

การวิเคราะห์ภาพถ่ายดาวเทียมโดยใช้โครงข่ายประสาทเทียมแบบ ART

SATELLITE IMAGE ANALYSIS USING ART NEURAL NETWORK



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของวารสารศึกษาศาสตร์ตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมไฟฟ้า

บัณฑิตวิทยาลัย

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2544

ISBN 974-649-252-1

สำนักหอสมุดกลาง พระจอมเกล้าลาดกระบัง

การวิเคราะห์ภาพถ่ายดาวเทียมโดยใช้โครงข่ายประสาทเทียมแบบ ART

SATELLITE IMAGE ANALYSIS USING ART NEURAL NETWORK



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต  
สาขาวิชาวิศวกรรมไฟฟ้า  
บัณฑิตวิทยาลัย

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2544

ISBN 974-648-252-1

เลขหมู่.....  
เลขทะเบียน.....40124  
วัน, เดือน, ปี.....16 สิงหาคม 2544

.....  
.....  
.....

ไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่สามารถ.....  
ให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของ.....

**SATELLITE IMAGE ANALYSIS USING ART NEURAL NETWORK**



**A THESIS SUBMITTED IN PARTIAL FULFILLMENT  
OF THE REQUIREMENT FOR THE DEGREE OF  
MASTER OF ENGINEERING IN ELECTRICAL ENGINEERING  
SCHOOL OF GRADUATE STUDIES  
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG**

**2001**

**ISBN 974-648-252-1**

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



**COPYRIGHT 2001**

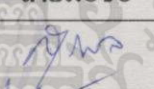
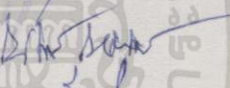
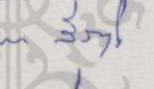

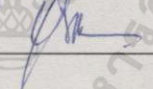
**SCHOOL OF GRADUATE STUDIES**

**KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG**

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บัณฑิตวิทยาลัย  
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง  
ใบรับรองวิทยานิพนธ์

หัวข้อวิทยานิพนธ์ การวิเคราะห์ภาพถ่ายดาวเทียมโดยใช้โครงข่ายประสาทเทียมแบบ ART  
SATELLITE IMAGE ANALYSIS USING ART NEURAL NETWORK  
ชื่อนักศึกษา นายสุพจน์ มงคลวรผล  
รหัสประจำตัว 39061053  
ปริญญา วิศวกรรมศาสตรมหาบัณฑิต  
สาขาวิชา วิศวกรรมไฟฟ้า  
อาจารย์ผู้ควบคุมวิทยานิพนธ์ รศ.ดร.ยุทธพงษ์ รังสรรค์เสรี

คณะกรรมการสอบวิทยานิพนธ์		ลายมือชื่อ
รศ.ดร.สุวิพล	สิทธิชีวภาค	
รศ.ณรงค์	เหมกรณ์	
รศ.นิภา	ลีลาจจิ	
ผศ.ดร.ปัญญา	จิติมัชฌิมา	
รศ.ดร.ยุทธพงษ์	รังสรรค์เสรี	

วัน/เดือนปี ที่สอบ 23 พฤษภาคม 2544 เวลา 12.00 – 13.00 น.

สถานที่สอบ ณ อาคาร 12 ชั้น 4 (ห้อง E12-404)

บัณฑิตวิทยาลัยรับรองแล้ว



(รศ.ดร.บุญวัฒน์ อัทธง)

คณบดีบัณฑิตวิทยาลัย

วันที่ 13 เดือน พฤษภาคม พ.ศ. 2544

หัวข้อวิทยานิพนธ์	การวิเคราะห์ภาพถ่ายดาวเทียม โดยใช้โครงข่ายประสาทเทียมแบบ ART
นักศึกษา	นายสุพจน์ มงคลวรผล
รหัสประจำตัว	39061053
ปริญญา	วิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชา	วิศวกรรมไฟฟ้า
พ.ศ.	2544

อาจารย์ผู้ควบคุมวิทยานิพนธ์ รศ.ดร. ยุทธพงษ์ รังสรรค์เสรี

### บทคัดย่อ

งานวิจัยนี้ได้ทำการวิเคราะห์ภาพถ่ายดาวเทียมมัลติสเปกตรัม ด้วยวิธีการของโครงข่ายประสาทเทียมอะแดปทีฟรีโซแนนซ์เทียร์ (ART) โดยใช้ทำการประยุกต์ ในการจำแนกข้อมูลจากภาพถ่ายดาวเทียม ซึ่งประกอบด้วย ART1 และ ART2 ใช้ข้อมูลอินพุตเป็นแบบไบนารี และจำนวนเต็มต่อเนื่อง ตามลำดับ โดยทำการคำนวณค่าอินพุตเวกเตอร์แต่ละพิกเซลที่อยู่ในแต่ละแบนด์ ซึ่งเราได้พยายามทำการปรับปรุงอัลกอริทึมและค่าตัวแปรต่างๆ ให้ได้ผลออกมาได้ใกล้เคียงมากที่สุดเท่าที่เป็นไปได้ โดยได้ใช้ภาพกรุงเทพฯที่ถ่ายจากดาวเทียม ADEOS และภาพถ่ายจังหวัดชุมพรจากดาวเทียม LANSAT-5 ซึ่งผลลัพธ์ที่ได้ ART1 สามารถแยกแยะภาพที่มีความคล้ายกันได้ และ ART2 สามารถแยกแยะภาพที่ให้ขอบเขตภาพได้ชัดเจน

<b>Thesis Title</b>	Satellite Image Analysis Using ART Neural Network
<b>Student</b>	Mr. Supoj Mongkolworaphol
<b>Student ID.</b>	39061053
<b>Degree</b>	Master of Engineering
<b>Programme</b>	Electrical Engineering
<b>Year</b>	2001
<b>Thesis Advisor</b>	Assoc. Prof. Dr. Yuttapong Rangsanseri

### ABSTRACT

In this research, remote-sensing multispectral images are analyzed and interpreted by means of a neural network approach. In particular, the advantages found by using Adaptive Resonance Theory network of the data are shown and commented. We used the ART1 and ART2 structures that accept binary data and continuous-value data, so that each input can be for each pixel directly the vector of the gray level values at each band. This choice is due to the attempt to simplify algorithm as much as possible. Experiments carried out with ADEOS images and LANDSAT-5 are given and compared with ground truth image. The result presented, ART introducing a clustering step to solve the class redundancy and highlighting the advantages of spectral analysis of data.


## กิตติกรรมประกาศ

ในการทำวิทยานิพนธ์ฉบับนี้ได้สำเร็จบรรลุได้ก็ด้วยความอนุเคราะห์และช่วยเหลือให้คำแนะนำให้คำปรึกษา ในหลายๆด้านจากท่านอาจารย์ รองศาสตราจารย์ ดร. ยุทธพงษ์ รั้งสรรค์เสรี ซึ่งท่านได้ชี้แนวทางในการทำวิจัยตลอดมา จนสำเร็จลงด้วยดี กระผมขอกราบขอบพระคุณเป็นอย่างสูง และขอขอบพระคุณ ท่านอาจารย์ ดร. ปัญญา จูติม์ชฌิมา ที่ได้ให้คำปรึกษาและคำแนะนำ

ผู้วิจัยขอขอบพระคุณ ดร.สุวิทย์ อ่องสมหวัง ผู้เชี่ยวชาญทางด้านระบบสารสนเทศศรพยากรป่าไม้และสิ่งแวดล้อม และคุณจิรวรรณ จารุพัฒน์ ผู้เชี่ยวชาญทางด้านภาพถ่ายดาวเทียมจากสำนักวิชาการป่าไม้ แห่งประเทศไทย ที่ให้ความอนุเคราะห์ทางด้านภาพถ่ายดาวเทียม

สุดท้ายนี้ ขอขอบพระคุณ บิดา มารดา ญาติพี่น้อง และเพื่อนๆ ทุกคนที่ได้เป็นกำลังใจและเป็นแรงผลักดันให้สำเร็จลงได้ด้วยดี

สุพจน์ มงคลวรผล



# สารบัญ


	หน้า
บทคัดย่อภาษาไทย.....	I
บทคัดย่อภาษาอังกฤษ.....	II
กิตติกรรมประกาศ.....	III
สารบัญ.....	IV
สารบัญตาราง.....	VII
สารบัญรูป.....	VIII
อภิธานศัพท์.....	X
บทที่ 1 บทนำ.....	1
1.1 ความเป็นมาของงานวิจัย.....	1
1.2 วัตถุประสงค์ของงานวิจัย.....	2
1.3 ขอบเขตของงานวิจัย.....	2
1.4 ทฤษฎีแนวความคิดที่ใช้ในการวิจัย.....	3
1.5 โครงสร้างของวิทยานิพนธ์.....	3
บทที่ 2 พื้นฐานของการสำรวจข้อมูลระยะไกล.....	4
2.1 พลังงานแม่เหล็กไฟฟ้า.....	5
2.1.1 ทฤษฎีคลื่น.....	6
2.1.2 ทฤษฎีอนุภาค.....	8
2.2 วิธีการจำแนกประเภทของภาพ.....	8
2.2.1 การจำแนกภาพแบบมีผู้สอน.....	9
2.2.1.1 การกำหนดข้อมูลที่ใช้ในการฝึกสอน.....	9
2.2.1.2 ขั้นตอนในการทำงานแบบมีผู้สอน.....	10
2.2.2 การจำแนกภาพแบบไม่มีผู้สอน.....	13

## สารบัญ(ต่อ)

	หน้า
บทที่ 3 โครงข่ายประสาทเทียม.....	21
3.1 ทฤษฎีเซลล์ประสาทเบื้องต้น.....	23
3.2 ทฤษฎีโครงข่ายประสาทเทียม.....	24
3.3 สถาปัตยกรรมของโครงข่ายประสาทเทียม.....	27
3.4 การฝึกสอนโครงข่ายประสาทเทียม.....	29
3.4.1 การเรียนรู้แบบมีผู้สอน.....	29
3.4.2 การเรียนรู้แบบไม่มีผู้สอน.....	29
3.5 กฎการเรียนรู้โครงข่ายประสาทเทียม.....	29
3.5.1 กฎการเรียนรู้แบบเฮบเบรน.....	31
3.5.2 กฎการเรียนรู้แบบเพอร์เซปตรอน.....	32
3.5.3 กฎการเรียนรู้แบบเคลค้ำ.....	33
3.5.4 กฎการเรียนรู้แบบมีการแข่งขัน.....	34
บทที่ 4 ทฤษฎีโครงข่ายประสาทเทียมแบบ ART.....	36
4.1 อะแดปทีฟรีโซแนนซ์เทียรี ART1.....	36
4.1.1 โครงสร้างของ ART1.....	36
4.1.2 ยูนิตเพิ่มเติมที่ใช้ในการตัดสินใจของ ART1.....	37
4.1.3 อัลกอริทึมที่ใช้ในการสอน ART1.....	38
4.2 อะแดปทีฟรีโซแนนซ์เทียรี ART2.....	44
4.2.1 โครงสร้างของ ART2.....	44
4.2.2 อัลกอริทึมที่ใช้ในการสอน ART2.....	46
บทที่ 5 ผลการทดลอง.....	55
5.1 ผลการทดลองกับภาพถ่ายดาวเทียม ADEOS.....	55
5.2 ผลการทดลองกับภาพถ่ายดาวเทียม LANDSAT-5.....	58

## สารบัญ(ต่อ)

	หน้า
บทที่ 6 บทสรุป.....	62
เอกสารอ้างอิง.....	64
ภาคผนวก.....	65
ภาคผนวก ก. ตารางแสดงรายละเอียดของดาวเทียม ADEOS JERS-1 และ MOS-1.....	66
ภาคผนวก ข ผลงานวิจัยที่ได้รับการตีพิมพ์.....	68
ประวัติผู้เขียน.....	73



# สารบัญตาราง

ตารางที่	หน้า
3.1 การปรับค่าตัวงน้ำหนักสำหรับกฎการสอนแบบต่างๆ.....	31
4.1 ค่าพารามิเตอร์ที่ใช้ใน ART1.....	42
4.2 ค่าพารามิเตอร์ที่ใช้ใน ART2.....	51



# สารบัญรูป


รูปที่	หน้า
2.1 คุณสมบัติของพลังงานแม่เหล็กไฟฟ้าตามทฤษฎีคลื่น.....	6
2.2 การจำแนกพลังงานแม่เหล็กไฟฟ้า.....	7
2.3 ลักษณะการจำแนกประเภทข้อมูลที่สำรวจจากระยะไกล.....	9
2.4 ตัวจำแนกประเภทแบบสี่เหลี่ยมคี่ขนาน.....	11
2.5 ตัวจำแนกประเภทแบบใช้ระยะห่างต่ำสุด.....	12
2.6 หลักการจำแนกประเภทแบบความน่าจะเป็นได้สูงสุด.....	12
2.7 การแข่งขันกันของตัวคลัสเตอร์ที่เป็นไปได้.....	14
2.8 การจำแนกภาพด้วยวิธีการทำซ้ำ.....	16
2.9 ศูนย์กลางการคลัสเตอร์.....	18
2.10 ค่าเฉลี่ยของอัลกอริทึมคลัสเตอร์ริงแบบเดี่ยว.....	18
2.11 ฮิสโตแกรมแบบสองมิติ.....	19
2.12 ค่าพีคในฮิสโตแกรมแบบสองมิติ.....	19
3.1 ลักษณะของเซลล์ประสาททางชีววิทยา.....	23
3.2 รูปแบบของเซลล์ประสาทเทียม.....	24
3.3 รูปแบบของเซลล์ประสาทเทียมแบบมี Hidden Units.....	25
3.4 ลักษณะของ Binary Step โดยใช้ค่า Threshold.....	26
3.5 ลักษณะของ Binary Sigmoid.....	27
3.6 ลักษณะของ Bipolar Sigmoid.....	27
3.7 ตัวอย่างของโครงข่ายแบบชั้นเดียว.....	28
3.8 ตัวอย่างของโครงข่ายแบบหลายชั้น.....	28
3.9 กฎการเรียนรู้ค่าน้ำหนัก.....	30
3.10 การฝึกสอนโครงข่ายของเฮบเบรน.....	32
3.11 กฎการเรียนรู้โครงข่ายของเพอร์เซปตรอน.....	33
3.12 กฎการเรียนรู้โครงข่ายของเดลต้า.....	34
3.13 กฎการเรียนรู้โครงข่ายแข่งขันแบบหาผู้ชนะ.....	35
4.1 โครงสร้างของ ART1.....	37

## สารบัญรูป(ต่อ)

รูปที่	หน้า
4.2 การทำงานของ Supplemental Unit.....	38
4.3 โพลชาร์ดแสดงการทำงานโปรแกรมของ ART1.....	39
4.4 โครงสร้างของ ART2.....	44
4.5 การเชื่อมต่อจากยูนิต W ไปยังยูนิต X ของ ART2.....	45
4.6 การขยายโครงสร้างในเลเยอร์ F1 ของ ART2.....	46
4.7 โพลชาร์ดแสดงการทำงานโปรแกรมของ ART2.....	48
5.1 ภาพถ่ายดาวเทียมบริเวณกรุงเทพฯที่ใช้ในการฝึกสอน.....	55
5.2 ผลการจำแนกภาพบริเวณกรุงเทพฯด้วย ART1.....	56
5.3 ผลการจำแนกภาพบริเวณกรุงเทพฯด้วย ART2.....	56
5.4 ผลการจำแนกภาพด้วย ART1 โดยการเพิ่มจำนวนคลัสเตอร์.....	57
5.5 ผลการจำแนกภาพด้วย ART2 โดยการเพิ่มจำนวนคลัสเตอร์.....	57
5.6 ภาพถ่ายดาวเทียมบริเวณจังหวัดชุมพร.....	58
5.7 ผลการจำแนกภาพบริเวณจังหวัดชุมพรด้วย ART1.....	59
5.8 ผลการจำแนกภาพบริเวณจังหวัดชุมพรด้วย ART1 โดยการเพิ่มจำนวนคลัสเตอร์.....	59
5.9 ผลการจำแนกภาพบริเวณจังหวัดชุมพรด้วย ART2.....	60
5.10 ผลการจำแนกภาพบริเวณจังหวัดชุมพรด้วย ART2 โดยการเพิ่มจำนวนคลัสเตอร์.....	60
5.11 ภาพจังหวัดชุมพรโดยการจำแนกจากผู้เชี่ยวชาญ.....	61

# อภิธานศัพท์

ART network	โครงข่ายประสาทเทียมที่พัฒนาโดยใช้ทฤษฎีอะแดปทีฟรีโซแนนซ์ โดย Carpenter และ Grossberg
Self-Organizing Map Network	โครงข่ายประสาทเทียมประเภทหนึ่งที่ใช้สอนให้โครงข่ายให้มีการเรียนรู้ด้วยตัวเอง ถูกพัฒนาโดย Teuvo Kohonen
Perceptron	โครงข่ายชั้นเดียว และสามารถแก้ปัญหาได้เป็นแบบเชิงเส้น
Classification	คือการจำแนกภาพออกเป็นกลุ่ม โดยแบ่งออกเป็นแบบมีผู้สอน และไม่มีผู้สอน
Clustering	คือการจำแนกภาพด้วยโครงข่ายของ ART แบบมีการแข่งขันเรียนรู้ด้วยตัวเอง
Segmentation	คือการจำแนกภาพวิธีหนึ่งด้วยการแบ่งกลุ่ม
Remote Sensing image data	การสำรวจข้อมูลภาพถ่ายระยะไกลจากดาวเทียม



# บทที่ 1

## บทนำ

เป็นเวลาหลายศตวรรษมาแล้วที่มนุษย์ได้ประดิษฐ์และพัฒนาเครื่องจักรขึ้นมาใช้งาน ซึ่งเราจะเห็นได้ว่าเครื่องจักรเหล่านี้จะถูกใช้สำหรับงานที่มีความยุ่งยากซับซ้อนและซ้ำๆ ถ้าหากใช้คนทำก็อาจจะทำให้เกิดความผิดพลาดได้ง่าย จนกระทั่งได้มีการพัฒนาเครื่องคอมพิวเตอร์ขึ้นมาและปัจจุบันคอมพิวเตอร์ได้เข้ามามีบทบาทมากขึ้นเรื่อยๆ ซึ่งงานส่วนใหญ่ที่ใช้คอมพิวเตอร์คือ งานจัดเก็บข้อมูล งานประมวลผลข้อมูล ดังนั้นนักวิทยาศาสตร์ได้เล็งเห็นถึงความสำคัญนี้ จึงได้พัฒนาคอมพิวเตอร์ให้มีความฉลาดยิ่งขึ้น โดยพยายามให้เครื่องคอมพิวเตอร์และ โปรแกรมที่ใช้ มีการเรียนรู้จดจำและสามารถตัดสินใจเองได้ ฉะนั้นทฤษฎีของระบบโครงข่ายประสาทเทียม (Neural Network System) หรือระบบจำลองนิเวศน์เน็ตเวิร์ค เป็นทฤษฎีหนึ่งที่น่าไปประยุกต์ใช้งานในการวิเคราะห์ข้อมูลและเพิ่มประสิทธิภาพให้กับคอมพิวเตอร์ ซึ่งในวิทยานิพนธ์เล่มนี้ได้นำเอาหลักการของนิเวศน์เน็ตเวิร์คแบบ ART (Adaptive Resonant Theory Neural Network) มาใช้ในการจำแนกข้อมูลภาพถ่ายดาวเทียม

### 1.1 ความเป็นมาของงานวิจัย

การจำแนกข้อมูลภาพถ่ายดาวเทียมในหน่วยงานของภาครัฐ พบว่าส่วนใหญ่ใช้วิธีจำแนกประเภทข้อมูลภาพถ่ายดาวเทียมด้วยสายตา ซึ่งเป็นวิธีที่ต้องอาศัยผู้เชี่ยวชาญด้านการแปลภาพทำการแยกแยะและเทียบสีของแต่ละประเภทข้อมูลจากภาพสีผสมของภาพถ่ายดาวเทียมจำนวน 3 แบนด์ การจำแนกข้อมูลภาพถ่ายดาวเทียมด้วยวิธีนี้จะกระทำได้ง่าย ถ้าข้อมูลแต่ละประเภทปรากฏสีและลักษณะที่แตกต่างกันอย่างเห็นได้ชัด แต่ในทางตรงกันข้ามถ้าข้อมูลแต่ละประเภทปรากฏสีและลักษณะที่ใกล้เคียงกันจะยากต่อการตัดสินใจควรเป็นข้อมูลประเภทใด ดังนั้นการจะใช้วิธีจำแนกภาพถ่ายดาวเทียมด้วยสายตาให้เกิดผลแม่นยำได้นั้น นอกจากจะต้องอาศัยคู่มือในการแปลที่ละเอียดถูกต้องแล้ว ผู้ที่ทำการแปลภาพควรมีความเชี่ยวชาญในพื้นที่ และต้องมีประสบการณ์ในการจำแนกข้อมูลด้วยสายตาพอสมควร

การนำโครงข่ายประสาทเทียมมาใช้ในการจำแนกข้อมูลภาพถ่ายดาวเทียม เป็นอีกทางเลือกหนึ่งที่น่าสนใจ เนื่องจากวิธีนี้อาศัยเพียงข้อมูลตัวอย่างของแต่ละประเภทเพียงจำนวนน้อย ซึ่งอาจได้มาจากการสำรวจภาคพื้นดิน หรือจากการเลือกโดยผู้เชี่ยวชาญในพื้นที่นั้นๆ เพื่อนำมาใช้ในขั้นตอนการฝึกสอนโครงข่าย หลังจากนั้นไม่ว่าจะเป็นในขั้นตอนของการฝึกสอน หรือในขั้นตอนของการแยกประเภทข้อมูลภาพถ่าย โครงข่ายจะทำการตัดสินใจเองโดยไม่ต้องอาศัยผู้เชี่ยวชาญแต่อย่างใด แต่จากการศึกษาในรายวิจัยที่ผ่านมาพบว่า การจำแนกข้อมูลภาพถ่ายดาวเทียมด้วยวิธีนี้ยังมีข้อเสียที่พบ

ในขั้นตอนของการฝึกสอนโครงข่าย กล่าวคือ การกำหนดรูปแบบของข้อมูลเอาต์พุตที่ต้องการ (Target Output) จะถูกจำกัดอยู่ที่การ “ใช่” หรือ “ไม่ใช่” ข้อมูลแต่ละประเภทเท่านั้น ซึ่งไม่เอื้ออำนวยต่อข้อมูลที่มีความคลุมเครือสูง ในขณะที่ระบบโครงข่ายประสาทเทียมแบบ ART ซึ่งเป็นวิธีที่ง่ายและการฝึกโครงข่ายใช้เวลาไม่มากนัก โดยหลักการของโครงข่ายจะทำการเรียนรู้โดยไม่มีผู้สอน (หรือไม่มีกำหนดรูปแบบของข้อมูลเอาต์พุตไว้ก่อน) Unsupervised Learning โดยในขณะที่ทำการฝึกตัวโครงข่ายจะทำการปรับตัวเอง สร้างค่าน้ำหนักเพื่อประเมินค่าอินพุตที่ป้อนเข้ามานั้นควรจะอยู่ในกลุ่มใดและนำความรู้จากค่าน้ำหนักที่เกิดจากการฝึกมาใช้ในการแยกแยะค่าอินพุตในการใช้งานครั้งต่อไป

## 1.2 วัตถุประสงค์ของงานวิจัย

1. เพื่อศึกษาแนวทางการนำโครงข่ายประสาทเทียมมาใช้ในการวิเคราะห์จำแนกภาพถ่ายจากดาวเทียม
2. เพื่อศึกษาคุณสมบัติและขั้นตอนการทำงานของ ART และนำมาประยุกต์
3. เพื่อศึกษาหาแนวทางการพัฒนาปรับปรุงอัลกอริทึมให้ได้มีประสิทธิภาพมากที่สุด
4. เพื่อศึกษาประสิทธิภาพในการแยกแยะกลุ่มของข้อมูลภาพ
5. เพื่อศึกษาปัญหาที่เกิดขึ้นจากการนำเอาทฤษฎีของนิวรัลเน็ตเวิร์คแบบ ART มาใช้งาน

## 1.3 ขอบเขตของงานวิจัย

ในเบื้องต้นเป็นการศึกษาเกี่ยวกับความรู้พื้นฐานของการสำรวจระยะไกล (Remote Sensing) ความเป็นมา คุณสมบัติต่างๆของภาพถ่ายดาวเทียม โดยได้ใช้ภาพ จากดาวเทียม ADEOS ของญี่ปุ่น มาใช้เป็นตัวแทนในการจำแนกภาพ

การศึกษาเกี่ยวกับทฤษฎีของโครงข่ายประสาทเทียมว่ามีลักษณะเป็นแบบใดบ้าง และแสดงถึงคุณสมบัติของโครงข่ายประสาทเทียมที่นิยมใช้รวมถึงข้อดีข้อเสีย จากนั้นทำการศึกษาโครงข่ายประสาทเทียมแบบ ART ซึ่งมีคุณสมบัติเป็นตัวคลัสเตอร์ (Cluster) แบบไม่มีผู้สอน (Unsupervised Learning) โดยจะประกอบไปด้วย ART1 และ ART2 ซึ่งต้องการใช้ค่าอินพุตที่แตกต่างกัน คือ ไบนารีอินพุต และ ค่าอินพุตที่ต่อเนื่อง ตามลำดับ และหลักการจำแนกข้อมูลภาพ

ในการทดลอง ผู้ทดลองได้ทำการเขียนอัลกอริทึม เพื่อทำการจำลองการทำงานของ นิวรัลเน็ตเวิร์คแบบ ART (ทั้ง ART1 และ ART2) จากนั้นนำไปทำการทดสอบในการแยกแยะประเภทของข้อมูลภาพถ่ายดาวเทียม ที่ได้มาจากดาวเทียม ADEOS ซึ่งใช้เวลาในการฝึกสอนโครงข่ายไม่นานมากนัก ขึ้นอยู่กับขนาดของข้อมูลที่นำมาทดลอง โดยค่าน้ำหนักที่ได้จะถูกใช้ทำหน้าที่ในการประเมินค่าอินพุตที่เข้ามาควรจะจัดไว้ในกลุ่มใด และค่าน้ำหนักที่ได้จากการฝึกจะนำไปใช้กับค่าอินพุตใน

ครั้งต่อไป และทำการเปลี่ยนโครงสร้างในส่วนของค่าปรับค่า เทรสโฮลด์ (Threshold) เพื่อเพิ่มประสิทธิภาพในการจดจำ และลดเวลาในการฝึกสอนโครงข่าย

#### 1.4 ทฤษฎีแนวความคิดที่ใช้ในการวิจัย

ทฤษฎีที่ใช้ประกอบการวิจัยนี้คือ การจำแนกภาพของภาพถ่ายดาวเทียม ด้วยวิธีนิวรัลเน็ตเวิร์คแบบ ART วิธีการฝึกสอนให้โครงข่ายทำการเรียนรู้ รวมทั้งผลที่ได้ของชุดค่าน้ำหนัก (Bottom-up และ Top-down) ที่คงที่ และจัดกลุ่มภาพ ตามภาพที่นำมาทดสอบ ด้วยการใช้อัลกอริทึมเพื่อจำแนกภาพ และการใช้ค่าตัวแปรต่างๆ เพื่อทำการปรับเปลี่ยนค่าเพื่อให้ได้ผลที่ใกล้เคียงมากที่สุด

