึ่งๆจะมีสถานะภายในการแปลงค่าอินพุทที่ได้รับเข้ามาให้เป็นเอาต์พุทโดยใช้ฟังก์ชันมูลฐานและฟังก์ชันกระตุ้น ซึ่งค่าเอาต์พุทของนิวรัลนี้จะส่งเป็นอินพุทให้กับนิวรัลในชั้นถัดไปดังรายละเอียดต่อไปนี้

แต่ละนิวรัล y จะได้รับอินพุทที่ส่งมาจากชั้นก่อนหน้านี้นี้ ซึ่งอินพุทคือ x_1, x_2, \dots, x_n และค่าน้ำหนักที่เชื่อมระหว่าง x_i กับ y คือ w_i

วิธีการหาเอาต์พุตของนิวรัล y คือ ผลรวมของอินพุตคูณกับน้ำหนัก ถ้ามีเทอมไบแอส (b) ก็สามารถนำเทอมไบแอสรวมด้วยดังสมการที่ 3.2

$$y_{in} = b + w_1x_1 + w_2x_2 + \dots + w_nx_n \quad \text{สมการที่ 3.2}$$

และนำค่า y_{in} คำนวณผ่านฟังก์ชันกระตุ้น เช่น ฟังก์ชันกระตุ้นแบบซิกมอยด์คือ logistic sigmoid function

$$\text{เอาต์พุต} = y = f(y_{in}) = 1 / (1 + \exp(-y_{in})) \quad \text{สมการที่ 3.3}$$

ถ้าเป็นฟังก์ชันกระตุ้นแบบเชิงเส้น

$$\text{เอาต์พุต} = y = f(y_{in}) = y_{in} \quad \text{สมการที่ 3.4}$$

เอาต์พุต y นี้ก็จะส่งไปเป็นอินพุตให้กับนิวรัลในชั้นถัดไป

สรุปหน้าที่ของนิวรัลแต่ละหน่วยซึ่งแสดงในรูป 3.3 มีดังนี้

1. รับสัญญาณจากนิวรัลหน่วยอื่นๆ (ทำงานคล้ายเดนไดรท์)
2. รวมสัญญาณจากนิวรัลหน่วยอื่นเข้าด้วยกัน โดยใช้ฟังก์ชันมูลฐาน (ทำงานคล้ายเซลล์นิวรัล)
3. แปลงสัญญาณที่รวมได้โดยใช้ฟังก์ชันกระตุ้น (ทำงานคล้ายเซลล์นิวรัล)
4. ส่งผลลัพธ์ที่ได้จากฟังก์ชันกระตุ้นไปยังนิวรัลถัดไป (ทำงานคล้ายแอกซอน)

3.2.2 พารามิเตอร์ที่มีความสำคัญสำหรับการทำงานของนิวรัล

3.2.2.1 น้ำหนัก (weight)

น้ำหนักหรือที่เรียกว่าสัญญาณเชื่อมโยงระหว่างนิวรัล จะถูกปรับเปลี่ยนค่าอยู่ตลอดเวลาในระหว่างการเรียนรู้ของข่ายงานสร้างแบบจำลองภายในขึ้นมาเพื่อให้มีค่าใกล้เคียงกับระบบที่สนใจ แบบจำลองภายในที่สร้างขึ้นมาจะสามารถใช้แทนแบบจำลองของกระบวนการได้ก็ต่อเมื่อผลลัพธ์ที่ออกจากระบบมีค่าใกล้เคียงกับผลลัพธ์ที่ออกจาข่ายงาน นั่นคือความแตกต่างของผลลัพธ์ที่ออกจากระบบกับผลลัพธ์ที่ออกจาข่ายงานต้องมีค่าน้อยที่สุดและอยู่ในช่วงที่ยอมรับได้

3.2.2.2 ฟังก์ชันมูลฐาน (basis function)

ฟังก์ชันมูลฐานคือการแทนการแมพฟังก์ (mapping) ทางคณิตศาสตร์ด้วยฟังก์ชัน $u(w,x)$ เมื่อ w คือแมทริกซ์ของน้ำหนัก และ x คืออินพุทเวกเตอร์ ฟังก์ชันมูลฐานทำหน้าที่ในการรวมสัญญาณที่ได้รับมาจากนิวรัลหน่วยอื่นๆเข้าด้วยกันและฟังก์ชันกระตุ้นจึงแปลงสัญญาณนี้เป็นเอาต์พุทของนิวรัล ฟังก์ชันมูลฐานสามารถแบ่งเป็น 2 ประเภท คือ ฟังก์ชันมูลฐานเชิงเส้น และฟังก์ชันมูลฐานรัศมี ดังแสดงในรูป 3.4

ก. ฟังก์ชันมูลฐานเชิงเส้น (linear basis function)

ฟังก์ชันมูลฐานเชิงเส้นเป็นฟังก์ชันชนิดไฮเปอร์เพลน (hyperplane) โดยเป็นฟังก์ชันมูลฐานอันดับที่ 1 ค่า net ที่ได้เป็นผลรวมเชิงเส้นของค่าอินพุทซึ่งแสดงในสมการที่ 3.5

$$u_i(w, x) = \sum_{j=1}^n w_{ij}x_j \quad \text{สมการที่ 3.5}$$

ข. ฟังก์ชันมูลฐานรัศมี (radial basis function RBF)

ฟังก์ชันมูลฐานรัศมีเป็นฟังก์ชันชนิดไฮเปอร์สเฟียร์ (hypersphere) โดยเป็นฟังก์ชันมูลฐานอันดับที่ 2 (ไม่เชิงเส้น) ค่า net ที่ได้จะแทนระยะทางไปยังชุดข้อมูลอ้างอิง (reference pattern)

$$u_i(w, x) = \sqrt{\sum_{j=1}^n (x_j - w_{ij})^2} \quad \text{สมการที่ 3.6}$$

นอกจากนี้ฟังก์ชันอันดับที่ 2 ยังสามารถขยายไปเป็นฟังก์ชันมูลฐานอิลิปติก (elliptic basis function) ได้อีกด้วย



(ก) ฟังก์ชันมูลฐานเชิงเส้น linear(hyperplane) (ข) ฟังก์ชันมูลฐานรัศมี radial (hypersphere)

รูปที่ 3.4 ฟังก์ชันมูลฐาน

3.2.2.3 ฟังก์ชันกระตุ้น (activation function)

ค่า net ที่อยู่ในรูปของฟังก์ชันมูลฐาน $u(w,x)$ จะถูกแปลงค่าโดยใช้ฟังก์ชันกระตุ้นไม่เชิงเส้น (nonlinear activation function) ฟังก์ชันที่ส่วนใหญ่นิยมใช้ทั่วไป เช่น ฟังก์ชันขั้นบันได (Step Function), ฟังก์ชันแรมพ์ (Ramp Function), ฟังก์ชันซิกมอยด์ (Sigmoid Function), ฟังก์ชันไบโพลาร์ (Bipolar Function), ฟังก์ชันเกาส์เซียน (Gaussian Function)

ก. ฟังก์ชันสเต็ป (Step function)

$$f(\text{net}) = \begin{cases} 1 & \text{if } \text{net} > 0 \\ 0 & \text{otherwise} \end{cases} \quad \text{สมการที่ 3.7}$$

ข. ฟังก์ชันแรมพ์ (Ramp Function)

$$f(\text{net}) = \begin{cases} 1 & \text{if } \text{net} \geq 1 \\ \text{net} & \text{if } |\text{net}| < 1 \\ -1 & \text{if } \text{net} \leq -1 \end{cases} \quad \text{สมการที่ 3.8}$$

ค. ฟังก์ชันซิกมอยด์ (Sigmoid Function)

$$f(\text{net}) = \frac{1}{1 + e^{-\frac{\text{net}}{\lambda}}} \quad \text{สมการที่ 3.9}$$

ส่วนใหญ่แล้วฟังก์ชันกระตุ้นที่นิยมคือฟังก์ชันซิกมอยด์ ซึ่งจะมีการแปลงค่าอินพุตที่มีค่าบวกมากๆ ให้เข้าใกล้ 1 หรือค่าลบมากๆ ให้ใกล้ 0 ดังสมการ 3.9 ดังนั้นช่วงของฟังก์ชันซิกมอยด์จะมีค่าระหว่าง $[0,1]$

ง. ฟังก์ชันเกาส์เซียน (Gaussian Function)

$$f(\text{net}) = ce^{-\frac{\text{net}^2}{\lambda^2}} \quad \text{สมการที่ 3.10}$$

ฟังก์ชันเกาส์เซียนนี้มีค่ามากที่สุดอยู่ที่ 1 ส่วนใหญ่จะใช้กับอัลกอริธึมแบบข่ายงานรัศมี (radial basis function network) สำหรับฟังก์ชันอื่นที่ใช้กันแต่ไม่นิยมมากนักได้แก่ ฟังก์ชันไบโพลาร์, ฟังก์ชันอาร์คแทนเจนต์, ฟังก์ชันไบโพลาร์อาร์คแทนเจนต์

จ. ฟังก์ชันไบโพลาร์ซิกมอยด์ (Bipolar Sigmoid Function)

ฟังก์ชันไบโพลาร์มีสมการดังนี้

$$f(\text{net}) = \frac{1}{1 + \exp(-\lambda \text{net})} - 1 \quad \text{สมการที่ 3.11}$$

ฟังก์ชันไบโพลาร์ซิกมอยด์มีสมการดังนี้

$$f(\text{net}) = -1 + 2 / (1 + \exp(-\text{net})) \quad \text{สมการที่ 3.12}$$

ฉ. ฟังก์ชันกระตุ้นแบบอาร์คแทนเจนต์ (*Arc Tangent Transfer Function*)

$$f(\text{net}) = \arctan(\text{net}/3.14159) + 0.5 \quad \text{สมการที่ 3.13}$$

ฟังก์ชันกระตุ้นนี้มีค่าอยู่ระหว่าง $[0,1]$ ข้อดีของฟังก์ชันนี้ คือเป็นทางเลือกหนึ่งสำหรับฟังก์ชันซิกมอยด์ เมื่อต้องการปรับค่าน้ำหนักที่มีค่ามาก

ซ. ฟังก์ชันกระตุ้นแบบไบโพลาร์อาร์คแทนเจนต์ (*Bipolar Arc Tangent Transfer Function*)

$$f(\text{net}) = \arctan((2.0 * \text{net}) / 3.14159) \quad \text{สมการที่ 3.14}$$

ฟังก์ชันนี้ให้ค่าเอาต์พุตอยู่ในช่วง $[-1,1]$ ข้อดีจะเหมือนกับแบบฟังก์ชันอาร์คแทน

ซ. ฟังก์ชันกระตุ้นแบบเชิงเส้น (*Linear Transfer Function*)

$$f(\text{net}) = \text{net} \quad \text{สมการที่ 3.15}$$

ฟังก์ชันนี้จะให้ค่าผลลัพธ์เท่ากับค่าอินพุต ฟังก์ชันนี้ปกติจะถูกใช้ในชั้นเอาต์พุต

เหตุผลที่ต้องใช้ฟังก์ชันกระตุ้น คือต้องการทำให้ข่ายงานเป็นแบบไม่เชิงเส้น ซึ่งถ้าเป็นแบบจำลองเชิงเส้นก็สามารถใช้ข่ายงานแบบเพอร์เซปตรอน (perceptron) ที่ไม่มีชั้นซ่อน และฟังก์ชันกระตุ้นแบบเชิงเส้นได้ แต่ถ้าต้องการแบบข่ายงานไม่เชิงเส้นต้องมีฟังก์ชันกระตุ้นแทนความไม่เป็นเชิงเส้น นั่นคือการทำข่ายงานแบบหลายชั้น และมีฟังก์ชันกระตุ้นที่ไม่เป็นเชิงเส้นเช่นฟังก์ชันซิกมอยด์ซึ่งได้แก่ logistic, tanh และฟังก์ชันเกาส์เซียน ซึ่งโดยปกติจะใช้บ่อยถ้าเป็นฟังก์ชัน tanh จะให้ค่าเอาต์พุต +/- ช่วยให้เราสามารถฝึกข่ายงานได้เร็วกว่าค่าบวกอย่างเดียว ส่วนฟังก์ชัน logistic และ tanh ต้องทำการสเกลช่วงของเป้าหมายให้อยู่ในช่วงเอาต์พุตหรือช่วงเอาต์พุตให้อยู่ในช่วงเป้าหมาย (การสเกลช่วงคือการคูณด้วยค่าคงที่ที่เหมาะสม) แต่ถ้าเป้าหมายไม่มีขอบเขตฟังก์ชันกระตุ้นควรจะเป็นฟังก์ชันกระตุ้นที่ไม่มีขอบเขต (unbounded activation function) ถ้าค่าเป้าหมายเป็นค่าบวกแต่ไม่ทราบค่าสูงสุด ควรใช้ฟังก์ชันกระตุ้นแบบเอ็กซ์โปเนนเชียล (exponential activation function) แต่ควรระวังการเกิดเอาต์พุตมีค่ามากเกินไป (overflow)

3.2.2.4 ฟังก์ชันความผิดพลาด (error function หรือ loss function)

เป้าหมายของการฝึกข่ายงานคือการลดค่าความผิดพลาดรวมของข่ายงานให้น้อยที่สุด ดังนั้นการเลือกชนิดความผิดพลาดจะมีอิทธิพลต่อความสำเร็จในการฝึกข่ายงานฟังก์ชันความผิดพลาดนี้ เป็นการวัดค่าความแตกต่างของค่าเป้าหมายกับค่าเอาต์พุตที่ได้จากข่ายงาน ซึ่งจะมีหลายประเภท ดังตัวอย่างต่อไปนี้

ก. ความผิดพลาดรวมกำลังสอง (sum square error)

ส่วนใหญ่แล้วจะใช้ค่าผลรวมของความผิดพลาดกำลังสอง (sum square error)

$$E(y,p)=(y-p)^2 \quad \text{สมการที่ 3.16}$$

ซึ่ง E คือความผิดพลาด, y คือค่าเอาต์พุต, และ p คือค่าเป้าหมาย

ถ้าเป็นความผิดพลาดของทั้งชุดข้อมูลก็นำมารวมกัน จะได้เป็นผลรวมความผิดพลาดยกกำลังสองหรือความผิดพลาดรวม (sum square error, SSE หรือ total error)

ข. ค่าความผิดพลาดเฉลี่ยกำลังสอง (Mean Square Error)

ในบางครั้งอาจใช้ค่าเฉลี่ยของค่าความผิดพลาดยกกำลังสอง (mean square error (MSE), average square error (ASE)) โดยค่าเฉลี่ยของความผิดพลาดกำลังสองใช้กับการแบ่งประเภทความผิด (ใช้กับข้อมูลไบนารี) การใช้ค่าเฉลี่ยของความผิดพลาดยกกำลังสองแทนความผิดพลาดรวมกับอัลกอริทึมการกระจายความผิดพลาดย้อนกลับ จะให้อัตราการเรียนรู้ไม่ค่อยรวดเร็วกับชุดข้อมูลในการฝึกได้ แต่ถ้าเป็นค่าผิดพลาดรวมต้องใช้ค่าอัตราการเรียนรู้น้อยมากสำหรับชุดข้อมูลการฝึกที่มีขนาดใหญ่

ให้ $z_m = (x_i, y_i)$, $i=1, \dots, m$ ซึ่ง m คือลำดับของชุดข้อมูลฝึกข่ายงาน

W = ค่าน้ำหนักในการเชื่อมต่อข่ายงาน

$g(x, W)$ = เอาต์พุตของฟังก์ชันข่ายงาน

ค่าความผิดพลาดเฉลี่ยกำลังสอง (Mean Square Error) สามารถคำนวณได้ดัง

สมการ 3.17

$$m^{-1}((y_1 - g(x_1, W))^2 + (y_2 - g(x_2, W))^2 + \dots + (y_m - g(x_m, W))^2) \quad \text{สมการที่ 3.17}$$

ค. ค่าความผิดพลาดเฉลี่ยสัมบูรณ์ (Mean Absolute Error)

สมการแสดงค่าความผิดพลาดเฉลี่ยสัมบูรณ์แสดงดังสมการที่ 3.18 ซึ่งเป็นการลดค่าความผิดพลาดของข้อมูลที่มีสัญญาณรบกวน ค่าที่ได้รับการฝึกจะมีค่าเบี่ยงเบนจากปกติ ค่าความผิดพลาดชนิดนี้ออกแบบให้ละเอียดหรือลดผลกระทบนี้ให้น้อยที่สุด ซึ่งค่าความผิดพลาดเฉลี่ยกำลังสองจะมีผลกระทบมากเนื่องจากการยกกำลังสอง ค่าที่ผิดพลาดจำนวนเล็กน้อยก็จะทำให้การเรียนรู้ผิดพลาด เพราะผลรวมจะไปเพิ่มมากขึ้นในค่าความผิดพลาด รวม

$$m^{-1}(|y_1 - g(x_1, W)| + |y_1 - g(x_1, W)| + \dots + |y_m - g(x_m, W)|) \quad \text{สมการที่ 3.18}$$

ง. ค่าความผิดพลาดเฉลี่ยกำลังสี่ (Mean Fourth Power Error)

สมการแสดงค่าความผิดพลาดกำลังสี่แสดงดังในสมการที่ 3.19

$$m^{-1}((y_1 - g(x_1, W))^4 + (y_1 - g(x_1, W))^4 + \dots + (y_m - g(x_m, W))^4) \quad \text{สมการที่ 3.19}$$

ส่วนใหญ่จะใช้กำลังสี่เมื่อต้องการเน้นความสำคัญของค่าความผิดพลาดให้มีขนาดใหญ่ ซึ่งวิธีนี้เป็นการคำนวณให้อัลกอริทึมเรียนรู้ในกรณีที่ค่าความผิดพลาดมีค่ามากที่สุด

จ. ค่าความผิดพลาดไฮเปอร์โบลิกกำลังสอง (Hyperbolic Square Error)

ค่าความผิดพลาดแบบไฮเปอร์โบลิกกำลังสองคือฟังก์ชันค่าความผิดพลาดที่พัฒนาโดย Scott Fahlman เป็นวิธีที่ปรับปรุงประสิทธิภาพของการฝึกข่ายงานแบบการกระจายความผิดพลาดย้อนกลับ ค่าความผิดพลาดในรูปแบบเดิมคือ E จะถูกคำนวณเป็นค่าผลต่างระหว่างค่าเอาต์พุตกับค่าเป้าหมาย แต่วิธีนี้ E แสดงดังสมการที่ 3.20 โดยค่าความผิดพลาดแบบไฮเปอร์โบลิกจะใช้คู่กับฟังก์ชันกระตุ้นชนิดที่ไม่เป็นไบโพลาร์ (non-bipolar transfer function)

$$E = \log((1+E)/(1-E)) \quad \text{สมการที่ 3.20}$$

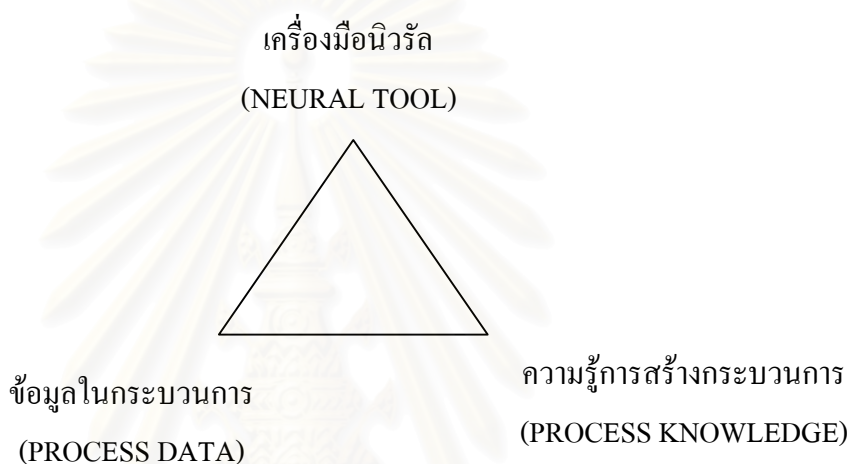
ฉ. ค่าความผิดพลาดไบโพลาร์ไฮเปอร์โบลิกกำลังสอง (Bipolar Hyperbolic Square Error)

ค่าความผิดพลาดไบโพลาร์ไฮเปอร์โบลิกจะคล้ายกับค่าความผิดพลาดไฮเปอร์โบลิกกำลังสอง แต่ชนิดนี้จะใช้กับฟังก์ชันกระตุ้นชนิดไบโพลาร์ (bipolar transfer function) เท่านั้น ดังสมการที่ 3.21

$$E = \log((2+E)/(2-E)) \quad \text{สมการที่ 3.21}$$

3.3 การออกแบบข่ายงานนิวรัล

การออกแบบข่ายงานนิวรัลที่ดีต้องมีองค์ประกอบพื้นฐาน 2 อย่างคือ ข้อมูลที่ใช้ในการฝึกข่ายงานนิวรัล (process data) และ ความรู้เกี่ยวกับกระบวนการสร้างแบบจำลอง (process knowledge) ดังแสดงในรูป 3.5 ถ้าต้องการแบบจำลองข่ายงานนิวรัลที่ดีควรมีข้อมูลที่ใช้ในการฝึกข่ายงานนิวรัลที่สร้างจากฐานข้อมูล (data-based model) ส่วนความรู้กระบวนการที่จะสร้างแบบจำลองจะเป็นเครื่องมือผลักดันให้แต่ละขั้นตอนของการสร้างแบบจำลองประสบความสำเร็จ



รูปที่ 3.5 พื้นฐานการออกแบบข่ายงานนิวรัล

3.3.1 ข้อมูลที่ใช้ในการฝึกข่ายงาน (Training Data)

ก. การเลือกชุดข้อมูลอินพุตและเอาต์พุต

หลักในการเลือกชุดข้อมูลอินพุตเข้าสู่ข่ายงานนิวรัล คือในกรณีที่เป็นแบบจำลองในสถานะคงที่ให้เลือกอินพุตที่มีผลกระทบต่อค่าเป้าหมาย แต่ถ้าเป็นแบบจำลองที่เป็นพลศาสตร์ (dynamics) นอกจากจะพิจารณาตัวแปรที่มีผลกระทบต่อค่าเป้าหมายแล้วยังต้องพิจารณาอนุกรมของช่วงเวลาของชุดข้อมูลอินพุตและเอาต์พุต ส่วนการเลือกชุดข้อมูลเอาต์พุตคือชุดข้อมูลที่ต้องการทำนาย ตัวแปรทั้งหมดถูกวัดในหน่วยที่ต่างกันและในช่วง ถ้าตัวแปรใดมีค่ามากกว่าก็จะมีค่าสำคัญไม่เท่ากัน เนื่องมาจากวิธีการปรับค่าน้ำหนัก ดังนั้นจึงต้องมีการลดค่าของตัวแปรอินพุตให้อยู่ในขอบเขตของค่าสูงต่ำเดียวกันทุกตัวแปร เพื่อจะให้ค่าน้ำหนักที่เหมาะสมสำหรับตัวแปรอินพุตและค่าเอาต์พุตมีค่าอยู่ในขอบเขตหนึ่งซึ่งมาจากลักษณะของฟังก์ชันกระตุ้น

ชุดข้อมูลที่ใช้ในการสร้างข่ายงานจะแบ่งชุดข้อมูลเป็น 3 ชุด ได้แก่ชุดข้อมูลชุดแรกใช้ในการฝึกข่ายงานเพื่อสร้างแบบจำลองภายในของข่ายงาน โดยใช้การปรับค่าน้ำหนักของข่ายงานจนมีค่าความผิดพลาดระหว่างค่าเป้าหมายกับค่าเอาต์พุตที่ได้จากข่ายงานน้อยจนกระทั่งอยู่ในขอบข่ายที่ยอมรับได้ ข้อมูลอีกชุดหนึ่งเป็นชุดในการทดสอบแบบจำลอง (cross validation data set) ซึ่งใช้เป็นตัวทดสอบความสามารถของข่ายงานว่าสามารถทำนายค่าเอาต์พุตได้ถูกต้องเพียงใด โดยชุดข้อมูลนี้จะคล้ายกับชุดฝึกข่ายงาน ส่วนข้อมูลชุดสุดท้ายใช้เป็นชุดทดสอบการใช้งานจริง โดยใช้แบบจำลองที่เป็นตัวแทนของกระบวนการ

ข. การเตรียมข้อมูล (data preparation)

การเตรียมข้อมูลเป็นสิ่งสำคัญที่จะทำให้แบบจำลองสำเร็จหรือไม่สำเร็จ เพราะจะทำให้ค่าของชุดข้อมูลที่ใช้ในการฝึกต่างกันแบบจำลองก็จะต่างกันด้วย

ค. การลดขนาดของช่วงในข้อมูล (data normalization)

การลดขนาดของช่วงข้อมูลจะทำอยู่ในช่วงระหว่างค่า 0 ถึง 1 เพราะค่าสัญญาณเอาต์พุตจะมีค่าอยู่ในช่วง 0 ถึง 1 และเป็นการลดขนาดของอินพุตที่มีขนาดใหญ่มากเกินไปกว่าอินพุตอื่นเพื่อทำให้มีความสำคัญเท่าเทียมกัน การลดขนาดช่วงของข้อมูลมี 4 วิธี

(1) Mean/std Deviation

วิธีนี้เป็นวิธีที่นิยมมาก แต่ละอินพุตจะเป็นอิสระต่อกัน

$$x_i' = (x_i - \text{mean}) / \text{std deviation} \quad \text{สมการที่ 3.22}$$

x_i' = อินพุตใหม่หลังจากการลดช่วงข้อมูลแล้ว

mean = ค่าเฉลี่ยของแต่ละอินพุต

std deviation = ค่าการเบี่ยงเบนมาตรฐานของแต่ละอินพุต

(2) Max Min Preprocessing

วิธีนี้จะคำนวณจากค่าสูงสุดและต่ำสุดของแต่ละอินพุตในชุดข้อมูลที่ใช้ในการฝึกและทดสอบข่ายงาน

$$x_i' = (x_i - (\max_i - \min_i) / 2) / (\max_i - \min_i) \quad \text{สมการที่ 3.23}$$

โดย \max_i = ค่ามากที่สุดของอินพุต

$\min_i =$ ค่าน้อยที่สุดของอินพุท

(3) Sum to 1 Normalization

$$x_i' = x_i / (\sum x_i) \quad \text{สมการที่ 3.24}$$

วิธีนี้จะไม่ประสบผลสำเร็จถ้ามีค่าอินพุทที่เป็นค่าบวกและค่าลบมากๆ

(4) Sum of Squares to 1 Preprocessing

วิธีนี้จะคล้ายวิธี Sum to 1 Normalization

$$x_i' = x_i / (\sum (x_i)^2)^{1/2} \quad \text{สมการที่ 3.25}$$

วิธีนี้จะสูญเสียค่าของข้อมูลที่มีขนาดใหญ่ ซึ่งจะสัมพันธ์กับเวกเตอร์ของอินพุท ขณะที่ยังรักษาทิศทางหรือความสัมพันธ์ระหว่างอินพุทเหมือนเดิม

