



การพัฒนาโมเดลทำนายแผนการเรียนในการศึกษาต่อระดับมัธยมศึกษาตอนปลายของนักเรียน
โรงเรียนสาธิตจุฬาลงกรณ์มหาวิทยาลัย ฝ่ายมัธยม : การประยุกต์ใช้เทคนิคเอนเซมเบิลโหวตร่วมกัน
ระหว่างเครือข่ายประสาท ชัฟฟอร์ตเวกเตอร์แมชชีน และต้นไม้ตัดสินใจ

Development of Prediction Model for Futuring Study Plans in Upper Secondary
School of Chulalongkorn University Demonstration Secondary School Students:
An Application of Ensemble Vote together with Neural Network,
Support Vector Machine and Decision Tree

ธนพัฒน์ ทองมา¹

Thanapat Thongma¹

บทคัดย่อ

การวิจัยครั้งนี้มีวัตถุประสงค์เพื่อ 1) ศึกษาประสิทธิภาพของโมเดลทำนายแผนการเรียนของนักเรียนในการศึกษาต่อระดับมัธยมศึกษาตอนปลายที่ได้จากการวิเคราะห์ด้วยเครือข่ายประสาท ชัฟฟอร์ตเวกเตอร์แมชชีน ต้นไม้ตัดสินใจ และเอนเซมเบิลโหวต และ 2) เปรียบเทียบประสิทธิภาพของโมเดลทำนายแผนการเรียนของนักเรียนในการศึกษาต่อระดับมัธยมศึกษาตอนปลายที่ได้จากการวิเคราะห์ด้วยแต่ละเทคนิค ประชากรที่ใช้ในการวิจัยครั้งนี้คือ นักเรียนชั้น ม.6 โรงเรียนสาธิตจุฬาลงกรณ์มหาวิทยาลัย ฝ่ายมัธยม ตัวอย่าง คือ นักเรียนรุ่นที่ 50 ถึง รุ่นที่ 53 จำนวน 787 คน ใช้โปรแกรมคอมพิวเตอร์ในการวิเคราะห์ข้อมูล ผลการวิจัยสรุปว่า โมเดลทำนายแผนการเรียนที่ได้จากการวิเคราะห์ด้วยแต่ละเทคนิคมีประสิทธิภาพการทำนายไม่แตกต่างกันมากนัก สำหรับโมเดลที่มีประสิทธิภาพการทำนายดีที่สุด คือ โมเดล S-E ซึ่งเป็นโมเดลที่สามารถใช้ทำนายกลุ่มการเรียนที่เหมาะสมกับนักเรียนใน 2 กลุ่มการเรียนหลัก ได้แก่ กลุ่มการเรียนวิทย์ และกลุ่มการเรียนศิลป์ โดยมีประสิทธิภาพของการทำนายด้วยเทคนิคเอนเซมเบิลโหวตได้ถูกต้องสูงที่สุด คิดเป็นร้อยละ 80.05 นอกจากนี้ยังพบว่า ผลการเรียนเฉลี่ยกลุ่มสาระการเรียนรู้คณิตศาสตร์ ระดับมัธยมศึกษาตอนต้น มีความสำคัญและมีอิทธิพลต่อการเลือกแผนการเรียนเป็นอย่างมาก

คำสำคัญ: เครือข่ายประสาท, ชัฟฟอร์ตเวกเตอร์แมชชีน, ต้นไม้ตัดสินใจ, เอนเซมเบิลโหวต

Abstract

The purposes of this research were to: (1) study the effectiveness of the prediction model for futuring study plans from a neural network, support vector machine, decision tree, and ensemble vote; and (2) compare the effectiveness of the prediction model for futuring study plans from those techniques. The research population included 787 Mathayom 6 students of Chulalongkorn University Demonstration School including Chulalongkorn University Demonstration School Class of 50–53. A computer program was used to analyse the neural network, support vector machine, decision tree, and ensemble vote. The research results indicate that there were only slight differences in the prediction model for futuring study plans from each technique. The S-E model could predict two suitable majors, with its best predictive performance for Science and Art. The S-E model with ensemble vote had an efficiency of 80.05 percent. Besides, the lower secondary school level GPA in Mathematics was the most important and had the greatest influence on the study plan selection.

Keywords: neural network, support vector machine, decision tree, ensemble vote

บทนำ

การจัดการศึกษาตามหลักสูตรมัธยมศึกษาตอนปลายในประเทศไทย แบ่งเป็นแผนการเรียนตามความถนัดและความสนใจของนักเรียน เพื่อมุ่งเน้นการเพิ่มพูนความรู้และทักษะเฉพาะด้าน สนองตอบความสามารถ ความถนัดและความสนใจของนักเรียนแต่ละคนทั้งด้านวิชาการและวิชาชีพ นักเรียนสามารถนำความรู้ไปประยุกต์ใช้ให้เกิดประโยชน์ในการศึกษาต่อและการประกอบอาชีพในอนาคตได้ (กระทรวงศึกษาธิการ, 2552) แผนการเรียนเหล่านี้มุ่งเน้นเนื้อหาในแต่ละกลุ่มสาระวิชาที่แตกต่างกันออกไป นำไปสู่การศึกษาในระดับอุดมศึกษาและอาชีพที่แตกต่างกัน นักเรียนที่เลือกเรียนในบางแผนการเรียนจะมีทางเลือกทางการศึกษาในระดับอุดมศึกษาและอาชีพในอนาคตที่จำกัด ดังนั้น การเลือกแผนการเรียนในการศึกษาต่อระดับมัธยมศึกษาตอนปลายในระบบการศึกษาของประเทศไทย จึงนับได้ว่าเป็นการตัดสินใจทางอาชีพครั้งสำคัญสำหรับนักเรียนชั้นมัธยมศึกษาปีที่ 3 ถ้านักเรียนเลือกแผนการเรียนที่ไม่ตรงกับความสามารถหรือความสนใจที่ตนเองถนัดย่อมนำไปสู่ปัญหาที่ตามมา คือ เรียนไม่ทันเพื่อน เรียนไม่รู้เรื่อง เปื่อหน่ายในการเรียน มีผลการเรียนที่ไม่ดี ทำให้นักเรียนรู้สึกไม่มั่นใจ และกลัวว่าจะเรียนไม่จบ จนมีผลทำให้ต้องเปลี่ยนแผนการเรียนหรือลาออกจากการเป็นนักเรียน

(กรมวิชาการ, 2533; ปรศนีย์ อัมเครือ, 2554; สุพัฒน์กุล ภัคโชค, 2555)