#### 1.5 โครงสร้างของวิทยานิพนธ์

งานวิจัยในวิทยานิพนธ์นี้ได้เน้นวิจัยเฉพาะ ส่วนของการจำแนกข้อมูลจากภาพ โดยได้นำเอาโครงข่ายประสาทเทียมแบบ ART (Adaptive Resonance Theory) มาประยุกต์ใช้งานจดจำ การจำแนกลักษณะประเภทของข้อมูลภาพ ซึ่ง โครงสร้างวิทยานิพนธ์แบ่งออกเป็น 6 ส่วนคือ

บทที่ 1 บทนำ กล่าวถึงความเป็นมาของวิทยานิพนธ์ วัตถุประสงค์ ขอบเขตในการวิจัย และโครงสร้างของวิทยานิพนธ์

บทที่ 2 พื้นฐานการสำรวจข้อมูลระยะไกล กล่าวถึงความเป็นมา คุณสมบัติ ประโยชน์ที่นำไปใช้ คุณสมบัติภาพถ่ายดาวเทียมที่ได้ และวิธีการจำแนกภาพเบื้องต้น

บทที่ 3 โครงข่ายประสาทเทียม กล่าวถึงโครงสร้างและการทำงาน แบบจำลองนิวรัลเน็ตเวิร์ค ฟังก์ชันที่ใช้ในการกระตุ้นเซลล์ วิธีการที่ใช้ในการฝึกสอนโครงข่าย ผลกระทบในการฝึกสอน

บทที่ 4 อะแดปทีฟรีโซแนนเทียรี (ART) กล่าวถึงโครงสร้างการทำงานของ ART1 และ ART2 วิธีที่ใช้ในการฝึกสอน หลักการจำแนกประเภทข้อมูลภาพวิธีต่างๆ และอัลกอริทึมที่ใช้

บทที่ 5 การทดลองและผลการทดลอง กล่าวถึงการทดลอง และการทดสอบการจำแนกข้อมูลภาพด้วยนิวรัลเน็ตเวิร์คแบบ ART ทั้งสองแบบ และเปรียบเทียบกับผลที่ได้

บทที่ 6 บทสรุป กล่าวถึงสรุปผลการทดลองการจำแนกข้อมูลภาพถ่ายดาวเทียมด้วยวิธีของนิวรัลเน็ตเวิร์คแบบ ART

## บทที่ 2

# พื้นฐานของการสำรวจข้อมูลระยะไกล

รีโมทเซนซิง (Remote Sensing) [1, 2] หรือระบบตรวจรู้ระยะไกลจัดเป็นวิธีการอันหนึ่งในการศึกษาหรือวิเคราะห์ข้อมูลเกี่ยวกับวัตถุ พื้นทีหรือปรากฏการณ์ต่างๆ บนพื้นผิวโลก โดยที่อุปกรณ์ ตรวจรู้ระยะไกลนั้นมิได้สัมผัสกับ วัตถุ พื้นทีหรือปรากฏการณ์นั้นๆ เลย ซึ่งจะสามารถแยกการศึกษาออกได้เป็นสองทางกว้างๆ คือ

1. การศึกษาเกี่ยวกับระบบการรับและการเก็บข้อมูล (Data Acquisition) เช่น ระบบอุปกรณ์บันทึกข้อมูลซึ่งผลิตเป็นข้อมูลภาพหรือข้อมูลตัวเลข ลักษณะการแผ่พลังงานจากการสะท้อนคลื่นแสงสีของวัตถุต่างๆ บนพื้นผิวโลกและชั้นบรรยากาศ เป็นต้น
2. ระบบการวิเคราะห์ข้อมูล (Data Analysis) เช่น การวิเคราะห์ข้อมูลภาพและทำการตีความหมายภาพด้วยคอมพิวเตอร์ กรรมวิธีการเน้นภาพด้วยคอมพิวเตอร์ เป็นต้น

ในปัจจุบันได้มีการใช้ประโยชน์จากข้อมูลภาพถ่ายดาวเทียมกันอย่างแพร่หลาย อาทิ การสำรวจแหล่งทรัพยากรธรรมชาติ การพัฒนาที่ดิน เป็นต้น โดยการนำข้อมูลภาพถ่ายดาวเทียมมาใช้ร่วมกับข้อมูลอื่นๆ เช่น แผนที่ภูมิประเทศ, แผนที่การใช้ที่ดิน, แผนที่ธรณีวิทยา, ปริมาณน้ำฝน, ข้อมูลการสำรวจภาคพื้นดิน เป็นต้น ซึ่งการพัฒนาภาพถ่ายดาวเทียมในลักษณะต่างๆ ดังกล่าวมาแล้วนั้นมักจะทำงานบนคอมพิวเตอร์แบบเวิร์กสแตชัน หรือมินิคอมพิวเตอร์ที่มีราคาค่อนข้างสูง อีกทั้งการพัฒนาโปรแกรมใช้งานค่อนข้างยุ่งยาก เป็นผลให้เกิดการจำกัดการใช้งานข้อมูลภาพถ่ายดาวเทียมในลักษณะการวิเคราะห์ข้อมูลภาพให้อยู่ในกลุ่มของหน่วยงานใหญ่ๆ ที่มีอุปกรณ์พร้อมเท่านั้น แต่ในความเป็นจริงยังมีหน่วยงานอื่นอีกมากมาย ที่จำเป็นต้องใช้ประโยชน์ในการวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมเพื่อจะสามารถปฏิบัติงานได้อย่างมีประสิทธิภาพสูงสุด อาทิเช่น หน่วยงานป่าไม้ในระดับท้องถิ่น การทางพิเศษแห่งประเทศไทย สำนักผังเมือง เป็นต้น ซึ่งหน่วยงานเหล่านี้มักจะมีเครื่องมือโครคอมพิวเตอร์กันอยู่แล้ว ดังนั้นถ้าการพัฒนาโปรแกรม หรือขบวนการพิเศษในการนำข้อมูลภาพถ่ายดาวเทียม ขึ้นแสดงผลบนมอนิเตอร์ของเครื่องมือโครคอมพิวเตอร์มีประสิทธิภาพและสามารถใช้งานจริงได้ง่าย ก็จะทำให้หน่วยงานระดับเล็กสามารถปฏิบัติงานได้อย่างมีประสิทธิภาพตามความต้องการของแต่ละหน่วยงาน การที่ภาพถ่ายจากระยะไกล หรือภาพถ่ายดาวเทียมได้รับความนิยมในการนำมาใช้เป็นข้อมูลในการจัดการทรัพยากร และสิ่งแวดล้อมนั้นๆ อาจเป็นเพราะคุณสมบัติของภาพถ่ายดาวเทียมในหลายด้านที่เอื้ออำนวยและมีความเหมาะสมได้ดังนี้

1. บันทึกข้อมูลเป็นบริเวณกว้าง (Synoptic View) ภาพจากดาวเทียมภาพหนึ่งๆ ครอบคลุมพื้นที่กว้าง ทำให้ได้ข้อมูลในลักษณะต่อเนื่องในระยะเวลาบันทึกภาพสั้นๆ สามารถศึกษาสภาพแวดล้อมต่างๆ ในบริเวณกว้างขวางต่อเนื่องในเวลาเดียวกันทั้งภาพ เช่น ภาพจาก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

LANDSATMSS และ TM หนึ่งภาพ กลุ่มพื้นที่ 185 X 185 กม. หรือ 34,225 ตร.กม. ภาพจาก SPOT กลุ่มพื้นที่ 3,600 ตร.กม. เป็นต้น

2. บันทึกภาพได้หลายช่วงคลื่น ดาวเทียมสำรวจทรัพยากรมีระบบกล้องสแกนเนอร์ ที่บันทึกภาพได้หลายช่วงคลื่นในบริเวณเดียวกัน ทั้งในช่วงคลื่นที่เห็นได้ด้วยตาเปล่า และช่วงคลื่นที่สายตามนุษย์มองไม่เห็น ทำให้มีประสิทธิภาพในการแยกวัตถุต่างๆ บนผิวโลกได้อย่างชัดเจน ตัวอย่างเช่น ระบบ TM ของดาวเทียม LANDSAT มี 7 ช่วงคลื่น และ OPS ของดาวเทียม JERS-1 มี 4 ช่วงคลื่น เป็นต้น

3. บันทึกภาพบริเวณเดิม (Repetitive Coverage) ดาวเทียมสำรวจมีวงโคจรจากเหนือลงใต้ และกลับมาขั้วจุดเดิมในเวลาท้องถิ่นอย่างสม่ำเสมอและในช่วงเวลาที่แน่นอน ตัวอย่างเช่นดาวเทียม LANDSAT โคจรกลับมาที่เดิมทุกๆ 16 วัน ส่วนดาวเทียม MOS โคจรกลับมาที่เดิมทุกๆ 17 วัน และดาวเทียม ADEOS โคจรกลับมาที่เดิมทุกๆ 41 วัน เป็นต้น ข้อมูลที่ได้จากการบันทึกในหลายๆ ช่วงเวลาเหล่านี้ ช่วยให้สามารถเปรียบเทียบ และติดตามการเปลี่ยนแปลงต่างๆ บนพื้นโลกได้เป็นอย่างดี

4. ภาพจากดาวเทียมให้รายละเอียดในหลายระดับ มีผลดีในการเลือกนำไปใช้ประโยชน์ในการศึกษาด้านต่างๆ ตามวัตถุประสงค์ เช่น ภาพจากดาวเทียม SPOT ระบบ PLA มีรายละเอียด 10 ม. สามารถศึกษาตัวเมือง เส้นทางคมนาคมระดับหมู่บ้าน ภาพระบบ MLA มีรายละเอียด 20 ม. ศึกษาการบุกรุกพื้นที่ป่าไม้เฉพาะจุดเล็กๆ และแหล่งน้ำขนาดเล็ก และภาพระบบ TM รายละเอียด 30 ม. ศึกษาสภาพการใช้ที่ดินระดับจังหวัด เป็นต้น

5. ภาพจากดาวเทียมสามารถให้สีผสม (False Color Composite) ได้หลายแบบ ขึ้นอยู่กับวัตถุประสงค์ที่ต้องการขยายรายละเอียดเฉพาะเรื่องให้เด่นชัด โดยสามารถผสมสีให้แตกต่างจากสิ่งแวดล้อมได้


6. การเน้นหรือปรับปรุงคุณภาพของภาพ (Image Enhancement) ภาพจากดาวเทียมต้นฉบับสามารถนำมาปรับปรุงคุณภาพให้มีรายละเอียดเพิ่มขึ้น โดยการปรับเปลี่ยนค่าความเข้ม ระดับสีเทา เพื่อเน้นข้อมูลที่ต้องการศึกษาให้มีความเด่นชัดขึ้น

## 2.1 พลังงานแม่เหล็กไฟฟ้า

พลังงานแม่เหล็กไฟฟ้า เป็นพลังงานรูปแบบหนึ่ง ในหลายๆ รูปแบบของพลังงาน เช่น พลังงานไฟฟ้า พลังงานเคมี และพลังงานกล พลังงานแม่เหล็กไฟฟ้าสามารถเคลื่อนที่จากแหล่งกำเนิดไปยังเป้าหมายต่างๆ ได้โดยการแผ่รังสีการอธิบายปรากฏการณ์ที่ค่อนข้างจะซับซ้อนสามารถกระทำได้โดยอาศัยทฤษฎี 2 ทฤษฎี คือ ทฤษฎีคลื่นและทฤษฎีอนุภาค

### 2.1.1 ทฤษฎีคลื่น

พลังงานแม่เหล็กไฟฟ้า ประกอบไปด้วยสนามแม่เหล็ก และสนามไฟฟ้า ทิศทางของสนามแม่เหล็ก ทิศทางของสนามไฟฟ้า และทิศทางการเคลื่อนที่ของคลื่นพลังงานแม่เหล็กไฟฟ้าที่ตั้งฉากซึ่งกันและกัน ดังรูปที่ 2.3



รูปที่ 2.1 คุณสมบัติของพลังงานแม่เหล็กไฟฟ้าตามทฤษฎีคลื่น


การเคลื่อนที่ของพลังงานแม่เหล็กไฟฟ้าเป็นไปในลักษณะของคลื่น จึงสามารถที่จะกำหนดความแตกต่างของพลังงานได้ สืบเนื่องจากความยาวคลื่น ( $\lambda$ ) คือ ระยะจากยอดคลื่นหนึ่งถึงอีกยอดคลื่นหนึ่ง และความถี่ ( $f$ ) ซึ่งก็คือจำนวนยอดคลื่นที่เคลื่อนที่ผ่านจุดๆ หนึ่งต่อหนึ่งหน่วยเวลา โดยมีความสัมพันธ์ระหว่างความยาวคลื่น ความถี่ และความเร็วแสง ( $C$ ) ดังสมการที่ 2.1

$$c = \lambda \cdot f \quad (2.1)$$

โดยที่  $C$  ค่าคงที่ของความเร็วคลื่นแม่เหล็กไฟฟ้า  $3 \times 10^8$  เมตร/วินาที ในสุญญากาศย่านความยาวคลื่นของพลังงานแม่เหล็กไฟฟ้าจะมีชื่อเรียกต่างๆ กัน ตั้งแต่ รังสีแกมมา (Gamma) รังสีเอ็กซ์ (X-Ray) รังสีอัลตราไวโอเล็ต (UV — Ultraviolet) แสงที่ตามองเห็น (Vision light) รังสีอินฟราเรด (IR — Infrared) จนถึงคลื่นวิทยุ (Radio wave) โดยเรียงลำดับจากความยาวคลื่นสั้นไปจนถึงความยาวคลื่นยาวตามลำดับ ดังรูปที่ 2.2 แสดงชื่อ และย่านความถี่ต่างๆ ของพลังงานแม่เหล็กไฟฟ้า มีสิ่งที่น่าสนใจคือ การแยกประเภทของรังสีอินฟราเรด และคลื่นวิทยุอาจจะแตกต่างกันไป ขึ้นกับสาขาวิชาการนั้นๆ ตามที่แสดงในตารางเป็นตัวอย่างที่ใช้นี้

คลื่นความถี่ย่านพลังงานแม่เหล็กไฟฟ้าที่ใช้ในการสำรวจจากระยะไกล ได้แก่ คลื่นใกล้อัลตราไวโอเล็ต (ความยาวคลื่น 0.3 ~ 0.4 ไมโครเมตร) คลื่นที่ตามองเห็น (ความยาวคลื่น 0.4 ~ 0.7 ไมโครเมตร) ประกอบไปด้วยแถบสีม่วง คราม น้ำเงิน เขียว เหลือง แสด และแดง คลื่นใกล้อินฟราเรด (Near infrared) คลื่นสั้นอินฟราเรด (Short wave infrared) อินฟราเรดความร้อน (Thermal infrared) (ความยาวคลื่น 0.7 ~ 14 ไมโครเมตร) และช่วงคลื่นไมโครเวฟ (Microwave) (ความยาวคลื่น 1 มิลลิเมตร ~ 1 เมตร) ซึ่งย่านแสงในช่วงอินฟราเรดใกล้ และอินฟราเรดคลื่นสั้น

นั้น ในบางครั้งจะเรียกว่าอินฟราเรดช่วงสะท้อน (ความยาวคลื่น 0.7 ~3 ไมโครเมตร) เพราะเป็นย่านที่ได้รับอิทธิพลจากการสะท้อนของพลังงานแสงอาทิตย์มากกว่าที่จะเกิดจากการแผ่รังสีจากพื้นโลก ในย่านอินฟราเรดความร้อน พลังงานส่วนใหญ่จะได้อมาจากการแผ่รังสีของพื้นผิว โดยที่ได้รับอิทธิพลจากการสะท้อนของพลังงานแสงอาทิตย์น้อยมาก ในขณะที่ดวงอาทิตย์เป็นแหล่งพลังงานที่มีการแผ่พลังงานไฟฟ้าสูงสุดนั้นคือความยาวคลื่น 0.5 ไมโครเมตร ซึ่งจะเป็นแหล่งพลังงานสำหรับการสำรวจระยะไกลย่านความถี่ที่ตามองเห็น และย่านอินฟราเรดสะท้อน โดยข้อมูลที่ได้จากการสำรวจระยะไกลในย่านแสงที่ตามองเห็น และอินฟราเรดสะท้อน ส่วนใหญ่จะขึ้นอยู่กับค่าการสะท้อน (Reflectance) ของวัตถุต่างๆ บนผิวโลกโดยที่แหล่งกำเนิดพลังงานที่ใช้ในการสำรวจจากระยะไกลย่านอินฟราเรดจะได้จากตัววัตถุเอง เนื่องจากวัตถุใดๆ ก็ตามที่มีอุณหภูมิในระดับปกติ จะมีความสามารถในการแผ่รังสีแม่เหล็กไฟฟ้าสูงสุดที่ความยาวคลื่นประมาณ 10 ไมโครเมตร การสำรวจระยะไกลย่านไมโครเวฟ สามารถแยกได้เป็น 2 ประเภท คือ การสำรวจระยะไกลย่านไมโครเวฟแบบพาสซีฟ (Passive) และการสำรวจระยะไกลย่านไมโครเวฟแบบแอคทีฟ (Active) ในการสำรวจระยะไกล ย่านไมโครเวฟแบบพาสซีฟ จะสามารถวัดค่าการแผ่รังสี ไมโครเวฟ (Microwave radiation) ได้จากวัตถุ ในขณะที่การสำรวจระยะไกลย่านไมโครเวฟแบบแอคทีฟ จะสามารถวัดค่าสัมประสิทธิ์การกระจายกลับ (Back scattering coefficient) ได้



รูปที่ 2.2 การจำแนกพลังงานแม่เหล็กไฟฟ้า

### 2.1.2 ทฤษฎีอนุภาค

คือพฤติกรรมของคลื่นแสงที่แผ่ออกจากแหล่งกำเนิด ซึ่งประกอบไปด้วยอนุภาคย่อยที่เรียกว่า ควอนตัมหรือโฟตอนอนุภาคย่อยเหล่านี้มีคุณสมบัติเหมือนอนุภาคอื่นๆ ที่ประกอบไปด้วยพลังงานและโมเมนตัม แต่แตกต่างกันที่โฟตอนมีมวลเป็นศูนย์เมื่อหยุดนิ่ง ฉะนั้นความสัมพันธ์ระหว่างพลังงานของโฟตอนของคลื่นแม่เหล็กไฟฟ้ากับความถี่เป็นดังสมการที่ 2.2 และจากสมการที่ 2.1 คูณด้วย  $\frac{h}{h}$  จะได้ดังสมการที่ 2.3 นั่นคือพลังงานโปรตอนเป็นส่วนผกผันกับความยาวคลื่นหมายความว่า ยิ่งคลื่นแสงมีความยาวคลื่นมากพลังงานโฟตอนก็จะมีค่าน้อย และในทางกลับกัน ถ้าคลื่นแสงมีความถี่สูง ค่าระดับพลังงานก็จะสูงตามด้วย สิ่งเหล่านี้เป็นความสัมพันธ์ของพฤติกรรมของพลังงานแม่เหล็กไฟฟ้า

$$E = h \cdot f \quad (2.2)$$

กำหนดให้

$E$  คือพลังงานของโฟตอน

$h$  คือค่าคงที่ Planck

$f$  คือค่าความถี่ของคลื่น


$$E = \frac{hc}{\lambda} \quad (2.3)$$

## 2.2 วิธีการจำแนกประเภทของภาพ [3]

ในหลักการจำแนกประเภทของข้อมูลเกี่ยวกับภาพ มัลติสเปกตรัม (Multispectral) ผลลัพธ์ที่สำเร็จลงได้ก็คือการรักษาความถูกต้องที่สามารถยอมรับได้ ซึ่งเป็นความต้องการในสิ่งแรกในการเลือกที่จะใช้เครื่องมือมาทำการวิเคราะห์และนำมาประยุกต์ใช้งาน ดังต่อไปนี้ขั้นตอนในการวิเคราะห์ที่ดีที่สุดของการจำแนกกลุ่มของข้อมูลแบบมีผู้สอน (Supervised Classification) และไม่มีผู้สอน (Unsupervised Classification) ได้ถูกนำมาทดสอบจากการทำงานที่เหมาะสมกับจุดอ่อนและจุดแข็งในการจำแนก

การจำแนกข้อมูลด้วยดาวเทียม หรือการจำแนกประเภท (Classification) ของข้อมูลที่สำรวจจากระยะไกล หมายถึง การจัดระดับจุดภาพ (Pixel) ที่มีคุณลักษณะคล้ายกันออกเป็นกลุ่มๆ โดยมีวัตถุประสงค์เพื่อแยกวัตถุประเภทต่างๆ ที่ปรากฏอยู่บนภาพออกจากกัน แสดงดังรูปที่ 2.3 ซึ่งระดับเหล่านี้เรียกว่าชนิดหรือประเภทของข้อมูล การจำแนกประเภททำโดยอาศัยคุณลักษณะเชิงคลื่นที่ชัดเจนของรูปลักษณะต่างๆ หรืออาจกล่าวได้ว่าการจำแนกประเภท คือการแบ่งปริภูมิสถานะของรูปลักษณะออกเป็นประเภทต่างๆ โดยอาศัยกฎการตัดสินใจ หรือเทคนิควิธีการของการจำแนกประเภทซึ่งมีอยู่ด้วยกัน 2 วิธีดังนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.3 ลักษณะการจำแนกประเภทข้อมูลที่สำคัญจากระยะไกล

### 2.2.1 การจำแนกภาพแบบมีผู้สอน (Supervised Classification)

เทคนิคในการจำแนกกลุ่มแบบมีผู้สอน ก็คือวิธีที่เราสามารถที่จะเตรียมข้อมูลเพื่อที่จะให้รู้ ว่าพิกเซลที่อยู่ในแต่ละกลุ่ม ซึ่งจะมีสัญลักษณ์ที่สามารถนำมาปรับปรุงของกลุ่มเหล่านั้นได้ พิกเซล ต้นแบบเหล่านี้จะถูกนำมาอ้างอิงตามข้อมูลที่ใช้ในการฝึกสอนและการรวบรวมพิกเซลเหล่านั้นจะ ทำให้เห็นกลุ่มที่อยู่ในรูปภาพและสัญลักษณ์ของกลุ่มที่มีการกระจายออกไป ซึ่งเราจะเรียกมันว่า ส่วนการฝึกสอน และขั้นตอนในการกำหนดสัญลักษณ์ของกลุ่มส่วนมากเราจะเรียกว่าการทำกรฝึก สอน (Training)

สัญลักษณ์ที่อยู่ในรูปภาพเกิดขึ้นมาจากข้อมูลที่ใช้ในการฝึกสอน จะแตกต่างกันขึ้นอยู่กับ ลักษณะของแต่ละประเภทที่ใช้ สำหรับสัญลักษณ์ของกลุ่ม Parallelepiped Classification จะมีค่าสูง หรือต่ำขึ้นอยู่กับค่าในสเปกตรัมแต่ละแบนด์ สำหรับกลุ่มที่ถูกจำแนกที่เป็นไปได้มากที่สุดจะถูก ประกอบขึ้นมาด้วยสัญลักษณ์เดียวกัน โดยมีการทำสัญลักษณ์ของข้อมูลในการฝึกสอนไว้ล่วงหน้า จากนั้นสัญลักษณ์ต่างๆ จะถูกประเมินผล เทคนิคอัลกอริทึมในการที่จะจดจำลักษณะของสเปกตรัม ในแต่ละประเภทจะถูกวิเคราะห์ในความสัมพันธ์ ด้วยเหตุนี้การนำคุณสมบัติของความสัมพันธ์ แบบมีผู้สอน โดยใช้ อัลกอริทึมในการเรียนรู้เกี่ยวกับข้อมูลนั้นจะเป็นไปได้ที่มันสามารถทำงานได้

#### 2.2.1.1 การกำหนดข้อมูลที่ใช้ในการฝึกสอน (Determination of Training Data)

ในขั้นตอนนี้ เราจะทำการวิเคราะห์ถึงการฝึกสอนพิกเซลแบบการจำแนกกลุ่ม โดยมีผู้ สอน ในการทำการฝึกสอน จะต้องเลือกผู้ฝึกสอนอย่างเหมาะสม โดยจะต้องมีความสัมพันธ์กับ พิกเซลที่ใช้ ในบางระบบการประมวลผลภาพได้มีการจัดเตรียมข้อมูลซึ่งทำการเปรียบเทียบกับข้อมูลที่ใช้ในการฝึกสอนพิกเซล มันเป็นสิ่งจำเป็นในการฝึกสอนข้อมูลอย่างน้อยก็เพื่อใช้ในการแยก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

แยะประเภทของข้อมูลที่สนใจ และโดยเฉพาะอย่างยิ่งกลุ่มของข้อมูลที่ปรากฏขึ้นมาในภาพที่ทำการวิเคราะห์ ทั้งกรณีนี้ และถ้าข้อมูลที่ใช้ในการฝึกสอนยังไม่หมดหรือยังมีเหลืออยู่ ซึ่งมันขึ้นอยู่กับข้อจำกัดที่ใช้ในการจำแนกกลุ่มที่มีค่าสูงหรือต่ำกว่าค่าที่กำหนดไว้ ซึ่งจะแน่ใจได้ว่าลักษณะพิกเซลที่ผิดพลาดจะไม่ถูกเลือก ข้อจำกัดของกลุ่มที่มีค่าไม่สามารถแยกแยะได้จะถูกกำหนดโดยการยอมให้พิกเซลเหล่านั้นไม่ถูกรวมเข้าไปอยู่ในกลุ่ม สำหรับการแยกแยะประเภทของกลุ่มที่เป็นไปได้มากที่สุดซึ่งข้อจำกัดจะถูกใช้โดยฟังก์ชันเป็นผู้เลือก สิ่งเหล่านี้จะชี้ให้เห็นว่าชุดที่ใช้ในการฝึกสอนได้ผลดีหรือไม่ ซึ่งมันสามารถที่จะกลั่นกรองและทำการแบ่งกลุ่มใหม่ได้ ข้อมูลที่ใช้ในการฝึกสอนจะถูกทำซ้ำๆ ให้อัดขึ้น และทำการจัดประเภทกลุ่มขึ้นมาใหม่ซึ่งในวิธีการนี้สามารถที่จะทำให้สำเร็จลงได้ด้วยการใช้การประมวลผลภาพและภาพที่ได้นำมาทดลอง

### 2.2.1.2 ขั้นตอนในการทำงานแบบมีผู้สอน (Steps In Supervised Classification)

Supervised Classification ส่วนมากแล้วจะถูกนำไปใช้สำหรับการวิเคราะห์เชิงวัตถุ (Quantitative Analysis) ของภาพถ่ายดาวเทียม นอกนั้นขึ้นอยู่กับการใช้อัลกอริทึมที่เหมาะสมเพื่อทำการกำหนดพิกเซลในภาพถ่ายดาวเทียมที่ใช้วิเคราะห์ มีอัลกอริทึมอยู่มากมายที่สามารถทำได้ ขอบเขตเบื้องต้นเหล่านี้ ขึ้นอยู่กับความสามารถที่เป็นไปได้ในการกระจายตัวของรูปแบบที่สนใจ ซึ่งมีมิติสเปกตรัม จะถูกแบ่งภายในกลุ่มข้อมูลที่กำหนดอย่างเหมาะสม ไม่คำนึงถึงวิธีการที่เฉพาะเจาะจงที่จะใช้ แต่สิ่งที่จำเป็นที่จะต้องปฏิบัติตามขั้นตอนดังนี้