วิธีที่ (1) และ (2) จะไม่สูญเสียข้อมูลใดๆ และสามารถขยายช่วงกลับได้โดยใช้สมการทางคณิตศาสตร์ แต่วิธีที่ (3) และ (4) ไม่สามารถขยายช่วงกลับได้วิธีนี้จึงเป็นวิธีที่สูญเสียค่าของข้อมูล

ง . จำนวนชุดข้อมูลในการฝึก (training pattern)

จำนวนชุดข้อมูลที่ใช้ในการฝึกข่างานก็เป็นสิ่งสำคัญ จำนวนชุดข้อมูลในการฝึกยิ่งมากแบบจำลองก็ยิ่งดี แต่หมายความว่ารวมถึงปริมาณข้อมูลและค่าความแตกต่างของชุดข้อมูลแต่ละชุดด้วย ถ้าข่างานมีชุดข้อมูลการฝึกที่ดีก็จะมีความสัมพันธ์ระหว่างอินพุทและเอาต์พุทดีขึ้น การเพิ่มจำนวนชุดข้อมูลนั้นคือการเพิ่มความแตกต่างของชุดข้อมูลจะเป็นการเพิ่มความซับซ้อนของการสร้างและออกแบบขั้นซ่อน ซึ่งจะแบ่งชุดข้อมูลนี้ประมาณ 10-20% สำหรับใช้เป็นชุดข้อมูลในการทดสอบ (test set)

3.3.2 ความรู้เกี่ยวกับการสร้างแบบจำลอง

ความรู้ในการสร้างแบบจำลองจะต้องประกอบไปด้วยองค์ประกอบดังต่อไปนี้

3.3.2.1. โครงสร้างของแบบจำลองและขนาดของโครงสร้าง

จากหน้าที่ของนิวรัลแต่ละหน่วยสามารถนำมาเขียนเป็น โครงสร้างของข่ายงานได้ คือโครงสร้างของข่ายงานประกอบด้วยชั้น (layer) อย่างน้อย 3 ชั้นเพื่อใช้ในการรับและส่งสัญญาณ เอาท์พุท ดังต่อไปนี้

(1) ชั้นอินพุท (input layer): ทำหน้าที่รับข้อมูลที่ใช้ในการฝึกข่ายงานนิวรัลและกระจายไปให้กับนิวรัลในชั้นซ้อนต่อไป จำนวนนิวรัลในชั้นอินพุทจะเท่ากับจำนวนค่าตัวแปรที่ใช้เป็นอินพุทในแบบจำลอง

(2) ชั้นซ่อน (hidden layer): จะทำการประมวลผลโดยการรวมสัญญาณ (โดยใช้ฟังก์ชันมูลฐาน) จากชั้นรับข้อมูลไปแปลงค่า (transform) เป็นสัญญาณเอาท์พุท โดยใช้ฟังก์ชันกระตุ้นและสัญญาณเอาท์พุทจะถูกส่งต่อไปให้นิวรัลในชั้นถัดไป โดยข้อมูลความรู้ต่างๆ ที่ประมวลได้จะถูกเก็บอยู่ในรูปค่าน้ำหนักและไบแอส ลักษณะการทำงานดังกล่าวจะกระทำซ้ำกันไปจนถึงชั้นเอาท์พุท ซึ่งชั้นซ่อนจะใช้เป็นตัวสร้างแบบจำลองภายในของระบบและสามารถมีได้มากกว่า 1 ชั้น

ในการออกแบบควรเริ่มต้นด้วยการออกแบบข่ายงานที่มีจำนวนของชั้นซ่อน และจำนวนนิวรัลในชั้นซ่อนน้อยๆ ถ้าการเรียนรู้ไม่เพียงพอหรือมีความสัมพันธ์กันไม่ดีพอควรสร้างความซับซ้อนของข่ายงานเพิ่มขึ้น โดยการปรับการเรียนรู้หรือการเพิ่มโครงสร้างของข่ายงาน

(3) ชั้นเอาท์พุท (output layer): ทำหน้าที่รวมสัญญาณจากชั้นซ่อนไปแปลงค่าเป็นผลลัพธ์ออกจากข่ายงานนิวรัลซึ่งจะเป็นคำตอบของปัญหาที่ต้องการต่อไป จำนวนนิวรัลในชั้นเอาท์พุทของข่ายงานนิวรัลเท่ากับจำนวนของตัวแปรที่ต้องการทำนาย

การกำหนดโครงสร้างและจำนวนของนิวรัลที่ต้องการในแต่ละชั้น ในแต่ละงาน จะไม่มีกฎเกณฑ์ที่แน่นอน เช่นในงานที่เป็นโครงสร้างการเชื่อมต่อแบบป้อนไปข้างหน้าที่มีชั้นซ่อน 1 ชั้นจะเหมาะสมในการใช้งานส่วนใหญ่ โดยปกติการเลือกชั้นซ่อนจะเริ่มต้นที่ชั้นซ่อน 1 ชั้นก่อนและค่อยทำการแก้ไขขนาดของโครงสร้างจากตอนเริ่มต้นโดยใช้วิธีลองผิดลองถูก เพื่อให้แบบจำลองเป็นที่พอใจโดยมีค่าความผิดพลาดอยู่ในช่วงที่ยอมรับได้ แต่ถ้าค่าความผิดพลาดอยู่ในช่วงที่ยอมรับไม่ได้ ขนาดของโครงสร้างต้องถูกปรับใหม่และทำการหาค่าความผิดพลาดใหม่ซ้ำไปเรื่อยๆ

โครงข่ายงานที่ต่างกันต้องการอัลกอริทึมในการฝึกข่ายงานที่ต่างกันและเวลาในการฝึกข่ายงานก็ไม่เท่ากันซึ่งสามารถทำให้เวลาลดลงได้โดยเลือกอัลกอริทึมที่เหมาะสม อย่างไรก็ตาม

ก็ตามในงานวิจัยนี้จะใช้อัลกอริทึมการกระจายความผิดพลาดย้อนกลับแบบ รีเวนเบอร์-มาร์ควอร์ ในการลดค่าผิดพลาดระหว่างค่าเป้าหมายกับค่าที่เอาต์พุตที่ทำนายได้จากข่ายงาน ดังนั้นในการออกแบบโครงสร้างของแบบจำลองต้องกำหนดดังต่อไปนี้

3.3.2.2 ชนิดของการเชื่อมโยงน้ำหนักในโครงสร้างของข่ายงานนิวิรัล (network connection)

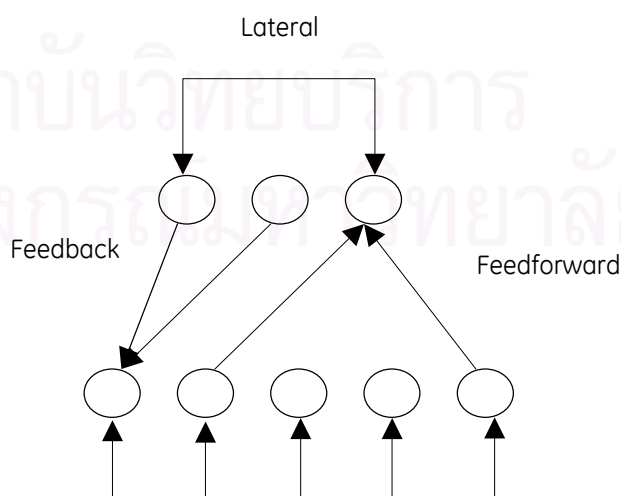
ข่ายงานนิวิรัลประกอบด้วยนิวิรัลและเมทริกซ์ของน้ำหนัก พฤติกรรมของข่ายงานขึ้นกับการเชื่อมโยงระหว่างนิวิรัลสองชั้นติดต่อกันโดยผ่านข่ายงานเชื่อมต่อที่เรียกว่า น้ำหนัก ซึ่งการติดต่อสื่อสารกันระหว่างชั้นแบ่งเป็น 4 ประเภท แสดงในรูปที่ 3.6 คือ

(1) การเชื่อมโยงแบบป้อนไปข้างหน้า (feedforward connection) เป็นการนำข้อมูลของนิวิรัลจากชั้นที่ต่ำกว่าและนำไปใช้ในชั้นที่อยู่เหนือกว่า

(2) การเชื่อมโยงแบบป้อนกลับ (feedback connection) เป็นการนำข้อมูลจากชั้นที่อยู่เหนือกว่าและส่งกลับมายังชั้นที่อยู่ต่ำกว่า

(3) การเชื่อมโยงภายในชั้น (lateral connection) เป็นการนำข้อมูลภายในชั้นเดียวกันและกระจายกลับมาใช้ในชั้นเดิม

(4) การเชื่อมโยงแบบหน่วงเวลา (time-delayed connection) เป็นการนำข้อมูลมาหน่วงเวลาแล้วนำเข้าไปรวมกับการเชื่อมโยงของข้อมูล เพื่อให้ได้แบบจำลองเป็นไดนามิก (temporal dynamics) ซึ่งนำมาประยุกต์ใช้กับการจดจำรูปแบบข้อมูล (temporal pattern recognition)



รูปที่ 3.6 โครงสร้างพื้นฐานของข่ายงานนิวิรัลที่แสดงการเชื่อมโยงแบบต่างๆ

การออกแบบข่ายงานที่เกี่ยวข้องกับการควบคุมการเชื่อมต่อของชั้นซ่อนภายใน ข่ายงานควรพิจารณาว่ามีการเชื่อมต่ออย่างไร ซึ่งปกติแล้วหลักที่สำคัญคือจะใช้การเชื่อมต่อข่ายงานแบบกระจายทั้งหมดมากกว่ากระจายบางส่วน

3.3.2.3 ฟังก์ชันกระตุ้น (transfer function)

ฟังก์ชันกระตุ้นใช้เพื่อจุดประสงค์สำหรับควบคุมความเข้มของสัญญาณขาออก (output signal strength) จากนิวรัลในแต่ละชั้น (ยกเว้นชั้นอินพุทจะใช้ค่าในชั้นอินพุทเหล่านั้น) ความเข้มของสัญญาณจะถูกกำหนดตามชนิดของฟังก์ชันกระตุ้น เช่นกำหนดความเข้มของสัญญาณขาออกอยู่ระหว่าง 0 ถึง 1 อินพุทที่จะมาผ่านฟังก์ชันกระตุ้นโดยส่วนใหญ่ได้มาจากการทำผลคูณแบบเวกเตอร์ (dot product) ระหว่างสัญญาณอินพุทของนิวรัลกับค่าน้ำหนัก (weight vector) ฟังก์ชันกระตุ้นที่นิยมใช้ส่วนใหญ่มีฟังก์ชันซิกมอยด์, ฟังก์ชันเกาส์เซียน, ฟังก์ชันไฮเปอร์โบลาร์แทนเจนท์ ซึ่งฟังก์ชันเหล่านี้สามารถกำหนดความเข้มแบบใดก็ได้ในแต่ละชั้น

3.3.2.4 การกำหนดค่าน้ำหนักเริ่มต้น (weight initialization)

การกำหนดค่าน้ำหนักเริ่มต้นจะมีผลต่อความเร็ว และคุณภาพของการฝึกข่ายงาน นิวรัล การกำหนดค่าน้ำหนักเริ่มต้นจะกำหนดเป็นค่าน้อยๆ คือเป็นตัวเลขสุ่ม เช่น ในช่วง -0.5 ถึง 0.5 (Bhat and McAvoy, 1954) ดังนั้นน้ำหนักที่ทำการเชื่อมต่อแต่ละชั้นจะมีความแตกต่างกันเล็กน้อยระหว่างการฝึกข่ายงานและมีผลกระทบต่อความผิดพลาดการฝึกที่มีค่าผิดพลาดต่ำที่สุด ถ้าค่าความผิดพลาดไม่อยู่ในช่วงที่พอใจจะทำการปรับค่าน้ำหนักใหม่และทำการเรียนรู้ซ้ำอีกครั้ง และถ้าไม่ได้ผลอีกให้ทำการกำหนดโครงสร้างของข่ายงานใหม่ ซึ่งวิธีเหล่านี้เป็นการปรับปรุงการฝึกข่ายงาน

3.3.2.5 การจำแนกการเรียนรู้ของข่ายงานนิวรัล

ในการออกแบบข่ายงานต้องทำการออกแบบอัลกอริทึมในการเรียนรู้ เพื่อให้ข่ายงานสามารถจำลองได้ใกล้เคียงกับสิ่งที่ต้องการเรียนรู้ การเรียนรู้ของระบบประสาทของมนุษย์ได้จากการเรียนรู้จากประสบการณ์ การจำลองการเรียนรู้โดยใช้ข่ายงานนิวรัลนี้จึงเรียกว่า machine learning algorithms เพราะว่าเป็นการปรับค่าน้ำหนักระหว่างนิวรัลเพื่อทำให้เกิดการเรียนรู้คำตอบของปัญหา

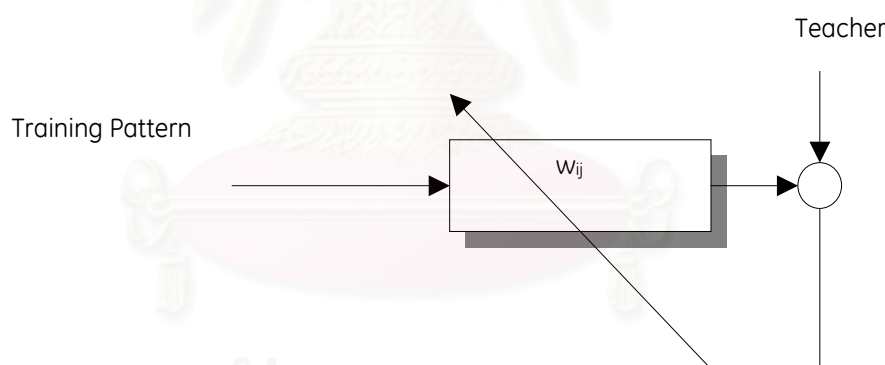
ในการฝึกข่ายงานนิวรัลให้เรียนรู้เพื่อหาคำตอบของปัญหาหนึ่ง ๆ นั้นอาศัยชุดของปัญหาและคำตอบของปัญหาที่ถูกต้องเพื่อนำมาใช้ในการฝึกข่ายงานนิวรัลให้สามารถสร้างคำตอบ

ของปัญหาให้คล้ายคลึงกับชุดของข้อมูลที่ได้รับการฝึกให้เรียนรู้ โดยทั่วไปแล้วข่ายงานนิวรัลสามารถจำแนกการเรียนรู้ได้ 2 ประเภท ดังนี้

3.3.2.5.1 ข่ายงานนิวรัลแบบมีการชี้นำ (supervised neural network)

เป็นการฝึกเครือข่ายนิวรัลให้เลียนแบบชุดข้อมูลตามที่กำหนด และสามารถส่งสัญญาณเอาต์พุตได้คล้ายคลึงกับชุดข้อมูลที่ป้อนให้เรียนรู้

ข่ายงานนิวรัลที่มีการชี้นำถูกฝึกโดยใช้คู่ลำดับของค่าอินพุตและค่าเป้าหมาย ค่าอินพุตใช้เป็นอินพุตให้แก่ข่ายงานและค่าเป้าหมายใช้เป็นผู้สอนดังแสดงในรูปที่ 3.7 ซึ่งถือว่าเป็นข้อได้เปรียบของการเรียนรู้วิธีนี้ เพราะมีเป้าหมายที่ต้องการเป็นผู้สอนโดยค่าที่แตกต่างกันระหว่างค่าเอาต์พุตที่ออกจากข่ายงานกับค่าเป้าหมายที่ต้องการจะเป็นข้อมูลที่ใช้ในการเรียนรู้ เพื่อให้ค่าแตกต่างระหว่างค่าเป้าหมายและเอาต์พุตของข่ายงานมีค่าน้อยที่สุด วิธีการปรับค่าน้ำหนักของข่ายงานเพื่อให้เครือข่ายนิวรัลเรียนรู้ จดจำข้อมูลสัญญาณอินพุต และสร้างสัญญาณเอาต์พุตได้สอดคล้องกับข้อมูลสัญญาณเป้าหมายตามที่กำหนดในชุดของข้อมูลที่ใช้ฝึก ซึ่งกระบวนการนี้อาจทำซ้ำจนค่าผิดพลาดอยู่ในช่วงที่ยอมรับได้



รูปที่ 3.7 การเรียนรู้ของข่ายงานนิวรัลในการปรับค่าน้ำหนักแบบมีการชี้นำ

ตัวอย่างข่ายงานนิวรัลแบบมีการชี้นำได้แก่ ข่ายงานเปอร์เซปตรอน (perceptron) ข่ายงานแบบอะคาไลน์ และข่ายงานแบบการกระจายความผิดพลาดย้อนกลับ ข่ายงานเปอร์เซปตรอนและอะคาไลน์เป็นข่ายงานที่มีชั้นของน้ำหนักเพียงชั้นเดียว จึงสามารถแก้ปัญหาได้เฉพาะปัญหาแบบเชิงเส้น สำหรับข่ายงานแบบกระจายย้อนกลับเป็นข่ายงานของน้ำหนักตั้งแต่ 2 ชั้นขึ้นไปจึงสามารถแก้ปัญหาแบบไม่เชิงเส้นได้เป็นอย่างดี ข่ายงานการเรียนรู้แบบการกระจายย้อนกลับเป็นอัลกอริทึมที่นำมาใช้ในฝึกข่ายงานนิวรัลเพื่อใช้ในการทำนายค่าเปอร์เซ็นต์ของแจ้ง และความหนักในงานวิจัยนี้ โดยข่ายงานนิวรัลจะถูกฝึกด้วยการใช้ชุดข้อมูลซึ่งมีการปรับค่าน้ำหนักเพื่อให้ค่า

เป้าหมายกับเอาที่พุทของข่ายงานมีค่าใกล้เคียงกัน ฟังก์ชันมูลฐานที่ใช้เป็นฟังก์ชันเชิงเส้น ฟังก์ชันกระตุ้นเป็นฟังก์ชันซิกมอยด์ และโครงสร้างการเชื่อมโยงเป็นแบบป้อนไปข้างหน้า โดยจำนวนชั้นในข่ายงานนิวัตหมายถึงชั้นของน้ำหนัก เป็นตัวแทนของการเปลี่ยนแปลงแบบเชิงเส้นแต่ชั้นของนิวัตแต่ละชั้นจะเกิดการเปลี่ยนแปลงแบบไม่เชิงเส้น ในทางปฏิบัติพบว่าชั้นซ่อนเพียงสองชั้นเพียงพอต่อการแก้ปัญหาาระบบต่างๆได้ทุกระบบ (สุรพล,1995) งานวิจัยนี้จะใช้อัลกอริทึมการกระจายย้อนกลับในการฝึกข่ายงานนิวัต และข่ายงานนิวัตแบบมีการชี้นำจะใช้ชุดข้อมูลที่ประกอบไปด้วยค่าอินพุท และเป้าหมายเป็นคู่ที่สอดคล้องกัน


Werbos (1974) ได้พัฒนาอัลกอริทึมการกระจายความผิดพลาดย้อนกลับ (backpropagation algorithm) และ Rumelhart (1986) นำเสนออัลกอริทึมนี้อีกครั้ง ทำให้อัลกอริทึมนี้เป็นที่รู้จักกันอย่างกว้างขวาง และเป็นอัลกอริทึมมาตรฐานที่ใช้ในการฝึกข่ายงานแบบมีการชี้นำ อัลกอริทึมการกระจายย้อนกลับเป็นวิธีที่คำนวณเกรเดียนต์อย่างได้ผล (Kung,1993)

เครือข่ายนิวัตแบบการกระจายความผิดพลาดย้อนกลับ เป็นเครือข่ายนิวัตที่ใช้วิธีการประมวลผลเป็นชั้นๆ โดยนำข้อมูลจากชุดข้อมูลที่ต้องการใช้ในการฝึกเครือข่าย (Training set) ป้อนข้อมูลเข้าที่ชั้นอินพุท (Input layer) ผ่านชั้นซ่อน (Hidden layer) จนถึงชั้นเอาที่พุท (output layer) สัญญาณออกจากชั้นเอาที่พุทถูกนำไปเปรียบเทียบกับสัญญาณตามที่ต้องการ (Desired Signal) หรือสัญญาณเป้าหมาย (Target Signal) ซึ่งได้จากชุดของข้อมูลที่นำมาใช้ฝึกเครือข่ายนิวัต ค่าแตกต่างระหว่างสัญญาณทั้งสองถูกแผ่ย้อนกลับเข้าสู่เครือข่ายนิวัตอีกครั้ง โดยผ่านทางชั้นเอาที่พุทผ่านชั้นซ่อนจนถึงชั้นอินพุท เพื่อปรับค่าพารามิเตอร์ของเครือข่ายนิวัตในแต่ละชั้น อันได้แก่ ค่าน้ำหนัก ค่าไบแอส และค่าพารามิเตอร์ต่างๆ ของกฎที่ใช้ในการเรียนรู้ทำให้เครือข่ายนิวัตสามารถเรียนรู้ชุดข้อมูลที่แฝงในรูปของค่าพารามิเตอร์ของเครือข่าย และสามารถสร้างสัญญาณออกซึ่งสอดคล้องกับข้อมูลที่ใช้ในการฝึกเครือข่าย

ข่ายงานนิวัตแบบกระจายย้อนกลับ มีฟังก์ชันมูลฐานเป็นฟังก์ชันมูลฐานเชิงเส้น และมีฟังก์ชันกระตุ้นเป็นฟังก์ชันซิกมอยด์ มีสมการ ไดนามิกดังสมการที่ 3.26 และ 3.27 ตามลำดับ ดังแสดงในรูปที่ 3.8

$$u_i(l) = \sum_{j=1}^N w_{ij}(l)a_j(l-1) + b_i(l) \quad \text{สมการที่ 3.26}$$

$$a_i(l) = f(u_i(l)) \quad 1 \leq i \leq N_i, \quad 1 \leq l \leq L \quad \text{สมการที่ 3.27}$$



รูปที่ 3.8 แสดงแบบจำลองนิวรัลในชั้นที่ 1

$a_i(I-1)$ = ค่าอินพุตที่ i ของชั้นอินพุต

O_i = ค่าเอาต์พุตที่ต้องการในชั้นเอาต์พุตตัวที่ i

$a_i(I) = f(a_i)$ = ค่าเอาต์พุตจริงของนิวรอน i

$u_i(I)$ = ค่าผลรวมของค่าน้ำหนักกับอินพุตโดยใช้การคำนวณแบบฟังก์ชันมาตรฐาน

w_{ij} = ค่าน้ำหนักที่เชื่อมต่อระหว่างนิวรัล i ในชั้นที่ $I-1$ กับนิวรัล j ในชั้นที่ I

E = ค่าความผิดพลาด (global error)

η = ค่าอัตราการเรียนรู้

$b_i(I)$ = ค่าไบอัสของชั้นที่ i

ข่ายงานนิวรัลแบบกระจายย้อนกลับประกอบไปด้วยหลาย ๆ นิวรัลที่มีการเชื่อมโยงแบบป้อนไปข้างหน้า โครงสร้างของข่ายงานนิวรัลจะประกอบไปด้วยชั้นอินพุต, ชั้นซ่อน, และชั้นเอาต์พุต ชั้นอินพุตประกอบด้วยนิวรัลที่ไม่มีการคำนวณใดๆแต่จะกระจายค่าอินพุตให้แก่ทุกๆนิวรัลในชั้นถัดไป ชั้นซ่อนที่อยู่ระหว่างชั้นอินพุต และชั้นเอาต์พุต ซึ่งข่ายงานนิวรัลสามารถมีชั้นซ่อนหลายชั้น แต่จะพิจารณาในที่นี้เพียงชั้นเดียวเท่านั้นเพื่อความง่ายต่อการเข้าใจ และชั้นสุดท้ายคือชั้นเอาต์พุต โดยจะทำหน้าที่ส่งค่าเอาต์พุตสุดท้ายของข่ายงานนิวรัลในชั้น

อินพุตรับ ค่าอินพุตเป็น i_1, \dots, i_{n_1} และมีน้ำหนักเป็น w_{1j}, \dots, w_{n_1j} และในแต่ละชั้นแทนด้วย $I = 0$ เป็นชั้นอินพุต, $I = 1$ เป็นชั้นซ่อนที่ 1, $I = 2$ เป็นชั้นเอาต์พุต

ผลรวมน้ำหนักของอินพุตของนิวรัลลำดับที่ j ในชั้นซ่อนคือ

$$u_j(1) = \sum_{i=1}^{N_1} w_{ij}(1)a_i(0) + b_j(1) \quad 1 \leq j \leq N_2 \quad \text{สมการที่ 3.28}$$

เอาต์พุตของนิวรัลลำดับที่ j ในชั้นซ่อนคือ

$$a_j(1) = f(u_j(1)) \quad 1 \leq j \leq N_2 \quad \text{สมการที่ 3.29}$$

เอาต์พุตของนิวรัลในชั้นซ่อนใช้เป็นอินพุตให้แก่นิวรัลในชั้นเอาต์พุต ดังสมการ

$$u_j(2) = \sum_{i=1}^{N_2} w_{ij}(2)a_i(1) + b_j(2) \quad 1 \leq j \leq N_3 \quad \text{สมการที่ 3.30}$$

นิวรัลในชั้นเอาต์พุตสร้างเอาต์พุตของกระบวนการที่ถูกทำนายในช่วง 1 รอบที่วนในการคำนวณจากชั้นอินพุตจนถึงชั้นเอาต์พุต ดังแสดงในสมการที่ 3.31

$$a_j(2) = f(u_j(2)) \quad \text{สมการที่ 3.31}$$

เมื่อ $b_j(1)$ เป็นเทอมไบอัส (bias term) ของชั้นที่ 1 ซึ่งเป็นน้ำหนัก โดยใช้ค่าอินพุตมีค่าเป็น 1 และ a_2 หมายถึงค่าเอาต์พุตจากข่ายงานนิวรัล

หมายเหตุ f แทนด้วยฟังก์ชันกระตุ้น ฟังก์ชันกระตุ้นมักจะเป็นฟังก์ชันซิกมอยด์ (sigmoid function) โดยมีสมการดังนี้คือ

$$f(x) = \frac{1}{1 + e^{(-x)}} \quad \text{สมการที่ 3.32}$$

และอนุพันธ์ของฟังก์ชันซิกมอยด์คือ

$$f'(x) = x(1-x) \quad \text{สมการที่ 3.33}$$

วิธีการออปติไมซ์ (optimization method)

กระบวนการที่ไม่เป็นเชิงเส้นหรือที่ซับซ้อนจะมีการเชื่อมโยงอินพุตไปสู่เอาต์พุต โดยใช้ชุดของน้ำหนักในข่ายงาน วัตถุประสงค์ของอัลกอริทึมก็คือ ต้องการหาค่าน้ำหนักให้ถูกต้องเพื่อที่สามารถจำลองแบบกระบวนการนั้น ให้สามารถทำนายค่าเอาต์พุตจากอินพุตที่รับเข้าไปได้ อย่างถูกต้อง ดังนั้นอัลกอริทึมการกระจายย้อนกลับเป็นอัลกอริทึมหนึ่งที่ต้องการลดค่าผิดพลาด

