



การวิเคราะห์คุณลักษณะพื้นฐานทางการศึกษาด้วยเทคนิคเหมือนของข้อมูล

Study of Educational Attributes Using Data Mining Technique

สุวิมล สิทธิชาติ (Suwimol Sittichat)*

บทคัดย่อ

งานวิจัยนี้ได้ศึกษาคุณลักษณะของนักศึกษาคณิตศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลล้านนา เชียงใหม่ ที่มีผลต่อการเรียนแคลคูลัส 1 สำหรับวิศวกรรม ด้วยเทคนิคเหมือนของข้อมูลเพื่อจำแนกนักศึกษาออกเป็น 2 กลุ่ม คือ กลุ่มเสี่ยงที่จะไม่ผ่านรายวิชา และกลุ่มที่ไม่มีความเสี่ยง โดยการวิเคราะห์ข้อมูลได้เก็บรวบรวมข้อมูลคุณลักษณะทั้ง 3 ด้าน รวมถึงปัจจัยส่วนบุคคลอื่นๆ ของนักศึกษาจำนวน 453 คน แล้วดำเนินตามกระบวนการ CRISP-DM (Cross Industry Standard Process for Data Mining) โดยใช้เทคนิคโครงข่ายประสาทเทียมและต้นไม้ตัดสินใจในการจำแนกประเภทข้อมูลและคัดเลือกคุณลักษณะที่สำคัญด้วย Filter Ranker Method โดยคำนวณค่าน้ำหนักด้วย Chi-Square และ Gain Ratio จากผลการศึกษา พบว่า ความแม่นยำในการจำแนกข้อมูลจาก 50 คุณลักษณะนั้น วิธี ANN มีค่า 71.52% และ Decision Trees - J48 มีค่า 66.23% หลังจากทำการคัดเลือกคุณลักษณะแสดงให้เห็นว่าการจำแนกข้อมูลด้วยวิธี ANN จาก 5 คุณลักษณะแรกที่ได้จากการคัดเลือกโดยวิธี Filter Ranker Method ที่คำนวณค่าน้ำหนักด้วย Chi-Square ทำให้ได้ค่าความถูกต้องมีค่าสูงสุด คือ 80.13% และการจำแนกข้อมูลด้วย Decision Tree ก็ให้ผลไปในทางเดียวกัน โดยมีค่าความถูกต้องสูงสุดที่ 75.83% คุณลักษณะที่ผ่านการคัดเลือกนั้นแสดงถึงคุณลักษณะในด้านพื้นฐานความรู้ของนักศึกษาที่มีมาก่อน จากผลการวิจัยนี้แสดงให้เห็นว่า เทคนิคเหมือนของข้อมูลสามารถนำมาประยุกต์ใช้ทางด้านการศึกษาใน การวิเคราะห์ข้อมูลเพื่อแก้ปัญหาเกี่ยวกับการเรียนการสอนได้

คำสำคัญ: เหมือนของข้อมูลทางการศึกษา การเลือกคุณลักษณะของข้อมูล โครงข่ายประสาทเทียม ต้นไม้ตัดสินใจ กระบวนการทำเหมือนของข้อมูล

Abstract

Classification of educational attributes to estimate achievement of students in Calculus I for Engineers course using data mining technique is presented. 453 students of engineering faculty at Rajamangala University of Technology Lanna were investigated. This study used CRISP-DM (Cross Industry Standard Process for Data Mining) method to process educational information. Artificial neural network (ANN) and Decision Tree were used to classify these students into two groups; risk and no risk to fail or drop out in the course with three factors and demographic information as input data. The features selection methods used in this study was Filter Ranker Method with Chi-Square and Gain Ratio Attribute Evaluators Techniques to improve accuracy of classification. The results showed that ANN classifier with 5 attributes from Chi-Square Attribute Evaluators Techniques have a highest accuracy at 80.13%. 5 selected attributes of Cognitive Entry Behaviors exhibited the best attributes for classification. The result indicates that data mining technique can be applied to process educational information and provide more meaningful information. It also is one of choice to be used in education for development of learning and teaching methods.

Keywords: Educational Data Mining, Features Selection, Artificial Neural Network, Decision Tree, CRISP-DM.

1. บทนำ

แคลคูลัสเป็นวิชาที่มีความสำคัญต่อการศึกษาในสาขา วิชาชีพของนักศึกษาวิศวกรรมศาสตร์ เนื่องจากเป็นวิชาที่ช่วยส่งเสริมประสบการณ์ของผู้เรียนในการฝึกสมอง พัฒนา

* กลุ่มวิชาคณิตศาสตร์ คณะวิทยาศาสตร์และเทคโนโลยีการเกษตร มหาวิทยาลัยเทคโนโลยีราชมงคลล้านนา เชียงใหม่

* Department of Mathematics, Faculty of Science and Agricultural Technology, Rajamangala University of Technology Lanna, Chiang Mai.

ระเบียบความคิดที่เป็นเหตุเป็นผล เป็นแนวทางให้เกิดความคิดริเริ่มสร้างสรรค์ แก้ปัญหาและนำไปใช้ประโยชน์ต่างๆ ทางวิศวกรรม รวมถึงเป็นพื้นฐานสำคัญที่จำเป็นในการศึกษาวิทยาศาสตร์และวิศวกรรมศาสตร์ ด้วยเหตุนี้ คณะวิศวกรรมศาสตร์มหาวิทยาลัยเทคโนโลยีราชมงคลล้านนา จึงได้กำหนดให้รายวิชาแคลคูลัส 1 สำหรับวิศวกรเป็นวิชาที่ต้องเรียนมาก่อน (Pre-requisites) สำหรับวิชาในหลักสูตร หล่ายรายวิชา ทำให้นักศึกษาที่เรียนไม่ผ่านรายวิชานี้จะเรียน บางวิชาในหลักสูตรไม่ได้ ซึ่งมีผลต่อการสำเร็จหลักสูตรของนักศึกษาอย่างมาก จากข้อมูลผลการเรียนของนักศึกษา ในรายวิชาแคลคูลัส 1 สำหรับวิศวกร จากแผนกที่เป็นนักศึกษาในมหาวิทยาลัยเทคโนโลยีราชมงคลล้านนา เชียงใหม่ ในหล่ายปีการศึกษาที่ผ่านมาพบว่า แต่ละปีการศึกษามีนักศึกษาไม่ผ่านรายวิชานี้ไม่ต่ำกว่าร้อยละ 40 ซึ่งผู้สอนได้พยายามปรับปรุงการจัดการเรียนการสอนหล่ายวิชี แต่ก็สามารถแก้ปัญหาได้เพียงส่วนหนึ่งเท่านั้น ผู้วิจัยซึ่งเป็นผู้สอนรายวิชานี้เห็นว่า ในการแก้ปัญหานั้นควรทำความเข้าใจเกี่ยวกับปัจจัยที่แท้จริงที่มีผลต่อการเรียนรู้ของนักศึกษา ก่อน โดยเฉพาะนักศึกษาที่มีแนวโน้มว่าจะไม่ผ่านรายวิชานี้ ซึ่งถือว่าเป็นกลุ่มเสี่ยงที่น่าจะมีคุณลักษณะบางประการที่จะสามารถบ่งชี้ได้ล่วงหน้า จากการศึกษาพบว่า คุณลักษณะที่มีผลต่อการเรียนมีหลายปัจจัย เช่น ปัจจัยส่วนบุคคล (เพศ [1], [2], [3], [4] รายได้ผู้ปกครอง [2] ทุนการศึกษา [5]) พฤติกรรมด้านความรู้ความคิด (เกรดเฉลี่ยสะสมก่อนเข้าศึกษา [1], [2], [5] เกรดเฉลี่ยสะสม [1], [6] ผลการเรียนรายวิชาอื่นๆ [7] กลุ่มสาขาวิชาที่เรียน [3], [4]) หรือพฤติกรรมด้านต่างๆ ของผู้เรียน เช่น พฤติกรรมการเข้าชั้นเรียนและการทำการบ้าน [8] พฤติกรรมการใช้อินเทอร์เน็ต [9] ซึ่งสอดคล้องกับ Bloom [10] ที่กล่าวว่าคุณลักษณะที่มีผลต่อการเรียนรู้ ประกอบด้วย พฤติกรรมด้านความรู้และความคิด (Cognitive Entry Behaviors) คุณลักษณะทางจิตใจ (Affective Entry Characteristics) และคุณภาพทางการเรียนการสอน (Quality of Instruction) งานวิจัยนี้จึงศึกษาคุณลักษณะทั้ง 3 ด้าน ดังกล่าว รวมถึงปัจจัยส่วนบุคคลอื่นๆ ว่าคุณลักษณะใดที่มีความสำคัญต่อการจำแนกนักศึกษากลุ่มที่มีความเสี่ยงที่จะไม่ผ่านรายวิชา เพื่อเป็นแนวทางในการแก้ปัญหาที่ตรงจุดที่บกพร่องจากคุณลักษณะที่วิเคราะห์ได้

