

การสร้างแบบจำลองและการออกแบบตัวควบคุมแบบข่ายงานนิวรัล
ของตัวย่อยเยื่อกระดาษ



นางสาว รदानุช วิเศษสรไพค์


สถาบันวิทยบริการ
วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมเคมี ภาควิชาวิศวกรรมเคมี
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2544

ISBN 974-03-1365-5

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

NEURAL NETWORK MODELING AND CONTROLLER DESIGN OF PULP DIGESTER



Miss Radanuch Visessonchok

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

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

Department of Chemical Engineering

Faculty of Engineering

Chulalongkorn University

Academic Year 2001

ISBN 974-03-1365-5

หัวข้อวิทยานิพนธ์	การสร้างแบบจำลองและการออกแบบตัวควบคุมแบบข่ายงานนิวรัลของตัวย่อย เยื่อกระดาษ
โดย	นางสาว รศานุช วิเศษสรไพศ
สาขาวิชา	วิศวกรรมเคมี
อาจารย์ที่ปรึกษา	อาจารย์ ดร.มนตรี วงศ์ศรี

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้บัณฑิตวิทยาลัยรับนี้เป็นส่วน
หนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต

..... คณบดีคณะวิศวกรรมศาสตร์
(ศาสตราจารย์ ดร.สมศักดิ์ ปัญญาแก้ว)

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ
(ศาสตราจารย์ ดร.ปิยะสาร ประเสริฐธรรม)

..... อาจารย์ที่ปรึกษา
(อาจารย์ ดร.มนตรี วงศ์ศรี)

..... กรรมการ
(รองศาสตราจารย์ ดร.ไพศาล กิตติศุภกร)

..... กรรมการ
(อาจารย์ ดร.เหมื่อนเดือน พิศาลพงศ์)

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

##4170472221 :MAJOR CHEMICAL ENGINEERING

KEYWORD : NEURAL NETWORK / MODELING / CONTROLLER

RADANUCH VISESSONCHOK : NEURAL NETWORK MODELING AND CONTROLLER

DESIGN OF PULP DIGESTER.THESIS ADVISOR : DR.MONTREE WONGSRI,

D.Sc,105 pp. ISBN 974-03-1365-5

In this research, the application of recurrent multilayered feed forward neural networks for estimation, modeling and control for pulp digester is studied. Error Back Propagation algorithms are used to train the networks.

For estimation, the neural networks are trained with simulated data of pulp digester to estimate Kappa number, controlled variable which is not on-line measurable. It is shown the estimator gives good estimation.Except for the case of 50% decreasing of certain activation energy parameters.

For control, the neural networks are trained to learn the forward and the inverse model of the pulp digester. The first model is used to simulate the process model and second model is used as an internal model controller (IMC). The results of using neural network estimator with neural network controller are shown that the controller can control the Kappa number at its set point with cooking time with good performance, including the error of initial estimations, feed stock and parameter changing occur. However controller is quite sensitive to some model parameter errors.

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

Department.....Chemical Engineering.... Student's signature.....

Field of study.....Chemical Engineering..... Advisor's signature.....

Academic year....2001.....

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลงได้ เนื่องจากได้รับความกรุณาจากอาจารย์ ดร. มนต์รี วงศ์ศรี ที่ได้ให้เกียรติเป็นอาจารย์ที่ปรึกษา ตลอดจนให้คำแนะนำแนวทางและข้อคิดเห็นต่าง ๆ แก่ข้าพเจ้า ตลอดมา ข้าพเจ้ารู้สึกซาบซึ้ง และขอกราบขอบพระคุณเป็นอย่างสูง

ขอกราบขอบพระคุณ ศาสตราจารย์ ดร.ปิยะसार ประเสริฐธรรม รองศาสตราจารย์ ดร.ไพศาล กิตติศุภกร และอาจารย์ ดร. เหมือนเดือน พิศาลพงศ์ ที่กรุณามาร่วมเป็นกรรมการสอบวิทยานิพนธ์ซึ่งได้ให้ความสนใจและให้ข้อคิดที่เป็นประโยชน์เพิ่มเติมต่องานวิจัยฉบับนี้

ขอกราบขอบพระคุณคณาจารย์ทุกท่านที่ได้ประสาทความรู้ให้แก่ข้าพเจ้าตลอดระยะเวลาของการศึกษาจนกระทั่งข้าพเจ้ามีโอกาสประสบความสำเร็จ

ขอขอบคุณพี่ๆ เพื่อนๆ และน้องๆ สมาชิกห้องควบคุมกระบวนการทุกท่านที่ให้คำแนะนำ ความช่วยเหลือและเป็นกำลังใจที่ดีตลอดมา

ขอขอบคุณเพื่อนทุกคนและคุณปรีดา ศิลป์วิทยารักษ์ ที่ให้คำปรึกษา แง่คิด ความช่วยเหลือในด้านต่างๆ และคอยเป็นกำลังใจที่สำคัญมาโดยตลอด รวมถึงบุคคลที่ผู้วิจัยไม่ได้กล่าวไว้ในที่นี้ ที่ให้การสนับสนุนตลอดจนให้ความช่วยเหลือในด้านต่าง ๆ แก่ผู้วิจัยเสมอมา

สุดท้ายนี้ขอกราบขอบพระคุณบิดา มารดา และทุกคนในครอบครัววิเศษสรวิโชค ที่ให้การสนับสนุน และเป็นกำลังใจมาตลอดจนสำเร็จการศึกษา

คุณค่าและประโยชน์อันพึงมีจากวิทยานิพนธ์ฉบับนี้ ผู้วิจัยขอมอบแด่ผู้มีพระคุณทุกท่าน

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

สารบัญ

หน้า

บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ.....	ช
สารบัญภาพ.....	ญ
สารบัญตาราง.....	ฐ
คำอธิบายสัญลักษณ์.....	ฑ

บทที่

1 บทนำ.....	1
1.1 ความสำคัญและที่มาของงานวิจัย.....	1
1.2 วัตถุประสงค์ของงานวิจัย.....	2
1.3 ขอบเขตของงานวิจัย.....	2
1.4 ขั้นตอนและวิธีการดำเนินการงานวิจัย.....	2
1.5 ประโยชน์ที่คาดว่าจะได้รับ.....	3
1.6 เนื้อหาวิทยานิพนธ์.....	3
2 ผลงานวิจัยที่ผ่านมา.....	4
2.1 ที่มาและผลงานทางด้านช่างงานนิเวศ.....	4
2.2 ผลงานทางด้านช่างงานนิเวศในวิศวกรรมเคมี.....	5
2.3 ผลงานที่เกี่ยวข้องกับงานวิจัย.....	7
3 ทฤษฎีเกี่ยวกับช่างงานนิเวศ.....	8
3.1 ชีวิตวิทยาของช่างงานนิเวศและแบบจำลองของช่างงานนิเวศในยุคแรกๆ.....	8
3.2 แบบจำลองของช่างงานนิเวศในปัจจุบัน.....	10
3.2.1 องค์ประกอบและหน้าที่ของนิเวศ.....	10
3.2.2 พารามิเตอร์ที่สำคัญต่อการทำงานของนิเวศ.....	11
3.2.2.1 น้ำหนัก.....	11
3.2.2.2 ฟังก์ชันมูลฐาน.....	11
3.2.2.3 ฟังก์ชันกระตุ้น.....	12
3.2.2.4 ฟังก์ชันความผิดพลาด.....	13

สารบัญ (ต่อ)

หน้า

3.3 การออกแบบข่ายงานนิเวศ.....	15
3.3.1 ข้อมูลที่ใช้ในการฝึกข่ายงาน.....	16
3.3.2 โครงสร้างของข่ายงานนิเวศ.....	16
3.3.2.1 การเชื่อมโยงน้ำหนักของข่ายงานนิเวศ.....	19
3.3.2.2 การจำแนกการเรียนรู้ของข่ายงานนิเวศ.....	19
3.3.3 ข่ายงานนิเวศแบบมีการชี้แนะ.....	21
3.3.3.1 การเรียนรู้แบบเปอร์เซปตรอน.....	22
3.3.3.2 การเรียนรู้แบบเดลตา.....	23
3.3.3.3 ข่ายงานนิเวศแบบกระจายความผิดพลาดย้อนกลับ.....	24
3.3.4 แบบจำลองของกระบวนการข่ายงานนิเวศ.....	37
3.4 บทสรุป.....	39
4 โครงสร้างของแบบจำลองและโครงสร้างของตัวควบคุม.....	40
4.1 โครงสร้างของแบบจำลอง.....	40
4.1.1 โครงสร้างของแบบจำลองกระบวนการ.....	40
4.1.2 โครงสร้างของแบบจำลองผกผันโดยตรง.....	41
4.1.3 โครงสร้างของแบบจำลองแบบผกผันโดยทางอ้อม.....	43
4.1.4 โครงสร้างของแบบจำลองโอบะเรเตอร์.....	43
4.2 โครงสร้างของตัวควบคุมแบบนิเวศ.....	45
4.2.1 โครงสร้างของการควบคุมแบบมีการชี้แนะ.....	45
4.2.2 โครงสร้างของการควบคุมแบบผกผันโดยตรง.....	45
4.2.3 โครงสร้างของการควบคุมแบบนิเวศอะแดปทีฟ.....	45
5 กระบวนการที่ใช้ในการศึกษา.....	48
5.1 ตัวอย่างเยื่อกระดาษ.....	48
5.2 แบบจำลองทางคณิตศาสตร์ของกระบวนการ.....	49
5.3 การปรับค่าพารามิเตอร์เพื่อใช้ในงานวิจัย.....	54
6 การทดลอง ผลการทดลองและวิเคราะห์ผลการทดลอง.....	59
6.1 การซิมูเลทกระบวนการ.....	59
6.2 การออกแบบแบบจำลองข่ายงานนิเวศ.....	59
6.2.1 แบบจำลองข่ายงานนิเวศของตัวประมาณค่า.....	60

สารบัญ (ต่อ)

หน้า

6.2.2	แบบจำลองข่ายงานนิวรัลของกระบวนการ.....	64
6.3	การออกแบบตัวควบคุม.....	68
6.4	ผลการประมาณค่าและควบคุม.....	71
6.5	ผลการทดสอบตัวประมาณค่าและตัวควบคุม.....	72
6.5.1	กรณีที่ค่าของสารป้อนของกระบวนการผิดพลาด.....	72
6.5.2	กรณีเมื่อพารามิเตอร์ของแบบจำลองของกระบวนการผิดพลาด.....	77
6.6	วิเคราะห์ผลการทดลอง.....	85
6.6.1	การออกแบบแบบจำลองข่ายงานนิวรัล.....	85
6.6.1.1	แบบจำลองข่ายงานนิวรัลของตัวประมาณค่า.....	85
6.6.1.2	แบบจำลองข่ายงานนิวรัลของกระบวนการ.....	85
6.6.2	การออกแบบตัวควบคุมด้วยข่ายงานนิวรัล.....	85
6.6.3	ผลการประมาณค่าและควบคุม.....	86
6.6.4	ผลการทดสอบตัวประมาณค่าและตัวควบคุม.....	86
6.6.4.1	กรณีที่ค่าของสารป้อนของกระบวนการผิดพลาด.....	86
6.6.4.2	กรณีเมื่อพารามิเตอร์ของแบบจำลองของกระบวนการผิดพลาด.....	86
7	สรุปผลการวิจัยและเสนอแนะ.....	87
7.1	สรุปผลการวิจัย.....	87
7.2	บทสรุป.....	88
7.3	ข้อเสนอแนะ.....	88
	รายการอ้างอิง.....	89 ภาค
	ผนวก.....	93
	ภาคผนวก ก โปรแกรมแม่ทแลบ.....	94
	ภาคผนวก ข ตัวควบคุมแบบป้อนกลับแบบพีไอ.....	97
	ภาคผนวก ค ตัวอย่างโปรแกรมที่สำคัญ.....	100
	ประวัติผู้เขียน.....	105

สารบัญภาพ

หน้า

รูปที่ 3.1 โครงสร้างของเซลล์ประสาท.....	9
รูปที่ 3.2 แบบจำลองการทำงานของนิวรอนเสนอโดย Mcculloh และ Pitts.....	9
รูปที่ 3.3 หน้าที่และการทำงานของนิวรอน.....	10
รูปที่ 3.4 ฟังก์ชันมูลฐาน.....	12
รูปที่ 3.5 ฟังก์ชันกระตุ้นเชิงเส้น.....	14
รูปที่ 3.6 ฟังก์ชันกระตุ้นแบบไม่เชิงเส้น.....	15
รูปที่ 3.7 องค์ประกอบของอินพุทเวกเตอร์ของแบบจำลอง.....	18
รูปที่ 3.8 องค์ประกอบของอินพุทเวกเตอร์ของแบบจำลองผกผัน.....	18
รูปที่ 3.9 โครงสร้างพื้นฐานของข่ายงานนิวรัลที่แสดงการเชื่อมโยงแบบต่างๆ.....	19
รูปที่ 3.10 การเรียนรู้ของข่ายงานนิวรัลในการปรับค่าน้ำหนัก.....	20
รูปที่ 3.11 การจำแนกข่ายงานนิวรัลตามการเรียนรู้.....	21
รูปที่ 3.12 ข่ายงานการเรียนรู้แบบเปอร์เซปตรอน.....	22
รูปที่ 3.13 การปรับหาขอบเขตแยกข้อมูล 2 ประเภทโดยข่ายงานเปอร์เซปตรอนเชิงเส้น.....	23
รูปที่ 3.14 ข่ายงานการเรียนรู้แบบเดลตา.....	24
รูปที่ 3.15 แบบจำลองของนิวรอนในชั้นที่ i	25
รูปที่ 3.16 การเรียนรู้แบบการกระจายความผิดพลาดย้อนกลับที่มีการรวมค่าแฟกเตอร์.....	33
รูปที่ 3.17 ขั้นตอนการเรียนรู้ของข่ายงานนิวรัล.....	34
รูปที่ 3.18 แบบจำลองแบบไม่กลับกระแส.....	38
รูปที่ 3.19 แบบจำลองแบบกลับกระแส.....	38
รูปที่ 4.1 โครงสร้างการเรียนรู้ของแบบจำลองกระบวนการ.....	42
รูปที่ 4.2 โครงสร้างการเรียนรู้ของแบบจำลองแบบผกผันโดยตรง.....	42
รูปที่ 4.3 โครงสร้างการเรียนรู้ของแบบจำลองแบบผกผันโดยทางอ้อม.....	44
รูปที่ 4.4 โครงสร้างการเรียนรู้ของแบบจำลองโอบิเรเตอร์.....	44
รูปที่ 4.5 โครงสร้างการควบคุมแบบผกผันโดยตรง.....	46
รูปที่ 4.6 โครงสร้างการควบคุมแบบนิวรัลอะแดปทีฟแบบเชิงเส้น.....	47
รูปที่ 4.5 โครงสร้างการควบคุมแบบนิวรัลอะแดปทีฟแบบไม่เชิงเส้น.....	47
รูปที่ 5.1 ตัวอย่างเยื่อกระดาษแบบกะ.....	48
รูปที่ 5.2 ผลของกระบวนการเมื่อใช้พารามิเตอร์ทุกค่าของ Lee และ Datta (1994).....	56

สารบัญญภาพ (ต่อ)

หน้า

รูปที่ 5.3 ผลของกระบวนการเมื่อปรับค่าพลังงานกระตุ้นอันดับหนึ่งขององค์ประกอบที่ 1 ของไม้ (E_{11}) เป็น $10.5e3$ kcal/kmol.....	57
รูปที่ 5.4 ผลของกระบวนการเมื่อปรับค่าพลังงานกระตุ้นอันดับหนึ่งขององค์ประกอบที่ 1 ของไม้ (E_{11}) เป็น $2.4e3$ kcal/kmol.....	58
รูปที่ 6.1 ข้อมูลอินพุท-เอาต์พุทในการฝึกข่ายงานของตัวประมาณค่า.....	61
รูปที่ 6.2 ข้อมูลอินพุท-เอาต์พุทในการทดสอบข่ายงานของตัวประมาณค่า.....	62
รูปที่ 6.3 ข้อมูลอินพุท-เอาต์พุทในการฝึกข่ายงานของแบบจำลองของกระบวนการ.....	65
รูปที่ 6.4 ข้อมูลอินพุท-เอาต์พุทในการทดสอบข่ายงานของแบบจำลองของกระบวนการ.....	66
รูปที่ 6.5 โครงสร้างโดยทั่วไปของการควบคุมแบบเอ็นไอเอ็มซี.....	68
รูปที่ 6.6 แผนภาพโครงสร้างรวมของการควบคุมกระบวนการย่อยเยื่อกระดาษแบบกะ.....	69
รูปที่ 6.7 โครงสร้างของตัวควบคุมที่ออกแบบสำหรับงานวิจัย.....	69
รูปที่ 6.8 โครงสร้างการควบคุมของตัวควบคุมพีไอ.....	70
รูปที่ 6.9 โครงสร้างของตัวควบคุมพีไอ.....	70
รูปที่ 6.10 ผลการประมาณค่าและควบคุมของตัวประมาณค่าข่ายงานนิวรัลร่วมกับ ตัวควบคุมข่ายงานนิวรัล.....	71
รูปที่ 6.11 ผลการประมาณค่าและควบคุมของตัวประมาณค่าข่ายงานนิวรัลร่วมกับ ตัวควบคุมพีไอ	71
รูปที่ 6.12 ผลการประมาณค่าและควบคุมของ Belarbi (2000).....	71
รูปที่ 6.13 ผลการทดสอบการประมาณค่าและการควบคุมของตัวประมาณค่า ข่ายงานนิวรัลร่วมกับตัวควบคุมข่ายงานนิวรัลเมื่อเปลี่ยนชนิดของไม้ เป็นไม้เนื้ออ่อน.....	74
รูปที่ 6.14 ผลการทดสอบการประมาณค่าและการควบคุมของตัวประมาณค่า ข่ายงานนิวรัลร่วมกับตัวควบคุมพีไอเมื่อเปลี่ยนชนิดของไม้เป็นไม้เนื้ออ่อน.....	74
รูปที่ 6.15 ผลการทดสอบการประมาณค่าและการควบคุมของ Belarbi (2000) เมื่อเปลี่ยนชนิดของไม้เป็นไม้เนื้ออ่อน.....	74
รูปที่ 6.16 ผลการทดสอบการประมาณค่าและการควบคุมของตัวประมาณค่า ข่ายงานนิวรัลร่วมกับตัวควบคุมข่ายงานนิวรัลเมื่อเปลี่ยนชนิดของไม้ เป็นไม้เนื้อแข็ง.....	75

สารบัญญภาพ (ต่อ)

หน้า

รูปที่ 6.17 ผลการทดสอบการประมาณค่าและความคุมของตัวประมาณค่า ทำงานนิเวศร่วมกับตัวควบคุมไฟเมื่อเปลี่ยนชนิดของไม้เป็นไม้เนื้อแข็ง.....	75
รูปที่ 6.18 ผลการทดสอบการประมาณค่าและการควบคุมของ Belarbi (2000) เมื่อเปลี่ยนชนิดของไม้เป็นไม้เนื้อแข็ง.....	76
รูปที่ 6.19 ผลการทดสอบการประมาณค่าและการควบคุมของ Lee และ Datta (1994) เมื่อเปลี่ยนชนิดของไม้เป็นไม้เนื้อแข็ง.....	76
รูปที่ 6.20 ผลการทดสอบตัวควบคุมเมื่อพลังงานกระตุ้นอันดับหนึ่งขององค์ประกอบ ที่ 1 ของไม้ (E_{11}) เพิ่มขึ้น 50%.....	78
รูปที่ 6.21 ผลการทดสอบตัวควบคุมเมื่อพลังงานกระตุ้นอันดับหนึ่งขององค์ประกอบ ที่ 1 ของไม้ (E_{11}) ลดลง 50%.....	78
รูปที่ 6.22 ผลการทดสอบตัวควบคุมเมื่อพลังงานกระตุ้นอันดับหนึ่งขององค์ประกอบ ที่ 2 ของไม้ (E_{12}) เพิ่มขึ้น 50%.....	79
รูปที่ 6.23 ผลการทดสอบตัวควบคุมเมื่อพลังงานกระตุ้นอันดับหนึ่งขององค์ประกอบ ที่ 2 ของไม้ (E_{12}) ลดลง 50%.....	79
รูปที่ 6.24 ผลการทดสอบตัวควบคุมเมื่อพลังงานกระตุ้นอันดับสองขององค์ประกอบ ที่ 1 ของไม้ (E_{21}) เพิ่มขึ้น 50%.....	80
รูปที่ 6.25 ผลการทดสอบตัวควบคุมเมื่อพลังงานกระตุ้นอันดับสองขององค์ประกอบ ที่ 1 ของไม้ (E_{21}) ลดลง 50%.....	80
รูปที่ 6.26 ผลการทดสอบตัวควบคุมเมื่อพลังงานกระตุ้นอันดับสองขององค์ประกอบ ที่ 2 ของไม้ (E_{22}) เพิ่มขึ้น 50%.....	81
รูปที่ 6.27 ผลการทดสอบตัวควบคุมเมื่อพลังงานกระตุ้นอันดับสองขององค์ประกอบ ที่ 2 ของไม้ (E_{22}) ลดลง 50%.....	81
รูปที่ 6.28 ผลการควบคุมของตัวควบคุมทำงานนิเวศเมื่อพลังงานกระตุ้นอันดับ หนึ่งขององค์ประกอบที่ 2 ของไม้ (E_{12}) ลดลง 15%.....	84
รูปที่ 6.29 ผลการควบคุมของตัวควบคุมทำงานนิเวศเมื่อพลังงานกระตุ้นอันดับ สองขององค์ประกอบที่ 2 ของไม้ (E_{22}) ลดลง 40%.....	84
รูปที่ ข.1 ระบบการควบคุมแบบป้อนกลับ (feedback control system).....	97

สารบัญตาราง

หน้า

ตารางที่ 5.1 แสดงค่าพารามิเตอร์ต่างๆของกระบวนการ.....	51
ตารางที่ 5.1(ต่อ) แสดงค่าพารามิเตอร์ต่างๆของกระบวนการ.....	52
ตารางที่ 5.2 แสดงค่าพารามิเตอร์ต่างๆที่สภาวะเริ่มต้น.....	53
ตารางที่ 5.3 แสดงค่าพารามิเตอร์ในสภาวะปฏิบัติการ.....	54
ตารางที่ 5.4 แสดงค่าพารามิเตอร์ที่ใช้ในงานวิจัยเทียบกับของ Lee และ Datta.....	55
ตารางที่ 6.1 แสดงค่าผลรวมค่าผิดพลาดยกกำลังสองของแบบจำลองข่ายงานนิวรัล ของตัวประมาณค่า.....	63
ตารางที่ 6.2 แสดงค่าผลรวมค่าผิดพลาดยกกำลังสองของแบบจำลองข่ายงานนิวรัล ของตัวประมาณค่า.....	67
ตารางที่ 6.3 แสดงค่าผลรวมค่าผิดพลาดยกกำลังสองของตัวควบคุมข่ายงานนิวรัล.....	69
ตารางที่ 6.4 ค่าพารามิเตอร์ที่ใช้ในการทดสอบตัวประมาณค่าและตัวควบคุม (Lee และ Datta, 1994).....	73
ตารางที่ 6.5 แสดงความคลาดเคลื่อนของตัวควบคุมและประมาณค่าในกรณีต่างๆ.....	83

คำอธิบายสัญลักษณ์

a, b	อันดับของปฏิกิริยาของ NaOH และ NaSH ตามลำดับ
A	พื้นที่หน้าตัดของการถ่ายเทมวล (m^2)
A_{1i}	แฟคเตอร์ความถี่อันดับหนึ่งขององค์ประกอบที่ i ของไม้ ($h^{-1} (kg/m^3)^{-1}$)
A_{2i}	แฟคเตอร์ความถี่อันดับสองขององค์ประกอบที่ i ของไม้ ($h^{-1} (kg/m^3)^{-1}$)
C_{ei}	ความเข้มข้นขององค์ประกอบที่ i ใน entrapped liquor (kg/m^3)
C_{fi}	ความเข้มข้นขององค์ประกอบที่ i ใน free liquor (kg/m^3)
Cp_{ei}	ความร้อนจำเพาะขององค์ประกอบที่ i ใน entrapped liquor (kcal/kg.K)
Cp_{fi}	ความร้อนจำเพาะขององค์ประกอบที่ i ใน free liquor (kcal/kg.K)
Cp_{ri}	ความร้อนจำเพาะขององค์ประกอบที่ i ในสายหมุนเวียน (kcal/kg.K)
Cp_{wi}	ความร้อนจำเพาะขององค์ประกอบที่ i ในไม้ (kcal/kg.K)
Cr_i	ความเข้มข้นขององค์ประกอบที่ i ในสายหมุนเวียน (kg/m^3)
E_{1i}	พลังงานกระตุ้นอันดับหนึ่งขององค์ประกอบที่ i ในไม้ (kcal/mol)
E_{2i}	พลังงานกระตุ้นอันดับสองขององค์ประกอบที่ i ในไม้ (kcal/mol)
Fr	อัตราการไหลของสายหมุนเวียน (m^3/h)
G_i	อัตราการเกิดรวมขององค์ประกอบที่ i ใน entrapped liquor (kg/h. dry wood mass)
ΔH_i	ความร้อนการเกิดของปฏิกิริยา (kcal/kg)
k_{1i}	ค่าคงที่การเกิดปฏิกิริยาอันดับหนึ่งขององค์ประกอบที่ i ในไม้ ($h^{-1} (kg/m^3)^{-1}$)
k_{2i}	ค่าคงที่การเกิดปฏิกิริยาอันดับสองขององค์ประกอบที่ i ในไม้ ($h^{-1} (kg/m^3)^{-1}$)
K_t	ความจุความร้อนรวม (kcal/K)
M_i	สัมประสิทธิ์การถ่ายเทมวลขององค์ประกอบที่ i ระหว่างเฟสของ entrapped liquor กับ free liquor (m/h)
M_w	มวลรวมของไม้แห้ง (kg)
M_{1i}	ค่าคงที่การทดลองที่ 1 ขององค์ประกอบที่ i ในไม้ (m/h)
M_{2i}	ค่าคงที่การทดลองที่ 2 ขององค์ประกอบที่ i ในไม้ (m/h)
N_e	จำนวนองค์ประกอบใน entrapped liquor
N_f	จำนวนองค์ประกอบใน free liquor
N_w	จำนวนองค์ประกอบในไม้
R	ค่าคงที่แก๊สอุดมคติ (kcal/mol.K)

คำอธิบายสัญลักษณ์ (ต่อ)

R_i	สัดส่วนมวลของอัตราการเกิดปฏิกิริยาขององค์ประกอบที่ i ในไม้เทียบกับมวลของไม้ (mass fraction/h)
S_{cij}	stiochiometric coefficient
T	อุณหภูมิของเครื่องย่อย (K)
T_r	อุณหภูมิของสายหมุนเวียน (K)
V_e	ปริมาตรรวมของ entrapped liquor (m^3)
V_f	ปริมาตรรวมของ free liquor (m^3)
X_i	ความเข้มข้นขององค์ประกอบที่ i ในไม้ (mass fraction)
X_{ui}	ความเข้มข้นขององค์ประกอบที่ i ของไม้ที่ไม่เกิดปฏิกิริยา (mass fraction)

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

บทที่ 1

บทนำ

1.1 ความสำคัญและที่มาของงานวิจัย

ในอุตสาหกรรมผลิตเยื่อกระดาษ มีความต้องการให้ได้ผลิตภัณฑ์เยื่อกระดาษที่มีคุณภาพดีและสม่ำเสมอ โดยใช้เครื่องย่อยเยื่อกระดาษแบบกะ (Batch pulp digester) เพื่อย่อยเนื้อไม้ให้เป็นเยื่อกระดาษโดยผ่านกระบวนการคราฟท์ (Kraft process) เพื่อทำการกำจัดลิกนิน (delignification) ถ้าอัตราการกำจัดลิกนินไม่เหมาะสม จะทำให้ต้องใช้สารเคมีในขั้นตอนการฟอกมากขึ้น ส่งผลให้เพิ่มปริมาณของเสียมีพิษ (Toxic wastes) มากยิ่งขึ้น ฉะนั้นจึงต้องทำการควบคุมอัตราการกำจัดลิกนินซึ่งมีผลต่อคุณภาพของเยื่อกระดาษ โดยสามารถควบคุมจากค่าแคปปาซึ่งเป็นค่าที่บ่งถึงปริมาณลิกนินที่เหลืออยู่ในเยื่อให้มีความใกล้เคียงกับค่าแคปปาที่ต้องการมากที่สุด อย่างไรก็ตามก็ยังคงมีปัญหาสำคัญ 2 ประการ คือ การขาดความเข้าใจในกระบวนการและค่าแคปปาเป็นค่าที่ไม่สามารถวัดได้ ดังนั้นจึงต้องมีวิธีการในการควบคุมและประมาณค่าที่เหมาะสม ซึ่งก็ได้มีการพัฒนาตัวควบคุมที่ใช้กับกระบวนการนี้มาโดยตลอด

ข่ายงานนิวรัลก็เป็นหนึ่งแนวทางที่นำมาใช้ในการประมาณค่าและควบคุมกระบวนการย่อยเยื่อกระดาษนี้ ข่ายงานนิวรัลเป็นเครื่องมือทางคณิตศาสตร์ประยุกต์อย่างหนึ่งสำหรับแก้ปัญหาแบบไม่เชิงเส้นได้เป็นอย่างดีโดยไม่จำเป็นต้องรู้ทฤษฎีหรือแบบจำลองคณิตศาสตร์ของระบบโดยใช้เทคนิคด้านปัญญาประดิษฐ์ (Artificial Intelligence) เนื่องจากการสร้างแบบจำลองของข่ายงานใช้เพียงค่าอินพุตและเอาต์พุตเท่านั้น กล่าวคือ ข่ายงานนิวรัลจะได้รับการฝึก (training) โดยป้อนค่าอินพุตที่สอดคล้องกับเอาต์พุต (training set) และเรียนรู้ชุดข้อมูลกลับไปกลับมาเพื่อให้ทำนายค่าเอาต์พุตที่ใกล้เคียงกับค่าเป้าหมายที่ได้ป้อนเข้าไป ระหว่างนั้นข่ายงานจะทำการสร้างแบบจำลองภายใน (internal model) แทนแบบจำลองจริงของกระบวนการ จนกระทั่งข่ายงานได้รับการฝึกจนได้ค่าเอาต์พุตที่เป็นที่ยอมรับแล้ว ก็จะนำข่ายงานนั้นไปใช้เป็นแบบจำลองเพื่อทำนายเอาต์พุตที่จะเกิดขึ้นตามเงื่อนไขของข้อมูลใหม่ที่ป้อนเข้าให้ข่ายงาน

การออกแบบให้ข่ายงานนิวรัลให้เป็นตัวควบคุมระบบ ข่ายงานจะได้รับการฝึกแบบการกระจายความผิดพลาดย้อนกลับ (Error back propagation: EBPT) จากชุดข้อมูลที่ป้อนเข้าไป เพื่อสร้างแบบจำลองภายในให้ใกล้เคียงกับแบบจำลองของกระบวนการ ซึ่ง EBPT นั้นอาศัยพื้นฐานจากกฎการเรียนรู้แบบเกรเดียนต์เดสเซนท์ (gradient descent rule) เพื่อให้เกิดความแตกต่างระหว่างผลลัพธ์ที่ได้จากแบบจำลองของกระบวนการกับข่ายงานนิวรัลน้อยที่สุด เมื่อได้แบบจำลองของกระบวนการแล้ว ทำการหาแบบจำลองผกผันของกระบวนการโดยการฝึกข่ายงานนิวรัลแบบ EBPT เช่นเดียวกับการหาแบบจำลองภายในของระบบ แต่กลับเอาค่าผลลัพธ์ที่ได้จากระบบ

มาเป็นข้อมูลในการฝึกช่างงานเพื่อให้ได้ค่าผลลัพธ์ที่จะใช้ป้อนให้กับระบบ เมื่อได้แบบจำลองภายในของช่างงานทั้งสองนี้แล้วจึงนำมาให้เป็นตัวควบคุมกระบวนการของระบบ

ดังนั้นเทคโนโลยีทางช่างงานนิวรัลจึงมีความเหมาะสมในการนำไปใช้แก้ปัญหาที่อยู่ในรูปแบบสมการเชิงเส้นและไม่เชิงเส้นที่มีความซับซ้อนได้เป็นอย่างดีโดยไม่จำเป็นต้องเข้าใจพื้นฐานของกระบวนการนั้นอย่างละเอียด ทำให้ช่างงานนิวรัลได้รับความนิยมเนื่องจากสามารถนำไปประยุกต์ใช้ได้กับงานหลายด้าน เช่น โรงงานอุตสาหกรรม หุ่นยนต์และการแพทย์ เป็นต้น และเป็นที่ยอมรับในวงการวิจัยทางวิศวกรรมศาสตร์และวิทยาศาสตร์

1.2 วัตถุประสงค์ของงานวิจัย

1. เพื่อพัฒนาแบบจำลองช่างงานนิวรัลของกระบวนการผลิตเยื่อกระดาษ
2. เพื่อออกแบบตัวควบคุมที่ใช้ช่างงานนิวรัลสำหรับการควบคุมค่าแคปปา (Kappa Number) ของกระบวนการย่อยเยื่อกระดาษ

1.3 ขอบเขตของงานวิจัย

1. กระบวนการที่ใช้ คือ กระบวนการย่อยเยื่อกระดาษ โดยใช้เครื่องย่อยกระดาษแบบกะ (Batch pulp digester) ซึ่งมีตัวแปรที่ต้องการควบคุม คือ ค่าแคปปา
2. อัลกอริทึมในการฝึกช่างงานนิวรัล คือ อัลกอริทึมการกระจายความผิดพลาดย้อนกลับ และศึกษาตัวควบคุมช่างงานนิวรัลแบบเอ็นไอเอ็มซี

1.4 ขั้นตอนและวิธีการดำเนินการงานวิจัย

แบ่งได้เป็น 5 ขั้นตอน ดังนี้

1. ศึกษาและค้นคว้าผลงานวิจัยในช่วงเวลาที่ผ่านมา
ขั้นตอนนี้เป็นขั้นตอนการศึกษาทฤษฎีเบื้องต้นของช่างงานนิวรัล รวมถึงการประยุกต์ใช้ช่างงานนิวรัลในด้านต่างๆ
2. ศึกษาอัลกอริทึมการกระจายความผิดพลาดย้อนกลับของช่างงานนิวรัล
3. จำลองกระบวนการโดยใช้แบบจำลองทางคณิตศาสตร์ (Mathematical models)
3. ออกแบบโครงสร้างของตัวควบคุมสำหรับการควบคุมค่าแคปปาของกระบวนการผลิตเยื่อกระดาษ
4. การทดลองและเก็บข้อมูลจากการทดลอง

