

การประยุกต์ใช้ซินเนอรัลจิสติกนิวโรลเน็ตเวิร์ก ในการจำแนกข้อมูล

กิตติชัย ลวันยานนท์¹ และ อ้นสวา นิลรัตน์ศิริกุล²

มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี บางมด ทุ่งครุ กรุงเทพฯ 10140

บทคัดย่อ

การจำแนกข้อมูลเป็นส่วนหนึ่งของงานหลายชนิดที่พบในสาขาวิชาปัญญาประดิษฐ์ ซินเนอรัลจิสติกนิวโรลเน็ตเวิร์กเป็นแนวทางหนึ่งที่ได้รับการพัฒนาขึ้นสำหรับเพิ่มประสิทธิภาพของการจำแนกข้อมูล บทความวิจัยนี้ได้กล่าวถึงการพัฒนาซินเนอรัลจิสติกนิวโรลเน็ตเวิร์กแบบรวมผลลัพธ์และซินเนอรัลจิสติกนิวโรลเน็ตเวิร์กแบบเลือกผลลัพธ์ในการจำแนกข้อมูลผู้ป่วยโรคหัวใจ (Heart Disease Data) ที่มีแหล่งที่มาจาก Cleveland Database นิวโรลเน็ตเวิร์ก 5 โครงสร้างที่นำมาใช้คือมัลติเลเยอร์เพอร์เซพตรอน เจนเนอรัลไลซ์ฟีดฟอร์เวิร์ดเน็ตเวิร์ก มอดูล่าเน็ตเวิร์ก เรเดียนเบซิสฟังก์ชัน และจอร์แดนเน็ตเวิร์ก ผลการจำแนกข้อมูลที่ดีที่สุดของซินเนอรัลจิสติกนิวโรลเน็ตเวิร์กทั้ง 2 แนวทาง ได้นำมาเปรียบเทียบกับผลการจำแนกข้อมูลที่ดีที่สุดของนิวโรลเน็ตเวิร์กโครงสร้างเดียว

ผลจากการเปรียบเทียบสรุปได้ว่าซินเนอรัลจิสติกแบบเลือกผลลัพธ์ (ด้วยวิธีหาค่าสูงสุด) สามารถจำแนกข้อมูลได้ถูกต้องสูงสุด โครงการวิจัยนี้ยังแสดงให้เห็นถึงความสามารถของซินเนอรัลจิสติกนิวโรลเน็ตเวิร์กในการจำแนกข้อมูล และลดความไม่ชัดเจนของผลลัพธ์ โดยเฉพาะในกรณีที่มีข้อมูลปรับสอนค่อนข้างจำกัด

คำสำคัญ : การจำแนกข้อมูล / จอร์แดนเน็ตเวิร์ก / เจนเนอรัลไลซ์ฟีดฟอร์เวิร์ดเน็ตเวิร์ก / ซินเนอรัลจิสติกนิวโรลเน็ตเวิร์ก / นิวโรลเน็ตเวิร์ก / มอดูล่าเน็ตเวิร์ก / มัลติเลเยอร์เพอร์เซพตรอน / เรเดียนเบซิสฟังก์ชันเน็ตเวิร์ก / Cleveland Database / Heart Disease Data

¹ ผู้ช่วยศาสตราจารย์ คณะเทคโนโลยีสารสนเทศ

² นักวิจัย คณะเทคโนโลยีสารสนเทศ

Application of Synergistic Neural Networks in Data Classification

Kittichai Lavangnananda¹ and Unhawa Ninrutsirikun²

King Mongkut's University of Technology Thonburi, Bangmod, Toongkru, Bangkok 10140

Abstract

Classification is one of many tasks in Artificial Intelligence. Synergistic approach to classification by neural networks is a recent method which can be used to improve the accuracy in classification. This research work implemented Synergistic Neural Networks to classify Heart Disease Data from Cleveland Data Base. It adopted two known approaches to synergistic neural networks, namely summation and selection approaches. Five different types of neural networks had been selected in the synergy namely Multilayer Perceptron, Generalized Feedforward Networks, Modular Networks, Radial Basis Function Networks, and Jordan networks. Comparison was made among the best results from individual neural networks, from summation-typed synergistic neural networks and from selection-typed synergistic neural networks.

The result from the comparison revealed that the selection-typed synergistic neural networks (maximum method) yielded the best accuracy. This work demonstrated the ability of synergistic neural networks in improving accuracy and reduces ambiguity in classification, especially when number of samples in training data set is limited.

Keywords : Classification / Jordan Network / Generalized Feedforward Network / Synergistic Neural Networks / Neural Networks / Modular Network / Multilayer Perceptron / Radial Basis Function Network / Cleveland Data Base / Heart Disease Data

¹ Assistant Professor, School of Information Technology.

² Researcher, School of Information Technology.

1. บทนำ

การจำแนกข้อมูล หมายถึงกระบวนการในการจัดกลุ่มข้อมูลที่มีลักษณะความสำคัญร่วมกัน ให้เข้าเป็นสมาชิกของกลุ่มข้อมูลเดียวกัน ในทางปัญญาประดิษฐ์ (Artificial Intelligence) นิวรอลเน็ตเวิร์กจัดเป็นเทคนิคสำหรับการจำแนกข้อมูลที่ได้รับคามนิยมและประสบความสำเร็จเป็นอย่างมาก [1] เนื่องจากความสามารถในการเรียนรู้และปรับตัวตามข้อมูลที่ได้รับในการฝึกสอน อย่างไรก็ตาม ความซับซ้อนและข้อจำกัดของจำนวนข้อมูลตัวอย่างอาจส่งผลกระทบต่อประสิทธิภาพของการจำแนกข้อมูลโดยนิวรอลเน็ตเวิร์ก

บทความนี้เริ่มต้นจากการชี้แจงแนวทางในการปรับปรุงประสิทธิภาพของนิวรอลเน็ตเวิร์กด้วยแนวทางซินเนอร์จิสติกนิวรอลเน็ตเวิร์ก สรุปวรรณกรรมที่เกี่ยวข้อง รวมถึงการศึกษาเปรียบเทียบประสิทธิภาพระหว่างซินเนอร์จิสติกนิวรอลเน็ตเวิร์กกับนิวรอลเน็ตเวิร์กโครงสร้างเดี่ยว ในการจำแนกข้อมูลผู้ป่วยโรคหัวใจจากแหล่งข้อมูลมาตรฐานของ Cleveland Database

