

การวิเคราะห์ปัจจัยในกิจวัตรยามเช้าที่ส่งผลต่อประสิทธิภาพการทำงาน ด้วยเทคนิคเหมืองข้อมูล

ทวีศักดิ์ เพชรคนชม^{1*}, สุพจน์ เสงพะพรหม² และ ไกรรุ่ง เสงพะพรหม²

¹สาขาวิชาวิทยาการข้อมูล คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏนครปฐม

²สาขาวิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏนครปฐม

*taveesakpech@gmail.com

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษารูปแบบกิจวัตรยามเช้า วิเคราะห์ความสัมพันธ์ระหว่างพฤติกรรมยามเช้ากับประสิทธิภาพในการทำงาน และคัดเลือกปัจจัยที่มีอิทธิพลต่อประสิทธิภาพในการทำงาน โดยประยุกต์ใช้เทคนิคเหมืองข้อมูล ภายใต้กระบวนการ CRISP-DM ได้แก่ การจัดกลุ่มข้อมูลด้วย K-Means Clustering การค้นหาความสัมพันธ์ด้วยอัลกอริทึม Apriori และการวิเคราะห์ความสำคัญของตัวแปรด้วยแบบจำลอง Random Forest ร่วมกับเทคนิค Feature Importance และ Permutation Importance ข้อมูลที่ใช้ในการศึกษาเป็นชุดข้อมูลพฤติกรรมกิจวัตรยามเช้า (Morning Routine Productivity Dataset) ผลการวิเคราะห์พบว่าปัจจัยด้านสภาวะอารมณ์ ระยะเวลาการนอน และการออกกำลังกายเป็นปัจจัยสำคัญที่มีอิทธิพลต่อประสิทธิภาพในการทำงานอย่างมีนัยสำคัญ ผลการวิจัยนี้สามารถนำไปใช้เป็นแนวทางในการปรับปรุงกิจวัตรยามเช้า โดยเฉพาะด้านอารมณ์และการนอนหลับเพื่อเพิ่มประสิทธิภาพในการทำงานได้อย่างมีประสิทธิภาพ และสามารถประยุกต์ใช้ในการพัฒนาระบบแนะนำกิจวัตรประจำวันในอนาคต

คำสำคัญ: เหมืองข้อมูล กิจวัตรยามเช้า ประสิทธิภาพการทำงาน

Analysis of Morning Routine Factors Influencing Work Performance Using Data Mining Techniques

Taveesak Pechkonchom^{1*}, Supoj Hengprapohm² and Kairung Hengprapohm²

¹Program in Data Science, Faculty of Science and Technology, Nakhon Pathom Rajabhat University

²Program in Computer Science, Faculty of Science and Technology, Nakhon Pathom Rajabhat University

*taveesakpech@gmail.com

Abstract

This research aims to explore morning routine patterns, analyze the relationships between morning behaviors and work productivity, and identify the key factors influencing work productivity. The study applies data mining techniques under the CRISP-DM framework, which include K-Means Clustering for data grouping, the Apriori algorithm for association rule mining, and a Random Forest model combined with Feature Importance and Permutation Importance techniques for variable importance analysis. The data used in this study is the Morning Routine Productivity Dataset. The analysis reveals that emotional state, sleep duration, and physical exercise are significant factors influencing work productivity. These findings can serve as guidelines for improving morning routines—particularly regarding emotional well-being and adequate sleep—to effectively enhance work productivity. Furthermore, they can be applied to develop daily routine recommendation systems in the future.

Keywords: Data Mining, Morning Routine, Work Productivity

1. บทนำ

ในยุคปัจจุบันที่การทำงานมีการแข่งขันสูงและการบริหารเวลาเป็นปัจจัยสำคัญต่อความสำเร็จ “ประสิทธิภาพในการทำงาน” (Work Productivity) จึงกลายเป็นตัวชี้วัดที่สำคัญทั้งในระดับบุคคลและองค์กร [1] โดยเฉพาะในบริบทของการทำงานที่ต้องอาศัยความพร้อมทั้งด้านร่างกายและจิตใจ หนึ่งในปัจจัยที่ได้รับความสนใจอย่างแพร่หลายคือ “กิจวัตรยามเช้า” (Morning Routine) ซึ่งเป็นช่วงเวลาสำคัญที่ส่งผลต่อระดับพลังงาน สมาธิ และความพร้อมในการปฏิบัติงานตลอดทั้งวัน กิจกรรมต่าง ๆ เช่น ระยะเวลาการนอนหลับ เวลาตื่นนอน การออกกำลังกาย การทำสมาธิ และการรับประทานอาหารเช้า ล้วนมีบทบาทต่อสภาวะทางกายและจิตใจของบุคคล อย่างไรก็ตาม รูปแบบกิจวัตรยามเช้าของแต่ละบุคคลมีความหลากหลาย และซับซ้อน การระบุว่าปัจจัยหรือพฤติกรรมใดส่งผลต่อประสิทธิภาพในการทำงานอย่างแท้จริงยังคงเป็นความท้าทายเนื่องจากปัจจัยต่าง ๆ มีความสัมพันธ์กันในลักษณะหลายมิติ และไม่สามารถอธิบายได้ด้วยการวิเคราะห์เชิงสถิติพื้นฐานเพียงอย่างเดียว อีกทั้งคำแนะนำทั่วไปเกี่ยวกับสุขภาพอาจไม่สามารถตอบสนองความแตกต่างเฉพาะบุคคลได้อย่างมีประสิทธิภาพ

ด้วยความก้าวหน้าของวิทยาการข้อมูล (Data Science) และเทคนิคเหมืองข้อมูล (Data Mining) ทำให้สามารถนำข้อมูลพฤติกรรมมาวิเคราะห์เพื่อค้นหารูปแบบ ความสัมพันธ์ และปัจจัยที่มีอิทธิพลต่อผลลัพธ์ได้อย่างมีประสิทธิภาพ งานวิจัยนี้จึงประยุกต์ใช้กระบวนการมาตรฐานสากล CRISP-DM (Cross-Industry Standard Process for Data Mining) [2] ร่วมกับ

เทคนิคเหมืองข้อมูลที่หลากหลาย ได้แก่ การจัดกลุ่มข้อมูลด้วยเทคนิค K-Means Clustering เพื่อจำแนกรูปแบบพฤติกรรม [3], การค้นหาความสัมพันธ์ด้วยอัลกอริทึม Apriori เพื่อวิเคราะห์ความสัมพันธ์ของปัจจัยที่เกิดร่วมกันบ่อย [4], และการสร้างแบบจำลองการเรียนรู้ของเครื่องด้วยวิธี Random Forest [5] เพื่อวิเคราะห์ความสำคัญของตัวแปร (Feature Importance)

งานวิจัยนี้มีเป้าหมายเพื่อค้นหารูปแบบกิจวัตรยามเช้า วิเคราะห์ความสัมพันธ์ระหว่างพฤติกรรมกิจวัตรยามเช้ากับประสิทธิภาพในการทำงาน และระบุปัจจัยสำคัญที่มีอิทธิพลต่อประสิทธิภาพในการทำงานอย่างมีนัยสำคัญ โดยใช้ชุดข้อมูลกิจวัตรยามเช้า (Morning Routine Productivity Dataset) ภายใต้กระบวนการวิเคราะห์มาตรฐาน CRISP-DM ซึ่งผลการศึกษาสามารถนำไปประยุกต์ใช้ในการออกแบบแนวทางการปรับปรุงกิจวัตรประจำวันของบุคคล โดยเฉพาะด้านการจัดการอารมณ์และการนอนหลับ เพื่อเพิ่มศักยภาพและประสิทธิภาพในการทำงานได้อย่างเหมาะสม ตลอดจนสามารถนำไปต่อยอดพัฒนาเป็นระบบแนะนำกิจวัตรประจำวันอัจฉริยะ (Recommendation System) หรือเครื่องมือสนับสนุนการตัดสินใจด้านพฤติกรรมในอนาคต

2. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง


2.1 แนวคิดเกี่ยวกับประสิทธิภาพการทำงานและคุณภาพการนอนหลับ

ประสิทธิภาพการทำงาน (Work Productivity) เป็นตัวชี้วัดความสามารถในการสร้างผลผลิตหรือการบรรลุเป้าหมายในการทำงานภายใต้ระยะเวลาที่กำหนด ปัจจัยสำคัญที่เป็นรากฐานของประสิทธิภาพการทำงานไม่ได้จำกัดอยู่เพียงทักษะทางวิชาชีพ แต่อาศัยความพร้อมทางด้านสรีรวิทยาและจิตวิทยาของบุคคล ซึ่งมักถูกกำหนดโดย "กิจวัตรยามเช้า" และ "พฤติกรรมการนอนหลับ"

งานวิจัยทางการแพทย์และอาชีวเวชศาสตร์ได้พิสูจน์ให้เห็นถึงความเชื่อมโยงอย่างชัดเจน ดังที่ M. R. Rosekind และคณะ [1] ได้ศึกษาต้นทุนทางเศรษฐกิจที่เกิดจากการนอนหลับที่ไม่มีคุณภาพ (Poor sleep) โดยผลการวิจัยระบุว่า ผู้ที่มีปัญหาด้านการนอนหลับหรือมีชั่วโมงการนอนที่ไม่เพียงพอ จะสูญเสียความสามารถในการจดจ่อ (Concentration) และมีระดับพลังงานที่ลดลง นำไปสู่การสูญเสียประสิทธิภาพในการทำงาน (Productivity loss) อย่างมีนัยสำคัญ ซึ่งแนวคิดนี้สอดคล้องกับสมมติฐานหลักของงานวิจัยที่มุ่งเน้นการวิเคราะห์ระยะเวลาการนอนร่วมกับปัจจัยแวดล้อมอื่น ๆ ในยามเช้า

2.2 กระบวนการมาตรฐานสำหรับการทำเหมืองข้อมูล (CRISP-DM)

การทำเหมืองข้อมูล (Data Mining) เป็นกระบวนการดึงความรู้และค้นหารูปแบบที่ซ่อนอยู่ในชุดข้อมูลขนาดใหญ่ เพื่อให้การดำเนินงานวิจัยเป็นไปอย่างมีแบบแผนและได้มาตรฐานสากล ผู้วิจัยจึงยึดหลักการทำงานตามกระบวนการ CRISP-DM (Cross-Industry Standard Process for Data Mining) [2] กระบวนการนี้ได้รับการยอมรับอย่างกว้างขวางว่าเป็นพิมพ์เขียว (Blueprint) ที่มีประสิทธิภาพสูงสุดสำหรับโครงการวิทยาการข้อมูล โดยประกอบด้วย 6 ขั้นตอนหลัก ได้แก่ การทำความเข้าใจธุรกิจหรือปัญหา (Business Understanding) การทำความเข้าใจข้อมูล (Data Understanding) การเตรียมข้อมูล (Data Preparation) การสร้างแบบจำลอง (Modeling) การประเมินผล (Evaluation) และการนำไปใช้งานจริง (Deployment) ดังแสดงในภาพที่ 1



ภาพที่ 1 หลักการทำงานตามกระบวนการ CRISP-DM

ที่มา: Chapman et al. (2000, p. 10)

2.3 เทคนิคเหมืองข้อมูลและการเรียนรู้ของเครื่อง

เพื่อให้บรรลุวัตถุประสงค์ในการค้นหารูปแบบและความสัมพันธ์ของข้อมูลพฤติกรรม ผู้วิจัยได้ประยุกต์ใช้อัลกอริทึมหลัก 3 รูปแบบ ได้แก่

2.3.1 K-Means Clustering: เป็นเทคนิคการเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) ที่มุ่งเน้นการจัดกลุ่มข้อมูลที่มีลักษณะคล้ายคลึงกันให้อยู่ในกลุ่ม (Cluster) เดียวกัน ดังที่ C. Thayod et al. [3] ได้อธิบายหลักการทำงานของอัลกอริทึมนี้ว่า ระบบจะทำการหาค่าศูนย์กลาง (Centroid) ขึ้นมาจำนวน K จุด จากนั้นจะคำนวณระยะทางระหว่างจุดข้อมูลกับจุดศูนย์กลาง และจัดสรรข้อมูลเข้าสู่กลุ่มที่ใกล้ที่สุด พร้อมทั้งปรับตำแหน่งจุดศูนย์กลางใหม่จนกว่าจะไม่มีมีการเปลี่ยนแปลง ในงานวิจัยนี้ เทคนิค K-Means ถูกนำมาใช้เพื่อจำแนกกลุ่มบุคคลตามรูปแบบกิจกรรมเข้าและระดับประสิทธิภาพการทำงาน

2.3.2 อัลกอริทึม Apriori: เป็นกลไกสำคัญในการค้นหาความสัมพันธ์ (Association Rules) เพื่อหาว่าเหตุการณ์ใดมักเกิดขึ้นร่วมกัน Y. Liu [4] ได้อธิบายถึงการประยุกต์ใช้อัลกอริทึม Apriori ในงานเหมืองข้อมูลว่า อัลกอริทึมจะทำงานโดยการสแกนฐานข้อมูลเพื่อหา "ชุดรายการที่เกิดขึ้นร่วมกันบ่อย" (Frequent Itemsets) โดยอาศัยค่าสนับสนุนขั้นต่ำ (Minimum Support) จากนั้นจึงสร้างกฎความสัมพันธ์ที่มีความน่าเชื่อถือผ่านการวัดค่าความเชื่อมั่น (Confidence) และค่า Lift อัลกอริทึมนี้จึงเหมาะสมอย่างยิ่งในการดักจับความสัมพันธ์ เช่น "หากนอนหลับเพียงพอและอารมณ์ดี จะส่งผลให้ประสิทธิภาพการทำงานสูง"

2.3.3 อัลกอริทึมป่าสุ่ม (Random Forests): เป็นเทคนิคการเรียนรู้แบบกลุ่มก้อน (Ensemble Learning) ที่ทรงประสิทธิภาพ ดังที่ A. Cutler et al. [5] ได้อธิบายว่า Random Forest พัฒนาต่อยอดมาจากต้นไม้ตัดสินใจ (Decision Tree) โดยใช้เทคนิคการสุ่มตัวอย่างข้อมูล (Bagging) และการสุ่มเลือกตัวแปรคุณลักษณะ (Feature Selection) ในการสร้างต้นไม้จำนวนหลายร้อยต้นขึ้นมารวมกัน จากนั้นจึงใช้หลักการโหวตเสียงข้างมากเพื่อตัดสินผลลัพธ์ การทำงานในลักษณะนี้ช่วยแก้ปัญหาความเอนเอียง (Overfitting) และเพิ่มความแม่นยำในการทำนายได้อย่างมาก

2.4 งานวิจัยที่เกี่ยวข้อง

Ishibashi และ Shimura [6] ได้ศึกษาความสัมพันธ์ระหว่างสุขภาวะการนอนหลับกับประสิทธิภาพการทำงานของพนักงานในประเทศญี่ปุ่น โดยเป็นการวิจัยภาคตัดขวางจากกลุ่มตัวอย่าง 2,897 คน ในสำนักงาน 17 แห่ง กรุงโตเกียว ผลการศึกษาพบว่า ผู้ที่นอนหลับวันละ 5–6 ชั่วโมงมีการสูญเสียประสิทธิภาพจากภาวะมาทำงานแต่ทำงานได้ไม่เต็มประสิทธิภาพ (Presenteeism) สูงกว่าผู้ที่นอนหลับ 7–8 ชั่วโมงอย่างมีนัยสำคัญทางสถิติ ($\beta = 0.068$, $p = 0.004$) และความสูญเสียยิ่ง

เพิ่มขึ้นในผู้ที่นอนน้อยกว่า 5 ชั่วโมง ($\beta = 0.105, p < 0.001$) แสดงให้เห็นว่าระยะเวลาการนอนที่สั้นลงสัมพันธ์กับการลดลงของประสิทธิภาพการทำงานอย่างชัดเจน

Oswald, Proto และ Sgroi [7] ศึกษาความสัมพันธ์เชิงสาเหตุระหว่างความสุขกับประสิทธิภาพการทำงาน โดยดำเนินการทดลองหลายรูปแบบกับผู้เข้าร่วมทั้งหมด 713 คน ผู้วิจัยใช้สิ่งเร้าที่ช่วยเพิ่มความสุข เช่น คลิปวิดีโอตลก รวมถึงศึกษาผลกระทบจากเหตุการณ์เชิงลบในชีวิต ผลการทดลองพบว่า ผู้เข้าร่วมที่ได้รับสิ่งเร้าให้มีความสุขมีประสิทธิภาพในการทำงานสูงขึ้นประมาณร้อยละ 10–12 เมื่อเทียบกับกลุ่มควบคุม ขณะที่เหตุการณ์ที่ทำให้ความสุขลดลง เช่น การเจ็บป่วยหรือการสูญเสียบุคคลในครอบครัว มีความสัมพันธ์กับประสิทธิภาพที่ลดลง

3. วิธีดำเนินการวิจัย

การศึกษาวิจัยเรื่อง “การวิเคราะห์ปัจจัยในกิจวัตรยามเช้าที่ส่งผลต่อประสิทธิภาพการทำงานด้วยเทคนิคเหมืองข้อมูล” เป็นการศึกษาเชิงวิเคราะห์ข้อมูล (Data Analytics) โดยดำเนินการวิจัยภายใต้กรอบกระบวนการมาตรฐานสากลสำหรับการทำเหมืองข้อมูลที่เรียกว่า CRISP-DM (Cross-Industry Standard Process for Data Mining) ซึ่งมีรายละเอียดของเครื่องมือและขั้นตอนวิธีดำเนินการวิจัย ดังต่อไปนี้

3.1 เครื่องมือที่ใช้ในการวิจัย

เครื่องมือหลักที่ใช้ในการเขียนและประมวลผลชุดคำสั่งวิเคราะห์ข้อมูลคือ Google Colab ซึ่งเป็นแพลตฟอร์มสำหรับเขียนและประมวลผลโค้ดภาษา Python บนระบบคลาวด์ (Cloud) โดยมีข้อดีคือผู้ใช้ไม่จำเป็นต้องติดตั้งโปรแกรมเพิ่มเติมลงบนเครื่องคอมพิวเตอร์ส่วนบุคคล สามารถรองรับการประมวลผลชุดข้อมูลที่มีขนาดใหญ่ได้ และมีความสะดวกในการเชื่อมต่อเพื่ออ่านหรือบันทึกไฟล์ข้อมูลร่วมกับพื้นที่จัดเก็บข้อมูลบน Google Drive

3.2 ขั้นตอนการดำเนินการวิจัยตามกรอบ CRISP-DM

การดำเนินงานวิจัยนี้ยึดหลักการทำงาน 6 ขั้นตอนตามกรอบมาตรฐาน CRISP-DM โดยมีรายละเอียดการปฏิบัติงานในแต่ละขั้นตอน ดังนี้

3.2.1 การทำความเข้าใจธุรกิจและปัญหา (Business Understanding) เป็นขั้นตอนการทำความเข้าใจโจทย์ปัญหาและแปลงเป้าหมายดังกล่าวให้อยู่ในรูปแบบของการวิเคราะห์ข้อมูล พร้อมทั้งวางแผนการดำเนินงาน ในขั้นตอนนี้ ผู้วิจัยมุ่งเน้นการศึกษาความสัมพันธ์ระหว่าง “กิจวัตรยามเช้า” กับ “ประสิทธิภาพในการทำงาน” โดยมีวัตถุประสงค์หลัก 3 ประการ ได้แก่ การค้นหารูปแบบพฤติกรรมของบุคคล, การวิเคราะห์ความสัมพันธ์ของพฤติกรรม และการระบุปัจจัยสำคัญที่มีอิทธิพลต่อประสิทธิภาพในการทำงาน

3.2.2 การทำความเข้าใจข้อมูล (Data Understanding) เป็นขั้นตอนที่เริ่มต้นจากการรวบรวมข้อมูลและตรวจสอบความถูกต้องของข้อมูล โดยผู้วิจัยได้ทำการรวบรวมชุดข้อมูลชุดหนึ่ง ชื่อ Morning Routine Productivity Dataset จากเว็บไซต์ www.kaggle.com ซึ่งมีจำนวนข้อมูลทั้งสิ้น 900 รายการ โดยประกอบด้วยตัวแปรคุณลักษณะ (Attributes/Columns) ที่เกี่ยวข้องกับพฤติกรรมยามเช้าจำนวน 11 ตัวแปร ดังแสดงรายละเอียดในตารางที่ 1



ตารางที่ 1 รายละเอียดและคำอธิบายตัวแปรในชุดข้อมูล Morning Routine Productivity Dataset

คอลัมน์	คำอธิบาย
Date	วันที่บันทึก
Wake-up Time	เวลาที่ผู้ใช้ตื่นนอน
Sleep Duration (hrs)	ระยะเวลาการนอนหลับทั้งหมด (ชั่วโมง)
Meditation (mins)	ระยะเวลาการทำสมาธิ (นาที)
Exercise (mins)	ระยะเวลาการออกกำลังกาย (นาที)
Breakfast Type	ประเภทของอาหารเช้าที่รับประทาน (เบา, หนัก, ไม่ทาน, โปรตีนสูง, คาร์โบไฮเดรตสูง)
Journaling (Y/N)	มีการบันทึกไดอารี่หรือไม่
Work Start Time	เวลาเริ่มทำงาน/เรียน
Productivity Score (1-10)	ระดับประสิทธิภาพการทำงาน (1-10)
Mood	อารมณ์โดยรวม (มีความสุข, เฉยๆ, เศร้า)
Notes	ข้อความที่บันทึก

3.2.3 การเตรียมข้อมูล (Data Preparation) เป็นกระบวนการทำความสะอาดข้อมูล (Data Cleaning) และแปลงข้อมูลดิบให้เป็นข้อมูลที่พร้อมสำหรับการวิเคราะห์และป้อนเข้าสู่แบบจำลอง โดยมีขั้นตอนการดำเนินการ ดังนี้

- การคัดเลือกและลบข้อมูล: ทำการลบข้อมูลคอลัมน์ที่ไม่เกี่ยวข้องกับการคำนวณออก ได้แก่ คอลัมน์ Date และ Notes

- การจัดรูปแบบและการแปลงข้อมูลเชิงคุณภาพ: ทำการแปลงข้อมูลเชิงคุณภาพ (Qualitative) ให้เป็นข้อมูลเชิงตัวเลข (Quantitative) ด้วยวิธี One-Hot Encoding เพื่อแปลงตัวแปรประเภทอาหารเช้า (Breakfast Type), การบันทึกไดอารี่ (Journaling) และสภาวะอารมณ์ (Mood) ให้อยู่ในรูปของเลขไบนารี 0 และ 1 รวมถึงแปลงหน่วยเวลาดีนอนและเวลาเริ่มงานให้อยู่ในรูปของ "นาที" (wake_up_min, work_start_min)

- การปรับมาตรฐานข้อมูล: ดำเนินการปรับมาตรฐานข้อมูล (Feature Scaling) เพื่อให้ตัวแปรทุกตัวมีความสมดุลกันและอยู่ในช่วงสเกลที่เหมาะสมต่อการคำนวณในอัลกอริทึม

- การจัดโครงสร้างข้อมูล: ทำการจัดเตรียมข้อมูลให้อยู่ในรูปแบบตารางเมทริกซ์ที่พร้อมสำหรับการสร้างแบบจำลองในขั้นตอนถัดไป

3.2.4 การสร้างแบบจำลอง (Modeling) ผู้วิจัยได้เลือกใช้เทคนิคเหมืองข้อมูลให้สอดคล้องกับวัตถุประสงค์ของการวิเคราะห์ เพื่อให้สามารถศึกษาข้อมูลได้ในหลายมิติ โดยแบ่งการสร้างแบบจำลองออกเป็น 3 ประเภท ดังนี้

- การจัดกลุ่มข้อมูล (Clustering): ใช้เทคนิคการจัดกลุ่มข้อมูลด้วยอัลกอริทึม K-Means Clustering เพื่อจำแนกรูปแบบกิจวัตรยามเช้าของบุคคล โดยอาศัยวิธี Elbow Method ในการพิจารณาหาจำนวนกลุ่ม (K) ที่เหมาะสมที่สุด ซึ่งการจัดกลุ่มนี้ช่วยให้สามารถเข้าใจลักษณะพฤติกรรมของบุคคลในแต่ละกลุ่ม และเปรียบเทียบระดับประสิทธิภาพในการทำงานระหว่างกลุ่มได้อย่างชัดเจน

- การค้นหากฎความสัมพันธ์ (Association Rules): ใช้เทคนิคการค้นหากฎความสัมพันธ์ด้วยอัลกอริทึม Apriori เพื่อค้นหาความสัมพันธ์ระหว่างตัวแปรพฤติกรรมกิจวัตรยามเช้า (เช่น การนอนหลับ อารมณ์ และการออกกำลังกาย) กับระดับประสิทธิภาพในการทำงาน โดยพิจารณาจากค่าความเชื่อมั่น (Confidence) และค่า Lift เพื่อประเมินความน่าเชื่อถือของกฎความสัมพันธ์ที่ค้นพบ

- การวิเคราะห์ปัจจัยสำคัญ (Feature Importance): ใช้แบบจำลอง Random Forest ในการวิเคราะห์ปัจจัยที่มีอิทธิพลต่อประสิทธิภาพในการทำงาน โดยกำหนดตัวแปรเป้าหมาย (Target) คือ "ระดับประสิทธิภาพในการทำงาน"

(Productivity Level) ในลักษณะการจำแนกประเภทข้อมูล (Classification) ทำการแบ่งชุดข้อมูลออกเป็น ชุดข้อมูลสำหรับฝึกสอน (Training Set) ร้อยละ 80 และชุดข้อมูลสำหรับทดสอบ (Testing Set) ร้อยละ 20 (อัตราส่วน 80:20) ซึ่งช่วยให้สามารถระบุปัจจัยที่มีอิทธิพลต่อประสิทธิภาพในการทำงานได้อย่างมีความน่าเชื่อถือ

หมายเหตุ: ในขั้นตอนนี้อาจพบว่าข้อมูลไม่พร้อมจำนวน จะทำการย้อนกลับไปขั้นตอนการเตรียมข้อมูลเพื่อปรับเปลี่ยนข้อมูลให้เหมาะสมกับแต่ละเทคนิคอีกครั้ง

3.2.5 การวัดประสิทธิภาพของโมเดล (Evaluation) เป็นขั้นตอนการตรวจสอบผลการวิเคราะห์ข้อมูลเพื่อให้แน่ใจว่าตรงตามวัตถุประสงค์ที่ตั้งไว้ในขั้นตอนแรก และประเมินความน่าเชื่อถือของผลลัพธ์ โดยแบ่งการประเมินตามกลุ่มเทคนิคดังนี้

- เทคนิค Apriori: วิเคราะห์ความแข็งแกร่งของกฎความสัมพันธ์ผ่านเกณฑ์ ค่าความเชื่อมั่น (Confidence) และ ค่า Lift
- แบบจำลอง Random Forest: ประเมินประสิทธิภาพในการจำแนกประเภทข้อมูลของโมเดลโดยใช้มาตรวัด ค่าความถูกต้อง (Accuracy) และ ค่า F1-score
- การยืนยันปัจจัย: ทำการวิเคราะห์เปรียบเทียบผลลัพธ์ค่าน้ำหนักความสำคัญของตัวแปรที่สกัดได้จากเทคนิค Feature Importance และเทคนิค Permutation Importance เพื่อยืนยันปัจจัยสำคัญที่ส่งผลต่อประสิทธิภาพการทำงานอย่างแท้จริง


3.2.6 การนำโมเดลไปใช้งานจริง (Deployment) เป็นขั้นตอนการนำความรู้ที่ได้จากการวิเคราะห์ไปใช้ในทางปฏิบัติ โดยผลการวิจัยนี้สามารถนำไปประยุกต์ใช้ในการออกแบบแนวทางการปรับปรุงกิจกรรมเข้าเพื่อเพิ่มประสิทธิภาพในการทำงานของบุคคล ตลอดจนสามารถนำไปต่อยอดพัฒนาเป็นระบบแนะนำกิจกรรมประจำวันอัจฉริยะ (Recommendation System) หรือเครื่องมือสนับสนุนการตัดสินใจด้านพฤติกรรมได้ในอนาคต

4. ผลการดำเนินงานและวิเคราะห์ข้อมูล

การวิเคราะห์ปัจจัยในกิจกรรมเข้าที่ส่งผลต่อประสิทธิภาพการทำงานด้วยเทคนิคเหมืองข้อมูล ผู้วิจัยได้ดำเนินการรันผลการทดลองและวิเคราะห์ข้อมูลผ่านโปรแกรม Google Colab โดยจำแนกผลการดำเนินงานออกเป็น 3 ส่วนหลัก ตามเกณฑ์มาตรฐานของการประเมินประสิทธิภาพในกระบวนการ CRISP-DM ได้แก่ ผลการจัดกลุ่มพฤติกรรม (Clustering) ผลการวิเคราะห์กฎความสัมพันธ์ (Association Rules) และผลการวิเคราะห์น้ำหนักความสำคัญของตัวแปร (Variable Importance)

4.1 ผลการจัดกลุ่มพฤติกรรมด้วยเทคนิค K-Means Clustering

ในการวิเคราะห์รูปแบบกิจกรรมเข้าของกลุ่มตัวอย่าง ผู้วิจัยได้ประยุกต์ใช้เทคนิค K-Means Clustering โดยเริ่มต้นจากการพิจารณาหาจำนวนกลุ่ม (K) ที่เหมาะสมที่สุดผ่านวิธี Elbow Method (ดังปรากฏในภาพที่ 2) พบว่า การจัดกลุ่มที่จำนวน K = 3 ให้ค่าความเหมาะสมเชิงสถิติสูงสุด ผู้วิจัยจึงทำการจำแนกกลุ่มข้อมูลออกเป็น 3 กลุ่มพฤติกรรม ผลการจัดกลุ่มแสดงดังตารางที่ 2



ภาพที่ 2 กราฟแสดงการหาค่า K ที่เหมาะสมด้วยวิธี Elbow Method

ตารางที่ 2 ผลการจัดกลุ่มข้อมูล

ตัวแปร	Cluster 0 (Moderate)	Cluster 1 (High Performance)	Cluster 2 (Low Performance)
เวลาดู (นาทีก)	406.60	411.37	414.52
ชั่วโมงการนอน	7.05	8.12	5.79
สมาธิ (นาทีก)	14.98	14.95	14.24
ออกกำลังกาย (นาทีก)	30.00	31.66	27.59
อาหารเช้า (Carb-rich)	0.20	0.23	0.20
อาหารเช้า (Heavy)	0.26	0.21	0.19
อาหารเช้า (Light)	0.20	0.20	0.18
อาหารเช้า (Protein-rich)	0.19	0.17	0.21
ไม่กินอาหารเช้า	0.15	0.19	0.22
Journaling	0.48	0.46	0.53
เวลาเริ่มงาน (นาทีก)	526.38	528.69	534.33
อารมณ์ Happy	0.00	1.00	0.00
อารมณ์ Neutral	1.00	0.00	0.00
อารมณ์ Sad	0.00	0.00	1.00
Productivity Score	5.75	8.12	3.56

เมื่อทำการวิเคราะห์คุณลักษณะเด่นของแต่ละกลุ่มข้อมูล สามารถสรุปพฤติกรรมเด่น ดังรายละเอียดในตารางที่ 3



ตารางที่ 3 ผลการวิเคราะห์และสรุปคุณลักษณะของกลุ่มข้อมูลพฤติกรรมยามเช้าทั้ง 3 กลุ่ม เรียงตามระดับประสิทธิภาพ (Productivity)

กลุ่มที่ (Cluster)	รูปแบบพฤติกรรมและกิจวัตรยามเช้าเด่นที่พบในกลุ่ม	ระดับประสิทธิภาพ (Productivity)
กลุ่มที่ 1 (Cluster 1)	เป็นกลุ่มที่มีระยะเวลาการนอนหลับเฉลี่ยอยู่ในเกณฑ์ดี สภาวะอารมณ์ยามเช้าเป็นเชิงบวก (Happy) มักมีกิจกรรมออกกำลังกายหรือทำสมาธิอย่างสม่ำเสมอ	ระดับสูง (High)
กลุ่มที่ 2 (Cluster 0)	เป็นกลุ่มที่มีพฤติกรรมในเกณฑ์ปานกลาง มีการทำกิจกรรมยามเช้าบ้างบางวัน สภาวะอารมณ์มีความผันแปรตามสถานการณ์	ระดับปานกลาง (Medium)
กลุ่มที่ 3 (Cluster 2)	เป็นกลุ่มที่มีระยะเวลาการนอนหลับค่อนข้างน้อย สภาวะอารมณ์ยามเช้ามักเป็นเชิงลบ (Sad) มักละเลยการรับประทานอาหารเช้าหรือไม่มีการออกกำลังกาย	ระดับต่ำ (Low)

4.2 ผลการค้นหากฎความสัมพันธ์ด้วยอัลกอริทึม Apriori

จากการวิเคราะห์ชุดรายการที่เกิดขึ้นร่วมกันบ่อย (Frequent Itemsets) ด้วยเทคนิค Apriori พบว่าพฤติกรรมในกิจวัตรยามเช้าที่มีค่าสนับสนุน (Support) ปรากฏในฐานข้อมูลสูงสุด ได้แก่ การออกกำลังกายสูง (exercise_high) มีค่าสนับสนุนอยู่ที่ 0.556667 รองลงมาคือกลุ่มประสิทธิภาพการทำงานสูง (productivity_high) อยู่ที่ 0.541111 และการนอนหลับเพียงพอ (sleep_high) อยู่ที่ 0.514444 นอกจากนี้ยังพบกลุ่มตัวแปรด้านสภาวะอารมณ์ ได้แก่ อารมณ์เชิงลบ (sad) มีค่าสนับสนุนอยู่ที่ 0.350000 และอารมณ์เชิงบวก (happy) มีค่าสนับสนุนอยู่ที่ 0.347778 รายละเอียดแสดงดังตารางที่ 4

เมื่อผู้วิจัยได้กำหนดเกณฑ์ขั้นต่ำเพื่อสกัดหากฎความสัมพันธ์ที่แข็งแกร่ง (Strong Rules) สามารถจำแนกผลการวิเคราะห์ออกเป็น 2 กลุ่มหลัก ดังนี้

4.2.1 กฎความสัมพันธ์สำหรับกลุ่มที่มีประสิทธิภาพการทำงานสูง (High Performance)

ผลการวิเคราะห์กฎความสัมพันธ์ที่ส่งผลต่อประสิทธิภาพการทำงานในระดับสูง แสดงรายละเอียดค่าสนับสนุน (Support), ค่าความเชื่อมั่น (Confidence), และค่า Lift ได้ดังตารางที่ 5 ซึ่งสามารถอธิบายได้ว่า



ตารางที่ 4 ผลการวิเคราะห์กฎความสัมพันธ์ (Association Rules)

ลำดับ	Index	Support	Itemsets
1	2	0.556667	exercise_high
2	7	0.541111	productivity_high
3	0	0.514444	sleep_high
4	4	0.488889	journaling
5	1	0.485556	sleep_low
6	8	0.458889	productivity_low
7	3	0.443333	exercise_low
8	13	0.430000	productivity_high, sleep_high
9	18	0.374444	productivity_low, sleep_low
10	6	0.350000	sad
11	5	0.347778	happy
12	12	0.347778	sleep_high, happy
13	32	0.347778	productivity_high, sleep_high, happy
14	28	0.347778	productivity_high, happy
15	21	0.337778	productivity_high, exercise_high
16	29	0.332222	sad, productivity_low
17	17	0.330000	sad, sleep_low
18	35	0.312222	sad, productivity_low, sleep_low
19	14	0.282222	exercise_high, sleep_low
20	9	0.274444	sleep_high, exercise_high
21	31	0.255556	productivity_high, sleep_high, exercise_high
22	16	0.247778	journaling, sleep_low
23	19	0.245556	journaling, exercise_high
24	26	0.244444	productivity_high, journaling
25	27	0.244444	journaling, productivity_low
26	23	0.243333	exercise_low, journaling
27	11	0.241111	journaling, sleep_high
28	25	0.240000	exercise_low, productivity_low
29	10	0.240000	exercise_low, sleep_high
30	22	0.218889	productivity_low, exercise_high



ตารางที่ 5 ผลการวิเคราะห์กฎความสัมพันธ์กลุ่มประสิทธิภาพการทำงานสูง

ลำดับ	Antecedents (เงื่อนไข)	Consequents (ผลลัพธ์)	Support	Confidence	Lift
1	happy	productivity_high + sleep_high	0.347778	1	2.33
2	happy + exercise_high	productivity_high + sleep_high	0.214444	1	2.33
3	exercise_high + sleep_high	happy + productivity_high	0.214444	0.78	2.25
4	happy + exercise_high + sleep_high	productivity_high	0.214444	1	1.85
5	happy	productivity_high	0.347778	1	1.85
6	happy + exercise_high	productivity_high	0.214444	1	1.85
7	happy + sleep_high	productivity_high	0.347778	1	1.85
8	exercise_high + sleep_high	productivity_high	0.255556	0.93	1.72
9	sleep_high	productivity_high	0.43	0.84	1.54

- อิทธิพลของอารมณ์เชิงบวก: ตัวแปรสภาวะอารมณ์มีความสุข (happy) มีความสัมพันธ์เชิงบวกอย่างแข็งแกร่งต่อการบรรลุประสิทธิภาพการทำงานสูงรวมกับการนอนหลับเพียงพอ (productivity_high + sleep_high) โดยให้ค่า Confidence เต็ม 1.00 และมีค่า Lift สูงถึง 2.33

- ความแน่นอนในการบรรลุเป้าหมาย: เมื่อพิจารณาเฉพาะการเกิดผลลัพธ์ประสิทธิภาพการทำงานสูง (productivity_high) พบว่าทั้งเงื่อนไขอารมณ์มีความสุข (happy), การมีอารมณ์มีความสุขรวมกับการออกกำลังกาย (happy + exercise_high), และการมีอารมณ์มีความสุขรวมกับการนอนหลับเพียงพอ (happy + sleep_high) ต่างให้ค่า Confidence เท่ากับ 1.00 และค่า Lift เท่ากับ 1.85 ในทุกกรณี

- ความสำคัญของการพักผ่อน: การนอนหลับที่เพียงพอเพียงอย่างเดียว (sleep_high) ก็สามารถส่งผลให้เกิดประสิทธิภาพการทำงานสูงได้ โดยให้ค่า Confidence เท่ากับ 0.84 และค่า Lift เท่ากับ 1.54 ซึ่งสะท้อนให้เห็นว่าเป็นปัจจัยพื้นฐานที่สำคัญต่อความพร้อมในการปฏิบัติงาน

4.2.2 กฎความสัมพันธ์สำหรับกลุ่มที่มีประสิทธิภาพการทำงานต่ำ (Low Performance)

สำหรับกลุ่มที่มีประสิทธิภาพในการทำงานต่ำ ผลการค้นหากฎความสัมพันธ์ที่แข็งแกร่งแสดงรายละเอียดดังตารางที่ 6

ตารางที่ 6 ผลการวิเคราะห์กฎความสัมพันธ์กลุ่มประสิทธิภาพการทำงานต่ำ

ลำดับ	Antecedents (เงื่อนไข)	Consequents (ผลลัพธ์)	Support	Confidence	Lift
1	sad	productivity_low + sleep_low	0.312222	0.89	2.38
2	sad	productivity_low	0.332222	0.95	2.07
3	sad + sleep_low	productivity_low	0.312222	0.95	2.06
4	sleep_low	sad + productivity_low	0.312222	0.64	1.94
5	journaling + sleep_low	productivity_low	0.201111	0.81	1.77
6	sleep_low	productivity_low	0.374444	0.77	1.68
7	exercise_high + sleep_low	productivity_low	0.2	0.71	1.54

จากตารางที่ 6 สามารถอธิบายได้ว่า

- อิทธิพลของอารมณ์เชิงลบ: สภาวะอารมณ์เศร้า (sad) มีความสัมพันธ์โดยตรงกับประสิทธิภาพการทำงานต่ำ (productivity_low) โดยมีค่า Confidence สูงถึง 0.95 และค่า Lift เท่ากับ 2.07. นอกจากนี้ยังพบว่าอารมณ์เศ้ามักเกิดร่วมกับภาวะการนอนไม่พอ (productivity_low + sleep_low) ด้วยค่า Confidence เท่ากับ 0.89 และค่า Lift สูงถึง 2.38
- ผลกระทบจากการนอนไม่เพียงพอ: การนอนหลับไม่เพียงพอ (sleep_low) มีความสัมพันธ์กับการลดลงของประสิทธิภาพการทำงาน (productivity_low) โดยมีค่า Confidence เท่ากับ 0.77. และเมื่อเกิดร่วมกับอารมณ์เชิงลบ (sad + sleep_low) จะยิ่งเพิ่มความสัมพันธ์ดังกล่าวให้เด่นชัดขึ้นด้วยค่า Confidence เท่ากับ 0.95
- พฤติกรรมกลบเกลื่อนที่ไม่เป็นผล: ผลการวิเคราะห์ชี้ให้เห็นว่า แม้บุคคลจะพยายามเขียนบันทึกไดอารี่หรือออกกำลังกายสูง แต่หากได้รับการพักผ่อนไม่เพียงพอ (journaling + sleep_low หรือ exercise_high + sleep_low) ก็มีแนวโน้มที่จะมีประสิทธิภาพการทำงานต่ำเช่นกัน โดยให้ค่า Confidence เท่ากับ 0.81 และ 0.71 ตามลำดับ

4.3 ผลการวิเคราะห์ปัจจัยสำคัญที่มีอิทธิพลต่อประสิทธิภาพการทำงานด้วยแบบจำลอง Random Forest

ในการวิเคราะห์และคัดเลือกปัจจัยในกิจกรรมเข้าที่มีอิทธิพลต่อระดับประสิทธิภาพในการทำงาน ผู้วิจัยได้พัฒนาแบบจำลองการเรียนรู้ของเครื่องด้วยอัลกอริทึม Random Forest โดยแบ่งชุดข้อมูลออกเป็นข้อมูลสำหรับฝึกสอนร้อยละ 80 และข้อมูลสำหรับทดสอบร้อยละ 20 (อัตราส่วน 80:20) ซึ่งผลการดำเนินงานสามารถแบ่งออกเป็น 4 ส่วนสำคัญ ดังนี้

4.3.1 ผลการประเมินประสิทธิภาพของแบบจำลอง (Model Evaluation)

ก่อนทำการสกัดค่าน้ำหนักความสำคัญของตัวแปร ผู้วิจัยได้ทำการทดสอบประสิทธิภาพในการทำนายของแบบจำลองบนชุดข้อมูลทดสอบ โดยผลลัพธ์จากรายงานการจำแนกประเภท (Classification Report) ปรากฏรายละเอียดดังนี้

- ภาพรวมของแบบจำลอง: แบบจำลองให้ค่าความถูกต้อง (Accuracy) รวมอยู่ที่ 0.84 (หรือร้อยละ 84.00) โดยมีค่าเฉลี่ยมาโคร (Macro Average) และค่าเฉลี่ยถ่วงน้ำหนัก (Weighted Average) ของทั้ง Precision, Recall และ F1-score อยู่ที่ 0.84 เท่ากันทั้งหมด แสดงดังตารางที่ 7

ตารางที่ 7 ผลการประเมินโมเดล Random Forest

กลุ่มข้อมูล	Precision	Recall	F1-score	Support
Class 0	0.87	0.78	0.82	87
Class 1	0.81	0.89	0.85	93
Accuracy	—	—	0.84	180
Macro Average	0.84	0.84	0.84	180
Weighted Average	0.84	0.84	0.84	180


- ประสิทธิภาพจำแนกตามกลุ่มเป้าหมาย:

1. คลาส 0 (กลุ่มประสิทธิภาพไม่สูง): มีค่าความแม่นยำ (Precision) อยู่ที่ 0.87, ค่าความครบถ้วน (Recall) อยู่ที่ 0.78 และค่า F1-score อยู่ที่ 0.82 จากจำนวนตัวอย่างจริง 87 รายการ
2. คลาส 1 (กลุ่มประสิทธิภาพสูง): มีค่าความแม่นยำ (Precision) อยู่ที่ 0.81, ค่าความครบถ้วน (Recall) อยู่ที่ 0.89 และค่า F1-score อยู่ที่ 0.85 จากจำนวนตัวอย่างจริง 93 รายการ

จากค่าคะแนนที่สมดุลระหว่าง Precision และ Recall ในทั้งสองคลาส บ่งชี้ว่าแบบจำลองมีความสามารถในการจำแนกประเภทข้อมูลที่เสถียร ไม่เกิดภาวะเอนเอียง (Bias) ไปทางกลุ่มใดกลุ่มหนึ่ง และมีความแม่นยำสูงเพียงพอที่จะนำไปใช้สัปดาห์ค่าน้ำหนักความสำคัญของตัวแปรในขั้นตอนต่อไปได้อย่างน่าเชื่อถือ

4.3.2 ผลการวิเคราะห์ความสำคัญของตัวแปรด้วยเทคนิค Feature Importance

ผู้วิจัยได้ทำการคำนวณค่าน้ำหนักความสำคัญของตัวแปร (Feature Importance) จากมาตรวัดการลดลงของค่าความไม่บริสุทธิ์ของข้อมูล (Gini Impurity reduction) โดยสามารถเรียงลำดับอิทธิพลของตัวแปรจากมากไปน้อย แสดงดังภาพที่ 3



ภาพที่ 3 กราฟแสดงลำดับความสำคัญของตัวแปร

จากภาพที่ 3 ผลลัพธ์ชี้ให้เห็นอย่างเด่นชัดว่า เพียงแค่ 3 ปัจจัยแรก ได้แก่ ชั่วโมงการนอนหลับ, อารมณ์เศร้า และ อารมณ์มีความสุข ก็มีสัดส่วนอิทธิพลในการตัดสินใจร่วมกันสูงถึงร้อยละ 70.98 ของโมเดลทั้งหมด ในขณะที่ปัจจัยอื่น ๆ แทบไม่มีนัยสำคัญต่อการแยกแยะประสิทธิภาพการทำงานเลย

5. สรุปผลการวิจัยและข้อเสนอแนะ

การศึกษาวิจัยเรื่อง “การวิเคราะห์ปัจจัยในกิจวัตรยามเช้าที่ส่งผลต่อประสิทธิภาพการทำงานด้วยเทคนิคเหมืองข้อมูล” มีวัตถุประสงค์เพื่อศึกษารูปแบบของกิจวัตรยามเช้า วิเคราะห์ความสัมพันธ์ระหว่างพฤติกรรมในยามเช้ากับประสิทธิภาพในการทำงาน และคัดเลือกปัจจัยสำคัญที่มีอิทธิพลต่อประสิทธิภาพในการทำงาน โดยใช้ชุดข้อมูลพฤติกรรมกิจวัตรยามเช้า (Morning Routine Productivity Dataset) จำนวน 900 รายการ ดำเนินการวิเคราะห์ภายใต้กระบวนการมาตรฐาน CRISP-DM ด้วยเทคนิค K-Means Clustering, อัลกอริทึม Apriori และแบบจำลอง Random Forest ร่วมกับเทคนิค Feature Importance ซึ่งสามารถสรุปผลและนำเสนอข้อเสนอแนะได้ดังต่อไปนี้

5.1 สรุปผลการวิจัย

จากการประมวลผลและวิเคราะห์ชุดข้อมูลพฤติกรรมยามเช้าของกลุ่มตัวอย่าง สามารถสรุปผลการวิจัยตามวัตถุประสงค์ทั้ง 3 ข้อได้ดังนี้

5.1.1 ผลการศึกษารูปแบบกิจวัตรยามเช้า (Clustering): จากการจัดกลุ่มข้อมูลด้วยเทคนิค K-Means Clustering ที่จำนวนกลุ่ม $K = 3$ สามารถจำแนกพฤติกรรมของบุคคลออกเป็น 3 กลุ่มอย่างเด่นชัด ได้แก่ กลุ่มที่ 1 (กลุ่มประสิทธิภาพสูง) มีลักษณะเด่นคือนอนหลับเพียงพอเฉลี่ย 7-8 ชั่วโมง มีสภาวะอารมณ์เชิงบวก และออกกำลังกายสม่ำเสมอ, กลุ่มที่ 2 (กลุ่มระดับปานกลาง) มีพฤติกรรมก้ำกึ่งและผันแปรตามสถานการณ์, และ กลุ่มที่ 3 (กลุ่มประสิทธิภาพต่ำ) มีลักษณะเด่นคือนอนหลับน้อยกว่า 6 ชั่วโมง มีสภาวะอารมณ์เชิงลบ และมักละเลยอาหารเช้า

5.1.2 ผลการวิเคราะห์กฎความสัมพันธ์ (Association Rules): จากการค้นหากฎความสัมพันธ์ด้วยอัลกอริทึม Apriori พบว่า "สภาวะอารมณ์" และ "ระยะเวลาการนอนหลับ" มีความสัมพันธ์กับประสิทธิภาพการทำงานอย่างมาก โดยบุคคลที่มีอารมณ์แจ่มใส (Happy) ร่วมกับได้นอนตั้งแต่ 7 ชั่วโมงขึ้นไป จะบรรลุประสิทธิภาพการทำงานสูงในทุกกรณี (Confidence = 1.00, Lift = 2.33) ในขณะที่บุคคลที่มีอารมณ์เศร้าหมอง (Sad) จะมีโอกาสทำงานได้ประสิทธิภาพต่ำสูงถึงร้อยละ 95 (Confidence = 0.95) และที่สำคัญคือ หากร่างกายพักผ่อนไม่เพียงพอ (Sleep_low) ต่อให้พยายามเขียนไดอารี่หรือออกกำลังกาย ก็ยังคงมีแนวโน้มที่จะทำงานได้ประสิทธิภาพที่ต่ำ (Confidence = 0.71 – 0.81)

5.1.3 ผลการคัดเลือกปัจจัยที่มีอิทธิพลสูงสุด (Variable Importance): จากแบบจำลอง Random Forest (ความถูกต้องร้อยละ 84) ผลการตรวจสอบยืนยันด้วยเทคนิค Feature Importance ชี้ให้เห็นว่า sleep_hours (ระยะเวลาการนอนหลับ) และ mood (สภาวะอารมณ์) คือสองปัจจัยชี้ขาด (Absolute Dominant Factors) ที่ส่งผลต่อประสิทธิภาพการทำงานมากที่สุด โดยมีกิจกรรมการออกกำลังกาย (exercise_min) และการทำสมาธิ (meditation_min) เป็นปัจจัยสนับสนุนในระดับรองลงมา ส่วนการเขียนบันทึกประจำวัน (journaling) และการเลือกประเภทของอาหารเช้า (Breakfast Type) มีอิทธิพลต่อแบบจำลองน้อยมากจนไม่มีนัยสำคัญทางสถิติ