1. ตัดสินใจที่จะกำหนดประเภท หรือกลุ่มภายในซึ่งภาพจะถูกจัดให้เป็นกลุ่มใหม่โดยประเภทของข้อมูลเหล่านี้สามารถยกตัวอย่างได้ เช่น น้ำ, ที่อยู่อาศัย, พื้นที่เพาะปลูก และกลุ่มของพื้นที่ ฯลฯ
2. เลือกพิกเซลต้นแบบในแต่ละชุดของประเภทที่ต้องการ พิกเซลทั้งหลายเหล่านี้จะรวมตัวกันเพื่อใช้เป็นข้อมูลของการฝึกสอน ชุดของข้อมูลในแต่ละประเภทสามารถจะถูกสร้างขึ้นได้โดยการใช้แผนที่, ภาพถ่ายทางอากาศ, คูสถานที่จริง หรือการแปลความหมายของภาพด้วยการใช้สีตรงกันข้ามผลิตรูปแบบจากข้อมูลภาพ
3. ใช้ข้อมูลทำการฝึกสอนแล้วในการประมาณค่าตัวแปรต่างๆ ของอัลกอริทึมที่ใช้ พารามิเตอร์เหล่านี้จะเป็นคุณลักษณะเฉพาะของรูปแบบที่ใช้ หรือเป็นสมการซึ่งถูกกำหนดให้มีการแบ่งในมิติสเปกตรัม
4. การใช้วิธีการฝึกสอนด้วยการระบุลงไปในภาพ หรือการจำแนกภาพทุกๆ พิกเซลภายในหนึ่งประเภทของข้อมูล จากนั้นภาพจะถูกจำแนกทั้งหมดอย่างต่อเนื่อง ตามที่การฝึกสอนในข้อ 2 อาจจะมีความต้องการของผู้ใช้ที่จะกำหนดพิกเซลของรูปภาพแค่ 1 เพอร์เซ็นต์ โดยหมายถึงว่าคอมพิวเตอร์จะทำการระบุข้อมูลที่เหลือด้วยการจำแนกแยกแยะภาพ


การจำแนกข้อมูลวิธีนี้จะต้องรู้ลักษณะเชิงคลื่น หรือรูปลักษณะของประชากรของแต่ละประเภท โดยผู้เชี่ยวชาญจะทำการสุ่มข้อมูลเทรนนิ่ง (Training Data) จากบริเวณที่สามารถกำหนดประเภทต่างๆ ได้อย่างชัดเจนมาทำการประมาณค่าสถิติประชากรของแต่ละกลุ่มโดยอาศัยเทคนิควิธีการจำแนกเชิงคณิตศาสตร์ ซึ่งมีอยู่ด้วยกันหลายวิธี แล้วนำมาใช้เป็นเกณฑ์ในการจำแนกข้อมูลชุดภาพที่เหลือต่อไป เทคนิคการจำแนกประเภทของวิธีแบบมีผู้สอน (Supervised Classification) ที่นิยมใช้โดยทั่วไปมีอยู่ด้วยกันหลายวิธี อาทิเช่น

### 1. ตัวจำแนกประเภทแบบสี่เหลี่ยมคู่ขนาน (Parallelepiped Classifier)


วิธีนี้จะเป็นการตัดแบ่งแต่ละแกนของปริภูมิรูปลักษณะหลายช่วงคลื่น ซึ่งเขตแดนการตัดสินใจของแต่ละกลุ่มถูกกำหนดโดยค่าสูงสุดและต่ำสุดในแต่ละแกน ความแม่นยำของวิธีนี้ขึ้นอยู่กับ การเลือกค่าต่ำสุดและค่าสูงสุด โดยพิจารณาจากค่าสถิติของประชากรของแต่ละกลุ่ม วิธีนี้ง่ายต่อ การใช้และความเข้าใจรวมทั้งใช้เวลาในการประมวลผลน้อยกว่าวิธีอื่น แต่ความแม่นยำจะต่ำในกรณี ที่การกระจายในปริภูมิรูปลักษณะมีความแปรปรวนร่วมหรือขึ้นต่อกันในแนวเฉียง รูปที่ 2.4 แสดงตัวอย่างของการจำแนกประเภทด้วยการใช้ตัวจำแนกประเภทแบบสี่เหลี่ยมคู่ขนาน

### 2. ตัวจำแนกประเภทแบบระยะห่างต่ำสุด (Minimum Distance Classifier)

สำหรับวิธีนี้จะกำหนดข้อมูลภาพที่ไม่รู้จักมาก่อนให้เป็นสมาชิกของกลุ่มที่เหมาะสม โดยวัดจากระยะห่างระหว่างข้อมูลภาพกับประเภทในปริภูมิหลายรูปลักษณะที่มีค่าต่ำสุด ซึ่งระยะห่างจะใช้เป็นดัชนีแสดงความคล้าย ดังนั้นระยะห่างที่สั้นที่สุดจึงหมายถึงความคล้ายกันมากที่สุด รูปที่ 2.5 แสดงแนวคิดของวิธีนี้




รูปที่ 2.4 ตัวจำแนกประเภทแบบสี่เหลี่ยมคู่ขนาน



รูปที่ 2.5 ตัวจำแนกประเภทแบบใช้ระยะห่างต่ำสุด

### 3. ตัวจำแนกประเภทแบบความน่าจะเป็นได้สูงสุด (Maximum Likelihood Classifier)

สำหรับวิธีนี้ถือได้ว่าเป็นวิธีจำแนกประเภทในการสำรวจระยะไกลที่ได้รับความนิยมมากที่สุดวิธีหนึ่ง ตัวจำแนกประเภทแบบความน่าจะเป็นได้สูงสุดจะอาศัยทฤษฎีของความน่าจะเป็นในการจัดจุดภาพให้อยู่ในกลุ่มที่เหมาะสม ซึ่งความน่าจะเป็นได้ (Likelihood) ในที่นี้ หมายถึงความน่าจะเป็นที่จุดภาพใดๆ จะเป็นสมาชิกของข้อมูลแต่ละประเภท ความน่าจะเป็นได้ที่จะเป็นสมาชิกของประเภทใดมากที่สุดก็จะตัดสินใจให้เป็นสมาชิกของประเภทนั้น หลักการจำแนกประเภทแบบความน่าจะเป็นได้สูงสุด แสดงดังรูปที่ 2.6



รูปที่ 2.6 หลักการจำแนกประเภทแบบความน่าจะเป็นได้สูงสุด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 2.2.2 การจำแนกภาพแบบไม่มีผู้สอน (Unsupervised Classification)

การจำแนกแบบไม่มีผู้สอน เป็นขั้นตอนในการวิเคราะห์หลักสถิติด้วยการใช้อัลกอริทึมในการหากลุ่มข้อมูล อัลกอริทึมที่ใช้ในการทำสถิติข้อมูลภาพในมัลติสเปกตรัม และจากนั้นจะทำการกำหนดพิกเซลทั้งหมดที่สนใจที่เป็นของสเปกตรัมเหล่านั้น ถึงแม้ว่าเราได้กำหนดสัญลักษณ์ไว้แล้วและความสัมพันธ์ยังไม่ได้อยู่ในกลุ่มที่กำหนด อย่างไรก็ตามมันจะไม่สำคัญถ้าการจำแนกกลุ่มแบบไม่มีผู้สอนนี้กำลังสนใจในข้อมูลนั้นอยู่ การทำสถิติตามการจำแนกกลุ่มของมัลติสเปกตรัม กลุ่มของข้อมูลหรือประเภทของสเปกตรัมจะเกี่ยวข้องกันกับประเภทของข้อมูล ข้อมูลที่เราจะทำการวิเคราะห์นี้จำเป็นต้องทำให้ชัดเจนเพียงพอสำหรับกลุ่มของข้อมูลที่สนใจ กลุ่มของข้อมูลประเภทอื่นๆ ถูกนำไปใช้โดยอัลกอริทึมเพื่อให้แน่ใจว่าลักษณะของข้อมูลมีความแตกต่างกันแต่ยังคงกำหนดสัญลักษณ์มากกว่าที่จะกำหนดชื่อ

ในการที่จะระบุประเภทของข้อมูลที่ตรงข้ามกับที่เราสนใจโดยส่วนมากแล้วจะให้สำเร็จได้ เมื่อทำการเพิ่ม Spatial เข้าไปในข้อมูลภาพโดยการสร้างขึ้นคล้ายกับพิกเซล สิ่งนี้จะมีประโยชน์สำหรับการจำแนกกลุ่มโดยไม่มีผู้สอน เพราะฉะนั้นเทคนิคนี้จะช่วยให้ดีขึ้น หมายถึงว่าสัญลักษณ์จะถูกสร้างเพิ่มเข้าไปยังกลุ่มของข้อมูล หลังจากที่ให้ข้อมูลเปรียบเทียบระหว่างการจำแนกกลุ่มข้อมูลแบบมีผู้สอนและไม่มีผู้สอน ก็คือกลุ่มของข้อมูลที่ถูกแบ่งออกเป็นกลุ่มๆ โดยวิเคราะห์จากทุกๆ ข้อมูลที่ได้เตรียมมา การวิเคราะห์ข้อมูลถูกใช้เพื่อที่จะแยกแยะกลุ่มของข้อมูลที่จะกำหนดในการแบ่งกลุ่มโดยคลัสเตอร์ (Cluster)

#### การกำหนดประเภทของข้อมูล (Delineation of Spectral Classes)

แอปพลิเคชันที่ประสบความสำเร็จในการจำแนกประเภทที่น่าจะเป็นจริงมากที่สุด จะขึ้นอยู่กับ การแยกแยะประเภทของสเปกตรัมได้อย่างถูกต้องในข้อมูลภาพที่สนใจ สิ่งเหล่านี้เป็นสิ่งที่จำเป็นในแต่ละประเภทที่ถูกจำลองขึ้นมาโดยการกระจายตัวเป็นปกติ ถ้าประเภทของสเปกตรัมเกิดขึ้นมีหลายรูปแบบ และมันไม่ได้ถูกนำมาจัดการแก้ปัญหา จากนั้นการจำลองจะไม่สามารถส่งผลกระทบได้อย่างชัดเจน

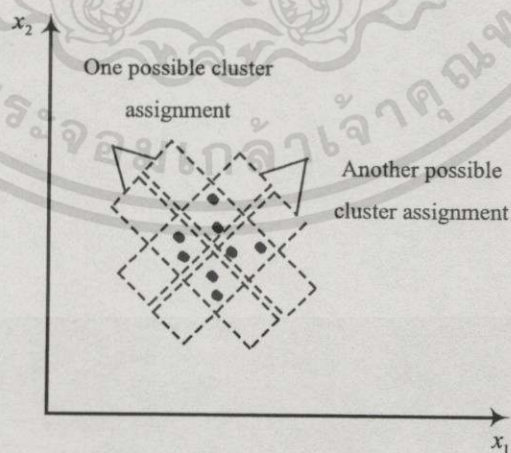
ผู้ใช้ข้อมูลที่ได้จากภาพถ่ายดาวเทียมสามารถที่จะกำหนดรายละเอียดของประเภทข้อมูลเหล่านั้น ในบางครั้งอาจเป็นไปได้ที่จะประมาณจำนวนประเภทของสเปกตรัมในข้อมูลที่อยู่ร่วมกัน แต่โดยทั่วไปผู้ใช้ควรมีแนวคิดเล็กน้อยที่จะจำแนกข้อมูลให้เข้าไปอยู่ในกลุ่มที่ไม่ซ้ำกัน ขั้นตอนของการทำคลัสเตอร์ริง (Clustering) สามารถที่จะนำไปใช้ตามจุดประสงค์เหล่านั้น วิธีการที่ได้กล่าวมานี้ได้นำไปประยุกต์ในการวิเคราะห์ข้อมูลมากมายที่ทำให้สามารถจะจดจำหรือรู้จัก โครงสร้างของข้อมูลที่ได้กำหนดไว้ได้

การทำคลัสเตอร์ริง สามารถถูกนำไปใช้สำหรับการจำแนกแบบไม่มีผู้สอนได้ด้วย ในเทคนิคนี้ภาพจะถูกจำแนกภายในกลุ่มของข้อมูลเดียวกันที่ไม่รู้จัก (Unknown Classes) มันเป็นงานเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ที่ผู้ใช้จะทำการกำหนดชนิด (Classes) หรือประเภทข้อมูลในภายหลัง มีวิธีการทำคลัสเตอร์ซึ่งมากมายหลายวิธีจะขอยกตัวอย่างดังต่อไปนี้

### 1. ตัววัดความคล้ายกันและหลักเกณฑ์การจำแนก (Similarity Metrics and Clustering Criteria)

การคลัสเตอร์ริงถือได้ว่าเป็นการจัดกลุ่มของพิกเซลในมัลติสเปกตรัม โดยพิกเซลจะเป็นสมาชิกเฉพาะในคลัสเตอร์ที่มีสเปกตรัมคล้ายๆ กัน เพื่อที่จะให้ขนาดของกลุ่มข้อมูลที่สัมพันธ์กันนี้เป็นสิ่งจำเป็นที่จะทำการวัดความเหมือนกันในกลุ่มข้อมูลหลายๆ ตัววัดความเหมือนกันได้ถูกเสนอแต่สิ่งเหล่านี้ได้ใช้ร่วมกันในขั้นตอนคลัสเตอร์ริงเป็นการวัดระยะห่างในมัลติสเปกตรัมอย่างสม่ำเสมอ โดยส่วนมากแล้วช่วงความถี่ที่พบเป็นระยะห่างแบบยูคลิเดียน (Euclidean Distance) และ ระยะห่าง L1 หรือ (Interpoint) ถ้า  $X_1$  และ  $X_2$  เป็นสองพิกเซลซึ่งจะถูกตรวจสอบความเหมือนกัน จากนั้นระยะห่างแบบยูคลิเดียนเป็นดังสมการที่ 2.4 โดยที่  $N$  เป็นจำนวนของสเปกตรัมทั้งหมด ระยะห่าง L1 ระหว่างพิกเซลเป็นดังสมการที่ 2.5 ในส่วนหลังนี้เป็นการคำนวณอย่างรวดเร็วเพื่อที่จะกำหนดค่าให้ชัดเจน อย่างไรก็ตามมันจะพบได้ว่าอย่างน้อยที่สุดความถูกต้องมีมากกว่าการวัดระยะห่างแบบอิกวิเดียน โดยการใช้การวัดระยะห่างซึ่งมันควรจะเป็นไปได้ที่จะกำหนดคลัสเตอร์ในข้อมูล อย่างไรก็ตามส่วนมากแล้วจะสามารถยอมรับได้ในการกำหนดคลัสเตอร์ของข้อมูลดังรูปที่ 2.7 เพื่อที่ว่าเมื่อคลัสเตอร์ริงที่เข้าร่วมแข่งขันได้ถูกพบตามที่ต้องการที่จะให้มีค่าเฉลี่ยซึ่งคุณภาพของคลัสเตอร์ริงสามารถจะถูกวัดออกมาได้ การที่จะได้มาเช่น การวัด ควรจะยอมกำหนดให้เพียงหนึ่งคลัสเตอร์ของข้อมูลที่ถูกเลือกอื่นๆ ทั้งหมด



รูปที่ 2.7 แสดงการแข่งขันกันของตัวคลัสเตอร์ที่เป็นไปได้

$$\begin{aligned}
 d(x_1, x_2) &= \|x_1 - x_2\| \\
 &= \{(x_1 - x_2)'(x_1 - x_2)\}^{\frac{1}{2}} \\
 &= \left\{ \sum_{i=1}^N (x_1 - x_2)^2 \right\}^{\frac{1}{2}}
 \end{aligned} \tag{2.4}$$

$$d(x_1, x_2) = \sum_{i=1}^N |x_{1i} - x_{2i}| \tag{2.5}$$


เกณฑ์หรือบรรทัดฐานของคลัสเตอร์ริง หรือที่เป็นตัววัดคุณภาพถูกรวมอยู่ในแอสควร์เออเรอร์ (Sum of Square Error) ค่าเฉลี่ย ดังสมการที่ 2.6 โดยที่  $M_i$  เป็นค่าเฉลี่ยของลำดับที่  $i$ th คลัสเตอร์  $x \in C_i$  เป็นรูปแบบที่ถูกกำหนดไว้ให้คลัสเตอร์นั้น และผลรวมภายนอกจะรวมคลัสเตอร์ทั้งหมด สิ่งนี้จะเป็นการคำนวณการวัดระยะห่างที่เพิ่มขึ้นของแต่ละรูปแบบจากคลัสเตอร์ที่เป็นศูนย์กลางสำหรับคลัสเตอร์แต่ละตัวที่มีลักษณะเฉพาะและจากนั้นจะทำการรวมการวัดคลัสเตอร์ทั้งหมด ถ้าระยะห่างที่ได้จากรูปแบบไปยังค่าเฉลี่ยคลัสเตอร์มีค่าน้อยจะทำให้ทั้งหมดมีค่าน้อย และคลัสเตอร์ริงนั้นจะถือว่ามีประโยชน์ คุณสมบัติอื่นๆ ของการวัดคลัสเตอร์ริงที่มีอยู่ หนึ่งในคุณสมบัตินั้นจะได้มาโดยการกำหนดค่าเฉลี่ยร่วมต่างๆ ของคลัสเตอร์ และด้วยการดูค่าเฉลี่ยของคลัสเตอร์เปรียบเทียบกับค่าเฉลี่ยทั้งหมดของข้อมูล

$$\begin{aligned}
 \text{SSE} &= \sum_{C_i} \sum_{x \in C_i} (x - m_i)'(x - m_i) \\
 &= \sum_{C_i} \sum_{x \in C_i} \|x - m_i\|^2
 \end{aligned} \tag{2.6}$$

## 2. ตัวเพิ่มประสิทธิภาพการคลัสเตอร์ริงด้วยวิธีการทำซ้ำ (Iterative Optimization

### Clustering)

ขั้นตอนการทำคลัสเตอร์ริงที่เพิ่มประสิทธิภาพด้วยการทำซ้ำ (Iterative Optimization Clustering) อาจเรียกได้ว่าค่าเฉลี่ยในการเคลื่อนย้าย มันเป็นพื้นฐานในการประเมินสิ่งที่เป็นเหตุเป็นผลของพิกเซลภายในคลัสเตอร์ที่เข้าร่วมการแข่งขัน และการเคลื่อนย้ายพิกเซลเหล่านั้นจากคลัสเตอร์หนึ่งไปยังคลัสเตอร์อื่นๆ เช่น ตัวอย่างการประเมินด้วย SSE (Sum of Square Error) ซึ่งมันทำการจำกัดในส่วนที่มีค่ามากเกินไป



รูปที่ 2.8 แสดงการจำแนกภาพด้วยวิธีการทำซ้ำ

พื้นฐานอัลกอริทึม

1. การเลือกตำแหน่ง  $C$  ในมัดติสเปกตรัม ซึ่งเป็นศูนย์กลางคลัสเตอร์ที่เข้าร่วมเราเรียกสิ่งเหล่านี้ว่าค่า

$$\hat{m}_i, i = 1, \dots, C \tag{2.7}$$

ที่ถูกเลือกตามการตัดสินใจกับการยอมรับว่าจะไม่มีพิกเซลเดียวกันอยู่ซ้ำกันสอง คลัสเตอร์ ซึ่งการหลีกเลี่ยงการเกิดคลัสเตอร์นี้ กับชุดข้อมูลที่ไม่ปกติเป็นการพิจารณาระหว่างค่าเฉลี่ยคลัสเตอร์ที่เริ่มต้นบนข้อมูลเดียวกัน สิ่งนี้จะสามารถช่วยให้เพิ่มการรวมกลุ่ม การเลือกค่า  $\hat{m}_i$  จำนวนของ  $C$  คลัสเตอร์ต้องถูกกำหนดก่อนโดยผู้ใช้

2. ตำแหน่งใดๆ ของแต่ละพิกเซลในกลุ่มของภาพจะถูกทดสอบจำแนก และพิกเซลจะ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ถูกกำหนดให้ใกล้เคียงกับคลัสเตอร์ที่เข้าร่วม      ข้อกำหนดนี้จะถูกสร้างบนพื้นฐานของยูคลิเดียน (Euclidian)

3. ค่าเฉลี่ยชุดใหม่ซึ่งผลลัพธ์ได้มาจากขั้นตอนการแบ่งกลุ่มในข้อที่ 2 เป็นการคำนวณดังนี้

$$m_i, i = 1, \dots, C \tag{2.8}$$

4. ถ้า  $m_i = \hat{m}_i$  สำหรับ  $i$  ทั้งหมด การกระทำนี้จะสิ้นสุด ถ้าเป็นอย่างอื่น  $\hat{m}_i$  จะถูกกำหนดค่าปัจจุบันตาม  $m_i$  และกระบวนการจะย้อนกลับไปทำข้อที่ 2 โดยแสดงดังรูปที่ 2.7 เป็นแบบ 2 มิติ


### 3. ตัวจำแนกภาพแบบทางเดียว (Single Pass Clustering Technique)

เพื่อการลดความเสียหายในการจำแนกข้อมูลของภาพถ่ายดาวเทียม เรามุ่งหวังที่จะหาทางเลือกที่ดีที่สุดอีกทางหนึ่ง (Alternative Optimization) และสามารถส่งเสริมหรือพัฒนาโปรแกรมสำหรับการวิเคราะห์ภาพถ่ายดาวเทียม บ่อยครั้งที่การขยายตัวเพิ่มขึ้นไปอย่างรวดเร็วเกิดความสูญเสียในความถูกต้องได้ อย่างไรก็ตามถ้าผู้ใช้ทราบถึงคุณลักษณะเหล่านี้ เขาก็สามารถที่จะนำไปใช้ได้อย่างได้ผล


#### อัลกอริทึมที่ใช้ของการจำแนกภาพแบบทางเดียว

ไม่ใช่ทุกส่วนของภาพที่ถูกจำแนกต้องใช้การพัฒนาแบบศูนย์กลางคลัสเตอร์ แต่ส่วนมากใช้สำหรับลดการสูญเสียในการสุ่มตัวอย่างอาจจะถูกเลือก และการจัดอาเรย์ (array) แถวแรกของตัวอย่างจะถูกใช้ในการเริ่มต้นของศูนย์กลางคลัสเตอร์ (Cluster Center) ในตัวอย่างแรกนี้เราได้เริ่มนำมาใช้ตามศูนย์กลางของคลัสเตอร์แรก ตัวอย่างที่สองในแถวแรกนี้อยู่ห่างไกลกว่าจากสิ่งแรก ที่ผู้ใช้กำหนดระยะห่างวิกฤต (Critical Distance) จากนั้นมันก็จะถูกใช้ในการรวมตัวกับศูนย์กลางคลัสเตอร์อีกอันหนึ่ง มิฉะนั้นทั้งสองตัวอย่างจะกล่าวได้ว่าเป็นของคลัสเตอร์เดียวกัน และค่าเฉลี่ยเหล่านี้จะถูกคำนวณตามศูนย์กลางคลัสเตอร์ใหม่ วิธีการนี้แสดงดังรูปที่ 2.9 ซึ่งเป็นการประยุกต์ใช้ดังตัวอย่างในแถวแรก ถ้าสมมุติว่าแถวแรกนี้ได้ถูกใช้ในการคำนวณของคลัสเตอร์ เช่นในตัวอย่างย่อยลำดับที่สองของแถวจะถูกตรวจสอบว่ามันใกล้เคียงกับกลุ่มคลัสเตอร์ มันจะถูกกำหนดให้กับคลัสเตอร์นั้น และสถิติของคลัสเตอร์จะถูกคำนวณเก็บไว้ ถ้ามันไม่ถูกต้องภายในจำนวนของที่ใช้กำหนด มิฉะนั้นมันก็จะถูกนำไปรวมกับศูนย์กลางคลัสเตอร์ใหม่ ดังแสดงในรูปที่ 2.10 ในตัวอย่างนี้ทั้งหมดจะถูกจำแนก และคลัสเตอร์ที่มีค่าน้อยกว่าจำนวนพิกเซลที่ผู้ใช้กำหนดก็จะถูกลบทิ้ง ภาพต้นแบบคลัสเตอร์ที่ต้องการจะถูกอ่านไปที่ละพิกเซล และพิกเซลแต่ละพิกเซลจะถูกกำหนดค่า

ให้สอดคล้องกับชนิดหรือประเภทที่มันใกล้เคียงมากที่สุด พิกเซลที่ไม่อยู่ในกลุ่มของศูนย์กลางคลัสเตอร์ก็จะไม่ถูกกำหนด



รูปที่ 2.9 แสดงศูนย์กลางการคลัสเตอร์



รูปที่ 2.10 แสดงค่าเฉลี่ยของอัลกอริทึมคลัสเตอร์รั้งแบบเดียว


#### 4. การจำแนกภาพโดยการเลือกจุดสูงสุดของภาพ (Clustering by Histogram Peak Selection)

ในการจำแนกภาพด้วยฮิสโตแกรม (Histogram) หลายมิติ ข้อมูลภาพจะแสดงพีก (Peak) ที่บ่งบอกว่าเป็นจุดที่มีค่าสูงสุดของภาพ แล้วนำมาจำแนกประเภทของภาพ หรือ ทำคลัสเตอร์ ฉะนั้นวิธีการจำแนกภาพด้วยวิธีนี้จึงได้นำมาใช้กับภาพถ่ายดาวเทียม ก็คือนำภาพมาสร้างเป็นรูป ฮิสโตแกรม (Histogram) และจากนั้นจะทำการค้นหาตำแหน่งของพีก (Peak) ซึ่งพิกเซลเหล่านั้นจะถูกเข้าร่วมกับพีกที่ใกล้ที่สุดเพื่อทำการสร้างคลัสเตอร์ โดยในการสร้างคลัสเตอร์จะทำการรวมจุด พีกที่ขนาดไม่สูงเข้ากับจุดพีกที่มีขนาดสูงกว่าในบริเวณใกล้เคียงกัน ซึ่งแสดงดังรูปที่ 2.11 จะสังเกตเห็นได้ว่ามีค่าพีกของฮิสโตแกรมหลายระดับ ซึ่งในการคลัสเตอร์จึงต้องไม่หลงนำพีกที่มีค่าต่ำ


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

มาทำคลัสเตอร์ก่อน โดยจะต้องดูพิกที่มีค่าสูงกว่าที่อยู่ในบริเวณใกล้เคียงกันด้วย และจะต้องรวมกันหลายพิก รูปที่ 2.12 แสดงค่าฮิสโตแกรมของพิกที่ถูกกับฮิสโตแกรมของพิกที่ผิด