โครงการวิจัยนี้มีวัตถุประสงค์หลัก 4 ประการคือ

1. พัฒนาระบบคอมพิวเตอร์โดยใช้เทคนิคนิวรอลเน็ตเวิร์กกับการจำแนกข้อมูลผู้ป่วยโรคหัวใจที่แบ่งคลาสข้อมูลออกเป็น 4 คลาส
2. จัดประเภทซินเนอร์จิสติกนิวรอลเน็ตเวิร์กในงานวิจัยต่างๆ ที่นำแนวทางนี้มาประยุกต์ใช้
3. ศึกษาแนวทางซินเนอร์จิสติกนิวรอลเน็ตเวิร์กที่เหมาะสมในการจำแนกข้อมูลผู้ป่วยโรคหัวใจ
4. เปรียบเทียบประสิทธิภาพการจำแนกข้อมูลผู้ป่วยโรคหัวใจระหว่างแนวทางซินเนอร์จิสติกนิวรอลเน็ตเวิร์กกับนิวรอลเน็ตเวิร์กโครงสร้างเดี่ยว

2. ซินเนอร์จิสติกนิวรอลเน็ตเวิร์ก

ซินเนอร์จิสติก (Synergistic) คือลักษณะของระบบที่มีการทำงานร่วมกันขององค์ประกอบต่างๆ ตั้งแต่ 2 หน่วยขึ้นไป ซินเนอร์จิสติกนิวรอลเน็ตเวิร์ก [2] [3] (Synergistic Neural Networks) จึงเปรียบเสมือนระบบที่มีการทำงานร่วมกันของกลุ่มผู้เชี่ยวชาญด้านนิวรอลเน็ตเวิร์กที่มีความรู้และความชำนาญในการแก้ไขปัญหา โดยผู้เชี่ยวชาญแต่ละท่านอาจจะให้เหตุผลในการตัดสินใจที่แตกต่างกัน ดังนั้นการตัดสินใจที่เกิดจากผู้เชี่ยวชาญหลายคน จึงเป็นการเพิ่มรายละเอียดของเหตุผลที่ใช้ในการตัดสินใจ ซึ่งน่าจะให้ผลลัพธ์ที่ดีกว่าการตัดสินใจของผู้เชี่ยวชาญเพียงท่านเดียว วิธีการแก้ไขปัญหาของซินเนอร์จิสติกนิวรอลเน็ตเวิร์กจะใช้นิวรอลคอมไบเนอร์ (Neural Combiner) ซึ่งเปรียบเสมือนตัวประมวลผลที่อาจจะเป็นโปรแกรมคอมพิวเตอร์หรือนิวรอลเน็ตเวิร์กอีกโครงสร้างหนึ่งก็ได้

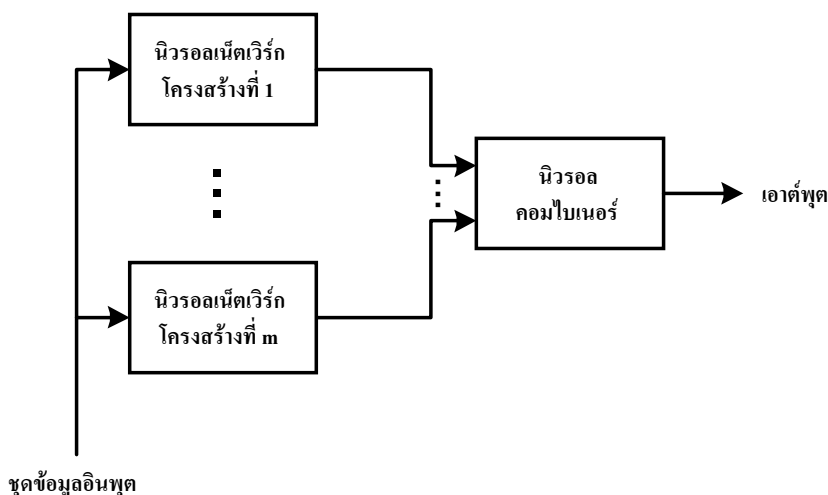
เนื่องจากซินเนอร์จิสติกนิเวรอลเน็ตเวิร์กเป็นเทคนิคใหม่ที่ยังไม่มีการนำไปประยุกต์ใช้มากนัก จึงยังไม่พบแนวทางในการจัดแบ่งประเภทอย่างชัดเจน จากการศึกษาและรวบรวมผลงานวิจัยที่เกี่ยวข้องสามารถจัดแบ่งประเภทของซินเนอร์จิสติกนิเวรอลเน็ตเวิร์กออกเป็น 2 ประเภทหลัก โดยแบ่งตามลักษณะของข้อมูลที่ใช้ในการปรับสอนและแนวทางการหาผลลัพธ์

1. การจัดประเภทตามข้อมูลที่ใช้

ในการจัดประเภทของซินเนอร์จิสติกนิเวรอลเน็ตเวิร์กโดยพิจารณาตามข้อมูลอินพุตที่ใช้สามารถแบ่งได้เป็น 2 ชนิดดังนี้

1.1 ข้อมูลอินพุตชุดเดียว

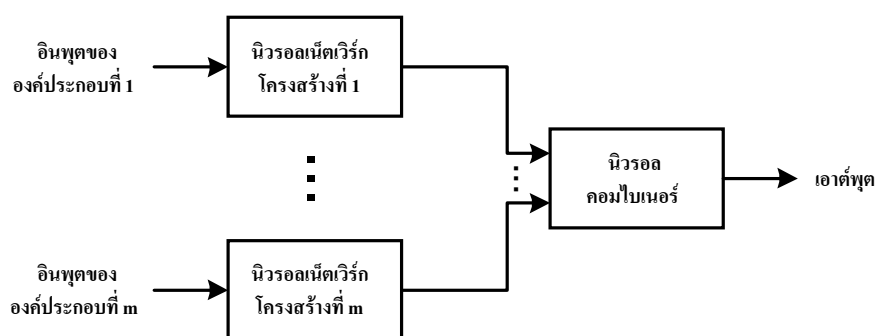
ซินเนอร์จิสติกลักษณะนี้จะมีข้อมูลอินพุตชุดเดียว โดยไม่มีการแตกองค์ประกอบของข้อมูลนิเวรอลเน็ตเวิร์กโครงสร้างเดี่ยวแต่ละโครงสร้างจะเรียนรู้ข้อมูลชุดเดียวกัน ซินเนอร์จิสติกประเภทข้อมูลอินพุตชุดเดียวแสดงได้ดังรูปที่ 1



