



รายงานผลการวิจัย

เรื่อง

การประยุกต์ใช้โครงข่ายประสาทเทียมเพื่อการวิเคราะห์การล้มละลายของสถาบัน
การเงินที่จดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทย

โดย

วรวัฒน์ เชิญสวัสดิ์

รายงานการวิจัยนี้ได้รับทุนอุดหนุนจากมหาวิทยาลัยธุรกิจบัณฑิตย์

พ.ศ. 2551

ISBN 978-974-671-579-9

บทคัดย่อ

วิกฤตเศรษฐกิจของเอเชียตะวันออกเฉียงใต้ที่ผ่านมาทำให้เราได้รับบทเรียนของการขาดระบบเตือนภัยล่วงหน้าทางเศรษฐกิจที่มีประสิทธิภาพ การได้รับรู้สัญญาณล่วงหน้าที่ได้มาจากแบบจำลองการพยากรณ์การล้มเหลว ที่มีความแม่นยำสูงนั้นสำคัญมาก เป็นเหตุให้เกิดงานวิจัยชิ้นนี้ เพื่อวิเคราะห์ปัจจัยทางการเงินและผู้ถือหุ้นของสถาบันการเงิน โดยใช้เทคนิคพีซีเอ (Principal Component Analysis) ซึ่งสามารถลดจำนวนมิติของข้อมูลของสถาบันการเงินซึ่งประกอบด้วย 31 ปัจจัยทางการเงิน หลังจากนั้นได้นำข้อมูลซึ่งได้จากเทคนิคพีซีเอมาทำการพยากรณ์โดยใช้เทคนิคโครงข่ายประสาทเทียม แบบแวลวิคิว (Learning Vector Quantization) แบบใช้ความน่าจะเป็น (Probabilistic Neural Network) และแบบแพร่ย้อนกลับ (Feedforward Network with Backpropagation Learning) แบบจำลองทั้งหมดนี้ได้ใช้ข้อมูลของสถาบันการเงินทั้งหมด 41 สถาบัน ระหว่างปี พ.ศ. 2536 - 2546

เลขทะเบียน.....	0200583
วันลงทะเบียน.....	5 ส.ค. 2551
เลขเรียกหนังสือ.....	332.75
	วจก
	[2551]
	ณ

คำสำคัญ: การล้มเหลว; สถาบันการเงินไทย; แบบจำลองการพยากรณ์; โครงข่ายประสาทเทียม; เทคนิคพีซีเอ

Abstract

The recent East Asian economic crisis is a lesson one can learn from the absence of effective early warning systems. To serve as a sound early warning signal, the accuracy of a failure prediction model is as important as its robustness over time. This study analyses financial and ownership variables using principal component analysis. It can reduce huge number of financial data of the business bankruptcy prediction problem. Using neural networks for bankruptcy forecasting, the obtained features are fed into neural networks as the input data. Our experiments examine the predictive performance of three neural networks: Learning Vector Quantization, Probabilistic Neural Network, and Feedforward network with backpropagation learning. All these approaches are applied to data sets of 41 Thai financial institutions for the period 1993-2003.

Keywords: Bankruptcy; Thailand financial institute; Prediction model; Neural Network; Principal Component Analysis

กิตติกรรมประกาศ

ผู้ทำงานวิจัยขอขอบคุณทุกท่านที่มีส่วนร่วม และเป็นกำลังใจ ที่ทำให้งานวิจัยชิ้นนี้สำเร็จลุล่วงไปได้ด้วยดี โดยเฉพาะ ดร. กิ่งกาญจน์ เชิญสวัสดิ์ ที่เป็นทุกสิ่งทุกอย่าง ขอขอบคุณ ผศ.ดร. พิรุณา พลศิริ สำหรับข้อมูล แนวคิด และความรู้ทางด้านเศรษฐศาสตร์

ขอขอบคุณมหาวิทยาลัยธุรกิจบัณฑิตที่ให้ทุนสนับสนุนงานวิจัยนี้

DRU

สารบัญ

	หน้า
ปกนอก	ก
บทคัดย่อภาษาไทย	ข
บทคัดย่อภาษาอังกฤษ	ค
กิตติกรรมประกาศ	ง
สารบัญ	จ
รายการภาพประกอบ	ช
รายการตาราง	ญ
บทที่ 1 บทนำ	
1.1 ความเป็นมาของปัญหา	1
1.2 วัตถุประสงค์	1
1.3 สมมติฐานของงานวิจัย	3
1.4 ขอบเขตของการวิจัย	3
1.5 ประโยชน์ที่คาดว่าจะได้รับ	3
บทที่ 2 ทฤษฎี เอกสาร งานวิจัย ที่เกี่ยวข้อง	
2.1 ทฤษฎีที่เกี่ยวข้อง	6
2.2 เทคนิคพีซีเอ	6

2.3 สถาปัตยกรรมโครงข่ายประสาทเทียม	13
2.3.1 โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าหลายชั้น	18
2.3.2 ตัวอย่างคุณลักษณะของปัญหาที่ใช้เป็นข้อมูลเข้า จากตัวอย่างงานวิจัยทางการแพทย์	20
2.4 การเรียนรู้ของโครงข่ายประสาทเทียม	21
2.4.1 การเรียนรู้แบบแพร่ย้อนกลับ (Back-propagation learning)	21
2.4.2 การเรียนรู้แบบแวลูเวกิว (Learning Vector Quantization)	23
2.4.3 การเรียนรู้แบบใช้ความน่าจะเป็น (Probabilistic Learning)	25
บทที่ 3 ขั้นตอนวิธีในการดำเนินงานวิจัย	
3.1 ขั้นตอนวิธีในการดำเนินงานวิจัย	27
3.2 การใช้เทคนิคพีซีเอเพื่อวิเคราะห์ข้อมูล	29
3.3 แบบจำลองการพยากรณ์ความล้มเหลวของสถาบันการเงิน	34
3.3.1 โครงสร้างของโครงข่ายประสาทเทียม แบบป้อนไปข้างหน้าหลาย ชั้น	34
3.3.2 ชุดข้อมูลเรียนรู้ และชุดข้อมูลทดสอบ	35
3.3.3 ลักษณะของข้อมูลเข้า	36
3.3.4 กำหนดค่าพารามิเตอร์ของการเรียนรู้แบบแพร่ย้อนกลับ	36
3.3.5 กำหนดค่าตัวแปรของการเรียนรู้แบบใช้ความน่าจะเป็น	36
3.3.6 กำหนดค่าตัวแปรของการเรียนรู้แบบแวลูเวกิว	36

บทที่ 4 ผลการทดลอง

4.1 ผลการวิเคราะห์ปัจจัยหลักของการปิดกิจการของสถาบันการเงิน	37
4.2 ผลการพยากรณ์การปิดกิจการของสถาบันการเงินโดยใช้โครงข่ายประสาทเทียม	39
4.2.1 การเรียนรู้แบบแพร่ย้อนกลับ	39
4.2.2 การเรียนรู้แบบใช้ความน่าจะเป็น	40
4.2.3 การเรียนรู้แบบแอสตีคว	41
4.3 ผลการวิเคราะห์ปัจจัยหลักของการปิดกิจการของสถาบันการเงิน	42

บทที่ 5 สรุปผลการทดลอง

5.1 สรุปผลการทดลอง	43
--------------------	----

บรรณานุกรม	45
------------	----

รายการภาพประกอบ

ภาพที่		หน้า
2.1	เซตข้อมูล $\{a, b, c, \dots, z\}$ บนปริภูมิ \mathcal{R}^3 (X_1, X_2, X_3)	7
2.2	เซตข้อมูล $\{a, b, c, \dots, z\}$ ในปริภูมิมาตรฐาน \mathcal{R}^3 (S_1, S_2, S_3)	8
2.3	แกนพีซีเอ ในปริภูมิมาตรฐาน	9
2.4	เซตข้อมูลบนแกนพีซีเอ	9
2.5	เซลล์ประสาททางชีววิทยา	14
2.6	กราฟการเชื่อมต่อภายในโครงข่าย	14
2.7	การเชื่อมโยงแบบป้อนไปข้างหน้า	15
2.8	ไดอะแกรมโครงข่ายประสาทเทียมแบบมีการป้อนไปเวียนกลับ	16
2.9	การเชื่อมโยงแบบการป้อนไปเวียนกลับ	16
2.10	โครงสร้างของโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าหลายชั้น	18
2.11	โมเดลทางคณิตศาสตร์ของการป้อนไปข้างหน้า	19
2.12	โมเดลทางคณิตศาสตร์ของเซลล์ประสาท	20
2.13	ตำแหน่งของเวกเตอร์โปรโตไทป์ซึ่งครอบคลุมข้อมูลเข้า	23
2.14	การครอบคลุมแบบไวโรนอย	23
2.15	โครงสร้างเครือข่ายแบบแอลวีคิว (การเรียนรู้แบบมีผู้สอน)	25
2.16	โมเดลคณิตศาสตร์การเรียนรู้แบบใช้ความน่าจะเป็น	25
3.1	Sigmoid function	35
4.1	กราฟความสัมพันธ์ระหว่างองค์ประกอบกับค่าไอเกน	37
4.2	ผลการแปลงข้อมูลบนระนาบใหม่ ซึ่งประกอบด้วย องค์ประกอบที่ 1-2	38

4.3 ผลการแปลงข้อมูลในปฏิภูมิใหม่ ซึ่งประกอบด้วย องค์กรประกอบที่ 1-3 38

D
P
U

รายการตาราง

ตารางที่		หน้า
1.1	ตัวแปรทางด้านการเงิน	2
1.2	ตัวแปรของผู้ถือหุ้น	2
2.1	สัญลักษณ์ทางคณิตศาสตร์และคำอธิบาย ที่เกี่ยวข้องกับทศนคฟี่ซีเอ	10
3.1	ชุดข้อมูลของสถาบันการเงินที่จดทะเบียนในตลาดหลักทรัพย์แห่ง ประเทศไทย ใช้ข้อมูลดิบในปี พ.ศ. 2536 เพื่อทำนายการล้มละลายในช่วงปี พ.ศ. 2537-2541	27
3.2	ชุดข้อมูลของสถาบันการเงินที่จดทะเบียนในตลาดหลักทรัพย์แห่ง ประเทศไทย ใช้ข้อมูลดิบในปี พ.ศ. 2537 เพื่อทำนายการล้มละลายในช่วงปี พ.ศ. 2538-2542	28
3.3	ชุดข้อมูลของสถาบันการเงินที่จดทะเบียนในตลาดหลักทรัพย์แห่ง ประเทศไทย ใช้ข้อมูลดิบในปี พ.ศ. 2538 เพื่อทำนายการล้มละลายในช่วงปี พ.ศ. 2539-2543	28
3.4	ชุดข้อมูลของสถาบันการเงินที่จดทะเบียนในตลาดหลักทรัพย์แห่ง ประเทศไทย ใช้ข้อมูลดิบในปี พ.ศ. 2539 เพื่อทำนายการล้มละลายในช่วงปี พ.ศ. 2540-2544	28
3.5	เมตริกซ์ข้อมูลของสถาบันการงานแต่ละปี ขนาด 105 x 37	30
3.6	Covariance matrix ขนาด 37 x 37	31

3.7	องค์ประกอบหลักของข้อมูลสถาบันการเงิน 37 ตัวแปร โดยใช้ เทคนิคพีซีเอ	31
3.8	Component matrix	33
4.1	ผลการพยากรณ์โดยใช้การเรียนรู้แบบแพร่ย้อนกลับ	39
4.2	ผลการพยากรณ์โดยใช้การเรียนรู้แบบใช้ความน่าจะเป็น	40
4.3	ผลการพยากรณ์โดยใช้การเรียนรู้แบบแอลวีคิว	41
5.1	เฉลี่ยเปอร์เซ็นต์ความถูกต้องของแบบจำลองพยากรณ์การปิดกิจการ กับข้อมูลชุดทดสอบ โดยใช้การเรียนรู้แบบแพร่ย้อนกลับ	43
5.2	เฉลี่ยเปอร์เซ็นต์ความถูกต้องของแบบจำลองพยากรณ์การปิดกิจการ กับข้อมูลชุดทดสอบ โดยใช้การเรียนรู้แบบใช้ความน่าจะเป็น	44
5.3	เฉลี่ยเปอร์เซ็นต์ความถูกต้องของแบบจำลองพยากรณ์การปิดกิจการ กับข้อมูลชุดทดสอบ โดยใช้การเรียนรู้แบบแอลวีคิว	44

บทที่ 1

บทนำ

1.1. ความเป็นมาของปัญหา

ประเทศไทยได้ประสบวิกฤตเศรษฐกิจอย่างรุนแรง ในปี พ.ศ. 2540 บริษัทจำนวนมากต้องเลิกกิจการไป โดยเฉพาะอย่างยิ่งสถาบันการเงินในประเทศต้องถูกปิดกิจการ เนื่องจากมูลค่าของเงินบาทอ่อนตัวลงอย่างมาก ซึ่งอาจจะไม่ใช่สาเหตุที่แท้จริงของการล้มละลายของบริษัท จึงทำให้เกิดงานวิจัยจำนวนมากเพื่อการศึกษา และวิเคราะห์ข้อมูลจากองค์ประกอบทางด้านเสถียรภาพการเงินของบริษัท รวมถึงข้อมูลของผู้ถือหุ้นและกรรมการบริษัท

จากตารางที่ 1.1-1.2 พบว่าจำนวนตัวแปรที่เกี่ยวข้องกับสถาบันการเงินนั้นมีจำนวนมาก ซึ่งในความเป็นจริงการล้มละลายของสถาบันการเงินนั้น อาจจะไม่ได้เกี่ยวข้องกับตัวแปรทั้งหมด งานวิจัยนี้จึงเสนอเทคนิคพีซีเอ (Principal Component Analysis) เพื่อทำการลดจำนวนตัวแปร เพื่อลดความซับซ้อนของโมเดลในการพยากรณ์ และประเมินความเสี่ยงด้วยเทคนิคของโครงข่ายประสาทเทียม (Artificial Neural Networks)

เครื่องมือที่ถูกนำมาใช้ในการวิเคราะห์ทางเทคนิคนี้ ส่วนใหญ่อาศัยการวิเคราะห์ทางสถิติ เช่น การวิเคราะห์เชิงเส้น การถดถอย และการวิเคราะห์อนุกรมเวลา เครื่องมือเหล่านี้ถูกพบว่าถึงขีดสุดของความสามารถในการทำนายแล้ว [Yao, 1995] เนื่องจากเครื่องมือเหล่านี้เป็นการหาความสัมพันธ์เชิงเส้น ทั้งๆ ที่ข้อมูลของตัวแปรทางการเงินนั้นไม่ใช่ข้อมูลเชิงเส้น ทำให้ไม่สามารถหาฟังก์ชันของความสัมพันธ์ระหว่างตัวแปรทางการเงิน ที่เป็นสาเหตุสำคัญกับการล้มละลายของสถาบันการเงิน

1.2. วัตถุประสงค์

- 1.2.1. เพื่อสร้างแบบจำลองใช้วิเคราะห์ความเสี่ยงต่อการล้มละลายของสถาบันการเงินในประเทศไทย โดยใช้เทคนิคโครงข่ายประสาทเทียม
- 1.2.2. เพื่อวิเคราะห์ตัวแปรที่มีผลกระทบต่อ การล้มละลายของสถาบันการเงิน โดยใช้เทคนิคพีซีเอ (Principal Component Analysis)

ตาราง 1.1 ตัวแปรทางด้านการเงิน [Altman, 1968]

Table 1: Financial variables

Financial variables	Sources
Investment in securities	Bal. Sheet
Loans and accrued interest receivables, NET	Bal. Sheet
Total assets	Bal. Sheet
Average of total assets	Calculation
Deposits	Bal. Sheet
Total liabilities	Bal. Sheet
Issued & paid-up preferred stocks/subordinated convt. bond	Bal. Sheet
Retained earnings	Bal. Sheet
Shareholders' equity	Bal. Sheet
Interest and dividend income	Inc. State.
Interest on loans	Inc. State.
Interest & dividend income after bad dept doubtful accounts	Inc. State.
Income tax expenses	Inc. State.
Earnings per share (Baht)	Inc. State.
Log of total assets	Calculation
One-year growth rate of total loans	Calculation
One-year growth rate of total assets	Calculation
Ratio of total loans to total assets	Calculation
Ratio of total of equity capital to total assets	Calculation
Ratio of total charge-offs to total loans	Calculation
Ratio of total interest income to total income	Calculation
Ratio of operating expense to total assets	Calculation
Ratio of operating expense to total revenue	Calculation
Ratio of total deposits to total assets	Calculation
Ratio of total deposits to total loans	Calculation
Return on Assets	Calculation
Return on Average Assets	Calculation
Earnings before tax to total assets	Calculation
Earnings before tax to average of assets	Calculation
Tobin's Q	Calculation

ตาราง 1.2 ตัวแปรของผู้ถือหุ้น [Bongini, 2001]

Table 2: Ownership variables

Ownership variables
Control rights by the largest shareholder (CRIGHTS)
Ownership rights held by the largest shareholder
Ratio of ownership to control rights
Largest shareholder
Type of ownership at the cutoff of 10% for all (Banks and Finance Companies)
1=Family
2=Crown Property Bureau
3=States
4=Foreigner
5=Widely hold (no controlling shareholder)
Dummy =1 if LARGE is a family (FAM)
Interaction between FAM and CRIGHTS (FAM*CRIGHTS)

1.3. สมมติฐานของงานวิจัย

งานวิจัยนี้จึงเสนอวิธีการทำนายโดยอาศัยโครงข่ายประสาทเทียมและการหาพารามิเตอร์ที่เหมาะสมมาเป็นข้อมูลที่ใช้ฝึกสอนโครงข่ายประสาทเทียมนั้นสามารถทำให้ผลลัพธ์เป็นที่น่าพอใจ แต่เนื่องจาก ความแม่นยำในการประเมินความเสี่ยงนั้นขึ้นกับข้อมูลที่จะนำมาฝึกสอน การวิจัยนี้จึงให้ความสำคัญในการแบ่งข้อมูลว่าส่วนใดจะนำไปเป็น ชุดฝึกสอน (Training set) ชุดประเมินผล (Validation set) และชุดทดสอบ (Test set) นอกจากนี้ยังใช้เทคนิคโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าหลายชั้น โดยใช้การเรียนรู้สามแบบดังนี้

- 1) การแพร่ย้อนกลับ (Backpropagation learning)
- 2) การใช้ความน่าจะเป็น (Probabilistic Neural Network)
- 3) แอลวีคิว (Learning Vector Quantization)

เนื่องจากข้อมูลของสถาบันการเงินที่นำมาวิเคราะห์ประกอบด้วยตัวแปรมากกว่า 40 ตัวแปร การวิจัยนี้จึงจะทำการวิเคราะห์ด้วยเทคนิคพีซีเอเพื่อลดจำนวนมิติของข้อมูลที่มี และวิเคราะห์ตัวแปรซึ่งซ่อนอยู่เมื่อเหลือจำนวนมิติที่เหมาะสม

1.4. ขอบเขตของการวิจัย

ข้อมูลที่นำมาวิเคราะห์เป็นข้อมูลทางการเงินและข้อมูลของผู้ถือหุ้น ของสถาบันการเงินที่จดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทย ระหว่างปี พ.ศ. 2536-2546

1.5. ประโยชน์ที่คาดว่าจะได้รับ

1.5.1 ผลต่อสังคม

- 1) ผู้บริหารสามารถใช้ผลลัพธ์ที่ได้จากแบบจำลองขั้นนี้ ในการตัดสินใจในการบริหารบริษัทเพื่อหลีกเลี่ยงความเสี่ยงต่อการล้มเหลวของบริษัท
- 2) ลูกค้านของบริษัท โดยเฉพาะของสถาบันการเงิน สามารถใช้ผลลัพธ์ที่ได้จากแบบจำลองขั้นนี้ในการตัดสินใจในการร่วมลงทุน

1.5.2 ผลต่อมหาวิทยาลัย

- 1) สร้างกลุ่มนักวิจัยที่เป็นลักษณะของสหสาขา ที่ใช้ศาสตร์ทางด้าน เศรษฐศาสตร์ การเงิน และการแก้ปัญหาเชิงปัญญาประดิษฐ์บนพื้นฐานของคณิตศาสตร์
- 2) สร้างความร่วมมือระหว่างหน่วยงาน คณะเทคโนโลยีสารสนเทศ มหาวิทยาลัยธุรกิจบัณฑิตย์ และศูนย์วิจัยเอวิก จุฬาลงกรณ์มหาวิทยาลัย
- 3) สร้างชื่อเสียงให้กับมหาวิทยาลัย เมื่อมีบทความวิจัยลงในวารสารต่างประเทศ บทความวิจัยที่นำเสนอในการประชุมระดับชาติ และนานาชาติ

1.5.3 ผลต่อกลุ่มผู้วิจัย

- 1) ได้แลกเปลี่ยนความรู้ระหว่างศาสตร์ ซึ่งมีโจทย์เป็นปัญหาจริงที่เกิดขึ้นในระบบเศรษฐกิจ ซึ่งใช้วิธีการแก้ปัญหาทางคณิตศาสตร์
- 2) สามารถนำผลวิจัยมาเขียนบทความลงวารสารนานาชาติ และร่วมประชุมวิชาการระดับชาติและนานาชาติ

1.6. นิยามคำศัพท์เฉพาะ

- 1) โครงข่ายประสาทเทียม (Artificial Neural Network) หมายถึง เทคนิคการพยากรณ์ เหมาะกับลักษณะข้อมูลซึ่งไม่ใช่เชิงเส้น
- 2) การแพร่ย้อนกลับ (Backpropagation learning) หมายถึง เทคนิคหนึ่งของการเรียนรู้ที่ใช้ในโครงข่ายประสาทเทียม ซึ่งมีคำอธิบายเชิงลึกในบทที่ 2
- 3) การใช้ความน่าจะเป็น (Probabilistic Neural Network) หมายถึง เทคนิคหนึ่งของการเรียนรู้ที่ใช้ในโครงข่ายประสาทเทียม ซึ่งมีคำอธิบายเชิงลึกในบทที่ 2
- 4) แอลวีคิว (Learning Vector Quantization) หมายถึง เทคนิคหนึ่งของการเรียนรู้ที่ใช้ในโครงข่ายประสาทเทียม ซึ่งมีคำอธิบายเชิงลึกในบทที่ 2
- 5) การเรียนรู้แบบมีผู้สอน (Supervised Learning) หมายถึง รูปแบบการเรียนรู้ของโครงข่ายประสาทเทียม ซึ่งกำหนดเป้าหมายของผลลัพธ์ชัดเจน ในขั้นตอนของการเรียนรู้

