

การสร้างคุณลักษณะแบบเพิ่มสำหรับการเรียนรู้เชิงลึกโดยใช้ตัวเข้ารหัสอัตโนมัติ

นายมงคล อุดมมิตรรัก

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

สาขาวิชาวิทยาศาสตร์คอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2556

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

บทคัดย่อและแฟ้มข้อมูลฉบับเต็มของวิทยานิพนธ์ตั้งแต่ปีการศึกษา 2554 ที่ให้บริการในคลังปัญญาจุฬาฯ (CUIR)

เป็นแฟ้มข้อมูลของนิสิตเจ้าของวิทยานิพนธ์ที่ส่งผ่านทางบัณฑิตวิทยาลัย



The abstract and full text of theses from the academic year 2011 in Chulalongkorn University Intellectual Repository (CUIR)

are the thesis authors' files submitted through the Graduate School.

Incremental Feature Construction for Deep Learning using Auto-Encoder

Mr. Mongkol Udommitrak

A Thesis Submitted in Partial Fulfillment of the Requirements  
for the Degree of Master of Science Program in Computer Science

Department of Computer Engineering

Faculty of Engineering

Chulalongkorn University

Academic Year 2013

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การสร้างคุณลักษณะแบบเพิ่มสำหรับการเรียนรู้เชิงลึกโดยใช้ตัว เข้ารหัสอัตโนมัติ
โดย	นายมงคล อุดมมิตรรัก
สาขาวิชา	วิทยาศาสตร์คอมพิวเตอร์
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	ศาสตราจารย์ ดร.บุญเสริม กิจศิริกุล

---

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้รับวิทยานิพนธ์ฉบับนี้  
เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต

.....คณบดีคณะวิศวกรรมศาสตร์  
(ศาสตราจารย์ ดร.บัณฑิต เอื้ออาภรณ์)

คณะกรรมการสอบวิทยานิพนธ์

.....ประธานกรรมการ  
(รองศาสตราจารย์ ดร.ญาใจ ลิมปิยะภรณ์)

.....อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก  
(ศาสตราจารย์ ดร.บุญเสริม กิจศิริกุล)

.....กรรมการ  
(ผู้ช่วยศาสตราจารย์ ดร.สุกรี สิ้นธุภิณโณ)

..... กรรมการภายนอกมหาวิทยาลัย  
(ผู้ช่วยศาสตราจารย์ ดร.ชลวิช นัทธี)

มงคล อุดมมิตรรัก: การสร้างคุณลักษณะแบบเพิ่มสำหรับการเรียนรู้เชิงลึกโดยใช้ตัว  
เข้ารหัสอัตโนมัติ (INCREMENTAL FEATURE CONSTRUCTION FOR DEEP  
LEARNING USING AUTO-ENCODER).

อ.ที่ปรึกษาวิทยานิพนธ์หลัก : ศ. ดร.บุญเสริม กิจศิริกุล, 55 หน้า.

วิทยานิพนธ์ฉบับนี้เป็นการนำเสนอแนวคิดของวิธีการสร้างคุณลักษณะแบบเพิ่ม  
สำหรับการเรียนรู้เชิงลึกโดยใช้ตัวเข้ารหัสอัตโนมัติ ซึ่งเป็นขั้นตอนวิธีใหม่สำหรับการเรียนรู้  
คุณลักษณะในแต่ละชั้นของเครือข่าย จากเดิมที่คุณลักษณะในแต่ละชั้นถูกสร้างพร้อมกันตั้งแต่  
เริ่มต้นฝึก เสนอแนวคิดใหม่ให้สร้างคุณลักษณะพื้นฐานขึ้นก่อนและเพิ่มคุณลักษณะเสริมเข้าไปจน  
ครบตามจำนวนคุณลักษณะที่กำหนด จากการทดลองกับข้อมูล MNIST และข้อมูล CIFAR-10  
พบว่าการเรียนรู้คุณลักษณะด้วยการสร้างแบบเพิ่มโดยใช้ตัวเข้ารหัสอัตโนมัติแบบบางผสมกับ  
แบบลดการรบกวนให้ค่าความแม่นยำที่ดีกว่าการเรียนรู้คุณลักษณะด้วยการสร้างแบบพร้อมกัน

ภาควิชา วิศวกรรมคอมพิวเตอร์ ... ลายมือชื่อนิสิต.....  
สาขาวิชา วิทยาศาสตร์คอมพิวเตอร์ ลายมือชื่อ อ.ที่ปรึกษาวิทยานิพนธ์หลัก.....  
ปีการศึกษา..... 2556.....

# # 5470329821 : MAJOR COMPUTER SCIENCE

KEYWORDS : FEATURE LEARNING, AUTO-ENCODER, DEEP LEARNING

MONGKOL UDOMMITRAK : INCREMENTAL FEATURE CONSTRUCTION  
FOR DEEP LEARNING USING AUTO-ENCODER. ADVISOR : PROF.  
BOONSERM KIJSIRIKUL, Ph.D., 55 pp.

In this thesis we proposed incremental feature construction for deep learning using an auto-encoder which is a novel alternative method for learning features of each layer of a neural. In conventional auto-encoder training, all feature units are simultaneously constructed at the beginning. Our method incrementally constructs features by adding primitive/simple features first and then gradually learns finer/more complicated features. We run experiments on the MNIST and CIFAR-10 data sets. The experimental results show that feature learning by combine sparse auto-encoder with denoising auto-encoders using our incremental feature construction provides better accuracy than ones using the conventional feature construction.

Department: Computer Engineering Student's Signature.....  
Field of Study: Computer Science Advisor's Signature.....  
Academic Year: 2013.....

## กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จไปได้ด้วยดี เพราะได้รับความกรุณาอย่างสูงจากศาสตราจารย์ ดร. บุญเสริม กิจศิริกุล อาจารย์ที่ปรึกษาวิทยานิพนธ์ ผู้วิจัยต้องขอกราบขอบพระคุณที่ท่านได้สละเวลาให้คำแนะนำมากมายด้วยความเมตตา ให้ความรู้ด้านวิชาการที่เป็นประโยชน์อย่างยิ่งต่อการศึกษาวิจัย และให้ความช่วยเหลือกับปัญหาต่างๆที่ส่งผลในด้านดีต่อการดำรงชีวิต

ขอกราบขอบพระคุณคณะกรรมการสอบวิทยานิพนธ์ทุกท่านเป็นอย่างสูง ได้แก่ รองศาสตราจารย์ ดร.ญาใจ ลิ้มปิยะภรณ์ ผู้ช่วยศาสตราจารย์ ดร.สุกรี สิ้นธุภิณฺญ์ และผู้ช่วยศาสตราจารย์ ดร.ชลวิธ นันทิ์ สำหรับความเมตตาและการสละเวลาอันมีค่า มาให้คำแนะนำมากมายที่เป็นประโยชน์ต่องานวิจัย

ขอกราบขอบพระคุณผู้ช่วยศาสตราจารย์ ดร.โปรดปราน บุญยพุกกณะ และ ผู้ช่วยศาสตราจารย์ ดร.อดิวงส์ สุขชาติ สำหรับโอกาสที่ให้ผู้วิจัยได้ศึกษาในระดับมหาบัณฑิต และขอกราบขอบพระคุณผู้ช่วยศาสตราจารย์ ดร.กรุง สีนอมิรมย์สรณญ์ ภาควิชาคณิตศาสตร์และวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย สำหรับความรู้ คำแนะนำและกำลังใจที่มอบให้ลูกศิษย์คนนี้เสมอมา

ขอขอบพระคุณอาจารย์ประจำภาควิชาวิศวกรรมคอมพิวเตอร์ทุกท่านเป็นอย่างสูงสำหรับทุกคำแนะนำดีๆ ที่ผู้วิจัยจะนำไปใช้ให้เกิดประโยชน์ต่อไปในอนาคต ขอขอบคุณเจ้าหน้าที่ประจำภาควิชาวิศวกรรมคอมพิวเตอร์ทุกท่าน รวมถึงรุ่นพี่และเพื่อนๆ ทุกท่านจากห้องปฏิบัติการ MIND lab, ISEL lab และ DSEL lab ที่คอยช่วยเหลือเกื้อกูลกันตลอด ทำให้ชีวิตตลอดการศึกษาพบเจอแต่ความสนุกสนาน ขอขอบคุณพี่พระจักร์ วิฑูรชาติ ที่ร่วมคิด ร่วมวิจัยและร่วมแก้ปัญหาด้วยกัน

ขอกราบขอบพระคุณ นางกันยา อุดมมิตรรัก มารดาผู้เสียสละและอดทนต่อความลำบาก เพื่อให้ลูกทุกคนประสบความสำเร็จ ขอขอบพระคุณนายโยธิน นายธนลาภ และนายสุรพล อุดมมิตรรัก ผู้เป็นบิดา พี่ชายและน้องชาย ขอขอบคุณนางสาวรวงคณา ทัสสะ ที่คอยอยู่เคียงข้างให้กำลังใจกันตลอดมา ทำยสุดนี้ขอขอบคุณทุกท่านทั้งที่ได้กล่าวมาและไม่ได้กล่าวถึง ทุกท่านมีส่วนร่วมให้วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงด้วยดีทุกประการ

# สารบัญ

หน้า

บทคัดย่อภาษาไทย .....	ง
บทคัดย่อภาษาอังกฤษ .....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ .....	ช
สารบัญตาราง.....	ณ
สารบัญแผนภูมิ.....	ญ
สารบัญภาพ .....	ฎ

## บทที่

1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของการวิจัย .....	2
1.3 ขอบเขตของการวิจัย.....	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ .....	3
1.5 ลำดับขั้นตอนในการเสนอผลการวิจัย.....	3
2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	4
2.1 ตัวเข้ารหัสอัตโนมัติแบบต่างๆ.....	4
2.1.1 ตัวเข้ารหัสอัตโนมัติแบบพื้นฐาน (Basic Auto-Encoder) .....	4
2.1.2 ตัวเข้ารหัสอัตโนมัติแบบเบาบาง (Sparse Auto-Encoder) .....	7
2.1.3 ตัวเข้ารหัสอัตโนมัติแบบลดการรบกวน (Denoising Auto-Encoder) .....	9
2.2 ตัวเข้ารหัสอัตโนมัติแบบหลายชั้น (Stacked Auto-Encoder) .....	10
2.3 การถดถอยซอฟท์แมกซ์ (Softmax regression) .....	11
2.4 งานวิจัยที่เกี่ยวข้อง .....	12
3 การสร้างคุณลักษณะแบบเพิ่ม (Incremental Feature Construction).....	20

บทที่	หน้า
4 การทดลองและผลการทดลอง.....	24
4.1 เครื่องมือที่ใช้ในการทดลอง.....	24
4.2 ข้อมูลที่ใช้ในการทดลอง.....	24
4.3 ข้อกำหนดในการทดลอง.....	25
4.4 ผลการทดลอง.....	28
4.5 วิเคราะห์ผลการทดลอง.....	34
5 สรุปผลงานวิจัย.....	38
5.1 บทสรุป.....	38
5.2 ข้อเสนอแนะ.....	38
รายการอ้างอิง.....	40
ภาคผนวก.....	44
ประวัติผู้เขียนวิทยานิพนธ์.....	55



## สารบัญตาราง

ตารางที่	หน้า
4-1 ค่าความแม่นยำของการจำแนกคุณลักษณะซึ่งได้จากการเรียนรู้ตัวเข้ารหัสอัตโนมัติแบบพื้นฐาน โดยใช้ข้อมูล MNIST .....	28
4-2 ค่าความแม่นยำของการจำแนกคุณลักษณะซึ่งได้จากการเรียนรู้ตัวเข้ารหัสอัตโนมัติแบบลดการรบกวน โดยใช้ข้อมูล MNIST .....	29
4-3 ค่าความแม่นยำของการจำแนกคุณลักษณะซึ่งได้จากการเรียนรู้ตัวเข้ารหัสอัตโนมัติแบบเบาบาง โดยใช้ข้อมูล MNIST .....	29
4-4 ค่าความแม่นยำของการจำแนกคุณลักษณะซึ่งได้จากการสร้างแบบเพิ่มโดยใช้ตัวเข้ารหัสอัตโนมัติแบบเบาบางผสมกับแบบลดการรบกวน ของข้อมูล MNIST .....	30
4-5 ค่าความแม่นยำของการจำแนกคุณลักษณะซึ่งได้จากการเรียนรู้ตัวเข้ารหัสอัตโนมัติแบบเบาบางใน 3 กลุ่มแรกและแบบลดการรบกวนในกลุ่มสุดท้าย โดยใช้ข้อมูล MNIST .....	30
4-6 ค่าความแม่นยำของการจำแนกคุณลักษณะซึ่งได้จากการเรียนรู้ตัวเข้ารหัสอัตโนมัติแบบต่างๆ โดยใช้ข้อมูล CIFAR-10 .....	31
4-7 ค่าความแม่นยำเฉลี่ยของการจำแนกคุณลักษณะของข้อมูล MNIST ซึ่งได้จากขั้นตอนวิธีการปรับซัด .....	31
4-8 ค่าความแม่นยำของการจำแนกคุณลักษณะของข้อมูล CIFAR-10 ซึ่งได้จากขั้นตอนวิธีการปรับซัด .....	31

## สารบัญแผนภูมิ

แผนภูมิที่	หน้า
4-1 แผนภูมิเปรียบเทียบค่าเฉลี่ยของค่าความแม่นยำของการจำแนกคุณลักษณะซึ่งได้จากการสร้างแบบพร้อมกันและได้จากการสร้างแบบเพิ่ม โดยใช้ข้อมูล MNIST.....	32
4-2 แผนภูมิเปรียบเทียบค่าเฉลี่ยของค่าความแม่นยำของการจำแนกคุณลักษณะของข้อมูล MNIST ซึ่งได้จากการสร้างแบบเพิ่ม 100-100-100-100 โดยใช้ตัวเข้ารหัสอัตโนมัติแบบเบาบางผสมกับแบบลดการรบกวนประเภทต่างๆ.....	32
4-3 แผนภูมิเปรียบเทียบค่าเฉลี่ยของค่าความแม่นยำของการจำแนกคุณลักษณะซึ่งได้จากการสร้างแบบเพิ่ม SSSS กับการสร้างแบบเพิ่ม SSSD .....	33
4-4 แผนภูมิเปรียบเทียบค่าความแม่นยำของการจำแนกคุณลักษณะซึ่งได้จากการสร้างแบบพร้อมกันและคุณลักษณะซึ่งได้จากการสร้างแบบเพิ่ม โดยใช้ข้อมูล CIFAR-10.....	33

## สารบัญภาพ

ภาพที่	หน้า
2-1	โครงข่ายการทำงานของตัวเข้ารหัสอัตโนมัติ.....5
2-2	คุณลักษณะที่ได้จากการเรียนรู้ด้วยขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติแบบเบาบาง.....7
2-3	กราฟของฟังก์ชันคลูแบคเคลเบลล.....8
2-4	โครงสร้างการทำงานของขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติแบบลดการลดรอบวง.....9
2-5	โครงสร้างการทำงานของตัวเข้ารหัสอัตโนมัติแบบหลายชั้น.....11
2-6	คุณลักษณะ 2 มิติที่ได้จากการฝึกข้อมูลตัวเลขลายมือ MNIST.....13
2-7	กราฟของฟังก์ชันที่ทำให้สมบูรณ์.....15
2-8	โครงสร้างการเรียนรู้คุณลักษณะแบบเพิ่มกับข้อมูลฝึกแบบออนไลน์.....16
2-9	โครงสร้างสถาปัตยกรรมของขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติแบบเบาบางและวนกลับผสม การแยกแยะ.....19
3-1	โครงสร้างของการฝึกคุณลักษณะพื้นฐานในกลุ่มแรก.....23
3-2	โครงสร้างของการฝึกคุณลักษณะเสริมในกลุ่มที่สอง.....23
3-3	โครงสร้างของการฝึกคุณลักษณะเสริมในกลุ่มที่สาม.....23
4-1	ตัวอย่างของข้อมูล MNIST.....24
4-2	ตัวอย่างของข้อมูล CIFAR-10.....25
4-3	ภาพสุ่มจากข้อมูล CIFAR-10.....26
4-4	ภาพเมตริกซ์ค่าน้ำหนัก $W_1$ ที่ได้จากการเรียนรู้ด้วยตัวเข้ารหัสอัตโนมัติแบบพื้นฐาน.....36
4-5	ภาพเมตริกซ์ค่าน้ำหนัก $W_1$ ที่ได้จากการเรียนรู้ด้วยตัวเข้ารหัสอัตโนมัติแบบเบาบาง.....37
ก-1	คุณลักษณะที่ได้จากการสร้างแบบพร้อมกัน 400 คุณลักษณะ ด้วยตัวเข้ารหัสอัตโนมัติ แบบพื้นฐาน โดยใช้ข้อมูล MNIST.....45
ก-2	คุณลักษณะที่ได้จากการสร้างแบบพร้อมกัน 400 คุณลักษณะ ด้วยตัวเข้ารหัสอัตโนมัติ แบบเบาบาง โดยใช้ข้อมูล MNIST.....45
ก-3	คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 40-80-80-200 ด้วยตัวเข้ารหัสอัตโนมัติ แบบพื้นฐาน โดยใช้ข้อมูล MNIST.....46
ก-4	คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 100-100-100-100 ด้วยตัวเข้ารหัสอัตโนมัติ แบบพื้นฐาน โดยใช้ข้อมูล MNIST.....46

ภาพที่	หน้า
ก-5 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 200-80-80-40 ด้วยตัวเข้ารหัสอัตโนมัติ แบบพื้นฐาน โดยใช้ข้อมูล MNIST .....	46
ก-6 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 40-80-80-200 ด้วยตัวเข้ารหัสอัตโนมัติ แบบเบาบาง โดยใช้ข้อมูล MNIST .....	47
ก-7 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 100-100-100-100 ด้วยตัวเข้ารหัสอัตโนมัติ แบบเบาบาง โดยใช้ข้อมูล MNIST .....	47
ก-8 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 200-80-80-40 ด้วยตัวเข้ารหัสอัตโนมัติ แบบเบาบาง โดยใช้ข้อมูล MNIST .....	47
ก-9 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 40-80-80-200 ด้วยการเรียนรู้แบบ SSSD โดยใช้ข้อมูล MNIST .....	48
ก-10 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 100-100-100-100 ด้วยการเรียนรู้แบบ SSSD โดยใช้ข้อมูล MNIST .....	48
ก-11 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 200-80-80-40 ด้วยการเรียนรู้แบบ SSSD โดยใช้ข้อมูล MNIST .....	48
ก-12 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 100-100-100-100 ด้วยการเรียนรู้แบบ SSDS โดยใช้ข้อมูล MNIST .....	49
ก-13 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 100-100-100-100 ด้วยการเรียนรู้แบบ SDSS โดยใช้ข้อมูล MNIST .....	49
ก-14 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 100-100-100-100 ด้วยการเรียนรู้แบบ DSSS โดยใช้ข้อมูล MNIST .....	49
ก-15 คุณลักษณะที่ได้จากการสร้างแบบพร้อมกัน 400 คุณลักษณะ ด้วยตัวเข้ารหัสอัตโนมัติ แบบพื้นฐาน โดยใช้ข้อมูล CIFAR-10 .....	50
ก-16 คุณลักษณะที่ได้จากการสร้างแบบพร้อมกัน 400 คุณลักษณะ ด้วยตัวเข้ารหัสอัตโนมัติ แบบเบาบาง โดยใช้ข้อมูล CIFAR-10 .....	50
ก-17 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 40-80-80-200 ด้วยตัวเข้ารหัสอัตโนมัติ แบบพื้นฐาน โดยใช้ข้อมูล CIFAR-10 .....	51
ก-18 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 100-100-100-100 ด้วยตัวเข้ารหัสอัตโนมัติ แบบพื้นฐาน โดยใช้ข้อมูล CIFAR-10 .....	51