การวิเคราะห์ข้อมูลด้วยเทคนิคเหมืองข้อมูล (Data Mining)

เป็นเทคนิคที่ใช้ในการค้นหาแนวโน้ม รูปแบบร่วม ลักษณะอื่นๆ ที่น่าสนใจ โดยไม่ต้องพึงพากการส่องงานทุกขั้นตอนจากนักวิเคราะห์ แต่จะอาศัยหลักการทางคณิตศาสตร์ สติติ และคอมพิวเตอร์ ซึ่งอาจจะคำนับความรู้ใหม่ๆ ที่น่าสนใจสำหรับนำไปใช้ในการตัดสินใจจากข้อมูลที่นักวิเคราะห์ไม่ได้คาดหมายมาก่อน เป็นเครื่องที่วิเคราะห์ได้รวดเร็ว แม่นยำและนำไปประยุกต์ใช้ได้หลายด้าน [1], [11], [12] เช่น การพยากรณ์ราคายางพารา [11] การทำนายความสามารถในการผลิตของลูกจ้าง [12] การประยุกต์ใช้ในการช่วยนักศึกษาเลือกสาขาวิชาที่เหมาะสม [1] ปัจจุบันได้มีการนำเอาระบบทำเหมืองข้อมูลมาใช้ทางการศึกษา เรียกว่า เหมืองข้อมูลทางการศึกษา (Educational Data Mining) เป็นการพัฒนาวิธีสำรวจสิ่งที่เกี่ยวข้องทางการศึกษาเพื่อหาชนิดของข้อมูลที่ไม่เคยพบมาก่อนหรืออาจเรียกว่าองค์ความรู้ใหม่ และใช้วิธีการเหล่านั้นเพื่อให้เข้าใจนักศึกษาและสิ่งที่เกี่ยวข้องได้ดีขึ้น [13]

วัตถุประสงค์ของงานวิจัยนี้จึงเป็นการนำเอatechniqueวิธีการทำเหมืองข้อมูลมาประยุกต์ใช้กับการศึกษา โดยศึกษาคุณลักษณะสำคัญที่มีผลต่อการเรียนของนักศึกษาในรายวิชาแคลคูลัส 1 สำหรับวิศวกร ในการจำแนกประเภทนักศึกษาออกเป็นกลุ่มที่มีความเสี่ยงที่ไม่ผ่านรายวิชาและกลุ่มที่ไม่มีความเสี่ยง

2. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

งานวิจัยนี้มีวัตถุประสงค์ที่มุ่งเน้นการใช้เทคนิคเหมืองข้อมูลมาประยุกต์กับการศึกษา โดยศึกษาคุณลักษณะสำคัญที่มีผลต่อการเรียนของนักศึกษาโดยใช้วิธีการจำแนกข้อมูล ด้วยอัลกอริทึมโครงข่ายประสาทเทียมและต้นไม้ตัดสินใจ จึงได้แบ่งทฤษฎีและงานวิจัยที่เกี่ยวข้องเป็น 6 ด้าน ได้แก่ เหมืองข้อมูลทางการศึกษา กระบวนการทำเหมืองข้อมูล ด้วยโมเดล CRISP-DM การเลือกคุณลักษณะของข้อมูล โครงข่ายประสาทเทียม ต้นไม้ตัดสินใจ และการทดสอบประสิทธิภาพของโมเดล

2.1 เหมืองข้อมูลทางการศึกษา

เหมืองข้อมูลทางการศึกษาเป็นสาขาวิชาที่เกี่ยวข้องกับการพัฒนาวิธีการสำรวจ ค้นหา องค์ความรู้ที่ถูกซ่อนไว้จากข้อมูลทางการศึกษาจำนวนมาก และใช้วิธีการนี้ในการทำความเข้าใจนักศึกษาและสิ่งที่เกี่ยวข้องกับการจัดการ

ศึกษาได้ดีขึ้น [14] การประยุกต์การทำเหมืองข้อมูลทางการศึกษานั้นแบ่งออกเป็น 4 กลุ่มตามวัตถุประสงค์ คือ (1) เพื่อปรับปรุงโมเดลนักศึกษาซึ่งจะช่วยพัฒนาการเรียนที่เหมาะสมกับศักยภาพของบุคคล (2) เพื่อค้นหาและปรับปรุงโมเดลของโครงสร้างความรู้หลักจากองค์ประกอบในสถาบันการศึกษา เพื่ออธิบายความสัมพันธ์ระหว่างองค์ประกอบ (3) เพื่อสนับสนุนการเรียนการสอนว่าวิธีการสอนใดที่มีประสิทธิภาพมากที่สุดสำหรับนักศึกษาแต่ละคน (4) เพื่อหาหลักฐานจากการศึกษาทดลองเพื่อขยายหรือปรับทฤษฎีและปรับปรุงทางการศึกษาให้ดีขึ้น ออกแบบระบบการเรียนรู้ให้ดีขึ้น [13], [15] ซึ่งจากการศึกษางานวิจัยที่ผ่านมา มีงานวิจัยที่ประยุกต์เทคนิคเหมืองข้อมูลมาใช้ทางการศึกษาจำนวนมาก ดังนี้