กำลังสองระหว่างค่าเป้าหมายกับผลลัพธ์จากข่ายงาน โดยใช้วิธีการอพติไมซ์แบบเกรเดียนต์เดสเซนท์ ซึ่งเป็นวิธีการลดความผิดพลาด (optimization method) ซึ่งแสดงในสมการ 3.34

สำหรับข้อมูลแต่ละชุด

minimize:

$$E = \frac{1}{2} \sum_{i=1}^{N_L} \{t_i - a_i(L)\}^2 \quad \text{สมการที่ 3.34}$$

subject to : $t_{\max} > t_i > t_{\min}$ สมการที่ 3.35

$$a_{\max} > a_i(L) > a_{\min} \quad \text{สมการที่ 3.36}$$

เมื่อ

E คือค่าความผิดพลาด(global error) ที่ขึ้นเอาที่พุทได้มาจากผลรวมกำลังสองของความแตกต่างของเอาที่พุทที่ได้จากการคำนวณ กับค่าเป้าหมายในชั้นเอาที่พุท

t_i คือค่าเป้าหมาย

t_{\max} คือค่าสูงสุดของเป้าหมาย

t_{\min} คือค่าต่ำสุดของเป้าหมาย

$a_i(L)$ คือค่าเอาที่พุทของข่ายงาน

a_{\max} คือค่าสูงสุดของเอาที่พุทของข่ายงาน

a_{\min} คือค่าต่ำสุดของเอาที่พุทของข่ายงาน

เกรเดียนต์เดสเซนท์คือการลดความผิดพลาดให้ต่ำที่สุด โดยการปรับค่าน้ำหนัก ดังนั้นถ้าทราบค่าอนุพันธ์ย่อย (partial derivative) ของค่าผิดพลาดเทียบกับค่าน้ำหนักแต่ละค่า จะทำให้รู้ทิศทางที่น้ำหนักไปในทิศทางที่ลดค่าผิดพลาด นั่นคือ $\partial E / \partial W_{ij}$ เป็นค่าเกรเดียนต์ในทิศทางลบของพื้นผิวความผิดพลาด เครื่องหมายลบแทนด้วยทิศทางเกรเดียนลดความผิดพลาด ดังนั้นวิธีการปรับค่าน้ำหนักใหม่ในทางลดความผิดพลาดให้ต่ำสุด ซึ่งควรจะเป็นความผิดพลาดจริง (global error) มากกว่าที่จะเป็นความผิดพลาดเฉพาะที่ (local error) สำหรับอัลกอริธึมการกระจายย้อนกลับจะทำการปรับค่าน้ำหนัก (w_{ij}) เพื่อให้ค่า E มีค่าต่ำสุด สมการการเรียนรู้แบบเกรเดียนต์แสดงดังในสมการ 3.37

$$W_{ij}^{m+1}(I) = W_{ij}^m(I) + \Delta W_{ij}(I) \quad \text{สมการที่ 3.37}$$

อนุพันธ์ของค่าผิดพลาดจะใช้วิธีการตามเทคนิคของกฎลูกโซ่ (chain rule) ของชุดของข้อมูลการฝึก (iteration)

$$\Delta w_{ij}^m(l) \propto - \frac{\partial E}{\partial w_{ij}^m(l)} \quad \text{สมการที่ 3.38}$$

$$\begin{aligned} \Delta w_{ij}^m(l) &= -\eta \frac{\partial E}{\partial w_{ij}^m(l)} \\ &= -\eta \frac{\partial E}{\partial a_i^m(l)} \frac{\partial a_i^m(l)}{\partial w_{ij}^m(l)} \end{aligned} \quad \text{สมการที่ 3.39}$$

จากสมการ 3.35 นำมาแยกพิจารณาที่ละเทอมและจากสมการ 3.38 และ 3.39 จะได้ว่า

$$\begin{aligned} \frac{\partial a_i^m(l)}{\partial w_{ij}^m(l)} &= \frac{\partial f(u_i^m(l))}{\partial w_{ij}^m(l)} \\ &= \frac{\partial f\left(\sum_{j=1}^N w_{ij}^m(l) a_j^m(l-1) + b_i(l)\right)}{\partial w_{ij}^m(l)} \\ &= f'(u_i^m(l) a_j^m(l-1)) \end{aligned} \quad \text{สมการที่ 3.40}$$

กำหนดให้สัญญาณความผิดพลาด, $\delta_i(l)$ เป็น


$$\delta_i^m(l) = - \frac{\partial E}{\partial a_i^m(l)} \quad \text{สมการที่ 3.41}$$

สมการที่ 3.49 และ 3.50 แทนในสมการ 3.48 จะได้สมการ 3.51 ได้

$$\Delta w_{ij}^m(l) = \eta \delta_i^m(l) f'(u_i^m(l) a_j^m(l-1)) \quad \text{สมการที่ 3.42}$$

η คืออัตราการเรียนรู้ (learning rate) ถ้าเลือกอัตราการเรียนรู้ที่มีค่ามาก แต่ละขั้นตอนที่มีการปรับน้ำหนักค่าความผิดพลาดจะสูงเกินจุดต่ำสุดและนำไปสู่การแกว่งตัวรอบ

จุดต่ำสุด ในทางตรงกันข้ามถ้าอัตราการเรียนรู้มีค่าน้อยมากจะเป็นสาเหตุให้เข้าสู่จุดต่ำสุดช้าซึ่งต้องใช้อัลกอริทึมที่ช่วยเร่ง ในการเรียนรู้เช่น Rprop หรือริเวนเบอเกอร์-มาร์คควอร์



รูปที่ 3.9 แสดงการปรับน้ำหนักสำหรับอัลกอริทึมการกระจายความผิดพลาดย้อนกลับ

ถ้าเกรเดียนต์ $\partial E/\partial w$ เป็นบวก ค่าน้ำหนักจะถูกลดด้วย Δw เพื่อที่จะทำให้เกรเดียนต์มีค่าน้อยที่สุด ถ้าเกรเดียนต์มีค่าเป็นลบค่าน้ำหนักจะเพิ่มไปทางบวก ดังนั้นค่าน้ำหนักจะถูกปรับจนกระทั่งค่าความแตกต่างของค่าเป้าหมายกับผลลัพธ์จากข่ายงานมีค่าน้อยที่สุดในช่วงที่ยอมรับได้

ขั้นตอนของการเรียนรู้อัลกอริทึมการกระจายย้อนกลับ

ในการเรียนรู้ของอัลกอริทึมการกระจายย้อนกลับ สำหรับข่ายงานนิวิรัลดังแสดงในรูปที่ 3.8 ต้องกำหนดรูปแบบ (pattern) ของข้อมูลการเรียนรู้ซึ่งประกอบด้วยกลุ่มข้อมูลของอินพุต u_i และค่าเป้าหมาย t_i จำนวน p คู่ เพื่อให้เครือข่ายนิวิรัล สร้างสัญญาณออกลักษณะเดียวกันชุดของข้อมูลที่ใช้ในการฝึกเครือข่ายสามารถเขียนแทนได้ ดังสมการต่อไปนี้

$$P = \{ (u_1, t_1), (u_2, t_2), \dots, (u_p, t_p) \} \quad \text{สมการที่ 3.43}$$

โดยที่ P ชุดของข้อมูลที่ใช้ในการฝึกเครือข่าย (Training Set)

p จำนวนชุดข้อมูลที่ใช้ในการฝึกเครือข่าย (Training pair)

ขั้นตอนที่ 1 การกำหนดค่าเริ่มต้นสำหรับพารามิเตอร์ของเครือข่ายนิวิรัล

การฝึกเครือข่ายนิวิรัลจำเป็นต้องกำหนดค่าอัตราการเรียนรู้ (learning rate, η) ให้มีค่ามากกว่าศูนย์ กำหนดค่าผิดพลาดต่ำสุด (E_{\min}) และกำหนดค่าเริ่มต้นให้กับน้ำหนัก (weight)

ที่เชื่อมต่อกันระหว่างนิวรัลแต่ละชั้น $w_{ij}(l)$ โดยใช้ค่าตัวเลขสุ่ม กำหนดข้อมูลคู่แรกเข้ามา $p = 1$ ค่าผิดพลาดเริ่มต้น $E = 0$ และเริ่มการเรียนรู้ด้วยการวนรอบครั้งที่ 1 ($q = \text{iteration}$) $q = 1$ เพื่อใช้เป็นจุดเริ่มต้นในกระบวนการประมวลผลของเครือข่าย

ขั้นตอนที่ 2 กระบวนการประมวลผล

กระบวนการประมวลผลของเครือข่ายนิวรัลแบ่งเป็น 2 ขั้นตอน

ขั้นตอนที่ 2.1 การคำนวณไปข้างหน้า (Feedforward Calculation)

การคำนวณเริ่มจากชั้นอินพุต ผ่านชั้นซ่อนภายในจนถึงชั้นเอาต์พุต แสดงได้ดังสมการที่ 3.44 ส่งอินพุตและค่าเป้าหมายที่สอดคล้องกันให้นิวรัลของชั้นอินพุต เพื่อรับข้อมูลซึ่ง $u = u_p$, $t = t_p$ และคำนวณค่าผลลัพธ์ให้นิวรัลในชั้นซ่อนและชั้นเอาต์พุต โดยใช้ฟังก์ชันซิกมอยด์เป็นฟังก์ชันกระตุ้น

$$u_i(l) = \sum_{j=1}^N w_{ij}(l)a_j(l-1) + b_i(l) \quad \text{สมการที่ 3.44}$$

$$a_i(l) = f(u_i(l)) \quad 1 \leq i \leq N_i, \quad 1 \leq l \leq L$$

เมื่ออินพุตคือ $x_i = a_i(0)$ และเอาต์พุตแทนด้วย $y_i = a_i(L)$ เมื่อ l คือจำนวนชั้นทั้งหมดของข่ายงานนิวรัล และ i คือนิวรอนที่ i ในชั้นที่ j

ขั้นตอนที่ 2.2 การแพร่ความคลาดเคลื่อนย้อนกลับ (Backpropagation of Error)

การปรับค่าน้ำหนักของเครือข่ายนิวรัลเพื่อลดค่าความคลาดเคลื่อน หรือความแตกต่างระหว่างข้อมูลเป้าหมาย t_i กับสัญญาณออกจากเครือข่ายนิวรัลในชั้นเอาต์พุต a_i วิธีการออปติไมซ์แบบเกรเดียนต์ โดยกำหนดฟังก์ชันความคลาดเคลื่อน (Error Function :E) ดังแสดงในสมการที่ 3.54

คำนวณค่าผิดพลาด ($E =$ ค่าผิดพลาดระหว่างค่าเป้าหมาย (t_i) และผลลัพธ์จากข่ายงาน ($a_i(L)$)

$$E^{\text{new}} = E^{\text{old}} + \frac{1}{2} \sum_{i=1}^N \{t_i - a_i(L)\}^2 \quad \text{สมการที่ 3.45}$$

การคำนวณค่าเวกเตอร์สัญญาณผิดพลาด สัญญาณความผิดพลาดสำหรับชั้นเอาต์พุต

$$\delta_i(l) = (t_i - a_i(l)) \quad , i=1,2,\dots,N_l \quad \text{สมการที่ 3.46}$$

สัญญาณความผิดพลาดสำหรับชั้นซ่อนแต่ละชั้น

$$\delta_i(l) = \sum_{j=1}^{N_{l+1}} (\delta_j(l+1) W_{ji}(l+1) a_j(l+1) (1 - a_i(l+1))) \quad , i=1,2,\dots,N_l \quad \text{สมการที่ 3.47}$$

ขั้นตอนที่ 3 การปรับค่า **น้ำหนักที่เชื่อมระหว่างชั้นเอาต์พุตกับชั้นซ่อน หรือชั้น**

อินพุตกับชั้นซ่อน

หลังจากการประมวลผลในขั้นที่ 2 เครือข่ายนิวรัลจะปรับฐานข้อมูลความรู้ภายในใหม่ ซึ่งอยู่ในรูปของการปรับค่าน้ำหนักและค่าน้ำหนักไบแอสในแต่ละชั้นให้ทันสมัยและสอดคล้องกับชุดข้อมูลความรู้ใหม่ที่ได้เรียนรู้เป็นผลให้ฟังก์ชันความคลาดเคลื่อนดังสมการ 3.48 มีค่าลดลง

เมื่อ $i = 1, 2, \dots, n_l$ และ $j = 1, 2, \dots, n_{l-1}$

w_{ij} = weight ของ node ที่ i ใน layer ชั้นที่ j

$$W_{ij}^{\text{new}}(l) = W_{ij}^{\text{old}}(l) + \eta \delta_i(l) a_j(l-1) \quad \text{สมการที่ 3.48}$$

ขั้นตอนที่ 4 ตรวจสอบจำนวนชุดข้อมูลการเรียนรู้

ข้อมูลที่ใช้ในการฝึกเครือข่าย (Training Set) จะถูกป้อนเข้ามาครั้งละ 1 คู่ลำดับ (Training Pair : (u_p, t_p)) ซึ่งประกอบไปด้วยข้อมูลอินพุตและข้อมูลเป้าหมาย แต่เนื่องจากชุดข้อมูลที่ใช้ในการฝึกเครือข่ายมีจำนวนทั้งสิ้น p ชุด ดังนั้นจำเป็นต้องตรวจสอบจำนวนข้อมูลที่ใช้ในการฝึกเครือข่ายได้รับมาครบหรือไม่ ถ้าชุดข้อมูลยังไม่ถูกทำงานจนครบรอบ ($P < p$) ให้ส่งข้อมูลของชุดถัดไปไปยังนิวรัลในชั้นอินพุต โดยที่ $p = p+1$ และ $q = q+1$ แล้วจึงกลับไปทำขั้นตอนที่ 2 แต่ถ้าข้อมูลเรียนรู้จนครบแล้ว ($p = p$) ให้ไปดำเนินการขั้นตอนที่ 5

ขั้นตอนที่ 5 ตรวจสอบความผิดพลาดกับค่าต่ำสุดที่ตั้งไว้

วัตถุประสงค์หลักของการฝึกเครือข่ายนิวรัลคือ การลดฟังก์ชันความคลาดเคลื่อนระหว่างข้อมูลที่ออกจากเครือข่ายนิวรัลและข้อมูลเป้าหมาย ดังนั้นในขั้นตอนการเรียนรู้จะเสร็จ

สมบูรณ์เมื่อค่าผิดพลาดในการเรียนรู้มีค่าน้อยกว่าค่าผิดพลาดต่ำสุดที่ตั้งไว้ ($E < E_{\min}$) ถ้า $E > E_{\min}$ แล้วให้ $E = 0$ และ $p = 1$ เริ่มวงจรการเรียนรู้ใหม่ตามขั้นตอนที่ 2

การเรียนรู้โดยวิธีการเพิ่มโมเมนตัม

การเรียนรู้โดยการใช้โมเมนตัม ช่วยเร่งให้การเรียนรู้ของข่ายงานเข้าสู่ค่าเป้าหมายได้เร็วขึ้น โดยการนำค่าน้ำหนักล่าสุดมาใช้ในการปรับค่าน้ำหนักในปัจจุบันตามขั้นตอนที่ 5 ด้วยสัดส่วนของค่าโมเมนตัมดังสมการ 3.49

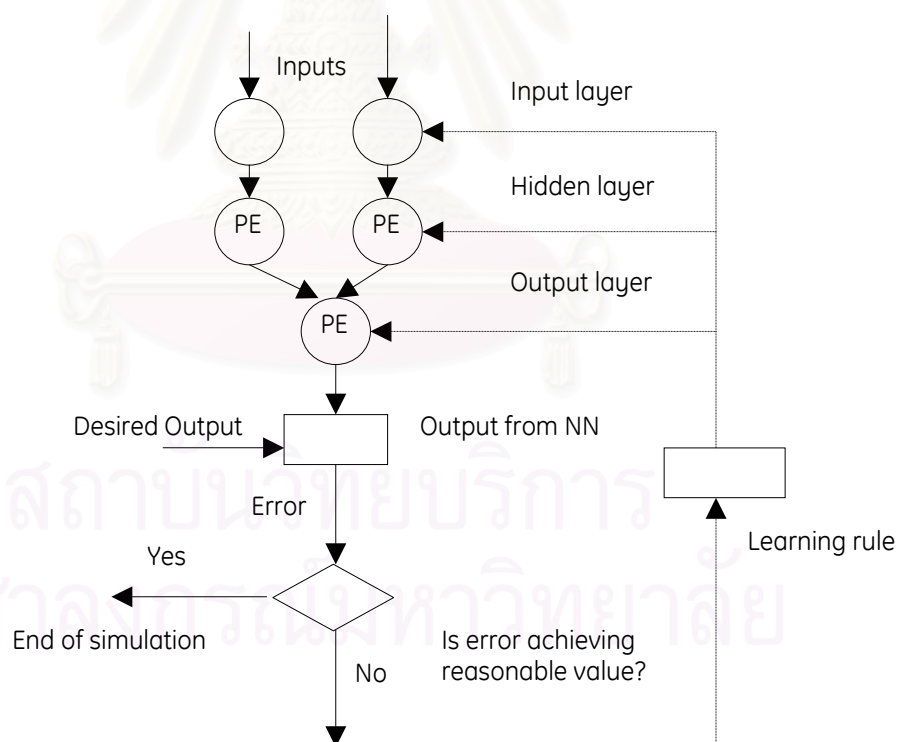
$$\Delta w(t) = -\eta \nabla e(t) + \alpha \Delta w(t-1)$$

สมการที่ 3.49

เมื่อ t คือจำนวนรอบของข้อมูลที่ฝึกข่ายงาน

α คือแฟกเตอร์โมเมนตัมที่มักเลือกค่าอยู่ระหว่าง 0-1

การเรียนรู้แบบการกระจายย้อนกลับสามารถอธิบายการทำงานได้ตามรูปที่ 3.10



รูปที่ 3.10 แสดงขั้นตอนการเรียนรู้ของข่ายงานนิวรัล

ชนิดของอัลกอริทึมการกระจายความผิดพลาดย้อนกลับ

1) Standard Backpropagation (Vanilla Backpropagation)

สมการอัลกอริทึม เสนอขึ้น โดย P.Werbos แสดงดังต่อไปนี้

$$\Delta w_{ij} = \eta \delta_j o_i \quad \text{สมการที่ 3.50}$$

$$\delta_j = f'_j(\text{net}_j)(t_j - o_j) \quad \text{ถ้า } j \text{ คือ เอาท์พุทนิวรัล} \quad \text{สมการที่ 3.51}$$

หรือ

$$\delta_j = f'_j(\text{net}_j) \sum_k \delta_k w_{jk} \quad \text{ถ้า } j \text{ คือ นิวรัลชั้นซ่อน} \quad \text{สมการที่ 3.52}$$

อัลกอริทึมนี้อาจเรียกว่า online backpropagation ได้เพราะว่าจะมีการปรับค่าน้ำหนักหลังจากมีการฝึกข่ายงานครบทุกชุดข้อมูล

2) Enhanced Backpropagation

Enhanced Backpropagation ใช้เทอมของโมเมนตัมเข้ามาช่วย และกำจัดจุดที่ไม่มี การเปลี่ยนแปลง (flat spot) ซึ่งเทอมของโมเมนตัมจะถูกนำเพิ่มในสมการของการปรับค่าน้ำหนักใหม่โดยการนำไปรวมกับค่าน้ำหนักเก่า ซึ่งจะหลีกเลี่ยงปัญหาการแกว่งตัวเมื่อค่าพื้นผิวความผิดพลาดมีค่าแคบมากของอัลกอริทึมการกระจายความผิดพลาดย้อนกลับแบบมาตรฐาน การปรับค่าน้ำหนักใหม่ของอัลกอริทึมนี้สามารถแสดงดังต่อไปนี้

$$\Delta w_{ij}(t+1) = \eta * \delta_j * o_i + \alpha \Delta w_{ij}(t) \quad \text{สมการที่ 3.53}$$

โดย α คือค่าคงที่ของโมเมนตัม

3) Backpropagation with Weight Decay

Weight Decay เสนอขึ้น โดย P.Werbos ซึ่งเป็นการลดน้ำหนักของการเชื่อมต่อ โดยค่า d ของน้ำหนักเดิมดังสมการต่อไปนี้

$$\Delta w_{ij}(t+1) = \eta * \delta_j * o_i - d w_{ij}(t) \quad \text{สมการที่ 3.54}$$

ค่าน้ำหนักจะถูกลดเข้าใกล้ค่า 0 จนกว่าจะได้ข่ายงานที่ต้องการ

4) Batch Backpropagation

Batch Backpropagation จะใช้สูตรเหมือนกับ vanilla backpropagation ความแตกต่างคือการปรับค่าน้ำหนัก นั่นคือ vanilla backpropagation จะมีการปรับน้ำหนักในแต่ละชุดข้อมูลที่เรียนรู้ ในขณะที่ batch backpropagation จะทำการปรับน้ำหนักเมื่อครบทุกชุดข้อมูล (ทุก 1 รอบของชุดข้อมูล) การปรับค่าน้ำหนักวิธีนี้เหมาะสำหรับการฝึกข่ายงานแบบขนาน

5) Quickprop

วิธีนี้เร่งการเรียนรู้โดยการใช้เส้นโค้งของพื้นผิวความผิดพลาด ซึ่งใช้การคำนวณอนุพันธ์อันดับสองของฟังก์ชันความผิดพลาด Quickprop มีสมมติฐานว่าค่าพื้นผิวความผิดพลาดจะเป็นแบบควอดราติก และพยายามที่จะข้ามไปอีกขั้นตอนหนึ่งจากตำแหน่งปัจจุบันไปสู่ค่าน้อยที่สุดของรูปพาราโบลา

Quickprop จะคำนวณอนุพันธ์ในทิศทางกรปรับน้ำหนัก หลังจากที่ได้คำนวณเกรเดียนต์แรกด้วยการกระจายความผิดพลาดย้อนกลับแบบมาตรฐาน ขั้นตอนที่จะลดค่าความผิดพลาดคือ

$$\Delta^{(t+1)} w_{ij} = S^{(t+1)} / (S^{(t)} - S^{(t+1)}) \Delta^{(t)} w_{ij} \quad \text{สมการที่ 3.55}$$

โดย w_{ij} คือ ค่าน้ำหนักการเชื่อมต่อระหว่างนิวรัล i และ j

$\Delta^{(t+1)}$ คือ การเปลี่ยนแปลงค่าน้ำหนักจริง

$S^{(t+1)}$ คือ อนุพันธ์บางส่วนของฟังก์ชันความผิดพลาด $1-v' w_{ij}$

$S^{(t)}$ คือ อนุพันธ์บางส่วนที่เป็นค่าสุดท้ายของฟังก์ชันความผิดพลาด

6) Rprop

Rprop มีการเปลี่ยนแปลง 2 แบบ แบบแรกคือการปรับปรุงขั้นตอนการกระจายย้อนกลับที่ทำอย่างรวดเร็ว แบบที่ 2 คือในทอมของการทำให้น้ำหนักลดลง (weight-decay) ถูกนำเข้ามารวมด้วย ซึ่งพารามิเตอร์ของการทำให้น้ำหนักลดลง คือ α (พารามิเตอร์การเรียนรู้ตัวที่ 3) ซึ่งมี 2 เป้าหมายคือ เพื่อลดค่าความผิดพลาดของเอาท์พุท (เป้าหมายทั่วไป) และลดขนาดของน้ำหนัก (เป้าหมายที่เพิ่มขึ้น) ฟังก์ชันความผิดพลาดแสดง ดังต่อไปนี้

$$E = \sum (t_i - o_i)^2 + 10^{-\alpha} \sum w_{ij}^2 \quad \text{สมการที่ 3.56}$$

เทอมของการทำให้น้ำหนักลดลง (weight decay, α) เป็นเทอมเอ็กซ์โปเนนเชียล ซึ่งจะทำให้ค่าน้ำหนักที่ลดลงเมื่อเปรียบเทียบกับอินพุตที่มีค่าเล็กมาก เช่น พารามิเตอร์การเรียนรู้ ตัวที่ 3 (α) = 4 ค่าน้ำหนักที่ลดลง (weight decay) ต่อความผิดพลาดของเอาต์พุตคือ 1:10000

Rprop ย่อมาจาก Resilient backpropagation และ เป็นการเรียนรู้แบบ adaptive learning การเรียนรู้จะเป็นแบบชี้หน้า ซึ่ง Rprop จะช่วยแก้ไขปัญหารีจอนาตอนุพันธ์บางส่วน ของค่าน้ำหนัก อนุพันธ์ที่จะแสดงนี้จะแสดงในทิศทางของการปรับค่าน้ำหนัก ขนาดของน้ำหนักที่เปลี่ยนแปลงมาจากค่าน้ำหนักเฉพาะ ที่เรียกว่า update-value $\Delta_{ij}^{(t)}$

ขั้นตอนที่ 1 การหาขนาดของน้ำหนักที่จะเปลี่ยนแปลง

$$\begin{aligned}\Delta w_{ij}^{(t)} &= -\Delta_{ij}^{(t)}, \text{ if } \partial E/\partial w_{ij}^{(t)} > 0 \\ &= +\Delta_{ij}^{(t)}, \text{ if } \partial E/\partial w_{ij}^{(t)} < 0 \\ &= 0, \text{ if else}\end{aligned} \quad \text{สมการที่ 3.57}$$

โดย $\partial E/\partial w_{ij}^{(t)}$ คือผลรวมของเกรเดียนทุกชุดข้อมูล

ถ้าแทน $\Delta_{ij}^{(t)}$ โดยค่าคงที่ update-value Δ สมการนี้จะเรียกว่า “Manhattan-update rule”

ขั้นตอนที่ 2 ของการเรียนรู้ Rprop คือการหา update-value ใหม่ $\Delta_{ij}^{(t)}$ ดังสมการต่อไปนี้

$$\begin{aligned}\Delta_{ij}^{(t)} &= \eta^+ * \Delta_{ij}^{(t-1)}, \text{ if } \partial E/\partial w_{ij}^{(t-1)} * \partial E/\partial w_{ij}^{(t)} > 0 \\ &= \eta^- * \Delta_{ij}^{(t-1)}, \text{ if } \partial E/\partial w_{ij}^{(t-1)} * \partial E/\partial w_{ij}^{(t)} < 0 \\ &= \Delta_{ij}^{(t-1)}, \text{ if else}\end{aligned} \quad \text{สมการที่ 3.58}$$