5.การวิเคราะห์ผลและจัดทำรายงาน

1.5 ประโยชน์ที่คาดว่าจะได้รับ

1. แบบจำลองแบบข่ายงานนิวรัลของกระบวนการผลิตเยื่อกระดาษ
2. ตัวควบคุมแบบนิวรัลที่เหมาะสมสำหรับการควบคุมค่าแคปปาของกระบวนการผลิตเยื่อกระดาษ

1.6 เนื้อหาวิทยานิพนธ์

เนื้อหาของวิจัยแบ่งออกเป็น 6 บท บทที่ 1 กล่าวถึงความสำคัญและที่มาของงานวิจัย วัตถุประสงค์ของงานวิจัย ขอบเขตการวิจัย ขั้นตอนและวิธีการดำเนินการวิจัย ประโยชน์ที่คาดว่าจะได้รับและเนื้อหาวิทยานิพนธ์ บทที่ 2 กล่าวถึงผลงานวิจัยที่ผ่านมา บทที่ 3 กล่าวถึงทฤษฎีเกี่ยวกับข่ายงานนิวรัลซึ่งอธิบายถึงโครงสร้างของข่ายงานนิวรัลในยุคแรกๆจนถึงโครงสร้างของข่ายงานนิวรัลในปัจจุบัน อัลกอริทึมการกระจายความผิดพลาดย้อนกลับ บทที่ 4 กล่าวถึงโครงสร้างของแบบจำลองและตัวควบคุมแบบต่างๆ บทที่ 5 กล่าวถึงกระบวนการย่อยเยื่อกระดาษที่เป็นกระบวนการที่ใช้ในการวิจัย บทที่ 6 กล่าวถึงการทดลอง ผลการทดลอง การวิเคราะห์ผลการทดลอง บทที่ 7 เป็นการสรุปผลการวิจัยและเสนอแนะ และในบทสุดท้ายเป็นภาคผนวกกล่าวถึงโปรแกรมแมทแลบที่ใช้ในการวิจัยครั้งนี้

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

บทที่ 2 ผลงานวิจัยที่ผ่านมา

บทนี้จะกล่าวถึงผลงานวิจัยเกี่ยวกับข่ายงานนิวรัลที่ผ่านมาซึ่งแบ่งออกเป็นที่มาและผลงานทางด้านข่ายงานนิวรัล ผลงานทางด้านข่ายงานนิวรัลในวิศวกรรมเคมี และผลงานวิจัยที่เกี่ยวข้องกับงานวิจัยโดยผลงานเหล่านี้ได้มีการพัฒนาอย่างต่อเนื่อง

2.1 ที่มาและผลงานทางด้านข่ายงานนิวรัล

Warren McCulloch และ Walter Pitts (1943) ทำการบุกเบิกการออกแบบข่ายงานนิวรัลแบบแรกโดยใช้ตรรกะทreshold (threshold logic) ด้วยหลายอินพุทและหนึ่งเอาต์พุท ซึ่งข่ายงานนี้สามารถใช้ได้กับระบบเชิงเส้นเท่านั้นเนื่องจากมีนิวรอนเพียงหน่วยเดียว ไม่มีการเชื่อมโยงกับนิวรอนหน่วยอื่น และค่าน้ำหนักถูกกำหนดให้คงที่

Frank Rosenblatt (1959) พัฒนาแบบจำลองของ McCulloch และ Pitts ได้ข่ายงานที่เรียกว่าเพอร์เซปตรอน (perceptron) ซึ่งจะมีการปรับค่าน้ำหนักระหว่างการเรียนรู้จนกว่าจะได้ค่าน้ำหนักที่ถูกต้อง โดยข่ายงานนี้มีน้ำหนักเพียงชั้นเดียว ใช้ฟังก์ชันเชิงเส้นเป็นฟังก์ชันมูลฐาน และฟังก์ชันแบบขั้นบันไดเป็นฟังก์ชันกระตุ้น

Bernard Widrow และ Marcian Hoff (1962) เสนอแบบจำลองข่ายงานนิวรัลแบบ ADALINE ที่ใช้กฎการเรียนรู้แบบเดลตา นั่นคือ การลดความแตกต่างระหว่างค่าผลลัพธ์จากข่ายงานกับค่าเป้าหมายโดยการปรับค่าน้ำหนักของข่ายงาน ซึ่งข่ายงานนี้มีน้ำหนักเพียง 1 ชั้น

Werbos (1974) เสนออัลกอริทึมแบบการกระจายความผิดพลาดย้อนกลับ (error backpropagation algorithm) ซึ่งเป็นวิธีการฝึกข่ายงานนิวรอนที่ใช้กฎการเรียนรู้แบบเดลตาทั่วไป ซึ่งในขณะนั้นยังไม่เป็นที่รู้จัก ต่อมา Rumelhart (1986) และคณะเสนออัลกอริทึมการกระจายความผิดพลาดย้อนกลับอีกครั้งจนเป็นที่รู้จักกันอย่างกว้างขวาง

Darpa (1988) ให้คำจำกัดความของข่ายงานนิวรัลว่า คือ “ระบบซึ่งประกอบด้วยหลายๆองค์ประกอบ มีการดำเนินงานในรูปแบบขนาน ซึ่งฟังก์ชันของมันถูกกำหนดโดยโครงสร้างของข่ายงาน ค่าน้ำหนักและจำนวนนิวรอน”

Leonard และ Kramer (1990) เสนอการเรียนรู้โดยการใช้ไมเนตัมซึ่งช่วยเร่งการเรียนรู้ของข่ายงานเมื่อใช้ร่วมกับอัลกอริทึมการกระจายความผิดพลาดย้อนกลับ

2.2 ผลงานทางด้านข่ายงานนิวรัลในวิศวกรรมเคมี

Bhat และ McAvoy (1989) ได้ทำการศึกษาระบบการปรับสภาพให้เป็นกลาง (pH neutralization process) ด้วยข่ายงานนิวรัลที่มีโครงสร้างแบบไปข้างหน้าและอัลกอริทึมการกระจายย้อนกลับ พบว่าแบบจำลองนิวรัลสามารถเรียนรู้แบบจำลองแบบไม่เชิงเส้นของกระบวนการได้ดีกว่าแบบจำลอง ARMA และยังสามารถถูกฝึกให้เรียนรู้แบบจำลองของกระบวนการแบบย้อนกลับได้

Narendra และ Parthasarathy (1990) เสนอการควบคุมแบบนิวรัลอะแดปทีฟ (neural adaptive) โดยใช้การเรียนรู้แบบไดนามิกแบบผกผันของแบบจำลองโดยทางอ้อม ข่ายงานนิวรัล 2 ข่ายงานถูกใช้ในวิธีการควบคุมซึ่งข่ายงานแรกเป็นแบบจำลองและอีกข่ายงานเป็นตัวควบคุม มีขั้นตอนการเรียนรู้ 2 ขั้นตอน คือ การฝึกข่ายงานให้เรียนรู้ไดนามิกของกระบวนการและฝึกข่ายงานนิวรัลที่เป็นตัวควบคุมเพื่อเรียนรู้การควบคุมที่ต้องการ โดยให้ค่าผิดพลาดกระจายย้อนกลับผ่านแบบจำลอง ผลการทดสอบพบว่าตัวควบคุมแบบนิวรัลอะแดปทีฟสามารถควบคุมกระบวนการแบบไม่เชิงเส้นได้เป็นอย่างดี

Thibault, Breusegem และ Cheruy (1990) ใช้ข่ายงานนิวรัลในการทำนายค่าตัวแปรในการหมัก โดยใช้ดังหมักแบบกวนต่อเนื่อง พบว่าแบบจำลองของข่ายงานนิวรัลสามารถทำนายค่าได้แม้ในสภาวะที่มีการรบกวน

Willis, Massimo, Montague, Tham และ Morris (1991) ศึกษาการสร้างแบบจำลองโดยใช้ข่ายงานนิวรัล โดยใช้กระบวนการที่จะสร้างแบบจำลอง 2 กระบวนการคือ กระบวนการหมักซึ่งจะใช้ข่ายงานนิวรัลทำการประมาณค่าความเข้มข้นมวลของจุลินทรีย์ (biomass concentration) และกระบวนการที่ 2 คือ หอกลิ้น ซึ่งจะประมาณค่าขององค์ประกอบของผลผลิตที่ยอดหอ

Dawson และ Schopflocher (1992) ศึกษาฟังก์ชันกระตุ้นแบบเกาส์เซียนและศึกษาการเรียนรู้ที่เร็วกว่าการใช้ฟังก์ชันกระตุ้นแบบซิกมอยด์

Nahas และคณะ (1992) ฝึกข่ายงานนิวรัลให้เรียนรู้แบบไดนามิกแบบผกผันของกระบวนการโดยใช้ตัวควบคุมแบบเอ็นไอเอ็มซี (nonlinear internal model control) ซึ่งประกอบด้วยตัวควบคุมและฟิลเตอร์ พบว่าโครงสร้างการควบคุมแบบเอ็นไอเอ็มซีรับประกันว่าจะไม่เกิดออฟเซตแต่ใช้ได้กับกระบวนการที่มีการผกผันที่คงตัว

Pollard และคณะ (1992) ใช้ข่ายงานแบบป้อนไปข้างหน้าหลายชั้นในการแก้ปัญหากระบวนการในอุตสาหกรรม โดยนำไปใช้ทำนายคุณสมบัติของชั้นเทอร์ย์ในหอกลิ้น โดยป้อนอัตราการไหลย้อนกลับเป็นอินพุท

Fan, Nikolaou และ White (1993) ศึกษาการผลิตโพลีเอทิลีนจากเฮปแทนที่สภาวะคงตัวโดยใช้ข่ายงานนิวรัลที่มีอัลกอริทึมแบบกระจายย้อนกลับโดยเพิ่มจำนวนฟังก์ชันในชั้นอินพุท (input layer)

สุรพล คำภา (1995) ศึกษาการสร้างแบบจำลองของข่ายงานนิวรัล โดยศึกษาโครงสร้างของข่ายงานนิวรอนแบบกลับกระแสและไม่กลับกระแส พบว่าแบบจำลองแบบกระแสเป็นโครงสร้างที่ข่ายงานเรียนรู้ได้เร็วกว่า เนื่องจากมีค่าเป้าหมายในอดีตเป็นตัวช่วยกำหนดแนวทางในการเรียนรู้ทำให้หาคำตอบได้รวดเร็ว โดยใช้พารามิเตอร์ต่างๆ คือ อัตราการเรียนรู้ ค่าโมเมนตัมและจำนวนนิวรอนในชั้นซ่อน และพบว่า การเพิ่มจำนวนชั้นซ่อนของโครงสร้างมิได้ทำให้การเรียนรู้เร็วขึ้น เพราะต้องเสียเวลาในการคำนวณค่าน้ำหนักที่เชื่อมโยงระหว่างนิวรอนมากขึ้น แต่อย่างไรก็ดี โครงสร้างที่มีชั้นซ่อนมากกว่า 1 ชั้น อาจเหมาะสมกับกระบวนการที่ซับซ้อนกว่านี้

Dirion และคณะ (1995) พัฒนาตัวควบคุมแบบจำลองย้อนกลับของข่ายงานนิวรัลและใช้ในการควบคุมอุณหภูมิของเซมิคอนดักเตอร์ในระดับปฏิบัติการปรากฏว่าผลที่ได้จะมีสมรรถนะดียิ่งขึ้น เมื่อพิจารณาถึงค่าไทม์ดีเลย์ด้วย

K.W.Lee และ H.N.Lam (1995) วิจัยว่าข่ายงานแบบป้อนไปข้างหน้าที่มีฟังก์ชันซิกมอยด์ซึ่งเป็นฟังก์ชันต่อเนื่องเป็นฟังก์ชันกระตุ้นจะให้ค่าความถูกต้องสูง

Kim และคณะ (1997) ใช้แบบแผนการควบคุมนิวรัลเชิงเส้นในการควบคุมกระบวนการเคมีที่เป็นแบบไม่เชิงเส้น โดยใช้โครงสร้างฟังก์ชันมูลฐานแบบรัศมี ในการ linearize ความสัมพันธ์ระหว่างค่าเอาต์พุทของตัวควบคุมเชิงเส้นกับค่าเอาต์พุทของกระบวนการ โดยทำการศึกษาระบบการจากถึงปฏิกรณ์แบบกวนอย่างต่อเนื่องและค่า pH เพื่อประเมินแผนการควบคุม

Krothapally และ Palanki (1997) ทำการพัฒนาข่ายงานนิวรัลเพื่อช่วยในการคำนวณสภาวะที่เหมาะสมในการปฏิบัติการโดยขึ้นกับสภาวะตั้งต้นกับค่าพารามิเตอร์ของกระบวนการแบบแบทช์ศึกษาโดยใช้กระบวนการการผลิตสารโพลีเมอร์ 2 ชนิด คือ กระบวนการผลิตสไตรีนและกระบวนการผลิต เมทิลเมทาไคเลท

Srdjan Nestic และ Miran Vrhovac (1997) ศึกษาและพัฒนาแบบจำลองการกักต่อนของคาร์บอนไดออกไซด์โดยการใช้ข่ายงานนิวรัล และทดสอบประสิทธิภาพของแบบจำลองด้วยข้อมูลจากการทดลองและมีการแสดงให้เห็นถึงการเลียนแบบข้อมูลโดยการเปรียบเทียบกับแบบ semi-empirical models

Vora และคณะ (1997) ใช้ข่ายงานนิวรัลที่มีอัลกอริทึมแบบกระจายไปข้างหน้า (countercurrent propagation) ในการตรวจสอบความผิดพลาดที่เกิดขึ้นของกระบวนการจากถึงปฏิกรณ์แบบกวนต่อเนื่อง พบว่ามีความสามารถในการเรียนรู้เพื่อตรวจสอบความผิดพลาดได้รวดเร็วกว่าการกระจายความผิดพลาดย้อนกลับ (Error back propagation)

H.H.Chen และคณะ (1999) เสนอการใช้เปอร์เซปตรอนแบบป้อนไปข้างหน้าหลายชั้น (Feedforward Multilayer Perceptrons) เพื่อใช้ตรวจสอบการหาตำแหน่งโดยใช้ข้อมูลจากเครื่องมือตรวจสอบอนุภาค

นงลักษณ์ พลรักษา (2001) ศึกษากระบวนการอุตสาหกรรมโพลีเอทิลีนโดยใช้ข่ายงานนิวรัลในการทำนายค่า โดยใช้ข้อมูลที่ได้จากการวัดค่าอุณหภูมิ ความดัน อัตราการไหล องค์ประกอบของก๊าซและตัวแปรอื่นแบบออนไลน์ในการเรียนรู้แบบการกระจายความผิดพลาดย้อนกลับแบบ Levenberg-Marquardt พบว่าสามารถทำนายค่าอัตราการไหลและความหนาแน่นได้ดีทั้งการฝึกข่ายงานและการทดสอบข่ายงาน รวมทั้งสามารถทำนายค่าแบบออนไลน์ได้

2.3 ผลงานวิจัยที่เกี่ยวข้องกับงานวิจัย

Lee และ Datta (1994) ทำการควบคุมกระบวนการย่อยเยื่อกระดาษด้วยตัวควบคุม MPC (Model predictive controller) ร่วมกับคาลมานฟิลเตอร์เพื่อควบคุมค่าแคปปา พบว่าสามารถควบคุมค่าแคปปาได้อย่างมีประสิทธิภาพ และประมาณค่าแคปปาได้ใกล้เคียงกับค่าแคปปาของกระบวนการ แต่ความสามารถในการประมาณค่าลดต่ำลงเมื่อพารามิเตอร์ของกระบวนการผิดพลาด

Belarbi, Bettou และ Mezaache (2000) ทำการศึกษากระบวนการย่อยเยื่อกระดาษโดยใช้ข่ายงานนิวรัลพีชชีที่มีอัลกอริทึมแบบกระจายย้อนกลับในการประมาณค่าและใช้พีชชีเป็นตัวควบคุมค่าแคปปา พบว่าสามารถควบคุมกระบวนการได้ดี และประมาณค่าแคปปาได้ใกล้เคียงกับค่าแคปปาของกระบวนการ เมื่อพารามิเตอร์ของกระบวนการผิดพลาด ตัวประมาณค่าก็ยังสามารถประมาณค่าได้แม้ประสิทธิภาพจะลดลง

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

บทที่ 3

ทฤษฎีเกี่ยวกับข่ายงานนิวรัล


บทนี้จะกล่าวถึงทฤษฎีเกี่ยวกับข่ายงานนิวรัลโดยแบ่งหัวข้อตามลำดับดังนี้ คือ หัวข้อ 3.1 กล่าวถึงชีววิทยาของนิวรอนและแบบจำลองของข่ายงานนิวรัลในยุคแรกๆถึงที่มาของแนวคิดของข่ายงานนิวรัล ส่วนหัวข้อ 3.2 กล่าวถึงแบบจำลองของข่ายงานนิวรัลในปัจจุบัน และในหัวข้อ 3.3 กล่าวถึงการออกแบบข่ายงานนิวรัลและองค์ประกอบพื้นฐานที่ใช้ในการออกแบบรวมถึงอัลกอริธึมการกระจายย้อนกลับและการเรียนรู้โดยการใช้โมเมนตัมซึ่งช่วยเร่งการเรียนรู้ให้เกิดได้เร็วขึ้น

3.1 ชีววิทยาของข่ายงานนิวรัลและแบบจำลองของข่ายงานนิวรัลในยุคแรกๆ

ข่ายงานนิวรัลได้แนวคิดมาจากการเลียนแบบโครงสร้างระบบประสาทของมนุษย์ ซึ่งประกอบด้วยกลุ่มของนิวรอนจำนวนมากที่เชื่อมต่อกันที่เรียกว่า ข่ายงานนิวรัล (neural network) โดยสามารถติดต่อกับนิวรอนหน่วยอื่นๆด้วยแอกซอน (axon) และซินแนปส์ (synapses) ข้อสมมติฐานเกี่ยวกับแบบจำลองของระบบประสาทคือนิวรอนจะทำการติดต่อกันโดยอาศัยการกระตุ้นทางไฟฟ้า (electrical impulse) แต่การทำงานของนิวรอนนั้นเกิดจากกระบวนการทางชีวเคมีในทางชีววิทยา นิวรอนจะประกอบด้วย 3 ส่วนดังรูปที่ 3.1

1. เดนไดรต์ (dendrite) แดกแขนงออกจากตัวเซลล์เพื่อรับสัญญาณจากแอกซอนของนิวรอนตัวอื่นเข้ามาและส่งต่อไปยังตัวเซลล์นิวรอน
2. ตัวเซลล์นิวรอน (cell body) ทำหน้าที่รวบรวมสัญญาณจากเดนไดรต์และส่งไปให้แอกซอน
3. แอกซอน (axon) ทำหน้าที่นำสัญญาณที่ออกจากตัวเซลล์นิวรอน และส่งไปยังเดนไดรต์ของนิวรอนถัดไป

เดนไดรต์จะรับสัญญาณจากแอกซอนของนิวรอนอื่นเข้ามาและส่งต่อไปให้ตัวเซลล์นิวรอน ตัวเซลล์นิวรอนจะรวมสัญญาณที่ได้รับส่งต่อไปให้แอกซอนจนถึงรอยต่อซินแนปส์ ซึ่งเป็นรอยต่อระหว่างแอกซอนของนิวรอนตัวปัจจุบันและเดนไดรต์ของนิวรอนตัวถัดไป โดยแอกซอนจะนำสัญญาณผ่านไปตามลำดับของคลื่นกระแสไฟฟ้า ซึ่งขึ้นกับค่าแรงดันต่างศักย์ของนิวรอนกับเนื้อเยื่อของนิวรอน (membrane) ที่สร้างแรงดันต่างศักย์กระจายผ่านแอกซอนไปจนถึงรอยต่อของซินแนปส์ จากแนวความคิดพื้นฐานดังกล่าวนี้มีนักวิจัยสนใจที่จะศึกษากลไกและโครงสร้างของระบบประสาทของมนุษย์ซึ่งนำไปสู่การพัฒนาแบบจำลองสำหรับการแก้ปัญหาที่ซับซ้อนซึ่งได้แก่การแก้ปัญหาแบบไม่เชิงเส้น




รูปที่ 3.1 โครงสร้างของเซลล์ประสาท

โดยในปี ค.ศ. 1943 McCulloch และ Pitts ได้เป็นผู้บุกเบิกการจำลองการทำงานของเซลล์ประสาทสมองโดยใช้สมการคณิตศาสตร์อย่างง่าย โดยมีข้อจำกัดว่าใช้ได้กับปัญหาทางตรรกศาสตร์อย่างง่ายเท่านั้น ต่อมาทั้งสองได้เสนอตรรกเทรชโฮลด์ (threshold logic) ดังแสดงในรูป 3.2 แบบจำลองนี้มีข้อจำกัดคือ ค่าอินพุตและเอาต์พุตเป็น 0 กับ 1 เท่านั้น และค่าน้ำหนักมีค่าคงที่ อีกทั้งไม่มีการติดต่อถึงกันระหว่างนิวรอนหน่วยอื่นเพราะมีนิวรอนเพียงหน่วยเดียวเท่านั้น แบบจำลองนี้จึงใช้ได้กับระบบเชิงเส้น สัญญาณที่ออกจากนิวรอนกำหนดด้วยเงื่อนไขดังสมการ (3.1)

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


ในปี ค.ศ. 1958 Rosenblatt ได้เสนอแบบจำลองเปอร์เซปตรอนซึ่งเป็นแบบจำลองข่ายงานแบบตัดสินใจเพื่อใช้ในการแยกข้อมูล 2 ระดับออกจากกัน ต่อมาในปี ค.ศ. 1969 Minsky และ Papert ทำการพิสูจน์คุณสมบัติของเปอร์เซปตรอนและชี้ให้เห็นถึงข้อจำกัดของแบบจำลองนี้ซึ่งสามารถแก้ปัญหาเฉพาะระบบที่เป็นเชิงเส้นเท่านั้น



รูปที่ 3.2 แบบจำลองการทำงานของนิวรอนเสนอโดย McCulloch และ Pitts

3.2 แบบจำลองของข่ายงานนิวรัลในปัจจุบัน

แบบจำลองของข่ายงานนิวรัลในปัจจุบันประกอบด้วยชั้นของนิวรอนและส่วนเชื่อมโยงระหว่างอินพุตกับเอาต์พุตที่เรียกว่า น้ำหนัก (weight) อินพุตของนิวรอนจะถูกนำมารวมกันโดยใช้ฟังก์ชันมูลฐาน (basis function) และส่งเอาต์พุตที่ออกจากฟังก์ชันมูลฐานไปแปลงด้วยฟังก์ชันกระตุ้น (activation function) ซึ่งจะได้เอาต์พุตของนิวรอนและส่งเอาต์พุตของนิวรอนนี้ไปเป็นอินพุตของนิวรอนถัดไปเป็นทอดๆ ดังนั้นองค์ประกอบและหน้าที่ของนิวรอนมีดังต่อไปนี้



รูปที่ 3.3 หน้าที่และการทำงานของนิวรอน

3.2.1 องค์ประกอบและหน้าที่ของนิวรอน

นิวรอนประกอบด้วย 3 ส่วนสำคัญ ดังนี้

1. หน่วยประมวลผล (processing elements) ที่เรียกว่า node
2. การเชื่อมต่อแบบซินแนปส์ (synaptic connection) เป็นส่วนที่เชื่อมต่อระหว่างนิวรอนในแต่ละชั้นสำหรับการส่งข้อมูลที่ประมวลผลได้จากนิวรอนหนึ่งไปยังอีกนิวรอนหนึ่ง
3. ค่าน้ำหนัก (weight) และค่าไบแอส (bias) ทำหน้าที่ในการขยายหรือลดขนาดของสัญญาณที่เข้าสู่ นิวรอนโดยการเชื่อมต่อแบบซินแนปส์

การเชื่อมโยงของข่ายงานนิวรอนแต่ละนิวรอนจะเชื่อมโดยกันโดยใช้ค่าน้ำหนัก และในนิวรอนหนึ่งๆจะแปลงค่าอินพุตที่รับเข้ามาให้เป็นเอาต์พุตโดยใช้ฟังก์ชันมูลฐานและฟังก์ชันกระตุ้น และค่าเอาต์พุตที่ได้นั้นจะถูกส่งไปเป็นอินพุตให้กับนิวรอนในชั้นถัดไปดังนี้

แต่ละนิวรอน y จะได้รับอินพุตจากชั้นก่อนหน้า ซึ่งอินพุต คือ x_1, x_2, \dots, x_n และค่าน้ำหนักเชื่อมระหว่าง x_1 กับ y คือ w_1 จากนั้นทำการหาเอาต์พุตของนิวรอน y ซึ่งก็คือ หาผลรวมของอินพุตคูณกับน้ำหนัก หากมีเทอมของไบแอสก็นำไปรวมด้วย

$$y_{in} = b + w_1 x_1 + w_2 x_2 + \dots + w_n x_n \quad (3.2)$$

ค่า y_{in} มาคำนวณผ่านฟังก์ชันกระตุ้น ตัวอย่างเช่น ฟังก์ชันกระตุ้นแบบเชิงเส้น จะได้

$$\text{เอาท์พุท} = y = f(y_{in}) = y_{in} \quad (3.3)$$

หรือถ้าเป็นฟังก์ชันกระตุ้นแบบซิกมอยด์จะได้

$$\text{เอาท์พุท} = y = f(y_{in}) = 1 / (1 + e^{-y_{in}}) \quad (3.4)$$

ซึ่งเอาท์พุทที่ได้นี้จะถูกส่งไปเป็นอินพุทให้กับนิวรอนในชั้นถัดไปต่อไป

โดยสรุปแล้วนิวรอนแต่ละหน่วยมีหน้าที่ดังนี้ (แสดงในรูปที่ 3.3)

1. รับสัญญาณจากนิวรอนหน่วยอื่นๆ
2. รวมสัญญาณจากนิวรอนหน่วยอื่นเข้าด้วยกันโดยใช้ฟังก์ชันมูลฐาน
3. แปลงสัญญาณที่รวมได้โดยใช้ฟังก์ชันกระตุ้น
4. ส่งผลลัพธ์ที่ได้จากฟังก์ชันกระตุ้นไปยังนิวรอนถัดไป

3.2.2 พารามิเตอร์ที่สำคัญต่อการทำงานของนิวรอน

3.2.2.1 น้ำหนัก (weight)

น้ำหนักหรือที่เรียกว่าสัญญาณที่เชื่อมโยงระหว่างนิวรอนจะถูกปรับค่าตลอดเวลา ในระหว่างการเรียนรู้ ข่ายงานสร้างแบบจำลองภายในขึ้นมาเพื่อให้มีค่าใกล้เคียงกับระบบแบบจำลองของข่ายงานนิรลซึ่งสามารถใช้แทนแบบจำลองของกระบวนการได้ก็ต่อเมื่อค่าผลลัพธ์ที่ออกจากระบบมีค่าใกล้เคียงกับค่าผลลัพธ์ที่ออกจากข่ายงาน โดยมีความแตกต่างของผลลัพธ์ในระดับที่ยอมรับได้

3.2.2.2 ฟังก์ชันมูลฐาน (Basis Function)

ฟังก์ชันมูลฐาน คือ การแมพฟังก์ชัน(mapping) ทางคณิตศาสตร์ด้วยฟังก์ชัน $u(w, x)$ เมื่อ w คือ เมทริกซ์ของน้ำหนักและ x คือ อินพุทเวกเตอร์ ฟังก์ชันมูลฐานทำหน้าที่ในการรวมสัญญาณที่ได้รับมาจากนิวรอนหน่วยอื่นๆเข้าด้วยกัน แล้วฟังก์ชันกระตุ้นจึงแปลงสัญญาณนี้เป็นเอาท์พุทของนิวรอน ฟังก์ชันมูลฐานแบ่งออกเป็น 2 ประเภท ดังรูปที่ 3.4 คือ

ก. ฟังก์ชันมูลฐานเชิงเส้น (Linear basis function, LBF)

ฟังก์ชันมูลฐานเชิงเส้นเป็นฟังก์ชันไฮเปอร์เพลน (hyperplane) โดยเป็นฟังก์ชันมูลฐานอันดับที่ 1 ค่า net ที่ได้เป็นผลรวมเชิงเส้นของค่าอินพุทดังสมการ

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

ข. ฟังก์ชันมูลฐานเชิงรัศมี (Radial basis function, RBF)

ฟังก์ชันมูลฐานเชิงรัศมีเป็นฟังก์ชันไฮเปอร์สเฟียร์ (hypersphere) โดยเป็นฟังก์ชันมูลฐานอันดับที่ 2 ค่า net ที่ได้จะแทนระยะทางไปยังชุดข้อมูลอ้างอิง แสดงดังสมการ

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

ทั้งนี้ฟังก์ชันอันดับที่ 2 ยังสามารถขยายไปเป็นฟังก์ชันมูลฐานอิลลิปติก (elliptic basis function) ได้อีกด้วย



(ก) ฟังก์ชันมูลฐานเชิงเส้น (hyperplane)

(ข) ฟังก์ชันมูลฐานรัศมี (hypersphere)

รูปที่ 3.4 ฟังก์ชันมูลฐาน

3.2.2.3 ฟังก์ชันกระตุ้น (Activation function)

ฟังก์ชันกระตุ้นทำหน้าที่แปลงค่า net ที่อยู่ในรูปของฟังก์ชันมูลฐานให้เป็นเอาต์พุทของนิวรอน ซึ่งฟังก์ชันกระตุ้นสามารถแบ่งออกเป็น 2 ประเภท คือ

ก. ฟังก์ชันกระตุ้นเชิงเส้น (Linear Activation Function)

ฟังก์ชันกระตุ้นเชิงเส้นที่นิยมได้แก่ ฟังก์ชันขั้นบันได (step function) และฟังก์ชันแรมพ์ (ramp function) โดยมีสมการดังนี้

- ฟังก์ชันขั้นบันได (Step Function)

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

- ฟังก์ชันแรมพ์ (Ramp Function)

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

ข. ฟังก์ชันกระตุ้นแบบไม่เชิงเส้น (Nonlinear Activation Function)

ฟังก์ชันกระตุ้นแบบไม่เชิงเส้น ได้แก่ ฟังก์ชันซิกมอยด์ (Sigmoid Function) และฟังก์ชันเกาส์เซียน (Gaussain Function) ซึ่งโดยส่วนใหญ่นิยมใช้ฟังก์ชันซิกมอยด์ ซึ่งจะมีการแปลค่าอินพุตที่มีค่าบวกมากๆ ให้เข้าใกล้ 1 หรือค่าลบมากๆ ให้เข้าใกล้ 0 ดังสมการ 3.9 ดังนั้นช่วงของฟังก์ชันซิกมอยด์จะมีค่าระหว่าง $[0,1]$

- ฟังก์ชันซิกมอยด์ (Sigmoid Function)

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

- ฟังก์ชันเกาส์เซียน (Gaussain Function)

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

3.2.2.4 ฟังก์ชันความผิดพลาด (error function)

ในการฝึกข่ายงานนิวรัลมีจุดประสงค์เพื่อลดค่าผิดพลาดรวมของข่ายงานให้มีค่าน้อยที่สุด ดังนั้นการบ่งชี้ถึงความสำเร็จในการฝึกข่ายงานจึงขึ้นอยู่กับประเภทของความผิดพลาดที่เลือกมาศึกษา เพราะฟังก์ชันความผิดพลาดเป็นการวัดค่าความแตกต่างของค่าเป้าหมายกับค่าเอาต์พุตที่ได้จากข่ายงาน ตัวอย่างของฟังก์ชันความผิดพลาดมีดังต่อไปนี้


ก. ความผิดพลาดรวมยกกำลังสอง (sum square error)

$$E(y, p) = (y - p)^2 \quad (3.11)$$


โดย E คือ ค่าความผิดพลาด , y คือ ค่าเอาต์พุต และ p คือค่าเป้าหมาย ส่วนใหญ่แล้วนิยมใช้ค่าของความผิดพลาดยกกำลังสองของข้อมูลทั้งชุดรวมกัน เรียกว่า ผลรวมความผิดพลาดยกกำลังสอง (Total sum square error)

ข. ค่าความผิดพลาดเฉลี่ยยกกำลังสอง (Mean square error)

การใช้ค่าความผิดพลาดเฉลี่ยกำลังสองจะช่วยให้การแบ่งประเภทความผิด หรือข้อมูลไบนารี ซึ่งเมื่อใช้ร่วมกับอัลกอริทึมการกระจายความผิดพลาดย้อนกลับแล้ว จะให้อัตราการเรียนรู้ไม่ค่อยเร็วกับข้อมูลในการฝึกได้




(ก) ฟังก์ชันขั้นบันได (Step Function)




(ข) ฟังก์ชันแรมพ์ (Ramp Function)

รูปที่ 3.5 ฟังก์ชันกระตุ้นเชิงเส้น



(ค) ฟังก์ชันซิกมอยด์ (Sigmoid Function)



(ง) ฟังก์ชันเกาส์เซียน (Gaussian Function)

รูปที่ 3.6 ฟังก์ชันกระตุ้นแบบไม่เชิงเส้น

3.3 การออกแบบข่ายงานนิเวศ

องค์ประกอบพื้นฐานที่สำคัญต่อการออกแบบข่ายงานนิเวศ คือ ข้อมูลที่ใช้ในการฝึกข่ายงานนิเวศ และความรู้เกี่ยวกับกระบวนการสร้างแบบจำลองซึ่งได้แก่โครงสร้างของข่ายงานนิเวศ ชนิดของการเชื่อมโยงและการเรียนรู้ของข่ายงานนิเวศ และแบบจำลองของกระบวนการ

3.3.1 ข้อมูลที่ใช้ในการฝึกข่ายงาน (Training data)

ในกรณีที่แบบจำลองอยู่ในสภาวะคงที่ การเลือกชุดข้อมูลอินพุตเข้าสู่ข่ายงานนิเวศจะเลือกอินพุตที่มีผลกระทบต่อค่าเป้าหมาย แต่หากแบบจำลองที่เป็นพลศาสตร์ (dynamics) นอกจากการพิจารณาตัวแปรที่มีผลต่อผลกระทบต่อค่าเป้าหมายแล้ว ยังต้องคำนึงถึงอนุกรมเวลาของช่วงข้อมูลอินพุตและเอาต์พุตอีกด้วย ส่วนการเลือกชุดข้อมูลเอาต์พุต คือ เลือกชุดข้อมูลที่ต้องการในการทำนาย

