

# The performance of data mining technique for prediction of delirium tremens

**Kuankidnuttha Arunsri**

Pakchongnana Hospital, Nakhon Ratchasima

---

## **Abstract**

Delirium tremens (DTs) is the most severe form of alcohol withdrawal syndrome that can lead to multiple physical complications, such as electrolyte imbalances, cardiovascular collapse. Untreated DTs carries a mortality rate of approximately 20 to 40%. Developing models for predicting DTs occurrence in hospitals could enable early diagnosis and timely treatment, significantly reducing the mortality rate to around 1-4%. To develop and compare the performance of models for predicting DTs in inpatients with alcohol dependence. A predictive model for DTs was developed using 10 data mining techniques. The data is collected from hospitalized patients diagnosed with alcohol dependence at Pakchong Nana Hospital. A training and testing set was created from a retrospective review of 1,960 electronic medical records, containing 11 features. The model's performance was

evaluated using 10-Fold Cross Validation. The most effective predictive model was Gradient Boosting Trees with feature selection, achieving an accuracy of 74.14%, precision of 72.56%, sensitivity of 78.02%, and an F-measure of 75.09%. The Gradient Boosting Trees with feature selection was found to be the most optimal predictive model when compared to other algorithms. This model could be further developed into a clinical decision support system (CDSS) for predicting delirium tremens in hospitalized patients diagnosed as alcohol dependence.

**Keywords:** Data mining; Alcohol dependence; Delirium tremens

*Received: 10 January 2025, Revised: 25 April 2025, Accepted: 1 May 2025*

---

Correspondence: Kuankidnuttha Arunsri, Pakchongnana Hospital, 400 Mittraphap Rd., Pak Chong, Pak Chong District, Nakhon Ratchasima 30130, Tel: 044 311 856, E-mail: kuankidnuttha15@gmail.com

# สมรรถนะของเทคนิคเหมืองข้อมูลสำหรับพยากรณ์การเกิดภาวะเพื่อสับสนจากการขาดสุรา

ควรคิดนัฐฐา อรุณศรี

โรงพยาบาลปากช่องนานา จังหวัดนครราชสีมา

## บทคัดย่อ

ภาวะเพื่อสับสนจากขาดสุรา (Delirium Tremens) เป็นภาวะถอนพิษสุราแบบรุนแรง นำมาสู่ภาวะแทรกซ้อนทางกายหลายอย่าง เช่น ภาวะไม่สมดุลของระดับเกลือแร่ในร่างกาย ภาวะล้มเหลวของระบบไหลเวียนโลหิต เป็นต้น หากไม่ได้รับการรักษา ผู้ป่วยมีอาการการเสียชีวิตสูงประมาณ 20-40% การพัฒนาแบบจำลองสำหรับการพยากรณ์การเกิดภาวะเพื่อสับสนจากขาดสุรา ในโรงพยาบาล จะช่วยให้สามารถวินิจฉัย และให้การรักษาได้ทันที่ ทำให้อัตราการเสียชีวิตลดลงอย่างมาก เหลือประมาณ 1-4% เพื่อสร้างและเปรียบเทียบสมรรถนะของแบบจำลองที่ใช้สำหรับพยากรณ์การเกิดภาวะเพื่อสับสนจากการขาดสุรา ผู้วิจัยสร้างแบบจำลองเพื่อพยากรณ์การเกิดภาวะเพื่อสับสนจากการขาดสุราโดยใช้เทคนิคเหมืองข้อมูล 10 วิธี ใช้ข้อมูลของผู้ป่วยติดสุราเรื้อรัง (Alcohol Dependence) ที่เข้ารับการรักษาแบบผู้ป่วยในของโรงพยาบาลปากช่องนานา สร้างชุดตัวแบบและชุดทดสอบตัวแบบ ซึ่งเป็นข้อมูลที่เกิดจากการทบทวนเวชระเบียนอิเล็กทรอนิกส์ย้อนหลัง จำนวน 1,960 ชุดข้อมูล และ 11 คุณลักษณะ จากนั้นหาค่าสมรรถนะของแบบจำลองโดยใช้วิธี 10-Fold Cross Validation แบบจำลองที่มี