ซึ่ง $0 < \eta^- < 1 < \eta^+$

วิธีการปรับมีดังต่อไปนี้ ทุกอนุพันธ์บางส่วนของการเปลี่ยนแปลงค่าน้ำหนัก w_{ij} จะเปลี่ยนตามเครื่องหมายซึ่งแสดงว่าการปรับน้ำหนักครั้งสุดท้ายมีค่ามากเกินไป และอัลกอริธึมก็ข้ามจุดต่ำสุดเฉพาะที่ (local minimum) update-value $\Delta_{ij}^{(t)}$ จะลดลงโดยค่า η^- ถ้าอนุพันธ์มีเครื่องหมายตรงกันข้าม update-value จะมีค่าเพิ่มขึ้นเพื่อที่จะเร่งเข้าสู่ค่าต่ำสุด ในกรณีที่ $\partial E/\partial w_{ij}^{(t-1)}$ มีค่าเป็น 0 จะไม่มีการปรับตัวเกิดขึ้นในขั้นตอนการเรียนรู้ และเพื่อจะลดจำนวนของพารามิเตอร์ จึงทำการกำหนดค่า η^- ให้อยู่ในช่วง $\eta^- = 0.5, \eta^+ = 1.2$

Rprop พยายามที่จะทำการปรับกระบวนการเรียนรู้โดยใช้ฟังก์ชันความผิดพลาด ซึ่งเรียกว่า batch learning หรือ learning by epoch ซึ่งหมายถึงการปรับค่าน้ำหนักจะถูกทำหลังจากได้เกรเดียนท์ของชุดข้อมูลทั้งหมดแล้ว

อัลกอริทึมการกระจายความผิดพลาดย้อนกลับแบบรีเวนเบอร์-มาร์ควอร์

วิธีรีเวนเบอร์-มาร์ควอร์เป็นวิธีการประมาณแบบ Newton's method อัลกอริทึมนี้ใช้อนุพันธ์อันดับสองเป็นฟังก์ชันความผิดพลาด (cost function) ดังนั้นการเข้าสู่ค่าที่ต้องการจึงดีกว่าวิธีเกรเดียนต์เดสเซนท์ โดยเฉพาะดีกว่าอนุพันธ์อันดับหนึ่งซึ่งอัลกอริทึมนี้สามารถแสดงดังสมการต่อไปนี้

$$e = d - F(\phi, u) \quad \text{สมการที่ 3.59}$$

$$J = e^2/2 \quad \text{สมการที่ 3.60}$$

$$\Delta\phi = -(\nabla^2 J(\phi))^{-1} \nabla J(\phi) \quad \text{สมการที่ 3.61}$$

โดย $\nabla^2 J(\phi)$ คือ Hessian matrix

$\nabla J(\phi)$ คือ เกรเดียนต์ความผิดพลาดของ j

ค่าความผิดพลาดในสมการที่ 3.59 จะทำการลดลงให้น้อยที่สุดดังสมการที่ 3.60

$$J_s = \begin{bmatrix} \frac{\partial e_1}{\partial \phi_1} & \dots & \frac{\partial e_1}{\partial \phi_B} \\ \vdots & \ddots & \vdots \\ \frac{\partial e_L}{\partial \phi_1} & \dots & \frac{\partial e_L}{\partial \phi_B} \end{bmatrix} \quad \text{สมการที่ 3.62}$$

โดยการใช้กฎในสมการที่ 3.61 เป้าหมายในการลดลงให้น้อยที่สุดดังสมการที่ 3.60 ถ้าใช้สมการ Taylor series ในการกระจาย $e(\phi)$ รอบจุดนั้นๆ สมการอนุพันธ์อันดับที่ 1 ของ Jacobian แสดงดังสมการ 3.62 และการปรับพารามิเตอร์แสดงในสมการที่ 3.63

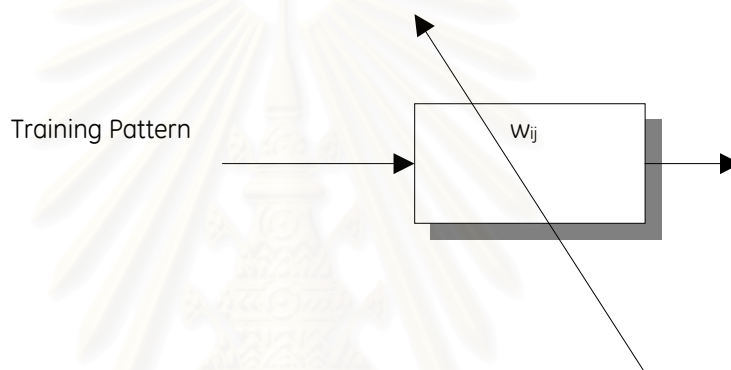
$$\Delta\phi = N_\phi = -(J_s^T J_s + uI)^{-1} J_s^T e \quad \text{สมการที่ 3.63}$$

โดย B คือ จำนวนพารามิเตอร์ที่สามารถปรับได้

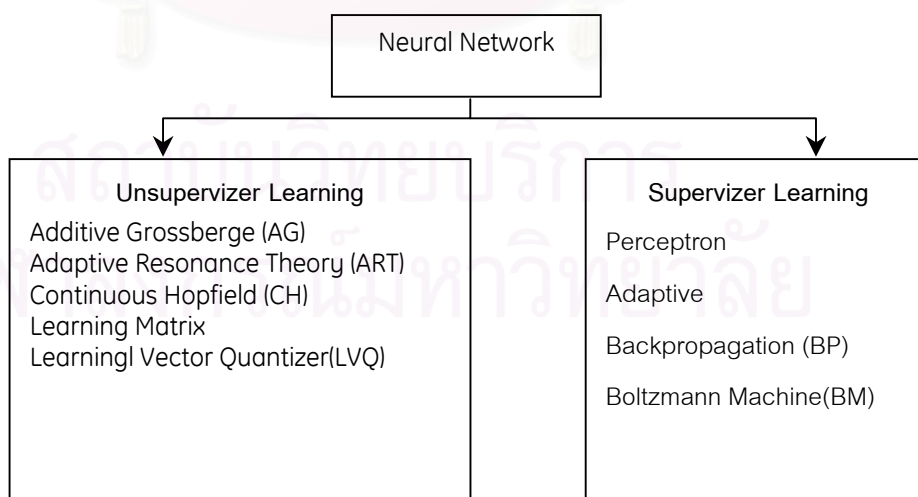
L คือ จำนวนเออร์ทพุท

3.3.2.5.2 ข่ายงานนิวรัลแบบไม่มีการชี้แนะ (unsupervised neural network)

ข่ายงานนิวรัลที่มีการเรียนรู้แบบไม่มีการชี้แนะ ต้องการเพียงค่าอินพุตในการฝึก ข่ายงานโดยไม่มีผู้สอนหรือค่าเป้าหมาย การปรับค่าพารามิเตอร์ของข่ายงานนิวรัลใช้สัญญาณเอาต์พุตอย่างเดี่ยวซึ่งแสดงในรูป 3.11 ในระหว่างการฝึกค่าน้ำหนักของข่ายงานจะถูกปรับโดยอินพุตที่คล้ายกันสร้างเอาต์พุตที่คล้ายกัน ซึ่งวิธีการปรับมีหลายวิธีในแต่ละวิธีมีวัตถุประสงค์เพื่อให้การเรียนรู้ของข่ายงานประเภทนี้ คล้ายกับสมองของมนุษย์ที่เปลี่ยนแปลงโครงสร้างของมันภายใต้อิทธิพลของประสบการณ์โดยไม่มีผู้สอน ตัวอย่างการเรียนรู้ประเภทนี้ได้แก่ AG(Additive Grossberg), Self Organizing Map (SOM), และ ART (Adaptive Resonance Theory) ดังแสดงในรูปที่ 3.12



รูปที่ 3.11 การเรียนรู้ของข่ายงานนิวรัลในการปรับค่าน้ำหนักแบบไม่มีการชี้แนะ



รูปที่ 3.12 ข่ายงานนิวรัลสามารถจำแนกเป็นแบบมีการชี้แนะและไม่มีการชี้แนะ

ตัวอย่างข่ายงานที่ไม่มีการเรียนรู้จะใช้สำหรับชุดข้อมูลที่มีค่าอินพุตอย่างเดียว ไม่มีค่าเป้าหมาย โดยจะยกตัวอย่าง 2 ประเภทได้แก่ Kohonen self-Organizing network และ Adaptive Resonance Theory (ART)

Kohonen Self-Organizing พัฒนาโดย Teuvo Kohonen ในช่วงต้นปี 1980 เป็นข่ายงานที่ไม่ใช้ค่าเป้าหมายในการฝึกข่ายงาน Fausett ได้กล่าวถึง Self-Organization process เป็นการแบ่งกลุ่มโดยนิเวศที่มีค่าเอาต์พุตมากที่สุดถือว่าเป็นเอาต์พุตของข่ายงาน สามารถยับยั้งหรือกระตุ้นนิเวศที่อยู่ข้างเคียงได้ และสามารถปรับน้ำหนักได้ โดยชุดทดสอบให้ค่าความผิดพลาดต่ำสุดคือ

$$D(g) = \sum (w_{ij} - w_i)^2 \quad \text{สมการที่ 3.64}$$

ใช้น้ำหนักเป็นค่าในการแบ่งกลุ่มแทนการสเกลใช้อินพุต ดังนั้นการปรับค่าน้ำหนัก คือ

$$w_{ij}(\text{new}) = w_{ij}(\text{old}) + \alpha [w_i - w_{ij}(\text{old})] \quad \text{สมการที่ 3.65}$$

การปรับน้ำหนักนิเวศทุก i ของเอาต์พุต j ค่า α จะลดลงถ้าการเรียนรู้เพิ่มขึ้น ข่ายงานแบบ Kohonen จะคล้ายกับแบบข่ายงาน Competitive, ข่ายงาน Max และแบบ Learning Vector Quantization

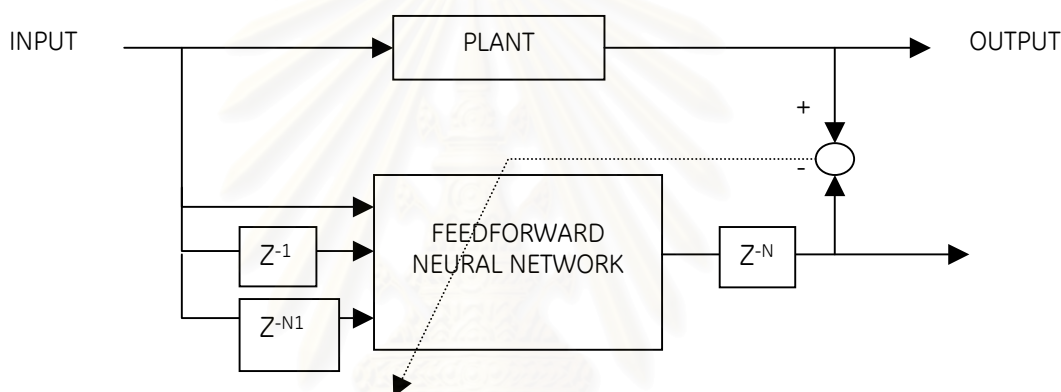
Adaptive Learning Resonant Theory (ART) พัฒนาโดย Stephen Grossberg ในกลางปี 1970 ซึ่งจะวิเคราะห์ตามความสำคัญของอินพุตและการแบ่งประเภทอินพุตเวกเตอร์ใช้ในการเรียนรู้แบบไม่มีการเรียนรู้ นิเวศมี 3 ชั้นคือ นิเวศจะมีชั้นอินพุต เอาต์พุต และชั้นเชื่อมระหว่างอินพุตและเอาต์พุต ระหว่างการเชื่อมของชั้นอินพุตกับชั้นเชื่อม (interface) หรือชั้นเชื่อมไปชั้นเอาต์พุตจะมีการเชื่อมของน้ำหนักกลับไปมา คือการเชื่อมของน้ำหนักแบบไปข้างหน้า ระหว่างชั้นเอาต์พุตกับชั้นเชื่อมจะทำการแบ่งกลุ่มค่าอินพุต ซึ่งจะถูกกำหนดเป็นข้อมูลอินพุตและการเชื่อมของน้ำหนักย้อนกลับมาจากชั้นเชื่อม ไปสู่ชั้นอินพุต เพื่อหาว่าข้อมูลอินพุตคล้ายกับเวกเตอร์ตัวอย่างของการแบ่งกลุ่มหรือไม่ ถ้าคล้ายถึงจะมีการปรับน้ำหนัก ถ้าไม่คล้ายกลุ่มนั้นจะถูกเปลี่ยนชุดอินพุตใหม่ ซึ่งจะทำการวนรอบ ซ้ำโดยการเรียนรู้ตามอัลกอริทึม

3.3.2.6 แบบจำลองกระบวนการของข่ายงานนิเวศ

แบบจำลองที่ใช้ในการหาแบบจำลองกระบวนการของข่ายงานนิเวศประกอบด้วยแบบจำลอง 2 แบบที่มีความแตกต่างกันในเรื่องของการจัดการข้อมูลอินพุตกับเอาต์พุตที่สอดคล้องกับการหน่วงเวลาก่อนที่จะป้อนให้ข่ายงานนิเวศได้เรียนรู้ แบบจำลองทั้งสองได้แก่ แบบจำลอง

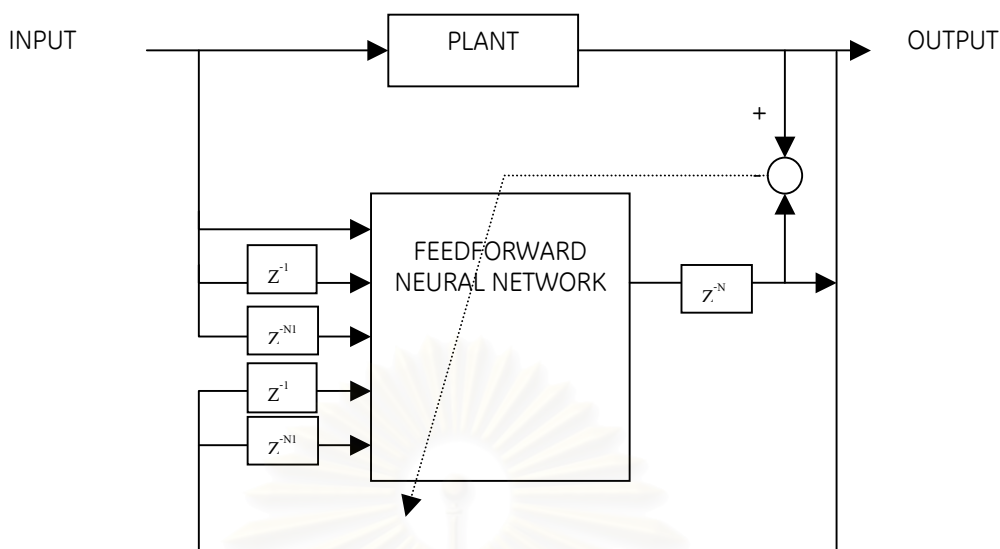
แบบไม่กลับกระแส, และแบบจำลองแบบกลับกระแส โดยกระบวนการที่ใช้อาจเป็นแบบสถิต (static) หรือ พลศาสตร์ (dynamic) ดังต่อไปนี้

(ก) แบบจำลองแบบไม่กลับกระแส (non-recurrent model) ใช้สำหรับจำลองกระบวนการแบบสถิต (static process) ซึ่งเอาที่พุดเป็นฟังก์ชันกับอินพุตที่เวลาปัจจุบัน และในอดีต และอินพุตเวกเตอร์ของข่ายงานนี้เป็นค่าอินพุตปัจจุบันและอินพุตในอดีตซึ่งแสดงในรูปที่ 3.13 การหาแบบจำลองของระบบนี้ เป็นการนำข้อมูลที่ใช้ป้อนเข้าสู่กระบวนการมาห้วงเวลาตามช่วงระยะเวลาที่ต้องการ จำนวนของการห้วงเวลาเท่ากับจำนวนนิรวัลในชั้นอินพุต โดยที่ไม่มีค่าเอาที่พุดจากกระบวนการมาใช้เพื่อเป็นข้อมูลในการป้อนให้กับนิรวัลในชั้นอินพุต



รูปที่ 3.13 แบบจำลองแบบไม่กลับกระแส

(ข) แบบจำลองแบบกลับกระแส (recurrent model) ใช้สำหรับกระบวนการทางพลศาสตร์ (dynamic process) ซึ่งเอาที่พุดปัจจุบันของข่ายงานขึ้นกับค่าอินพุตในปัจจุบัน, อินพุตในอดีตและเอาที่พุดในอดีตซึ่งแสดงในรูปที่ 3.14 จำนวนของการห้วงเวลาที่ต้องการจะเป็นอินพุตและเอาที่พุดทั้งเส้นทางป้อนไปข้างหน้าและป้อนกลับ ซึ่งขึ้นอยู่กับคุณสมบัติของกระบวนการ การหาแบบจำลองของระบบนี้ทำโดยการนำข้อมูลที่ป้อนเข้าสู่ระบบกับเอาที่พุดของกระบวนการมาห้วงเวลาก่อนป้อนเข้าสู่ชั้นอินพุตของข่ายงาน ซึ่งวิธีการนี้เป็นที่นิยมมากที่สุด เนื่องจากค่าเป้าหมายในอดีตของระบบจะเป็นตัวช่วยกำหนดแนวทางในการเรียนรู้ โดยทำให้ทิศทางในการหาคำตอบได้รวดเร็ว ดังนั้นจึงใช้วิธีการนี้สร้างแบบจำลองในงานวิจัยนี้



รูปที่ 3.14 แบบจำลองแบบกลับกระแส

3.3.2.7 วงจรการทำงานของอัลกอริทึมแบบการกระจายความผิดพลาดย้อนกลับ

วงจรการทำงานของอัลกอริทึมแบบการกระจายความผิดพลาดย้อนกลับมี 3 ขั้นตอนหลักๆคือ

(ก) ขั้นตอนการกำหนดโครงสร้างของข่ายงานนิวิรัล (definition phase) ก็จะมีการกำหนดโครงสร้างของข่ายงานนิวิรัล ได้แก่ จำนวนชั้นในข่ายงาน จำนวนนิวิรัลในแต่ละชั้น การเชื่อมต่อระหว่างนิวิรัล การกำหนดค่าของน้ำหนักและไบอัส กำหนดอัตราการเรียนรู้ กำหนดค่าโมเมนตัม

(ข) ขั้นตอนการฝึกข่ายงาน (training phase) จะนำชุดข้อมูลที่ประกอบไปด้วย อินพุตและค่าเป้าหมายมาใช้ในการฝึกข่ายงาน โดยจะมีการฝึกข่ายงานให้เรียนรู้โดยการปรับค่าน้ำหนัก จนกระทั่งค่าความผิดพลาด (ผลต่างของค่าเอาต์พุตที่ได้จากข่ายงานกับค่าเป้าหมาย) จะอยู่ในระดับที่ยอมรับได้จึงถือว่าเสร็จสิ้นสำหรับการฝึกข่ายงาน

(ค) ขั้นตอนการทดสอบ (testing phase) ข่ายงานเมื่อได้รับการฝึกข่ายงานอย่างเหมาะสมในขั้นตอนที่ 2 เรียบร้อยแล้ว จะนำแบบจำลองนั้นมาทดสอบโดยใช้อินพุตอีกชุดหนึ่งในการทดสอบเพื่อสังเกตผลของค่าเอาต์พุตของแบบจำลองข่ายงานนิวิรัลมาเปรียบเทียบกับค่าเป้าหมายว่าอยู่ในระดับที่ยอมรับได้หรือไม่โดยไม่ต้องมีการปรับค่าน้ำหนักย้อนกลับไปใน ข่ายงาน

การเรียนรู้มากเกินไปจะเกิดขึ้นเมื่อแบบจำลองเริ่มที่จะเรียนรู้ แต่ว่าถ้าชุดข้อมูลมีการเรียนรู้มากเกินไปประสิทธิภาพการเรียนรู้ในชุดข้อมูลเหล่านั้นเพิ่มขึ้น แต่ประสิทธิภาพในชุดทดสอบจะลดลงไป ซึ่งต้องขึ้นอยู่กับความเหมาะสมของการฝึกข่างานและความพึงพอใจของค่าความผิดพลาดระหว่างค่าเป้าหมายกับค่าเอาต์พุตที่ได้จากการทำนายจากข่างาน ส่วนใหญ่จะพิจารณา ค่าผิดพลาดในเทอมของ ผลรวมของค่าความผิดพลาดยกกำลังสอง (sum squared error) ชุดทดสอบ

3.3.2.7.1 วิธีการฝึกข่างาน

การฝึกข่างานคือ กระบวนการหาค่าออฟติไมซ์ของน้ำหนักที่เชื่อมต่อระหว่างนิวรัลแต่ละชั้นและค่าไบแอส การกำหนดค่าน้ำหนักเริ่มต้นทั้งหมดของข่างานด้วยตัวเลขสุ่มที่มีค่าน้อยๆ (ทั้งค่าบวกและลบ) กระบวนการฝึกจะทำการวนซ้ำไปหลายรอบจนกระทั่งค่าความผิดพลาดระหว่างค่าเป้าหมายและเอาต์พุตที่ทำนายได้จากข่างานจะเป็นที่พอใจ ซึ่งการคำนวณแต่ละรอบ (ครบทุกชุดข้อมูล) จะเรียกว่า epoch ค่าเอาต์พุตจากข่างานที่สัมพันธ์กับชุดข้อมูลอินพุตทั้งหมดในชุดข้อมูลการฝึกจะถูกทำนายออกมา และค่าน้ำหนักจะถูกปรับในทิศทางลดค่าความผิดพลาดลง ค่าน้ำหนักจะถูกปรับสำหรับทุกชุดข้อมูลและทุกรอบเพื่อให้เข้าสู่ค่าออฟติไมซ์

ค่า nt = จำนวนของชุดข้อมูล x, y โดย x คือเมตริกซ์ของอินพุตและ y คือเมตริกซ์ของค่าเป้าหมาย ในหนึ่งรอบหมายถึงการป้อนข้อมูลจำนวน nt ชุด

ค่าความผิดพลาดของชั้นเอาต์พุตที่ได้ในแต่ละรอบจะกระจายย้อนกลับลงมาที่ชั้นซ่อนที่ถัดลงมาจากชั้นเอาต์พุตโดยจะกระจายย้อนกลับลงมาถึงชั้นอินพุต เพื่อปรับค่าน้ำหนักให้ค่าความผิดพลาดของค่าเป้าหมายและค่าเอาต์พุตจากข่างานมีค่าลดลง

3.3.2.7.2 การทดสอบข้อมูล (Model Validation)

ในการทดสอบข้อมูลจะมีการนำชุดทดสอบเข้ามาป้อนเป็นอินพุต เพื่อทดสอบเอาต์พุตกับค่าเป้าหมายว่ามีค่าความผิดพลาดอยู่ในช่วงที่ยอมรับได้หรือไม่ โดยไม่มีการปรับน้ำหนัก

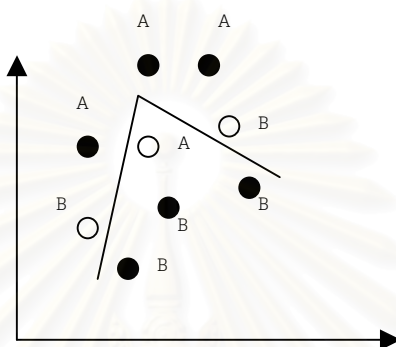
แบบจำลองที่เรียนรู้ชุดข้อมูลมากเกินไป ประสิทธิภาพการเรียนรู้ในชุดข้อมูลจะเพิ่มขึ้นแต่ประสิทธิภาพในชุดข้อมูลทดสอบจะลดลง ซึ่งต้องขึ้นอยู่กับความเหมาะสมการฝึกข่างาน และความพึงพอใจในผลการทดสอบ

3.3.2.8 ปัญหาที่พบสำหรับการฝึกข่างาน

ก. การประมาณระหว่างเส้นโค้งมากเกินไป (Overfitting)

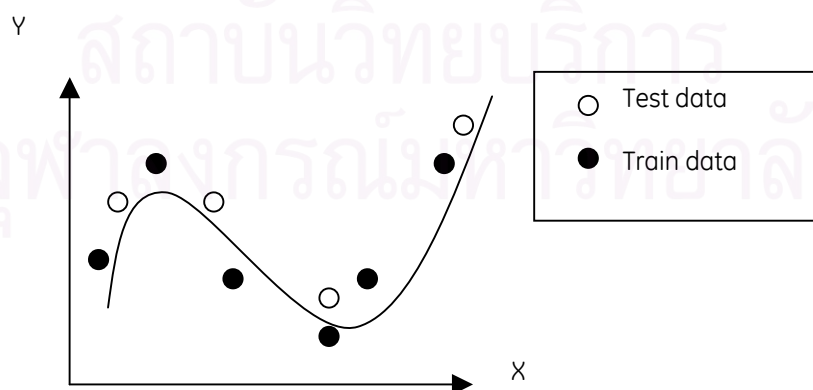
ช่างานมีการเรียนรู้มากเกินไป ทำให้ประสิทธิภาพในการเรียนรู้ชุดข้อมูลในการทดสอบหรือข้อมูลที่ป้อนเข้ามาใหม่น้อยลง ถึงแม้ว่าประสิทธิภาพในการเรียนรู้ชุดข้อมูลในการฝึกเพิ่มขึ้นก็ตาม

ในบางข้อมูลของชุดทดสอบจะถูกแบ่งผิคขอบเขตปัญหาคือ ช่างานมีอิสระมากเกินไปและมีการยึดติดตามข้อมูลของการฝึกช่างานมากเกินไป รูปที่ 3.15 แสดงการประมาณค่าระหว่างเส้นอย่างเหมาะสม




รูปที่ 3.15 ช่างานมีการประมาณค่าระหว่างเส้นอย่างเหมาะสม

ในกราฟรูปที่ 3.16 แสดงเอาท์พุทที่ตอบสนองกับอินพุทแทนที่ด้วยจุดทึบ และจุดกลวงจะเป็นข้อมูลที่ใช้ในการทดสอบช่างาน และเส้นโค้งก็มีการพาดผ่านจุดของข้อมูลฝึกช่างาน ความผิดพลาดจะเข้าใกล้ศูนย์ แต่ถ้ามีการเปลี่ยนแปลงโครงสร้างช่างานเช่นจำนวนชั้นซ่อนเอาท์พุทอาจจะใกล้เคียงกับชุดเป้าหมายมากขึ้นก็ได้ ถ้ามีจำนวนนิวรัลในชั้นซ่อนมากช่างานมีอิสระมาก เอาท์พุทสามารถเปลี่ยนแปลงอย่างรวดเร็วเมื่อเกิดการเปลี่ยนแปลงอินพุทจะได้กราฟดังรูปที่ 3.18



รูปที่ 3.16 ช่างานมีการประมาณค่าระหว่างเส้นอย่างเหมาะสม

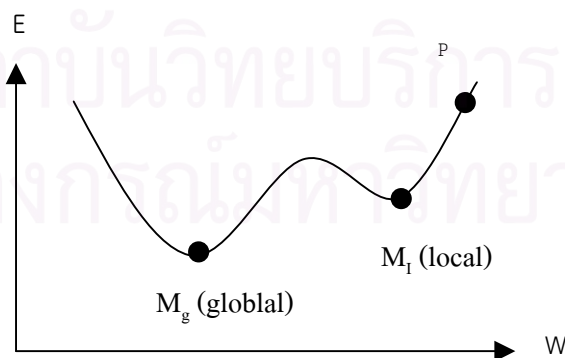


รูปที่ 3.17 ข่ายงานมีการแบ่งประเภทผิดเนื่องจากการประมาณค่าระหว่างเส้นมากเกินไป (overfitting)