โรงเรียนสาธิตจุฬาลงกรณ์มหาวิทยาลัย ฝ่ายมัธยม เป็นสถานศึกษาที่จัดตั้งขึ้นโดยมีวัตถุประสงค์เพื่อเป็นสถานฝึกหัดวิชาชีพรู (laboratory school) สำหรับนิสิตคณะครุศาสตร์ และจัดการศึกษาระดับชั้นมัธยมศึกษาให้กับนักเรียนทุกคนตามความสนใจ ความถนัด และศักยภาพของแต่ละบุคคล โดยเฉพาะอย่างยิ่งนักเรียนชั้นมัธยมศึกษาปีที่ 3 เป็นระดับชั้นที่สำคัญต่อการตัดสินใจเลือกศึกษาต่อในระดับมัธยมศึกษาตอนปลาย การเลือกศึกษาต่อในแผนการเรียนที่เหมาะสมกับความสามารถและความสนใจของตนเองถนัดมากที่สุดจะทำให้ นักเรียนสามารถเรียนรู้ได้อย่างมีความสุขและประสบความสำเร็จตามเป้าหมายในอนาคต หากนักเรียนเลือกแผนการเรียนที่ไม่ตรงกับความสามารถหรือความสนใจที่ตนเองถนัดแล้ว นักเรียนอาจตัดสินใจเปลี่ยนแผนการเรียนในภายหลัง ซึ่งการเปลี่ยนแผนการเรียนกลางคัน ทำให้เกิดการสูญเสียเวลาและโอกาส (สุพัฒน์กุล ภัคโชค, 2555; หน่วยทะเบียนและประเมินผล, 2560)

ข้อมูลสถิติจำนวนนักเรียนแผนการเรียนวิทย์-คณิต โรงเรียนสาธิตจุฬาลงกรณ์มหาวิทยาลัย ฝ่ายมัธยม ปีการศึกษา 2556-2559 ของหน่วยทะเบียนและประเมินผล (2560) (ตาราง 1) พบว่า นักเรียนแผนการเรียนวิทย์-คณิตจำนวนหนึ่งทำเรื่องขอย้ายแผนการเรียนระหว่างการเรียนไปเรียนแผนการเรียนอื่น เช่น ศิลป์-คณิต ศิลป์-ภาษา ศิลป์-อหส (ภาษาอังกฤษ-ไทย-สังคม) นักเรียนกลุ่มนี้เกิดการสูญเสียเวลาในการเรียนวิชาคณิตศาสตร์เพิ่มเติม ฟิสิกส์ เคมี และชีววิทยา ที่ได้เรียนมาก่อนหน้านี้ หรือแม้แต่เรียนที่ย้ายจากแผนการเรียนศิลป์-คณิตไปยังแผนการเรียนศิลป์อื่น ก็เกิดการสูญเสียเวลาในการเรียนวิชาคณิตศาสตร์เพิ่มเติมเช่นกัน

ตาราง 1

ข้อมูลสถิติจำนวนนักเรียนแผนการเรียนวิทย์-คณิต โรงเรียนสาธิตจุฬาลงกรณ์มหาวิทยาลัย ฝ่ายมัธยม
ปีการศึกษา 2556-2559

นักเรียน รุ่น	ปีการศึกษา							
	2556		2557		2558		2559	
	ภาคเรียน ที่ 1	ภาคเรียน ที่ 2	ภาคเรียน ที่ 1	ภาคเรียน ที่ 2	ภาคเรียน ที่ 1	ภาคเรียน ที่ 2	ภาคเรียน ที่ 1	ภาคเรียน ที่ 2
CUD 50	136	135	135	135	-	-	-	-
CUD 51	139	130	120	118	115	115	-	-
CUD 52	-	-	134	125	123	119	116	116

หมายเหตุ: หน่วย: คน

ผู้วิจัยในฐานะอาจารย์ประจำชั้นมัธยมศึกษาปีที่ 3 ตั้งแต่ปีการศึกษา 2559 สนใจศึกษาตัวแปรที่จะสามารถทำนายแผนการเรียนที่เหมาะสมสำหรับนักเรียนในการศึกษาต่อระดับมัธยมศึกษาตอนปลาย จากการสังเคราะห์ผลงานวิจัยที่เกี่ยวข้องกับการเลือกแผนการเรียนตั้งแต่ปี พ.ศ. 2538 ถึงปี พ.ศ. 2558 พบว่า ตัวแปรที่ส่งผลต่อการเลือกแผนการเรียนอย่างมีนัยสำคัญทางสถิติส่วนใหญ่ คือ ผลการเรียนเฉลี่ยสะสมในระดับมัธยมศึกษาตอนต้น (จินตนา โนนวงศ์ และคณะ, 2558; จิราลักษณ์ ฤทธิเดชโยธิน, 2544; ทิศาวุฒิ โชตินิสากรณ์, 2545; ปุณทิการามพุดชา, 2547; รัตนกรณ ชนะขำ, 2545; สุปัทธน์กุล ภัคโชค, 2555; สุมิตรา ศรีชูชาติ, 2538; สุริชา เชื้อวงศ์, 2552) อย่างไรก็ตาม เพื่อความละเอียดในการทำนายแผนการเรียนให้มีความถูกต้องและชัดเจนมากยิ่งขึ้น ผู้วิจัยปรับตัวแปรผลการเรียนเฉลี่ยสะสมในระดับมัธยมศึกษาตอนต้น เนื่องจากในแต่ละแผนการเรียนมีจุดเน้นในเนื้อหาที่แตกต่างกัน เช่น แผนการเรียนวิทย์-คณิต เป็นกลุ่มที่เน้นการเรียนรู้ในวิชาวิทยาศาสตร์และคณิตศาสตร์ แผนการเรียนศิลป์-คณิต เป็นกลุ่มที่เน้นการเรียนรู้ในวิชาคณิตศาสตร์และภาษาอังกฤษ และแผนการเรียนศิลป์-ภาษา เป็นกลุ่มที่เน้นการเรียนรู้ในวิชาภาษาอังกฤษและภาษาไทย (กรมสามัญศึกษา, 2546; Sintanakul & Sanrach, 2016) ผู้วิจัยปรับตัวแปรโดยแยกออกเป็นตัวแปรผลการเรียนเฉลี่ย 5 กลุ่มสาระการเรียนรู้ ประกอบด้วย ภาษาไทย คณิตศาสตร์ วิทยาศาสตร์ สังคมศึกษา และภาษาต่างประเทศ เพื่อนำมาใช้ในการสร้างโมเดลทำนาย

แผนการเรียนรู้ หากสามารถทำนายแผนการเรียนรู้ที่เหมาะสมกับคุณลักษณะหรือความถนัดของนักเรียนได้ ย่อมเป็นการสนับสนุนนักเรียนให้สามารถตัดสินใจเลือกแผนการเรียนรู้ที่เหมาะสมกับตนได้ นำไปสู่การเรียนรู้ในระดับมัธยมศึกษาตอนปลายอย่างมีคุณภาพ ตลอดจนนำไปสู่ความพร้อมที่จะศึกษาต่อในระดับการศึกษาที่สูงขึ้นต่อไป


