



การเรียนรู้แบบรวมกลุ่มด้วยโครงข่ายประสาทเทียมเอดาบูท สำหรับการจำแนกข้อมูล Adaboost Artificial Neural Network Ensemble Learning for Classification

เดช ธรรมศิริ (Dech Thammasiri)* และ พยุง มีสัจ (Phayung Meesad)**

บทคัดย่อ

ในปัจจุบันการเพิ่มความแม่นยำสำหรับการจำแนกข้อมูลถือเป็นเรื่องสำคัญ ดังนั้น งานวิจัยครั้งนี้เป็นการนำเสนอวิธีการจำแนกข้อมูลด้วยวิธีร่วมกันตัดสินใจโดยใช้ เทคนิคโครงข่ายประสาทเทียมรวมกับการรวมกลุ่มตัดสินใจโดยใช้เทคนิคเอดาบูทเพื่อให้ความถูกต้องในการจำแนกข้อมูลที่สูงขึ้น ทดสอบบนฐานข้อมูลโรคเบาหวานได้แก่ Diabetes Data จาก UCI การทดสอบความถูกต้องในการจำแนกข้อมูล Diabetes Data พบว่า เทคนิคการร่วมกันตัดสินใจจากหลายโมเดลที่ผ่านการรวมกลุ่มตัดสินใจด้วยเทคนิคเอดาบูทมีผลลัพธ์ที่ดีกว่าการใช้เทคนิคแบบโมเดลเดี่ยว โดยผลการวิจัยพบว่า สำหรับข้อมูล Diabetes Data ให้ผลลัพธ์ความถูกต้องสูงสุดที่ 75.02 % ในขณะที่โมเดลเดี่ยวให้ความแม่นยำที่น้อยกว่า

คำสำคัญ: การจำแนกข้อมูล เอดาบูท วิธีการรวมกลุ่มโครงข่ายประสาทเทียม

Abstract

Currently, performance accuracy for classification is critical. In this paper, we propose an ensemble classification technique based on artificial neural network ensemble classifier by Adaboost in order to increase classification accuracy. For classification accuracy test on Diabetes Data, we found that the proposed artificial neural network ensemble classifier by adaboost yields better performance

than that of single model. The results show that Diabetes Data achieved best performance with 75.02%, while single model show lower accuracy.

Keyword: Classification, Adaboost, Ensemble, Artificial Neural Network.

1. บทนำ

ปัจจุบันนักวิจัยจำนวนมากได้ให้ความสำคัญกับปัญหาที่ต้องการวิธีการจำแนกข้อมูลที่แม่นยำ โดยมีการนำเสนอวิธีการที่หลากหลาย เช่น การนำเอาเทคนิคด้านปัญญาประดิษฐ์ (Artificial Intelligence) มาประยุกต์ใช้ ได้แก่ เทคนิคต้นไม้ช่วยตัดสินใจ (Decision Tree Models) [1] เทคนิคโครงข่ายประสาทเทียม (Artificial Neural Networks) [2] เทคนิคซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine หรือ SVM) [3] เป็นต้น

แต่ถึงแม้ว่าเทคนิคข้างต้นจะให้ผลลัพธ์ในการจำแนกข้อมูลที่แม่นยำแต่การเป็นโมเดลเดี่ยว (Single Model) นั้นทำให้มีการกำหนดกลุ่มของข้อมูลที่ใช้ในการเรียนรู้ รวมทั้งมีการกำหนดค่าพารามิเตอร์ที่ตายตัว บางครั้งเกิดปัญหาความโน้มเอียง (Bias) หนทางหนึ่งที่จะสามารถลดค่าความโน้มเอียงได้คือการใช้วิธีการร่วมกันตัดสินใจ (Ensemble) หากแต่วิธีการรวมกลุ่มถ้าจะให้มีประสิทธิภาพที่ดีได้มีผู้วิจัยดังเช่น Wang และคณะ [4] ให้คำแนะนำว่า “โดยทั่วไปแล้วประสิทธิภาพของการรวมกลุ่มจะขึ้นอยู่กับ ความหลากหลาย และความแม่นยำของตัวแทนในการจำแนกข้อมูล”