เมื่อเลือกชุดข้อมูลอินพุทและเอาต์พุทที่เหมาะสมได้แล้ว จะแบ่งชุดข้อมูลออกเป็น 2 ชุด นั่นคือ ชุดที่ 1 จะใช้ในการฝึกข่ายงานเพื่อสร้างแบบจำลองภายในของข่ายงาน โดยมีการปรับค่าน้ำหนักของข่ายงานจนความผิดพลาดระหว่างค่าเป้าหมายกับค่าเอาต์พุทมีค่าน้อยจนอยู่ในระดับที่ยอมรับได้ และข้อมูลชุดที่ 2 ใช้ในการทดสอบแบบจำลอง (cross validation data set) เพื่อทดสอบว่าข่ายงานสามารถทำนายค่าเอาต์พุทได้ถูกต้องหรือไม่

3.3.2 โครงสร้างของข่ายงานนิเวรล

ข่ายงานจะประกอบไปด้วยชั้นนิเวรอนอย่างน้อย 3 ชั้น เพื่อทำหน้าที่รับและส่งสัญญาณเอาต์พุท ได้แก่

1. ชั้นอินพุท (input layer) ทำหน้าที่รับข้อมูลที่ใช้ในการฝึกข่ายงานนิเวรลและส่งไปให้กับนิเวรอนในชั้นซ้อนต่อไป
2. ชั้นซ่อน (hidden layer) ทำหน้าที่ประมวลผลโดยการรวมสัญญาณจากชั้นอินพุทโดยใช้ฟังก์ชันมูลฐานและแปลงค่าโดยใช้ฟังก์ชันกระตุ้น จากนั้นส่งสัญญาณที่ได้ให้แก่นิเวรอนในชั้นเอาต์พุท ซึ่งข้อมูลที่ประมวลได้จะถูกเก็บอยู่ในรูปค่าน้ำหนักและค่าไบแอส ลักษณะการทำงานดังกล่าวจะทำซ้ำกันไปจนถึงชั้นเอาต์พุท โดยชั้นซ่อนมีได้มากกว่าหนึ่งชั้น
3. ชั้นเอาต์พุท (output layer) ทำหน้าที่รวมสัญญาณจากชั้นซ่อนและแปลงค่าโดยใช้ฟังก์ชันกระตุ้น จากนั้นจึงส่งสัญญาณที่ได้เพื่อเป็นผลลัพธ์ออกจากข่ายงานนิเวรล

โครงสร้างของข่ายงานจะแตกต่างกันขึ้นกับการใช้งาน จำนวนตัวแปรในกระบวนการที่ศึกษาและการออกแบบของผู้วิจัย ซึ่งความแตกต่างของโครงสร้างก็มีผลต่อการเลือกใช้อัลกอริทึมในการฝึกข่ายงาน โดยการออกแบบโครงสร้างข่ายงานนิเวรล จำเป็นต้องพิจารณาถึงองค์ประกอบต่างๆของโครงสร้าง นั่นคือ จำนวนชั้นต่างๆและจำนวนนิเวรอนในชั้นนั้นๆดังนี้

- ชั้นอินพุท

จำนวนนิเวรอนในชั้นอินพุทของข่ายงานนิเวรลจะมีค่าเท่ากับจำนวนตัวแปรที่ใช้เป็นอินพุทในแบบจำลอง หรืออินพุทเวกเตอร์ที่ป้อนให้ข่ายงาน โดยอินพุทเวกเตอร์ของแบบจำลองและแบบจำลองผกผันมีความแตกต่างกันดังนี้

ก. อินพุทเวกเตอร์ของแบบจำลอง

อินพุทเวกเตอร์ของแบบจำลองประกอบด้วยค่าอินพุทของกระบวนการในปัจจุบัน ค่าอินพุทของกระบวนการในอดีต, n_u และเอาต์พุทของกระบวนการในอดีต, n_y ซึ่งแสดงดังรูปที่ 3.7 โดยค่าเหล่านี้จะเป็นอินพุทให้แก่ข่ายงาน ดังนั้นในชั้นอินพุทจึงมีนิเวรอน, $N_1 = n_u + n_y + 1$

หน่วย เพื่อง่ายต่อการเข้าใจ ในรูปที่ 3.7 จะใช้สัญลักษณ์อินพุทเวกเตอร์ (I) ซึ่งมีสมาชิก N_1 ตัว โดยกำหนดเป็นสัญลักษณ์ดังนี้

$$I(k) = f \{u(k), \dots, u(k - n_u), y(k - n_u), y(k - \theta - 1), \dots, y(k - \theta - n_y)\}$$

เมื่อ $u(k)$ คือค่าอินพุทของกระบวนการที่เวลา k $y(k)$ คือเอาต์พุทของกระบวนการที่เวลา k และ θ คือเดดไทม์

ข. อินพุทเวกเตอร์ของแบบจำลองผกผัน

อินพุทเวกเตอร์ของแบบจำลองแบบผกผันประกอบด้วยค่าเอาต์พุทของกระบวนการที่มีและไม่มีเดดไทม์ในอดีต, n_y และค่าอินพุทของกระบวนการในอดีต, n_u ซึ่งแสดงดังรูปที่ 3.8 โดยค่าเหล่านี้จะเป็นอินพุทให้แก่ข่ายงาน ดังนั้นในชั้นอินพุทของข่ายงานจึงมีนิวรอน, $N_2 = n_u + n_y + 1$ หน่วย และเพื่อง่ายต่อการเข้าใจ ในรูปที่ 3.8 จะใช้สัญลักษณ์อินพุทเวกเตอร์ (I) ซึ่งมีสมาชิก N_2 ตัว โดยกำหนดเป็นสัญลักษณ์ดังนี้

$$I(k) = f \{y(k), y(k - \theta - 1), \dots, y(k - \theta - n_y), u(k - 1), \dots, u(k - n_u)\}$$


เมื่อ $u(k)$ คือค่าอินพุทของกระบวนการที่เวลา k $y(k)$ คือเอาต์พุทของกระบวนการที่เวลา k และ θ คือเดดไทม์

- ชั้นซ่อน

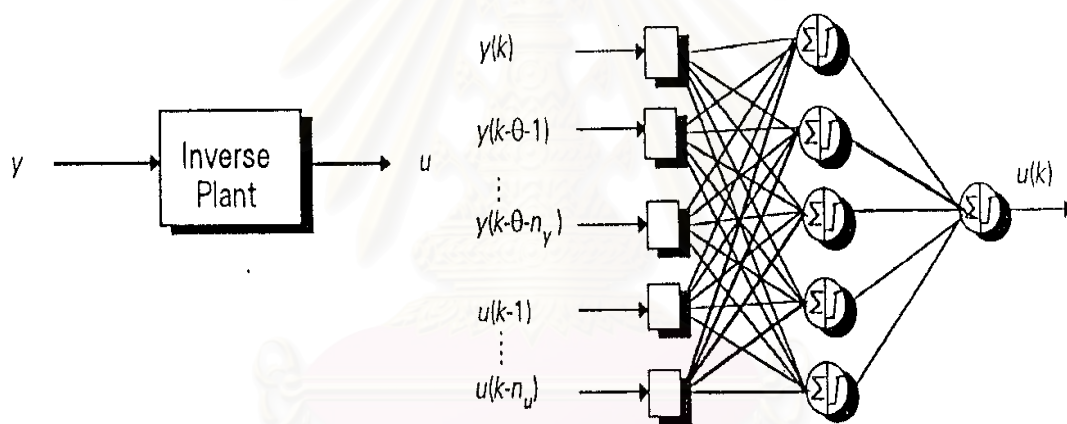
จำนวนของชั้นซ่อนและจำนวนนิวรอนในแต่ละชั้นซ่อนขึ้นกับปัจจัยต่างๆ เช่น จำนวนชุดข้อมูลที่ฝึกข่ายงาน จำนวนนิวรอนในชั้นอินพุทและเอาต์พุท และความสัมพันธ์ระหว่างอินพุทกับเอาต์พุท โดยการเริ่มต้นออกแบบโครงสร้างข่ายงานที่ดี ควรเริ่มการกำหนดจำนวนของชั้นซ่อนและ จำนวนนิวรอนในแต่ละชั้นซ่อนให้มีความน้อยๆก่อน แล้วจึงค่อยเพิ่มความซับซ้อนของข่ายงานขึ้นเมื่อความสัมพันธ์ที่ได้ยังไม่ดีพอ

-ชั้นเอาต์พุท

จำนวนนิวรอนในชั้นเอาต์พุทจะเท่ากับจำนวนตัวแปรที่ต้องการทำนาย



รูปที่ 3.7 องค์ประกอบของอินพุทเวกเตอร์ของแบบจำลอง



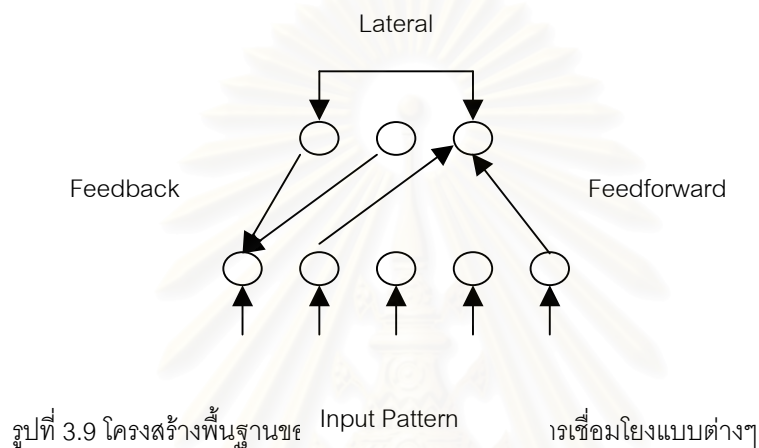
รูปที่ 3.8 องค์ประกอบของอินพุทเวกเตอร์ของแบบจำลองผกผัน

3.3.2.1 การเชื่อมโยงน้ำหนักของข่ายงานนิวรัล

ข่ายงานนิวรัลประกอบด้วยนิวรอนและเมทริกซ์ของน้ำหนัก พฤติกรรมของข่ายงานขึ้นกับการเชื่อมโยงระหว่างนิวรอนสองชั้นซึ่งติดต่อกันโดยผ่านข่ายงานเชื่อมต่อที่เรียกว่า น้ำหนัก ซึ่งการเชื่อมโยงระหว่างชั้นแบ่งได้เป็น 4 ประเภท คือ

1. การเชื่อมโยงแบบป้อนไปข้างหน้า (feedforward connection) เป็นการนำข้อมูลของนิวรอนจากชั้นที่ต่ำกว่าและนำไปใช้ในชั้นที่อยู่เหนือกว่า

2. การเชื่อมโยงแบบป้อนกลับ (feedback connection) เป็นการนำข้อมูลจากชั้นที่อยู่เหนือกว่าและส่งกลับมายังชั้นที่อยู่ต่ำกว่า
3. การเชื่อมโยงภายในชั้น (lateral connection) เป็นการนำข้อมูลภายในชั้นเดียวกันและกระจายกลับมายังชั้นเดิม
4. การเชื่อมโยงแบบหน่วงเวลา (time-delayed connection) เป็นการนำข้อมูลมาหน่วงเวลาแล้วนำเข้าไปรวมกับการเชื่อมโยงของข้อมูล เพื่อให้ได้แบบจำลองเป็นไดนามิก(temporal dynamics) ซึ่งนำมาประยุกต์ใช้กับการจดจำรูปแบบเชิงเวลา (temporal pattern recognition)



3.3.2.2 การจำแนกการเรียนรู้ของข่ายงานนิเวรัล

ข่ายงานนิเวรัลสามารถจำแนกตามการเรียนรู้ได้เป็น 2 ประเภท คือ ของข่ายงานได้เป็น 2 ประเภทได้แก่


ก. ข่ายงานนิเวรัลแบบมีการชี้แนะ (supervised neural network)

การเรียนรู้แบบที่มีการชี้แนะเป็นการฝึกข่ายงานนิเวรัลโดยใช้ชุดคู่ลำดับของอินพุทและค่าเป้าหมายที่สอดคล้องกัน โดยค่าอินพุทจะใช้เป็นอินพุทของข่ายงาน และใช้เอาต์พุทเป็นผู้สอน ดังแสดงในรูปที่ 3.10(ก) และฝึกข่ายงานให้เลียนแบบชุดข้อมูลตามที่กำหนดจนสามารถส่งสัญญาณเอาต์พุทได้คล้ายกับชุดข้อมูลที่ป้อนให้เรียนรู้ ซึ่งเป็นข้อดีของการเรียนรู้วิธีนี้เพราะมีเป้าหมายที่ต้องการเป็นผู้สอน โดยความแตกต่างของค่าเอาต์พุทที่ออกจากข่ายงานกับค่าเป้าหมายที่ต้องการจะเป็นข้อมูลที่ใช้ในการเรียนรู้เพื่อลดความแตกต่างของค่าเอาต์พุทของข่ายงานกับค่าเป้าหมายให้น้อยที่สุด


การเรียนรู้จะทำโดยการปรับค่าน้ำหนักของข่ายงานเพื่อให้ข่ายงานนิเวรัลเรียนรู้และจดจำข้อมูลสัญญาณอินพุทและสร้างสัญญาณได้สอดคล้องกับข้อมูลสัญญาณเป้าหมายตามที่กำหนดในชุดของข้อมูลที่ใช้ฝึก เพื่อทำให้เกิดความแตกต่างระหว่างเอาต์พุทที่ต้องการและเอาต์พุทของข่ายงานให้มีค่าน้อยที่สุด กระบวนการนี้อาจทำซ้ำจนกระทั่งค่าผิดพลาดเป็นค่าน้อยที่ยอมรับได้ ตัวอย่างของข่ายงานประเภทนี้ได้แก่ เพอร์เซปตรอน (perceptron) อะดาลิน (adaline) และการกระจายความผิดพลาดย้อนกลับ (Error Back Propagation) ซึ่งแสดงดังรูปที่ 3.11

ข. ข่ายงานนิวรัลแบบไม่มีการชี้แนะ (Unsupervised neural network)

การเรียนรู้แบบไม่มีการชี้แนะต้องการใช้เพียงค่าอินพุตในการฝึกข่ายงานโดยไม่มีผู้สอนหรือค่าเป้าหมาย ซึ่งแสดงในรูปที่ 3.10(ข) ในระหว่างการฝึกค่าน้ำหนักของข่ายงานจะถูกปรับโดยอินพุตที่คล้ายกันและสร้างเอาต์พุตที่คล้ายกัน ซึ่งการปรับมีหลายวิธีซึ่งแต่ละวิธีจะมีการเรียนรู้จะเป็นการปรับตัวบนพื้นฐานของประสบการณ์เพื่อจัดกลุ่มให้เข้ากับชุดข้อมูลที่ผู้ใช้เรียนรู้ที่ผ่านมาโดยไม่มีผู้สอน ตัวอย่างของข่ายงานนิวรัลประเภทนี้ ได้แก่ AG (Additive grossberg) และ ART(Adaptive resonance theory) ดังแสดงในรูปที่ 3.11

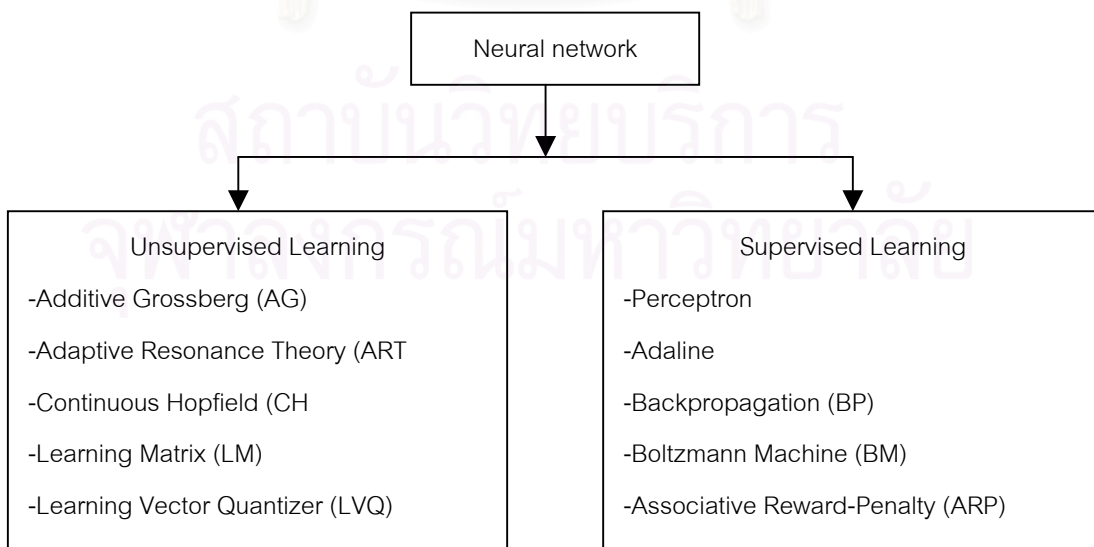


(ก) ข่ายงานนิวรัลแบบมีการชี้แนะ (supervised neural network)



(ข) ข่ายงานนิวรัลแบบไม่มีการชี้แนะ (unsupervised neural network)

รูปที่ 3.10 การเรียนรู้ของข่ายงานนิวรัลในการปรับค่าน้ำหนัก



รูปที่ 3.11 การจำแนกข่ายงานนิวรัลตามการเรียนรู้

3.3.3 ข่ายงานนิเวศแบบมีการชี้นำ (supervised neural network)

ข่ายงานนิเวศแบบมีการชี้นำ ได้แก่ ข่ายงานเปอร์เซปตรอน ข่ายงานแบบอะดาไลน์ และ ข่ายงานแบบการกระจายความผิดพลาดย้อนกลับ ข่ายงานเปอร์เซปตรอนและข่ายงานแบบอะดาไลน์เป็นข่ายงานที่มีชั้นของน้ำหนักเพียงชั้นเดียว ดังนั้นสองข่ายงานนี้จึงสามารถแก้ปัญหาได้เฉพาะแบบเชิงเส้นเท่านั้น ส่วนข่ายงานแบบการกระจายความผิดพลาดย้อนกลับเป็นข่ายงานที่มีชั้นของน้ำหนักตั้งแต่ 2 ชั้นขึ้นไป จึงสามารถใช้แก้ปัญหาแบบไม่เชิงเส้นได้อย่างดี

ข่ายงานนิเวศแบบมีการชี้นำจะใช้ชุดข้อมูลที่ประกอบไปด้วยค่าอินพุตและเอาต์พุตที่เป็นคู่ที่สอดคล้องกัน

$$[u, O] = \{[u_1, O_1], [u_2, O_2], [u_3, O_3], \dots, [u_n, O_n]\} \quad (3.12)$$

เมื่อ n คือจำนวนชุดของข้อมูลที่ใช้ในการฝึก วัตถุประสงค์ในการฝึกข่ายงาน คือหาค่าน้ำหนักที่เหมาะสมและทำให้ค่าแตกต่างระหว่างค่าเป้าหมายกับค่าที่ออกจากข่ายงานน้อยที่สุด ข้อกำหนดของค่าความแตกต่างคือผลรวมระหว่างค่าเป้าหมายกับเอาต์พุตของข่ายงานกำลังสอง (sum square error, SSE) ฟังก์ชันของผลต่างกำลังสอง คือ

$$E = [t - f(u, w)]^2 \quad (3.13)$$

โดย E คือฟังก์ชันพลังงานหรือฟังก์ชันต้นทุน (energy function or cost function) ของระบบ แบบจำลองของข่ายงานเป็นฟังก์ชันของอินพุตและเมทริกซ์ของน้ำหนัก, $y = f(u, w)$ เมทริกซ์ของน้ำหนักสามารถปรับค่าได้เพื่อให้ฟังก์ชันพลังงานมีค่าต่ำลงจนเหลือน้อยที่สุดไปในทิศทางลดลงของเกรเดียนต์ (gradient)

3.3.3.1 ข่ายงานการเรียนรู้แบบเปอร์เซปตรอน (Perceptron)

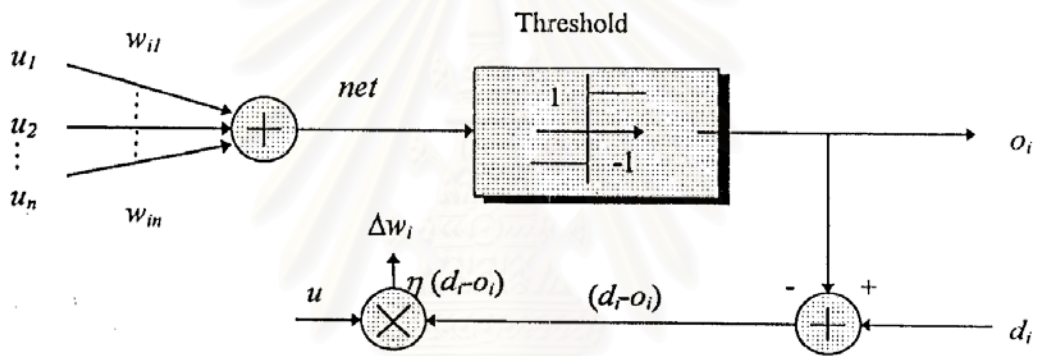
Rosenblatt (1958) ได้เสนอข่ายงานเปอร์เซปตรอนซึ่งเป็นแบบจำลองข่ายงานนิเวศแบบตัดสินใจเพื่อใช้ในการแยกข้อมูล 2 ระดับออกจากกัน โดยมีขอบเขตการตัดสินใจเป็นแบบเชิงเส้น (linear decision) ดังแสดงในรูปที่ 3.12 และ 3.13 ข่ายงานจะอาศัยสัญญาณเรียนรู้จากค่าแตกต่างระหว่างค่าเป้าหมายกับค่าเอาต์พุตที่ออกจากข่ายงานนิเวศและวนซ้ำจนกระทั่งได้ค่าน้ำหนักที่ถูกต้อง จึงเป็นการเรียนรู้แบบมีการชี้นำ เปอร์เซปตรอนใช้ฟังก์ชันมูลฐานเป็นฟังก์ชันเชิงเส้นและฟังก์ชันกระตุ้นเป็นฟังก์ชันแบบไบโพลาสเตฟ โดยสัญญาณการเรียนรู้แสดงสมการที่ 3.14

$$r = d_i - o_i \tag{3.14}$$


เมื่อ $o_i = f(u, w)$ และ d_i คือค่าเป้าหมายโดยการปรับค่าน้ำหนักแสดงดังสมการ 3.15

$$\Delta w_{ij} = \eta [d_i - f(w_{ij}^T u)] x_j \quad \text{เมื่อ } j = 1, 2, 3, \dots, n \tag{3.15}$$

ซึ่งการเรียนรู้แบบเปอร์เซปตรอนสามารถนำไปประยุกต์ใช้ได้กับระบบตัวเลขไบนารีเท่านั้น ดังนั้นแบบจำลองนี้จึงสามารถนำไปใช้ในแยกข้อมูล 2 ระดับออกจากกัน ซึ่งการปรับค่าน้ำหนักจะถูกกระทำก็ต่อเมื่อค่าเอาต์พุตจากข่ายงานนิวรัลไม่ตรงกับค่าเป้าหมาย



รูปที่ 3.12 ข่ายงานการเรียนรู้แบบเปอร์เซปตรอน



รูปที่ 3.13 การปรับหาขอบเขตแยกข้อมูล 2 ประเภท โดยข่ายงานเปอร์เซปตรอนเชิงเส้น

3.3.3.2 การเรียนรู้แบบเดลตา

McClelland และ Rumelhart (1986) เสนอแบบจำลองของข่ายงาน ADALINE (ADAaptive LINear Element) ที่ใช้กฎการเรียนรู้แบบเดลตาในการหาค่าน้ำหนัก

กฎการเรียนรู้แบบเดลตา (delta learning rule) เป็นการเรียนรู้แบบชี้้นำเพียงชนิดเดียวที่ใช้กับฟังก์ชันกระตุ้นแบบต่อเนื่อง ฟังก์ชันมูลฐานเป็นฟังก์ชันมูลฐานเชิงเส้น โครงสร้างการเรียนรู้ของข่ายงานอะดาไลนมีชั้นของน้ำหนักเพียง 1 ชั้น ดังรูปที่ 3.14 โดยมีนิยามการเรียนรู้ (learning signal,r) ดังนี้

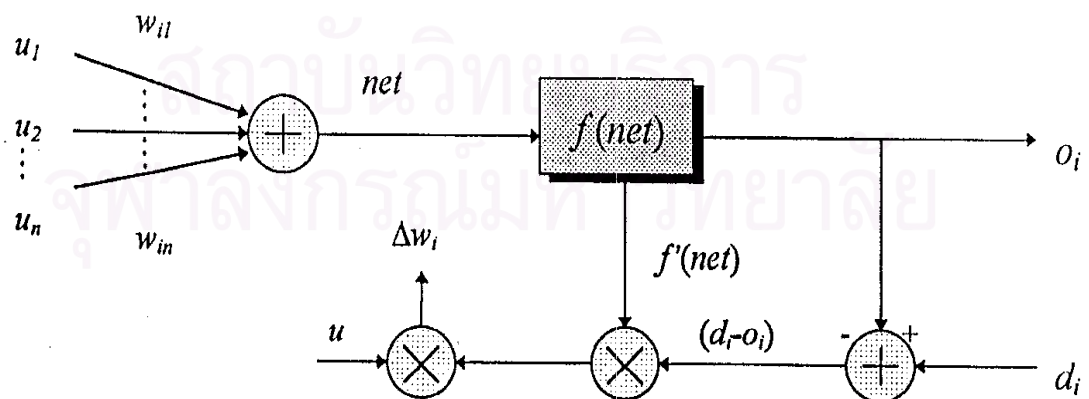
$$r = [d_i - f(\text{net})]f'(\text{net}) \tag{3.16}$$

เมื่อ $f'(\text{net})$ คืออนุพันธ์ของฟังก์ชันกระตุ้น, $f(\text{net})$ ซึ่งคำนวณจาก $\text{net} = w_{ij}u$

กฎการเรียนรู้สามารถหาได้จากค่าผิดพลาดระหว่าง o_i และ d_i ยกกำลังสอง การคำนวณเกรเดียนท์เวกเตอร์ (gradient vector) ได้จากการหาค่าอนุพันธ์ของค่าผิดพลาดเทียบกับ w_i เพื่อปรับค่าน้ำหนักซึ่งการเรียนรู้อยู่บนพื้นฐานการลดค่ากำลังสองของค่าแตกต่างให้น้อยที่สุด โดยมีนิยามดังนี้

$$\text{minimize } e = \frac{1}{2} (\sum (d_i - o_i)^2) \tag{3.17}$$

เมื่อเปรียบเทียบการเรียนรู้ของข่ายงานแบบเดลตากับเปอร์เซปตรอนพบว่ากฎการเรียนรู้แบบเดลตาใช้ค่าความแตกต่างของค่าเป้าหมาย, d_i เอาท์พุทของข่ายงาน, o_i บ้อนกลับโดยใช้การออดิไมซ์ ส่วนการเรียนรู้แบบเปอร์เซปตรอนใช้ค่าความแตกต่างระหว่างค่าเป้าหมายกับค่าเอาท์พุทของข่ายงานนิวัลโดยตรงเพื่อใช้ในการปรับค่าน้ำหนัก



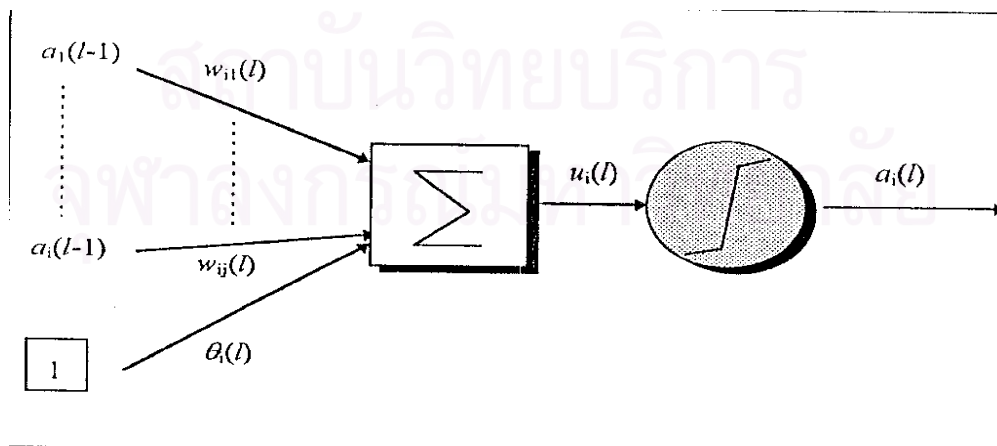
รูปที่ 3.14 ข่ายงานการเรียนรู้แบบเดลตา

3.3.3.3 ข่ายงานนิวรัลแบบกระจายความผิดพลาดย้อนกลับ (Error Back propagation neural network)

Werbos (1974) พัฒนาอัลกอริทึมการกระจายความผิดพลาดย้อนกลับ (Error Back propagation algorithm) ต่อมา Rumelhart (1986) ได้เสนออัลกอริทึมนี้อีกครั้งจึงทำให้อัลกอริทึมนี้เป็นที่รู้จักกันอย่างกว้างขวางและเป็นอัลกอริทึมมาตรฐานที่ใช้ในการฝึกข่ายงานแบบมีกรชี้นำ อัลกอริทึมการกระจายความผิดพลาดย้อนกลับนี้เป็นวิธีที่สามารถนำไปประยุกต์ใช้ในการหาจุดเหมาะสมสำหรับฟังก์ชันพลังงานเพื่อทำการหาค่าเกรเดียนท์อย่างได้ผล (Kung, 1993)

ข่ายงานนิวรัลแบบการกระจายความผิดพลาดย้อนกลับมีฟังก์ชันมูลฐานเป็นฟังก์ชันมูลฐานเชิงเส้น และมีฟังก์ชันซิกมอยด์เป็นฟังก์ชันกระตุ้น มีสมการไดนามิกดังสมการ (3.18) และ (3.19) ตามลำดับ และแสดงดังในรูปที่ 3.15

ข่ายงานนิวรัลแบบกระจายความผิดพลาดย้อนกลับจะทำการประมวลผลเป็นขั้นๆ โดยนำข้อมูลที่ต้องการใช้ในการฝึกเครือข่าย (Training set) ป้อนข้อมูลเข้าที่ชั้นอินพุท (Input layer) ผ่านชั้นซ่อน (Hidden layer) จนถึงชั้นเอาต์พุท (Output layer) สัญญาณที่ออกจากชั้นเอาต์พุทจะถูกนำไปเปรียบเทียบกับสัญญาณเป้าหมาย (Target signal) ซึ่งได้จากชุดของข้อมูลที่นำมาใช้ฝึกข่ายงาน จากนั้นค่าแตกต่างระหว่างสัญญาณทั้งสองจะถูกย้อนกลับเข้าสู่ข่ายงานอีกครั้ง โดยผ่านทางชั้นเอาต์พุทและชั้นซ่อนจนถึงชั้นอินพุท เพื่อปรับค่าพารามิเตอร์ ซึ่งได้แก่ น้ำหนัก ไบแอส และพารามิเตอร์ต่างๆของกฎที่ใช้ในการเรียนรู้ของข่ายงานในแต่ละชั้น ทำให้ข่ายงานสามารถเรียนรู้ชุดข้อมูลในรูปของพารามิเตอร์ และสร้างสัญญาณที่สอดคล้องกับข้อมูลที่ใช้ในการฝึกข่ายงาน



รูปที่ 3.15 แบบจำลองของนิวรอนในชั้นที่ i

- โดย $a_i(l-1)$ = ค่าอินพุตที่ i ของชั้นอินพุต
 O_i = ค่าเอาต์พุตที่ต้องการในชั้นเอาต์พุตตัวที่ i
 $a_i(l) = f(a_i) =$ ค่าเอาต์พุตจริงของนิวรอน i
 $u_i(l)$ = ค่าผลรวมของค่าน้ำหนักกับอินพุตโดยใช้การคำนวณแบบฟังก์ชันมูลฐาน
 w_{ij} = ค่าน้ำหนักที่เชื่อมต่อระหว่างนิวรอน i ในชั้นที่ $i-1$ กับนิวรอน j ในชั้นที่ i
 E = ค่าความผิดพลาด (global error)
 η = ค่าอัตราการเรียนรู้
 $b_i(l)$ = ค่าไบแอสของชั้นที่ i

$$u_i(l) = \sum_{j=1}^N w_{ij}(l)a_j(l-1) + \theta_i(l) \quad (3.18)$$

$$a_i(l) = f(u_i(l)) \quad 1 \leq i \leq N_i; 1 \leq l \leq L \quad (3.19)$$

ข่ายงานนิวรัลแบบกระจายย้อนกลับจะประกอบไปด้วยนิวรอนหลายๆนิวรอนที่เชื่อมโยงกันแบบป้อนไปข้างหน้า โดยโครงสร้างของข่ายงานนิวรัลจะประกอบด้วยชั้นอินพุต ชั้นซ่อนและชั้นเอาต์พุต ซึ่งชั้นอินพุตประกอบด้วยนิวรอนที่ไม่มีการคำนวณใดๆ แต่จะกระจายค่าอินพุตให้กับนิวรอนในชั้นถัดไป ส่วนชั้นซ่อนที่อยู่ระหว่างชั้นอินพุตและชั้นเอาต์พุตสามารถมีได้หลายชั้น แต่ในกรณีนี้จะพิจารณาเพียงชั้นเดียวเท่านั้น และชั้นเอาต์พุตทำหน้าที่ส่งค่าเอาต์พุตสุดท้ายของข่ายงานนิวรัล โดยนิวรอนในชั้นอินพุตรับค่าอินพุตเป็น i_1, \dots, i_N และมีน้ำหนักเป็น w_{1j}, \dots, w_{Nj} และในแต่ละชั้นแทน $i=0$ เป็นชั้นอินพุต $i=1$ เป็นชั้นซ่อนและ $i=2$ เป็นชั้นเอาต์พุต ผลรวมน้ำหนักของอินพุตของนิวรอนลำดับที่ j ในชั้นซ่อน คือ

$$u_j(1) = \sum_{i=1}^{N_1} w_{ij}(1)a_i(0) + b_j(1) \quad 1 \leq j \leq N_2 \quad (3.20)$$

เอาต์พุตของนิวรอนลำดับที่ j ในชั้นซ่อน คือ

$$a_j(1) = f(u_j(1)) \quad 1 \leq j \leq N_2 \quad (3.21)$$

เอาต์พุตของนิวรอนในชั้นซ่อนใช้เป็นอินพุตให้แก่นิวรอนในชั้นเอาต์พุตอีกทอดหนึ่ง

$$u_j(2) = \sum_{j=1}^{N_2} w_{ij}(2)a_j(1) + b_j(2) \quad 1 \leq j \leq N_3 \quad (3.22)$$