รูปที่ 1 ซินเนอร์จิสติกประเภทข้อมูลอินพุตชุดเดียว

1.2 ข้อมูลอินพุตหลายชุด

ซินเนอร์จิสติกลักษณะนี้องค์ประกอบของข้อมูลอินพุตจะแตกออกเป็นหลายองค์ประกอบหรือใช้ข้อมูลอินพุตมากกว่า 1 ชุด ข้อมูลอินพุตอาจถูกดำเนินการ preprocess เพื่อลดความแปรปรวน (Noise) ของข้อมูลหรือเพื่อให้ได้คุณลักษณะเด่นอื่นๆ ของข้อมูล ตัวอย่างเช่น ข้อมูลอุณหภูมิ (ซึ่งสามารถแตกองค์ประกอบของข้อมูลออกเป็น 2 ส่วน คือข้อมูลค่าเฉลี่ยเคลื่อนที่ของอุณหภูมิและข้อมูลค่าผลต่างของอุณหภูมิกับค่าเฉลี่ยเคลื่อนที่) นิเวรอลเน็ตเวิร์กโครงสร้างเดี่ยว แต่ละโครงสร้างจะเรียนรู้องค์ประกอบของข้อมูลแต่ละส่วน ตัวอย่างของนิเวรอลคอมไบเนอ์ของข้อมูลลักษณะนี้ได้แก่ การหาผลรวม (Summation) และการคูณผลลัพธ์ (Product) รูปที่ 2 แสดงแนวทางซินเนอร์จิสติกประเภทข้อมูลอินพุตหลายชุด



รูปที่ 2 ชินเนอร์จิสติกประเภทข้อมูลอินพุตหลายชุด

2. การจัดประเภทตามการหาผลลัพธ์

ในการจัดประเภทของชินเนอร์จิสติกนิวรอนเน็ตเวิร์กโดยพิจารณาตามแนวทางในการหาผลลัพธ์สามารถแบ่งได้เป็น 2 ชนิดคือ ชินเนอร์จิสติกแบบรวมผลลัพธ์และชินเนอร์จิสติกแบบเลือกผลลัพธ์

กำหนดให้สัญลักษณ์ที่แสดงในสมการทางคณิตศาสตร์ใช้แทนค่าดังต่อไปนี้

S_j = เอาต์พุตของระบบ

c_{ij} = เอาต์พุตของแอททริบิวท์ j ของนิวรอนเน็ตเวิร์กโครงสร้างที่ i

c_{kj} = เอาต์พุตของแอททริบิวท์ j ของนิวรอนเน็ตเวิร์กโครงสร้างที่ k

O_{kj} = เอาต์พุตของแอททริบิวท์ที่อยู่ในตำแหน่งมัธยฐาน

v_{ij} = คะแนนที่ได้รับของแอททริบิวท์ j ของนิวรอนเน็ตเวิร์กโครงสร้างที่ i

m = จำนวนโครงสร้างทั้งหมด

n = จำนวนแอททริบิวท์ทั้งหมด

2.1 ชินเนอร์จิสติกแบบรวมผลลัพธ์

ชินเนอร์จิสติกแบบรวมผลลัพธ์ เป็นระบบที่ใช้แนวทางการหาผลลัพธ์สุทธิของการทำงาน โดยนำผลลัพธ์ของนิวรอนเน็ตเวิร์กโครงสร้างเดี่ยวทุกโครงสร้างมารวมผล (Combine) ด้วยนิวรอนคอมไบเนอร์ ตัวอย่างของนิวรอนคอมไบเนอร์สำหรับแนวทางนี้ได้แก่ การหาผลรวม (Summation) และการคูณผลลัพธ์ (Product) ซึ่งมีรายละเอียดดังต่อไปนี้

2.1.1 การหาผลรวม (Summation)

ชุดข้อมูลผลลัพธ์ของนิวรอนเน็ตเวิร์กแต่ละโครงสร้างถูกส่งไปยังนิวรอนคอมไบเนอร์ เพื่อรวมผลของระบบในแต่ละแอททริบิวท์ โดยผลลัพธ์ของระบบคือผลรวมของค่าที่ได้รับในแต่ละนิวรอนเน็ตเวิร์ก อธิบายการหาผลรวมได้ด้วยสมการต่อไปนี้

$$S_j = \sum_{i=1}^m c_{ij} \quad (1 \leq j \leq n) \quad (1)$$

2.1.2 การคูณผลลัพท์ (Product)

การคูณผลลัพท์ เป็นแนวทางที่คล้ายกับการรวมผลลัพท์ โดยนิรอลคอมไบเนอร์จะคูณผลลัพท์ของนิรอลเน็ตเวิร์กโครงสร้างเดี่ยวแยกตามแอททริบิวท์ โดยผลลัพท์ของระบบคือผลคูณของค่าที่ได้รับในแต่ละนิรอลเน็ตเวิร์ก อธิบายการหาผลคูณได้ด้วยสมการต่อไปนี้

$$S_j = \prod_{i=1}^m c_{ij} \quad (1 \leq j \leq n) \quad (2)$$

2.2 ซินเนอร์จิสติกแบบเลือกผลลัพท์

ผลลัพท์ของนิรอลเน็ตเวิร์กโครงสร้างเดี่ยวทุกโครงสร้างถูกส่งมาที่นิรอลคอมไบเนอร์เพื่อพิจารณาคัดเลือกผลลัพท์ที่ถือว่าเป็นค่าที่ดีที่สุดในบรรดาค่าของผลลัพท์ต่างๆ ในแต่ละโครงสร้างเดี่ยวของข้อมูล การคัดเลือกผลลัพท์จะใช้หลักการทางคณิตศาสตร์และสถิติอันได้แก่ การหาค่าสูงสุด (Maximum) การลงคะแนน (Voting) และการหามัธยฐาน (Median) รายละเอียดของวิธีดังกล่าวมีดังนี้

2.2.1 การหาค่าสูงสุด (Maximum)

ผลลัพท์ที่ได้จากนิรอลเน็ตเวิร์กโครงสร้างเดี่ยวแต่ละโครงสร้างจะถูกนำไปเปรียบเทียบเพื่อหาค่าสูงสุด แอททริบิวท์ที่ให้ค่าสูงสุดคือผลลัพท์ของระบบ อธิบายการหาค่าสูงสุดได้ด้วยสมการต่อไปนี้

$$S_j = c_{ij} \mid c_{ij} > c_{kj} \quad \forall k, k \neq i \quad (1 \leq i, k \leq m) \quad (1 \leq j \leq n) \quad (3)$$

