

การจำแนกวัสดุและครุภัณฑ์โดยการเรียนรู้ของเครื่อง: กรณีศึกษา หน่วยวัสดุ คณะพาณิชยศาสตร์และการบัญชี มหาวิทยาลัยธรรมศาสตร์

ณัฐธิดา สุจินพรัหม* และ มงคลชัย ไชโย

คณะพาณิชยศาสตร์และการบัญชี มหาวิทยาลัยธรรมศาสตร์ อำเภอกองหลวง จังหวัดปทุมธานี 12121

*อีเมลผู้ประพันธ์บรรณกิจ: nuthida.s@tbs.tu.ac.th

บทคัดย่อ

การวิจัยจากงานประจำนี้มีวัตถุประสงค์เพื่อสร้างต้นแบบปัญญาประดิษฐ์ด้วยวิธีการเรียนรู้ของเครื่อง เพื่อจำแนกวัสดุและครุภัณฑ์ตามหลักมาตรฐานของสำนักงานงบประมาณ โดยใช้ซอฟต์แวร์ออเรนจ์ดาต้าไมนิงเป็นเครื่องมือ โดยกำหนดข้อมูลสำหรับการเรียนรู้ของเครื่องซึ่งฝึกฝนจากข้อมูลตัวอย่างด้วยวิธี Logistic Regression และวิธี Neural Network และนำต้นแบบที่ฝึกฝนได้มาใช้จำแนกประเภทของวัสดุและครุภัณฑ์สำหรับงานจัดซื้อของคณะฯ ที่เกิดขึ้นในปีประเมินผลการปฏิบัติงาน 2567 จำนวน 204 รายการ ต้นแบบที่ 1 ฝึกฝนจากข้อมูลตัวอย่าง 171 รายการ ผลทดสอบกับข้อมูลจริงพบว่า Logistic Regression ได้ค่า F-1 Score 0.818 และ Neural Network ได้ค่า 0.814 ต้นแบบที่ 2 ฝึกฝนจากข้อมูลตัวอย่างเพิ่มเติมอีก 652 รายการ รวมเป็น 823 รายการ ผลทดสอบกับข้อมูลจริงพบว่า Logistic Regression ได้ค่า F-1 Score 0.886 และ Neural Network ได้ค่า 0.881 ซึ่งแสดงให้เห็นว่า การเพิ่มจำนวนข้อมูลตัวอย่างส่งผลให้ประสิทธิภาพของต้นแบบเพิ่มขึ้น โดย Logistic Regression มีค่า F-1 Score เพิ่มขึ้น 6.80% และ Neural Network เพิ่มขึ้น 7.30% จากการทดลองสรุปได้ว่า สามารถสร้างต้นแบบสำหรับจำแนกวัสดุและครุภัณฑ์โดยใช้วิธีการเรียนรู้ของเครื่องในการจัดซื้อของคณะฯ ได้จริง และต้นแบบการจำแนกที่เหมาะสมและมีประสิทธิภาพสูงสุด คือ วิธี Logistic Regression ซึ่งมีค่า F-1 Score ใกล้เคียงกับวิธี Neural Network และในอนาคตมีแนวทางการพัฒนาประสิทธิภาพของต้นแบบต่อไปได้ โดยการนำข้อมูลการจัดซื้อจัดจ้างที่เกิดขึ้นมาใช้ในการฝึกฝนต้นแบบเพื่อเพิ่มประสิทธิภาพของต้นแบบ

คำสำคัญ: การเรียนรู้ของเครื่อง, การจำแนกประเภทวัสดุ, วัสดุและครุภัณฑ์, ออเรนจ์ดาต้าไมนิง, วิจัยจากงานประจำ (R2R)

Material and Durable Articles Classification Using Machine Learning: A Case Study of the Procurement Unit, Faculty of Commerce and Accountancy, Thammasat University, Thailand

Nuthida Sujinprum and Mongkolchai Chaiyo

Faculty of Commerce and Accountancy, Thammasat University, Khlong Luang, Pathum Thani 12121, Thailand

*Corresponding author's e-mail: nuthida.s@tbs.tu.ac.th

Abstract

This Routine-to-Research (R2R) study aims to develop an artificial intelligence prototype using machine learning techniques to classify supplies and durable assets in accordance with the Budget Bureau standards, employing Orange Data Mining software as the primary tool. The research methodology involved training predictive models using Logistic Regression and Neural Network algorithms. These developed prototypes were subsequently tested on actual procurement items of the faculty from the 2024 performance evaluation year, comprising 204 entries. The experimental results indicated that Prototype 1, trained on 171 sample items, yielded F1-scores of 0.818 for Logistic Regression and 0.814 for Neural Network. Conversely, Prototype 2, which integrated an additional 652 training samples (bringing the total dataset to 823 items), demonstrated a substantial improvement in classification performance. Specifically, the F1-score for Logistic Regression increased to 0.886 (a 6.80% increase), and the Neural Network F1-score reached 0.881 (a 7.30% increase). These findings confirm that expanding the training dataset directly enhances the prototype's classification efficiency. In conclusion, machine learning techniques can be effectively utilized to construct classification prototypes for faculty procurement processes. The Logistic Regression model emerged as the most appropriate and highly efficient approach, delivering precise results with lower model complexity. For future research, continuously incorporating newly generated procurement data into the training phase is recommended to further enhance the prototype's classification accuracy and robustness.