จากกราฟจะพบว่าเส้นโค้งพาดผ่านแต่ละชุดข้อมูลฝึกข่ายงาน ซึ่งมีค่าความผิดพลาดเข้าใกล้ศูนย์ แต่สำหรับชุดข้อมูลทดสอบจะไม่อยู่ตำแหน่งใกล้เคียงกับกราฟฝึกข่ายงานข่ายงานนี้มีการเรียนรู้ที่ไม่ดี

ข . ค่าความผิดพลาดเฉพาะที่ (local minima)

พิจารณาดังรูป 3.18 ซึ่งเริ่มต้นจากการกำหนดค่าน้ำหนักที่จุด P ถ้าทำการปรับน้ำหนักตามเกรเดียนต์เดสเซนท์จะพบว่าค่าต่ำสุดที่เข้าหาคือ M_l ซึ่งไม่ใช่ M_g ซึ่งเรียกว่าความผิดพลาดเฉพาะที่ (local minimum) และสัมพันธ์กับคำตอบของข่ายงานเพียงบางส่วนสำหรับชุดข้อมูลในการฝึกข่ายงาน M_g คือ ค่าความผิดพลาดจริง (global minimum) ซึ่งจะต้องการหาจนกว่าจะหนีออกจากค่า M_l ดังนั้นไม่เคยมาถึงจุด M_g นี้



รูปที่ 3.18 ความผิดพลาดเฉพาะที่ (local minima)

3.4 บทสรุป

อัลกอริทึมการกระจายความผิดพลาดย้อนกลับ สามารถใช้กับข่ายงานหลายชั้นแบบป้อนไปข้างหน้าทั้งข่ายงานที่เป็นแบบเชิงเส้นและไม่เป็นเชิงเส้น โดยสามารถใช้ร่วมกับฟังก์ชันกระตุ้นได้หลายชนิด รวมทั้งเหมาะกับการแก้ปัญหาที่เป็นการประมาณฟังก์ชันหรือการแบ่งประเภทของข้อมูล ลักษณะของจำนวนอินพุตและจำนวนเอาต์พุตเป็นข้อมูลที่ต้องการสำหรับข่ายงาน ส่วนจำนวนชั้นซ่อนและจำนวนนิวรัลในแต่ละชั้นซ่อนจะขึ้นอยู่กับการออกแบบที่เหมาะสม

ในประเภทของอัลกอริทึมการกระจายความผิดพลาดย้อนกลับ อัลกอริทึมแบบมาตรฐานจะใช้เวลาฝึกข่ายงานช้ามาก เพราะต้องใช้การอัปเดตการเรียนรู้บ่อยสำหรับการเรียนรู้ให้เสถียรและความผิดพลาดของข่ายงานจะตกอยู่ที่จุดความผิดพลาดเฉพาะที่ (local minima) มากกว่าจุดผิดพลาดต่ำสุดจริง (global minima) ซึ่งการตกอยู่ที่จุดผิดพลาดเฉพาะที่จะดีหรือไม่ขึ้นอยู่กับว่าจุดผิดพลาดเฉพาะที่อยู่ใกล้กับจุดผิดพลาดจริงมากเท่าใดและความต้องการค่าความผิดพลาดมีค่าเท่าใด ส่วนปัญหาที่ควรป้องกันคือปัญหาการประมาณระหว่างเส้นโค้งมากเกินไป นั่นคือถ้ามีนิวรัลในชั้นซ่อนมาก ข่ายงานจะมีความเป็นอิสระมาก (ตัวแปรที่ต้องการออกฟิตไม่ซ้กันมีมากขึ้น) หรือเกิดการประมาณระหว่างเส้นโค้งมากเกินไป (overfitting) แต่นิวรัลเพิ่มขึ้นก็จะให้ค่าความผิดพลาดเฉพาะที่มีค่าต่ำลง อย่างไรก็ตามถ้ามีการเพิ่มเทอมโมเมนตัมเข้าไปในอัลกอริทึมจะช่วยลดความน่าจะเป็นที่ความผิดพลาดของข่ายงานจะตกบนค่าความผิดพลาดเฉพาะที่มีค่ามาก ๆ และสามารถช่วยลดเวลาในการฝึกข่ายงานเนื่องจากมีการเรียนรู้แบบ adaptive learning เข้ามาช่วย เนื่องจากจะทำให้ค่าอัปเดตการเรียนรู้มีค่ามากขึ้น อัปเดตการเรียนรู้สามารถทำได้อย่างรวดเร็วและยังทำให้ข่ายงานยังสามารถเสถียรอยู่ แต่วิธีที่สามารถช่วยเร่งการเรียนรู้ที่ดีที่สุดคือ Levenberg-Marquardt optimization เป็นวิธีที่ช่วยเร่งการเรียนรู้จากวิธีอัลกอริทึมมาตรฐานสามารถลดเวลาในการฝึกข่ายงานได้ถึง 78 เท่าแต่มีข้อเสียเนื่องจากต้องใช้หน่วยความจำมาก ดังนั้นในงานวิจัยนี้จึงเลือกใช้อัลกอริทึมแบบบริเวนเบอเกอร์-มาร์ควอร์กับโครงสร้างข่ายงานป้อนไปข้างหน้าหลายชั้น โดยใช้แบบจำลองแบบกลับกระแสนี้เป็น โครงสร้างที่คัดเลือกกว่าเหมาะสมกับงานวิจัยนี้

บทที่ 4

ขั้นตอนการดำเนินงานวิจัย

ในบทนี้กล่าวถึงขั้นตอนการดำเนินงานวิจัย ประกอบด้วย อุปกรณ์และสารเคมี, ขั้นตอนการทดลองการผลิตแยมพู่, ขั้นตอนการทดลองฆ่างานนิวรัลสำหรับการสร้างแบบจำลอง โดยมีรายละเอียดดังนี้

4.1 อุปกรณ์ และสารเคมี

1. เครื่องกวนผสมแยมพู่ขนาด 1 ลิตร โดยจำลองมาจากเครื่องกวนผสมแยมพู่ที่ใช้ในโรงงานอุตสาหกรรมขนาด 200 ลิตร



ก. ถังกวนผสมแยมพู่ขนาด 200 ลิตร



ข. ถังผสมกวนแยมพู่ขนาด 1 ลิตร

รูปที่ 4.1 แสดงถังผสมกวนแยมพู่

2. ส่วนผสมแยมพู่จากโรงงานอุตสาหกรรม
3. ขวดพลาสติกขนาด 500 มิลลิลิตร สำหรับเก็บตัวอย่างแยมพู่
4. เครื่องชั่งน้ำหนัก
5. เครื่องวัดความหนืด
6. เครื่องวัดความเป็นกรด-ด่าง
7. เครื่องวัดเปอร์เซ็นต์ของแข็ง

4.2 ขั้นตอนการทดลองการผลิตแชมพู

วัตถุประสงค์เพื่อศึกษาผลของอุณหภูมิที่มีต่อเปอร์เซ็นต์ของแข็งของแชมพูที่ผลิตได้

1. เตรียมส่วนผสมแชมพูและน้ำในอัตราส่วน 2 : 1
2. เทส่วนผสมลงในถังผสม



รูปที่ 4.2 แสดงการเทส่วนผสมแชมพูลงในถังผสม



รูปที่ 4.3 แสดงการเทน้ำลงในถังผสม

3. กวนผสมแชมพูที่อุณหภูมิ 25 °C, 30 °C, 35 °C, 40 °C, 45 °C, และ 50 °C เป็นเวลา 10 นาที



รูปที่ 4.4 แสดงการกวนผสมแชมพู

4. ตั้งทิ้งไว้จนฟองอากาศหมด



รูปที่ 4.5 แสดงแชมพูที่ตั้งทิ้งไว้จนฟองอากาศหมดไป

5. เก็บตัวอย่างใส่ขวดพลาสติกปริมาณ 500 มิลลิลิตร
6. นำตัวอย่างไปวัดค่าความหนืด, ความเป็นกรด-ด่าง, และเปอร์เซ็นต์ของแข็ง
7. ทำการทดลองซ้ำ โดยเพิ่มระยะเวลาการกวนผสมในขั้นตอนที่ 3 เป็น 15 นาที, 20 นาที, 25 นาที, 30 นาที, และ 35 นาที
8. ทำการผสมซ้ำ โดยเปลี่ยนอัตราส่วนผสมแชมพูและน้ำในขั้นตอนที่ 1 เป็น 1:1

ผลการทดลองแสดงดังตารางที่ 4.1

ตารางที่ 4.1 แสดงผลการทดลองผลิตเซมพู

อัตราส่วนผสม	เวลาผสม (นาที)	อุณหภูมิ (°C)	ความหนืด (cp)	ความเป็น กรด-ด่าง	เปอร์เซ็นต์ของแข็ง (%)
1:1	10	25	80	5.83	10
		30	110	5.33	13
		35	380	5.7	12
		40	170	5.65	12
		45	390	5.74	10
		50	150	5.67	13
	15	25	700	5.75	11
		30	820	5.48	13
		35	420	5.74	12
		40	170	5.55	11
		45	260	5.67	13
		50	130	5.54	11
	20	25	170	5.68	11
		30	250	5.59	11
		35	1070	5.77	13
		40	190	5.62	12
		45	200	5.77	12
		50	230	5.74	13
	25	25	940	5.96	13
		30	330	5.65	17
		35	450	5.7	13
		40	240	5.92	10
		45	400	5.83	13
		50	460	5.77	12
	30	25	350	5.76	12
		30	170	5.84	13
		35	230	5.85	13
		40	470	5.8	13
		45	290	5.83	13
		50	200	5.76	11
35	25	1070	5.75	13	
	30	260	5.63	13	
	35	460	5.67	12	
	40	280	5.77	12	
	45	340	5.52	13	
	50	1010	5.3	14	

อัตราส่วนผสม	เวลาผสม (นาที)	อุณหภูมิ (°C)	ความหนืด (cp)	ความเป็น กรด-ด่าง	เปอร์เซ็นต์ของแข็ง (%)
2:1	10	25	12300	5.76	16
		30	6500	5.54	16
		35	10400	5.48	16
		40	12550	5.83	17
		45	9000	5.8	17
		50	6650	5.94	17
	15	25	10650	5.36	16
		30	8200	5.6	16
		35	8350	5.78	17
		40	8350	5.78	17
		45	9250	5.71	17
		50	10500	5.76	17
	20	25	8900	5.38	15
		30	10700	5.38	17
		35	8150	5.96	16
		40	9200	5.79	17
		45	12500	5.49	17
		50	9000	5.78	17
	25	25	10300	5.94	17
		30	10900	5.44	17
		35	13500	5.92	17
		40	10200	5.92	17
		45	7650	5.62	17
		50	11150	5.74	18
	30	25	5250	5.53	16
		30	5000	5.88	17
		35	8200	5.92	16
		40	8850	5.68	17
		45	10120	5.4	16
		50	1340	5.54	17
35	25	6250	5.53	17	
	30	9000	5.55	16	
	35	6500	5.71	17	
	40	4100	5.96	17	
	45	14300	5.68	17	
	50	17250	5.62	18	

4.3 ขั้นตอนการทดลอง ข่ายงานนิวิรัล สำหรับสร้างแบบจำลอง

4.3.1 การแบ่งข้อมูล

หลังจากได้ข้อมูลจากการทดลองแล้วนำข้อมูลเหล่านี้มาแบ่งออกเป็น 3 ชุด โดยข้อมูลชุดที่ 1 (70% ของข้อมูลทั้งหมด) ใช้สำหรับฝึกข่ายงานนิวิรัล, ข้อมูลชุดที่ 2 (20% ของข้อมูลทั้งหมด) ใช้สำหรับทดสอบความสามารถของข่ายงานนิวิรัล และชุดที่ 3 (10% ของข้อมูลทั้งหมด) ใช้สำหรับทำสอบข่ายงานในการใช้งานจริง

4.3.2 การออกแบบโครงสร้างข่ายงานนิวิรัล

การออกแบบแบบจำลองข่ายงานนิวิรัลด้วยการฝึกข่ายงาน ด้วยอัลกอริธึมการกระจายความผิดพลาดย้อนกลับ (Error Backpropagation Algorithm) เป็นที่นิยมอย่างมาก ทำการจำลองโดยใช้ Neural Network Toolbox โปรแกรม MATLAB

กรณีที่ 1 การออกแบบข่ายงานป้อนไปข้างหน้าชั้นซ่อน 1 ชั้น (Feedforward Single Hidden Layer)

จำลองข่ายงานที่มีโครงสร้างชั้นซ่อน 1 ชั้น โดยเปลี่ยนแปลงจำนวนนิวิรัล (Neural Node) ในชั้นซ่อนตั้งแต่ 3, 5, 7, 8, 9, 11, 13, 15, 17 และ 19 โหนด

กรณีที่ 2 การออกแบบข่ายงานป้อนไปข้างหน้าชั้นซ่อน 2 ชั้น (Feedforward Two Hidden Layers)

จำลองข่ายงานที่มีโครงสร้างชั้นซ่อน 2 ชั้น โดยเปลี่ยนแปลงจำนวนนิวิรัล (Neural Node) ในชั้นซ่อนที่ 1 ตั้งแต่ 3, 5, 7, 9 และ 13 โหนด ส่วนชั้นซ่อนที่ 2 ตั้งแต่ 3, 5, 7, 8, 9, 11, 13, 15, 17 และ 19 โหนด

องค์ประกอบทั้งหมดสามารถสรุปได้ดังนี้

Training Algorithm	:	Back Propagation Algorithm
Basis Function	:	Linear Basis Function
Transfer Function	:	Log-Sigmoid Function and/or Tan-Sigmoid Function
Input Signals Data	:	Fraction, Time, and Temperature
Output Signals Data	:	% Solid and Viscosity
To Predict	:	% Solid and Viscosity


โดยในแต่ละนิวัตใช้ฟังก์ชันกระตุ้นซิกมอยด์ และได้รับการเรียนรู้โดยใช้วิธีรีเวนเบอกร์-มาร์ควอร์สำหรับการลดค่าความคลาดเคลื่อนระหว่างค่าจริงจากการผลิต และค่าที่ได้จากข่ายงาน โดยจำนวนรอบการฝึกข่ายงาน (Epoch) ขึ้นกับฟังก์ชันค่าความผิดพลาดแบบกำลังสองเฉลี่ย (Mean Square Error) เมื่อค่า MSE น้อยสุดที่ 0.001 การเรียนรู้จะหยุด และนำข่ายงานนี้ไปทดสอบเพื่อใช้เป็นตัวแทนของระบบต่อไป

ตารางที่ 4.2 แสดงจำนวนข่ายงานทั้งหมด

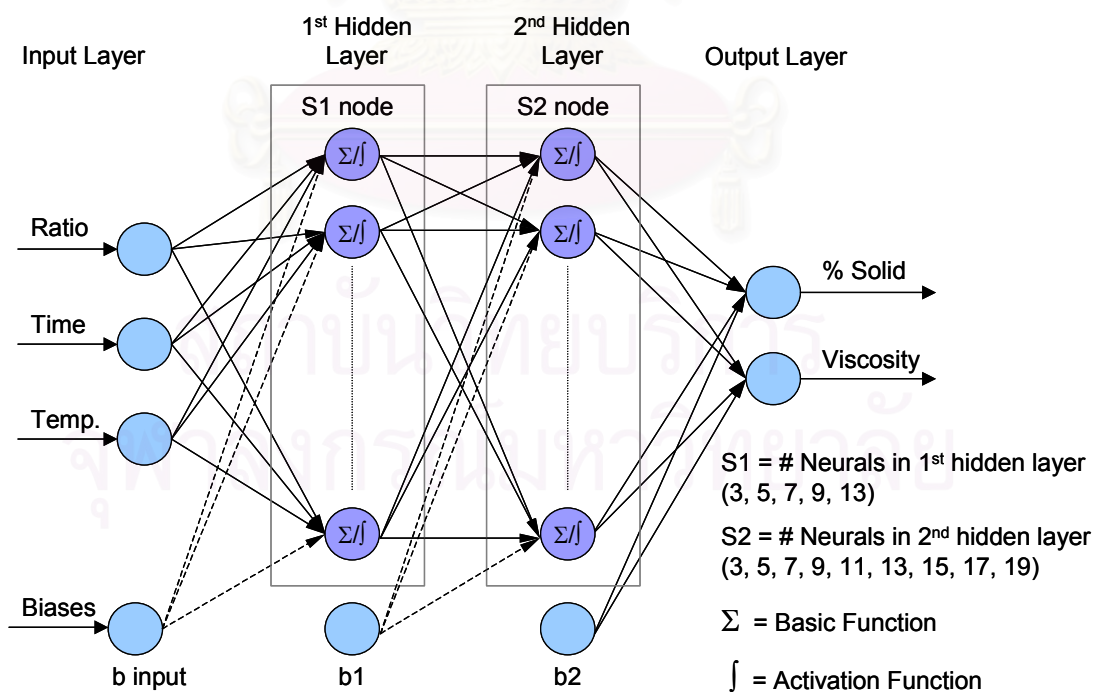
ลักษณะข่ายงาน	ฟังก์ชันกระตุ้น	จำนวนข่ายงาน	ชั้นซ่อนที่ 1	ชั้นซ่อนที่ 2
Single Layer	Log-Sigmoid Function	9	3, 5, 7, 9, 11, 13, 15, 17, 19	-
	Tan-Sigmoid Function	9	3, 5, 7, 9, 11, 13, 15, 17, 19	-
Two Layer	Log-Sigmoid Function/ Log-Sigmoid Function	36	3, 5, 9, 13	3, 5, 7, 9, 11, 13, 15, 17, 19
	Log-Sigmoid Function/ Tan-Sigmoid Function	36	3, 5, 9, 13	3, 5, 7, 9, 11, 13, 15, 17, 19
	Tan-Sigmoid Function/ Log-Sigmoid Function	36	3, 5, 7, 13	3, 5, 7, 9, 11, 13, 15, 17, 19
	Tan-Sigmoid Function/ Tan-Sigmoid Function	36	3, 5, 7, 13	3, 5, 7, 9, 11, 13, 15, 17, 19

ขั้นตอนของโปรแกรมสำหรับการฝึกข่ายงาน และการทดสอบข่ายงาน

1. การเตรียมชุดข้อมูลอินพุต และ เอาท์พุต มาใช้สำหรับ ฝึกข่ายงาน และทดสอบข่ายงาน
2. ออกแบบโครงสร้างข่ายงาน ตั้งแต่จำนวนชั้นซ่อน จำนวนนิวัตในแต่ละชั้นซ่อน
3. กำหนดค่าเริ่มต้นของค่าถ่วงน้ำหนัก ส่วนใหญ่ใช้ค่าถ่วงน้ำหนักแบบสุ่ม
4. ทำการฝึกข่ายงานใช้ โปรแกรม MATLAB โดยใช้อัลกอริทึมแบบรีเวนเบอกร์ – มาร์ควอร์ และทำการออปติไมซ์ฟังก์ชันค่าความผิดพลาดแบบกำลังสองเฉลี่ย (MSE) น้อยสุด
5. นำข่ายงานที่ได้มาทดสอบ ว่าสามารถทำให้ค่าความผิดพลาดแบบกำลังสองเฉลี่ย (MSE) ตามที่กำหนดได้หรือไม่




รูปที่ 4.6 แสดงโครงสร้างข่ายงานนิวรัลที่มี 1 ชั้นซ่อน



รูปที่ 4.7 แสดงโครงสร้างข่ายงานนิวรัลที่มี 2 ชั้นซ่อน

6. ถ้าไม่ได้โปรแกรมจะทำการกำหนดปรับค่าตัวงน้ำหนักใหม่ แล้วเริ่มฝึกข่ายงานอีกรอบ ทำจนกว่า การทดสอบข่ายงานได้ค่าความผิดพลาดแบบกำลังสองเฉลี่ย ตามที่กำหนด
7. สุดท้ายทำการเปลี่ยนแปลงโครงสร้างข่ายงานเพื่อที่ว่าข่ายงานใดให้ ค่าความผิดพลาดแบบกำลังสองเฉลี่ยน้อยสุดในชุดข้อมูลทดสอบ จึงนำข่ายงานนั้นไปใช้ทำนาย หรือเป็นตัวแทนของระบบ (Identification of Models)

ดังนั้นในการจำลองจึงมีการออกแบบข่ายงานจำนวนมากโดยใช้การลองผิดลองถูก (Trial and Error) เพื่อทำการค้นหาข่ายงานที่สามารถใช้เป็นแบบจำลองที่เป็นตัวแทนของระบบที่ดีที่สุด



รูปที่ 4.8 แสดงขั้นตอนของโปรแกรมในการหาแบบจำลอง

4.3.3 การคัดเลือกข่ายงาน

สำหรับการพิจารณาคัดเลือกข่ายงานที่เหมาะสมสำหรับใช้เป็นแบบจำลอง ในงานวิจัยนี้ได้นำดัชนีมาเปรียบเทียบเพื่อเป็นตัวตัดสินใจว่าจะเลือกใช้ข่ายงานใด คือ ค่า Mean Square Error (MSE) และ ค่า Root Mean Square Error (RMS) ซึ่งพิจารณาจากความแตกต่างระหว่างผลจากการทำนาย และผลจากการทดลองผลิต (ข้อมูลชุดที่ 2) โดยเลือกข่ายงานที่สามารถให้ ค่า MSE และ RMS นี้ต่ำสุด ดังนี้

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - p_i)^2 \quad \text{สมการที่ 4.1}$$

$$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - p_i)^2} \quad \text{สมการที่ 4.2}$$

การเปรียบเทียบผลการทำนาย

สำหรับการพิจารณาผลการทำนายของแบบจำลองที่ได้รับการคัดเลือก ในงานวิจัยนี้ได้นำค่าฟังก์ชันประสิทธิภาพ (Performance Function) ที่ใช้สำหรับทดสอบซึ่งอ้างอิงจากบทความของ Lei Zhi Chen และคณะ (1998) ซึ่งสามารถบอกเปอร์เซ็นต์ค่าความผิดพลาดระหว่างเอาท์พุทของข่ายงาน กับ ค่าจากข้อมูลจริงได้แก่

- Root Mean Square Percent Error Index (RMSP Error Index)

$$\text{RMSP Error index} = \sqrt{\frac{\sum_{i=1}^n (y_i - p_i)^2}{\sum_{i=1}^n p_i^2}} \times 100 \quad \text{สมการที่ 4.3}$$

- Maximum Percent Error Index (MP Error Index)

$$\text{MP Error index} = \frac{\max |y_i - p|}{\max |p_i|} \times 100 \quad \text{สมการที่ 4.4}$$

4.4 สรุปขั้นตอนการดำเนินงานวิจัย

4.4.1 ขั้นตอนการทดลองผลิตแชมป์

1. เตรียมส่วนผสม
2. ทดลองผลิตแชมป์ที่อัตราส่วนผสม, เวลา, และอุณหภูมิต่างๆ
3. นำแชมป์ที่ได้ไปวัดค่าความหนืด, ความเป็นกรด-ด่าง, และเปอร์เซ็นต์ของแข็ง

4.4.2 ขั้นตอนการศึกษาแบบจำลองข่ายงานนิวรัล

1. แบ่งข้อมูลที่ได้จากการทดลองผลิตแอมพู 72 ข้อมูลเป็น 3 ชุด คือ ข้อมูลสำหรับฝึกข่ายงาน (70% ของข้อมูลทั้งหมด) ข้อมูลสำหรับทดสอบความสามารถของข่ายงาน (20% ของข้อมูลทั้งหมด) และข้อมูลสำหรับทดสอบข่ายงานในการใช้งานจริง (10% ของข้อมูลทั้งหมด)
2. ออกแบบโครงสร้างข่ายงานนิวรัล
3. ทำการฝึกและทดสอบข่ายงาน พร้อมทั้งคัดเลือกข่ายงานเพื่อใช้เป็นแบบจำลอง
4. นำแบบจำลองที่ได้ไปทำนายความเปอร์เซ็นต์ของแข็งและความหนืดของแอมพู

4.4.3 ขั้นตอนการเปรียบเทียบผลการทำนาย

1. เปรียบเทียบผลการทำนายโดยใช้ RMSP (Root Mean Square Percent Error) และ MP (Maximum Percent Error)
2. นำผลการทำนายที่ได้เปรียบเทียบกับระหว่างผลจากการทดลอง (Experiment) กับผลจากแบบจำลองข่ายงานนิวรัล (Neural Network Model)

บทที่ 5

ผลการจำลอง และวิเคราะห์ผลงานวิจัย

ในบทนี้กล่าวถึงการผลการใช้ข่ายงานนิเวศสำหรับการทำนายเปอร์เซ็นต์ของแข็งของ แชมพู โดยการนำชุดข้อมูลอินพุต และเอาต์พุตจากผลการทดลอง แสดงผลตามขั้นตอนการดำเนินงานวิจัย หลังจากได้รวบรวมข้อมูลแล้วทำการแบ่งชุดข้อมูลออกเป็น 3 ชุด คือ 1. ชุดที่ใช้สำหรับฝึกข่ายงาน (Training Pattern Data) เพื่อให้เกิดการเรียนรู้ด้วยอัลกอริทึมการกระจายความผิดพลาดย้อนกลับ (Error Backpropagation Algorithm) 2. ชุดที่ใช้สำหรับทดสอบความสามารถของข่ายงาน (Validation Pattern Data) 3. ชุดที่ใช้สำหรับทดสอบข่ายงาน (Testing Pattern Data) เพื่อทดสอบข่ายงานที่เหมาะสมที่สุด และนำแบบจำลองที่ได้ไปทำนายเปอร์เซ็นต์ของแข็งของ แชมพู

5.1 ผลการฝึกและทดสอบข่ายงาน


5.1.1 ผลการฝึกและทดสอบข่ายงานนิเวศแบบชั้นซ่อน 1 ชั้น

จากการฝึกและทดสอบข่ายงานทั้งหมด 18 ข่ายงาน พบว่าข่ายงานนิเวศแบบ 1 ชั้นซ่อน ทำนายเปอร์เซ็นต์ของแข็งได้ดี แต่ยังทำนายความหนืดไม่ได้ดี (ผลการทำนายทั้งหมดแสดงดังตารางที่ ก.1 ในภาคผนวก ก.)