2.2.2 การลงคะแนน (Voting)

การลงคะแนน เป็นแนวทางที่จะต้องทำการลงคะแนนให้กับแอททริบิวท์ที่ให้ค่าสูงสุดของนิรอลเน็ตเวิร์กแต่ละโครงสร้าง อธิบายวิธีการลงคะแนนได้ด้วยสมการต่อไปนี้

$$v_{ij} = \begin{cases} 1 & \text{if } c_{ij} > c_{kj} \quad \forall k, k \neq i \quad (1 \leq i, k \leq m) \quad (1 \leq j \leq n) \\ 0 & \text{Otherwise} \end{cases} \quad (4)$$

เมื่อลงคะแนนครบทุกโครงสร้างแล้วจะมีขั้นตอนการคัดเลือกผลลัพท์โดยการรวมคะแนนแอททริบิวท์ที่มีคะแนนรวมสูงสุดคือผลลัพท์ของระบบ อธิบายการรวมคะแนนได้ด้วยสมการต่อไปนี้

$$S_j = \sum_{i=1}^m v_{ij} \quad (1 \leq j \leq n) \quad (5)$$

2.2.3 การหามัธยฐาน (Median)

มัธยฐาน คือค่าที่อยู่กึ่งกลางของชุดข้อมูลที่ได้เรียงลำดับแล้ว การหามัธยฐานนั้นจะนำผลลัพท์ที่ได้จากนิรอลเน็ตเวิร์กแต่ละโครงสร้างมาจัดลำดับจากค่าต่ำสุดไปหาค่าสูงสุด ค่าที่อยู่ในตำแหน่งกลางคือผลลัพท์ของระบบ อธิบายการหามัธยฐานได้ด้วยสมการต่อไปนี้

$$S_j = O_{kj} \quad (1 \leq j \leq n) \quad (6)$$

$$k = \frac{m+1}{2} \text{ โดย } m \text{ คือจำนวนเต็มคี่} \quad (7)$$

เมื่อ k แทนตำแหน่งที่อยู่ตรงกลาง

3. งานวิจัยที่เกี่ยวข้อง

มีการนำแนวทางซินเนอร์จิสติกนิวรอลเน็ตเวิร์กมาประยุกต์ใช้ในงานด้านนิวรอลเน็ตเวิร์กอย่างจริงจังในการควบคุมและบอกตำแหน่งของวัตถุให้กับแขนของหุ่นยนต์ [3] โดยงานวิจัยนี้ได้นำเสนอและพิสูจน์ให้เห็นว่าผลที่ได้จาก Synergistic Neural Model มีความถูกต้อง (Accuracy) สูงกว่านิวรอลเน็ตเวิร์กโครงสร้างเดี่ยว อีกทั้งสามารถลดเวลาที่ใช้ในการปรับสอนด้วย งานวิจัยด้านการจำแนกข้อมูลด้วยนิวรอลเน็ตเวิร์กได้นำแนวทางซินเนอร์จิสติกมาประยุกต์ใช้เช่นกัน ในการจำแนกประเภทข้อบกพร่องของเนื้อไม้ (Synergistic Classification System for Wood Defect Identification) [2][4] งานวิจัยนี้พบว่าวิธีซินเนอร์จิสติกนิวรอลเน็ตเวิร์กที่ใช้ค่ามัธยฐาน (Median) ให้ผลลัพธ์ที่ดีที่สุด (ค่าความถูกต้องที่ร้อยละ 92.0) ในขณะที่นิวรอลเน็ตเวิร์กโครงสร้างเดี่ยวที่ดีที่สุดให้ค่าความถูกต้องสูงสุดไม่เกินร้อยละ 85.0 แนวทางซินเนอร์จิสติกได้มีการนำมาประยุกต์ใช้ในงานการพยากรณ์เช่นกัน ตัวอย่างงานด้านนี้คือการศึกษาประสิทธิภาพของซินเนอร์จิสติกนิวรอลเน็ตเวิร์กในการพยากรณ์อุณหภูมิ [5] งานวิจัยนี้แยกองค์ประกอบของข้อมูลออกเป็นสองส่วนคือค่าเฉลี่ยเคลื่อนที่ของอุณหภูมิและผลต่างของค่าอุณหภูมิจริงกับค่าเฉลี่ยเคลื่อนที่ โดยค่าพยากรณ์อุณหภูมิจริงเกิดจากผลรวมของค่าพยากรณ์ขององค์ประกอบทั้งสองส่วนนี้ งานวิจัยนี้สามารถพยากรณ์ได้แม่นยำมากกว่างานวิจัยที่เกิดขึ้นก่อนที่ใช้ข้อมูลชุดเดียวกัน [6][7]

นอกจากงานทางด้านนิวรอลเน็ตเวิร์กแล้ว ยังได้มีการนำซินเนอร์จิสติกมาประยุกต์ใช้ในการจำแนกข้อมูลในแขนงวิชา (Subfield) อื่นของปัญญาประดิษฐ์ ตัวอย่างดังกล่าวคือการนำ Genetic Algorithm มาประยุกต์เข้ากับ Inductive Learning ในการเรียนรู้การจำแนกข้อมูลของนักศึกษา (Synergistic Genetic Algorithms for Inductive Learning) [8][9] งานวิจัยนี้ทำการจัดแบ่งข้อมูลนักศึกษาออกเป็น 3 ส่วน แต่เนื่องจากความจำกัดของจำนวนข้อมูล ทำให้ความถูกต้องในการเรียนรู้ในระดับค่อนข้างต่ำ (ร้อยละ 42) ซินเนอร์จิสติกของสามยูนิตของการเรียนรู้ในแต่ละกลุ่มสามารถเพิ่มประสิทธิภาพการจำแนกข้อมูลโดยรวมได้ในระดับความถูกต้องเพิ่มขึ้นเป็นร้อยละ 74

จากการศึกษารวบรวมงานวิจัยที่ใกล้เคียงสามารถสรุปได้ว่า การประยุกต์ใช้ซินเนอร์จิสติกนิวรอลเน็ตเวิร์กมากับงานด้านการจำแนกข้อมูลและการพยากรณ์ได้ประสบความสำเร็จ อีกทั้งงานวิจัยเหล่านี้ได้แสดงให้เห็นว่าแนวทางซินเนอร์จิสติกนิวรอลเน็ตเวิร์กสามารถปรับปรุงประสิทธิภาพการทำงานของนิวรอลเน็ตเวิร์กได้