นิเวรอนในชั้นเอาต์พุตสร้างเอาต์พุตของกระบวนการที่ถูกทำนายในช่วงหนึ่งคาบการเก็บตัวอย่าง (one sampling period) หรือช่วงหนึ่งรอบที่วนในการคำนวณจากชั้นอินพุตจนถึงชั้นเอาต์พุต ดังแสดงในสมการ

$$a_j(2) = f(u_j(2)) \quad (3.23)$$

เมื่อ $b_i(1)$ และ b_j เป็นเทอมไบแอส (bias term) ซึ่งเป็นน้ำหนักโดยใช้ค่าอินพุตที่มีค่าเป็น 1 และ a_2 หมายถึงค่าเอาต์พุตจากข่ายงานนิเวรล

เมื่อ f แทนด้วยฟังก์ชันกระตุ้นซึ่งมักเป็นฟังก์ชันซิกมอยด์ (sigmoid function) โดยมีสมการดังนี้

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.24)$$

และอนุพันธ์ของฟังก์ชันซิกมอยด์ คือ

$$f'(x) = x(1-x) \quad (3.25)$$

โดยค่าอนุพันธ์ของฟังก์ชันซิกมอยด์จะนำไปใช้ในอัลกอริทึมการกระจายความผิดพลาดย้อนกลับที่จะกล่าวถึงในหัวข้อถัดไป

วิธีการหาค่าเหมาะที่สุด (Optimization method)

อัลกอริทึมการกระจายความผิดพลาดย้อนกลับเป็นอัลกอริทึมที่ต้องการลดค่าผิดพลาดกำลังสองระหว่างค่าเป้าหมายกับผลลัพธ์จากข่ายงาน โดยใช้วิธีการหาค่าเหมาะที่สุดแบบเกรเดียนต์เดสเซนทซึ่งเป็นวิธีการลดความผิดพลาด ซึ่งแสดงในสมการ (3.26) เพื่อหาค่าน้ำหนักที่ถูกต้องเพื่อที่สามารถจำลองแบบกระบวนการให้สามารถทำนายค่าเอาต์พุตจากค่าอินพุตที่รับเข้าไปได้ถูกต้อง

สำหรับข้อมูลแต่ละชุด

$$\begin{aligned} \text{minimize} \quad & E = \frac{1}{2} \sum_{i=1}^{N_i} (t_i - a_i(L))^2 \\ \text{subject to :} \quad & t_{\max} > t_i > t_{\min} \end{aligned} \quad (3.26)$$

$$a_{\max} > a_i(L) > a_{\min}$$

เมื่อ	E	คือค่าความผิดพลาด (global error) ที่ชั้นเอาต์พุต ได้มาจากผลรวมกำลังสองของความแตกต่างของเอาต์พุตที่ได้จากการคำนวณกับค่าเป้าหมายในชั้นเอาต์พุต
	t_i	คือ ค่าเป้าหมาย
	t_{\max}	คือค่าสูงสุดของเป้าหมาย
	t_{\min}	คือค่าต่ำสุดของเป้าหมาย
	$a_i(L)$	คือ ค่าเอาต์พุตของข่ายงาน
	a_{\max}	คือค่าสูงสุดของเอาต์พุตของข่ายงาน
	a_{\min}	คือค่าต่ำสุดของเอาต์พุตของข่ายงาน

เพราะเกรเดียนต์เดสเซนท์ คือการลดค่าผิดพลาดให้ต่ำที่สุดโดยการปรับค่าน้ำหนัก ดังนั้นจะทราบทิศทางที่น้ำหนักไปในทิศทางที่ลดค่าความผิดพลาดเมื่อทราบค่าอนุพันธ์ย่อย (partial derivative) ของค่าผิดพลาดเทียบกับค่าน้ำหนักแต่ละค่า นั่นคือ $\partial E / \partial w_{ij}$ สำหรับอัลกอริทึมการกระจายความผิดพลาดย้อนกลับจะทำการปรับค่าน้ำหนัก (w_{ij}) เพื่อให้มีค่า E ต่ำที่สุด สมการการเรียนรู้แบบเกรเดียนต์แสดงในสมการ (3.27)

$$w_{ij}^{new}(L) = w_{ij}^{old}(L) + \Delta w_{ij}(L) \quad (3.27)$$

อนุพันธ์ของค่าผิดพลาดจะใช้วิธีการตามเทคนิคของกฎลูกโซ่ (Chain Rule) ของชุดข้อมูลการฝึก (iteration)

$$\begin{aligned} \Delta w_i(L) &= -\eta \frac{\partial E}{\partial w_i(L)} \\ &= -\eta \frac{\partial E}{\partial a_i(L)} \frac{\partial a_i(L)}{\partial w_i(L)} \end{aligned} \quad (3.28)$$

จากสมการ 3.28 นำมาแยกพิจารณาที่ละเทอมจะได้

$$\begin{aligned}
\frac{\partial a_i(l)}{\partial w_{ij}(l)} &= \frac{\partial f(u_i(l))}{\partial w_{ij}(l)} \\
&= \frac{\partial f(\sum_{j=1}^N w_{ij}(l)a_j(l-1) + \theta_i(l))}{\partial w_{ij}(l)} \quad (3.29) \\
&= f'(u_i(l))a_j(l-1)
\end{aligned}$$

กำหนดให้สัญญาณความผิดพลาด $\delta_i(l)$ เป็น

$$\delta_i(l) = -\frac{\partial E}{\partial a_i(l)} \quad (3.30)$$

แทน (3.29) และ (3.30) ใน (3.28) จะได้

$$\Delta w_{ij}(l) = \eta \delta_i(l) f'(u_i(l)) a_j(l-1) \quad (3.31)$$

ก. ค่าสัญญาณความแตกต่างในชั้นเอาต์พุตสามารถหาได้จากการแทนค่า E ลงในสมการ (3.30)

$$\begin{aligned}
\delta_i(L) &= -\frac{\partial E}{\partial a_i(L)} \\
&= -\frac{\partial (\frac{1}{2} \sum_{i=1}^N (t_i - a_i(L))^2)}{\partial a_i(L)} \quad (3.32)
\end{aligned}$$

$$= -\frac{1}{2}(2)(t_i - a_i(L))(-1)$$

$$\delta_i(L) = t_i - a_i(L)$$

ข. ค่าสัญญาณความแตกต่างในชั้นซ่อน คือ

$$\begin{aligned}
\delta_i(l) &= -\frac{\partial E}{\partial a_i(l)} \\
&= -\sum_{j=1}^N \frac{\partial E}{\partial u_i(l+1)} \frac{\partial u_i(l+1)}{\partial a_i(l)} \quad (3.33)
\end{aligned}$$

นำมาแยกที่ละเทอมโดยพิจารณาเทอมแรกจะได้

$$\begin{aligned} -\frac{\partial E}{\partial u_i(l+1)} &= -\frac{\partial\left(\frac{1}{2}(t_i - a_i(L))^2\right)}{\partial u_i(l+1)} \\ &= (t_i - a_i(L))\frac{\partial a_i(L)}{\partial u_i(l+1)} \end{aligned}$$

สมการ (3.14) แทนค่าลงใน $a_i(L)$ จะได้

$$-\frac{\partial E}{\partial u_i(l+1)} = (t_i - a_i(L))\frac{\partial f(u_i(L))}{\partial u_i(l+1)}$$

ในกรณีนี้ $L = l+1$ ดังนั้น

$$-\frac{\partial E}{\partial u_i(l+1)} = (t_i - a_i(L))f'(u_i(l+1))$$

สมการ (3.32) แทนค่าใน $(t_i - a_i(L))$ จะได้

$$-\frac{\partial E}{\partial u_i(l+1)} = \delta_i(l+1)f'(u_i(l+1)) \quad (3.34)$$

สมการ (3.33) เทอมที่ 2 ที่ได้จากการแทนสมการ (3.13) คือ

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

$$\begin{aligned}\frac{\partial u_i(l+1)}{\partial a_i(l)} &= \frac{\partial (w_{ij}(l+1)a_i(l) + \theta_i(l+1))}{\partial a_i(l)} \\ &= w_{ij}(l+1)\end{aligned}\quad (3.35)$$

สมการ (3.34) และ (3.35) แทนใน (3.33) โดย $l = L-1, \dots, 1$ จะได้สัญญาณความแตกต่างในชั้นซ่อน คือ

$$\delta_i(l) = \sum_{j=1}^{N_{l+1}} \delta_j(l+1) f'(u_i(l+1)) w_{ij}(l+1) \quad (3.36)$$

ถ้ามีชั้นซ่อนจำนวน n ชั้นต้องคำนวณหาค่าสัญญาณความแตกต่างใน (3.36) จำนวน n ครั้งเพื่อนำไปใช้เป็นแฟคเตอร์ในการปรับค่าน้ำหนัก

แทนค่า (3.31) ลงใน (3.27) ค่าน้ำหนักเชื่อมโยงระหว่างชั้นที่ l กับชั้นที่ $l-1$ สามารถปรับค่าโดยความสัมพันธ์ดังนี้ (ตามลำดับของ $l = L-1, \dots, 1$)

$$w_{ij}^{new}(l) = w_{ij}^{old}(l) + \eta \delta_i(l) f'(u_i(l)) a_j(l-1) \quad (3.37)$$

สำหรับการเรียนรู้ที่ใช้อัลกอริทึมการกระจายย้อนกลับ สัญญาณความแตกต่างของชั้นที่ต่ำกว่า $\delta_i(l)$ สามารถคำนวณได้โดยการรวมสัญญาณความแตกต่างของชั้นที่อยู่เหนือกว่า $\delta_i(l+1)$ ดังนั้นสัญญาณความแตกต่างจึงสามารถกระจายย้อนกลับผ่านชั้นทั้งหมดจากชั้นบนลงสู่ชั้นล่าง ซึ่งหมายถึงว่าชั้นอยู่เหนือกว่าจะมีอิทธิพลต่อชั้นที่อยู่ต่ำกว่า

ขั้นตอนของอัลกอริทึมการกระจายความผิดพลาดย้อนกลับ

การเรียนรู้ของอัลกอริทึมการกระจายความผิดพลาดย้อนกลับสำหรับข่ายงานนิวรัลแสดงดังรูปที่ 3.15 ต้องกำหนดรูปแบบ (pattern) ของข้อมูลการเรียนรู้ ซึ่งเป็นกลุ่มข้อมูลของคู่ลำดับของอินพุต u_i และค่าเป้าหมาย t_i จำนวน p คู่ โดยชุดของข้อมูลสามารถเขียนแทนได้ดังนี้

$$P = \{(u_1, t_1), (u_2, t_2), (u_3, t_3), \dots, (u_p, t_p)\} \quad (3.38)$$

โดย P คือชุดของข้อมูลที่ใช้ในการฝึกเครือข่าย (Training set)

p คือจำนวนชุดข้อมูลที่ใช้ในการฝึกเครือข่าย (Training pair)

ขั้นตอนที่ 1 กำหนดค่าเริ่มต้นของพารามิเตอร์ของข่ายงานนิวรัล

กำหนดค่าอัตราการเรียนรู้ (learning rate, η) ให้มีค่ามากกว่าศูนย์ กำหนดค่าผิดพลาดต่ำสุด (E_{\min}) และกำหนดค่าเริ่มต้นให้กับน้ำหนัก(weight)ที่เชื่อมต่อระหว่างนิวรอนแต่ละชั้น $W_{ij}(l)$ โดยใช้ตัวเลขสุ่มค่าน้ำหนักที่มีค่าน้อยๆ กำหนดข้อมูลคู่แรกเข้ามา $p = 1$ ให้ค่าผิดพลาดเริ่มต้น $E = 0$ และเริ่มการเรียนรู้ด้วยการวนรอบครั้งที่ 1 ($q = 1$) เพื่อเริ่มต้นกระบวนการประมวลผลของข่ายงาน

ขั้นตอนที่ 2 กระบวนการประมวลผล

กระบวนการประมวลผลผลของข่ายงานนิเวศแบ่งออกเป็น 2 ขั้นตอน คือ

2.1 การคำนวณไปข้างหน้า (Feedforward Calculation)

การคำนวณเริ่มจากชั้นอินพุท ผ่านชั้นซ่อนภายในจนถึงชั้นเอาต์พุท ซึ่งแสดงดังสมการ (3.39) ส่งอินพุทและค่าเป้าหมายที่สอดคล้องกันให้นิวรอนของชั้นอินพุทเพื่อรับข้อมูลซึ่งก็คือ $u = u_p, t = t_p$ และคำนวณค่าผลลัพธ์ให้นิวรอนในชั้นซ่อนและชั้นเอาต์พุทโดยใช้ฟังก์ชันซิกมอยด์เป็นฟังก์ชันกระตุ้น

$$\begin{aligned} u_i(l) &= \sum_{j=1}^N w_{ij}(l)a_j(l-1) + \theta_i(l) \\ a_i(l) &= f(u_i(l)) \quad 1 \leq i \leq N_i; 1 \leq l \leq L \end{aligned} \quad (3.39)$$

เมื่ออินพุทคือ $x_i = a_j(0)$ และเอาต์พุทคือ $y_i = a_i(L)$ และ l คือจำนวนชั้นทั้งหมดของข่ายงานนิเวศ ส่วน i คือนิวรอนที่ i ในชั้น j

2.2 การคำนวณและแพร่ความคลาดเคลื่อนย้อนกลับ (Backpropagation of Error)

ทำการคำนวณค่าความผิดพลาดเพื่อใช้ในการปรับค่าน้ำหนักของข่ายงานนิเวศเพื่อลดค่าความคลาดเคลื่อนหรือค่าแตกต่างระหว่างค่าเป้าหมาย t_i กับสัญญาณที่ออกจากข่ายงานนิเวศในชั้นเอาต์พุท a_i โดยการออปติไมซ์แบบเกรเดียนต์ โดยให้ E คือค่าผิดพลาดระหว่างค่าเป้าหมาย (t_i) กับผลลัพธ์จากข่ายงาน ($a_i(L)$)

$$E^{new} = E^{old} + \frac{1}{2} \sum_{i=1}^{N_3} \{t_i - a_i(L)\}^2 \quad (3.40)$$

เมื่อ N_L คือ จำนวนนิวรอนในชั้นเอาต์พุท t_i คือค่าเป้าหมายของนิวรอนในชั้นเอาต์พุทตัวที่ i และ o_i คือเอาต์พุทของนิวรอนในชั้นเอาต์พุทตัวที่ i

ทำการคำนวณค่าเวกเตอร์สัญญาณความผิดพลาดโดยสัญญาณความผิดพลาดสำหรับชั้นเอาต์พุต คือ

$$\delta_i(L) = (t_i - a_i(L)) \quad \text{เมื่อ } i = 1, 2, \dots, N_L \quad (3.41)$$

และสัญญาณความผิดพลาดสำหรับชั้นซ่อน คือ

$$\delta_i(l) = \sum_{j=1}^{N_{i+1}} (\delta_j(l+1)W_{ij}(l+1)a_j(l+1)(1-a_j(l+1))) \quad \text{เมื่อ } i = 1, 2, \dots, N_i \quad (3.42)$$

ในกรณีที่มีจำนวนชั้นซ่อน n ชั้น ต้องหาค่าสัญญาณความผิดพลาด n ครั้งด้วย

ขั้นตอนที่ 3 ปรับค่าน้ำหนักที่เชื่อมระหว่างชั้น

เป็นการปรับค่าน้ำหนักที่เชื่อมระหว่างชั้นเอาต์พุตกับชั้นซ่อนและระหว่างชั้นอินพุตกับชั้นซ่อน โดยเมื่อทำงานนิรอรอนผ่านการประมวลผลจากขั้นตอนที่ 2 แล้ว หน่วยงานจะทำการปรับค่าน้ำหนักและไบแอสในแต่ละชั้นใหม่เพื่อให้สอดคล้องกับชุดข้อมูลความรู้ใหม่ที่ได้เรียนรู้ ทำให้ฟังก์ชันความคลาดเคลื่อนดังสมการ (3.43) มีค่าลดลง

$$W_{ij}(l)^{new} = W_{ij}(l)^{old} + \eta \delta_i(l) a_j(l-1) \quad (3.43)$$

เมื่อ $i = 1, 2, \dots, N_l$ $j = 1, 2, \dots, N_{l-1}$ และ w_{ij} คือน้ำหนักของ node ที่ i ใน layer ชั้นที่ j

ขั้นตอนที่ 4 ตรวจสอบชุดข้อมูลการเรียนรู้

ในการฝึกข่ายงานนิรวัล ข้อมูลที่ใช้ในการฝึกจะถูกป้อนเข้ามาทีละ 1 คู่ลำดับของข้อมูลอินพุตและข้อมูลเป้าหมายและเนื่องจากชุดข้อมูลที่ใช้ฝึกมีจำนวนมากจึงต้องทำการตรวจสอบจำนวนข้อมูลที่ใช้ในการฝึกข่ายงานได้รับมาครบหรือไม่ ถ้าชุดข้อมูลยังไม่ถูกทำงานจนครบรอบ ($p < P$) ให้ส่งข้อมูลของชุดถัดไป ไปยังนิรอรอนในชั้นอินพุต โดยที่ $p = p + 1$ และ $q = q + 1$ แล้วจึงกลับไปทำขั้นตอนที่ 2 แต่ถ้าชุดข้อมูลได้ถูกเรียนรู้จนครบแล้ว ให้ไปดำเนินการขั้นตอนที่ 5

ขั้นตอนที่ 5 ตรวจสอบค่าความผิดพลาดกับค่าต่ำสุดที่ตั้งไว้

ขั้นตอนการเรียนรู้จะเสร็จสมบูรณ์เมื่อค่าความผิดพลาดในการเรียนรู้มีค่าน้อยกว่าค่าความผิดพลาดต่ำสุดที่ตั้งไว้ ($E < E_{\min}$) เพราะวัตถุประสงค์ของการฝึกข่ายงานนิวรัลก็คือ การลดค่าความผิดพลาดระหว่างข้อมูลที่ออกจากข่ายงานกับค่าเป้าหมายให้มีค่าน้อยที่สุด ถ้า $E > E_{\min}$ แล้วให้ $E = 0$ และ $p = 1$ แล้วเริ่มวงจรการเรียนรู้ใหม่ตามขั้นตอนที่ 2


การเร่งการเรียนรู้โดยใช้โมเมนตัม

การเรียนรู้โดยใช้โมเมนตัมช่วยเร่งให้การเรียนรู้ของข่ายงานเข้าสู่ค่าเป้าหมายได้เร็วขึ้น โดยการนำค่าน้ำหนักล่าสุดมาใช้ในการปรับค่าน้ำหนักในปัจจุบันตามขั้นตอนที่ 3 และ 4 ตามสัดส่วนของค่าโมเมนตัมดังสมการ (3.44)

$$\Delta w(t) = -\eta \nabla E(t) + \alpha \Delta w(t-1) \quad (3.44)$$

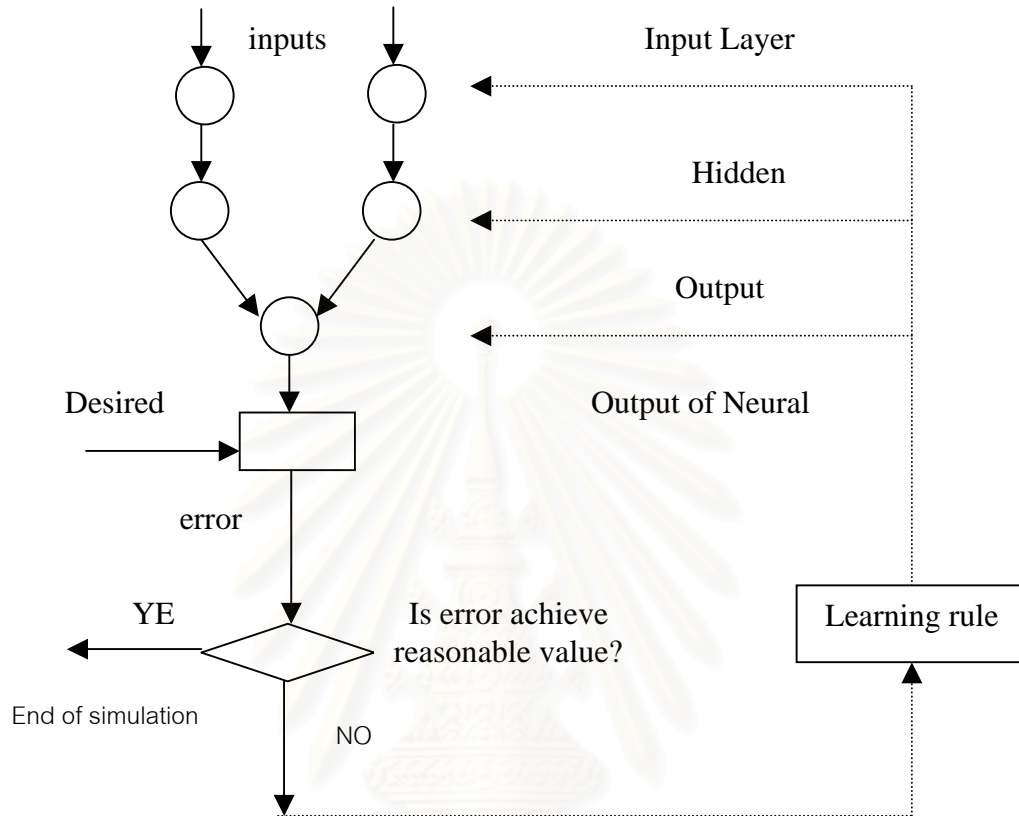
เมื่อ t คือ จำนวนรอบของข้อมูลที่ฝึกข่ายงาน
 α คือ แฟคเตอร์โมเมนตัมที่มักเลือกค่าอยู่ระหว่าง 0-1

รูปที่ 3.16 แสดงวิธีการเร่งการเรียนรู้ของข่ายงานโดยใช้โมเมนตัม และการเรียนรู้เริ่มต้นที่จุด A' ค่าเกรเดียนท์ของค่าความผิดพลาดเมื่อเทียบกับค่าน้ำหนัก $\partial E / \partial w_1$ และ $\partial E / \partial w_2$ ที่จุด A' และ A'' มีเครื่องหมายตรงกัน ดังนั้นองค์ประกอบเกรเดียนท์จะถูกนำมารวมกันซึ่งทำให้การเข้าสู่ค่าเป้าหมายรวดเร็วขึ้น โดยการปรับค่าน้ำหนักที่จุด A'' ซึ่งอาศัยค่าน้ำหนักที่จุด A' เข้ามาช่วยด้วยตามสัดส่วนของค่าโมเมนตัม



รูปที่ 3.16 การเรียนรู้แบบการกระจายความผิดพลาดย้อนกลับที่มีการรวมค่าแพกเตอร์โมเมนตัม
มาใช้ในการปรับค่าน้ำหนัก


ดังนั้นหลักการเรียนรู้ของข่ายงานนิวรัลแบบการกระจายความผิดพลาดย้อนกลับ สามารถอธิบายได้ดังรูปที่ 3.17



รูปที่ 3.17 ขั้นตอนการเรียนรู้ของข่ายงานนิวรัล

ตัวอย่างที่ 3.1 การคำนวณข่ายงานนิวรัลที่ใช้อัลกอริทึมการกระจายความผิดพลาดย้อนกลับ

ตัวอย่างนี้เป็นข่ายงานนิวรัลแบบป้อนไปข้างหน้า 2 ชั้น โดยมีชั้นอินพุต 1 ชั้น ชั้นซ่อน 1 ชั้นที่มีจำนวนนิวรอนในชั้นซ่อน 2 นิวรอน และชั้นเอาต์พุต 1 ชั้น



ขั้นตอนการเรียนรู้ของอัลกอริทึมการกระจายความผิดพลาดย้อนกลับสามารถคำนวณได้
ดังนี้

กำหนดชุดข้อมูลมี 1 ชุด คือ

$$\text{อินพุท} \quad p = 5$$

$$\text{เป้าหมาย} \quad t = 1 + \sin\left(\frac{p \times p_i}{4}\right) = 0.293$$

ขั้นตอนที่ 1 การกำหนดค่าเริ่มต้นของพารามิเตอร์ของข่ายงานนิวรัล

กำหนดค่า	อัตราการเรียนรู้ (learning rate): η	= 0.1
	ความผิดพลาดต่ำสุด:	$E_{\min} = 0.02$
	น้ำหนักเริ่มต้น(weight):	$W1(1,1) = -0.270$
		$W1(2,1) = -0.410$
		$W2(1,1) = -0.090$
		$W2(1,2) = -0.170$
	ไบแอส(bias):	$b1(1) = -0.480$
		$b1(2) = -0.130$
		$b2 = 0.480$
	ค่าผิดพลาดเริ่มต้น :	$E = 0$

เริ่มการเรียนรู้ด้วยการวนรอบ, q ครั้งที่ 1 ($q=1$) เพื่อใช้เป็นจุดเริ่มต้นในกระบวนการประมวลผล

ขั้นตอนที่ 2 กระบวนการประมวลผล

1.1 การคำนวณไปข้างหน้า (Feedforward Calculation) ดังสมการ (3.39)

$$u_i(l) = \sum_{j=1}^N w_{ij}(l)a_j(l-1) + \theta_i(l) \quad (3.39)$$

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

คำนวณฟังก์ชันมูลฐานชั้นอินพุท	$n1(1) = (0.270*5) + (-0.48*1) = -1.83$
คำนวณฟังก์ชันกระตุ้นซิกมอยด์ชั้นอินพุท	$a1(1) = 1/(1 + e^{-(-1.83)}) = 0.138$
คำนวณฟังก์ชันมูลฐานชั้นซ่อนที่ 1	$n1(2) = (-0.410*5) + (-0.13*1) = -2.18$
คำนวณฟังก์ชันกระตุ้นซิกมอยด์ชั้นซ่อนที่ 1	$a1(2) = 1/(1 + e^{-(-2.18)}) = 0.102$

คำนวณฟังก์ชันมาตรฐานชั้นเอาต์พุท	$n1(3) = (0.09*0.138*5)+(-0.17*0.102)+$
	$(-0.48*1) = 0.475$
คำนวณฟังก์ชันกระตุ้นเชิงเส้นชั้นเอาต์พุท	$a2 = 0.475$
คำนวณค่าความผิดพลาดชั้นเอาต์พุท	$e = t - a2 = 0.293 - 0.475 = -0.182$

1.2 การกระจายความผิดพลาดย้อนกลับ (Error Backpropagation)

เมื่อสัญญาณความผิดพลาดสำหรับชั้นเอาต์พุทจากสมการ (3.41) คือ

$$\delta_i(L) = (t_i - a_i(L)) \quad , i = 1, 2, \dots, N_i \quad (3.41)$$

โดย $e = -0.182$ จะได้ว่า

$$s2 = -2 * -0.182 * 0.475 / 0.475 = 0.365$$

และเมื่อสัญญาณความผิดพลาดสำหรับชั้นซ่อนแต่ละชั้น จากสมการ (3.42) คือ

$$\delta_i(l) = \sum_{j=1}^{N_{i+1}} (\delta_j(l+1) W_{ij}(l+1) a_j(l+1) (1 - a_j(l+1))) \quad , i = 1, 2, \dots, N \quad (3.42)$$

จะได้ว่า

$$s1(1) = (0.365 * 0.09 * 0.138 * (1 - 0.138)) = 0.004$$

$$s1(2) = (0.365 * -0.17 * 0.102 * (1 - 0.102)) = -0.006$$

ขั้นตอนที่ 3 การปรับค่าน้ำหนักที่เชื่อมระหว่างชั้นเอาต์พุทกับชั้นซ่อน หรือชั้นอินพุทกับชั้นซ่อนดังสมการ (3.43)

$$W_{ij}(l)^{new} = W_{ij}(l)^{old} + \eta \delta_i(l) a_j(l-1) \quad (3.43)$$

จะได้

$$W1(1,1) = -0.27 + (0.1 * 0.004 * 5) = -0.268$$

$$b1(1) = -0.480 + (0.1 * 0.004 * 1) = -0.480$$

$$W1(2,1) = -0.41 + (0.1 * -0.006 * 5) = -0.413$$

$$b1(2) = -0.130 + (0.1 * -0.006 * 1) = -0.131$$

$$W2(1,1) = 0.09+(0.1*0.365*0.138) = 0.095$$

$$W2(1,2) = -0.170+(0.1*0.365*0.102) = -0.166$$

$$b2 = 0.480+(0.1*0.365*1) = 0.517$$

ขั้นตอนที่ 4 ตรวจสอบจำนวนชุดข้อมูลการเรียนรู้

ข้อมูลเรียนรู้จนครบแล้ว ($p=p$) ให้ดำเนินการต่อในขั้นตอนที่ 5

ขั้นตอนที่ 5 ตรวจสอบความผิดพลาดกับค่าต่ำที่สุดที่ตั้งไว้

ตรวจสอบว่า $E < E_{\min}$ หรือไม่: $-0.182 > 0.02$

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

ถ้า $E < E_{\min}$ แล้วให้หยุดการฝึกข่ายงาน

3.3.3 แบบจำลองของกระบวนการข่ายงานนิวรัล

แบบจำลองที่ใช้ในการหาแบบจำลองของกระบวนการของข่ายงานนิวรัลมีอยู่ 2 แบบ คือ แบบจำลองแบบไม่กลับกระแสกับแบบจำลองแบบกลับกระแส ซึ่งทั้งสองแบบจำลองนี้มีความแตกต่างกันในด้านการจัดการข้อมูลอินพุตกับเอาต์พุตที่สอดคล้องกันกับการหน่วงเวลาก่อนที่จะป้อนให้กับข่ายงานได้เรียนรู้ โดยกระบวนการที่ใช้อาจเป็นแบบสถิต (static) หรือพลศาสตร์ (dynamic)

ก. แบบจำลองแบบไม่กลับกระแส (non-recurrent model)

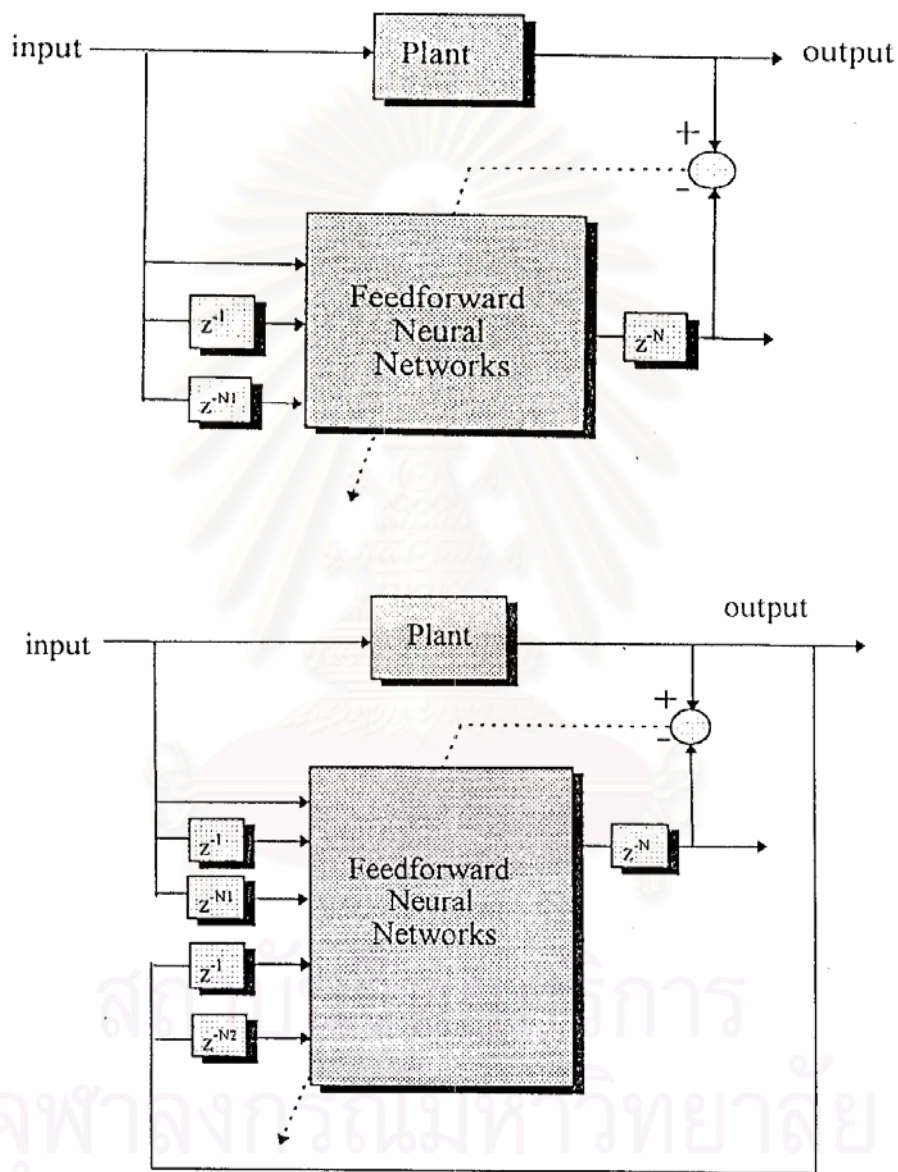
แบบจำลองนี้ใช้จำลองกระบวนการแบบสถิต (static process) ซึ่งเอาต์พุตเป็นฟังก์ชันกับอินพุตที่เวลาปัจจุบันและในอดีต โดยอินพุตเวกเตอร์ของข่ายงานนี้เป็นค่าอินพุตปัจจุบันและอินพุตในอดีต แบบจำลองนี้หาได้โดยการนำข้อมูลที่ป้อนเข้าสู่กระบวนการมาหน่วงเวลาตามช่วงระยะเวลาที่ต้องการ จำนวนการหน่วงเวลาจะเท่ากับจำนวนนิวรอนในชั้นอินพุต โดยที่ไม่มีค่าเอาต์พุตจากกระบวนการมาใช้เป็นข้อมูลในการป้อนให้กับนิวรอนในชั้นอินพุตเลย ดังแสดงในรูปที่ 3.18

ข. แบบจำลองแบบกลับกระแส (recurrent model)

เหมาะกับการกระบวนการทางพลศาสตร์ (dynamic process) เอาต์พุตปัจจุบันของข่ายงานขึ้นกับค่าอินพุตในปัจจุบัน อินพุตในอดีตและเอาต์พุตในอดีต แสดงดังรูปที่ 3.19 จำนวนของการหน่วงเวลาที่ต้องการจะเป็นอินพุตและเอาต์พุตทั้งเส้นทางป้อนไปข้างหน้าและป้อนกลับ ซึ่งขึ้นกับคุณสมบัติของกระบวนการ แบบจำลองนี้หาได้โดยการนำข้อมูลที่ป้อนเข้าสู่ระบบกับเอาต์พุตของ

กระบวนการมาหนึ่งเวลา ก่อนป้อนเข้าสู่ชั้นอินพุทของข่ายงาน แบบจำลองนี้จะมีค่าเป้าหมายในอดีตของระบบเป็นตัวช่วยกำหนดแนวทางในการเรียนรู้โดยทำให้หาคำตอบได้เร็วขึ้น จึงเป็นวิธีการที่นิยมมากที่สุดและเลือกใช้วิธีการนี้เพื่อสร้างแบบจำลองในงานวิจัยนี้