- 6) การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) หมายถึง รูปแบบการเรียนรู้ของโครงข่ายประสาทเทียม ซึ่งไม่กำหนดเป้าหมายของผลลัพธ์ ในขั้นตอนของการเรียนรู้
- 7) การล้มละลายของสถาบันการเงิน หมายถึง การปิดกิจการ และการรวมกิจการเข้ากับสถาบันการเงินหรือธนาคารอื่นๆ
- 8) Type I error หมายถึง ร้อยละของอัตราส่วนระหว่างจำนวนที่ผลพยากรณ์ว่าสถาบันการเงินนั้นไม่ล้มละลายแต่ความเป็นจริงนั้น สถาบันการเงินนั้นล้มละลายต่อจำนวนของสถาบันการเงินที่ไม่ล้มละลายทั้งหมด
- 9) Type II error หมายถึง ร้อยละของอัตราส่วนระหว่างจำนวนที่ผลพยากรณ์ว่าสถาบันการเงินนั้นล้มละลายแต่ความเป็นจริงนั้น สถาบันการเงินนั้นไม่ล้มละลายต่อจำนวนของสถาบันการเงินที่ล้มละลายทั้งหมด

บทที่ 2

ทฤษฎี เอกสาร งานวิจัย ที่เกี่ยวข้อง

2.1. ทฤษฎีที่เกี่ยวข้อง

งานวิจัยนี้เสนอแบบจำลองการทำนายความล้มเหลวของสถาบันทางการเงิน โดยใช้โครงข่ายประสาทเทียม (Artificial neural networks) แบบป้อนไปข้างหน้า (Feedforward) โดย ข้อมูลนำเข้าโครงข่ายประสาทเทียมนั้น ได้จากการวิเคราะห์หาปัจจัยที่มีผลต่อความล้มเหลวของสถาบันทางการเงินมากที่สุด โดยใช้เทคนิคทางสถิติ ที่เรียกว่า principal component analysis ซึ่งสามารถสกัดเฉพาะปัจจัยซึ่งมีผลต่อการทำนายว่าสถาบันนั้นล้มเหลวหรือไม่


ทฤษฎี เอกสารและงานวิจัยที่เกี่ยวข้องนั้นแยกสรุปเป็นหัวข้อดังนี้

1. เทคนิคพีซีเอ (Principal Component Analysis)
2. สถาปัตยกรรมโครงข่ายประสาทเทียม
3. การเรียนรู้ของโครงข่ายประสาทเทียมทั้ง 3 แบบ คือ แบบแพร่ย้อนกลับ แบบใช้ความน่าจะเป็น และแบบแอลวีคิว


2.2. เทคนิคพีซีเอ

เทคนิคพีซีเอ ย่อมาจาก “Principal Component Analysis” คือ เทคนิคทางสถิติที่นิยมใช้กับชุดข้อมูลที่มีมิติสูง โดยวิเคราะห์องค์ประกอบหลักเพื่อลดจำนวนมิติของข้อมูล องค์ประกอบเหล่านี้สามารถจัดลำดับของความสำคัญโดยอาศัยค่าลักษณะเฉพาะ (Eigenvalue) ที่คำนวณจากเมทริกซ์ความแปรปรวนร่วมเกี่ยว (Covariance matrix) ของชุดข้อมูลที่ค่าเฉลี่ยเท่ากับศูนย์ ค่าลักษณะเฉพาะสูง หมายถึง องค์ประกอบหลักที่ให้ค่าความแปรปรวนสูงสุด บางแอปพลิเคชันใช้หลักการพีซีเอ แต่เรียกชื่อแตกต่างกัน เช่น Karthunen Loeve transform, Hotelling transform หรือ Proper Orthogonal Decomposition (POD) เป็นต้น

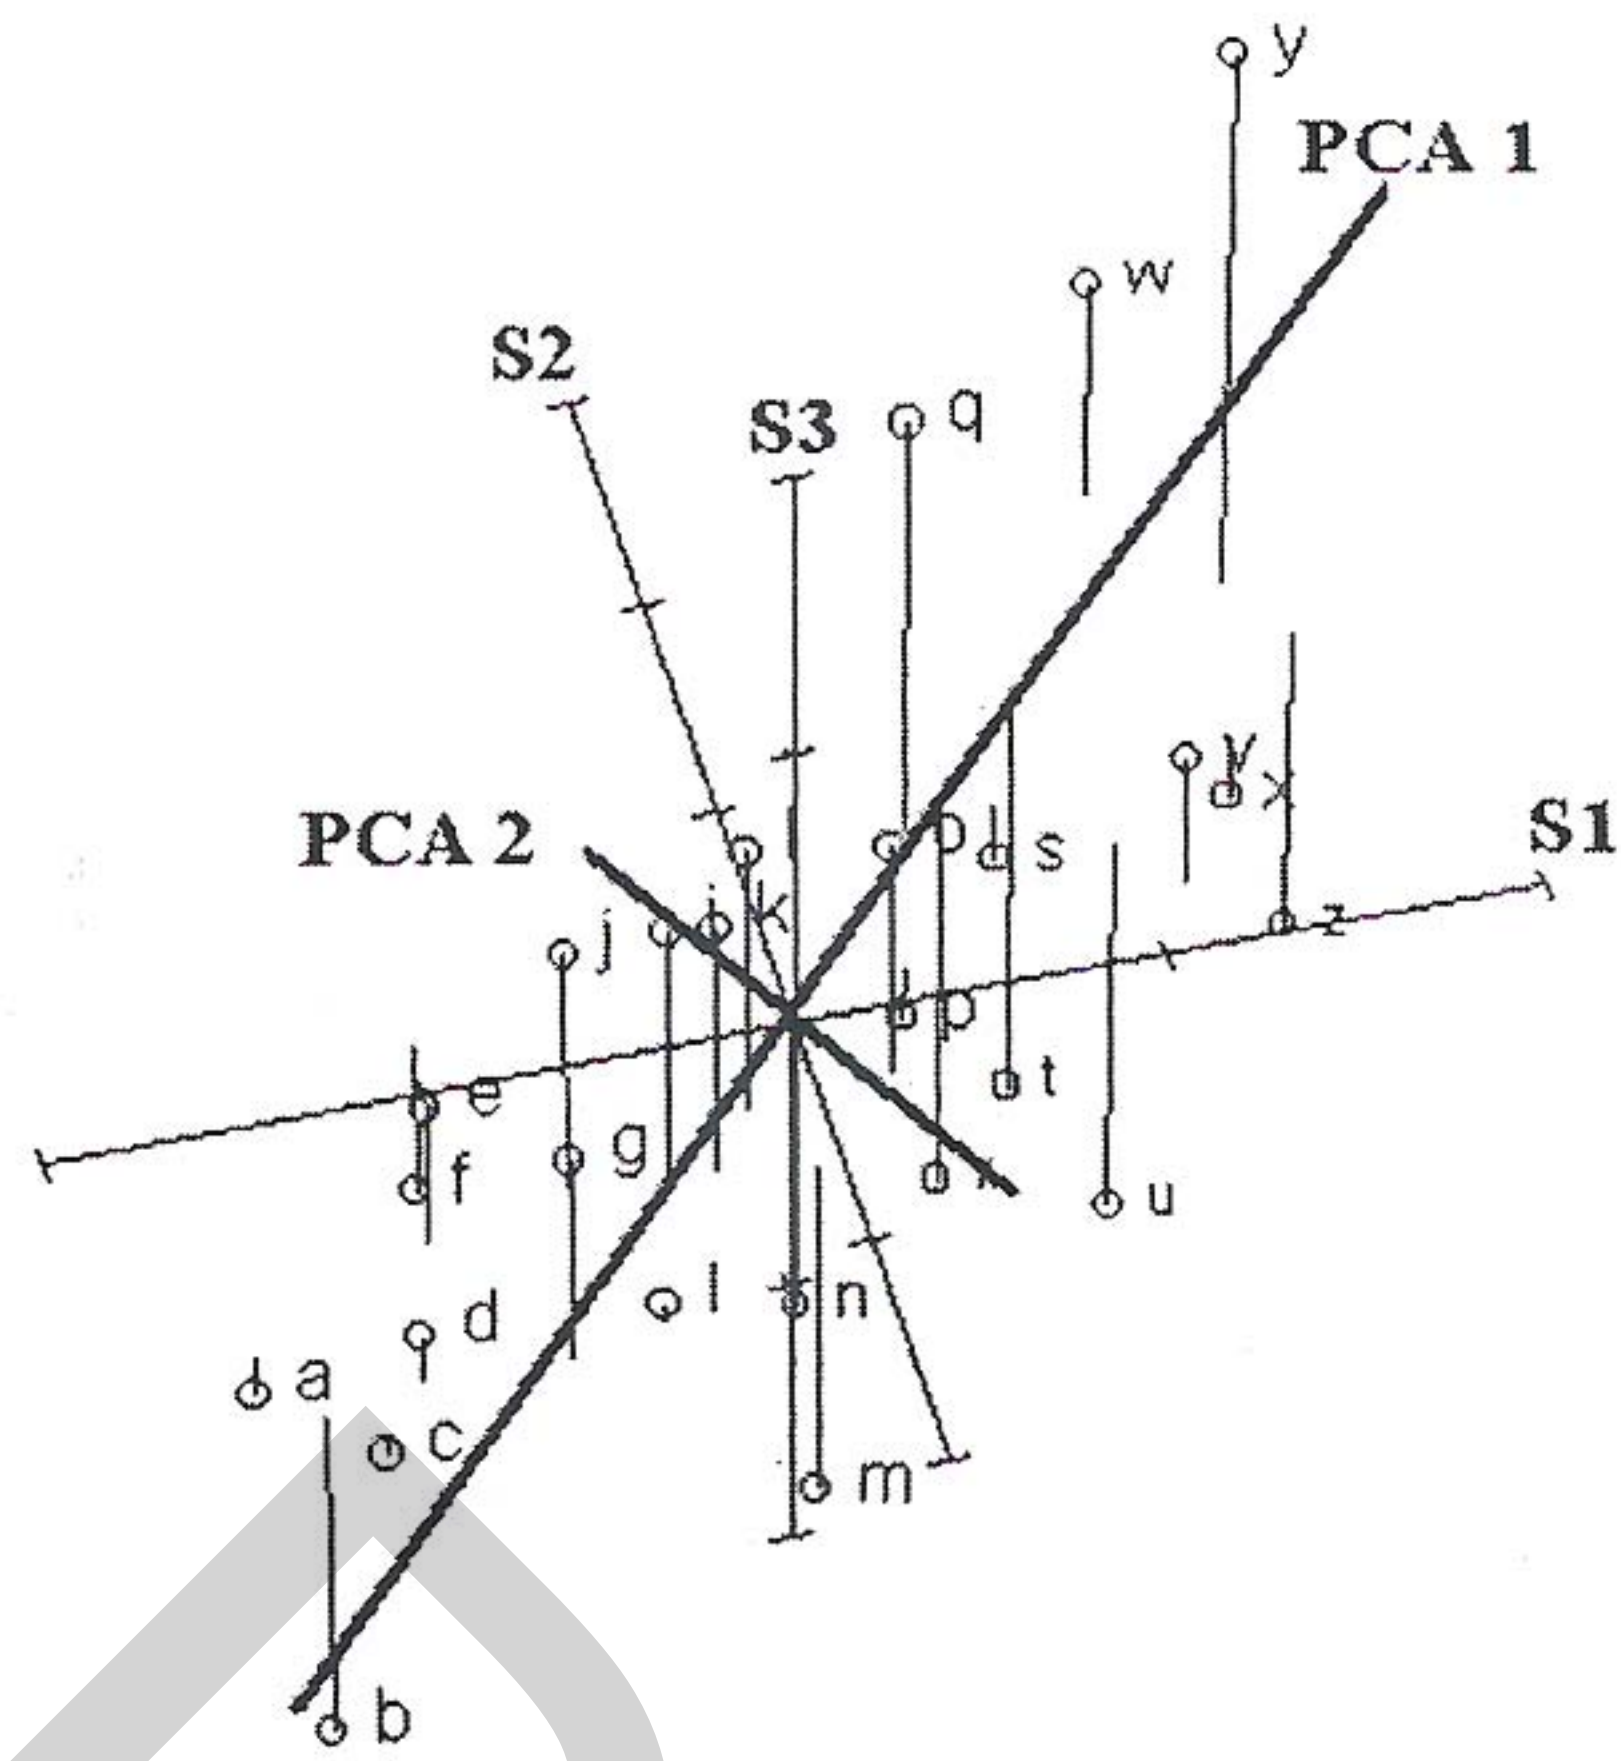
ตัวอย่างการใช้เทคนิคพีซีเอ บนข้อมูลสามมิติ ประกอบด้วยแกน (X_1, X_2, X_3) แสดงในภาพ 2.1 ซึ่งประกอบด้วยเซตข้อมูล $\{a, b, c, \dots, z\}$ บนปริภูมิ \mathcal{R}^3 เริ่มด้วยการแปลงไปปริภูมิมาตรฐาน (Standardize) บนแกนใหม่ (S_1, S_2, S_3) แสดงในภาพ 2.2 โดยกำหนดให้ค่าเฉลี่ยใหม่ของเซตข้อมูล เท่ากับศูนย์ จากนั้นระนาบพีซีเอ ซึ่งประกอบด้วยแกน PCA1 และ PCA2 สามารถคำนวณด้วยการหา Eigenvalue และ Eigenvalue ของเซตข้อมูลในปริภูมิมาตรฐาน ดังแสดงในภาพ 2.3 เมื่อหมุนแกน PCA1 เป็นแกน X แล้ว แกน PCA2 เป็นแกน Y แล้วนั้น เซตข้อมูลที่ได้แสดงในภาพ 2.4



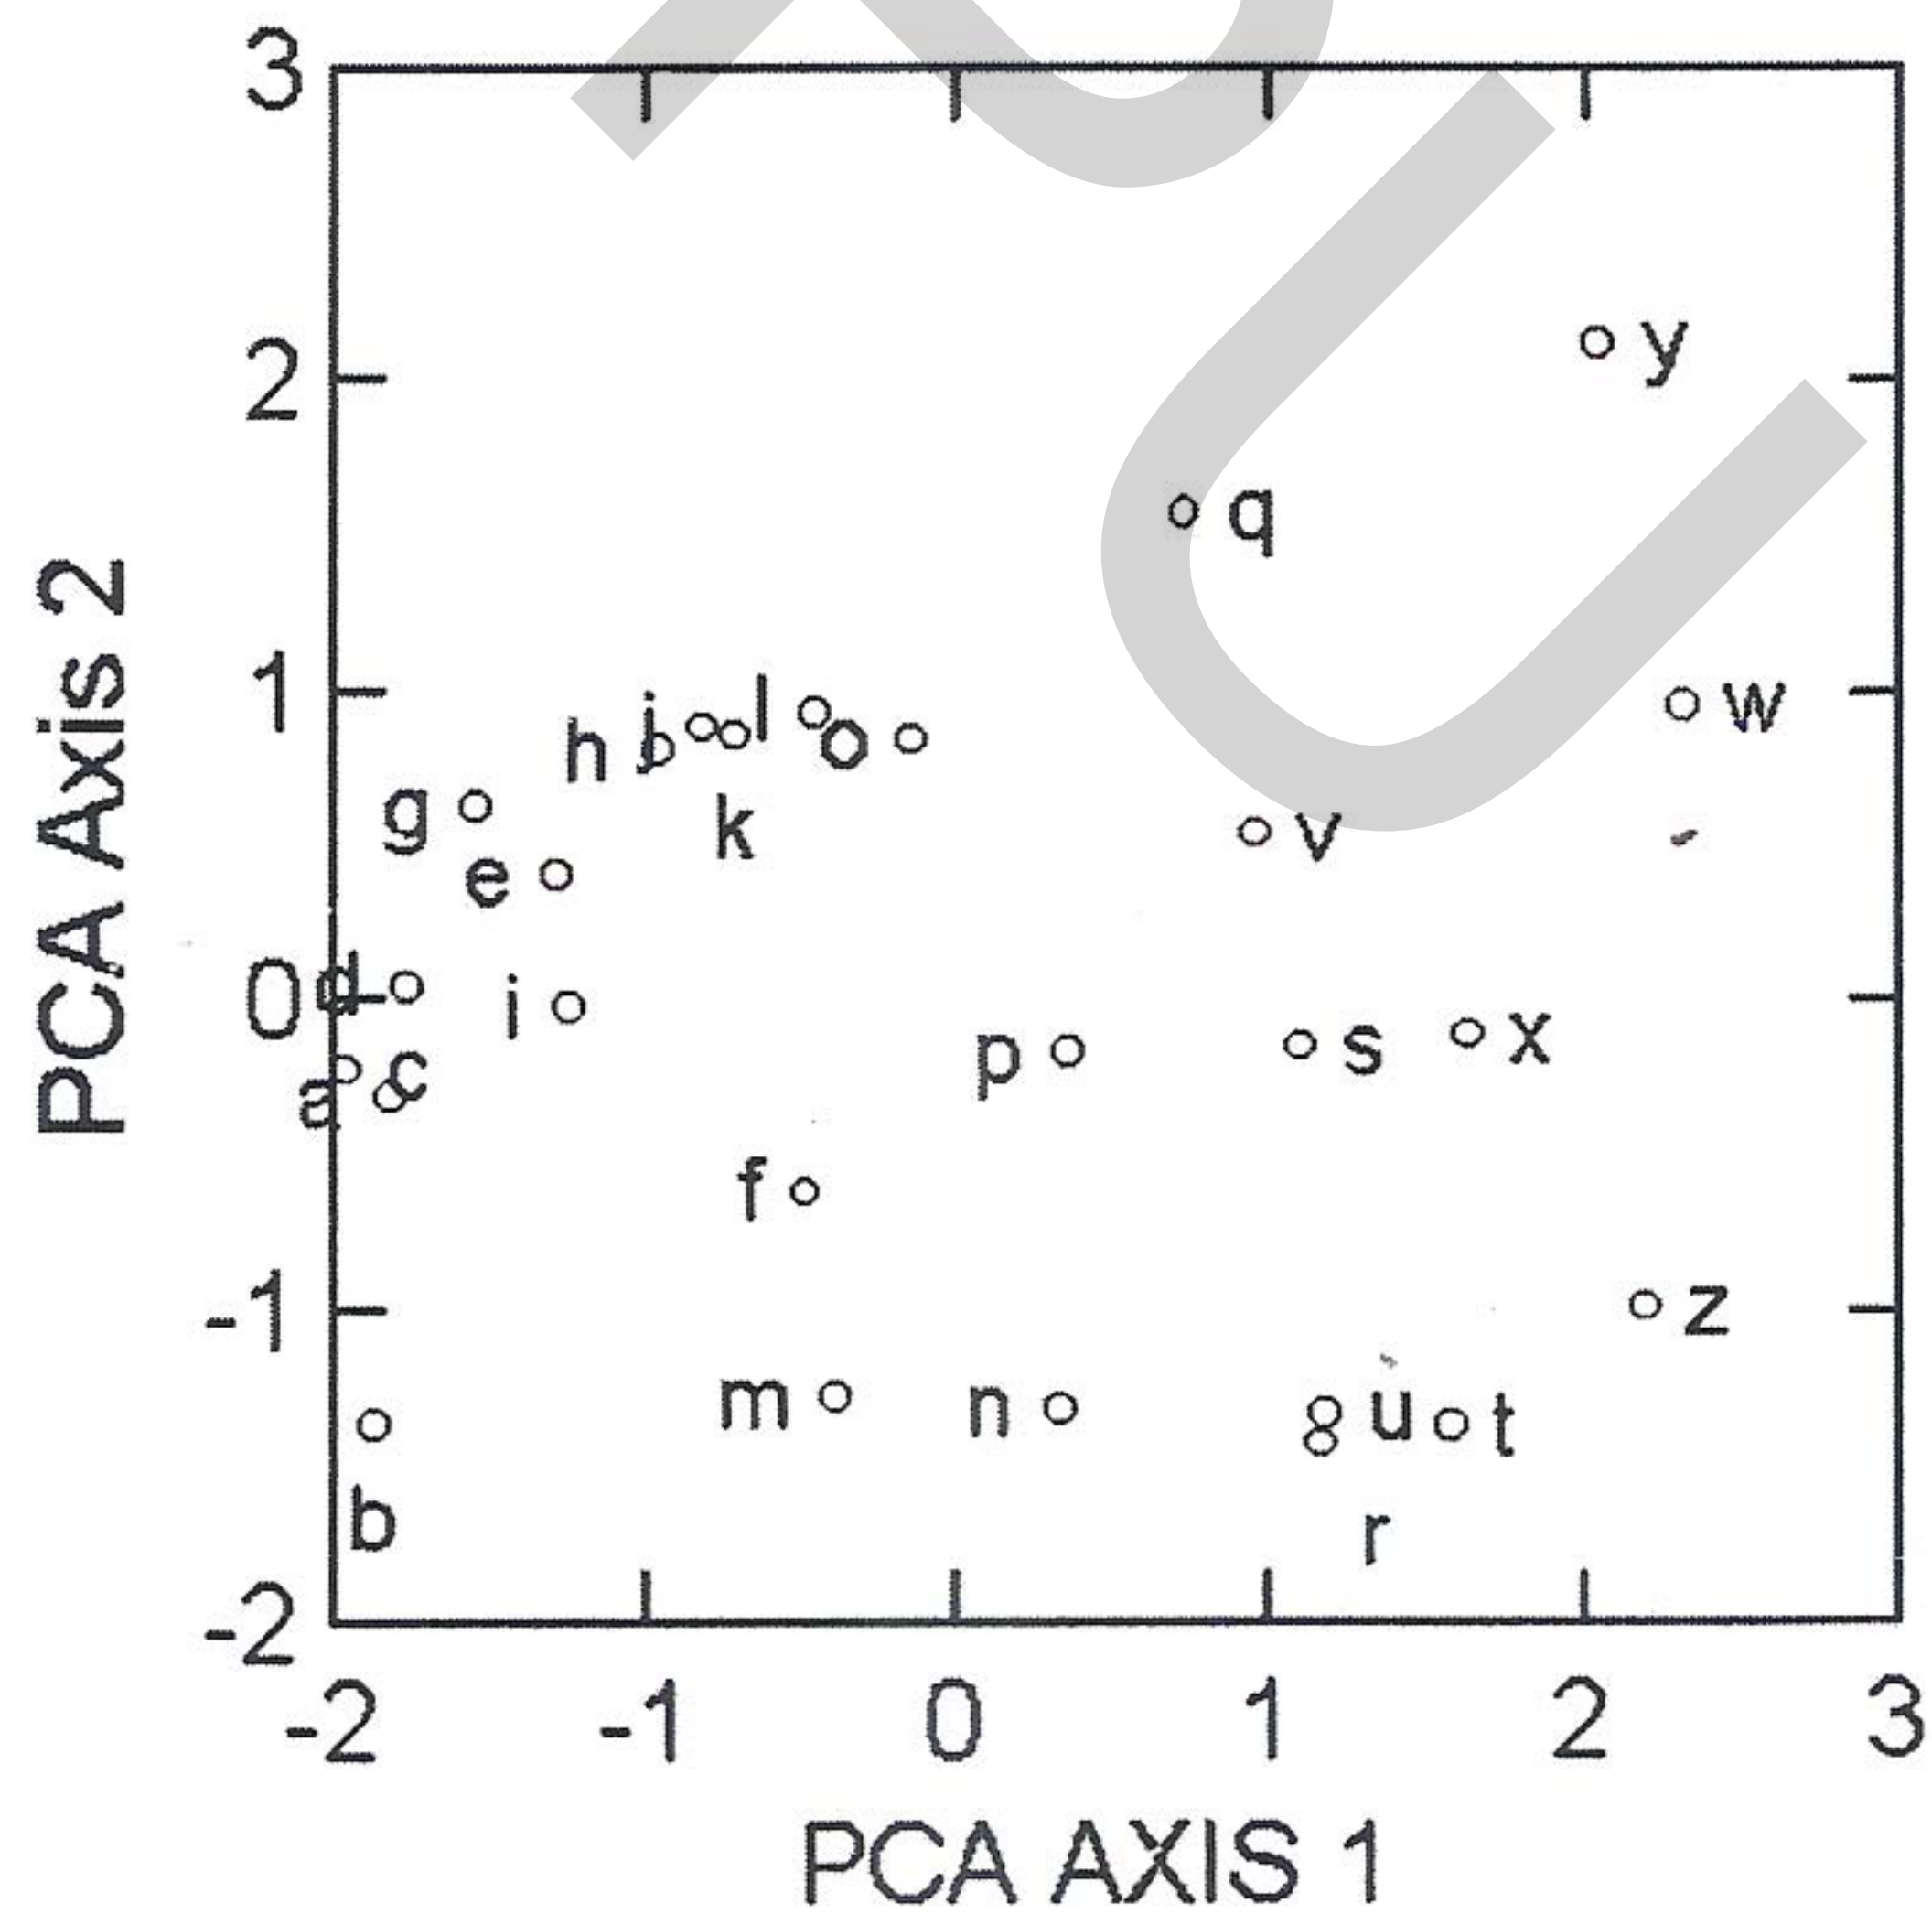
ภาพ 2.1 เซตข้อมูล $\{a, b, c, \dots, z\}$ บนปริภูมิ \mathcal{R}^3 (X_1, X_2, X_3)



