การแบ่งแยกการขันสกรูโดยใช้วิธีเอสวีเอ็ม

SCREW FASTENING CLASSIFICATION USING SVM

นายจตุรงค์ ปานตา รหัส 51381047

นายบดินทร์ แสงม้า รหัส 51381177

ปริญญานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาหลักสูตรปริญญาวิศวกรรมศาสตรบัณฑิต

สาขาวิชาวิศวกรรมไฟฟ้า ภาควิชาวิศวกรรมไฟฟ้าและคอมพิวเตอร์

คณะวิศวกรรมศาสตร์ มหาวิทยาลัยนเรศวร

ปีการศึกษา 2554

ใบรับรองปริญญานิพนธ์

ชื่อหัวข้อโครงงาน **การแบ่งแยกการขันสกรู โดยใช้วิธีเอสวีเอ็ม**

ผู้ดำเนินโครงงาน นายจตุรงค์ ปานตา รหัส 51381047

นายบดินทร์ แสงม้า รหัส 51381177

ที่ปรึกษาโครงงาน ดร. ศุภวรรณ พลพิทักษ์ชัย

สาขาวิชา วิศวกรรมไฟฟ้า

ภาควิชา วิศวกรรมไฟฟ้าและคอมพิวเตอร์

ปีการศึกษา 2554

....

คณะวิศวกรรมศาสตร์ มหาวิทยาลัยนเรศวร อนุมัติให้ปริญญานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิศวกรรมศาสตรบัณฑิต สาขาวิชาวิศวกรรมไฟฟ้า

....ที่ปรึกษาโครงงาน

(ดร. ศุภวรรณ พลพิทักษ์ชัย)

....กรรมการ

(ดร. นิพัทธ์ จันทรมินทร์)

....กรรมการ

(ดร. มุฑิตา สงฆ์จันทร์)

ชื่อหัวข้อโครงงาน	การแบ่งแยกการขันสกรูโดยใช้วิธีเอสวีเอ็ม
ผู้ดำเนินโครงงาน	นายจตุรงค์ ปานตา รหัส 51381047
	นายบดินทร์ แสงม้า รหัส 51381177
ที่ปรึกษาโครงงาน	ดร. ศุภวรรณ พลพิทักษ์ชัย
สาขาวิชา	วิศวกรรมไฟฟ้า
ภาควิชา	วิศวกรรมไฟฟ้าและคอมพิวเตอร์
ปีการศึกษา	2554

บทคัดย่อ

โครงงานนี้มีวัตถุประสงค์เพื่อศึกษาการแบ่งแยกการขันสกรูโดยใช้วีธีเอสวีเอ็ม ซึ่งใช้ตัดสินว่าสกรูที่ตรวจสอบนั้นเป็นการขันแบบสมบูรณ์หรือไม่สมบูรณ์โดยไม่ต้องใช้สายตาของผู้ทำงาน ในการแบ่งแยกข้อมูลด้วยเอสวีเอ็ม มีฟังก์ชันเคอร์เนลให้ใช้สามประเภทคือ ฟังก์ชันเคอร์เนลเชิงเส้น ฟังก์ชันเรเดียลเบสิสเคอร์เนล และฟังก์ชันโพลิโนเมียลเคอร์เนล การทดลองแสดงให้เห็นถึงผลของการใช้งานเคอร์เนลแต่ละประเภทและค่าพารามิเตอร์ที่เหมาะสม โดยทำการทดลองกับข้อมูลการขันสกรูทั้ง 5 ประเภทและเปรียบเทียบผลที่ได้

Project title	Screw Fastening Classification using SVM		
Name	Mr. Chaturong	Panta	ID. 51381047
	Mr. Bodint	Sangma	ID. 51381177
Project advisor	Ms. Supawan	Phonphitakchai, Ph.D.	
Major	Electrical Engineering		
Department	Electrical and Computer Engineering		
Academic year	2011		

Abstract

This project studies screw classification using SVM technique. Using this technique, screw fastening can be detected to be complete or incomplete fastening without looking by eyes of worker. SVM classification uses three kernel functions; linear kernel, radial basis kernel and polynomial kernel. The experiments show results of using those kernel functions and their proper values of parameters. Five types of screw fastening data are simulated and their simulation results are compared.

กิตติกรรมประกาศ

โครงงานเรื่องการแบ่งแยกการขันสกรูโดยใช้วิธีเอสวีเอ็ม สำเร็จได้ด้วยดีด้วยความกรุณาจาก ดร. ศุภวรรณ พลพิทักษ์ชัย ซึ่งเป็นอาจารย์ที่ปรึกษาให้กับโครงงานนี้ ที่กรุณาให้คำปรึกษา คำแนะนำ และช่วยเหลือตรวจสอบแก้ไขข้อบกพร่องต่างๆ ตลอดจนให้ความรู้และข้อคิดเห็นที่เป็นประโยชน์ต่อโครงงานนี้ด้วยความเอาใจใส่เป็นอย่างดีจนกระทั่งโครงงานเสร็จสมบูรณ์

ขอขอบคุณ ดร. นิพัทธ์ จันทรมินทร์ และ ดร. มุฑิตา สงฆ์จันทร์ ซึ่งเป็นคณะกรรมการสอบโครงงาน ที่ให้คำแนะนำในการดำเนินโครงงานและการเขียนปริญญานิพนธ์

ผู้ดำเนินโครงงานขอกราบขอบพระคุณทุกท่านที่มีส่วนร่วมในการดำเนินโครงงานนี้ จนทำให้โครงงานนี้สำเร็จลุล่วงไปได้ด้วยดี มา ณ โอกาสนี้

นายจตุรงค์ ปานตา

นายบดินทร์ แสงม้า

สารบัญ

หน้า

สารบัญ (ต่อ)

หน้า

สารบัญตาราง

ตารางที่ หน้า

สารบัญรูป

บทที่ 1
บทนำ

1.1 ที่มาและความสำคัญของโครงงาน

เครื่องการเรียนรู้ (Machine Learning) เป็นงานวิจัยเพื่อหาวิธีการทำให้ระบบคอมพิวเตอร์สามารถเรียนรู้ปรับปรุงตัวเองได้ หรืออาจกล่าวได้ว่าการเรียนรู้คือ การศึกษาวิธีวิเคราะห์เพื่อจำแนกหรือแจกแจงข้อมูลจำนวนมาก การเรียนรู้เป็นการหาความสัมพันธ์ระหว่างข้อมูลขาเข้าและขาออกซึ่งจะแสดงในรูปฟังก์ชันเบื้องหลัง (Underlying function) การหาความสัมพันธ์จะมีสองแบบคือ การจำแนก (Classification) คือการแบ่งกลุ่มระหว่างข้อมูลเช่นแบ่งระหว่างตัว x กับ o โดยมีเส้นไฮเปอร์เพลน (Hyperplane) ในการแบ่งข้อมูลออกจากกัน อย่างที่สองคือการถดถอยเชิงเส้น (Regression) คือการลากเส้นไปตามจุดต่างๆจะเป็นเชิงเส้น หรือไม่เป็นเชิงเส้นก็ได้

ในปี ค.ศ. 1960 ได้มีผู้เสนอใช้เคอร์เนลโดยมีข้อแตกต่างกับวิธีการเรียนรู้ที่มีมาก่อนหน้านี้ในแง่ของความสามารถในการหาค่าความผิดพลาดที่ต่ำที่สุดที่สามารถหาข้อพิสูจน์ได้อย่างแน่นอน นอกจากนั้นยังสามารถใช้ได้กับการแบ่งกลุ่มชนิดไม่เป็นเชิงเส้นซึ่งได้ถูกนำมาประยุกต์ใช้ในทางการแพทย์ เช่น การแบ่งข้อมูลดีเอ็นเอ ในงานด้านการแบ่งกลุ่มของข้อมูลวิธีเคอร์เนล (Kernel method) ถูกนำมาประยุกต์ใช้เพื่อคำนวณค่าผลคูณภายในปริภูมิแต่งเติม (Feature space) ที่มีมิติสูงขึ้น ประสิทธิภาพของการจำแนกประเภทหรือการประมาณค่านั้นจะขึ้นอยู่กับเคอร์เนลที่เลือกใช้ ซึ่งสามารถปรับให้เหมาะสมกับปัญหาที่กำลังสนใจและให้ผลการแบ่งกลุ่ม หรือการประมาณค่าที่ดีขึ้นในปริภูมิแต่งเติม

เอสวีเอ็ม (SVM) ย่อมาจาก Support Vector Machine คือวิธีที่ใช้ในการแบ่งกลุ่มแบบเส้นตรง (Linear classifier) ที่ทำงานโดยใช้ฟังก์ชันเคอร์เนล โดยใช้หลักการหาขอบที่กว้างที่สุดและการแก้ปัญหาแบบมีข้อแม้ (Constrain optimization) ข้อดีของเอสวีเอ็มคือสามารถหาค่าได้ในจุดที่ต่ำที่สุด (Global minima) ได้ดีกว่าวิธีโครงข่ายประสาท (Neural network) นอกจากนั้นยังสามารถใช้ได้กับการแบ่งกลุ่มชนิดไม่เป็นเชิงเส้นได้ด้วย

ดังนั้นโครงงานนี้จึงได้ใช้วิธีเอสวีเอ็มนำมาใช้ในการขันสกรู โดยการค้นคว้าหาสมการทางคณิตศาสตร์ที่สามารถใช้แบ่งแยกแรงที่เกิดขึ้นทั้งสองประเภทโดยใช้เอสวีเอ็ม จากนั้นสมการการแบ่งแยกที่ได้จะนำมาใช้เป็นเครื่องตรวจสอบการขันสกรูโดยไม่ต้องใช้สายตา โดยการทำนายจากผลของแรงบิดที่เกิดขึ้นในระหว่างการขันสกรู ผลที่ได้จะมีลักษณะที่แตกต่างกันระหว่างรูปแบบการขัน

ที่สมบูรณ์และไม่สมบูรณ์ โดยโครงงานนี้จะมุ่งเน้นไปที่การค้นคว้าสมการทางคณิตศาสตร์ที่สามารถใช้แบ่งแยกผลของแรงที่เกิดขึ้นว่าเป็นการขันชนิดใด โดยใช้วิธีเอสวีเอ็ม

1.2 วัตถุประสงค์ของโครงงาน

ศึกษาการแบ่งแยกข้อมูลโดยใช้วิธีเอสวีเอ็มด้วยโปรแกรมแมทแลป เพื่อนำไปประยุกต์ใช้ในการแบ่งแยกการขันสกรูแบบสมบูรณ์และไม่สมบูรณ์โดยใช้วิธีเอสวีเอ็มได้

1.3 ขอบเขตของโครงงาน

1. ศึกษาทฤษฎีของการแบ่งแยกข้อมูลโดยใช้วิธีเอสวีเอ็ม
2. ทำการแบ่งแยกข้อมูลโดยวิธีเอสวีเอ็มด้วยการเขียนโปรแกรมแมทแลป
3. ทำการแบ่งแยกการขันสกรูโดยวิธีเอสวีเอ็มและแสดงผลการแบ่งแยกได้

1.4 ขั้นตอนและแผนการดำเนินงาน

รายละเอียด	ปี 2554							ปี 2555		
	มิ.ย.	ก.ค.	ส.ค.	ก.ย.	ต.ค.	พ.ย.	ธ.ค.	ม.ค.	ก.พ.	มี.ค.
1. ศึกษาทฤษฎีเอสวีเอ็ม										
2. ศึกษาข้อมูลชนิดต่างๆ เพื่อนำมาทำการแบ่งแยก										
3. ใช้โปรแกรมแมทแลปในการแบ่งแยกการขันสกรู และแสดงผลเปรียบเทียบ										
4. จัดทำปริญญานิพนธ์ฉบับสมบูรณ์										

1.5 ประโยชน์ที่คาดว่าจะได้รับจากโครงงาน

1. สามารถแบ่งแยกข้อมูลโดยวิธีเอสวีเอ็มได้
2. นำการแบ่งแยกข้อมูลโดยวิธีเอสวีเอ็มไปใช้ในการแบ่งแยกการขันสกรูได้
3. นำความรู้ในการแบ่งแยกข้อมูลที่ได้ไปใช้ในการตรวจสอบการขันสกรูได้

1.6 งบประมาณ

1. ค่าเอกสาร โปรแกรมแมทแลป	200	บาท
2. ค่าถ่ายเอกสารและค่าเข้าเล่มรายงานฉบับสมบูรณ์	1,000	บาท
3. ค่าพิมพ์เอกสาร	500	บาท
4. ค่าวัสดุคอมพิวเตอร์	300	บาท
รวมเป็นเงินทั้งสิ้น (สองพันบาทถ้วน)	2,000	บาท