Keywords: Machine Learning, Procurement Classification, Materials and Durable Articles, Orange Data Mining, Routine-to-Research (R2R)

บทนำ

การจำแนกประเภทของพัสดุที่จะดำเนินการจัดซื้อจัดจ้างตามระเบียบพัสดุว่าเป็นวัสดุหรือเป็นครุภัณฑ์ เป็นเรื่องที่มีความสำคัญ มีความซับซ้อน และเกิดความผิดพลาดคลาดเคลื่อนได้ง่าย เนื่องจากการพิจารณาโดยเจ้าหน้าที่พัสดุแต่ละคนอาจมีประสบการณ์และความชำนาญในการจำแนกแตกต่างกันไป ประกอบกับในปัจจุบันมีรายการของวัสดุและครุภัณฑ์ชนิดใหม่เพิ่มมากขึ้น การจำแนกโดยหลักเกณฑ์เดิมจึงยังต้องอาศัยความรู้และประสบการณ์เฉพาะตัวของเจ้าหน้าที่เป็นหลัก ส่งผลให้มีโอกาสเกิดข้อผิดพลาดขึ้นได้ ด้วยเหตุนี้ คณะฯ จึงมีแนวนโยบายในการปรับปรุงพัฒนากระบวนการทำงาน โดยมุ่งเน้นการนำเทคโนโลยีมาประยุกต์ใช้เพื่อเพิ่มประสิทธิภาพการทำงานประจำ

การวิจัยนี้จึงมีวัตถุประสงค์เพื่อสร้างต้นแบบปัญญาประดิษฐ์ด้วยวิธีการเรียนรู้ของเครื่อง สำหรับการจำแนกรายการที่เป็นวัสดุและครุภัณฑ์ตามหลักมาตรฐานการจำแนกของสำนักงานงบประมาณ โดยฝึกฝนแบบจำลองให้สอดคล้องกับการดำเนินการทางพัสดุของคณะฯ บนหลักการของอธิปไตยทางด้านปัญญาประดิษฐ์ (AI Sovereignty) รวมทั้งทดลองและทดสอบเพื่อหาต้นแบบที่เหมาะสมและมีประสิทธิภาพสูงสุด โดยใช้กรอบแนวคิดการวิจัยจากงานประจำ (R2R) และใช้ซอฟต์แวร์ Orange Data Mining (Demšar et al., 2013) เป็นเครื่องมือหลักในการดำเนินงาน

ผู้วิจัยได้กำหนดข้อมูลสำหรับการเรียนรู้ของเครื่องตามแนวทางของสำนักงานงบประมาณ (สำนักงานงบประมาณ, 2559) ซึ่งในขั้นแรกมีข้อมูลตัวอย่างจำนวน 171 รายการ และได้เพิ่มเติมข้อมูลฝึกฝนอีกจำนวน 652 รายการ เพื่อสร้างและทดสอบต้นแบบด้วยวิธี Logistic Regression และวิธี Neural Network จากนั้นนำต้นแบบที่ผ่านการฝึกฝนมาใช้จำแนกประเภทพัสดุจริงจากการจัดซื้อของคณะฯ ที่เกิดขึ้นในปีประเมินผลการปฏิบัติงาน 2567 จำนวน 204 รายการ

การวิจัยนี้ดำเนินการบนพื้นฐานแนวคิดปัญญาประดิษฐ์และการเรียนรู้ของเครื่อง (Bishop, 2006; Russell & Norvig, 2021) ซึ่งเป็นสาขาย่อยที่มุ่งพัฒนาวิธีการให้ระบบสามารถเรียนรู้จากข้อมูลและปรับปรุงประสิทธิภาพได้ด้วยตนเองโดยไม่ต้องเขียนกฎเกณฑ์อย่างละเอียด (Mitchell, 1997) ได้ให้คำจำกัดความของการเรียนรู้ของเครื่องว่า โปรแกรมคอมพิวเตอร์จะเกิดการเรียนรู้หากประสิทธิภาพการทำงานดีขึ้นเมื่อได้รับประสบการณ์เพิ่มขึ้น

ในการวิจัยนี้ได้เลือกใช้วิธีการฝึกฝนต้นแบบจำนวน 2 วิธีเพื่อนำมาเปรียบเทียบประสิทธิภาพ ได้แก่

Logistic Regression: เป็นวิธีการจำแนกประเภทแบบ Supervised Learning (Hastie et al., 2009) ที่นิยมใช้ในงานจำแนกแบบสองกลุ่ม (Binary Classification) แม้จะมีชื่อเป็น Regression แต่ใช้สำหรับประมาณความน่าจะเป็นในการอยู่ในกลุ่มใดกลุ่มหนึ่งด้วยฟังก์ชันโลจิสติก (Logistic Function) เพื่อแปลงค่าให้อยู่ในช่วง 0 ถึง 1 (Hosmer et al., 2013) มีจุดเด่นคือโครงสร้างแบบจำลองที่สามารถตีความความสัมพันธ์ระหว่างตัวแปรได้ง่าย จึงมักใช้เป็นแบบจำลองพื้นฐาน (Baseline Model) ในการเปรียบเทียบประสิทธิภาพ

Neural Network (โครงข่ายประสาทเทียม): เป็นแบบจำลองที่จำลองการทำงานของระบบประสาทมนุษย์ ประกอบด้วยหน่วยประมวลผล (Neuron) ที่เชื่อมโยงกันเป็นชั้น ได้แก่ ชั้นข้อมูลเข้า (Input Layer) ชั้นซ่อน (Hidden Layer) และชั้นผลลัพธ์ (Output Layer) โดยแบบจำลองจะปรับค่าน้ำหนัก (Weights) ระหว่างนิวรอนเพื่อจับความสัมพันธ์ที่ไม่เป็นเชิงเส้นและมีความซับซ้อนสูง (Goodfellow et al., 2016; Haykin, 2009)

สำหรับการประมวลผลข้อมูลข้อความ (Text Mining) ผู้วิจัยได้นำหลักการจัดเตรียมและแปลงข้อความให้เป็นเวกเตอร์เชิงตัวเลข (Feldman & Sanger, 2007) โดยเลือกใช้วิธี Document Embedding (Le & Mikolov, 2014) หรือ Doc2Vec ซึ่งเป็นวิธีที่สะท้อนความหมายเชิงบริบทของคำในประโยคสั้นได้ดีกว่าวิธีดั้งเดิมอย่าง Bag of Words ทำให้นำไปใช้จำแนกข้อความพัสดุที่มีขนาดสั้นแต่หลากหลายได้อย่างมีประสิทธิภาพ