ในการสร้างโมเดลทำนายแผนการเรียนรู้ของนักเรียนจำเป็นต้องอาศัยการวิเคราะห์จำแนกประเภทข้อมูลออกเป็นกลุ่ม ๆ ซึ่งต้องทราบล่วงหน้าว่ามีกลุ่มอะไรบ้างและมีข้อมูลของหน่วยตัวอย่างในแต่ละกลุ่มก่อน เครือข่ายประสาท (neural network: NN) และซัพพอร์ตเวกเตอร์แมชชีน (support vector machine: SVM) ต่างเป็นเทคนิคการวิเคราะห์รูปแบบใหม่ที่มีถูกนำมาใช้ในการจำแนกประเภทของข้อมูลในปัจจุบัน (ก้องเกียรติ บุญเสริม, 2552; ศจีมาจ ขวัญเมือง, 2548) นอกจากนี้ ยังมีการประยุกต์วิธีวิเคราะห์ข้อมูลจากศาสตร์ทางวิทยาการคอมพิวเตอร์มาใช้จำแนกประเภทของข้อมูลที่เรียกว่า ต้นไม้ตัดสินใจ (decision tree: DT) (กฤษณะ ไวยมัย และคณะ, 2544) คุณสมบัติเด่นของต้นไม้ตัดสินใจ คือ มีความยืดหยุ่นและมีความสามารถในการประมวลผลและทำนายผลได้อย่างแม่นยำ โดยมีรูปแบบโครงสร้างที่มีลำดับขั้นของการตัดสินใจ (Rokach, 2008) ลักษณะคล้ายกับต้นไม้กลับหัวที่มีรากอยู่ด้านบน และใบอยู่ด้านล่างสุด ทั้งเครือข่ายประสาท ซัพพอร์ตเวกเตอร์แมชชีน และต้นไม้ตัดสินใจ ต่างเป็นเทคนิคที่มีขั้นตอนการจำแนกประเภทข้อมูลเริ่มจากการแบ่งข้อมูลเป็นสองส่วน ได้แก่ ข้อมูลฝึกฝน (training data) และข้อมูลทดสอบ (testing data) แต่ละชุดข้อมูลประกอบด้วยข้อมูลของตัวแปรทำนาย และกลุ่มที่แต่ละหน่วยตัวอย่างเป็นสมาชิก ข้อมูลฝึกฝนจะถูกนำไปใช้ในการสร้างโมเดลการจำแนกประเภท และโมเดลนี้จะถูกนำไปใช้จำแนกประเภทข้อมูลของหน่วยตัวอย่างในข้อมูลทดสอบ โมเดลที่ได้รับการทดสอบว่ามีความถูกต้องสูงก็จะถูกนำไปใช้ทำนายข้อมูลใหม่ต่อไป

แม้ว่าเทคนิควิธีการจำแนกและทำนายข้อมูลจะถูกพัฒนาขึ้นเพื่อให้ผลการวิเคราะห์มีความแม่นยำมากยิ่งขึ้น แต่ในปัจจุบันยังไม่มีงานวิจัยใดที่ศึกษาประสิทธิภาพของโมเดลการทำนายแผนการเรียนรู้โดยใช้เทคนิควิธีทั้งสามเทคนิควิธีร่วมกันหรือที่เรียกว่า การวิเคราะห์เอ็นเซมเบิลโหวต (ensemble vote) ซึ่งเป็นเทคนิคการทำนายข้อมูลโดยการสร้างโมเดลจำแนกประเภทข้อมูลหลายโมเดลโดยใช้ชุดข้อมูลฝึกฝนชุดเดียวกันด้วยเทคนิคการวิเคราะห์มากกว่าหนึ่งเทคนิค เพื่อช่วยกันทำนายกลุ่มประเภทข้อมูลด้วยวิธีการโหวตเสียงข้างมาก

เทคนิคนี้มีประสิทธิภาพดีกว่าการใช้โมเดลจำแนกประเภทข้อมูลเพียงโมเดลเดียว (เอกสิทธิ์ พชรวงศ์ศีกดา, 2557) งานวิจัยนี้ผู้วิจัยสนใจศึกษาประสิทธิภาพของโมเดลทำนายแผนการเรียน ได้จากการวิเคราะห์โดยใช้เอ็นซัมเบิลโหวตร่วมกันระหว่างเครือข่ายประสาท ชัฟฟอร์ต เวกเตอร์แมชชีนและต้นไม้ตัดสินใจ ตามกรอบแนวคิดในการวิจัย (ภาพ 1) เพื่อให้ได้โมเดลทำนายแผนการเรียนของนักเรียนในการศึกษาต่อในระดับมัธยมศึกษาตอนปลายที่มีประสิทธิภาพมากที่สุด ซึ่งจะช่วยให้นักเรียนสามารถเลือกเรียนในแผนการเรียนที่เหมาะสมกับตนเองมากยิ่งขึ้น และจะเป็นประโยชน์ให้ผู้สนใจได้ใช้เป็นแนวทางในการศึกษาต่อไป

ภาพ 1

กรอบแนวคิดการวิจัย



วัตถุประสงค์

1. เพื่อศึกษาประสิทธิภาพของโมเดลทำนายแผนการเรียนของนักเรียนในการศึกษาต่อระดับมัธยมศึกษาตอนปลายที่ได้จากการวิเคราะห์ด้วยเครือข่ายประสาท ชัฟฟอร์ต เวกเตอร์แมชชีน ต้นไม้ตัดสินใจ และเอ็นซัมเบิลโหวตร่วมกันระหว่างสามเทคนิคดังกล่าว

2. เพื่อเปรียบเทียบประสิทธิภาพของโมเดลทำนายแผนการเรียนของนักเรียนในการศึกษาต่อระดับมัธยมศึกษาตอนปลายที่ได้จากการวิเคราะห์ด้วย 1) เครือข่ายใยประสาท 2) ซัพพอร์ทเวกเตอร์แมชชีน 3) ต้นไม้ตัดสินใจ และ 4) เอ็นเซมเบิลโหวตร่วมกันระหว่างสามเทคนิคดังกล่าว

วิธีการวิจัย

1. ประชากรและตัวอย่าง

ประชากรที่ใช้ในการวิจัยครั้งนี้ คือ นักเรียนชั้น ม.6 โรงเรียนสาธิตจุฬาลงกรณ์มหาวิทยาลัย ฝ่ายมัธยม ตัวอย่าง คือ นักเรียนชั้น ม.6 รุ่นที่ 50–53 จำนวนทั้งสิ้น 787 คน โดยผู้วิจัยกำหนดขนาดตัวอย่างในการสร้างโมเดลการจำแนกด้วยเทคนิคซัพพอร์ทเวกเตอร์แมชชีน และต้นไม้ตัดสินใจเพื่อให้ได้ค่าพารามิเตอร์ที่น่าเชื่อถือ ซึ่งต้องอาศัยข้อมูลในการวิเคราะห์อย่างน้อย 500 คน (Kavzoglu & Colkesen, 2012; Vanajakshi & Rilett, 2004) และสอดคล้องกับการกำหนดขนาดตัวอย่างขั้นต่ำในการวิเคราะห์ด้วยเครือข่ายใยประสาท (Garson, 1998) สรุปจำนวนนักเรียนจำแนกตามรุ่นและแผนการเรียน (ตาราง 2)

ตาราง 2

จำนวนตัวอย่างนักเรียนชั้น ม.6 โรงเรียนสาธิตจุฬาลงกรณ์มหาวิทยาลัย ฝ่ายมัธยม จำแนกตามรุ่นและแผนการเรียน

รุ่นนักเรียน	จำนวนนักเรียน (คน)				
	วิทย์-คณิต	ศิลป์-คณิต	ศิลป์-ภาษา	ศิลป์-อหส	รวม
CUD50	135	36	20	21	212
CUD51	115	43	23	10	191
CUD52	116	33	31	14	194
CUD53	109	44	30	7	190
รวม	475	156	104	52	787
ร้อยละ	60.36	19.82	13.21	6.61	100.00