* ภาควิชาเทคโนโลยีสารสนเทศ คณะเทคโนโลยีสารสนเทศ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

** ภาควิชาครุศาสตร์ไฟฟ้า คณะครุศาสตร์อุตสาหกรรม มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

ตั้งเช่นงานวิจัยของ Yao และคณะ [5] ได้นำเสนอการรวมกลุ่มช่วยในการตัดสินใจโดยใช้เทคนิคต้นไม้ช่วยตัดสินใจร่วมกับวิธีการ Boosting โดยได้ทดสอบประสิทธิภาพกับข้อมูลจาก UCI ผลที่ได้แสดงให้เห็นว่าวิธีการดังกล่าวให้ประสิทธิภาพที่ดีกว่าโมเดลแบบเดี่ยว Jian และคณะ [6] ได้ใช้เทคนิคการรวมกลุ่มตัดสินใจร่วมกับเทคนิคโครงข่ายประสาทเทียม พบว่า วิธีการที่ได้นำเสนอให้ผลลัพธ์ที่แม่นยำ Chen และคณะ [7] ได้นำเสนอการใช้ตัวจำแนกข้อมูลด้วยเทคนิคซัพพอร์ตเวกเตอร์แมชชีนที่มีการกำหนดค่าเคอร์เนลฟังก์ชัน รวมทั้งค่าพารามิเตอร์ที่หลากหลายสำหรับสร้างตัวจำแนกข้อมูล ผลที่ได้มีประสิทธิภาพที่ดีกว่าการใช้โมเดลเทคนิคซัพพอร์ตเวกเตอร์แมชชีนแบบเดี่ยว จะเห็นได้ว่าเทคนิคการรวมกลุ่มสามารถช่วยเพิ่มประสิทธิภาพให้กับโมเดล

ในส่วนของการสร้างตัวแทนการเรียนรู้ที่หลากหลายได้มีผู้วิจัยหลายท่านได้นำเสนอไว้ดังนี้ Ying และคณะ [8] ได้ใช้วิธีซัพพอร์ตเวกเตอร์แมชชีน วิธีโครงข่ายประสาทเทียม และวิธีต้นไม้ช่วยตัดสินใจ ร่วมกันจำแนกข้อมูลอีเมลขยะ Yong และคณะ [9] ได้ใช้ KNN และ Bayes เป็นตัวจำแนกข้อมูลพร้อมด้วยการใช้วิธีการเรียนรู้แบบรวมกลุ่มและใช้ วิธีเชิงพันธุกรรมช่วยเลือกคุณลักษณะที่เหมาะสม Zhou และคณะ [10] Chen และคณะ [7] ได้นำเสนอการใช้ตัวจำแนกข้อมูลด้วยวิธีซัพพอร์ตเวกเตอร์แมชชีน ที่มีการกำหนดค่าเคอร์เนลฟังก์ชัน รวมทั้งค่าพารามิเตอร์ที่หลากหลาย ดังนั้นจะเห็นได้ว่าการสร้างตัวแทนในการเรียนรู้ที่หลากหลาย ทำให้ตัวแทนที่สร้างขึ้นมาสามารถนำไปแก้ปัญหาที่หลากหลายได้เช่นเดียวกัน อีกทั้งยังเป็นการเพิ่มประสิทธิภาพโดยรวมของโมเดลอีกด้วย