นอกจากนี้ การวิจัยยังดำเนินงานภายใต้กรอบแนวคิด อธิปไตยทางด้านปัญญาประดิษฐ์ (AI Sovereignty) (Floridi, 2020; Abecassis et al., 2025) ซึ่งเน้นย้ำถึงความสามารถขององค์กรในการควบคุมข้อมูลและพึ่งพาเทคโนโลยีภายในตนเอง เพื่อรักษาความปลอดภัยของข้อมูลพัสดุและลดการพึ่งพาระบบประมวลผลภายนอกหรือระบบคลาวด์ต่างประเทศ

วัตถุประสงค์การวิจัย

1) สร้างต้นแบบปัญญาประดิษฐ์ด้วยวิธีการเรียนรู้ของเครื่อง สำหรับการจำแนกรายการที่เป็นวัสดุและครุภัณฑ์ ตามหลักมาตรฐานการจำแนกวัสดุและครุภัณฑ์ โดยมีการฝึกฝนเรียนรู้ด้วยวิธีการการเรียนรู้ของเครื่องให้สอดคล้องกับการดำเนินการทางพัสดุของคณะฯ บนหลักการของอธิปไตยทางด้านปัญญาประดิษฐ์

2) ทดลองและทดสอบต้นแบบปัญญาประดิษฐ์ที่ได้จากวิธีการเรียนรู้ของเครื่อง ที่เหมาะสมและมีประสิทธิภาพสูงสุดสำหรับการจำแนกรายการที่เป็นวัสดุและครุภัณฑ์สำหรับการใช้งานภายในคณะฯ

ระเบียบวิธีวิจัย

กรอบแนวคิดในการวิจัย ดำเนินการบนพื้นฐานการวิจัยจากงานประจำ โดยการนำประเด็นที่เป็นปัญหาที่เกิดขึ้นจากการปฏิบัติงานประจำ ซึ่งในกรณีนี้คือการปฏิบัติงานตามภารกิจของหน่วยพัสดุ ที่มีหน้าที่หลักในการดำเนินการจัดซื้อจัดจ้างให้ถูกต้องตามกฎหมาย รวมทั้งการดำเนินการอย่างมีประสิทธิภาพและประสิทธิผล ภายใต้นโยบายการบริหารงานของคณะฯ โดยกรอบการวิจัยจะดำเนินการบนหลักของการประยุกต์ใช้เทคโนโลยีและทฤษฎีทางด้านวิทยาการคอมพิวเตอร์ เพื่อปรับปรุงแก้ไขปัญหาและอุปสรรคในการปฏิบัติงาน รวมทั้งการพัฒนาแนวทางการทำงานโดยมุ่งเน้นผลสัมฤทธิ์ของการปฏิบัติงานตามตัวชี้วัดที่กำหนดไว้ในแต่ละรอบปีการประเมินผลการปฏิบัติงานเป็นหลัก

วิธีการดำเนินการวิจัย

1) ประชากรและชุดข้อมูลที่ใช้ในการวิจัย

(1.1) ข้อมูลตามหนังสือเวียนสำนักงบประมาณ ที่ นร 0704/ว 37 เรื่อง แนวทางการพิจารณาสิ่งของที่จัดเป็นวัสดุและครุภัณฑ์ตามหลักการจัดประเภทรายจ่ายตามงบประมาณ (สำนักงบประมาณ, 2559) ได้กำหนดตัวอย่างสิ่งของที่จัดเป็นวัสดุโดยสภาพและสิ่งของที่เป็นครุภัณฑ์โดยสภาพ รวม 171 รายการ ใช้สำหรับสร้างต้นแบบที่ 1

(1.2) ข้อมูลตามหนังสือเวียนสำนักงบประมาณ ที่ นร 0704/ว 37 จำนวน 171 รายการและข้อมูลตัวอย่างเพิ่มเติมตามหนังสือเวียนสำนักงบประมาณ ที่ นร 0704/ว 37 จำนวน 652 รายการ รวมทั้งหมด 823 รายการ ใช้สำหรับสร้างต้นแบบที่ 2

(1.3) ข้อมูลจากการจัดซื้อจัดจ้างของคณะฯ เฉพาะงานซื้อ ในปีประเมินผลการปฏิบัติงาน 2567 ระหว่างเดือนกรกฎาคม 2566 ถึง มิถุนายน 2567 จำนวน 204 สำหรับทดสอบการทำนายของต้นแบบที่ฝึกฝนได้ ใช้สำหรับทดสอบต้นแบบที่ 1 และต้นแบบที่ 2 โดยมีผลการจำแนกที่ถูกต้องจากหัวหน้าเจ้าหน้าที่พัสดุที่มีประสบการณ์โดยอ้างอิงกับรายการที่ดำเนินการแล้วจากการจัดซื้อจัดจ้างของคณะฯ เพื่อใช้เปรียบเทียบกับผลการจำแนกที่ได้จากต้นแบบที่ 1 และต้นแบบที่ 2

2) เครื่องมือที่ใช้ในการวิจัย

(2.1) เครื่องมือหลักในการวิจัยจะใช้ซอฟต์แวร์ออเรนจ์ดาต้าไมนิงในการพัฒนาต้นแบบโดยการสร้างและฝึกฝนต้นแบบ รวมทั้งการปรับรายละเอียดของต้นแบบ และทดสอบต้นแบบที่ได้ จนได้ค่าความถูกต้องของต้นแบบอยู่ในระดับที่สามารถนำไปใช้งานจริงได้ โดยการสร้างต้นแบบและฝึกฝนต้นแบบ

(2.2) การกำหนดโครงสร้างข้อมูลสำหรับการฝึกฝนแบบจำลองในการเตรียมคลังข้อมูลสำหรับการเรียนรู้ของเครื่องกำหนดโครงสร้างข้อมูลเป็น 3 ส่วน Name: ส่วนข้อมูลข้อความที่เป็นชื่อเรียกของวัสดุหรือครุภัณฑ์ภาษาไทย Category: ส่วนการจำแนกประเภทหลัก โดยกำหนดให้ระบบระบุสถานะเป็น “วัสดุ” หรือ “ครุภัณฑ์” Type: ส่วนรายละเอียดหรือกลุ่มประเภทย่อยของวัสดุและครุภัณฑ์ที่มีการจำแนกตามระเบียบพัสดุ