2. การเก็บรวบรวมข้อมูล

2.1 ดำเนินการติดต่อหน่วยทะเบียนและประเมินผล โรงเรียนสาธิตจุฬาลงกรณ์

มหาวิทยาลัย ฝ่ายมัธยม เพื่อขอข้อมูลประวัติผลการเรียนเฉลี่ย (GPA) กลุ่มสาระการเรียนรู้ภาษาไทย คณิตศาสตร์ วิทยาศาสตร์ สังคมศึกษาฯ และภาษาต่างประเทศ ในระดับมัธยมศึกษาตอนต้น ของนักเรียนชั้น ม.6 รุ่นที่ 50 ถึงรุ่นที่ 53

2.2 นำข้อมูลผลการเรียน (GPA) ของนักเรียนแต่ละคนมาจับคู่กับแผนการเรียนที่นักเรียนคนนั้นศึกษาอยู่ในชั้น ม.6

3. การวิเคราะห์ข้อมูล

3.1 เนื่องจากจำนวนตัวอย่างในแต่ละแผนการเรียนไม่เท่ากัน ซึ่งส่งผลต่อความแกร่งของสถิติที่ใช้ในการวิเคราะห์ อาจทำให้ผลการวิเคราะห์ขาดความน่าเชื่อถือได้ (Hair et al., 2010) ผู้วิจัยจึงวิเคราะห์ข้อมูลโดยแบ่งเป็นสองโมเดล ดังนี้

1) โมเดล S-M-L-T วิเคราะห์โดยใช้ตัวอย่างทั้งหมดทุกแผนการเรียน ได้แก่ แผนการเรียนวิทย์-คณิต (Science-Math), ศิลป์-คณิต (English-Math), ศิลป์-ภาษา (English-Language) และศิลป์-ทั่วไป (English-Thai & Social)

2) โมเดล S-E วิเคราะห์โดยใช้การยุบรวมตัวอย่างให้เหลือเพียง 2 กลุ่ม ซึ่งตัวอย่างในแผนการเรียนวิทย์-คณิต ให้ชื่อว่า “กลุ่มวิทย์” (Science) และตัวอย่างนักเรียนในแผนการเรียนศิลป์-คณิต, ศิลป์-ภาษา และศิลป์-ทั่วไป ยุบรวมเป็นกลุ่มเดียว ให้ชื่อว่า “กลุ่มศิลป์” (English)

3.2 ใช้การวิเคราะห์ด้วยเทคนิคเอ็นเซมเบิลโหวตร่วมกันระหว่างเครือข่ายประสาทซัพพอร์ทเวกเตอร์แมชชีน และต้นไม้ตัดสินใจ โดยใช้โปรแกรมคอมพิวเตอร์

3.3 ในการแบ่งข้อมูลเพื่อใช้ในการทดสอบประสิทธิภาพของโมเดลที่ได้จากการวิเคราะห์ด้วยเทคนิคเครือข่ายประสาท ซัพพอร์ทเวกเตอร์แมชชีน และต้นไม้ตัดสินใจ จะใช้วิธี 10-fold cross-validation test

3.4 สำหรับการวัดประสิทธิภาพของโมเดล พิจารณาจากค่าความถูกต้องในการจำแนกข้อมูล เรียกว่าค่า accuracy โดยคำนวณจากจำนวนหน่วยตัวอย่างที่ได้รับการทำนายกลุ่มได้อย่างถูกต้องทั้งหมดหารด้วยจำนวนหน่วยตัวอย่างทั้งหมด

ผลการวิจัย


ผู้วิจัยนำเสนอผลการวิจัย ดังนี้

1. ผลการวิเคราะห์ด้วยเทคนิคเครือข่ายประสาท

ผลการวิเคราะห์ข้อมูลทำให้ได้โครงสร้างเครือข่ายประสาทของโมเดล S-M-L-T และโมเดล S-E (ภาพ 2 - 3) โดยภายในโครงสร้างเครือข่ายประสาทของแต่ละโมเดล พบว่ามีเส้นเชื่อมโยงแสดงถึงค่าน้ำหนักระหว่าง Input node (ตัวแปรทำนาย) และ Hidden node ซึ่งเป็นองค์ประกอบของโครงสร้าง (ตาราง 3) ผลการวิเคราะห์ พบว่า ตัวแปรทำนายในโมเดล S-M-L-T สามารถเรียงลำดับความสำคัญตามผลรวมค่าสัมบูรณ์ของน้ำหนักของตัวแปรทำนายที่ใช้ในการวิเคราะห์จากมากไปน้อย คือ MathGPA (29.832), SciGPA (23.585), SocGPA (22.540), EngGPA (20.857) และ ThaGPA (15.221) ตามลำดับ และสำหรับโมเดล S-E สามารถเรียงลำดับความสำคัญของตัวแปรทำนายตามผลรวมค่าสัมบูรณ์ของน้ำหนักของตัวแปรทำนายจากมากไปน้อย คือ MathGPA (36.721), SciGPA (32.566), ThaGPA (26.406), SocGPA (24.865) และ EngGPA (17.295) ตามลำดับ


ภาพ 2

โครงสร้างเครือข่ายประสาทของโมเดล S-M-L-T



ภาพ 3

โครงสร้างเครือข่ายประสาทของโมเดล S-E



ตาราง 3

ค่าน้ำหนักระหว่าง input node (ตัวแปรทำนาย) และ hidden node

โมเดล	Input node (ตัวแปรทำนาย)	Hidden node						ผลรวม ค่าสัมบูรณ์ของ น้ำหนักตัวแปร ทำนาย
		Node 1	Node 2	Node 3	Node 4	Node 5	Node 6	
S-M-L-T	ThaGPA	-7.614	-2.043	0.199	-1.796	0.724	2.845	15.221
	MathGPA	11.642	5.279	-1.795	4.994	5.072	1.050	29.832

ตาราง 3 (ต่อ)

ค่าน้ำหนักระหว่าง input node (ตัวแปรทำนาย) และ hidden node

โมเดล	Input node (ตัวแปรทำนาย)	Hidden node						ผลรวม ค่าสัมบูรณ์ของ น้ำหนักตัวแปรทำนาย
		Node 1	Node 2	Node 3	Node 4	Node 5	Node 6	
	SciGPA	4.646	5.255	1.938	7.667	3.651	0.428	23.585
	SocGPA	2.039	0.702	-10.118	-7.159	-3.227	-0.705	22.540
	EngGPA	-4.834	-3.754	2.698	0.836	-2.939	5.796	20.857
	Threshold	1.469	-4.083	-4.583	-3.867	-5.454	2.927	-
S-E	ThaGPA	1.909	2.901	-7.951	11.684	1.961	-	26.406
	MathGPA	-1.013	8.988	4.010	-12.816	9.894	-	36.721
	SciGPA	-5.249	5.017	5.165	-9.851	7.284	-	32.566
	SocGPA	-3.066	-7.066	-8.709	3.736	-2.288	-	24.865
	EngGPA	-0.854	-3.601	3.600	8.148	-1.092	-	17.295
	Threshold	0.218	-6.563	-7.246	-5.748	-6.157	-	-