ในการใช้เลือกพิกของฮิสโตแกรม (Histogram Peak Selection) มาทำการจำแนกภาพ ซึ่ง จะทำการพิจารณาในการคำนวณ โดยเลือกภาพขนาด 100 x 100 พิกเซล จะได้พื้นที่ภาพขนาด 10,000 พิกเซล จากดาวเทียม LANDSAT ประกอบด้วยสเปกตรัมสี่แบนด์ ในหนึ่งแบนด์ประกอบไปด้วย 256 ค่าสี (ค่า brightness จาก 1 พิกเซลเท่ากับ 8 บิต) จากนั้นจะได้ภาพสีมิตินขนาด  $256^4 = 4295$  ล้านค่าสี ถ้าค่าสีถูกรวมให้เป็นชุดเดียวกันทั้งหมดแล้วผลลัพธ์ของพิกที่ได้จะมีค่าน้อยมาก โดยทั่วไป แล้วในการเฉลี่ยเพียงหนึ่งพิกเซลในทุกๆ ครั้งล้านค่าสี จะมีค่าพิกเพียงหนึ่งค่าเท่านั้น ซึ่งจริงๆ แล้วไม่ควรนำค่าพิกนี้ไปจำแนกเป็นกลุ่มคลัสเตอร์ เพราะมันจะเป็นค่าไม่ถูกต้อง ค่าสีที่ถูกต้องจะต้องไม่ถูกรวมอยู่ในรูปแบบเดียวกัน แต่ค่าสีที่มีความเด่นชัดเพียงหนึ่งค่าสี ในแต่ละองค์ประกอบหลายๆ สเปกตรัม พิกเทียมจำนวนมากจะเกิดจากสีที่แยกตัวออกไป โดยพิกเซลหนึ่งๆ จะอยู่รอบๆ ค่าสีที่ว่าง ในการกำจัดปัญหาเหล่านี้ จะทำการรวบรวมหลายๆ ค่าสีซึ่งมีความเด่นชัดในทุกๆ มิติน ที่ใกล้กัน โดยภาพที่ได้จะมีความละเอียดไม่ดัดนัก แต่ก็ยอมรับได้เพราะภาพที่ได้แบ่งประเภท (cluster) ออกมานั้น ได้ลักษณะที่ใกล้เคียงมากที่สุด




รูปที่ 2.11 แสดงฮิสโตแกรมแบบสองมิติน



รูปที่ 2.12 แสดงค่าพีคในฮีสโตแกรมแบบสองมิติ

5. การจำแนกภาพด้วยวิธีของนิวรัลเน็ตเวิร์ค (Classification Using Neural Network)

การจำแนกภาพด้วยวิธีของนิวรัลเน็ตเวิร์ค หรือ โครงข่ายประสาทเทียม เป็นอีกวิธีการหนึ่ง ที่มีการนำมาใช้ในการจำแนกภาพด้วย ในวิทยานิพนธ์ฉบับนี้เราได้นำวิธีการของโครงข่ายประสาทเทียมแบบ ART มาใช้ซึ่งวิธีการจะอธิบายในบทถัดไป



### บทที่ 3

## โครงข่ายประสาทเทียม

โครงข่ายประสาทเทียมได้เริ่มมีการคิดค้นมานานนับมาตั้งแต่ปี ค.ศ. 1940 โดยในช่วงเวลาที่ก่อให้เกิดสถาปัตยกรรมของโครงข่ายประสาทเทียมชนิดต่างๆ ในปี ค.ศ. 1943 Warren McCulloch และ Walter Pitts ได้ออกแบบนิเวรอนที่ถือเป็นต้นกำเนิดและพื้นฐานของโครงข่ายประสาทเทียมในปัจจุบัน โครงข่ายของ McCulloch และ Pitts ประกอบด้วยชั้นของโครงข่ายจำนวน 2 ชั้น คือ ชั้นอินพุตและชั้นเอาต์พุต โครงข่ายจะมีการเชื่อมโยงจากชั้นอินพุตไปยังชั้นเอาต์พุตโดยผ่านน้ำหนัก (weight) ซึ่งค่าน้ำหนักจะถูกกำหนดค่าไว้ตายตัว การทำงานเบื้องต้นของโครงข่ายคือนำไปใช้จำลองฟังก์ชันทางลอจิก พื้นฐานคือ ฟังก์ชัน AND ฟังก์ชัน OR ฟังก์ชัน NOT และฟังก์ชัน XOR โดยนำเสนอการกำหนดค่าน้ำหนักเพื่อให้โครงข่ายทำงานได้กับการจำลองตามฟังก์ชันดังกล่าว

ในปี ค.ศ. 1949 Donald Hebb ได้ออกแบบกฎการเรียนรู้สำหรับ โครงข่ายประสาทเทียมเป็นคนแรก ซึ่งกฎการเรียนรู้แบบนี้คือขั้นตอนของกระบวนการปรับแต่งค่าน้ำหนักเพื่อทำให้เกิดค่าเอาต์พุต

ในปี ค.ศ. 1957 Frank Rosenblatt ได้นำเสนอรูปแบบที่สำคัญ รูปแบบหนึ่งของโครงข่ายประสาทเทียมที่เรียกว่าเพอร์เซพตรอน เป็นสถาปัตยกรรมอันประกอบไปด้วยชั้นอินพุตต่อผ่านค่าน้ำหนักไปยังชั้นนิเวรอนที่ชั้นเอาต์พุต และใช้กฎการเรียนรู้ของเพอร์เซพตรอนในการปรับแต่งค่าน้ำหนักที่มีประสิทธิภาพดีกว่ากฎการเรียนรู้ของเฮบบ์

ในปี ค.ศ. 1960 Bernard Widrow และ Marcian Hoff ได้พัฒนาการเรียนรู้ซึ่งใกล้เคียงกับการเรียนรู้ของเพอร์เซพตรอนและนำกฎนี้ไปใช้กับระบบ หรือรูปแบบที่ชื่อว่าอะดาไลน์ รูปแบบอะดาไลน์คือรูปแบบที่พัฒนาจากอะดาไลน์ โดยวิดโรว์

ในปี ค.ศ. 1972 Teuvo Kohonen ได้เริ่มพัฒนาการเรียนรู้แบบจัดตัวเอง (Self-Organized) สถาปัตยกรรมของโครงข่ายโคโฮเนนนี้ ประกอบด้วยจำนวนชั้น 2 ชั้น คือชั้นอินพุต และชั้นเอาต์พุต การเชื่อมโยงที่ชั้นอินพุตไปยังนิเวรอนที่ชั้นเอาต์พุตนั้นจะต่อผ่านน้ำหนัก ข้อแตกต่างจากโครงข่ายอื่นๆ คือกระบวนการเรียนรู้ที่สามารถจัดกลุ่มข้อมูลอินพุตได้ด้วยตัวของมันเอง และเรียกการเรียนรู้นี้ว่าการเรียนรู้แบบแข่งขัน (Competitive Learning)

หลังจากปี ค.ศ. 1980 เป็นต้นมาได้มีพัฒนารูปแบบของโครงข่ายประสาทเทียมชนิดต่างๆ เช่น รูปแบบจัดตัวเองที่เรียกว่า ART คิดค้นโดย Stephen Grossber และ Gail Carpenter รูปแบบโครงข่ายฮอปฟิลด์ คิดค้นโดย John Hopfield นีโอคอกนิตรอน คิดค้นโดย Kunihiko Fukushima รูปแบบโบลสแมนน์แมชชีน (Boltzmann Machine) คิดค้นโดยนักวิจัยหลายคน และรูปแบบที่นิยมใช้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

กันมาก คือรูปแบบแพร่ย้อนกลับ (Back-Propagation) คิดค้นโดย David Parker และ David Rumelhard

ปัจจุบันคอมพิวเตอร์ได้เข้ามามีบทบาทในการทำงานเป็นอย่างมาก ซึ่งงานบางอย่างคอมพิวเตอร์จะสามารถทำได้รวดเร็วกว่ามนุษย์หลายเท่า ตัวอย่างเช่น การจัดการด้านฐานข้อมูล, การประมวลผลได้สูงและถูกนำไปใช้ในงานหลาย ๆ ด้านได้เป็นอย่างดี แต่งานบางอย่างที่ทำได้ด้วยคอมพิวเตอร์เมื่อนำผลมาเปรียบเทียบกับมนุษย์แล้ว มนุษย์สามารถทำงานได้ดีกว่าและเร็วกว่ามาก เช่นการจดจำหน้าภาพหน้าคน การจดจำเสียง ซึ่งถ้าเป็นคอมพิวเตอร์แล้วอาจจะไม่สามารถจดจำได้ อีกทั้งเวลาที่ใช้ในการประมวลผลก็ใช้เวลานานมากด้วย

ความแตกต่างระหว่างมนุษย์ และคอมพิวเตอร์ในการทำงานจากตัวอย่างที่กล่าวข้างต้น เนื่องจากสมองของมนุษย์มีความแตกต่างจากคอมพิวเตอร์ กล่าวคือสมองมนุษย์ประกอบด้วยเซลล์ประสาทจำนวนมากมายเชื่อมต่อกันกับเซลล์ ซึ่งเซลล์เหล่านี้ทำหน้าที่เป็นหน่วยประมวลผลให้กับสมองมนุษย์ การส่งสัญญาณของเซลล์ประสาทระหว่างเซลล์หนึ่งสู่อีกเซลล์หนึ่งใช้เวลาเร็วมาก คือประมาณสิบส่วนล้านวินาที ซึ่งรูปแบบการส่งสัญญาณทำในลักษณะขนานกัน และวิธีการแก้ปัญหาของสมองมนุษย์ใช้ประสบการณ์ที่เกิดจากการเรียนรู้ในครั้งอดีต นำมาวิเคราะห์เพื่อแก้ปัญหานั้นๆ ขณะที่สถาปัตยกรรมของคอมพิวเตอร์ ประกอบด้วยหน่วยประมวลเพียงหน่วยเดียว และการทำงานใช้ชุดคำสั่งงานเป็นแบบลำดับขั้น อีกทั้งวิธีการแก้ปัญหาต่าง ๆ นั้นจะต้องทราบลำดับขั้นตอนการทำงานที่แน่นอนของปัญหานั้น

ดังนั้น เมื่อเราต้องการให้คอมพิวเตอร์สามารถจัดการกับปัญหาในลักษณะที่กล่าวข้างต้น จึงได้มีการนำสถาปัตยกรรมของสมองมนุษย์มาเป็นตัวแบบในการประมวลผลด้วยคอมพิวเตอร์ ซึ่งเรียกว่าระบบโครงข่ายประสาทเทียม (Artificial Neural Network)


โครงข่ายประสาทเทียมประกอบด้วยหน่วยประมวลผลแบบง่าย ๆ จำนวนมหาศาลที่เชื่อมต่อกันซึ่งเรียกหน่วยนี้ว่า นิวรอน (Neurons) เซลล์ (Cell) หรือ โหนด (Nodes) และ เรียกส่วนที่เชื่อมต่อกันระหว่างโหนดนี้ว่า ส่วนเชื่อมต่อ (Interconnection) ส่วนเชื่อมต่อจะเก็บความรู้ ซึ่งใช้ในการแก้ปัญหานั้น ๆ ของโครงข่าย ซึ่งความรู้ที่ใช้ในการแก้ปัญหานั้นจะได้มาจากการเรียนรู้ตัวอย่างของปัญหา ซึ่งเราสามารถเปรียบเทียบโครงข่ายประสาทเทียมกับสมองมนุษย์ได้ในแง่ของการเก็บข้อมูลต่าง ๆ ในรูปของแพตเทิร์นของส่วนเชื่อมต่อ (Pattern of Interconnections) และลักษณะการแก้ปัญหาวัยวิธีการเรียนตัวอย่างซึ่งเทียบได้กับการสะสมประสบการณ์ของมนุษย์

โครงข่ายประสาทเทียมได้ถูกนำมาประยุกต์ในงานด้านต่าง ๆ หลายด้าน เช่น การเก็บข้อมูล (Storing), การเรียกข้อมูลมาใช้งาน (Recall Data) และ การแบ่งกลุ่มแพตเทิร์นที่มีลักษณะเหมือนกัน (Pattern Classification) เป็นต้น โครงข่ายประสาทเทียมมีคุณสมบัติซึ่งเรียกว่า Generalization กล่าวคือโครงข่ายสามารถวิเคราะห์หรือสร้างคำตอบสำหรับปัญหาซึ่งมีลักษณะ ที่

เหมือนหรือคล้ายกับตัวอย่างที่นำมาสอนได้อย่างมีประสิทธิภาพ โดยที่ปัญหานั้นไม่เคยถูกนำมาสอนให้กับโครงข่ายเลย

### 3.1 ทฤษฎีเซลล์ประสาทเบื้องต้น [4, 5, 6]


ระบบประสาทมนุษย์ประกอบด้วยเซลล์ประสาทประมาณ  $10^{11}$  เซลล์ และมีการเชื่อมต่อกันระหว่างเซลล์ประมาณ  $10^{15}$  จุด ลักษณะเซลล์ประสาททางชีวภาพประกอบด้วย 3 ส่วนหลักคือ เดนไดร (Dendrites), โซมา (Soma) หรือตัวเซลล์ (Cell Body) และแอกซอน (Axon) ส่วนที่เชื่อมระหว่างตัวเซลล์กับแอกซอนของเซลล์อื่น ๆ ที่อยู่รอบ ๆ ข้างเรียกว่า ไชนแนปส์ (Synapse) โดยตัวเดนไดรซ์จะรับสัญญาณจากเซลล์ประสาทที่อยู่รอบ ๆ ข้างผ่านทางไชนแนปส์ ด้วยปฏิกิริยาทางเคมี ซึ่งสัญญาณที่เข้ามานี้ คือประจุอิเล็กตรอนโดยปฏิกิริยาเคมีที่เกิดขึ้นจะทำให้การปรับเปลี่ยนความถี่ของสัญญาณที่เข้ามา ตัวเซลล์ทำหน้าที่รวมสัญญาณที่เข้ามาแล้วทำการส่งสัญญาณออกให้กับแอกซอนเพื่อผ่านต่อไปกับเซลล์อื่น ๆ ซึ่งสัญญาณที่ออกจากตัวเซลล์มีลักษณะเป็นแบบสัญญาณกระตุ้นให้กับเซลล์อื่น กล่าวคือ ถ้าค่าสัญญาณที่ส่งออกจากตัวเซลล์มีจำนวน 100 ครั้งต่อวินาทีถือว่าค่าสัญญาณที่ส่งออกเป็นสถานะการกระตุ้น (Fire) โดยทั่วไปเราสนใจสัญญาณที่ออกจากเซลล์ประสาทในรูปของสถานะการกระตุ้นและไม่กระตุ้น ให้กับเซลล์ที่อยู่รอบข้างมากกว่าสนใจเงื่อนไขที่เกี่ยวข้องที่ทำให้เซลล์ประสาทเกิดสถานะนี้ขึ้นมา แสดงดังรูปที่ 3.1



รูปที่ 3.1 ลักษณะของเซลล์ประสาททางชีววิทยา

### 3.2 ทฤษฎีโครงข่ายประสาทเทียม (Artificial Neural Network)[5]

ตัวเซลล์ประสาทเทียมที่ใช้ใน Artificial Neural Network มีคุณลักษณะพื้นฐานเหมือนกับเซลล์ประสาททางชีววิทยา รูปที่ 3.2 แสดงลักษณะของตัวแบบเซลล์ประสาทเทียมที่ใช้กัน โดยทั่วไปซึ่งใช้พื้นฐานจากตัวแบบที่เสนอโดย McCulloch และ Pitts ในปี 1943 จากรูปที่ 3.2 เซลล์ประสาทเทียมรับสัญญาณ  $X_1-X_n$  จากเซลล์รอบข้าง โดยไซแนปส์หรือส่วนเชื่อมต่อจะทำการปรับเปลี่ยนหรือถ่วงน้ำหนักค่าสัญญาณที่เข้ามาด้วย  $W_1-W_n$  สมการที่ 3.1 แสดงการหาค่าผลรวมสัญญาณที่เข้าสู่เซลล์ประสาทเทียมโหนดที่  $i$  ซึ่งเรียกว่าค่า  $x_i$  Input และ  $y_i$  คือค่าสัญญาณที่ออกจากเซลล์ประสาทเทียม ซึ่งจะปรากฏที่แอกซอน โดยค่าสัญญาณนี้จะส่งผ่านทางฟังก์ชันกระตุ้น (Activation Function)  $f_i()$  ซึ่งฟังก์ชันนี้ทำหน้าที่เลือกผ่านค่าสัญญาณให้กับแอกซอน โดยจะทำการย่อขนาดของผลรวมสัญญาณที่ออกจากตัวเซลล์ให้อยู่ในช่วง 0 ถึง 1 แต่ในบางครั้งอาจไม่มีการใช้ฟังก์ชันการกระตุ้นก็ได้ สมการที่ 3.2 แสดงการหาค่าฟังก์ชันการกระตุ้นของสมการที่ 3.1



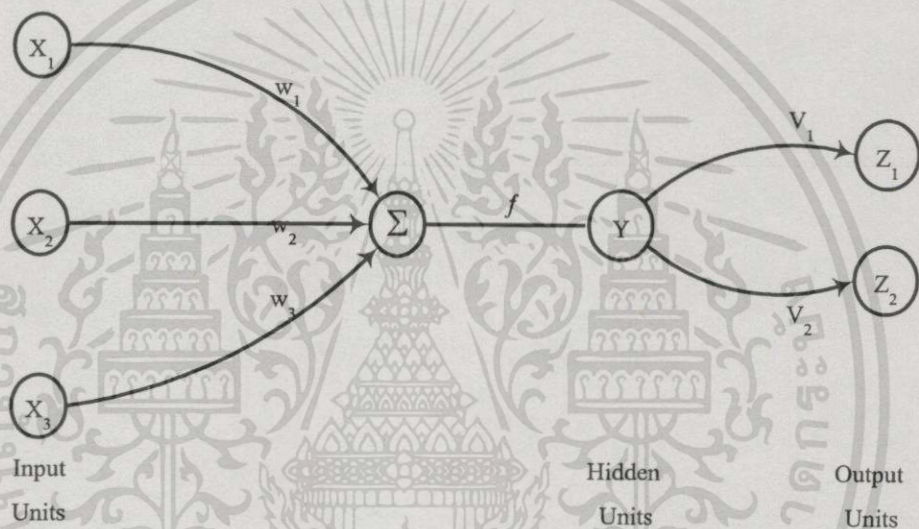
รูปที่ 3.2 รูปแบบของเซลล์ประสาทเทียม

$$x_i = \sum x_j w_{ij} \tag{3.1}$$

$$y_i = f_i(x_i) \quad i = 1, 2 \dots m \tag{3.2}$$

- โดยที่
- $x_j$  : ค่าสัญญาณลำดับที่  $j$  ที่เข้าสู่เซลล์ประสาทเทียมโหนดที่  $i$
  - $w_{ij}$  : ค่าน้ำหนักสัญญาณลำดับที่  $j$  ที่เข้าสู่เซลล์ประสาทเทียมโหนดที่  $i$
  - $x_i$  : ค่า  $x$  Input ของเซลล์ประสาทเทียมโหนดที่  $i$
  - $f_i()$  : ฟังก์ชันกระตุ้นของเซลล์ประสาทเทียมโหนดที่  $i$
  - $y_i$  : ค่าสัญญาณที่ออกจากเซลล์ประสาทเทียมโหนดที่  $i$
  - $m$  : จำนวนเซลล์ประสาทเทียมของโครงข่าย

นิวรัล  $Y$  จะถูกเชื่อมต่อไปยัง  $Z_1$  และ  $Z_2$  กับค่าน้ำหนัก  $v_1$  และ  $v_2$  ตามลำดับ ดังแสดงในรูปที่ 3.3 นิวรัล  $Y$  จะส่งสัญญาณ  $y$  ไปยังแต่ละยูนิตที่เอาต์พุต ซึ่งค่าที่ได้รับจะแตกต่างกัน เพราะฉะนั้นในแต่ละสัญญาณ จะถูกปรับแต่งให้มีค่าที่เหมาะสมตามค่าน้ำหนักโดยขึ้นอยู่กับค่าอินพุตที่ได้รับ โครงข่ายประสาทเทียมที่แสดงในรูปที่ 3.3 เป็นแบบ Hidden Unit พร้อมกับฟังก์ชันที่ใช้ในการกระตุ้นแบบไม่เป็นเชิงเส้น ซึ่งมันมีความสามารถในการแก้ปัญหาได้มากกว่า อีกอย่างหนึ่งก็คือมันก็จะมีความยากเพิ่มขึ้นสำหรับการฝึกสอน โครงข่ายในส่วนของ Hidden Unit



รูปที่ 3.3 รูปแบบของเซลล์ประสาทเทียมแบบมี Hidden Units

ค่าของส่วนเชื่อมต่อของเซลล์ประสาทเทียมอาจมีค่าเป็นบวก ลบ หรือศูนย์ก็ได้ ดังนั้นในการปรับแต่งค่าสัญญาณที่เข้าสู่เซลล์ประสาทด้วยค่าน้ำหนักของส่วนเชื่อมต่อ ถ้าข้อมูลที่เข้าสู่เซลล์ประสาทเทียมมีค่าเป็นบวก และค่าของส่วนเชื่อมต่อเป็นบวกด้วยก็จะก่อให้เกิดสภาพเสริมกัน (Excitatory) และถ้าค่าของส่วนเชื่อมต่อมีค่าเป็นลบ ก็จะลดค่าความเข้มของข้อมูลที่เข้ามานั้น ส่วนในกรณีที่ค่าของส่วนเชื่อมต่อเท่ากับศูนย์หมายถึง ส่วนเชื่อมต่อตรงส่วนนั้น ไม่มีการทำงาน

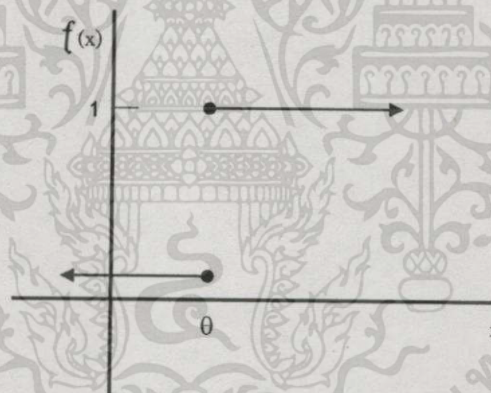
ค่าผลลัพธ์ที่ได้จากฟังก์ชันการกระตุ้นนี้ จะทำให้เซลล์ประสาทเทียมมีลักษณะเหมือนกับเซลล์ประสาททางชีววิทยา กล่าวคือค่าผลลัพธ์ที่ได้จากฟังก์ชันกระตุ้นเป็นค่าที่อยู่ในช่วง 0 ถึง 1 ถ้าค่าสัญญาณที่ออกจากเซลล์ประสาททางชีววิทยา มีลักษณะเป็นสถานะของการกระตุ้นเราจะสามารถแทนความหมายสถานะการกระตุ้นของเซลล์ประสาทด้วยค่า 1 และการไม่กระตุ้น 0 รูปแบบฟังก์ชันกระตุ้นที่นิยมใช้มีดังต่อไปนี้

1. Step Function ฟังก์ชันนี้นิยมใช้ในโครงข่ายแบบชั้นเดียว (Single Layer) ซึ่งใช้ในการแปลงค่า X Input ที่อยู่ในรูปของค่าต่อเนื่องให้อยู่ในรูปของไบนารี (Binary) คือ 1 และ 0 หรือ ไบโพลาร์ (Bipolar) คือ 1 และ -1 ฟังก์ชันนี้จะใช้ค่าเทรชโอล์ด (Theshold)  $\theta$  ในการกำหนดการแปลงค่า ซึ่งเรียกฟังก์ชันนี้เรียกว่า Threshold Function หรือ Heavisde Function ตัวอย่างโครงข่ายที่ใช้ฟังก์ชันนี้ได้แก่ Adaline สมการที่ 3.3 แสดงสมการของ Threshold Function

$$\begin{aligned} f(x) &= 1 \quad \text{if } x \geq \theta \\ &= 0 \quad \text{if } x < \theta \end{aligned} \quad (3.3)$$

โดยที่  $x$  : ค่า x Input ที่ของเซลล์ประสาทเทียม


$\theta$  : ค่าเทรชโอล์ดที่ใช้ในการแปลงค่าของเซลล์ประสาทเทียม



รูปที่ 3.4 ลักษณะของ Binary Step โดยใช้ค่า Threshold

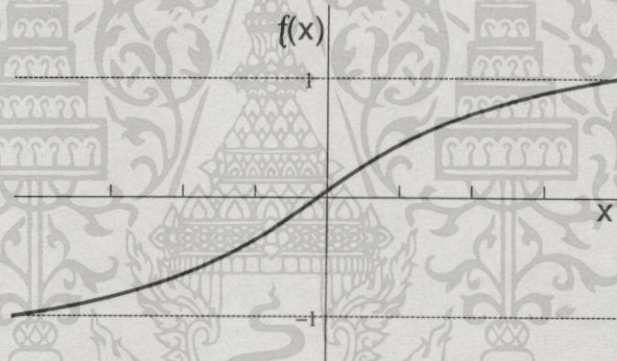
2. Sigmoid Function (S-shaped curves) ฟังก์ชันนี้ปกติแล้วนิยมนำมาใช้ในการแปลงค่า X Input ให้อยู่ในรูปของช่วง 0 ถึง 1 ซึ่งเรียกว่า Binary Sigmoid ฟังก์ชัน หรืออยู่ในช่วง -1 ถึง 1 ซึ่งเรียกว่า Bipolar Sigmoid ฟังก์ชันที่นำมาใช้ในการแปลงค่าเป็น Sigmoid Function โดยทั่วไปแล้ว Logistic Function และ Hyperbolic Tangent Function แสดงในสมการที่ 3.4 และ 3.5 ตามลำดับ ซึ่งฟังก์ชันเหล่านี้มีประโยชน์ อย่างมากในการสอนโครงข่ายแบบแพร่ย้อนกลับ (Backpropagation Network) รูปที่ 3.5 และ 3.6 แสดงตัวอย่างของ Binary Sigmoid และ Bipolar Sigmoid ด้วย Logistic Function และ Hyperbolic Tangent Function ตามลำดับ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.5 ลักษณะของ Binary Sigmoid

$$f(x) = \frac{1}{1 + e^{(-x)}} \quad (3.4)$$



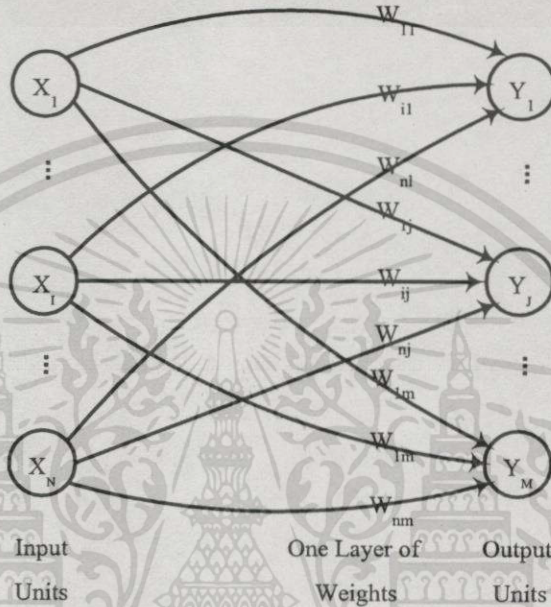
รูปที่ 3.6 ลักษณะของ Bipolar Sigmoid

$$f(x) = \frac{1 - e^{(-2x)}}{1 + e^{(-2x)}} \quad (3.5)$$

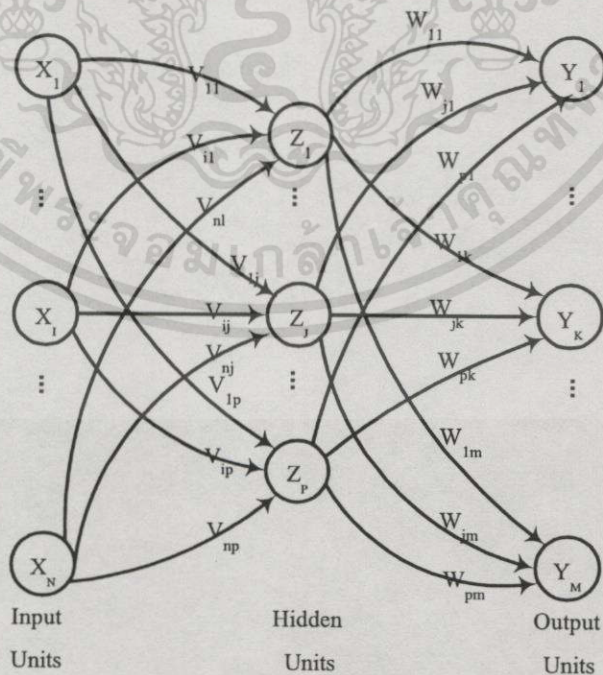
### 3.3 สถาปัตยกรรมของโครงข่ายประสาทเทียม (Neural Network Architecture)