ภาพ 2.2 เซตข้อมูล $\{a, b, c, \dots, z\}$ ในปริภูมิมาตรฐาน \mathbb{R}^3 ($S1, S2, S3$)



ภาพ 2.3 แกนพีซีเอ ในปริภูมิมาตรฐาน



ภาพ 2.4 เซตข้อมูลบนแกนพีซีเอ

ตาราง 2.1 สัญลักษณ์ทางคณิตศาสตร์และคำอธิบาย ที่เกี่ยวข้องกับเทคนิคพีซีเอ

สัญลักษณ์	คำอธิบาย	ขนาดมิติ	ดัชนี
$\mathbf{X} = \{x(m, n)\}$	เมทริกซ์ข้อมูล ประกอบด้วยเซตของ เวกเตอร์ข้อมูลทั้งหมด โดยกำหนดให้ เวกเตอร์จัดเรียงแนวคอลัมน์	$M \times N$	$m = 1 \dots M$ $n = 1 \dots N$
N	จำนวนคอลัมน์เวกเตอร์ในชุดข้อมูล	1×1	-
M	จำนวนสมาชิกในแต่ละคอลัมน์เวกเตอร์ (มิติ)	1×1	-
L	จำนวนมิติในปริภูมิใหม่	1×1	-
$\boldsymbol{\mu} = \{\mu(m)\}$	เวกเตอร์ค่าเฉลี่ย แต่ละสมาชิก คือ ค่าเฉลี่ย แถว m ของเมทริกซ์ข้อมูล	$M \times 1$	$m = 1 \dots M$
$\mathbf{s} = \{s(m)\}$	เวกเตอร์ค่าเบี่ยงเบนมาตรฐาน แต่ละสมาชิก คือ ค่าเบี่ยงเบนมาตรฐานของแถว m ของ เมทริกซ์ข้อมูล	$M \times 1$	$m = 1 \dots M$
$\mathbf{h} = \{h(n)\}$	เวกเตอร์ซึ่งประกอบด้วยค่า 1 ทั้งหมด	$1 \times N$	$n = 1 \dots N$
$\mathbf{B} = \{B(m, n)\}$	ค่าเบี่ยงเบนจากค่าเฉลี่ยของแต่ละแถว m ของเมทริกซ์ข้อมูล	$M \times N$	$m = 1 \dots M$ $n = 1 \dots N$
$\mathbf{Z} = \{Z(m, n)\}$	ค่า z ซึ่งคำนวณจากค่าเฉลี่ยและค่าเบี่ยงเบน มาตรฐานของแถว m ของเมทริกซ์ข้อมูล (Z-scores)	$M \times N$	$m = 1 \dots M$ $n = 1 \dots N$
$\mathbf{C} = \{C(p, q)\}$	เมทริกซ์ความแปรปรวนร่วมเกี่ยว (Covariance matrix)	$M \times N$	$p = 1 \dots M$ $q = 1 \dots N$
$\mathbf{R} = \{R(p, q)\}$	เมทริกซ์สหสัมพันธ์ (Correlation matrix)	$M \times N$	$p = 1 \dots M$ $q = 1 \dots N$
$\mathbf{V} = \{V(p, q)\}$	เมทริกซ์ของเวกเตอร์ลักษณะเฉพาะ โดย กำหนดให้เวกเตอร์ลักษณะเฉพาะเรียงตาม คอลัมน์	$M \times N$	$p = 1 \dots M$ $q = 1 \dots N$

$\mathbf{D} = \{D(p, q)\}$	เมทริกซ์แยงมุม โดยกำหนดให้ค่าลักษณะเฉพาะเรียงตามแนวทแยงหลัก และสมาชิกที่เหลือมีค่าเท่ากับศูนย์	$M \times N$	$p = 1 \dots M$ $q = 1 \dots N$
$\mathbf{W} = \{W(p, q)\}$	เมทริกซ์ของเวกเตอร์ฐานหลัก โดยกำหนดให้เวกเตอร์เรียงตามคอลัมน์	$M \cdot L$	$p = 1 \dots M$ $q = 1 \dots L$
$\mathbf{Y} = \{Y(m, n)\}$	เมทริกซ์ผลลัพธ์ ซึ่งเป็นผลจากการแปลงข้อมูล \mathbf{X} ไปในปริภูมิใหม่	$L \times N$	$m = 1 \dots L$ $n = 1 \dots N$

สูตรคณิตศาสตร์ของเทคนิคพีซีเอ

การใช้เทคนิคพีซีเอ เพื่อลดจำนวนมิติของข้อมูล จากเดิมจำนวนตัวแปร = M ให้เป็นจำนวนตัวแปรหลัก = L กำหนดให้ข้อมูลเข้า คือ $\mathbf{X} = \{x(m, n)\}$ มีมิติขนาด $M \times N$ และผลลัพธ์ คือ $\mathbf{Y} = \{y(l, n)\}$ มีมิติขนาด $L \times N$ สัญลักษณ์ที่ใช้และคำอธิบายแสดงดังตารางที่ 2.1 ขั้นตอนในการวิเคราะห์ประกอบด้วย

1. จัดเรียงชุดข้อมูล \mathbf{X} ซึ่งมีทั้งหมด N ชุด แต่ละชุดประกอบด้วย M ตัวแปร

$$\mathbf{X} = \begin{pmatrix} x(1,1) & \dots & x(1,N) \\ \vdots & \ddots & \vdots \\ x(M,1) & \dots & x(M,N) \end{pmatrix} \quad (2.1)$$

กำหนดให้ $x(i, j)$ คือ ตัวแปรที่ i ของข้อมูลที่ j
โดยที่ $1 \leq i \leq M$ และ $1 \leq j \leq N$

2. คำนวณเวกเตอร์ค่าเฉลี่ย $\boldsymbol{\mu} = \{\mu(m)\}$ โดยให้ $\mu(m)$ หมายถึงค่าเฉลี่ยของชุดข้อมูลสำหรับตัวแปรที่ m

$$\mu(m) = \frac{1}{N} \sum_{n=1}^N x(m, n) \quad (2.2)$$

3. ปรับชุดข้อมูลใหม่ \mathbf{B} ให้มีค่าเฉลี่ยเท่ากับศูนย์

$$\mathbf{B} = \mathbf{X} - \boldsymbol{\mu} \cdot \mathbf{h} \quad (2.3)$$

กำหนดให้ $\mathbf{h} = \{h(n) = 1 | 1 \leq n \leq N\}$

4. คำนวณเมทริกซ์ความแปรปรวนร่วมเกี่ยว \mathbf{C} ซึ่งมีขนาด $M \times N$

$$\mathbf{C} = E(\mathbf{B} \times \mathbf{B}) = E(\mathbf{B} \times \mathbf{B}^T) = \frac{1}{N} \mathbf{B} \times \mathbf{B}^T \quad (2.4)$$

กำหนดให้ $E(\cdot)$ เป็นฟังก์ชันคาดหมาย (Expectation function)

\times เป็นการคูณภายนอก

\mathbf{B}^T เป็นเมทริกซ์สลับเปลี่ยน

5. คำนวณเมทริกซ์ทแยงมุมของค่าลักษณะเฉพาะ \mathbf{D} และเมทริกซ์ของเวกเตอร์ลักษณะเฉพาะ \mathbf{V} ของเมทริกซ์ความแปรปรวนร่วมเกี่ยว \mathbf{C}

$$\mathbf{V}^{-1} \mathbf{C} \mathbf{V} = \mathbf{D} \quad (2.5)$$

กำหนดให้ $D(p, q) = \begin{cases} \lambda_m; & p = q = m \\ 0 & ; p \neq q \end{cases}$

6. จัดเรียงลำดับคู่ค่าลักษณะเฉพาะกับเวกเตอร์ลักษณะเฉพาะให้มีลำดับค่าลักษณะเฉพาะจากมากไปน้อย
7. คำนวณค่าพลังงานของเวกเตอร์ลักษณะเฉพาะ $\mathbf{g} = \{g(m)\}$

$$g(m) = \sum_{q=1}^m D(p, q) \quad (2.6)$$

กำหนดให้ $p = q$ และ $1 \leq m \leq M$

8. คัดเลือกเวกเตอร์ลักษณะเฉพาะจำนวน L เวกเตอร์ เป็นเวกเตอร์ฐานหลักของ ปริภูมิใหม่ ภายใต้งैอนไข $g(m=L) \geq 90\%$

$$W(p,q) = V(p,q) \quad (2.7)$$

กำหนดให้ $1 \leq p \leq M$ และ $1 \leq q \leq L$

9. แปลงข้อมูลเดิมเป็นค่า z

$$Z = B \div (s \otimes h) \quad (2.8)$$

$$s = \{s(m)\} = \sqrt{C(p,q)} \quad (2.9)$$

กำหนดให้ $1 \leq p = q = m \leq M$

\otimes เป็นการคูณแบบสมาชิกต่อสมาชิก

\div เป็นการหารแบบสมาชิกต่อสมาชิก

10. คำนวณข้อมูลใหม่ $Y = \{Y(l,n)\}$ บนปริภูมิ $L \times N$

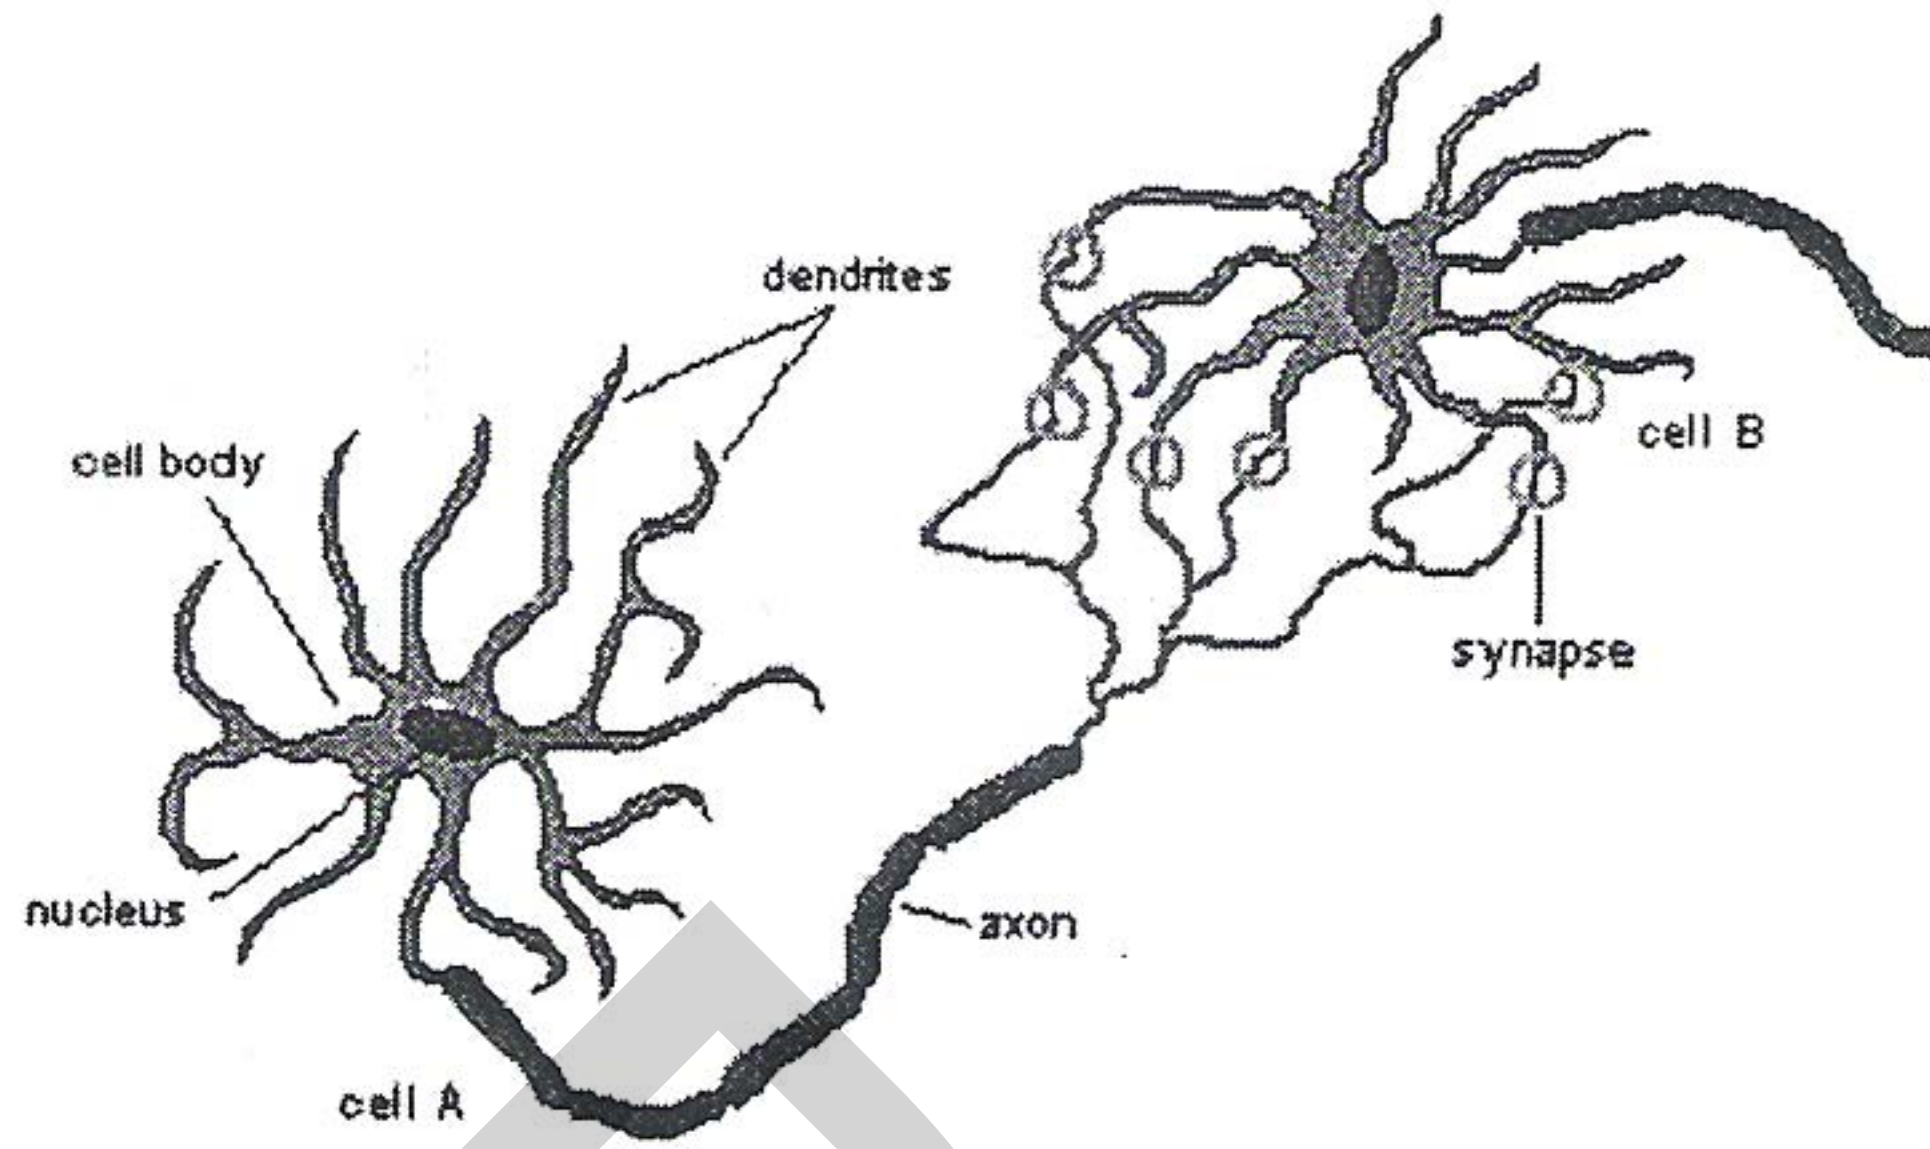
$$Y = W^T \cdot Z \quad (2.10)$$

2.3. สถาปัตยกรรมโครงข่ายประสาทเทียม

โครงข่ายประสาทเทียม (Artificial neural network) คือแบบจำลองทางคณิตศาสตร์ที่ ประมวลผลสารสนเทศแบบปมประสาทซึ่งเชื่อมต่อกันเสมือนเกิดขึ้นจริงในสมองมนุษย์ มีวัตถุประสงค์เพื่อการเรียนรู้และจดจำแบบรูปแบบ


แนวคิดนี้ได้มาจากการศึกษาข่ายงานไฟฟ้าชีวภาพ (Bioelectric network) ในสมอง ซึ่ง ประกอบด้วย เซลล์ประสาท หรือ "นิวรอน" (Neurons) และ จุดประสานประสาท (Synapses) แต่ละเซลล์ประสาทประกอบด้วยปลายในการรับกระแสประสาท เรียกว่า "เดนไดรต์" (Dendrite) ซึ่งเป็นหน่วยรับข้อมูลเข้า และปลายในการส่งกระแสประสาทเรียกว่า "แอกซอน" (Axon) ซึ่งเป็นเหมือนหน่วยแสดงผลข้อมูลของเซลล์ เซลล์เหล่านี้ทำงานด้วยปฏิกิริยาไฟฟ้าเคมี เมื่อมีการกระตุ้นด้วยสิ่งเร้าภายนอกหรือกระตุ้นด้วยเซลล์ด้วยกัน กระแสประสาทจะวิ่งผ่านเดน

ใครที่เข้าสู่นิวเคลียสซึ่งจะเป็นตัวตัดสินใจว่าต้องกระตุ้นเซลล์อื่น ๆ ต่อหรือไม่ ถ้ากระแสประสาทแรงพอ นิวเคลียสก็จะกระตุ้นเซลล์อื่น ๆ ต่อไปผ่านทางแอกซอนของมัน แสดงดังภาพ 2.5



ภาพ 2.5 เซลล์ประสาททางชีววิทยา

การเชื่อมโยงเซลล์ประสาทจำนวนหนึ่งเข้าด้วยกันเป็นโครงข่ายประสาทเทียม นั้นสามารถเชื่อมโยงแบบใดก็ได้โดยที่ไม่มีขอบเขตจำกัด อย่างไรก็ตาม ซึ่งมีลักษณะของกราฟแสดงดังภาพ 2.6 ใช้สัญลักษณ์ X แทนข้อมูลเข้า และ F แทนผลลัพธ์ที่ได้ จุดบนกราฟแทนหน่วยประสาทเทียม ซึ่งเชื่อมโยงกันแบบป้อนไป แสดงดังภาพ ก. และแบบป้อนไปเวียนกลับ แสดงดังภาพ ข.