(2.3) การสร้างต้นแบบและวิธีการเรียนรู้ของเครื่อง

ต้นแบบสร้างโดยการเตรียมข้อมูลด้วยวิธี Document Embedding ตามภาพที่ 1 สำหรับการฝึกฝน โดยใช้วิธีในกลุ่ม Supervised Learning จำนวน 2 วิธีเพื่อนำมาวิเคราะห์เปรียบเทียบประสิทธิภาพพร้อมกัน ได้แก่ 1) Neural Network 2) Logistic Regression


(2.4) การวัดผลและวิเคราะห์ประสิทธิภาพของต้นแบบที่ฝึกฝนได้และการทดสอบการทำนายผล ด้วยค่า Confusion Matrix ใน 5 ตัวชี้วัด 1) Area under ROC 2) Classification Accuracy 3) F-1 Score 4) Precision 5) Recall โดยเลือกใช้ค่า F-1 Score เป็นตัวชี้วัดหลักในการเปรียบเทียบค่าประสิทธิภาพของต้นแบบทั้ง 2 แบบ ที่ได้จากการฝึกฝนและการทำนายผลของต้นแบบกับข้อมูลจริง เพื่อเลือกต้นแบบที่เหมาะสมกับการนำมาใช้งานโดยพิจารณาจากต้นแบบที่มีประสิทธิภาพสูงสุดตามค่าตัวชี้วัดประสิทธิภาพ F-1 Score

ผลการวิจัย

จากการทดลองและการฝึกฝนต้นแบบได้ต้นแบบปัญญาประดิษฐ์สำหรับการจำแนกรายการที่เป็นวัสดุและครุภัณฑ์ ต้นแบบที่ 1 จำนวน 2 ต้นแบบคือ 1) LogisticRegression_model1.pkcls และ 2) NeuralNetwork_model1.pkcls ตามภาพที่ 3 และตารางที่ 1




ภาพที่ 1 โครงสร้างต้นแบบปัญหาประดิษฐ์สำหรับการจำแนกรายการที่เป็นวัสดุและครุภัณฑ์ ต้นแบบที่ 1 ต้นแบบที่ 2



ภาพที่ 2 จำนวนรายการข้อมูลที่ใช้ฝึกฝนต้นแบบที่ 1


ผลการฝึกฝนต้นแบบที่ 1 จำนวนข้อมูลฝึกฝน 171 รายการ ข้อมูลตามภาพที่ 2



ภาพที่ 3 ผลการฝึกฝนต้นแบบที่ 1


ตารางที่ 1 ผลการฝึกฝนต้นแบบที่ 1 จากข้อมูลวัสดุและครุภัณฑ์ตัวอย่างจำนวน 171 รายการ

ต้นแบบ	AUC	CA	F1	Prec	Recall
Logistic Regression	0.883	0.807	0.805	0.806	0.807
Neural Network	0.873	0.819	0.819	0.819	0.819



ภาพที่ 4 จำนวนรายการข้อมูลที่ใช้ฝึกฝนต้นแบบที่ 2

ผลการฝึกฝนต้นแบบที่ 2 จำนวนข้อมูลฝึกฝน 823 รายการ ข้อมูลตามภาพที่ 4



ภาพที่ 5 ผลการฝึกฝนต้นแบบที่ 2

ตารางที่ 2 ผลการฝึกฝนต้นแบบที่ 2 จากข้อมูลวัสดุและครุภัณฑ์ตัวอย่างจำนวน 823 รายการ

ต้นแบบ	AUC	CA	F1	Prec	Recall
Logistic Regression	0.884	0.817	0.817	0.817	0.817
Neural Network	0.892	0.827	0.827	0.828	0.827

จากการทดลองและการฝึกฝนต้นแบบ ได้ต้นแบบปัญญาประดิษฐ์สำหรับการจำแนกรายการที่เป็นวัสดุและครุภัณฑ์ ต้นแบบที่ 2 จำนวน 2 ต้นแบบคือ 1) LogisticRegression_model2.pkcls และ 2) NeuralNetwork_model2.pkcls ตามภาพที่ 5 และตารางที่ 2

ผลการทำนายต้นแบบที่ 1 กับข้อมูลจริง จำนวน 204 รายการ ตามตารางที่ 3

ตารางที่ 3 ผลการทำนายต้นแบบที่ 1 กับข้อมูลที่ดำเนินงานจริง จำนวน 204 รายการ

ต้นแบบ	AUC	CA	F1	Prec	Recall
Logistic Regression	0.893	0.799	0.818	0.868	0.799
Neural Network	0.898	0.794	0.814	0.867	0.794

ผลการทดสอบจำแนกวัสดุและครุภัณฑ์ เมื่อนำต้นแบบที่ 1 มาทดสอบกับข้อมูลการจัดซื้อจัดจ้างของคณะฯ ที่เกิดขึ้นในปี ประเมิน 2567 จำนวน 204 รายการ ได้ผลตามภาพที่ 6 และภาพที่ 7

Predictions - Orange

Show probabilities for: Classes in data ☒ Show classification errors Restore Original Order