5.1.2 ผลการฝึกและทดสอบข่ายงานนิเวศแบบชั้นซ่อน 2 ชั้น

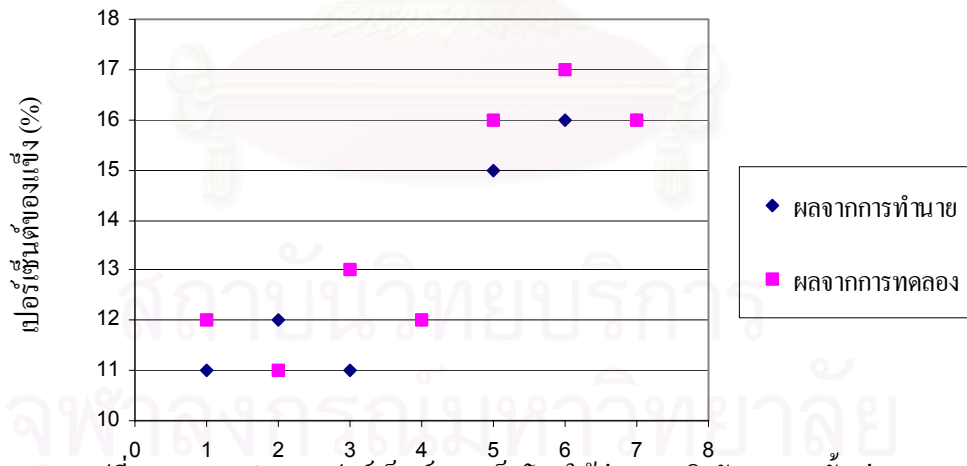
จากการฝึกและทดสอบข่ายงานทั้งหมด 144 ข่ายงาน พบว่าข่ายงานนิเวศแบบ 2 ชั้นซ่อน สามารถทำนายเปอร์เซ็นต์ของแข็งและความหนืดได้ดีกว่าข่ายงานนิเวศแบบ 1 ชั้นซ่อน (ผลการทำนายทั้งหมดแสดงดังตารางที่ ก.1 ในภาคผนวก ก.)

จุฬาลงกรณ์มหาวิทยาลัย




รูปที่ 5.1 ผลการทำนายเปอร์เซ็นต์ของแข็งโดยใช้ข่ายงานนิวรัลแบบ 1 ชั้นชอน

Model Log 3




รูปที่ 5.2 ผลการทำนายเปอร์เซ็นต์ของแข็งโดยใช้ข่ายงานนิวรัลแบบ 1 ชั้นชอน

Model Log 15




รูปที่ 5.3 ผลการทำนายเปอร์เซ็นต์ของแข็งโดยใช้ข่ายงานนิเวศแบบ 1 ชั้นซ่อน

Model Tan 3



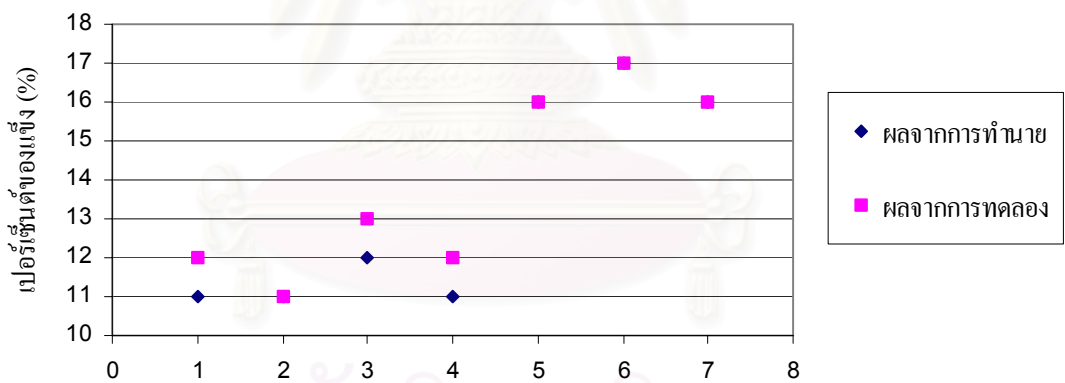
รูปที่ 5.4 ผลการทำนายเปอร์เซ็นต์ของแข็งโดยใช้ข่ายงานนิเวศแบบ 1 ชั้นซ่อน

Model Tan 7



รูปที่ 5.5 ผลการทำนายเปอร์เซ็นต์ข้อเท็จจริงโดยใช้ข่ายงานนิวรัลแบบ 1 ชั้นซ่อน


Model Tan 9




รูปที่ 5.6 ผลการทำนายเปอร์เซ็นต์ข้อเท็จจริงโดยใช้ข่ายงานนิวรัลแบบ 2 ชั้นซ่อน

Model Log-Log 3/17


จุฬาลงกรณ์มหาวิทยาลัย



รูปที่ 5.7 ผลการทำนายเปอร์เซ็นต์ของแข็งโดยใช้ข่ายงานนิเวศแบบ 2
ชั้นซ่อน Model Log-Tan 5/9




รูปที่ 5.8 ผลการทำนายเปอร์เซ็นต์ของแข็งโดยใช้ข่ายงานนิเวศแบบ 2 ชั้นซ่อน
Model Tan-Tan 5/9




รูปที่ 5.9 ผลการทำนายเปอร์เซ็นต์ของแข็งโดยใช้ข่ายงานนิวัตแบบ 2 ชั้นซ่อน

Model Tan-Tan 7/7




รูปที่ 5.10 ผลการทำนายเปอร์เซ็นต์ของแข็งโดยใช้ข่ายงานนิวัตแบบ 2

ชั้นซ่อน Model Tan-Tan 5/5




รูปที่ 5.11 ผลการทำนายความหนืดโดยใช้ข่ายงานนิวรัลแบบ 1 ชั้นซ่อน

Model Log 3




รูปที่ 5.12 ผลการทำนายความหนืดโดยใช้ข่ายงานนิวรัลแบบ 1 ชั้นซ่อน

Model Log 15




รูปที่ 5.13 ผลการทำนายความหนืดโดยใช้ข่ายงานนิวรัลแบบ 1 ชั้นซ่อน

Model Tan 3




รูปที่ 5.14 ผลการทำนายความหนืดโดยใช้ข่ายงานนิวรัลแบบ 1 ชั้นซ่อน

Model Tan 7




รูปที่ 5.15 ผลการทำนายความหนืดโดยใช้ข่ายงานนิวรัลแบบ 1 ชั้นซ่อน

Model Tan 9




รูปที่ 5.16 ผลการทำนายความหนืดโดยใช้ข่ายงานนิวรัลแบบ 2 ชั้นซ่อน

Model Log-Log 3/17




รูปที่ 5.17 ผลการทำนายความหนืดโดยใช้ข่ายงานนิวรัลแบบ 2 ชั้นซ่อน

Model Log-Tan 5/9




รูปที่ 5.18 ผลการทำนายความหนืดโดยใช้ข่ายงานนิวรัลแบบ 2 ชั้นซ่อน

Model Tan-Tan 5/9



รูปที่ 5.19 ผลการทำนายความหนืดโดยใช้ข่ายงานนิวรัลแบบ 2 ชั้นซ่อน

Model Tan-Tan 7/7



รูปที่ 5.20 ผลการทำนายความหนืดโดยใช้ข่ายงานนิวรัลแบบ 2 ชั้นซ่อน

Model Tan-Tan 5/5

5.2 การเปรียบเทียบผลการทำนาย

ในส่วนนี้เป็นการแสดงค่าดัชนีสำหรับการเปรียบเทียบแบบจำลองทั้ง 162 แบบจำลอง เพื่อเปรียบเทียบการทำนายค่าเปอร์เซ็นต์ของแข็งและความหนืด ค่าดัชนีที่ใช้คือ ดัชนี Root Mean Square Percent Error Index (RMSP Error Index) และ Maximun Percent Error Index (MP Error Index) ซึ่งเป็นดัชนีสำหรับเปรียบเทียบความแตกต่างระหว่างผลจากการทำนายและผลจากการทดลอง ดังแสดงในตารางที่ 5.1

$$RMSP \text{ Error index} = \sqrt{\frac{\sum_{i=1}^n (y_i - p_i)^2}{\sum_{i=1}^n p_i^2}} \times 100 \quad \text{สมการที่ 5.1}$$

$$MP \text{ Error index} = \frac{\max |y_i - p_i|}{\max |p_i|} \times 100 \quad \text{สมการที่ 5.2}$$

การหาสมรรถนะความถูกต้องในการทำนาย (Accuracy Performance) ของข่ายงาน เพื่อคัดเลือกแบบจำลองที่ดีที่สุดหาจากสมการที่ 5.3 และแสดงในตารางที่ 5.1

$$\text{Accuracy Performance} = 100 - \frac{\sum_{i=1}^n (RMSP_i * MP_i)}{n} \quad \text{สมการที่ 5.3}$$

หมายเหตุ: ค่าดัชนีและสมรรถนะความถูกต้องในการทำนายของทั้ง 162 ข่ายงานนำเสนอในตารางที่ ข.1 ของภาคผนวก ข

ตารางที่ 5.1 แสดงค่าดัชนีความผิดพลาด RMSP, MP และสมรรถนะความถูกต้องของข่ายงาน 1 ชั้น
ซ่อน 5 ข่ายงาน และ 2 ชั้นซ่อน 5 ข่ายงานที่มีค่าความผิดพลาดต่ำสุด

จำนวน ชั้นซ่อน	Model	เปอร์เซ็นต์ของแจ้ง		ความหนืด		สมรรถนะความถูกต้อง (Accuracy Performance)
		RMSP (%)	MP (%)	RMSP (%)	MP (%)	
1	Model Log 3	4.66	0.83	19.07	97.83	69.40
1	Model Log 15	7.62	8.33	19.37	88.82	68.96
1	Model Tan 3	3.81	0.59	18.58	100.00	69.25
1	Model Tan 7	6.02	8.33	9.66	110.43	66.39
1	Model Tan 9	7.12	1.18	21.16	102.94	66.90
2	Model Log-Log 3/17	4.66	8.33	16.15	60.43	-4.93
2	Model Log-Tan 5/9	9.71	8.33	15.73	42.83	80.85
2	Model Tan-Tan 5/5	5.39	0.83	23.78	74.71	73.83
2	Model Tan-Tan 5/9	7.62	8.33	26.68	56.00	75.34
2	Model Tan-Tan 7/7	7.62	1.18	18.31	65.75	76.78

บทที่ 6

สรุปผลการวิจัย

6.1 สรุปผลการวิจัย

แหมพู่เป็นสิ่งจำเป็นในชีวิตประจำวันเพื่อใช้ชำระล้างคราบไขมัน ละออง เหนือโคล และสิ่งสกปรกออกจากเส้นผมและหนังศีรษะ ซึ่งในปัจจุบันมีการแข่งขันในตลาดสูงมากทำให้ผู้ผลิตต้องมีการพัฒนาคุณภาพผลิตภัณฑ์และกระบวนการผลิตอย่างต่อเนื่อง การศึกษาวิจัยที่มีผลต่อการผลิตและการสร้างแบบจำลองสามารถช่วยให้บริษัทผู้ผลิตนำไปประยุกต์ใช้ได้

เนื่องจากกระบวนการผลิตแหมพู่มีพฤติกรรมแบบไม่เป็นเชิงเส้น ในงานวิจัยนี้จึงเลือกใช้ข่ายงานนิวรัลในการออกแบบแบบจำลองสำหรับทำนายเปอร์เซ็นต์ของแข็งและความหนืดของแหมพู่ ข้อมูลที่ใช้ในการฝึกและทดสอบข่ายงานได้จากการทำการทดลองผลิตแหมพู่ด้วยถังผสมแหมพู่ขนาด 1 ลิตรโดยเปลี่ยนอุณหภูมิของถังผลิตตั้งแต่ 25 – 50 °C, เวลาในการผลิตตั้งแต่ 10 – 35 นาที และอัตราส่วนผสมที่ใช้ของสารเคมีและน้ำเป็น 1 และ 2 ทำให้ได้ข้อมูลทั้งหมด 72 ชุดข้อมูล

ในการออกแบบโครงสร้างข่ายงานนิวรัล ใช้การเชื่อมโยงโครงสร้างแบบกระจายย้อนกลับและอัลกอริทึมการเรียนรู้แบบบริเวนเบอเกอร์-มาร์ควอร์ ออกแบบข่ายงาน ทั้งหมด 162 ข่ายงาน ซึ่งแต่ละข่ายงานมีโครงสร้างแตกต่างกัน โดยทำการเปลี่ยนโครงสร้างชั้นซ่อน ตั้งแต่ 1 – 2 ชั้นซ่อน และจำนวนนิวรัลในแต่ละชั้นซ่อนตั้งแต่ 3 – 19 โหนด เพื่อให้ได้ข่ายงานที่เหมาะสมที่สุด ฝึกข่ายงานทั้ง 162 ข่ายงานโดยใช้ข้อมูลที่ได้จากการทดลอง 72 ชุดข้อมูล นำข้อมูลมาแบ่งออกเป็น 3 ชุดข้อมูลคือ ข้อมูลชุดที่ 1 (70% ของข้อมูลทั้งหมด) ใช้ในการฝึกข่ายงาน, ข้อมูลชุดที่ 2 (20% ของข้อมูล ทั้งหมด) ใช้ในการทดสอบความสามารถของข่ายงาน และข้อมูลชุดที่ 3 (10% ของข้อมูลทั้งหมด) ใช้ทดสอบ การใช้งานจริง

การเปรียบเทียบความแตกต่างระหว่างผลจากการทำนายและผลจากการทดลอง ใช้ค่าดัชนี Root Mean Square Percent Error Index (RMSP Error Index) และ Maximun Percent Error Index (MP Error Index) และคัดเลือกข่ายงานโดยใช้ค่าสมรรถนะความถูกต้องในการทำนาย (Accuracy Performance)

6.1.1 สรุปผลการทำนายเปอร์เซ็นต์ของแข็ง

จากผลการทำนายเปอร์เซ็นต์ของแข็ง ข่ายงานนิวรัลทั้งที่มีโครงสร้างชั้นซ่อน 1 และ 2 ชั้น สามารถทำนายได้แม่นยำ โดยข่ายงานที่ทำนายเปอร์เซ็นต์ของแข็งได้ดีที่สุดมี 2 ข่ายงาน ซึ่งให้ค่า RMSP และ MP ของการทำนายเปอร์เซ็นต์ของแข็งเท่ากันคือ 3.81% และ 0.59% ตามลำดับ

- ข่ายงานนิวรัลที่มีโครงสร้างแบบ 1 ชั้นซ่อน ซึ่งมีจำนวนนิวรัล 3 โหนด ในชั้นซ่อน และใช้ Tan-Sigmoid Function เป็นฟังก์ชันกระตุ้น

- ข่ายงานนิวรัลที่มีโครงสร้างแบบ 2 ชั้นซ่อน ซึ่งมีจำนวนนิวรัล 13 โหนด ในชั้นซ่อนที่ 1 และ 15 โหนดในชั้นซ่อนที่ 2 และใช้ Tan-Sigmoid Function เป็นฟังก์ชันกระตุ้นในชั้นซ่อนที่ 1 และ Log-Sigmoid Function เป็นฟังก์ชันกระตุ้นในชั้นซ่อนที่ 2

6.1.2 สรุปผลการทำนายความหนืด

จากผลการทำนายความหนืด ข่ายงานนิวรัลที่มีโครงสร้างชั้นซ่อน 1 ชั้นไม่สามารถทำนายได้ ส่วนข่ายงานนิวรัลที่มีโครงสร้างชั้นซ่อน 2 ชั้นสามารถทำนายได้ แต่ยังไม่ค่อยดีนัก โดยข่ายงานที่ทำนายความหนืดได้ดีที่สุด ซึ่งให้ค่า RMSP และ MP ของการทำนายความหนืดคือ 15.73% และ 42.83% ตามลำดับ คือข่ายงานนิวรัลที่มีโครงสร้างแบบ 2 ชั้นซ่อน ซึ่งมีจำนวนนิวรัล 5 โหนด ในชั้นซ่อนที่ 1 และ 9 โหนดในชั้นซ่อนที่ 2 และใช้ Log-Sigmoid Function เป็นฟังก์ชันกระตุ้นในชั้นซ่อนที่ 1 และ Tan-Sigmoid Function เป็นฟังก์ชันกระตุ้นในชั้นซ่อนที่ 2

6.1.3 สรุปผลการคัดเลือกข่ายงาน

จากการคำนวณหาค่าสมรรถนะความถูกต้องของข่ายงานนิวรัลทั้งหมด 162 ข่ายงาน พบว่าข่ายงานนิวรัลที่มีสมรรถนะความถูกต้องในการทำนายเปอร์เซ็นต์ของแข็งและความหนืด สูงที่สุด ซึ่งมีค่าสมรรถนะความถูกต้องในการทำนาย 80.85% คือข่ายงานนิวรัลที่มีโครงสร้างแบบ 2 ชั้นซ่อน ซึ่งมีจำนวนนิวรัล 5 โหนด ในชั้นซ่อนที่ 1 และ 9 โหนดในชั้นซ่อนที่ 2 และใช้ Log-Sigmoid Function เป็นฟังก์ชันกระตุ้นในชั้นซ่อนที่ 1 และ Tan-Sigmoid Function เป็นฟังก์ชันกระตุ้นในชั้นซ่อนที่ 2 โดยค่า RMSP และ MP ของการทำนายเปอร์เซ็นต์ของแข็งคือ 9.71%

และ 8.33% ตามลำดับ และค่าดังกล่าวของการทำนายความหนืดคือ 15.73% และ 42.83% ตามลำดับ ซึ่งเป็นค่าที่ใกล้เคียงกับค่าที่คำนวณได้มากที่สุด

6.2 บทสรุป

แบบจำลองข่ายงานนิวรัลเป็นเครื่องมือสำหรับกระบวนการเรียนรู้ เพื่อวิเคราะห์ความสัมพันธ์ของระบบที่มีความซับซ้อนและระบบที่ไม่เป็นเชิงเส้นได้อย่างมีประสิทธิภาพ ในงานวิจัยนี้จึงนำมาประยุกต์ใช้เพื่อจำลองการผลิตแอมพู และทำนายเปอร์เซ็นต์ของแข็งและความหนืด การรวบรวมข้อมูลอินพุตและเอาต์พุตสำหรับใช้ฝึกและทดสอบข่ายงานได้จากการทำการทดลองด้วยเครื่องทดลองขนาด 1 ลิตร การออกแบบโครงสร้างแบบจำลองข่ายงานนิวรัลทำได้เพิ่มจำนวนชั้นซ่อนและจำนวนนิวรัลในข่ายงาน ซึ่งยังจำเป็นต้องใช้วิธีการลองผิดลองถูกเพื่อให้ได้ข่ายงานที่เหมาะสม โดยพิจารณาจากดัชนีความผิดพลาดและสมรรถนะความถูกต้องในการทำนาย

ในงานวิจัยนี้ทำการออกแบบแบบจำลองข่ายงานนิวรัลทั้งหมด 162 ข่ายงาน และแบบจำลองข่ายงานนิวรัลที่ดีที่สุด คือข่ายงานนิวรัลที่มีโครงสร้าง แบบ 2 ชั้นซ่อน ซึ่งมีจำนวนนิวรัล 5 โหนดในชั้นซ่อนที่ 1 และ 9 โหนดในชั้นซ่อนที่ 2 และใช้ Log-Sigmoid Function เป็นฟังก์ชันกระตุ้นในชั้นซ่อนที่ 1 และ Tan-Sigmoid Function เป็นฟังก์ชันกระตุ้นในชั้นซ่อนที่ 2 ข่ายงานนี้สามารถทำนายเปอร์เซ็นต์ของแข็งได้แม่นยำ แต่ยังไม่สามารถทำนายความหนืดได้มากนัก ทั้งนี้อาจเนื่องมาจากความผิดพลาดที่เกิดจากการทำการทดลองผลิตแอมพู และค่าความหนืดที่ต้องการทำนายมีความแตกต่างกันมาก ซึ่งจำนวนชุดข้อมูล 72 ชุดข้อมูลที่ใช้ในการฝึกและทดสอบข่ายงานอาจยังไม่มากพอทำให้ข่ายงานยังเรียนรู้ได้ไม่ดีและไม่สามารทำนายความหนืดได้

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

รายการอ้างอิง

ภาษาไทย

จุฑาทิพย์ เพชรเชิดศักดิ์. การใช้ข่ายงานนิวรัลชนิดป้อนไปข้างหน้าแบบหลายชั้น

สำหรับการระบุระบบการประมาณค่าฟังก์ชันและการควบคุมขั้นสูง.

วิทยานิพนธ์ปริญญาโทมหาบัณฑิต วิศวกรรมเคมี คณะวิศวกรรมศาสตร์

จุฬาลงกรณ์มหาวิทยาลัย, 2543

นงลักษณ์ พลรักษา.

การทำนายค่าอัตราการไหลและความหนาแน่นของพอลิเมอร์ในเครื่องปฏิกรณ์แบบถัง

กวนต่อเนื่อง โดยใช้ข่ายงานนิวรัล. วิทยานิพนธ์ปริญญาโทมหาบัณฑิต วิศวกรรมเคมี

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย, 2543.

พัฐกานต์ เชียงน้อย. แชมป์...ตลาดที่ไม่นิ่ง [ระบบออนไลน์]. สานเศรษฐกิจ, 2547.

http://www.consumerthai.org/displace_board/view.php?id=587 [1 กุมภาพันธ์ 2549]

พันธพงศ์ ตั้งธีระสุนันท์. แบบจำลองข่ายงานนิวรัล สำหรับทำนาย ความเข้มข้นกรด

และความเข้มข้นไอออนเหล็กที่ได้รับจากกระบวนการนำกลับกรดไฮโดรคลอริก

โดยการแลกเปลี่ยนไอออน. วิทยานิพนธ์ปริญญาโทมหาบัณฑิต วิศวกรรมเคมี

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย, 2547

ไพโรจน์ สัญญะเดชากุล, เลขานุการ. แก้ไขมาตรฐานผลิตภัณฑ์ชุมชนแชมพู แก้ไขครั้งที่ 1.

สำนักมาตรฐานผลิตภัณฑ์อุตสาหกรรม, 2548.

http://www.tisi.go.th/otop/pdf_file/tcps92_48.pdf [1 กุมภาพันธ์ 2549]

สุรพล คำสุภา. การสร้างแบบจำลองกระบวนการไม่เป็นเชิงเส้นโดยใช้ข่ายงานนิวรัล.

วิทยานิพนธ์ปริญญาโทมหาบัณฑิต วิศวกรรมเคมี คณะวิศวกรรมศาสตร์

จุฬาลงกรณ์มหาวิทยาลัย, 2538.

ภาษาอังกฤษ

D.L.Yu. and J.B.Gomn. Implementation of neural network predictive control to a multivariable chemical reactor. Control Engineering Practice. 11 (2003):1315-1323

Dave Anderson and George McNeill. Artificial Neural Networks Technology. A DACS State-of-the Art Report Kaman Sciences Corporation. 258 Genesse Street Utica. NY,1992

David P.B.T.B. Strik, Alexander M. Domnanovich, Loredana Zani, Rudolf and Peter Holubar. Prediction of trace Compound in biogas from Anaerobic digestion using the MATLAB Neural network Toolbox. Environmental Modeling & Software. 20 (2005): 803-810

- H.S.Lee, C.J.Matthews, R.D.Braddock, G.C.Sander and F.Gandola. A MATLAB method of Iones template for transport equations. Environmental Modeling & Software. 19 (2004): 603-614
- Jacek M. Zurada. Introduction to Artificial Neural Systems. Info Access Distribution, 1992.
- Jutatip Petcherdsak. Use of multiplayer feed forward networks for system identification, function approximation, and advance control. Master's Thesis, Department of Chemical Engineering, Faculty of Engineering, Chulalongkorn University, 1999
- Khoshaba. T., K. Badie and R.M. Hashemi. EMG patten classification based on back-propagation neural for prosthesis control. Proc. Annual Intl. Conf. IEEE Eng. Med. & Biol. Soc. 1474-1475, 1990
- M.A.Hussain. Neural Network Techniques and Application in Chemical Process Control System. CRC Press, 2003
- Mark E.Davis. Numerical Methods and Modeling for Chemical Engineers. John Wiley & Sons, 1984
- Marzuki Khalid and Sigeru Omatu. A neural network controller for a temperature control system. IEEE Control System Mag. 6 (1992): 58-64
- Mohamed Azlan Hussain, Paisan Kittisupakorn, and Wachira Daosud. Implementation of Neural-Network-Based Inverse-Model Control Strategies on an Exothermic Reactor. Jornal of the Science Society of Thailand. 27 (2001): 41-45
- Neural Network ToolBox user's guide [Computer program]. The Matworks Inc. Massachusetts USA, 1992
- Paisan Kittisupakorn, Nongluk Polruksa, and Wachira Daosud. Neural Networks Model for the Extimation of Melt Flow Rate and Density of Polymers. 9th APCCHE Congress and CHEMECA, 2002
- RePhiroz Bhagat, An Introduction to Neural Nets. Chem. Engng. Prog. 55-60, 1990
- S.M.A.Razavi, S.M.Mousavi, and S.A.Mortazavi. Dynamic prediction of milk ultrafiltration performance A neural network approach. Chemical Engineering Science. 58 (2003): 4185-4195
- Sang Hyun Sohn, Sea Cheon Oh, and Yeong-koo Yeo. Prediction of Air Pollutant by Using an Artificial Neural Network. Korean J. Chem. Eng. 16 (1999): 368-387

Shampoo and Conditioner – US – March 2005 [Online]. Global Information, Inc. 2005. Available from: http://www.the-infoshop.com/study/mt29031_shampoo_conditioner.html [2006, February 1]

S.Y. Kung. Digital Neural Networks. Prentice Hall international, 1993.