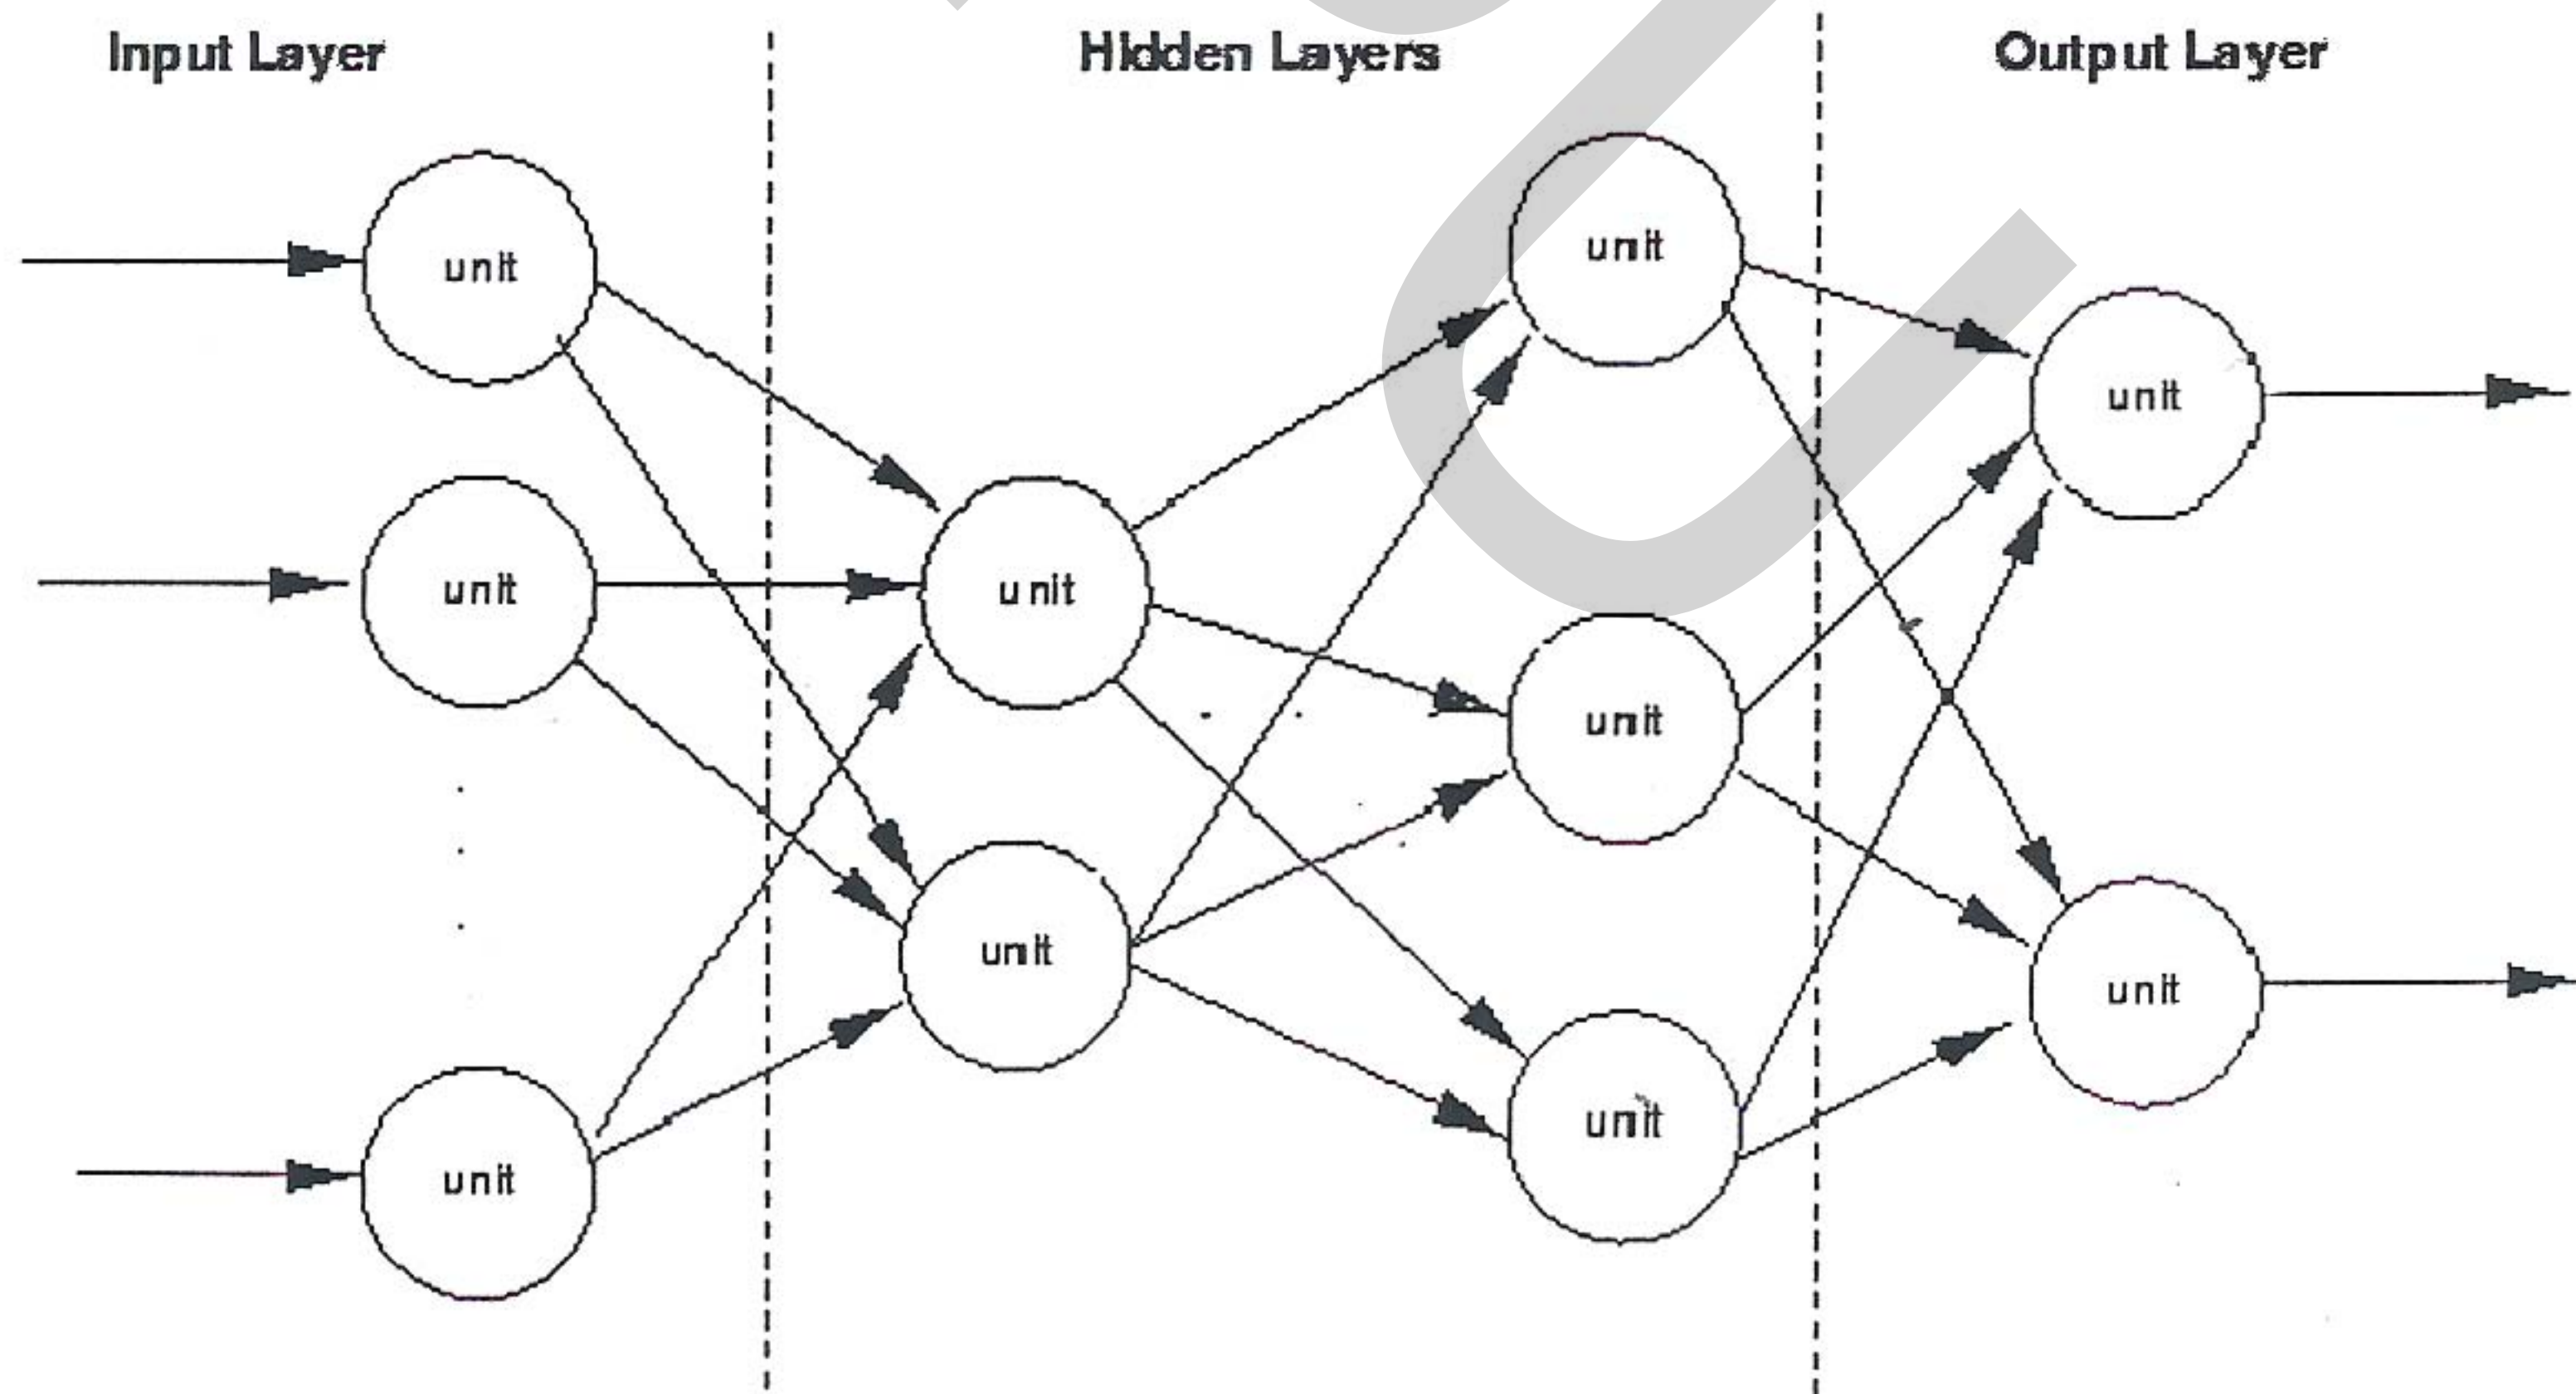
ก. กราฟทั่วไปของโครงข่ายแบบป้อนไป

ข. กราฟเฉพาะการป้อนไปเวียนกลับ

ภาพ 2.6 กราฟการเชื่อมต่อภายในโครงข่าย

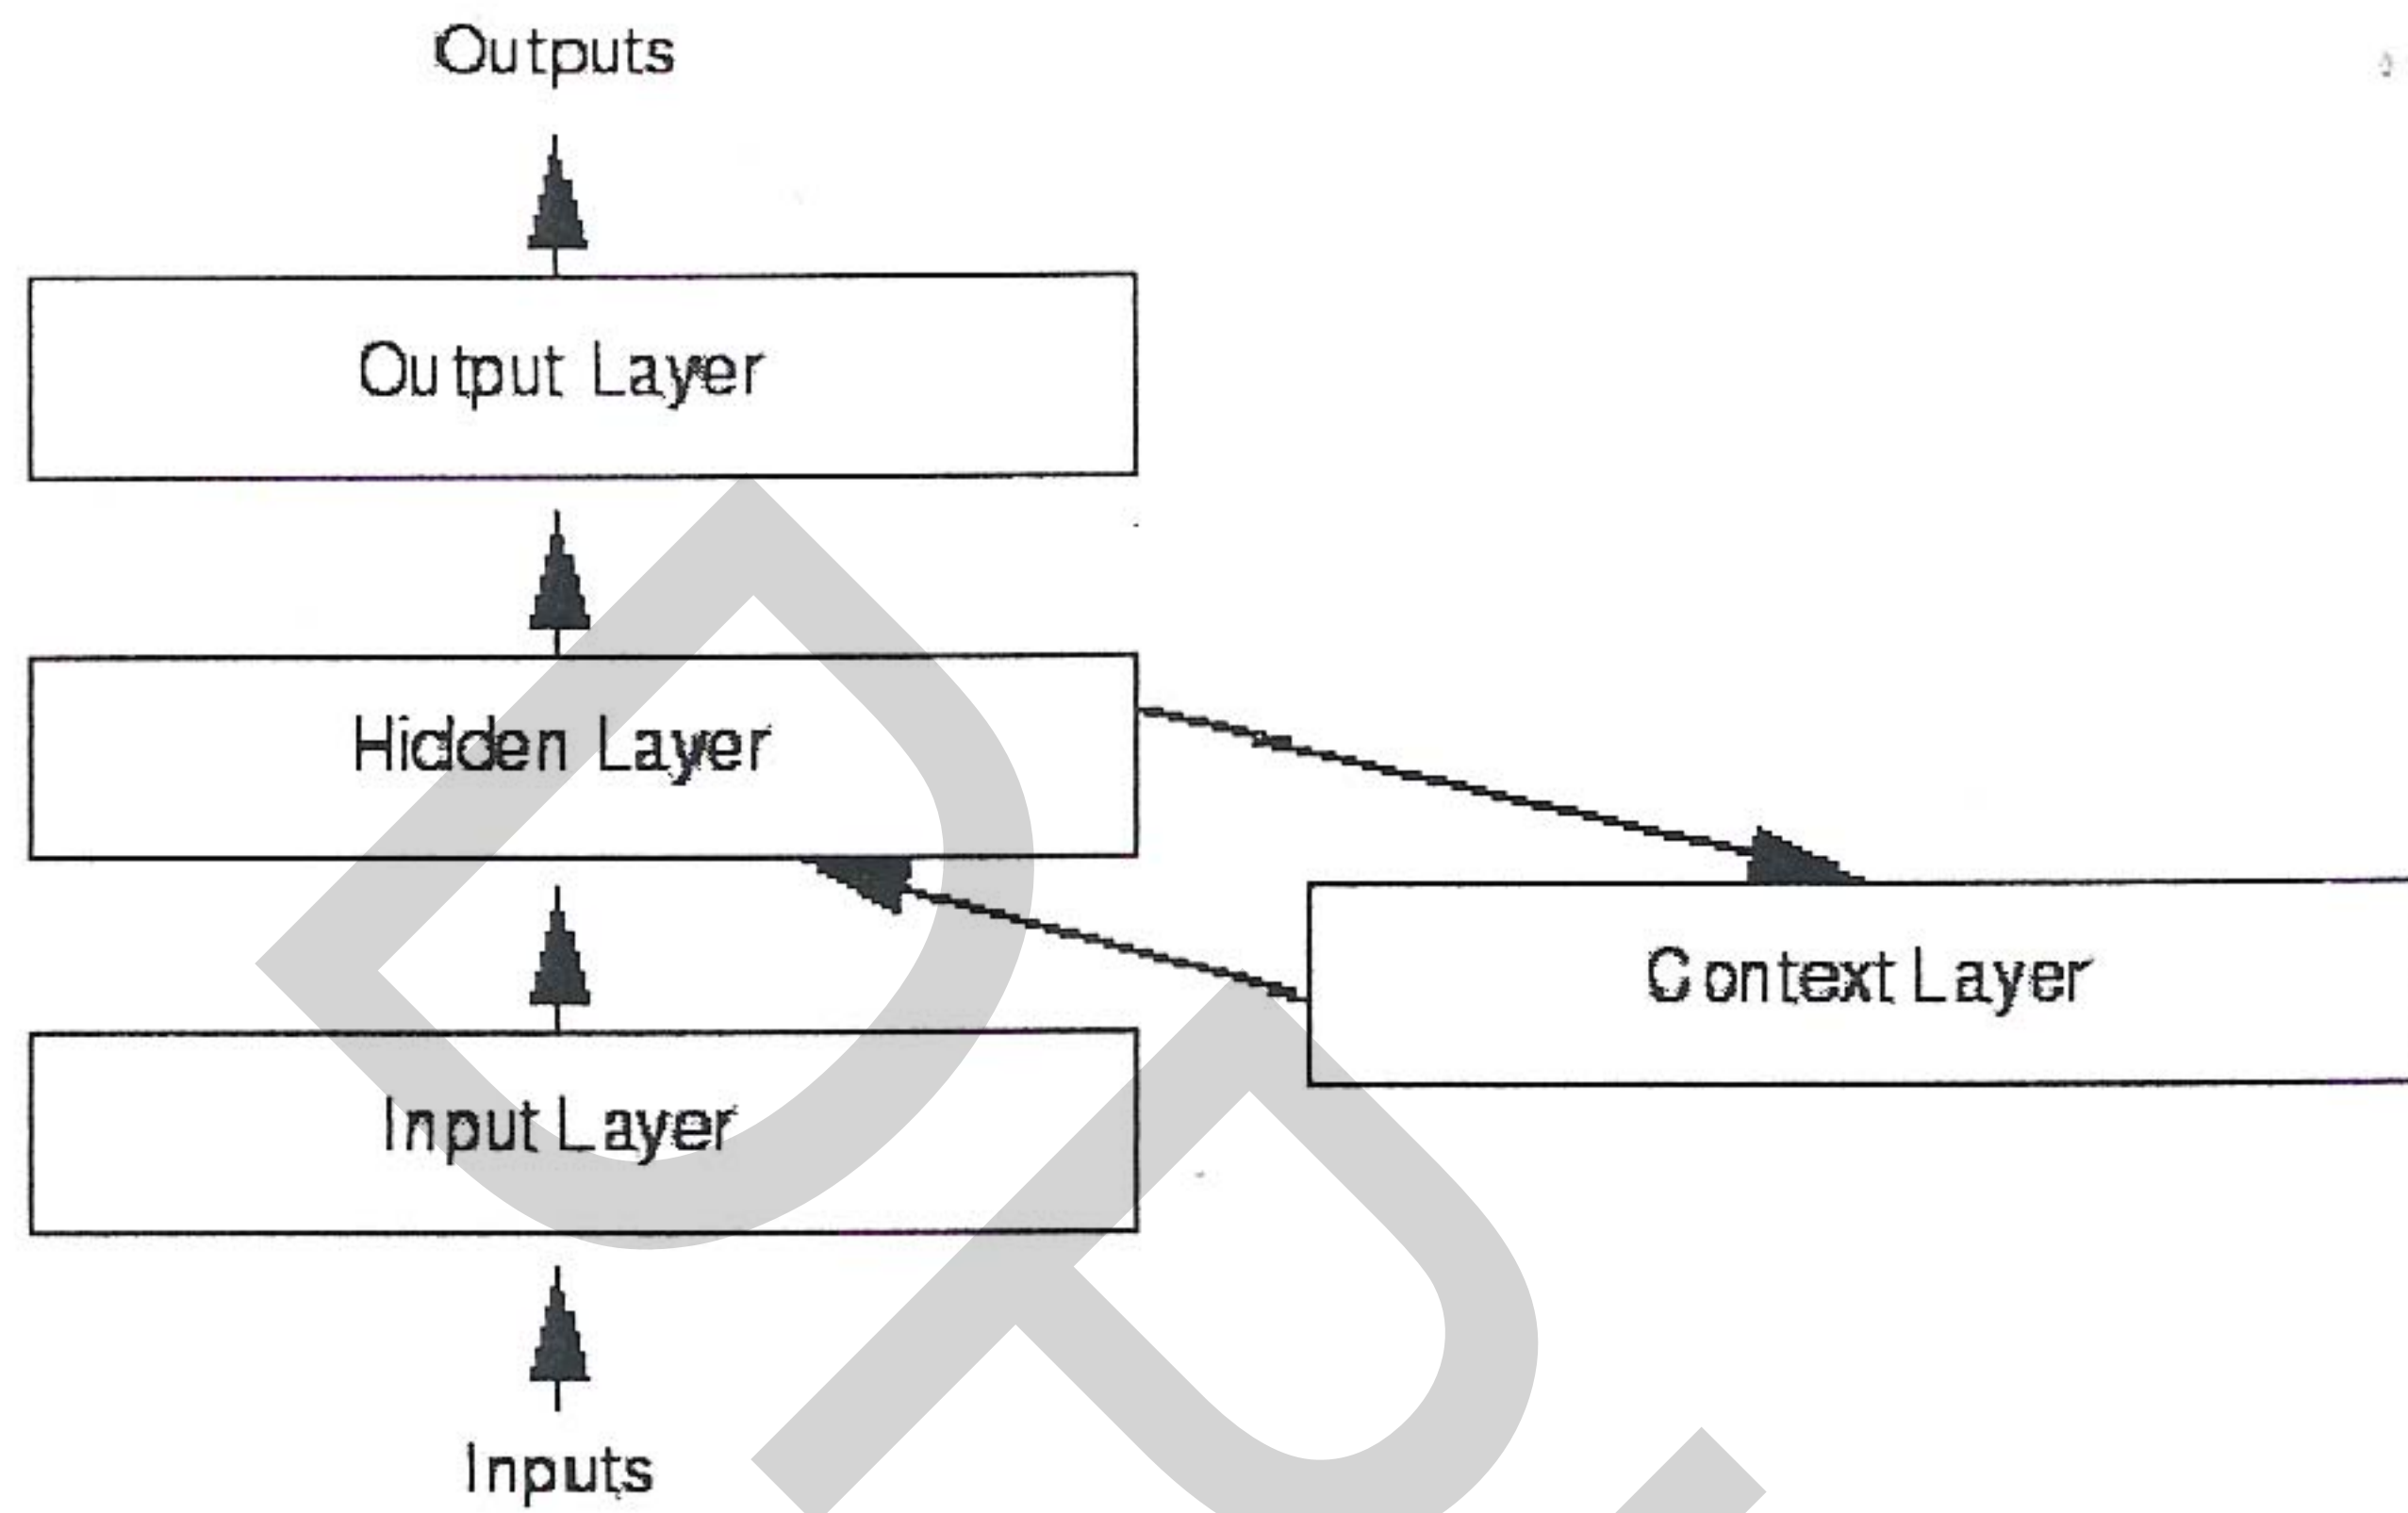
ในทางปฏิบัติแล้ว เทคนิคการเรียนรู้ของโครงข่ายประสาทเทียมมักจะถูกออกแบบมาให้ใช้งานได้กับสถาปัตยกรรมโครงข่ายประสาทเทียมที่มีลักษณะเฉพาะเท่านั้นสถาปัตยกรรมโครงข่ายประสาทเทียมที่พบทั่วไปจะมีลักษณะหลักๆ คือ มีการจัดเซลล์ประสาทเทียมเป็นชั้นๆ (Layer) ชั้นที่รับข้อมูลเข้าเรียกว่าชั้นอินพุต (Input layer) ชั้นที่ผลิตผลตอบของโครงข่ายเรียกว่าชั้นเอาต์พุต (Output layer) ส่วนชั้นอื่นๆ ที่มีส่วนในการช่วยทำการประมวลผลอยู่ภายในเรียกว่าชั้นซ่อน (Hidden layer) ในโครงข่ายประสาทเทียมอาจมีชั้นซ่อนได้หลายชั้น โครงสร้างพื้นฐานจะมีลักษณะเป็นการประกอบกันของ 2 รูปแบบ คือ (1) แบบป้อนไปข้างหน้า (2) แบบป้อนไปเวียนกลับ