งานวิจัยของ เฉลิมพล ทัพชัย และคณะ [6] ได้สร้างโมเดลสำหรับการพยากรณ์ผลการเรียนของนักศึกษา จากข้อมูลผลการเรียน และให้เกรดเฉลี่ยสะสมในภาคการศึกษา ถัดไปซึ่งใช้เป็นคลาสเป้าหมายสำหรับการพยากรณ์ แล้วทำการวิเคราะห์ประสิทธิภาพเบรียบเทียบระหว่าง 4 โมเดล พบว่า โมเดลพยากรณ์ที่สร้างขึ้นด้วยวิธี Decision Tree-J48 ให้ค่าความถูกต้องในการพยากรณ์มากที่สุด มีค่าความถูกต้องสูงที่สุดที่ 89.96% และความผิดพลาดสัมบูรณ์ 0.076 ต่ำกว่าวิธีอื่นๆ

งานวิจัยของ ทิพย์หทัย ทองธรรมชาติ และคณะ [7] ได้ทำนายผลสัมฤทธิ์ทางการเรียนโดยใช้เทคนิคเคมีนในการจัดกลุ่มผลสัมฤทธิ์ทางการเรียน ใช้เทคนิคการคัดเลือกชุดตัวแปรแบบอัตราส่วนเกณร์ร่วมกับวิธีการค้นหาแบบจัดลำดับ ในการคัดเลือกตัวแปรสำคัญสำหรับใช้ในการทำนาย และใช้วิธีโครงข่ายประสาทเทียมแบบแพร์กัลบ์ และชัพพอร์ต เวกเตอร์แมชีนมาใช้ในการจำแนกประเภทผลสัมฤทธิ์ทางการเรียน ตัวแปรที่ใช้ในการทำนาย คือ ข้อมูลภูมิหลัง และข้อมูลผลการเรียนรายวิชา ผลการศึกษาพบว่า ข้อมูลผลการเรียนรายวิชาเป็นข้อมูลสำคัญในการทำนายผลสัมฤทธิ์ทางการเรียน และการจำแนกประเภทด้วยวิธีโครงข่ายประสาทที่ยมแบบแพร์กัลบ์ให้ค่าความถูกต้องสูงกว่า ชัพพอร์ตเวกเตอร์แมชีน

Rafe Torabi และคณะ [4] ได้ประยุกต์ใช้การจำแนกข้อมูลด้วย Bayesian Networks ทำนายคะแนนรายวิชาจากประวัติทางการศึกษา เพศ ภาคการศึกษา และผู้สอน เพื่อเป็นข้อมูล

ในการตัดสินใจเลือกวิชาเรียนให้เหมาะสมกับผู้เรียน อันเป็นปัจจัยหลักที่มีผลต่อการประสิทธิภาพทางการเรียน และลดอัตราการไม่ประสบความสำเร็จทางการเรียน ผลการวิจัยชี้ให้เห็นว่า โมเดลที่สร้างขึ้นสามารถใช้ทำนายได้และใช้เป็นเครื่องมือหนึ่งที่ช่วยแก้ปัญหาในการจัดการเรียนได้

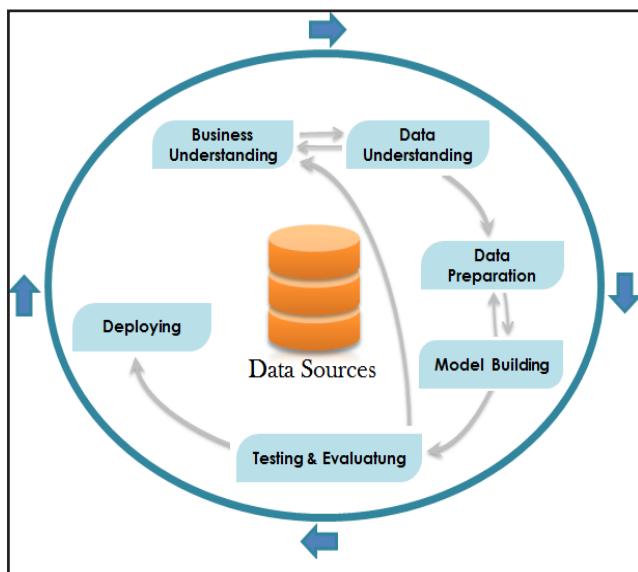
Parneet Kaur และคณะ [16] ได้ประยุกต์เหมืองข้อมูลกับการศึกษาโดยทำการเบรียบเทียบการจำแนกประเภทเพื่อทำนายและวิเคราะห์ลักษณะผู้ที่เรียนช้า 5 วิชี ได้แก่ Multilayer Perceptron, Naïve Bayes, SMO, J48 และ REP Tree พบว่า Multilayer Perceptron เป็นอัลกอริทึมที่ใช้ทำนายได้ดีที่สุด และนอกจากนี้งานวิจัยยังชี้ให้เห็นว่าสามารถช่วยระบุผู้ที่เรียนช้าซึ่งจะช่วยให้สถาบันได้จัดเตรียมสิ่งสนับสนุนเพิ่มเติมเพื่อช่วยผู้เรียนในกลุ่มนี้ได้ล่วงหน้า

งานวิจัยที่นำเสนอี้จะใช้เทคนิคเหมืองข้อมูลในการจำแนกผู้เรียนออกเป็นกลุ่มที่มีความเสี่ยงที่จะไม่ผ่านรายวิชา และกลุ่มที่ไม่มีความเสี่ยงจากคุณลักษณะของนักศึกษาด้วยวิธีโครงข่ายประสาทเทียม และใช้เทคนิคการคัดเลือกคุณลักษณะเพื่อคัดเลือกตัวแปรที่มีความสำคัญมากที่สุดในการจำแนก

2.2 กระบวนการทำเหมืองข้อมูลด้วย CRISP-DM

กระบวนการทำเหมืองข้อมูลตามโมเดลมาตรฐาน CRISP-DM (Cross Industry Standard Process for Data Mining) เป็นโมเดลหนึ่งที่นิยมนำไปประยุกต์ใช้ในงานด้านต่างๆ ที่ต้องการวิเคราะห์ข้อมูลด้วยเทคนิคเหมืองข้อมูล ได้ผลที่รวดเร็วและนาเชื่อถือ [17] และเป็นเครื่องมือที่ช่วยให้ผู้ใช้สามารถเรียนรู้และดำเนินการวิเคราะห์ข้อมูลด้วยเทคนิคเหมืองข้อมูล ได้อย่างถูกต้องและมีประสิทธิภาพ [5] ประกอบด้วย 6 ขั้นตอน ได้แก่ (1) Business Understanding เป็นการแปลงปัญหาที่ได้ให้อยู่ในรูปโจทย์ของการวิเคราะห์ข้อมูล พร้อมทั้งวางแผนในการดำเนินการ (2) Data Understanding เริ่มจากการเก็บรวบรวมข้อมูล แล้วทำการตรวจสอบความถูกต้องของข้อมูลที่รวบรวมมาและพิจารณาว่าจะใช้ข้อมูลทั้งหมดหรือเลือกข้อมูลบางส่วนมาใช้ในการวิเคราะห์ (3) Data Preparation เป็นขั้นตอนที่ทำการแปลงข้อมูลที่ได้ทำการเก็บรวบรวมมาให้เป็นข้อมูลที่สามารถนำไปวิเคราะห์ในขั้นถัดไปได้ โดยการแปลงข้อมูลนี้อาจจะต้องมีการทำข้อมูลให้ถูกต้อง เช่น แปลงข้อมูลให้อยู่ในช่วงเดียวกันหรือการเติมข้อมูลที่ขาดหายไปเป็นขั้นตอนที่ใช้เวลามากที่สุดของ