หมายเหตุ ถัวเฉลี่ยทุกรายการ

บทที่ 2
การแบ่งกลุ่มข้อมูล

การแบ่งแยกข้อมูลด้วยเอสวีเอ็มถูกนำไปใช้งานอย่างแพร่หลายเนื่องจาก ได้เปรียบตรงที่สามารถแบ่งแยกข้อมูลที่มีลักษณะซับซ้อนที่ไม่สามารถแบ่งแยกได้ด้วยฟังก์ชันเชิงเส้น โดยอาศัยทฤษฎีที่เรียกว่าวิธีเคอร์เนล (Kernel method) โดยทั่วไปจะใช้งาน 2 ประเภทคือ การแบ่งแยก (Classification) และการถดถอย (Regression) การแบ่งแยกด้วยวิธีเอสวีเอ็มจะกล่าวถึงหลักการการแบ่งแยก และการแทนค่าด้วยเคอร์เนล ซึ่งการแสดงข้อมูลด้วยเคอร์เนลจะเป็นการส่งค่าข้อมูลแบบไม่เป็นเชิงเส้น ไปที่มิติที่สูงกว่าเดิมที่สามารถทำการแบ่งแยกได้ง่ายกว่าเดิม

2.1 การแบ่งแยกข้อมูลแบบไบนารี

โดยทั่วไปการแบ่งแยกข้อมูลที่มี 2 กลุ่มจะเป็นการหาระนาบที่สามารถแยกข้อมูลที่ออกมาเป็น 2 กลุ่มได้ กำหนดให้ข้อมูลประกอบไปด้วย 2 กลุ่ม และสามารถแสดงได้ดังนี้

$$(y_i, x_i), \ldots, (y_i, x_i), \epsilon x \times \{\pm 1\} \tag{2.1}$$

เมื่อ i=1,…,L และต้องการที่จะหาฟังก์ชันการตัดสินใจ F ว่าข้อมูลใหม่ที่ได้มาจะอยู่ในกลุ่ม -1 หรือ +1

$$F: x \rightarrow \{\pm 1\} \tag{2.2}$$

กำหนดให้ x คือเซตไม่ว่างที่ x_i ถูกเลือกออกมา และ y_i คือกลุ่มของข้อมูล

ข้อมูลที่ให้มาถูกสมมติให้มีจำนวน D แอททริบิว หรือมีมิติเท่ากับ D และสามารถแบ่งแยกได้แบบเชิงเส้น นั่นคือสามารถวาดเส้นตรงที่สามารถแบ่งข้อมูลออกเป็น 2 กลุ่มได้ในกรณีที่ข้อมูลมากกว่าสองมิติ เส้นตรงนั้นจะเรียกว่าเป็นไฮเปอร์เพลน (Hyperplane) และสามารถแสดงได้ดังสมการต่อไปนี้

$$(w \cdot x) + b = 0 \tag{2.3}$$

เมื่อ w เป็นค่าเวกเตอร์น้ำหนักที่นอร์มอลกับไฮเปอร์เพลน และ b คือค่าไบแอส ไฮเปอร์เพลนที่เหมาะสมสามารถสร้างได้โดยการเลือกค่า w และ b ที่สอดคล้องกับสมการต่อไปนี้

$$x_i \cdot w + b \geq 1 \text{ for } y_i = +1$$

$$x_i \cdot w + b \geq 1 \text{ for } y_i = -1 \tag{2.4}$$

สมการข้างต้นสามารถรวมได้เป็น

$$y_i(x \cdot w + b) - 1 \geq 0\forall_i \tag{2.5}$$

จากไฮเปอร์เพลนแสดงค่ามาร์จิน (ระยะระหว่างข้อมูลที่ใกล้ที่สุดทั้ง 2 กลุ่ม) มีค่าเท่ากับ $\frac{1}{\|w\|}$ ซึ่งเป็นค่าที่เราต้องการหาค่ามากที่สุด โดยต้องสอดคล้องกับข้อบังคับที่สมการที่ (2.5) ดังนั้นสามารถเขียนได้ดังนี้

$$\min \|w\| \text{ โดยที่ } y_i(x_i \cdot w + b) - 1 \geq 0\forall_i \tag{2.6}$$

อย่างไรก็ตามการหาค่าที่มากที่สุดของ $\|w\|$ สามารถเปลี่ยนไปเป็นการหาค่าที่น้อยที่สุดของ $\frac{1}{2}w^2$ ซึ่งจะหมายถึงการหาคำตอบของปัญหาควอดราติก (Quadratic programming optimization:QP) ดังนั้นสมการที่ (2.6) จะเปลี่ยนไปเป็น

$$\min \|w\|^2 \text{ โดยที่ } y_i(x_i \cdot w + b) - 1 \geq 0\forall_i \tag{2.7}$$

การหาออพติไมเซชั่น (Optimization) ของสมการที่ (2.7) จะต้องใช้ตัวคูณลากรานจ์ (Lagrange multiplier) $\alpha_i \leq 0$ $(\alpha = \alpha_1, \ldots, \alpha_m)$ และลากราเจียน (Lagragian)

$$L_p \equiv \frac{1}{2}\|w\|^2 - \alpha[y_i(x_i \cdot w + b) - 1\forall_i]$$

$$\equiv \frac{1}{2}\|w\|^2 - \sum_{i=1}^{L} \alpha_i[y_i(x_i \cdot w + b) - 1]$$

$$\equiv \frac{1}{2}\|w\|^2 - \sum_{i=1}^{L} \alpha_i y_i(x_i \cdot w + b) + \sum_{i=1}^{L} \alpha_i$$

$$L(w, b, \alpha) = \frac{1}{2}\|w\|^2 - \sum_{i=1}^{m} \alpha_i[y_i(< x_i, w > +b) - 1] \tag{2.8}$$

สมการดังกล่าวเรียกว่าเป็นไพรมอลออพติไมเซชั่น (Primal optimization) นั่นคือสามารถหาค่าที่น้อยที่สุดได้โดยเทียบกับตัวแปรไพรมอล w และ b นอกจากนั้นยังสามารถหาค่าที่มากที่สุดเทียบกับตัวแปรดูอัล (Dual variable) α_i ได้ ผลคูณระหว่างค่าบังคับ (Constraint) และตัวคูณลากรานจ์ในสมการที่ (2.8) จะหายไปที่จุดเหมาะสม (Optimal point) ดังนั้น

$$\alpha_i[y_i(< x_i, w > +b) - 1] = 0 \tag{2.9}$$

การหาค่าที่น้อยที่สุดสามารถทำได้โดยการหาอนุพันธ์ของสมการที่ (2.8) เทียบกับ w และ b และให้ค่าการหาอนุพันธ์มีค่าเป็นศูนย์ดังสมการต่อไปนี้

$$\frac{\partial L}{\partial b}(w, b, \alpha) = -\sum_{i=1}^{m} \alpha_i y_i = 0 \tag{2.10}$$

$$\frac{\partial L}{\partial w}(w,b,\alpha) = w - \sum_{i=1}^{m} \alpha_i y_i x_i = 0$$

(2.11)

แทนค่าสมการข้างต้นลงในสมการที่ (2.8) จะได้ปัญหาออพติไมเซชันแบบดูอัล (Dual optimization problem)

$$L_D \equiv \sum_{i=1}^{L} \alpha_i - \frac{1}{2}\sum_{i,j} \alpha_i \alpha_j y_i y_j x_i \cdot x_j \text{ โดยที่ } \alpha_i \geq 0 \forall_i, \sum_{i=1}^{m} \alpha_i y_i = 0$$

$$\equiv \sum_{i=1}^{m} \alpha_i - \frac{1}{2}\sum_{i,j} \alpha_i H_{ij} \alpha_j \text{ where } H_{ij} \equiv y_i y_j x_i x_j$$

$$\equiv \sum_{i=1}^{L} \alpha_i - \frac{1}{2}\alpha^T H \alpha \text{ โดยที่ } \alpha_i \geq 0 \forall_i, \sum_{i=1}^{L} \alpha_i y_i = 0 \quad (2.12)$$

คำตอบสามารถหาได้จากสมการต่อไปนี้

$$max_{a=R^m} \sum_{i=1}^{m} \alpha_i - \frac{1}{2}\sum_{i,j=1}^{m} \alpha_i \alpha_j y_i y_j K_{ij} \quad (2.13)$$

$$max_{\alpha}\left[\sum_{i=1}^{m} \alpha_i - \frac{1}{2}\alpha^T H \alpha\right] \text{ โดยที่ } \alpha_i \geq 0 \forall_i \text{ and } \sum_{i=1}^{L} \alpha_i y_i = 0 \quad (2.14)$$

โดยที่ $\alpha_i \geq 0$ สำหรับทุกๆ $i = 1, \ldots, m$ และ

$$\sum_{i,j=1}^{m} \alpha_i y_i = 0 \quad (2.15)$$

เมื่อ $K_{ij} =< x_i, x_j >$ คือผลคูณแบบจุด (Dot product) ดังนั้นสมการการตัดสินใจ (Decision function) จะมีค่าเป็น

$$f(x) = sgn(\sum_{i=1}^{m} \alpha_i y_i < x_i x_j > +b) \quad (2.16)$$

โดยที่ปัญหานี้เรียกว่าคอนเวกซ์ออพติไมชั่น (Convex optimition) ซึ่งสามารถแก้ปัญหาโดยใช้ Q_p ซึ่งจะได้ค่าที่ α เป็นคำตอบจากสมการที่ (2.10) จะทำให้ได้ค่า w และ b เป็นคำตอบต่อมาทุกๆข้อมูลที่สอดคล้องกับสมการที่ (2.11) ซึ่งจะเป็นซัพพอร์ตเวกเตอร์ x_s จะอยู่ในรูป

$$y_s = (x_s \cdot w + b) = 1 \quad (2.17)$$

แทนในสมการที่ (2.11) จะได้

$$y_s(\sum_{m \epsilon S} \alpha_m y_m x_m \cdot x_s + b) = 1 \quad (2.18)$$

ที่ S คือเซตของซัพพอร์ตเวกเตอร์ดังนั้นจากสมการที่ (2.1) และสมการที่ (2.2)

$$y_s^2(\sum_{m\epsilon S} \alpha_m y_m x_m \cdot x_s + b) = y_s \quad (2.19)$$

$$b = y_s - \sum_{m\epsilon S} \alpha_m y_m x_m \cdot x_s \quad (2.20)$$

กำหนดให้ b คำนวณได้จากสมการที่ (2.20) ไฮเปอร์เพลนที่ได้จะเป็นค่าที่เหมาะสม นั่นคือ เป็นระนาบที่ห่างจากข้อมูลทั้ง 2 กลุ่มที่ใกล้กันที่สุดมีค่ามากที่สุด ซึ่งจะมีลักษณะที่สำคัญอีกอย่างหนึ่งคือ ข้อมูลที่อยู่ใกล้ไฮเปอร์เพลนมากที่สุดจะมีค่า $\alpha_i \geq 0$ และข้อมูลเหล่านี้จะเรียกว่าเป็นซัพพอร์ตเวกเตอร์ ในขณะที่ข้อมูลอื่นๆ ที่ไม่ใช่ซัพพอร์ตเวกเตอร์เท่านั้น ในขณะที่ข้อมูลอื่นๆ ที่เหลือไม่มีผลต่อการวางตัวของเส้นไฮเปอร์เพลนเลย

2.2 การแทนที่ด้วยเคอร์เนล

ไฮเปอร์เพลนที่เหมาะสมที่หาได้จากหัวข้อที่แล้วถูกสร้างบนปริภูมิผลคูณ (Dot product space) ดังนั้นจึงไม่เพียงพอที่จะใช้งานกับปัญหาที่น่าสนใจหลายๆอย่างเช่น ปัญหาไม่เป็นเชิงเส้น ดังนั้นจึงต้องให้ข้อมูลขาเข้าเป็นเวกเตอร์อยู่ในปริภูมิฟีเจอร์โดยใช้การแมป $\Phi: x \to H$ เมื่อ $x \to x = \Phi(x)$

การส่งข้อมูลไปที่ปริภูมิฟีเจอร์มีข้อดีในด้านการเรียนรู้โดนใช้พีชคณิตเชิงเส้น นั่นคือ ข้อมูลที่สามารถแบ่งได้ด้วยวิธีไม่เชิงเส้น สามารถส่งไปที่ปริภูมิที่มีมิติมากขึ้น (ปริภูมิฟีเจอร์) ที่สามารถแบ่งแยกข้อมูลได้ด้วยวิธีเชิงเส้น การแมปปิ้งสามารถทำได้ด้วยการแทนที่ผลคูณภายใน

$$x_x \cdot x_j \to \Phi(x_i) \cdot \Phi(x_j) \quad (2.21)$$

สมการแมปปิ้ง $\Phi(x_i)$ จะถูกเรียกว่าเคอร์เนลฟังก์ชัน

$$K(x_i \cdot x_j) = \Phi(x_i) \cdot \Phi(x_j) \quad (2.22)$$

เคอร์เนลฟังก์ชันมีหลายฟังก์ชันที่เป็นที่นิยมใช้ อาทิเช่น

1. เคอร์เนลเชิงเส้น $K(x_i \cdot x_j) = x_i^T x_j$

2. เรเดียลเบสิสเคอร์เนล $K(x_i \cdot x_j) = \exp(-\|x_i - x_j\|^2/\sigma^2)$

3. โพลิโนเมียลเคอร์เนล $K(x_i \cdot x_j) = (x_i \cdot x_j + 1)^b$

กำหนดให้ค่า σ และ b เป็นค่าพารามิเตอร์ที่ผู้ใช้ต้องกำหนดค่าให้ก่อนเริ่มทำงาน

ในการส่งข้อมูลไปที่ปริภูมิฟีเจอร์เราจะแทนค่า $< x_i x_j >$ ด้วย $K(x_i \cdot x_j)$ ซึ่งหมายถึงเคอร์เนลฟังก์ชัน การแทนค่านี้จะเรียกว่าเคอร์เนลทริค (Kernel trick) ที่สามารถทำให้เอสวีเอ็มทำงานแบบไม่เป็นเชิงเส้นได้ นั่นคือเป็นการหาค่ามากที่สุดของฟังก์ชันต่อไปนี้

$$max_{a=R^m} \sum_{i=1}^{m} \alpha_i - \frac{1}{2} \sum_{i,j=1}^{m} \alpha_i \alpha_j y_i y_j K_{ij} \qquad (2.23)$$