แบบป้อนไปข้างหน้า (Feedforward) อาจจัดได้เป็นสองแบบย่อยคือ แบบมีชั้นของเซลล์ประสาทชั้นเดียว และแบบมีชั้นของเซลล์ประสาทหลายชั้น โดยปกติแล้ว การเชื่อมโยงจะถูกกำหนดขึ้นระหว่างชั้นที่ติดกัน โดยจะมีการเชื่อมโยงระหว่างเซลล์ประสาทเทียมทุกตัว จากชั้นหนึ่งๆ ไปยังเซลล์ประสาทเทียมทุกตัวในชั้นต่อไป ในบางสถาปัตยกรรมอาจมีการเชื่อมโยงข้ามชั้นก็ได้ แสดงตัวอย่างการเชื่อมโยงระหว่างเซลล์ของ Input layer ไปยัง Hidden layer และเชื่อมไปยัง Output layer ในกรณีนี้ Hidden layers อาจประกอบได้มากกว่าหนึ่งชั้น การเชื่อมโยงจะเป็นแบบป้อนไปข้างหน้า สังเกตได้จากลูกศรที่ชี้ไปยังเซลล์ข้างหน้า




ภาพ 2.7 การเชื่อมโยงแบบป้อนไปข้างหน้า

แบบมีการป้อนไปเวียนกลับ (Recurrent) ในสถาปัตยกรรมบางแบบ โครงข่ายประสาทเทียมอาจมีการเชื่อมโยงที่ถูกกำหนดขึ้นระหว่างเซลล์ประสาทเทียมในชั้นหนึ่งๆ ย้อนกลับไปยังชั้นอื่นๆ ก่อนหน้านั้น หรือแม้แต่ภายในชั้นเดียวกันเอง แสดงในไดอะแกรมภาพ 2.8 ซึ่งมีชั้นที่เพิ่มขึ้นมา คือ Context layer เซลล์ในชั้นนี้ได้รับข้อมูลเข้าย้อนมาจากเซลล์ในชั้น Outputs รวมทั้งข้อมูลเข้าจากตัวเองและเซลล์ข้างเคียงในชั้นเดียวกัน แสดงในภาพ 2.9



ภาพ 2.8 ไดอะแกรมโครงข่ายประสาทเทียมแบบมีการป้อนไปเวียนกลับ



ภาพ 2.9 การเชื่อมโยงแบบการป้อนไปเวียนกลับ

พบว่ามีการวิจัยมากมายที่เกี่ยวข้องกับการใช้เทคนิคของเครือข่ายประสาททั้งงานทางด้านการจดจำภาพ จำแนกชนิดวัตถุและงานด้านอื่นๆ ทั้งนี้เนื่องจากการใช้เครือข่ายประสาทนั้นสามารถช่วยลดปัญหาในเรื่องการควบคุมสถานะแวดล้อมเพราะการเรียนรู้ของระบบที่ใช้ตัวอย่างภาพในหลายรูปแบบ นอกจากนี้การใช้เครือข่ายประสาทแม้ว่าจะไม่ทราบกลไกหรือรูปแบบสมการทางคณิตศาสตร์ที่ใช้ในการคำนวณก็สามารถให้ผลลัพธ์ได้ ตัวอย่างงานวิจัย ได้แก่

Frank Storbeck and Berent Daan [Storbeck, 2001] ได้ทำงานวิจัยการจำแนกชนิดปลาที่อยู่บนสายพานโดยใช้เครือข่ายประสาทที่ใช้รูปแบบการเรียนรู้แบบแพร่ย้อนกลับ ซึ่งให้ผลการจำแนกถูกต้องมากกว่า 95%

งานวิจัยของ Jens Langner [Langner, 2007] ได้ใช้เครือข่ายประสาทแบบป้อนไปข้างหน้า โดยใช้การเรียนรู้แบบแพร่ย้อนกลับ ที่มีจำนวนชั้นซ่อน 1 ชั้น ในการจำแนกพันธุ์ของใบไม้ โดยใช้ค่าไซน์และโคไซน์ของมุมระหว่างจุดที่เป็นเส้นขอบของใบไม้ซึ่งเรียกว่า token เป็นค่าอินพุต ซึ่งพบว่าระบบจะสามารถจำแนกพันธุ์ของใบไม้ได้ถ้าใช้มากกว่า 5 ภาพต่อสายพันธุ์ เพื่อให้ระบบเรียนรู้ นอกจากงานวิจัยดังกล่าวแล้วยังมีงานวิจัยที่เกี่ยวข้องกับการจำแนกชนิดพืชอีกโดยใช้เครือข่ายประสาทแบบ Self-Organizing Map (SOM) เพื่อจำแนกประเภทรั้วพืชออกจากหญ้าโดยใช้คุณสมบัติการดูดกลืนแสงเป็นอินพุต [Moshou, 2001]

Zhang, Mengjie [Zhang, 2007] งานวิจัยนี้ได้ใช้เทคนิคเครือข่ายประสาทในการจดจำวัตถุขนาดเล็กโดยมีอินพุตเป็นข้อมูลในแต่ละพิกเซลของภาพ ทั้งนี้เพื่อลดขั้นตอนก่อนการประมวลผลและการแยกคุณลักษณะ จากงานวิจัยนี้พบว่าการใช้เครือข่ายประสาทแบบป้อนไปข้างหน้าหลายชั้น (Multilayer feed-forward) สามารถหาตำแหน่งและจำแนกวัตถุที่มีในภาพได้ในเฉพาะกรณีที่ภาพนั้นไม่มีความซับซ้อนมากนัก เช่น รูปวงกลม รูปสี่เหลี่ยม และเหรียญ แต่ไม่สามารถใช้ได้ในกรณีภาพที่มีความซับซ้อนมาก เช่น แยกชนิดเส้นเลือดในเรตินา ซึ่งให้ค่าความแม่นยำน้อยกว่า 10%


ในงานวิจัยทางด้านการพัฒนาความสามารถในการมองเห็นของหุ่นยนต์ ของ Mitziias, Dimitris A. and Basil G. Mertzios [Mitziias, 2004] ได้ใช้ระบบ Neural Multiclassifier System (NEMUS) ซึ่งเป็นระบบที่ใช้ตัวจำแนก (Classifier) หลายชนิดร่วมกัน โดยมีการทำงานหลัก 2 ขั้นตอน คือ ขั้นแรกจำแนกจากกลุ่มของคุณลักษณะที่แตกต่างกัน 3 กลุ่ม (คุณลักษณะทางเรขาคณิต, โมเมนต์และเทคนิคการประมาณค่ารูปหลายเหลี่ยม) โดยใช้ Back-propagation neural classifiers ในขั้นถัดมาจึงนำผลลัพธ์ที่ได้มาประมวลผลร่วมกันโดยใช้ Decision Making Network (DM-Net) พบว่า การใช้คุณลักษณะเพียงกลุ่มเดียวจะให้ความถูกต้องสูงสุดเพียง

75.6% แต่หากใช้ร่วมกันจะให้ค่าความถูกต้องสูงสุด 98.3 % งานวิจัยนี้นอกจากจะเป็นตัวอย่างของการใช้เครือข่ายประสาทในการจำแนกวัตถุแล้วยังแสดงให้เห็นถึงการใช้คุณลักษณะหลายกลุ่มร่วมกันเพื่อช่วยในการจำแนกวัตถุอีกด้วย

หัวข้อต่อไปจะอธิบายวิธีการทำงานของโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าหลายชั้น

2.3.1. โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าหลายชั้น

โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าหลายชั้น นั้นใช้การเชื่อมโยงแบบป้อนไปข้างหน้าซึ่งได้กล่าวไปแล้ว เพียงแต่เพิ่มจำนวนชั้นใน Hidden layers ซึ่งอาจประกอบ 3 ชั้น คือ Layer1, Layer 2 และ Layer 3 แสดงในภาพ 2.10



ภาพ 2.10 โครงสร้างของโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าหลายชั้น

โมเดลทางคณิตศาสตร์ของโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าหลายชั้น แสดงในภาพ 2.11 นั้น มีเวกเตอร์อินพุต $X = \{x_i\}$ กำหนดให้ $x_i \in \mathcal{R}^p$ และเวกเตอร์ผลลัพธ์ $Y = \{y_i\}$ กำหนดให้ $y_i \in \mathcal{R}^m$ ซึ่งประกอบด้วยสมการการคำนวณภายในเซลล์ประสาทแต่ละชั้นดังนี้

1. Hidden layer

$$h_j = \sigma(u_j)$$

$$u_j = \sum_{i=1}^p w_{ji}^h x_i \quad (2.11)$$

กำหนดให้ h_j คือ ผลลัพธ์ของเซลล์ใน Hidden layer ซึ่ง $1 \leq j \leq L$

$\sigma(\cdot)$ คือ Activation function

w_{ji}^h คือ ค่าน้ำหนักกำกับไว้บนเส้น ji เชื่อมเซลล์ในชั้นซ่อน j กับเซลล์ในชั้นอินพุต i

W^h คือ เวกเตอร์น้ำหนัก $\{w_{ji}^h\}$

2. Output layer

$$y_k = \sigma(v_k)$$


$$v_k = \sum_{j=1}^m w_{kj}^y h_j \tag{2.12}$$

กำหนดให้ y_k คือ ผลลัพธ์ของเซลล์ใน Output layer ซึ่ง $1 \leq k \leq m$

$\sigma(\cdot)$ คือ Activation function


w_{kj}^y คือ ค่าน้ำหนักกำกับไว้บนเส้น kj เชื่อมเซลล์ในชั้นเอาต์พุต k กับเซลล์ในชั้นซ่อน j

W^y คือ เวกเตอร์น้ำหนัก $\{w_{kj}^y\}$



ภาพ 2.11 โมเดลทางคณิตศาสตร์ของการป้อนไปข้างหน้า

จากสมการ 2.11 - 2.12 นั้นสามารถเขียนไดอะแกรมการคำนวณอย่างง่ายของเซลล์ประสาทหนึ่งหน่วย คือ นำผลรวมของข้อมูลเข้าซึ่งคูณกับค่าน้ำหนักนั้น นำผลที่ได้ผ่านลิมีเตอร์ ในที่นี้ใช้ Sigmoid function จนได้ผลลัพธ์นั้น แสดงในภาพ 2.12



ภาพ 2.12 โมเดลทางคณิตศาสตร์ของเซลล์ประสาท

2.3.2. ตัวอย่างคุณลักษณะของปัญหาที่ใช้เป็นข้อมูลเข้า จากตัวอย่างงานวิจัยทางด้านการแพทย์

การประยุกต์ใช้งานโครงข่ายประสาทเทียมนั้นจำเป็นอย่างยิ่งที่จะต้องเตรียมข้อมูลเข้า ดังนั้นการสกัดคุณลักษณะของปัญหาเพื่อให้ได้ข้อมูลเข้านั้นเป็นขั้นตอนที่สำคัญยิ่ง เช่น งานด้านการจดจำรูปแบบเพื่อการจำแนกชนิดวัตถุ เป็นต้น

J. Marotz, C. Lübbert and W. Eisenbei [Marotz, 2001] วิจัยเกี่ยวกับการจดจำวัตถุเพื่อนับจำนวนโคโลนีของแบคทีเรียในงานเพาะเลี้ยง ดังนั้นจึงต้องให้ระบบจดจำลักษณะรูปร่างของโคโลนีก่อน คุณลักษณะของปัญหานี้ประกอบด้วย

- (1) ค่าต่ำสุด สูงสุด และค่าเฉลี่ย ของรัศมี
- (2) ค่า compactness ซึ่งเป็นค่าตัวแปรทางรูปร่าง

Ouychai Intharasombat [Intharasombat, 2003] ได้วิจัยเรื่องการวิเคราะห์ประเภทของเนื้องอก ได้ใช้คุณลักษณะทางรูปร่าง ดังต่อไปนี้

- (1) พื้นที่
- (2) เส้นรอบวง
- (3) ค่า compactness
- (4) ค่ารัศมี
- (5) Fourier Descriptor (FD)

C. Solomon and Dinesh Somasundaram [Solomon, 2007] มีจุดประสงค์การวิจัยเพื่อหาคุณลักษณะที่เหมาะสม ในการจำแนกชนิดเซลล์เม็ดเลือดขาว คุณลักษณะของปัญหานี้ประกอบด้วย

- (1) พื้นที่
- (2) เส้นรอบวง

- (3) ค่า compactness
- (4) ค่า curvature
- (5) ค่าพลังงานการงอตัว
- (6) ค่าโมเมนต์
- (7) ลักษณะทางสี
- (8) ผลลัพธ์จากฟังก์ชันเกเบอร์ (Gabor function)

Soltanian-Zadeh, Hamid, Farshid Rafiee-Rad and Siamak Pourabdollah-Nejad D. [Hamid, 2004] เป็นวิจัยทางการแพทย์เพื่อการตรวจวินิจฉัยมะเร็งเต้านมจากภาพถ่ายแมมโมแกรม โดยคุณลักษณะทางรูปร่างที่นำมาใช้ ได้แก่

- (1) ขนาดของ microcalcification
- (2) ค่า Compactness
- (3) ค่าโมเมนต์

2.4. การเรียนรู้ของโครงข่ายประสาทเทียม

2.4.1. การเรียนรู้แบบแพร่ย้อนกลับ (Back-propagation learning)

การเรียนรู้แบบแพร่ย้อนกลับถูกนำไปประยุกต์ใช้มากที่สุดในการใช้งานโครงข่ายประสาทเทียม โดยลักษณะของการเรียนรู้แล้ว การเรียนรู้แบบแพร่ย้อนกลับไม่จำเป็นต้องใช้เฉพาะโครงข่ายที่มีสถาปัตยกรรมแบบป้อนไปข้างหน้าหลายชั้นเพียงแบบเดียว แต่การจับคู่ดังกล่าวได้รับความนิยมนำไปใช้งานมากที่สุด การเรียนรู้แบบแพร่ย้อนกลับนี้เป็นการเรียนรู้แบบมีผู้สอน (Supervised Learning) ขั้นตอนในการเรียนรู้แบบแพร่ย้อนกลับจะเริ่มด้วยการส่งข้อมูลที่จะใช้สอนเข้าไปในโครงข่ายทางชั้นอินพุต ชั้นอินพุตซึ่งโดยปกติจะไม่มีการประมวลผล จะทำหน้าที่ส่งกระจายข้อมูลนั้นไปยังเซลล์ประสาทเทียมต่างๆ ในชั้นซ่อน จากนั้นเซลล์ประสาทเทียมทุกตัวในชั้นซ่อน จะทำการประมวลผลตามวิธีการของแบบจำลองเซลล์ประสาทเทียม ซึ่งจะคล้ายคลึงกับแบบจำลองของเม็γκัลลอสและพิตส์ แต่มีการสร้างผลตอบด้วยสมการคณิตศาสตร์ที่มีคุณลักษณะเฉพาะบางประการ การประมวลผลเกิดจากชั้นซ่อนชั้นแรกผ่านไปตามชั้นซ่อนชั้นต่างๆจนสร้างผลตอบที่ชั้นเอาต์พุต

ผลตอบที่ออกมาจากชั้นเอาต์พุตจะถูกเปรียบเทียบกับค่าเป้าหมายที่กำหนด เพื่อคำนวณค่าความคลาดเคลื่อน (error) จากนั้นปริมาณการปรับแต่งค่าน้ำหนักของแต่ละขั้วสัญญาณเข้าของแต่ละเซลล์ประสาทเทียมในชั้นเอาต์พุตก็จะถูกคำนวณขึ้น โดยดูจากความคลาดเคลื่อนและค่าของสัญญาณที่วิ่งเข้ามาทางขั้วเข้านั้นๆประกอบกันในขั้นตอนต่อไป จะเป็นการคำนวณปริมาณการปรับค่าน้ำหนักที่ขั้วสัญญาณของแต่ละเซลล์ประสาทเทียมในชั้นซ่อนต่างๆ แต่

เนื่องจากไม่สามารถกำหนดค่าเป้าหมายของผลตอบจากเซลล์ประสาทเทียมในชั้นซ่อนได้ ความคลาดเคลื่อนของเซลล์ประสาทเทียมในชั้นซ่อนจึงถูกมองว่า เป็นการไหลย้อนกลับของความคลาดเคลื่อนออกมาจากเซลล์ประสาทเทียมต่างๆ ของชั้นเอาต์พุตหลังจากรวบรวมค่าความคลาดเคลื่อนที่ไหลย้อนกลับมาแล้ว หลักการคำนวณปริมาณการปรับแต่งค่าน้ำหนักในเซลล์ประสาทเทียมของชั้นซ่อนต่างๆ ก็ใช้หลักการเดียวกับชั้นเอาต์พุตคือ ดูจากผลรวมความคลาดเคลื่อนที่ไหลย้อนกลับมายังเซลล์ประสาทเทียมตัวนั้นๆ ประกอบกับค่าของสัญญาณเข้าที่วิ่งผ่านเข้ามาทางขั้วสัญญาณเข้านั้นด้วย


เมื่อค่าน้ำหนักที่ขั้วสัญญาณเข้าของเซลล์ประสาทเทียมทุกตัวถูกปรับแต่งหมดแล้ว โครงข่ายประสาทเทียมก็พร้อมจะเรียนรู้ข้อมูลตัวอย่างต่อไป ในทางปฏิบัติแล้ว จะต้องใช้ข้อมูลตัวอย่างจำนวนมาก และจะต้องสอนข้อมูลตัวอย่างเหล่านี้ซ้ำๆ กันหลายๆ รอบ จึงจะสามารถสอนโครงข่ายประสาทเทียมชนิดนี้จนเรียนรู้ได้อย่างถูกต้อง อัลกอริทึมการเรียนรู้แบบแพร่ย้อนกลับ แสดงในกรอบ 2.1

กรอบ 2.1 อัลกอริทึมการเรียนรู้แบบแพร่ย้อนกลับ [Haykin, 1999]

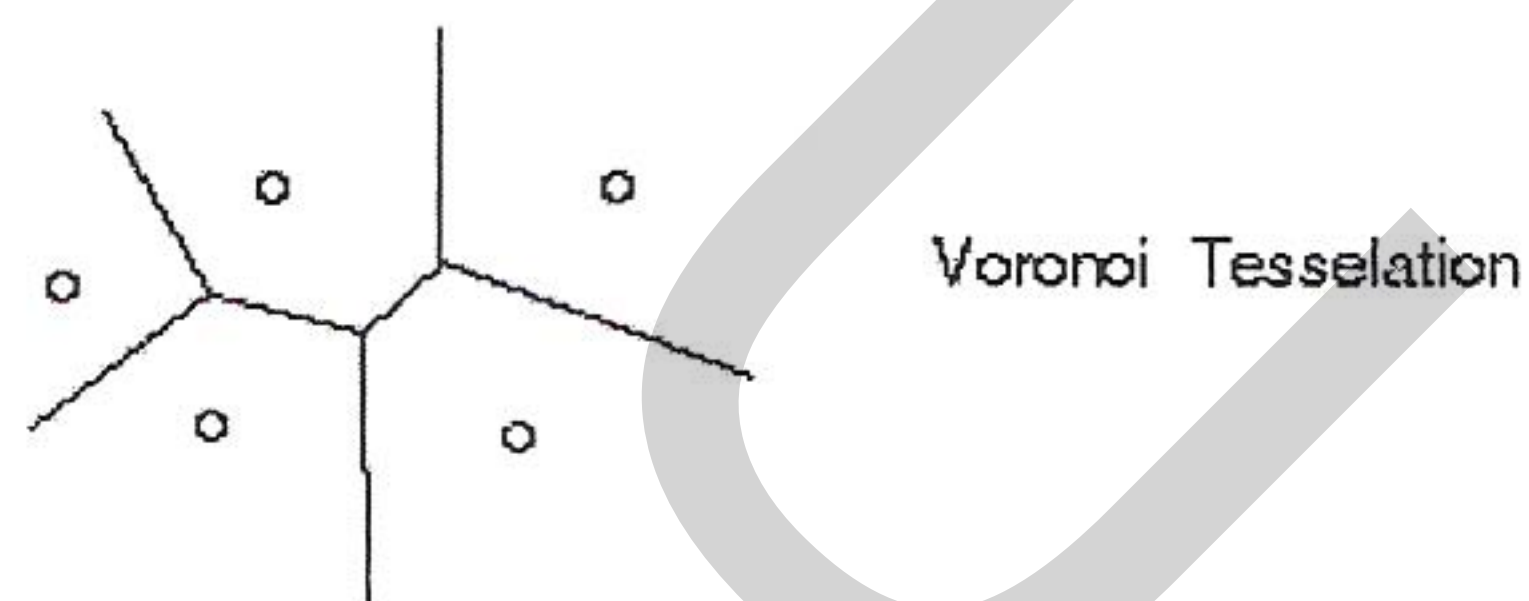
1. Initialize the weights in the network (often randomly)
2. repeat
 - * for each example e in the training set do
 1. $O = \text{neural-net-output}(\text{network}, e)$; forward pass
 2. $T = \text{teacher output for } e$
 3. Calculate error $(T - O)$ at the output units
 4. Compute δ_{wi} for all weights from hidden layer to output layer ; backward pass
 5. Compute δ_{wi} for all weights from input layer to hidden layer ; backward pass
 - continued
 - 6. Update the weights in the network
 - * end
3. until all examples classified correctly or stopping criterion satisfied

2.4.2. การเรียนรู้แบบแวลิวีคิว (Learning Vector Quantization)

การเรียนรู้แบบแวลิวีควินั้นใช้พื้นฐานความรู้ของการจับกลุ่มด้วยตนเอง แบบ Kohonen ซึ่งแต่ละกลุ่มจะมีผู้แทนกลุ่มเรียกว่า โปรโตไทป์ (Prototype) จากภาพ 2.13 โปรโตไทป์แทนด้วยวงกลม ซึ่งส่วนใหญ่ตำแหน่งของโปรโตไทป์จะอยู่ภายในกลุ่มข้อมูลซึ่งแทนด้วยบวก ซึ่งครอบคลุมกลุ่มของข้อมูลของตนถึงเส้นแบ่ง หรือเขตแบ่ง เรียกว่า Voronoi Tessellation แสดงตัวอย่างในภาพ 2.14 อัลกอริทึมการคำนวณหาเวกเตอร์โปรโตไทป์แสดงในกรอบ 2.2



ภาพ 2.13 ตำแหน่งของเวกเตอร์โปรโตไทป์ซึ่งครอบคลุมข้อมูลเข้า



ภาพ 2.14 การครอบคลุมแบบโวโรนอย

กรอบ 2.2 อัลกอริธึมการคำนวณหาเวกเตอร์โปรโตไทป์ [Haykin, 1999]