กระบวนการ CRISP - DM (4) Modeling เป็นขั้นตอนการวิเคราะห์ข้อมูลด้วยเทคนิคเหมืองข้อมูล เช่น การจำแนกกลุ่มข้อมูล (Classification) การจัดกลุ่มข้อมูล (Clustering) การหากฎความสัมพันธ์ของข้อมูล (Association) ซึ่งในขั้นตอนนี้หลายเทคนิคจะถูกนำมาใช้เพื่อให้ได้คำตอบที่ดีที่สุด (5) Evaluation เป็นการวัดประสิทธิภาพของผลลัพธ์ที่ได้จาก การวิเคราะห์ต่างกับวัตถุประสงค์ที่ได้ตั้งไว้หรือไม่ และ มีความน่าเชื่อถือเพียงใด (6) Deployment เป็นการนำความรู้ที่ได้ไปใช้ประโยชน์ต่อในองค์กรหรือบริษัท [18] ซึ่งมีแผนภาพการดำเนินงานตามขั้นตอนดังภาพที่ 1



ภาพที่ 1 กระบวนการวิเคราะห์ข้อมูลด้วย CRISP-DM

2.3 การเลือกคุณลักษณะของข้อมูล

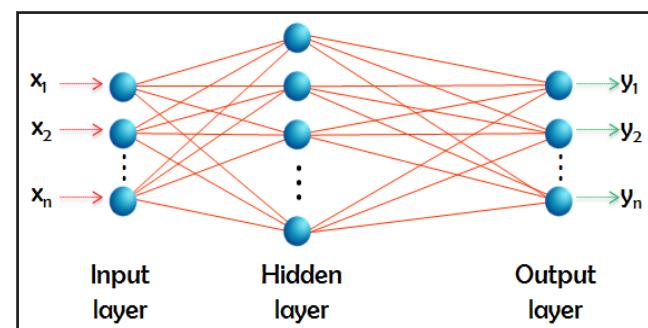
เทคนิคการคัดเลือกคุณลักษณะของข้อมูล (Feature Selection) เป็นเทคนิคที่ช่วยลดจำนวนคุณลักษณะ ซึ่ง เป็นการตัดคุณลักษณะที่มีความสำคัญน้อยหรือไม่สำคัญ ออกไป ทำให้ได้คุณลักษณะของข้อมูลที่มีความสำคัญเพื่อ เพิ่มประสิทธิภาพและความแม่นยำของการจำแนกข้อมูล [3], [19] การคัดเลือกคุณลักษณะแบบได้เป็น 3 ประเภท ได้แก่ Filter, Wrapper และ Embedded [3] ในงานวิจัยนี้ได้ใช้การคัดเลือกคุณลักษณะแบบ Filter ซึ่งเป็นอัลกอริทึมที่มีการคำนวณหาค่าหน้างานซึ่งอาจจะเป็นค่าความสัมพันธ์ระหว่างแต่ละคุณลักษณะและคลาสเป้าหมาย และจะเลือกคุณลักษณะโดย เรียงลำดับตามค่าหน้างานที่คำนวณได้ แล้วเลือกคุณลักษณะที่มีค่าหน้างานมากกว่าที่ต้องการมาใช้งาน [20] มีข้อดีคือ

ไม่ต้องคำนึงถึงขั้นตอนวิธีของการเรียนรู้แบบใดแบบหนึ่ง และประมวลผลได้รวดเร็ว [21]

2.4 โครงข่ายประสาทเทียม

วิธีโครงข่ายประสาทเทียมเป็นโมเดลที่ใช้อย่างแพร่หลาย และได้รับความสนใจมาศึกษาวิจัยอย่างมากใน หลักหลายสาขาวิชา [9], [22] เนื่องจากมีข้อได้เปรียบ หลักประการ เช่น ยอมรับต่อชุดข้อมูลที่มีค่าผิดพลาด (Noisy data) ได้ สามารถจัดหมวดหมู่ตามลักษณะของข้อมูล ได้ด้วยตัวเองซึ่งเป็นการเรียนรู้แบบไม่มีการสอนระบบ (Unsupervised Learning) สามารถจำรูปแบบหรือประมาณ ความสัมพันธ์ที่มีความไม่แน่นอน ซับซ้อน ที่ไม่สามารถ จำลองแบบในเชิงความน่าจะเป็นได้ จึงถูกประยุกต์ใช้ กับงานหลักหลายสาขาวิชาและมักจะให้ความแม่นยำใน การทำนายสูง [23]

โครงข่ายประสาทเทียมมีแนวคิดในการเรียนแบบ การทำงานของระบบประสาทมนุษย์ด้วยโปรแกรมคอมพิวเตอร์ ให้สามารถเรียนรู้และจดจำจากประสบการณ์ที่ผ่านมาได้โดย การเรียนรู้และจดจำของโครงข่ายประสาทเทียมใช้วิธี เพอร์เซปตรอนหลายชั้น (Multilayer Perceptron; MLP) [22] ซึ่งประกอบด้วย 3 ส่วน ได้แก่ ชั้นรับข้อมูลเข้า (Input layer) ชั้นซ่อน (Hidden layer) และชั้นส่งออกผลลัพธ์ (Output layer) ดังแสดงในภาพที่ 2



ภาพที่ 2 แผนภาพโครงข่ายประสาทเทียม

ในแต่ละชั้นประกอบไปด้วยเซลล์ประสาทเทียม (Neuron) เชื่อมตอกันเป็นโครงข่ายเซลล์ประสาทเทียมในชั้นรับข้อมูล ทำหน้าที่รับข้อมูลและส่งต่อไปยังเซลล์ประสาทเทียมในชั้น ซ่อนเพื่อทำการคำนวณความสอดคล้องของข้อมูล หลังจากนั้นส่งต่อไปยังชั้นแสดงผลลัพธ์ ซึ่งสามารถคำนวณได้ตาม สมการที่ 1

$$y = \sum_{i=1}^n w_i x_i \quad (1)$$

โดย y คือ ผลลัพธ์
 X คือ ข้อมูลในชั้นรับข้อมูล
 w คือ น้ำหนักการเชื่อมต่อระหว่างชั้น