โดยที่ $\alpha_\mathrm{i} \geq 0$ สำหรับทุกๆ i=1,...,m และ $\sum_{i=1}^{m} \alpha_i y_i = 0$

ดังนั้นจะได้เงื่อนไขที่สอดคล้องกันของ Karush-Kuhn-Tucker (KKT) ดังนี้

$$y_i(x \cdot w + b) - 1 \geq 0 \forall_i$$

$$\alpha_i \geq 0 \forall_i$$

$$\alpha_i [(y_i < x_i, w > +b) - 1] = 0 \forall_i \qquad (2.24)$$

สมการเหล่านี้จะสอดคล้องเมื่อหาคำตอบของการหาค่ามากที่สุดได้ นอกจากนั้นข้อมูลที่เข้ามาใหม่จะสามารถตัดสินได้ว่าเป็นกลุ่มใดจากเครื่องหมายที่ได้สมการการตัดสินใจต่อไปนี้

$$f(x) = sgn(\sum_{i=1}^{m} \alpha_i y_i K < x_i, x_j > + b) \qquad (2.25)$$

2.3 การแบ่งแยกที่มีการผิดกลุ่มได้

ในการใช้งานจริงบางครั้งข้อมูลจะมีสัญญาณรบกวน และเอสวีเอ็มไม่สามารถแบ่งแยกได้อย่างถูกต้อง การลดความผิดพลาดเนื่องจากสัญญาณรบกวนสามารถทำได้โดยการใช้วิธีที่เรียกว่าซอฟต์มาร์จิน (Soft margin) หลักการจะเหมือนกับหัวข้อที่ผ่านมา แต่จะมีการใช้กล่องข้อบังคับ (Box constraint)

$$0 \leq \alpha_i \leq c \qquad (2.26)$$

และจะได้ค่าที่บวกน้อยๆ สำหรับเคอร์เนลเมตริกซ์

$$K(x_i \cdot x_i) \leftarrow K(x \cdot x_i) + \lambda \qquad (2.27)$$

ค่า c และ λ จะควบคุมสมดุลระหว่างค่าผิดพลาดของการสอนและความสามารถในการทำนายค่าในอนาคต ซึ่งจะถูกเลือกโดยค่าเฉลี่ยของข้อมูลที่ใช้ทดสอบ ดังนั้นสมการที่ (2.5) จะมีการใช้ค่าตัวแปรบวกที่เรียกว่าตัวแปรหย่อนบวก (Positive slack variable: ξ_i)

$$y_i(x_i \cdot w + b) \geq 1 - \xi_i \qquad (2.28)$$

จากนั้นจะต้องมีการหาค่าที่น้อยที่สุดของค่าผลรวมของความผิดพลาด $\sum_{i=1}^{m} \xi_i$ บวกกับ $\|w\|^2$

$$\min\left[\frac{1}{2} w \cdot w + c \sum_{i=1}^{m} \xi_i\right] \tag{2.29}$$

และจะได้ฟังก์ชันไพรมอลดังนี้

$$L(w, b, \alpha, \xi) = \frac{1}{2} w \cdot w + c \sum_{i=1}^{m} \xi_i - \sum_{i=1}^{m} \alpha_i [y_i(x_i \cdot w + b) - 1 + \xi_i] - \sum_{i=1}^{m} r_i \xi_i \tag{2.30}$$

โดยมีตัวคูณลากรานจ์ $\alpha_i \geq 0$ และ $r_i \geq 0$ จากนั้นหาอนุพันธ์โดยเทียบกับ w, b และ ξ จากนั้นแทนค่ากลับลงไปที่ฟังก์ชันไพรมอลเพื่อที่จะได้ฟังก์ชันดูอัลดังนี้

$$W(\alpha) = \sum_{i=1}^{m} \alpha_i - \frac{1}{2} \sum_{i,j=1}^{m} \alpha_i \alpha_j y_i y_j K(x_i \cdot x_j) - \frac{1}{4c} \sum_{i=1}^{m} \alpha_i^2 \tag{2.31}$$

ซึ่งสมการดังกล่าวมีการแทนค่าเคอร์เนลฟังก์ชันเรียบร้อยแล้ว การหาค่ามากที่สุดจะได้ค่า w และ b ที่เป็นคำตอบที่ต้องการซึ่งมีวิธีการหาคล้ายกับหัวข้อที่ผ่านมา ค่าที่ได้สามารถนำไปสร้างเป็นฟังก์ชันการตัดสินใจได้ว่าข้อมูลที่ได้มาใหม่อยู่กลุ่มใด

2.4 การใช้งานเอสวีเอ็มสำหรับข้อมูลที่ไม่อนุญาตให้มีการผิดกลุ่ม

เมื่อใช้เอสวีเอ็มในการแยกแยะความแตกต่างเส้นตรงเชิงเดียวซึ่งอธิบายมาแล้วในหัวข้อที่ 2.1 จะสามารถสรุปเป็นขั้นตอนได้ดังนี้

1. สร้าง H เมื่อ $H_{ij} = y_i y_j x_i x_j$

2. หา α ที่ทำให้ $\sum_{i=1}^{L} \alpha_i - \frac{1}{2} \alpha^T H \alpha$ มีค่ามากที่สุด โดยมีข้อจำกัดดังต่อไปนี้ $\alpha_i \geq 0 \forall_i$ and $\sum_{i=1}^{L} \alpha_i y_i = 0$ ซึ่งสมการนี้สามารถแก้ได้โดยใช้โปรแกรม QP (Quandratic Programming)

3. คำนวณหา $w = \sum_{i=1}^{L} \alpha_i y_i x_i$

4. หาเซตของเวกเตอร์เกื้อหนุน S โดยการหาดัชนีที่ทำให้ $\alpha_i \geq 0$

5. คำนวณหา $b = \frac{1}{N_s} \sum_{s \epsilon S} (y_s - \sum_{m \epsilon S} \alpha_m y_m x_m \cdot x_s)$ ในแต่ละข้อมูลใหม่ x' จะสามารถแบ่งกลุ่มได้จากสมการตัดสิน $y' = sgn(w \cdot x' + b)$

บทที่ 3
การทดลองการแบ่งข้อมูลด้วยวิธีเอสวีเอ็ม

จากหลักการและวิธีแบ่งกลุ่มด้วยวิธีเอสวีเอ็มที่ได้กล่าวมาแล้วในบทที่ 2 ในบทนี้จะเป็นการแสดงผลการแบ่งกลุ่มที่ได้ โดยใช้โปรแกรมแมทแลปในการแบ่งแยกข้อมูล

วิธีการที่ใช้ในการแบ่งกลุ่มคือ นำข้อมูลที่เรามีมาสร้างเป็นกลุ่ม โดยจะมีทั้งหมด 2 กลุ่ม ได้แก่ -1 และ +1 เมื่อได้กลุ่มในการแยกข้อมูลแล้ว เราก็จะนำข้อมูลที่เราสร้างไว้เป็นกลุ่มมาใส่ในโปรแกรมแมทแลป แล้วดูว่าข้อมูลเหล่านั้นตกอยู่ในกลุ่มไหนของเส้นแบ่งแยกที่ได้ แล้วทำการเขียนโปรแกรมให้ข้อมูลที่อยู่ในกลุ่มของ -1 เป็นเครื่องหมายบวก และข้อมูลที่อยู่ในกลุ่มของ +1 เป็นเครื่องหมายดอกจัน โดยสร้างข้อมูลเป็น 3 ประเภท

1. ข้อมูลประเภทที่ 1 จะแบ่งเป็น 2 กลุ่มเป็นข้อมูลที่มีค่าบวกและค่าลบที่แบ่งแยกออกจากกันสามารถแบ่งแยกได้ด้วยเส้นตรงดังแสดงในรูปที่ 3.1

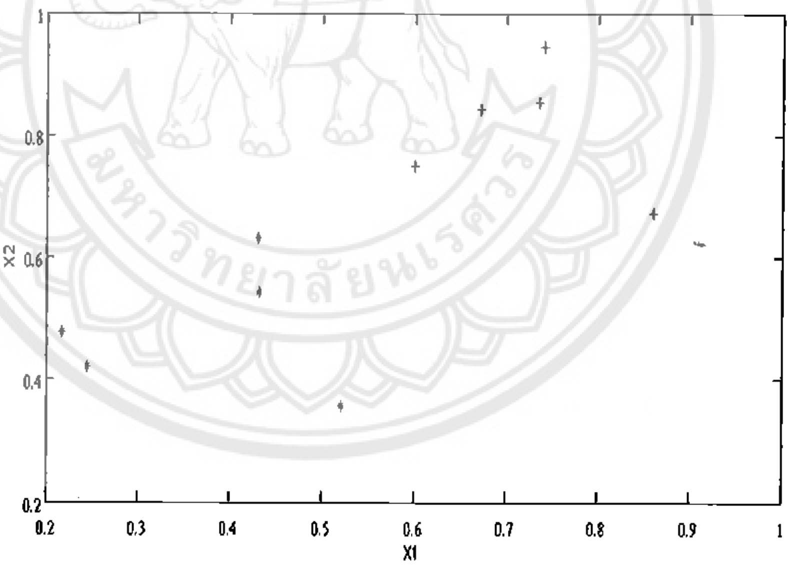

รูปที่ 3.1 ข้อมูลประเภทที่ 1

2. ข้อมูลประเภทที่ 2 จะแบ่งเป็น 2 กลุ่มค่าบวกและค่าลบนั้นกระจายอยู่ติดกันไม่สามารถแบ่งแยกได้ด้วยเส้นตรงดังแสดงในรูปที่ 3.2

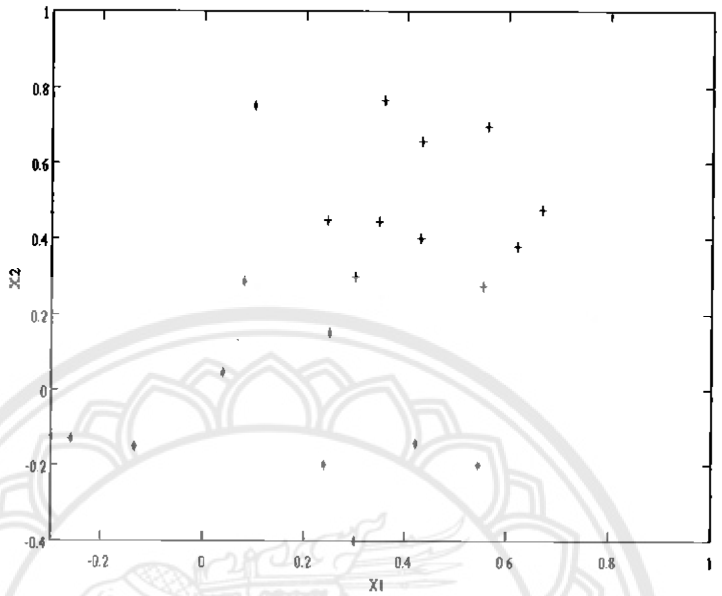

รูปที่ 3.2 ข้อมูลประเภทที่ 2

3. ข้อมูลประเภทที่ 3 จะมี 3 กลุ่มและมีลักษณะคล้ายกับข้อมูลประเภทที่ 1 แต่ละข้อมูลค่าบวกเพิ่มขึ้นมาอีก 1 กลุ่มไม่สามารถแบ่งแยกได้ด้วยเส้นตรงดังแสดงในรูปที่ 3.3