4. ข้อมูลที่ใช้ในงานวิจัย


ข้อมูลที่น่ามาใช้ในงานวิจัยนี้คือข้อมูลผู้ป่วยโรคหัวใจ (Heart Disease Data) [10] ที่มีแหล่งที่มาจาก Cleveland Database ซึ่งเป็นข้อมูลสาธารณะของผู้ป่วยโรคหัวใจที่มีความสมบูรณ์มากที่สุด ข้อมูลชุดนี้ได้แยกอาการของโรคหัวใจออกเป็น 4 คลาส (4 ระดับอาการ) ข้อมูลแต่ละชุดประกอบด้วยแอททริบิวต์ที่ระบุถึงปัจจัยที่เกี่ยวข้องกับการจำแนกข้อมูล (ข้อมูลอินพุต) 13 แอททริบิวต์ และแอททริบิวต์ที่แสดงคลาสของอาการโรคหัวใจของชุดนั้น (เอาต์พุตคลาส) ชุดข้อมูลที่ใช้ทั้งหมดมี 297 ชุดและได้ถูกแบ่งออกเป็นข้อมูลสำหรับปรับสอน (Training Set) จำนวน 247 ชุดและข้อมูลสำหรับการทดสอบ (Testing Set) จำนวน 50 ชุด คลาสและจำนวนผู้ป่วยในคลาสที่ใช้ในงานวิจัยนี้แสดงได้ดังตารางที่ 1

ตารางที่ 1 คลาสของข้อมูลผู้ป่วยโรคหัวใจที่ใช้ในโครงการวิจัย

คลาส	ความหมาย	จำนวนผู้ป่วย (คน)
1	ผู้ที่ไม่ปรากฏอาการของโรคหัวใจ	161
2	ผู้ป่วยที่ปรากฏอาการโรคหัวใจขั้นเริ่มต้น	54
3	ผู้ป่วยที่ปรากฏอาการโรคหัวใจขั้นกลาง	34
4	ผู้ป่วยที่ปรากฏอาการโรคหัวใจขั้นรุนแรงและรุนแรงที่สุด	48

5. นิวรอลเน็ตเวิร์กที่พัฒนาขึ้น

งานวิจัยนี้ได้เลือกใช้นิวรอลเน็ตเวิร์กโครงสร้างเดี่ยวทั้งหมด 5 โครงสร้าง อันได้แก่ มัลติเลเยอร์เพอร์เซพตรอน (Multilayer Perceptron) เจนเนอรัลไลซ์ฟีดฟอร์เวิร์ดเน็ตเวิร์ก (Generalized Feedforward Networks) มอดูลาร์เน็ตเวิร์ก (Modular Networks) เรเดียลเบซิสฟังก์ชันเน็ตเวิร์ก (Radial Basis Function Networks) จอร์แดนเน็ตเวิร์ก (Jordan Networks) โดยนิวรอลเน็ตเวิร์กทั้ง 5 โครงสร้างเป็นโครงสร้างที่เหมาะสมและนิยมใช้ในการจำแนกข้อมูล โครงสร้างของนิวรอลเน็ตเวิร์กที่พัฒนาขึ้นประกอบด้วย 13 อินพุตและ 4 เอาต์พุต อินพุต x_1 ถึง x_{13} คือค่าแอททริบิวต์ที่ใช้ในการวิเคราะห์ฟังก์ชันของค่าเอาต์พุต y_1 ถึง y_4 อยู่ที่ $[0,1]$ ซึ่งแสดงถึงความเป็นไปได้ของแต่ละคลาสของชุดข้อมูลโดยค่าสูงสุดของ y_1 ถึง y_4 แสดงถึงคลาสของผู้ป่วยในชุดข้อมูลนั้น รูปที่ 3 แสดงถึงโครงสร้างของนิวรอลเน็ตเวิร์กที่พัฒนาขึ้น ตารางที่ 2 แสดงผลการจำแนกข้อมูลที่ได้จากนิวรอลเน็ตเวิร์กแต่ละโครงสร้าง



รูปที่ 3 โครงสร้างของนิวรอลเน็ตเวิร์กที่ใช้ในการจำแนกข้อมูล

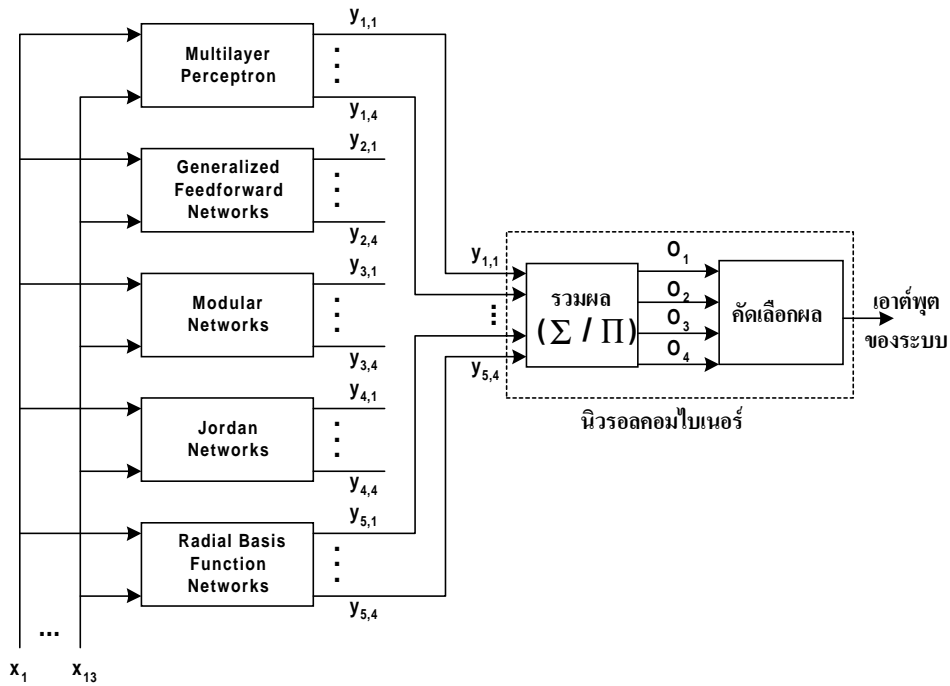
ตารางที่ 2 ผลการจำแนกข้อมูลผู้ป่วยโรคหัวใจโดยนิวรอลเน็ตเวิร์ก