ภาพที่	หน้า
ก-19 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 200-80-80-40 ด้วยตัวเข้ารหัสอัตโนมัติ แบบพื้นฐานโดยใช้ข้อมูล CIFAR-10 .....	51
ก-20 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 40-80-80-200 ด้วยตัวเข้ารหัสอัตโนมัติ แบบเบาบาง โดยใช้ข้อมูล CIFAR-10 .....	52
ก-21 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 100-100-100-100 ด้วยตัวเข้ารหัสอัตโนมัติ แบบเบาบาง โดยใช้ข้อมูล CIFAR-10 .....	52
ก-22 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 200-80-80-40 ด้วยตัวเข้ารหัสอัตโนมัติ แบบเบาบาง โดยใช้ข้อมูล CIFAR-10 .....	52
ก-23 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 40-80-80-200 ด้วยการเรียนรู้แบบ SSSD โดยใช้ข้อมูล CIFAR-10 .....	53
ก-24 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 100-100-100-100 ด้วยการเรียนรู้แบบ SSSD โดยใช้ข้อมูล CIFAR-10 .....	53
ก-25 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 200-80-80-40 ด้วยการเรียนรู้แบบ SSSD โดยใช้ข้อมูล CIFAR-10 .....	53
ก-26 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 40-80-80-200 ด้วยการเรียนรู้แบบ DSSS โดยใช้ข้อมูล CIFAR-10 .....	54
ก-27 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 100-100-100-100 ด้วยการเรียนรู้แบบ DSSS โดยใช้ข้อมูล CIFAR-10 .....	54
ก-28 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 200-80-80-40 ด้วยการเรียนรู้แบบ DSSS โดยใช้ข้อมูล CIFAR-10 .....	54

## บทที่ 1

### บทนำ

#### 1.1 ความเป็นมาและความสำคัญของปัญหา

วิธีการเรียนรู้ของเครื่อง (Machine learning method) ที่มีระดับชั้น 1, 2 หรือ 3 ชั้น เรียกว่า การเรียนรู้เชิงตื้น (Shallow learning) และขั้นตอนวิธีการเรียนรู้ที่มีจำนวนระดับชั้นมากกว่า 3 ชั้นขึ้นไป เรียกว่า การเรียนรู้เชิงลึก (Deep learning) การเรียนรู้เชิงลึกมีลักษณะคล้ายการเรียนรู้ในสมองมนุษย์ที่มีระดับชั้นของความคิดเป็นลำดับชั้นหลายชั้น ดังนั้นหากต้องการพัฒนาความสามารถของการเรียนรู้ของเครื่องคอมพิวเตอร์ให้ทัดเทียมกับความสามารถของมนุษย์ การเรียนรู้เชิงลึกจึงเหมาะแก่การศึกษาและพัฒนาเป็นอย่างยิ่ง สอดคล้องกับในปัจจุบันที่การเรียนรู้เชิงลึกกำลังได้รับความสนใจเป็นอย่างมาก [1], [2]

การเรียนรู้เชิงลึกไม่ใช่เรื่องใหม่ที่เพิ่งมีการพูดถึงกัน แต่ได้มีนักวิจัยศึกษามานานหลายปีแล้ว [3], [4], [5] เพียงแต่การวิจัยส่วนใหญ่เน้นเป็นการนำการเรียนรู้แบบชี้นำ (Supervised learning) มาต่อกันหลายชั้น ซึ่งผลวิจัยพบว่า การเรียนรู้โดยใช้ระดับชั้นเพียง 2 หรือ 3 ชั้น ให้ผลลัพธ์ที่ดีกว่าการเรียนรู้ที่มากกว่า 3 ชั้น ด้วยเหตุผลเช่น ความซับซ้อนในขั้นตอนการฝึกที่เพิ่มมากขึ้น เมื่อมีระดับชั้นของการเรียนรู้มากขึ้น หรือการใช้พารามิเตอร์เริ่มต้นที่แตกต่างกันส่งผลให้เกิดผลลัพธ์แบบเฉพาะที่ (Local optimum) หลากหลายค่า [6]

อย่างไรก็ตาม ไม่ใช่ว่าทุกขั้นตอนวิธีการเรียนรู้เชิงลึกในอดีตจะล้มเหลวเสียหมด ข่ายงานประสาทคอนโวลูชันแนล (Convolutional neural network) [7], [8] เป็นขั้นตอนวิธีหนึ่งที่ใช้แนวคิดของระบบโครงสร้างการมองเห็นของสายตามนุษย์ ซึ่งนำค่าคลาดเคลื่อนของความชัน (Error gradient) มาใช้กับแนวคิดนี้ได้ขั้นตอนวิธีการเรียนรู้เชิงลึกที่ง่ายต่อการฝึกและได้ผลลัพธ์ที่ดีที่สุดกับหลายปัญหาการจำแนก (Classification) และปัญหาการรู้จำ (Recognition)

ในปี 2006 การเรียนรู้เชิงลึกกลับมาได้รับความสนใจอย่างจริงจังอีกครั้ง เมื่อมีการคิดค้นขั้นตอนวิธีการเรียนรู้เชิงลึกที่มีประสิทธิภาพขึ้น นั่นคือ ข่ายงานความเชื่อเชิงลึก (Deep Belief Networks) [9] ซึ่งเป็นวิธีการเรียนรู้ที่พัฒนามาจากวิธีเครื่องโบลต์สแมนแบบจำกัด (Restricted Boltzmann Machine) และเป็นการเรียนรู้แบบไม่ชี้นำ (Unsupervised learning) และในเวลาถัดมาไม่นานก็มีขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติหลายชั้น (Stacked Auto-encoders) [10], [11], [12] โดยวิธีการเรียนรู้ที่ได้กล่าวมาทั้งหมดนี้ ได้ถูกนำมาใช้เป็นแนวทางพื้นฐานให้แก่งานวิจัยมากมาย

เพื่อพัฒนาขั้นตอนวิธีการเรียนรู้ให้มีประสิทธิภาพดียิ่งขึ้น อาทิเช่น ตัวเข้ารหัสอัตโนมัติแบบเบาบาง (Sparse Auto-Encoders) [13], ตัวเข้ารหัสอัตโนมัติแบบลดการรบกวน (Denoising Auto-Encoders) [14], ข่ายงานความเชื่อเชิงลึกคอนโวลูชันแนล (Convolutional Deep Belief Networks) [15], ตัวเข้ารหัสอัตโนมัติคอนโวลูชันแนลหลายชั้น (Stacked Convolutional Auto-Encoders) [16] และข่ายงานแมกซ์เอาท์ (Maxout network) [17] เป็นต้น

สถาปัตยกรรมของการเรียนรู้เชิงลึกที่ได้กล่าวมาข้างต้น มีลักษณะพื้นฐานเป็นโครงข่ายหลายระดับชั้น ในระดับชั้นแรกเป็นการเรียนรู้แบบไม่ชี้้นำ ซึ่งเป็นการเรียนรู้คุณลักษณะที่ใช้เป็นตัวแทนของข้อมูล (Feature representation learning) ระดับชั้นที่สูงขึ้นไปเป็นการเรียนรู้คุณลักษณะที่ได้จากการเรียนรู้คุณลักษณะในชั้นที่ต่ำกว่า และในระดับชั้นสุดท้ายเป็นการเรียนรู้แบบชี้้นำ เมื่อพิจารณาขั้นตอนการเรียนรู้ของโครงข่ายนี้ จะพบว่า หากสามารถเรียนรู้คุณลักษณะในชั้นล่างให้มีประสิทธิภาพดี ก็จะส่งผลดีกับการเรียนรู้ในชั้นถัดมาและชั้นบนสุดด้วย และเมื่อพิจารณาข้อมูลฝึกที่ใช้ในการเรียนรู้ จะเห็นว่า การเรียนรู้คุณลักษณะเป็นการใช้ประโยชน์โดยตรงจากข้อมูลแบบไม่ชี้้นำซึ่งเป็นข้อมูลส่วนใหญ่ในปัญหาการเรียนรู้ ด้วยเหตุทั้งหมดนี้ การเรียนรู้คุณลักษณะจึงเป็นประเด็นสำคัญในการพัฒนาการเรียนรู้เชิงลึกให้มีประสิทธิภาพมากยิ่งขึ้น

## 1.2 วัตถุประสงค์ของการวิจัย

วัตถุประสงค์ของงานวิจัยนี้คือการพัฒนาการเรียนรู้คุณลักษณะ โดยการนำเสนอแนวคิดใหม่สำหรับขั้นตอนวิธีการสร้างคุณลักษณะให้กับการเรียนรู้ข้อมูลรูปภาพแบบไม่ชี้้นำ และศึกษาปัจจัยสำคัญที่ส่งผลต่อประสิทธิภาพในการจำแนกของคุณลักษณะที่ได้จากขั้นตอนวิธีการสร้างแบบใหม่

## 1.3 ขอบเขตของการวิจัย

1. งานวิจัยนี้วัดประสิทธิภาพของคุณลักษณะด้วยค่าความแม่นยำของการจำแนกเปรียบเทียบระหว่างคุณลักษณะที่ได้จากวิธีการสร้างคุณลักษณะแบบพร้อมกันกับคุณลักษณะที่ได้จากวิธีการสร้างคุณลักษณะแบบเพิ่ม
2. งานวิจัยนี้นำขั้นตอนการสร้างคุณลักษณะประยุกต์ใช้กับขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติแบบพื้นฐาน ตัวเข้ารหัสอัตโนมัติแบบเบาบาง ตัวเข้ารหัสอัตโนมัติแบบลดการรบกวน และตัวเข้ารหัสอัตโนมัติแบบเบาบางผสมกับแบบลดการรบกวน

3. ทดลองกับข้อมูลที่งานวิจัยทั่วไปใช้เป็นเกณฑ์มาตรฐาน ได้แก่
  - 3.1 MNIST เป็นข้อมูลภาพขาวดำรูปตัวเลข 0-9 ที่เขียนด้วยลายมือ แต่ละรูปมีขนาด 28x28 มิติ แบ่งเป็นข้อมูลฝึก 60,000 รูปและข้อมูลทดสอบ 10,000 รูป
  - 3.2 CIFAR-10 เป็นข้อมูลรูปภาพสี 10 ประเภท ประกอบไปด้วยรูป นก, แมว, กวาง, สุนัข, กบ, ม้า, เรือ, เครื่องบิน, รถยนต์ และรถบรรทุก แต่ละรูปมีขนาด 32x32 มิติ แบ่งเป็นข้อมูลฝึก 50,000 รูป และข้อมูลทดสอบ 10,000 รูป
3. พัฒนาขั้นตอนวิธีและทดลองผลกับคอมพิวเตอร์ Intel (R) Core-i5, CPU @2.40GHz, 6.00 GB RAM ผ่านระบบปฏิบัติการวินโดวส์ 64 บิต โดยใช้โปรแกรม Matlab R2011b
4. ใช้ขั้นตอนวิธีบีเอฟจีเอสแบบจำกัดความจำ (L-BFGS) และขั้นตอนวิธีการถดถอยซอฟท์แมกซ์ (Softmax regression) ในการหาค่าต่ำสุดของฟังก์ชันจุดประสงค์และใช้สำหรับการเรียนรู้การจำแนกในชั้นบนสุดของโครงข่าย ตามลำดับ

#### 1.4 ประโยชน์ที่คาดว่าจะได้รับ

1. ได้ศึกษาแนวคิดของการเรียนรู้เชิงลึกและการเรียนรู้คุณลักษณะ
2. ได้แนวคิดของการสร้างคุณลักษณะแบบใหม่และตระหนักถึงปัจจัยสำคัญที่สามารถพัฒนาให้การเรียนรู้คุณลักษณะมีประสิทธิภาพสูงขึ้น
3. ได้แนวคิดใหม่ที่สามารถนำไปประยุกต์ใช้กับปัญหาการจำแนกและปัญหาการเรียนรู้จำในซีวีดีจริงได้

#### 1.5 ลำดับขั้นตอนในการเสนอผลการวิจัย

1. ศึกษาทฤษฎีและหลักการพื้นฐานที่ใช้ในการวิจัยและศึกษางานวิจัยที่เกี่ยวข้อง
2. ออกแบบและพัฒนาขั้นตอนวิธีการเรียนรู้คุณลักษณะโดยนำไปประยุกต์ใช้กับขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติ
3. จัดทำ (Implement) ขั้นตอนวิธีการที่นำเสนอ
4. วิเคราะห์ผลการทดลอง
5. สรุปผลและเรียบเรียงวิทยานิพนธ์



## บทที่ 2

### ทฤษฎีและงานวิจัยที่เกี่ยวข้อง


ในบทนี้จะอธิบายขั้นตอนการเรียนรู้การจำแนกของข้อมูลรูปภาพซึ่งประกอบไปด้วยส่วนของการเรียนแบบไม่ชี้แนะและส่วนของการเรียนรู้แบบชี้แนะ สำหรับการเรียนรู้แบบไม่ชี้แนะจะพิจารณาขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติซึ่งเป็นขั้นตอนวิธีหลักของงานวิจัยนี้ โดยจะอธิบายหลักการและแนวคิดของขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติแบบต่างๆ ได้แก่ ตัวเข้ารหัสอัตโนมัติแบบพื้นฐาน ตัวเข้ารหัสอัตโนมัติแบบเบาบาง และตัวเข้ารหัสอัตโนมัติแบบลดการรบกวน สำหรับขั้นตอนการเรียนรู้แบบชี้แนะจะพิจารณาขั้นตอนวิธีการถดถอยซอฟท์แมกซ์ ซึ่งเป็นขั้นตอนวิธีที่ใช้สำหรับหาค่าความแม่นยำของการจำแนก ในส่วนท้ายเป็นการรวบรวมงานวิจัยที่เกี่ยวข้อง

#### 2.1 ตัวเข้ารหัสอัตโนมัติแบบต่างๆ

##### 2.1.1 ตัวเข้ารหัสอัตโนมัติแบบพื้นฐาน (Basic Auto-Encoder)

ตัวเข้ารหัสอัตโนมัติ คือขั้นตอนวิธีพื้นฐานสำหรับนำไปประกอบเพื่อสร้างเครือข่ายเชิงลึก การใช้งานตัวเข้ารหัสอัตโนมัติทำงานคล้ายกับข่ายงานประสาทเทียม (Artificial neural network) คือมีชั้นขาเข้า (Input layer) ชั้นซ่อน (Hidden layer) และชั้นขาออก (Output layer) แตกต่างกันที่ตัวเข้ารหัสอัตโนมัติเป็นการเรียนรู้แบบไม่ชี้แนะ กล่าวคือ เป็นการเรียนรู้เพื่อทำให้ข้อมูลขาออกมีลักษณะใกล้เคียงกับข้อมูลขาเข้า ลักษณะจึงเหมือนกับการฝึกข้อมูลขาเข้า  $x$  ให้เข้ารหัส (Encode) ได้ชั้นซ่อน  $a = f(x)$  และสามารถถอดรหัส (Decode) ได้เป็น  $y = g(a)$  โดยที่  $x \approx y$  ดังนั้นสิ่งที่ได้จากการฝึกตัวเข้ารหัสอัตโนมัติคือฟังก์ชันเข้ารหัส  $f$  ที่สามารถแปลงข้อมูล  $x$  ให้เป็นคุณลักษณะ  $a$  และนำคุณลักษณะ  $a$  ไปใช้เป็นตัวแทนของ  $x$  ต่อไป เราเรียกการเรียนรู้ในลักษณะนี้ว่า การเรียนรู้คุณลักษณะที่ใช้เป็นตัวแทนของข้อมูลได้

สำหรับขั้นตอนการเรียนรู้ของตัวเข้ารหัสอัตโนมัติ เริ่มต้น กำหนดให้ข้อมูลแบบไม่ชี้แนะจำนวน  $m$  ตัวอย่าง  $\{x^{(1)}, x^{(2)}, \dots, x^{(m)}\}$  โดยที่ข้อมูลแต่ละตัวอย่างเป็นเวกเตอร์ของจำนวนจริงที่มีค่าอยู่ในช่วง  $[0, 1]$  ขนาด  $d_x$  นั่นคือ  $x^{(i)} \in [0, 1]^{d_x}$  และกำหนดพารามิเตอร์เริ่มต้นแบบสุ่ม  $(W, b) = \{W_1, b_1, W_2, b_2\}$  โดยที่  $W_1$  เป็นเมทริกซ์ของจำนวนจริงขนาด  $d_h \times d_x$  นั่นคือ  $W_1 \in \mathbb{R}^{d_h} \times \mathbb{R}^{d_x}$  เรียก  $W_1$  ว่าเมทริกซ์ของค่าน้ำหนัก (Weight matrix) และ  $W_2$  เป็นเมทริกซ์ของจำนวนจริงขนาด  $d_x \times d_h$  นั่นคือ  $W_2 \in \mathbb{R}^{d_x} \times \mathbb{R}^{d_h}$  และ  $b_1 \in \mathbb{R}^{d_h}$  และ  $b_2 \in \mathbb{R}^{d_x}$



ภาพที่ 2-1: โครงข่ายการทำงานของขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติ

เป็นเวกเตอร์ค่าคลาดเคลื่อน (Bias vector) ของชั้นซ่อนและชั้นขาออก ตามลำดับ จากนั้นทำการคำนวณป้อนค่าไปข้างหน้า (Feed forward) โดยส่งค่า  $x^{(i)}$  ไปยังชั้นซ่อนซึ่งเป็นชั้นคุณลักษณะที่ใช้เป็นตัวแทนของข้อมูล (Hidden Representation layer) โดยใช้ฟังก์ชันไม่เชิงเส้น (Non-linear function) เช่น ฟังก์ชันซิกมอยด์  $\text{sigmoid}(x) = \frac{1}{1+e^{-x}}$  หรือฟังก์ชันไฮเพอร์โบลิคแทนเจนต์  $\text{tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$  ในงานวิจัยนี้ใช้ฟังก์ชันซิกมอยด์ (Sigmoid) ได้ค่าในชั้นซ่อนเป็น  $a^{(i)} \in [0,1]^{d_h}$  โดยที่  $a^{(i)} = \text{sigmoid}(W_1 x^{(i)} + b_1)$  จากนั้นคำนวณต่อไปที่ชั้นขาออกได้  $y^{(i)} \in [0,1]^{d_x}$  โดยที่  $y^{(i)} = \text{sigmoid}(W_2 a^{(i)} + b_2)$  เมื่อกำหนดป้อนค่าไปข้างหน้าเสร็จสิ้น จะได้  $y^{(i)}$  ซึ่งมีค่าแตกต่างจาก  $x^{(i)}$  อยู่ ดังภาพที่ 2-1 ดังนั้นจึงต้องมีการปรับพารามิเตอร์ ( $W, b$ ) เพื่อให้  $y^{(i)}$  มีค่าใกล้เคียงกับ  $x^{(i)}$  มากที่สุด นำไปสู่ขั้นตอนวิธีการหาค่าที่เหมาะสมที่สุด (Optimization method) โดยมีฟังก์ชันจุดประสงค์ (Objective function) เป็นฟังก์ชันที่ต้องการหาค่าต่ำสุดของฟังก์ชัน  $L(x, y)$  ซึ่งเป็นฟังก์ชันผลต่างระหว่าง  $x^{(i)}$  กับ  $y^{(i)}$  โดยเรียกผลต่างนี้ว่าค่าความผิดพลาดจากการสร้างใหม่ (Reconstruction error) ดังนั้นตัวเข้ารหัสอัตโนมัติจึงมีฟังก์ชันจุดประสงค์ดังนี้

$$J_{AE}(W, b) = \min_{(W, b)} \left\{ \frac{1}{2m} \cdot \sum_{i=1}^m L(x^{(i)}, y^{(i)}) \right\}$$

สำหรับฟังก์ชัน  $L(x, y)$  ซึ่งเป็นฟังก์ชันสำหรับคำนวณผลต่างระหว่าง  $x$  และ  $y$  สามารถเลือกใช้ได้ทั้งฟังก์ชันค่าคลาดเคลื่อนกำลังสอง (Squared error function) นั่นคือ  $L(x, y) = \sum (y - x)^2$  หรือฟังก์ชันครอส-เอนโทรปี (Cross-Entropy function) นั่นคือ  $L(x, y) = \sum [x \log(y) + (1-x) \log(1-y)]$

สำหรับการปรับพารามิเตอร์เพื่อหาค่าต่ำสุดของฟังก์ชันจุดประสงค์ มีขั้นตอนวิธีที่นิยมใช้ทั้งหมด 3 วิธี ได้แก่ วิธีการเคลื่อนลงตามความชัน (Gradient descent), วิธีบีเอพีเอสแบบจำกัดความจำ (Limited-memory BFGS) และวิธีความชันสังยุค (Conjugate gradient) ในงานวิจัยนี้เลือกใช้ขั้นตอนวิธี L-BFGS เพราะสามารถทำงานกับปัญหาที่ข้อมูลมีขนาดมิติน้อย ซึ่งจะกล่าวต่อไปในหัวข้อที่ 2.4

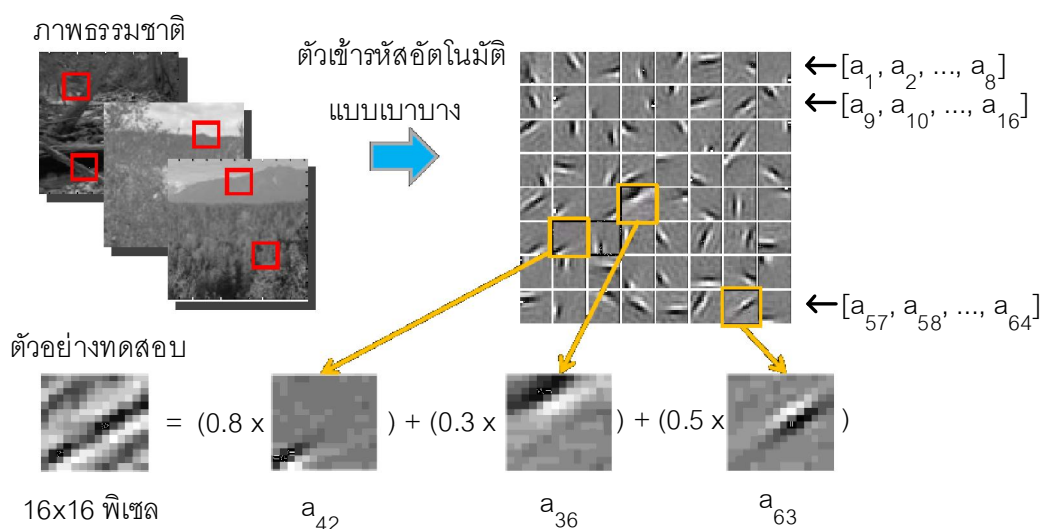
ปัญหาหนึ่งที่สำคัญของการเรียนรู้ คือ ปัญหาการปรับเหมาะเกินไป (Over-fitting) กล่าวคือ การเรียนรู้แบบจำลองหนึ่งด้วยข้อมูลฝึกชุดหนึ่ง หากข้อมูลฝึกชุดนั้นมีลักษณะไม่ทั่วไป เมื่อใช้ระยะเวลาของการเรียนรู้มากๆ แบบจำลองที่ได้ยิ่งมีความเหมาะสมกับข้อมูลฝึกชุดนั้น จนส่งผลตรงกันข้ามกับข้อมูลทดสอบที่มีลักษณะทั่วไปหรือมีลักษณะแตกต่างจากข้อมูลฝึก ทำให้ความถูกต้องของแบบจำลองลดน้อยลง สำหรับขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติก็เช่นกัน หากเกิดปัญหาการปรับเหมาะเกินไปขึ้น แบบจำลองหรือคุณลักษณะที่ได้จะเหมาะสำหรับใช้เป็นตัวแทนของข้อมูลฝึกเท่านั้น แต่จะไม่สามารถใช้เป็นตัวแทนของข้อมูลทดสอบได้ และด้วยเหตุที่ตัวเข้ารหัสอัตโนมัติมีการทำงานคล้ายกับข่ายงานประสาทเทียม ปัญหาการปรับเหมาะเกินไปจึงสามารถแก้ไขได้ด้วยวิธีการทำให้ถูกต้อง (Regularization method) โดยเพิ่มพจน์ย่อยสลายค่าน้ำหนัก (Weight decay term) เข้าไปที่ฟังก์ชันจุดประสงค์ของตัวเข้ารหัสอัตโนมัติ ดังนี้

$$J_{AE}(W, b) = \min_{(W, b)} \left\{ \frac{1}{m} \cdot \sum_{i=1}^m L(x^{(i)}, y^{(i)}) + \lambda \sum_{\ell=1}^2 \sum_{j=1}^{d_x} \sum_{i=1}^{d_h} (W_{\ell})_{ij}^2 \right\}$$

โดยที่  $\lambda$  คือพารามิเตอร์ควบคุมการย่อยสลายของน้ำหนัก (Weight decay parameter)

## 2.1.2 ตัวเข้ารหัสอัตโนมัติแบบเบาบาง (Sparse Auto-Encoder)

ตัวเข้ารหัสอัตโนมัติแบบเบาบาง คือ ตัวเข้ารหัสอัตโนมัติที่ทำการเรียนรู้จนได้พารามิเตอร์  $(W, b)$  ที่สามารถแปลงข้อมูลเป็นคุณลักษณะ  $a$  ซึ่งมีค่าของสมาชิกส่วนใหญ่เป็น 0 และเมื่อนำคุณลักษณะมาวาดภาพพบว่ามีลักษณะเป็นรูปขีด (pen strokes) คล้ายกับส่วนประกอบของภาพที่ถูกนำมาฝึก ตัวเข้ารหัสอัตโนมัติแบบเบาบางมีประโยชน์ทั้งในด้านการคำนวณเพราะใช้คุณลักษณะเพียงไม่กี่คุณลักษณะก็สามารถใช้เป็นตัวแทนของข้อมูลได้ คุณลักษณะที่ได้มีเป็นคุณลักษณะเด่นของข้อมูล ดังภาพที่ 2-2 แสดงตัวอย่างจากการเรียนรู้ตัวเข้ารหัสอัตโนมัติแบบเบาบาง เป็นภาพที่ได้จากการนำ  $W_1$  ขนาด  $64 \times 256$  มาวาดเป็นภาพคุณลักษณะ 64 คุณลักษณะ จะเห็นว่าตัวอย่างทดสอบที่มีขนาด 256 สามารถถูกแทนด้วยคุณลักษณะเพียง 3 คุณลักษณะเท่านั้น



$[x_1, x_2, x_3, \dots, x_{256}]$  สามารถแทนได้ด้วย  $[0, 0, \dots, 0, 0.3, 0, \dots, 0, 0.8, \dots, 0, 0.5, 0]$

ภาพที่ 2-2: คุณลักษณะที่ได้จากการเรียนรู้ด้วยขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติแบบเบาบาง ซึ่งใช้คุณลักษณะเพียง 3 ค่า เป็นตัวแทนของตัวอย่างทดสอบขนาด  $16 \times 16$  ได้ [18]

การทำให้คุณลักษณะส่วนใหญ่ของข้อมูลมีค่าเป็น 0 คือการทำให้  $\sum_{j=1}^{d_h} a_j$  มีค่าน้อยๆ

ใกล้เคียง 0 โดยอาศัยหลักการลู่ออกคูลแบคเลเบลอ (Kullback-Leibler divergence) นั่นคือ

$$KL(\rho \parallel \tilde{\rho}) = \rho \log \frac{\rho}{\tilde{\rho}} + (1-\rho) \log \frac{1-\rho}{1-\tilde{\rho}}$$

ซึ่งมีคุณสมบัติสำคัญคือ ค่า  $KL(\rho \parallel \tilde{\rho})$  มีค่า

ต่ำสุดเป็น 0 เมื่อ  $\tilde{\rho} = \rho$  และ  $KL(\rho \parallel \tilde{\rho})$  มีค่าเพิ่มขึ้นแบบทางเดียว (Monotone increasing)

เมื่อ  $\tilde{\rho}$  ลู่ออกจาก  $\rho$  ดังที่ภาพ 2-3 ดังนั้นหากเราต้องการให้  $\sum_{j=1}^{d_h} a_j$  มีค่าน้อยๆ เราสามารถเพิ่ม

ฟังก์ชันลู่ออกคูลแบคเลเบลอเข้าไปที่ฟังก์ชันจุดประสงค์ของตัวเข้ารหัสอัตโนมัติได้ดังนี้

$$J_{\text{sparse}}(W, b) = J_{AE}(W, b) + \beta \cdot \frac{1}{m} \sum_{i=1}^m KL(\rho \parallel \tilde{\rho}_i)$$


โดยกำหนดให้  $\beta$  เป็นค่าน้ำหนักสำหรับควบคุมการลู่เข้าของฟังก์ชันความเบาบาง,  $\tilde{\rho} = \sum_{j=1}^{d_h} a_j$

และ  $\rho$  เป็นค่าคงที่ เรียกว่า  $\rho$  พารามิเตอร์สำหรับกำหนดความเบาบาง (Sparsity parameter)

ตัวอย่างเช่น หากต้องการให้  $\sum_{j=1}^{d_h} a_j$  น้อยๆ เข้าใกล้ 0.1 ให้กำหนด  $\rho = 0.1$  ขั้นตอนการหาค่า

เหมาะที่สุดก็จะทำงานเพื่อหา  $(W, b)$  ที่ทำให้ค่าความผิดพลาดจากการสร้างใหม่มีค่าต่ำที่สุดและ

ทำให้ผลรวมของคุณลักษณะ  $\tilde{\rho} = \sum_{j=1}^{d_h} a_j$  มีค่าเข้าใกล้ 0.1 ที่สุด




ภาพที่ 2-3: กราฟของฟังก์ชันคูลแบคเลเบลอ โดยที่  $\rho = 0.1$

### 2.1.3 ตัวเข้ารหัสอัตโนมัติแบบลดการรบกวน (Denosing Auto-Encoder)

ตัวเข้ารหัสอัตโนมัติแบบลดการรบกวน คือ ตัวเข้ารหัสอัตโนมัติที่มีการเปลี่ยนข้อมูลเริ่มต้น  $x$  ให้เป็นข้อมูลที่ถูกรบกวน  $\tilde{x}$  (Corrupted input) โดยใช้ค่าเฉลี่ยของการส่งแบบสุ่ม (means of a stochastic mapping)  $\tilde{x} \sim q_D(\tilde{x} | x)$  เมื่อข้อมูลถูกรบกวนแล้วจึงเริ่มขั้นตอนตามวิธีของตัวเข้ารหัสอัตโนมัติแบบปกติ กล่าวคือ ทำการคำนวณป้อนค่าไปข้างหน้าด้วยสมการ  $a^{(i)} = \text{sigmoid}(W_1 \tilde{x}^{(i)} + b_1)$  และ  $y^{(i)} = \text{sigmoid}(W_2 a^{(i)} + b_2)$  แต่ฟังก์ชันจุดประสงค์ยังคงเป็นการคำนวณค่าต่ำสุดของผลต่างระหว่าง  $x^{(i)}$  กับ  $y^{(i)}$  ดังภาพที่ 2-4 ดังนั้นตัวเข้ารหัสอัตโนมัติแบบลดการรบกวนจึงมีความสามารถในการฝึกคุณลักษณะให้มีความทนทาน เพราะแม้ว่าจะเรียนรู้จากข้อมูลรบกวน  $\tilde{x}$  แต่สามารถแปลงกลับไปเป็นข้อมูลเริ่มต้น  $x$  อีกครั้งได้

โดยทั่วไป นิยมใช้ตัวรบกวน  $q_D$  3 รูปแบบ คือ 1) ตัวรบกวนแบบเกาส์เซียน (Gaussian noise) เป็นตัวรบกวนอย่างง่ายซึ่งเหมาะกับข้อมูลที่มีค่าเป็นจำนวนจริง หากข้อมูลรูปภาพถูกรบกวนด้วยตัวรบกวนนี้ ภาพที่ได้จะมีลักษณะคล้ายกับการถูกรอยด้วยเม็ดทรายกระจายทั่วภาพ 2) ตัวรบกวนแบบพริกไทยและเกลือ (Salt and pepper noise) เป็นตัวรบกวนที่ทำงานโดยการสุ่มปรับให้ข้อมูลบางค่าเป็น 0 หรือ 1 หากข้อมูลรูปภาพถูกรบกวนด้วยตัวรบกวนนี้ พิกเซลที่ปรับค่าเป็น 0 มีลักษณะคล้ายกับการถูกรอยด้วยเกลือและพิกเซลที่ปรับค่าเป็น 1 มีลักษณะคล้ายกับการถูกรอยด้วยพริกไทย 3) ตัวรบกวนแบบการปิดบังด้วยหน้ากาก (Masking noise) เป็นตัวรบกวนที่ทำงานโดยการสุ่มปรับให้ข้อมูลบางค่าเป็น 0 ซึ่งงานวิจัยนี้เลือกใช้ตัวรบกวนรูปแบบนี้ เพราะทำให้ข้อมูลมีลักษณะของการถูกปิดไว้หรือมีลักษณะคล้ายกับการทำให้ข้อมูลบางส่วนหายไป



ภาพที่ 2-4: โครงสร้างการทำงานของขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติแบบลดการรบกวน [14]

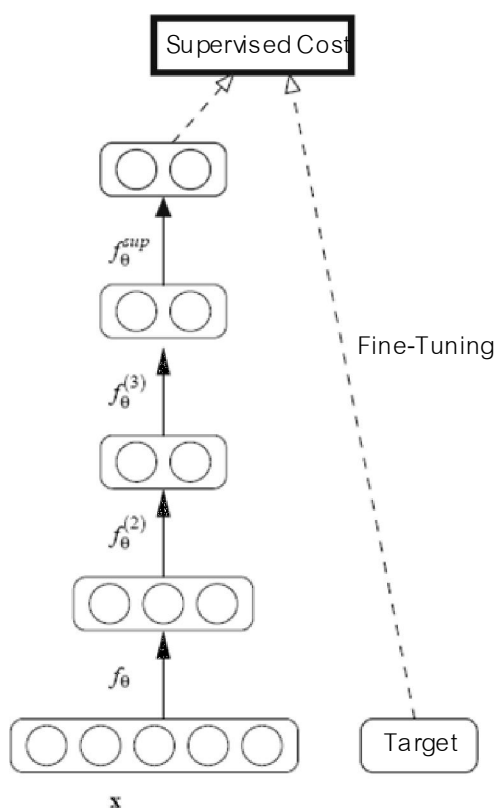
จากลักษณะการทำงานของตัวเข้ารหัสอัตโนมัติแบบลดการรบกวน สรุปได้ว่าตัวเข้ารหัสอัตโนมัติแบบลดการรบกวน มีประโยชน์ในการหาคุณลักษณะที่ดีที่แม้จะเรียนรู้มาจากข้อมูลที่ถูกรบกวน แต่ยังสามารถใช้เป็นตัวแทนของข้อมูลได้ หรือกล่าวได้ว่า คุณลักษณะที่ได้มีความทนทานต่อการถูกรบกวน แม้ว่าข้อมูลขาเข้าบางส่วนถูกรบกวน ตัวเข้ารหัสอัตโนมัติแบบลดการรบกวนก็สามารถเรียนรู้เพื่อเติมค่าที่หายไปของข้อมูลได้

## 2.2 ตัวเข้ารหัสอัตโนมัติแบบหลายชั้น (Stacked Auto-Encoder)

ตัวเข้ารหัสอัตโนมัติที่ได้กล่าวมาในหัวข้อ 2.1 เป็นเพียงการเรียนรู้คุณลักษณะเพียงชั้นเดียว ยังไม่ใช้การเรียนรู้เชิงลึกที่จะต้องมีความซับซ้อนมากกว่า 3 ชั้นขึ้นไป ซึ่งการนำตัวเข้ารหัสอัตโนมัติมาสร้างเป็นการเรียนรู้เชิงลึกได้ต้องนำมาต่อกันหลายชั้น เรียกว่า ตัวเข้ารหัสอัตโนมัติแบบหลายชั้น ขั้นตอนการฝึกใช้หลักการแยกเป็นชั้นแบบละโมบ (Greedy layer-wise) คือฝึกให้เสร็จไปที่ละชั้น จากชั้นแรกข้อมูลขาเข้าเป็นข้อมูลดิบ (Raw data)  $x$  เมื่อทำการฝึกจนเสร็จจะได้พารามิเตอร์  $\theta^{(1)}$  และฟังก์ชัน  $f_{\theta^{(1)}}$  ที่สามารถแปลงข้อมูล  $x$  เป็นคุณลักษณะ  $a^{(1)}$  ได้ จากนั้นใช้คุณลักษณะ  $a^{(1)}$  เป็นข้อมูลขาเข้าสำหรับการฝึกในชั้นที่สอง จนได้พารามิเตอร์  $\theta^{(2)}$  และฟังก์ชัน  $f_{\theta^{(2)}}$  ที่สามารถแปลงข้อมูล  $a^{(1)}$  เป็นคุณลักษณะ  $a^{(2)}$  ทำเช่นนี้ไปเรื่อยๆจนถึงชั้นบนสุดจะเป็นการเรียนรู้แบบชี้้นำ ดังภาพที่ 2-5