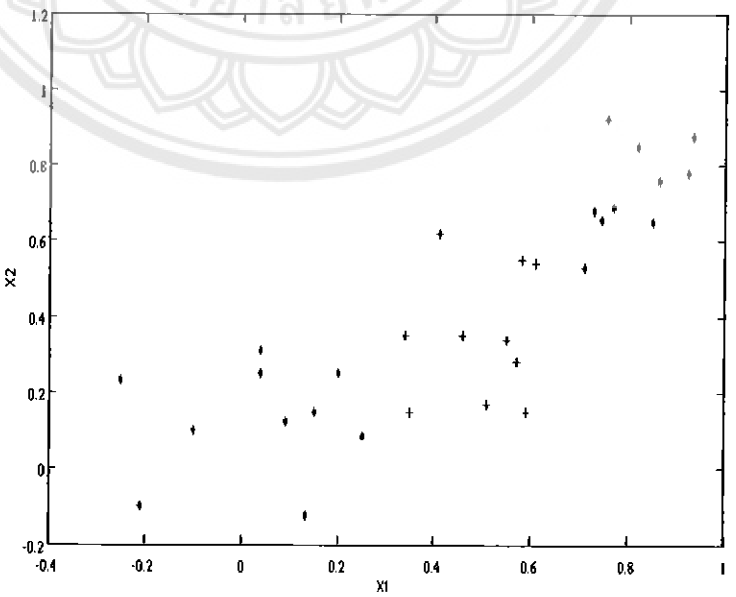

รูปที่ 3.3 ข้อมูลประเภทที่ 3

ขั้นตอนการแบ่งแยกข้อมูลโดยเอสวีเอ็ม แสดงได้ดังรูปที่ 3.4 ขั้นตอนในการแบ่งแยกข้อมูลมีดังนี้ เลือกข้อมูลที่ใช้สอนที่มีอยู่ 3 ประเภท แล้วทำการเลือกเคอร์เนลฟังก์ชันที่เกี่ยวข้องมาทำการแบ่งแยกข้อมูลแล้วเลือกค่าพารามิเตอร์ที่เกี่ยวข้องซึ่งประกอบไปด้วยค่า σ, b ซึ่งค่า σ คือค่าพารามิเตอร์ของเรเดียลเบสิสเคอร์เนล และค่า b คือค่าพารามิเตอร์ของโพลิโนเมียลเคอร์เนล แล้วทำการสอนและสร้างสมการการตัดสินใจในโปรแกรมแมทแลป ดังรูปที่ 3.4

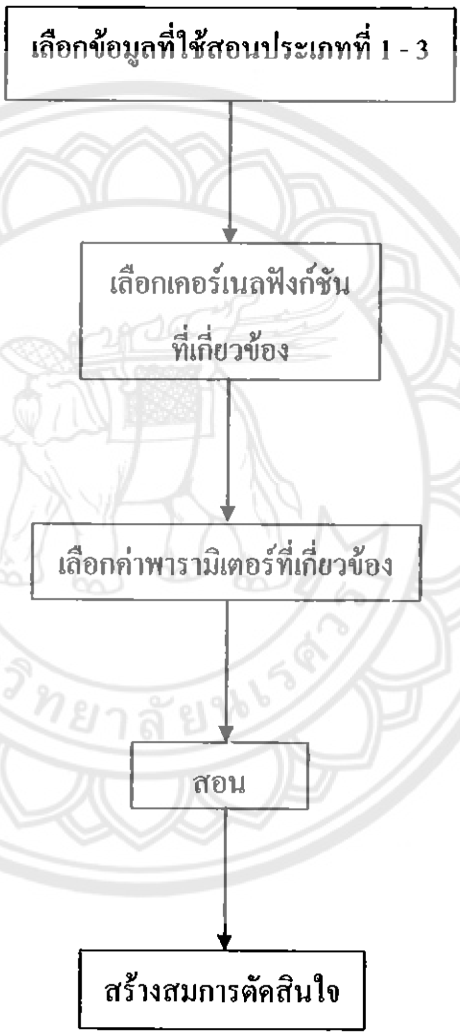

รูปที่ 3.4 ขั้นตอนการแบ่งแยกข้อมูลด้วยเอสวีเอ็ม

การแบ่งแยกข้อมูลโดยเอสวีเอ็มเคอร์เนลโดยใช้ฟังก์ชัน 3 แบบ ดังนี้ เคอร์เนลเชิงเส้น เรเดียลเบสิสเคอร์เนลและโพลิโนเมียลเคอร์เนล ขั้นต่อไปจะแสดงผลการแบ่งแยกที่เกิดขึ้นในการใช้เคอร์เนลฟังก์ชันในการแบ่งแยกทั้ง 3 แบบ ที่ใช้ข้อมูล 3 ประเภท

3.1 ข้อมูลประเภทที่ 1

3.1.1 การแบ่งแยกข้อมูลโดยใช้เคอร์เนลเชิงเส้น แบ่งข้อมูลประเภทที่ 1 ดังรูปที่ 3.5

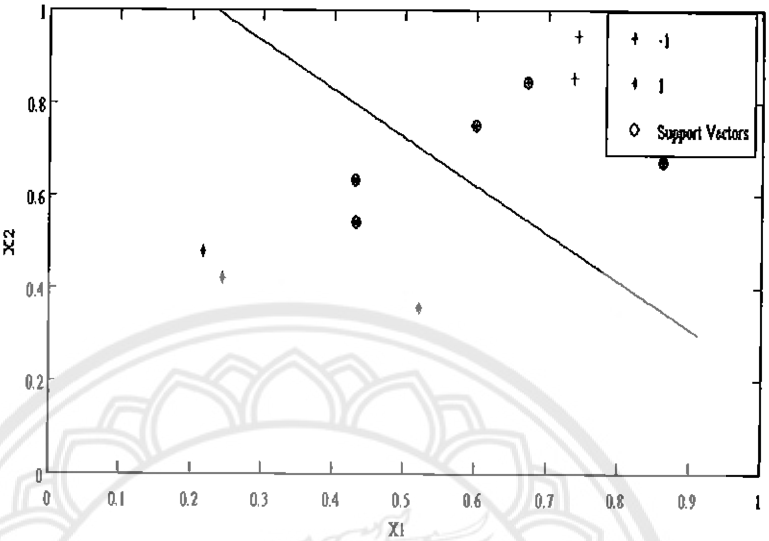

รูปที่ 3.5 การแบ่งแยกข้อมูลประเภทที่ 1 โดยใช้เคอร์เนลเชิงเส้น

ผลที่ได้จากการทดลองนำข้อมูลไปทำการแบ่งแยกข้อมูลด้วยเคอร์เนลเชิงเส้น ผลที่ได้คือ ข้อมูลประเภทที่ 1 สามารถแบ่งแยกได้ด้วยเส้นตรง ซึ่งข้อมูลประเภทที่ 1 เป็นข้อมูลที่ไม่มีความซับซ้อนในการแบ่งแยก จึงสามารถใช้เคอร์เนลเชิงเส้นในการแบ่งแยกข้อมูลได้

3.1.2 การแบ่งแยกข้อมูลโดยใช้เรเดียลเบสิสเคอร์เนล แบ่งข้อมูลประเภทที่ 1 แล้วการเปลี่ยนค่า σ เป็นค่าต่างๆ ได้ดังดังรูปที่ 3.6

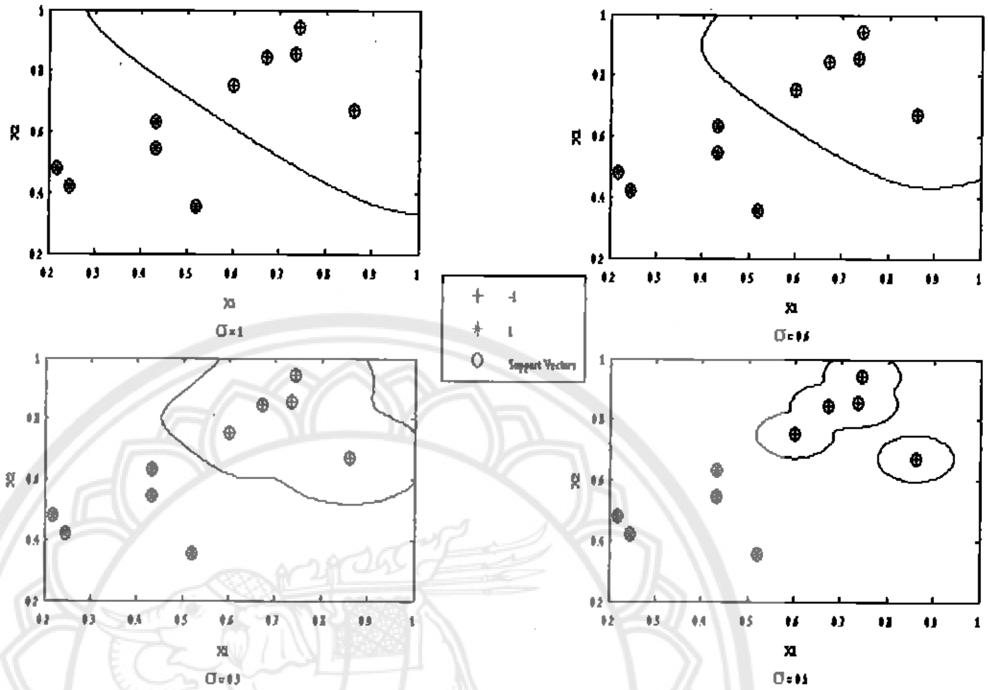

รูปที่ 3.6 การแบ่งแยกข้อมูลประเภทที่ 1 โดยใช้เรเดียลเบสิสเคอร์เนล

ผลที่ได้จากการทดลองนำข้อมูลไปทำการแบ่งแยกข้อมูลด้วยเรเดียลเบสิสเคอร์เนล ผลที่ได้คือ ข้อมูลประเภทที่ 1 สามารถแบ่งได้ด้วยเรเดียลเบสิสเคอร์เนล เมื่อมีการปรับค่าพารามิเตอร์ของเรเดียลเบสิสเคอร์เนลให้มีค่าลดลงก็จะทำให้มีการแบ่งแยกข้อมูลได้มีความละเอียดสูงขึ้น

3.1.3 การแบ่งแยกข้อมูลโดยใช้โพลิโนเมียลเคอร์เนล แบ่งข้อมูลประเภทที่ 1 แล้วการเปลี่ยนค่า b เป็นค่าต่างๆ ได้ดังรูปที่ 3.7

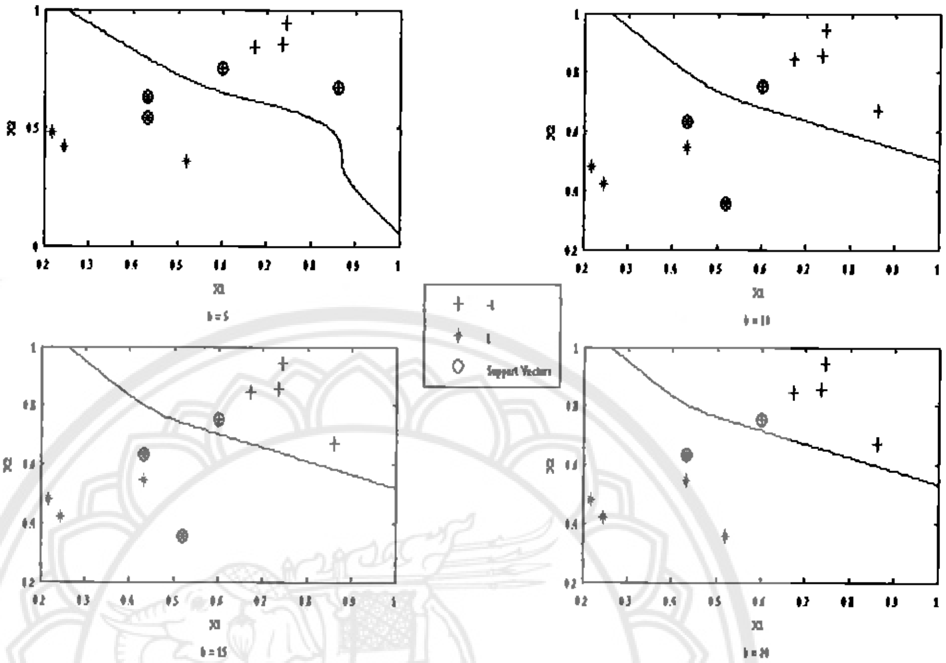

รูปที่ 3.7 การแบ่งแยกข้อมูลประเภทที่ 1 โดยใช้โพลิโนเมียลเคอร์เนล

ผลที่ได้จากการทดลองนำข้อมูลไปทำการแบ่งแยกข้อมูลด้วยโพลิโนเมียลเคอร์เนล ผลที่ได้คือ ข้อมูลประเภทที่ 1 สามารถแบ่งได้ด้วยโพลิโนเมียลเคอร์เนล เมื่อมีการปรับค่าพารามิเตอร์ของโพลิโนเมียลเคอร์เนล ให้มีค่ามากขึ้นก็จะทำให้มีการแบ่งแยกข้อมูลได้มีความละเอียดสูงขึ้น

3.2 ข้อมูลประเภทที่ 2

3.2.1 การแบ่งแยกข้อมูลโดยใช้เคอร์เนลเชิงเส้น แบ่งข้อมูลประเภทที่ 2 ได้ดังรูปที่ 3.8