2.5 ต้นไม้เต็ตสินใจ

ต้นไม้เต็ตสินใจเป็นเทคนิคหนึ่งของการจำแนกข้อมูลที่ถูกใช้อย่างแพร่หลายเนื่องจากให้ผลลัพธ์เป็นโครงสร้างของต้นไม้ทำให้เข้าใจและอธิบายความสัมพันธ์ได้ดี [24] งานวิจัยนี้ใช้อัลกอริทึม J48 หรืออัลกอริทึมของ C4.5 ซึ่งถูกพัฒนาขึ้นมาโดย J. Ross Quinlan ใช้หลักการของ Information Gain หรือ Entropy Reduction เพื่อจำแนก Node โดยการทดลองเลือกแต่ละคุณลักษณะมาทำหน้าที่เป็น Root Node และวัดค่า Gain ซึ่งเป็นค่าที่ชี้ว่าคุณลักษณะนั้นจะช่วยจำแนกคลาส (Leaf) ของข้อมูลได้เพียงใด คุณลักษณะที่มีค่า Gain สูงที่สุดก็จะเป็น Root Node และ Node ถัดไปจะมีค่า Gain ลดลงนั่นกันไป [25], [26] สูตรที่ใช้ในการคำนวณหาค่า Gain ตามสมการที่ 3 ต้องเริ่มจากการหาค่า Entropy ดังสมการที่ 2

$$\text{Entropy}(S) = - \sum_{i=1}^n p_i \log_2 p_i \quad (2)$$

โดย S คือ คุณลักษณะที่นำมาวัดค่า Entropy

p_i คือ สัดส่วนของจำนวนสมาชิกของกลุ่ม i กับจำนวนสมาชิกทั้งหมดของกลุ่มตัวอย่าง

$$\text{Gain}(S, A) = \text{Entropy}(S) - \sum_{v \in \text{Values}(A)} \frac{|S_v|}{S} \text{Entropy}(S_v) \quad (3)$$

โดยที่ A คือ คุณลักษณะ A

$|S_v|$ คือ สมาชิกของคุณลักษณะ A ที่มีค่า v

$|S|$ คือ จำนวนสมาชิกของกลุ่มตัวอย่าง

2.6 การทดสอบประสิทธิภาพของโมเดล

วิธีทดสอบประสิทธิภาพของโมเดลโดยวิธีการตรวจสอบ k -fold (k-Fold Cross Validation) เป็นวิธีที่นิยมใช้เนื่องจากเป็นการลดความผิดพลาดของผลลัพธ์จากการสุ่มเลือกกลุ่มข้อมูลให้ระบบเรียนรู้ (Training data) และกลุ่มทดสอบโมเดล (Testing data) ที่ไม่เหมาะสม [5] การวัดประสิทธิภาพด้วยวิธีนี้ทำได้โดยการแบ่งข้อมูลออกเป็น k ส่วนเท่าๆ กัน ซึ่งในงานวิจัยนี้กำหนดให้ $k = 10$ ข้อมูลหนึ่งส่วนจะใช้เป็นชุด

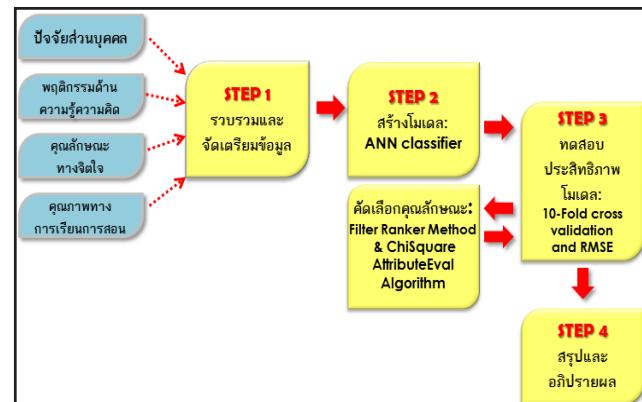
ทดสอบประสิทธิภาพของโมเดล (Testing data) และ 9 ส่วนที่เหลือเป็นชุดสอนให้ระบบเรียนรู้ (Training data) จากนั้นจะเปลี่ยนชุดข้อมูลส่วนถัดไปเป็นชุดทดสอบ ส่วนที่เหลือเป็นชุดสอนให้ระบบเรียนรู้ ทำงานไปเช่นนี้จนครบทั้ง 10 ส่วน

3. วิธีดำเนินการวิจัย

งานวิจัยนี้ดำเนินตามขั้นตอน CRISP-DM ดังนี้

3.1 Business Understanding

งานวิจัยนี้ได้ศึกษาคุณลักษณะที่มีผลต่อการเรียน ได้แก่ พฤติกรรมด้านความรู้และความคิด คุณลักษณะทางจิตใจ และคุณภาพทางการเรียนการสอน รวมถึงปัจจัยส่วนบุคคล อีนๆ ว่าคุณลักษณะใดมีความสำคัญในการจำแนกนักศึกษา ที่จัดเป็นกลุ่มเสี่ยงที่จะไม่ผ่านรายวิชาแคลคูลัส 1 สำหรับวิศวกร โดยมีการวางแผนดังภาพที่ 3



ภาพที่ 3 ขั้นตอนการทำเหมืองข้อมูลของงานวิจัยนี้

3.2 Data Understanding

งานวิจัยนี้ทำการเก็บข้อมูลคุณลักษณะที่ใช้เป็นตัวแปรนำเข้าจากแบบสำรวจเกี่ยวกับข้อมูลส่วนบุคคล (เช่น เพศ อายุ งานพิเศษ เงินกู้เพื่อการศึกษา) ผลการเรียนปรับพื้นฐานทางคณิตศาสตร์ ข้อมูลด้านการศึกษาในระดับปริญญาตรี (เช่น วุฒิการศึกษา สังกัดสถานศึกษา เกรดเฉลี่ย) แบบวัดเจตคติและความสนใจต่อวิชาคณิตศาสตร์และแบบประเมินความคิดเห็นต่อระบบการเรียนและสถาบัน รวมถึงผลการเรียนในรายวิชาแคลคูลัส 1 สำหรับวิศวกร เพื่อให้ครอบคลุมคุณลักษณะทั้ง 3 ด้าน รวมถึงปัจจัยส่วนบุคคลอีนๆ รวม 50 คุณลักษณะ โดยข้อมูลทั้งหมดได้มาจากนักศึกษาคณิตศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลล้านนา เชียงใหม่ จำนวน 453 คน