2. ผลการวิเคราะห์ด้วยเทคนิคซัพพอร์ตเวกเตอร์แมชชีน

ผู้วิจัยวิเคราะห์ข้อมูลด้วยเทคนิคซัพพอร์ตเวกเตอร์แมชชีนแบบหนึ่งต่อทั้งหมด (one-against-all) โดยใช้โปรแกรมคอมพิวเตอร์ และเลือกใช้ชุดคำสั่ง Optimize Parameters (Grid) ในการทดสอบแบบลองผิดลองถูกเพื่อหารูปแบบของ kernel function ที่เหมาะสมสำหรับการจำแนกกลุ่มของข้อมูลในแต่ละโมเดลได้อย่างมีประสิทธิภาพมากที่สุด ผลการวิเคราะห์พบว่า kernel function รูปแบบ anova และรูปแบบ dot เป็นรูปแบบที่เหมาะสมกับข้อมูลในโมเดล S-M-L-T และโมเดล S-E ตามลำดับ รูปแบบ kernel function ดังกล่าวสามารถจำแนกกลุ่มของข้อมูลในแต่ละโมเดลได้อย่างมีประสิทธิภาพ ซึ่งพบว่า โมเดล S-M-L-T ได้รูปแบบการพิจารณาจำแนกกลุ่มของข้อมูล 4 รูปแบบ ได้แก่ 1 vs. all other, 2 vs. all other, 3 vs. all other และ 4 vs. all other ตัวอย่างการพิจารณาจำแนกกลุ่ม เช่น รูปแบบ 1 vs. all other เป็นการพิจารณาความเป็นสมาชิกในกลุ่ม 1 (วิทย์-คณิต) ว่าข้อมูลนั้นเป็นสมาชิกในกลุ่มที่ 1 หรือไม่ ถ้าไม่เป็นสมาชิกในกลุ่ม 1 แล้วจะพิจารณาความเป็นสมาชิกในกลุ่ม 2 (ศิลป์-คณิต)

ต่อไป นั่นคือ รูปแบบ 2 vs. all other พิจารณาเช่นนี้ไปเรื่อย ๆ จนกว่าจะพบว่า ข้อมูลนั้น เป็นสมาชิกของกลุ่มใด สำหรับโมเดล S-E ซึ่งมีอยู่ด้วยกัน 2 กลุ่ม คือ กลุ่มวิทย์ และกลุ่มศิลป์ ได้รูปแบบการพิจารณาจำแนกกลุ่มของข้อมูลเพียงรูปแบบเดียว คือ การพิจารณาว่า ข้อมูลนั้น เป็นสมาชิกในกลุ่ม 1 (กลุ่มวิทย์) หรือกลุ่ม 2 (กลุ่มศิลป์) โดยความสำคัญของตัวแปรทำนาย กับการพิจารณาความเป็นสมาชิกในกลุ่มใดกลุ่มหนึ่ง สามารถเรียงลำดับตามผลรวมค่าสัมบูรณ์ ของค่าน้ำหนักของตัวแปรทำนายในการสร้างแบ่งแยกกลุ่มข้อมูลในแต่ละกลุ่ม (ตาราง 4)

ตาราง 4

ค่าน้ำหนักของตัวแปรทำนายสำหรับสร้างเส้นแบ่งแยกกลุ่มข้อมูลในการวิเคราะห์ซัพพอร์ตเวกเตอร์แมชชีน ของแต่ละโมเดล

โมเดล	เส้นแบ่งแยก	ตัวแปรทำนาย				
		ThaGPA	MathGPA	SciGPA	SocGPA	EngGPA
S-M-L-T	1 vs. all other	0.018	0.595	0.311	0.080	0.104
	2 vs. all other	0.007	0.002	0.067	-0.001	0.007
	3 vs. all other	0.122	-0.193	-0.033	0.097	0.105
	4 vs. all other	-0.033	-0.152	-0.090	-0.146	-0.197
ผลรวมค่าสัมบูรณ์ของน้ำหนัก		0.180	0.942	0.501	0.324	0.413
S-E	วิทย์ vs. ศิลป์	-0.344	1.002	0.779	-0.225	-0.186


หมายเหตุ: กลุ่ม 1 หมายถึง แผนการเรียนวิทย์-คณิต (S) กลุ่ม 2 หมายถึง แผนการเรียนศิลป์-คณิต (M) กลุ่ม 3 หมายถึง แผนการเรียนศิลป์-ภาษา (L) กลุ่ม 4 หมายถึง แผนการเรียนศิลป์-ทั่วไป (T)

3. ผลการวิเคราะห์ด้วยเทคนิคต้นไม้ตัดสินใจ

ในการวิเคราะห์ข้อมูลด้วยเทคนิคต้นไม้ตัดสินใจ ผู้วิจัยได้ใช้โปรแกรมคอมพิวเตอร์ โดยเลือกใช้ชุดคำสั่ง Optimize Parameters (Grid) ในการทดสอบแบบลองผิดลองถูก เพื่อหา เกณฑ์หรือวิธีการในการวิเคราะห์ต้นไม้ตัดสินใจที่เหมาะสมสำหรับการจำแนกกลุ่มของข้อมูลใน แต่ละโมเดลได้อย่างมีประสิทธิภาพมากที่สุด ผลการวิเคราะห์ พบว่า เกณฑ์ accuracy และ เกณฑ์ information_gain เป็นเกณฑ์ที่เหมาะสมกับข้อมูลในโมเดล S-M-L-T และโมเดล S-E ตามลำดับ (ภาพ 4-5)

ภาพ 4


ต้นไม้ตัดสินใจเลือกแผนการเรียนของโมเดล S-M-L-T



หมายเหตุ: "1" หมายถึง แผนการเรียนวิทย์-คณิต (S) "2" หมายถึง แผนการเรียนศิลป์-คณิต (M)
 "3" หมายถึง แผนการเรียนศิลป์-ภาษา (L) "4" หมายถึง แผนการเรียนศิลป์-ทั่วไป (T)

ภาพ 5

ต้นไม้ตัดสินใจเลือกแผนการเรียนของโมเดล S-E



หมายเหตุ: "1" หมายถึง แผนการเรียนวิทย์-คณิต (S) "2" หมายถึง แผนการเรียนศิลป์-คณิต (M)

4. การเปรียบเทียบประสิทธิภาพของโมเดลจากการวิเคราะห์ด้วยเทคนิคเครือข่าย
 โยประสาท ซัพพอร์ตเวกเตอร์แมชชีน ต้นไม้ตัดสินใจ และเอ็นเซมเบิลโหวต

ผู้วิจัยทำการวิเคราะห์โมเดล S-M-L-T และโมเดล S-E ด้วยเทคนิคเอ็นเซ็มเบิลโหวตร่วมกันระหว่างเครือข่ายประสาท ชัฟฟอร์ตเวกเตอร์แมชชีน และต้นไม้ตัดสินใจ รวมผลทำนายแผนการเรียนจากแต่ละเทคนิคด้วยวิธีการโหวตเสียงข้างมาก ผลการวิเคราะห์เปรียบเทียบประสิทธิภาพการจำแนกข้อมูล พบว่าโมเดลที่มีประสิทธิภาพในการทำนายแผนการเรียนได้ดีที่สุดในทุกเทคนิคการวิเคราะห์ คือ โมเดล S-E โดยมีประสิทธิภาพของการทำนายด้วยเทคนิคเอ็นเซ็มเบิลโหวตได้ถูกต้องคิดเป็นร้อยละ 80.05 รองลงมาคือ ชัฟฟอร์ตเวกเตอร์แมชชีน ต้นไม้ตัดสินใจ และเครือข่ายประสาท ตามลำดับ (ตาราง 5)