สำหรับการให้น้ำหนักสำหรับตัวแทนที่เหมาะสม Lei และคณะ [11] ได้นำเสนอการใช้เทคนิคเอดาบูท สำหรับใช้ในการจำแนกข้อมูลแบบสอบถามที่เกี่ยวกับด้านการท่องเที่ยวภายในประเทศจีน ผลที่ได้พบว่าการใช้เทคนิคเอดาบูทให้ผลลัพธ์ที่แม่นยำกว่าการใช้โมเดลแบบเดี่ยว Khaleghian และคณะ [12] ได้ใช้เทคนิค เอดาบูทเพื่อเพิ่มประสิทธิภาพของ Tied Factor Analysis (TFA) สำหรับการตรวจจับภาพใบหน้า ดังนั้นสำหรับงานวิจัยในครั้งนี้ ผู้วิจัยได้ให้ความสำคัญด้านการแก้ปัญหาต่างๆ เหล่านี้ เพื่อหาวิธีการที่เหมาะสมสำหรับการเรียนรู้แบบรวมกลุ่ม โดยการสร้างตัวจำแนก

ข้อมูลที่มีการกำหนดค่าพารามิเตอร์ที่เหมาะสมเพื่อเพิ่มประสิทธิภาพของตัวจำแนกข้อมูลแบบรวมกันตัดสินใจพร้อมด้วยการกำหนดน้ำหนักให้กับตัวจำแนกข้อมูลที่เหมาะสมด้วยเทคนิคเอดาบูท สำหรับนำไปสร้างโมเดลใหม่ที่มีประสิทธิภาพด้านการจำแนกข้อมูลได้ถูกต้องมากขึ้น

2. ทฤษฎีที่เกี่ยวข้อง

2.1 เทคนิคโครงข่ายประสาทเทียม [13]

การเรียนรู้ของนิวรอนเน็ตเวิร์ก ทำได้โดยการส่งข้อมูลเข้ามายังส่วนที่เรียกว่าเพอร์เซ็ปตรอน (Perceptron) สามารถเทียบได้กับเซลล์สมองของมนุษย์ โดยที่เพอร์เซ็ปตรอนทำการรับข้อมูลที่อยู่ในรูปของเมทริกซ์ซึ่งเป็นตัวเลข เข้ามาคำนวณ สำหรับฟังก์ชันผลรวม (Summation Function) มีการทำงานดังสมการที่ (1)

$$n = \sum_{i=1}^z x_i w_i + b \quad (1)$$

โดยที่ n ตัวแปร คือ ผลรวมที่ได้จากฟังก์ชันผลรวม

ตัวแปร x_i คือ ค่าข้อมูลเข้าตัวที่ i

ตัวแปร w_i คือ ค่าน้ำหนักของนิวรอนตัวที่ i

ตัวแปร z คือ จำนวนนิวรอนชั้นข้อมูลเข้า

ตัวแปร b คือ ค่าความโน้มเอียง

ตัวแปร i มีค่าตั้งแต่ 1 ถึง z

2.2 เทคนิคเอดาบูท (Adaboost Algorithm)

เทคนิคนี้เป็นวิธีการให้น้ำหนักสำหรับตัวจำแนกโดยให้น้ำหนักจากค่าความยากของข้อมูลที่วัดจากความผิดพลาดของตัวจำแนกข้อมูลก่อนหน้ามีลำดับขั้นตอนการทำงานดังนี้

1) ส่วนของข้อมูลนำเข้า (Input) : ได้แก่ กลุ่มของข้อมูลที่นำมาใช้สำหรับการฝึกสอนและคำอธิบายข้อมูล

กำหนดให้ $(x_1, y_1), \dots, (x_n, y_n)$ โดยที่

$x_i \in R^z, y_i \in y = \{-1, +1\}$ และจำนวนตัวจำแนกข้อมูลที่จะนำมา รวมกลุ่ม แทนด้วย T และ n แทนจำนวน เรคคอร์ดของข้อมูลที่ให้ทั้งหมด

2) กำหนดค่าเริ่มต้น (Initialize) : ค่าน้ำหนักของชุดฝึกสอน แทนด้วย $w_i^1 = \frac{1}{n}; i = 1, \dots, N$ (ขั้นตอนนี้เป็น การนอร์มอลไลซ์น้ำหนัก (Normalize the weights) w_i บนตัวอย่างของชุดข้อมูลฝึกสอน โดยเริ่มต้นแบบเดียวกัน)