- Choose the number of clusters M
- Initialize the prototypes w_{*1}, \dots, w_{*m} (one simple method for doing this is to randomly choose M vectors from the input data)
- Repeat until stopping criterion is satisfied:
 - Randomly pick an input x
 - Determine the "winning" node k by finding the prototype vector that satisfies

$$|w_{*k} - x| \leq |w_{*i} - x| \quad (\text{for all } i)$$

note: if the prototypes are normalized, this is equivalent to maximizing $w_{*i} \cdot x$

- Update *only the winning prototype weights* according to

$$w_{*k}(\text{new}) = w_{*k}(\text{old}) + \mu(x - w_{*k}(\text{old}))$$

เทคนิคแอลวีคิว เป็นการเรียนรู้แบบมีผู้สอนนั้น แสดงในภาพ 2.15 นั้นต้องกำหนดเอาต์พุตให้กับข้อมูล x ดังนั้นหลังจากการครอบคลุมแบบไวโรนอยซึ่งมีโปรโตไทป์กำหนดกลุ่ม จึงต้องทำการปรับค่าโปรโตไทป์ให้ถูกต้องกับเอาต์พุต

สมมติให้ x มีเอาต์พุต ξ_x เป็นข้อมูลภายในโปรโตไทป์ w_c มีเอาต์พุต ξ_{w_c} สูตรการปรับค่า w_c เป็นดังนี้

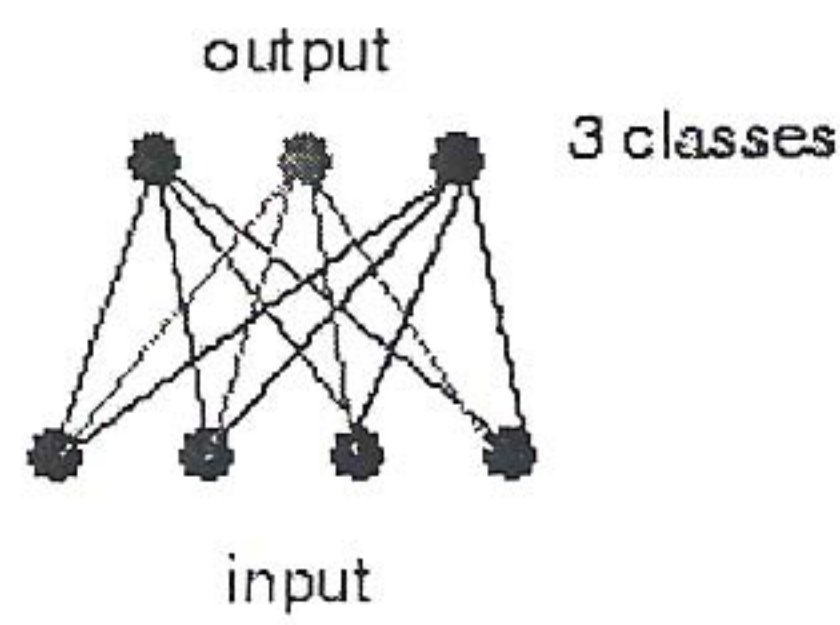
1) กรณี $\xi_x = \xi_{w_c}$

$$w_c(n+1) = w_c(n) + \alpha_n(x_i - w_c(n)) \quad (2.13)$$

2) กรณี $\xi_x \neq \xi_{w_c}$

$$w_c(n+1) = w_c(n) - \alpha_n(x_i - w_c(n)) \quad (2.14)$$

กำหนดให้ α_n เป็นค่าถ่วงน้ำหนักการปรับ



The prototypes are represented by the weight vectors connecting to each output node.

Here there are 3 prototypes:

w_1 = the weights connecting to output 1

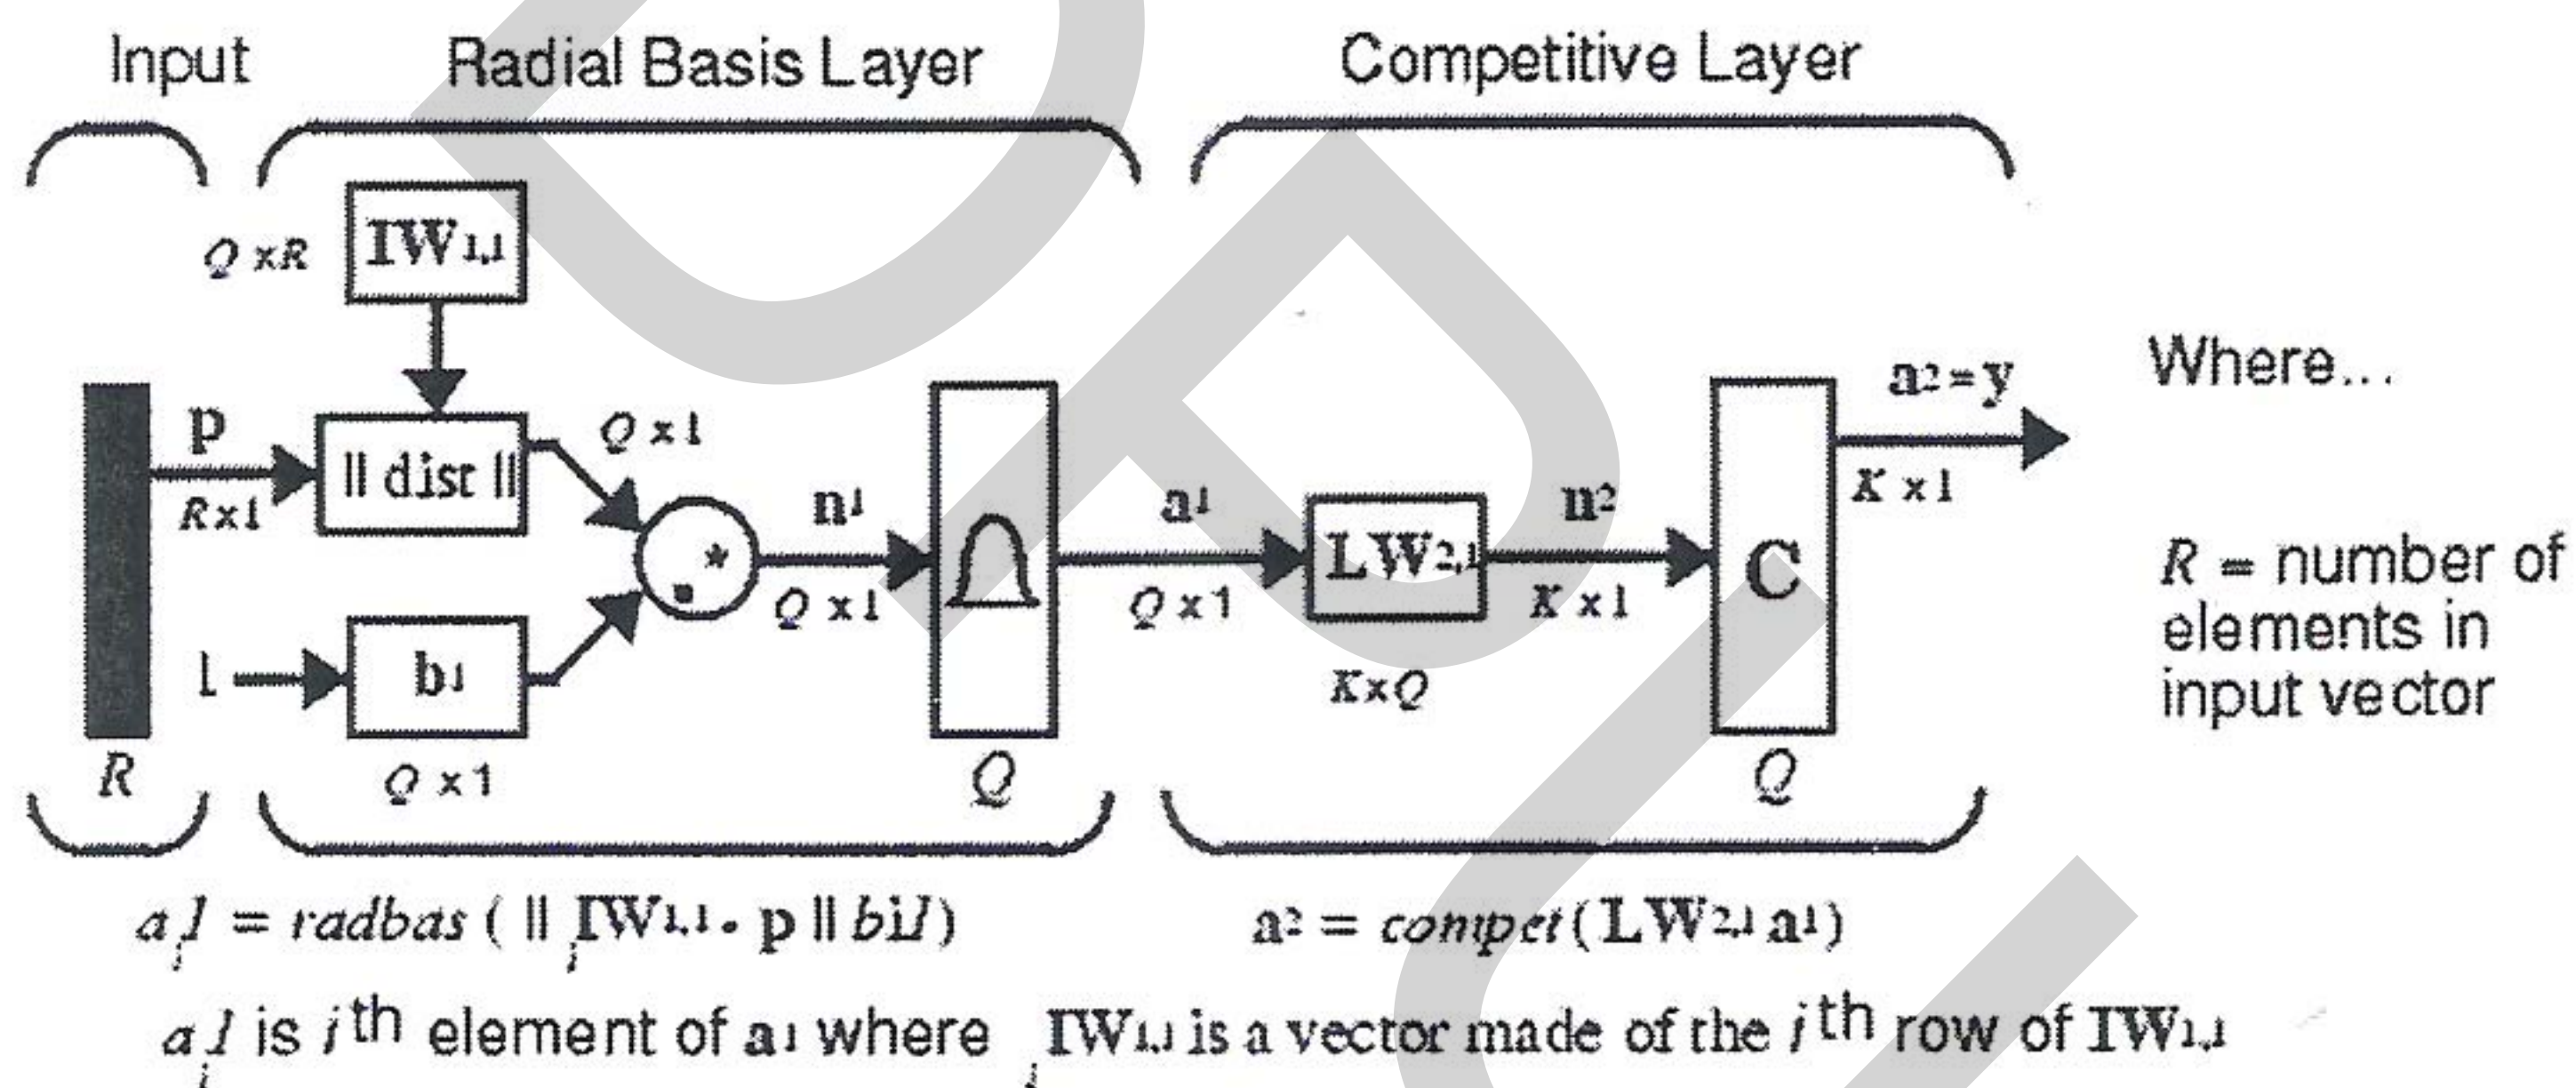
w_2 = the weights connecting to output 2

w_3 = the weights connecting to output 3

ภาพ 2.15 โครงสร้างเครือข่ายแบบแวลวีกิว (การเรียนรู้แบบมีผู้สอน)

2.4.3. การเรียนรู้แบบใช้ความน่าจะเป็น (Probabilistic Learning)

การเรียนรู้แบบใช้ความน่าจะเป็นนั้นอาศัยข้อได้เปรียบของโครงสร้างแบบ Radial Basis Function (RBF) ผสมกับ Competitive Learning เข้าด้วยกัน แสดงในภาพ 2.16



$$a_j = \text{radbas}(\|IW_{1,1} \cdot p - b_j\|)$$

a_j is j th element of a_1 where $IW_{1,1}$ is a vector made of the j th row of $IW_{1,1}$

$$a^2 = \text{compet}(LW_{2,1} a^1)$$

Q = number of input/target pairs = number of neurons in layer 1
 K = number of classes of input data = number of neurons in layer 2

ภาพ 2.16 โมเดลคณิตศาสตร์การเรียนรู้แบบใช้ความน่าจะเป็น [Demuth, 1992]

โครงข่ายประสาทเทียมซึ่งรองรับการเรียนรู้แบบใช้ความน่าจะเป็นนั้น ประกอบด้วยสามส่วนหลักคือ

- 1) Input: ชั้นข้อมูลนำเข้า เพื่อเตรียมข้อมูลเข้าเป็นคอลัมน์เวกเตอร์ P ขนาด $R \times 1$ ซึ่งกำหนดให้ R แทน จำนวนสมาชิกของข้อมูลนำเข้า (ขนาดมิติ)

- 2) Radial Basis Layer: ชั้นเรเดียลเบซีส ซึ่งประกอบด้วยเซลล์ประสาทหนึ่งหน่วย โดยใช้สูตรคำนวณภายในเซลล์ดังนี้

$$a_i^1 = \text{radbas}(|\mathbf{IW}_i^{1,1} \cdot \mathbf{P} | b_i^1) \quad (2.15)$$

โดยกำหนด a_i^1 แทน สมาชิกของ a^1

$\mathbf{IW}_i^{1,1}$ แทน เวกเตอร์ซึ่งได้จาก แถวที่ i ของเมตริกซ์ $\mathbf{IW}^{1,1}$

b_i^1 แทน คอลัมน์เวกเตอร์ซึ่งมีขนาดเท่ากับจำนวนคู่ของข้อมูลนำเข้าและผลลัพธ์ที่

กำหนด

- 3) Competitive Layer: ชั้นแข่งขัน โดยอาศัยหลักการของการเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) ซึ่งใช้สูตรในการคำนวณดังนี้

$$a^2 = \text{compet}(\mathbf{LW}^{2,1} a^1) \quad (2.16)$$

โดยกำหนด a_i^2 แทน สมาชิกของ a^1

$\mathbf{IW}_i^{2,1}$ แทน เวกเตอร์ซึ่งได้จาก แถวที่ i ของเมตริกซ์ $\mathbf{IW}^{2,1}$

บทที่ 3

ขั้นตอนวิธีในการดำเนินงานวิจัย

3.1. ขั้นตอนวิธีในการดำเนินงานวิจัย

ขั้นตอนวิธีในการดำเนินงานวิจัย ประกอบด้วย 5 ส่วนหลัก ดังนี้

- 1) รวบรวมข้อมูลของสถาบันการเงินที่จดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทยทั้งหมด 41 แห่ง ซึ่งประกอบด้วยตัวแปรทางการเงิน และตัวแปรของผู้ถือหุ้น ทั้งหมด 37 ตัวแปร แสดงในตาราง 1.1 – 1.2 ซึ่งข้อมูลนี้เก็บระหว่างปี พ.ศ. 2536 – 2546
- 2) จัดชุดข้อมูลที่ใช้ในการทำการทดลอง ซึ่งใช้ข้อมูลดิบปี พ.ศ. 2536 – 2539 (ค.ศ. 1993 – 1996) คำนวณความเสี่ยงการล้มละลายล่วงหน้าภายในระยะเวลา 1-5 ปี แสดงในตารางที่ 3.1 -3.4 ซึ่งในแต่ละชุดข้อมูลแบ่งประเภทของสถาบันการเงินฯ เป็น”ปิดกิจการ” และ”ดำเนินกิจการต่อ”

กำหนดความหมายของกลุ่มข้อมูลดังนี้

- “t-1” หมายถึง การพยากรณ์หนึ่งปีล่วงหน้า
- “t-2” หมายถึง การพยากรณ์ล่วงหน้า 1-2 ปี
- “t-3” หมายถึง การพยากรณ์ล่วงหน้า 1-3 ปี
- “t-4” หมายถึง การพยากรณ์ล่วงหน้า 1-4 ปี
- “t-5” หมายถึง การพยากรณ์ล่วงหน้า 1-5 ปี

ตาราง 3.1 ชุดข้อมูลของสถาบันการเงินที่จดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทย ซึ่งใช้ข้อมูลดิบในปี พ.ศ. 2536 เพื่อทำนายการล้มละลายในช่วงปี พ.ศ. 2537-2541

ชื่อกลุ่มข้อมูล	การล้มละลาย ในช่วงปี (พ.ศ.)	สถานภาพของบริษัท	
		จำนวนบริษัทที่ ปิดกิจการ	จำนวนบริษัทที่ ดำเนินกิจการต่อ
t-1	2537	0	34
t-2	2537 – 2538	0	34
t-3	2537 – 2539	0	34
t-4	2537 – 2540	19	15
t-5	2537 – 2541	24	10

ตาราง 3.2 ชุดข้อมูลของสถาบันการเงินที่จดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทย
ซึ่งใช้ข้อมูลดิบในปี พ.ศ. 2537 เพื่อทำนายการล้มละลายในช่วงปี พ.ศ. 2538-2542

ชื่อกลุ่มข้อมูล	การล้มละลาย ในช่วงปี (พ.ศ.)	สถานภาพของบริษัท	
		จำนวนบริษัทที่ ปิดกิจการ	จำนวนบริษัทที่ ดำเนินกิจการต่อ
t-1	2538	0	35
t-2	2538 – 2539	0	35
t-3	2538 – 2540	20	15
t-4	2538 – 2541	25	10
t-5	2538 – 2542	25	10

ตาราง 3.3 ชุดข้อมูลของสถาบันการเงินที่จดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทย
ซึ่งใช้ข้อมูลดิบในปี พ.ศ. 2538 เพื่อทำนายการล้มละลายในช่วงปี พ.ศ. 2539-2543

ชื่อกลุ่มข้อมูล	การล้มละลาย ในช่วงปี (พ.ศ.)	สถานภาพของบริษัท	
		จำนวนบริษัทที่ ปิดกิจการ	จำนวนบริษัทที่ ดำเนินกิจการต่อ
t-1	2539	0	37
t-2	2539 – 2540	21	16
t-3	2539 – 2541	26	11
t-4	2539 – 2542	27	10
t-5	2539 – 2543	27	10

ตาราง 3.4 ชุดข้อมูลของสถาบันการเงินที่จดทะเบียนในตลาดหลักทรัพย์แห่งประเทศไทย
ซึ่งใช้ข้อมูลดิบในปี พ.ศ. 2539 เพื่อทำนายการล้มละลายในช่วงปี พ.ศ. 2540-2544

ชื่อกลุ่มข้อมูล	การล้มละลาย ในช่วงปี (พ.ศ.)	สถานภาพของบริษัท	
		จำนวนบริษัทที่ ปิดกิจการ	จำนวนบริษัทที่ ดำเนินกิจการต่อ
t-1	2540	24	17
t-2	2540 – 2541	30	11
t-3	2540 – 2542	31	10
t-4	2540 – 2543	31	10
t-5	2540 – 2544	32	9

- 3) วิเคราะห์ตัวแปรทางการเงิน 30 ตัวแปร และตัวแปรของผู้ถือหุ้น 7 ตัวแปร โดยใช้เทคนิคพีซีเอ ซึ่งได้อธิบายในบทที่ 2
- 4) สร้างแบบจำลองการพยากรณ์ความล้มเหลวของสถาบันการเงิน โดยใช้โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าหลายชั้น ซึ่งใช้การเรียนรู้ 3 แบบที่กล่าวในบทที่ 2 คือ
 - การเรียนรู้แบบแพร่ย้อนกลับ (Back Propagation)
 - การเรียนรู้แบบใช้ความน่าจะเป็น (Probabilistic Learning)
 - การเรียนรู้แบบแวลวีกิว (Learning Vector Quantization)
- 5) เปรียบเทียบผลลัพธ์ที่ได้จากการใช้เทคนิคในข้อ 3) สำหรับค่า Type I Error และ Type II Error ทางสถิติ (อ่านคำนิยามในบทที่ 1)

3.2. การใช้เทคนิคพีซีเอเพื่อวิเคราะห์ข้อมูล

การวิเคราะห์ข้อมูลของสถาบันการเงินที่ได้รวบรวม ระหว่างปี พ.ศ. 2536-2546 นั้น ประกอบด้วยตัวแปรทางการเงิน และตัวแปรของผู้ถือหุ้น ทั้งหมด 37 ตัวแปร เพื่อหาองค์ประกอบหลักเป็นส่วนสำคัญก่อนการสร้างแบบจำลองการพยากรณ์ เนื่องจากการลดจำนวนมิติของข้อมูลโดยใช้เทคนิคพีซีเอเป็นที่นิยมในการวิจัยทางสถิติ และวิทยาศาสตร์ เพื่อให้ได้มาซึ่งแบบจำลองซึ่งไม่ซับซ้อน และความถูกต้องของการพยากรณ์ที่สูงขึ้น

จากทฤษฎีเทคนิคพีซีเอ ซึ่งกล่าวในบทที่ 2 นั้น การใช้เทคนิคพีซีเอเริ่มจากนำข้อมูลของแต่ละสถาบันการเงิน และแต่ละปี มาสร้างเป็นเมตริกซ์ได้ขนาด 105×37 ซึ่งแนวตั้งแทนตัวแปร แนวนอนแทนสถาบันการเงินแต่ละปี แสดงในตาราง 3.5 หลังจากนั้นคำนวณหา Covariance matrix แสดงในตาราง 3.6