S.Z. Ain, H.T. Zu and T.J. McAvoy. Comparison of Four Neural Net Learning Methods for Dynamic System Identification. IEEE Trans. Neural Networks 3 (1992): 122-130

William L.Luyben, Process Modeling, Simulation, and Control for Chemical Engineers. Singapore: McGraw-Hill, 1990



สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย



ภาคผนวก

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

ภาคผนวก ก

ผลการทำนายของข่ายงานนิวรัล

ตารางที่ ก.1 แสดงผลการทำนายของข่ายงานนิวรัลทั้งหมด 162 ข่ายงาน

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลในชั้นซ่อนที่ 1	จำนวนนิวรัลในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
1	1	logsig - purelin	3	0	12	12	269	380
					12	11	250	170
					12	13	292	400
					12	12	10	460
					16	16	8,872	10,650
					16	17	9,531	12,500
					16	16	8,446	8,200
2	1	logsig - purelin	5	0	11	12	531	380
					12	11	379	170
					12	13	972	400
					12	12	498	460
					16	16	9,246	10,650
					16	17	9,022	12,500
					16	16	8,965	8,200
3	1	logsig - purelin	7	0	11	12	266	380
					11	11	-454	170
					12	13	-217	400
					12	12	530	460
					16	16	9,553	10,650
					16	17	9,475	12,500
					17	16	9,549	8,200
4	1	logsig - purelin	9	0	12	12	423	380
					11	11	346	170
					11	13	902	400
					12	12	-276	460
					16	16	8,404	10,650
					16	17	10,127	12,500
					17	16	8,104	8,200

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
5	1	logsig - purelin	11	0	12	12	-807	380
					10	11	2,396	170
					11	13	-20	400
					12	12	3,091	460
					15	16	9,894	10,650
					17	17	9,964	12,500
					16	16	8,833	8,200
6	1	logsig - purelin	13	0	11	12	504	380
					11	11	565	170
					12	13	158	400
					12	12	378	460
					15	16	10,048	10,650
					17	17	10,418	12,500
					16	16	7,926	8,200
7	1	logsig - purelin	15	0	11	12	172	380
					12	11	321	170
					11	13	48	400
					12	12	607	460
					15	16	9,280	10,650
					16	17	9,399	12,500
					16	16	9,179	8,200
8	1	logsig - purelin	17	0	11	12	762	380
					13	11	214	170
					11	13	150	400
					12	12	1,169	460
					15	16	9,172	10,650
					17	17	9,670	12,500
					16	16	9,326	8,200
9	1	logsig - purelin	19	0	12	12	459	380
					12	11	1,991	170
					11	13	4,154	400
					13	12	303	460
					15	16	11,350	10,650
					16	17	9,173	12,500
					16	16	9,589	8,200

แบบจำลองที่	จำนวนชั้นซ้อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
10	1	tansig - purelin	3	0	12	12	353	380
					11	11	340	170
					12	13	84	400
					12	12	149	460
					16	16	9,634	10,650
					16	17	9,353	12,500
					16	16	8,902	8,200
11	1	tansig - purelin	5	0	11	12	290	380
					12	11	716	170
					12	13	119	400
					12	12	722	460
					16	16	9,453	10,650
					16	17	9,511	12,500
					16	16	9,513	8,200
12	1	tansig - purelin	7	0	11	12	514	380
					11	11	64	170
					12	13	101	400
					13	12	968	460
					15	16	10,183	10,650
					16	17	11,178	12,500
					16	16	9,099	8,200
13	1	tansig - purelin	9	0	12	12	569	380
					11	11	345	170
					11	13	240	400
					13	12	652	460
					16	16	8,263	10,650
					16	17	9,880	12,500
					17	16	9,757	8,200
14	1	tansig - purelin	11	0	11	12	1,545	380
					12	11	1,328	170
					12	13	937	400
					12	12	-141	460
					13	16	6,496	10,650
					18	17	10,872	12,500
					17	16	10,394	8,200

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
15	1	tansig - purelin	13	0	13	12	550	380
					11	11	1,121	170
					12	13	150	400
					11	12	428	460
					15	16	13,414	10,650
					16	17	9,958	12,500
					16	16	9,089	8,200
16	1	tansig - purelin	15	0	12	12	594	380
					11	11	765	170
					11	13	-302	400
					12	12	-414	460
					15	16	9,166	10,650
					17	17	9,147	12,500
					16	16	8,578	8,200
17	1	tansig - purelin	17	0	11	12	559	380
					13	11	469	170
					12	13	279	400
					12	12	1,034	460
					15	16	10,408	10,650
					16	17	8,994	12,500
					16	16	6,792	8,200
18	1	tansig - purelin	19	0	14	12	3,198	380
					12	11	1,101	170
					13	13	356	400
					12	12	1,243	460
					15	16	12,615	10,650
					17	17	6,220	12,500
					16	16	10,128	8,200
19	2	logsig - logsig - purelin	3	3	12	12	361	380
					12	11	364	170
					12	13	361	400
					12	12	361	460
					15	16	7,020	10,650
					16	17	8,407	12,500
					16	16	7,726	8,200

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
20	2	logsig - logsig - purelin	3	5	11	12	302	380
					12	11	301	170
					11	13	256	400
					13	12	137	460
					16	16	9,761	10,650
					17	17	10,055	12,500
					16	16	9,126	8,200
21	2	logsig - logsig - purelin	3	7	12	12	77	380
					12	11	82	170
					12	13	226	400
					12	12	135	460
					16	16	8,549	10,650
					17	17	12,107	12,500
					16	16	8,369	8,200
22	2	logsig - logsig - purelin	3	9	11	12	71	380
					12	11	1,052	170
					12	13	281	400
					12	12	393	460
					16	16	9,722	10,650
					17	17	9,397	12,500
					16	16	7,339	8,200
23	2	logsig - logsig - purelin	3	11	12	12	1,431	380
					12	11	1,332	170
					12	13	1,063	400
					12	12	1,124	460
					16	16	9,832	10,650
					17	17	11,209	12,500
					16	16	9,204	8,200
24	2	logsig - logsig - purelin	3	13	11	12	528	380
					12	11	321	170
					11	13	209	400
					12	12	586	460
					16	16	9,933	10,650
					16	17	9,543	12,500
					16	16	7,687	8,200

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
25	2	logsig - logsig - purelin	3	15	11	12	16	380
					12	11	832	170
					12	13	822	400
					12	12	940	460
					16	16	9,313	10,650
					16	17	9,947	12,500
					16	16	8,311	8,200
26	2	logsig - logsig - purelin	3	17	11	12	344	380
					11	11	248	170
					12	13	303	400
					11	12	182	460
					16	16	8,118	10,650
					17	17	10,989	12,500
					16	16	8,085	8,200
27	2	logsig - logsig - purelin	3	19	11	12	74	380
					11	11	598	170
					12	13	1,055	400
					11	12	516	460
					15	16	9,282	10,650
					17	17	9,784	12,500
					16	16	8,628	8,200
28	2	logsig - logsig - purelin	5	3	12	12	228	380
					12	11	571	170
					12	13	348	400
					12	12	825	460
					16	16	9,564	10,650
					16	17	10,115	12,500
					16	16	9,458	8,200
29	2	logsig - logsig - purelin	5	5	12	12	1,240	380
					12	11	335	170
					12	13	125	400
					11	12	111	460
					15	16	10,292	10,650
					16	17	10,432	12,500
					17	16	10,506	8,200

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
30	2	logsig - logsig - purelin	5	7	12	12	1,091	380
					13	11	341	170
					12	13	1,984	400
					14	12	1,201	460
					18	16	11,172	10,650
					17	17	7,012	12,500
					16	16	6,583	8,200
31	2	logsig - logsig - purelin	5	9	11	12	800	380
					11	11	745	170
					12	13	364	400
					12	12	-121	460
					16	16	8,659	10,650
					16	17	9,917	12,500
					16	16	7,170	8,200
32	2	logsig - logsig - purelin	5	11	11	12	316	380
					11	11	1,657	170
					12	13	329	400
					12	12	214	460
					15	16	11,030	10,650
					17	17	8,563	12,500
					15	16	8,872	8,200
33	2	logsig - logsig - purelin	5	13	11	12	1,609	380
					12	11	342	170
					11	13	1,190	400
					12	12	177	460
					15	16	11,292	10,650
					16	17	7,733	12,500
					15	16	7,383	8,200
34	2	logsig - logsig - purelin	5	15	11	12	18	380
					12	11	494	170
					12	13	349	400
					12	12	407	460
					16	16	12,606	10,650
					16	17	9,337	12,500
					16	16	11,983	8,200

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
35	2	logsig - logsig - purelin	5	17	11	12	-1,065	380
					12	11	251	170
					11	13	49	400
					13	12	2,768	460
					16	16	8,661	10,650
					17	17	11,459	12,500
					16	16	8,746	8,200
36	2	logsig - logsig - purelin	5	19	13	12	469	380
					11	11	758	170
					12	13	319	400
					11	12	308	460
					16	16	9,595	10,650
					17	17	9,564	12,500
					16	16	9,100	8,200
37	2	logsig - logsig - purelin	9	3	12	12	638	380
					12	11	376	170
					12	13	435	400
					12	12	399	460
					16	16	9,717	10,650
					17	17	9,124	12,500
					17	16	8,878	8,200
38	2	logsig - logsig - purelin	9	5	12	12	137	380
					12	11	227	170
					12	13	938	400
					12	12	664	460
					16	16	8,966	10,650
					16	17	9,365	12,500
					16	16	8,711	8,200
39	2	logsig - logsig - purelin	9	7	12	12	454	380
					12	11	472	170
					12	13	327	400
					13	12	614	460
					16	16	8,910	10,650
					16	17	8,139	12,500
					16	16	8,834	8,200

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
40	2	logsig - logsig - purelin	9	9	11	12	805	380
					13	11	4,012	170
					11	13	-86	400
					12	12	-247	460
					16	16	9,893	10,650
					16	17	9,435	12,500
					16	16	6,804	8,200
41	2	logsig - logsig - purelin	9	11	12	12	1,844	380
					11	11	629	170
					11	13	1,109	400
					12	12	533	460
					16	16	10,130	10,650
					16	17	9,901	12,500
					16	16	9,412	8,200
42	2	logsig - logsig - purelin	9	13	11	12	1,258	380
					12	11	826	170
					11	13	1,629	400
					13	12	311	460
					15	16	10,684	10,650
					16	17	10,252	12,500
					16	16	8,001	8,200
43	2	logsig - logsig - purelin	9	15	12	12	1,657	380
					12	11	1,113	170
					12	13	458	400
					12	12	341	460
					15	16	9,909	10,650
					16	17	9,610	12,500
					16	16	6,002	8,200
44	2	logsig - logsig - purelin	9	17	11	12	-1,099	380
					13	11	2,333	170
					13	13	506	400
					13	12	682	460
					16	16	9,181	10,650
					16	17	8,634	12,500
					15	16	8,069	8,200

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแจ้ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
45	2	logsig - logsig - purelin	9	19	10	12	411	380
					13	11	1,144	170
					12	13	860	400
					13	12	1,455	460
					16	16	10,005	10,650
					16	17	9,411	12,500
					15	16	8,870	8,200
46	2	logsig - logsig - purelin	13	3	12	12	360	380
					12	11	591	170
					12	13	589	400
					12	12	516	460
					16	16	9,400	10,650
					16	17	9,608	12,500
					16	16	9,550	8,200
47	2	logsig - logsig - purelin	13	5	12	12	423	380
					11	11	549	170
					11	13	88	400
					12	12	119	460
					15	16	6,295	10,650
					17	17	10,340	12,500
					16	16	7,674	8,200
48	2	logsig - logsig - purelin	13	7	11	12	-61	380
					13	11	1,915	170
					12	13	1,138	400
					12	12	1,208	460
					16	16	7,490	10,650
					16	17	7,792	12,500
					15	16	6,601	8,200
49	2	logsig - logsig - purelin	13	9	12	12	751	380
					13	11	1,331	170
					11	13	539	400
					13	12	446	460
					16	16	9,046	10,650
					17	17	9,283	12,500
					17	16	7,982	8,200

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
50	2	logsig - logsig - purelin	13	11	12	12	960	380
					12	11	849	170
					12	13	1,291	400
					14	12	584	460
					15	16	10,878	10,650
					16	17	10,235	12,500
					16	16	9,836	8,200
51	2	logsig - logsig - purelin	13	13	11	12	108	380
					13	11	644	170
					11	13	390	400
					12	12	1,296	460
					16	16	9,881	10,650
					16	17	8,870	12,500
					14	16	7,513	8,200
52	2	logsig - logsig - purelin	13	15	12	12	135	380
					12	11	508	170
					12	13	221	400
					12	12	7	460
					16	16	9,707	10,650
					17	17	8,134	12,500
					16	16	7,806	8,200
53	2	logsig - logsig - purelin	13	17	12	12	870	380
					12	11	560	170
					11	13	37	400
					13	12	465	460
					16	16	12,309	10,650
					16	17	9,457	12,500
					16	16	10,694	8,200
54	2	logsig - logsig - purelin	13	19	13	12	1,656	380
					14	11	2,343	170
					11	13	862	400
					12	12	-291	460
					17	16	11,271	10,650
					17	17	8,672	12,500
					17	16	12,036	8,200

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
55	2	logsig - tansig - purelin	3	3	11	12	232	380
					11	11	11	170
					12	13	669	400
					11	12	2	460
					16	16	7,636	10,650
					16	17	8,362	12,500
					16	16	7,863	8,200
56	2	logsig - tansig - purelin	3	5	12	12	704	380
					12	11	641	170
					12	13	594	400
					11	12	449	460
					15	16	9,485	10,650
					16	17	9,853	12,500
					16	16	9,823	8,200
57	2	logsig - tansig - purelin	3	7	11	12	427	380
					13	11	1,376	170
					11	13	153	400
					13	12	442	460
					16	16	9,958	10,650
					16	17	10,114	12,500
					16	16	9,464	8,200
58	2	logsig - tansig - purelin	3	9	13	12	-489	380
					12	11	-419	170
					12	13	680	400
					12	12	370	460
					16	16	9,708	10,650
					16	17	9,663	12,500
					16	16	8,402	8,200
59	2	logsig - tansig - purelin	3	11	13	12	774	380
					11	11	267	170
					11	13	210	400
					13	12	1,331	460
					16	16	9,976	10,650
					16	17	9,488	12,500
					16	16	7,995	8,200

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
60	2	logsig - tansig - purelin	3	13	11	12	399	380
					12	11	404	170
					12	13	404	400
					12	12	29	460
					16	16	8,216	10,650
					16	17	9,394	12,500
					16	16	8,617	8,200
61	2	logsig - tansig - purelin	3	15	11	12	706	380
					12	11	210	170
					12	13	349	400
					12	12	354	460
					16	16	8,789	10,650
					16	17	9,172	12,500
					16	16	8,214	8,200
62	2	logsig - tansig - purelin	3	17	13	12	3,794	380
					12	11	352	170
					11	13	322	400
					13	12	-1,448	460
					16	16	7,972	10,650
					16	17	10,369	12,500
					17	16	9,511	8,200
63	2	logsig - tansig - purelin	3	19	12	12	203	380
					11	11	552	170
					11	13	539	400
					13	12	501	460
					16	16	8,506	10,650
					17	17	8,361	12,500
					16	16	8,263	8,200
64	2	logsig - tansig - purelin	5	3	11	12	274	380
					13	11	85	170
					12	13	235	400
					13	12	38	460
					15	16	6,872	10,650
					17	17	8,538	12,500
					17	16	6,957	8,200

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแจ้ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
65	2	logsig - tansig - purelin	5	5	11	12	540	380
					12	11	1,350	170
					12	13	1,886	400
					13	12	2,057	460
					16	16	8,974	10,650
					16	17	9,402	12,500
					16	16	9,339	8,200
66	2	logsig - tansig - purelin	5	7	11	12	367	380
					13	11	746	170
					11	13	324	400
					10	12	142	460
					16	16	10,019	10,650
					17	17	10,369	12,500
					17	16	9,572	8,200
67	2	logsig - tansig - purelin	5	9	11	12	479	380
					12	11	176	170
					11	13	520	400
					13	12	263	460
					18	16	9,588	10,650
					16	17	9,979	12,500
					17	16	9,098	8,200
68	2	logsig - tansig - purelin	5	11	11	12	43	380
					11	11	1,330	170
					12	13	221	400
					12	12	72	460
					16	16	9,298	10,650
					17	17	10,190	12,500
					16	16	8,953	8,200
69	2	logsig - tansig - purelin	5	13	11	12	1,456	380
					12	11	365	170
					11	13	582	400
					12	12	319	460
					18	16	6,595	10,650
					18	17	6,089	12,500
					17	16	9,000	8,200

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
70	2	logsig - tansig - purelin	5	15	12	12	745	380
					13	11	2,100	170
					11	13	220	400
					13	12	-2,424	460
					16	16	9,905	10,650
					17	17	11,133	12,500
					16	16	8,335	8,200
71	2	logsig - tansig - purelin	5	17	11	12	649	380
					12	11	1,113	170
					13	13	1,676	400
					14	12	2,685	460
					16	16	9,123	10,650
					17	17	9,968	12,500
					16	16	7,745	8,200
72	2	logsig - tansig - purelin	5	19	12	12	829	380
					12	11	880	170
					12	13	165	400
					12	12	2,627	460
					15	16	9,621	10,650
					16	17	8,064	12,500
					16	16	8,534	8,200
73	2	logsig - tansig - purelin	9	3	12	12	2,551	380
					11	11	372	170
					11	13	271	400
					12	12	472	460
					15	16	9,383	10,650
					16	17	9,467	12,500
					16	16	9,467	8,200
74	2	logsig - tansig - purelin	9	5	11	12	433	380
					12	11	326	170
					12	13	278	400
					12	12	416	460
					16	16	9,228	10,650
					17	17	10,384	12,500
					16	16	8,286	8,200

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
75	2	logsig - tansig - purelin	9	7	11	12	641	380
					13	11	1,502	170
					12	13	2,653	400
					14	12	2,509	460
					16	16	10,215	10,650
					17	17	9,711	12,500
					16	16	8,079	8,200
76	2	logsig - tansig - purelin	9	9	12	12	774	380
					12	11	575	170
					13	13	310	400
					13	12	749	460
					16	16	10,156	10,650
					17	17	9,532	12,500
					17	16	7,639	8,200
77	2	logsig - tansig - purelin	9	11	11	12	555	380
					12	11	952	170
					11	13	875	400
					12	12	918	460
					16	16	9,523	10,650
					16	17	7,758	12,500
					16	16	8,472	8,200
78	2	logsig - tansig - purelin	9	13	10	12	17	380
					13	11	695	170
					11	13	201	400
					13	12	1,581	460
					14	16	10,028	10,650
					16	17	10,132	12,500
					16	16	9,280	8,200
79	2	logsig - tansig - purelin	9	15	12	12	1,037	380
					12	11	1,012	170
					11	13	445	400
					13	12	2,376	460
					16	16	10,794	10,650
					17	17	9,966	12,500
					16	16	9,920	8,200

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
80	2	logsig - tansig - purelin	9	17	12	12	4,710	380
					10	11	356	170
					13	13	2,728	400
					12	12	-782	460
					15	16	10,805	10,650
					16	17	9,620	12,500
					14	16	8,811	8,200
81	2	logsig - tansig - purelin	9	19	12	12	1,171	380
					10	11	2,734	170
					13	13	1,418	400
					13	12	1,271	460
					13	16	9,454	10,650
					17	17	5,408	12,500
					17	16	7,456	8,200
82	2	logsig - tansig - purelin	13	3	12	12	127	380
					12	11	755	170
					12	13	115	400
					12	12	27	460
					16	16	9,247	10,650
					16	17	10,188	12,500
					16	16	9,846	8,200
83	2	logsig - tansig - purelin	13	5	12	12	1,007	380
					12	11	703	170
					12	13	564	400
					12	12	513	460
					16	16	8,360	10,650
					16	17	11,044	12,500
					16	16	9,487	8,200
84	2	logsig - tansig - purelin	13	7	12	12	2,005	380
					12	11	1,498	170
					11	13	-298	400
					12	12	288	460
					16	16	9,260	10,650
					16	17	9,414	12,500
					15	16	8,633	8,200

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
85	2	logsig - tansig - purelin	13	9	12	12	387	380
					12	11	462	170
					12	13	366	400
					12	12	466	460
					16	16	10,172	10,650
					17	17	8,892	12,500
					16	16	7,414	8,200
86	2	logsig - tansig - purelin	13	11	12	12	704	380
					9	11	922	170
					11	13	-25	400
					12	12	-97	460
					16	16	10,717	10,650
					17	17	9,606	12,500
					16	16	8,167	8,200
87	2	logsig - tansig - purelin	13	13	13	12	537	380
					15	11	1,021	170
					11	13	1,215	400
					13	12	1,724	460
					16	16	9,238	10,650
					17	17	9,470	12,500
					16	16	10,523	8,200
88	2	logsig - tansig - purelin	13	15	13	12	25	380
					11	11	622	170
					10	13	-8	400
					12	12	-83	460
					15	16	18,845	10,650
					17	17	10,248	12,500
					17	16	6,293	8,200
89	2	logsig - tansig - purelin	13	17	14	12	324	380
					11	11	1,206	170
					12	13	194	400
					12	12	-412	460
					15	16	14,201	10,650
					17	17	8,810	12,500
					16	16	7,877	8,200

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
90	2	logsig - tansig - purelin	13	19	12	12	1,225	380
					11	11	1,770	170
					11	13	1,050	400
					12	12	260	460
					16	16	11,650	10,650
					17	17	9,441	12,500
					16	16	7,308	8,200
91	2	tansig - logsig - purelin	3	3	12	12	561	380
					12	11	547	170
					12	13	1,704	400
					12	12	926	460
					15	16	7,732	10,650
					16	17	8,232	12,500
					16	16	8,648	8,200
92	2	tansig - logsig - purelin	3	5	12	12	329	380
					12	11	341	170
					12	13	450	400
					12	12	439	460
					16	16	8,968	10,650
					16	17	9,104	12,500
					16	16	9,029	8,200
93	2	tansig - logsig - purelin	3	7	12	12	400	380
					12	11	460	170
					11	13	285	400
					12	12	1,904	460
					16	16	7,863	10,650
					16	17	8,120	12,500
					16	16	7,946	8,200
94	2	tansig - logsig - purelin	3	9	11	12	286	380
					13	11	830	170
					11	13	760	400
					13	12	1,405	460
					16	16	7,665	10,650
					17	17	9,314	12,500
					16	16	8,756	8,200

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแจ้ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
95	2	tansig - logsig - purelin	3	11	12	12	540	380
					12	11	327	170
					12	13	1,878	400
					13	12	-130	460
					15	16	6,335	10,650
					15	17	7,339	12,500
					15	16	6,254	8,200
96	2	tansig - logsig - purelin	3	13	12	12	-172	380
					13	11	758	170
					12	13	397	400
					13	12	510	460
					16	16	9,288	10,650
					17	17	11,275	12,500
					16	16	8,948	8,200
97	2	tansig - logsig - purelin	3	15	11	12	272	380
					12	11	553	170
					12	13	376	400
					12	12	649	460
					16	16	9,192	10,650
					16	17	9,480	12,500
					16	16	8,172	8,200
98	2	tansig - logsig - purelin	3	17	12	12	84	380
					12	11	107	170
					13	13	-885	400
					12	12	-359	460
					16	16	9,018	10,650
					16	17	9,123	12,500
					17	16	9,734	8,200
99	2	tansig - logsig - purelin	3	19	12	12	587	380
					12	11	607	170
					12	13	292	400
					12	12	576	460
					15	16	8,972	10,650
					17	17	9,969	12,500
					16	16	9,825	8,200

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
100	2	tansig - logsig - purelin	5	3	12	12	1,015	380
					12	11	492	170
					12	13	341	400
					12	12	278	460
					16	16	9,263	10,650
					16	17	9,968	12,500
					16	16	8,708	8,200
101	2	tansig - logsig - purelin	5	5	12	12	402	380
					12	11	692	170
					11	13	-481	400
					12	12	282	460
					16	16	8,106	10,650
					17	17	9,186	12,500
					16	16	8,397	8,200
102	2	tansig - logsig - purelin	5	7	11	12	186	380
					11	11	576	170
					12	13	40	400
					13	12	1,113	460
					16	16	9,356	10,650
					17	17	10,554	12,500
					16	16	7,847	8,200
103	2	tansig - logsig - purelin	5	9	11	12	312	380
					12	11	1,065	170
					11	13	431	400
					13	12	612	460
					15	16	9,874	10,650
					16	17	9,382	12,500
					16	16	7,994	8,200
104	2	tansig - logsig - purelin	5	11	11	12	14	380
					12	11	336	170
					11	13	1,308	400
					12	12	375	460
					15	16	8,299	10,650
					17	17	10,438	12,500
					16	16	8,496	8,200

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
105	2	tansig - logsig - purelin	5	13	11	12	1,076	380
					12	11	330	170
					11	13	605	400
					12	12	317	460
					16	16	9,499	10,650
					16	17	9,847	12,500
					16	16	9,111	8,200
106	2	tansig - logsig - purelin	5	15	11	12	583	380
					12	11	495	170
					12	13	586	400
					13	12	2,375	460
					16	16	11,856	10,650
					17	17	9,862	12,500
					16	16	8,298	8,200
107	2	tansig - logsig - purelin	5	17	12	12	984	380
					12	11	231	170
					11	13	16	400
					12	12	149	460
					16	16	9,474	10,650
					16	17	8,945	12,500
					16	16	8,167	8,200
108	2	tansig - logsig - purelin	5	19	11	12	141	380
					12	11	1,039	170
					11	13	333	400
					13	12	42	460
					15	16	12,906	10,650
					16	17	8,892	12,500
					16	16	8,666	8,200
109	2	tansig - logsig - purelin	7	3	12	12	552	380
					12	11	336	170
					11	13	359	400
					13	12	2,476	460
					16	16	8,906	10,650
					16	17	9,315	12,500
					16	16	8,941	8,200

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
110	2	tansig - logsig - purelin	7	5	12	12	979	380
					12	11	871	170
					11	13	199	400
					12	12	1,990	460
					15	16	9,362	10,650
					16	17	9,978	12,500
					16	16	10,282	8,200
111	2	tansig - logsig - purelin	7	7	13	12	1,141	380
					11	11	3,088	170
					12	13	1,415	400
					11	12	-111	460
					16	16	9,762	10,650
					16	17	9,068	12,500
					16	16	7,036	8,200
112	2	tansig - logsig - purelin	7	9	12	12	825	380
					11	11	860	170
					11	13	637	400
					11	12	877	460
					16	16	7,979	10,650
					17	17	9,294	12,500
					17	16	7,442	8,200
113	2	tansig - logsig - purelin	7	11	12	12	825	380
					11	11	210	170
					10	13	56	400
					12	12	3,142	460
					16	16	10,725	10,650
					17	17	9,682	12,500
					16	16	8,975	8,200
114	2	tansig - logsig - purelin	7	13	12	12	999	380
					13	11	480	170
					11	13	-49	400
					13	12	451	460
					15	16	11,600	10,650
					17	17	10,454	12,500
					17	16	9,651	8,200

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
115	2	tansig - logsig - purelin	7	15	13	12	1,016	380
					13	11	730	170
					12	13	130	400
					12	12	-140	460
					17	16	9,363	10,650
					17	17	8,526	12,500
					16	16	8,536	8,200
116	2	tansig - logsig - purelin	7	17	12	12	953	380
					11	11	174	170
					12	13	241	400
					12	12	202	460
					15	16	11,339	10,650
					17	17	9,968	12,500
					17	16	9,623	8,200
117	2	tansig - logsig - purelin	7	19	11	12	418	380
					11	11	781	170
					11	13	559	400
					12	12	1,131	460
					16	16	12,816	10,650
					17	17	10,298	12,500
					16	16	8,873	8,200
118	2	tansig - logsig - purelin	13	3	12	12	760	380
					12	11	543	170
					12	13	764	400
					12	12	646	460
					16	16	9,941	10,650
					16	17	9,155	12,500
					16	16	7,886	8,200
119	2	tansig - logsig - purelin	13	5	12	12	535	380
					12	11	493	170
					12	13	1,039	400
					13	12	1,311	460
					16	16	8,636	10,650
					16	17	8,874	12,500
					16	16	8,658	8,200

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
120	2	tansig - logsig - purelin	13	7	14	12	6,257	380
					11	11	511	170
					11	13	553	400
					12	12	15	460
					15	16	8,280	10,650
					16	17	9,853	12,500
					16	16	8,946	8,200
121	2	tansig - logsig - purelin	13	9	12	12	598	380
					10	11	451	170
					12	13	1,448	400
					12	12	1,512	460
					16	16	11,449	10,650
					17	17	10,121	12,500
					16	16	8,782	8,200
122	2	tansig - logsig - purelin	13	11	12	12	285	380
					12	11	905	170
					10	13	753	400
					12	12	555	460
					16	16	9,462	10,650
					16	17	9,410	12,500
					16	16	6,512	8,200
123	2	tansig - logsig - purelin	13	13	12	12	1,775	380
					12	11	1,608	170
					13	13	946	400
					13	12	2,185	460
					14	16	7,565	10,650
					17	17	9,198	12,500
					16	16	10,072	8,200
124	2	tansig - logsig - purelin	13	15	12	12	554	380
					11	11	1,181	170
					12	13	885	400
					12	12	-3,098	460
					16	16	12,005	10,650
					17	17	10,236	12,500
					17	16	10,261	8,200