โครงข่ายประสาทเทียมประกอบด้วยเซลล์ประสาทเทียมหรือโหนดจำนวนมาก ที่เชื่อมต่อกัน ซึ่งการเชื่อมต่อกันจะแบ่งออกเป็นกลุ่มย่อยเรียกว่า ชั้น (Layer) โดยทั่วไปแล้ว แบ่งออกเป็น 2 แบบ คือ โครงข่ายแบบชั้นเดียว (Single Layer) และโครงข่ายแบบหลายชั้น (Multilayer) การกำหนดจำนวนชั้นของโครงข่ายนี้ส่วนที่เป็นหน่วยรับข้อมูลเข้า (Input Unit) จะไม่ถูกนับด้วยเนื่องจากเป็นส่วนที่ไม่มีการคำนวณ (หนังสือบางเล่มถือว่าหน่วยข้อมูลเข้านี้เป็นชั้นของโครงข่ายด้วย) ดังนั้น เราอาจกล่าวได้ว่าจำนวนชั้นของโครงข่ายคือ จำนวนชั้นของส่วนเชื่อมต่อที่ถูกถ่วงน้ำหนัก โดยปกติแล้ว โครงข่ายแบบหลายชั้นสามารถแก้ปัญหาที่มีความซับซ้อนได้ดีกว่าโครงข่ายแบบชั้นเดียว และเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ในบางปัญหานั้นไม่สามารถแก้ปัญหาคด้วยโครงข่ายแบบชั้นเดียวได้ รูปที่ 3.7 แสดงลักษณะการต่อของโครงข่ายชั้นเดียว ซึ่งตัวแบบที่สถาปัตยกรรมแบบนี้ได้แก่ BAM, Hopfield ส่วนรูปที่ 3.8 แสดงสถาปัตยกรรมแบบหลายชั้นซึ่งตัวแบบได้แก่ Backpropagation, Self-Organizing Maps, Counter-propagation



รูปที่ 3.7 ตัวอย่างของโครงข่ายแบบชั้นเดียว



รูปที่ 3.8 ตัวอย่างของโครงข่ายแบบหลายชั้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่จากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.4 การฝึกสอนโครงข่ายประสาทเทียม

โครงข่ายประสาทเทียมประกอบด้วยเซลล์ประสาทหลาย ๆ เซลล์ ทำงานร่วมกันเพื่อแก้ปัญหาต่าง ๆ โดยโครงข่ายประสาทเทียมจะถูกฝึกให้เรียนรู้จากตัวอย่างเพื่อจะได้มีความรู้ที่จะนำไปแก้ปัญหาต่อไป แบบจำลองต่าง ๆ จะมีขั้นตอนในการฝึกที่แตกต่างกัน การฝึกโครงข่ายประสาทเทียม สามารถแบ่งตามลักษณะของการเรียนรู้ได้ 2 ประเภทคือ

#### 3.4.1 การเรียนรู้แบบมีผู้สอน (Supervised Learning)

การเรียนรู้แบบมีผู้สอน ข้อมูลจะต้องประกอบด้วยตัวอย่างข้อมูล ที่เราต้องการสอน และผลลัพธ์ที่เราต้องการให้โครงข่ายสร้างเมื่อมีการนำข้อมูลเข้าในลักษณะเดียวกันมาเป็นข้อมูลเข้า (Input) ขณะสอน โครงข่ายชนิดนี้จะกำหนดค่าผลลัพธ์เป้าหมายให้กับข้อมูลเข้าแต่ละตัว โครงข่ายจะนำค่าที่ผิดพลาดที่ได้จากการคำนวณโครงข่ายกับผลลัพธ์ที่ต้องการให้โครงข่ายสร้างนั้นมาเป็นค่าน้ำหนัก เพื่อปรับให้ได้ค่าข้อมูลออกมาตรงตามผลลัพธ์เป็นไปตามที่ต้องการ ซึ่งโดยตัวอย่างแบบจำลอง อาทิ เช่น Backpropagation, Adaline, Perceptron

#### 3.4.2 การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning)

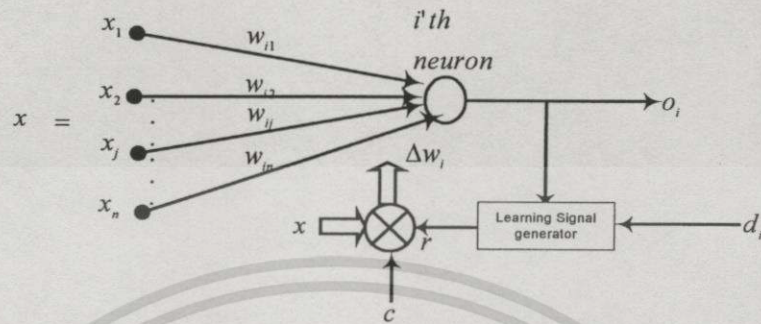
การเรียนรู้แบบไม่มีผู้สอนนี้จะทำการสอนโครงข่ายด้วยการป้อนรูปแบบข้อมูลเข้าอย่างต่อเนื่องเพียงอย่างเดียว โดยไม่มีการส่งค่าผลลัพธ์เป้าหมายให้กับข้อมูลเข้าแต่ละตัว ซึ่งการปรับค่าน้ำหนักได้ใช้ข้อมูลที่น่ามาสอนเป็นตัวปรับค่า โดยค่าน้ำหนักจะปรับตามกลุ่มที่ข้อมูลเข้ามีรูปแบบคล้ายๆ กัน ตัวอย่างแบบจำลองนี้ อาทิเช่น Counterpropagation (CPN) และ Adaptive Resonance Theory (ART)

การวิจัยในวิทยานิพนธ์ฉบับนี้จะเป็นแบบจำลองโครงข่ายประสาทเทียม ART ซึ่งมีโครงสร้างแบบ มัลติเลเยอร์ (Multilayer) ซึ่งมีรูปแบบในการเรียนรู้แบบ Unsupervised Learning และใช้อัลกอริทึมแบบคลัสเตอร์ นำมาทดสอบการรู้จำการจำแนกข้อมูลภาพ ทั้ง ART1 และ ART2

### 3.5 กฎการเรียนรู้โครงข่ายประสาทเทียม (Neural Network Learning Rules)

กฎการเรียนรู้ของโครงข่ายประสาทเทียมถูกพิจารณาเป็นองค์ประกอบย่อย ๆ โดยค่าน้ำหนักจะถูกเปลี่ยนแปลงได้ขึ้นอยู่กับสัญญาณอินพุตที่มันได้รับ ซึ่งทำให้มีค่าเอาต์พุตเกิดขึ้นและการร่วมกันตอบสนองของผู้สอน ในบางกรณีสัญญาณของผู้สอนไม่ได้ถูกเตรียมไว้และไม่มีข้อมูลของความคิดผลที่จะนำไปใช้ได้ ฉะนั้นโครงข่ายประสาทเทียมจะปรับปรุงค่าน้ำหนักพื้นฐานบนอินพุตหรือเอาต์พุตเท่านั้น สิ่งนี้เป็นกรณีสำหรับการเรียนรู้แบบไม่มีผู้สอน เรามาศึกษาวิธีการเรียนรู้ของค่าน้ำหนัก  $w_i$  หรือองค์ประกอบ  $w_{ij}$  การฝึกสอนโครงข่ายถูกแสดงในรูปที่ 3.9 ซึ่งรูปแบบ

ในหน้าที่การทำงานของโครงข่ายประสาทเทียมอาจจะแตกต่างกัน โปรดสังเกตว่าค่าตัวแปรที่เรา กำหนดบางที่จะถูกรวมเข้าไปในการเรียนรู้ตามค่านำหนักแต่ละอัน



รูปที่ 3.9 กฎการเรียนรู้ค่านำหนัก

ตามกฎการเรียนรู้ต่างๆ ไป จะถูกนำไปใช้ในการศึกษานิเวิร์ลเน็ตเวิร์ค โดยชุดค่านำหนัก  $w_i = [w_{i1} \ w_{i2} \ \dots \ w_{in}]$  ชุดค่านำหนักนี้จะถูกเพิ่มเข้าไปในส่วนของการคูณกับค่าอินพุต  $x$  และการเรียนรู้สัญญาณ  $r$  เป็นหน้าที่โดยทั่วไปของ  $w_i$ ,  $x$  และบางครั้งสัญญาณผู้ฝึกสอนเป็น  $d_i$  เพราะฉะนั้นเราจะได้เน็ตเวิร์คแสดงในรูปที่ 3.9 และเราจะได้สมการที่ 3.6 ซึ่งในการเพิ่มค่านำหนัก  $w_i$  คูณด้วยค่าเวลา  $t$  ของขั้นตอนการเรียนรู้เป็นดังสมการที่ 3.7

$$r = r(w_i, x, d_i) \tag{3.6}$$

$$\Delta w_i(t) = cr [w_i(t), x(t), d_i(t)] x(t) \tag{3.7}$$

โดยที่ค่า  $c$  เป็นจำนวนเต็มบวกถูกเรียกว่าเป็นค่าคงที่ที่ใช้ในการเรียนรู้ โดยทำการกำหนดอัตราส่วนของการเรียนรู้ ค่าชุดของน้ำหนักจะเปลี่ยนไปตามค่า  $t$  และกลายเป็นค่าคงที่ถัดไปหรือการเรียนรู้ในขั้นตอนถัดไปดังสมการที่ 3.8a ซึ่งด้วยกำลังที่ได้ตกลงกันไว้จะถูกนำไปใช้ในสมการที่ 3.8b ในการเรียนรู้ในสมการที่ 3.8 ทั้งหมด สมมติให้มีการปรับปรุ้ค่านำหนัก  $w_i(t)$  จะได้ดังสมการที่ 3.9

$$w_i(t + 1) = w_i(t) + cr [w_i(t), x(t), d_i(t)] x(t) \tag{3.8a}$$

$$w_i^{k+1} = w_i^k + cr(w_i^k, x^k, d_i^k) x^k \tag{3.8b}$$

$$dw_i(t)/dt = crx(t) \tag{3.9}$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.1 แสดงการปรับค่าถ่วงน้ำหนักสำหรับกฎการสอนแบบต่างๆ

กฎการสอน	การปรับค่าถ่วงน้ำหนัก	ค่าเริ่มต้นของค่าถ่วงน้ำหนัก	การ สอน	Activation Function
Hebb	$\Delta w_{ij} = c f(w_j^i X_j)$	0	U	Any
Preceptron	$\Delta w_{ij} = c(d_i - f(w_j^i X_j))x_j$	จำนวนจริงใดๆ	S	Binary Bipolar or Binary Unipolar
Delta	$\Delta w_i = c(d_i - o_i) f'(w_j^i X_j) X_j$	จำนวนจริงใดๆ	S	ฟังก์ชันต่อเนื่อง
Widrow-Hoff	$\Delta w_{ij} = c(d_i - w_j^i) x_j$	จำนวนจริงใดๆ	S	Any
Correlation	$\Delta w_{ij} = c d_i x_j$	0	S	Any
Winner-Take-All	$\Delta w_{mj} = c(x_i - w_{mj})$ m : โหนดที่เป็น Winner	Random Normalized	U	ฟังก์ชันต่อเนื่อง
Outstar	$\Delta w_{ij} = c(d_i - w_{ij})$	0	S	ฟังก์ชันต่อเนื่อง

c เป็นค่าคงที่ของอัตราการเรียนรู้

S: การฝึกสอนแบบ ไม่มีผู้สอน U : การฝึกสอนแบบมีผู้สอน

$\Delta w_{ij}$  : ค่าถ่วงน้ำหนักที่ถูกปรับค่าและมีการเชื่อมต่อระหว่างอินพุตโหนดที่ i และเอาต์พุตโหนดที่ j

### 3.5.1 กฎการเรียนรู้แบบเฮบบรอน (Hebbian Learning Rule)

กฎการเรียนรู้นี้ต้องการค่าน้ำหนักในการเริ่มต้น โดยการสุ่มค่าน้อยๆ ประมาณ  $w_i = 0$  ก่อนที่จะทำการเรียนรู้ กฎการเรียนรู้เป็นการแสดงการเรียนรู้แบบไม่มีผู้สอน ซึ่งข้อมูลจะถูกส่งตรงไปยังเอาต์พุต ในการกำหนดขั้นตอนซึ่งถ้าการคูณกันระหว่างเอาต์พุตและอินพุต หรือ  $o_j x_j$  มีค่าเป็นบวก ผลลัพธ์นี้จะเพิ่มเข้าไปในค่าน้ำหนัก  $w_{ij}$  หรือมีจะนั้นค่าน้ำหนักจะมีค่าลดลง มันสามารถพบได้ว่าเอาต์พุตที่ได้มีความถูกต้องในแต่ละคราวสำหรับค่าอินพุตแต่ละค่าที่ใช้ เพราะฉะนั้น ปริมาตรรูปแบบของอินพุตจะมีผลมากที่สุดโดยค่าน้ำหนักของโครงข่าย และจะได้ค่าเอาต์พุตที่มีค่าใหญ่ที่สุด ตั้งแต่ที่มันเริ่มต้นซึ่งกฎของ Hebbian ได้มีการประเมินในจำนวนของตัวเลข ในบางกรณีกฎของ Hebbian จำเป็นต้องทำการปรับปรุงเพื่อจะยับยั้งการเพิ่มขึ้นของค่าน้ำหนัก ซึ่งจะถูกแทนที่เมื่อการกระตุ้นและการตอบสนองยินยอมพร้อมกันอย่างสม่ำเสมอในสัญญาณนั้นๆ ดังรูปที่ 3.10


สำหรับสัญญาณที่ใช้ในการเรียนรู้ในกฎข้อนี้มีค่าดังสมการที่ 3.10 จากนั้นจะทำการเพิ่มค่าชดเชยน้ำหนัก ซึ่งทำให้ค่าน้ำหนักกลายเป็นสมการที่ 3.11a , 3.11b และ 3.11c ตามลำดับ

$$r = f(w_i^t x) \quad (3.10)$$

$$\Delta w_i = c f'(w_i^t x) x \quad (3.11a)$$

$$\Delta w_{ij} = c f'(w_i^t x) x_j \quad (3.11b)$$

$$\Delta w_{ij} = c o_j x_k, \text{ for } j = 1, 2, \dots, n \quad (3.11c)$$



รูปที่ 3.10 แสดงการฝึกสอนโครงข่ายของเฮบเบรอน

### 3.5.2 กฎการเรียนรู้แบบเพอร์เซปตรอน (Perceptron Learning Rule)

สำหรับกฎการเรียนรู้ของเพอร์เซปตรอน ซึ่งเป็นการเรียนรู้ถึงความแตกต่างของสัญญาณระหว่างความต้องการและการตอบสนองที่ถูกต้องของโครงข่ายประสาทเทียม ฉะนั้นการเรียนรู้นี้เป็นการเรียนรู้แบบมีผู้สอนและสัญญาณที่ใช้ในการเรียนรู้จะมีค่าเท่ากับสมการที่ 3.12 และค่าเอาท์พุทมีค่าเท่ากับ  $o_i = \text{sgn}(w_i^t x)$  และ  $d_i$  เป็นค่าที่ใช้ในการตอบสนองแสดงดังรูปที่ 3.11 ค่าน้ำหนักจะถูกปรับแต่งด้วยวิธีการดังสมการที่ 3.13a และ 3.13b

$$r = d_i - o_i \quad (3.12)$$

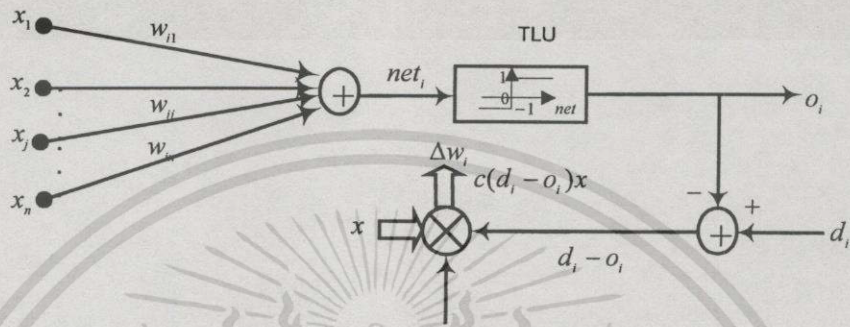
$$\Delta w_i = c [d_i - \text{sgn}(w_i^t x)] x \quad (3.13a)$$

$$\Delta w_{ij} = c [d_i - \text{sgn}(w_i^t x)] x_j, \text{ สำหรับ } j = 1, 2, \dots, n \quad (3.13b)$$

โปรดสังเกตว่ากฎการเรียนรู้ในหัวข้อนี้ สามารถนำไปใช้สำหรับโครงข่ายประสาทเทียมที่เป็นไบนารี ภายใตกฎนี้ค่าน้ำหนักจะถูกปรับเปลี่ยนถ้าเพียงแต่ค่าเอาท์พุทที่ได้มีค่าไม่ถูกต้อง เนื่องจากค่าที่ผิดพลาดเป็นสิ่งจำเป็นในการเรียนรู้ ซึ่งถูกรวมเข้าไปในกฎการฝึกสอนนี้ เห็นได้ชัดว่าตั้งแต่ความต้องการในการตอบสนองมีค่าเท่ากับ 1 หรือ -1 จะทำให้ค่าน้ำหนักมีการปรับเปลี่ยนโดย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$\Delta w_i = \pm 2cx$  ที่สามารถนำสัญญาณเพิ่มเข้าไปได้ เมื่อ  $d_i=1$  และ  $\text{sgn}(w_i'x) = -1$  และสามารถนำสัญญาณที่เป็นลบ เมื่อ  $d_i = -1$  และ  $\text{sgn}(w_i'x) = 1$  การปรับเปลี่ยนค่าน้ำหนักจะมีค่าเป็นศูนย์เมื่อความต้องการและการตอบสนองที่ถูกต้องตรงกัน กฎของการเรียนรู้พอร์เซปตรอนเป็นการเรียนรู้แบบมีผู้สอนของโครงข่ายประสาทเทียม ซึ่งค่าน้ำหนักจะถูกเริ่มต้นได้ทุกๆ ค่าในวิธีนี้



รูปที่ 3.11 กฎการเรียนรู้โครงข่ายของพอร์เซปตรอน

### 3.5.3 กฎการเรียนรู้แบบเดลต้า (Delta Learning Rule)

สำหรับกฎการเรียนรู้ของเดลต้า เป็นเพียงการตรวจสอบความต่อเนื่องในการทำงานของฟังก์ชันตามที่ได้กำหนดไว้ ซึ่งเป็นการฝึกสอนแบบมีผู้สอน ดังสมการที่ 3.14 ซึ่งใช้ในการเรียนรู้

$$r = [d_i - f(w_i'x)] f'(w_i'x) \tag{3.14}$$

ในส่วนของ  $f'(w_i'x)$  ได้รับมาจากฟังก์ชันที่ใช้ในการกระตุ้นถูกคำนวณโดย  $f'(net)$  โดยที่  $net = w_i'x$  โปรดสังเกตุได้จากรูปที่ 3.12 ในกฎการเรียนรู้ข้อนี้มันสามารถที่จะได้รับค่าผิดพลาดจากเงื่อนไขของค่ากำลังระหว่าง  $o_i$  และ  $d_i$  ในการคำนวณเกรเดียนเวกเตอร์ (gradient vector) กับค่าชด้น้ำหนักที่เกี่ยวข้อง ดังสมการที่ 3.15a, 3.15b, 3.15c และ 3.15d และค่าน้ำหนักจะถูกปรับแต่งเป็นดังสมการที่ 3.16

กฎของเดลตานั้นได้เริ่มนำมาใช้ในการฝึกสอนนิวิรัลเน็ตเวิร์ค โดยได้ทำไปพร้อมๆ กับกฎการฝึกสอนของพอร์เซปตรอน ซึ่งจะถูกรู้จักได้ว่าเป็นกฎการฝึกสอนพอร์เซปตรอนแบบต่อเนื่อง


$$E = \frac{1}{2} (d_i - o_i)^2 \tag{3.15a}$$

$$E = \frac{1}{2} [d_i - f(w_i'x)]^2 \tag{3.15b}$$

$$\nabla E = - (d_i - o_i) f'(w_i^t x) x \tag{3.15c}$$

$$\frac{\partial E}{\partial w_{ij}} = - (d_i - o_i) f'(w_i^t x) x_j, \quad \text{สำหรับ } j = 1, 2, \dots, n \tag{3.15d}$$

$$\Delta w_i = c(d_i - o_i) f'(net_i) x \tag{3.16}$$



รูปที่ 3.12 กฎการเรียนรู้โครงข่ายแบบ เดลต้า

### 3.5.4 กฎการเรียนรู้แบบมีการแข่งขัน (Winner-Take-All Learning Rule)

กฎข้อนี้แตกต่างจากข้อที่ผ่านมา โดยกฎการเรียนรู้ในข้อนี้เป็นการเรียนรู้แบบมีการแข่งขัน (Competitive Learning) และถูกนำไปใช้สำหรับการฝึกสอนโครงข่ายโดยไม่มีผู้ฝึกสอน โดยทั่วไปการเรียนรู้แบบ Winner-Take-All ถูกใช้เรียนรู้โดยการเก็บสถิติของค่าอินพุต

โดยหนึ่งในโครงข่ายค่าเอาต์พุตที่ได้ ที่มีค่าสูงสุดในการตอบสนองค่าอินพุต  $x$  ซึ่งค่าเอาต์พุตที่ได้จะถูกประกาศให้เป็นผู้ชนะ ดังแสดงดังรูปที่ 3.13 ในขณะที่ผลลัพธ์ที่ได้ของเหตุการณ์ที่ชนะซึ่งค่าชูดน้ำหนักจะถูกแสดงดังสมการที่ 3.17 ค่าชูดน้ำหนัก  $w_m$  จะประกอบไปด้วยค่าน้ำหนักที่ถูกปรับปรุงแสดงดังรูปที่ 3.13 ซึ่งเป็นการปรับปรุงค่าน้ำหนักในขั้นตอนการเรียนรู้แบบไม่มีผู้สอน โดยได้ทำการเพิ่มการคำนวณในสมการที่ 3.18a และ 3.18b ในขณะที่ค่า  $\alpha > 0$  เป็นค่าคงที่ใช้ในการเรียนรู้ให้มีค่าน้อยๆ ซึ่งจะทำให้ค่าชูดน้ำหนักที่ใช้ในการเรียนรู้ลดลงอย่างต่อเนื่องและจะทำให้ได้ค่าที่ได้ดีค่าคงที่มากที่สุด พื้นฐานในการเลือกผู้ชนะตามหลักเกณฑ์การกระตุ้นมากที่สุดในการจำนวนนิรวัลทั้งหมดที่มีส่วนร่วมในการแข่งขันเป็นดังสมการที่ 3.19

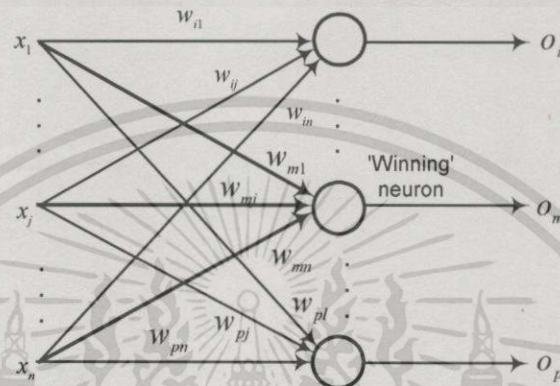
$$w_m = [w_{m1} \ w_{m2} \ \dots \ w_{mn}]^t \tag{3.17}$$

$$\Delta w_m = \alpha (x - w_m) \tag{3.18a}$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\Delta w_{mj} = \alpha(x_j - w_{mj}), \text{ สำหรับ } j = 1, 2, \dots, n \quad (3.18b)$$

$$w_m^t x = \max_{i=1,2,\dots,p} (w_i^t x) \quad (3.19)$$



รูปที่ 3.13 แสดงกฎการเรียนรู้โครงข่ายแข่งขันแบบหาผู้ชนะ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## โครงข่ายประสาทเทียมแบบ ART

โครงข่ายประสาทเทียมแบบอะแดปทีฟรีโซแนนซ์เทียร์ หรือ (ART) ถูกพัฒนาโดย Carpenter และ Grossberg ได้แก่ ART1 ถูกออกแบบมาสำหรับรับค่าอินพุทไบนารี และ ART2 สำหรับรับค่าอินพุทที่ต่อเนื่อง (Continuous Value) โครงข่ายของ ART เหล่านี้จะถูกนำไปใช้ในการเรียนรู้โดยไม่มีผู้สอน (Unsupervised Learning) ค่าอินพุทที่ถูกป้อนเข้ามาอาจจะถูกแสดงได้หลาย ๆ รูปแบบ ในแต่ละครั้งค่าอินพุทที่ได้แสดงเหมาะสมกับคลัสเตอร์ที่ถูกเลือก และค่าน้ำหนัก (Weight) จะถูกปรับแต่งเพื่อขอให้คลัสเตอร์ได้ทำการเรียนรู้ค่าอินพุทนั้นๆ โดยค่าอินพุทที่เหมือนกันจะอยู่ในคลัสเตอร์เดียวกัน ซึ่งโครงข่ายประสาทเทียมแบบ ART ถูกออกแบบมาเพื่อให้ผู้ใช้สามารถควบคุมระดับความเหมือนกันของกลุ่มของอินพุทให้อยู่ในคลัสเตอร์ที่เหมือนกันได้