3) ทำการวนรอบ (Loop) : ตั้งแต่ $t = 1, \dots, T$

3.1) ใช้กลุ่มข้อมูลชุดฝึกสอน เรียนรู้ทำการจำแนก

ประเภทข้อมูล h_i โดยใช้ค่าน้ำหนักของกลุ่มฝึกสอน h_i คำนวณหาค่าความผิดพลาดในการฝึกสอนของตัวจำแนกข้อมูลดังสมการที่ 2

$$\varepsilon_i = \sum_{i=1}^N W_i^t, y_i \neq h_i(x_i) \quad (2)$$

3.2) กำหนดค่าน้ำหนัก α_i ให้กับตัวจำแนกข้อมูล h_i ตามสมการที่ 3

$$\alpha_i = \frac{1}{2} \ln \left(\frac{1 - \varepsilon_i}{\varepsilon_i} \right) \quad (3)$$

3.3) ทำการปรับปรุงค่าน้ำหนักของข้อมูลชุดฝึกสอนดังสมการที่ 4

$$w_i^{t+1} = \frac{w_i^t \exp \{-\alpha_i y_i h_i(x_i)\}}{c_i} \quad (4)$$

โดยที่ c_i คือ ค่าคงที่มาตรฐาน ไม่และค่ารวมของน้ำหนักจะมีค่าเท่ากับ ดังสมการที่ 5

$$\sum_{i=1}^N w_i^{t+1} = 1 \quad (5)$$

4) ผลลัพธ์ (Output) : ผลที่ได้ดังสมการที่ 6

$$f(x) = \text{sign} \left(\sum_{i=1}^t \alpha_i h_i(x) \right) \quad (6)$$

3. วิธีการและโมเดลที่นำเสนอ

ในงานวิจัยนี้เริ่มต้นที่การนำข้อมูลมาทำการ นอร์มัลไลซ์ (Normalization) โดยปรับค่าข้อมูลให้อยู่ในรูปแบบเดียวกัน จากนั้นได้นำเสนอวิธีการสร้างตัวจำแนกข้อมูลที่หลากหลาย โดยใช้ วิธีการสุ่มกลุ่มตัวอย่าง เพื่อสร้างความแตกต่างบนกลุ่มข้อมูลสำหรับการฝึกฝน (Training Sets) ซึ่งประกอบด้วยกลุ่มตัวอย่างจำนวน N ตามจำนวนของตัวจำแนกข้อมูลที่ได้กำหนดขึ้น สำหรับงานวิจัยนี้ได้ใช้ตัวจำแนกทั้งสิ้น 30 ตัวที่ข้อมูลถูกสุ่มและสร้างมาจากกลุ่มข้อมูลสำหรับการสอน โดยที่กลุ่มข้อมูลที่สุ่มสร้างขึ้นมาจากถูกเรียกว่า Bootstrap [14] สำหรับการสุ่มจำนวนกลุ่มตัวอย่าง จากกลุ่มข้อมูลสำหรับการสอน มีความน่าจะเป็น ดังสมการที่ (7)

$$n_i = 1 - \left(1 - \frac{1}{m} \right)^m \quad (7)$$

โดยที่ n_i คือ กลุ่มข้อมูลที่ถูกรวมสร้างขึ้นมา

m คือ จำนวนข้อมูลตัวอย่างทั้งหมด ที่อยู่ในกลุ่มข้อมูลสำหรับการฝึกฝน

โดยที่กลุ่มข้อมูล จะถูกนำไปสอนให้กับตัวจำแนกข้อมูล ซึ่งได้แก่การใช้ เทคนิคโครงข่ายประสาทเทียม โดยที่ผู้วิจัยได้กำหนดเลือกใช้โครงข่ายที่แตกต่างกัน 6 โครงสร้างสำหรับการเลือกใช้จะทำการสุ่มเพื่อเลือกโครงสร้างที่จะนำมาสร้างโมเดล ถึงแม้ว่าจะมีการสุ่มเลือกโครงสร้างที่ซ้ำกัน แต่เนื่องจากข้อมูลที่ใช้ในการสอนโมเดลนั้นจะยังคงแตกต่างกันอยู่ ทำให้ได้รูปแบบของโมเดลที่แตกต่างกัน ดังตารางที่ 1