	Logistic Regression	error	Neural Network	error	category	type	name
1	0.18 : 0.82 → วัสดุ	0.181	0.00 : 1.00 → วัสดุ	0.000	วัสดุ	วัสดุ	อะไหล่
2	0.50 : 0.50 → ครุภัณฑ์	0.505	0.40 : 0.60 → วัสดุ	0.402	วัสดุ	วัสดุ	แบตเตอรี่สำหรับบี
3	0.01 : 0.99 → วัสดุ	0.014	0.00 : 1.00 → วัสดุ	0.000	วัสดุ	วัสดุ	กระดาษ
4	0.80 : 0.20 → ครุภัณฑ์	0.800	0.94 : 0.06 → ครุภัณฑ์	0.943	วัสดุ	วัสดุ	วัสดุสำนักงาน
5	0.01 : 0.99 → วัสดุ	0.006	0.00 : 1.00 → วัสดุ	0.000	วัสดุ	วัสดุ	น้ำดื่ม
6	0.43 : 0.57 → วัสดุ	0.434	0.36 : 0.64 → วัสดุ	0.355	วัสดุ	วัสดุ	อุปกรณ์จ่ายไฟ
7	0.09 : 0.91 → วัสดุ	0.085	0.00 : 1.00 → วัสดุ	0.000	วัสดุ	วัสดุ	หนังสือภาษาอังกฤษ..
8	0.98 : 0.02 → ครุภัณฑ์	0.022	1.00 : 0.00 → ครุภัณฑ์	0.000	ครุภัณฑ์	ครุภัณฑ์	เครื่องปรับอากาศ
9	0.10 : 0.90 → วัสดุ	0.101	0.01 : 0.99 → วัสดุ	0.007	วัสดุ	วัสดุ	หมึกพิมพ์
10	0.22 : 0.78 → วัสดุ	0.220	0.01 : 0.99 → วัสดุ	0.010	วัสดุ	วัสดุ	วัสดุก่อสร้าง
11	0.10 : 0.90 → วัสดุ	0.101	0.01 : 0.99 → วัสดุ	0.007	วัสดุ	วัสดุ	หมึกพิมพ์
12	0.11 : 0.89 → วัสดุ	0.113	0.00 : 1.00 → วัสดุ	0.001	วัสดุ	วัสดุ	ตำรา
13	0.11 : 0.89 → วัสดุ	0.113	0.00 : 1.00 → วัสดุ	0.001	วัสดุ	วัสดุ	ตำรา
14	0.18 : 0.82 → วัสดุ	0.181	0.00 : 1.00 → วัสดุ	0.000	วัสดุ	วัสดุ	อะไหล่
15	0.08 : 0.92 → วัสดุ	0.075	0.00 : 1.00 → วัสดุ	0.000	วัสดุ	วัสดุ	หนังสือ

☒ Show performance scores Target class: (Average over classes)

Model	AUC	CA	F1	Prec	Recall	MCC
Logistic Regression	0.893	0.799	0.818	0.868	0.799	0.517
Neural Network	0.898	0.794	0.814	0.867	0.794	0.511

204 | 204 | 204 | 2x204

ภาพที่ 6 ผลการทำนายต้นแบบที่ 1

		Predicted		Σ
		ครุภัณฑ์	วัสดุ	
Actual	ครุภัณฑ์	31	6	37
	วัสดุ	35	132	167
Σ		66	138	204

Neural Network

		Predicted		Σ
		ครุภัณฑ์	วัสดุ	
Actual	ครุภัณฑ์	31	6	37
	วัสดุ	36	131	167
Σ		67	137	204

Logistic Regression

ภาพที่ 7 ค่า Confusion Matrix ผลการทำนายโดยใช้ต้นแบบที่ 1 กับข้อมูลที่ดำเนินงานจริง จำนวน 204 รายการ

ผลการทำนายต้นแบบที่ 2 กับข้อมูลจริง จำนวน 204 รายการ ตามตารางที่ 4

ตารางที่ 4 ผลการทำนายต้นแบบที่ 2 กับข้อมูลที่ดำเนินงานจริง จำนวน 204 รายการ

ต้นแบบ	AUC	CA	F1	Prec	Recall
Logistic Regression	0.936	0.877	0.886	0.912	0.877
Neural Network	0.907	0.873	0.881	0.901	0.873

ผลการทดสอบจำแนกวัตถุและครุภัณฑ์ เมื่อนำต้นแบบที่ 2 มาทดสอบกับข้อมูลการจัดซื้อจัดจ้างของคณะฯ ที่เกิดขึ้นในปี ประเมิน 2567 จำนวน 204 รายการ ได้ผลตามภาพที่ 8 และภาพที่ 9

Predictions - Orange									
Show probabilities for Classes in data ☒ Show classification errors Restore Original Order									
	Logistic Regression	error	Neural Network	error	category	type	name	Dim1	Dim2
1	0.15 : 0.85 → วัสดุ	0.150	0.00 : 1.00 → วัสดุ	0.000	วัสดุ	วัสดุ	อะไหล่	-0.0558363	0.00718346
2	0.33 : 0.67 → วัสดุ	0.325	0.00 : 1.00 → วัสดุ	0.000	วัสดุ	วัสดุ	แบตเตอรี่สำหรับ	-0.402099	0.929991
3	0.00 : 1.00 → วัสดุ	0.003	0.00 : 1.00 → วัสดุ	0.000	วัสดุ	วัสดุ	กระดาษ	-0.218116	0.323835
4	0.40 : 0.60 → วัสดุ	0.402	0.00 : 1.00 → วัสดุ	0.005	วัสดุ	วัสดุ	วัสดุสำนักงาน	-0.138116	0.11922
5	0.03 : 0.97 → วัสดุ	0.025	0.01 : 0.99 → วัสดุ	0.007	วัสดุ	วัสดุ	น้ำดื่ม	0.164133	0.15516
6	0.61 : 0.39 → ครุภัณฑ์	0.614	0.16 : 0.84 → วัสดุ	0.157	วัสดุ	วัสดุ	อุปกรณ์จ่ายไฟ	-0.1907	0.326765
7	0.37 : 0.63 → วัสดุ	0.371	0.00 : 1.00 → วัสดุ	0.000	วัสดุ	วัสดุ	หนังสือภาษาอังกฤษ...	0.110496	0.0442097
8	0.88 : 0.12 → ครุภัณฑ์	0.118	1.00 : 0.00 → ครุภัณฑ์	0.000	ครุภัณฑ์	ครุภัณฑ์	เครื่องปรับอากาศ	0.079624	0.446118
9	0.25 : 0.75 → วัสดุ	0.254	0.00 : 1.00 → วัสดุ	0.002	วัสดุ	วัสดุ	หมวกพิมพ์	-0.153979	0.249524
10	0.51 : 0.49 → ครุภัณฑ์	0.512	0.00 : 1.00 → วัสดุ	0.002	วัสดุ	วัสดุ	วัสดุก่อสร้าง	-0.0338031	0.108344
11	0.25 : 0.75 → วัสดุ	0.254	0.00 : 1.00 → วัสดุ	0.002	วัสดุ	วัสดุ	หมวกพิมพ์	-0.153979	0.249524
12	0.30 : 0.70 → วัสดุ	0.296	0.00 : 1.00 → วัสดุ	0.001	วัสดุ	วัสดุ	ตำรา	-0.0114563	0.228943
13	0.30 : 0.70 → วัสดุ	0.296	0.00 : 1.00 → วัสดุ	0.001	วัสดุ	วัสดุ	ตำรา	-0.0114563	0.228943
14	0.15 : 0.85 → วัสดุ	0.150	0.00 : 1.00 → วัสดุ	0.000	วัสดุ	วัสดุ	อะไหล่	-0.0558363	0.00718346
15	0.14 : 0.86 → วัสดุ	0.136	0.00 : 1.00 → วัสดุ	0.000	วัสดุ	วัสดุ	หนังสือ	0.0254162	0.300019
☒ Show performance scores Target class: (Average over classes)									
Model	AUC	CA	F1	Prec	Recall	MCC			
Logistic Regression	0.936	0.877	0.886	0.912	0.877	0.680			
Neural Network	0.907	0.873	0.881	0.901	0.873	0.649			