รูปที่ 3.18 แบบจำลองแบบไม่กลับกระแส



รูปที่ 3.19 แบบจำลองแบบกลับกระแส

3.4 บทสรุป

การนำรายงานนิวัตน์ไปประยุกต์ใช้กับกระบวนการ ต้องคำนึงถึงโครงสร้างของรายงานที่เหมาะสม ซึ่งจะแตกต่างกันไปขึ้นกับแต่ละกระบวนการ ทั้งจำนวนอินพุตเวกเตอร์ เอาท์พุทเวกเตอร์ จำนวนนิเวศในชั้นซ่อน และจำนวนชั้นซ่อน การเลือกการเรียนรู้ซึ่งในงานวิจัยนี้เลือกใช้อัลกอริทึมการกระจายย้อนกลับ กับโครงสร้างรายงานแบบป้อนไปข้างหน้าหลายชั้นโดยใช้แบบจำลองแบบกลับกระแส



สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

บทที่ 4

โครงสร้างของแบบจำลอง และโครงสร้างของตัวควบคุม

ในบทนี้กล่าวถึงโครงสร้างของแบบจำลองของข่ายงานนิวรัล ซึ่งมีอยู่ 4 โครงสร้าง (Brown, 1994) คือ แบบจำลองกระบวนการ แบบจำลองแบบผกผันโดยตรง แบบจำลองแบบผกผันโดยทางอ้อมและแบบจำลองโอเปอเรเตอร์ และกล่าวถึงโครงสร้างการควบคุมแบบต่างๆ คือ การควบคุมแบบมีการชี้้นำ การควบคุมแบบผกผันโดยตรงและการควบคุมแบบนิวรัลอะแดพทีฟ

4.1 โครงสร้างการเรียนรู้ของแบบจำลอง

แบบจำลองที่ใช้ในการศึกษาเรื่องระบบควบคุมมีอยู่ 4 แบบ (Brown, 1994) คือ โครงสร้างของแบบจำลองกระบวนการ (structure of plant model) โครงสร้างของแบบจำลองแบบผกผันโดยตรง (structure of direct inverse model) โครงสร้างของแบบจำลองแบบผกผันโดยทางอ้อม (structure of indirect inverse model) และโครงสร้างของแบบจำลองแบบโอเปอเรเตอร์ (structure of operator model)

4.1.1 โครงสร้างของแบบจำลองกระบวนการ

แบบจำลองของกระบวนการมักใช้ภายในลู่อุปการควบคุมแบบป้อนกลับ(feedback control loop) ซึ่งต้องการการประมาณค่าของเอาต์พุทของกระบวนการเพื่อทำนายสมรรถนะของกระบวนการซึ่งเอาต์พุทของมันไม่สามารถหาได้เนื่องจากการหน่วงเวลา (time delay) โครงสร้างแบบนี้ซึ่งแสดงดังรูปที่ 4.1 เป็นโครงสร้างที่ง่าย สัญญาณการควบคุมที่ใช้เป็นอินพุทและเอาต์พุทของกระบวนการได้มาจากการสุ่มตัวอย่างแล้วนำมาสร้างอินพุทเวกเตอร์ (input vector) ของข่ายงาน ซึ่งอินพุทเวกเตอร์ก็คือ ค่าอินพุทของกระบวนการในปัจจุบัน และค่าอินพุทของกระบวนการในอดีตซึ่งนำมาใช้เป็นอินพุทให้แก่ข่ายงาน และนำค่าความแตกต่างระหว่างเอาต์พุทของข่ายงานและเอาต์พุทของกระบวนการมาใช้ในการปรับค่าน้ำหนักเพื่อลดความผิดพลาดระหว่างเอาต์พุทของข่ายงานกับเอาต์พุทของกระบวนการ

$$\varepsilon_y(t) = y_p(t) - y_m(t) \quad (4.1)$$

เมื่อ $y_p(t)$ คือเอาต์พุตของกระบวนการ และ $y_m(t)$ คือเอาต์พุตของข่ายงานที่เวลา t การเรียนรู้ถูกกำหนดเพื่อลดค่าผลรวมของค่าผิดพลาดยกกำลังสอง (Sum square error) ให้มีค่าน้อยที่สุดและฟังก์ชันพลังงานจะหาได้โดย

$$J_y = E(\varepsilon_y^2(t)) \quad (4.2)$$

4.1.2 โครงสร้างของแบบจำลองแบบผกผันโดยตรง

การสร้างแบบจำลองแบบผกผันโดยตรงนั้นมีจุดประสงค์เพื่อสร้างตัวควบคุม การฝึกข่ายงานต้องการข้อมูลของกระบวนการที่สามารถผกผันได้ หรือกระบวนการที่ไม่สามารถผกผันได้แต่อินพุตของกระบวนการสามารถผกผันได้ในช่วงที่สนใจ :ซึ่งโครงสร้างนี้แสดงในรูปที่ 4.2 โดยฟังก์ชันพลังงาน คือ

$$J_u = E(\varepsilon_u^2(t)) \quad (4.3)$$

เมื่อ $\varepsilon_u(t) = u(t) - u_m(t)$ โดยที่ $u(t)$ คือสัญญาณการควบคุม และ $u_m(t)$ คือเอาต์พุตของข่ายงาน สำหรับกระบวนการที่มีอินพุตหนึ่งค่าและเอาต์พุตหนึ่งค่า ค่าผิดพลาดของสัญญาณการควบคุมสัมพันธ์กับค่าผิดพลาดในเอาต์พุตของกระบวนการดังนี้ เมื่อคูณ $u(t) - u_m(t)$ กับสมการที่ 4.1 ทั้งเศษและส่วน จะได้

$$\varepsilon_y(t) = \frac{y_p(t) - y_m(t)}{u(t) - u_m(t)} \times u(t) - u_m(t) \quad (4.4)$$

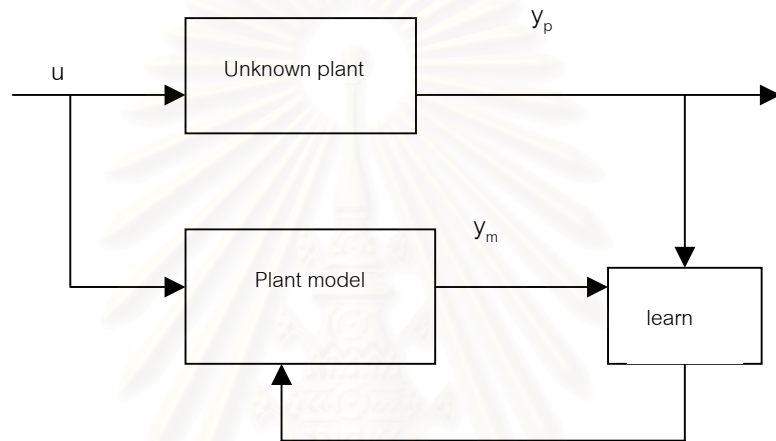
ดังนั้น
$$\frac{d\varepsilon_y(t)}{du(t)} = dy(t) \varepsilon_u(t) \quad (4.5)$$

เมื่อ $\frac{dy}{du}$ เป็นอนุพันธ์ของกระบวนการหรือ Jacobian ดังนั้นฟังก์ชันพลังงานทั้งสองในสมการ (4.2) และ (4.3) สามารถประมาณให้มีความสัมพันธ์กันโดย

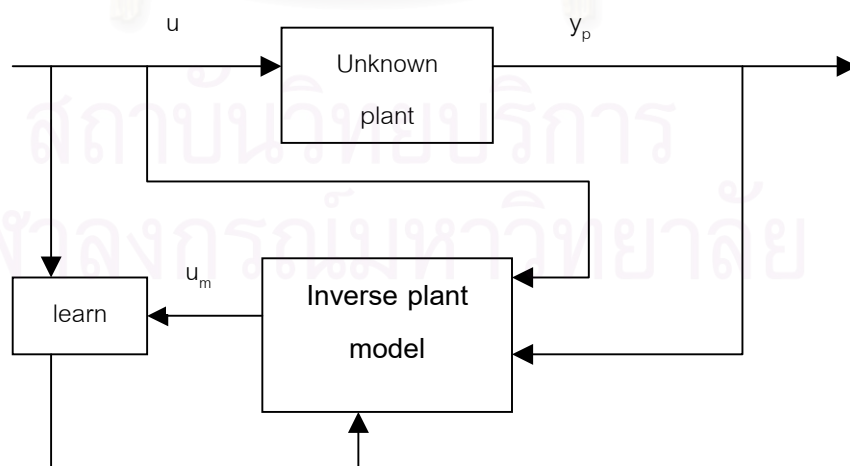
$$J_y = \left(\frac{dy(t)}{du(t)} \right)^2 \varepsilon_u^2(t) \quad (4.6)$$

ถ้าค่าผิดพลาดของเอาต์พุตไม่สัมพันธ์กับ Jacobian ผลของ Jacobian จะสามารถรวมเข้าไปใน อัตราการเรียนรู้ (learning rate) ทำให้สมการที่ (4.6) อยู่ในรูปที่ง่ายขึ้น ดังสมการที่ (4.7)

$$J_y = E \left(\left(\frac{dy(t)}{du(t)} \right)^2 \right) J_u \quad (4.7)$$



รูปที่ 4.1 โครงสร้างการเรียนรู้ของแบบจำลองกระบวนการ



รูปที่ 4.2 โครงสร้างการเรียนรู้ของแบบจำลองแบบผกผันโดยตรง

ดังนั้นฟังก์ชันพลังงาน, J_y จึงมีความสัมพันธ์กับฟังก์ชันพลังงาน, J_u ดังสมการ (4.7) โดยแบบจำลองแบบนี้ต้องการสัญญาณการควบคุมเป็นเป้าหมายในการฝึกข่ายงาน และในระหว่างการควบคุมจะไม่ทราบสัญญาณการควบคุมนี้ ดังนั้นแบบจำลองนี้จึงสามารถฝึกข่ายงานแบบออฟไลน์เท่านั้น

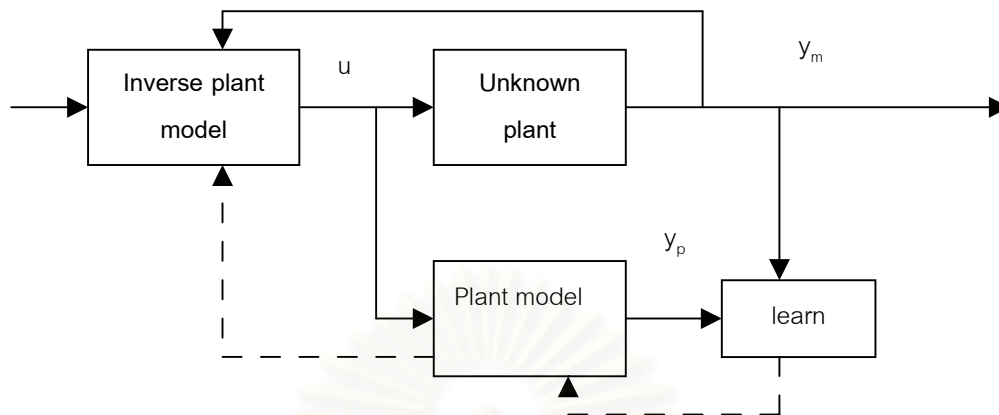
4.1.3 โครงสร้างของแบบจำลองแบบผกผันโดยทางอ้อม

Jordan และ Rumelhart (1991) ได้ศึกษาโครงสร้างของแบบจำลองแบบผกผันโดยทางอ้อมซึ่งแสดงในรูปที่ 4.3 โดยต้องใช้แบบจำลองแบบป้อนไปข้างหน้า (feedforward model) ของกระบวนการเข้ามาช่วยและใช้ค่าความแตกต่างระหว่างเอาต์พุตของกระบวนการกับเอาต์พุตที่ต้องการเป็นสัญญาณค่าความผิดพลาดโดยย้อนกลับผ่านแบบจำลองกระบวนการในการปรับค่าน้ำหนักของแบบจำลอง

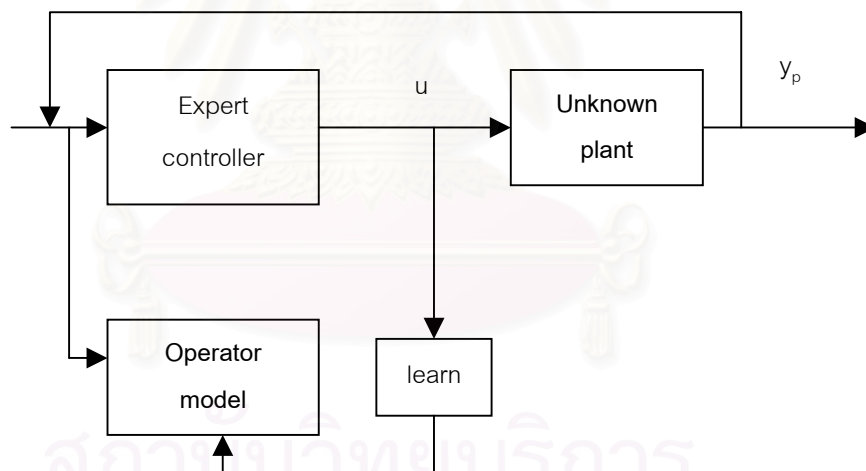
ต่อมา Hunt และคณะ (1992) ได้เสนอว่าสามารถสร้างตัวควบคุมได้จากโครงสร้างแบบจำลองแบบผกผันโดยทางอ้อม แต่อาจมีความไวบัสต์น้อยกว่าตัวควบคุมที่มีการเรียนรู้ตัวอื่น ๆ ในกรณีที่ไม่ใช่ข้อมูลป้อนกลับ

4.1.4 โครงสร้างของแบบจำลองโอบิเรเตอร์

การสร้างตัวควบคุมชนิดนี้ได้ถูกเสนอโดย Shepanki และ Macy (1978) ซึ่งเป็นอัลกอริทึมการเรียนรู้จากผู้เชี่ยวชาญ (expert) และการตอบสนองจะสร้างเอาต์พุตได้ตามต้องการซึ่งใช้เพื่อฝึกข่ายงาน แต่จำเป็นต้องกรองสัญญาณก่อนที่จะนำไปฝึกเนื่องจากโอบิเรเตอร์จะกระทำต่ออินพุตที่คล้ายๆกันแตกต่างกัน สัญญาณที่ใช้ฝึกจึงมีสัญญาณรบกวนมาก แบบจำลองชนิดนี้ซึ่งแสดงดังรูปที่ 4.4 มีข้อจำกัด คือ ตัวควบคุมที่ได้ขึ้นกับทักษะของโอบิเรเตอร์แต่ละคน



รูปที่ 4.3 โครงสร้างการเรียนรู้ของแบบจำลองแบบผกผันโดยทางอ้อม



รูปที่ 4.4 โครงสร้างการเรียนรู้ของแบบจำลองโอบะเรเตอร์

4.2 โครงสร้างของตัวควบคุมแบบนิวรัล (Neural control)

ในบทที่ 2 เห็นได้ว่ามีผู้เสนอโครงสร้างการควบคุมโดยใช้ข่ายงานนิวรัลหลายแบบ ในที่นี้จะกล่าวถึงโครงสร้างที่เป็นพื้นฐาน คือ โครงสร้างการควบคุมแบบมีการชี้นำ โครงสร้างการควบคุมแบบผกผันโดยทางตรงซึ่งเป็นตัวควบคุมที่ใช้ในงานวิจัยนี้

4.2.1 โครงสร้างของการควบคุมแบบมีการชี้นำ (Supervised control)

ข่ายงานนิวรัลเลียนแบบการทำงานของมนุษย์โดยข่ายงานได้รับอินพุตและเอาต์พุตจากระบบ และผลต่างของเอาต์พุตของข่ายงานกับเอาต์พุตที่ต้องการจะถูกป้อนกลับเพื่อเปลี่ยนแปลงค่าน้ำหนักของข่ายงานในทิศทางที่ลดค่าผิดพลาด เมื่อข่ายงานมีการตอบสนองแล้วการฝึกจะสิ้นสุดลง การควบคุมแบบมีการชี้นำทำได้ง่ายทั้งในแนวความคิดและปฏิบัติ

4.2.2 โครงสร้างของการควบคุมแบบผกผันโดยทางตรง (Direct inverse control)

ข่ายงานนิวรัลจะสามารถนำมาใช้เป็นตัวควบคุมได้ ถ้ากระบวนการสามารถแทนได้ด้วยฟังก์ชันที่ผกผันได้ ในขั้นตอนการฝึกสำหรับโครงสร้างการควบคุมแบบผกผันโดยตรงซึ่งแสดงในรูปที่ 4.5(ก) ข่ายงานได้เรียนรู้ฟังก์ชันแบบผกผันของกระบวนการ และได้รับเอาต์พุตจากกระบวนการเป็นอินพุต ความแตกต่างระหว่างเอาต์พุตของตัวควบคุมแบบนิวรัลกับอินพุตของกระบวนการคือค่าสัญญาณความผิดพลาดซึ่งถูกใช้เพื่อปรับค่าน้ำหนักของข่ายงานโดยใช้อัลกอริทึมการกระจายความผิดพลาดย้อนกลับ เมื่อข่ายงานได้รับการฝึกแล้วกระบวนการจะถูกควบคุมด้วยโครงสร้างแบบผกผันโดยทางตรงแสดงดังรูปที่ 4.5(ข) เมื่อการรวมกันของ $F(F^{-1}) = 1$ นั่นคือเอาต์พุตของกระบวนการจะเท่ากับอินพุต, X นั่นเอง วิธีนี้ไม่สามารถใช้ได้กับกระบวนการที่ฟังก์ชันของกระบวนการผกผันไม่ได้เนื่องจากอาจมีอินพุตของกระบวนการมากกว่าหนึ่งตัวที่ให้เอาต์พุตค่าเดียวกัน

4.2.3 โครงสร้างของการควบคุมแบบนิวรัลอะแดปทีฟ (Neural adaptive control)

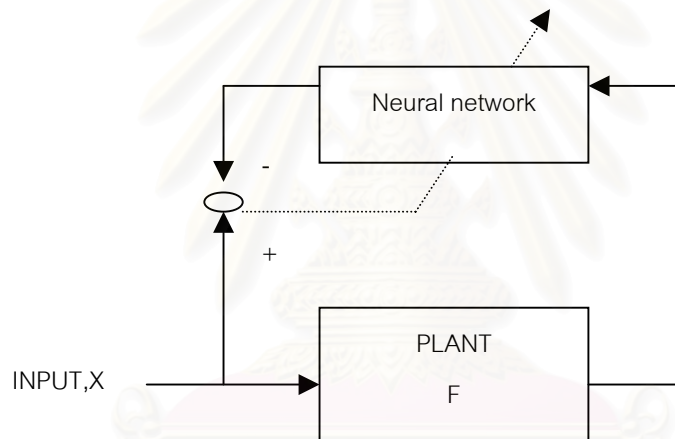
โครงสร้างการควบคุมแบบนิวรัลอะแดปทีฟแบ่งเป็นสองโครงสร้าง คือ โครงสร้างการควบคุมแบบนิวรัลอะแดปทีฟแบบเชิงเส้นและการควบคุมแบบนิวรัลอะแดปทีฟแบบไม่เชิงเส้น

ก. โครงสร้างการควบคุมแบบนิรวัลอะแดฟทีฟแบบเชิงเส้น


โครงสร้างการควบคุมแบบนิรวัลอะแดฟทีฟแบบเชิงเส้นซึ่งแสดงดังรูปที่ 4.6 เป็นการเรียนรู้โดยทางตรง ซึ่งไม่สามารถใช้ได้กับกระบวนการแบบไม่เชิงเส้น เนื่องจากไม่สามารถหาการเปลี่ยนแปลงคุณสมบัติของการตอบสนองของตัวควบคุมเพื่อทำให้ค่าผิดพลาดสำหรับการควบคุมมีค่าน้อยที่สุดได้

ข. โครงสร้างการควบคุมแบบนิรวัลอะแดฟทีฟแบบไม่เชิงเส้น

โครงสร้างการควบคุมแบบนิรวัลอะแดฟทีฟแบบไม่เชิงเส้นซึ่งแสดงดังรูปที่ 4.7 เป็นการเรียนรู้โดยทางอ้อม ซึ่งโครงสร้างนี้สามารถใช้ได้กับทั้งกระบวนการที่เป็นเชิงเส้นและไม่เป็นเชิงเส้น ในระหว่างการฝึกทั้งแบบจำลองที่ได้จากข่ายงานและกระบวนการจะได้รับอินพุตค่าเดียวกัน ซึ่งค่าผิดพลาดก็คือค่าความแตกต่างของเอาต์พุตของแบบจำลองกับเอาต์พุตของกระบวนการจะถูกกระจายย้อนกลับเพื่อปรับค่าน้ำหนัก เมื่อได้รับการฝึกแล้วเอาต์พุตของแบบจำลองจะใกล้เคียงกับเอาต์พุตของกระบวนการ

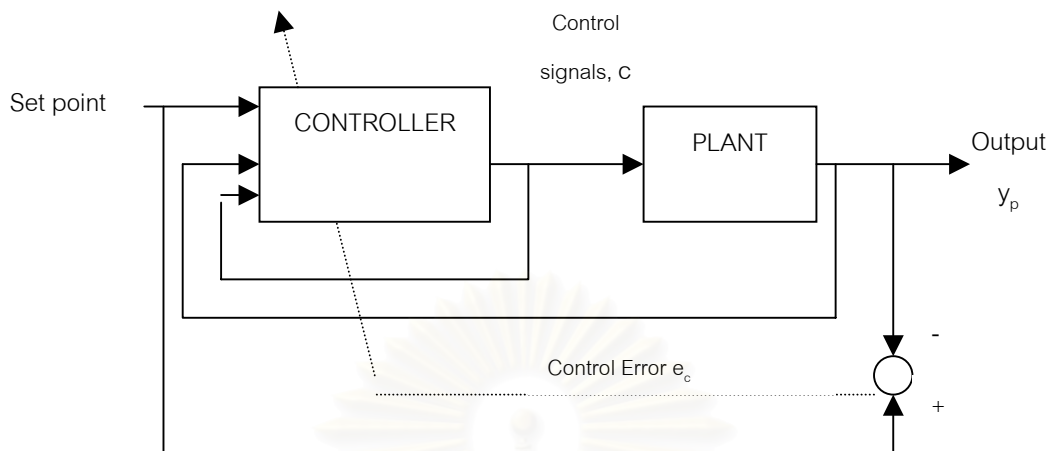


(ก) การเรียนรู้อินเวอร์สฟังก์ชัน

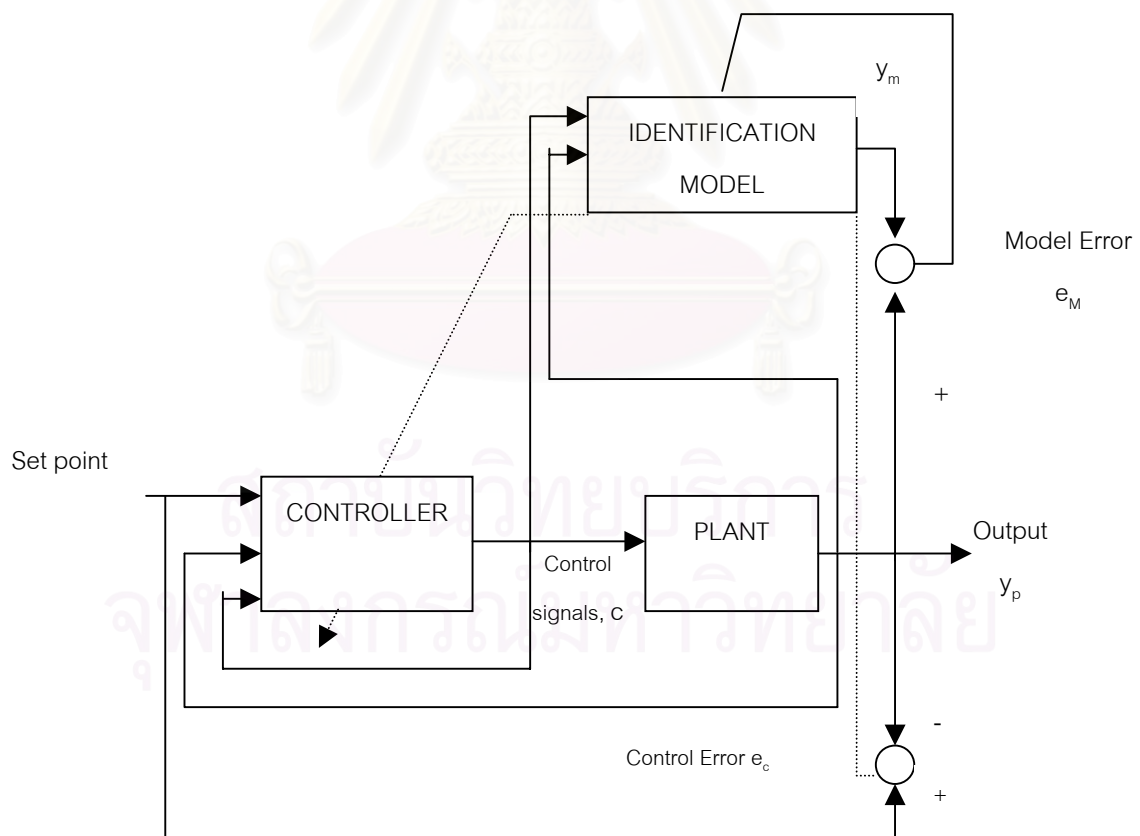


(ข) การควบคุมโดยใช้อินเวอร์สฟังก์ชัน

รูปที่ 4.5 โครงสร้างการควบคุมแบบผกผันโดยทางตรง



รูปที่ 4.6 โครงสร้างการควบคุมแบบนิรลอะแดฟทีฟแบบเชิงเส้น




รูปที่ 4.7 โครงสร้างการควบคุมแบบนิรลอะแดฟทีฟแบบไม่เชิงเส้น

บทที่ 5 กระบวนการที่ใช้ในการศึกษา

ในบทนี้จะกล่าวถึงกระบวนการย่อยเยื่อกระดาษซึ่งเป็นกระบวนการที่ใช้ในการศึกษาโดยอธิบายถึงตัวย่อยเยื่อกระดาษ และแบบจำลองทางคณิตศาสตร์ของกระบวนการที่ใช้รวมถึงสภาวะต่างๆของกระบวนการ

5.1 ตัวย่อยเยื่อกระดาษ

กระบวนการผลิตเยื่อกระดาษสามารถทำได้หลายวิธี แต่ที่เป็นที่นิยมโดยทั่วไป คือ กระบวนการคราฟท์ (Kraft process) หรือกระบวนการซัลเฟต (sulfate process) ซึ่งกระบวนการนี้จะใช้ทั้งตัวย่อยเยื่อกระดาษแบบกะ (Batch digester) และแบบต่อเนื่อง (continuous digester) โดยในการวิจัยทำการศึกษาย่อยเยื่อกระดาษแบบกะ ในกระบวนการคราฟท์จะมีขั้นตอนการกำจัดลิกนิน (Delignification) โดยใช้สารละลายที่ประกอบด้วยโซเดียมไฮดรอกไซด์ (Sodiumhydroxide:NaOH) และโซเดียมซัลไฟด์ (Sodiumsulphide: Na_2S) ในสัดส่วนโมลโดยประมาณ 5:2 ตามลำดับ มีความเป็นกรด-เบส (pH) อยู่ในช่วง 13.5-14.0 ปฏิกริยาจะถูกกระตุ้นด้วยความร้อนหมุนเวียนจากเครื่องแลกเปลี่ยนความร้อนภายนอก (external heat exchanger) โดยอุณหภูมิในการปฏิบัติการจะอยู่ในช่วง $160-180^\circ\text{C}$ เมื่อเวลาครบตามกำหนดขึ้นไม้จะถูกผลักดันให้เคลื่อนไปยังถังเก็บ ทำให้ชิ้นไม้แตกย่อยออกเป็นเยื่อ จากนั้นเยื่อนี้ก็จะผ่านหน่วยการผลิตอื่นๆ ต่อไปจนครบกระบวนการผลิตกระดาษ



รูปที่ 5.1 ตัวย่อยเยื่อกระดาษแบบกะ (Batch pulp digester)

ในกระบวนการย่อยเยื่อกระดาษนั้นต้องการให้ได้เยื่อกระดาษที่มีคุณภาพดีและสม่ำเสมอ จึงต้องทำการควบคุมค่าแคปปา (Kappa number) ซึ่งเป็นค่าที่บ่งถึงปริมาณลิกนินที่เหลืออยู่ในเยื่อให้มีค่าใกล้เคียงกับค่าแคปปาที่ต้องการมากที่สุด

เพราะฉะนั้นตัวแปรควบคุม คือ ค่าแคปปา และตัวแปรปรับคืออุณหภูมิและอัตราการไหลของสายหมุนเวียน (Recirculated liquor) แต่เนื่องจากกระบวนการนี้มีข้อจำกัด คือ ไม่สามารถวัดค่าแคปปาได้โดยตรงและออนไลน์ จึงต้องทำการประมาณค่าจากค่าตัวแปรอื่นที่วัดได้ ซึ่งก็คืออุณหภูมิของเครื่องย่อยเยื่อกระดาษและความเข้มข้นโซเดียมไฮดรอกไซด์ใน free liquor (Effective alkali) โดยค่าแคปปานั้นนอกจากจะขึ้นกับตัวแปรทั้งสองที่สามารถวัดได้นี้แล้วยังขึ้นกับชนิดของไม้ที่ใช้เป็นวัตถุดิบอีกด้วย

5.2 แบบจำลองทางคณิตศาสตร์ของกระบวนการ

สมการค่าแคปปา

$$K = 653.3(X_1 + X_2) \quad (5.1)$$

สมการสมดุลมวลขององค์ประกอบของไม้

$$\frac{dx}{dt} = R_i \quad (1 \leq i \leq 5) \quad (5.2)$$

โดยองค์ประกอบ i ที่ 1 ถึง 5 ของไม้ คือ high-reactive lignin, low-reactive lignin, cellulose, galactoglucosannan (hemicellulose 1) และ araboxylan (hemicellulose 2) ตามลำดับ

สมการสมดุลมวลย่อยใน entrapped liquor

$$V_e \frac{dC_{e_i}}{dt} = M_w G_i - M_i A(C_{e_i} - C_{f_i}) \quad (1 \leq i \leq 4) \quad (5.3)$$

สมการสมดุลมวลย่อยใน free liquor

$$V_f \frac{dC_{f_i}}{dt} = M_i A(C_{e_i} - C_{f_i}) - F_r(C_{f_i} - C_{f_i}) \quad (1 \leq i \leq 4) \quad (5.4)$$

โดยองค์ประกอบ i ที่ 1 ถึง 4 ใน entrapped liquor และ free liquor คือ dissolved lignin dissolved solid (ยกเว้น ลิกนินที่ออกมาจากไม้) NaOH และ Na_2S ตามลำดับ

สมการสมดุลพลังงาน

$$K_t \frac{dT}{dt} = M_w \sum_{i=1}^{N_w} (-R_i)(-\Delta H_i) + F_r \sum_{i=1}^{N_f+1} C_{r_i} C_{p_r} (T_r - T) \quad (5.5)$$

โดยอัตราการเกิดปฏิกิริยาเคมี คือ

$$R_i = -[k_{1_i} C_{e_3} + k_{2_i} C_{e_3}^a C_{e_4}^b](X_i - X_{u_i}) \quad (5.6)$$

และสัมประสิทธิ์อัตราการเกิดปฏิกิริยาเป็นไปตามความสัมพันธ์ของอาร์เรเนียส

$$k_{1_i} = A_{1_i} e^{E_{1_i}/RT} \quad (5.7)$$

$$k_{2_i} = A_{2_i} e^{E_{2_i}/RT} \quad (5.8)$$

โดยอัตราการเกิดขององค์ประกอบใน entrapped liquor เป็นดังนี้

$$\text{Lignin} : G_1 = -\sum_{j=1}^2 R_j \quad (5.9)$$

$$\text{Solid} : G_2 = -\sum_{j=3}^5 R_j \quad (5.10)$$

$$\text{NaOH} : G_3 = -\sum_{j=1}^5 S_{c_{3j}} R_j \quad (5.11)$$

$$\text{NaSH} : G_4 = -\sum_{j=1}^5 S_{c_{4j}} R_j \quad (5.12)$$

สัมประสิทธิ์การถ่ายเทมวลขององค์ประกอบระหว่างเฟสของ entrapped liquor กับ free liquor

$$M_i = M_{1_i} + M_{2_i} T \quad (5.13)$$

ความจุความร้อนรวมเป็นดังนี้

$$K_t = [M_w \sum_{i=1}^{N_w} C_{p_{w_i}} X_i + V_e \sum_{i=1}^{N_e+1} C_{p_{e_i}} C_{e_i} + V_f \sum_{i=1}^{N_f+1} C_{p_{f_i}} C_{f_i}] \quad (5.14)$$

ตารางที่ 5.1 แสดงค่าพารามิเตอร์ต่างๆของกระบวนการที่ใช้ในการวิจัย

ลำดับ	พารามิเตอร์	ค่าพารามิเตอร์	หน่วย
1	A ₁₁	19.41	h ⁻¹ (kg/m) ⁻¹
	A ₁₂	4.16e+12	
	A ₁₃	445.12	
	A ₁₄	108	
	A ₁₅	7.5e+05	
2	A ₂₁	7e+3	h ⁻¹ (kg/m) ^{-a-b}
	A ₂₂	2.75e+4	
	A ₂₃	8.3e+3	
	A ₂₄	6e+3	
	A ₂₅	1.75e+4	
3	E ₁₁	6.45e+3	kcal/kmol
	E ₁₂	29.1e+3	
	E ₁₃	17.55e+4	
	E ₁₄	14.85e+3	
	E ₁₅	22.05e+3	

ตารางที่ 5.1(ต่อ) แสดงค่าพารามิเตอร์ของกระบวนการที่ใช้ในงานวิจัย

ลำดับ	พารามิเตอร์	ค่าพารามิเตอร์	หน่วย
4	E_{21}	21.9e+3	kcal/kmol
	E_{22}	12.35e+3	
	E_{23}	19.85e+4	
	E_{24}	17.45e+3	
	E_{25}	18.25e+3	
5	a	0.5	-
6	b	0.5	-
7	X_{U1}	0	-
	X_{U2}	0	
	X_{U3}	0.071	
	X_{U4}	0.025	
	X_{U5}	0	
8	Sc_{31}	0.166	kg/kg
	Sc_{32}	0.166	
	Sc_{33}	0.395	
	Sc_{34}	0.395	
	Sc_{35}	0.395	
9	Sc_{41}	0.0546	kg/kg
	Sc_{42}	0.0546	
	Sc_{43}	0	
	Sc_{44}	0	
	Sc_{45}	0	
10	M_{11}	-0.06	M/h
11	M_{21}	2e-4	M/h.K
12	ΔH_i	102.8	kcal/kg
13	Cp_{wi}	0.36	kcal/kg.K