โครงสร้างของนิวรอลเน็ตเวิร์ก	ผลการจำแนกข้อมูลได้ถูกต้อง (%)				ความถูกต้องโดยรวม (%)
	คลาส 1	คลาส 2	คลาส 3	คลาส 4	
Multilayer Perceptron	92.0	10.0	42.9	75.0	66.0
Generalized Feedforward Networks	84.0	30.0	57.1	25.0	60.0
Modular Networks	92.0	-	57.1	75.0	66.0
Radial Basis Function Networks	92.0	10.0	28.8	50.0	66.0
Jordan Networks	84.0	20.0	85.7	50.0	60.0

ตัวเลขในตารางที่ 2 แสดงความถูกต้องในการจำแนกข้อมูลของแต่ละคลาสและโดยรวม (ทั้ง 4 คลาส) ของนิวรอลเน็ตเวิร์กแต่ละโครงสร้าง ผลลัพธ์ในตารางที่ 2 ได้แสดงให้เห็นว่านิวรอลเน็ตเวิร์กสามารถจำแนกข้อมูลของผู้ป่วยที่อยู่ในคลาส 1 และคลาส 4 ได้ดีกว่าในคลาส 2 และคลาส 3 จากการวิเคราะห์ผลลัพธ์อย่างถี่ถ้วนได้แสดงให้เห็นถึงความไม่ชัดเจนในการจำแนกกลุ่มของคลาส 2 และคลาส 3 กล่าวคือผลลัพธ์ของข้อมูลหลายชุดมีค่า y_1 และ y_4 ที่ต่ำอย่างชัดเจนในขณะที่ความแตกต่างของค่า y_2 และ y_3 นั้นใกล้เคียงพอสมควร ทำให้เกิดความไม่ชัดเจนในการจำแนกกลุ่มระหว่าง 2 คลาสนี้ ตัวอย่างเช่น ผลลัพธ์จากข้อมูลชุดหนึ่งอาจมีค่า $y_1 = 0.10$ $y_2 = 0.54$ $y_3 = 0.63$ $y_4 = 0.20$ ในกรณีนี้ข้อมูลชุดนี้จะถูกจำแนกอยู่ในคลาส 3 เนื่องจาก y_3 มีค่าสูงสุด ความแตกต่างของค่า y_2 และ y_3 ที่ไม่เด่นชัดเพียงพอนี้ส่งผลให้ความถูกต้องในการจำแนกข้อมูลของ 2 คลาสนี้มีค่าที่ค่อนข้างต่ำ ปัจจัยหนึ่งที่ทำให้ค่าความถูกต้องต่ำเกิดจากจำนวนข้อมูลที่ค่อนข้างจำกัดใน 2 คลาสนี้ สำหรับความสำคัญของจำนวนข้อมูลที่เพียงพอได้กล่าวไว้ในหัวข้อสิ่งที่ค้นพบ

6. ซินเนอร์จิสติกนิวรอลเน็ตเวิร์กที่พัฒนาขึ้น

ความถูกต้องในการจำแนกข้อมูลของนิวรอลเน็ตเวิร์กโครงสร้างเดี่ยวอยู่ในเกณฑ์ที่ไม่สูงนัก เนื่องจากชุดข้อมูลปรับสอนมีค่อนข้างจำกัด (297 ชุด) และผลลัพธ์จากการจำแนกข้อมูลในบางกรณีมีความคลุมเครืออยู่ดังตัวอย่างที่กล่าวไว้ในหัวข้อที่แล้ว การพัฒนาซินเนอร์จิสติกนิวรอลเน็ตเวิร์กจึงมีจุดประสงค์เพื่อปรับปรุงประสิทธิภาพและความถูกต้องในการจำแนกข้อมูล งานวิจัยนี้ได้้นำแนวทางซินเนอร์จิสติกทั้งแบบรวมผลลัพธ์และแบบเลือกผลลัพธ์ มาใช้ในการจำแนกข้อมูลผู้ป่วยโรคหัวใจ โดยใช้ข้อมูลอินพุตชุดเดียว รูปแบบของซินเนอร์จิสติกแบบรวมผลลัพธ์แสดงไว้ดังรูปที่ 4



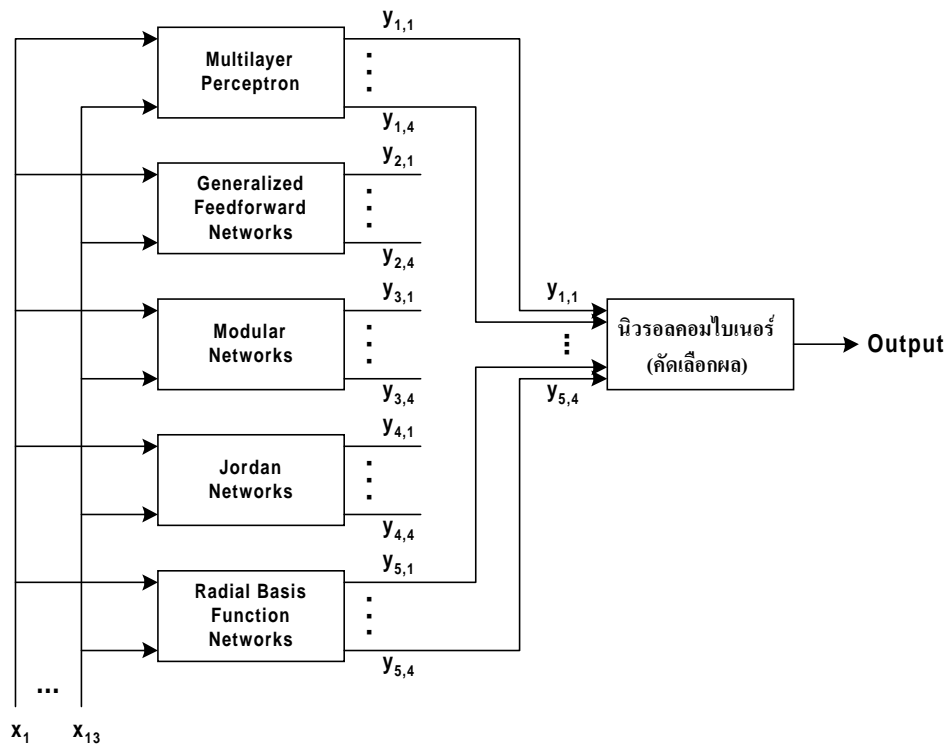
รูปที่ 4 ชินเนอร์จิสติกแบบรวมผลลัพธ์ที่ใช้ในการจำแนกข้อมูล