ตารางที่ 1 รายละเอียดโครงข่ายโครงข่ายประสาทเทียม

โครงข่ายที่	จำนวนนิวรอน	รูปแบบฟังก์ชันกระตุ้น	
		ชั้นซ่อน	ชั้นผลลัพธ์
1	30-20-1	'logsig' 'tansig' 'purelin'	'traincgb'
2	3-1	'tansig' 'purelin'	'traingdm'
3	10-50-1	'tansig' 'tansig' 'purelin'	'trainrp'
4	8-10-1	'tansig' 'tansig' 'tansig'	'trainbr'
5	8-20-1	'tansig' 'purelin' 'logsig'	'trainbfg'
6	12-10-1		'trainrp'

นอกจากนั้นทำการกำหนดจำนวนรอบการเรียนรู้ไว้ที่ 500 รอบ กำหนดเป้าหมายการเรียนรู้ไว้ที่ 0.0001 โดยมีขั้นตอนการสร้างตัวจำแนกข้อมูลดังรูปที่ 1


3.1 ข้อมูลและเครื่องมือที่ใช้ในการวิจัย

การวัดประสิทธิภาพของโมเดล งานวิจัยครั้งนี้ได้ใช้ข้อมูลจาก UCI ซึ่งเป็นข้อมูลเปิดสำหรับนำไปทดสอบประสิทธิภาพ อัลกอริทึมทางด้าน AI ได้แก่ฐานข้อมูล Diabetes Data [15] รายละเอียดดังตารางที่ 2

ตารางที่ 2 รายละเอียดข้อมูลที่ใช้ในการวิจัย

	ตัวอย่าง	แอตทริบิว	คลาส +1	คลาส -1
Diabetes data	768	8	268	500

การประเมินผลใช้การประเมินผลจากประสิทธิภาพการจำแนกข้อมูล โดยวัดค่าความถูกต้องแม่นยำ (Accuracy) ในการจำแนกข้อมูลในกลุ่มข้อมูลทดสอบ ดังสมการที่ 8



ภาพที่ 1 ขั้นตอนการสร้างตัวจำแนกข้อมูล

$$Accuracy = \left(\frac{TP + TN}{TP + FN + TN + FP} \right) 100 \quad (8)$$

โดยที่ TP คือค่า True Positive
TN คือค่า True Negative
FP คือค่า False Positive
FN คือค่า False Negative

3.2 โมเดลที่ใช้เปรียบเทียบเพื่อหาประสิทธิภาพ

งานวิจัยนี้ได้ผู้วิจัยทดลองประสิทธิภาพในการในการจำแนกข้อมูลสำหรับ 4 โมเดล ดังตารางที่ 3

ตารางที่ 3 รายละเอียดโมเดลที่ทดลอง


โมเดล	รายละเอียดโมเดลที่ทดลอง	ชื่อย่อ
1	Decision Tree	DT
2	Neural Network	NN
3	Support Vector Machine	SVM
4	Neural Network+Adaboost	NNAB

4. ผลการวิจัยและการอภิปรายผล

ผลการทดลองที่ได้จากงานวิจัยสำหรับฐานข้อมูล Diabetes data พบว่า โมเดล NNAB ให้ผลลัพธ์ความแม่นยำที่สุด 75.02% รองลงมาเป็นโมเดล DT ให้ผลความแม่นยำ 74.66% โมเดล SVM และ โมเดล NN ให้ผลความแม่นยำที่ 72.66% ตามลำดับ ดังตารางที่ 4 และภาพที่ 2