ภาพที่ 8 ผลการทำนายต้นแบบที่ 2

		Predicted		
Actual	ครุภัณฑ์	32	5	37
	วัสดุ	21	146	167
	Σ	53	151	204
Neural Network				
		Predicted		
Actual	ครุภัณฑ์	34	3	37
	วัสดุ	22	145	167
	Σ	56	148	204
Logistic Regression				

ภาพที่ 9 ค่า Confusion Matrix ผลการทำนายโดยใช้ต้นแบบที่ 2 กับข้อมูลที่ดำเนินงานจริง จำนวน 204 รายการ

สรุปผลการวิจัย

จากผลการวิจัยสรุปได้ว่า สามารถสร้างต้นแบบปัญญาประดิษฐ์ด้วยวิธีการเรียนรู้ของเครื่องสำหรับการจำแนกวัสดุและครุภัณฑ์จำนวน 2 ต้นแบบคือ ต้นแบบที่ 1 และต้นแบบที่ 2 และจากการทดลองพบว่าต้นแบบที่ 2 ที่ใช้วิธี Logistic Regression มีประสิทธิภาพสูงที่สุดในการจำแนกวัสดุและครุภัณฑ์สำหรับการใช้งานภายในคณะฯ

ต้นแบบที่ 1

มีการฝึกฝนจากข้อมูลตัวอย่างของวัสดุและครุภัณฑ์จำนวนรวม 171 รายการ และนำต้นแบบมาทดสอบกับข้อมูลจริงซึ่งเป็นข้อมูลการจัดซื้อจัดจ้างของคณะฯ ที่เกิดขึ้นในปีประเมิน 2567 จำนวน 204 รายการ

ต้นแบบที่ฝึกฝนด้วยวิธี Logistic Regression เป็นต้นแบบที่มีค่าประสิทธิภาพในการจำแนกวัสดุและครุภัณฑ์ ที่ค่า F-1 Score 0.805 ในช่วงของการฝึกฝนต้นแบบ และได้ค่า F-1 Score 0.818 เมื่อนำต้นแบบมาทดสอบกับข้อมูลจริง

ต้นแบบที่ฝึกฝนด้วยวิธี Neural Network เป็นต้นแบบที่มีค่าประสิทธิภาพในการจำแนกวัสดุและครุภัณฑ์ ที่ค่า F-1 Score 0.819 ในช่วงของการฝึกฝนต้นแบบ และได้ค่า F-1 Score 0.814 เมื่อนำต้นแบบมาทดสอบกับข้อมูลจริง

ต้นแบบที่ 2

มีการฝึกฝนจากข้อมูลตัวอย่างของวัสดุและครุภัณฑ์จำนวนรวม 823 รายการ และนำต้นแบบมาทดสอบกับข้อมูลจริงซึ่งเป็นข้อมูลการจัดซื้อจัดจ้างของคณะฯ ที่เกิดขึ้นในปีประเมิน 2567 จำนวน 204 รายการ

ต้นแบบที่ฝึกฝนด้วยวิธี Logistic Regression เป็นต้นแบบที่มีค่าประสิทธิภาพในการจำแนกวัสดุและครุภัณฑ์ ที่ค่า F-1 Score 0.817 ในช่วงของการฝึกฝนต้นแบบ และได้ค่า F-1 Score 0.886 เมื่อนำต้นแบบมาทดสอบกับข้อมูลจริง

ต้นแบบที่ฝึกฝนด้วยวิธี Neural Network เป็นต้นแบบที่มีค่าประสิทธิภาพในการจำแนกวัสดุและครุภัณฑ์ ที่ค่า F-1 Score 0.827 ในช่วงของการฝึกฝนต้นแบบ และได้ค่า F-1 Score 0.881 เมื่อนำต้นแบบมาทดสอบกับข้อมูลจริง

ในขั้นตอนการฝึกฝนต้นแบบ ประสิทธิภาพของต้นแบบที่ถูกฝึกฝนโดยวิธี Logistic Regression และวิธี Neural Network มีค่า F-1 Score อยู่ในระดับใกล้เคียงกัน โดยในขั้นตอนการฝึกฝนต้นแบบ วิธี Neural Network มีค่า F-1 Score สูงกว่าวิธี Logistic Regression อยู่ 0.014 สำหรับต้นแบบที่ 1 และ 0.010 สำหรับต้นแบบที่ 2 คิดเป็น 1.40% และ 1.00% ตามลำดับ (อ้างอิงจากค่าประสิทธิภาพ F-1 Score รวมที่ 100%)