ในแต่ละครั้ง การฝึกสอนค่าอินพุทอาจจะถูกนำมาแสดงได้หลายครั้ง ค่าอินพุทค่าหนึ่งอาจจะถูกวางลงในคลัสเตอร์แรกในครั้งแรกที่มันถูกแสดง และหลังจากนั้นอาจจะถูกวางลงในคลัสเตอร์ที่แตกต่างกันเมื่อมันถูกแสดงในครั้งต่อมา (ค่าน้ำหนักก็จะเกิดการเปลี่ยนแปลง)

### 4.1 อะแดปทีฟรีโซแนนซ์เทียร์ ART1 [4]

#### 4.1.1 โครงสร้างของ ART1

ART1 ถูกออกแบบมาเพื่อทำการคลัสเตอร์อินพุทไบนารี ซึ่งยอมให้ส่วนของค่าตัวเลขที่ไม่ได้เป็นศูนย์มีได้หลายแบบ และผู้ใช้สามารถที่จะกำหนดระดับของความเหมือนกันในกลุ่ม ซึ่งจะอยู่ในคลัสเตอร์เดียวกันได้ โครงสร้างของโครงข่ายประสาทเทียมแบบ ART1 ประกอบด้วย 2 ส่วนคือ  $F_1$  และ  $F_2$  (Cluster) กับ Reset Unit เพื่อควบคุมระดับความเหมือนกันของอินพุทที่ถูกวางลงในแต่ละคลัสเตอร์ที่เหมือนกัน  $F_1$  Unit ประกอบด้วย อินพุทเลเยอร์  $F_1(a)$  และอินเตอร์เฟทเลเยอร์  $F_1(b)$  ซึ่งจะทำกรแลกเปลี่ยนข้อมูลกับคลัสเตอร์เลเยอร์  $F_2$

แต่ละยูนิตในอินพุทเลเยอร์  $F_1(a)$  จะถูกต่อไปยังอินเตอร์เฟทเลเยอร์  $F_1(b)$  ที่สอดคล้องกัน และจะถูกต่อไปยัง Reset Unit ดังแสดงในรูปที่ 4.1 ในแต่ละยูนิตในอินเตอร์เฟทเลเยอร์  $F_1(b)$  จะถูกต่อไปยังแต่ละยูนิตในคลัสเตอร์เลเยอร์  $F_2$  ตามเส้นทางสองเส้นทางของค่าน้ำหนักโดย  $F_1(b)$  ยูนิต  $X_i$  จะถูกต่อไปยัง  $F_2$  ยูนิต  $Y_j$  โดย  $B_{ij}$  (Bottom-Up Weight) เช่นเดียวกันกับ ยูนิต  $Y_j$  จะถูกต่อไปยังยูนิต  $X_i$  โดย  $T_{ji}$  (Top-Down Weight) และค่า  $B_{ij}$  เพียงตัวเดียวที่ถูกกำหนดในการเชื่อมต่อระหว่าง เลเยอร์  $F_1$  และ  $F_2$  ทำนองเดียวกัน  $T_{ji}$  ก็จะถูกเชื่อมต่อระหว่างเลเยอร์  $F_1$  และ  $F_2$



รูปที่ 4.1 แสดงโครงสร้างของ ART1

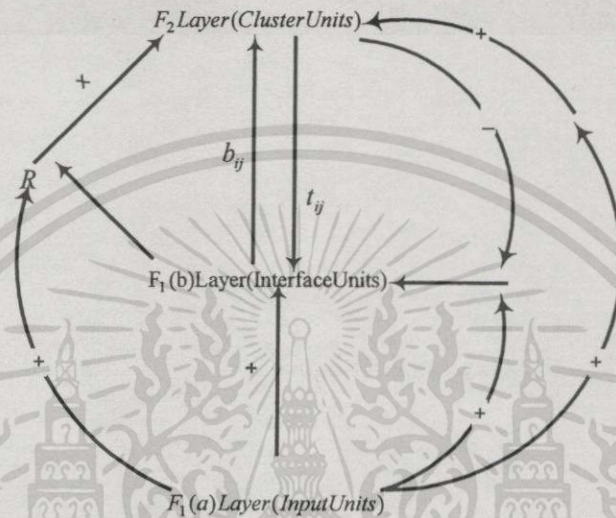
#### 4.1.2 ยูนิตเพิ่มเติมที่ใช้ในการตัดสินใจของ ART1 (Supplemental Units)

อัลกอริทึมที่ใช้สอน ART ที่ได้กล่าวมา อธิบายถึงการประมวลผลของโครงข่ายประสาทเทียม (Neural Network Process) ในเทอมของเลเยอร์  $F_1$ ,  $F_2$  และ หน่วย  $R$  ซึ่งในสภาวะการทำงานจริง บางเลเยอร์จะมีสถานะในการทำงานหลายสถานะ และเซลล์ประสาทจะมีการตอบรับแตกต่างกันในสถานะที่แตกต่างกัน ตัวอย่างที่แสดงให้เห็นการตอบรับที่แตกต่างกัน เช่น เมื่อเลเยอร์  $F_1(b)$  ได้รับสัญญาณอินพุตจากเลเยอร์  $F_1(a)$  ซึ่งในขณะนั้นเลเยอร์  $F_2$  ยังไม่แอกทีฟ ผลจากการกระตุ้นก็คือเซลล์ประสาทในเลเยอร์  $F_1(b)$  ซึ่งรับค่าอินพุตมาจากเลเยอร์  $F_1(a)$  จะ on ในหน่วยที่ได้รับสัญญาณจากเลเยอร์  $F_1(a)$  แต่ขณะที่เลเยอร์  $F_2$  แอกทีฟ เมื่อเลเยอร์  $F_1(b)$  ได้รับสัญญาณกระตุ้น เซลล์ประสาทในเลเยอร์  $F_2$  จะ on เฉพาะหน่วยที่ได้รับสัญญาณจากทั้งเลเยอร์  $F_2$  และอินพุตยูนิตเท่านั้น อย่างไรก็ตามในการทำงานจริง เซลล์ประสาททางชีววิทยา (Bioneural) โดยตัวมันเองไม่สามารถตัดสินใจได้ว่าสถานะที่เกิดเป็นสถานะแบบใดและควรทำอย่างไร หน่วยที่ใช้ควบคุมการตัดสินใจส่วนนี้คือ Supplemental Units (Gain Control Units) ซึ่งประกอบด้วยหน่วย  $G_1$  และ  $G_2$  ดังแสดงในรูปที่ 4.2 กำหนดให้สัญญาณกระตุ้นคือ + สัญญาณยับยั้งคือ - จากภาพจะเห็นว่าเซลล์ประสาทในเลเยอร์  $F_1(b)$  สามารถรับสัญญาณได้ 3 ทางคือ จาก  $F_1(a)$ ,  $G_1$  และ จากเลเยอร์  $F_2$  โดยผ่านชุดน้ำหนัก  $t_{ji}$  ส่วนเซลล์ประสาทในเลเยอร์  $F_2$  สามารถรับสัญญาณได้ 3 ทางคือ จาก  $F_1(b)$  โดยผ่านชุดน้ำหนัก  $t_{ji}$ ,  $G_2$  และ หน่วย  $R$  การ on ในเลเยอร์ใด ๆ จะเกิดขึ้นก็ต่อเมื่อได้รับสัญญาณ 2 ใน 3 ทาง ตามกฎ 2 ใน 3 (Two-Third Rules)

เมื่อมีอินพุตเข้ามา ในขณะที่  $F_2$  ยังไม่แอกทีฟ สัญญาณจะถูกส่งไปให้เซลล์ประสาทในเลเยอร์  $F_1(b)$  หน่วย  $G_1$  และหน่วย  $G_2$  ซึ่งในกรณีนี้พบว่าเซลล์ประสาทในเลเยอร์  $F_1(b)$  ได้รับ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับกรใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สัญญาณ 2 ทิศทางคือจาก  $F_1(a)$  และ  $G_1$  จึงอยู่ในสถานะ on แต่ขณะที่  $F_2$  แอคทีฟ  $F_2$  จะส่งสัญญาณ กระตุ้นให้  $F_1(b)$  และส่งสัญญาณ ยับยั้งให้กับ  $G_1$   $F_1(b)$  จึงได้รับสัญญาณจาก  $F_2$  โดยผ่านชุดน้ำหนัก  $t_{ji}$  และได้รับสัญญาณจากเลเยอร์  $F_1(a)$   $F_1(b)$  จึง on เฉพาะหน่วยที่ได้รับสัญญาณทั้งจาก  $F_2$  และ  $F_1(a)$




รูปที่ 4.2 แสดงการทำงานของ Supplemental Unit ( $G_1, G_2$ )

#### 4.1.3 อัลกอริทึมที่ใช้ในการฝึกสอน ART1

นอร์มอไรซ์เซชันของเวกเตอร์  $x$  (เวกเตอร์ที่ใช้ในการติดต่อในส่วนของ  $F_1$ ) ให้จำนวนขององค์ประกอบซึ่งค่าน้ำหนัก Top-Down สำหรับผู้ชนะยูนิต  $F_2$  คือ  $t_{ji}$  และค่าอินพุต  $s$  ถ้าอัตราส่วนระหว่าง  $\|x\|$  และ  $\|s\|$  มีค่ามากกว่าหรือเท่ากับ ค่าตัวแปร  $\rho$  (Vigilance) ซึ่งค่าน้ำหนัก (Top-Down และ Bottom-Up) สำหรับคลัสเตอร์ที่ชนะจะถูกปรับเปลี่ยนค่า

อย่างไรก็ตามถ้าอัตราส่วนนี้มีค่าน้อยกว่า ค่าตัวแปร  $\rho$  (Vigilance) คลัสเตอร์ที่ถูกเลือกจะถูกยกเลิก และคลัสเตอร์ในยูนิตอื่นๆ จะถูกเลือกมาแทนที่ คลัสเตอร์ที่ชนะในปัจจุบันจะกลายเป็นตัวเปรียบเทียบเพื่อว่ามันจะไม่ถูกเลือกมาแข่งขันใหม่ และการกระตุ้นในยูนิต  $F_1$  จะถูก Reset ให้เป็นศูนย์ ค่าอินพุตที่เริ่มต้นใหม่จะถูกส่งสัญญาณไปยังยูนิตอินเตอร์เฟซเหมือนกัน ซึ่งสัญญาณที่ส่งเข้าไปใหม่นี้จาก Bottom-Up ไปยังเลเยอร์  $F_2$  และการแข่งขันก็就会被ทำซ้ำขึ้นอีก (แต่ยูนิตที่ถูกยับยั้งไว้จะไม่มีส่วนรวม) กระบวนการทำงานจะทำต่อเนื่อง ไปจนกระทั่งค่าน้ำหนักมีการเปลี่ยนแปลงคงที่ หรือยูนิตทั้งหมดเป็นยูนิตที่ถูกยับยั้งไว้ ในการทำงานที่ผ่านมานั้นถ้ายูนิตถูกยับยั้งโดยผู้ใช้ทั้งหมด มันอาจจะต้องลดค่าตัวแปร  $\rho$  (Vigilance) ให้เหมาะสมโดยยอมให้มีค่าน้อยใกล้เคียงกับค่าอินพุตที่ถูกวางลงบนคลัสเตอร์เดียวกัน หรือจะเพิ่มจำนวนของยูนิตคลัสเตอร์ หรือกำหนดรูปแบบของค่าอินพุตปัจจุบันตามผลลัพธ์ที่ไม่สามารถหากลุ่มของคลัสเตอร์ได้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.3 โพลชาร์ตแสดงการทำงาน โปรแกรมของ ART1

### ที่มาของสมการที่ใช้ในการเรียนรู้

ตามสมการดิฟเฟอเรนเชียลสำหรับค่าน้ำหนัก (Top-down) (บน  $F_2$  ยูนิต  $J$ ) คือ สมการที่ 4.1 จากสมการที่ 4.1 Grossberg และ Carpenter ได้ทำการเขียนสมการใหม่สำหรับ ART1 โดยเป็นดังสมการที่ 4.2 และสมการดิฟเฟอเรนเชียลในสมการที่ 4.1 จะกลายเป็นสมการที่ 4.3

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\frac{d}{dt}b_{ji} = K_1[-E_{ji}b_{ji} + x_i] \quad (4.1)$$

$$K_2 = 1, \quad E_{ji} = 1 \quad (4.2)$$

$$\frac{d}{dt}t_{ji} = -t_{ji} + x_i \quad (4.3)$$

เราทำการกำหนดสมการดิฟเฟอเรนเชียลกับค่าสัมประสิทธิ์คงที่ซึ่งมีค่าเป็นดังสมการที่ 4.4 เพื่อหาค่าคงที่ของค่าน้ำหนัก เราใช้ตามสมการที่ 4.5

$$\frac{d}{dt}t_{ji} = 0 \quad (4.4)$$

$$t_{ji} = x_i \quad (4.5)$$

สมการดิฟเฟอเรนเชียลสำหรับค่าน้ำหนัก  $b_{ji}$  (Bottom-up) มีความจำเป็นเหมือนกันกับสมการของค่าน้ำหนัก  $t_{ji}$  (Top-down) ตามสมการที่ 4.6 อย่างไรก็ตามเพื่อที่จะให้ ART1 ตอบสนองที่สัมพันธ์กันกับรูปแบบ (ซึ่งอาจจะมีจำนวนที่แตกต่างกันขององค์ประกอบเป็น 1 มากกว่าที่จะเป็น 0) มันเป็นสิ่งสำคัญสำหรับทำให้ค่าน้ำหนัก  $b_{ji}$  (Bottom-up) คงที่ ตามสัดส่วนของกรอนอร์มอไรซ์เวกเตอร์ในการกระตุ้นเลขเซอร์  $F_i$  สิ่งนี้จะสามารถสำเร็จลงได้โดยใช้สมการที่ 4.7 ดังนั้นสมการดิฟเฟอเรนเชียลจะเป็นสมการที่ 4.8

$$\frac{d}{dt}b_{ij} = K_1[-E_{ij}b_{ij} + x_i] \quad (4.6)$$

$$E_{ij} = x_i + L^{-1} \sum_{k \neq i} x_k \quad (4.7)$$

และ

$$\frac{d}{dt}b_{ij} = KL \left[ -b_{ij}x_i - b_{ij}L^{-1} \sum_{k \neq i} x_k + x_i \right] \quad (4.8)$$

$$= K \left[ (1 - b_{ij})Lx_i - b_{ij} \sum_{k \neq i} x_k \right]$$

มันเป็นการสะดวกในการพิจารณาเหตุการณ์แยกกันเมื่อ  $F_i$  และ  $x_i$  ถูกกระตุ้น และไม่ถูกกระตุ้น (i) ถ้ายูนิต  $F_i$  ให้ค่า  $x_i$  ( $x_i = 0 \rightarrow$ ) ไม่ถูกกระทำจะได้สมการที่ 4.9 และ สมการดิฟเฟอเรนเชียลจะกลายเป็นสมการที่ 4.10 ก่อนหน้านี้ในสมการที่ 4.7 เพื่อที่จะหาค่าน้ำหนักที่คงที่ซึ่ง  $b_{ij} = 0$  เราทำการเขียนใหม่โดยค่า 0 และแก้ปัญหา  $b_{ij}$  ดังนั้นจะได้สมการที่ 4.11

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\sum_{k \neq i} x_k = \|x\| \quad (4.9)$$

$$\frac{d}{dt} b_{ij} = K \left[ -b_{ij} \sum_{k \neq i} x_k \right] = K [-b_{ij} \|x\|] \quad (4.10)$$

$$0 = K [-b_{ij} \|x\|] \quad (4.11)$$

(ii) ถ้ายูนิท  $F_i$  ให้ค่า  $x_i$  ( $x_i = 1 \rightarrow$ ) ถูกกระทำจะได้สมการที่ 4.12 จากนั้นสมการดิฟเฟอเรนเชียลจะเป็นดังสมการที่ 4.13 ซึ่งก่อนหน้านี้ได้หาค่าน้ำหนักที่คงที่ของ Bottom-up จะได้สมการที่ 4.14 เมื่อเราลองกำหนดค่าเป็น 0 แล้วทำการแก้ปัญหาค่าสำหรับ  $b_{ij}$  ผลลัพธ์ที่ได้จะเป็นดังสมการที่ 4.15 เพราะฉะนั้นผลรวมของค่าน้ำหนัก Top-down จะเป็นดังสมการที่ 4.16 และค่าน้ำหนัก Bottom-up จะเป็นดังสมการที่ 4.17 และค่าพารามิเตอร์ต่างๆ ที่ใช้ในอัลกอริทึมสำหรับฝึกสอน ART1 แสดงดังตารางที่ 4.1

$$\sum_{k \neq i} x_k = \|x\| - 1 \quad (4.12)$$

$$\frac{d}{dt} b_{ij} = K [(1 - b_{ij})L - b_{ij} (\|x\| - 1)] \quad (4.13)$$

$$b_{ij} = \frac{L}{L - 1 + \|x\|} \quad (4.14)$$

$$0 = K [(1 - b_{ij})L - b_{ij} (\|x\| - 1)] \quad (4.15)$$

$$t_{ji} = x_i \quad (4.16)$$

$$b_{ij} = \frac{Lx_i}{L - 1 + \|x\|} \quad (4.17)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.1 แสดงค่าพารามิเตอร์ที่ใช้ใน ART1

Parameter	Description
$n$	จำนวนโหนดของอินพุทเวกเตอร์
$m$	จำนวนคลัสเตอร์ที่ทำการรวมตัวได้สูงสุด
$b_{ij}$	ค่าน้ำหนัก Bottom-up จาก ยูนิต $F_1(b) X_i$ ไปยัง ยูนิต $F_2 Y_j$
$t_{ji}$	ค่าน้ำหนัก Top-down จาก ยูนิต $F_2 Y_j$ ไปยัง ยูนิต $X_i$
$\rho$	ค่าพารามิเตอร์ที่ใช้กำหนดขนาดของกลุ่มของคลัสเตอร์
$s$	ค่าไบนารีอินพุทเวกเตอร์
$x$	ค่าพารามิเตอร์ที่ได้รับการกระตุ้น
$\ x\ $	ผลรวมของ เวกเตอร์ $x_i$

Step 0 กำหนดพารามิเตอร์เริ่มต้น

$$L > 1,$$

$$0 < \rho \leq 1.$$

ค่าน้ำหนักเริ่มต้น

$$0 < b_{ij}(0) < \frac{L}{L-1+n}$$

$$t_{ji}(0) = 1$$

Step 1. While ตรวจสอบเงื่อนไขเป็นเท็จ, ทำขั้นตอน 2-13.

Step 2. ทำการฝึกสอนในแต่ละอินพุท, ทำขั้นตอน 3-12.

Step 3. ทำการกระตุ้นยูนิต  $F_2$   
ทำการกระตุ้นยูนิต  $F_1(a)$  ไปยังอินพุท  $s$ .

Step 4. นอร์มอไลซ์อินพุท  $s$

$$\|s\| = \sum_i s_i$$

Step 5. ส่งสัญญาณอินพุทเลเยอร์  $F_1(a)$  ไปยัง  $F_1(b)$

$$x_i = s_i$$

Step 6. ใน  $F_2$  แต่ละตัว  $\neq -1$

If  $y_i \neq -1$ , then

$$y_j = \sum_i b_{ij} x_i$$

Step 7. While ถ้ายูนิตรีเซ็ทเป็นจริง, ทำขั้นตอน 8-1

Step 8. หา YJ โดยที่  $y_j \geq y_j$  สำหรับทุกๆ ตัวของ j

If  $y_j = -1$ , then

กลับไปหาค่า  $y_j$  ใหม่

Step 9. ทำการคำนวณ  $F_1(b)$  ใหม่

$$x_i = s_i t_{ji}$$

Step 10. ทำการนอร์มอไลซ์ของ x

$$\|X\| = \sum_i x_i$$

Step 11. ทดสอบยูนิตรีเซ็ท

If  $\frac{\|X\|}{\|S\|} < \rho$  then

$y_j = -1$  กลับไปทำขั้นตอน 7

If  $\frac{\|X\|}{\|S\|} \geq \rho$

then ไปทำขั้นตอน 12

Step 12. ปรับปรุงค่าชุดน้ำหนักในแต่ละโหนดที่ชนะ J

$$b_{ij}(\text{new}) = \frac{Lx_i}{L-1+\|X\|}$$

$$t_{ji}(\text{new}) = x_i$$


Step 13. ทดสอบเงื่อนไขการปรับปรุงค่าน้ำหนักและกลับไปเริ่มต้นใหม่

## 4.2 อะแดปทีฟรีโซแนนซ์เทียรี ART2 [4]

โครงข่ายประสาทเทียมแบบอะแดปทีฟรีโซแนนซ์เทียรี ART2 ถูกออกแบบมาสำหรับค่าอินพุตที่ต่อเนื่อง (Continuous Valued) คล้ายกับการทำงานตาม ART1 ซึ่งทำงานโดยใช้ค่าอินพุตไบนารี ความแตกต่างระหว่าง ART2 และ ART1 มีผลเกี่ยวเนื่องกับการปรับปรุงค่าอินพุตให้เหมาะสมกับองค์ประกอบของค่าอินพุตที่ต่อเนื่อง มันมีความซับซ้อนมากในส่วนเลเยอร์  $F_1$  ของ ART2 ซึ่งมันจำเป็นต้องใช้ เพราะค่าอินพุตที่ต่อเนื่องอาจจะถูกใช้ร่วมกัน เลเยอร์  $F_1$  ใน ART2 จะถูกรวมอยู่ในองค์ประกอบของ นอร์มอลไลซ์เซชัน (Normalization) และ นอยส์ซัพเพรสชัน (Noise Suppression) ในการเพิ่มเติมส่วนที่จะเปรียบเทียบของชุดน้ำหนัก (Bottom up และ Top down) ซึ่งจำเป็นสำหรับในส่วนของ Reset Units มีสองประเภทของอินพุตที่ต่อเนื่องสำหรับที่ใช้ใน ART2 ข้อแรก


### 4.2.1 โครงสร้างของ ART2

โครงสร้างของ ART2 ได้แสดงในรูปที่ 4.4 เลเยอร์  $F_1$  ประกอบด้วยยูนิต 6 ประเภทได้แก่ ( $W_i, X_i, U_i, V_i, P_i$  และ  $Q_i$ ) โดยมียูนิตทั้งหมดเท่ากับ  $n$  ในแต่ละประเภท ( $n$  เป็นขนาดของรูปแบบอินพุต) ยูนิตย่อยระหว่างยูนิต  $W_i$  และ  $X_i$  ได้รับสัญญาณทั้งหมดจากยูนิต  $W$  ซึ่งทำการคำนวณ การนอร์มอลไลซ์ของเวกเตอร์  $w$  มันจะส่งสัญญาณไปยังยูนิต  $X_i$  แต่ละตัว และมันก็ยังจะได้รับสัญญาณกระตุ้นจากยูนิต  $W_i$  ด้วย ในรายละเอียดของส่วนนี้จะถูกแสดงในรูปที่ 4.5



รูปที่ 4.4 แสดงโครงสร้างของ ART2

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับกรใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.5 แสดงการเชื่อมต่อจากยูนิต W ไปยังยูนิต X ของ ART2

โดยยูนิตย่อยนี้ได้ทำบทบาทคล้าย ๆ กันกับยูนิตระหว่าง  $P_i$  และ  $Q_i$  รวมทั้งยูนิต  $V_i$  และ  $U_i$  ด้วย ในแต่ละยูนิต  $X_i$  และยูนิต  $Q_i$  จะถูกเชื่อมต่อไปยังยูนิต  $V_i$

สัญลักษณ์บนเส้นทางการเชื่อมต่อระหว่างยูนิตต่างๆ ในเลเยอร์  $F_1$  ตามรูปที่แสดง 4.4 ซึ่งให้เห็นว่าการส่งผ่านสัญญาณจะถูกส่งผ่านไปยังในแต่ละยูนิต อย่างไรก็ตามการเชื่อมต่อระหว่างยูนิต  $P_i$  และ  $Y_j$  ทำการแสดงค่าน้ำหนักซึ่งจะถูกคูณด้วยสัญญาณที่ถูกส่งไปบนเส้นทางเหล่านั้น ตัวกระตุ้นให้ยูนิต  $F_2$  เป็นโหนดขณะคือ  $d$  ซึ่งมีค่าระหว่าง  $0 < d < 1$  โดยฟังก์ชัน  $x$  และ  $q$  จะใช้ในการกระตุ้น และสัญลักษณ์  $\rightarrow$  บอกรหัสการทำงานออร์มอลิซ

การทำงานของเลเยอร์  $F_2$  ไม่จำเป็นต้องถูกเปลี่ยนจากการทำงานใน ART1 ยูนิตที่สมบูรณ์ใน Winner-Take-All โหมด สำหรับที่จะเรียนรู้ในแต่ละรูปแบบของอินพุตที่ต้องการเหมือนกับใน ART1 การเรียนรู้ที่เกิดขึ้นโดยค่าน้ำหนักเวกเตอร์ Top-Down มีค่าเพียงพอสำหรับค่าอินพุตเวกเตอร์ และการทดสอบการรีเซ็ทใน ART1 และ ART2 จะแตกต่างกัน

ยูนิต  $U_i$  ทำหน้าที่คล้ายกับอินพุตของเลเยอร์  $F_1$  ใน ART1 อย่างไรก็ตามใน ART2 บางขั้นตอนของอินพุตเป็นสิ่งจำเป็น เพราะค่าอินพุตที่มีขนาดใหญ่บางที่แตกต่างมากกว่าค่าอินพุตไบนารีใน ART1 ยูนิต  $P_i$  มีหน้าที่ทำการติดต่อกับยูนิต  $F_1$  ในโครงสร้างของ ART1 และในบทบาทของยูนิตย่อยใน ART1 ถูกรวมเข้าไปในเลเยอร์  $F_1$  รูปที่ 4.6 ได้ขยายรูปของเลเยอร์  $F_1$  ใน ART2 จากรูปที่ 4.4 ยูนิต  $X_i$  และ  $Q_i$  จะทำงานเมื่อได้รับค่าจากโครงข่ายอินพุตเหล่านั้น ฟังก์ชันย่อย ๆ เหล่านี้ทุก ๆ องค์ประกอบของเวกเตอร์ในการกระตุ้นให้ระดับนั้นต่ำลงมาโดยผู้เลือกค่า  $\theta$  โดยเส้นทางการเชื่อมต่อจาก  $W_i$  ถึง  $U_i$  และ จาก  $Q_i$  ถึง  $V_i$  ได้ทำการกำหนดค่าน้ำหนัก  $a$  และ  $b$  ตามลำดับ