3.3 Data Preparation

หลังจากที่ได้ข้อมูลที่รวบรวมแล้ว จึงทำการเตรียมข้อมูล โดยการทำให้ข้อมูลมีความสมบูรณ์ ถูกต้อง (Data Cleaning) ทำการคัดเลือกข้อมูล (Data Selection) และเปลี่ยนรูปแบบข้อมูลให้อยู่ในรูปแบบที่เหมาะสมในการวิเคราะห์ (Data Transformation) เช่น ตัวแปรคุณวุฒิของนักศึกษา ก่อนเข้ามายังมหาวิทยาลัย มีการกำหนดให้ “ 1 ” แทนคุณวุฒิระดับปวช. “ 2 ” แทนคุณวุฒิระดับปวส. และ “ 3 ” แทนคุณวุฒิระดับมัธยมศึกษาตอนปลาย เป็นต้น โดยมีรายละเอียดดังแสดงในตารางที่ 1

ตารางที่ 1 การแปลงข้อมูลนำเข้า

Input Variable (Attribute)	Domain : Normalized Score
Gender	Male : 1, Female : 2
Age	17-19: 1, 20-22: 2, 23-25: 3, > 25: 4
Major	Electricity: ELT, Mechanic: MED, Civil: CIV, Industry: IND, Computer: COM, Tool&Die: T&D, Electronic: ELE, Mining: MIN, Agriculture: AGR
Curriculum	Regular(4years): 1, Special(4years): 2, Regular(2years): 3, Special(2years): 4
Loan	Yes: 1, No: 2
Accommodations	Family House: 1, Relatives House: 2, Dormitory: 3, Other: 4
Job	Yes : 1, No : 2
Parent Income	0–15000 bt.: 1, 15001–30000 bt.: 2, 30001–45000 bt.: 3
Father Career	Agriculture: 1, Bureaucrat: 2, Contractor: 3, Merchant: 4, Other: 5
Mother career	Agriculture: 1, Bureaucrat: 2, Contractor: 3, Merchant: 4, Other: 5
Father Education	Undergraduate: 1, Graduate: 2, Postgraduate: 3
Mother Education	Undergraduate: 1, Graduate: 2, Postgraduate: 3
Qualification	Vocational Certificate: VC High Vocational Certificate: HVC High School: HS
Institution at High Level	Government: GO, Private: PR
GPA	0–1.99: 1, 2.00–2.49: 2, 2.50–2.99: 3, 3.00–3.49: 4, 3.50–4.00: 5
Math GPA	0–1.99: 1, 2.00–2.49: 2, 2.50–2.99: 3, 3.00–3.49: 4, 3.50–4.00: 5
Math Pre Test Score	0–6: 1, 7–12: 2, 13–18: 3, 19–24: 4, 25–30: 5
Mathematics Attitude (17 items)	Rating scale; Strongly Disagree: 1, Disagree: 2 Neither Agree/Nor Disagree: 3, Agree: 4 Strongly Agree: 5
Opinion of Quality Instruction (16 items)	Rating scale; Strongly Disagree: 1, Disagree: 2 Neither Agree/Nor Disagree: 3, Agree: 4 Strongly Agree: 5
Grade	< D+ : Risk > D+ : No risk

3.4 Model Building

งานวิจัยนี้ใช้เทคนิคการจำแนกประเภทข้อมูล (Data Classification) ด้วยวิธีโครงข่ายประสาทเทียมและต้นไม้ตัดสินใจด้วยโปรแกรม WEKA เพื่อจัดข้อมูลให้อยู่ในกลุ่มที่กำหนด คือ กลุ่มที่มีความเสี่ยงจะไม่ผ่านรายวิชา และกลุ่มที่ไม่มีความเสี่ยง

หลังจากที่ได้ผลจากการวิเคราะห์ข้อมูลเบื้องต้นจาก 50 คุณลักษณะแล้ว ในงานวิจัยนี้ใช้เทคนิคการคัดเลือกคุณลักษณะของข้อมูลด้วย Filter Ranker Method โดยเปรียบเทียบการคำนวณค่าหน้าหักด้วย Chi-Square และ Gain Ratio

3.5 Testing and Evaluation

ในงานวิจัยนี้ใช้วิธีทดสอบประสิทธิภาพของโมเดลโดยวิธีการตรวจสอบทั่วไป (k-Fold Cross Validation) โดยกำหนดให้ $k = 10$ (10-Fold Cross Validation)

3.6 Deployment

การวิเคราะห์ข้อมูลด้วยเทคนิคเหมืองข้อมูลจะทำให้ได้คุณลักษณะที่มีความสำคัญต่อการจำแนกนักศึกษากลุ่มที่มีความเสี่ยงที่จะไม่ผ่านรายวิชาและคุณลักษณะที่สำคัญต่อการเรียนรู้วิชาที่บกพร่องจากคุณลักษณะที่วิเคราะห์ได้

4. ผลการดำเนินงาน

ผลการวิเคราะห์คุณลักษณะที่มีผลต่อการเรียนทั้ง 3 ด้าน และปัจจัยส่วนบุคคลอื่นๆ จำนวน 50 คุณลักษณะ แสดงในตารางที่ 2

ตารางที่ 2 Confusion Matrix ของผลการจำแนกข้อมูลโดย ANN และ Decision Trees - J48

	Risk	No Risk	Accuracy (%)
Artificial Neural Network (ANN)			
Risk	145	60	70.73
No Risk	69	179	72.18
	<i>Overall</i>		71.52
Decision Trees - J48			
Risk	122	83	59.51
No Risk	70	178	71.77
	<i>Overall</i>		66.23

จากผลการวิเคราะห์ในตารางที่ 2 พบว่า ค่าความแม่นยำในการจำแนกข้อมูลด้วย ANN มีค่า 71.52% และ Decision

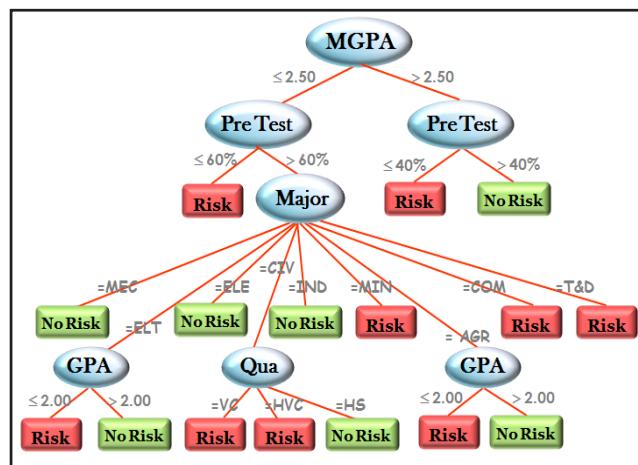
Trees-J48 มีค่า 66.23% ซึ่งค่าที่ได้นี้ยังมีความแม่นยำไม่มากพอ ซึ่งอาจเป็นผลจากคุณลักษณะบางอย่างที่ไม่เกี่ยวข้องหรือมีความสำคัญน้อย จึงทำการคัดเลือกคุณลักษณะที่สำคัญใหม่ด้วย Filter Ranker Method โดยใช้การคำนวณค่าหน้าหักด้วย Chi-Square และ Gain Ratio ทำให้ลดจำนวนคุณลักษณะได้ 60% จากนั้นจึงใช้ 5, 7 และ 10 คุณลักษณะแรก ตามลำดับ มาทำการวิเคราะห์อีกรอบ ได้ผลเปรียบเทียบกับก่อนคัดเลือกคุณลักษณะดังแสดงในตารางที่ 3