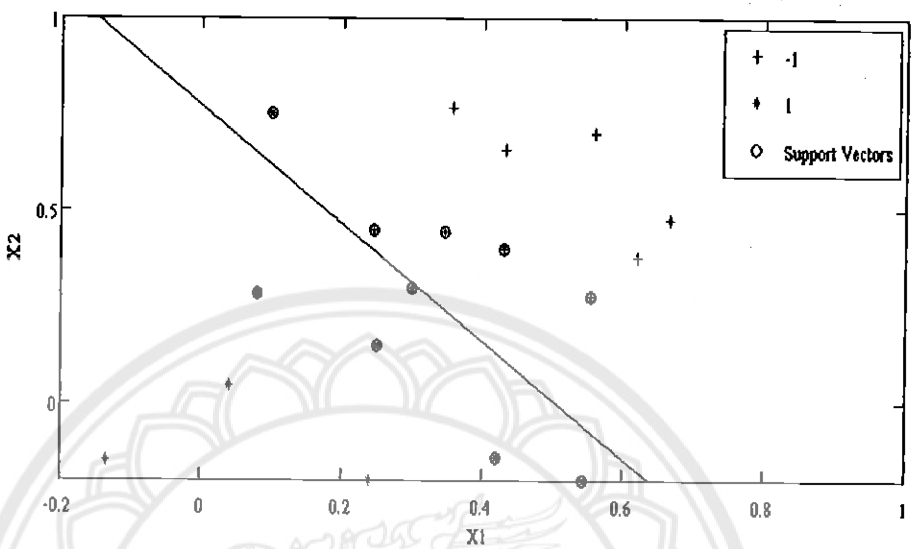

รูปที่ 3.8 การแบ่งแยกข้อมูลประเภทที่ 2 โดยใช้เคอร์เนลเชิงเส้น

ผลที่ได้จากการทดลองนำข้อมูลไปทำการแบ่งแยกข้อมูลด้วยเคอร์เนลเชิงเส้น ผลที่ได้คือ ข้อมูลประเภทที่ 2 ไม่สามารถแบ่งแยกได้ด้วยเส้นตรง ซึ่งข้อมูลประเภทที่ 2 เป็นข้อมูลที่มีข้อมูลค่าบวกและค่าลบกระจายอยู่ติดและมีความซับซ้อนในการแบ่งแยก จึงไม่สามารถใช้เคอร์เนลเชิงเส้นในการแบ่งแยกข้อมูลได้

3.2.2 การแบ่งแยกข้อมูลโดยใช้เรเดียลเบสิสเคอร์เนล แบ่งข้อมูลประเภทที่ 2 แล้วการเปลี่ยนค่า σ เป็นค่าต่างๆ ได้ดังรูปที่ 3.9

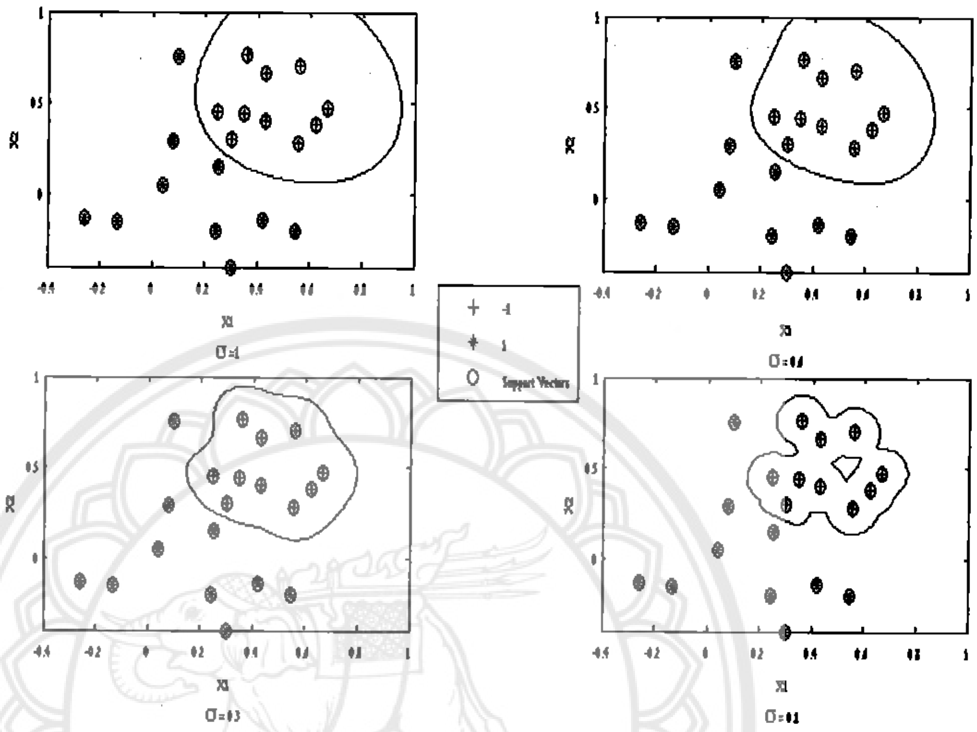

รูปที่ 3.9 การแบ่งแยกข้อมูลประเภทที่ 2 โดยใช้เรเดียลเบสิสเคอร์เนล

ผลที่ได้จากการทดลองนำข้อมูลไปทำการแบ่งแยกข้อมูลด้วยเรเดียลเบสิสเคอร์เนล ผลที่ได้คือ ข้อมูลประเภทที่ 2 มีความซับซ้อน สามารถแบ่งได้ด้วยเรเดียลเบสิสเคอร์เนล เมื่อมีการปรับค่าพารามิเตอร์ของเรเดียลเบสิสเคอร์เนลให้มีค่าลดลงก็จะทำให้มีการแบ่งแยกข้อมูลได้มีความละเอียดสูงขึ้น

3.2.3 การแบ่งแยกข้อมูลโดยใช้โพลิโนเมียลเคอร์เนล แบ่งข้อมูลประเภทที่ 2 แล้วการเปลี่ยนค่า b เป็นค่าต่างๆ ได้ดังรูปที่ 3.10

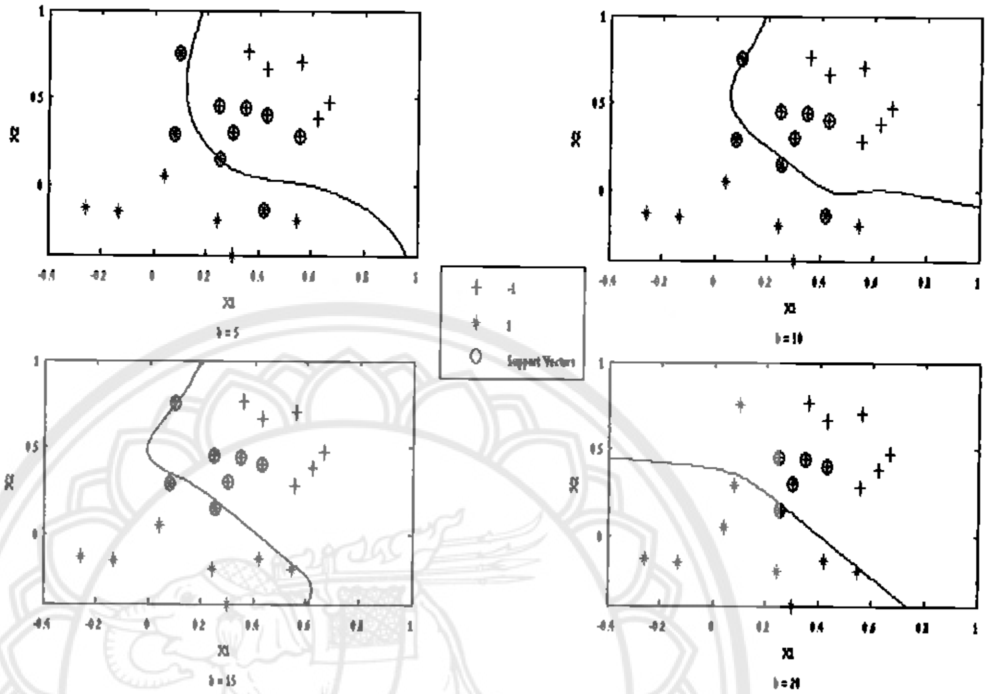

รูปที่ 3.10 การแบ่งแยกข้อมูลประเภทที่ 2 โดยใช้โพลิโนเมียลเคอร์เนล

ผลที่ได้จากการทดลองนำข้อมูลไปทำการแบ่งแยกข้อมูลด้วยโพลิโนเมียลเคอร์เนล ผลที่ได้คือ ข้อมูลประเภทที่ 2 สามารถแบ่งได้ด้วยโพลิโนเมียลเคอร์เนล เมื่อมีการปรับค่าพารามิเตอร์ของโพลิโนเมียลเคอร์เนล ให้มีค่ามากขึ้นก็จะทำให้มีการแบ่งแยกข้อมูลได้มีความละเอียดสูงขึ้น แต่ถ้ามากไปก็อาจจะทำการแบ่งแยกไม่ได้ด้วยดังผลการทดลองที่เกิดขึ้น

3.3 ข้อมูลประเภทที่ 3

3.3.1 การแบ่งแยกข้อมูลโดยใช้เคอร์เนลเชิงเส้น แบ่งข้อมูลประเภทที่ 3 ได้ดังรูปที่ 3.11

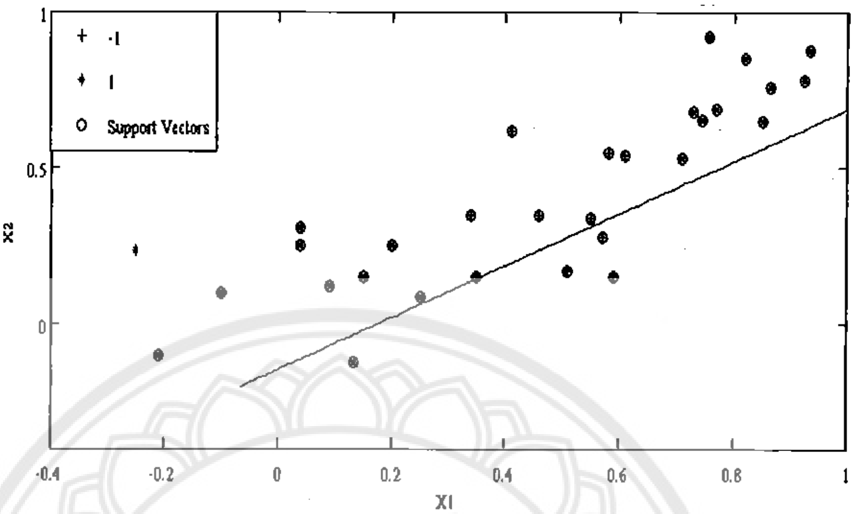

รูปที่ 3.11 การแบ่งแยกข้อมูลประเภทที่ 3 โดยใช้เคอร์เนลเชิงเส้น

ผลที่ได้จากการทดลองนำข้อมูลไปทำการแบ่งแยกข้อมูลด้วยเคอร์เนลเชิงเส้น ผลที่ได้คือ ข้อมูลประเภทที่ 3 ไม่สามารถแบ่งแยกได้ด้วยเส้นตรง ซึ่งข้อมูลประเภทที่ 3 เป็นข้อมูลที่มีค่าลบอยู่ระหว่างค่าบวกและเป็นข้อมูลที่ความซับซ้อนในการแบ่งแยก จึงไม่สามารถใช้เคอร์เนลเชิงเส้นในการแบ่งแยกข้อมูลได้

3.3.2 การแบ่งแยกข้อมูลโดยใช้เรเดียลเบสิสเคอร์เนล แบ่งข้อมูลประเภทที่ 3 แล้วการเปลี่ยนค่า σ เป็นค่าต่างๆ ได้ดังรูปที่ 3.12

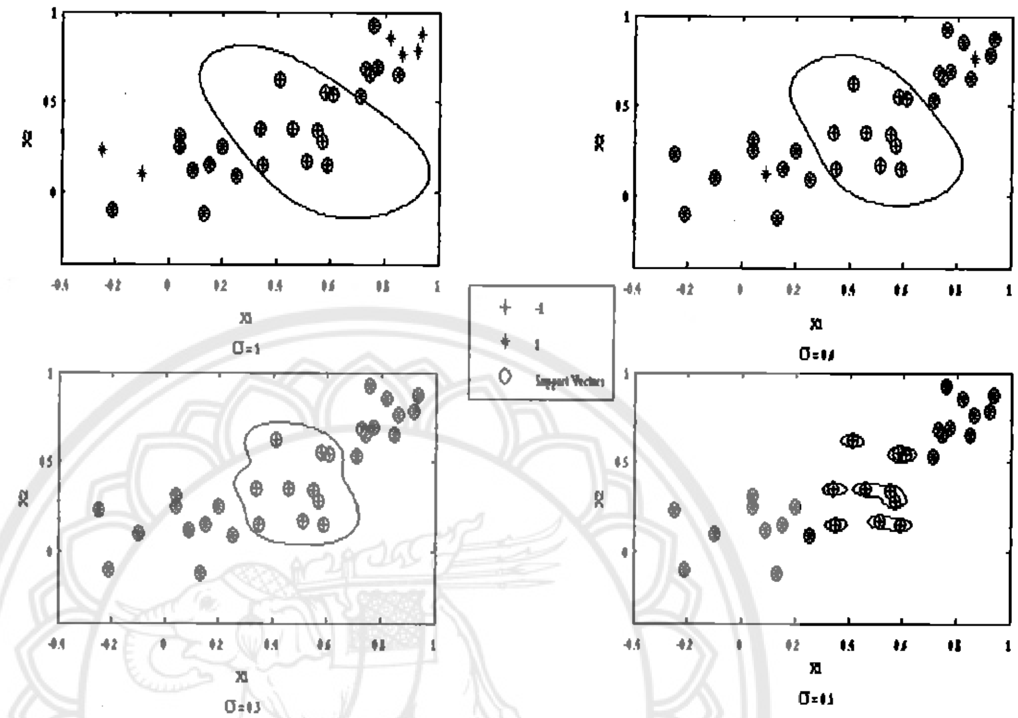

รูปที่ 3.12 การแบ่งแยกข้อมูลประเภทที่ 3 โดยใช้เรเดียลเบสิสเคอร์เนล

ผลที่ได้จากการทดลองนำข้อมูลไปทำการแบ่งแยกข้อมูลด้วยเรเดียลเบสิสเคอร์เนล ผลที่ได้คือ ข้อมูลประเภทที่ 3 เป็นข้อมูลที่มีค่าลบอยู่ระหว่างค่าบวกและมีความซับซ้อน สามารถแบ่งได้ด้วยเรเดียลเบสิสเคอร์เนล เมื่อมีการปรับค่าพารามิเตอร์ของเรเดียลเบสิสเคอร์เนลให้มีค่าลดลงก็จะทำให้มีการแบ่งแยกข้อมูลได้มีความละเอียดสูงขึ้น