รูปที่ 4.6 แสดงการขยายโครงสร้างในเลเยอร์  $F_1$  ของ ART2


4.2.2 อัลกอริทึมที่ใช้ในการสอน ART2

ค่าตัวแปรอินพุตที่ใช้ป้อนเข้าไป  $S = (s_1, \dots, s_i, \dots, s_n)$  และค่าเริ่มต้นของตัวแปรต่าง ๆ จะถูกกำหนดให้มีค่าเป็นศูนย์ การคำนวณภายในเลเยอร์  $F_1$  ค่ายูนิต  $U_i$  ถูกกระตุ้นให้ทำงานจากค่าเริ่มต้น (ซึ่งจะได้รับค่าที่ถูกกระตุ้นมาจากการนอร์มอลไลซ์ค่า  $V_i$ ) ถัดจากนั้นสัญญาณจะถูกส่งจากยูนิต  $U_i$  ไปยังยูนิต  $W_i$  และ  $P_i$  จากการกระตุ้นยูนิต  $W_i$  และ  $P_i$  จะเกิดการคำนวณ ยูนิต  $W_i$  จะรวมสัญญาณที่มันได้รับจากยูนิต  $U_i$  และสัญญาณอินพุต  $s_i$  ยูนิต  $P_i$  จะรวมสัญญาณที่ได้รับจากยูนิต  $U_i$  และค่าน้ำหนัก Top-Down ที่มันได้มาจากเลเยอร์  $F_2$  ถ้ามีการทำงานเกิดขึ้น การกระตุ้นให้ยูนิต  $X_i$  และ  $Q_i$  ทำการนอร์มอลไลซ์โดยได้รับสัญญาณจากยูนิต  $W_i$  และ  $P_i$  ตามลำดับ ในแต่ละยูนิตจะเกิดการคำนวณทุก ๆ ยูนิตก่อนที่สัญญาณจะถูกส่งไปยังยูนิต  $V_i$  จากนั้นยูนิต  $V_i$  ก็จะทำการรวมสัญญาณที่ได้รับมาจากยูนิต  $X_i$  และ  $Q_i$  พร้อม ๆ กัน และก็จะเป็นการสิ้นสุดในรอบของการปรับปรุงเลเยอร์  $F_1$  ฟังก์ชันที่ใช้ในการกระตุ้นยูนิต  $U_i$  และ  $P_i$  ให้ไปถึงจุดที่คงที่ หลังจากที่มีการปรับปรุงเลเยอร์  $F_1$  ดังสมการที่ 4.18 แล้วฟังก์ชันนี้จะทำการเปรียบเทียบทุก ๆ สัญญาณว่ามีค่าน้อยกว่า  $\theta$  หรือไม่ ถ้าเป็นก็จะกำหนดค่านั้นให้เป็นศูนย์ โดยค่าของตัวแปร  $\theta$  นี้จะถูกกำหนดโดยผู้ใช้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โครงข่ายนี้จะสมบูรณ์เมื่อคลัสเตอร์ยูนิตแรกถูกเลือกในแต่ละรูปแบบของอินพุต ได้มีการยอมรับ และไม่มีการ Reset เกิดขึ้น

$$f(x) = \begin{cases} x & \text{if } x \geq \theta \\ 0 & \text{if } x < \theta \end{cases} \quad (4.18)$$



รูปที่ 4.7 โฟลชาร์ตแสดงการทำงานโปรแกรมของ ART2

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หลังจากที่มีการกระตุ้นยูนิต  $F_1$  แล้ว ยูนิต  $P_i$  จะส่งสัญญาณเหล่านี้ไปยังเลเยอร์  $F_2$  โดยทำการแข่งขันกันในยูนิตคลัสเตอร์เพื่อเลือกผู้ที่ชนะเท่านั้น เป็นผู้ที่ได้รับการเรียนรู้รูปแบบของอินพุตนั้น ๆ ยูนิต  $U_i$  และ  $P_i$  ในเลเยอร์  $F_1$  ได้ส่งสัญญาณไปยังยูนิต  $R_i$  ด้วย (Reset) ซึ่งมันจะทำการตรวจสอบทุก ๆ ครั้งที่มันได้รับสัญญาณจาก  $P_i$  โดยได้รับค่ามาจากยูนิต  $U_i$  อย่างไรก็ตาม สิ่งเหล่านี้จะสำเร็จได้ก็ต่อเมื่อยูนิต  $P_i$  ได้รับสัญญาณค่าน้ำหนัก (Top-Down) และไม่มีการ Reset เกิดขึ้น ขั้นตอนการทำงานเหล่านี้ยังคงทำงานต่อเนื่องไป จนกระทั่งยูนิตคลัสเตอร์ที่มีการยอมรับได้ถูกเลือก โดยคลัสเตอร์ที่แข่งขันกันผ่านข้อจำกัดของการ Reset แล้วมีการเรียนรู้เกิดขึ้น

การเรียนรู้ในอะแดปทีฟริโซแนนทียรี (ART) ประกอบด้วยในส่วนของรูปแบบที่ใช้เป็นอินพุต ในการกระตุ้นให้ฟังก์ชันทั้งหมดที่อยู่ในโครงข่ายให้ทำงานจะกำหนดค่าเริ่มต้นให้เป็นศูนย์ และยูนิตที่อยู่ในเลเยอร์  $F_2$  ยังไม่ทำงาน เมื่อกำหนดอินพุตนั้นได้ถูกแสดงขึ้นมาและมันก็จะเป็นสัญญาณอินพุตที่ถูกส่งไปอย่างต่อเนื่องจนกระทั่งการเรียนรู้ได้สิ้นสุดลงอย่างสมบูรณ์ ผู้ใช้จะเป็นผู้กำหนดค่าพารามิเตอร์โดยขึ้นอยู่กับรูปแบบค่าอินพุตที่ใช้ การควบคุมยูนิตรีเซทของ ART1 และ ART2 โดยมันจะทำหน้าที่ในการควบคุมสถานะของแต่ละโหนดในเลเยอร์  $F_2$

### ที่มาของสมการที่ใช้ในการเรียนรู้ ART2

สมการเหล่านี้ได้ถูกนำมาปรับปรุงใหม่โดย Grossberg และ Carpenter สำหรับรูปแบบทั่วๆ ไปของสมการดิฟเฟอเรนเชียลสำหรับใช้กระตุ้นในการตัดสินใจยูนิต  $z$  ในเลเยอร์  $F_1$  เป็นดังสมการที่ 4.19 เมื่อ  $A$  เป็นค่าคงที่ที่เป็นบวก  $J^+$  เป็นค่าที่ใช้ในการกระตุ้นอินพุตทั้งหมดไปยังยูนิต และ  $J^-$  เป็นค่าที่ใช้ในการยับยั้งอินพุตทั้งหมดไปยังยูนิต ในโครงข่ายของ ART ได้ทำการสมมุติในการทำให้เปลี่ยนการกระตุ้นให้มีความเร็วมากกว่ากระบวนการอื่นๆ ฉะนั้นการกระตุ้นจะมาถึงจุดที่คงที่ก่อนที่สัญญาณอินพุตทุกสัญญาณจะมีการเปลี่ยนแปลง สิ่งนี้จะนำไปสู่รูปแบบทั่วๆ ไปของสมการสำหรับการกระตุ้นให้เกิดไปสู่จุดคงที่ดังสมการที่ 4.20 เราได้เลือกค่า  $A$  เพื่อให้ได้มาซึ่งรูปแบบสมการในการกระตุ้นที่ง่ายๆ สำหรับยูนิตที่ได้รับสัญญาณอินพุตที่ไม่ได้ถูกยับยั้งเราให้  $A = 1$  ตัวแสดงค่าอินพุตที่ไม่ได้ถูกยับยั้งดังรูปที่ 4.4 ไปตามลูกศร ฉะนั้นยูนิต  $W_i$  จะได้รับค่าอินพุตที่ไม่ถูกยับยั้ง ค่าอินพุตที่เข้ามากระตุ้นเหล่านี้ที่มาจากยูนิต  $U_i$  และสัญญาณอินพุต  $s_i$  ดังนั้นการกระตุ้นไปสู่จุดคงที่สำหรับยูนิต  $W_i$  จะแสดงดังสมการที่ 4.21 เหมือนกับว่ายูนิต  $P_i$  จะได้รับสัญญาณกระตุ้นจากยูนิต  $U_i$  และยูนิต  $F_2$  โดยการกระตุ้นของยูนิต  $F_2$  จะมีค่าเป็น 0 และ  $d$  ก็จะมีค่าเป็น 0 ถ้ามันยังไม่ได้ทำงาน เราได้แสดงยูนิตของผู้ชนะโดยใช้สัญลักษณ์  $J$  เพื่อที่ว่ากระตุ้นจนกระทั่งคงที่สำหรับยูนิต  $P_i$  จะแสดงดังสมการที่ 4.22 ที่  $t_{ii}$  เป็นค่าน้ำหนัก Top-down จากยูนิต  $Y_i$  ไปยังยูนิต  $P_i$  ถ้าไม่เกิดการดำเนินงานในยูนิต  $F_2$  การกระตุ้นของยูนิต  $P_i$  จะมีค่าดังสมการที่ 4.23

$$\frac{dz}{dt} = -Az + J^+ - zJ^- \quad (4.19)$$

$$z = \frac{J^+}{A + J^-} \quad (4.20)$$

$$w_i = s_i + au_i \quad (4.21)$$

$$p_i = u_i + dt_{ji} \quad (4.22)$$

$$p_i = u_i \quad (4.23)$$

บทบาทของตัวขับเคลื่อนใน ART2 จะเป็นการนอร์มอไลซ์ในการกระตุ้นที่ตำแหน่งวนรอบการคำนวณ สำหรับยูนิตที่ได้รับอินพุตที่ถูกลบยั้งเราจะแทนค่า A ให้มีค่าเท่ากับตัวแปร e ที่มีค่าน้อยๆ สิ่งนี้จะเป็นตัวป้องกันกรณีที่ไม่ได้รับสัญญาณอินพุตเข้ามา แต่จะยอมให้ยูนิตทำการนอร์มอไลซ์ตามความยาวของยูนิต ในแต่ละยูนิต  $X_i$  ที่ได้รับสัญญาณการกระตุ้นจากยูนิต  $W_i$  และสัญญาณที่ยับยั้งจะมีค่าเท่ากับการนอร์มอไลซ์ของเวกเตอร์ที่ใช้ในการกระตุ้นในยูนิต  $W_i$  ฉะนั้นจะได้สมการเป็นดังที่ 4.24 คล้ายๆ กับว่าในแต่ละยูนิต  $Q_i$  ได้รับสัญญาณกระตุ้นจากยูนิต  $P_i$  และสัญญาณยับยั้งจะเท่ากับการนอร์มอไลซ์ของเวกเตอร์ที่ได้รับการกระตุ้นจากยูนิต  $P_i$  ซึ่งจะทำได้รูปแบบที่เหมือนกันกับสมการการกระตุ้นของยูนิต  $Q_i$  ดังสมการที่ 4.25 สำหรับยูนิต  $V_i$  เราให้ A มีค่าเท่ากับ 1 และยูนิต U เราให้ A มีค่าเท่ากับ e ตามที่ได้อธิบายมาก่อนหน้านี้สำหรับยูนิตในเลเยอร์  $F_1$  จะได้สมการที่ 4.26

$$x_i = \frac{w_i}{e + \|W\|} \quad (4.24)$$

$$q_i = \frac{p_i}{e + \|P\|} \quad (4.25)$$

$$v_i = f(x_i) + bf(q_i), \quad u_i = \frac{v_i}{e + \|V\|} \quad (4.26)$$

สมการดิฟเฟอเรนเชียลที่ใช้ในการปรับเปลี่ยนค่าน้ำหนักสำหรับค่าน้ำหนัก Top-down ซึ่งแสดงเป็น  $J$  คือยูนิตกลิตเตอร์ที่ขณะดังสมการที่ 4.27 คล้ายๆ กันสมการดิฟเฟอเรนเชียลค่าน้ำหนัก Bottom-up ดังสมการที่ 4.28 และสมการที่ใช้ในการรีเซ็ตแสดงดังสมการที่ 4.29 สิ่งนี้แสดงให้เห็นว่าถ้ายูนิต  $F_2$  ได้เลือกกลิตเตอร์ที่ชนะแล้วก็จะไม่จำเป็นในการตรวจสอบมันอีก ซึ่งต้องการเพียงว่า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หลังจากผู้ชนะได้ยอมรับในการเรียนรู้แล้วก็จะไม่มียูนิตรีเซทที่จะสามารถยับยั้งการยอมรับนั้น เพื่อที่จะวิเคราะห์ในการระวาง ซึ่งเป็นสิ่งจำเป็นเพื่อที่จะไม่ให้เกิดเหตุการณ์นั้นขึ้น เราได้ทำการพิจารณาทำการเปลี่ยนแปลงใน  $\|r\|$  ระหว่างการเรียนรู้ที่เป็นไปได้ ภายหลังจากยูนิต  $F_2$  ได้รับเลือกเป็นผู้ชนะแล้ว  $p = u + dt$  เพราะฉะนั้น  $\|r\| = \frac{\|u + cp\|}{\|u + c\|p\|}$  จะได้สมการที่ 4.30

$$\frac{d}{dt}t_{ji} = du_i + d(d-1)t_{ji} \quad (4.27)$$

$$t_{ji}(\text{new}) = \alpha du_i + [1 + \alpha d(d-1)]t_{ji}(\text{old})$$

$$\frac{d}{dt}b_{ij} = du_i + d(d-1)b_{ij} \quad (4.28)$$

$$b_{ij}(\text{new}) = \alpha du_i + [1 + \alpha d(d-1)]b_{ij}(\text{old})$$

$$\|r\| = \frac{\|u + cp\|}{\|u + c\|p\|} \quad (4.29)$$

$$\|r\| = \frac{\|(1+c)u + cdt\|}{1+c\|u + dt\|} \quad (4.30)$$

มันเป็นความต้องการที่ว่ายูนิตที่ชนะได้ยอมรับโดยยูนิตรีเซทแล้ว ซึ่งมันจะไม่ถูกปฏิเสธระหว่างการเรียนรู้ เราเห็นว่า  $\|r\| = 1/(1-d)$  ถ้าค่าน้ำหนักได้รับการเรียนรู้ในรูปแบบก่อนหน้านี้ อย่างไรก็ตาม  $\|r\|$  จะมีค่าลดลงระหว่างการฝึกสอนก่อนที่จะย้อนกลับไปยัง  $1/(1-d)$  ตั้งแต่ค่าที่น้อยที่สุดของ  $\|r\|$  เกิดขึ้นสำหรับ  $X_{\min}$  (ซึ่งมีค่ามากกว่า 1) เราสามารถทำให้แน่ใจได้ว่า  $\|r\|$  จะไม่ลดค่าลงระหว่างการฝึกสอนตรงเท่าที่ค่าเริ่มต้นของ  $X$  มีค่าน้อยกว่า 1 ถ้าสิ่งนี้ได้รับการรับรองดังนั้น  $\|r\|$  จะเพิ่มขึ้นถ้า  $\|r\|$  จะมีค่าลดลง โดยที่ค่าเริ่มต้นของ  $X$  จะมีค่าน้อยกว่า 1 ดังสมการที่ 4.31 ค่าเริ่มต้นที่ใช้สำหรับค่าน้ำหนัก Top-down เราได้กำหนดค่าเริ่มต้นให้เป็น 0 เพื่อป้องกันการรีเซท เมื่อยูนิตคลาสเตอร์ไม่ได้มีการเรียนรู้ในรูปแบบก่อนหน้า และถ้ามันได้เลือกคลาสเตอร์ที่เป็นผู้ชนะค่าน้ำหนักของ Top-down ก็จะมีค่าไม่เป็น 0 การนอร์มอไลซ์ค่าเริ่มต้นของค่าน้ำหนัก Bottom-up สำหรับทุกๆ ยูนิตควรมีค่าน้อยกว่าหรือเท่ากับ  $1/(1-d)$  ซึ่งมันเป็นการนอร์มอไลซ์ค่าน้ำหนักหลังจากการฝึกสอน ถ้าการนอร์มอไลซ์ของค่าน้ำหนัก Bottom-up เริ่มต้นมีค่ามากกว่าการนอร์มอไลซ์ค่าน้ำหนักหลังจากการเรียนรู้ จากนั้นค่าน้ำหนักก็จะลดค่าลงระหว่างการเรียนรู้และจะได้ค่าผู้ชนะอันใหม่ทันทีที่ได้เลือก ค่าน้ำหนัก Bottom-up ที่ใช้ในการเริ่มต้นมีค่าเท่ากับสมการที่ 4.32

$$\frac{cd}{1-d} < 1 \quad (4.31)$$

$$b_{ij}(0) = \frac{1}{(1-d)\sqrt{n}} \quad (4.32)$$

ค่าพารามิเตอร์ ที่ใช้ในอัลกอริทึมของ ART2 แสดงดังตารางที่ 4.2

ตารางที่ 4.2 แสดงค่าพารามิเตอร์ที่ใช้ใน ART2

Parameter	Description
n	จำนวน โหนดยูนิตอินพุต ( $F_1$ layer)
m	จำนวนของ ยูนิตคลัสเตอร์ ( $F_2$ layer)
a,b	ค่าพารามิเตอร์ร่วมในชุดค่าน้ำหนัก
d	ค่าพารามิเตอร์ใช้กระตุ้นผู้ชนะในยูนิต $F_2$
e	เป็นค่าพารามิเตอร์ที่ใช้ป้องกันการหาร ที่เป็นศูนย์
$\theta$	ค่าพารามิเตอร์ที่ใช้ในการจำกัดค่า ที่เป็น Noise
$\alpha$	ค่าพารามิเตอร์ที่ใช้ปรับเปลี่ยนในการเรียนรู้
$\rho$	ค่าพารามิเตอร์ที่ใช้กำหนดการรวมกลุ่มของ คลัสเตอร์
$t_{ji}$	ค่าน้ำหนัก Top-down
$b_{ij}$	ค่าน้ำหนัก Bottom-up

Step 0. ค่าตัวแปรเริ่มต้น

a, b,  $\theta$ , c, d, e,

Step 1. ทำขั้นตอน 2-12

Step 2. คำนวณแต่ละค่าอินพุต, ทำขั้นตอน 3-11.

Step 3. ทำการปรับค่ากระตุ้นใน  $F_1$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\begin{aligned} u_i &= 0, & q_i &= 0, \\ w_i &= s_i, & p_i &= 0, \\ v_i &= f(x_i), & x_i &= \frac{s_i}{e + \|s\|}, \end{aligned}$$

ปรับปรุงยูนิต  $F_1$  อีกครั้งหนึ่ง

$$u_i = \frac{v_i}{e + \|v\|}, \quad w_i = s_i + au_i,$$

$$p_i = u_i, \quad x_i = \frac{w_i}{e + \|w\|},$$

$$q_i = \frac{p_i}{e + \|p\|}, \quad v_i = f(x_i) + bf(q_i),$$

Step 4. คำนวณค่าที่ได้ไปยังยูนิต  $F_2$

$$y_j = \sum_i b_{ij} p_i$$

Step 5. ในขณะที่ทดสอบการรีเซ็ต ถ้าเป็นจริงทำขั้นตอนที่ 6-7

Step 6. หาค่า  $Y_j$  ในยูนิต  $F_2$  ซึ่งมีค่ามากที่สุด  
 $y_j \geq y_j$  for  $j = (1, \dots, m)$ .

Step 7. ตรวจสอบเงื่อนไขการรีเซ็ต

$$u_i = \frac{v_i}{e + \|v\|},$$

$$p_i = u_i + dt_{ji},$$

$$r_i = \frac{u_i + cp_i}{e + \|u\| + c\|p\|}$$

If  $\|r\| < -e$ , then

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
 ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$y_j = -1$$

ถ้ารีเซตเป็นจริงกลับไปทำขั้นตอนที่ 5 ใหม่

If  $\|r\| \geq \rho - e$ , then

$$w_i = s_i + au_i,$$

$$x_i = \frac{w_i}{e + \|w\|},$$

$$v_i = f(x_i) + bf(q_i),$$

$$q_i = \frac{p_i}{e + \|p\|},$$

ถ้ารีเซตเป็นเท็จ ไปทำขั้นตอนที่ 8

Step 8.

ทำขั้นตอนที่ 9-11 โดยกำหนดจำนวนในการเรียนรู้

Step 9.

ปรับปรุงชุดค่านำหนักสำหรับยูนิตที่ชนะ  $j$

$$t_{ji} = adu_i + \{1 + cd(d-1)\}t_{ji},$$

$$b_{ji} = adu_i + \{1 + cd(d-1)\}b_{ji}.$$

Step 10. ปรับปรุงค่าที่ใช้ในการกระตุ้น  $F_i$

$$u_i = \frac{v_i}{e + \|v\|},$$

$$w_i = s_i + au_i,$$

$$p_i = u_i + dt_{ji}$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$x_i = \frac{w_i}{e + \|w\|},$$

$$q_i = \frac{p_i}{e + \|p\|},$$

$$v_i = f(x_i) + bf(q_i),$$

Step 11. ทดสอบเงื่อนไขของค่านำหนักในการปรับปรุง

Step 12. ทดสอบเงื่อนไขเพิ่มเติมในการฝึกสอน



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 5

### ผลการทดลอง


การทดลองนี้เป็นการจำแนกข้อมูลภาพด้วยโครงข่ายประสาทเทียมแบบ ART ซึ่งเป็นการทำคลัสเตอร์ริง (Clustering) วิธีหนึ่ง โดยมี ART1 ใช้ข้อมูลอินพุทเป็นแบบไบนารี และ ART2 เป็นแบบข้อมูลต่อเนื่องซึ่งเป็นการเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) โดยในการทดลองนี้ เราได้ใช้ภาพจากดาวเทียม ADEOS บริเวณกรุงเทพฯ และภาพถ่ายจากดาวเทียม LANDSAT-5 ของจังหวัดชุมพร ประเทศไทย โดยจะนำภาพที่ได้ทำการจำแนกจากโปรแกรม มาทำการเปรียบเทียบกับภาพที่ได้สำรวจแล้วจากผู้เชี่ยวชาญ และภาพที่มีการเปลี่ยนค่าตัวแปรต่างๆ ทำการเปรียบเทียบระหว่าง ART1 กับ ART2

#### 5.1 ผลการทดลองกับภาพถ่ายดาวเทียม ADEOS


เราได้้นำภาพถ่ายดาวเทียม บริเวณกรุงเทพฯ เขตดอนเมือง ดังรูปที่ 5.1 มาทำการทดสอบจากรูปที่ 5.1 ซึ่งเป็นภาพ 3 แบนด์ ขนาด 256 x 256 พิกเซล โดยผลการทดลองที่ได้จะแสดงดังรูปที่ 5.2 ด้วยวิธีการของ ART1 โดยมีค่าพารามิเตอร์ที่ใช้ในอัลกอริทึมประกอบ และ ผลการทดลองดังรูปที่ 5.3 ด้วยวิธีของ ART2 ส่วนในรูปที่ 5.4 และ 5.5 แสดงการเพิ่มจำนวนคลัสเตอร์ของทั้งสองวิธี



รูปที่ 5.1 ภาพถ่ายจากดาวเทียมบริเวณกรุงเทพฯ ที่ใช้ในการฝึกสอน




รูปที่ 5.2 ผลการจำแนกภาพบริเวณกรุงเทพฯ ด้วย ART1




รูปที่ 5.3 ผลการจำแนกภาพบริเวณกรุงเทพฯ ด้วย ART2

จากผลการทดลองที่ได้แสดงดังรูปที่ 5.2 ผลการจำแนกโดยใช้วิธีของ ART1 โดยที่ค่าพารามิเตอร์ที่ใช้  $L = 3$ ,  $\rho = 0.2$ ,  $n = 24$  และจำนวนคลัสเตอร์ที่ได้แบ่งออกเป็น 5 คลัสเตอร์ ซึ่งสังเกตได้จากภาพจะประกอบไปด้วย สี แดง สีส้ม สีเหลือง สีเขียว และสีดำ อย่างเห็นได้ชัด

จากรูปที่ 5.3 แสดงผลการจำแนกด้วย ART2 โดยค่าพารามิเตอร์ที่ใช้  $a = 10$ ,  $b = 10$ ,  $\theta = 0.05$ ,  $c = 0.1$ ,  $d = 0.9$ ,  $e = 0.1$ ,  $\alpha = 0.5$   $\rho = 0.4$  และจำนวนคลัสเตอร์ที่ได้จากรูปคือ 4 คลัสเตอร์ ซึ่งประกอบด้วย สีน้ำเงิน สีส้ม สีเขียว และสีแดง โดยคลัสเตอร์ที่ได้เมื่อเปรียบเทียบกับวิธี ART1จะมีจำนวนคลัสเตอร์น้อยกว่า และการจำแนกกลุ่มที่มีความคล้ายกันหรือซับซ้อนได้ไม่ดี เช่น สีแดงเห็นไม่ชัดเจน แต่ภาพที่ได้จาก ART2 สามารถเห็นขอบเขตหรือลักษณะของภาพได้ชัดเจน



รูปที่ 5.4 ผลการจำแนกภาพด้วย ART1 ด้วยการเพิ่มจำนวนคลัสเตอร์




รูปที่ 5.5 ผลการจำแนกภาพด้วย ART2 โดยการเพิ่มจำนวนคลัสเตอร์


จากผลการทดลองที่ได้ในรูปที่ 5.4 โดยการเพิ่มจำนวนคลัสเตอร์เป็น 7 คลัสเตอร์ โดยมีค่าพารามิเตอร์เท่าเดิม แสดงให้เห็นว่าใน ART1 เราสามารถทำการควบคุมจำนวนคลัสเตอร์ได้ แต่เมื่อจำนวนคลัสเตอร์สูงขึ้นจะทำให้ภาพดูได้ไม่ชัดเจน จากรูปที่ 5.5 ได้ทำการทดลองเพิ่มจำนวนคลัสเตอร์ เป็น 7 คลัสเตอร์ โดยใช้ค่าพารามิเตอร์เท่าเดิม ด้วยวิธี ART2 สังเกตภาพที่ได้เมื่อเปรียบเทียบกับรูปที่ 5.4 แสดงให้เห็นว่าจำนวนคลัสเตอร์ไม่ได้เพิ่มขึ้นตามที่ต้องการ

## 5.2 ผลการทดลองกับภาพถ่ายดาวเทียม LANSAT-5


ภาพที่ 5.6 เป็นภาพที่นำมาทดสอบภาพหนึ่ง ซึ่งเป็นภาพถ่ายจากดาวเทียม LANDSAT-5 บริเวณจังหวัดชุมพร ซึ่งเป็นภาพ ขนาด 256 x 256 พิกเซล ประกอบด้วยแบนด์ 1(a), 4(b), 5(c), 7(d) โดยผลการทดลองที่ได้แสดงดังรูปที่ 5.7, 5.8 ด้วยวิธี ART1 และ รูปที่ 5.9, 5.10 ด้วยวิธี ART2



รูปที่ 5.6 ภาพถ่ายดาวเทียมบริเวณจังหวัดชุมพร




รูปที่ 5.7 ผลการจำแนกภาพบริเวณจังหวัดชุมพรด้วย ART1




รูปที่ 5.8 ผลการจำแนกภาพบริเวณจังหวัดชุมพรด้วย ART1 โดยเพิ่มจำนวนคลัสเตอร์

จากผลการทดลองที่ได้จากรูปที่ 5.7 จำแนกภาพด้วยวิธี ART1 พารามิเตอร์ที่ใช้  $L = 2$ ,  $\rho = 0.2$ ,  $n = 32$  โดยจำนวนคลัสเตอร์ที่ได้ทั้งหมดคือ 5 คลัสเตอร์