แต่เมื่อเปรียบเทียบกันระหว่างต้นแบบที่ 1 และต้นแบบที่ 2 ซึ่งทั้ง 2 ต้นแบบฝึกฝนด้วยวิธี Logistic Regression และวิธี Neural Network โดยในขั้นตอนการทดสอบด้วยข้อมูลจริง วิธี Logistic Regression และวิธี Neural Network ได้ค่า F-1 Score ใกล้เคียงกัน โดยวิธี Logistic Regression มีค่า F-1 Score สูงกว่าวิธี Neural Network อยู่ 0.004 สำหรับต้นแบบที่ 1 และ 0.005 สำหรับต้นแบบที่ 2 คิดเป็น 0.40% และ 0.50% ตามลำดับ (อ้างอิงจากค่าประสิทธิภาพ F-1 Score รวมที่ 100%)

การฝึกฝนต้นแบบด้วยข้อมูลตัวอย่างที่เพิ่มมากขึ้นมีผลต่อค่าประสิทธิภาพของต้นแบบที่เพิ่มขึ้น โดยทั้งต้นแบบที่ฝึกฝนด้วยวิธี Logistic Regression และวิธี Neural Network ในขั้นตอนการทดสอบต้นแบบด้วยข้อมูลจริง เปรียบเทียบระหว่างต้นแบบที่ 1 (จำนวนการฝึกฝน 171 ตัวอย่าง) และต้นแบบที่ 2 (จำนวนการฝึกฝน 823 ตัวอย่าง) เมื่อเปรียบเทียบค่าประสิทธิภาพที่เพิ่มขึ้นของต้นแบบที่ 2 เมื่อเปรียบเทียบกับต้นแบบที่ 1 สำหรับวิธี Logistic Regression และวิธี Neural Network มีค่า F-1 Score เพิ่มขึ้น 0.068 และ 0.073 คิดเป็น 6.80% และ 7.30% ตามลำดับ (อ้างอิงจากค่าประสิทธิภาพ F-1 Score รวมที่ 100%)

จากการทดลองพบว่า เมื่อมีการฝึกฝนต้นแบบแล้วนำต้นแบบไปใช้งานจริง ประสิทธิภาพในการจำแนกระหว่างวัสดุและครุภัณฑ์ของต้นแบบที่มีการฝึกฝนมีค่าประสิทธิภาพที่ใกล้เคียงกันทั้งวิธี Logistic Regression และวิธี Neural Network และทั้ง 2 วิธีมีประสิทธิภาพของต้นแบบเพิ่มขึ้นเมื่อเพิ่มข้อมูลตัวอย่างในการฝึกฝนต้นแบบเพิ่มขึ้น โดยเมื่อเปรียบเทียบกันระหว่างต้นแบบที่ฝึกฝนระหว่างวิธี Logistic Regression และวิธี Neural Network ในการใช้งานจริงพบว่าต้นแบบที่ฝึกฝนด้วยวิธี Logistic Regression มีประสิทธิภาพของต้นแบบสูงกว่าต้นแบบที่ฝึกฝนด้วยวิธี Neural Network แม้ว่าในขั้นตอนการฝึกฝน วิธี Logistic Regression มีประสิทธิภาพของต้นแบบต่ำกว่าต้นแบบที่ฝึกฝนด้วยวิธี Neural Network ก็ตาม

อภิปรายผลการวิจัยและข้อเสนอแนะ

จากการทดลองพบว่า เมื่อมีการฝึกฝนต้นแบบแล้วนำต้นแบบไปใช้งานจริง ประสิทธิภาพในการจำแนกระหว่างวัสดุและครุภัณฑ์ของต้นแบบที่มีการฝึกฝนมีค่าประสิทธิภาพที่ใกล้เคียงกันทั้งวิธี Logistic Regression และวิธี Neural Network และทั้ง 2 วิธีมีประสิทธิภาพของต้นแบบเพิ่มขึ้นเมื่อเพิ่มข้อมูลตัวอย่างในการฝึกฝนต้นแบบเพิ่มขึ้น โดยเมื่อเปรียบเทียบกันระหว่างต้นแบบที่ฝึกฝน

ระหว่างวิธี Logistic Regression และวิธี Neural Network ในการใช้งานจริงพบว่าต้นแบบที่ฝึกฝนด้วยวิธี Logistic Regression มีประสิทธิภาพของต้นแบบสูงกว่าต้นแบบที่ฝึกฝนด้วยวิธี Neural Network แม้ว่าในขั้นตอนการฝึกฝน วิธี Logistic Regression มีประสิทธิภาพของต้นแบบต่ำกว่าต้นแบบที่ฝึกฝนด้วยวิธี Neural Network ก็ตาม

ซึ่งสามารถอธิบายได้จากลักษณะวิธีแบบ Neural Network (Goodfellow et al., 2016; Haykin, 2009) และ ลักษณะของวิธีแบบ Logistic Regression (Hosmer et al., 2013) ในกรณีที่ข้อมูลที่ซับซ้อนวิธีการฝึกฝนแบบ Neural Network จะได้ค่าประสิทธิภาพของต้นแบบที่ดีกว่าโดยวิธีแบบ Neural Network มีความสามารถในการเรียนรู้ความสัมพันธ์ที่ไม่เป็นเชิงเส้นและซับซ้อน จึงเหมาะกับข้อมูลที่มีรูปแบบหลากหลายกว่าวิธีแบบ Logistic Regression แต่จากผลที่ได้โดยสาเหตุที่วิธีแบบ Logistic Regression มีประสิทธิภาพที่ดีกว่าวิธีแบบ Neural Network ในการวิจัยนี้เนื่องจากลักษณะของข้อมูลที่มีการจำแนกเป็นข้อมูลที่ไม่ซับซ้อนและการจำแนกเป็นลักษณะการจำแนกประเภทเพียงประเภทใดประเภทหนึ่งระหว่าง 2 ประเภทคือระหว่างวัสดุและครุภัณฑ์ ซึ่งโดยลักษณะของข้อมูลแล้ววิธีการจำแนกแบบ Logistic Regression จึงมีแนวโน้มที่จะมีประสิทธิภาพที่ดีกว่าการจำแนกแบบ Neural Network ที่เหมาะกับข้อมูลที่มีความซับซ้อนและความยาวของข้อมูลในแต่ละรายการมาก