เมื่อทำการฝึกตัวเข้ารหัสอัตโนมัติแบบหลายชั้นจนเสร็จ ขั้นตอนสุดท้ายเป็นขั้นตอนวิธีการปรับซัด (Fine-tuning) คือการเรียนรู้แบบชี้้นำ โดยเริ่มจากการคำนวณบ่อนค่าไปข้างหน้าจะเริ่มตั้งแต่ชั้นแรกไปจนถึงชั้นสุดท้ายและทำการปรับพารามิเตอร์ของทุกชั้นพร้อมกันอีกครั้งหนึ่ง เพื่อให้พารามิเตอร์ทั้งระบบสอดคล้องกัน ผลลัพธ์ที่ได้มีค่าความแม่นยำของการจำแนกเพิ่มสูงขึ้น

ในวิทยานิพนธ์ฉบับนี้จะทำการทดลองกับตัวเข้ารหัสอัตโนมัติเพียงชั้นเดียว เพื่อทดสอบประสิทธิภาพของขั้นตอนวิธีที่นำเสนอก่อน โดยสมมติฐานว่าหากการเรียนรู้หนึ่งชั้นให้ผลลัพธ์ที่ดีขึ้น ย่อมส่งผลให้การเรียนรู้หลายชั้นมีประสิทธิภาพที่ดียิ่งขึ้น



ภาพที่ 2-5: โครงสร้างการทำงานของตัวเข้ารหัสอัตโนมัติแบบหลายชั้น [19]

### 2.3 การถดถอยซอฟต์แมกซ์ (Softmax Regression)

ขั้นตอนวิธีการถดถอยซอฟต์แมกซ์ คือ ขั้นตอนวิธีการถดถอยโลจิสติกแบบจำแนกหลายประเภท (Multi-class logistic regression method) ซึ่งเป็นขั้นตอนวิธีการเรียนรู้แบบชี้้นำ โดยขั้นตอนการทำงาน เริ่มจากตัวอย่างฝึก  $m$  ตัวอย่าง แต่ละตัวอย่างมีฉลากเป้าหมาย (Target label) ซึ่งมีค่าแตกต่างกัน  $k$  ค่า นั่นคือ  $\{(x^{(1)}, t^{(1)}), (x^{(2)}, t^{(2)}), \dots, (x^{(m)}, t^{(m)})\}$  โดยที่  $x \in [0, 1]^{d_x}$  และ  $t^{(i)} \in \{1, 2, \dots, k\}$  และกำหนดพารามิเตอร์เริ่มต้นแบบสุ่ม  $w \in \mathbb{R}^{k \times d_x}$  จากนั้นคำนวณป้อนค่าไปข้างหน้าได้ข้อมูลขาออกเป็นค่าความน่าจะเป็นที่ข้อมูล  $x^{(i)}$  มีฉลากเป็น  $j$  โดยที่  $j = 1, 2, 3, \dots, k$  โดยใช้สมการ



$$P(y^{(i)} = j | x^{(i)}) = \frac{e^{\{W_j x^{(i)} - \max(W_j x^{(i)})\}}}{\sum_{j=1}^k e^{\{W_j x^{(i)} - \max(W_j x^{(i)})\}}}, \forall j \in \{1, 2, 3, \dots, k\}$$

โดยที่  $W_j$  คือเมทริกซ์  $W$  แถวที่  $j$  จากนั้นเริ่มขั้นตอนการหาค่าเหมาะที่สุดเพื่อปรับ  $W$  ให้  $P(y^{(i)} = j | x^{(i)})$  มีค่าเข้าใกล้ 1 เมื่อ  $t^{(i)} = j$  และ  $P(y^{(i)} = j | x^{(i)})$  มีค่าเข้าใกล้ 0 เมื่อ  $t^{(i)} \neq j$  โดยใช้ฟังก์ชันจุดประสงค์ดังนี้

$$J_{\text{softmax}}(W) = \min_W \left\{ \frac{1}{m} \sum_{i=1}^m \sum_{j=1}^k \left[ \left( 1(t^{(i)}, j) - P(y^{(i)} = j | x^{(i)}) \right) \cdot (x^{(i)})^T \right] \right\}$$


โดยที่  $1(t^{(i)}, j) = 1$  เมื่อ  $t^{(i)} = j$  และ  $1(t^{(i)}, j) = 0$  เมื่อ  $t^{(i)} \neq j$  ขั้นตอนวิธีสำหรับการหาค่าเหมาะที่สุดสามารถใช้ได้ทั้ง วิธีการเคลื่อนลงตามความชัน, วิธีบีเอพีเอสแบบจำกัดความจำ และวิธีความชันสังยุค โดยในงานวิจัยนี้เลือกใช้ขั้นตอนวิธีบีเอพีเอสแบบจำกัดความจำเช่นเดียวกับการปรับพารามิเตอร์ในขั้นตอนวิธีตัวเข้าอัตโนมัติ

## 2.4 งานวิจัยที่เกี่ยวข้อง

งานวิจัยของ Y. Bengio [1] ได้นำเสนอสถาปัตยกรรมการเรียนรู้เชิงลึกสำหรับปัญญาประดิษฐ์ (Learning Deep Architectures for AI) ซึ่งเป็นการอธิบายแนวคิดและทฤษฎีต่างๆ ที่เกี่ยวข้องกับการสถาปัตยกรรมการเรียนรู้เชิงลึกตั้งแต่จุดเริ่มต้นจนถึงปี 2009 รวมไปถึงการอธิบายประโยชน์จากขั้นตอนวิธีที่นำการเรียนรู้แบบไม่ชี้นำมาต่อกันหลายชั้น เช่น ข่ายงานความเชื่อเชิงลึก (Deep Belief Networks) เป็นต้น งานวิจัยนี้จึงมีประโยชน์อย่างยิ่งสำหรับผู้เริ่มศึกษา งานวิจัยที่เกี่ยวข้องกับการเรียนรู้เชิงลึก

งานวิจัยของ G. E. Hinton และ R. R. Salakhutdinov [12] ได้นำเสนอการลดขนาดมิติของข้อมูลด้วยข่ายงานประสาท (Reducing the Dimensionality of Data with Neural

Networks) โดยเสนอขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติต่อกันหลายชั้นและทดลองกับข้อมูลตัวเลข MNIST, ข้อมูล รูปหน้าคน Olivetti face และข้อมูลข้อความข่าว Reuters ผลการทดลองพบว่าการเรียนรู้เชิงลึกด้วยวิธีการนำตัวเข้ารหัสอัตโนมัติมาต่อกันหลายชั้นให้ผลลัพธ์ที่ดีกว่าการเรียนรู้เชิงตื้น โดยเฉพาะอย่างยิ่งกับข้อมูล MNIST ที่เริ่มต้นจากข้อมูลขาเข้าขนาด 784 มิติจากนั้นทำการเรียนรู้ตัวเข้ารหัสอัตโนมัติจนได้คุณลักษณะขนาด 1000 มิติ และนำคุณลักษณะไปฝึกต่ออีกสามชั้นจนได้คุณลักษณะขนาด 500, 250 และ 2 มิติ ชั้นสุดท้ายเรียนรู้คุณลักษณะขนาด 2 มิติ เพื่อนำข้อมูลแต่ละตัวอย่างมาลงจุดในระนาบ 2 มิติ ได้ผลลัพธ์ดังภาพที่ 2-6



ภาพที่ 2-6: คุณลักษณะ 2 มิติที่ได้จากการฝึกข้อมูลตัวเลขลายมือ MNIST จำนวน 60,000 ตัวอย่างฝึก โดยสุ่มเลือกตัวเลขละ 500 ตัว รวม 5,000 ตัวเลข ภาพด้านซ้ายได้จากขั้นตอนวิธีการวิเคราะห์องค์ประกอบหลัก (Principle component analysis) และภาพด้านขวาจากขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติแบบ 4 ชั้น โดยใช้จำนวนคุณลักษณะ เริ่มตั้งแต่ชั้นขาเข้าจนถึงชั้นสุดท้าย เป็น 784-1000-500-250-2 ซึ่งภาพที่ได้จะเห็นถึงการรวมกลุ่มกันของคุณลักษณะของข้อมูลประเภท (Class) เดียวกัน

งานวิจัยของ D. Erhan และคณะ [20] ได้นำเสนองานวิจัยเรื่อง ทำไมขั้นตอนก่อนการฝึกแบบไม่ชี้นำจึงเพิ่มประสิทธิภาพให้กับการเรียนรู้เชิงลึก (Why does unsupervised pre-training

help deep learning) ซึ่งอธิบายถึงเหตุผลและความสำคัญของการเรียนรู้คุณลักษณะต่อการเรียนรู้แบบชี้หน้า โดยเปรียบเทียบผลการทดลองของการเรียนรู้แบบชี้หน้าอย่างเดียวกับการเรียนรู้แบบชี้หน้าที่ทำการเรียนรู้คุณลักษณะแบบไม่ชี้หน้าก่อน ผลการทดลองก็พบความแตกต่างอย่างเห็นได้ชัด งานวิจัยนี้จึงช่วยแสดงให้เห็นถึงประโยชน์ของการพัฒนาการเรียนรู้คุณลักษณะแบบไม่ชี้หน้าที่จะช่วยเพิ่มประสิทธิภาพให้กับการเรียนรู้เชิงลึก

งานวิจัยของ S. Rifai, P. Vincent, X. Muller, X. Glorot และ Y. Bengio [21] ได้นำเสนอขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติแบบหดย่อ (Contractive Auto-Encoder) ซึ่งเป็นตัวเข้ารหัสอัตโนมัติที่เพิ่มฟังก์ชันโพรเบนิอุสนอร์มของจาโคเบียน (The Frobenius norm of the Jacobian)  $J_f(x)$  เข้าไปที่ฟังก์ชันจุดประสงค์ ดังนี้

$$J_{CAE}(W, b) = J_{AE}(W, b) + \lambda \|J_f(x)\|_F^2$$

โดยที่  $x^{(i)}$  คือข้อมูลขาเข้า,  $h^{(i)} = \text{sigmoid}(W^{(1)}x^{(i)} + b^{(1)})$  และ

$$\|J_f(x)\|_F^2 = \sum_{ij} \left( \frac{\partial h_j^{(i)}(x)}{\partial x^{(i)}} \right)^2 \text{ เรียกฟังก์ชัน } \|J_f(x)\|_F^2 \text{ นี้ว่า ฟังก์ชันการหดย่อ (Contractive}$$

penalty) ซึ่งผลการทดลองพบว่าตัวเข้ารหัสอัตโนมัติแบบหดย่อให้ค่าความแม่นยำที่สูงขึ้นเมื่อเปรียบเทียบกับตัวเข้ารหัสอัตโนมัติแบบพื้นฐานและตัวเข้ารหัสอัตโนมัติแบบลดการรบกวน

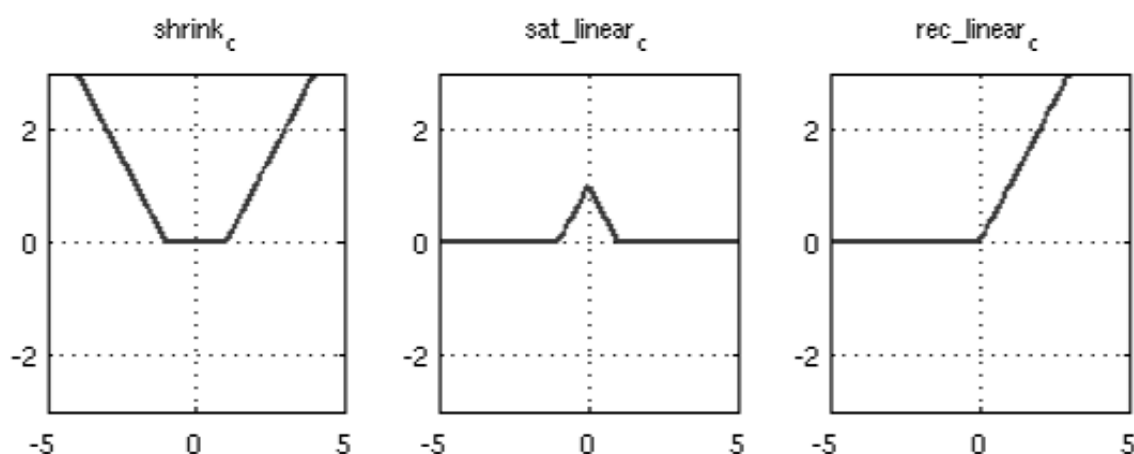
งานวิจัยของ Quoc V. Le, J. Ngiam, A. Coates, A. Lahiri, B. Prochown และ Andrew Y. Ng [22] ได้นำเสนอขั้นตอนการหาค่าเหมาะที่สุดสำหรับการเรียนรู้เชิงลึก (On Optimization Methods for Deep Learning) โดยการทดลองเปรียบเทียบความซับซ้อนและระยะเวลาในการหาผลเฉลยที่ดีที่สุดของปัญหาการเรียนรู้เชิงลึกระหว่างขั้นตอนวิธีการเคลื่อนลงตามความชัน, วิธีบีเอฟจีเอสแบบจำกัดความจำ และวิธีความชันสังยุค ซึ่งผลการทดลองพบว่าวิธีบีเอฟจีเอสแบบจำกัดความจำและวิธีความชันสังยุคมีประสิทธิภาพที่ดีกว่าวิธีการเคลื่อนลงตามความชันในหลายกรณี หนึ่งในหลายกรณีนั้นมีการทดลองกับตัวเข้ารหัสอัตโนมัติแบบเบาบางด้วยการทดลองยังพบว่าวิธีบีเอฟจีเอสแบบจำกัดความจำเหมาะสำหรับการหาค่าเหมาะที่สุดของปัญหาที่มีขนาดมิติไม่มากจนเกินไปและเหมาะกับขั้นตอนวิธีที่ใช้พารามิเตอร์จำนวนน้อย เช่น

ขั้นตอนวิธีข่ายงานประสาทคอนโวลูชันแนล (Convolutional neural network) และพบว่าวิธีความ  
ชั้นสั่งยุคเหมาะกับการใช้หาค่าเหมาะที่สุดของปัญหาที่มีขนาดมิติมาก

งานวิจัยของ R. Goroshin และ Y. LeCun [23] ได้นำเสนอขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติ  
แบบอิ่มตัว (Saturating Auto-Encoders) ซึ่งเป็นตัวเข้ารหัสอัตโนมัติที่ปรับปรุงวิธีการทำให้ถูกต้อง  
โดยใช้ฟังก์ชันจุดประสงค์ดังนี้

$$J_{SATAE}(W, b) = \min_{(W, b)} \left\{ \frac{1}{2m} \cdot \sum_{i=1}^m \|x - (W_2 \cdot f_c(W_1 x + b_1) + b_2)\|^2 + \alpha \sum_{i=1}^{d_h} f_c(W_1 x + b_1) \right\}$$


โดยที่  $f_c$  คือฟังก์ชันการกระตุ้น (Activation function) ซึ่งจากเดิมในขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติ  
แบบพื้นฐานจะใช้ฟังก์ชันซิกมอยด์หรือฟังก์ชันไฮเพอร์โบลิกแทนเจนต์ แต่ตัวเข้ารหัสอัตโนมัติแบบ  
อิ่มตัวจะเปลี่ยนเป็นฟังก์ชันที่ทำให้สมบูรณ์ (Complementary function) ได้แก่ฟังก์ชันชริก  
(Shrink), ฟังก์ชันเชิงเส้นแบบทำให้ถูกต้อง (Rectified linear function) และฟังก์ชันเชิงเส้นแบบ  
อิ่มตัว (Saturated linear function) กราฟของฟังก์ชันทั้ง 3 ประเภท ดังภาพที่ 2-7



ภาพที่ 2-7: กราฟของฟังก์ชันที่ทำให้สมบูรณ์ ได้แก่ ฟังก์ชันชริก ฟังก์ชันเชิงเส้นแบบอิ่มตัว และ  
ฟังก์ชันเชิงเส้นแบบทำให้ถูกต้อง ตามลำดับ

งานวิจัยของ G. Zhou, K. Sohn และ H. Lee propose [24] ได้นำเสนอการเรียนรู้คุณลักษณะแบบเพิ่มออนไลน์ด้วยตัวเข้ารหัสอัตโนมัติแบบลดการรบกวน (Online incremental feature learning with Denoising auto-encoders) ซึ่งเป็นการเรียนรู้คุณลักษณะของข้อมูลแบบออนไลน์ขนาดใหญ่และมีจุดประสงค์หลักเพื่อหาจำนวนคุณลักษณะที่เหมาะสมที่สุดกับข้อมูลในช่วงเวลาหนึ่ง โดยขั้นตอนวิธีในการเรียนรู้ประกอบด้วย 2 ขั้นตอนหลัก คือ ขั้นตอนการเพิ่มคุณลักษณะ (Feature adding) และขั้นตอนการรวมคุณลักษณะ (Feature merging) ดังภาพที่ 2-8 ประโยชน์ของคุณลักษณะที่ถูกเพิ่มเข้าไปจะช่วยลดค่าความผิดพลาดจากการสร้างใหม่ และคุณลักษณะที่ถูกรวมเข้าด้วยกันจะช่วยลดปัญหาการปรับเหมาะเกินไป จากการทดลองพบว่าได้ผลที่ดีที่สุดในยุคสมัย (State-of-the-art) กับข้อมูลออนไลน์ขนาดใหญ่

ขั้นตอนการเพิ่มคุณลักษณะของงานวิจัยนี้มีการทำงานที่คล้ายกับขั้นตอนการเพิ่มคุณลักษณะของงานวิจัยที่นำเสนอในวิทยานิพนธ์เล่มนี้ แต่มีวัตถุประสงค์ของการเพิ่มคุณลักษณะที่แตกต่างกัน ซึ่งรายละเอียดจะกล่าวในบทถัดไป



ภาพที่ 2-8: โครงสร้างการเรียนรู้คุณลักษณะแบบเพิ่มกับข้อมูลฝึกแบบออนไลน์ คุณลักษณะที่เพิ่มขึ้นคือหน่วยสี่เทาเข้มทางด้านขวา คุณลักษณะที่ถูกรวมเข้าด้วยกันคือหน่วยที่อยู่ในกรอบจุดและรวมเป็นคุณลักษณะที่หน่วยสี่ดำ