ตารางที่ 5.2 แสดงค่าพารามิเตอร์ต่างๆที่สภาวะเริ่มต้น

ลำดับ	พารามิเตอร์	คำอธิบาย	ค่าที่สภาวะเริ่มต้น	หน่วย
1	X_1	ความเข้มข้นขององค์ประกอบในไม้ตัวที่ 1	0.0528	-
2	X_2	ความเข้มข้นขององค์ประกอบในไม้ตัวที่ 2	0.2112	-
3	X_3	ความเข้มข้นขององค์ประกอบในไม้ตัวที่ 3	0.4852	-
4	X_4	ความเข้มข้นขององค์ประกอบในไม้ตัวที่ 4	0.1428	-
5	X_5	ความเข้มข้นขององค์ประกอบในไม้ตัวที่ 5	0.7220	-
6	Ce_1	ความเข้มข้นขององค์ประกอบใน entrapped liquor ตัวที่ 1	0	kg/m ³
7	Ce_2	ความเข้มข้นขององค์ประกอบใน entrapped liquor ตัวที่ 2	0	kg/m ³
8	Ce_3	ความเข้มข้นขององค์ประกอบใน entrapped liquor ตัวที่ 3	0	kg/m ³
9	Ce_4	ความเข้มข้นขององค์ประกอบใน entrapped liquor ตัวที่ 4	0	kg/m ³
10	Cf_1	ความเข้มข้นขององค์ประกอบใน free liquor ตัวที่ 1	1.0000	kg/m ³
11	Cf_2	ความเข้มข้นขององค์ประกอบใน free liquor ตัวที่ 2	2.0000	kg/m ³
12	Cf_3	ความเข้มข้นขององค์ประกอบใน free liquor ตัวที่ 3	47.6327	kg/m ³
13	Cf_4	ความเข้มข้นขององค์ประกอบใน free liquor ตัวที่ 4	11.3535	kg/m ³
14	T	อุณหภูมิ	80	เซลเซียส

ตารางที่ 5.3 แสดงค่าพารามิเตอร์ในสภาวะปฏิบัติการ

ลำดับ	พารามิเตอร์	ค่าที่สภาวะปฏิบัติการ	หน่วย
1	พื้นที่หน้าตัด	105.75	ตารางเมตร
2	ค่าแคปปาเริ่มต้น	172.5	-
3	ค่าแคปปาเป้าหมาย (Ksp)	50	-
4	เวลา (Cooking time)	2	ชั่วโมง
5	ระยะเวลาที่สุ่มตัวอย่าง (Sampling time)	0.0025	ชั่วโมง
6	อุณหภูมิเป้าหมาย (Tsp)	443	เซลเซียส

โดยกระบวนการย่อยเยื่อกระดาษนี้มีเงื่อนไขว่า อุณหภูมิในสายหมุนเวียนจะมีค่ามากที่สุดได้ไม่เกิน 250°C และมีค่าน้อยที่สุดเท่ากับอุณหภูมิของเครื่องย่อยเยื่อกระดาษ และอัตราการไหลของสายหมุนเวียนมีค่ามากที่สุดและน้อยที่สุดเท่ากับ 1 และ $0.5 \text{ m}^3/\text{hr}$ ตามลำดับ

5.3 การปรับค่าพารามิเตอร์เพื่อใช้ในงานวิจัย

ในงานวิจัยนี้ใช้แบบจำลองทางคณิตศาสตร์และพารามิเตอร์ของ Lee และ Datta (1994) ซึ่งแสดงในหัวข้อที่ 5.2 และตารางที่ 5.1 โดยมีการปรับค่าพารามิเตอร์บางตัว โดยค่าที่ปรับเพื่อใช้ในงานวิจัยเทียบกับค่าของ Lee และ Datta แสดงในตารางที่ 5.4 เนื่องจากเมื่อใช้ค่าพารามิเตอร์ทั้งหมดของ Lee และ Datta (1994) พบว่ากระบวนการไม่เกิดปฏิกิริยาและการเปลี่ยนแปลงใดๆ แสดงผลดังรูปที่ 5.2 เห็นได้ว่าค่าแคปปา สัดส่วนมวลขององค์ประกอบทั้ง 5 ของไม้ รวมถึงปริมาณ white liquor ไม่มีการเปลี่ยนแปลงค่าใดๆ แสดงว่าไม่เกิดปฏิกิริยาใดๆ ขึ้น

พารามิเตอร์ที่ทำการปรับค่า คือ พลังงานกระตุ้นอันดับหนึ่งและสองขององค์ประกอบทั้ง 5 ของไม้ โดยการปรับค่าพารามิเตอร์เพื่อใช้ในงานวิจัยมีหลักการดังนี้


1. ปรับค่าของ Lee และ Datta ลงจนถึงค่าแรกที่เริ่มเกิดปฏิกิริยาและมีการเปลี่ยนแปลงของสาร
2. ปรับค่าต่อไปจนถึงค่าแรกที่ทำให้ไม่สามารถอ่านค่าแคปปาได้
3. เลือกใช้ค่ากลางระหว่างค่าที่ได้จากขั้นตอนที่ 1 และ 2 เป็นค่าในการวิจัย

ตารางที่ 5.4 ค่าพารามิเตอร์ที่ใช้ในงานวิจัยเทียบกับของ Lee และ Datta (1994)


พารามิเตอร์	ค่าจริงจาก Lee และ Datta	ค่าที่ใช้ในการวิจัย	หน่วย
E_{11}	639.28	6.45	$*10^3$
E_{12}	33.77	29.1	kcal/kmol
E_{13}	1.94e+3	17.55	
E_{14}	717.94	14.85	
E_{15}	3.95e+18	22.05	
E_{21}	7.5e+3	21.9	$*10^3$
E_{22}	9e+3	12.35	kcal/kmol
E_{23}	1e+4	19.85	
E_{24}	9e+3	17.45	
E_{25}	4e+4	18.25	

ตัวอย่างการปรับค่า E_{11} ทำโดยการลดค่าจริงของ Lee และ Datta ตามขั้นตอนที่ 1 จนได้ค่า E_{11} เท่ากับ $10.5e3$ kcal/kmol ซึ่งเป็นค่าแรกที่เริ่มเกิดปฏิกิริยาและมีการเปลี่ยนแปลงของสารแสดงดังรูปที่ 5.3 เห็นได้ว่าค่าแคปปาเริ่มลดลง แม้สัดส่วนมวลขององค์ประกอบทั้ง 5 ของไม้จะยังคงไม่เปลี่ยนแปลงเนื่องจากปฏิกิริยาเพิ่งเริ่มเกิดขึ้น ความเข้มข้นของ white liquor ก็ลดลงแสดงให้เห็นว่าเริ่มถูกใช้ไปในการทำปฏิกิริยา จากนั้นลดค่าต่อไปตามขั้นตอนที่ 2 ได้ค่า E_{11} เท่ากับ $2.4e3$ kcal/kmol ซึ่งเป็นค่าแรกที่ทำให้กราฟค่าแคปปาขาด ซึ่งไม่สามารถอ่านค่าได้ แสดงดังรูปที่ 5.4 ดังนั้นทำการเลือกค่ากลางระหว่างค่าที่ได้จากขั้นตอนที่ 1 และ 2 คือ $6.45e3$ kcal/kmol


สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย



(ก) ค่าแคปปา




(ข) สัดส่วนมวลขององค์ประกอบของไม้




(ค) ความเข้มข้นของ White Liquor


รูปที่ 5.2 ผลของกระบวนการเมื่อใช้พารามิเตอร์ทุกค่าของ Lee และ Datta (1994)



(ก) ค่าแคปปา




(ข) สัดส่วนมวลขององค์ประกอบของไม้




(ค) ความเข้มข้นของ White Liquor

รูปที่ 5.3 ผลของกระบวนการเมื่อปรับค่าพลังงานกระตุ้นอันดับหนึ่งขององค์ประกอบที่ 1 ของ


ไม้(E_{11}) เป็น $10.5e3$ kcal/kmol



(ก) ค่าแคปปา



(ข) สัดส่วนมวลขององค์ประกอบของไม้



(ค) ความเข้มข้นของ White Liquor

รูปที่ 5.4 ผลของกระบวนการเมื่อปรับค่าพลังงานกระตุ้นอันดับหนึ่งขององค์ประกอบที่ 1 ของไม้

(E_{11}) เป็น $2.4e3$ kcal/kmol

บทที่ 6

การทดลอง ผลการทดลอง และวิเคราะห์ผลการทดลอง

ในบทนี้กล่าวถึงการใช้ข่ายงานนิวรัลในการหาแบบจำลองเพื่อเป็นแบบจำลองที่แทนกระบวนการและเป็นตัวประมาณค่าเนื่องจากค่าแคปปาซึ่งเป็นตัวแปรควบคุมเป็นค่าที่ไม่สามารถวัดได้จึงต้องทำการประมาณค่าจากตัวแปรอื่นที่สามารถวัดได้ โดยเริ่มจากการซิมูเลทแบบจำลองทางคณิตศาสตร์ของกระบวนการย่อยเยื่อกระดาษ และนำข้อมูลอินพุท-เอาต์พุทที่ได้จากกระบวนการไปฝึกข่ายงานนิวรัลด้วยอัลกอริทึมการกระจายความความผิดพลาดย้อนกลับ แล้วทำการทดสอบข่ายงานด้วยข้อมูลอินพุท-เอาต์พุทอีกชุดเพื่อหาโครงสร้างข่ายงานที่เหมาะสม จากนั้นหาแบบจำลองฝึกฝนเพื่อใช้เป็นตัวควบคุมกระบวนการ และทดสอบตัวประมาณค่าและตัวควบคุม โดยกล่าวถึงผลการทดลอง วิเคราะห์ผลการทดลอง รวมถึงสรุปผลการทดลอง

6.1 การซิมูเลทแบบจำลองของกระบวนการ

กระบวนการย่อยเยื่อกระดาษที่ใช้ในการศึกษาเป็นกระบวนการแบบไม่เชิงเส้น ทำการซิมูเลทกระบวนการจริง โดยใช้สมการทางคณิตศาสตร์ในบทที่ 5 ด้วยวิธีเชิงตัวเลข (numerical method) โดยวิธีออยเลอร์ (Euler's Method) ด้วย step size เท่ากับ 1 ให้ได้อินพุทและเอาต์พุทจากการซิมูเลทที่มีความสอดคล้องกัน

6.2 การออกแบบแบบจำลองข่ายงานนิวรัล

ในงานวิจัย ออกแบบแบบจำลองข่ายงานนิวรัลจำนวน 2 ชุด โดยชุดแรกเป็นตัวประมาณค่า อีกชุดหนึ่งเป็นแบบจำลองข่ายงานนิวรัลของกระบวนการโดยแบบจำลองทั้งสองชุดมีขั้นตอนการออกแบบดังนี้

1. เตรียมชุดข้อมูลอินพุทและเอาต์พุทจากการซิมูเลทกระบวนการ 2 ชุด โดยข้อมูลชุดที่ 1 ใช้เป็นข้อมูลในการฝึกข่ายงาน (Training set) และข้อมูลชุดที่ 2 ใช้เป็นข้อมูลในการทดสอบข่ายงานที่สร้างขึ้นมา (Cross Validation)
2. ออกแบบข่ายงานนิวรัลแบบป้อนไปข้างหน้าหลายชั้น (multilayer feed forward networks) ตามแบบจำลองแบบกลับกระแส (recurrent model) โดยใช้ฟังก์ชันมูลฐานเป็นฟังก์ชันเชิงเส้นและฟังก์ชันกระตุ้นเป็นฟังก์ชันซิกมอยด์ โดยใช้อัลกอริทึมการกระจายความผิดพลาดย้อนกลับ (error backpropagation algorithm)

3. ทำการหาจำนวนชั้นช้อนและจำนวนนิรอนในชั้นช้อนที่เหมาะสมเพื่อหาแบบจำลองที่ต้องการโดยเลือกแบบจำลองที่ให้ค่าความผิดพลาดรวมกำลังสอง (sum square error) น้อยที่สุด
4. ทำการทดสอบแบบจำลองที่ได้ด้วยข้อมูลชุดที่ 2

จากหัวข้อ 3.3.2 เห็นได้ว่าทั้งในการออกแบบแบบจำลองข่ายงานนิรวัล ตัวประมาณค่าและตัวควบคุม ต้องทำการหาโครงสร้างของข่ายงานนิรวัลที่เหมาะสม โดยในการวิจัยนี้มีโครงสร้างข่ายงานนิรวัลดังนี้ คือ


1. จำนวนนิรอนในชั้นอินพุท ได้จากการทดลองหาจำนวนนิรอนในชั้นอินพุทซึ่งขึ้นกับอินพุทเวกเตอร์ที่ป้อนเข้าแก่ข่ายงานนิรวัล
2. จำนวนนิรอนในชั้นช้อน ได้จากการทดลอง โดยในที่นี้ทดลองใช้จำนวนนิรอนในชั้นช้อนเป็น 3,5,7,9 และ11 ตามลำดับ ซึ่งโครงสร้างที่เหมาะสม ก็คือ จำนวนนิรอนในชั้นช้อนที่ทำให้ค่าความผิดพลาดรวมระหว่างเอาต์พุทของข่ายงานกับค่าเป้าหมายมีค่าน้อยที่สุด
3. จำนวนนิรอนในชั้นเอาต์พุท จำนวนนิรอนในชั้นเอาต์พุทจะมีค่าเท่ากับจำนวนเอาต์พุทของกระบวนการ ซึ่งในการทดลองนี้จำนวนนิรอนในชั้นเอาต์พุทของตัวประมาณค่าและแบบจำลองเท่ากับ 1 เนื่องจากกระบวนการมีเอาต์พุทเพียง 1 ค่า
4. จำนวนชั้นช้อน ในการทดลองใช้จำนวนชั้นช้อน 1 ชั้น

6.2.1 แบบจำลองข่ายงานนิรวัลของตัวประมาณค่า


เนื่องจากปัญหาของการควบคุมกระบวนการย่อยเยื่อกระดาษ คือ ค่าแคปปา ซึ่งเป็นตัวแปรควบคุมไม่สามารถวัดค่าออนไลน์ได้ จึงใช้การประมาณค่าจากตัวแปรอื่นที่วัดค่าได้เข้ามาช่วย โดยใช้ข่ายงานนิรวัล โดยอินพุทของตัวประมาณค่าคือ อุณหภูมิของเครื่องย่อยเยื่อกระดาษ (T) และความเข้มข้นของโซเดียมไฮดรอกไซด์ ส่วนเอาต์พุทของตัวประมาณค่า คือค่าแคปปา โดยข้อมูลอินพุทและเอาต์พุทที่ใช้ในการฝึกและทดสอบข่ายงานแสดงดังรูปที่ 6.1 และ 6.2 ได้จากการเปลี่ยนค่าอุณหภูมิของสายหมุนเวียนและอัตราการไหลของสายหมุนเวียนแบบสุ่ม และบันทึกค่าทุกๆ 0.0025 ชั่วโมง เป็นเวลา 2 ชั่วโมง รวมตัวอย่างสุ่มทั้งหมด 800 ค่า

สำหรับการออกแบบโครงสร้างข่ายงานนิรวัลสำหรับตัวประมาณค่า พบว่าจากตารางที่ 6.1 โครงสร้างอินพุทเวกเตอร์ที่ให้ค่าผิดพลาดน้อยที่สุดเท่ากับ 0.0020 คือ ที่จำนวนการหน่วงเวลาของอินพุท, $n_u = 0$ จำนวนการหน่วงเวลาของเอาต์พุท, $n_y = 2$ และจำนวนนิรอนในชั้นช้อนเท่ากับ 5 ทำให้อินพุทเวกเตอร์ที่เหมาะสม คือ 4


ดังนั้นโครงสร้างที่เหมาะสมของตัวประมาณค่า (จำนวนนิรอนในชั้นอินพุท-จำนวนนิรอนในชั้นซ่อน-จำนวนนิรอนในชั้นเอาต์พุท) คือ 4-5-1 เนื่องจากมีค่าความผิดพลาดต่ำที่สุด



(ก) อุณหภูมิของเครื่องย่อยเยื่อกระดาษใช้เป็นอินพุทในการฝึกข่ายงาน




(ข) ความเข้มข้นของโซเดียมไฮดรอกไซด์ใช้เป็นอินพุทในการฝึกข่ายงาน




(ค) ค่าแคลปาใช้เป็นเอาต์พุทในการฝึกข่ายงาน


รูปที่ 6.1 ข้อมูลอินพุทและเอาต์พุทในการฝึกข่ายงานของตัวประมาณค่า



(ก) อุณหภูมิของเครื่องย่อยเยื่อกระดาษใช้เป็นอินพุตในการทดสอบข่ายงาน



(ข) ความเข้มข้นของโซเดียมไฮดรอกไซด์ใช้เป็นอินพุตในการทดสอบข่ายงาน



(ง) ค่าแคปปาใช้เป็นเอาต์พุตในการทดสอบข่ายงาน

รูปที่ 6.2 ข้อมูลอินพุตและเอาต์พุตในการทดสอบข่ายงานของตัวประมาณค่า

ตารางที่ 6.1 แสดงค่าผลรวมค่าผิดพลาดยกกำลังสองของแบบจำลองข่ายงานนิวรัลของตัว
ประมาณค่า

จำนวนการหน่วงเวลา		ผลรวมค่าผิดพลาดยกกำลังสอง (SSE)				
อินพุท	เอาต์พุท	จำนวนนิวรอนในชั้นซ่อน				
		3	5	7	9	11
0	0	8.9438	8.2075	7.5630	5.4522	5.4898
	1	0.5590	0.5390	0.412	0.2684	0.3331
	2	0.2942	0.0020	0.0351	0.0022	0.0054
	3	0.338	0.0600	0.0428	0.0553	0.0460
	4	0.3694	0.2820	0.0350	0.0337	0.0442
1	0	8.4221	6.8871	6.6536	5.0537	4.8668
	1	0.4859	0.4492	0.4250	0.2522	0.2988
	2	0.3051	0.0450	0.0320	0.0280	0.0042
	3	0.0420	0.0100	0.0280	0.0443	0.0406
	4	0.0287	0.0218	0.0035	0.0321	0.0301
2	0	8.1855	5.3328	5.6130	5.2285	4.9418
	1	0.4530	0.5090	0.3206	0.2445	0.2517
	2	0.2881	0.0360	0.0551	0.0029	0.0045
	3	0.0204	0.0300	0.0412	0.0363	0.0396
	4	0.0213	0.0322	0.0029	0.0320	0.0400
3	0	7.5224	5.7796	6.5563	3.4546	3.4898
	1	0.5610	0.4825	0.2220	0.148	0.3381
	2	0.2290	0.0020	0.0035	0.029	0.0032
	3	0.2558	0.0428	0.0270	0.0347	0.0241
	4	0.2021	0.0230	0.0040	0.0288	0.0359


6.2.2 แบบจำลองข่ายงานนิรวัลของกระบวนการ

ในการสร้างแบบจำลองของข่ายงานนิรวัล เป็นการสร้างแบบจำลองภายในแทนแบบจำลองของกระบวนการจริง โดยอินพุทของแบบจำลอง คือ คุณสมบัติของสายหมุนเวียน (Tr) อัตราการไหลของสายหมุนเวียน (Fr) และความเข้มข้นของไซเดียมไฮดรอกไซด์ (Cf_3) ส่วนเอาต์พุทของกระบวนการ คือ ค่าแคปปา


ข้อมูลอินพุทและเอาต์พุทที่ใช้ในการฝึกและทดสอบข่ายงานแสดงดังรูปที่ 6.3 และ 6.4 ซึ่งได้จากการเปลี่ยนค่าคุณสมบัติของสายหมุนเวียนและอัตราการไหลของสายหมุนเวียนแบบสุ่ม (True random) และบันทึกค่าทุกๆ 0.0025 ชั่วโมงเป็นเวลา 2 ชั่วโมง รวมตัวอย่างสุ่มทั้งหมด 800 ค่า

สำหรับการออกแบบโครงสร้างข่ายงานนิรวัลสำหรับแบบจำลองข่ายงานนิรวัลของกระบวนการ พบว่าจากตารางที่ 6.2 โครงสร้างอินพุทเวกเตอร์ที่ให้ค่าผิดพลาดน้อยที่สุดเท่ากับ 0.0013 คือ ที่จำนวนการหน่วงเวลาของอินพุท, $n_x = 0$ จำนวนการหน่วงเวลาของเอาต์พุท, $n_y = 2$ และจำนวนนิรวัลในชั้นซ่อนเท่ากับ 7 ทำให้อินพุทเวกเตอร์ที่เหมาะสม คือ 5


ดังนั้นโครงสร้างที่เหมาะสมของตัวประมาณค่า (จำนวนนิรวัลในชั้นอินพุท-จำนวนนิรวัลในชั้นซ่อน-จำนวนนิรวัลในชั้นเอาต์พุท) คือ 5-7-1 เนื่องจากมีค่าความผิดพลาดต่ำที่สุด




(ก) อุณหภูมิของสายหมุ่นเวียนใช้เป็นอินพุตในการฝึกข่ายงาน



(ข) อัตราการไหลของสายหมุ่นเวียนใช้เป็นอินพุตในการฝึกข่ายงาน




(ค) ความเข้มข้นของโซเดียมไฮดรอกไซด์ใช้เป็นอินพุตในการฝึกข่ายงาน




(ง) ค่าแคปปาใช้เป็นเอาต์พุตในการฝึกข่ายงาน


รูปที่ 6.3 ข้อมูลอินพุตและเอาต์พุตในการฝึกข่ายงานของแบบจำลอง




(ก) อุณหภูมิของสายหมุ่นเวียนใช้เป็นอินพุตในการทดสอบซ้ำงาน



(ข) อัตราการไหลของสายหมุ่นเวียนใช้เป็นอินพุตในการทดสอบซ้ำงาน



(ค) ความเข้มข้นของโซเดียมไฮดรอกไซด์ใช้เป็นอินพุตในการทดสอบซ้ำงาน



(ง) ค่าแคปปาใช้เป็นเอาต์พุตในการทดสอบซ้ำงาน

รูปที่ 6.4 ข้อมูลอินพุตและเอาต์พุตในการทดสอบซ้ำงานของแบบจำลอง

ตารางที่ 6.2 แสดงค่าผลรวมค่าผิดพลาดยกกำลังสองของแบบจำลองข่ายงานนิวรัลของกระบวนการ

จำนวนการหน่วงเวลา		ผลรวมค่าผิดพลาดยกกำลังสอง (SSE)				
อินพุท	เอาต์พุท	จำนวนนิวรอนในชั้นซ่อน				
		3	5	7	9	11
0	0	7.3438	6.5124	5.5275	5.2951	5.4008
	1	0.2590	0.2539	0.1415	0.1618	0.1337
	2	0.0242	0.0020	0.0013	0.0022	0.0054
	3	0.0138	0.0069	0.0428	0.0553	0.0460
	4	0.0224	0.0080	0.0350	0.0337	0.0442
1	0	6.2281	5.8871	5.6536	5.0537	4.8668
	1	0.2774	0.2292	0.1755	0.1844	0.1990
	2	0.0254	0.0150	0.0022	0.010	0.0142
	3	0.0094	0.0190	0.0061	0.0544	0.0098
	4	0.0314	0.0218	0.0035	0.0049	0.0052
2	0	5.7854	5.2833	4.4822	4.8278	3.7334
	1	0.3054	0.1809	0.1320	0.1445	0.1578
	2	0.0338	0.0556	0.0055	0.0033	0.0065
	3	0.0200	0.0045	0.0041	0.0033	0.0029
	4	0.0211	0.0342	0.0029	0.0024	0.0040
3	0	6.4487	5.2247	5.5573	4.4546	3.4865
	1	0.2088	0.1485	0.1250	0.1408	0.1381
	2	0.0265	0.0020	0.0035	0.029	0.0032
	3	0.0255	0.0028	0.0270	0.0034	0.0027
	4	0.0143	0.0023	0.0044	0.0028	0.0035


6.3 การออกแบบตัวควบคุม

ตัวควบคุมที่ทำการออกแบบในงานวิจัยนี้เป็นตัวควบคุมแบบใช้แบบจำลองภายใน ซึ่งจะได้รับการสร้างแบบจำลองแบบผกผันของแบบจำลองข้างงานนิเวศของกระบวนการ โดยเลือกใช้โครงสร้างการควบคุมแบบเอ็นไอเอ็มซีซึ่งแสดงดังรูปที่ 6.5 โดยออกแบบตัวควบคุมออกเป็น 2 ส่วน แสดงดังรูปที่ 6.7 คือ


ส่วนที่ 1 อินพุท คือ ค่าแคปปาเป้าหมายที่ลบความผิดพลาดระหว่างค่าแคปปาจากแบบจำลองกระบวนการและจากแบบจำลองข้างงานนิเวศ ($sp - (y_p - y_m)$) ค่าแคปปาจากกระบวนการ คุณณหภูมิของสายหมุนเวียน (Tr) ในอดีตและอัตราการไหลของสายหมุนเวียน (Fr) ในอดีต เอาท์พุท คือ คุณณหภูมิของสายหมุนเวียน (Tr) โดยคุณณหภูมิของสายหมุนเวียนที่ได้นี้จะถูกส่งไปยังกระบวนการต่อไป

ส่วนที่ 2 อินพุท คือ ค่าแคปปาเป้าหมายที่ลบความผิดพลาดระหว่างค่าแคปปาจากแบบจำลองกระบวนการและจากแบบจำลองข้างงานนิเวศ ($sp - (y_p - y_m)$) ค่าแคปปาจากกระบวนการ คุณณหภูมิของสายหมุนเวียน (Tr) ในอดีตและอัตราการไหลของสายหมุนเวียน (Fr) ในอดีต เอาท์พุท คือ อัตราการไหลของสายหมุนเวียน (Fr) โดยอัตราการไหลของสายหมุนเวียนที่ได้นี้จะถูกส่งไปยังกระบวนการต่อไป

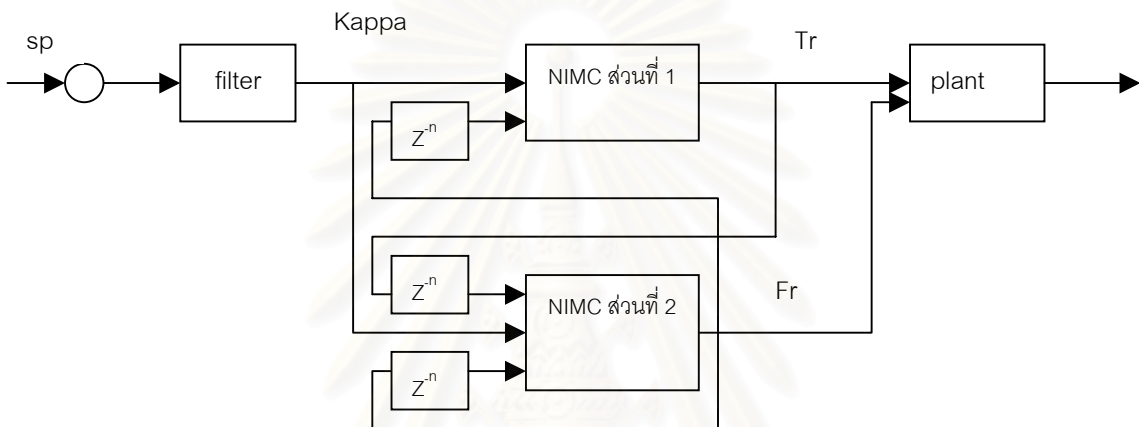
โดยโครงสร้างของการควบคุมและจากการออกแบบ เพราะฉะนั้นอินพุทเวกเตอร์ของตัวควบคุมแต่ละส่วนมี 7 ค่า คือ ค่าแคปปาเป้าหมายที่ลบความผิดพลาดระหว่างค่าแคปปาจากแบบจำลองกระบวนการและจากแบบจำลองข้างงานนิเวศ ($sp - (y_p - y_m)$) ค่าแคปปาในปัจจุบัน ค่าแคปปาในอดีต 2 ค่า คุณณหภูมิของหมุนเวียนในอดีต 2 ค่า และอัตราการไหลของสายหมุนเวียนในอดีต 2 ค่า



รูปที่ 6.5 โครงสร้างโดยทั่วไปของการควบคุมแบบเอ็นไอเอ็มซี



รูปที่ 6.6 แผนภาพโครงสร้างของการควบคุมกระบวนการย่อยเยื่อกระดาษ



รูปที่ 6.7 โครงสร้างของตัวควบคุมที่ออกแบบสำหรับงานวิจัย


เมื่ออินพุทเวกเตอร์ถูกกำหนดจากการออกแบบและโครงสร้างการควบคุมไว้แล้ว พบว่า ที่จำนวนนิเวรอนในชั้นซ่อนของตัวควบคุมส่วนที่ 1 และ 2 เท่ากับ 5 และ 9 ตามลำดับให้ค่าผิดพลาดน้อยที่สุดเท่ากับ 6.9582 และ 8.2833 ตามลำดับ ดังแสดงในตารางที่ 6.3

ตารางที่ 6.3 แสดงค่าผลรวมค่าผิดพลาดยกกำลังสองของตัวควบคุมข่ายงานนิเวรัล


ตัวควบคุม	SSE ที่จำนวนนิเวรอนในชั้นซ่อนต่างๆ				
	3	5	7	9	11
NIMC ส่วนที่ 1	11.3559	6.9582	7.6825	9.5425	9.9511
NIMC ส่วนที่ 2	10.5427	9.9443	11.2095	8.2833	10.5147

เพราะฉะนั้น โครงสร้างข่ายงานนิเวรัลที่เหมาะสมสำหรับการออกแบบตัวควบคุมข่ายงานนิเวรัลแบบเอ็นไอเอ็มซีทั้ง 2 ส่วน คือ 7-5-1 และ 7-9-1 ตามลำดับ

ทำการเปรียบเทียบผลการควบคุมกับตัวควบคุมพีไอที่ใช้ร่วมกับตัวประมาณค่าช่่างาน
 นิเวศที่ออกแบบไว้ในหัวข้อที่ 6.2.1 โครงสร้างตัวควบคุมพีไอแบ่งออกเป็น 2 ส่วนแสดงดังรูปที่ 6.8
 โดยส่วนที่ 1 ใช้รับสัญญาณของสายหมุนเวียน (Tr) และส่วนที่ 2 ใช้รับอัตราการไหลของสาย
 หมุนเวียน (Fr)



รูปที่ 6.8 โครงสร้างการควบคุมของตัวควบคุมพีไอ




รูปที่ 6.9 โครงสร้างของตัวควบคุมพีไอทั้ง 2 ส่วน

โดยได้ค่าแฟกเตอร์การจูนตัวควบคุมพีไอส่วนที่ 1 คือ $K_{c_1} = 45$, $\tau_{i_1} = 1250$ และค่าแฟก
 เตอร์การจูนตัวควบคุมพีไอส่วนที่ 2 คือ $K_{c_2} = 6$, $\tau_{i_2} = 22$

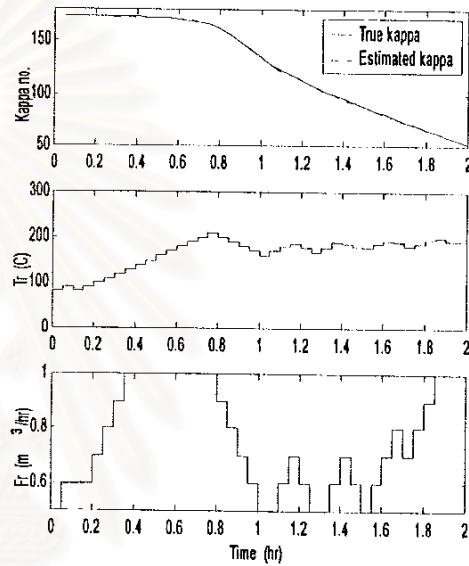
จุฬาลงกรณ์มหาวิทยาลัย

6.4 ผลการประมาณค่าและควบคุม

จากรูปที่ 6.6 เมื่อใช้โครงสร้างต่างๆที่ออกแบบเพื่อควบคุมค่าแคปปาให้เข้าสู่ค่าเป้าหมาย ในเวลาที่กำหนด คือ 2 ชั่วโมง ได้ผลการประมาณค่าและควบคุมแสดงดังรูปที่ 6.10 เปรียบเทียบกับตัวควบคุมพีไอ (PI Controller) ที่ใช้ร่วมกับตัวประมาณค่าข่ายงานนิวรัลในรูปที่ 6.11 และเปรียบเทียบแนวโน้มการเปลี่ยนแปลงค่ากับ Belarbi (2000) ซึ่งใช้ตัวประมาณค่าพีซีซีนิวรัล (fuzzy neural network) ร่วมกับตัวควบคุมฟัซซี (fuzzy logic controller) แสดงดังรูปที่ 6.12




รูปที่ 6.10



รูปที่ 6.11

รูปที่ 6.10 ผลการประมาณค่าและควบคุมของตัวประมาณค่าข่ายงานนิวรัลร่วมกับตัวควบคุมข่ายงานนิวรัล

รูปที่ 6.11 ผลการประมาณค่าและควบคุมของตัวประมาณค่าข่ายงานนิวรัลร่วมกับตัวควบคุมพีไอ



รูปที่ 6.12 ผลการประมาณค่าและควบคุมของ Belarbi (2000)

จากรูปที่ 6.10 และ 6.11 เห็นได้ว่าการใช้ตัวประมาณค่าข่ายงานนิวรัลร่วมกับตัวควบคุมข่ายงานนิวรัลและตัวควบคุมพีไอสามารถประมาณค่าแคปปาได้ใกล้เคียงค่าจริงมาก คือมีอินทิกรัลความผิดพลาดในการประมาณเท่ากับ 0.3306 และ 0.3559 ตามลำดับ และเมื่อเปรียบเทียบแนวโน้มการประมาณค่ากับตัวประมาณค่าพีซีนิวรัลในรูปที่ 6.12 พบว่าตัวประมาณค่าข่ายงานนิวรัลสามารถประมาณค่าได้ดีกว่า

เมื่อพิจารณาตัวควบคุม ตัวควบคุมข่ายงานนิวรัลในรูปที่ 6.10 สามารถควบคุมค่าแคปปาให้เข้าสู่ค่าเป้าหมายได้ดี โดยให้ค่าแคปปากลัดเคลื่อนไปจากค่าแคปปาเป้าหมายไป 0.0552 ส่วนตัวควบคุมพีไอในรูปที่ 6.11 ให้ค่าความคลาดเคลื่อนเท่ากับ 0.0996 แสดงให้เห็นว่าตัวควบคุมทั้งสองสามารถควบคุมกระบวนการได้ และเมื่อเปรียบเทียบแนวโน้มกับตัวควบคุมพีซีในรูปที่ 6.12 พบว่าสามารถควบคุมได้ดีเช่นกัน