ตาราง 5

ประสิทธิภาพการจำแนกข้อมูล จำแนกตามโมเดลและเทคนิควิเคราะห์

โมเดล	เครือข่ายประสาท	ชัฟฟอร์ตเวกเตอร์แมชชีน	ต้นไม้ตัดสินใจ	เอ็นเซ็มเบิลโหวต
S-M-L-T	68.23	67.60	65.95	67.98
S-E	79.29	79.80	79.54	80.05

หมายเหตุ: หน่วย: ร้อยละ

สรุปผลการวิจัย

ผลการวิจัยสรุปได้ว่าโมเดลทำนายแผนการเรียนที่ได้จากการวิเคราะห์ด้วยเครือข่ายประสาท ชัฟฟอร์ตเวกเตอร์แมชชีน ต้นไม้ตัดสินใจ และเทคนิคเอ็นเซ็มเบิลโหวต จะมีประสิทธิภาพการทำนายไม่แตกต่างกันมากนัก และสำหรับโมเดลที่มีประสิทธิภาพการทำนายได้ดีที่สุดในการวิจัยครั้งนี้คือโมเดล S-E ซึ่งเป็นโมเดลที่สามารถใช้ทำนายกลุ่มการเรียนที่เหมาะสมกับนักเรียนใน 2 กลุ่มการเรียนหลัก ได้แก่ กลุ่มการเรียนวิทย์ และกลุ่มการเรียนศิลป์ โดยมีประสิทธิภาพของการทำนายด้วยเทคนิคเอ็นเซ็มเบิลโหวตได้ถูกต้องสูงที่สุดคิดเป็นร้อยละ 80.05 นอกจากนี้ยังพบว่าผลการเรียนเฉลี่ยกลุ่มสาระการเรียนรู้คณิตศาสตร์ ระดับมัธยมศึกษาตอนต้น จะมีความสำคัญและมีอิทธิพลต่อการเลือกแผนการเรียนเป็นอย่างมาก

อภิปรายผล

ผลการวิจัยสามารถอภิปรายในประเด็นต่าง ๆ ดังนี้

1. ตัวแปรที่สามารถทำนายแผนการเรียนรู้ของนักเรียนในการศึกษาต่อระดับมัธยมศึกษาตอนปลาย

ในการวิเคราะห์โมเดลทำนายแผนการเรียนรู้ด้วยเครือข่ายประสาท และซัพพอร์ตเวกเตอร์แมชชีน ใช้ตัวแปรทุกตัวแปรในการวิเคราะห์ แต่ให้ค่าน้ำหนักของแต่ละตัวแปรในการวิเคราะห์ไม่เท่ากัน ทำให้ไม่สามารถอธิบายได้ว่า ตัวแปรใดเป็นตัวแปรทำนายแผนการเรียนรู้ได้อย่างมีนัยสำคัญทางสถิติ แต่สามารถเรียงลำดับความสำคัญของตัวแปรทำนายตามผลรวมของค่าสัมบูรณ์ของน้ำหนักของตัวแปรทำนายในการวิเคราะห์ได้ ซึ่งพบว่า ผลการเรียนรู้เฉลี่ยกลุ่มสาระการเรียนรู้คณิตศาสตร์ ระดับมัธยมศึกษาตอนต้น (MathGPA) มีความสำคัญและมีอิทธิพลต่อการเลือกแผนการเรียนรู้มากที่สุด ในทุกโมเดลและทุกเทคนิควิธีวิเคราะห์

สำหรับการวิเคราะห์โมเดลด้วยต้นไม้ตัดสินใจ จำนวนตัวแปรทำนายที่นำมาใช้ในโมเดลขึ้นอยู่กับระดับความลึกของต้นไม้ ในการวิเคราะห์โมเดลด้วยเทคนิคต้นไม้ตัดสินใจในงานวิจัยนี้ โมเดล S-M-L-T ได้ผลการวิเคราะห์ต้นไม้ 4 ชั้น และโมเดล S-E ได้ผลการวิเคราะห์ต้นไม้ 1 ชั้นเท่านั้น อย่างไรก็ตาม ผลการวิเคราะห์โมเดลทั้งสองด้วยเทคนิคต้นไม้ตัดสินใจพบว่า ผลการเรียนรู้เฉลี่ยกลุ่มสาระการเรียนรู้คณิตศาสตร์ ระดับมัธยมศึกษาตอนต้น (MathGPA) เป็นตัวแปรที่ใช้เป็นโหนดแรกสุดบนต้นไม้ แสดงให้เห็นว่า ตัวแปรดังกล่าวมีความสำคัญและมีอิทธิพลต่อการเลือกแผนการเรียนรู้มากที่สุด เช่นเดียวกับผลการวิเคราะห์ด้วยเครือข่ายประสาทและซัพพอร์ตเวกเตอร์แมชชีนที่ได้กล่าวมาในข้างต้น สอดคล้องกับผลการวิจัยของ สุพรรณกุล ภัคโชค (2555) และ สุมิตรรา ศรีชูชาติ (2538) ที่กล่าวว่า การที่นักเรียนมีผลการเรียนสูงย่อมแสดงให้เห็นถึงความขยัน ตั้งใจ และรับผิดชอบต่อการเรียนของนักเรียน ทำให้นักเรียนมีความพร้อมในการศึกษาต่อและมีโอกาสในการเลือกศึกษาต่อในสาขาวิชาที่ตนเองสนใจได้อย่างหลากหลายมากยิ่งขึ้น เห็นได้ว่า ถ้านักเรียนมีผลการเรียนในระดับม.ต้นสูง นักเรียนย่อมมีแนวโน้มเลือกศึกษาต่อในแผนการเรียนวิทย์-คณิต เป็นอันดับแรก และยังสามารถเลือกแผนการเรียนใดก็ได้ตามแต่ความต้องการของผู้เรียน

2. การเปรียบเทียบผลการวิเคราะห์โมเดลในแต่ละเทคนิควิธี

ผลการเปรียบเทียบประสิทธิภาพของโมเดลทำนายแผนการเรียนรู้ในแต่ละโมเดลพบว่า โมเดลที่ได้จากการวิเคราะห์ด้วยเครือข่ายประสาท ซัพพอร์ตเวกเตอร์แมชชีน ต้นไม้ตัดสินใจ และเทคนิคเอ็นเอ็มบีแอลโหวต มีประสิทธิภาพการทำนายไม่แตกต่างกันมากนัก

ทั้งนี้อาจเป็นผลมาจากกลุ่มเป้าหมายนักเรียนที่ใช้ในการวิจัยครั้งนี้มีจำนวนไม่ถึง 1,000 คน อาจไม่มากพอที่จะนำมาใช้เป็นข้อมูลฝึกฝนสำหรับสร้างโมเดลทำนายในแต่ละเทคนิควิธีการวิเคราะห์เพื่อให้มีความแตกต่างของประสิทธิภาพการทำนายอย่างชัดเจน (Garson, 1998; Kavzoglu & Colkesen, 2012; Vanajakshi & Rilett, 2004) โมเดลที่มีประสิทธิภาพการทำนายได้ดีที่สุดในการวิจัยครั้งนี้ คือ โมเดล S-E ซึ่งมีประสิทธิภาพการทำนายได้ถูกต้อง คิดเป็นร้อยละ 80.05 สำหรับการวิเคราะห์ด้วยเทคนิคเอ็นเอ็มบีแอลโหวต คิดเป็นร้อยละ 79.80 สำหรับการวิเคราะห์ด้วยซัพพอร์ตเวกเตอร์แมชชีน คิดเป็นร้อยละ 79.54 สำหรับการวิเคราะห์ด้วยต้นไม้ตัดสินใจ และคิดเป็นร้อยละ 79.29 สำหรับการวิเคราะห์ด้วยเครือข่ายประสาท