งานวิจัยของ Y. Bengio, A. Courville และ P. Vincent [2] ได้นำเสนอการทบทวนและมุมมองใหม่ต่อการเรียนรู้คุณลักษณะที่ใช้เป็นตัวแทน (Representation Learning: A Review and New Perspectives) ซึ่งเป็นการรวบรวมผลงานวิจัยที่เกี่ยวข้องกับการเรียนรู้คุณลักษณะแบบไม่ชี้แนะและการเรียนรู้อื่นๆที่เกี่ยวข้องกับการเรียนรู้เชิงลึก โดยมีจุดประสงค์สำคัญเพื่อตอบคำถาม

ว่าคุณลักษณะที่ดีควรเป็นอย่างไร งานวิจัยนี้จึงมีประโยชน์อย่างยิ่งสำหรับผู้ที่ต้องการติดตามพัฒนาการของการเรียนรู้คุณลักษณะและการเรียนรู้เชิงลึก รวมไปถึงทิศทางของงานวิจัยในอนาคต

งานวิจัยของ A. Coates, A. Ng และ H. Lee [25] ได้นำเสนอการวิเคราะห์ข่ายงานชั้นเดียวในการเรียนรู้คุณลักษณะแบบไม่ชี้แนะ (An analysis of single-layer networks in unsupervised feature learning) ซึ่งมีการแสดงให้เห็นถึงปัจจัยพื้นฐานง่ายๆ แต่มีผลกระทบต่อประสิทธิภาพของการเรียนรู้มากๆ เช่น การกำหนดจำนวนคุณลักษณะในชั้นซ่อนให้เหมาะสมมีความสำคัญกว่าการกำหนดจำนวนชั้นของการเรียนรู้หรือการเลือกขั้นตอนวิธีการการเรียนรู้ ผลการทดลองกับข้อมูล CIFAR-10 และข้อมูล NORB พบว่าการใช้คุณลักษณะจำนวนมากและใช้จำนวนชั้นหลายชั้นให้ผลลัพธ์ที่ดีที่สุดในยุคสมัย และยังพบว่าขั้นตอนวิธีการจัดกลุ่มด้วยค่าเฉลี่ย  $k$  ค่า (K-Mean clustering) ซึ่งเป็นขั้นตอนวิธีเก่าแก่ที่สามารถจัดทำและเรียนรู้ได้รวดเร็วและไม่ต้องปรับพารามิเตอร์จำนวนมาก ให้ผลลัพธ์ที่ดีขึ้นเมื่อเทียบกับการทดลองในอดีต

งานวิจัยของ Hinton และคณะ [26] ได้นำเสนอการปรับปรุงข่ายงานประสาทโดยการป้องกันการปรับตัวร่วมของคุณลักษณะ (Improving neural networks by preventing co-adaptation of feature detectors) ซึ่งเป็นการเสนอขั้นตอนวิธีที่เรียบง่าย นั่นคือการสุ่มตัดข้อมูลทิ้งไป ซึ่งสามารถเลือกตัดทิ้งได้ทั้งชั้นขาเข้าและชั้นซ่อน เรียกขั้นตอนวิธีนี้ว่า วิธีสัญญาณตกหาย (Dropout method) เกิดประโยชน์ต่อการป้องกันปัญหาการปรับเหมาะเกินไปและช่วยให้การประมวลผลรวดเร็วขึ้น ซึ่งผลการทดลองพบว่าวิธีสัญญาณตกหายเพิ่มประสิทธิภาพให้กับขั้นตอนวิธีการเรียนรู้แบบไม่ชี้แนะทุกวิธี ตัวอย่างเช่น ตัวเข้ารหัสอัตโนมัติ, ข่ายงานประสาทคอนโวลูชัน, โมเดลซ่อนของมาร์คอฟ (Hidden Markov model), ข่ายงานความเชื่อเชิงลึก เป็นต้น และยังได้ผลการทดลองที่ดีที่สุดในยุคสมัยกับหลายปัญหาการจำแนก[31]

งานวิจัยของ Jason Tyler Rolfe และ Yann LeCun [27] ได้นำเสนอตัวเข้ารหัสอัตโนมัติแบบเบาบางและวนกลับผสมการแยกแยะ (Discriminative Recurrent Sparse Auto-Encoders) ซึ่งเป็นการนำขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติแบบวนกลับมาประยุกต์ใช้กับตัวเข้ารหัสอัตโนมัติแบบเบาบาง และนำฟังก์ชันจุดประสงค์ของการเรียนรู้แบบไม่ชี้แนะรวมกับฟังก์ชันจุดประสงค์ของการเรียนรู้แบบชี้แนะ โดยขั้นตอนของการเรียนรู้ตัวเข้ารหัสอัตโนมัติแบบวนกลับ เริ่มต้นจากข้อมูลขาเข้า  $x$  ขนาด  $m$  มิติ และข้อมูลชั้นซ่อน  $z^t$  ขนาด  $n$  มิติ ซึ่ง  $z^t$  เป็นข้อมูลชั้นซ่อนที่ได้จากการวนกลับ

รอบที่  $t$  จากทั้งหมด  $T$  รอบ โดยเริ่มต้นกำหนดให้  $z^0 = 0$  และ  $T$  เป็นค่าคงที่ที่กำหนดขึ้น การคำนวณป้อนค่าไปข้างหน้าเพื่อให้ได้ข้อมูลขาออก  $y$  ใช้สมการ

$$z^{t+1} = \max(0, E \cdot x + S \cdot z^t - b) \text{ และ } \bar{x} = D \cdot z^T$$

เมื่อ  $E$  เป็นเมทริกซ์เข้ารหัส (Encoding matrix) ขนาด  $n \times m$ ,  $S$  เป็นเมทริกซ์ที่ใช้อธิบายต่อไป (Explaining away matrix) ขนาด  $n \times n$ ,  $b$  เป็นเวกเตอร์ค่าคลาดเคลื่อนขนาด  $n$  มิติ และ  $D$  เป็นเมทริกซ์ถอดรหัส (Decoding matrix) ขนาด  $m \times n$  เมื่อคำนวณป้อนค่าไปข้างหน้าเสร็จ นำ  $\bar{x}$  ไปคำนวณค่าความผิดพลาดจากการสร้างใหม่ของ  $x$  กับ  $\bar{x}$  ได้ฟังก์ชันจุดประสงค์ของส่วนที่เป็นการเรียนรู้แบบไม่ชี้้นำดังนี้

$$J_U = \min_{(E,S,b)} \left\{ \frac{1}{2} \cdot \|x - \bar{x}\|_2^2 + \lambda \cdot \|z^T\|_1 \right\}$$

และสำหรับการเรียนรู้แบบชี้้นำเริ่มจากนำ  $z^T$  ไปปรับให้เป็นปกติ (Normalization) ได้เป็น

$$\frac{z^T}{\|z^T\|} \text{ และนำไปคำนวณกับฟังก์ชันโลจิสติก } \text{logistic}_y(z) = z_y - \log\left(\sum_i e^{z_i}\right) \text{ ได้ฟังก์ชัน}$$


จุดประสงค์ของส่วนที่เป็นการเรียนรู้แบบชี้นำดังนี้

$$J_S = \min_C \left\{ \text{logistic}_y\left(C \cdot \frac{z^T}{\|z^T\|}\right) \right\}$$

โดยที่  $C$  เป็นเมทริกซ์พารามิเตอร์ขนาด  $n \times \ell$  เมื่อ  $\ell$  คือจำนวนประเภท (Class) ของข้อมูล ดังนั้นฟังก์ชันจุดประสงค์ของตัวเข้ารหัสอัตโนมัติแบบเบาบางและวนกลับผสมการแยกแยะ คือ

$$J_{DrSAE} = J_U + J_S \text{ โดยสรุปแล้วขั้นตอนวิธีนี้เป็นการเรียนรู้แบบชี้นำรวมกับการเรียนรู้แบบไม่}$$

ชี้นำ การทำงานคล้ายกับขั้นตอนการปรับขีด แต่มีการวนกลับของการคำนวณข้อมูลชั้นซ่อน แสดงเป็นโครงสร้างสถาปัตยกรรมได้ดังภาพที่ 2-9



ภาพที่ 2-9: โครงสร้างสถาปัตยกรรมของชั้นต่อนิวรัลตัวเข้ารหัสอัตโนมัติแบบเบาบางและวนกลับ  
 ผสมการแยกแยะ เพื่อเป็นการฝึกพารามิเตอร์  $E, S, b, D, C$



### บทที่ 3

#### การสร้างคุณลักษณะแบบเพิ่ม

ในบทนี้เป็นการอธิบายแนวคิดและขั้นตอนการสร้างคุณลักษณะแบบเพิ่ม ขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติทั้งหมดที่ได้กล่าวมาในหัวข้อที่ 2.1 มีขั้นตอนการสร้างคุณลักษณะที่เหมือนกัน นั่นคือ 1) คุณลักษณะทั้งหมดจะถูกสร้างขึ้นพร้อมกันตั้งแต่เริ่มต้นการฝึก กล่าวคือ คำนวณค่าทั้งหมดจะถูกใช้คำนวณค่าไปข้างหน้าพร้อมกันและถูกปรับค่าทุกรอบในขั้นตอนการฝึก 2) จำนวนคุณลักษณะที่ต้องกำหนดขึ้นเอง หากกำหนดจำนวนคุณลักษณะมากเกินไป ผลจากการฝึกคุณลักษณะทั้งหมดพร้อมกัน อาจทำให้เกิดคุณลักษณะที่มีค่าซ้ำซ้อนกัน (Redundancy) และได้คุณลักษณะที่ไม่มีประโยชน์ แต่หากกำหนดจำนวนคุณลักษณะน้อยเกินไป ผลจากการฝึกอาจทำให้เกิดคุณลักษณะที่ไม่เพียงพอต่อการใช้เป็นตัวแทนข้อมูล ดังนั้นงานวิจัยนี้จึงเสนอขั้นตอนการสร้างคุณลักษณะวิธีใหม่โดยยังคงกำหนดจำนวนคุณลักษณะขึ้นเอง แต่เพิ่มความหลากหลายของคุณลักษณะโดยการปรับเปลี่ยนให้เกิดลำดับของการสร้าง เรียกขั้นตอนการสร้างคุณลักษณะวิธีใหม่นี้ว่า การสร้างคุณลักษณะแบบเพิ่ม (Incremental feature construction) กล่าวคือคุณลักษณะทั้งหมดจะไม่ถูกสร้างขึ้นพร้อมกัน แต่จะถูกแบ่งออกเป็นกลุ่มๆ และสร้างขึ้นทีละกลุ่มในระหว่างการฝึก โดยคุณลักษณะพื้นฐาน (Primitive/simple feature) ที่จำเป็นของข้อมูลจะได้จากกลุ่มของคุณลักษณะที่ถูกสร้างขึ้นก่อน และคุณลักษณะที่ถูกสร้างขึ้นนี้จะส่งผลต่อคุณลักษณะในกลุ่มถัดไป ทำให้คุณลักษณะที่สร้างขึ้นภายหลังกลายเป็นคุณลักษณะเสริม (Finer/more complicated feature) ที่จะช่วยเพิ่มความสมบูรณ์ในการใช้เป็นตัวแทนข้อมูลได้ โดยรายละเอียดของขั้นตอนการฝึกจะกล่าวในย่อหน้าถัดไป

ขั้นตอนวิธีการสร้างคุณลักษณะแบบเพิ่มด้วยตัวเข้ารหัสอัตโนมัติแบบพื้นฐาน กำหนดค่าเริ่มต้น  $\{x^{(1)}, x^{(2)}, \dots, x^{(m)}\}$  เป็นเซตของตัวอย่างฝึก  $m$  ตัวอย่าง โดยที่  $x^{(i)} \in [0, 1]^{d_x}$ ,  $\{a^{(1)}, a^{(2)}, \dots, a^{(k)}\}$  เป็นเซตของกลุ่มของคุณลักษณะ  $k$  กลุ่ม โดยที่  $a^{(i)} \in [0, 1]^{d_{a^{(i)}}}$  (ดังนั้น  $a^{(1)}$  เป็นกลุ่มของคุณลักษณะพื้นฐานที่จะถูกสร้างขึ้นก่อน และ  $a^{(2)}$  ถึง  $a^{(k)}$  เป็นกลุ่มของ

คุณลักษณะเสริมที่ถูกสร้างขึ้นตามลำดับ), เมทริกซ์ค่าน้ำหนัก  $W_1 = \begin{bmatrix} W_1^{(1)} \\ W_1^{(2)} \\ \vdots \\ W_1^{(k)} \end{bmatrix}$  โดยที่

$W_1^{(i)} \in \mathbb{R}^{d_{a^{(i)}} \times d_x}$  และ  $W_2 = \begin{bmatrix} W_2^{(1)} & W_2^{(2)} & \dots & W_2^{(k)} \end{bmatrix}$  โดยที่  $W_2^{(i)} \in \mathbb{R}^{d_x \times d_{a^{(i)}}$   
และ  $b_1^{(i)} \in \mathbb{R}^{d_{a^{(i)}} \times 1}$  และ  $b_2^{(i)} \in \mathbb{R}^{d_x \times 1}$  เป็นเวกเตอร์ค่าคลาดเคลื่อนของคุณลักษณะ  $a^{(i)}$   
และข้อมูลขาออก  $y$  ตามลำดับ

ขั้นตอนการสร้างคุณลักษณะแบบเพิ่ม เริ่มต้นจากการสร้างคุณลักษณะพื้นฐาน  $a^{(1)}$  โดยการคำนวณป้อนค่าไปข้างหน้าจากสมการเข้ารหัส

$$a^{(1)} = \text{sigm}(W_1^{(1)} x^{(i)} + b_1^{(1)})$$

และสมการถอดรหัส

$$y^{(i)} = \text{sigm}(W_2^{(1)} a^{(1)} + b_2^{(1)})$$

จากนั้นเข้าสู่ขั้นตอนการหาค่าเหมาะที่สุดโดยขั้นตอนวิธีบีเอพจีเอสแบบจำกัดความจำ ซึ่งเป็นการปรับค่า  $W_1^{(1)}$ ,  $b_1^{(1)}$ ,  $W_2^{(1)}$  และ  $b_2^{(1)}$  เพื่อหาค่าต่ำสุดของผลต่างระหว่าง  $x^{(i)}$  และ  $y^{(i)}$  โดยมีฟังก์ชันจุดประสงค์ดังนี้

$$J_{AE}(W_1^{(1)}, b_1^{(1)}, W_2^{(1)}, b_2^{(1)}) = \min_{(W, b)} \left\{ \frac{1}{m} \sum_{i=1}^m (x^{(i)} - y^{(i)})^2 + \lambda \sum_{\ell=1}^2 (W_\ell^{(1)})^2 \right\}$$

เมื่อฝึกคุณลักษณะกลุ่มแรกจนเสร็จเรียบร้อยแล้ว ให้ทำการเก็บรักษาค่า  $W_2^{(1)} a^{(1)} + b_2^{(1)}$ ไว้ สำหรับการฝึกคุณลักษณะในกลุ่มที่สองและจะไม่ถูกปรับค่าอีก ดังภาพที่ 3-1 และ 3-2

การฝึกคุณลักษณะในกลุ่มที่สองเริ่มต้นโดยการคำนวณป้อนค่าไปข้างหน้าเช่นเดิมด้วยสมการ

$$a^{(2)} = \text{sigm}(W_1^{(2)} x^{(i)} + b_1^{(2)})$$

แต่สมการถดถอยเป็น


$$y^{(i)} = \text{sigm}\left((W_2^{(1)} a^{(1)} + b_2) + (W_2^{(2)} a^{(1)} + b_2)\right)$$

จากนั้นเข้าสู่ขั้นตอนการปรับพารามิเตอร์เพื่อหาค่าที่เหมาะสมที่สุดเช่นเดิม จนได้  $W_1^{(2)}$ ,  $b_1^{(2)}$ ,  $W_2^{(2)}$  และ  $b_2^{(2)}$  ที่ทำให้ผลต่างระหว่าง  $x^{(i)}$  และ  $y^{(i)}$  มีค่าต่ำที่สุด หรือกล่าวได้ว่าฟังก์ชันจุดประสงค์สำหรับการเรียนรู้คุณลักษณะกลุ่มที่สองคือ


$$J_{AE}(W_1^{(2)}, b_1^{(2)}, W_2^{(2)}, b_2^{(2)}) = \min_{(W,b)} \left\{ \frac{1}{m} \cdot \sum_{i=1}^m (x^{(i)} - y^{(i)})^2 + \lambda \sum_{\ell=1}^2 (W_\ell^{(2)})^2 \right\}$$

เมื่อฝึกคุณลักษณะกลุ่มที่สองเสร็จก็ทำการเพิ่มคุณลักษณะในกลุ่มถัดไปและฝึกจนตามขั้นตอนที่ได้กล่าวมาข้างต้นจนครบทุกกลุ่ม ดังภาพที่ 3-3


นอกจากที่ขั้นตอนวิธีการสร้างคุณลักษณะแบบเพิ่มที่สามารถนำไปใช้แทนการสร้างคุณลักษณะแบบเดิมในขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติแต่ละแบบได้แล้ว ประโยชน์อย่างหนึ่งจากการแบ่งฝึกคุณลักษณะทีละกลุ่มคือการนำตัวเข้ารหัสอัตโนมัติหลายๆประเภทมาร่วมกันสร้างคุณลักษณะให้กับการฝึกข้อมูลชุดเดียวกันได้ แทนที่จะใช้ตัวเข้ารหัสอัตโนมัติประเภทเดียวกันกับทุกกลุ่ม ในงานวิจัยนี้ ได้นำตัวเข้ารหัสอัตโนมัติแบบบางซึ่งมีความสามารถในการเรียนรู้คุณลักษณะเด่นของข้อมูลมาใช้ร่วมกับตัวเข้ารหัสอัตโนมัติแบบลดการรบกวนซึ่งมีความสามารถในการเรียนรู้คุณลักษณะที่ทนทานต่อการรบกวนได้ ผลการทดลองพบว่าคุณลักษณะที่ได้มีประสิทธิภาพในการจำแนกสูงขึ้น พร้อมกับอธิบายปัจจัยต่างๆที่ส่งผลต่อการเรียนรู้ ได้แก่ จำนวนคุณลักษณะพื้นฐาน จำนวนคุณลักษณะเสริม และลำดับของขั้นตอนวิธีการเรียนรู้ในแต่ละกลุ่ม โดยรายละเอียดจะกล่าวในบทที่ 4 และบทที่ 5 ต่อไป



ภาพที่ 3-1: โครงสร้างของการฝึกคุณลักษณะพื้นฐานในกลุ่มแรก  $a^{(1)}$



ภาพที่ 3-2: โครงสร้างของการฝึกคุณลักษณะเสริมในกลุ่มที่สอง  $a^{(2)}$   
โดยที่คุณลักษณะกลุ่มแรกถูกฝึกเสร็จแล้ว (คุณลักษณะสีเทา) และไม่ถูกปรับค่าอีก