การปรับค่าของตัวแปรปรับของตัวควบคุมข่ายงานนิวรัล อุณหภูมิของสายหมუნเวียนจะเพิ่มขึ้นจากอุณหภูมิของเครื่องย่อย นั่นคือ 80°C จนเข้าสู่ค่าอุณหภูมิที่เหมาะสมที่ทำให้ปฏิกิริยาเกิดได้ดี ส่วนการปรับค่าของอัตราการใช้ของสายหมუნเวียนก็สอดคล้องกับการปรับอุณหภูมิของสายหมუნเวียน ในขณะที่ตัวควบคุมพีไอมีการปรับและแกว่งของค่าตัวแปรปรับมากกว่า

แสดงให้เห็นว่าการใช้ตัวประมาณค่าข่ายงานนิวรัลร่วมกับตัวควบคุมข่ายงานนิวรัลสามารถประมาณค่าและควบคุมค่าแคปปาของกระบวนการได้ดี และมีการแกว่งของค่าตัวแปรปรับน้อยกว่า

6.5 ผลการทดสอบตัวประมาณค่าและตัวควบคุม

6.5.1 กรณีที่ค่าของสารป้อนของกระบวนการผิดพลาด


ในแต่ละรอบการผลิตของกระบวนการย่อยเยื่อกระดาษแบบกะ ค่าของสารป้อนของกระบวนการอาจมีความแตกต่างกันขึ้นกับชนิดของวัตถุดิบและปริมาณของสารที่ป้อนเข้าสู่กระบวนการ จึงต้องทำการทดสอบสมรรถนะในการประมาณค่าและการควบคุม โดยในงานวิจัยนี้ทดสอบในกรณีที่เปลี่ยนชนิดของไม้ ซึ่งส่งผลให้พารามิเตอร์ของกระบวนการมีการเปลี่ยนแปลง โดยแบ่งการทดสอบเป็น 2 กรณี คือ

1. การเปลี่ยนชนิดของไม้เป็นไม้เนื้ออ่อน แสดงผลการทดสอบในรูปที่ 6.13
2. การเปลี่ยนชนิดของไม้เป็นไม้เนื้อแข็ง แสดงผลการทดสอบในรูปที่ 6.15


โดยการเปลี่ยนชนิดของไม้ทั้ง 2 กรณี มีผลทำให้พารามิเตอร์ของกระบวนการเปลี่ยนแปลงดังแสดงในตารางที่ 6.4 เปรียบเทียบกับตัวควบคุมพีไอ Belarbi (2000) ที่ใช้ตัวประมาณค่าพีชชีนิวัลร์ร่วมกับตัวควบคุมพีชชี และ Lee และ Datta (1994) ซึ่งใช้ตัวประมาณค่าคาลมานฟิลเตอร์ร่วมกับตัวควบคุมแบบโมเดลพรีดิกทีฟ (Model predictive controller, MPC) ซึ่งแสดงผลในรูปที่ 6.13 ถึง 6.19

ตารางที่ 6.4 ค่าพารามิเตอร์ที่ใช้ในการทดสอบตัวประมาณค่าและตัวควบคุม(Lee และ Datta,1994)

พารามิเตอร์	ค่าจริง	ค่าที่เปลี่ยนแปลงไป	
		กรณีที่ 1	กรณีที่ 2
X_1	0.0528	-0.01	+0.01
X_2	0.2112	-0.05	+0.05
X_3	0.4852	-0.02	+0.02
X_4	0.1428	-0.02	+0.02
X_5	0.0722	-0.01	+0.01
Ce_1	0	0	0
Ce_2	0	0	0
Ce_3	0	0	0
Ce_4	0	0	0
Cf_1	1	-1	-1
Cf_2	2	-2	-2
Cf_3	47.6327	-3	+3
Cf_4	11.3535	-2	+2
T	80	-1	+1




รูปที่ 6.13



รูปที่ 6.14

รูปที่ 6.13 ผลการทดสอบการประมาณค่าและควบคุมของตัวประมาณค่าข่ายงานนิวรัลร่วมกับตัวควบคุมข่ายงานนิวรัลเมื่อเปลี่ยนชนิดของไม้เป็นไม้เนื้ออ่อน


รูปที่ 6.14 ผลการทดสอบการประมาณค่าและควบคุมของตัวประมาณค่าข่ายงานนิวรัลร่วมกับตัวควบคุมพีไอเมื่อเปลี่ยนชนิดของไม้เป็นไม้เนื้ออ่อน




รูปที่ 6.15 ผลการทดสอบการประมาณค่าและควบคุมของBelarbi (2000) เมื่อเปลี่ยนชนิดของไม้เป็นไม้เนื้ออ่อน

จากรูปที่ 6.13 ถึง 6.15 พบว่าเมื่อเปลี่ยนชนิดของไม้เป็นไม้เนื้ออ่อน ตัวประมาณค่าช่างงานนิรวัลเมื่อใช้ร่วมกับตัวควบคุมเอ็นไอเอ็มซีและพีไอมีความผิดพลาดในการประมาณค่าเริ่มต้น โดยมีค่าอินทิกรัลความผิดพลาดเท่ากับ 8.1310 และ 8.2554 ตามลำดับ อย่างไรก็ตาม ก็สามารถประมาณค่าให้เข้าสู่ค่าจริงได้เร็วกว่า Belarbi (2000) ซึ่งประมาณค่าได้ใกล้เคียงกับค่าจริงเป็นบางช่วง

เมื่อพิจารณาตัวควบคุม ตัวควบคุมช่างงานนิรวัลในรูปที่ 6.13 สามารถควบคุมค่าแคปปาให้เข้าสู่ค่าเป้าหมายได้ในเวลาที่กำหนดโดยมีความคลาดเคลื่อนจากค่าเป้าหมายเท่ากับ 2.5281 และตัวควบคุมพีไอให้ค่าคลาดเคลื่อนเท่ากับ 2.5022 โดยตัวแปรปรับของตัวควบคุมพีไอมีการแกว่งค่ามากกว่า แสดงให้เห็นว่าตัวควบคุมช่างงานนิรวัลเหมาะสมในการใช้ควบคุมกระบวนการ และเมื่อเปรียบเทียบกับ Belarbi (2000) พบว่ามีแนวโน้มการเปลี่ยนแปลงค่าในแนวทางเดียวกัน




รูปที่ 6.16




รูปที่ 6.17

รูปที่ 6.16 ผลทดสอบการประมาณค่าและควบคุมของตัวประมาณค่าช่างงานนิรวัลร่วมกับตัวควบคุมช่างงานนิรวัลเมื่อเปลี่ยนชนิดของไม้เป็นไม้เนื้อแข็ง

รูปที่ 6.17 ผลทดสอบการประมาณค่าและควบคุมของตัวประมาณค่าช่างงานนิรวัลร่วมกับตัวควบคุมพีไอเมื่อเปลี่ยนชนิดของไม้เป็นไม้เนื้อแข็ง



รูปที่ 6.18



รูปที่ 6.19

รูปที่ 6.18 ผลทดสอบการประมาณค่าและควบคุมของ Belarbi (2000) เมื่อเปลี่ยนชนิดของไม้เป็นไม้เนื้อแข็ง

รูปที่ 6.19 ผลทดสอบการประมาณค่าและควบคุมของ Lee และ Datta (1994) เมื่อเปลี่ยนชนิดของไม้เป็นไม้เนื้อแข็ง

จากรูปที่ 6.16 ถึง 6.19 พบว่าเมื่อเปลี่ยนชนิดของไม้เป็นไม้เนื้อแข็ง การใช้ตัวประมาณค่า ข่ายงานนิวรัลร่วมกับตัวควบคุมข่ายงานนิวรัลและตัวควบคุมพีไอมีความผิดพลาดในการประมาณค่าเริ่มต้นน้อยกว่าในกรณีไม้เนื้ออ่อน โดยมีอินทิกรัลความผิดพลาดเท่ากับ 6.3730 และ 6.8035 ตามลำดับ แต่ก็สามารถประมาณค่าเข้าสู่ค่าจริงได้เร็วเมื่อเปรียบเทียบกับ Belarbi (2000) และ Lee และ Datta (1994)

เมื่อพิจารณาตัวควบคุม ตัวควบคุมข่ายงานนิวรัลและพีไอสามารถควบคุมค่าแคปปาให้เข้าสู่ค่าเป้าหมายได้เช่นเดียวกับ Belarbi (2000) และ Lee และ Datta (1994) โดยมีความคลาดเคลื่อนของตัวควบคุมเท่ากับ 1.5690 และ 1.5586 โดยแนวโน้มการปรับค่าอุณหภูมิและอัตราการไหลของสายหมุนเวียนของตัวควบคุมทั้งสองมีแนวโน้มเช่นเดียวกับในสภาวะปกติ นั่นคือ ตัวควบคุมพีไอมีการแกว่งค่าของตัวแปรปรับมากกว่า แสดงว่าตัวควบคุมข่ายงานนิวรัลควบคุมได้ดีกว่า

จากการทดสอบเมื่อค่าของสายป้อนของกระบวนการผิดพลาด กล่าวได้ว่า ตัวประมาณค่า ข่ายงานนิวรัลสามารถประมาณค่าได้แม้ว่าจะมีความผิดพลาดในการประมาณค่าเริ่มต้นและตัวควบคุมข่ายงานนิวรัลสามารถควบคุมกระบวนการได้


6.5.2 กรณีเมื่อพารามิเตอร์ของแบบจำลองทางคณิตศาสตร์ของกระบวนการผลิตพลาด

ค่าพารามิเตอร์ของแบบจำลองทางคณิตศาสตร์ของกระบวนการอาจคลาดเคลื่อนไปจากค่าของกระบวนการจริงในอุตสาหกรรมได้ ซึ่งจะส่งผลต่อการควบคุมกระบวนการ เพราะฉะนั้นจึงจำเป็นต้องทำการทดสอบสมรรถนะของตัวควบคุมที่สร้างขึ้น โดยทำการทดสอบตัวควบคุมเมื่อมีการเปลี่ยนแปลงค่าพารามิเตอร์ต่างๆ โดยแบบจำลองทางคณิตศาสตร์ของเครื่องย่อยเยื่อกระดาษที่ทำการศึกษามีพารามิเตอร์มากถึง 36 ตัว จึงเลือกทดสอบเฉพาะพารามิเตอร์ที่มีความสำคัญและมีอิทธิพลต่อค่าแคปปา ซึ่งก็คือ พลังงานกระตุ้นอันดับหนึ่ง (E_1) และพลังงานกระตุ้นอันดับสอง (E_2) ขององค์ประกอบที่ 1 และ 2 ของไม้ เนื่องจากองค์ประกอบที่ 1 และ 2 ของไม้เป็นค่าลิกนินที่บ่งถึงค่าแคปปา


โดยแบ่งการทดสอบตัวควบคุมที่สภาวะการเปลี่ยนแปลงพารามิเตอร์ ดังนี้

1. พลังงานกระตุ้นอันดับหนึ่งขององค์ประกอบที่ 1 ของไม้ (E_{11}) เพิ่มขึ้นและลดลง 50%
2. พลังงานกระตุ้นอันดับหนึ่งขององค์ประกอบที่ 2 ของไม้ (E_{12}) เพิ่มขึ้นและลดลง 50%
3. พลังงานกระตุ้นอันดับสองขององค์ประกอบที่ 1 ของไม้ (E_{21}) เพิ่มขึ้นและลดลง 50%
4. พลังงานกระตุ้นอันดับสองขององค์ประกอบที่ 2 ของไม้ (E_{22}) เพิ่มขึ้นและลดลง 50%

ผลการทดสอบแสดงในรูปที่ 6.20 ถึง 6.27




ตัวควบคุมข่ายงานนิวัล




ตัวควบคุมพีไอ

รูปที่ 6.20 การเปรียบเทียบการควบคุมของตัวควบคุมข่ายงานนิวัลกับตัวควบคุมพีไอเมื่อพลังงานกระตุ้นอันดับหนึ่งขององค์ประกอบที่ 1 ของไม้ (E_{11}) เพิ่มขึ้น 50%




ตัวควบคุมข่ายงานนิวัล




ตัวควบคุมพีไอ


รูปที่ 6.21 การเปรียบเทียบการควบคุมของตัวควบคุมข่ายงานนิวัลกับตัวควบคุมพีไอเมื่อพลังงานกระตุ้นอันดับหนึ่งขององค์ประกอบที่ 1 ของไม้ (E_{11}) ลดลง 50%




รูปที่ 6.22 การเปรียบเทียบการควบคุมของตัวควบคุมข่ายงานนิรวัลกับตัวควบคุมพีไอเมื่อพลังงานกระตุ้นอันดับหนึ่งขององค์ประกอบที่ 2 ของไม้ (E_{12}) เพิ่มขึ้น 50%



รูปที่ 6.23 การเปรียบเทียบการควบคุมของตัวควบคุมข่ายงานนิรวัลกับตัวควบคุมพีไอเมื่อพลังงานกระตุ้นอันดับหนึ่งขององค์ประกอบที่ 2 ของไม้ (E_{12}) ลดลง 50%




ตัวควบคุมข่ายงานนิวรัล




ตัวควบคุมพีไอ

รูปที่ 6.24 การเปรียบเทียบการควบคุมของตัวควบคุมข่ายงานนิวรัลกับตัวควบคุมพีไอเมื่อค่าพลังงานกระตุ้นที่ 2 ขององค์ประกอบที่ 1 (E_{21}) เพิ่มขึ้น 50%




ตัวควบคุมข่ายงานนิวรัล




ตัวควบคุมพีไอ

รูปที่ 6.25 การเปรียบเทียบการควบคุมของตัวควบคุมข่ายงานนิวรัลกับตัวควบคุมพีไอเมื่อพลังงานกระตุ้นอันดับสองขององค์ประกอบที่ 1 ของไม้ (E_{21}) ลดลง 50%




ตัวควบคุมช่างงานนิรวัล




ตัวควบคุมพีไอ

รูปที่ 6.26 การเปรียบเทียบการควบคุมของตัวควบคุมช่างงานนิรวัลกับตัวควบคุมพีไอเมื่อพลังงานกระตุ้นอันดับสองขององค์ประกอบที่ 2 ของไม้ (E_{22}) เพิ่มขึ้น 50%



ตัวควบคุมช่างงานนิรวัล



ตัวควบคุมพีไอ

รูปที่ 6.27 การเปรียบเทียบการควบคุมของตัวควบคุมช่างงานนิรวัลกับตัวควบคุมพีไอเมื่อพลังงานกระตุ้นอันดับสองขององค์ประกอบที่ 2 ของไม้ (E_{22}) ลดลง 50%

จากรูปที่ 6.20 และ 6.21 พบว่า เมื่อพลังงานกระตุ้นอันดับหนึ่งขององค์ประกอบที่ 1 ของไม้ (E_{11}) เพิ่มขึ้นและลดลง 50% ตัวควบคุมข่ายงานนิวรัลสามารถควบคุมค่าแคปไปให้เข้าสู่ค่าเป้าหมายได้ดีโดยมีค่าคลาดเคลื่อนเพียง 0.4931 และ 1.0608 ตามลำดับ ส่วนตัวควบคุมพีไอก็สามารถควบคุมกระบวนการได้ดีโดยมีค่าคลาดเคลื่อนเท่ากับ 1.2957 และ 1.0063 ตามลำดับ โดยการปรับค่าของตัวแปรปรับ นั่นคือ อุณหภูมิและอัตราการไหลของสายหมุนเวียนของตัวควบคุมพีไอมีการแกว่งค่ามากกว่า สำหรับตัวประมาณค่าข่ายงานนิวรัลเมื่อใช้ร่วมกับตัวควบคุมข่ายงานนิวรัลและตัวควบคุมพีไอพบว่ามีประสิทธิภาพในการประมาณค่าได้ดี

จากรูปที่ 6.22 พบว่า เมื่อพลังงานกระตุ้นอันดับหนึ่งขององค์ประกอบที่ 2 ของไม้ (E_{12}) เพิ่มขึ้น 50% ตัวควบคุมข่ายงานนิวรัลสามารถควบคุมค่าแคปไปให้เข้าสู่ค่าเป้าหมายได้ดีโดยมีค่าคลาดเคลื่อนเพียง 0.0506 ในขณะที่ตัวควบคุมพีไอเกิดความคลาดเคลื่อนถึง 19.8556 อีกทั้งตัวแปรปรับยังมีการแกว่งค่ามากกว่าอีกด้วย สำหรับตัวประมาณค่าข่ายงานนิวรัลเมื่อใช้ร่วมกับตัวควบคุมข่ายงานนิวรัลและตัวควบคุมพีไอพบว่ามีประสิทธิภาพในการประมาณค่าโดยมีค่าอินทิกรัลความผิดพลาดเท่ากับ 6.9724 และ 7.5385 ตามลำดับ

จากรูปที่ 6.23 พบว่า เมื่อพลังงานกระตุ้นอันดับหนึ่งขององค์ประกอบที่ 2 ของไม้ (E_{12}) ลดลง 50% ตัวควบคุมทั้งสองไม่สามารถควบคุมกระบวนการได้ เห็นได้จากกราฟที่ขาด เพราะการลดค่า E_{12} ลง 50% มีผลทำให้เพิ่มอัตราการทำปฏิกิริยาขององค์ประกอบที่ 2 ของไม้ (x_2) ค่อนข้างมาก จึงใช้ไซโตเดียมไฮดรอกไซด์หมดไปตั้งแต่ในช่วงแรก

จากรูปที่ 6.24 และ 6.25 พบว่า เมื่อพลังงานกระตุ้นอันดับสองขององค์ประกอบที่ 1 ของไม้ (E_{21}) เพิ่มขึ้นและลดลง 50% ตัวควบคุมข่ายงานนิวรัลสามารถควบคุมค่าแคปไปให้เข้าสู่ค่าเป้าหมายได้ดีโดยมีค่าคลาดเคลื่อนเพียง 0.5552 และ 0.0558 ตามลำดับ ส่วนตัวควบคุมพีไอก็สามารถควบคุมกระบวนการได้ดีโดยมีค่าคลาดเคลื่อนเท่ากับ 0.0529 และ 0.4052 ตามลำดับ โดยการปรับค่าของตัวแปรปรับของตัวควบคุมพีไอมีการแกว่งค่ามากกว่า สำหรับตัวประมาณค่าข่ายงานนิวรัลเมื่อใช้ร่วมกับตัวควบคุมข่ายงานนิวรัลและตัวควบคุมพีไอพบว่ามีประสิทธิภาพในการประมาณค่าได้ดี

จากรูปที่ 6.26 พบว่า เมื่อพลังงานกระตุ้นอันดับสองขององค์ประกอบที่ 2 ของไม้ (E_{22}) เพิ่มขึ้น 50% ตัวควบคุมข่ายงานนิวรัลและตัวควบคุมพีไอสามารถควบคุมค่าแคปไปให้เข้าสู่ค่าเป้าหมายได้ดีโดยมีค่าคลาดเคลื่อนเพียง 0.0725 และ 0.0700 ตามลำดับ โดยการปรับค่าของตัวแปรปรับของตัวควบคุมพีไอมีการแกว่งค่ามากกว่า สำหรับตัวประมาณค่าข่ายงานนิวรัลเมื่อใช้ร่วมกับตัวควบคุมข่ายงานนิวรัลและตัวควบคุมพีไอพบว่ามีประสิทธิภาพในการประมาณค่าได้ดี

จากรูปที่ 6.27 พบว่า เมื่อพลังงานกระตุ้นอันดับสองขององค์ประกอบที่ 2 ของไม้ (E_{22}) ลดลง 50% ตัวควบคุมทั้งสองไม่สามารถควบคุมกระบวนการได้ เห็นได้จากกราฟที่ขาด เพราะการลด


ค่า E_{22} ลง 50% มีผลทำให้เพิ่มอัตราการทำปฏิกิริยาขององค์ประกอบที่ 2 ของไม้ (x_2) ค่อนข้างมาก จึงใช้โซเดียมไฮดรอกไซด์หมดไปตั้งแต่ในช่วงแรก

ค่าความคลาดเคลื่อนของตัวควบคุมและอินทิกรัลความผิดพลาดของตัวควบคุมทั้งสองในกรณีต่างๆสรุปรวมในตารางที่ 6.5


ตารางที่ 6.5 แสดงความคลาดเคลื่อนของตัวควบคุมและตัวประมาณค่าในกรณีต่างๆ

กรณี	อินทิกรัลความผิดพลาดของตัวประมาณค่า		ความคลาดเคลื่อนของตัวควบคุม	
	NIMC	PI	NIMC	PI
สภาวะปกติ	0.3306	0.3559	0.0552	0.0996
เปลี่ยนเป็นไม้เนื้ออ่อน	8.1310	8.2554	2.5281	2.5022
เปลี่ยนเป็นไม้เนื้อแข็ง	6.3730	6.8035	1.5690	1.5586
E_{11} เพิ่มขึ้น 50%	0.9803	0.8506	0.4931	1.2957
ลดลง 50%	1.5711	1.4419	1.0608	1.0063
E_{12} เพิ่มขึ้น 50%	6.9724	7.5385	0.0560	19.8556
ลดลง 50%	-	-	-	-
E_{21} เพิ่มขึ้น 50%	0.5684	0.5523	0.0552	0.0529
ลดลง 50%	0.5704	0.5523	0.0558	0.4052
E_{22} เพิ่มขึ้น 50%	0.7219	0.7004	0.0725	0.0700
ลดลง 50%	-	-	-	-

จากการทดสอบเห็นได้ว่า เมื่อพลังงานกระตุ้นอันดับหนึ่งและสองขององค์ประกอบที่ 2 ของไม้ (E_{12} , E_{22}) ลดลง 50% ซึ่งแสดงดังรูปที่ 6.23 และ 6.27 ตัวควบคุมข่ายงานนิวรัลไม่สามารถควบคุมกระบวนการได้ จึงทำการหาค่าความผิดพลาดสูงสุดของ E_{12} และ E_{22} ที่ทำให้ตัวควบคุมข่ายงานนิวรัลยังคงสามารถควบคุมกระบวนการได้ พบว่า เมื่อ E_{12} ลดลง 15% และเมื่อ E_{22} ลดลง 40% ทำให้ตัวควบคุมยังคงสามารถควบคุมกระบวนการได้ แสดงดังรูปที่ 6.28 และ 6.29 แสดงให้เห็นว่าการลดลงของพลังงานกระตุ้นอันดับหนึ่งขององค์ประกอบที่ 2 ของไม้ (E_{12}) มีอิทธิพลต่อกระบวนการมากกว่าการลดลงของพลังงานกระตุ้นอันดับสองขององค์ประกอบที่ 2 ของไม้ (E_{22})



รูปที่ 6.28 ผลการควบคุมของข่ายงานนิวรัลเมื่อพลังงานกระตุ้นอันดับหนึ่งขององค์ประกอบที่ 2 ของไม้ (E_{12}) ลดลง 15%



รูปที่ 6.29 ผลการควบคุมของข่ายงานนิวรัลเมื่อยพลังงานกระตุ้นอันดับสองขององค์ประกอบที่ 2 ของไม้ (E_{22}) ลดลง 40%

จากการทดสอบกรณีพารามิเตอร์ของกระบวนการผิดพลาด พบว่าเมื่อใช้ตัวประมาณค่าข่ายงานนิวรัลร่วมกับตัวควบคุมข่ายงานนิวรัล โดยส่วนใหญ่แล้ว มีประสิทธิภาพในการประมาณค่า และมีสมรรถนะในการควบคุมค่าแคปปาได้ดี ทั้งนี้ขึ้นกับอิทธิพลของพารามิเตอร์แต่ละที่มีต่อกระบวนการ โดยตัวควบคุมมีความไวต่อความผิดพลาดของพลังงานกระตุ้นอันดับหนึ่งและสองขององค์ประกอบที่ 2 ของไม้ และเมื่อเปรียบเทียบกับตัวควบคุมพีไอ พบว่าตัวควบคุมข่ายงานนิวรัลดีกว่าตัวควบคุมพีไอ เพราะตัวแปรปรับมีการแกว่งค่าน้อยกว่า

6.6 วิเคราะห์ผลการทดลอง

6.6.1 การออกแบบแบบจำลองข่ายงานนิวรัล

6.6.1.1 แบบจำลองข่ายงานนิวรัลของตัวประมาณค่า

โครงสร้างข่ายงานนิวรัลของตัวประมาณค่า มีอินพุทของกระบวนการ คือ อุณหภูมิของเครื่องย่อยเยื่อกระดาษ และความเข้มข้นของโซเดียมไฮดรอกไซด์ เออร์พุท คือ ค่าแคปปา จากการทดสอบพบว่าโครงสร้างที่เหมาะสมของตัวประมาณค่า (จำนวนนิวรอนในชั้นอินพุท-จำนวนนิวรอนในชั้นซ่อน-จำนวนนิวรอนในชั้นเออร์พุท) คือ 4-5-1 เนื่องจากโครงสร้างอินพุทเวกเตอร์ที่มีจำนวนการหน่วงเวลาของอินพุท, $n_u = 0$ จำนวนการหน่วงเวลาของเออร์พุท, $n_y = 2$ และจำนวนนิวรอนในชั้นซ่อนเท่ากับ 5 ให้ ค่าผลรวมค่าผิดพลาดยกกำลังสองน้อยที่สุดเท่ากับ 0.0020

6.6.1.2 แบบจำลองข่ายงานนิวรัลของกระบวนการ

โครงสร้างข่ายงานนิวรัลของแบบจำลองข่ายงานนิวรัลของกระบวนการ มีอินพุทของกระบวนการ คือ อุณหภูมิของสายหมุนเวียน อัตราการไหลของสายหมุนเวียน และความเข้มข้นของโซเดียมไฮดรอกไซด์ เออร์พุท คือ ค่าแคปปา จากการทดสอบพบว่าโครงสร้างที่เหมาะสมของแบบจำลองข่ายงานนิวรัลของกระบวนการ (จำนวนนิวรอนในชั้นอินพุท-จำนวนนิวรอนในชั้นซ่อน-จำนวนนิวรอนในชั้นเออร์พุท) คือ 5-7-1 เนื่องจากโครงสร้างอินพุทเวกเตอร์ที่มีจำนวนการหน่วงเวลาของอินพุท, $n_u = 0$ จำนวนการหน่วงเวลาของเออร์พุท, $n_y = 2$ และจำนวนนิวรอนในชั้นซ่อนเท่ากับ 7 ให้ค่าผลรวมค่าผิดพลาดยกกำลังสองน้อยที่สุดเท่ากับ 0.0013

6.6.2 การออกแบบตัวควบคุมข่ายงานนิวรัล

ตัวควบคุมข่ายงานนิวรัลแบบเอ็นไอเอ็มซีได้จากการทำแบบจำลองผกผันของแบบจำลองข่ายงานนิวรัลของกระบวนการซึ่งเป็นแบบจำลองภายในของกระบวนการ โดยทำการออกแบบตัวควบคุมเป็น 2 ส่วนดังคำอธิบายในหัวข้อ 6.1.5 พบว่า จากการทดสอบพบว่าโครงสร้างที่เหมาะสมของตัวควบคุมข่ายงานนิวรัลทั้ง 2 ส่วน (จำนวนนิวรอนในชั้นอินพุท-จำนวนนิวรอนในชั้นซ่อน-จำนวนนิวรอนในชั้นเออร์พุท) คือ 7-5-1 และ 7-9-1 ตามลำดับเนื่องจากให้ค่าผลรวมค่าผิดพลาดยกกำลังสองน้อยที่สุดเท่ากับ 6.9582 และ 8.2833 ตามลำดับ

6.6.3 ผลการประมาณค่าและควบคุม

ในสถานะของสายป้อนของกระบวนการมีค่าดังตารางที่ 5.1- 5.3 การใช้ตัวประมาณค่าร่วมกับตัวควบคุมข่ายงานนิวรัลมีประสิทธิภาพในการประมาณค่าและควบคุม นั่นคือ สามารถประมาณค่าแคปไปได้แม่นยำและใกล้เคียงกับค่าจริง และสามารถควบคุมค่าแคปไปให้เข้าสู่ค่าเป้าหมายได้ในเวลาดำหนด โดยตัวควบคุมพีไอก็สามารถควบคุมกระบวนการได้ดีเช่นกัน แต่ตัวแปรปรับซึ่งก็คือ อุณหภูมิและอัตราการไหลของสายหมุนเวียนมีการแกว่งค่ามากกว่า แสดงว่าตัวควบคุมข่ายงานนิวรัลดีกว่าตัวควบคุมพีไอ

6.6.4 ผลการทดสอบตัวประมาณค่าและตัวควบคุม

6.6.4.1 กรณีที่ค่าของสารป้อนของกระบวนการผิดพลาด

ในการทดสอบตัวประมาณค่าและตัวควบคุมในกรณีที่สารป้อนของกระบวนการมีการเปลี่ยนแปลงไป จากรูปที่ 6.13 ถึง 6.19 พบว่า ตัวประมาณค่าข่ายงานนิวรัลมีความผิดพลาดในการประมาณค่าเริ่มต้น โดยเมื่อเปลี่ยนเป็นไม้เนื้ออ่อนจะมีความผิดพลาดในการประมาณค่ามากกว่าไม้เนื้อแข็ง ส่วนตัวควบคุมข่ายงานนิวรัลและตัวควบคุมพีไอต่างก็มีสมรรถนะในการควบคุม แต่เห็นได้ว่าตัวควบคุมข่ายงานนิวรัลดีกว่าเนื่องจากการแกว่งของค่าตัวแปรปรับน้อยกว่า

6.6.4.2 กรณีพารามิเตอร์ของแบบจำลองของกระบวนการผิดพลาด

การควบคุมสำหรับกรณีพารามิเตอร์ของแบบจำลองของกระบวนการผิดพลาด โดยพารามิเตอร์ที่ใช้ในการศึกษา คือ พลังงานกระตุ้นอันดับหนึ่งและสองขององค์ประกอบที่ 1 และ 2 ของไม้ (E_{11} , E_{12} , E_{21} , E_{22}) มีค่าเพิ่มขึ้นและลดลง 50% โดยส่วนใหญ่แล้วพบว่า การใช้ตัวประมาณค่าและตัวควบคุมข่ายงานนิวรัลสามารถควบคุมกระบวนการได้ดี ยกเว้นการลดลง 50% ของ E_{12} และ E_{22} ที่ทำให้ไม่สามารถควบคุมกระบวนการได้ และจากการทดสอบพบว่าเมื่อ E_{12} ลดลง 15% และ E_{22} ลดลง 40% เป็นความผิดพลาดสูงสุดที่ทำให้ตัวควบคุมยังสามารถควบคุมกระบวนการได้ แสดงว่าตัวควบคุมไวต่อความผิดพลาดของ E_{12} และ E_{22}

อย่างไรก็ตามกล่าวได้ว่าตัวควบคุมข่ายงานนิวรัลมีสมรรถนะในการควบคุมดีกว่าตัวควบคุมพีไอ เห็นได้ชัดจากกรณีที่ E_{12} เพิ่มขึ้น 50% ตัวควบคุมข่ายงานนิวรัลมีค่าคลาดเคลื่อนเพียง 0.0560 ในขณะที่ตัวควบคุมพีไอมีค่าคลาดเคลื่อนสูงถึง 19.8556 อีกทั้งยังมีการแกว่งของค่าตัวแปรปรับ

บทที่ 7

สรุปผลการวิจัย

จากการวิเคราะห์ผลการทดลองในบทที่ 6 สามารถสรุปผลการใช้ช่างงานนิรวัลในการประมาณค่าสร้างแบบจำลองและตัวควบคุมของกระบวนการย่อยเยื่อกระดาษได้ดังนี้

7.1 สรุปผลการวิจัย

ในงานวิจัยนี้ ทำการออกแบบตัวประมาณค่า แบบจำลองช่างงานนิรวัล และตัวควบคุมสำหรับกระบวนการย่อยเยื่อกระดาษแบบกะ โดยใช้ช่างงานนิรวัลแบบป้อนไปข้างหน้าหลายชั้นโดยมีอัลกอริทึมการเรียนรู้แบบการกระจายความผิดพลาดย้อนกลับที่มีฟังก์ชันมูลฐานเชิงเส้นแบบไฮเปอร์พลานและมีฟังก์ชันกระตุ้นแบบซิกมอยด์ โดยทำการจำลองกระบวนการเพื่อให้ได้ข้อมูลอินพุท-เอาต์พุทที่สอดคล้องกัน แล้วนำมาใช้ในการออกแบบแบบจำลองสำหรับตัวประมาณค่าและแบบจำลองช่างงานนิรวัล โดยทำการเก็บข้อมูลอินพุท-เอาต์พุทมา 2 ชุด ข้อมูลอินพุท-เอาต์พุทชุดที่ 1 ถูกใช้เป็นอินพุทในช่างงานและเป็นตัวสอนแบบจำลองให้มีค่าเอาต์พุทที่จะได้จากช่างงานใกล้เคียงกับค่าเป้าหมาย จากนั้นทำการทดสอบช่างงานด้วยชุดข้อมูลอินพุท-เอาต์พุทชุดที่ 2 แล้วเลือกโครงสร้างที่เหมาะสมโดยพิจารณาค่าผลรวมค่าผิดพลาดยกกำลังสองที่น้อยที่สุดของชุดทดสอบช่างงาน จากนั้นทำการออกแบบแบบจำลองฝึกฝน เพื่อใช้เป็นตัวควบคุม ซึ่งในงานวิจัยนี้ใช้โครงสร้างการควบคุมแบบเอ็นไอเอ็มซี

จากการหาโครงสร้างช่างงานนิรวัลที่เหมาะสมสำหรับกระบวนการ ได้ผลดังนี้

- โครงสร้างช่างงานนิรวัลที่เหมาะสมสำหรับการสร้างตัวประมาณค่า คือ 4-5-1
- โครงสร้างช่างงานนิรวัลที่เหมาะสมสำหรับแบบจำลองช่างงาน คือ 5-7-1
- โครงสร้างช่างงานนิรวัลที่เหมาะสมสำหรับตัวควบคุมส่วนที่ 1 คือ 7-5-1
- โครงสร้างช่างงานนิรวัลที่เหมาะสมสำหรับตัวควบคุมส่วนที่ 2 คือ 7-9-1

ผลการประมาณค่าของตัวประมาณค่าช่างงานนิรวัลเมื่อลูปิดโดยใช้โครงสร้างของตัวประมาณค่าแบบจำลองและตัวควบคุมที่มีโครงสร้างช่างงานนิรวัลที่เหมาะสมข้างต้น พบว่าตัวประมาณค่าสามารถประมาณค่าแคปปาได้ดี มีอินทิกรัลความผิดพลาดในการประมาณค่าต่ำ เข้าสู่ค่าจริงได้เร็ว รวมถึงกรณีพารามิเตอร์ของกระบวนการผิดพลาด แต่ในกรณีที่ค่าของสายป้อนของกระบวนการผิดพลาดหรือมีการเปลี่ยนแปลงชนิดของไม้ จะเกิดความผิดพลาดในการประมาณค่าเริ่มต้น แสดงให้เห็นว่าตัวประมาณค่าด้วยช่างงานนิรวัลมีประสิทธิภาพในการประมาณค่ากระบวนการย่อยเยื่อกระดาษ

เมื่อทดสอบโครงสร้างการควบคุมช่างงานนิรวัลแบบเอ็นไอเอ็มซีเทียบกับตัวควบคุมพีไอ พบว่าตัวควบคุมช่างงานนิรวัลมีสมรรถนะในการควบคุม รวมถึงกรณีค่าของสารป้อนและพารามิเตอร์ของแบบจำลองทางคณิตศาสตร์ของกระบวนการผิดพลาด โดยส่วนใหญ่ตัวควบคุมยังสามารถควบคุมค่าแคปปาของกระบวนการได้ ทั้งนี้สมรรถนะในการควบคุมเมื่อพารามิเตอร์ของแบบจำลองทางคณิตศาสตร์ของกระบวนการผิดพลาดขึ้นกับอิทธิพลของพารามิเตอร์นั้นๆที่มีต่อการควบคุมกระบวนการ โดยตัวควบคุมช่างงานนิรวัลมีความไวต่อการลดลงของพลังงานกระตุ้นอันดับหนึ่งและสองขององค์ประกอบที่ 2 ของไม้

7.2 บทสรุป

จากงานวิจัยนี้สามารถสรุปได้ว่า ข่ายงานนิเวศแบบป้อนไปข้างหน้าหลายชั้นที่มีแบบจำลองแบบกลับกระแสน้ำโดยใช้อัลกอริทึมการกระจายความผิดพลาดย้อนกลับ สามารถนำไปประยุกต์ใช้ในการประมาณค่า สร้างแบบจำลองและตัวควบคุมของกระบวนการย่อยเยื่อกระดาษแบบกะได้

7.3 ข้อเสนอแนะ

1. นำข้อมูลจริงที่วัดได้จากโรงงานมาเป็นข้อมูลอินพุต-เอาต์พุตในการฝึกและทดสอบข่ายงานแทนข้อมูลที่ได้จากการจำลองแบบจำลองทางคณิตศาสตร์ของกระบวนการ เพื่อข่ายงานจะได้เรียนรู้ค่าที่ใกล้เคียงกับกระบวนการผลิตจริง
2. ควรมีการประมาณค่าพารามิเตอร์ที่สำคัญและมีอิทธิพลต่อกระบวนการเพื่อเพิ่มความถูกต้องและสมรรถนะในการควบคุม

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

รายการอ้างอิง

ภาษาไทย

- ไพศาล กิตติศุภกร. **การควบคุมกระบวนการอัตโนมัติขั้นสูง**. เอกสารประกอบการสอน ปรับปรุงครั้งที่ 3. ภาควิชาวิศวกรรมเคมี จุฬาลงกรณ์มหาวิทยาลัย, ธันวาคม 2542
- นงลักษณ์ พลรักษา. **การทำนายค่าอัตราการไหลและความหนาแน่นของพอลิเมอร์โดยใช้ข่ายงานนิวรอน**. วิทยานิพนธ์ปริญญาโทบริหารธุรกิจ สาขาวิศวกรรมเคมี บัณฑิตวิทยาลัย จุฬาลงกรณ์มหาวิทยาลัย, 2543.
- สันติ ลิ้มพรชัยเจริญ. **การใช้ข่ายงานนิวรัลเป็นตัวควบคุมแบบไม่เชิงเส้น**. วิทยานิพนธ์ปริญญาโทบริหารธุรกิจ สาขาวิศวกรรมเคมี บัณฑิตวิทยาลัย จุฬาลงกรณ์มหาวิทยาลัย, 2539.
- สุรพล คำสุภา. **การสร้างแบบจำลองกระบวนการไม่เชิงเส้นโดยการใช้ข่ายงานนิวรัล**. วิทยานิพนธ์ปริญญาโทบริหารธุรกิจ สาขาวิศวกรรมเคมี บัณฑิตวิทยาลัย จุฬาลงกรณ์มหาวิทยาลัย, 2538.