แบบจำลองที่	จำนวนชั้นซ่อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
125	2	tansig - logsig - purelin	13	17	13	12	1,656	380
					11	11	1,333	170
					12	13	207	400
					11	12	279	460
					16	16	10,223	10,650
					16	17	9,185	12,500
					16	16	8,356	8,200
126	2	tansig - logsig - purelin	13	19	12	12	1,049	380
					11	11	18	170
					10	13	-784	400
					13	12	421	460
					15	16	9,281	10,650
					17	17	8,731	12,500
					17	16	8,457	8,200
127	2	tansig - tansig - purelin	3	3	13	12	1,721	380
					12	11	399	170
					12	13	708	400
					12	12	547	460
					16	16	8,546	10,650
					16	17	9,493	12,500
					16	16	9,492	8,200
128	2	tansig - tansig - purelin	3	5	11	12	593	380
					12	11	417	170
					11	13	758	400
					12	12	413	460
					16	16	9,153	10,650
					16	17	8,832	12,500
					16	16	8,815	8,200
129	2	tansig - tansig - purelin	3	7	11	12	178	380
					12	11	433	170
					12	13	500	400
					12	12	557	460
					16	16	9,077	10,650
					16	17	8,794	12,500
					16	16	9,181	8,200

แบบจำลองที่	จำนวนชั้นซ้อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแจ้ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
130	2	tansig - tansig - purelin	3	9	11	12	452	380
					12	11	425	170
					11	13	-146	400
					12	12	-1,048	460
					16	16	9,595	10,650
					16	17	9,578	12,500
					16	16	9,816	8,200
131	2	tansig - tansig - purelin	3	11	11	12	1,500	380
					11	11	1,095	170
					12	13	811	400
					12	12	764	460
					16	16	9,513	10,650
					16	17	9,116	12,500
					16	16	5,460	8,200
132	2	tansig - tansig - purelin	3	13	11	12	689	380
					11	11	688	170
					12	13	328	400
					12	12	349	460
					15	16	6,483	10,650
					17	17	9,748	12,500
					17	16	9,404	8,200
133	2	tansig - tansig - purelin	3	15	11	12	323	380
					12	11	311	170
					11	13	239	400
					13	12	415	460
					16	16	10,779	10,650
					16	17	9,324	12,500
					16	16	9,940	8,200
134	2	tansig - tansig - purelin	3	17	12	12	-99	380
					12	11	19	170
					12	13	153	400
					13	12	32	460
					15	16	8,412	10,650
					17	17	11,294	12,500
					16	16	8,605	8,200

แบบจำลองที่	จำนวนชั้นซ้อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
135	2	tansig - tansig - purelin	3	19	11	12	139	380
					12	11	441	170
					12	13	316	400
					12	12	723	460
					16	16	8,567	10,650
					17	17	10,486	12,500
					16	16	9,038	8,200
136	2	tansig - tansig - purelin	5	3	11	12	139	380
					12	11	441	170
					12	13	316	400
					12	12	723	460
					16	16	8,567	10,650
					17	17	10,486	12,500
					16	16	9,038	8,200
137	2	tansig - tansig - purelin	5	5	12	12	297	380
					12	11	297	170
					12	13	304	400
					12	12	364	460
					16	16	8,633	10,650
					16	17	9,048	12,500
					17	16	9,947	8,200
138	2	tansig - tansig - purelin	5	7	11	12	576	380
					12	11	84	170
					12	13	12	400
					12	12	32	460
					16	16	8,717	10,650
					17	17	10,244	12,500
					16	16	8,117	8,200
139	2	tansig - tansig - purelin	5	9	11	12	188	380
					12	11	127	170
					11	13	176	400
					13	12	405	460
					16	16	7,129	10,650
					16	17	9,130	12,500
					16	16	7,782	8,200

แบบจำลองที่	จำนวนชั้นซ้อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
140	2	tansig - tansig - purelin	5	11	12	12	382	380
					13	11	-114	170
					11	13	676	400
					12	12	739	460
					16	16	9,575	10,650
					16	17	9,268	12,500
					17	16	9,807	8,200
141	2	tansig - tansig - purelin	5	13	12	12	1,927	380
					11	11	421	170
					11	13	-1,032	400
					12	12	575	460
					15	16	9,923	10,650
					16	17	8,291	12,500
					16	16	8,678	8,200
142	2	tansig - tansig - purelin	5	15	12	12	9	380
					11	11	-598	170
					11	13	371	400
					13	12	1,414	460
					16	16	9,450	10,650
					16	17	9,001	12,500
					16	16	8,647	8,200
143	2	tansig - tansig - purelin	5	17	10	12	830	380
					11	11	-144	170
					11	13	-22	400
					12	12	540	460
					16	16	8,938	10,650
					16	17	9,437	12,500
					16	16	8,192	8,200
144	2	tansig - tansig - purelin	5	19	11	12	-160	380
					12	11	507	170
					11	13	753	400
					13	12	2,204	460
					15	16	9,668	10,650
					16	17	11,384	12,500
					16	16	7,682	8,200

แบบจำลองที่	จำนวนชั้นซ้อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
145	2	tansig - tansig - purelin	7	3	12	12	782	380
					12	11	853	170
					12	13	1,053	400
					12	12	1,647	460
					16	16	9,535	10,650
					16	17	9,660	12,500
					16	16	9,515	8,200
146	2	tansig - tansig - purelin	7	5	11	12	549	380
					12	11	314	170
					11	13	306	400
					12	12	16	460
					16	16	8,624	10,650
					17	17	9,963	12,500
					16	16	7,051	8,200
147	2	tansig - tansig - purelin	7	7	12	12	407	380
					12	11	82	170
					11	13	663	400
					12	12	459	460
					15	16	9,955	10,650
					16	17	9,327	12,500
					15	16	7,371	8,200
148	2	tansig - tansig - purelin	7	9	11	12	590	380
					12	11	132	170
					12	13	395	400
					13	12	958	460
					15	16	9,880	10,650
					16	17	9,181	12,500
					16	16	9,121	8,200
149	2	tansig - tansig - purelin	7	11	12	12	653	380
					11	11	362	170
					11	13	-638	400
					12	12	663	460
					16	16	9,779	10,650
					16	17	9,296	12,500
					16	16	8,980	8,200

แบบจำลองที่	จำนวนชั้นซ้อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
150	2	tansig - tansig - purelin	7	13	11	12	170	380
					13	11	512	170
					11	13	1,621	400
					12	12	1,319	460
					15	16	10,457	10,650
					16	17	9,858	12,500
					16	16	9,471	8,200
151	2	tansig - tansig - purelin	7	15	11	12	443	380
					12	11	601	170
					11	13	1	400
					12	12	953	460
					16	16	11,220	10,650
					17	17	10,431	12,500
					16	16	6,880	8,200
152	2	tansig - tansig - purelin	7	17	11	12	448	380
					11	11	-533	170
					11	13	405	400
					12	12	-750	460
					15	16	11,046	10,650
					16	17	9,259	12,500
					16	16	6,985	8,200
153	2	tansig - tansig - purelin	7	19	12	12	2,105	380
					11	11	1,445	170
					12	13	1,022	400
					11	12	410	460
					15	16	8,280	10,650
					16	17	8,976	12,500
					16	16	10,519	8,200
154	2	tansig - tansig - purelin	13	3	11	12	208	380
					11	11	20	170
					11	13	382	400
					11	12	-1,289	460
					17	16	11,398	10,650
					17	17	11,497	12,500
					17	16	9,266	8,200

แบบจำลองที่	จำนวนชั้นซ้อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
155	2	tansig - tansig - purelin	13	5	11	12	1,143	380
					12	11	2,586	170
					12	13	1,146	400
					12	12	1,392	460
					16	16	9,084	10,650
					16	17	7,944	12,500
					16	16	8,071	8,200
156	2	tansig - tansig - purelin	13	7	12	12	988	380
					12	11	881	170
					11	13	698	400
					13	12	1,400	460
					15	16	9,307	10,650
					15	17	7,391	12,500
					16	16	8,307	8,200
157	2	tansig - tansig - purelin	13	9	11	12	794	380
					12	11	446	170
					12	13	431	400
					12	12	-306	460
					16	16	11,347	10,650
					17	17	9,976	12,500
					16	16	8,992	8,200
158	2	tansig - tansig - purelin	13	11	12	12	602	380
					12	11	689	170
					11	13	-3,259	400
					11	12	-28	460
					17	16	9,727	10,650
					17	17	9,831	12,500
					18	16	8,910	8,200
159	2	tansig - tansig - purelin	13	13	12	12	410	380
					13	11	637	170
					11	13	430	400
					12	12	379	460
					15	16	8,533	10,650
					17	17	9,023	12,500
					16	16	6,977	8,200

แบบจำลองที่	จำนวนชั้นซ้อน	ฟังก์ชันกระตุ้น	จำนวนนิวรัลโนดในชั้นซ่อนที่ 1	จำนวนนิวรัลโนดในชั้นซ่อนที่ 2	เปอร์เซ็นต์ของแข็ง		ความหนืด	
					ผลจากการทำนาย (%)	ผลจากการทดลอง (%)	ผลจากการทำนาย (cp)	ผลจากการทดลอง (cp)
160	2	tansig - tansig - purelin	13	15	14	12	1,274	380
					13	11	362	170
					12	13	1,243	400
					12	12	863	460
					16	16	10,568	10,650
					17	17	9,065	12,500
					17	16	8,505	8,200
161	2	tansig - tansig - purelin	13	17	13	12	-467	380
					10	11	532	170
					11	13	327	400
					11	12	73	460
					16	16	9,224	10,650
					16	17	8,764	12,500
					17	16	8,597	8,200
162	2	tansig - tansig - purelin	13	19	12	12	2,479	380
					11	11	1,383	170
					14	13	3,397	400
					14	12	1,554	460
					15	16	8,864	10,650
					15	17	9,806	12,500
					18	16	5,641	8,200

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

ภาคผนวก ข

ค่าดัชนี RMSP, MP และสมรรถนะความถูกต้อง (Accuracy Performance) ของข่ายงานนิวัต

ตารางที่ ข.1 แสดงค่าดัชนีความผิดพลาด RMSP, MP และสมรรถนะความถูกต้องในการทำนาย (Accuracy Performance) ของแบบจำลองทั้งหมด 162 ข่ายงาน

แบบจำลอง ที่	Model	เปอร์เซ็นต์ของแข็ง		ความหนืด		สมรรถนะความถูกต้อง (Accuracy Performance) (%)
		RMSP (%)	MP (%)	RMSP (%)	MP (%)	
1	Model Log 3	4.66	0.83	19.07	97.83	69.40
2	Model Log 5	5.39	8.33	21.12	143.00	55.54
3	Model Log 7	5.39	8.33	19.60	367.06	-0.09
4	Model Log 9	6.60	1.18	18.47	160.00	53.44
5	Model Log 11	6.60	1.18	24.87	1309.41	-235.51
6	Model Log 13	4.66	8.33	12.18	232.35	35.62
7	Model Log 15	7.62	8.33	19.37	88.82	68.96
8	Model Log 17	8.52	8.33	18.99	154.13	52.51
9	Model Log 19	7.62	1.18	30.27	1071.18	-177.56
10	Model Tan 3	3.81	0.59	18.58	100.00	69.25
11	Model Tan 5	5.39	8.33	19.28	321.18	11.46
12	Model Tan 7	6.02	8.33	9.66	110.43	66.39
13	Model Tan 9	7.12	1.18	21.16	102.94	66.90
14	Model Tan 11	10.08	8.33	28.84	681.18	-82.11
15	Model Tan 13	6.02	8.33	21.70	559.41	-48.87
16	Model Tan 15	6.02	1.18	21.25	350.00	5.39
17	Model Tan 17	7.62	8.33	20.94	175.88	46.81
18	Model Tan 19	6.60	16.67	40.90	741.58	-101.43
19	Model Log-Log 3/3	5.39	0.83	29.92	114.12	62.44
20	Model Log-Log 3/5	7.12	8.33	15.18	77.06	73.08
21	Model Log-Log 3/7	3.81	0.83	11.97	79.74	75.92

แบบจำลอง ที่	Model	เปอร์เซ็นต์ของแข็ง		ความหนืด		สมรรถนะความถูกต้อง (Accuracy Performance) (%)
		RMSP (%)	MP (%)	RMSP (%)	MP (%)	
22	Model Log-Log 3/9	4.66	8.33	18.95	518.82	-37.69
23	Model Log-Log 3/11	3.81	0.83	14.07	683.53	-75.56
24	Model Log-Log 3/15	7.12	8.33	16.88	88.82	69.71
25	Model Log-Log 3/17	5.39	8.33	16.60	389.41	-4.93
26	Model Log-Log 3/17	4.66	8.33	16.15	60.43	77.60
27	Model Log-Log 3/19	5.39	8.33	17.33	251.76	29.30
28	Model Log-Log 5/3	4.66	0.83	16.12	235.88	35.63
29	Model Log-Log 5/5	6.60	0.83	17.80	226.32	37.12
30	Model Log-Log 5/7	9.71	1.65	32.93	396.00	-10.07
31	Model Log-Log 5/9	4.66	8.33	19.28	338.24	7.37
32	Model Log-Log 5/11	5.39	8.33	23.34	874.71	-127.94
33	Model Log-Log 5/13	8.08	8.33	27.78	323.42	8.10
34	Model Log-Log 5/15	5.39	8.33	29.00	190.59	41.67
35	Model Log-Log 5/17	7.12	8.33	19.54	501.74	-34.18
36	Model Log-Log 5/19	4.66	8.33	17.99	345.88	5.78
37	Model Log-Log 9/3	4.66	0.83	19.51	121.18	63.46
38	Model Log-Log 9/5	4.66	0.83	19.87	134.50	60.04
39	Model Log-Log 9/7	5.39	0.83	25.86	177.65	47.57
40	Model Log-Log 9/9	8.52	8.33	28.60	2260.00	-476.36
41	Model Log-Log 9/11	6.02	1.18	18.34	385.26	-2.70
42	Model Log-Log 9/13	8.08	8.33	15.23	385.88	-4.38
43	Model Log-Log 9/15	5.39	0.83	21.96	554.71	-45.72
44	Model Log-Log 9/17	7.62	8.33	26.69	1272.35	-228.75
45	Model Log-Log 9/19	9.33	16.67	19.29	572.94	-54.56
46	Model Log-Log 13/3	4.66	0.83	18.83	247.65	32.01
47	Model Log-Log 13/5	6.02	1.18	26.82	222.94	35.76

แบบจำลอง ที่	Model	เปอร์เซ็นต์ของแข็ง		ความหนืด		สมรรถนะความถูกต้อง (Accuracy Performance) (%)
		RMSP (%)	MP (%)	RMSP (%)	MP (%)	
48	Model Log-Log 13/7	7.62	8.33	34.02	1026.47	-169.11
49	Model Log-Log 13/9	8.52	1.65	20.71	682.94	-78.46
50	Model Log-Log 13/11	7.62	1.39	16.75	399.41	-6.29
51	Model Log-Log 13/13	10.08	8.33	21.25	278.82	20.38
52	Model Log-Log 13/15	3.81	0.83	24.66	198.82	42.97
53	Model Log-Log 13/17	7.12	1.18	23.58	229.41	34.68
54	Model Log-Log 13/19	10.77	8.33	33.06	1278.24	-232.60
55	Model Log-Tan 3/3	5.39	8.33	28.10	99.57	64.65
56	Model Log-Tan 3/5	6.02	0.83	18.35	277.06	24.44
57	Model Log-Tan 3/7	8.93	8.33	16.59	709.41	-85.82
58	Model Log-Tan 3/11	5.39	8.33	17.36	346.47	5.61
59	Model Log-Tan 3/11	7.12	8.33	17.66	189.35	44.38
60	Model Log-Tan 3/13	5.39	8.33	21.77	137.65	56.72
61	Model Log-Tan 3/15	5.39	8.33	20.84	85.79	69.91
62	Model Log-Tan 3/17	8.08	8.33	29.20	898.42	-136.01
63	Model Log-Tan 3/19	6.02	1.18	25.49	224.71	35.65
64	Model Log-Tan 5/3	8.08	8.33	30.67	91.74	65.30
65	Model Log-Tan 5/5	6.02	8.33	24.27	694.12	-83.19
66	Model Log-Tan 5/7	10.08	8.33	14.67	338.82	7.02
67	Model Log-Tan 5/9	9.71	8.33	15.73	42.83	80.85
68	Model Log-Tan 5/11	3.81	8.33	16.67	682.35	-77.79
69	Model Log-Tan 5/13	9.33	8.33	41.97	283.16	14.30
70	Model Log-Tan 5/15	8.08	1.65	20.84	1135.29	-191.47
71	Model Log-Tan 5/17	6.60	8.33	22.11	554.71	-47.94
72	Model Log-Tan 5/19	5.39	0.83	27.92	471.09	-26.30
73	Model Log-Tan 9/3	6.60	1.18	22.56	571.32	-50.41

แบบจำลอง ที่	Model	เปอร์เซ็นต์ของแข็ง		ความหนืด		สมรรถนะความถูกต้อง (Accuracy Performance) (%)
		RMSP (%)	MP (%)	RMSP (%)	MP (%)	
74	Model Log-Tan 9/5	4.66	8.33	13.93	91.76	70.33
75	Model Log-Tan 9/7	8.52	8.33	23.79	783.53	-106.04
76	Model Log-Tan 9/9	4.66	0.83	17.02	238.24	34.81
77	Model Log-Tan 9/11	7.12	8.33	27.17	460.00	-25.66
78	Model Log-Tan 9/13	11.42	16.67	16.21	308.82	11.72
79	Model Log-Tan 9/15	6.60	1.18	20.52	495.29	-30.90
80	Model Log-Tan 9/17	7.12	0.83	31.95	1139.47	-194.84
81	Model Log-Tan 9/19	9.33	1.17	42.58	1508.24	-290.33
82	Model Log-Tan 13/3	4.66	0.83	17.81	344.12	8.15
83	Model Log-Tan 13/5	4.66	0.83	16.98	313.53	16.00
84	Model Log-Tan 13/7	7.12	1.18	22.16	781.18	-102.91
85	Model Log-Tan 13/11	3.81	0.83	20.33	171.76	50.82
86	Model Log-Tan 13/11	7.62	1.65	16.82	442.35	-17.11
87	Model Log-Tan 13/13	12.63	8.33	24.09	500.59	-36.41
88	Model Log-Tan 13/15	9.33	8.33	47.66	265.88	17.20
89	Model Log-Tan 13/17	6.60	16.67	28.91	609.41	-65.40
90	Model Log-Tan 13/19	5.39	1.18	21.01	941.18	-142.19
91	Model Tan-Log 3/3	5.39	0.83	29.33	326.00	9.62
92	Model Tan-Log 3/5	4.66	0.83	21.14	100.59	68.19
93	Model Tan-Log 3/7	6.60	1.18	29.42	313.91	12.22
94	Model Tan-Log 3/9	8.52	8.33	24.85	388.24	-7.48
95	Model Tan-Log 3/11	8.08	0.83	39.11	369.50	-4.38
96	Model Tan-Log 3/13	6.60	1.65	11.63	345.88	8.56
97	Model Tan-Log 3/15	5.39	8.33	18.41	225.29	35.64
98	Model Tan-Log 3/17	4.66	0.83	23.62	321.25	12.41
99	Model Tan-Log 3/19	4.66	0.83	18.95	257.06	29.62

แบบจำลอง ที่	Model	เปอร์เซ็นต์ของแข็ง		ความหนืด		สมรรถนะความถูกต้อง (Accuracy Performance) (%)
		RMSP (%)	MP (%)	RMSP (%)	MP (%)	
100	Model Tan-Log 5/3	4.66	0.83	16.45	189.41	47.16
101	Model Tan-Log 5/5	6.02	1.18	23.46	307.06	15.57
102	Model Tan-Log 5/7	4.66	8.33	13.71	238.82	33.62
103	Model Tan-Log 5/9	8.08	8.33	18.21	526.47	-40.27
104	Model Tan-Log 5/11	7.12	8.33	17.94	227.00	34.90
105	Model Tan-Log 5/13	7.12	8.33	17.01	183.16	46.09
106	Model Tan-Log 5/15	5.39	8.33	19.07	416.30	-12.27
107	Model Tan-Log 5/15	6.60	1.18	20.82	158.95	53.11
108	Model Tan-Log 5/19	8.08	8.33	23.92	511.18	-37.88
109	Model Tan-Log 7/3	7.12	1.18	23.00	438.26	-17.39
110	Model Tan-Log 7/5	7.12	1.18	21.49	412.35	-10.54
111	Model Tan-Log 7/7	5.39	8.33	26.87	1716.47	-339.27
112	Model Tan-Log 7/9	6.60	1.18	23.66	405.88	-9.33
113	Model Tan-Log 7/11	8.08	1.78	21.81	583.04	-53.68
114	Model Tan-Log 7/13	8.93	1.65	15.28	182.35	47.95
115	Model Tan-Log 7/15	7.12	8.33	23.55	329.41	7.90
116	Model Tan-Log 7/17	4.66	0.59	16.63	150.79	56.83
117	Model Tan-Log 7/19	6.02	8.33	17.93	359.41	2.08
118	Model Tan-Log 13/3	4.66	0.83	19.05	219.41	39.01
119	Model Tan-Log 13/5	5.39	0.83	23.52	190.00	45.07
120	Model Tan-Log 13/7	8.52	16.67	37.74	1546.58	-302.37
121	Model Tan-Log 13/9	3.81	0.83	16.30	262.00	29.27
122	Model Tan-Log 13/11	8.93	1.78	20.72	432.35	-15.95
123	Model Tan-Log 13/13	6.60	0.83	30.41	845.88	-120.93
124	Model Tan-Log 13/15	3.81	0.59	27.30	773.48	-101.30
125	Model Tan-Log 13/17	5.39	8.33	20.55	684.12	-79.60

แบบจำลอง ที่	Model	เปอร์เซ็นต์ของแข็ง		ความหนืด		สมรรถนะความถูกต้อง (Accuracy Performance) (%)
		RMSP (%)	MP (%)	RMSP (%)	MP (%)	
126	Model Tan-Log 13/19	9.33	1.78	23.11	296.00	17.45
127	Model Tan-Tan 3/3	5.39	8.33	22.50	352.89	2.72
128	Model Tan-Tan 3/5	7.12	8.33	21.98	145.29	54.32
129	Model Tan-Tan 3/7	5.39	8.33	22.64	154.71	52.23
130	Model Tan-Tan 3/9	7.12	8.33	21.02	327.83	8.92
131	Model Tan-Tan 3/11	4.66	8.33	25.89	544.12	-45.75
132	Model Tan-Tan 3/13	5.39	8.33	28.16	304.71	13.35
133	Model Tan-Tan 3/15	7.62	8.33	19.76	82.94	70.34
134	Model Tan-Tan 3/17	5.39	0.83	14.53	126.05	63.30
135	Model Tan-Tan 3/19	4.66	8.33	16.61	159.41	52.75
136	Model Tan-Tan 5/3	4.66	8.33	16.61	159.41	52.75
137	Model Tan-Tan 5/5	5.39	0.83	23.78	74.71	73.83
138	Model Tan-Tan 5/7	4.66	8.33	16.52	97.00	68.37
139	Model Tan-Tan 5/9	7.62	8.33	26.68	56.00	75.34
140	Model Tan-Tan 5/11	8.52	1.65	20.67	167.06	50.53
141	Model Tan-Tan 5/13	6.60	1.18	26.10	407.11	-10.25
142	Model Tan-Tan 5/15	6.60	1.18	21.45	451.76	-20.25
143	Model Tan-Tan 5/17	8.08	16.67	19.47	184.71	42.77
144	Model Tan-Tan 5/19	8.08	8.33	13.39	379.13	-2.23
145	Model Tan-Tan 7/3	4.66	0.83	20.00	401.76	-6.81
146	Model Tan-Tan 7/5	6.60	8.33	18.95	96.52	67.40
147	Model Tan-Tan 7/7	7.62	1.18	18.31	65.75	76.78
148	Model Tan-Tan 7/9	6.60	8.33	19.44	108.26	64.34
149	Model Tan-Tan 7/11	6.02	1.18	19.52	259.50	28.44
150	Model Tan-Tan 7/13	8.93	8.33	18.07	305.25	14.85
151	Model Tan-Tan 7/15	6.60	8.33	14.34	253.53	29.30

แบบจำลอง ที่	Model	เปอร์เซ็นต์ของแข็ง		ความหนืด		สมรรถนะความถูกต้อง (Accuracy Performance) (%)
		RMSP (%)	MP (%)	RMSP (%)	MP (%)	
152	Model Tan-Tan 7/17	7.12	8.33	20.44	413.53	-12.36
153	Model Tan-Tan 7/19	5.39	0.69	29.01	750.00	-96.27
154	Model Tan-Tan 13/3	7.62	8.33	13.13	380.22	-2.32
155	Model Tan-Tan 13/5	5.39	8.33	30.34	1421.18	-266.31
156	Model Tan-Tan 13/7	8.93	1.18	29.70	418.24	-14.51
157	Model Tan-Tan 13/9	4.66	8.33	15.70	166.52	51.19
158	Model Tan-Tan 13/11	8.93	1.18	25.78	914.75	-137.66
159	Model Tan-Tan 13/13	8.08	1.65	23.28	274.71	23.07
160	Model Tan-Tan 13/15	8.52	16.67	20.08	235.26	29.87
161	Model Tan-Tan 13/17	8.08	8.33	22.55	222.89	34.54
162	Model Tan-Tan 13/19	10.08	1.39	31.30	749.25	-98.00

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

ประวัติผู้เขียนวิทยานิพนธ์

นางสาว วิไลรัตน์ แซ่หยาง เกิดเมื่อวันที่ 31 สิงหาคม 2520 สำเร็จการศึกษาระดับปริญญาวิศวกรรมศาสตรบัณฑิต สาขาวิชาวิศวกรรมเคมี ภาควิชาวิศวกรรมเคมี คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี เมื่อปีการศึกษา 2541 และเข้าศึกษาต่อในหลักสูตรวิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมเคมี ภาควิชาวิศวกรรมเคมี จุฬาลงกรณ์มหาวิทยาลัย ภาคนอกเวลาราชการ ในปีการศึกษา 2544 ปัจจุบันทำงานที่บริษัท ยีอี วอเตอร์ แอนด์ โพรเซส เทคโนโลยีส์ (ประเทศไทย) จำกัด ในตำแหน่งผู้จัดการผลิตภัณฑ์



สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย