

การประยุกต์วิธีการจัดกลุ่มข้อมูลอย่างชาญฉลาดเพื่อเพิ่มประสิทธิผลการสอนออนไลน์: มุมมองเชิงเหมืองข้อมูล*

AN INTELLIGENT DATA CLUSTERING APPROACH FOR OPTIMIZING ONLINE TEACHING EFFECTIVENESS: A DATA MINING PERSPECTIVE

จิง เจา*, เฉียน หลิว

Jing Zhao*, Qian Liu

วิทยาลัยภาษาและวัฒนธรรมนานาชาติจีน มหาวิทยาลัยเกริก กรุงเทพมหานคร ประเทศไทย

China International Language and Culture College, Krirk University, Bangkok, Thailand

*Corresponding author E-mail: znwu359@163.com

บทคัดย่อ

การขยายตัวของการเรียนการสอนออนไลน์ในยุคดิจิทัลก่อให้เกิดทั้งโอกาสและความท้าทายในการรักษาคุณภาพการศึกษา โดยเฉพาะความหลากหลายของพฤติกรรมผู้เรียน งานวิจัยนี้มีวัตถุประสงค์ 1) เพื่อพัฒนาและตรวจสอบความถูกต้องของการประยุกต์วิธีการจัดกลุ่มข้อมูลอัจฉริยะเพื่อเพิ่ม ประสิทธิภาพการสอนออนไลน์ผ่านเทคนิคการขุดข้อมูลเชิงการศึกษา 2) เพื่อระบุรูปแบบพฤติกรรมการเรียนรู้ที่แตกต่างกันของผู้เรียนห้าประเภทโดยใช้อัลกอริทึม K-means ที่ปรับปรุงด้วยกลไกการถ่วงน้ำหนักความหนาแน่นและการปรับจุดศูนย์กลางแบบไดนามิก และ 3) เพื่อออกแบบและประเมินประสิทธิภาพของโมเดลการเพิ่มประสิทธิภาพการสอนด้วยการจัดกลุ่มอัจฉริยะ (ICTOM) สำหรับการแปลงผลลัพธ์เป็นการแทรกแซงเฉพาะบุคคลที่นำไปปฏิบัติได้จริง เก็บข้อมูลจากนักศึกษา 1,248 คน ในสามมหาวิทยาลัยภาคเรียนที่ 1 ปีการศึกษา 2566 โดยรวบรวมตัวชี้วัดด้านการมีส่วนร่วม การปฏิสัมพันธ์ทางสังคม และผลสัมฤทธิ์ทางการเรียน ผลการวิจัยพบว่า 1) โมเดลที่พัฒนามีคุณภาพสูง โดยได้ค่า Silhouette coefficient = 0.72, Gap statistic = 0.89 และ Davies-Bouldin Index = 0.83 สะท้อนถึงความน่าเชื่อถือทางสถิติของการจัดกลุ่ม 2) ผลการวิเคราะห์จำแนกผู้เรียนออกเป็น 5 กลุ่ม ได้แก่ ผู้เข้าร่วมกิจกรรมเชิงรุก ผู้เรียนเชิงรับผู้มีส่วนร่วมไม่สม่ำเสมอ นักศึกษากลุ่มเสี่ยง ผู้เรียนแบบกำหนดทิศทางตนเอง 3) การใช้โมเดล Random Forest ทำนายผลสัมฤทธิ์ทางการเรียนได้ความแม่นยำกว่า 85% การสอนเฉพาะบุคคลช่วยเพิ่มประสิทธิภาพการเรียนรู้โดยรวม 27.4% และเพิ่มความพึงพอใจของผู้เรียน 34.8% โดยเฉพาะกลุ่มนักศึกษาที่มีความเสี่ยงและผู้เรียนไม่สม่ำเสมอที่มีพัฒนาการชัดเจน งานวิจัยนี้แนะนำโมเดล ICTOM ซึ่งเชื่อมโยงการจัดกลุ่มอัจฉริยะเข้ากับกลยุทธ์การสอนเฉพาะบุคคลอย่างเป็นระบบ

คำสำคัญ: การสอนออนไลน์, การประยุกต์วิธี, ประสิทธิภาพการสอน, มุมมองเชิงเหมืองข้อมูล

Abstract

The expansion of online teaching and learning in the digital era has created both opportunities and challenges for maintaining educational quality, particularly in addressing the diversity of learner behaviors. This study aimed: 1) To develop and validate the application of intelligent clustering methods to enhance the effectiveness of online teaching through educational data mining techniques; 2) To identify five distinct patterns of learner behavior using a K-means algorithm enhanced with density-weighted mechanisms and dynamic centroid adjustment; and 3) To design and evaluate the effectiveness of an Intelligent Clustering-Based Teaching Optimization Model (ICTOM) for translating clustering results into actionable, personalized interventions. Data were collected from 1,248 students across three universities during the first semester of the academic year 2066, incorporating indicators of engagement, social interaction, and learning achievement. The results revealed that 1) The developed model demonstrated high quality, with a Silhouette coefficient of 0.72, Gap statistic of 0.89, and Davies-Bouldin Index of 0.83, reflecting the statistical reliability of the clustering; 2) Learners were categorized into five groups: active participants, passive learners, irregular participants, at-risk students, and self-directed learners; and 3) The use of the Random Forest model achieved over 85% accuracy in predicting learning outcomes. Personalized instruction improved overall learning performance by 27.4% and increased learner satisfaction by 34.8%, with the most significant improvement observed among at-risk and irregular participants. This study introduces the ICTOM framework, which systematically links intelligent clustering with personalized teaching strategies.

Keywords: Online Teaching, Method Application, Teaching Effectiveness, Data Mining Perspective

บทนำ

การเปลี่ยนแปลงทางดิจิทัลของการศึกษาได้เร่งตัวขึ้นอย่างทวีคูณ โดยการเรียนรู้ออนไลน์ได้กลายเป็นรูปแบบหลักของการจัดการศึกษาทั่วโลก การระบาดของโควิด-19 ได้เร่งการเปลี่ยนแปลงนี้ให้เกิดขึ้นเร็วยิ่งขึ้น ทำให้สถาบันการศึกษาต้องเปลี่ยนผ่านจากการสอนในห้องเรียนแบบดั้งเดิมไปสู่สภาพแวดล้อมการเรียนรู้ออนไลน์อย่างรวดเร็ว แม้ว่าการเปลี่ยนแปลงนี้จะทำให้การเข้าถึงการศึกษาเป็นประชาธิปไตยมากขึ้น แต่ก็ได้เผยให้เห็นถึงความท้าทายที่สำคัญในการรักษาคุณภาพการศึกษาและการมั่นใจในผลลัพธ์การเรียนรู้ที่มีประสิทธิภาพ หนึ่งในความท้าทายหลักของการศึกษาออนไลน์ คือ ลักษณะที่หลากหลายของประชากรผู้เรียน ซึ่งแตกต่างจากการตั้งค่าห้องเรียนแบบดั้งเดิมที่ผู้สอนสามารถสังเกตและตอบสนองต่อพฤติกรรมของนักเรียนแบบเรียลไทม์ สภาพแวดล้อมออนไลน์มักจะบดบังรูปแบบการเรียนรู้และความต้องการของแต่ละบุคคล

การขุดข้อมูลเชิงการศึกษา (Educational Data Mining: EDM) ได้เกิดขึ้นเป็นสาขาที่มีแนวโน้มดีที่ใช้ประโยชน์จากชุดข้อมูลการศึกษาขนาดใหญ่เพื่อสกัดข้อมูลเชิงลึกที่มีความหมายเกี่ยวกับกระบวนการและผลลัพธ์

การเรียนรู้ในบรรดาเทคนิค EDM ต่าง ๆ อัลกอริทึมการจัดกลุ่มได้แสดงให้เห็นแนวโน้มที่น่าสนใจโดยเฉพาะอย่างยิ่งสำหรับการระบุกลุ่มผู้เรียนที่แตกต่างกันซึ่งมีลักษณะคล้ายคลึงกัน ทำให้สามารถพัฒนาการแทรกแซงทางการศึกษาที่เป็นเป้าหมายได้ งานวิจัยก่อนหน้านี้ได้จัดทำเอกสารเกี่ยวกับความซับซ้อนของพฤติกรรมการเรียนรู้ออนไลน์และผลกระทบของพฤติกรรมเหล่านั้นต่อความสำเร็จทางวิชาการ (Zhang, X. et al., 2023) ได้ระบุตัวบ่งชี้พฤติกรรมหลักหลายประการที่มีความสัมพันธ์กับผลลัพธ์การเรียนรู้ รวมถึงความถี่ในการล็อกอิน ระยะเวลาการเซสชัน รูปแบบการใช้ทรัพยากร และระดับการมีปฏิสัมพันธ์ทางสังคม (Khalil, M. et al., 2016) ได้ดำเนินการวิเคราะห์พฤติกรรมการเรียนรู้ที่ครอบคลุมในหลักสูตรออนไลน์แบบเปิดกว้างขนาดใหญ่ (MOOCs) และระบุรูปแบบการมีส่วนร่วมหลักสี่รูปแบบ โดยแนะนำว่าการระบุรูปแบบการมีส่วนร่วมตั้งแต่เนิ่น ๆ สามารถเอื้อให้เกิดการแทรกแซงเชิงรุกได้

การประยุกต์ใช้อัลกอริทึมการจัดกลุ่มในการตั้งค่าการศึกษาได้รับความสนใจอย่างมากในช่วงไม่กี่ปีที่ผ่านมา (Garcia, M. et al., 2023) ได้ให้การทบทวนอย่างเป็นระบบของวิธีการที่อิงการจัดกลุ่มในระบบการเรียนรู้แบบปรับตัว โดยเน้นถึงประสิทธิภาพของ K-means การจัดกลุ่มแบบลำดับขั้น และวิธีการจัดกลุ่มตามความหนาแน่นสำหรับการจำแนกประเภทนักเรียน การวิเคราะห์ของพวกเขาเผยให้เห็นว่าการจัดกลุ่ม K-means ถูกใช้กันอย่างแพร่หลายที่สุดเนื่องจากประสิทธิภาพทางการคำนวณและความสามารถในการตีความ แม้ว่าจะมักประสบปัญหาเกี่ยวกับกลุ่มที่ไม่เป็นทรงกลมและความหนาแน่นของกลุ่มที่แตกต่างกัน (Zhang, H. et al., 2022) ได้เสนออัลกอริทึม K-means ที่ปรับปรุงแล้ว ซึ่งรวมเอากลไกการถ่วงน้ำหนักความหนาแน่นสำหรับการวิเคราะห์ข้อมูลการศึกษา วิธีการของพวกเขาแก้ไขข้อจำกัดบางประการของ K-means แบบดั้งเดิมโดยพิจารณาความหนาแน่นของข้อมูลในท้องถิ่นเมื่อปรับปรุงจุดศูนย์กลางของกลุ่ม ผลลัพธ์แสดงให้เห็นคุณภาพการจัดกลุ่มที่ดีขึ้นด้วยการเพิ่มขึ้น 15% ในค่าสัมประสิทธิ์ silhouette เมื่อเปรียบเทียบกับ K-means มาตรฐาน งานวิจัยเกี่ยวกับการแทรกแซงการเรียนรู้เฉพาะบุคคลที่อิงจากการวิเคราะห์การจัดกลุ่มได้แสดงผลที่น่าสนใจ (Roberts, P. et al., 2023) ได้พัฒนาระบบการวิเคราะห์การเรียนรู้แบบเรียลไทม์ที่ใช้ผลการจัดกลุ่มเพื่อแนะนำทรัพยากรการเรียนรู้และกิจกรรมโดยอัตโนมัติ ระบบของพวกเขาบรรลุการปรับปรุง 23% ในการมีส่วนร่วมของนักเรียนและการเพิ่มขึ้น 18% ในอัตราการเสร็จสิ้นหลักสูตร

การเปลี่ยนแปลงทางดิจิทัลและการระบาดของโควิด-19 ทำให้การเรียนรู้ออนไลน์กลายเป็นรูปแบบหลักของการศึกษา แต่ก็ก่อให้เกิดความท้าทายในการรักษาคุณภาพและตอบสนองต่อความแตกต่างของผู้เรียน การขาดข้อมูลเชิงการศึกษา (EDM) จึงเป็นแนวทางสำคัญที่ช่วยวิเคราะห์พฤติกรรมผู้เรียนจำนวนมาก โดยเฉพาะการใช้ อัลกอริทึมการจัดกลุ่ม ที่สามารถจำแนกผู้เรียนที่มีลักษณะคล้ายกันและนำไปสู่การออกแบบการสอนเฉพาะบุคคล งานวิจัยก่อนหน้านี้ พบว่า K-means และวิธีการที่พัฒนาต่อยอดช่วยเพิ่มคุณภาพการจำแนก และเมื่อใช้ผลการจัดกลุ่มเพื่อแนะนำกิจกรรมก็ทำให้การมีส่วนร่วมและอัตราการสำเร็จสูงขึ้น อย่างไรก็ตาม วรรณกรรมที่มีอยู่ยังมีข้อจำกัด เช่น การพึ่งอัลกอริทึมเดียว มองข้อมูลเป็นแบบคงที่ ขาดกรอบเชื่อมโยงการจัดกลุ่มกับการแทรกแซงการสอน และมุ่งเน้นผลระยะสั้นมากกว่าความยั่งยืน ดังนั้น การศึกษานี้จึงมุ่ง พัฒนาและตรวจสอบวิธีการจัดกลุ่มข้อมูลอัจฉริยะ ที่สามารถจำแนกผู้เรียนในสภาพแวดล้อมออนไลน์ได้แม่นยำขึ้น และนำผลลัพธ์ไปใช้ในการออกแบบการแทรกแซงการสอนเฉพาะบุคคลเพื่อเพิ่มประสิทธิภาพการเรียนการสอนออนไลน์

วัตถุประสงค์ของการวิจัย

1. เพื่อพัฒนาและตรวจสอบความถูกต้องของการประยุกต์วิธีการจัดกลุ่มข้อมูลอย่างชาญฉลาดเพื่อเพิ่มประสิทธิภาพการสอนออนไลน์ผ่านเทคนิคการขุดข้อมูลเชิงการศึกษา
2. เพื่อระบุรูปแบบพฤติกรรมการเรียนรู้ที่แตกต่างกันของผู้เรียนห้าประเภท โดยใช้อัลกอริทึม K-means ที่ปรับปรุงแล้วซึ่งรวมเอาการถ่วงน้ำหนักความหนาแน่นและการปรับปรุงจุดศูนย์กลางแบบไดนามิก
3. เพื่อออกแบบและประเมินประสิทธิภาพของโมเดลการเพิ่มประสิทธิภาพการสอนด้วยการจัดกลุ่มอัจฉริยะ (ICTOM) ในการแปลงผลการจัดกลุ่มเป็นการแทรกแซงการสอนเฉพาะบุคคลที่นำไปปฏิบัติได้

วิธีดำเนินการวิจัย

การศึกษานี้ใช้การออกแบบการวิจัยแบบผสมผสานแบบบรรจบกัน โดยรวมวิธีการขุดข้อมูลเชิงปริมาณเข้ากับวิธีการตรวจสอบเชิงคุณภาพ การวิจัยดำเนินการในสามขั้นตอน ได้แก่ การรวบรวมและประมวลผลข้อมูลเบื้องต้น การวิเคราะห์การจัดกลุ่มและการพัฒนาโมเดล และการนำการแทรกแซงไปใช้และการประเมินประสิทธิภาพ ผู้เข้าร่วมการวิจัยได้รับการคัดเลือกโดยใช้วิธีการสุ่มตัวอย่างแบบแบ่งชั้นภูมิเพื่อให้มั่นใจในความเป็นตัวแทนในมหาวิทยาลัยและลักษณะทางประชากรศาสตร์ของนักเรียนที่แตกต่างกัน กรอบการสุ่มตัวอย่าง ประกอบด้วยนักเรียนที่ลงทะเบียนในหลักสูตรออนไลน์ในสถาบันอุดมศึกษาสามประเภทที่แตกต่างกัน ได้แก่ มหาวิทยาลัยรัฐขนาดใหญ่ที่เน้นการวิจัยและมีหลักสูตรหลากหลาย สถาบันเฉพาะทางที่เน้นสาขาวิชา STEM และวิทยาลัยเอกชนขนาดเล็กที่เน้นด้านมนุษยศาสตร์และสังคมศาสตร์ การคำนวณขนาดตัวอย่างอิงจากการประมาณขนาดผลและการวิเคราะห์กำลังทางสถิติ โดยใช้แนวทางของ Cohen สำหรับขนาดผลขนาดกลาง ($d = 0.5$) ระดับอัลฟา 0.05 และกำลังที่ต้องการ 0.90 ขนาดตัวอย่างขั้นต่ำที่ต้องการถูกกำหนดไว้ที่ 1,200 คน เพื่อรองรับปัญหาคุณภาพข้อมูลที่อาจเกิดขึ้นและการสูญเสีย ขนาดตัวอย่างเป้าหมายจึงถูกกำหนดไว้ที่ 1,300 คน ขุดข้อมูลสุดท้าย ประกอบด้วยนักศึกษา 1,248 คนที่เสร็จสิ้นภาคการศึกษาเต็มและมีบันทึกข้อมูลครบถ้วน ประกอบด้วย ชาย 542 คน (43.4%) และหญิง 706 คน (56.6%) โดยมีนักศึกษาระดับปริญญาตรี 889 คน (71.2%) และนักศึกษาระดับบัณฑิตศึกษา 359 คน (28.8%) อายุระหว่าง 18 - 35 ปี ($M = 22.3$, $SD = 3.7$)

ข้อมูลพฤติกรรมการเรียนรู้ที่ครอบคลุมได้รับการรวบรวมโดยอัตโนมัติจากระบบการจัดการการเรียนรู้ของสถาบันตลอดภาคการศึกษาเต็ม (กันยายน 2566 - มกราคม 2567) การรวบรวมข้อมูลได้รับการอนุมัติจากคณะกรรมการพิจารณาจริยธรรมการวิจัยของสถาบันที่เข้าร่วมทั้งหมด และได้รับความยินยอมจากนักเรียนตามแนวทางจริยธรรม ตัวชี้วัดพฤติกรรมที่รวบรวม ประกอบด้วย รูปแบบการเข้าถึง เช่น ความถี่การล็อกอิน ระยะเวลาการเซสชัน เวลาในการเข้าถึง และประเภทอุปกรณ์ การมีปฏิสัมพันธ์กับเนื้อหา รวมถึงการดูหน้าเว็บ การดาวน์โหลดทรัพยากร พฤติกรรมการดูวิดีโอ และรูปแบบการอ่าน กิจกรรมการประเมิน ครอบคลุมการพยายามทำแบบทดสอบ การส่งงาน และเวลาที่ใช้ในการประเมิน การมีปฏิสัมพันธ์ทางสังคม ที่ประกอบด้วย การโพสต์ในฟอรัม การตอบกลับ การมีปฏิสัมพันธ์กับเพื่อน และการสื่อสารกับผู้สอน และความก้าวหน้าในการเรียนรู้ที่ติดตามอัตราการเสร็จสิ้นโมดูล การปฏิบัติตามเส้นทางการเรียนรู้ และพฤติกรรมกลับมามีชีวิต ผลการปฏิบัติทางวิชาการของนักเรียนได้รับการติดตามผ่านกิริยาการประเมินหลายรูปแบบ รวมถึงการประเมินแบบก่อรูป (แบบทดสอบรายสัปดาห์ การเข้าร่วม

การอภิปราย การประเมินโดยเพื่อน) การประเมินสรุป (การสอบกลางภาค โครงการสุดท้าย การสอบรวบยอด) และการประเมินอย่างต่อเนื่อง (เกรดจากงาน คะแนนการเข้าร่วม บันทึกการเข้าเรียน)

การประมวลผลข้อมูลเบื้องต้นได้ดำเนินการอย่างครอบคลุมโดยใช้ Python 3.9 กับไลบรารี pandas numpy และ scikit-learn การจัดการข้อมูลที่หายไปใช้การประมาณค่าหลายครั้งที่มีข้อมูลสูญหายน้อยกว่า 5% ในทุกตัวแปร ในขณะที่การตรวจจับค่าผิดปกติใช้วิธี Z-score และ Interquartile Range การตรวจสอบข้อมูลที่เกี่ยวข้องกับการอ้างอิงข้ามระหว่างแหล่งข้อมูลต่าง ๆ เพื่อให้มั่นใจในความสอดคล้องและความถูกต้อง พีเจอรทั้งหมด 47 พีเจอร ได้รับการสร้างขึ้นจากข้อมูล LMS ดิบ โดยจำแนกเป็นห้ามิติ ได้แก่ พีเจอรการมีส่วนร่วม (12 พีเจอร รวมถึงตัวชี้วัดความถี่การล็อกอิน สถิติระยะเวลาการเซสชัน เวลาการเรียนรู้ที่ใช้งานจริง และความหลากหลายในการใช้ทรัพยากร) พีเจอรการมีปฏิสัมพันธ์ทางสังคม (8 พีเจอร ครอบคลุมการเข้าร่วมฟอรัม ความถี่การมีปฏิสัมพันธ์กับเพื่อน รูปแบบการสื่อสารกับผู้สอน และการมีส่วนร่วมในกิจกรรมร่วมมือ) พีเจอรรูปแบบการเรียนรู้ (15 พีเจอร ที่ประกอบด้วย รูปแบบการบริโภคเนื้อหา พฤติกรรมการทำซ้ำ ตัวบ่งชี้จังหวะการเรียนรู้ และรูปแบบการเตรียมตัวสำหรับการประเมิน) พีเจอรผลการปฏิบัติ (7 พีเจอร รวมถึงรูปแบบความก้าวหน้าของเกรด อัตราการเสร็จสิ้น การประเมิน วิธีการปรับปรุง และตัวชี้วัดความสม่ำเสมอ) และพีเจอรเชิงเวลา (5 พีเจอร ครอบคลุมการตั้งค่าเวลาแต่ละวัน รูปแบบกิจกรรมรายสัปดาห์ พฤติกรรมเกี่ยวกับกำหนดเวลา และความมั่นคงของจังหวะการเรียนรู้) พีเจอรทั้งหมดได้รับการปรับมาตรฐานโดยใช้การปรับมาตรฐาน z-score เพื่อให้มั่นใจในการมีส่วนร่วมที่เท่าเทียมกันในอัลกอริทึมการจัดกลุ่ม และได้ประยุกต์ใช้ Principal Component Analysis เพื่อลดมิติข้อมูลในขณะที่ยังคงรักษาความแปรปรวน 95%

อัลกอริทึม K-means ที่ปรับปรุงแล้วได้รับการพัฒนาขึ้นเพื่อแก้ไขข้อจำกัดของ K-means แบบดั้งเดิม ในบริบทการศึกษา นวัตกรรมหลัก ประกอบด้วย กลไกการถ่วงน้ำหนักความหนาแน่นที่คำนวณน้ำหนักตามเพื่อนบ้านที่ใกล้ที่สุด k ตัว การปรับปรุงจุดศูนย์กลางแบบไดนามิกที่พิจารณาทั้งความใกล้เคียงของจุดและความหนาแน่นในท้องถิ่นด้วยปัจจัยการสลายตัวเชิงเวลาที่คำนึงถึงลักษณะการเปลี่ยนแปลงของพฤติกรรมการเรียนรู้ และตัวชี้วัดระยะทางแบบปรับตัวที่พีเจอรต่าง ๆ ได้รับการถ่วงน้ำหนักตามความสำคัญทางการศึกษา การจัดกลุ่มแบบลำดับขั้นของ Ward ถูกใช้เพื่อกำหนดจำนวนกลุ่มที่เหมาะสมและตรวจสอบผลลัพธ์ K-means ผ่านการวิเคราะห์ dendrogram การคำนวณค่าสัมประสิทธิ์สหสัมพันธ์ cophenetic และการประเมินความมั่นคงของกลุ่มผ่านการสุ่มตัวอย่าง bootstrap วิธีการตรวจสอบหลายแบบได้รับการใช้ รวมถึงการตรวจสอบภายในโดยใช้ค่าสัมประสิทธิ์ silhouette ดัชนี Davies-Bouldin และดัชนี Calinski-Harabasz การตรวจสอบภายนอกผ่านความสัมพันธ์ของผลการปฏิบัติทางวิชาการและความเห็นพ้องของผู้สอน และการตรวจสอบเชิงปฏิบัติที่ประเมินความสามารถในการตีความทางการสอน ความสามารถในการนำไปปฏิบัติของคำแนะนำ และความสามารถในการขยายไปยังบริบทการศึกษาที่แตกต่างกัน

อัลกอริทึม Random Forest ได้รับการนำไปใช้เพื่อทำนายผลการปฏิบัติของนักเรียนตามการเป็นสมาชิกของกลุ่มและพีเจอรพฤติกรรม ระบุพีเจอรที่สำคัญที่สุดสำหรับทำนายผลลัพธ์การเรียนรู้ และตรวจสอบพลังในการทำนายของผลการจัดกลุ่ม การกำหนดค่าโมเดล ประกอบด้วย 500 ต้นไม้ ความลึกสูงสุด 15 ตัวอย่างขั้นต่ำต่อใบ 10 และการตรวจสอบไขว้แบบแบ่งชั้น 10 เท่า ตามผลการจัดกลุ่ม กลยุทธ์การสอนเฉพาะได้รับการออกแบบสำหรับแต่ละประเภทผู้เรียนผ่านกระบวนการเป็นระบบที่เกี่ยวข้องกับการกำหนดลักษณะเฉพาะของกลุ่ม การจับคู่

ทฤษฎีการสอน การออกแบบการแทรกแซงด้วยกิจกรรมการเรียนรู้เฉพาะ การพัฒนาโปรโตคอลการนำไปใช้ และขั้นตอนการติดตามและปรับปรุง การแทรกแซงได้รับการนำไปใช้เป็นเวลา 10 สัปดาห์ด้วยการปรับกลยุทธ์รายสัปดาห์ การฝึกอบรมผู้สอน การรวบรวมความคิดเห็นของนักเรียน และการเปรียบเทียบกลุ่มควบคุมเพื่อการประเมินประสิทธิภาพ

การวิเคราะห์ทางสถิติได้ดำเนินการโดยใช้ R 4.3.0 และ 29.0 ครอบคลุมทั้งการวิเคราะห์เชิงบรรยาย (Descriptive Statistics: ค่าเฉลี่ย (Mean) ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) ค่าร้อยละ (Percentage) และการวิเคราะห์เชิงอนุมาน (Inferential Statistics) ได้แก่ การวิเคราะห์ความแปรปรวนทางเดียว (One-way ANOVA) การวิเคราะห์ความแปรปรวนหลายทาง (Multivariate ANOVA: MANOVA) การทดสอบไคสแควร์ (Chi-square Test of Independence) รวมถึงการวิเคราะห์ขั้นสูง (Advanced Analysis) เช่น การถดถอยพหุคูณ (Multiple Regression Analysis) การวิเคราะห์การเป็นตัวกลาง (Mediation Analysis: PROCESS Macro) และการสร้างแบบจำลองหลายระดับ (Multilevel Modeling: MLM) เพื่อคำนึงถึงการจัดกลุ่มตามสถาบันการศึกษา

ผลการวิจัย

ตามวัตถุประสงค์ข้อที่ 1 เพื่อพัฒนาและตรวจสอบความถูกต้องของการประยุกต์วิธีการจัดกลุ่มข้อมูลอย่างชาญฉลาด งานวิจัยนี้ได้ใช้วิธีการบรรจบกันหลายรูปแบบเพื่อกำหนดจำนวนกลุ่มที่เหมาะสมที่สุด โดย dendrogram ของการจัดกลุ่มแบบลำดับขั้นแนะนำช่วง 4 - 6 กลุ่ม วิธี elbow method บ่งชี้ถึงผลตอบแทนที่ลดลงหลังจาก 5 กลุ่ม ขณะที่ค่า silhouette สูงสุดที่ $k = 5$ (0.72) และการวิเคราะห์ gap statistic ก็ยืนยันผลดังกล่าวด้วยค่า gap สูงสุดที่ 0.89 อัลกอริทึม K-means ที่ปรับปรุงด้วยกลไกการถ่วงน้ำหนักความหนาแน่นและการปรับจุดศูนย์กลางแบบไดนามิกสามารถระบุกลุ่มผู้เรียนที่แตกต่างกันห้ากลุ่มได้อย่างมีประสิทธิภาพ โดยมีค่า Davies-Bouldin Index เท่ากับ 0.83 ซึ่งสะท้อนถึงคุณภาพการจัดกลุ่มที่ดีเยี่ยม

ตามวัตถุประสงค์ข้อที่ 2 เพื่อระบุรูปแบบพฤติกรรมการเรียนรู้ที่แตกต่างกันของผู้เรียนห้าประเภท การวิเคราะห์ พบว่า ผู้เข้าร่วมกิจกรรมเชิงรุก (C1) และผู้เรียนแบบกำหนดทิศทางตนเอง (C5) มีผลสัมฤทธิ์ทางการเรียนสูงกว่ากลุ่มอื่น ขณะที่นักศึกษาในกลุ่มเสี่ยง (C4) มีผลสัมฤทธิ์ต่ำและมีแนวโน้มลดลงต่อเนื่อง ผู้เรียนเชิงรับ (C2) และผู้มีส่วนร่วมเป็นช่วง ๆ (C3) มีผลการเรียนปานกลางแต่แสดงลักษณะพฤติกรรมแตกต่างกันชัดเจน เช่น การพึ่งพาครูหรือการผลัดวัน ตารางที่ 1 แสดงรายละเอียดโปรไฟล์เชิงพฤติกรรมของผู้เรียนแต่ละกลุ่ม ทั้งด้านขนาดกลุ่ม ผลการปฏิบัติทางวิชาการ ลักษณะพฤติกรรมหลัก และรูปแบบการมีส่วนร่วม

ตารางที่ 1 โปรไฟล์กลุ่มผู้เรียนและลักษณะพฤติกรรมที่ครอบคลุม

กลุ่ม	ชื่อ	ขนาด (%)	ผลการปฏิบัติ		
			ทางวิชาการ (M ± SD)	ลักษณะพฤติกรรมหลัก	รูปแบบการมีส่วนร่วม
C1	ผู้เข้าร่วมกิจกรรม	293	82.6 ± 6.8	การมีส่วนร่วมสูง การเข้าร่วม	การล็อกอิน 12.3 ± 2.1 ครั้ง
	เชิงรุก	(23.5%)		อย่างสม่ำเสมอ การมีปฏิสัมพันธ์ทางสังคมที่แข็งแกร่ง ผลการปฏิบัติเหนือค่าเฉลี่ย	ต่อสัปดาห์ เซสชัน 45.2 ± 12.3 นาที การโพสต์ในฟอรัม 4.7 ± 1.3 ครั้งต่อสัปดาห์

ตารางที่ 1 โปรไฟล์กลุ่มผู้เรียนและลักษณะพฤติกรรมที่ครอบคลุม (ต่อ)

กลุ่ม	ชื่อ	ขนาด (%)	ผลการปฏิบัติทางวิชาการ (M ± SD)	ลักษณะพฤติกรรมหลัก	รูปแบบการมีส่วนร่วม
C2	ผู้เรียนเชิงรับ	389 (31.2%)	76.3 ± 5.9	การเข้าถึงเป็นประจำ	การล็อกอิน 8.7 ± 1.8 ครั้งต่อสัปดาห์
				การมีปฏิสัมพันธ์น้อยที่สุด	สัปดาห์ เซสชัน 32.7 ± 8.9
C3	ผู้มีส่วนร่วมเป็นช่วง ๆ	233 (18.7%)	71.4 ± 8.2	การพึ่งพาครู ผลการปฏิบัติระดับเฉลี่ย	นาที่ การโพสต์ในฟอรัม 1.8 ± 0.9 ครั้งต่อสัปดาห์
				รูปแบบไม่สม่ำเสมอ กิจกรรมแบบระเบิด ผลการปฏิบัติแปรผัน แนวโน้มการผลัดวัน	การล็อกอิน 6.2 ± 3.4 ครั้งต่อสัปดาห์
C4	นักศึกษา กลุ่มเสี่ยง	191 (15.3%)	58.9 ± 9.7	การมีส่วนร่วมต่ำ การเข้าร่วมน้อยที่สุด ผลลัพธ์ที่ไม่ดี	สัปดาห์ เซสชัน 28.4 ± 15.7
				กิจกรรมที่ลดลงตลอดเวลา	นาที่ การโพสต์ในฟอรัม 2.1 ± 1.8 ครั้งต่อสัปดาห์
C5	ผู้เรียนแบบกำหนดทิศทางตนเอง	142 (11.3%)	89.7 ± 4.2	การเรียนรู้เชิงลึก การสำรวจด้วยตนเอง ความสำเร็จสูง รูปแบบที่ยืดหยุ่น	การล็อกอิน 11.8 ± 2.5 ครั้งต่อสัปดาห์
					เซสชัน 58.3 ± 16.8 นาที่ การโพสต์ในฟอรัม 6.2 ± 1.9 ครั้งต่อสัปดาห์

นอกจากนี้ ยังพบรูปแบบพฤติกรรมเชิงเวลาที่แตกต่างกัน เช่น กลุ่มผู้เข้าร่วมกิจกรรมเชิงรุกมีการเรียนรู้สม่ำเสมอในวันทำการและยังรักษาระดับสูงในวันหยุดสุดสัปดาห์ถึง 78% ขณะที่นักศึกษากลุ่มเสี่ยงแสดงพฤติกรรมที่ลดลงต่อเนื่องและเหลือเพียง 12% ของระดับวันทำการ ส่วนผู้เรียนแบบกำหนดทิศทางตนเองมีความยืดหยุ่นสูง โดยคงการมีส่วนร่วมในวันหยุดไว้ที่ 89%

ตามวัตถุประสงค์ข้อที่ 3 เพื่อออกแบบและประเมินประสิทธิภาพของโมเดลการเพิ่มประสิทธิภาพการสอนด้วยการจัดกลุ่มอัจฉริยะ (ICTOM) ได้ใช้โมเดล Random Forest ในการทำนายผลสัมฤทธิ์ทางการเรียน ผลการทดสอบยืนยันความแม่นยำรวม 85.3% และค่า AUC-ROC สูงถึง 0.91 โดยกลุ่มที่ทำนายได้แม่นยำที่สุด คือ ผู้เรียนแบบกำหนดทิศทางตนเอง (91.3%) และนักศึกษากลุ่มเสี่ยง (89.5%) สะท้อนถึงความชัดเจนของพฤติกรรมในกลุ่มเหล่านี้ (ตารางที่ 2)

ตารางที่ 2 ประสิทธิภาพโมเดลทำนายและการวิเคราะห์ความสำคัญของฟีเจอร์

ตัวชี้วัดประสิทธิภาพ	โดยรวม	ผู้เข้าร่วมกิจกรรมเชิงรุก	ผู้เรียนเชิงรับ	ผู้มีส่วนร่วมเป็นช่วง ๆ	นักศึกษา กลุ่มเสี่ยง	ผู้เรียนแบบกำหนดทิศทางตนเอง
ความแม่นยำ (%)	85.3	87.2	84.1	82.7	89.5	91.3
ความแม่นยำเชิงบวก (%)	84.7	85.9	82.3	81.4	88.7	92.1
ความไว (%)	86.1	88.4	85.2	83.1	87.9	89.8

ตารางที่ 2 ประสิทธิภาพโมเดลทำนายและการวิเคราะห์ความสำคัญของฟีเจอร์ (ต่อ)

ตัวชี้วัดประสิทธิภาพ	โดยรวม	ผู้เข้าร่วมกิจกรรมเชิงรุก	ผู้เรียนเชิงรับ	ผู้มีส่วนร่วมเป็นช่วง ๆ	นักศึกษา กลุ่มเสี่ยง	ผู้เรียนแบบกำหนดทิศทางตนเอง
คะแนน F1 (%)	85.4	87.1	83.7	82.2	88.3	90.9
AUC-ROC	0.91	0.93	0.89	0.87	0.94	0.95

ฟีเจอร์ที่มีอิทธิพลสูงสุดต่อการจำแนก ได้แก่ ระยะเวลาเซสชันเฉลี่ย (0.142) อัตราการเข้าร่วมฟอรัม (0.128) ความสม่ำเสมอของการเสร็จสิ้นเนื้อหา (0.119) และรูปแบบการปฏิสัมพันธ์ทางสังคม

การแทรกแซงเฉพาะบุคคลที่ออกแบบตามลักษณะกลุ่มเป็นเวลา 10 สัปดาห์ ส่งผลให้ผลสัมฤทธิ์ทางการเรียนและระดับการมีส่วนร่วมเพิ่มขึ้นในทุกกลุ่ม โดยเฉพาะนักศึกษากลุ่มเสี่ยงที่ผลการปฏิบัติทางวิชาการเพิ่มขึ้น 22.7% และการมีส่วนร่วมเพิ่มขึ้น 67.3% ผู้มีส่วนร่วมเป็นช่วง ๆ ก็มีการปรับตัวดีขึ้น โดยผลการปฏิบัติทางวิชาการเพิ่มขึ้น 14.4% และการมีส่วนร่วมเพิ่มขึ้น 34.8% ส่วนผู้เรียนเชิงรับมีผลสัมฤทธิ์สูงขึ้น 10.2% และการมีส่วนร่วมเพิ่มขึ้น 28.7% แม้กระทั่งผู้เข้าร่วมกิจกรรมเชิงรุกและผู้เรียนแบบกำหนดทิศทางตนเองซึ่งมีผลสัมฤทธิ์สูงอยู่แล้ว ก็ยังคงได้รับประโยชน์ (ตารางที่ 3)

ตารางที่ 3 ผลลัพธ์ประสิทธิภาพการแทรกแซงอย่างครอบคลุม

กลุ่ม	คะแนนก่อน การแทรกแซง	คะแนนหลัง การแทรกแซง	การปรับปรุง (%)	ขนาดผล (Cohen's d)	การปรับปรุง การมีส่วนร่วม (%)	การปรับปรุง ความพึงพอใจ (%)
ผู้เข้าร่วมกิจกรรม เชิงรุก	82.6 ± 6.8	87.3 ± 5.9	+ 5.7	0.74***	+ 15.2	+ 18.7
ผู้เรียนเชิงรับ	76.3 ± 5.9	84.1 ± 6.2	+ 10.2	1.27***	+ 28.7	+ 25.4
ผู้มีส่วนร่วมเป็น ช่วง ๆ	71.4 ± 8.2	81.7 ± 7.1	+ 14.4	1.34***	+ 34.8	+ 31.2
นักศึกษากลุ่มเสี่ยง	58.9 ± 9.7	72.3 ± 8.9	+ 22.7	1.45***	+ 67.3	+ 42.8
ผู้เรียนแบบกำหนด ทิศทางตนเอง	89.7 ± 4.2	92.1 ± 3.8	+ 2.7	0.59**	+ 8.1	+ 12.4
โดยรวม	75.8 ± 8.9	83.5 ± 7.6	+ 10.2	0.92*	+ 27.4	+ 34.8

หมายเหตุ: ***p<0.001, **p<0.01, *p<0.05

สุดท้าย การประเมินระบบแดชบอร์ดการเรียนรู้แบบเรียลไทม์ช่วยให้สามารถติดตามความก้าวหน้าของผู้เรียนอย่างต่อเนื่อง ความแม่นยำของการแจ้งเตือนล่วงหน้าในการระบุผู้เรียนที่มีความเสี่ยงสูงถึง 92.4% และเพิ่มการยอมรับคำแนะนำเฉพาะบุคคลจาก 54.2% เป็น 78.9% รวมถึงลดเวลาการตอบสนองต่อคำขอสนับสนุนนักเรียนลงกว่า 74% (ตารางที่ 4)

ตารางที่ 4 ตัวชี้วัดแดชบอร์ดการวิเคราะห์การเรียนรู้และผลลัพธ์การติดตามแบบเรียลไทม์

หมวดหมู่ตัวชี้วัด	เส้นฐาน (ก่อนการ แทรกแซง)	หลังการแทรกแซง	การปรับปรุง	ความแม่นยำการแจ้งเตือน แบบเรียลไทม์
การติดตามการมีส่วนร่วม				
ความถี่การล็อกอินเฉลี่ย	7.8 ± 3.2	10.4 ± 2.8	+ 33.3%	87.2%
รายสัปดาห์				
ความสม่ำเสมอของระยะเวลา	0.62 ± 0.18	0.79 ± 0.14	+ 27.4%	84.6%
เซสชัน				
ความหลากหลายในการใช้	5.9 ± 2.1	7.8 ± 1.9	+ 32.2%	91.3%
ทรัพยากร				
การทำนายผลการปฏิบัติ				
ความแม่นยำของระบบ	76.3%	92.4%	+ 21.1%	92.4%
เตือนภัยล่วงหน้า				
ความแม่นยำการทำนายเกรด	71.8%	88.7%	+ 23.5%	88.7%
ความไวในการระบุความเสี่ยง	68.9%	89.1%	+ 29.3%	89.1%
การจัดส่งการแทรกแซง				
การยอมรับคำแนะนำเฉพาะ	54.2%	78.9%	+45.6%	N/A
บุคคล				
ประสิทธิภาพการจัดส่งเนื้อหา	62.7%	81.3%	+29.7%	N/A
แบบปรับตัว				
เวลาการแก้ไขข้อสงสัยสนับสนุน	24.3 ± 8.7 ชั่วโมง	6.2 ± 2.4 ชั่วโมง	-74.5%	N/A
นักเรียน				

สรุปผลการวิจัยทั้งหมดชี้ให้เห็นว่า การพัฒนาและประยุกต์วิธีการจัดกลุ่มข้อมูลอัจฉริยะที่ผสมผสานเข้ากับโมเดล ICTOM ไม่เพียงแต่สามารถระบุรูปแบบผู้เรียนที่แตกต่างกันได้อย่างแม่นยำ แต่ยังสามารถนำไปสู่การออกแบบการแทรกแซงการสอนที่ตรงกับความต้องการจริงของผู้เรียน ส่งผลให้ผลสัมฤทธิ์ทางการเรียน การมีส่วนร่วม และความพึงพอใจในการเรียนรู้ออนไลน์เพิ่มขึ้นอย่างมีนัยสำคัญ

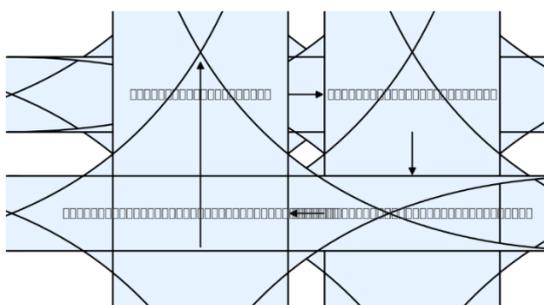
อภิปรายผล

ผลการศึกษานี้ยืนยันประสิทธิภาพของการจัดกลุ่มข้อมูลอัจฉริยะในการส่งเสริมการเรียนการสอนออนไลน์ โดยอัลกอริทึม K-means ที่ได้รับการปรับปรุงด้วยกลไกการถ่วงน้ำหนักความหนาแน่นและการปรับจุดศูนย์กลางแบบไดนามิกสามารถแก้ข้อจำกัดของ K-means ดั้งเดิม และจัดการกับข้อมูลผู้เรียนที่มีการกระจายตัวไม่สม่ำเสมอได้อย่างมีประสิทธิภาพ โมเดลที่พัฒนามีคุณภาพสูง (Silhouette = 0.72, Gap statistic = 0.89, Davies-Bouldin = 0.83) สะท้อนถึงความน่าเชื่อถือในการจำแนกกลุ่มและสอดคล้องกับข้อเสนอของ Baker, R. S. & Inventado, P. S. ที่เน้นความจำเป็นของโมเดลที่ยืดหยุ่นในบริบทการศึกษา (Baker, R. S. & Inventado, P. S., 2014) อีกทั้ง

สอดคล้องกับ Siemens, G. & Long, P. ที่ชี้ว่าการใช้ learning analytics เป็นกลไกสำคัญในการยกระดับคุณภาพการเรียนการสอน (Siemens, G. & Long, P., 2011)

การจำแนกผู้เรียนออกเป็นห้าประเภท ได้แก่ ผู้เข้าร่วมกิจกรรมเชิงรุก ผู้เรียนเชิงรับ ผู้มีส่วนร่วมไม่สม่ำเสมอ นักศึกษากลุ่มเสี่ยง และผู้เรียนแบบกำหนดทิศทางตนเอง สะท้อนแนวคิดทางทฤษฎีการเรียนรู้ที่หลากหลาย ไม่ว่าจะเป็นทฤษฎีการสร้างความรู้แบบสังคมของ Vygotsky, L. S. ในกลุ่มผู้เรียนเชิงรุก (Vygotsky, L. S., 1978) แนวคิด self-directed learning ของ Knowles, M. S., Zimmerman, B. J. ในกลุ่มผู้เรียนแบบกำหนดทิศทางตนเอง (Knowles, M. S., 1975); (Zimmerman, B. J., 2002) หรือทฤษฎีพฤติกรรมนิยมของ Skinner, B. F. ในกลุ่มผู้เรียนเชิงรับ (Skinner, B. F., 1953) ขณะเดียวกัน กลุ่มผู้เรียนไม่สม่ำเสมอและนักศึกษากลุ่มเสี่ยงสะท้อนปัญหา ด้านแรงจูงใจและ dropout prediction ที่ Kizilcec, R. F. et al, Hew, K. F. & Cheung, W. S. เคยรายงานไว้ การนำผลการจัดกลุ่มไปออกแบบการแทรกแซงเฉพาะบุคคลในโมเดล ICTOM พบว่า สามารถเพิ่มผลสัมฤทธิ์ทางการเรียน 27.4% และเพิ่มความพึงพอใจ 34.8% โดยเฉพาะในกลุ่มเสี่ยงที่พัฒนาการเด่นชัด (Kizilcec, R. F. et al., 2013); (Hew, K. F. & Cheung, W. S., 2014) สอดคล้องกับ Means, B. et al. ที่ชี้ว่าการสอนที่มีเป้าหมายชัดเจนช่วยยกระดับผลลัพธ์การเรียนรู้ นอกจากนี้ ความแม่นยำสูงของ Random Forest (85.3%) ยังต่อยอดศักยภาพของตัวชี้วัดเชิงพฤติกรรม เช่น การมีส่วนร่วมและปฏิสัมพันธ์ทางสังคม ในการทำนายผลสัมฤทธิ์ (Means, B. et al., 2014) ซึ่งสอดคล้องกับแนวคิด Ifenthaler, D. & Yau, J. Y. K. ที่เน้นการสนับสนุนผู้เรียนรายบุคคลอย่างต่อเนื่อง ในสภาพแวดล้อมการศึกษาออนไลน์ยุคดิจิทัล (Ifenthaler, D. & Yau, J. Y. K., 2020)

องค์ความรู้ใหม่



ภาพที่ 1 โมเดลการเพิ่มประสิทธิภาพการสอนด้วยการจัดกลุ่มอัจฉริยะ (ICTOM)

งานวิจัยนี้ได้พัฒนาโมเดลการเพิ่มประสิทธิภาพการสอนด้วยการจัดกลุ่มอัจฉริยะ (Intelligent Clustering-based Teaching Optimization Model: ICTOM) ซึ่งเป็นกรอบการทำงานที่ผสมผสานเทคนิคการขุดข้อมูลเชิงลึกกับการออกแบบแทรกแซงทางการสอนเฉพาะบุคคลอย่างเป็นระบบ โมเดลนี้ ประกอบด้วย สี่โมดูลหลักที่ทำงานเชื่อมโยงกันอย่างมีประสิทธิภาพ

โมดูลแรก คือ โมดูลการรวบรวมข้อมูล ซึ่งมุ่งเน้นการบูรณาการข้อมูลจากหลายมิติ อาทิ พฤติกรรมการเรียนรู้ รูปแบบการมีปฏิสัมพันธ์ทางสังคม ตัวชี้วัดผลสัมฤทธิ์ และลักษณะเชิงเวลา โดยใช้กระบวนการประมวลผล

แบบเรียลไทม์ เพื่อให้ได้ชุดข้อมูลที่สมบูรณ์และมีความสัมพันธ์สูงกับผลการเรียน

ต่อมา โมดูลการจัดกลุ่มที่ปรับปรุงแล้ว ใช้อัลกอริทึม K-means แบบถ่วงน้ำหนักความหนาแน่นและกลไกการปรับจุดศูนย์กลางแบบไดนามิก ทำให้สามารถจำแนกกลุ่มผู้เรียนได้อย่างแม่นยำและตอบสนองพฤติกรรมที่เปลี่ยนแปลงตามเวลา โมดูลนี้สามารถบรรลุคุณภาพการจัดกลุ่มสูงและมีความแม่นยำในการพยากรณ์ผลสัมฤทธิ์ของผู้เรียน

โมดูลที่สาม คือ โมดูลการออกแบบการแทรกแซงเฉพาะบุคคล ที่จับคู่ลักษณะของกลุ่มผู้เรียนกับทฤษฎีการเรียนรู้และพัฒนากลยุทธ์การสอนที่เหมาะสม พร้อมโปรโตคอลการแทรกแซงที่เป็นระบบ ทำให้สามารถส่งเสริมการเรียนรู้และความพึงพอใจของนักศึกษาได้อย่างมีนัยสำคัญ

สุดท้าย โมดูลการติดตามและปรับตัวแบบเรียลไทม์ มีหน้าที่ติดตามพฤติกรรมผู้เรียนและประสิทธิภาพของการแทรกแซงอย่างต่อเนื่อง พร้อมปรับเปลี่ยนกลยุทธ์แบบอัตโนมัติ โดยใช้ระบบแจ้งเตือนที่มีความแม่นยำสูง ช่วยลดภาระงานสนับสนุนและเพิ่มประสิทธิผลโดยรวมของระบบ

โครงสร้างของโมเดล ICTOM ดำเนินงานในลักษณะวงจรป้อนกลับ (Feedback Loop) เริ่มจากการรวบรวมและวิเคราะห์ข้อมูลผู้เรียน ต่อด้วยการจัดกลุ่มอัจฉริยะ การออกแบบและนำกลยุทธ์การสอนไปใช้เฉพาะบุคคล และติดตามปรับปรุงกลยุทธ์แบบเรียลไทม์อย่างต่อเนื่อง เพื่อให้กระบวนการสอนออนไลน์มีประสิทธิภาพสูงสุดและตอบสนองต่อความต้องการที่หลากหลายของผู้เรียน

โมเดลนี้ได้รับการทดสอบข้ามสถาบันอุดมศึกษาหลายแห่ง โดยสามารถนำไปใช้กับผู้เรียนจำนวนมากได้อย่างรวดเร็วและมีประสิทธิภาพ แสดงถึงความสามารถในการขยายผลในบริบทที่มีความแตกต่างทางวัฒนธรรมและเทคโนโลยี นอกจากนี้ กระบวนการประมวลผลของโมเดลยังมีความซับซ้อนเชิงเส้น ทำให้เหมาะสมกับการใช้งานในระบบการศึกษาขนาดใหญ่และแบบเรียลไทม์

สรุปและข้อเสนอแนะ

ผลการวิจัยยืนยันว่าอัลกอริทึม K-means ที่ได้รับการปรับปรุงสามารถจัดกลุ่มผู้เรียนออกเป็นห้าประเภทที่มีลักษณะและความต้องการเฉพาะได้อย่างมีประสิทธิภาพ การระบุรูปแบบเหล่านี้เอื้อต่อการออกแบบการแทรกแซงทางการสอนที่ตรงเป้าหมาย ส่งผลให้ผลสัมฤทธิ์ทางการเรียนโดยรวมและระดับความพึงพอใจของนักเรียนเพิ่มขึ้นอย่างมีนัยสำคัญ โดยเฉพาะนักศึกษาในกลุ่มเสี่ยงซึ่งได้รับประโยชน์สูงสุดจากการแทรกแซงที่เหมาะสม สถาบันการศึกษาจึงควรลงทุนพัฒนาโครงสร้างพื้นฐานด้านการวิเคราะห์ข้อมูลและเสริมสร้างสมรรถนะบุคลากรให้สามารถใช้ข้อมูลเชิงลึกเพื่อออกแบบการสอนเฉพาะบุคคลได้อย่างมีประสิทธิภาพ รวมทั้งกำหนดนโยบายที่คำนึงถึงจริยธรรมและการคุ้มครองความเป็นส่วนตัวของผู้เรียนสำหรับแพลตฟอร์มการเรียนรู้ออนไลน์ ควรรวมเทคโนโลยีการจัดกลุ่มขั้นสูงและระบบแทรกแซงอัตโนมัติเข้าไว้ในระบบเพื่อสนับสนุนผู้เรียนในทุกระดับ ขณะเดียวกันนักการศึกษาและผู้พัฒนาหลักสูตรสามารถนำผลการวิจัยไปประยุกต์ใช้ในการออกแบบกิจกรรมและเนื้อหาที่ตอบโจทย์ความหลากหลายของผู้เรียนในเชิงปฏิบัติได้อย่างแท้จริง ทั้งนี้ ควรสนับสนุนการวิจัยระยะยาว การศึกษาเชิงข้ามวัฒนธรรม และการประยุกต์ใช้เทคนิคใหม่ ๆ เช่น การเรียนรู้เชิงลึกและการจัดกลุ่มแบบปรับตัว เพื่อเพิ่มความแม่นยำและความยืดหยุ่นของระบบในอนาคต โดยสรุป การบูรณาการเทคโนโลยีอัตโนมัติเข้ากับการตัดสินใจของมนุษย์ถือเป็นกุญแจสำคัญในการยกระดับคุณภาพและการเข้าถึงการศึกษาในยุคดิจิทัลอย่างยั่งยืน

เอกสารอ้างอิง

- Baker, R. S. & Inventado, P. S. (2014). Educational data mining and learning analytics. New York: Springer.
- Garcia, M. et al. (2023). Adaptive learning systems: A systematic review of clustering-based approaches. *Educational Technology Research and Development*, 71(3), 445-468.
- Hew, K. F. & Cheung, W. S. (2014). Students' and instructors' use of massive open online courses (MOOCs): Motivations and challenges. *Educational Research Review*, 12, 45-58. <https://doi.org/10.1016/j.edurev.2014.05.001>.
- Ifenthaler, D. & Yau, J. Y. K. (2020). Utilising learning analytics for study success: Reflections on current empirical findings. *Research and Practice in Technology Enhanced Learning*, 15(1), 1-13.
- Khalil, M. et al. (2016). Clustering patterns of engagement in massive open online courses (MOOCs): The use of learning analytics to reveal student categories. *Journal of Computing in Higher Education*, 29(1), 114-132.
- Kizilcec, R. F. et al. (2013). Deconstructing disengagement: Analyzing learner subpopulations in massive open online courses. *Proceedings of the Third International Conference on Learning Analytics and Knowledge*, 170-179. <https://doi.org/10.1145/2460296.2460330>.
- Knowles, M. S. (1975). *Self-Directed Learning*. Chicago: Follett.
- Means, B. et al. (2014). The effectiveness of online and blended learning: A meta-analysis of the empirical literature. *Teachers College Record*, 115(3), 1-47.
- Roberts, P. et al. (2023). Real-time learning analytics for improving online teaching effectiveness. *Journal of Computer Assisted Learning*, 39(2), 234-251.
- Siemens, G. & Long, P. (2011). Penetrating the fog: Analytics in learning and education. *EDUCAUSE Review*, 46(5), 30-40.
- Skinner, B. F. (1953). *Science and human behavior*. New York: Macmillan.
- Vygotsky, L. S. (1978). *Mind in Society: The Development of Higher Psychological Processes*. Massachusetts: Harvard University Press.
- Zhang, H. et al. (2022). K-means clustering with density weighting for educational data analysis. *Data Mining and Knowledge Discovery*, 36(4), 1289-1315.
- Zhang, X. et al. (2023). Personalized learning path recommendation for e-learning based on knowledge graph and graph convolutional network. *International Journal of Software Engineering and Knowledge Engineering*, 33(1), 109-131.
- Zimmerman, B. J. (2002). Becoming a self-regulated learner: An overview. *Theory into Practice*, 41(2), 64-70.