3.3.3 การแบ่งแยกข้อมูลโดยใช้โพลิโนเมียลเคอร์เนล แบ่งข้อมูลประเภทที่ 3 แล้วการเปลี่ยนค่า b เป็นค่าต่างๆ ได้ดังรูปที่ 3.13

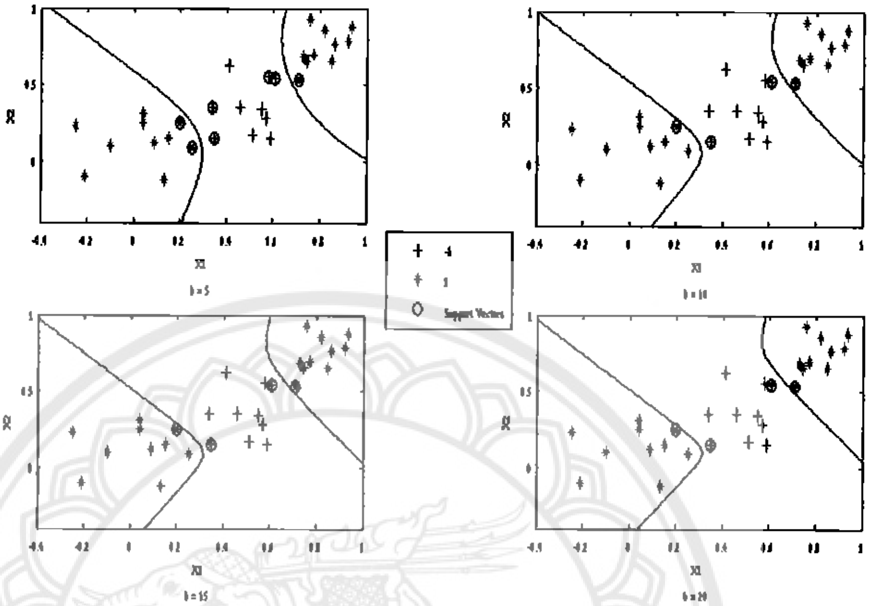

รูปที่ 3.13 การแบ่งแยกข้อมูลประเภท 3 โดยใช้โพลิโนเมียลเคอร์เนล

ผลที่ได้จากการทดลองนำข้อมูลไปทำการแบ่งแยกข้อมูลด้วยโพลิโนเมียลเคอร์เนล ผลที่ได้คือ ข้อมูลประเภทที่ 3 เป็นข้อมูลที่มีค่าลบอยู่ระหว่างค่าบวกและมีความซับซ้อนสามารถแบ่งได้ด้วยโพลิโนเมียลเคอร์เนล เมื่อมีการปรับค่าพารามิเตอร์ของโพลิโนเมียลเคอร์เนล ให้มีค่ามากขึ้นก็จะทำให้มีการแบ่งแยกข้อมูลได้มีความละเอียดสูงขึ้น

จากการที่ได้นำเคอร์เนลฟังก์ชันมาทำการทดสอบแบ่งแยกข้อมูลในประเภทต่างพบว่าเคอร์เนลเชิงเส้นจะแบ่งแยกข้อมูลได้เป็นเส้นตรง และจะไม่สามารถแบ่งแยกข้อมูลที่มีความซับซ้อนมากๆ เนื่องจากลักษณะของฟังก์ชันเส้นตรงไม่สามารถสร้างสมการแบ่งแยกที่ซับซ้อนได้ การนำเคอร์เนลฟังก์ชันเป็นแบบเรเดียลเบสิสมาแบ่งแยกข้อมูลพบว่าเป็นฟังก์ชันที่สามารถแบ่งแยกข้อมูลที่มีความซับซ้อนได้ โดยที่มีการกำหนดค่า σ และพบว่าเมื่อกำหนดค่า σ ให้มีค่าน้อยลงจะทำให้สามารถแบ่งแยกได้ดีขึ้นและไฮเปอร์เพลนที่ได้จะมีความซับซ้อนที่มากกว่า ส่วนการนำแบบเคอร์เนลฟังก์ชันแบบโพลิโนเมียลมาทำการแบ่งแยกข้อมูลจะพบว่ามีการแบ่งแยกได้ดีและสามารถแบ่งแยกข้อมูลที่มีความซับซ้อนได้เหมือนเช่นเดียวกับแบบเรเดียลเบสิส แต่มีการกำหนดค่า b ให้กับฟังก์ชันโพลิโนเมียลทำให้สามารถแบ่งแยกได้ดีเมื่อเพิ่มค่า b ให้มีค่ามากขึ้น แต่ถ้ามากไปก็อาจจะทำการ

แบ่งแยกไม่ได้ด้วยดังผลการทดลองที่เกิดขึ้น ในบทต่อไปจะนำ 3 วิธีดังกล่าวไปใช้ในการแบ่งแยกการขันสกรู

บทที่ 4

การทดลองแบ่งแยกการขันสกรูด้วยวิธีเอสวีเอ็ม

แรงที่เกิดขึ้นในการขันสกรูทั้งแบบสมบูรณ์และไม่สมบูรณ์จะถูกเก็บข้อมูล เพื่อนำมาทำการแบ่งแยกด้วยวิธีเอสวีเอ็ม แต่ก่อนที่จะนำมาทำการแบ่งแยกจะต้องนำข้อมูลมาทำการประมวลผลในเบื้องต้น (Pre-processing) เสียก่อน เพื่อให้เหมาะสมกับการใช้งาน การแบ่งแยกด้วยวิธีเอสวีเอ็มจะมีอยู่ 2 ขั้นตอนคือ ขั้นตอนสอน (Training) เพื่อที่จะได้มาซึ่งสมการการแบ่งแยก และขั้นตอนทดสอบ (Validation) เพื่อทดสอบดูประสิทธิภาพของสมการการแบ่งแยกที่ได้ ดังนั้นข้อมูลที่ถูกเก็บค่ามาจะถูกแบ่งเป็น 2 กลุ่มคือกลุ่มที่ใช้สอนและกลุ่มที่ใช้ทดสอบ ในการทำโครงนี้ได้ข้อมูลสอน 200 ข้อมูล และข้อมูลทดสอบ 100 ข้อมูล ในแต่ละหนึ่งข้อมูลของการขันสกรูจะถูกเก็บค่ามา 125 ข้อมูล (125 แอททริบิว) และแบ่งกลุ่มของข้อมูลว่าเป็นชนิดใด (+1 เป็นการขันแบบสมบูรณ์ และ -1 เป็นการขันแบบไม่สมบูรณ์)

4.1 ลักษณะของแรงที่เกิดขึ้นในการขันสกรู

สกรูที่ถูกขันเรียบร้อยแล้วเมื่อเขียนกราฟแรงระหว่างการขันจะได้ 2 ลักษณะคือการขันแบบสมบูรณ์และแบบไม่สมบูรณ์แสดงดังรูปที่ 4.1 จากข้อมูลทั้ง 2 ชนิดจะเห็นได้ว่าลักษณะกระแสที่ใช้ในการขันสกรูมีลักษณะที่แตกต่างกัน นั่นคือการขันที่สมบูรณ์จะมีกระแสที่ต่ำในช่วงแรก และเพิ่มขึ้นอย่างรวดเร็วจนมีค่าคงที่ในระยะเวลาหนึ่งของช่วงท้าย ส่วนการขันที่ไม่สมบูรณ์จะมีกระแสที่มีรูปแบบอยู่ 3 ชนิดนั่นคือ ค่าคงที่ตลอด คงที่แล้วเพิ่มขึ้นในช่วงท้ายแต่ยังมีการแกว่งของกระแส และเพิ่มขึ้นต่อเนื่อง ซึ่งลักษณะที่แตกต่างกันนี้สามารถนำไปแบ่งแยกชนิดของข้อมูลได้ต่อไป

อย่างไรก็ตามข้อมูลการขันที่สมบูรณ์และไม่สมบูรณ์ซึ่งถือว่าอยู่ในอนุกรมเวลาที่ได้มานั้นยังไม่สามารถทำการแบ่งแยกได้ ต้องมีการแปลงข้อมูลเสียก่อนซึ่งจะใช้การแปลงข้อมูลอนุกรมเวลาให้อยู่ในรูปสี่เหลี่ยม (Rectangular representation) หลังจากผ่านการแปลงข้อมูลจะถูกเปลี่ยนให้อยู่ในรูปแอททริบิวที่จำกัดและสามารถนำไปแบ่งแยกต่อไปได้ ซึ่งสามาถนำไปวิเคราะห์ระบบที่ถูกเก็บข้อมูลรวมถึงสามารถทำนายลักษณะข้อมูลในอนาคตได้

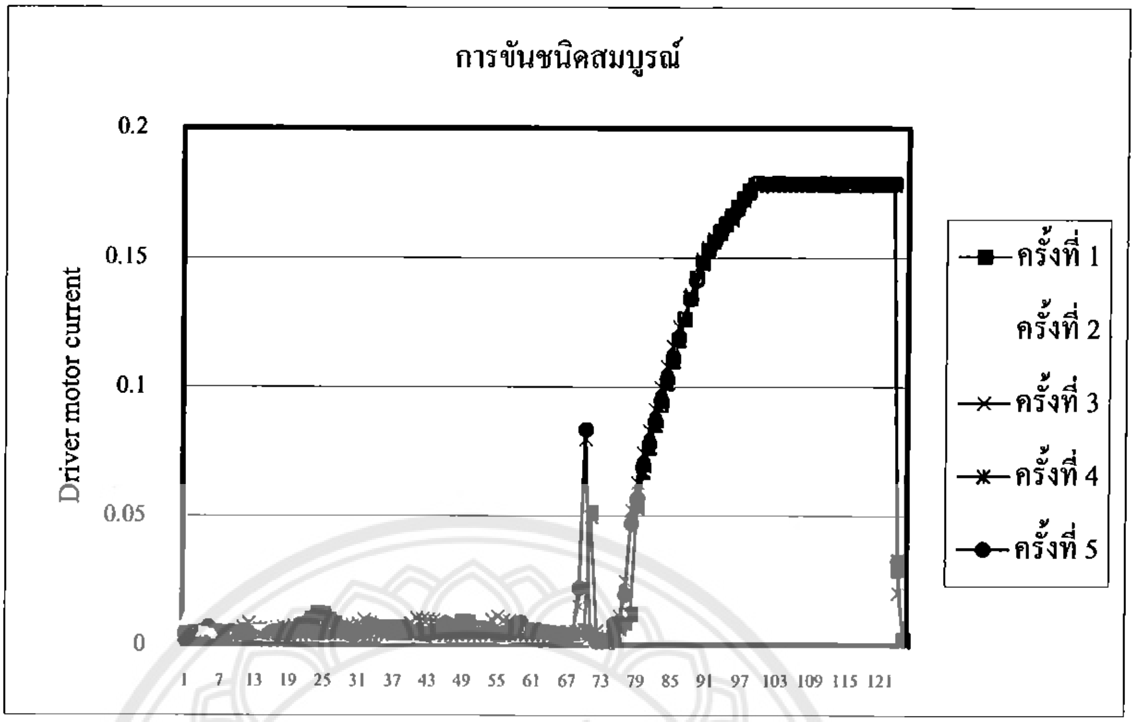

(ก)