ตารางที่ 4 ผลเปรียบเทียบที่ได้จากแต่ละโมเดล

ข้อมูล Diabetes data	
โมเดล	ความแม่นยำสูงสุด(%)
DT	74.66
NN	72.66
SVM	72.66
NNAB	75.02



ภาพที่ 2 กราฟเปรียบเทียบผลที่ได้จากแต่ละโมเดล

จากผลลัพธ์ที่ได้จากการทดลองจะพบว่า แนวทางในการนำตัวจำแนกข้อมูลที่หลากหลายมารวมกันตัดสินใจสามารถช่วยเพิ่มประสิทธิภาพความแม่นยำได้มากกว่าการใช้วิธีการแบบโมเดลเดี่ยว (Single Model) อันเนื่องมาจากการใช้เทคนิคการรวมกลุ่มสามารถลดการเกิดปัญหาความโน้มเอียง (Bias) ซึ่งปัญหานี้มักเกิดขึ้นจากการกำหนดกลุ่มของข้อมูลที่ใช้ในการเรียนรู้ รวมทั้งมีการกำหนดค่าพารามิเตอร์ที่ตายตัว อีกทั้งการใช้เทคนิคเอดาบูทช่วยในการให้น้ำหนักกับแต่ละตัวจำแนกเป็นการช่วยเพิ่มประสิทธิภาพยิ่งขึ้นอีกด้วย

จากผลลัพธ์ที่ได้จากการทดลองจะพบว่า แนวทางในการนำตัวจำแนกข้อมูลที่หลากหลายมารวมกันตัดสินใจ

สามารถช่วยเพิ่มประสิทธิภาพความแม่นยำได้มากกว่าการใช้วิธีการแบบโมเดลเดี่ยว (Single Model) อันเนื่องมาจากการใช้เทคนิคการรวมกลุ่มสามารถลดการเกิดปัญหาความโน้มเอียง (Bias) ซึ่งปัญหานี้มักเกิดขึ้นจากการกำหนดกลุ่มของข้อมูลที่ใช้ในการเรียนรู้ รวมทั้งมีการกำหนดค่าพารามิเตอร์ที่ตายตัว อีกทั้งการใช้เทคนิคเอดาบัทช่วยในการให้น้ำหนักกับแต่ละตัวจำแนกเป็นการช่วยเพิ่มประสิทธิภาพยิ่งขึ้นอีกด้วย

5. สรุปผลการวิจัยและข้อเสนอแนะ

การวิจัยในครั้งนี้ เป็นการสร้างโมเดลที่มีประสิทธิภาพสำหรับการจำแนกข้อมูล ผลวิจัยพบว่า การนำเอาเทคนิคโครงข่ายประสาท ร่วมกันตัดสินใจด้วยเทคนิคการรวมกลุ่ม โดยใช้เทคนิคเอดาบัท พบว่าเทคนิคการร่วมกันตัดสินใจให้ผลลัพธ์ที่ดีกว่าการใช้เทคนิคแบบโมเดลเดี่ยว นอกจากนี้ยังพบอีกว่าการให้น้ำหนักกับตัวจำแนกข้อมูลจะทำให้โมเดลที่มีประสิทธิภาพยิ่งขึ้น ทั้งนี้เพราะเมื่อนำตัวจำแนกข้อมูลที่หลากหลายมารวมกันด้วยวิธีการร่วมกันตัดสินใจของตัวจำแนกเป็นการลดปัญหาการเกิดความโน้มเอียงของข้อมูลและการให้น้ำหนักที่เหมาะสมของแต่ละตัวจำแนกจะช่วยให้เสริมประสิทธิภาพในการจำแนกข้อมูล ทำให้โมเดลที่ได้มีประสิทธิภาพมากยิ่งขึ้น

ในอนาคตผู้วิจัยมีแนวคิดในการนำเอาวิธีการเลือกตัวจำแนกที่เหมาะสมโดยใช้วิธีการทางพันธุกรรม สำหรับประยุกต์ใช้เพื่อให้เกิดความแม่นยำในการจำแนกข้อมูลเพิ่มขึ้น

6. เอกสารอ้างอิง

[1] K. Zeitouni and N. Chelghoum, "Spatial Decision Tree-Application to Traffic Risk Analysis," in *Proceedings of the ACS/IEEE International Conference on Computer Systems and Applications*: IEEE Computer Society, 2001.