จากผลการวิจัยพบว่าเทคนิคการเรียนรู้ของเครื่องสามารถนำมาประยุกต์ใช้ในการจำแนกประเภทวัสดุและครุภัณฑ์ได้อย่างมีประสิทธิภาพโดยค่าประสิทธิภาพของต้นแบบที่ฝึกฝนมีผลเพิ่มขึ้นตามจำนวนข้อมูลที่ใช้ในการฝึกฝน การใช้เทคนิค Document Embedding ช่วยให้ระบบสามารถเข้าใจความหมายและบริบทของข้อความได้ดีกว่า ส่งผลให้ต้นแบบมีความสามารถในการจำแนกประเภทข้อมูลได้อย่างแม่นยำมากขึ้น โดยเฉพาะข้อมูลรายการพัสดุที่มีลักษณะเป็นข้อความสั้นและมีความหลากหลาย การวิจัยมีหลักการสร้างต้นแบบโดยอ้างอิงจากหลักการทำงานของ Document Embedding ของ (Le & Mikolov, 2014)

การนำผลการวิจัยไปใช้ประโยชน์และแนวทางการวิจัยในอนาคต จากผลการวิจัยสามารถนำแนวทางการวิจัยที่ได้จากการวิจัยนี้ไปดำเนินการในกรณีของการจำแนกกรณีการดำเนินการต่างๆ ของงานในหน่วยพัสดุ รวมถึงงานในหน่วยงานอื่นในคณะฯ รวมถึงหน่วยงานรัฐอื่นๆ ซึ่งมีหลักการดำเนินการที่มีลักษณะเดียวกันคือมีความจำเป็นต้องดำเนินการให้ถูกต้องครบถ้วนในกฎระเบียบต่างๆ มีกฎเกณฑ์ชัดเจนแต่มีรูปแบบและลักษณะของข้อมูลหรือวิธีการที่เกี่ยวข้องกับการดำเนินการที่หลากหลายและซับซ้อนและมีการเปลี่ยนแปลงของข้อมูลอย่างต่อเนื่อง รวมถึงมีผู้ปฏิบัติงานที่เกี่ยวข้องเป็นจำนวนมากซึ่งจะพบกับปัญหาในการสร้างมาตรฐานการดำเนินการที่อยู่บนมาตรฐานเดียวกันทำได้ยาก และในบริบทที่ข้อมูลที่เกี่ยวข้องในการดำเนินการเป็นข้อมูลที่เป็นความลับหรือเป็นข้อมูลภายในของหน่วยงานที่มีระเบียบและข้อกำหนดในเก็บรักษาข้อมูลตามระเบียบของหน่วยงานรัฐ

กิตติกรรมประกาศ

งานวิจัยนี้สำเร็จลุล่วงไปได้ด้วยดีด้วยความกรุณาและการสนับสนุนจากหลายฝ่าย ผู้วิจัยขอขอบพระคุณคณะพาณิชยศาสตร์และการบัญชี มหาวิทยาลัยธรรมศาสตร์ ที่ได้กรุณาสับสนุนงบประมาณค่าลงทะเบียนเข้าร่วมงานและค่าใช้จ่ายในการเดินทางไปนำเสนอผลงาน ซึ่งเป็นส่วนสำคัญอย่างยิ่งในการเผยแพร่ผลงานวิจัยในครั้งนี้

เอกสารอ้างอิง

- สำนักงบประมาณ. (2559, 6 มกราคม). *หนังสือเวียนสำนักงบประมาณ ที่ นร 0704/ว 37 เรื่อง แนวทางการพิจารณาสิ่งของที่จัดเป็นวัสดุและครุภัณฑ์ตามหลักการจำแนกประเภทรายจ่ายตามงบประมาณ*. กรุงเทพฯ: สำนักงบประมาณ
- Abecassis, A., Bengio, Y., Mialhe, N., et al. (2025). *A blueprint for multinational advanced AI development*. Oxford Martin AI Governance Initiative.
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
- Demšar, J., Curk, T., Erjavec, A., Gorup, Č., Hočevár, T., Milutinovič, M., Možina, M., Polajnar, M., Toplak, M., Starič, A., Štajdohar, M., Umek, L., Žagar, L., Žbontar, J., Žitnik, M., & Zupan, B. (2013). Orange: Data mining toolbox in Python. *Journal of Machine Learning Research*, 14(71), 2349-2353.
- Feldman, R., & Sanger, J. (2007). *The text mining handbook: Advanced approaches in analyzing unstructured data*. England: Cambridge University Press.
- Floridi, L. (2020). The fight for digital sovereignty: What it is, and why it matters, especially for the EU. *Philosophy & Technology*, 33, 369-378. <https://doi.org/10.1007/s13347-020-00423-6>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. USA: MIT Press.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference,*

- and prediction* (2nd ed.). New York: Springer.
- Haykin, S. (2009). *Neural networks and learning machines* (3rd ed.). Pearson.
- Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied logistic regression* (3rd ed.). USA: John Wiley & Sons.
- Le, Q. V., & Mikolov, T. (2014). *Distributed representations of sentences and documents* (pp. 1188-1196). In Proceedings of the 31st International Conference on Machine Learning. China: PMLR.
- Mitchell, T. M. (1997). *Machine learning*. UK: McGraw-Hill.
- Russell, S., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). UK: Pearson.