ข้อเสนอแนะ

ข้อเสนอแนะในการนำผลไปใช้

สำหรับนักเรียน

ผลการวิจัยในครั้งนี้ทำให้ได้โมเดลทำนายแผนการเรียนที่เหมาะสมกับความถนัดและความสนใจของนักเรียนในการศึกษาต่อในระดับมัธยมศึกษาตอนปลาย ซึ่งมีส่วนช่วยสนับสนุนการตัดสินใจในการเลือกแผนการเรียนที่เหมาะสมกับความสามารถของตน อย่างไรก็ตาม ผลการวิเคราะห์อยู่ในรูปของชุดอัลกอริทึมคอมพิวเตอร์ เวลานำไปใช้งานต้องมีการเตรียมข้อมูลเพื่อป้อนเข้าสู่คอมพิวเตอร์ในการทำนาย ซึ่งอาจไม่สะดวกต่อการนำไปใช้งานได้ทันที ดังนั้น การเลือกโมเดลที่วิเคราะห์ด้วยเทคนิคต้นไม้ตัดสินใจเป็นตัวทำนายแผนการเรียนจึงสะดวกต่อการใช้งานมากกว่า

นอกจากนี้ จากการวิเคราะห์โมเดลด้วยเครือข่ายประสาท และซัพพอร์ตเวกเตอร์แมชชีน จะได้ผลการวิเคราะห์ค่าน้ำหนักของตัวแปรทำนายที่ใช้ในโมเดล ทำให้สามารถเรียงลำดับความสำคัญของตัวแปรทำนายในการทำนายแผนการเรียน (ตาราง 6) ซึ่งพบว่า ผลการเรียนรู้เฉลี่ยกลุ่มสาระการเรียนรู้คณิตศาสตร์ ระดับมัธยมศึกษาตอนต้น (MathGPA) มีความสำคัญและมีอิทธิพลต่อการเลือกแผนการเรียนเป็นอย่างมาก ดังนั้น ในการเลือกแผนการเรียนของนักเรียนในอนาคต นักเรียนต้องเตรียมตัวและทำคะแนนในวิชาคณิตศาสตร์ให้ดีเพื่อที่นักเรียนจะสามารถเลือกแผนการเรียนในการศึกษาต่อระดับมัธยมศึกษาตอนปลายได้ตามต้องการ

ตาราง 6

ลำดับความสำคัญของตัวแปรทำนายในการทำนายแผนการเรียนด้วยเครือข่ายประสาท และซัพพอร์ตเวกเตอร์แมชชีน จำแนกตามโมเดล

ลำดับ ความสำคัญ	เครือข่ายประสาท		ซัพพอร์ตเวกเตอร์แมชชีน	
	โมเดล S-M-L-T	โมเดล S-E	โมเดล S-M-L-T	โมเดล S-E
	MathGPA	MathGPA	MathGPA	MathGPA
	SciGPA	SciGPA	SciGPA	SciGPA
	SocGPA	ThaGPA	EngGPA	ThaGPA
	EngGPA	SocGPA	SocGPA	SocGPA
	ThaGPA	EngGPA	ThaGPA	EngGPA

สำหรับผู้ปกครองและครู

ลำดับความสำคัญของตัวแปรทำนายในการทำนายแผนการเรียน (ตาราง 6) ผู้ปกครองสามารถนำข้อมูลดังกล่าวไปใช้เพื่อเป็นการเตรียมความพร้อมเพื่อให้นักเรียนได้เรียนในแผนการเรียนที่ต้องการ ตลอดจนทำให้นักเรียนและผู้ปกครองได้ร่วมกันวางแผนทางการศึกษาเพื่อที่ผลสำเร็จทางการเรียนและการทำงานในอนาคตต่อไป

ข้อเสนอแนะในการวิจัยครั้งต่อไป

- 1) ควรเพิ่มขนาดตัวอย่างที่ใช้ในการวิเคราะห์อย่างน้อย 1,000 คน
- 2) ในการพัฒนาโมเดลทำนายแผนการเรียนในอนาคตต่อไปนั้น ควรมีการศึกษาตัวแปรอื่น ๆ ที่เกี่ยวข้องกับการเลือกแผนการเรียนของนักเรียนเพิ่มเติม เช่น ความถนัด ความสนใจในอาชีพของนักเรียน การสนับสนุนจากครอบครัว การรับรู้ความสามารถของตนเอง รวมทั้งจัดกลุ่มตัวแปรและใช้การวิเคราะห์โมเดลสมการโครงสร้าง SEM เพื่อให้ทราบว่า แต่ละปัจจัยมีอิทธิพลต่อการเลือกแผนการเรียนทั้งทางตรงและทางอ้อมมากน้อยเพียงใด
- 3) การวิเคราะห์เพื่อจำแนกกลุ่มในปัจจุบันยังมีการคิดค้นพัฒนาการวิเคราะห์อย่างต่อเนื่องหลากหลายวิธี เช่น Naïve Bayes, K-means, Gradient Boosted Trees, Bootstrap Aggregating (Bagging), Random Forest ในการวิจัยครั้งต่อไปควรใช้เทคนิควิธีใหม่ที่เหมาะสมกับข้อมูลในการวิเคราะห์เพื่อสร้างโมเดลทำนายแผนการเรียน