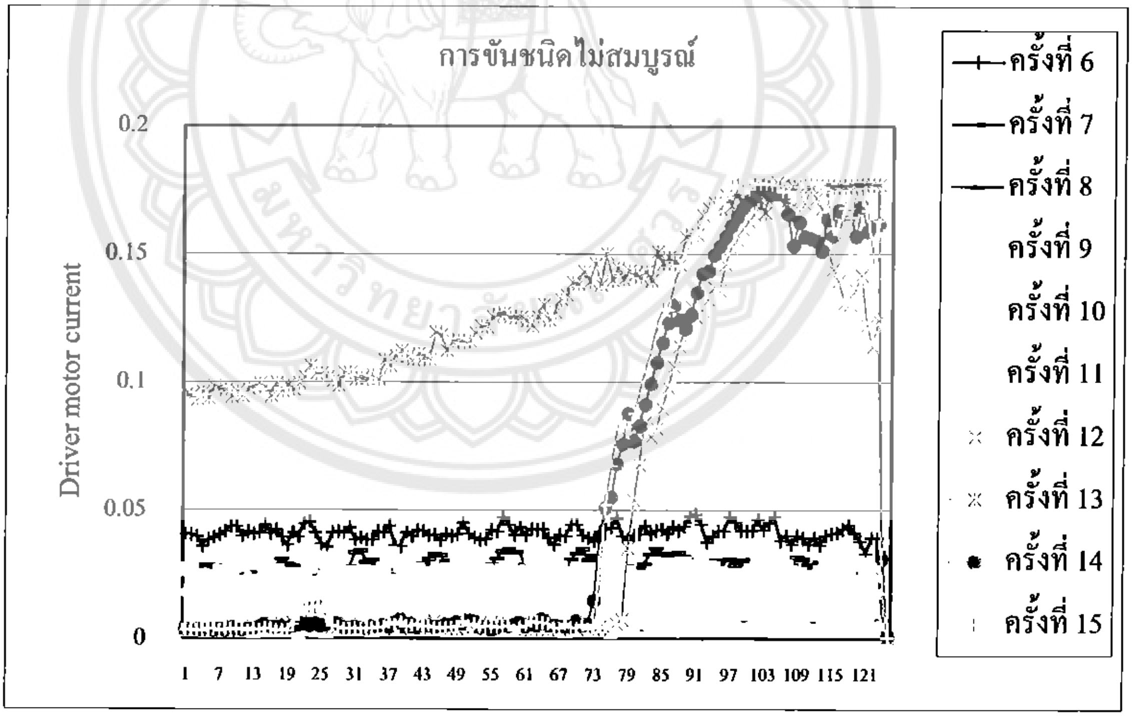

(ข)

รูปที่ 4.1 ตัวอย่างแรงที่เกิดขึ้นในการขันสกรูแบบ (ก) สมบูรณ์ และ (ข) ไม่สมบูรณ์

ตัวอย่างข้อมูลที่เก็บได้ตัวที่ 1 คือ

$$X_1=[\underbrace{-1.0478 \quad -1.2452 \quad -1.1568 \quad \cdots \quad -0.7904}_{125\ \text{แอททริบิว}}] \quad Y_1=[+1]$$

ข้อมูลสำหรับใช้สอนจะอยู่ในรูปเมตริกซ์ดังนี้

$$X\_train=\underbrace{\begin{bmatrix} -1.0478 & -1.2452 & \cdots & -0.7905 \\ -0.7321 & -0.8969 & \cdots & -1.0600 \\ \vdots & \vdots & \cdots & \vdots \\ -1.1404 & -1.0609 & \cdots & -0.6622 \end{bmatrix}}_{125\ \text{แอททริบิว}} \quad Y=\left.\begin{bmatrix} +1 \\ +1 \\ \vdots \\ -1 \end{bmatrix}\right\}200\ \text{ข้อมูล}$$

ข้อมูลสำหรับใช้ทดสอบจะอยู่ในรูปแบบเมตริกซ์ดังนี้

$$X\_test=\underbrace{\begin{bmatrix} -0.9499 & -0.5590 & \cdots & -1.2787 \\ -0.8970 & -1.2022 & \cdots & -0.8123 \\ \vdots & \vdots & \cdots & \vdots \\ -0.8970 & -1.2022 & \cdots & -0.8284 \end{bmatrix}}_{125\ \text{แอททริบิว}} \quad Y=\left.\begin{bmatrix} +1 \\ +1 \\ \vdots \\ -1 \end{bmatrix}\right\}100\ \text{ข้อมูล}$$

จากตัวอย่างข้อมูลที่แสดงไว้ จะเห็นว่าค่าไม่เหมาะสมนั่นคือมีค่าที่น้อยมาก จะต้องมีการทำให้เป็นบรรทัดฐาน (Normolise) เสียก่อน ในที่นี้จะปรับค่าข้อมูลให้อยู่ระหว่าง [-1, +1] โดยค่าข้อมูลที่น้อยที่สุดจะถูกปรับค่าให้เป็น -1 และค่าข้อมูลที่มากที่สุดจะถูกปรับค่าให้เป็น +1

ในการสร้างข้อมูลสำหรับการแบ่งแยกด้วยวิธีเอสวีเอ็มจะดูผลของจำนวนแอททริบิวด้วย ถ้ามีการปรับให้จำนวนแอททริบิวน้อยลง (น้อยกว่า 125) จะทำให้ผลการแบ่งแยกเป็นอย่างไร ดังนั้นจึงมีการสร้างข้อมูลขึ้นมาอีก 4 กลุ่มซึ่งมีจำนวนแอททริบิวเป็น 60, 40, 30 และ 20 โดยอาศัยการเฉลี่ยข้อมูลทุกๆ 2, 3, 4 และ 6 แอททริบิว ดังนั้นข้อมูลที่ใช้ในการสอนและทดสอบการแบ่งด้วยวิธีเอสวีเอ็มจะมี 5 กลุ่มดังนี้

1. ข้อมูลประเภทที่ 1: จำนวนแอททริบิว 125 แอททริบิว
2. ข้อมูลประเภทที่ 2: จำนวนแอททริบิว 60 แอททริบิว
3. ข้อมูลประเภทที่ 3: จำนวนแอททริบิว 40 แอททริบิว
4. ข้อมูลประเภทที่ 4: จำนวนแอททริบิว 30 แอททริบิว
5. ข้อมูลประเภทที่ 5: จำนวนแอททริบิว 20 แอททริบิว

4.2 การแบ่งแยกแรงด้วยวิธีเอสวีเอ็ม

ในส่วนนี้ข้อมูลทั้ง 5 กลุ่มที่ได้จากหัวข้อที่ 4.1 ถูกนำมาแบ่งแยกด้วยวิธีเอสวีเอ็มว่าการขันสกรูเป็นแบบใด สมบูรณ์หรือไม่สมบูรณ์ โดยใช้ทฤษฎีของเอสวีเอ็มได้แสดงไว้ในบทที่ 2 เนื่องจากลักษณะแรงทั้ง 2 ชนิดมีลักษณะที่แตกต่างกันอย่างเห็นได้ชัด ดังนั้นการแบ่งแยกที่ใช้จะเป็นแบบไม่อนุญาตให้มีการผิดกลุ่ม และก่อนหน้าที่จะเริ่มการสอนเอสวีเอ็มให้หาไฮเปอร์เพลนที่เหมาะสมจะต้องมีการเลือกเคอร์เนลฟังก์ชันและค่าพารามิเตอร์ที่เกี่ยวข้องเสียก่อน ซึ่งเป็นการเลือกใน 3 ฟังก์ชันที่แสดงไว้ในหัวข้อ 2.2 และแผนผังการแบ่งแยกแรงด้วยวิธีเอ็สวีเอ็มแสดงได้ดังรูปที่ 3.4 ซึ่งในขั้นตอนนี้สิ่งที่ได้คือค่าพารามิเตอร์ σ และ b ซึ่งถูกคำนวณด้วยการเขียนโปรแกรมแมทแลปสามารถนำไปสร้างเป็นฟังก์ชันการตัดสินใจได้ตามสมการที่ (2.25) หรือเรียกอีกอย่างว่าไฮเปอร์เพลน

ขั้นตอนต่อไปจะเป็นการทดสอบซึ่งแผนผังในขั้นตอนนี้แสดงดังภาพที่ 3.4 โดยจะนำข้อมูลที่เตรียมไว้สำหรับใช้ทดสอบมาใส่ในฟังก์ชันตัดสินใจ ค่าที่ได้จากการคำนวณด้วยโปรแกรมแมทแลป (+1 เป็นการขันแบบสมบูรณ์ และ -1 เป็นการขันแบบไม่สมบูรณ์) จะเป็นค่าที่เอสวีเอ็มตัดสินใจว่าแรงที่ใช้ในการขันสกรูที่กำลังทำนายนั้นเป็นการขันชนิดใด ค่าที่ได้นี้จะนำมาเปรียบเทียบกับค่ากลุ่มที่ได้จากการเก็บข้อมูล ซึ่งถ้าค่ากลุ่มทั้งสองชนิดมีค่าตรงกันหรือความแตกต่างมีค่าเป็นศูนย์หมายถึงเอสวีเอ็มทำนายกลุ่มหรือแบ่งกลุ่มได้ถูกต้อง นอกจากนั้นค่าความแตกต่างนี้ยังสามารถนำมาคำนวณประสิทธิภาพในการแบ่งแยกได้ซึ่งในโครงงานนี้แสดงออกมาเป็นค่าเปอร์เซ็นต์การผิดกลุ่ม ค่าน้อยแสดงถึงประสิทธิภาพที่ดีในการแบ่งแยกด้วยเอสวีเอ็ม

4.3 ผลการแบ่งแยกด้วยวิธีเอสวีเอ็ม

ประสิทธิภาพของการแบ่งแยกด้วยวิธีเอสวีเอ็มถูกแสดงด้วยค่าเปอร์เซ็นต์การผิดกลุ่ม ซึ่งค่าน้อยจะหมายถึงประสิทธิภาพที่ดีในการทำนายแรงในการขันสกรูว่าเป็นการขันแบบสมบูรณ์หรือไม่สมบูรณ์ ผลที่ได้จะแสดงเปอร์เซ็นต์การผิดกลุ่มของข้อมูลทั้ง 5 ประเภทโดยทำการทดสอบกับเคอร์เนลฟังก์ชัน 3 ชนิด และมีการเปลี่ยนค่าพารามิเตอร์ของเคอร์เนลฟังก์ชันนั้นๆ เพื่อทดสอบว่าค่าพารามิเตอร์ที่ควรจะเป็นมีค่าเท่าใด

4.3.1 การแบ่งแยกด้วยวิธีเอสวีเอ็มโดยใช้เคอร์เนลเชิงเส้น

ผลที่ได้จากการแบ่งแยกข้อมูลทั้ง 5 ประเภทโดยใช้เคอร์เนลเชิงเส้นนั้น ข้อมูลทั้ง 5 ประเภทมีเปอร์เซ็นต์การผิดกลุ่ม (Missclass) ที่ดีที่สุดในการแบ่งนี้คือ 6% เท่ากันดังแสดงในตารางที่ 4.1

ตารางที่ 4.1 ผลการแบ่งแยกโดยใช้เคอร์เนลเชิงเส้น

Linear Kernel				
ข้อมูล ประเภทที่ 1	ข้อมูล ประเภทที่ 2	ข้อมูล ประเภทที่ 3	ข้อมูล ประเภทที่ 4	ข้อมูล ประเภทที่ 5
missclass	missclass	missclass	missclass	missclass
6%	6%	6%	6%	6%

4.3.2 การแบ่งแยกด้วยวิธีเอสวีเอ็มโดยใช้เรเดียลเบสิสเคอร์เนล

ผลที่ได้จากการแบ่งแยกข้อมูลทั้ง 5 ประเภทโดยการใช้เรเดียลเบสิสเคอร์เนลนั้น เปอร์เซ็นต์การผิดกลุ่มของข้อมูลทั้ง 5 ประเภทนั้นขึ้นอยู่กับการปรับค่าพารามิเตอร์ σ ให้เหมาะสมกับข้อมูลประเภทนั้นๆ ค่าพารามิเตอร์ที่เหมาะสมของข้อมูลประเภทที่ 1 คือ 10 กับ 15 โดยโดยมีเปอร์เซ็นต์การผิดกลุ่ม คือ 6% ค่าพารามิเตอร์ที่เหมาะสมของข้อมูลประเภทที่ 2 คือ 5 กับ 10 โดยมีเปอร์เซ็นต์การผิดกลุ่มคือ 6% ค่าพารามิเตอร์ที่เหมาะสมของข้อมูลประเภทที่ 3 คือ 2 กับ 5 โดยมีเปอร์เซ็นต์การผิดกลุ่มคือ 6% ค่าพารามิเตอร์ที่เหมาะสมของข้อมูลประเภทที่ 4 คือ 1.5, 2 และ 5 โดยมีเปอร์เซ็นต์การผิดกลุ่มคือ 6% ค่าพารามิเตอร์ที่เหมาะสมของข้อมูลประเภทที่ 5 คือ 1, 1.5, 2 และ 5 โดยเปอร์เซ็นต์การผิดกลุ่มคือ 6% ดังแสดงในตารางที่ 4.2 แต่จากการทำการแบ่งแยกพบว่าค่าพารามิเตอร์ส่วนมากจะอยู่ในช่วง 10-15 จึงทำให้มีการเลือกค่าพารามิเตอร์ถึง 25 เท่านั้นเพื่อเปรียบเทียบเท่านั้น

ตารางที่ 4.2 การแบ่งแยกโดยใช้เรเดียลเบสิสเคอร์เนล

Radial Basis Kernel					
ข้อมูล / พารามิเตอร์ σ	ข้อมูลประเภทที่ 1	ข้อมูลประเภทที่ 2	ข้อมูลประเภทที่ 3	ข้อมูลประเภทที่ 4	ข้อมูลประเภทที่ 5
	missclass	missclass	missclass	missclass	missclass
0.001	8%	10%	8%	8%	8%
0.005	8%	8%	8%	8%	8%
0.01	8%	8%	8%	8%	8%
0.05	8%	8%	8%	8%	8%
0.1	8%	8%	8%	8%	8%
0.15	8%	8%	8%	8%	8%
0.3	8%	8%	8%	8%	8%
0.5	8%	8%	8%	8%	8%
1	8%	8%	8%	7%	6%
1.5	8%	8%	7%	6%	6%
2	8%	7%	6%	6%	6%
5	7%	6%	6%	6%	6%
10	6%	6%	7%	7%	10%
15	6%	10%	10%	10%	10%
20	8%	10%	10%	10%	10%
25	10%	10%	10%	10%	10%