ภาพที่ 3-3: โครงสร้างของการฝึกคุณลักษณะเสริมในกลุ่มที่สาม  $a^{(3)}$   
โดยที่คุณลักษณะกลุ่มแรกและกลุ่มที่สองถูกฝึกเสร็จแล้ว (คุณลักษณะสีเทา) และไม่ถูกปรับค่าอีก

## บทที่ 4

### การทดลองและผลการทดลอง

ในบทนี้เป็นการอธิบายรายละเอียดของการทดลอง ซึ่งประกอบไปด้วย เครื่องมือที่ใช้ในการทดลอง ข้อมูลที่ใช้ในการทดลอง ข้อกำหนดในการทดลอง และผลการทดลอง

#### 4.1 เครื่องมือที่ใช้ในการทดลอง

การทดลองกับเครื่องคอมพิวเตอร์ Intel (R) Core-i5, CPU @2.40GHz, 6.00 GB RAM ผ่านระบบปฏิบัติการวินโดวส์ 64 บิต

พัฒนาขั้นตอนวิธีโดยใช้โปรแกรม Matlab R2011b และการหาค่าเหมาะที่สุด ใช้ขั้นตอนวิธีปีเอฟจีเอสแบบจำกัดความจำ โดยใช้ได้จากฟังก์ชัน minFunc [28]

#### 4.2 ข้อมูลที่ใช้ในการทดลอง

ข้อมูลที่ใช้ในการทดลองเป็นข้อมูลทำงานวิจัยทั่วไปใช้เป็นเกณฑ์มาตรฐาน ได้แก่

4.2.1 MNIST [29] เป็นข้อมูลภาพขาวดำรูปตัวเลข 0-9 ที่เขียนด้วยลายมือ แต่ละรูปมีขนาด 28x28 มิติ แบ่งเป็นข้อมูลฝึก 60,000 รูป ข้อมูลทดสอบ 10,000 รูป รวมทั้งหมดเป็น 70,000 รูป ดังภาพที่ 4-1

4.2.2 CIFAR-10 [30] เป็นข้อมูลรูปภาพสี 10 ประเภท ประกอบไปด้วยรูป นก, แมว, กวาง, สุนัข, กบ, ม้า, เรือ, เครื่องบิน, รถยนต์ และรถบรรทุก แต่ละรูปมีขนาด 32x32 มิติ แบ่งเป็นข้อมูลฝึก 50,000 รูป และข้อมูล ทดสอบ 10,000 รูป รวมทั้งหมดเป็น 60,000 รูป ดังภาพที่ 4-2



ภาพที่ 4-1: ตัวอย่างของข้อมูล MNIST ซึ่งเป็นภาพขาวดำรูปตัวเลข 0-9 ที่เขียนด้วยลายมือ



ภาพที่ 4-2: ตัวอย่างของข้อมูล CIFAR-10 ซึ่งเป็นรูปภาพสี 10 ประเภท ประกอบไปด้วยรูป นก, แมว, กวาง, สุนัข, กบ, ม้า, เรือ, เครื่องบิน, รถยนต์ และรถบรรทุก

#### 4.3 ข้อกำหนดในการทดลอง

วิทยานิพนธ์ฉบับนี้ใช้เกณฑ์การวัดประสิทธิภาพของขั้นตอนการสร้างคุณลักษณะแบบเพิ่มโดยพิจารณาจากค่าความแม่นยำของการจำแนกคุณลักษณะที่ได้จากการสร้างคุณลักษณะแบบเพิ่มเปรียบเทียบกับคุณลักษณะที่ได้จากการสร้างคุณลักษณะแบบพร้อมกัน เนื่องจากการสร้างคุณลักษณะเป็นขั้นตอนหนึ่งของขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติและตัวเข้ารหัสอัตโนมัติก็มีหลายประเภท การทดลองจึงนำขั้นตอนการสร้างคุณลักษณะไปทดสอบกับตัวเข้ารหัสอัตโนมัติ 3 ประเภท ได้แก่ ขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติแบบพื้นฐาน ตัวเข้ารหัสอัตโนมัติแบบเบาบาง และตัวเข้ารหัสอัตโนมัติแบบเบาบางผสมกับแบบลดการรบกวน

การทดลองกำหนดให้คุณลักษณะที่ขึ้นซ้อนมีขนาด 400 มิติ ดังนั้นการสร้างคุณลักษณะแบบพร้อมกันจึงใช้คุณลักษณะทั้ง 400 คุณลักษณะคำนวณพร้อมกันตั้งแต่เริ่มต้นฝึกและปรับค่าพร้อมกันตลอดการเรียนรู้ สำหรับการสร้างคุณลักษณะแบบเพิ่ม การทดลองต้องการศึกษาว่าจำนวนคุณลักษณะพื้นฐานที่ถูกสร้างขึ้นก่อนกับจำนวนคุณลักษณะเสริมที่สร้างเพิ่มภายหลังมีผลกระทบอย่างไรต่อประสิทธิภาพในการจำแนก การทดลองจึงแบ่งประเภทการสร้างคุณลักษณะแบบเพิ่ม ออกเป็น 3 ประเภท แต่ละประเภทแตกต่างกันที่จำนวนการเพิ่มคุณลักษณะในแต่ละครั้ง ประเภทที่ 1 สร้างคุณลักษณะพื้นฐานจำนวน 40 คุณลักษณะขึ้นก่อน และสร้างคุณลักษณะเสริมจำนวน 80, 80 และ 200 คุณลักษณะ ตามลำดับ จนครบ 400 คุณลักษณะ (ใช้สัญลักษณ์ 40-80-80-200 แทนการสร้างคุณลักษณะแบบเพิ่มประเภทที่ 1), ประเภทที่ 2 สร้างคุณลักษณะพื้นฐานจำนวน 100 คุณลักษณะขึ้นก่อน และสร้างคุณลักษณะเสริมอีกครั้งละ 100 คุณลักษณะ (ใช้สัญลักษณ์ 100-100-100-100 แทนการสร้างคุณลักษณะแบบเพิ่มประเภทที่ 2) และประเภทที่ 3 สร้างคุณลักษณะพื้นฐานจำนวน 200 คุณลักษณะ และสร้างคุณลักษณะเสริมจำนวน 80, 80 และ

40 คุณลักษณะ ตามลำดับ (ใช้สัญลักษณ์ 200-80-80-40 แทนการสร้างคุณลักษณะแบบเพิ่มประเภทที่ 3)

สำหรับข้อมูล CIFAR-10 ซึ่งแต่ละตัวอย่างมีขนาด  $3 \times 32 \times 32 = 3072$  การทดลองเลือกใช้ภาพสีแดงสีเขียวและตัดขอบของภาพแต่ละตัวอย่างออกด้านละ 2 พิกเซล ดังภาพที่ 4-3 ทำให้ข้อมูลขาเข้ามีขนาด  $28 \times 28 = 784$  เท่ากับขนาดของข้อมูล MNIST แต่เนื่องจากข้อมูลภาพสีมีค่าอยู่ระหว่าง 0 ถึง 255 ดังนั้นก่อนทำการทดลองจึงต้องแปลงค่าให้ข้อมูลด้วยวิธีการทำให้เป็นปกติ (Normalization method) เพื่อปรับค่าให้อยู่ในช่วง 0 ถึง 1 โดยเลือกใช้การแปลงค่าโดยอาศัยฟังก์ชันซิกมอยด์ (Sigmoidal) กล่าวคือข้อมูล  $y$  แปลงค่าเป็น  $y'$  ด้วยสมการ

$$y' = \frac{1}{2} \left( \frac{1 - e^{-\alpha}}{1 + e^{-\alpha}} + 1 \right)$$

โดยที่  $\alpha = \frac{y - \bar{y}}{sd}$ ,  $\bar{y}$  และ  $sd$  คือค่าเฉลี่ยเลขคณิตและส่วนเบี่ยงเบนมาตรฐานของข้อมูล  $y$  ตามลำดับ

สำหรับเมทริกซ์ค่าน้ำหนักเริ่มต้นและเวกเตอร์ค่าคลาดเคลื่อนเริ่มต้น  $(W_1, b_1, W_2, b_2)$  สร้างจากการสุ่มค่าขึ้นมาครั้งเดียวและนำไปใช้เป็นพารามิเตอร์เริ่มต้นในการฝึกของทุกการทดลอง สำหรับขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติแบบพื้นฐาน ใช้พารามิเตอร์ควบคุมการย่อยสลายของน้ำหนัก  $\lambda = 0.003$  ขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติแบบเบาบางใช้ค่าน้ำหนักสำหรับควบคุมการลู่เข้าของฟังก์ชันความเบาบาง  $\beta = 3$  และขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติแบบลดการรบกวนใช้การลดรบกวนแบบการปิดบังด้วยหน้ากากโดยแต่ละรอบการฝึกจะสุ่มให้ 20% ของทุกตัวอย่างถูกปรับค่าเป็น 0



ภาพที่ 4-3: ภาพสุนัขจากข้อมูล CIFAR-10 ภาพด้านซ้ายเป็นภาพตั้งต้นขนาด  $32 \times 32$  ภาพตรงกลางเป็นภาพที่ทำการปรับให้เป็นปกติโดยใช้ฟังก์ชันซิกมอยด์ และภาพด้านขวาเป็นภาพที่ทำการตัดขอบออกด้านละ 2 พิกเซลให้เหลือขนาด  $28 \times 28$

การทดลองกำหนดให้จำนวนรอบของการฝึกเป็น 400 รอบต่อการฝึกคุณลักษณะหนึ่งกลุ่ม ดังนั้นคุณลักษณะที่ได้จากการสร้างแบบพร้อมกันหรือการสร้างแบบเพิ่ม แต่ละคุณลักษณะ จะถูกปรับค่า 400 ครั้งเท่ากัน

เช่นเดียวกันกับขั้นตอนวิธีการถดถอยซอฟต์แวร์แมชชีนซึ่งเป็นขั้นตอนวิธีการเรียนรู้แบบชี้ นำมาใช้วัดประสิทธิภาพในการจำแนกของคุณลักษณะ โดยทุกการทดลองได้กำหนดจำนวนรอบสูงสุดไว้ที่ 400 รอบและกำหนดพารามิเตอร์เริ่มต้นแบบสุ่มเป็นค่าเดียวกันเสมอ

อนึ่ง การสร้างคุณลักษณะแบบเพิ่มสามารถเลือกใช้ขั้นตอนวิธีที่แตกต่างกันในการฝึกคุณลักษณะในแต่ละกลุ่มได้ การทดลองจึงนำขั้นตอนวิธีตัวเข้ารหัสอัตโนมัติแบบบางซึ่งมีความสามารถในการเรียนรู้คุณลักษณะเด่นและตัวเข้ารหัสอัตโนมัติแบบลดการรบกวนซึ่งมีความสามารถในการเรียนรู้คุณลักษณะที่มีความทนทานต่อการรบกวนมาใช้เรียนรู้ร่วมกัน เพื่อให้คุณลักษณะที่ได้ประกอบไปด้วยคุณลักษณะที่เด่นและคุณลักษณะที่ทนทานต่อการรบกวน แต่เนื่องจากการทดลองพบว่าคุณลักษณะที่เรียนรู้ด้วยตัวเข้ารหัสอัตโนมัติแบบลดการรบกวนให้มีค่าความแม่นยำในการจำแนกต่ำกว่าคุณลักษณะที่เรียนรู้ด้วยตัวเข้ารหัสอัตโนมัติแบบบาง การทดลองจึงใช้ตัวเข้ารหัสอัตโนมัติแบบลดการรบกวนในการฝึกคุณลักษณะ 1 กลุ่มและใช้ตัวเข้ารหัสอัตโนมัติแบบบางในการฝึกคุณลักษณะ 3 กลุ่ม โดยจำนวนคุณลักษณะในแต่ละกลุ่มเป็นแบบ 100-100-100-100 และเพื่อเปรียบเทียบลำดับของการนำตัวเข้ารหัสอัตโนมัติแบบลดการรบกวนไปใช้กับแต่ละกลุ่ม การทดลองจึงแบ่งประเภทของการเรียนรู้เป็น 4 ประเภท ดังนี้ ประเภทที่ 1 ให้ตัวเข้ารหัสอัตโนมัติแบบลดการรบกวนเรียนรู้คุณลักษณะกลุ่มสุดท้ายและให้ตัวเข้ารหัสอัตโนมัติแบบบางเรียนรู้คุณลักษณะ 3 กลุ่มแรก (ใช้สัญลักษณ์ SSSD) ประเภทที่ 2 ให้ตัวเข้ารหัสอัตโนมัติแบบลดการรบกวนเรียนรู้คุณลักษณะกลุ่มที่สามและให้ตัวเข้ารหัสอัตโนมัติแบบบางไปเรียนรู้คุณลักษณะ 3 กลุ่มที่เหลือ (ใช้สัญลักษณ์ SSDS) ประเภทที่ 3 ให้ตัวเข้ารหัสอัตโนมัติแบบลดการรบกวนเรียนรู้คุณลักษณะกลุ่มที่สองและให้ตัวเข้ารหัสอัตโนมัติเรียนรู้คุณลักษณะ 3 กลุ่มที่เหลือ (ใช้สัญลักษณ์ SDSS) และประเภทสุดท้าย ให้ตัวเข้ารหัสอัตโนมัติแบบลดการรบกวนไปเรียนรู้คุณลักษณะกลุ่มแรกและให้ตัวเข้ารหัสอัตโนมัติแบบบางเรียนรู้คุณลักษณะ 3 กลุ่มหลัง (ใช้สัญลักษณ์ DSSS)

การทดลองได้เพิ่มขั้นตอนการปรับซัด (Fine-tuning) เพื่อเพิ่มความแม่นยำของจำแนก โดยการปรับพารามิเตอร์ทั้งระบบพร้อมกันอีกครั้งหนึ่ง ซึ่งการปรับซัดจะดำเนินการเมื่อขั้นตอนการเรียนรู้คุณลักษณะและเรียนรู้แบบชี้เสร็จสิ้นแล้ว



#### 4.4 ผลการทดลอง

เกณฑ์การประเมินผลสำหรับข้อมูล MNIST ใช้การทดสอบที (Paired T-test) ซึ่งเป็นการเปรียบเทียบค่าเฉลี่ยของค่าความแม่นยำที่ได้จากการจำแนกข้อมูลทดสอบซึ่งได้จากการแบ่งด้วยวิธีตรวจสอบแบบไขว้ 5 ชุด (5-fold cross validation) กล่าวคือ แบ่งข้อมูล MNIST ทั้งหมด 70,000 ตัวอย่างออกเป็น 5 กลุ่ม กลุ่มละ 14,000 ตัวอย่าง แต่ละกลุ่มนำข้อมูลมาไขว้รวมกันเป็นข้อมูล 5 ชุด โดยข้อมูลชุดที่ k คือการใช้ข้อมูลกลุ่มที่ k เป็นข้อมูลทดสอบและใช้ข้อมูลกลุ่มที่เหลือเป็นข้อมูลฝึก เช่น การแบ่งด้วยวิธีตรวจสอบแบบไขว้ 5 ชุด การทดลองกับข้อมูลชุดที่ 2 คือการใช้ข้อมูลกลุ่มที่ 2 เป็นข้อมูลทดสอบและใช้ข้อมูลกลุ่มที่ 1, 3, 4 และ 5 เป็นข้อมูลฝึก เป็นต้น

เกณฑ์การประเมินผลสำหรับข้อมูล CIFAR-10 ใช้การเปรียบเทียบค่าความแม่นยำของการจำแนกคุณลักษณะที่ได้จากการข้อมูลฝึกจำนวน 50,000 ตัวอย่างและข้อมูลทดสอบจำนวน 10,000 ตัวอย่าง

**ตารางที่ 4-1** ค่าความแม่นยำของการจำแนกคุณลักษณะซึ่งได้จากการเรียนรู้ตัวเข้ารหัสอัตโนมัติแบบพื้นฐาน โดยใช้ข้อมูล MNIST

ชุดของข้อมูล	ค่าความแม่นยำ			
	การสร้างแบบ พร้อมกัน	การสร้างแบบเพิ่ม 40-80-80-200	การสร้างแบบเพิ่ม 100-100-100-100	การสร้างแบบเพิ่ม 200-80-80-40
ชุดที่ 1	92.97	92.55	92.85	<b>93.00</b>
ชุดที่ 2	<b>93.16</b>	92.51	92.74	92.97
ชุดที่ 3	<b>92.85</b>	92.15	92.39	92.59
ชุดที่ 4	92.79	92.41	92.34	<b>92.86</b>
ชุดที่ 5	<b>94.10</b>	93.55	93.61	93.94
ค่าเฉลี่ย	<b>93.17</b>	92.63	92.78	93.07

**ตารางที่ 4-2** ค่าความแม่นยำของการจำแนกคุณลักษณะซึ่งได้จากการเรียนรู้ตัวเข้ารหัสอัตโนมัติแบบลดการรบกวน โดยใช้ข้อมูล MNIST

ชุดของข้อมูล	ค่าความแม่นยำ			
	การสร้างแบบ พร้อมกัน	การสร้างแบบเพิ่ม 40-80-80-200	การสร้างแบบเพิ่ม 100-100-100-100	การสร้างแบบเพิ่ม 200-80-80-40
ชุดที่ 1	94.77	92.80	93.65	93.87
ชุดที่ 2	94.41	92.76	93.59	93.81
ชุดที่ 3	94.53	92.72	93.45	93.82
ชุดที่ 4	94.16	92.46	93.28	93.46
ชุดที่ 5	95.46	93.64	94.49	94.98
ค่าเฉลี่ย	94.67	92.88	93.69	93.99

**ตารางที่ 4-3** ค่าความแม่นยำของการจำแนกคุณลักษณะซึ่งได้จากการเรียนรู้ตัวเข้ารหัสอัตโนมัติแบบเบาบาง โดยใช้ข้อมูล MNIST

ชุดของข้อมูล	ค่าความแม่นยำ			
	การสร้างแบบ พร้อมกัน	การสร้างแบบเพิ่ม 40-80-80-200	การสร้างแบบเพิ่ม 100-100-100-100	การสร้างแบบเพิ่ม 200-80-80-40
ชุดที่ 1	96.89	96.54	96.76	96.84
ชุดที่ 2	96.52	96.56	96.65	96.74
ชุดที่ 3	96.65	96.48	96.69	96.74
ชุดที่ 4	96.27	96.21	96.39	96.35
ชุดที่ 5	97.43	97.44	97.59	97.52
ค่าเฉลี่ย	96.75	96.65	96.82	96.84

ตารางที่ 4-4 ค่าความแม่นยำของการจำแนกคุณลักษณะ ซึ่งได้จากการสร้างแบบเพิ่ม 100-100-100-100 โดยใช้ตัวเข้ารหัสอัตโนมัติแบบบางผสมกับแบบลดการรบกวน ของข้อมูล MNIST