รายการอ้างอิง

ภาษาไทย

- กรมวิชาการ กระทรวงศึกษาธิการ. (2533). *หลักสูตรมัธยมศึกษาตอนปลาย พุทธศักราช 2524 (ฉบับปรับปรุง พ.ศ. 2533)*. กรุงเทพมหานคร.
- กรมสามัญศึกษา กระทรวงศึกษาธิการ. (2546). *พระราชบัญญัติการศึกษาแห่งชาติ พ.ศ. 2542 และที่แก้ไขเพิ่มเติม (ฉบับที่ 2) พ.ศ. 2545*. องค์การรับส่งสินค้าและพัสดุภัณฑ์ กัลยาณิธิ.
- กระทรวงศึกษาธิการ. (2552). *หลักสูตรแกนกลางการศึกษาขั้นพื้นฐาน พุทธศักราช 2551*. ชุมชนสหกรณ์การเกษตรแห่งประเทศไทย.
- กฤษณะ ไวยมัย, ชิตชนก ส่งศิริ, และ ธนาวิทย์ รักธรรมานนท์. (2544). การใช้เทคนิคดาต้าไมน์นิ่ง เพื่อพัฒนาคุณภาพการศึกษานิสิตคณะวิศวกรรมศาสตร์. *The Nectec Technical Journal*, 3(11), 134-142.
- ก้องเกียรติ บุญเสริม. (2552). *ปัจจัยที่ส่งผลต่อการตัดสินใจเรียนกวดวิชาของนักเรียนมัธยมศึกษาตอนต้น: การวิเคราะห์จำแนกกลุ่มพหุกับการวิเคราะห์ซัพพอร์ตเวกเตอร์แมชชีน* [วิทยานิพนธ์ปริญญาโทบริหารธุรกิจ]. Chulalongkorn University Intellectual Repository (CUIR). <http://cuir.car.chula.ac.th/handle/123456789/16148>
- จินตนา โนนวงศ์, วราพร เอรารวรรณ์, และ พัฒนพงษ์ วันจันทิก. (2558). ปัจจัยที่ส่งผลต่อการตัดสินใจเลือกแผนการเรียนของนักเรียนชั้นมัธยมศึกษาปีที่ 3: การวิเคราะห์จำแนกกลุ่มและการวิเคราะห์ซัพพอร์ตเวกเตอร์แมชชีน. *วารสารศึกษาศาสตร์มหาวิทยาลัยมหาสารคาม*, 9(พิเศษ), 77-92.
- จิราลักษณ์ ฤทธิเดชโยธิน. (2544). *ปัจจัยที่สัมพันธ์กับการตัดสินใจเรียนต่อชั้นมัธยมศึกษาตอนปลายของนักเรียนชั้นมัธยมศึกษาปีที่ 3 สังกัดกรมสามัญศึกษาเขตการศึกษา 12* [วิทยานิพนธ์ปริญญาโทบริหารธุรกิจ ไม่ได้ตีพิมพ์]. มหาวิทยาลัยบูรพา.
- ทศาวุฒิ โชตินิสากรณ์. (2545). *ความสนใจในอาชีพของนักเรียนชั้นมัธยมศึกษาปีที่ 3 โรงเรียนวัดโนนทัยพายัพ จังหวัดเชียงใหม่* [วิทยานิพนธ์ปริญญาโทบริหารธุรกิจ]. CMU Intellectual Repository. <http://cmuir.cmu.ac.th/jspui/handle/6653943832/24769>

- ปรีศนีย์ อุ่มเครือ. (2554). ประสบการณ์ของนักเรียนชั้นมัธยมศึกษาปีที่ 4 ที่ไม่มั่นใจในการตัดสินใจเลือกแผนการเรียน [วิทยานิพนธ์ปริญญาโทมหาบัณฑิต ไม่ได้ตีพิมพ์]. จุฬาลงกรณ์มหาวิทยาลัย.
- ปทุมทิศา रामพุดซา. (2547). ปัจจัยที่ส่งผลต่อการเลือกศึกษาต่อของนักเรียนชั้นมัธยมศึกษาปีที่ 3 เขตพื้นที่การศึกษาที่ 1 จังหวัดนครราชสีมา [วิทยานิพนธ์ปริญญาโทมหาบัณฑิต ไม่ได้ตีพิมพ์]. มหาวิทยาลัยรามคำแหง.
- รัตนกรณ ชนขำ. (2545). การศึกษาความสัมพันธ์ระหว่างปัจจัยบางประการกับการตัดสินใจเลือกอาชีพของนักเรียนมัธยมศึกษาตอนปลาย โรงเรียนสาธิตมหาวิทยาลัยรามคำแหง [วิทยานิพนธ์ปริญญาโทมหาบัณฑิต ไม่ได้ตีพิมพ์]. มหาวิทยาลัยรามคำแหง.
- ศศิมาจ ขวัญเมือง. (2548). ปัจจัยที่ส่งผลต่อผลิตภาพการวิจัยของอาจารย์มหาวิทยาลัยของรัฐ: การวิเคราะห์ลิสรเลและเครือข่ายใยประสาท [วิทยานิพนธ์ปริญญาโทมหาบัณฑิต]. Chulalongkorn University Intellectual Repository (CUIR). <http://cuir.car.chula.ac.th/handle/123456789/7933>
- สุพัฒน์กุล ภัคโชค. (2555). ตัวแบบการเลือกแผนการเรียนระดับมัธยมศึกษาตอนปลาย โดย การพิจารณาผลการเรียนรายวิชาหลักด้วยเทคนิคเหมืองข้อมูล [วิทยานิพนธ์ปริญญาโทมหาบัณฑิต]. มหาวิทยาลัยธุรกิจบัณฑิต. <http://libdoc.dpu.ac.th/thesis/148547.pdf>
- สุมิตรรา ศรีชูชาติ. (2538). สถิติวิเคราะห์การเลือกแผนการเรียนของนักเรียนในระดับชั้นมัธยมศึกษาตอนปลาย จังหวัดเชียงราย [วิทยานิพนธ์ปริญญาโทมหาบัณฑิต]. CMU Intellectual Repository. <http://cmuir.cmu.ac.th/jspui/handle/6653943832/32756>
- สุริชา เชื้อวงศ์. (2552). ปัจจัยที่สัมพันธ์ต่อการตัดสินใจเรียนต่อของนักเรียนชั้นมัธยมศึกษาปีที่ 3 ในกลุ่มสหวิทยาเขตหนองใหญ่ สังกัดสำนักงานเขตพื้นที่การศึกษาชลบุรี เขต 1 [วิทยานิพนธ์ปริญญาโทมหาบัณฑิต ไม่ได้ตีพิมพ์]. มหาวิทยาลัยบูรพา.
- หน่วยทะเบียนและประเมินผล โรงเรียนสาธิตจุฬาลงกรณ์มหาวิทยาลัย ฝ่ายมัธยม. (2560). จำนวนนักเรียนแผนการเรียนวิทย์-คณิต โรงเรียนสาธิตจุฬาลงกรณ์มหาวิทยาลัย ฝ่ายมัธยม ปีการศึกษา 2556–2559 [แผ่นพับ]. (ม.ป.ท.).

เอกสิทธิ์ พชรวงศ์ศักดิ์. (2557). *การวิเคราะห์ข้อมูลด้วยเทคนิคดาต้า ไมน์นิ่ง เบื้องต้น*. เอเชีย ดิจิตอลการพิมพ์.

ภาษาอังกฤษ

Garson, G. D. (1998). *Neural networks an introductory guide for social scientists*. SAGE.

Hair, J. F., Jr., Black, W. C., Babin, B. J., & Anderson, R. E. (2010). *Multivariate data analysis* (7th ed.). Prentice Hall.

Kavzoglu, T., & Colkesen, I. (2012). The effects of training set size for performance of support vector machines and decision trees. *Proceeding of the 10th International Symposium on Spatial Accuracy Assessment in Natural Resources and Environmental Sciences Florianopolis-SC*, 1-6. http://www.gtu.edu.tr/Files/UserFiles/80/jeodezi/yayinlar/pdf/accuracy_2012colkesen.pdf

Rokach, L. (2008). *Data mining with decision trees: Theory and application*. World Scientific.

Sintanakul, T., & Sanrach, C. (2016). A model of decision support system for choosing high school learning plan using students' O-NET score and multiple intelligence. *International Journal of Information and Education Technology*, 6(7), 555-559.

Vanajakshi, L., & Rilett, L. R. (2004, June 14-17). A comparison of the performance of artificial neural networks and support vector machines for the prediction of vehicle speed. In A. Broggi (Chair), *IEEE intelligent vehicles symposium* (pp. 194-199). Parma, Italy. <https://doi.org/10.1109/IVS.2004.133638>