ผลลัพธ์ของเอาต์พุตของระบบ (คลาสที่ข้อมูลชุดนั้นเป็นสมาชิก) จะได้รับคัดเลือกผลโดยพิจารณาจากค่า O_1 ถึง O_4 ที่ได้รับการรวมผลของวิธีต่างๆ โดยค่าที่สูงสุดของ O_1 ถึง O_4 เป็นตัวกำหนดคลาสของข้อมูลชุดนั้น ซึ่งผลของการจำแนกข้อมูลโดยชินเนอร์จิสติกแบบรวมผลลัพธ์ถูกแสดงไว้ดังตารางที่ 3

ตารางที่ 3 ผลการจำแนกข้อมูลโดยชินเนอร์จิสติกแบบรวมผลลัพธ์

วิธีการรวมผลลัพธ์	ผลการจำแนกข้อมูลได้ถูกต้อง (%)				ความถูกต้องโดยรวม (%)
	คลาส 1	คลาส 2	คลาส 3	คลาส 4	
การหาผลรวม	92.0	20.0	71.4	62.5	70.0
การคูณผลลัพธ์	92.0	10.0	85.7	62.5	70.0

รูปแบบของชินเนอร์จิสติกแบบเลือกผลลัพธ์ที่พัฒนาขึ้นและผลการจำแนกข้อมูลแสดงได้ดังรูปที่ 5 และตารางที่ 4 ตามลำดับ



รูปที่ 5 ชินเนอร์จิสติกแบบเลือกผลลัพธ์ที่ใช้ในการจำแนกข้อมูล

ตารางที่ 4 ผลการจำแนกข้อมูลโดยชินเนอร์จิสติกแบบเลือกผลลัพธ์

วิธีการเลือกผลลัพธ์	ผลการจำแนกข้อมูลได้ถูกต้อง (%)				ความถูกต้องโดยรวม (%)
	คลาส 1	คลาส 2	คลาส 3	คลาส 4	
การหาค่าสูงสุด	96.0	30.0	85.7	87.5	80.0
การลงคะแนน	92.0	10.0	85.7	87.5	74.0
การหามัธยฐาน	92.0	20.0	85.7	87.5	76.0

ผลการจำแนกข้อมูลโดยรวมที่ดีที่สุดอยู่ที่ร้อยละ 80 ค่าผลลัพธ์อาจดูไม่สูงนักเนื่องมาจากความจำกัดของจำนวนข้อมูล หากจำนวนข้อมูลในแต่ละคลาสมีมากเพียงพอคาดว่าแนวทางที่นำมาใช้นี้จะให้ผลลัพธ์ที่น่าพอใจ อย่างไรก็ตามงานวิจัยที่ได้นำ Cleveland Data มาใช้นี้ [10]-[12] เป็นการจำแนกข้อมูลออกเพียง 2 กลุ่มคือ กลุ่มที่ไม่ปรากฏอาการ และกลุ่มที่ปรากฏอาการเท่านั้น จากการศึกษาค้นคว้าที่ผ่านมายังไม่พบงานวิจัยที่จำแนกข้อมูลชุดนี้มากกว่า 2 กลุ่ม

7. สิ่งที่ได้ค้นพบ

สิ่งที่ได้ค้นพบจากงานวิจัยสามารถสรุปได้ดังนี้

1. ซินเนอร์จิสติกนิเวรอลเน็ตเวิร์กจัดเป็นระบบหนึ่งที่เหมาะสมกับการจำแนกข้อมูล เนื่องจากเป็นแนวทางที่นำผลการจำแนกข้อมูลที่ได้จากนิเวรอลเน็ตเวิร์กโครงสร้างต่างๆ มาพิจารณาหาผลลัพธ์ของระบบ โดยเฉพาะในกรณีที่ข้อมูลปรับสอนมีจำนวนจำกัดหรือมีความไม่ชัดเจนในผลลัพธ์
2. ประสิทธิภาพการจำแนกข้อมูลของนิเวรอลเน็ตเวิร์กและซินเนอร์จิสติกนิเวรอลเน็ตเวิร์กมีความเกี่ยวข้องกับจำนวนข้อมูลในการปรับสอนของวิธีการดังกล่าว ความถูกต้องของการจำแนกข้อมูลจะต่ำ เมื่อจำนวนข้อมูลตัวอย่างในคลาสนั้นๆ มีจำนวนจำกัดและคลาสที่มีจำนวนข้อมูลตัวอย่างที่มากเพียงพอ ความถูกต้องของผลการจำแนกข้อมูลในคลาสนั้นๆ จะอยู่ในระดับที่น่าพอใจ
3. การจำแนกข้อมูลของนิเวรอลเน็ตเวิร์กโครงสร้างเดี่ยวแต่ละโครงสร้างที่เลือกใช้ มีผลกระทบโดยตรงกับความถูกต้องของซินเนอร์จิสติกนิเวรอลเน็ตเวิร์กที่โครงสร้างเดี่ยวนั้นรวมอยู่ด้วย กล่าวคือประสิทธิภาพโดยรวมของซินเนอร์จิสติกนิเวรอลเน็ตเวิร์ก อาจขึ้นอยู่กับความถูกต้องของนิเวรอลเน็ตเวิร์กหน่วยใดหน่วยหนึ่ง

8. ข้อเสนอแนะ

การจำแนกข้อมูลโดยซินเนอร์จิสติกนิเวรอลเน็ตเวิร์กเป็นจุดเริ่มต้นในการศึกษาระบบการทำงานร่วมกันของนิเวรอลเน็ตเวิร์ก ข้อเสนอแนะที่ได้จากการวิจัยสามารถสรุปได้ดังนี้