ภาษาอังกฤษ

- Antsaklis, P.J. Neural Networks for Control Systems. **IEEE Transactions on Neural Networks** 1,2 (June 1990): 242-244.
- B. Jacques de Villiers., and Barnard, E. Back Propagation Neural Networks With One and Two Hidden Layers. **IEEE Transactions on Neural Networks** 4,1 (January 1992): 136-141.
- Baht, N. V., and McAvoy, T. J. Use of neural nets for dynamic modeling and control of chemical process systems. **Computers Chem Eng.** 14 (1990): S573-582.
- Barsamian, A., and Macias, J. Inferential Property Prediction Using Neural Network. **Hydrocarbon Processing** 77,10 (October 1998): 107-115.
- Belarbi, K., Bettou, K. and Mezache, A. Fuzzy Neural Networks for Estimation and Fuzzy Controller Design: Simulation study for a Pulp Batch Digester. **Journal of Process Control** 10 (2000): 35-41.

- Bequette, B. W. Nonlinear Control of Chemical Processes: A Review. **Ind. Eng. Chem. Res.** 30 (1991): 1391-1413.
- Chen, H. H., Manry, M. T., and Chandrasekaran, H. A Neural Network Training Algorithm Utilizing Multiple Sets of Linear Equations. **Neurocomputing** 25,1 (April 1999): 55-72.
- Datta, A. K., Lee, J. H., et. al. Model-Based Monitoring and Control of Batch Pulp Digester. **Proceedings of the American Control Conference** (June 1994): 500-504.
- Dawson, M., and Schopflocher, D. Modifying the Generalized Delta Rule to Train Networks of Non-Monotonic Processor for Pattern Classification. **Connection Science** 1,1 (1991): 19-31.
- Dirion, J. L., Cabassus, M., Lann, V. Le., and Gasamatta, G. Design of a Neural Controller by Inverse Modeling. **Computers Chem Eng.** 19 (1995): 797-802.
- Doherty, S. K., et. al. Experiment Design Considerations for Non-Linear System Identification Using Neural Networks. **Computers Chem Eng.** 21,3 (1997): 327-346.
- Dorsey, A. W., and Lee, J. H. Subspace Identification for Batch Processes. **Proceedings of the American Control Conference** (June 1999): 2538-2542.
- Fan, J. Y., Nikolaou, M., and White, R. E. An Approach to Fault Diagnosis of Chemical Processes via Neural Networks. **AIChE Journal** 39,1 (1993): 82-88.
- Haysin, S. **Neural Networks: A comprehensive Foundation**. 2nd ed. Prentice-Hall, 1999.
- Hunt, K. J., and Sbarbaro, D. Neural Networks for Nonlinear Internal Model Control. **IEEE Proc.-D.** 138,5 (1991): 413.
- Hunt, K. J., and Sbarbaro, D. Neural Networks for Control System- A Survey. **Automatica** 28 (1992): 1083-1112.
- Karim, M. N., and Rivera, S. L. Comparison of Feed-Forward and Recurrent Neural Networks for Bioprocess State Estimation. **European Symposium on Computer Aided Process Engineering** (1993): S369-S377.
- Kim, H. C., Shen, X., and Rao, M. Quality Prediction by Neural Network for Pulp and Paper Processes. **IEEE.** (1993): 104-107.

- Kim, S. J., Lee, M., Park, S., Lee, S. Y., and Prak, C. H. A Neural Linearizing Control Scheme for Nonlinear Chemical Processes. **Computers Chem Eng.** 21,2 (1997): 187-20.
- Kramer, M. A., and Leonard, J. A. Diagnosis using Backpropagation Neural Networks. **Computers Chem Eng.** 14 (1990): 1323-1338.
- Krothapally, M., and Palanki, S. A Neural Network Strategy for Batch Process Optimization. **Computers Chem Eng.** 21 (1997): S463-S468.
- Lee, J. H., and Datta, A. K. Nonlinear Inferential Control of Pulp Digesters **AIChE Journal** 40,1 (1994): 50-64.
- Leonard, J., and Kramer, M. A. Improvement of the Back Propagation Algorithm for Training Neural Networks. **Computers Chem Eng.** 14,3 (1990): 337-341.
- McCulloch, W. S., and Pitts, W. A logical Calculus of the Ideas Immanent in Neuronal Activity. **Bulletin of Mathematical Biophysics** 5 (1943): 115-133.
- Minsky, M., and Papert, S. **Perceptrons**. Cambridge :MIT Press, 1969.
- Miranda, A. F., Musari, M. T., and Coughlin, D. R. Pulp Digester Level Prediction Using Multiresolution Networks of Locally Active Units. **IEEE.** (1997): 663-637.
- Musavi, M. T., et. al. A Neuro-Fuzzy System for Prediction of Pulp Digester K-Number. **IEEE** 5 (1991): 836-839.
- Nahas, E. P., Henson, M. A., and Seborg, D.E. Nonlinear Internal Model Control Strategy for Neural Network Models. **Computers Chem Eng.** 16,12 (1992): 1039-1057.
- Narendra, K. S., and Parthasarathy, K. Gradient Methods for The Optimization of Dynamical Systems Containing Neural Networks. **IEEE Transactions on Neural Networks** 2,2 (1990): 252-262.
- Pollard, e. t. Improving Distillation Column by using Neural Network. Available from: <http://www.Latter.Demon.Co.uk/technical/neuralnetworks/page8.html>
- Psaltis, D., Sideris, A., and Yamamura, A. A Multilayered Neural Networks Controllers. **IEEE Control Syst Mag.** 10,3 (April 1989): 44-48.
- Rosenblatt, F. The Peraptron : A Probabilistic Model for Information Storage and Organization in The Brain. **Psychology Review** 15 (1958): 92-99.

- Srdjan Nestic, and Miran Vrhovac. A Neural Network Model for CO₂ Corrosion of CarbonSteel. **The Journal of Corrosion Science and Engineering (JCSE)** 1 (March 1999): Paper 6.
- Taji, K., Miyake, T., and Tamura, H. On Error Back Propagation Algorithm Using Absolute Error Function. **IEEE**. (1999): 401-406.
- Thibault, J., Breusegem, V. V., and Cheruy, A. On-line Prediction of Fermentation Variables Using Neural Networks. **Biotechnology and Bioengineering** 36 (1990): 1041-1048.
- Thompson, M. L., and Kramer, M. A. Modeling Chemical Processes Using Prior Knowledge and Neural Networks. **AIChE Journal** 40,8 (1994): 1328-1340.
- Vora, N., Tambe, S. S., and Kulkarni, B. D. Counterpropagation Neural Networks for Fault Detection and Diagnosis. **Computers Chem Eng.** 21,2 (1997): 177-185.
- Werbos, P. J. **Beyond Regression : New Tools for Prediction and Analysis in The Behavior Sciences**. Ph.D.Thesis, Harvard University Committee in Applied Mathematics, 1974.
- Willis, M. J., Massimo, C. D., Montague, G. A., Tham, M. T., and Morris, A. J. Artificial Neural Networks in Process Engineering. **IEEE Proceedings** 138,3 (1991)



สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย



ภาคผนวก

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

ภาคผนวก ก

โปรแกรมแมทแลบ (Matlab)

โปรแกรมแมทแลบ (Matlab) เป็นโปรแกรมที่ใช้ในการคำนวณทางคณิตศาสตร์ขั้นสูงและใช้แก้ปัญหาที่เป็นเมทริกซ์และเวกเตอร์ ข้อดีของการเขียนโปรแกรมด้วยแมทแลบ คือ ง่ายกว่าโปรแกรมภาษาอื่นๆ เนื่องจากโปรแกรมแมทแลบได้รวมเอาคุณสมบัติที่ดีของโปรแกรมภาษาอื่นเข้ามา เช่น ไม่ต้องประกาศชื่อและชนิดของตัวแปรที่เหมือนกับโปรแกรมภาษาเบสิก และการโครงสร้างการเขียนโปรแกรมเป็นโครงสร้างที่เข้าใจง่ายที่ใช้ในโปรแกรมภาษาซีและปาสคาล

โปรแกรมแมทแลบ (Matlab) มีชื่อย่อมาจาก **matrix laboratory** แมทแลบเป็นภาษาคอมพิวเตอร์ขั้นสูงสำหรับการคำนวณทางเทคนิคที่ประกอบด้วยการคำนวณเชิงตัวเลข กราฟฟิกที่ซับซ้อนและการจำลองแบบเพื่อให้มองเห็นภาพพจน์ได้ง่ายและชัดเจน แต่เดิมโปรแกรมแมทแลบถูกเขียนขึ้นมาเพื่อใช้ในการคำนวณทางเมทริกซ์ที่พัฒนามาจากโครงการที่ชื่อ LINKPACK และ EISPACK ต่อมาแมทแลบก็ได้รับการพัฒนาขึ้นเป็นเวลาหลายปี จึงทำให้แมทแลบมีฟังก์ชันต่างๆ ให้เลือกใช้มากมายและเป็นที่ยอมรับในการใช้งานด้านอุตสาหกรรม คณิตศาสตร์ วิศวกรรมและวิทยาศาสตร์แขนงต่างๆ

ก.1 ความสามารถของโปรแกรมแมทแลบ

โปรแกรมแมทแลบเป็นโปรแกรมที่ได้รับความนิยมทั้งในวงการศึกษาซึ่งใช้ในการวิจัยและการสอนทางคณิตศาสตร์และในทางอุตสาหกรรมซึ่งใช้ในการวิจัยทางวิศวกรรมและการแก้ปัญหาทางคณิตศาสตร์ เช่นการควบคุมกระบวนการแบบอัตโนมัติ การทำงานของโปรแกรมแมทแลบจะเป็นฟังก์ชันของคำสั่งที่อยู่ในรูปของโปรแกรม 'M-file' ซึ่งฟังก์ชันเหล่านี้เป็นเรื่องมือที่ใช้ในการหาคำตอบ เรียกว่า ทุลบ็อกซ์ (Toolbox) โดยโปรแกรมแมทแลบมีทุลบ็อกซ์ต่างๆ เช่น

- ก. การคำนวณและการแก้ปัญหาด้วยคุณสมบัติพิเศษของเมทริกซ์
- ข. การคำนวณโพลีโนเมียล
- ค. การจัดการเกี่ยวกับเวกเตอร์และการวิเคราะห์ข้อมูล
- ง. การจัดการเกี่ยวกับการแสดงผลกราฟ
- จ. การติดต่อสื่อสาร (communication toolbox)
- ฉ. การแก้ปัญหาทางสถิติ (statistics toolbox)

- ซ. เวฟเลท (wavelet)
- ช. การประมวลผลภาพ (image processing toolbox)
- ฅ. การแก้ปัญหาด้านระบบควบคุม (control system toolbox)
- ญ. โครงข่ายนิวรัล (neural networks toolbox)
- ฎ. ฟัซซี่ลอจิก (fuzzy logic toolbox)
- ฏ. การประมวลผลสัญญาณ (signal processing toolbox)
- ฐ. เครื่องมือในการสร้างแบบจำลองในการควบคุมแบบโมเดลพรีดิกทีฟ (Model Predictive Control toolbox)
- ฑ. การออกแบบระบบควบคุมไม่เชิงเส้น (Nonlinear Control Design toolbox)
- ฒ. การออปติไมเซชัน (Optimization toolbox)

ก.2 จุดเด่นของโปรแกรมแมทแลบ

- 2.1 มีฟังก์ชันคณิตศาสตร์ให้เลือกใช้ในการคำนวณมากมาย และสามารถสร้างฟังก์ชันขึ้นมาใช้งานได้เองตามความต้องการ
- 2.2 สามารถแก้ปัญหาทางคณิตศาสตร์ที่มีความซับซ้อนได้ดีอีกทั้งยังวิเคราะห์และตรวจสอบข้อมูลได้ง่ายและรวดเร็ว
- 2.3 มี simulink ซึ่งทำให้สามารถสร้างบล็อกไดอะแกรมเพื่อใช้ทดสอบและประเมินผลระบบพลศาสตร์ต่างๆก่อนนำไปใช้งานจริง
- 2.4 เหมาะกับการใช้งานด้านกราฟฟิก เนื่องจากมีความสามารถในการแสดงภาพทั้งสองและสามมิติในรูปแบบพื้นผิวและระดับสูงต่ำ (contour) และยังสามารถนำภาพมาต่อกันเพื่อสร้างเป็นภาพเคลื่อนไหวได้อีกด้วย
- 2.5 สามารถทำการประมวลผลร่วมกับโปรแกรมอื่นได้ เช่น ฟอรัทแรน (Fortran) ซี หรือซีพลัสหรือไมโครซอฟท์วิซวลซี (C/C++, Microsoft visual C++)
- 2.6 โปรแกรมแมทแลบมีเครื่องมือสำหรับการสร้างแบบจำลองของข่ายงานนิวรัลซึ่งมีอัลกอริทึมหลายชนิดให้เลือกสำหรับการสร้างข่ายงาน

ก.3 ข้อจำกัดของโปรแกรมแมทแลบ

การเลือกใช้คอมพิวเตอร์สำหรับโปรแกรมแมทแลบต้องเป็นคอมพิวเตอร์ที่มีความเร็วสูง เนื่องจากโปรแกรมแมทแลบนี้เป็นโปรแกรมที่ใช้คำนวณทางคณิตศาสตร์และกราฟิกที่มีความซับซ้อน คอมพิวเตอร์ส่วนบุคคลที่เหมาะสมกับโปรแกรมแมทแลบ คือ มีหน่วยประมวลผล (CPU) ตั้งแต่เพนเทียมขึ้นไป หน่วยความจำ (RAM) อย่างน้อย 32 เมกะไบต์ และฮาร์ดดิสก์ควรมีพื้นที่ว่างมากกว่า 80 เมกะไบต์

ก.4 การเขียนโปรแกรมด้วยคำสั่งในโปรแกรมแมทแลบ

โปรแกรมแมทแลบจะรับคำสั่งทีละ 1 บรรทัดในพื้นที่หน้าต่างของโปรแกรม หลังจากรับคำสั่งแล้วโปรแกรมแมทแลบจะประมวลผลและแสดงผลทางหน้าต่างการทำงานและสามารถสร้างไฟล์ที่ประกอบด้วยชุดคำสั่ง โดยเก็บอยู่ในรูป "ชื่อไฟล์.M" หรือที่เรียกว่า เอ็มไฟล์ (M-files) การประมวลผลจะทำการประมวลผลทีละคำสั่งตามลำดับก่อนหลัง การเขียนเอ็มไฟล์มีอยู่ 2 รูปแบบ คือ สคริปไฟล์และฟังก์ชันไฟล์

ในการเขียนโปรแกรมแมทแลบด้วยเอ็มไฟล์ (M-files) จะมีรูปแบบการเขียนโปรแกรมเป็น 2 รูปแบบ คือ สคริปเอ็มไฟล์ (Script M-files) กับเอ็มไฟล์ฟังก์ชัน (M-files functions) ทั้ง 2 แบบนี้เป็นไฟล์มีสกุล.m ที่สร้างขึ้นจากหน้าต่างโปรแกรมเอดิเตอร์ (editor) โดยโปรแกรมที่เป็นเอ็มไฟล์ฟังก์ชันจะผ่านเข้า/ออกค่าตัวแปรต่างๆให้กับแมทแลบเวิร์คสเปซ (MATLAB Workspace) เฉพาะค่าผลลัพธ์ที่เป็นเอาต์พุทของคำสั่งเท่านั้น ส่วนโปรแกรมที่เป็นสคริปเอ็มไฟล์ จะผ่านเข้า/ออกค่าตัวแปรต่างๆทุกตัวภายในโปรแกรมให้กับแมทแลบเวิร์คสเปซ


ภาคผนวก ข

ตัวควบคุมแบบป้อนกลับแบบพีไอ

ในบทนี้กล่าวถึงทฤษฎีของตัวควบคุมแบบพีไอซึ่งใช้เป็นตัวเปรียบเทียบในงานวิจัย

ข.1 ทฤษฎีของตัวควบคุมพีไอ

การควบคุมแบบป้อนกลับแบบพีไอเป็นการควบคุมแบบพื้นฐานที่เข้าใจได้ง่ายและใช้กันทั่วไปในการควบคุมกระบวนการอุตสาหกรรมทั่วไป โครงสร้างของระบบควบคุมแบบป้อนกลับแสดงดังรูปที่ ข.1 โดยตัวควบคุมจะทำการเปรียบเทียบค่าตัวแปรควบคุมกระบวนการ c กับค่าเป้าหมาย sp แล้วสร้างสัญญาณเอาต์พุต u เพื่อปรับสภาพของกระบวนการ โดยตัดสินใจจากค่าความผิดพลาดในการควบคุม $e = sp - c$ ซึ่งลักษณะความสัมพันธ์ระหว่างความผิดพลาดในการควบคุม e กับสัญญาณเอาต์พุต u ของตัวควบคุมขึ้นกับชนิดและคุณสมบัติของตัวควบคุมแต่ละชนิด



รูปที่ ข.1 ระบบการควบคุมแบบป้อนกลับ (feedback control system)

ตัวควบคุมแบบพื้นฐานที่ใช้ในระบบควบคุมแบบป้อนกลับในกระบวนการอุตสาหกรรมโดยทั่วไปมี 3 ประเภท คือ ตัวควบคุมแบบพี ตัวควบคุมแบบพีไอและตัวควบคุมแบบพีไอดี

ก. ตัวควบคุมแบบพี (Proportional Controller หรือ P Controller)

สัญญาณเอาต์พุตจะแปรผันตรงตามค่าผิดพลาดในการควบคุม

$$u(t) = K_c e(t) + u_s \quad (ข.1)$$

K_c คือเกนสัดส่วน (proportional gain) ของตัวควบคุม u_s คือค่าไบแอส (bias signal) ของตัวควบคุม และ $u(t)$ คือเอาต์พุตของตัวควบคุม ซึ่งตัวควบคุมแบบพีสามารถแสดงอัตราการควบคุมได้ 2 แบบ คือ ค่าเกนสัดส่วน (K_c) และแบนด์สัดส่วน (proportional band, PB) ซึ่งหมายถึงค่าความผิดพลาดในการควบคุม e ที่ทำให้สัญญาณเอาต์พุตมีค่าสูงสุด โดย $PB = 100/K_c$

กระบวนการอุตสาหกรรมทั่วไปสามารถใช้ตัวควบคุมที่มีเกนสัดส่วน $0.2 \leq K_c \leq 100$ หรือค่าแบนด์สัดส่วนน้อยจะมีความไวในการตอบสนองต่อค่าความผิดพลาดในการควบคุมสูง ทราన్สเฟอ์ฟังก์ชันของตัวควบคุมแบบพี คือ

$$G_c(s) = K_c \quad (ข.2)$$

ข. ตัวควบคุมแบบพีไอ (Porportional-Integral Controller หรือ PI Controller)
สัญญาณเอาต์พุตมีความสัมพันธ์กับค่าความผิดพลาดในการควบคุมตามสมการ

$$u(t) = K_c e(t) + \frac{K_c}{\tau_I} \int_0^t e(t) dt + u_s \quad (ข.3)$$

เมื่อ τ_I คือ ค่าคงที่เวลาอินทิกรัล (Integral time constant) หรือเวลารีเซ็ต (reset time) ของตัวควบคุมแบบไอ ซึ่งตัวควบคุมแบบไอแสดงอัตราการควบคุมโดยใช้ค่าคงที่เวลาอินทิกรัล มีหน่วยเป็นครั้งต่อนาทีซึ่งมีค่าเป็น $1/\tau_I$ ซึ่งกระบวนการทางอุตสาหกรรมทั่วไปสามารถใช้ตัวควบคุมที่มีค่าคงที่อินทิกรัล $0.1 \leq \tau_I \leq 50$ นาที

ค่าคงที่อินทิกรัล τ_I หมายถึงช่วงเวลาที่ตัวควบคุมใช้ในการเพิ่มสัญญาณเอาต์พุตแบบไอจนมีค่าเท่ากับสัญญาณที่ได้จากการควบคุมแบบพีเพียงอย่างเดียวหนึ่งครั้ง หรือตัวควบคุมแบบไอต้องใช้เวลา τ_I เพื่อเพิ่มสัญญาณเอาต์พุตให้มีค่าเท่ากับสัญญาณที่ได้จากการควบคุมแบบพีหนึ่งครั้ง สัญญาณเอาต์พุตของตัวควบคุมแบบไอจะมีการเปลี่ยนแปลงค่าเพิ่มขึ้นหรือลดลงตลอดเวลาที่ยังคงมีค่าความผิดพลาดในการควบคุมอยู่ โดยทราన్สเฟอ์ฟังก์ชันของตัวควบคุมพีไอ คือ

$$G_c(s) = K_c \left(1 + \frac{1}{\tau_I s} \right) \quad (ข.4)$$

ค. ตัวควบคุมแบบพีไอดี (Proportional-Integral-Derivative Controller หรือ PID Controller)

สัญญาณเอาต์พุตของตัวควบคุม คือ

$$u(t) = K_c e(t) + \frac{K_c}{\tau_I} \int_0^t e(t) dt + K_c \tau_D \frac{de(t)}{dt} + u_s \quad (1.5)$$

เมื่อ τ_D คือค่าคงที่อนุพันธ์ (derivative time constant) ของตัวควบคุมแบบดี โดยตัวควบคุมแบบดีสร้างเอาต์พุตแบบดีจากเทอม $\frac{de(t)}{dt}$ ในสมการที่ 1.5 ซึ่งจะเปลี่ยนแปลงค่าทันทีที่ค่าความผิดพลาดในการควบคุม $e(t)$ มีการเปลี่ยนแปลง โดยสัญญาณการควบคุมแบบดีถูกสร้างเพื่อลดความผิดพลาดในการควบคุมล่วงหน้า

ทรานส์เฟอร์ฟังก์ชันของตัวควบคุมแบบพีไอดี คือ

$$G_c(s) = K_c \left(1 + \frac{1}{\tau_I s} + \tau_D s \right) \quad (1.6)$$

สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

ภาคผนวก ค.

ตัวอย่างโปรแกรมที่สำคัญ

โปรแกรมที่สำคัญสำหรับงานวิจัยนี้ คือ โปรแกรมสำหรับซิมมูลเตทกระบวนการเพื่อนำข้อมูลอินพุทและเอาต์พุทที่ได้จากการซิมมูลเตทมาใช้ในการสร้างข่ายงานนิวรัล

ค.1 ตัวอย่างโปรแกรมการซิมมูลเตทกระบวนการ

โปรแกรมนี้ใช้วิธีออยเลอร์ (Euler's method) ในการแก้สมการอนุพันธ์ โดยเลือกอินพุทและเอาต์พุทแบบสุ่ม (True random)

```
clear
```

```
clc
```

```
%Parameter
```

```
ss = 1e3;
```

```
E1=[ 6.45*ss,29.10*ss,17.55*ss,14.85*ss,22.05*ss ];
```

```
E2=[ 21.9*ss,12.35*ss,19.85*ss,17.45*ss,18.25*ss ];
```

```
A1=[ 19.41,4.16e12,445.12,108,7.05e5 ];
```

```
A2=[ 7e3,2.75e4,8.3e3,6e3,1.75e4 ];
```

```
S3=[ 0.166,0.166,0.395,0.395,0.395 ];
```

```
S4=[ 0.0546,0.0546,0,0,0 ];
```

```
Xu=[ 0,0,0.071,0.025,0 ];
```

```
R=1.9872;
```

```
CT=3;
```

```
Cp=0.36;
```

```
Frmin=0.5;
```

```
Cpl=1;
```

```
dt=0.005;
```

```
a=0.5;
```

```
b=0.5;
```

```
Frmax=1;
```

```
dH=102.8;
```

```
Mw=100;
```

```
A=105.75;
```

```
Trmin=353;
```

```
Ve=0.1175;
```

```
Vf=0.2325;
```

```
n=CT/dt;
```

```
Trmax=523;
```

```
M1=-0.07;
```

```
M2=2e-4;
```

```
Tsp=443;
```

```
Ksp=50;
```

```
%Initial Value
```

```
T(1)=353;
```

```
Ce1(1)=0;
```

```
Cf1(1)=1;
```

```
X1(1)=0.0528; T(1)=353;
```

```

Ce2(1)=0;           Cf2(1)=2;           X2(1)=0.2112;
Ce3(1)=0;           Cf3(1)=47.6327;        X3(1)=0.4852;
Ce4(1)=0;           Cf4(1)=11.3535;       X4(1)=0.1428;
Ce5(1)=0;           Cf5(1)=1000;         X5(1)=0.0722;

```

```
%Uniform Random Inputs
```

```
Trs=(Trmax-Trmin)* rand(1,n+1)+Trmin;
```

```
Frs=(Frmax-Frmin)* rand(1,n+1)+Frmin;
```

```
%===== MAIN LOOP =====%
```

```
for t=1:1:n+1
```

```
Cf=[ Cf1(t),Cf2(t),Cf3(t),Cf4(t),Cf5(t) ];
```

```
Ce=[ Ce1(t),Ce2(t),Ce3(t),Ce4(t),Ce5(t) ];
```

```
X=[ X1(t),X2(t),X3(t),X4(t),X5(t) ];
```

```
k1=A1.*exp(-E1/(R*T(t)));
```

```
k2=A2.*exp(-E2/(R*T(t)));
```

```
Ri=(-1)*(k1*Ce3(t)+k2*(Ce3(t)^a)*(Ce4(t)^b)).*(X-Xu);
```

```
RH=(-dH)*(-Ri);
```

```
SumRH=sum(RH);
```

```
SumT=sum(Cf*Cpl*(Trs(t)-T(t)));
```

```
Kt=(Mw*sum(Cp*X))+(Ve*sum(Cpl*Ce))+(Vf*sum(Cpl*Cf));
```

```
%Reactor temp Balance
```

```
T(t+1)=T(t)+(dt/Kt)*(Mw*SumRH+Frs(t)*SumT);
```

```
%Concentration in wood
```

```
X1(t+1)=X1(t)+dt*Ri(1);
```

```
X2(t+1)=X2(t)+dt*Ri(2);
```

```
X3(t+1)=X3(t)+dt*Ri(3);
```

```
X4(t+1)=X4(t)+dt*Ri(4);
```

```
X5(t+1)=X5(t)+dt*Ri(5);
```

%Mass transfer coefficient

$$M_i = M_1 + M_2 * T(t);$$

%Concentration in free liquor

$$C_{f1}(t+1) = C_{f1}(t) + (dt/V_f) * (M_i * A * (C_{e1}(t) - C_{f1}(t)));$$

$$C_{f2}(t+1) = C_{f2}(t) + (dt/V_f) * (M_i * A * (C_{e2}(t) - C_{f2}(t)));$$

$$C_{f3}(t+1) = C_{f3}(t) + (dt/V_f) * (M_i * A * (C_{e3}(t) - C_{f3}(t)));$$

$$C_{f4}(t+1) = C_{f4}(t) + (dt/V_f) * (M_i * A * (C_{e4}(t) - C_{f4}(t)));$$

$$C_{f5}(t+1) = C_{f5}(t);$$

%Total rate of generation in entrapped liquor

$$G_1 = -\sum(R_i(1:2));$$

$$G_2 = -\sum(R_i(3:5));$$

$$G_3 = \sum(S_3 * R_i);$$

$$G_4 = \sum(S_4 * R_i);$$

%Concentration in entrapped liquor

$$C_{e1}(t+1) = C_{e1}(t) + (dt/V_e) * (M_w * G_1 - M_i * A * (C_{e1}(t) - C_{f1}(t)));$$

$$C_{e2}(t+1) = C_{e2}(t) + (dt/V_e) * (M_w * G_2 - M_i * A * (C_{e2}(t) - C_{f2}(t)));$$

$$C_{e3}(t+1) = C_{e3}(t) + (dt/V_e) * (M_w * G_3 - M_i * A * (C_{e3}(t) - C_{f3}(t)));$$

$$C_{e4}(t+1) = C_{e4}(t) + (dt/V_e) * (M_w * G_4 - M_i * A * (C_{e4}(t) - C_{f4}(t)));$$

$$C_{e5}(t+1) = C_{e5}(t);$$

%Kappa No

$$K_s(t) = 653.6 * (X_1(t) + X_2(t));$$

end; %MAIN LOOP

%Sampling

$$\text{samptime} = 0.0025;$$

$$\text{fixtime} = 2;$$

$$\text{sampnum} = \text{fixtime} / \text{samptime};$$

$$i = 0;$$

$$j = 1;$$

while j <= n+1

```

i=i+1;
Tr(i,:)=Trs(j);
Fr(i,:)=Frs(j);
K(i,:)=Ks(j);
temp(i,:)=T(j);
j=j+(samptime/dt);
end;
Tr=Tr(1:sampnum+1);
Fr=Fr(1:sampnum+1);
Kk=K(1:sampnum+1);
Kk1=K(2:sampnum+2);
Tk=temp(1:sampnum+1);
Tk1=temp(2:sampnum+2);
data=[ Tk Tr Fr ];

%===== Result =====%
cutplot=fixtime/dt;
for t=1:1:cutplot+1
    tn(t) = dt*(t-1);
end;

figure
subplot(221)
plot(tn,T(1:cutplot+1),tn(1:cutplot+1),Tsp*ones(cutplot+1,1),'k:')
ylabel('Reactor temp (K)')
xlabel('Time (hr)')
subplot(222)
plot(tn,Ks(1:cutplot+1));
xlabel('hr')
ylabel('Kappa no. ');
subplot(223)
plot(tn,Trs(1:cutplot+1))
ylabel('Tr (K)')
xlabel('Time (hr)')
subplot(224)

```



```
plot(tn,Frs(1:cutplot+1))  
ylabel('Fr (m^3/hr)')  
xlabel('Time (hr)')
```



สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย

ประวัติผู้เขียนวิทยานิพนธ์

นางสาวรดาณัฐ วิเศษสรโรช เกิดเมื่อวันที่ 13 เมษายน พ.ศ. 2521 เขตปทุมวัน
จ.กรุงเทพมหานคร สำเร็จการศึกษาในระดับมัธยมศึกษาปีที่ 5 จากโรงเรียนสตรีวิทยา เมื่อ พ.ศ.
2537 สำเร็จการศึกษา ปริญญาวิทยาศาสตรบัณฑิตสาขาอุตสาหกรรมเกษตร จากสถาบัน
เทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง เมื่อ พ.ศ. 2541



สถาบันวิทยบริการ
จุฬาลงกรณ์มหาวิทยาลัย