ชุดของข้อมูล	ค่าความแม่นยำ			
	SSSD	SSDS	SDSS	DSSS
ชุดที่ 1	96.99	96.71	96.01	94.57
ชุดที่ 2	96.95	96.69	95.86	94.56
ชุดที่ 3	96.91	96.70	95.85	94.54
ชุดที่ 4	96.69	96.38	95.37	94.44
ชุดที่ 5	97.64	97.48	96.69	95.55
ค่าเฉลี่ย	97.03	96.79	95.96	94.73

ตารางที่ 4-5 ค่าความแม่นยำของการจำแนกคุณลักษณะ ซึ่งได้จากการเรียนรู้ตัวเข้ารหัสอัตโนมัติแบบบางใน 3 กลุ่มแรกและแบบลดการรบกวนในกลุ่มสุดท้าย (SSSD) โดยใช้ข้อมูล MNIST

ชุดของข้อมูล	ค่าความแม่นยำ		
	การสร้างแบบเพิ่ม 40-80-80-200	การสร้างแบบเพิ่ม 100-100-100-100	การสร้างแบบเพิ่ม 200-80-80-40
ชุดที่ 1	96.99	96.86	97.10
ชุดที่ 2	96.95	96.79	96.99
ชุดที่ 3	96.91	96.78	97.04
ชุดที่ 4	96.69	96.46	96.59
ชุดที่ 5	97.64	97.50	97.66
ค่าเฉลี่ย	96.88	97.03	97.08

**ตารางที่ 4-6** ค่าความแม่นยำของการจำแนกคุณลักษณะ ซึ่งได้จากการเรียนรู้แบบต่างๆ โดยข้อมูลทดสอบ CIFAR-10

ตัวเข้ารหัส อัตราโน้มนำ	การสร้างแบบ พร้อมกัน	การสร้างแบบเพิ่ม 40-80-80-200	การสร้างแบบเพิ่ม 100-100-100-100	การสร้างแบบเพิ่ม 200-80-80-40
แบบพื้นฐาน	28.46	26.95	27.63	28.37
แบบเบาบาง	37.21	36.76	37.69	37.63
SSSD	-	<b>37.86</b>	<b>38.01</b>	<b>37.91</b>
DSSS	-	32.11	27.60	29.18

**ตารางที่ 4-7** ค่าความแม่นยำเฉลี่ยของการจำแนกคุณลักษณะของข้อมูล MNIST ซึ่งได้จากขั้นตอนวิธีการปรับซัด


ตัวเข้ารหัส อัตราโน้มนำ	การสร้างแบบ พร้อมกัน	การสร้างแบบเพิ่ม 40-80-80-200	การสร้างแบบเพิ่ม 100-100-100-100	การสร้างแบบเพิ่ม 200-80-80-40
แบบพื้นฐาน	98.30	98.26	98.26	98.28
แบบเบาบาง	98.27	98.26	98.29	98.27
SSSD	-	98.29	98.29	98.27
DSSS	-	98.28	98.30	98.27

**ตารางที่ 4-8** ค่าความแม่นยำของการจำแนกคุณลักษณะของข้อมูลทดสอบ CIFAR-10 ซึ่งได้จากขั้นตอนวิธีการปรับซัด


ตัวเข้ารหัส อัตราโน้มนำ	การสร้างแบบ พร้อมกัน	การสร้างแบบเพิ่ม 40-80-80-200	การสร้างแบบเพิ่ม 100-100-100-100	การสร้างแบบเพิ่ม 200-80-80-40
แบบพื้นฐาน	42.13	42.38	41.60	42.21
แบบเบาบาง	42.57	42.27	43.24	42.73
SSSD	-	43.07	43.46	42.77
DSSS	-	42.36	40.31	41.40



**แผนภูมิที่ 4-3** แผนภูมิเปรียบเทียบค่าเฉลี่ยของค่าความแม่นยำของการจำแนกคุณลักษณะซึ่งได้จากการสร้างแบบเพิ่ม SSSS กับการสร้างแบบเพิ่ม SSSD



**แผนภูมิที่ 4-4** แผนภูมิเปรียบเทียบค่าความแม่นยำของการจำแนกคุณลักษณะซึ่งได้จากการสร้างแบบพร้อมกันและคุณลักษณะซึ่งได้จากการสร้างแบบเพิ่ม โดยใช้ข้อมูล CIFAR-10



#### 4.5 วิเคราะห์ผลการทดลอง

จากตารางที่ 4-1 และตารางที่ 4-2 การทดลองกับข้อมูล MNIST พบว่าคุณลักษณะที่ได้จากการเรียนรู้ด้วยตัวเข้ารหัสอัตโนมัติแบบพื้นฐานและแบบลดการรบกวน โดยใช้ในการสร้างแบบพร้อมกันให้ค่าความแม่นยำของการจำแนกที่ดีกว่าการสร้างแบบเพิ่มทั้ง 3 ประเภท

จากตารางที่ 4-3 พบว่าคุณลักษณะที่ได้จากการเรียนรู้ด้วยตัวเข้ารหัสอัตโนมัติแบบเบาบางกับข้อมูล MNIST เมื่อสร้างคุณลักษณะแบบเพิ่ม 200-80-80-40 ให้ค่าความแม่นยำของการจำแนกที่ดีกว่าการสร้างคุณลักษณะแบบพร้อมกันด้วยช่วงความมั่นใจ (Confidence interval) 90%

เมื่อนำมาเปรียบเทียบกับแผนภูมิที่ 4-1 พบว่าการสร้างคุณลักษณะแบบเพิ่ม 200-80-80-40 ให้ค่าความแม่นยำของการจำแนกที่ดีกว่าการสร้างแบบเพิ่ม 100-100-100-100 และ 40-80-80-200 ตามลำดับ ดังนั้นการสร้างคุณลักษณะแบบเพิ่มจะให้ผลลัพธ์ที่ดีขึ้นเมื่อจำนวนคุณลักษณะพื้นฐานมีจำนวนไม่น้อยเกินไป

จากตารางที่ 4-4 การทดลองกับข้อมูล MNIST โดยการสร้างคุณลักษณะแบบเพิ่ม 100-100-100-100 พบว่าการเรียนรู้แบบ SSSD ให้ค่าความแม่นยำของการจำแนกสูงที่สุด เรียงลงมาเป็นการเรียนรู้แบบ SSDS, SDSS และ DSSS ตามลำดับ จะเห็นได้ชัดว่าหากเรียงลำดับให้ตัวเข้ารหัสอัตโนมัติแบบลดการรบกวนเรียนรู้คุณลักษณะเสริมในกลุ่มท้ายจะให้ผลลัพธ์ที่ดีขึ้น เมื่อนำมาเปรียบเทียบกับสร้างคุณลักษณะแบบเพิ่มด้วยตัวเข้ารหัสอัตโนมัติแบบเบาบางทุกกลุ่ม และการสร้างคุณลักษณะแบบพร้อมกัน ดังแผนภูมิที่ 4-2 พบว่าการเรียนรู้แบบ SSSD ให้ค่าความแม่นยำของการจำแนกสูงที่สุด ดังนั้นจึงนำการเรียนรู้แบบ SSSD ทดลองด้วยการแบ่งจำนวนคุณลักษณะแบบ 40-80-80-200 และ 200-80-80-40 ได้ผลการทดลองดังตารางที่ 4-5 และเมื่อนำมาเปรียบเทียบกับสร้างคุณลักษณะแบบพร้อมกัน ดังแผนภูมิที่ 4-3 การวัดประสิทธิภาพของการเรียนรู้แบบ SSSD โดยการสร้างคุณลักษณะแบบเพิ่ม 40-80-80-200 ให้ค่าความแม่นยำของการจำแนกที่ดีกว่าคุณลักษณะที่ได้จากการสร้างแบบพร้อมกันด้วยตัวเข้ารหัสอัตโนมัติแบบเบาบางด้วยช่วงความมั่นใจ 95% และการสร้างคุณลักษณะแบบเพิ่ม 100-100-100-100 และ 200-80-80-40 ให้ค่าความแม่นยำของการจำแนกที่ดีกว่าการสร้างคุณลักษณะแบบพร้อมกันด้วยช่วงความมั่นใจ 99%

จากตารางที่ 4-6 การทดลองกับข้อมูล CIFAR-10 พบว่าค่าความแม่นยำสอดคล้องกับผลการทดลองของข้อมูล MNIST นั่นคือ คุณลักษณะที่ได้จากการสร้างแบบพร้อมกันด้วยตัวเข้ารหัสอัตโนมัติแบบพื้นฐานให้ค่าความแม่นยำของการจำแนกที่ดีกว่าคุณลักษณะที่สร้างแบบเพิ่มคุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 100-100-100-100 และ 200-80-80-40 ด้วยตัวเข้ารหัส

อัตโนมัติแบบเบาบางให้ค่าความแม่นยำของการจำแนกดีกว่าการสร้างคุณลักษณะแบบพร้อมกัน และคุณลักษณะที่ได้จากการสร้างแบบเพิ่มด้วยการเรียนรู้แบบ SSSD ให้ค่าความแม่นยำของการจำแนกดีกว่าคุณลักษณะที่ได้จากการสร้างแบบเพิ่มด้วยการเรียนรู้แบบ DSSS


จากตารางที่ 4-7 และตารางที่ 4-8 พบว่าขั้นตอนวิธีการปรับชุดช่วยเพิ่มค่าความแม่นยำของการจำแนกข้อมูลได้ แต่เพราะว่าหลักการทำงานของการปรับชุดเป็นเพียงการปรับพารามิเตอร์เพื่อหาค่าต่ำสุดของผลต่างระหว่างค่าที่ทำนายกับผลากที่แท้จริงของข้อมูลเท่านั้น ไม่ได้คำนึงถึงคุณสมบัติเฉพาะของคุณลักษณะที่ได้จากการเรียนรู้ในแต่ละประเภท ผลจากการปรับชุดจึงทำให้สูญเสียคุณสมบัติเหล่านั้นไป ทำให้การจำแนกคุณลักษณะของข้อมูลชนิดเดียวกัน ไม่ว่าจะคุณลักษณะนั้นจะเรียนรู้จากการสร้างประเภทใดหรือจากการเรียนรู้ตัวเข้ารหัสอัตโนมัติประเภทใด ค่าความแม่นยำที่ได้มีค่าใกล้เคียงกันทั้งหมด

สิ่งที่น่าสนใจจากการทดลองนี้ คือภาพของเมตริกซ์ค่าน้ำหนัก  $W_1$  ซึ่งเป็นผลลัพธ์ที่ต้องการจากตัวเข้ารหัสอัตโนมัติ เมื่อพิจารณาภาพของเมตริกซ์ค่าน้ำหนักที่ได้จากการเรียนรู้ข้อมูล MNIST ด้วยตัวเข้ารหัสอัตโนมัติแบบพื้นฐาน พบว่าเมตริกซ์ค่าน้ำหนักจากการสร้างแบบพร้อมกันมีลักษณะไม่แตกต่างจากการสร้างแบบเพิ่ม ดังภาพที่ 4-4 เมื่อพิจารณาภาพของเมตริกซ์ค่าน้ำหนักที่ได้จากการเรียนรู้ข้อมูล MNIST ด้วยตัวเข้ารหัสอัตโนมัติแบบเบาบาง พบว่าเมตริกซ์ค่าน้ำหนักที่ได้จากการสร้างแบบพร้อมกันมีลักษณะทั้งหมดเป็นขีดซึ่งคล้ายกับส่วนประกอบของตัวเลข แต่เมตริกซ์ค่าน้ำหนักที่ได้จากการสร้างแบบเพิ่มมีลักษณะเป็นขีดคล้ายส่วนประกอบของตัวเลขในบริเวณของคุณลักษณะพื้นฐานที่ถูกสร้างขึ้นก่อนและมีลักษณะเป็นตัวเลขที่ซับซ้อนมากขึ้นในบริเวณของคุณลักษณะเสริมที่ถูกสร้างขึ้นภายหลัง ดังภาพที่ 4-5 สำหรับภาพของเมตริกซ์ค่าน้ำหนักที่ได้จากการเรียนรู้ทุกประเภทสามารถดูเพิ่มเติมได้ที่บทความผนวก ก


อนึ่ง หากเปรียบเทียบขั้นตอนการสร้างคุณลักษณะแบบเพิ่มในวิทยานิพนธ์ฉบับนี้กับขั้นตอนการสร้างคุณลักษณะแบบเพิ่มของงานวิจัยที่เสนอโดย G. Zhou และคณะ [24] พบว่างานวิจัยของ G. Zhou มีจุดประสงค์หลักของงานวิจัยคือการหาจำนวนคุณลักษณะที่เหมาะสมที่สุดที่สามารถใช้เป็นตัวแทนของข้อมูลแบบออนไลน์ซึ่งมีปริมาณขนาดใหญ่ได้ กล่าวคือปัญหาเริ่มต้นของงานวิจัยมาจากข้อมูลที่มีจำนวนมากและไม่ได้ถูกนำมาเป็นข้อมูลฝึกพร้อมกันตั้งแต่เริ่มต้น ส่งผลทำให้คุณลักษณะที่ได้จากการเรียนรู้ข้อมูลในระยะเวลาใดเวลาหนึ่งมีความสามารถเป็นตัวแทนของข้อมูลในช่วงเวลานั้นเท่านั้น เมื่อมีข้อมูลฝึกตัวใหม่เข้ามาจึงต้องมีการปรับจำนวนคุณลักษณะ ด้วยวิธีการเพิ่มคุณลักษณะเข้าไปและเพื่อป้องกันไม่ให้เกิดปัญหาการปรับเหมาะสมเกินไปจึงมีวิธี การนำคุณลักษณะที่เหมือนกันรวมเข้าด้วยกัน ดังนั้นแม้ว่าขั้นตอนการเพิ่ม



คุณลักษณะจะมีวิธีการคล้ายคลึงกับขั้นตอนวิธีของงานวิจัยในวิทยานิพนธ์ฉบับนี้ แต่จุดประสงค์ของการเพิ่มคุณลักษณะนั้นแตกต่างกัน กล่าวคือ จุดประสงค์ของงานวิจัยที่เกี่ยวข้องนี้ คือการหาจำนวนคุณลักษณะที่เหมาะสมที่สุดที่สามารถใช้เป็นตัวแทนของข้อมูลแบบออนไลน์ขนาดใหญ่ได้ แต่จุดประสงค์ของงานวิจัยในวิทยานิพนธ์ฉบับนี้ คือการเพิ่มประสิทธิภาพให้กับคุณลักษณะของข้อมูลที่มีจำนวนแน่นอน โดยการกำหนดลำดับการสร้างขึ้นเพื่อไม่ให้คุณลักษณะทั้งหมดถูกสร้างพร้อมกัน



ภาพที่ 4-4: ภาพเมทริกซ์ค่าน้ำหนัก  $W_1$  ที่ได้จากการเรียนรู้คุณลักษณะด้วยตัวเข้ารหัสอัตโนมัติแบบพื้นฐาน ภาพทางซ้ายได้จากการสร้างแบบพร้อมกัน และภาพทางขวาได้จากการสร้างแบบเพิ่ม 200-80-80-40 ซึ่งจะเห็นว่าลักษณะของทั้งคู่ไม่แตกต่างกัน



ภาพที่ 4-5: ภาพเมทริกซ์ค่าน้ำหนัก  $W_1$  ที่ได้จากการเรียนรู้คุณลักษณะด้วยตัวเข้ารหัสอัตโนมัติแบบเบาบาง ภาพทางซ้ายได้จากการสร้างแบบพร้อมกันซึ่งมีลักษณะเป็นขีดคล้ายส่วนประกอบของตัวเลขในทุกบริเวณ และภาพทางขวาได้จากการสร้างแบบเพิ่ม 100-100-100-100 ซึ่งบริเวณด้านบนของภาพมีลักษณะเป็นขีดและบริเวณด้านล่างของภาพมีลักษณะเป็นตัวเลขที่ซับซ้อนขึ้น

## บทที่ 5

### สรุปผลงานวิจัย

ในบทนี้จะกล่าวถึงบทสรุปของงานวิจัย ปัญหาที่พบและข้อเสนอแนะ ซึ่งสามารถใช้เป็นแนวทางในการพัฒนางานวิจัยต่อไป

#### 5.1 บทสรุป

วิทยานิพนธ์ฉบับนี้ได้นำเสนอแนวคิดของการสร้างคุณลักษณะแบบเพิ่มสำหรับการเรียนรู้เชิงลึกโดยใช้ตัวเข้ารหัสอัตโนมัติ เภนธ์การวัดประสิทธิภาพพิจารณาจากการเปรียบเทียบค่าความแม่นยำของการจำแนกระหว่างคุณลักษณะที่ได้จากการสร้างแบบเพิ่มกับคุณลักษณะที่ได้จากการสร้างแบบพร้อมกัน จากผลการทดลองกับข้อมูล MNIST และข้อมูล CIFAR-10 สรุปได้ว่าการสร้างคุณลักษณะแบบเพิ่มช่วยเพิ่มประสิทธิภาพให้กับการเรียนรู้คุณลักษณะได้ โดยมีปัจจัยหลัก 2 ข้อคือ 1) จำนวนคุณลักษณะพื้นฐานที่ถูกสร้างขึ้นกลุ่มแรกต้องมีจำนวนไม่น้อยเกินไป 2) การกำหนดลำดับของประเภทของตัวเข้ารหัสอัตโนมัติที่เหมาะสมกับคุณลักษณะในแต่ละกลุ่ม ตัวอย่างหนึ่งที่ประสบความสำเร็จที่สุดในการทดลองคือ การสร้างคุณลักษณะแบบเพิ่ม 200-80-80-40 ด้วยการเรียนรู้แบบ SSSD พบว่าคุณลักษณะพื้นฐานมีจำนวนมากและถูกเรียนรู้ด้วยตัวเข้ารหัสอัตโนมัติแบบบาง จึงเป็นการสร้างคุณลักษณะเด่นของข้อมูลขึ้นมาก่อน จากนั้นจึงเพิ่มคุณลักษณะเสริมจากตัวเข้ารหัสอัตโนมัติแบบบางเข้าไปอีก 2 กลุ่มได้คุณลักษณะที่มีความซับซ้อนขึ้น จนถึงคุณลักษณะในกลุ่มสุดท้ายที่เรียนรู้จากตัวเข้ารหัสอัตโนมัติแบบลดการรบกวนด้วยจำนวนไม่มากเกินไป ทำให้ได้คุณลักษณะเสริมที่ทนทานต่อการถูกรบกวน ส่งผลให้คุณลักษณะโดยรวมมีประสิทธิภาพมากยิ่งขึ้น