1. ทดลองใช้จำนวนโครงสร้างของนิเวรอลเน็ตเวิร์กโครงสร้างเดี่ยวมากขึ้น (จำนวนโครงสร้างเดี่ยวที่ใช้ควรเป็นเลขคี่) โดยการเพิ่มนิเวรอลเน็ตเวิร์กโครงสร้างอื่น เช่น Learning Vector Quantization (LVQ) [13][14] หรือทำการ Process ข้อมูลก่อนโดยใช้หลักการของ Principle Component Analysis [15] เพื่อปรับการกระจายของข้อมูลให้เกาะตัวกันมากขึ้น ซึ่งอาจทำให้การแบ่งกลุ่มง่ายขึ้น
2. ทดลองหาผลลัพธ์ของระบบโดยใช้นิเวรอลเน็ตเวิร์กอีก 1 โครงสร้างทำหน้าที่เป็นนิเวรอลคอมไบเนอร์
3. ทดลองใช้ซินเนอร์จิสติกนิเวรอลเน็ตเวิร์กจากโครงสร้างเดียวกันทั้งหมด โดยกำหนดให้แต่ละโครงสร้างมีค่าพารามิเตอร์ต่างๆ ที่แตกต่างกัน

9. สรุป

การจำแนกข้อมูลเพื่อช่วยในการวินิจฉัยทางการแพทย์เป็นงานที่ให้ความสำคัญกับความถูกต้องของผลการจำแนกข้อมูล โดยเฉพาะข้อมูลของผู้ป่วยโรคหัวใจซึ่งเป็นข้อมูลที่มีความซับซ้อนและมีข้อจำกัดของจำนวนข้อมูลตัวอย่าง เทคนิคซินเนอร์จิสเป็นแนวทางใหม่ที่เกิดจากการทำงานร่วมกันของนิเวรอลเน็ตเวิร์กโครงสร้างเดี่ยวหลายโครงสร้าง โดยเป็นการเพิ่มรายละเอียดและเหตุผลที่ใช้ในการตัดสินใจ งานวิจัยนี้แสดงให้เห็นว่าซินเนอร์จิสติกนิเวรอลเน็ตเวิร์กเป็นแนวทางที่สามารถปรับปรุงประสิทธิภาพการจำแนกข้อมูลได้ จากผลการทดลองแสดงให้เห็นว่าซินเนอร์จิสติกแบบ

เลือกผลลัพธ์โดยการหาค่าสูงสุดที่สามารถจำแนกข้อมูลของผู้ป่วยโรคหัวใจได้ถูกต้องมากที่สุด งานวิจัยนี้เป็นการนำเสนอแนวทางการพัฒนาวิธีการจำแนกข้อมูลให้มีประสิทธิภาพอีกวิธีหนึ่ง

10. กิตติกรรมประกาศ

งานวิจัยนี้สำเร็จลุล่วงไปได้ด้วยดี ผู้วิจัยขอขอบคุณ Dr. Rob J. Alcock ที่กรุณาแนะนำแนวทางอันเป็นประโยชน์ และคณะเทคโนโลยีสารสนเทศ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี ที่ให้ทุนสนับสนุนการวิจัย

เอกสารอ้างอิง

1. Michie, D., Spiegelhalter, D. J. and Taylor, C. C. (Eds.), 1994, "Machine Learning, Neural and Statistical Classification," Chichester, Ellis Horwood, pp. 1-6.
2. Pham, D. T. and Alcock, R. J., 1998, "Artificial Intelligence Based Techniques for Processing Segmented Images of Wood Boards," *Proc. Instn Mech. Engrs, Part E, Journal of Process Mechanical Engineering*, 212(E2), pp. 119-129.
3. Pham, D. T. and Sagiroglu, S., 1995, "Synergistic Neural Model of a Robot Sensor for Part Orientation Detection," *Robotics*, 13, pp. 531-538
4. Pham, D. T., Pham, P., and Alcock, P. J. *Intelligent Manufacturing. In Novel Intelligent Automation and Control System (Ed. J. Pferiffer)*, Vol. I, 1998 (Papierflieger, Clausthal-Zellerfeld).
5. นุชอนงค์ พิทักษ์ภากร, 2543, "ประสิทธิภาพของซินเนอร์จิสติกนิวรอลเน็ตเวิร์กในการพยากรณ์อุณหภูมิ," *โครงการเฉพาะเรื่องปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาเทคโนโลยีสารสนเทศ คณะเทคโนโลยีสารสนเทศ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี*, 45 หน้า.
6. จรรย์รัตน์ พุกษานันท์, 2541, "การประยุกต์ใช้นิวรอลเน็ตเวิร์กในการพยากรณ์อุณหภูมิ," *วิทยานิพนธ์ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาเทคโนโลยีสารสนเทศ คณะเทคโนโลยีสารสนเทศ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี*, 72 หน้า.
7. กิตติชัย ล้วนยานนท์ และจรรย์รัตน์ พุกษานันท์, 2542, "Competency of Neural Networks in Forecast Using Highly Fluctuated Data," *Proc. of the National Computer Science and Engineering Conference (NCSEC'99)*, 16-17 ธันวาคม, The Landmark Hotel, Bangkok, Thailand.
8. รัตนา จรัสสุวัฒน์, 2543, "Synergistic Genetic Algorithms for Inductive Learning (SynGAIL)," *วิทยานิพนธ์ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาเทคโนโลยีสารสนเทศ คณะเทคโนโลยีสารสนเทศ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี*, 45 หน้า.

9. กิตติชัย ล้วนยานนท์ และรัตนา จรัสสุภวัฒน์, 2543, “การจำแนกข้อมูลประชากรโดย Genetic Algorithms for Inductive Learning (GAIL),” *การประชุมวิชาการสถิติประยุกต์ครั้งที่ 13 “การสำรวจความคิดเห็นของสาธารณชน*, 26-27 ตุลาคม, สถาบันบัณฑิตพัฒนบริหารศาสตร์, กรุงเทพฯ.
10. David, W. A., 1988, “Heart Disease Data,” <ftp://ftp.ics.uci.edu/machine-learning-databases/>
11. Alcock, R. J. and Monolopoulos, Y., 1999, “Using Genetic Algorithms for Inductive Learning,” *3rd IMACS Inter. Multiconference on Circuits, System, Communications, and Computer (CSCC’99)*, Athens, Greece, June 4-7, 1999, pp. 1-6.
12. Ultragem Data Mining, 2000, “The Classification Rules for the Heart Disease Problem,” <http://www.ultragem.com/heartrul2.htm>
13. Pham, D. T. and Oztenel, E., 1996, *Intelligent Quantity Control*, Springer-Verlag, London, UK.
14. Kohonen, T., 1988, “The ‘Neural’ Phonetic Typewriter,” *IEEE Computer*, Vol. 21, No. 3, pp. 11-22.
15. Oja, E., 1989, “Neural Networks, Principal Components, and Subspaces,” *Journal of Neural Systems*, Vol. 1, pp. 61-68.