การคำนวณค่าไอเกนและเวกเตอร์ไอเกนซึ่งเทคนิคพีซีเอนั้นวิเคราะห์องค์ประกอบหลักโดยเรียงลำดับค่าไอเกนจากมากไปน้อย แสดงในตาราง 3.7 และคำนวณหา Component matrix ซึ่งแสดงค่า Correlation ระหว่างตัวแปรเดิม 37 ตัวแปร กับองค์ประกอบหลัก 4 ตัวแปร ซึ่งมีค่าไอเกนสูงสุด 4 ลำดับแรก แสดงในตาราง 3.8

ตาราง 3.5 เมตริกซ์ข้อมูลของสถาบันการเงินแต่ละปี ขนาด 105 x 37

ข้อมูลของสถาบันการเงินแต่ละปี	ตัวแปร				
	INV	LOAN	..	LARGE	CRIGHTS
ACL 2003	9,270.74	10,246.41		1	4.6900
ACL 2002	9,875.84	12,377.07		1	5.3000
ACL 2001	10,504.90	15,333.36		1	6.3200
ACL 2000	8,478.64	19,426.39		1	7.4300
ACL 1999	12,753.83	21,399.46		1	7.4300
ACL 1998	3,074.22	33,714.17		4	28.3100
ACL 1997	4,123.24	42,496.37		1	29.8900
ACL 1996	5,810.38	53,147.93		1	28.9800
ACL 1995	5,880.26	52,560.01		1	31.1100
ACL 1994	5,066.40	46,263.51		1	31.7000
ACL 1993	3,459.12	41,075.63		1	30.3000
AIFT 2001	709.88	6,211.06		4	93.0400
AIFT 2000	338.79	4,729.88		4	89.2900
AIFT 1999	486.03	5,028.45		4	80.0000
AIFT 1998	570.42	5,586.74		4	75.2900
AIFT 1997	554.59	7,302.63		4	14.1400
AIFT 1996	725.31	8,760.78		4	14.1400
AIFT 1995	779.99	7,901.76		4	14.1400
AIFT 1994	773.20	7,011.34		4	14.1400
...					...
WALL 1993	1,929.81	14,482.55		1	20.2800

คำอธิบายท้ายตาราง 3.6:

คอลัมน์แรก แสดง ชื่อของสถาบันการเงินซึ่งใช้ตัวย่อ และปี ค.ศ. ของปีซึ่งแสดงข้อมูลทางการเงิน ตั้งแต่คอลัมน์สองเป็นต้นไป แสดงค่าต่างๆ ของแต่ละตัวแปรทางการเงิน และตัวแปรผู้ถือหุ้น แสดงในตาราง

1.1

ตัวอย่างเช่น บริษัท ACL มีข้อมูลในปี 2003 ดังนี้ ค่า INV เป็น 9,270.74, ค่า LOAN เป็น 10,246.41, ..., ค่า LARGE เป็น 1 และ ค่า CRIGHTS เป็น 4,6900

ตาราง 3.6 Covariance matrix ขนาด 37 x 37

	INV	LOAN	...	OWN
INV	1.7288e+009	7.1965e+009		12051
LOAN	7.1965e+009	3.7936e+010		26828
...				...
OWN	12051	26828		2.0479

ตาราง 3.7 องค์ประกอบหลักของข้อมูลสถาบันการเงิน 37 ตัวแปร โดยใช้เทคนิคพีซีเอ

องค์ประกอบ (Component)	ค่าไอเกน Eigenvalues	ร้อยละความแปรปรวน (Percent of Variance)	ร้อยละของ ความแปรปรวนสะสม (Percent of Cumulative)
1	2.3524	65.2608	65.2608
2	0.5302	14.7086	79.9694
3	0.2713	7.5252	87.4946
4	0.1303	3.6146	91.1092
5	0.0954	2.6477	93.7569
6	0.0577	1.6005	95.3574
7	0.0388	1.0770	96.4344
8	0.0303	0.8394	97.2738
9	0.0217	0.6031	97.8769
10	0.0169	0.4696	98.3465
11	0.0158	0.4374	98.7839
12	0.0092	0.2550	99.0389
13	0.0067	0.1860	99.2249
14	0.0050	0.1381	99.363
15	0.0039	0.1096	99.4726
16	0.0037	0.1021	99.5747
17	0.0030	0.0822	99.6569
18	0.0024	0.0655	99.7224

ตาราง 3.7 (ต่อ) องค์ประกอบหลักของข้อมูลสถาบันการเงิน 37 ตัวแปร โดยใช้เทคนิคพีซีเอ

องค์ประกอบ (Component)	ค่าไอเกน Eigenvalues	ร้อยละความแปรปรวน (Percent of Variance)	ร้อยละของ ความแปรปรวนสะสม (Percent of Cumulative)
19	0.0019	0.0531	99.7755
20	0.0015	0.0417	99.8172
21	0.0013	0.0361	99.8533
22	0.0010	0.0277	99.881
23	0.0009	0.0248	99.9058
24	0.0008	0.0222	99.928
25	0.0006	0.0174	99.9454
26	0.0005	0.0146	99.96
27	0.0004	0.0105	99.9705
28	0.0003	0.0084	99.9789
29	0.0002	0.0063	99.9852
30	0.0002	0.0048	99.99
31	0.0001	0.0036	99.9936
32	0.0001	0.0023	99.9959
33	0.0001	0.0015	99.9974
34	0.0000	0.0010	99.9984
35	0.0000	0.0008	99.9992
36	0.0000	0.0005	99.9997
37	0.0000	0.0003	100

ตาราง 3.8 Component matrix

ตัวแปร	องค์ประกอบ (ลำดับที่)			
	Component number			
	1	2	3	4
1.INV	.927	.103	-.106	-.126
2.LOAN	.994	-.025	.021	.064
3.TA	.999	.004	-.008	.015
4.AVGTA	.992	-.086	-.051	-.068
5.DEP	.957	.118	.258	-.033
6.LIA	.848	-.242	-.404	.153
7.PAIDUP_PREI	.998	-.020	.017	.017
8.RE	-.093	.012	.060	-.015
9.EQUITY	.285	-.062	-.246	-.738
10.INT_INC	.541	.191	-.085	.692
11.INT_LOAN	.895	.165	-.171	.000
12.INC_AFBD	.981	-.108	.002	-.060
13.TAX	.948	-.164	-.037	-.019
14.EPS	.959	-.157	.019	-.096
15.SIZE	.933	.051	-.051	.054
16.GROWTH_L	.154	-.412	-.164	-.751
17.GROWTH_A	.414	.388	.106	.680
18.LOAN_TA	.658	.477	-.085	.127
19.EQUITY_TA	.947	.011	.036	-.083
20.CHOFF_TL	.307	.520	.045	.662
21.INTINC_TINC	.765	.381	-.137	.179
22.OEXP_TA	.224	.510	.069	.694
23.OEXP_REV	.212	.522	.093	.680
24.DEP_TA	.108	.245	-.059	.443
25.DEP_LOAN	.909	-.085	.041	.194

ตาราง 3.8 (ต่อ) Component matrix

ตัวแปร	องค์ประกอบ (ลำดับที่)			
	Component number			
	1	2	3	4
26.ROA	-.058	.326	.250	.504
27.ROAATA	-.030	.387	.248	.485
28.EBT/TA	.075	-.099	.260	.589
29.EBT/ATA	-.091	.233	-.276	-.273
30.MV	-.053	-.125	-.156	-.561
31.TOBINQ	.121	-.364	.122	.159
32.ORIGHTS	-.239	-.018	-.070	-.475
33.O/C	-.289	.041	-.050	-.378
34.CUT5_10	-.094	.270	.743	.179
35.CUTOFF10	-.073	.337	.656	.127
36. LARGE	.092	.215	.171	.664
37. CRIGHTS	.100	.342	.134	.592

3.3. แบบจำลองการพยากรณ์ความล้มเหลวของสถาบันการเงิน

3.3.1. โครงสร้างของโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าหลายชั้น


งานวิจัยนี้ใช้โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าหลายชั้น ประกอบด้วย ชั้นอินพุต ชั้นซ่อน และชั้นเอาต์พุต จำนวนเซลล์ประสาทในชั้นกำหนดดังนี้

- 1) ชั้นอินพุต มีจำนวนเซลล์ประสาทเท่ากับจำนวนองค์ประกอบที่คำนวณได้จากเทคนิคพีซีเอ ซึ่งในที่นี้จะคัดเลือกเฉพาะองค์ประกอบซึ่งมีค่า Eigenvalue มากกว่า 0.1
- 2) ชั้นเอาต์พุต มีจำนวนเซลล์ประสาทสัมพันธ์กับผลลัพธ์ที่เป็นไปได้ นั่นคือ “ปิดกิจการ” หรือ “ดำเนินกิจการต่อ” หมายถึงมี 2 เซลล์ในชั้นเอาต์พุต
- 3) ชั้นซ่อน มีจำนวนเซลล์ประสาทระหว่าง 4-10 เซลล์ เนื่องจากจำนวนเซลล์ประสาทในชั้นซ่อนจะมีผลต่อ Overfitting หรือ Underfitting ระหว่างการ

ประมวลผล จำนวนเซลล์ที่เหมาะสมไม่เกิน ผลรวมของจำนวนเซลล์ในชั้นอินพุต และเอาต์พุต

นอกจากนี้ Activation function ที่ใช้คือ Sigmoid function แสดงในสมการ 3.1 และกราฟแสดงในภาพ 3.1

$$\varphi(x) = \frac{1}{1+e^{-x}} \quad (3.1)$$



ภาพ 3.1 Sigmoid function

3.3.2. ชุดข้อมูลเรียนรู้ และชุดข้อมูลทดสอบ

การสร้างแบบจำลองโดยใช้โครงข่ายประสาทเทียมแบบมีผู้สอนนั้น จำเป็นต้องเตรียมข้อมูลสำหรับชุดเรียนรู้ และชุดทดสอบ แยกจากกัน ซึ่งมีเงื่อนไขการจัดการดังนี้

- 1) อัตราส่วนของชุดเรียนรู้ต่อชุดทดสอบนั้นเป็น 70:30
- 2) อัตราส่วนของสถาบันการเงินใน “กลุ่มดำเนินการต่อ” ต่อ “กลุ่มปิดกิจการ” เป็น 80:20

งานวิจัยนี้สร้างชุดเรียนรู้และชุดทดสอบจำนวนทั้งหมด 10 ชุด แบบสุ่ม ในกรณีที่ข้อมูลขาดหายไป ผู้วิจัยได้ใช้การหาค่าเฉลี่ยของตัวแปรนั้นและใช้ค่านั้นสำหรับ “missing value” อย่างไรก็ตาม เงื่อนไขที่กล่าวมาข้างต้นอาจมีข้อยกเว้น เนื่องจากข้อมูลที่รวบรวมมานั้นมีจำนวนไม่มากพอ โดยเฉพาะอย่างยิ่งอัตราส่วนของสถาบันการเงินที่ปิดกิจการ กับ ที่ดำเนินการ ต่อเนื่อง จากตาราง 3.1 – 3.4 แสดงตัวอย่าง

- 1) ข้อมูลคิปี พ.ศ. 2536 เฉพาะชุด t-4 และ t-5 นำมาใช้พยากรณ์
- 2) ข้อมูลคิปี พ.ศ. 2537 เฉพาะชุด t-3, t-4 และ t-5 นำมาใช้พยากรณ์
- 3) ข้อมูลคิปี พ.ศ. 2538 เฉพาะชุด t-2, t-3, t-4 และ t-5 นำมาใช้พยากรณ์
- 4) ข้อมูลคิปี พ.ศ. 2539 ทุกชุด t-1, t-2, t-3, t-4 และ t-5 นำมาใช้พยากรณ์

3.3.3. ลักษณะของข้อมูลเข้า

ข้อมูลสถาบันการเงินที่รวบรวมตั้งแต่ปี พ.ศ. 2536 – 2546 มีจำนวนตัวแปรทางการเงิน 31 ตัวแปร และตัวแปรของผู้ถือหุ้น 6 ตัวแปร รวม 37 ตัวแปรนั้น เมื่อใช้เทคนิคพีซีเอเพื่อกำหนดหาองค์ประกอบหลักในช่วงต่อไปนี้

- 1) จำนวนองค์ประกอบหลักน้อยกว่า 5
- 2) จำนวนองค์ประกอบหลักระหว่าง 5 ถึง 9
- 3) จำนวนองค์ประกอบหลักระหว่าง 10 ถึง 19
- 4) จำนวนองค์ประกอบหลักระหว่าง 20 ถึง 37

3.3.4. กำหนดค่าพารามิเตอร์ของการเรียนรู้แบบแพร่ย้อนกลับ

Matlab 7.0 เป็นเครื่องมือที่ใช้ในการสร้างแบบจำลองการพยากรณ์ โดยใช้โครงข่ายประสาทเทียมซึ่งกล่าวในข้อ 3.1 คำสั่งสร้างโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับคือ “newlm” โดยกำหนดค่าพารามิเตอร์ในการเรียนรู้แบบแพร่ย้อนกลับดังนี้

```
net.trainingParam.epochs = 1000
```

```
net.trainingParam.goal = 0.00005
```

3.3.5. กำหนดค่าตัวแปรของการเรียนรู้แบบใช้ความน่าจะเป็น

Matlab 7.0 เป็นเครื่องมือที่ใช้ในการสร้างแบบจำลองการพยากรณ์โดยใช้โครงข่ายประสาทเทียมแบบความน่าจะเป็น ซึ่งใช้คำสั่งว่า “newpnn” และกำหนดช่วงความน่าจะเป็นระหว่าง 0.25 ถึง 0.75

3.3.6. กำหนดค่าตัวแปรของการเรียนรู้แบบแอลวีคิว

Matlab 7.0 เป็นเครื่องมือที่ใช้ในการสร้างแบบจำลองการพยากรณ์โดยใช้โครงข่ายประสาทเทียมแบบแอลวีคิว ซึ่งใช้คำสั่งว่า “newlvq” และกำหนดค่าพารามิเตอร์ในการเรียนรู้แบบแอลวีคิวดังนี้

```
net.trainingParam.epochs = 2,000
```

```
net.trainingParam.goal = 0.0005
```



บทที่ 4

ผลการทดลอง

4.1. ผลการวิเคราะห์ปัจจัยหลักของการปิดกิจการของสถาบันการเงิน

องค์ประกอบหลักซึ่งได้จากการใช้เทคนิคพีซีเอ ในบทที่ 3 นั้น สามารถนำมาเขียนกราฟแสดงความสัมพันธ์ระหว่างค่าไอเกน กับองค์ประกอบหลักตามลำดับค่าไอเกนจากมากไปน้อย ซึ่งมีจำนวนองค์ประกอบทั้งหมด 37 ตัวแปร แต่มีเพียง 2 องค์ประกอบหลักเท่านั้น ที่มีค่ามากกว่า 0.5

แสดงชัดเจนว่า ข้อมูลของสถาบันการเงินทั้ง 41 สถาบัน ระหว่างปี พ.ศ. 2536 – 2546 ซึ่งเดิมประกอบด้วย 37 ตัวแปร (37 มิติ) สามารถใช้เทคนิคพีซีเอลดจำนวนมิติของข้อมูล ไม่เกิน 15 มิติ สังเกตจากภาพ 4.1 ซึ่งค่าไอเกนขององค์ประกอบหลักลำดับหลังจาก 15 ไปนั้น เกือบเป็นศูนย์ ซึ่งไม่มีผลกระทบต่อการนำองค์ประกอบที่เหลือ ไปใช้ในแบบจำลองพยากรณ์