ตารางที่ 3 ผลการจำแนกข้อมูลก่อนและหลังการคัดเลือกคุณลักษณะ

Filter Ranker Method	Attributes	Accuracy Percentage	
		ANN	Decision Tree-J48
Chi-Square	5	80.13	75.83
	7	78.15	75.06
	10	75.94	74.39
Gain Ratio	5	72.41	72.85
	7	76.82	74.83
	10	72.63	73.73
No Feature Selection	50	71.52	66.23

พบว่า การจำแนกข้อมูลด้วย ANN จาก 5 คุณลักษณะแรกที่ได้จากการคัดเลือกคุณลักษณะโดยวิธี Filter Ranker Method ที่คำนวณค่าหน้าหักด้วย Chi-Square ทำให้ได้ค่าความถูกต้องสูงสุดคือ 80.13% และการจำแนกข้อมูลด้วย Decision Tree ก็ให้ผลในทางเดียวกัน โดยมีค่าความถูกต้องสูงสุด 75.83% คุณลักษณะจากการจัดอันดับทั้ง 5 ได้แก่ 1) เกรดเฉลี่ยคณิตศาสตร์ก่อนระดับปริญญาตรี 2) คะแนนสอบพื้นฐานทางคณิตศาสตร์ก่อนเรียน 3) GPA ก่อนระดับปริญญาตรี 4) สาขาวิชา และ 5) คุณวุฒิทางการศึกษา ก่อนปริญญาตรี ซึ่งเมื่อพิจารณาจากผลการจำแนกข้อมูลด้วย Decision Tree ดังแสดงในภาพที่ 4 พบว่า เมื่อต้องการทราบว่านักศึกษาอยู่ในกลุ่มเสี่ยงที่จะไม่ผ่านรายวิชาหรือไม่นั้นจะพิจารณาจากคุณลักษณะและเงื่อนไขที่กำหนดไว้ในโหนดต่างๆ ใน Decision Tree โดยพิจารณาลงมาตามทางของต้นไม้ที่จะหนดที่ตรงกับลักษณะของนักศึกษา จนกระหึ่งถึงคลาสปลายทาง [1] คือ เสี่ยง (Risk) ที่จะไม่ผ่านรายวิชา หรือ ไม่มีความเสี่ยง (No Risk) จาก Decision Tree ในภาพที่ 4 ทำให้สรุปได้ว่า คุณลักษณะแรกที่ควรพิจารณา

ก่อนคือ เกรดเฉลี่ยคณิตศาสตร์ก่อนระดับปริญญาตรีของนักศึกษา หากอยู่ในระดับสูงกว่า 2.50 และมีคะแนนสอบพื้นฐานทางคณิตศาสตร์ก่อนเรียนสูงกว่า 40% จะไม่มีความเสี่ยง เด็กต่ำกว่า 2.50 และมีคะแนนสอบพื้นฐานทางคณิตศาสตร์ก่อนเรียนต่ำกว่า 60% ถือว่าเสี่ยง แต่ถ้าสูงกว่า 60% จะพิจารณาสาขาวิชาที่เรียนดังนี้ สาขาวิเครื่องกล อิเล็กทรอนิกส์และอุตสาหการ ไม่มีความเสี่ยง สาขาวิเหมืองแร่ แม่พิมพ์และคอมพิวเตอร์ อยู่ในกลุ่มเสี่ยง และสาขาวิเครื่องจักรกลเกษตร ไฟฟ้า และโยธา มีเงื่อนไขที่ต้องพิจารณาต่อไป คือ สาขาวิเครื่องจักรกลเกษตรและสาขาวิไฟฟ้าที่มี GPA ก่อนระดับปริญญาตรีต่ำกว่า 2.00 อยู่ในกลุ่มเสี่ยง ส่วนสาขาวิชาโยธาจะพิจารณาต่อที่คุณวุฒิการศึกษา ก่อนปริญญาตรี หากมีคุณวุฒิระดับมัธยมปลาย จะไม่มีความเสี่ยง แต่หากมีคุณวุฒิปวช.และปวส. จะอยู่ในกลุ่มเสี่ยง



ภาพที่ 4 Decision Tree การจำแนกนักศึกษาออกเป็นกลุ่มเสี่ยง/ไม่เสี่ยง

5. สรุป

การวิจัยนี้ได้ใช้เทคนิคเหมืองข้อมูลเพื่อมาวิเคราะห์คุณลักษณะในด้านต่างๆ ของนักศึกษาระดับปริญญาตรี ชั้นปีที่ 1 ที่มีผลต่อการเรียนเพื่อหาว่าคุณลักษณะใดที่มีความสำคัญในการบ่งชี้ว่านักศึกษามีความเสี่ยงที่จะไม่ผ่านรายวิชาและคุณลักษณะใดที่จะช่วยให้ผ่านรายวิชา ผลการวิเคราะห์ได้มาในรูปแบบของต้นไม้ที่มีโหนดต่างๆ ที่แสดงถึงคุณลักษณะต่างๆ ของนักศึกษา ที่มีผลต่อการเรียน ต่อไปนี้ คือ 1) Business understanding (1) Business understanding (2) Data understanding (3) Data preparation (4) Model

building (5) Testing and evaluation และ (6) Deployment และจำแนกข้อมูลออกเป็น 2 กลุ่ม คือ กลุ่มที่มีความเสี่ยงที่จะไม่ผ่านและกลุ่มที่ไม่มีความเสี่ยง โดยใช้วิธีโครงข่ายประสาทเทียม (ANN) ด้วยเทคนิค MLP และ Decision Tree - J48 ผลการวิเคราะห์พบว่า ความแม่นยำในการจำแนกข้อมูลในการคัดเลือกคุณลักษณะทางการศึกษาวิธี ANN มีค่า 71.52% และ Decision Tree มีค่า 66.23% และหลังการคัดเลือกคุณลักษณะพบว่า การจำแนกข้อมูลด้วยวิธี ANN จาก 5 คุณลักษณะแรกที่ได้จากการคัดเลือกคุณลักษณะโดยวิธี Filter Ranker Method ที่คำนวณค่าน้ำหนักด้วย Chi-square ทำให้ได้ความถูกต้องสูงสุดคือ 80.13% และการจำแนกข้อมูลด้วย Decision Tree ก็ให้ผลในทางเดียวกัน โดยมีความถูกต้องสูงสุดที่ 75.83% ซึ่งจะเห็นว่าคุณลักษณะที่มีความสำคัญต่อการจำแนกข้อมูลคือ คุณลักษณะที่เกี่ยวข้องกับความรู้พื้นฐานของนักศึกษาที่มีมาก่อน สอดคล้องกับพฤติกรรมด้านความรู้และความคิด (Cognitive Entry Behaviors) ตามทฤษฎีการเรียนรู้ของ Bloom [10]