#### 5.2 ข้อเสนอแนะ

การทดลองยังสามารถปรับเปลี่ยนพารามิเตอร์ให้เหมาะสมยิ่งขึ้นได้ เช่น เปลี่ยนการทดลองด้วยตัวเข้ารหัสอัตโนมัติประเภทอื่นหรือปรับเปลี่ยนการผสมกันของตัวเข้ารหัสอัตโนมัติในแต่ละกลุ่มคุณลักษณะ ซึ่งในปัจจุบันมีการนำเสนอดัชนีเข้ารหัสอัตโนมัติประเภทใหม่ขึ้นหลายประเภท, การปรับเปลี่ยนขั้นตอนการหาค่าต่ำสุดของฟังก์ชันจุดประสงค์จากขั้นตอนบีเอพีเอ

สแบบจำกัดความจำซึ่งเป็นการฝึกแบบชุด (Batch training) เป็นการฝึกแบบชุดเล็ก (Mini-batch training) หรือการฝึกแบบสุ่ม (Stochastic training) โดยใช้ขั้นตอนวิธีการเคลื่อนลงตามความชัน, การปรับค่าคงที่ต่างๆที่ใช้ในการทดลอง เช่น ร้อยละของการรบกวนข้อมูลในตัวเข้ารหัสอัตโนมัติแบบลดการรบกวน จำนวนการแบ่งกลุ่มของคุณลักษณะ จำนวนของคุณลักษณะที่เพิ่มขึ้นในแต่ละกลุ่ม เป็นต้น

ขั้นตอนวิธีการปรับซัดหลังจากเรียนรู้คุณลักษณะและเรียนรู้แบบชี้้นำเสรีจลิน ช่วยเพิ่มความแม่นยำของจำแนกให้สูงขึ้น แต่ผลจากการปรับซัดของพารามิเตอร์ที่ฝึกจากตัวเข้ารหัสอัตโนมัติที่แตกต่างกันกลับให้ผลลัพธ์ที่ไม่แตกต่างกัน เช่น แม้ว่าจะเรียนรู้คุณลักษณะจากตัวเข้ารหัสอัตโนมัติแบบบางแต่การปรับซัดที่ไม่มีการเพิ่มฟังก์ชันความเบาบางเข้าไปที่ฟังก์ชันจุดประสงค์ ทำให้ฟังก์ชันจุดประสงค์ของการปรับซัดเป็นเพียงการหาค่าต่ำสุดของผลต่างระหว่างค่าที่ทำนายกับฉลากที่แท้จริงของข้อมูลเท่านั้น ทำให้คุณลักษณะที่มีความเบาบางถูกปรับซัดจนหมดไป ทั้งที่ก่อนการปรับซัด ความเบาบางของคุณลักษณะส่งผลต่อค่าแม่นยำอย่างยิ่ง ดังนั้นผู้วิจัยจึงเสนอแนะให้มีการปรับปรุงขั้นตอนวิธีการปรับซัดให้ยังคงคุณสมบัติที่ดีของคุณลักษณะเอาไว้เพื่อเพิ่มประสิทธิภาพให้ดียิ่งขึ้น

ปัญหาหนึ่งในเรื่องของการจัดทำทดลอง คือปัญหาเรื่องเครื่องมือที่ใช้ในการทดลอง เนื่องจากข้อมูลมีขนาดใหญ่ทำให้ใช้เวลาในการทดลองนาน การทดลองปรับเปลี่ยนค่าพารามิเตอร์จึงทำได้ไม่สะดวก หากต้องการทดลองกับปัญหาที่มีขนาดใหญ่กว่าข้อมูล MNIST ก็ไม่สามารถทำการทดลองได้ การแก้ปัญหานี้ทำได้โดยการจัดหาเครื่องมือที่เพิ่มประสิทธิภาพในด้านการประมวลผลและด้านความจำ หรือในปัจจุบันงานวิจัยจำนวนมากที่เกี่ยวข้องกับการเรียนรู้เชิงลึก ประสบความสำเร็จอย่างสูง [32] จากการประยุกต์ใช้กับหน่วยประมวลผลด้านกราฟฟิก (Graphic processing units) ซึ่งใช้ระยะเวลาในการเรียนรู้้น้อยมากเมื่อเทียบกับการประมวลผลด้วยหน่วยประมวลผลกลาง (Central processing units) ส่งผลให้ขั้นตอนของการเรียนรู้สามารถทดลองปรับเปลี่ยนพารามิเตอร์ให้เหมาะสมที่สุดได้ และสามารถเพิ่มจำนวนรอบของการฝึกหรือเพิ่มจำนวนตัวอย่างฝึก จนเกิดเป็นโมเดลหรือคุณลักษณะที่มีประสิทธิภาพสูงมากยิ่งขึ้น

## รายการอ้างอิง

- [1] Bengio, Y., Learning Deep Architectures for AI. Foundations and Trends in Machine Learning, 2009.
- [2] Bengio, Y., Courville, A., and Vincent, P., Representation Learning: A Review and New Perspectives, 2012.
- [3] McClelland, J., Rumelhart, D. and the PDP Research Group, Parallel Distributed Processing: Explorations in the Microstructure of Cognition. Cambridge, MIT Press, vol. 2, 1986.
- [4] Hinton, G., Connectionist learning procedures. Artificial Intelligence, 40, 185–234, 1989.
- [5] Utgoff, P. and Stracuzzi, D. Many-layered learning. Neural Computation, 14, 2497–2539, 2002.
- [6] Bengio, Y. and LeCun, Y., Scaling learning algorithms towards AI. In Bottou L., Chapelle, O., DeCoste, D. and Weston, J., Large Scale Kernel Machines. MIT Press, 2007.
- [7] LeCun Y., Boser B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W. and Jackel, J. D., Backpropagation Applied to Handwritten Zip Code Recognition. Neural Computation, 1(4), 541–551, 1989.
- [8] LeCun, Y., Bottou, L., Bengio, Y. and Haffner, P., Gradient-Based Learning Applied to Document Recognition. Proceedings of the IEEE, 86(11): 2278–2324, November 1998.
- [9] Hinton, G. E., Osindero, S., and Teh, Y. W., A Fast Learning Algorithm for Deep Belief Nets. Neural Computation, 18, 1527–1554, 2006.
- [10] Ranzato, M., Huang, F., Boureau, Y. and LeCun Y., Unsupervised Learning of Invariant Feature Hierarchies with Applications to Object Recognition. In Proceeding Computer Vision and Pattern Recognition Conference, 2007.

- [11] Bengio, Y., Lamblin, P., Popovici, D. and Larochelle, H., Greedy Layer-Wise Training of Deep Networks. The Conference on Neural Information Processing Systems, 2006.
- [12] Hinton G. E. and Salakhutdinov, R. R., Reducing the Dimensionality of Data with Neural Networks. Science Volume 311, 2006
- [13] Ng, A. Y., Sparse Autoencoder. CS294A Lecture notes, Available from : <http://www.stanford.edu/class/cs294a/sparseAutoencoder.pdf>, 2012
- [14] Vincent, P., Larochelle, H., Bengio, Y. and Manzagol, P.A., Extracting and Composing Robust Features with Denoising Auto-Encoders. Proceedings of the 25<sup>th</sup> International Conference on Machine Learning, Helsinki, Finland, 2008.
- [15] Lee, H., Grosse, R., Ranganath, R. and Ng, A. Y., Convolutional Deep Belief Networks for Scalable Unsupervised Learning of Hierarchical Representations. Proceedings of the 26<sup>th</sup> International Conference on Machine Learning, Montreal, Canada, 2009.
- [16] Masci, J., Meier, U., Ciresan, D. and Schmidhuber, J., Stacked Convolutional Auto-Encoders for Hierarchical Feature Extraction. The International Conference on Artificial Neural Networks, Springer-Verlag Berlin Heidelberg, 2011.
- [17] Goodfellow, I. J., Warde-Farley, D., Mirza, M., Courville, A., Bengio, Y., Maxout Networks. eprint [arXiv: 1302.4389](https://arxiv.org/abs/1302.4389), February 2013.
- [18] Ng, A. Y., Machine Learning and AI via Brain simulations. Institute for Pure and Applied Mathematics, 2012.
- [19] Vincent, P., Larochelle, H., Lajoie, I., Bengio, Y. and Manzagol, P.A., Stacked Denoising Autoencoders: Learning useful Representations in a Deep Network with a Local Denoising Criterion. The Journal of Machine Learning Research 11, 2010.


- [20] Erhan, D., Bengio, Y., Courville, A., Manzagol, P. A., Vincent, P. and Bengio, S., Why does unsupervised pre-training help deep learning?. The Journal of Machine Learning Research, 11, 625-660, 2010.
- [21] Rifai, S., Vincent, P., Muller, X., Glorot, X., & Bengio, Y., Contractive auto-encoders: Explicit invariance during feature extraction. In Proceedings of the 28th International Conference on Machine Learning (ICML-11), pp. 833-840, 2011.
- [22] Ngiam, J., Coates, A., Lahiri, A., Prochnow, B., Ng, A., and Le, Q. V, On Optimization Methods for Deep Learning. Proceedings of the 28<sup>th</sup> International Conference on Machine Learning, WA, USA, 2011.
- [23] Goroshin, R. and LeCun, Y., Saturating Auto-Encoders. arXiv:1301.3577v3 [cs.LG] 20 Mar 2013.
- [24] Zhou, G., Sohn, K., & Lee, H., Online incremental feature learning with denoising autoencoders. In International Conference on Artificial Intelligence and Statistics, pp. 1453-1461, 2012.
- [25] Coates, A., Ng, A. Y. and Lee, H., An analysis of single-layer networks in unsupervised feature learning. In International Conference on Artificial Intelligence and Statistics, pp. 215-223, 2011.
- [26] Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. R., Improving neural networks by preventing co-adaptation of feature detectors. arXiv preprint arXiv:1207.0580, 2012.
- [27] Rolfe, J. T., & LeCun, Y., Discriminative Recurrent Sparse Auto-Encoders. arXiv preprint arXiv:1301.3775, 2012.
- [28] Schmidt, M., The minFunc Toolbox for Matlab. minFunc [Online]. 2005. Available from: <http://www.di.ens.fr/~mschmidt/Software/minFunc.html>, [2013, January 1].
- [29] LeCun, Y., & Cortes, C., The MNIST database of handwritten digits [Online]. 1998. Available from: <http://yann.lecun.com/exdb/mnist/>, [2013, January 1].

- [30] Krizhevsky, A., & Hinton, G., Learning multiple layers of features from tiny images. Master's thesis, Department of Computer Science, University of Toronto, 2009.
- [31] Benenson, R., Discover the current state of the art in objects classification [Online]. 2013 Available from: [http://rodrigob.github.io/are\\_we\\_there\\_yet/build/classification\\_datasets\\_results.html](http://rodrigob.github.io/are_we_there_yet/build/classification_datasets_results.html), [2013, August 1].
- [32] Ciresan, D. C., Meier, U., Gambardella, L. M., & Schmidhuber, J., Deep big simple neural nets excel on handwritten digit recognition, Xiv:1003.0358v1 [cs.NE], Mar 2010.




ภาคผนวก


ภาคผนวก ก  
ภาพเมตริกซ์ค่าน้ำหนักจากการเรียนรู้คุณลักษณะ




ภาพที่ ก-1 คุณลักษณะที่ได้จากการสร้างแบบพร้อมกัน 400 คุณลักษณะ  
ด้วยตัวเข้ารหัสอัตโนมัติแบบพื้นฐาน โดยใช้ข้อมูล MNIST



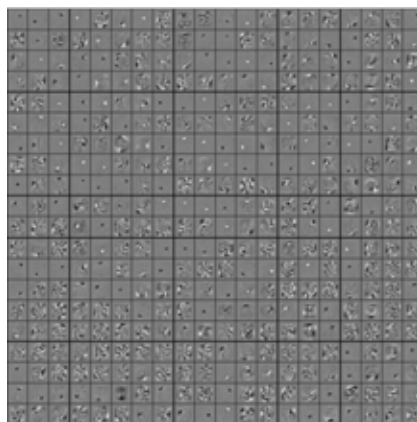
ภาพที่ ก-2 คุณลักษณะที่ได้จากการสร้างแบบพร้อมกัน 400 คุณลักษณะ  
ด้วยตัวเข้ารหัสอัตโนมัติแบบเบาบาง โดยใช้ข้อมูล MNIST




ภาพที่ ก-3 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 40-80-80-200  
ด้วยตัวเข้ารหัสอัตโนมัติแบบพื้นฐาน โดยใช้ข้อมูล MNIST




ภาพที่ ก-4 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 100-100-100-100  
ด้วยตัวเข้ารหัสอัตโนมัติแบบพื้นฐาน โดยใช้ข้อมูล MNIST




ภาพที่ ก-5 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 200-80-80-40  
ด้วยตัวเข้ารหัสอัตโนมัติแบบพื้นฐาน โดยใช้ข้อมูล MNIST




ภาพที่ ก-6 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 40-80-80-200  
ด้วยตัวเข้ารหัสอัตโนมัติแบบเบาบาง โดยใช้ข้อมูล MNIST




ภาพที่ ก-7 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 100-100-100-100  
ด้วยตัวเข้ารหัสอัตโนมัติแบบเบาบาง โดยใช้ข้อมูล MNIST




ภาพที่ ก-8 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 200-80-80-40  
ด้วยตัวเข้ารหัสอัตโนมัติแบบเบาบาง โดยใช้ข้อมูล MNIST




ภาพที่ ก-9 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 40-80-80-200 ด้วยตัวเข้ารหัสอัตโนมัติแบบเบาบางใน 3 กลุ่มแรกและแบบลดการรบกวนในกลุ่มสุดท้าย (SSSD) โดยใช้ข้อมูล MNIST




ภาพที่ ก-10 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 100-100-100-100 ด้วยตัวเข้ารหัสอัตโนมัติแบบเบาบางใน 3 กลุ่มแรกและแบบลดการรบกวนในกลุ่มสุดท้าย (SSSD) โดยใช้ข้อมูล MNIST




ภาพที่ ก-11 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 200-80-80-40 ด้วยตัวเข้ารหัสอัตโนมัติแบบเบาบางใน 3 กลุ่มแรกและแบบลดการรบกวนในกลุ่มสุดท้าย (SSSD) โดยใช้ข้อมูล MNIST




ภาพที่ ก-12 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 100-100-100-100 ด้วยตัวเข้ารหัสอัตโนมัติแบบลดการรบกวนในกลุ่มที่สามและแบบเบาบางใน 3 กลุ่มที่เหลือ (SSDS) โดยใช้ข้อมูล MNIST




ภาพที่ ก-13 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 100-100-100-100 ด้วยตัวเข้ารหัสอัตโนมัติแบบลดการรบกวนในกลุ่มที่สองและแบบเบาบางใน 3 กลุ่มที่เหลือ (SDSS) โดยใช้ข้อมูล MNIST




ภาพที่ ก-14 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 100-100-100-100 ด้วยตัวเข้ารหัสอัตโนมัติแบบลดการรบกวนในกลุ่มแรกและแบบเบาบางใน 3 กลุ่มหลัง (DSSS) โดยใช้ข้อมูล MNIST




ภาพที่ ก-15 คุณลักษณะที่ได้จากการสร้างแบบพร้อมกัน 400 คุณลักษณะ  
ด้วยตัวเข้ารหัสอัตโนมัติแบบพื้นฐาน โดยข้อมูล CIFAR-10




ภาพที่ ก-16 คุณลักษณะที่ได้จากการสร้างแบบพร้อมกัน 400 คุณลักษณะ  
ด้วยตัวเข้ารหัสอัตโนมัติแบบเบาบาง โดยใช้ข้อมูล CIFAR-10



ภาพที่ ก-17 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 40-80-80-200  
ด้วยตัวเข้ารหัสอัตโนมัติแบบพื้นฐาน โดยใช้ข้อมูล CIFAR-10



ภาพที่ ก-18 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 100-100-100-100  
ด้วยตัวเข้ารหัสอัตโนมัติแบบพื้นฐาน โดยใช้ข้อมูล CIFAR-10




ภาพที่ ก-19 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 200-80-80-40  
ด้วยตัวเข้ารหัสอัตโนมัติแบบพื้นฐาน โดยใช้ข้อมูล CIFAR-10







ภาพที่ ก-20 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 40-80-80-200  
ด้วยตัวเข้ารหัสอัตโนมัติแบบเบาบาง โดยใช้ข้อมูล CIFAR-10




ภาพที่ ก-21 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 100-100-100-100  
ด้วยตัวเข้ารหัสอัตโนมัติแบบเบาบาง โดยใช้ข้อมูล CIFAR-10




ภาพที่ ก-22 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 200-80-80-40  
ด้วยตัวเข้ารหัสอัตโนมัติแบบเบาบาง โดยใช้ข้อมูล CIFAR-10




ภาพที่ ก-23 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 40-80-80-200 ด้วยตัวเข้ารหัสอัตโนมัติแบบเบาบางใน 3 กลุ่มแรกและแบบลดการรบกวนในกลุ่มสุดท้าย โดยใช้ข้อมูล CIFAR-10




ภาพที่ ก-24 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 100-100-100-100 ด้วยตัวเข้ารหัสอัตโนมัติแบบเบาบางใน 3 กลุ่มแรกและแบบลดการรบกวนในกลุ่มสุดท้าย โดยใช้ข้อมูล CIFAR-10




ภาพที่ ก-25 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 200-80-80-40 ด้วยตัวเข้ารหัสอัตโนมัติแบบเบาบางใน 3 กลุ่มแรกและแบบลดการรบกวนในกลุ่มสุดท้าย โดยใช้ข้อมูล CIFAR-10



ภาพที่ ก-26 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 40-80-80-200 ด้วยตัวเข้ารหัสอัตโนมัติแบบลดการรบกวนในกลุ่มแรกและแบบเบาบางใน 3 กลุ่มหลัง โดยใช้ข้อมูล CIFAR-10



ภาพที่ ก-27 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 100-100-100-100 ด้วยตัวเข้ารหัสอัตโนมัติแบบลดการรบกวนในกลุ่มแรกและแบบเบาบางใน 3 กลุ่มหลัง โดยใช้ข้อมูล CIFAR-10



ภาพที่ ก-28 คุณลักษณะที่ได้จากการสร้างแบบเพิ่ม 200-80-80-40 ด้วยตัวเข้ารหัสอัตโนมัติแบบลดการรบกวนในกลุ่มแรกและแบบเบาบางใน 3 กลุ่มหลัง โดยใช้ข้อมูล CIFAR-10

## ประวัติผู้เขียนวิทยานิพนธ์

นายมงคล อุดมมิตรรัก เกิดเมื่อวันที่ 23 มกราคม พ.ศ. 2530 ที่กรุงเทพมหานคร สำเร็จการศึกษาปริญญาวิทยาศาสตรบัณฑิต สาขาคณิตศาสตร์ จากจุฬาลงกรณ์มหาวิทยาลัย ในปีการศึกษา 2552 หลังจากนั้นได้เข้าศึกษาในหลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิทยาศาสตร์คอมพิวเตอร์ ที่ภาควิชาวิศวกรรมศาสตร์คอมพิวเตอร์ คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย ในปีการศึกษา 2554