ผลการวิจัยสะท้อนให้เห็นว่า ระยะเวลาการนอนหลับและสภาวะอารมณ์เป็นปัจจัยหลักที่เชื่อมโยงกับประสิทธิภาพการทำงาน ซึ่งสอดคล้องกับแนวคิดของ Rosekind และคณะ [1] ที่อธิบายว่าการนอนหลับไม่เพียงพอส่งผลให้ความสามารถในการจัดจ่อและระดับพลังงานลดลง จนนำไปสู่การสูญเสียประสิทธิภาพในการทำงาน โดยผลการจัดกลุ่มเชิงปริมาณพบว่า กลุ่มประสิทธิภาพสูงมีระยะเวลานอนเฉลี่ย 8.12 ชั่วโมง และมีคะแนนประสิทธิภาพเฉลี่ย 8.12 คะแนน ขณะที่กลุ่มประสิทธิภาพต่ำมีระยะเวลานอนเฉลี่ยเพียง 5.79 ชั่วโมง และมีคะแนนประสิทธิภาพเฉลี่ย 3.56 คะแนน หรือต่ำกว่ากัน 4.56 คะแนน นอกจากนี้ ผลจาก Apriori ยังยืนยันแนวโน้มดังกล่าว โดยอารมณ์มีความสุขร่วมกับการนอนเพียงพอสัมพันธ์กับ

ประสิทธิภาพสูงด้วยค่า Confidence เท่ากับ 1.00 และ Lift เท่ากับ 2.33 ขณะที่อารมณ์เศร้าสัมพันธ์กับประสิทธิภาพต่ำด้วยค่า Confidence เท่ากับ 0.95 และ Lift เท่ากับ 2.07 ผลดังกล่าวสอดคล้องกับ Random Forest ซึ่งมีความถูกต้องร้อยละ 84 และพบว่าตัวแปรระยะเวลาการนอน อารมณ์เศร้า และอารมณ์มีความสุขมีส่วนความสำคัญรวมกันร้อยละ 70.98 จึงอาจสรุปได้ว่า ความพร้อมด้านการพักผ่อนและสภาวะทางจิตมีบทบาทต่อประสิทธิภาพการทำงานมากกว่ากิจกรรมเสริมบางประเภท เช่น การเขียนบันทึกหรือประเภทอาหารเข้า อย่างไรก็ตาม ผลที่พบเป็นความสัมพันธ์จากชุดข้อมูลที่ศึกษา จึงยังไม่ควรตีความว่าเป็นความสัมพันธ์เชิงสาเหตุโดยตรง

5.2 ข้อเสนอแนะ

5.2.1 ข้อเสนอแนะเพื่อการนำผลการวิจัยไปใช้ประโยชน์

สำหรับบุคคลทั่วไป (Personal Application) ควรเลิกยึดติดกับ "จำนวนรายการกิจวัตรยามเช้าที่ต้องทำแข่งกับเวลา" (Rigid Morning Checklist) และเปลี่ยนมามุ่งเน้นที่ Sleep Hygiene (สุขอนามัยในการนอน) เป็นอันดับแรก โดยตั้งเป้าหมายการนอนให้ได้ 7.5 ชั่วโมงขึ้นไป และเมื่อตื่นขึ้นมา กิจกรรมแรกที่ควรทำ ไม่ใช่การนั่งสมาธิหรือเขียนบันทึกความรู้สึกเครียด แต่คือการทำกิจกรรมที่ "ยกระดับอารมณ์ให้แจ่มใส" (Mood Booster) เป็นลำดับแรก

สำหรับฝ่ายทรัพยากรบุคคลในองค์กร (Corporate HR) นโยบายส่งเสริมประสิทธิภาพการทำงานของพนักงาน ควรเปลี่ยนจากการจัดอบรมเรื่อง "เทคนิคการจัดโต๊ะทำงานหรือการเขียน To-Do List ยามเช้า" ไปสู่การรณรงค์เรื่อง Right to Disconnect (ห้ามส่งงานนอกเวลาจนเพื่อไม่ให้รบกวนเวลาของพนักงาน) และการจัดสวัสดิการที่ส่งเสริมสุขภาพจิตและสภาวะอารมณ์

สำหรับการต่อยอดเชิงอุตสาหกรรมซอฟต์แวร์ สามารถนำค่าน้ำหนัก (Feature Weights) ของ sleep_hours, mood_sad และ mood_happy ที่ได้จากโมเดล Random Forest ไปใช้เป็นสมการแกนกลาง (Core Inference Engine) ในการพัฒนา "แอปพลิเคชันแนะนำกิจวัตรประจำวันอัจฉริยะ" (Personalized Routine Recommender) ที่สามารถปรับเปลี่ยนคำแนะนำยามเช้าให้สอดคล้องกับชั่วโมงการนอนที่แท้จริงของผู้ใช้ในแต่ละวันได้แบบไดนามิก

5.2.2 ข้อเสนอแนะสำหรับการทำวิจัยครั้งต่อไป

งานวิจัยในอนาคตควรเปลี่ยนจากการใช้ชุดข้อมูลจำลอง/บันทึกด้วยมือ ไปสู่การเชื่อมต่อ API ดึงข้อมูลสรีรวิทยาจริงจากอุปกรณ์อัจฉริยะ (เช่น ข้อมูล Sleep Stages: Deep/REM sleep หรือค่าความแปรปรวนของอัตราการเต้นของหัวใจ: HRV) เพื่อให้ได้มาตรวัดทางสรีรวิทยาที่มีความละเอียดสูง รวมถึงการศึกษาผลกระทบแบบข้ามเวลา (Longitudinal Time-Series) ซึ่งควรมีการวิเคราะห์ข้อมูลในลักษณะอนุกรมเวลา เพื่อศึกษา "ภาระหนี้การนอนสะสม" (Cumulative Sleep Debt) ว่าการรอนนอนติดต่อกันเป็นเวลาที่ต่างกันจะส่งผลต่อสภาวะอารมณ์และประสิทธิภาพต่างกันอย่างไร นอกจากนี้ยังมีประเด็นการประยุกต์ใช้เทคนิค AI อธิบายได้ (Explainable AI: XAI) ที่ควรนำไลบรารีขั้นสูง เช่น SHAP (SHapley Additive exPlanations) มาพล็อตกระจายตัวข้อมูล เพื่อจุดตัดหักเห (Threshold) ที่ชัดเจนว่า การนอนลดลงกี่ชั่วโมงจะส่งผลต่ออารมณ์ที่แย่งระดับใด และทำให้อัตราการร่วงหล่นของ Productivity ถึงจะเข้าสู่จุดวิกฤตได้

6. เอกสารอ้างอิง (References)

- [1] M. R. Rosekind, K. B. Gregory, M. M. Mallis, A. M. Brandt, B. Seal, and D. Lerner, "The cost of poor sleep: workplace productivity loss and associated costs," *Journal of Occupational and Environmental Medicine*, vol. 52, no. 1, pp. 91–98, 2010.
- [2] Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., & Wirth, R. (2000). CRISP-DM 1.0: Step-by-step data mining guide. SPSS Inc.