4.3.3 การแบ่งแยกด้วยวิธีเอสวีเอ็มโดยใช้โพลิโนเมียลเคอร์เนล

ผลที่ได้จากการแบ่งแยกข้อมูลทั้ง 5 ประเภทโดยการใช้โพลิโนเมียลเคอร์เนล เปอร์เซ็นต์การผิดกลุ่มและประสิทธิภาพของข้อมูลทั้ง 5 ประเภทขึ้นอยู่กับการปรับค่าพารามิเตอร์ b ให้เหมาะสมกับข้อมูลประเภทนั้นๆ ค่าพารามิเตอร์ที่เหมาะสมของข้อมูลประเภทที่ 1 คือ 1, 2 และ 3 โดยมีเปอร์เซ็นต์การผิดกลุ่มคือ 6% ค่าพารามิเตอร์ที่เหมาะสมของข้อมูลประเภทที่ 2 คือ 1, 2, 3 และ 4โดยมีเปอร์เซ็นต์การผิดกลุ่มคือ 6 เปอร์เซ็นต์ ค่าพารามิเตอร์ที่เหมาะสมของข้อมูลประเภทที่ 3 คือ 1, 2, 3 และ 4 โดยมีเปอร์เซ็นต์การผิดกลุ่มคือ 6% ค่าพารามิเตอร์ที่เหมาะสมของข้อมูลประเภทที่ 4 คือ 1, 2, 3, 4 และ 5 ค่าพารามิเตอร์ที่เหมาะสมของข้อมูลประเภทที่ 5 คือ 1, 2, 3, 4, 5 และ 6 โดยมีเปอร์เซ็นต์การผิดกลุ่มคือ 6% ดังแสดงในตารางที่ 4.3 ถ้ามีการกำหนดค่าพารามิเตอร์เกิน 10 โปรแกรมจะไม่สามารถทำการแบ่งแยกข้อมูลได้ ดังนั้นการทดลองจึงใช้ค่า b ไม่เกิน 10

ตารางที่ 4.3 ผลการแบ่งแยกโดยใช้โพลิโนเมียลเคอร์เนล

Polynomial Kernel					
ข้อมูล / พารามิเตอร์ b	ข้อมูล ประเภทที่ 1	ข้อมูล ประเภทที่ 2	ข้อมูล ประเภทที่ 3	ข้อมูล ประเภทที่ 4	ข้อมูล ประเภทที่ 5
	missclass	missclass	missclass	missclass	missclass
1	6%	6%	6%	6%	6%
2	6%	6%	6%	6%	6%
3	6%	6%	6%	6%	6%
4	41%	6%	6%	6%	6%
5	90%	21%	10%	6%	6%
6	90%	90%	90%	13%	6%
7	90%	90%	48%	12%	16%
8	90%	10%	11%	10%	30%
9	90%	90%	90%	90%	29%
10	90%	10%	90%	10%	10%

4.4 การเปรียบเทียบวิธีเอสวีเอ็มกับแบบโครงข่ายประสาท

1. ข้อดีและข้อเสียของวิธีเอสวีเอ็ม

ข้อดี

1. ในการแบ่งแยกข้อมูลโดยการใช้วิธีเอสวีเอ็มจะมีการปรับค่าพารามิเตอร์เพื่อที่จะหาเส้นแบ่งได้ง่ายกว่าระบบโครงข่าย
2. วิธีเอสวีเอ็มสามารถเลือกใช้ฟังก์ชันในการแบ่งแยกข้อมูลที่เหมาะสมกับประเภทของข้อมูลได้
3. วิธีเอสวีเอ็มเคอร์เนลฟังก์ชันแบบเชิงเส้นสามารถแบ่งแยกข้อมูลได้ทั้งแบบข้อมูลมากและน้อยได้เท่ากันและดีที่สุดในโครงงานนี้
4. ถ้าหากจำนวนข้อมูลมีน้อยจะทำให้แบ่งแยกได้ดีและเลือกค่าพารามิเตอร์ได้หลายค่า

ข้อเสีย

1. ในการแบ่งแยกข้อมูลโดยการใช้วิธีเอสวีเอ็มจะมีเปอร์เซ็นต์การผิดกลุ่มมากกว่าระบบโครงข่าย
2. ต้องมีการกำหนดค่าพารามิเตอร์ให้กับเคอร์เนลฟังก์ชันแบบเรเดียลเบสิสเคอร์เนลและโพลิโนเมียลเคอร์เนลให้เหมาะสม ถ้าหากมีมากหรือน้อยเกินไปจะทำให้ได้เปอร์เซ็นต์การผิดกลุ่ม นั้นมาก
3. ถ้าหากมีการกำหนดค่าพารามิเตอร์ที่มากเกินไปสำหรับเคอร์เนลฟังก์ชันแบบโพลิโนเมียลเคอร์เนล จะทำให้ไม่สามรถทำการแบ่งกลุ่มได้
4. เคอร์เนลฟังก์ชันแบบเรเดียลเบสิสเคอร์เนลและโพลิโนเมียลเคอร์เนล ถ้าหากจำนวนข้อมูลมีมากจะทำให้มีการแบ่งกลุ่มได้น้อยและค่าพารามิเตอร์ที่ใช้ก็มีน้อยด้วยเช่นกัน

2. ข้อดีและข้อเสียของระบบโครงข่ายประสาทเทียม

ข้อดี

1. แสดงค่าเปอร์เซ็นต์ผิดกลุ่มได้น้อยที่สุด
2. สามารถแบ่งแยกข้อมูลที่มีความละเอียดมาก
3. มีความหลากหลายรูปแบบ
4. สามารถประมาณค่าพารามิเตอร์ต่างๆไม่ว่าจะเป็นค่าการเรียนรู้ ค่าจุดซ้อนเพื่อหาค่าเปอร์เซ็นต์ผิดกลุ่มน้อยที่สุด
5. โครงข่ายประสาทเทียมเป็นวิธีที่ได้รับความนิยมสูง

<u>ข้อเสีย</u>

1. มีความยุ่งยากในการปรับค่าพารามิเตอร์ เพื่อหาค่าที่เหมาะสม
2. ยิ่งเพิ่มจำนวนชั้นจะส่งผลต่อเวลาในการประมวลผลนานขึ้น
3. เนื่องด้วยในโครงข่ายประสาทเทียม จะมีค่าสุ่มในระบบ จึงทำให้ต้องทำประมวลหลายครั้งเพื่อหาค่าเฉลี่ย

บทที่ 5
สรุปผลการแบ่งกลุ่มข้อมูลด้วยวิธีเอสวีเอ็ม

ในบทนี้เป็นการสรุปผลการแบ่งกลุ่มข้อมูลด้วยวิธีเอ็สวีเอ็ม ซึ่งทำการทดลองโดยเปลี่ยนเคอร์เนลฟังก์ชันนั่นคือเคอร์เนลฟังก์ชันแบบเคอร์เนลเชิงเส้น เรเดียลเบสิสเคอร์เนล และโพลิโนเมียลเคอร์เนล และค่าพารามิเตอร์ที่ใช้ในเคอร์เนลฟังก์ชันทั้ง 3 ประเภท ในการทดลองเพื่อดูผลที่เกิดขึ้นในการทำนายข้อมูลการขันแบบสมบูรณ์และไม่สมบูรณ์

5.1 ผลจากการใช้เคอร์เนลฟังก์ชันทั้งสามประเภท

1. เคอร์เนลฟังก์ชันแบบเคอร์เนลเชิงเส้น

เคอร์เนลเชิงเส้นนั้นเมื่อนำไปแบ่งแยกข้อมูลทั้ง 5 ประเภทผลที่ได้คือเปอร์เซ็นต์การผิดกลุ่มของข้อมูลแต่ละประเภทมีค่าเท่ากันหมดทุกประเภท แสดงว่าการใช้เคอร์เนลเชิงเส้นเหมาะสมกับข้อมูลทั้ง 5 ประเภท

2. เคอร์เนลฟังก์ชันแบบเรเดียลเบสิสเคอร์เนล

การใช้เรเดียลเบสิสเคอร์เนลนั้นถ้าข้อมูลมีจำนวนมากก็จะมีผลในการแบ่งแยกข้อมูลดังนั้นจึงต้องมีการปรับค่าพารามิเตอร์ σ ให้เหมาะสมกับข้อมูลประเภทนั้นๆ เพื่อให้เปอร์เซ็นต์การผิดกลุ่มมีค่าน้อยที่สุดเพื่อให้มีการแบ่งแยกข้อมูลได้ดีขึ้น เมื่อพารามิเตอร์มีค่ามากเกินไปหรือน้อยเกินไปจะทำให้เปอร์เซ็นต์การผิดกลุ่มมีค่ามาก ทำให้มีการแบ่งแยกข้อมูลได้ไม่ถูกต้องและถ้าข้อมูลมีจำนวนมากก็จะมีผลในการแบ่งแยกข้อมูล การใช้เรเดียลเบสิสเคอร์เนลเหมาะสมกับข้อมูลประเภทที่ 5 ที่ค่า σ มีค่าเท่ากับ 6%

3. เคอร์เนลฟังก์ชันแบบโพลิโนเมียลเคอร์เนล

การใช้โพลิโนเมียลเคอร์เนลนั้นถ้าข้อมูลมีจำนวนมากก็จะมีผลในการแบ่งแยกข้อมูลและต้องมีการปรับค่าพารามิเตอร์ b ให้เหมาะสมกับข้อมูลประเภทนั้นๆ เพื่อให้เปอร์เซ็นต์การผิดกลุ่มมีค่าน้อยที่สุดทำให้มีการแบ่งแยกข้อมูลได้ดีขึ้น เมื่อพารามิเตอร์มีค่ามากเกินไป จะทำให้เปอร์เซ็นต์การผิดกลุ่มนั้นมีค่ามาก จากการทดลองพบว่าทำให้มีการแบ่งแยกข้อมูลได้ไม่ถูกต้อง จากการทดลองพบว่าการใช้โพลิโนเมียลเคอร์เนลเหมาะสมกับข้อมูลประเภทที่ 5 ที่ค่า b มีค่าเท่ากับ 6%

5.2 ปัญหาและข้อเสนอแนะ

1. ค่าพารามิเตอร์ที่เหมาะสมที่ได้จากการทดลองเหมาะสมกับสกรูที่ใช้ในการทดลอง ในกาทำโครงงานมีเพียงแค่ชนิดเดียวเท่านั้นและรูที่ใช้ขันมีแค่ขนาดเดียว ถ้ามีการเปลี่ยนขนาดหรือรูของสกรู ค่าพารามิเตอร์ที่เหมาะสมจะต้องทำการทดลองเพื่อหาค่าที่ดีที่สุดใหม่ทั้งหมด

2. การทดลองด้วยวิธีเอสวีเอ็มสามารถประยุกต์ใช้กับงานให้หลากหลายมากขึ้นเช่น แบ่งแยกดีเอ็นเอผู้ป่วยมะเร็งเม็ดเลือดขาว ผู้ป่วยโรคหัวใจ เป็นต้น

5.3 แนวทางการพัฒนาโครงงานต่อไป

1. เพิ่มจำนวนข้อมูลให้มีมากขึ้นเพื่อทำให้การแบ่งแยกได้ชัดเจนยิ่งขึ้นและลดเปอร์เซ็นต์การผิดกลุ่มให้มีค่าน้อยลง

2. ทำการปรับข้อมูลให้ไม่เกินช่วง -1 กับ +1 เพื่อทำการลดเปอร์เซ็นต์การผิดกลุ่มให้น้อยลง เนื่องจากโครงงานนี้ยังมีบางข้อมูลที่ไม่อยู่ในช่วง -1 กับ +1 จึงทำให้มีเปอร์เซ็นต์การผิดกลุ่มที่มาก

3. ทำการปรับค่าพารามิเตอร์ให้ละเอียดมากยิ่งขึ้นเพื่อหาค่าเปอร์เซ็นต์การผิดกลุ่มที่น้อยที่สุด

เอกสารอ้างอิง

[1] ลัญฉกร วุฒิสิทธิกุลกิจ และคณะ"**การใช้งานโปรแกรม Matlab เบื้องต้น**", พิมพ์ครั้งที่ 3, สำนักพิมพ์แห่งจุฬาลงกรณ์มหาวิทยาลัย, 2551.

[2] C. Cortes and V. Vapnik. "**Support Vector Networks**", Machine Learning, 20: pages 273-297, 1995.

[3] S. Gunn. "**Support Vector Machine for Classification and Regression**", ISIS Technical Report, University of Southampton, UK, 1998.

[4] D. M. Etter. "**Introduction to Matlab for engineers and scientists**", 2002.

[5] T. Fletcher. " **Support Vector Machines Explained**", 2009.