จากรูปที่ 5.8 ได้เป็นการ เพิ่มจำนวนคลัสเตอร์ขึ้นเป็น 7 คลัสเตอร์ด้วยวิธี ART1 ซึ่งแสดงให้เห็นว่า ART1 สามารถเพิ่มจำนวนคลัสเตอร์ได้ แต่เนื่องจากจำนวนคลัสเตอร์มีมากเกินไปทำให้ภาพออกมาดูได้ยากกว่า รูปที่ 5.8




รูปที่ 5.9 แสดงผลการจำแนกภาพบริเวณจังหวัดชุมพรด้วย ART2



รูปที่ 5.10 ผลการจำแนกภาพบริเวณจังหวัดชุมพร ART2 โดยเพิ่มจำนวนคลัสเตอร์

จากรูปที่ 5.9 จำแนกภาพด้วยวิธี ART2 ค่าพารามิเตอร์ที่ใช้  $a = 10$ ,  $b = 10$ ,  $\theta = 0.1$ ,  $c = 0.1$ ,  $d = 0.9$ ,  $e = 0.1$ ,  $\alpha = 0.2$   $\rho = 0.4$  และจำนวนคลัสเตอร์ที่ได้เท่ากับ 4 คลัสเตอร์ ซึ่งก็ประกอบไปด้วย สีแดง สีเขียว สีเหลือง สีม่วง โดยรูปที่ได้ก็มีลักษณะเห็นขอบเขตภาพได้เด่นชัด เมื่อเปรียบเทียบกับภาพที่จำแนกด้วย ART1 จะเห็นว่าภาพที่ได้ดีกว่า แต่จำนวนคลัสเตอร์ที่ได้น้อยกว่า

จากรูปที่ 5.10 ได้เป็นการทดลองเพิ่มจำนวนคลัสเตอร์ เป็น 7 คลัสเตอร์โดยผลที่ได้แสดงให้เห็นว่า การจำแนกข้อมูลด้วยวิธี ART2 ไม่สามารถเพิ่มจำนวนคลัสเตอร์ และก็ไม่สามารถจำแนกภาพที่มีความคลุมเคลือสูงได้เมื่อเปรียบเทียบกับ ART1 แต่เมื่อพิจารณาจากภาพที่ได้จะสังเกตเห็นว่า ขอบเขตหรือจุดต่อ จุดเว้าต่างๆ ของภาพก็ได้ให้รายละเอียดได้ดี



รูปที่ 5.11 ภาพจังหวัดชุมพรโดยทำการจำแนกจากผู้เชี่ยวชาญ

จากผลการทดลองที่ได้ ในการจำแนกภาพด้วย ART1 ภาพที่ได้จะสามารถแยกกลุ่มของภาพที่ใกล้เคียงกันออกมาได้ สังเกตได้จากรูปที่ 5.2 ซึ่งเมื่อเทียบกับรูปต้นแบบ ART1 สามารถแยกสีที่แตกต่างกันออกมาได้ และในรูปที่ 5.7 ก็เช่นกัน สามารถแยกในส่วนที่เป็นสีน้ำตาลออกมาได้ เมื่อเทียบกับรูปที่ 5.11 คือส่วนสีเขียว ซึ่งสิ่งเหล่านี้ไม่มีใน ART2 แต่ใน ART2 ก็มีข้อดีที่ว่าสามารถจำแนกภาพที่เห็นขอบเขตที่ชัดเจนกว่าใน ART1

## บทที่ 6

### บทสรุป

ในงานวิจัยนี้ ได้ทำการทดลองจำแนกภาพถ่ายดาวเทียมด้วยวิธีการ โครงข่ายประสาทเทียมแบบอะเคปทีพีรีโซแนซ (ART) ซึ่งแบ่งออกเป็น 2 ประเภทคือ ART1 และ ART2 โดยค่าอินพุตที่ถูกป้อนเข้าไปเป็นไบนารีสำหรับ ART1 และเป็นจำนวนเต็มต่อเนื่องสำหรับ ART2 ซึ่งการจำแนกภาพด้วยวิธีเหล่านี้ จะต้องมีการฝึกสอนข้อมูลให้เกิดการเรียนรู้และจดจำลักษณะของข้อมูลนั้นๆ ได้ โดยการฝึกสอนเป็นแบบไม่มีผู้สอน หมายถึงจะต้องแข่งขันกันเรียนรู้ (competitive learning) ให้ได้ผู้ชนะจนกระทั่งค่าการเปลี่ยนแปลงคงที่มากที่สุด ซึ่งหลังจากนั้นจะเก็บข้อมูลที่รู้จำนั้นไว้เป็นค่าถ่วงน้ำหนัก และสามารถนำไปใช้จำแนกข้อมูลในลักษณะเดียวกันได้ในครั้งต่อไป ซึ่งก็จะช่วยให้การวิเคราะห์ข้อมูลนั้นเร็วขึ้น

จากผลการทดลองที่ได้ จะสังเกตเห็นได้ว่าภาพที่ถูกจำแนกด้วย ART1 จะสามารถจำแนกภาพที่มีความคลุมเครือหรือภาพที่มีความคล้ายคลึงกันมากๆ ได้ดีกว่า ART2 เนื่องจากว่าข้อมูลที่ เป็นแบบไบนารีจะมีความแตกต่างระหว่างข้อมูลน้อยกว่าวิธีของ ART2 ซึ่งข้อมูลจำนวนเต็มที่ต่อเนื่องจะมีค่าความแตกต่างกันมากกว่า และค่าพารามิเตอร์ต่างๆ ก็มีความสำคัญเพราะจะต้องถูกนำไปใช้ในการคำนวณด้วย โดยค่าของพารามิเตอร์ต้องทำการปรับเปลี่ยนให้เหมาะสม เพื่อให้ได้ภาพที่จำแนกได้ดีที่สุด ซึ่งค่าพารามิเตอร์ที่ได้ใช้ในผลการทดลองก็เป็นค่าที่ได้ปรับเปลี่ยนจนกระทั่งได้ภาพที่แสดงในผลการทดลอง ทั้งนี้ก็ขึ้นอยู่กับภาพที่ใช้ ขนาดของภาพ และคุณภาพของภาพที่ถ่าย ซึ่งก็จะส่งผลให้ค่าเวลาที่ใช้ในการฝึกสอนเร็วหรือช้าได้ โดยจากการทดลองได้ใช้เวลาไม่นานในการฝึกสอน จากภาพที่ใช้ทดสอบ และ ART1 ก็ใช้เวลาน้อยกว่า ART2 ด้วย ซึ่งก็เป็นผลมาจากที่มีค่าระยะห่างของข้อมูลน้อยกว่า และสิ่งที่เห็นได้ชัดเจนอีกอย่างหนึ่งก็คือจำนวนคลัสเตอร์ใน ART1 ซึ่งเราสามารถที่จะควบคุมได้ดีกว่าใน ART2

วิธีการของนิวรัลเน็ตเวิร์คอะเคปทีพีรีโซแนซเทียมนี้นี้ยังมีข้อดีอีกที่ว่า เนื่องจากการเรียนรู้แบบไม่ต้องมีผู้ฝึกสอนจึงไม่ต้องหาข้อมูลที่ถูกต้องมาใช้ฝึกสอน ซึ่งในบางกรณีนั้นอาจจะต้องเสียค่าใช้จ่ายมากในการหาข้อมูลนั้นมา และมันยังสามารถนำเอาข้อมูลที่เรียนรู้แล้วนำกลับมาใช้ใหม่ได้

สรุปว่าการจำแนกภาพด้วยวิธีนิวรัลเน็ตเวิร์คอะเคปทีพีรีโซแนซนี้ สามารถจำแนกภาพที่มีความคลุมเครือของภาพได้ โดยค่าระยะห่างของข้อมูลที่เป็นค่าอินพุตถ้ามีค่าน้อยก็จะช่วยให้คุณภาพของภาพออกมาดีใน ART1 ซึ่งก็จะใช้เวลาในการฝึกสอนน้อยกว่าใน ART2 แต่ทั้งนี้ก็ขึ้นอยู่กับภาพที่นำมาใช้เป็นตัวแทนด้วย ประกอบกับการทดสอบหาค่าพารามิเตอร์ที่เหมาะสมมาใช้ในการคำนวณให้กับภาพนั้นๆ และวิธีการจำแนกภาพก็จะเห็นได้ว่าใน ART1 สามารถที่จะกำหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จำนวนคลัสเตอร์ที่ต้องการได้ แต่ใน ART2 เราไม่สามารถที่จะกำหนดจำนวนคลัสเตอร์ได้ และควรเลือกใช้จำนวนคลัสเตอร์ที่เหมาะสมกับภาพนั้นๆ โดยจากผลที่ได้เราเลือกกำหนดจำนวนคลัสเตอร์เท่ากับ 5 เพื่อให้เห็นลักษณะของภาพได้ชัดเจน



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## เอกสารอ้างอิง

- [1] คาราศรี ดาวเรือง. รีโมทเซนซิงพื้นฐาน. กรุงเทพฯ: สมาคมส่งเสริมเทคโนโลยี (ไทย-ญี่ปุ่น) และ สถาบันเทคโนโลยีพระจอมเกล้าธนบุรี. 2533.
- [2] สำนักงานคณะกรรมการวิจัยแห่งชาติ. คำบรรยายเรื่องการสำรวจจากระยะไกล. กรุงเทพฯ : โรงพิมพ์คุรุสภาลาดพร้าว. 2540.
- [3] Richards, J. A. **Remote Sensing Digital Image Analysis**. Springer Verlag, New York : 1994.
- [4] Fausett L. **Fundamentals of Neural Network, Architecture, Algorithm and Application.**, New Jersey : Prentice-Hall. 1994.
- [5] Lippmann R.P. **An Introduction to Computing with Neural Networks**. USA : Addison Wesley. 1989.
- [6] Yoh-Han P. **Adaptive Pattern Recognition and Neural Network**. USA : Addison Wesley. 1989.
- [7] Bischof H., Scheccider W., and Pinz A.J. "Multispectral Classification of Landsat Images Using Neural Networks." **IEEE Trans Geoscience and Remote Sensing**, vol. 30, no. 3, May 1992. pp. 482-490.
- [8] Carpenter G.A., Grossberg S., and D.B. "ART 2-A : An Adaptive Resonance algorithm for rapid category learning and recognition." **Neural network**. Vol. 4, 1991. pp. 493-504.
- [9] Capenter G. A. and Grossberg S. "The ART of Adaptive Pattern Recognition by Self-prganizing neural network", **IEEE Computer**. Vol. 21, No. 3, March 1998. pp. 77-88.
- [10] Heermann P.D. and Khozenie N. "Classification of Multispectral Remote Sensing Data Using a Back-Propagation Neural Network." **IEEE Trans On Geoscience and Remote Sensing** vol. 30, Jan. 1992. pp. 81-88.
- [11] Mark B. and Howard D. **Neural Network Toolbox for use with Matab**. Mass : The Math Works, Inc. 1996.



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## ภาคผนวก ก.

## ตารางแสดงรายละเอียดของดาวเทียม

## ADEOS, JERS – 1 และ MOS – 1

ตารางแสดงรายละเอียดของดาวเทียม JERS-1 และ MOS-1

ดาวเทียม	องค์ประกอบวงโคจร	เครื่องวัดในการสำรวจ			
		ชื่อเครื่องวัด	ช่วงคลื่น/ความถี่	มุมมอง สนาม ฃ ขณะนั้น	ความกว้าง ของแนว ถ่ายภาพ
JERS-1	สัมพันธ์กับดวงอาทิตย์ ระดับสูง : 568 ก.ม. มุมมอง : 98 องศา โคจรกลับมาที่จุดเดิม : 44 วัน	OPS (Optical Sensor) VINR (Visible and Near Infrared Radiometer) เครื่องวัดคลื่นที่ ตามองเห็นและอินฟราเรด ใกล้	0.52 – 0.60 ไมโครเมตร 0.63 – 0.69 ไมโครเมตร 0.76 – 0.86 ไมโครเมตร	18 x 24 ม.	75 กม.
		SWIR (Short Wavelength Infrared Radiometer) เครื่อง วัดคลื่นอินฟราเรดช่วงคลื่น สั้น	1.60 – 1.71 ไมโครเมตร 2.01 – 2.12 ไมโครเมตร 2.13 – 2.25 ไมโครเมตร 2.27 – 2.40 ไมโครเมตร	18 x 24 ม.	75 กม.
		SAR (Synthetic Aperture Radar) HH polarization (3 look) เรดาร์แบบช่องเปิด สังเคราะห์ โพลาริเซชันแบบ HH(3 ลูก)	1,275 กิกะเฮิรตซ์	18 x 18 ม.	75 กม.
MOS-1	สัมพันธ์กับดวงอาทิตย์ ระดับสูง : 909 ก.ม. มุมมอง : 99 องศา โคจรกลับมาที่จุดเดิม : 17 วัน	MESSR (Multispectral Electronics self Scanning Radiometer) เครื่องวัดคลื่นที่ ตามองเห็นและอินฟราเรด ใกล้	0.51 – 0.59 ไมโครเมตร 0.61 – 0.69 ไมโครเมตร 0.72 – 0.80 ไมโครเมตร 0.80 – 1.10 ไมโครเมตร		100 กม. x 2
		VTIR (Visible and Thermal IR Radiometer) เครื่องวัด คลื่นที่ตามองเห็นและ อินฟราเรดความร้อน	0.5 – 0.7 ไมโครเมตร	0.9 กม.	1,500 กม.
			6.0 – 7.0 ไมโครเมตร	2.7 กม.	
			0.61 – 0.69 ไมโครเมตร 0.72 – 0.80 ไมโครเมตร		
MSR (Microwave Soundar Radiometer) เครื่องวัดห้วง คลื่นไมโครเมตร	23.8 กิกะเฮิรตซ์ 314 กิกะเฮิรตซ์	31 กม. 23 กม.	317 กม.		

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับหน่วยงานเพื่อการศึกษเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## ตารางแสดงรายละเอียดของดาวเทียม ADEOS

ดาวเทียม	องค์ประกอบวงโคจร	เครื่องมือในการสำรวจ			
		ชื่อเครื่องมือวัด	ช่วงคลื่น/ความถี่	มุมมอง สนาม ขณะนั้น	ความกว้าง ของแนว ถ่ายภาพ
ADEOS	สัมพันธ์กับดวงอาทิตย์ ระดับสูง : 797 กม. มุมเอียง : 99 องศา โคจรกลับมาที่จุดเดิม : 41 วัน	OCT (Ocean Color and Temperature Scanner) เครื่องการวัดอุณหภูมิและ สีน้ำทะเล	0.402 – 0.422 ไมโครเมตร	700 ม.	1.400 กม.
			0.433 – 0.453 ไมโครเมตร		
			0.480 – 0.500 ไมโครเมตร		
			0.510 – 0.530 ไมโครเมตร		
			0.555 – 0.575 ไมโครเมตร		
			0.655 – 0.675 ไมโครเมตร		
			0.745 – 0.785 ไมโครเมตร		
0.845 – 0.885 ไมโครเมตร					
3.55 – 3.85 ไมโครเมตร					
AVNIR (Advanced Visible And Near Infrared Radiometer) เครื่องวัดคลื่น ที่ตามองเห็นและอินฟราเรด ใกล้แบบก้าวหน้า	16 ม.	80 กม. มุมมอง	0.40 – 0.50 ไมโครเมตร		
			0.52 – 0.62 ไมโครเมตร		
			0.62 – 0.72 ไมโครเมตร		
			0.82 – 0.92 ไมโครเมตร		
0.52 – 0.72 ไมโครเมตร	8 ม.	40 องศา			
NSCAT (NASA Scatterometer) เครื่องวัดการ กระจายของนาซา	13,995 ไมโครเมตร	25 กม.	1,200 กม.		
TOMS (Total Ozone Mapping) เครื่องวัด สเปกตรัมที่ใช้เครื่องวัด ไอโซนร่วม	42 กม.	2,795 กม.	304.0,312.5 ไมโครเมตร		
			325.0,317.5 ไมโครเมตร		
			332.6,360.0 ไมโครเมตร		
IMG (Interferometric Monitor for Greenhouse Gases) เครื่องวัดแสดงแทรก สอดสำหรับก๊าซเรือน กระจก	3 – 15 ไมโครเมตร	8 กม.	20 กม.		
POLDER (Polarization and Directionality of the Earth's Reflectance) การ โพลาไรเซชันและสภาพทิศ ทางของการสะท้อนของ โลก	5 กม.	1,440 กม. X 1,920 กม.	0.433 – 0.453 ไมโครเมตร		
			0.480 – 0.500 ไมโครเมตร		
			0.510 – 0.530 ไมโครเมตร		
			0.555 – 0.575 ไมโครเมตร		
			0.660 – 0.680 ไมโครเมตร		
0.760 – 0.770 ไมโครเมตร					
ILAS (Improved Limb Atmospheric Sounder) เครื่องหยั่งบรรยากาศแนว เฉียงนอกโลกแบบปรับปรุง			0.753 – 0.784 ไมโครเมตร		
			6.0 – 6.8 ไมโครเมตร		
			7.3 – 11.8 ไมโครเมตร		

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับกรใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก ข.

## ผลงานวิจัยที่ได้รับการตีพิมพ์

Asian Conference on Remote Sensing (December 4-8, 2000)

### URBAN IMAGE ANALYSIS USING ADAPTIVE RESONANCE THEORY

Supoj MONGKOLWORAPHOL, Yuttapong RANGSANSERI and Punya THITIMAJSHIMA

Department of Telecommunications Engineering, Faculty of Engineering

King Mongkut's Institute of Technology Ladkrabang, Bangkok 10520

Tel: (66-2) 326-9967, Fax: (66-2) 326-9086

E-mail: Supoj.mongkolworaphol@compaq.com, {ktpunya, kryuttha}@kmitl.ac.th  
THAILAND

**KEY WORD:** Urban Image Analysis, Adaptive Resonance Theory, Neural Network

**ABSTRACT:** In this paper multispectral images of an urban environment are analyzed and interpreted by means of a neural network approach. In particular, the advantages found by using Adaptive Resonance Theory network of the data are shown and commented. We used the ART2 structure accepts floating-point data, so that each input can be for each pixel directly the vector of the gray level values at each band. This choice is due to the attempt to simplify algorithm as much as possible. Experiments carried out with ADEOS images will be given.

#### 1. INTRODUCTION

The analysis of urban structure is gaining more and more interest, due to the fact that this kind of study may be useful for a number of applications, e.g. settlement detection, population estimation, mapping of land use and changes, assessment of urban activities on the landscape. In particular, remote sensing has a growing importance in this field; indeed, it gives the possibility to observe at difference scales and without interference the urban environment at rates that are clearly impossible for a study on the ground. Computer-aided classification of earth terrain based on the segmentation of remotely sensed image, e.g., Landsat, JERS-1, ADEOS, and SPOT, has provided an alternate, effective method for the above mapping purpose. Adaptive Resonance Theory (ART) architecture is neural networks that carry out stable self-organization of recognition codes for arbitrary sequence of input pattern. Adaptive Resonance Theory first emerged from an analysis of the instabilities inherent in feed forward adaptive coding structure (Grossberg, 1976a, 1976b). More recent work has led to the development of three classes of ART neural network architecture, specified as system differential equations: ART1 and ART2 (Carpenter, 1991). By especially ART2 self-organizes recognition categories for arbitrary sequences of either binary or

analog inputs. ART2 is designed to perform for continuous-valued input vectors the same type of tasks as ART1 does for binary input vectors. The differences between ART2 and ART1 reflect the modifications need to accommodate patterns with continuous-valued components. The more complex F1 field of ART2 is necessary because continuous-valued input vector may be arbitrarily close together. The F1 field in ART2 includes a combination of normalization and noise suppression, in addition to the comparison of the bottom-up and top-down signals needed for the reset mechanism.




Figure 1: ADEOS image of Bangkok area.

## 2. THE ART2 NEURAL ALGORITHM

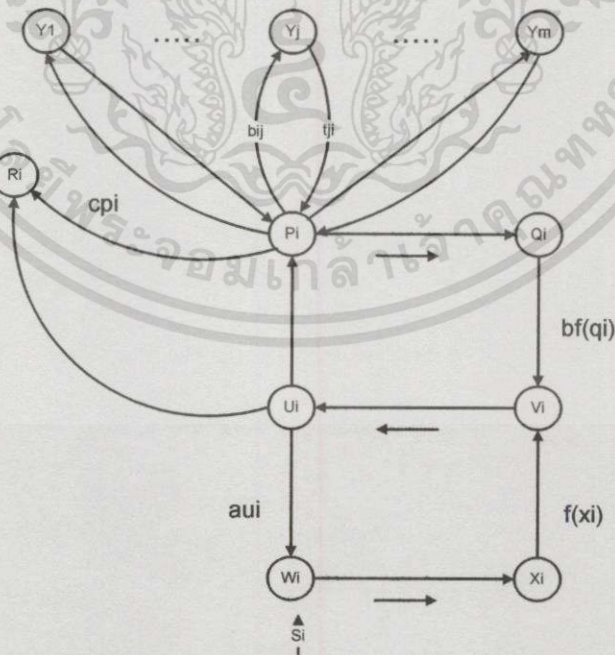


Figure 2: Typical ART2 architecture.

The ART2 architecture (Carpenter, 1991), (Fausett, 1994), which consists of two main modules: the attentional and the orienting modules. The attentional module is

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

further divided into two fields: an input representation field F1 and a category representation field F2. F1 consist of (w, x, v, u, p, and q), each having n neural. The F2 field contains only one layer, which is denote by Y and serves as a competitive layer. There are top-down and bottom-up full connections between F1 and F2. Pattern prototypes are to be preserved on these connections. The input signal is  $S = (S_1, \dots, S_i, \dots, S_n)$  continues to be sent while all of the sections to be described are performed. At the beginning of a learning trail, all activation is set to zero. The computation within the F1 layer can be thought of as originating with the computation of the activation of unit  $U_i$  (the activation of unit  $V_i$  normalized to approximately unit length). Next, a signal is sent from each unit  $U_i$  to its associated units  $W_i$  and  $P_i$ . The activation of units  $W_i$  and  $P_i$  are then computed. Unit  $W_i$  sum the signal it received from  $U_i$  and the input signal  $S_i$ .  $P_i$  sum the signal it receives from  $U_i$  and the top-down signal it receives if there is an active F2 unit. The activation of  $X_i$  and  $Q_i$  are normalized version of the signal at  $W_i$  and  $P_i$ . An activation function is applied at each of units before the signal is sent to  $V_i$ .  $V_i$  then sums the signals if receives concurrently from  $X_i$  and  $Q_i$ ; this completes one cycle of updating the F1 layer.

The activates of the F1 layer are formulated, respectively, as

$$\begin{aligned} u_i &= \frac{v_i}{e + \|V\|}, & x_i &= \frac{w_i}{e + \|W\|}, & q_i &= \frac{p_i}{e + \|P\|}, \\ w_i &= s_i + au_i, & p_i &= u_i + dt_{ji}, & v_i &= f(x_i) + bf(q_i), \end{aligned} \quad (1)$$

$$r_i = \frac{u_i + c p_i}{e + \|U\| + c \|P\|} \quad (2)$$

After the activation of the F1 units have reached equilibrium, the  $P_i$  units sent their signals to the F2 layer, where the winner-take-all competition chooses the candidate cluster unit to learn the input pattern. The units  $U_i$  and  $P_i$  in the F1 layer also send signal to the corresponding reset unit  $R_i$ . The reset mechanism can check for a reset each time it receives signal from  $P_i$  and  $U_i$ , which aggregates the activities of  $P_i$  and  $U_i$  and transmits the result to the vigilance parameter. Vigilance parameter then decides whether or not a reset signal is emitted to the layer Y in field F2. There are also gain control units in the network. They normalize activity patterns over layers. (Fausett, 1994)

We propose an unsupervised approach to the neural classification of the source images. This choice is due to the attempt to simplify as much as possible the detection of the urban features by the automatic analysis of the data. Therefore, we look for competitive algorithms suitable for the task. We need neural networks able to aggregate data in consistent clusters. The ART2 neural algorithm respectively, as

Step0. Initial parameter

Step1. Perform the specified number of training

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับกรใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- Step2. For each input vector update F1 unit
- Step3. Update F1 unit activation again
- Step4. Compute signals to F2 units
- Step5. Check for reset
- Step6. Perform the specified of learning iterations
- Step7. Update weights for winning unit
- Step8. Update F1 unit again
- Step9. Test stopping condition for weight update
- Step10. Test stopping condition for number of training

### 3. EXPERIMENTAL RESULTS



Figure 3: Classification result of the area in Fig 1.

The classification was applied to a three-band image of Bangkok (Fig. 1). The image was recorded by the ADEOS satellite. We applied the previously presented neural classification algorithm to this data set by OPS image the result are completely satisfying. The neural classification starts by applying an ART network looking for spectral aggregation of the pixel. The three-band data are aggregate an input vector in order to match the ability of ART networks to discriminated against different pattern. Fig. 3 presents spectral classification result obtained by the ART2 algorithm and we found very difficult to tune the network parameters to obtain satisfying result.

### 4. CONCLUSION

This work simplifies and completes the ART approach to remote sensing data analysis introduced in (Silva, 1997). We apply the methodology to urban environments and multiband data introduce a clustering step to solve class redundancy and high lightening the advantages and disadvantages of data analysis. The results presented, corresponding to a part of data, are satisfying, and it can be using to analysis another image for classification by computer-aided.

## 5. ACKNOWLEDGEMENT


The authors wish to thank the National Research Council of Thailand (NRCT) for providing the satellite image data

## REFERECNES

Carpenter A. G., Grossberg S. and Rosen. B. D., 1991. ART 2-A:, an adaptive resonance algorithm for rapid category learning and recognition. *neural network*, (4), pp. 493-504.

Fausett L., 1994. *Fundamentals of Neural Network Architecture Algorithm and Application*. Prentice-Hall.


Silva S. and Caetano M., 1997. Using Artificial Recurrent Neural Nets to Identify Spectral and Spatial Pattern for Satellite Imagery Classification of Urban Area. In: *Neurocomputation in Remote Sensing Data Analysis*, I. Kanellopoulos et al. (eds.), Springer: Berlin, pp. 151-159.



## ประวัติผู้เขียน

นายสุพจน์ มงคลวรผล เกิดเมื่อวันที่ 28 มิถุนายน 2514 ที่จังหวัดกรุงเทพมหานคร สำเร็จการศึกษา วิศวกรรมศาสตรบัณฑิต สาขาวิชาอิเล็กทรอนิกส์ จากมหาวิทยาลัยเอเซียอาคเนย์ ปีการศึกษา 2537

ปี พ.ศ. 2537-2540 ทำงานที่บริษัท Ingres (Thailand) Ltd., ในตำแหน่ง Application Consultant ปี พ.ศ. 2540-2543 ทำงานที่บริษัท Unisys (Thailand) Ltd., ในตำแหน่ง Service Engineer และในปี พ.ศ. 2543 จนถึงปัจจุบัน ทำงานอยู่ที่ บริษัท Compaq Computer Corporation (Thailand) Ltd., ในตำแหน่ง Support Specialist



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้