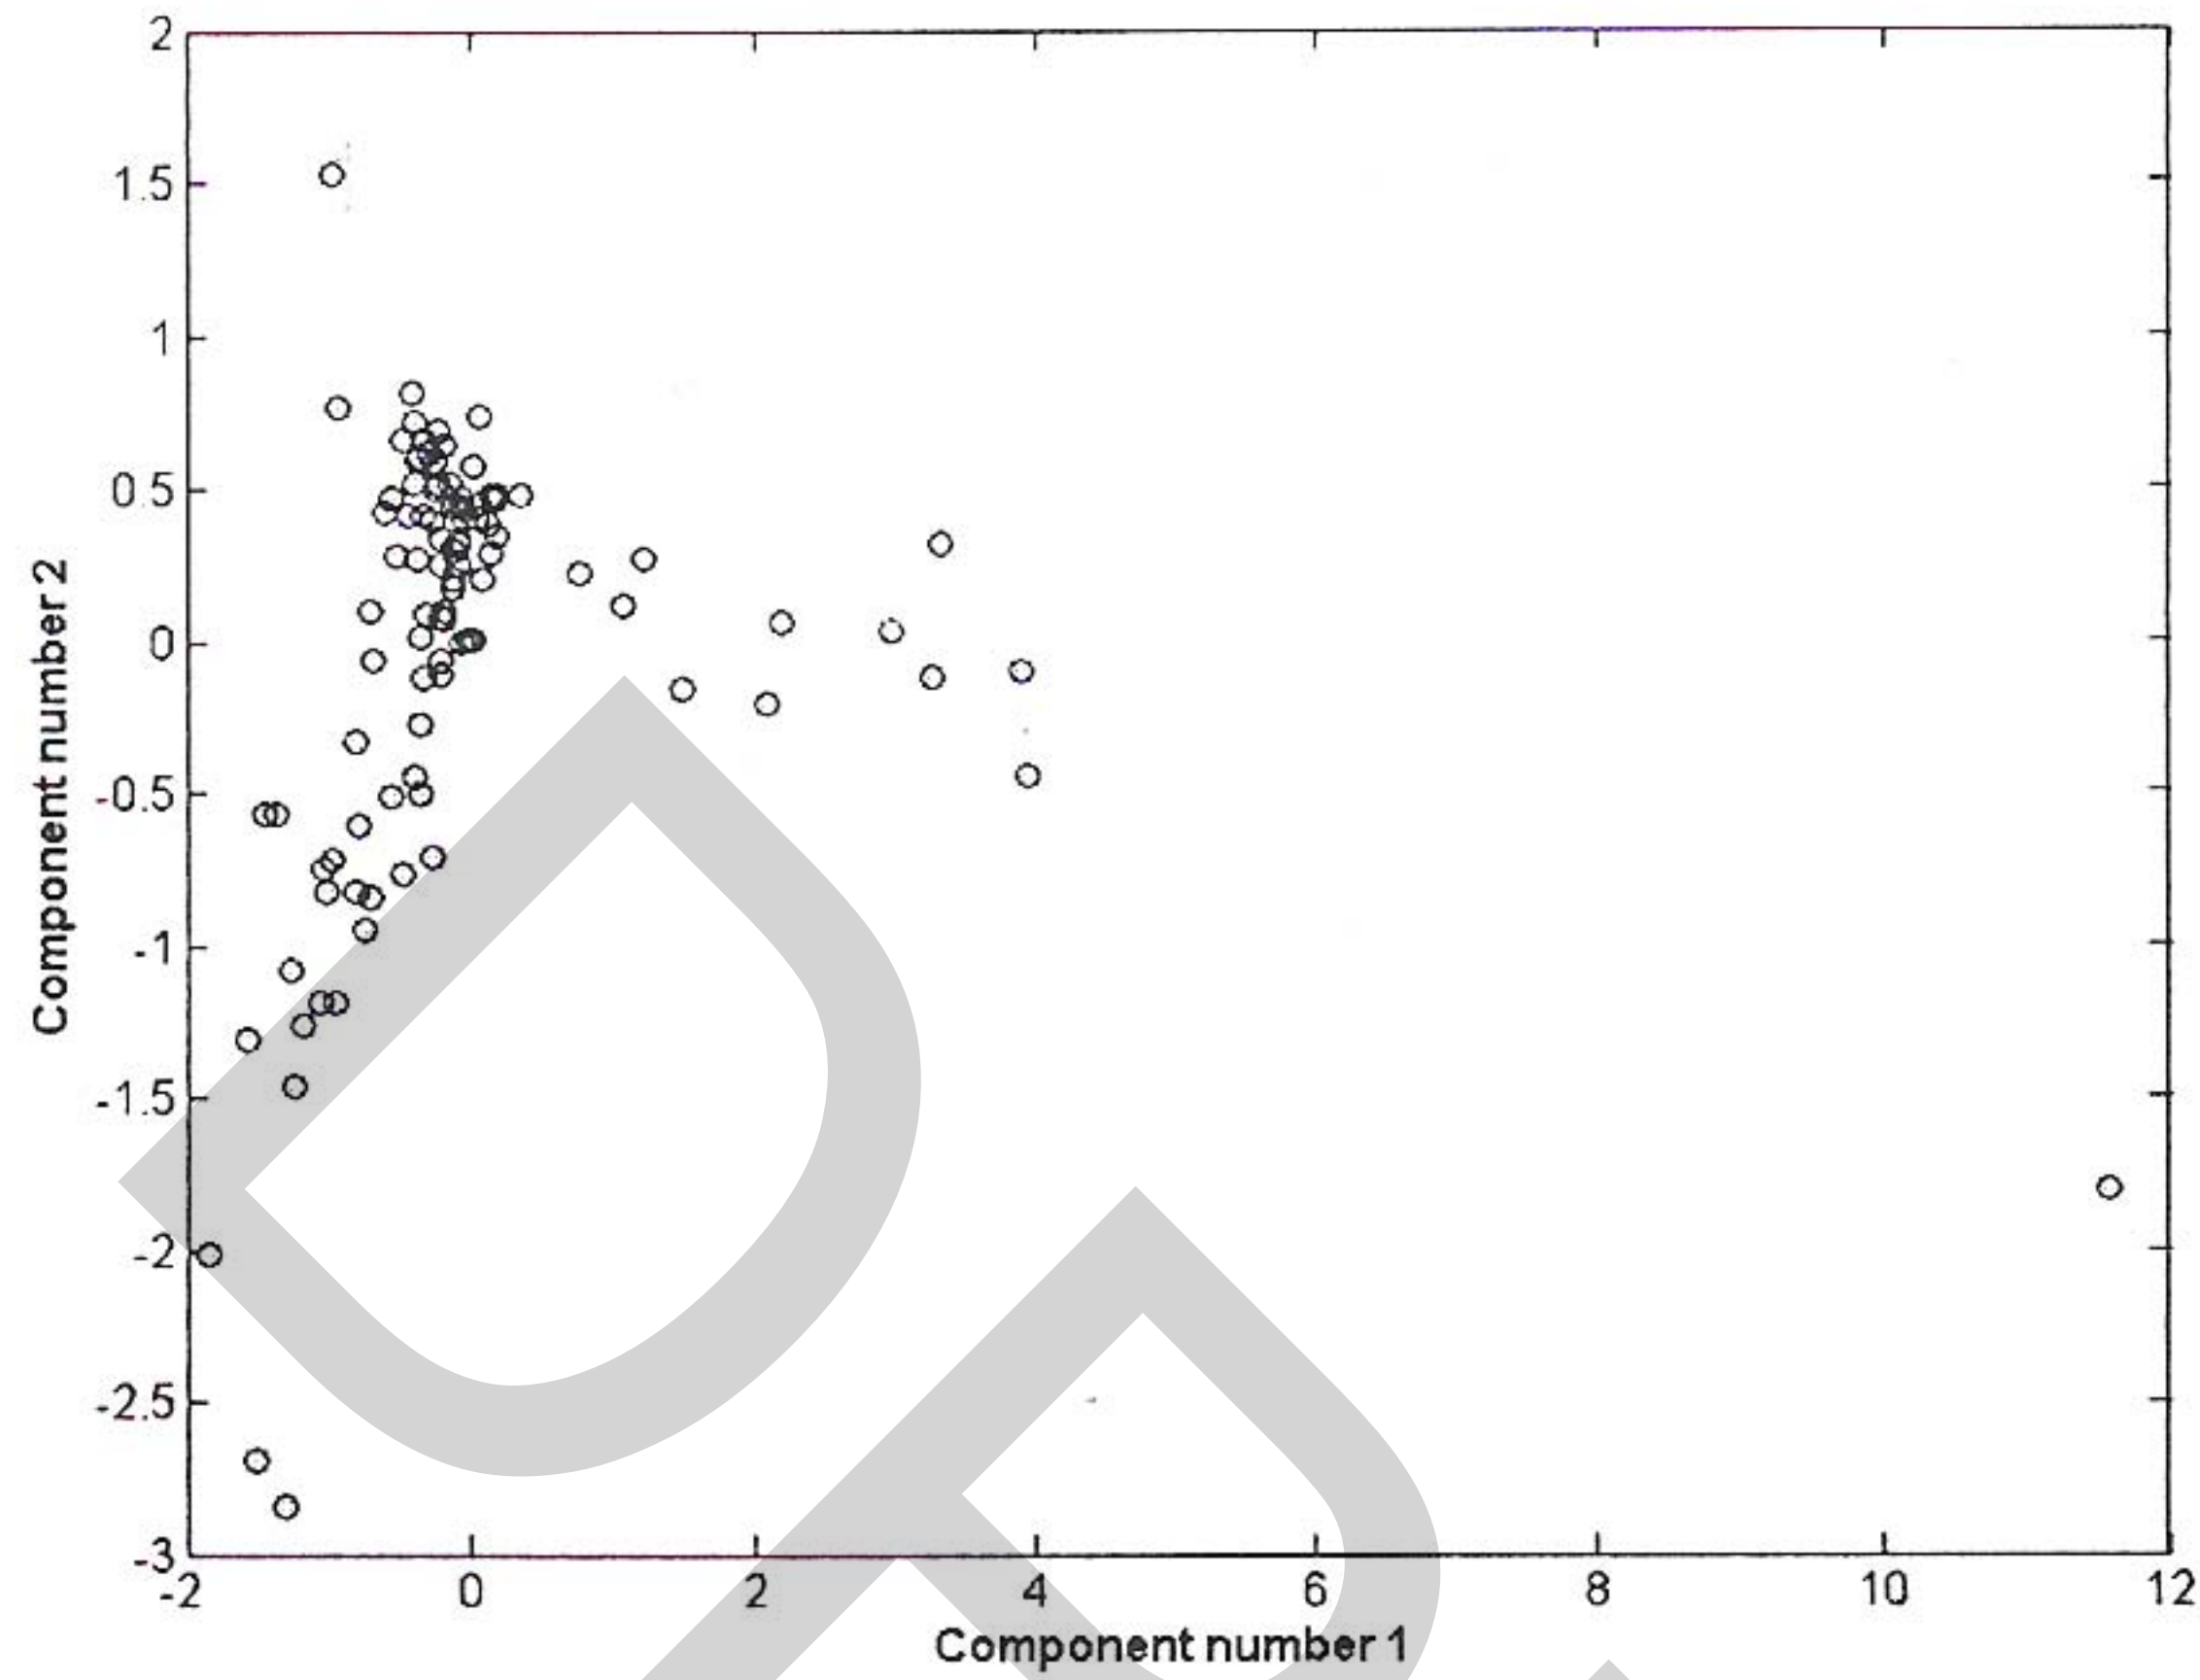


ภาพ 4.1 กราฟความสัมพันธ์ระหว่างองค์ประกอบกับค่าไอเกน


(Component Number, Eigenvalue)

ภาพ 4.2 แสดงการกระจายข้อมูลในระนาบใหม่ซึ่งประกอบด้วยแกนองค์ประกอบหลัก 1 (แกน X) และแกนองค์ประกอบหลัก 2 (แกน Y) ขณะที่ ภาพ 4.3 แสดงการกระจายข้อมูลในปริภูมิใหม่ 3 มิติ ซึ่งเพิ่มแกนองค์ประกอบหลัก 3 (แกน Z)

จุดข้อมูลในภาพ 4.2 – 4.3 นั้นมีทั้งหมด 105 จุด นั้นแทนข้อมูลของสถาบันการเงินแต่ละปี จากตาราง 3.7 ซึ่งข้อมูลดิบในตารางนี้แปลงมาเป็นข้อมูลในมิติใหม่ 2 มิติ และ 3 มิติ ซึ่งสามารถนำมาเขียนกราฟได้ และลดความซับซ้อนของแบบจำลองซึ่งได้จากองค์ประกอบหลักเหล่านี้



ภาพ 4.2 ผลการแปลงข้อมูลบนระนาบใหม่ ซึ่งประกอบด้วย องค์ประกอบที่ 1-2
(Component number 1, Component number 2)



ภาพ 4.3 ผลการแปลงข้อมูลในปริภูมิใหม่ ซึ่งประกอบด้วย องค์ประกอบที่ 1-3
(Component number 1, Component number 2, Component number 3)

4.2. ผลการพยากรณ์การปิดกิจการของสถาบันการเงินโดยใช้โครงข่ายประสาทเทียม

4.2.1. การเรียนรู้แบบแพร่ย้อนกลับ

ผลการพยากรณ์การปิดกิจการของสถาบันการเงิน โดยใช้การเรียนรู้แบบแพร่ย้อนกลับ โดยใช้ชุดข้อมูลจากตาราง 3.3 – 3.6 และกำหนดค่าพารามิเตอร์ตามบทที่ 3 นั้น ผลที่ได้แสดงในตาราง 4.1

ตาราง 4.1 ผลการพยากรณ์โดยใช้การเรียนรู้แบบแพร่ย้อนกลับ

ชุดข้อมูล	จำนวนองค์ประกอบ	ข้อมูลชุดทดสอบ			ข้อมูลชุดเรียนรู้
		เปอร์เซ็นต์ความถูกต้อง	Type I error	Type II error	เปอร์เซ็นต์ความถูกต้อง
t-1	20-37	100	0.00	0.00	100
	10-19	100	0.00	0.00	100
	5-9	100	0.00	0.00	100
	<5	88.89	0.00	33.33	100
t-2	20-37	93.75	9.09	0.00	100
	10-19	93.75	9.09	0.00	100
	5-9	93.75	9.09	0.00	100
	<5	87.50	18.18	0.00	100
t-3	20-37	86.96	5.26	50.00	100
	10-19	91.30	0.00	50.00	100
	5-9	91.30	0.00	50.00	100
	<5	86.96	0.00	75.00	100
t-4	20-37	83.33	10.00	30.00	100
	10-19	83.33	10.00	30.00	100
	5-9	90.00	0.00	30.00	100
	<5	83.33	0.00	50.00	100
t-5	20-37	83.33	9.09	37.50	100
	10-19	83.33	9.09	37.50	100
	5-9	90.00	0.00	37.50	100
	<5	66.67	22.73	62.50	100

4.2.2. การเรียนรู้แบบใช้ความน่าจะเป็น

ผลการพยากรณ์การปิดกิจการของสถาบันการเงิน โดยใช้การเรียนรู้แบบใช้ความน่าจะเป็น โดยใช้ชุดข้อมูลจากตาราง 3.3 – 3.6 และกำหนดค่าพารามิเตอร์ตามบทที่ 3 นั้น ผลที่ได้แสดงในตาราง 4.2

ตาราง 4.2 ผลการพยากรณ์โดยใช้การเรียนรู้แบบใช้ความน่าจะเป็น

ชุดข้อมูล	จำนวนองค์ประกอบ	ข้อมูลชุดทดสอบ			ข้อมูลชุดเรียนรู้
		เปอร์เซ็นต์ความถูกต้อง	Type I error	Type II error	เปอร์เซ็นต์ความถูกต้อง
t-1	20-37	88.89	0.00	33.33	87.50
	10-19	88.89	0.00	33.33	87.50
	5-9	88.89	0.00	33.33	87.50
	<5	88.89	0.00	33.33	87.50
t-2	20-37	87.50	18.18	0.00	80.65
	10-19	87.50	18.18	0.00	83.87
	5-9	93.75	9.09	0.00	88.71
	<5	87.50	9.09	20.00	88.71
t-3	20-37	78.26	15.26	50.00	83.33
	10-19	82.26	5.26	75.00	83.33
	5-9	91.30	0.00	50.00	86.67
	<5	69.57	26.32	50.00	77.78
t-4	20-37	83.33	10.00	30.00	77.78
	10-19	86.67	10.00	20.00	80.00
	5-9	93.33	0.00	20.00	85.74
	<5	66.67	25.00	50.00	76.92
t-5	20-37	83.33	9.09	37.50	77.78
	10-19	83.33	9.09	37.50	80.00
	5-9	93.33	0.00	25.00	85.74
	<5	66.67	22.73	62.50	76.92

4.2.3. การเรียนรู้แบบแอลวีคิว

ผลการพยากรณ์การปิดกิจการของสถาบันการเงิน โดยใช้การเรียนรู้แบบแพร่ย้อนกลับ โดยใช้ชุดข้อมูลจากตาราง 3.3 – 3.6 และกำหนดค่าพารามิเตอร์ตามบทที่ 3 นั้น ผลที่ได้แสดงใน ตาราง 4.3

ตาราง 4.3 ผลการพยากรณ์โดยใช้การเรียนรู้แบบแอลวีคิว

ชุดข้อมูล	จำนวน องค์ประกอบ	ข้อมูลชุดทดสอบ			ข้อมูลชุดเรียนรู้
		เปอร์เซ็นต์ ความถูกต้อง	Type I error	Type II error	เปอร์เซ็นต์ ความถูกต้อง
t-1	20-37	100	0.00	0.00	93.75
	10-19	100	0.00	0.00	93.75
	5-9	100	0.00	0.00	100
	<5	88.89	0.00	33.33	93.75
t-2	20-37	87.50	18.18	0.00	91.94
	10-19	87.50	18.18	0.00	91.94
	5-9	93.75	9.09	0.00	96.77
	<5	75.00	27.27	20.00	88.71
t-3	20-37	86.96	5.26	50.00	88.89
	10-19	86.96	5.26	50.00	88.89
	5-9	91.30	0.00	50.00	88.89
	<5	65.22	31.58	50.00	77.78
t-4	20-37	83.33	10.00	30.00	85.74
	10-19	83.33	10.00	30.00	85.74
	5-9	83.33	0.00	50.00	85.74
	<5	66.67	25.00	50.00	76.92
t-5	20-37	83.33	9.09	37.50	85.74
	10-19	83.33	9.09	37.50	85.74
	5-9	83.33	9.09	37.50	85.74
	<5	66.67	22.73	62.50	76.92

4.3 ผลการวิเคราะห์ปัจจัยหลักของการปิดกิจการของสถาบันการเงิน

องค์ประกอบหลักซึ่งได้จากการใช้เทคนิคพีซีเอ ในบทที่ 3 นั้น สามารถนำมาเขียนกราฟแสดงความสัมพันธ์ระหว่างค่าไอเกน กับองค์ประกอบหลักตามลำดับค่าไอเกนจากมากไปน้อย ซึ่งมีจำนวนองค์ประกอบทั้งหมด 37 ตัวแปร แต่มีเพียง 2 องค์ประกอบหลักเท่านั้น ที่มีค่ามากกว่า 0.5

บทที่ 5

สรุปผลการทดลอง

จากตาราง 4.1 – 4.3 แสดงให้เห็นว่า แบบจำลองการพยากรณ์โดยใช้โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าหลายชั้นนั้นให้เปอร์เซ็นต์ความถูกต้องเฉลี่ยของทุกชุดทดสอบ และการเรียนรู้ทั้งสามแบบ คือ 86.06 แยกเป็น

- 1) ค่าเฉลี่ยเปอร์เซ็นต์ความถูกต้องของการเรียนรู้แบบแพร่ย้อนกลับจากตาราง 5.1 คือ 88.87
- 2) ค่าเฉลี่ยเปอร์เซ็นต์ความถูกต้องของการเรียนรู้แบบใช้ความน่าจะเป็นจากตาราง 5.2 คือ 84.49
- 3) ค่าเฉลี่ยเปอร์เซ็นต์ความถูกต้องของการเรียนรู้แบบแอลวีกิวจากตาราง 5.3 คือ 84.82

ตาราง 5.1 เฉลี่ยเปอร์เซ็นต์ความถูกต้องของแบบจำลองพยากรณ์การปิดกิจการกับข้อมูลชุดทดสอบ โดยใช้การเรียนรู้แบบแพร่ย้อนกลับ

จำนวนองค์ประกอบที่ใช้	ข้อมูลชุดทดสอบ					เฉลี่ยเปอร์เซ็นต์ความถูกต้อง
	t-1	t-2	t-3	t-4	t-5	
20-37	100	93.75	86.96	83.33	83.33	89.47
10-19	100	93.75	91.3	83.33	83.33	90.34
5-9	100	93.75	91.3	90	90	93.01
<5	88.89	87.5	86.96	83.33	66.67	82.67
เฉลี่ยเปอร์เซ็นต์ความถูกต้อง	97.22	92.18	89.13	84.99	80.83	88.87

นอกจากนี้ ผลการพยากรณ์โดยใช้จำนวนองค์ประกอบหลักต่างๆ กันนั้น การเรียนรู้ทั้งสามแบบให้ผลลัพธ์ตรงกันว่า จำนวนองค์ประกอบหลักที่ดีที่สุด คือ ช่วง 5-9 และถ้าใช้จำนวนองค์ประกอบต่ำกว่า 5 จะให้ผลการพยากรณ์ที่แย่ที่สุด

สังเกตได้ว่า ความถูกต้องของการพยากรณ์กับชุดข้อมูลทดสอบนั้นเรียงตามลำดับจากมากไปน้อย เนื่องจากข้อมูลชุดทดสอบประกอบด้วยจำนวนสถาบันการเงินไม่เท่ากัน และมีลำดับจากน้อยไปมาก ตามชุด t-1, t-2, t-3, t-4 และ t-5 ทำให้เปอร์เซ็นต์ความถูกต้องเฉลี่ยสูงสุดเรียงจาก t-1, t-2, t-3, t-4 และ t-5 ตามลำดับ

ตาราง 5.2 เฉลี่ยเปอร์เซ็นต์ความถูกต้องของแบบจำลองพยากรณ์การปิดกิจการ
กับข้อมูลชุดทดสอบ โดยใช้การเรียนรู้แบบใช้ความน่าจะเป็น

จำนวน องค์ประกอบที่ใช้	ข้อมูลชุดทดสอบ					เฉลี่ย เปอร์เซ็นต์ ความถูกต้อง
	t-1	t-2	t-3	t-4	t-5	
20-37	88.89	87.5	78.26	83.33	83.33	84.26
10-19	88.89	87.5	82.26	86.67	83.33	85.73
5-9	88.89	93.75	91.3	93.33	93.33	92.12
<5	88.89	87.5	69.57	66.67	66.67	75.86
เฉลี่ยเปอร์เซ็นต์ ความถูกต้อง	88.89	89.06	80.34	82.50	81.66	84.49

ตาราง 5.3 เฉลี่ยเปอร์เซ็นต์ความถูกต้องของแบบจำลองพยากรณ์การปิดกิจการ
กับข้อมูลชุดทดสอบ โดยใช้การเรียนรู้แบบเอลวิคิว

จำนวน องค์ประกอบที่ใช้	ข้อมูลชุดทดสอบ					เฉลี่ย เปอร์เซ็นต์ ความถูกต้อง
	t-1	t-2	t-3	t-4	t-5	
20-37	100	87.5	86.96	83.33	83.33	88.22
10-19	100	87.5	86.96	83.33	83.33	88.22
5-9	100	93.75	91.3	83.33	83.33	90.34
<5	88.89	75	65.22	66.67	66.67	72.49
เฉลี่ยเปอร์เซ็นต์ ความถูกต้อง	97.22	85.93	82.61	79.16	79.16	84.82

บรรณานุกรม

- [Altman, 1968] E. Altman, "Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy," *J. Finance*, vol. 23, pp. 589-609, 1968.
- [Altman, 1981] E. Altman, "Application of Classification Techniques in Business, Banking, and Finance," in *Contemporary Studies in Economic & Financial Analysis*, vol. 3, Greenwich: JAI Press, 1981.
- [Altman, 1997] E. Altman and P. Narayanan, "An International Survey of Business Failure Classification Models," *Financial Markets, Institutions & Instruments*, vol. 6, pp. 1-57, 1997.
- [Atiya, 2001] A. Atiya, "Bankruptcy Prediction for Credit Risk Using Neural Networks: A Survey and New Results," *IEEE Transactions on Neural Networks*, vol. 12, pp. 929-935, 2001.
- [Aziz, 2004] M. Aziz and H. Dar, "Predicting Corporate Bankruptcy: Whither Do We Stand?," unpublished working paper, 2004.
- [Beaver, 1966] W. Beaver, "Financial ratios as Predictors of failure," *J. Accounting Research*, vol. 4, pp. 71-111, 1966.
- [Blum, 1974] M. Blum, "Failing Company Discriminant Analysis," *J. Accounting Research*, vol. 12, pp. 1-25, 1974.
- [Bongini, 2001] P. Bongini, S. Claessens, and G. Ferri, "The Political Economy of Distress in East Asian Financial Institutions," *J. Financial Services Research*, vol. 19, pp. 5-25, 2001.
- [Coats, 1993] P. Coats and L. Fant, "Recognizing financial distress patterns using a neural network tool," *Financial Management*, vol. 22, pp. 142-155, 1993.
- [Deakin, 1972] E. Deakin, "A Discriminant Analysis of Predictors of Business Failure," *J. Accounting Research*, pp. 167-179, Spring, 1972.
- [Demuth, 1992] Howard Demuth, Mark Beale. "Neural Network Toolbox For Use with Matlab," The MathWorks, Inc., 1992.
- [Fernandez, 1995] E. Fernandez and I. Olmeda, "Bankruptcy prediction with artificial neural networks," *Lect. Notes Comput. Sc.*, pp. 1142-1146, 1995.

- [Gentry, 1985] J. Gentry, P. Newbold, and D. Whitford, "Classifying Bankruptcy Firms with Funds Flow Components," *J. Accounting Research*, pp. 146-160, 1985.
- [Intharasombat, 2003] Ouychai Intharasombat, "Mammographic Masses Classification Using Active Contour Models and Shape Features," Ph.M. Dissertation, Mahidol University, 2003.
- [Yao, 1995] Jingtao YAO and Hean-Lee POH, "Forecasting the KLSE Index Using Neural networks," *IEEE International Conference*, Vol, 2, pp. 1012-1017, 1995.
- [Langner, 2007] Jens Langner, *Leaves Recognition v1.0*. [Online]. Accessed 20 August 2007. Available from <http://damato.light-speed.de/lrecog/>
- [Marotz, 2001] J. Marotz, C. Lübbert and W. Eisenbeiß, "Effective Object Recognition for Automated Counting of Colonies in Petri Dishes (automated colony counting)," *ScienceDirect* 66, 2-3, pp. 183-198, 2001.
- [Martin, 1977] D. Martin, "Early Warning of Bank Failure: A Logit Regression Approach," *J. Banking & Finance*, vol. 1, 249-276, 1977.
- [Meyer, 1970] P. Meyer and H. Pifer, "Prediction of Bank Failure," *J. Finance*, vol. 25, pp. 853-868, 1970.
- [Mitziias, 2004] Mitziias, Dimitris A. and Basil G. Mertzios, "A Neural Multiclassifier System for Object Recognition in Robotic Vision Applications," *ScienceDirect* 36, 3-4 , pp. 315-330, 2004.
- [Moshou, 2001] Dimitrio Moshou, et al, "A Neural Network Based Plant Classifier," *ScienceDirect* 31, 1, pp. 5-16, 2001.
- [Ohlson, 1980] J. Ohlson, "Financial Ratios and the Probabilistic Prediction of Bankruptcy," *J. Accounting Research*, vol. 18, pp. 109-131, 1980.
- [Pettaway, 1980] R. Pettaway and J. Sinkey, "Establishing On-Site Bank Examination Priorities: An Early-Warning System Using Accounting and Market Information," *J. Finance*, vol. 35, pp. 137-150, 1980.
- [Salchenberger, 1992] L. Salchenberger, E. Cinar, and N. Lash, "Neural networks for financial diagnosis," *Decision Sciences*, vol. 23., pp. 889-916, 1992.

- [Solomon, 2007] C. Solomon, and Dinesh Somasundaram. Feature Extraction of White Blood Cell Images [Online]. Accessed 8 February 2007, Available from <http://www.personal.psu.edu/users/d/u/dus150/Documents/papersd.doc>
- [Hamid, 2004] Hamid Soltanian-Zadeh, Farshid Rafiee-Rad and Siamak Pourabdollah-Nejad D. "Comparison of Multiwavelet, Wavelet, Haralick, and Shape Features for Microcalcification Classification in Mammograms." *ScienceDirect* 37, 10, pp. 1973-1986, 2004.
- [Haykin, 1999] Simon Haykin. "Neural Networks: A comprehensive foundation." Prentice Hall, 1999.
- [Storbeck, 2001] Frank Storbeck and Berent Daan, "Fish Species Recognition Using Computer Vision and a Neural Network," *ScienceDirect* 51, 1, pp. 11-15, 2001.
- [Sinkey, 1975] J. Sinkey, "A Multivariate Statistical Analysis of the Characteristics of Problem Banks," *J. Finance*, vol. 30, pp. 21-36, 1975.
- [Zhang, 1999] G. Zhang, M. Hu, and B. Patuwo et al., "Artificial neural networks in bankruptcy prediction: General framework and cross-validation analysis," *European J. Oper. Res.*, vol. 116, pp. 16-32, 1999.
- [Zhang, 2007] Mengjie Zhang, A Pixel-Based Approach to Recognizing Small Objects in Large Pictures Using Neural Networks [Online]. Accessed 22 November 2007. Available from <http://www.mcs.vuw.ac.nz/~mengjie/papers/cspsc97.pdf>