[2] เดช ธรรมศิริ ณรงค์ โพธิ วาทีนี นุ้ยเพียร ภัทรารุณิ แสงศิริ ภรณ์ยา อามฤตรัตน์ และ พยุง มีสัจ, "การให้คะแนนสินเชื่อโดยวิธีการทำเหมืองข้อมูลด้วยเทคนิคโครงข่ายประสาทเทียม แบบแพร่กระจายย้อนกลับ," *NCCIT 2008*, 2551.

[3] เดช ธรรมศิริ และ พยุง มีสัจ, "การจำแนกข้อมูลโดยวิธีการรวมกลุ่มของเทคนิคซัพพอร์ทเวกเตอร์แมชชีน โดยการปรับพารามิเตอร์ด้วยขั้นตอนวิธีเชิงพันธุกรรม รวมทั้งการเลือกใช้ลักษณะที่เหมาะสมด้วยวิธีการสัมประสิทธิ์สหสัมพันธ์," *NCCIT 2010*, 2553.

[4] S. j. Wang, A. Mathew, Y. Chen, L. f. Xi, L. Ma, and J. Lee, "Empirical analysis of support vector machine ensemble classifiers," *Expert Syst. Appl.*, vol. 36, pp. 6466-6476, 2009.

[5] Y. Yao, Z. Fu, X. Zhao and W. Cheng, "Combining Classifier Based on Decision Tree," *WASE International Conference on Information Engineering 2009*, icie, vol.2, pp. 37-40, 2009.

[6] J. Wang, J. Yang, S. Li, Q. Dai, and J. Xie, "Number Image Recognition Based on Neural Network Ensemble," in *Proceedings of the Third International Conference on Natural Computation - Volume 01*: IEEE Computer Society, 2007.

[7] S. Chen, W. Wang, and H. V. Zuylen, "Construct support vector machine ensemble to detect traffic incident," *Expert Systems with Applications*, vol. 36, pp. 10976-10986, 2009.

[8] K. C. Ying, S.-W. Lin, Z. J. Lee, and Y. T. Lin, "An ensemble approach applied to classify spam e-mails," *Expert Syst. Appl.*, vol. 37, pp. 2197-2201, 2010.

[9] X. Pei-Yong, D. X. Qian, and J. B. Ning, "A GA-based feature selection and ensemble learning for high-dimensional datasets," *International Conference on Machine Learning and Cybernetics*, pp. 7-12, 2009.

[10] L. Zhou, K. K. Lai, and L. Yu, "Least squares support vector machines ensemble models for credit scoring," *Expert Systems with Applications*, vol. 37, pp. 127-133, 2010.

[11] W. Yu and L. Cheng De, "Learning by Bagging and Adaboost based on Support Vector Machine," *5th IEEE International Conference on Industrial Informatics*, pp. 663-668, 2007.



- [12] S. Khaleghian, H. R. Rabiee, and M. H. Rohban, "Face recognition across large pose variations via Boosted Tied Factor Analysis," in *Applications of Computer Vision (WACV)*, 2011 *IEEE Workshop*, pp. 190-195, 2011.
- [13] พยุง มีสัจ. "ระบบฟัซซีและโครงข่ายประสาทเทียม," เอกสารประกอบการสอน คณะเทคโนโลยีสารสนเทศ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ, 2553.
- [14] L. Breiman, "Bagging predictors," *Machine Learning*, vol. 24, pp. 123-140, 1996.
- [15] Diabetes Data set. Retrieved February, 10, 2008, From <http://archive.ics.uci.edu/ml/datasets/Pima+Indians+Diabetes/>, 2008.