ผลการวิเคราะห์นี้แสดงให้เห็นว่าเทคนิคเหมือนของข้อมูลสามารถนำมาวิเคราะห์ข้อมูลทางการศึกษาและวิเคราะห์คุณลักษณะพื้นฐานทางการศึกษาที่มีผลต่อการเรียนของนักศึกษาในระดับปริญญาตรีได้ นอกจากนี้การเลือกคุณลักษณะพื้นฐานทางการศึกษาที่มีความสอดคล้องกับความเป็นจริงของนักศึกษาคือปัจจัยหนึ่งที่จะทำให้การวิเคราะห์มีประสิทธิภาพและความถูกต้องมากขึ้น เพื่อนำผลการวิเคราะห์ไปปรับปรุงและพัฒนาการเรียนการสอนให้ดีขึ้นทั้งทางด้านวิธีการสอน สื่อการเรียนการสอนและสิ่งสนับสนุนอื่นๆ เป็นต้น

6. เอกสารอ้างอิง

- [1] K. Waimai, C. Songsiri and T. Rakthamanon. "An Improved Quality of Engineering Graduates by Proposing Data Mining System." *NECTEC Technical Journal*, Vol. 3, No. 11, pp. 134-142, 2001.
- [2] P. Butheak and S. Boonlue. "Graduation Forecasting Science and Technology Silpakorn University," Vol. 1, No. 6, pp. 40-49, November-December, 2014.
- [3] T. Nilmanee, S. Saelee, and S. Krootjohn. "The Feature Selection for Student's Success with Neural Network by Classification." *The 9th National Conference on Computing and Information Technology*, pp. 761-766, 2013.
- [4] R. Torabi, P. Moradi and A. R. Khantaimoori. "Predict Student Scores Using Bayesian Networks." *Procedia-Social and Behavioral Sciences*, Vol. 46, pp. 4476 – 4480, 2012.
- [5] B. Sen, E. Ucar, and D. Delen. "Predicting and Analyzing Secondary Education Placement-Test Scores: A Data Mining Approach." *Expert Systems with Applications*, Vol. 39, pp. 9468–9476, 2012.
- [6] C. Tapsai, P. Meesad and S. Chunngam. "Prediction of Student Achievement of Suan Sunandha Rajabhat University by Data Mining." *Conference on ACTIS & NCOBA*, pp. 160-164, 2015.
- [7] T. Thongthammachart, N. Chanamarn, and P. Sittidech. "Applying Classify Techniques for Predicting Learning Achievement." *The Eighth National Conference on Computing and Information Technology*, pp. 598-604, 2012.
- [8] J.F. Superby, J. P. Vandamme, and N. Meskens. "Determination of Factors Influencing the Achievement of The First-Year University Students Using Data Mining Methods." *Proceedings of the Workshop on Educational Data Mining at the 8th International Conference on Intelligent Tutoring Systems*, pp. 37-44, 2006.
- [9] T. Prakobpol. "A Comparison of Forecasting Grade Point Average Between Neural Network and Multiple Regression Methods from Internet Usage Behavior Among Students in Faculty of Science and Technology Huachiew Chalermprakiet University." *HCU Journal*, Vol. 16, No. 31, pp. 49-64, July-December, 2012.
- [10] N. Senemoglu and K. Fogelman. "Effects of Enhancing Behavior of Students and Use of Feedback-Corrective Procedures." *The Journal of Educational Research*, Vol. 89, No.1, pp. 59-63, 1995.
- [11] J. Chuainakorn and M. Rattanasiriwongwut.



“The System of Rubber Price Forecast Using Neural Technique A Case Study: Rubber Research Institute of Thailand.” *The 5th National Conference on Computing and Information Technology*, pp. 845-850, 2009.

[12] M. Kaya, A. E. Keles and E. L. Oral. “Construction Crew Productivity Prediction by Using Data Mining Methods.” *Procedia-Social and Behavioral Sciences*, Vol. 141, pp. 1249 – 1253, 2014.

[13] W. Srisujjalertwaja and D. Praserttipong. “Educational Data Mining.” *The Quarterly Journal of Science CMU*, Vol. 20, pp. 9-12, July-September, 2014.

[14] *Educational Data Mining*. Available Online at <http://www.educationaldatamining.org>, accessed on 25 December 2016.

[15] R. S. Baker and K. Yacef. “The State of Educational Data Mining in 2009: A Review and Future Visions.” *Journal of Educational Data Mining*, Vol. 1, No. 1, pp. 3-16, 2009.

[16] P. Kaur, M. Singh, G. S. Josan. “Classification and Prediction Based Data Mining Algorithms to Predict Slow Learners in Education Sector.” *Procedia Computer Science*, Vol. 57, pp. 500 – 508, 2015.

[17] C. Shearer. “The CRISP-DM model: The New Blueprint for Data Mining.” *Journal of Data Warehousing*, Vol. 5, No. 4, pp. 13-22, 2000.

[18] E. Pacharawongsakda. *CRISP-DM*. Available Online at <http://dataminingtrend.com/2014/data-mining-techniques/crisp-dm-example>, accessed on 20 January 2017.

[19] M. Ramaswami and R. Bhaskaran. “A Study on Feature Selection Techniques in Educational Data Mining.” *Journal of Computing*, Vol. 1, No. 1, pp. 7-11, 2009.

[20] E. Pacharawongsakda. *Feature Selection Using Information Gain*. Available Online at <http://dataminingtrend.com/2014/data-mining-techniques/feature-selection-information-gain>, accessed on 21 September 2017.

[21] P. Juncharern, S. Hengphraphorm, and K. Hengphraphorm. “An Efficiency Comparison of Feature Selection Methods for Microarray Data Classification.” *Proceedings of the 8th NPRU National Academic Conference*. pp. 496-504, 2016.

[22] O. E. Askin and F. Gokalp. “Comparing the Predictive and Classification Performances of Logistic Regression and Neural Networks A Case Study on Timss 2011.” *Procedia - Social and Behavioral Sciences*, Vol. 106, pp. 667 – 676, 2013.

[23] J. Han and M. Kamber. “Chapter 6 Classification and Prediction.” *DATA MINING: Concepts and Techniques*, Second Edition, Published by Morgan Kaufmann Publishers, ISBN 1-55860-901-6, 2006.

[24] O. Panto, M. Theantong. “A Comparative Efficiency of Classification of VARK Learning Style Using Data Mining Techniques.” *Journal of Industrial Technology Ubon Ratchathani Rajabhat University*, Vol. 4, No. 1, pp. 1-11, January-June, 2014.

[25] S. Pilabutr. “Prediction to Graduation with Data Mining.” *Sripatum Chonburi Journal*, Vol. 12, No. 6, August, 2016.

[26] P. Palwisut. Improving Decision Tree Technique in Imbalanced Data Sets Using SMOTE for Internet Addiction Disorder Data.” *Information Technology Journal*, Vol. 12, No. 1, pp. 54-63, January-June, 2016.