สมรรถนะในการทำนายที่ดีที่สุด คือ แบบจำลองโดยใช้อัลกอริทึมแบบ Gradient Boosting Trees พร้อมการเลือกคุณสมบัติของแอตทริบิวต์ มีค่าความแม่นยำ (Accuracy) 74.14% ค่าความเที่ยง (Precision) 72.56% ค่าความไว (Sensitivity) 78.02% และค่าประสิทธิภาพโดยรวม (F-measure) 75.09% โดยสรุปแบบจำลองโดยใช้อัลกอริทึมแบบ Gradient Boosting Trees พร้อมการเลือกคุณสมบัติของแอตทริบิวต์ แบบจำลองที่สมรรถนะเหมาะสมที่สุดเมื่อเทียบกับวิธีที่ใช้เปรียบเทียบร่วมกัน สามารถนำไปพัฒนาระบบสนับสนุนการตัดสินใจทางคลินิกเพื่อใช้พยากรณ์ภาวะเพื่อสับสนจากการขาดสุรา

**คำสำคัญ:** การทำเหมืองข้อมูล ภาวะติดสุรา ภาวะเพื่อสับสนจากการขาดสุรา

วันที่รับต้นฉบับ: 10 มกราคม 2568, วันที่แก้ไข: 25 เมษายน 2568, วันที่ตอบรับ: 1 พฤษภาคม 2568

## บทนำ

ภาวะถอนพิษสุรา (Alcohol Withdrawal Syndrome: AWS) มักเกิดขึ้นในผู้ป่วยติดสุรา (Alcohol Dependence) โดยอาการแสดงเกิดภายใน 6-24 ชั่วโมงหลังจากหยุดหรือลดปริมาณการดื่มสุราอย่างรวดเร็ว พบประมาณ 8% ของผู้ป่วยในที่มีภาวะติดสุราเรื้อรังที่เข้ารับการรักษาในโรงพยาบาล<sup>[1]</sup> แสดงออกตั้งแต่อาการเล็กน้อย ปานกลาง และรุนแรงถึงขั้นเกิดภาวะเพื่อสับสนจากการถอนสุรา (Delirium Tremens) ซึ่งภาวะดังกล่าว มักเกิดขึ้นภายใน 48-72 ชั่วโมงหลังจากหยุดสุรา แต่ในบางกรณีอาจใช้เวลาถึง 7-10 วัน ความชุกของภาวะดังกล่าวประมาณ 5-10% ในผู้ป่วยที่มีอาการถอนพิษสุรา และ

อาจสูงขึ้นในบางสถานการณ์ทางคลินิก เช่น ในหอผู้ป่วยวิกฤติ (ICU) หรือผู้ป่วยที่มีประวัติการดื่มแอลกอฮอล์เป็นเวลานาน เป็นต้น<sup>[2]</sup> ภาวะเพื่อสับสนจากถอนสุราเป็นภาวะถอนพิษสุราแบบรุนแรง ซึ่งเพิ่มระยะเวลาการรักษาในโรงพยาบาลสูงเป็นสองเท่าทำให้เกิดภาวะแทรกซ้อนทางกายตามมา เช่น ภาวะกล้ามเนื้อสลาย (Rhabdomyolysis) ปอดอักเสบจากการสำลัก (Aspiration Pneumonia) อาการหัวใจเต้นผิดจังหวะ (Arrhythmia) เป็นต้น หากรักษาไม่ทันที่ มีอัตราการเสียชีวิตสูงได้ถึง 20% ในทางกลับกัน การวินิจฉัยและการรักษาที่ทันที่ที่สามารถลดอัตราการเสียชีวิตลงเหลือประมาณ 1-4%<sup>[3]</sup>

อัลกอริทึมการทำเหมืองข้อมูล (Data Mining) เป็นกระบวนการวิเคราะห์ข้อมูลขนาดใหญ่ เพื่อค้นหารูปแบบและกฎที่มีอยู่ในฐานข้อมูล การทำเหมืองข้อมูลที่ช่วยได้แก่ การหาความสัมพันธ์ การจัดกลุ่ม การจำแนกประเภทข้อมูล และการวิเคราะห์ข้อมูลที่ไม่มีโครงสร้าง<sup>[4]</sup> ในปัจจุบัน การเรียนรู้ของเครื่อง (Machine Learning) ซึ่งเป็นสาขาหนึ่งของการทำ

ผู้นิพนธ์ประสานงาน: ควรคิดนัฐฐา อรุณศรี, โรงพยาบาลปากช่องนานา, 400 ถ.มิตรภาพ ต.ปากช่อง อ.ปากช่อง จ.นครราชสีมา โทร. 044 311 856, E-mail: kuankidnuttha15@gmail.com

เหมือนข้อมูลได้รับความนิยมอย่างมากในทางการแพทย์ โดยเฉพาะในการวินิจฉัยโรคและทำนายผลลัพธ์ เทคนิคการเรียนรู้จากเครื่องสามารถประมวลผลข้อมูลจำนวนมากจากเวชระเบียนอิเล็กทรอนิกส์ (Electronic Medical Records: EMRs) เพื่อระบุรูปแบบและแนวโน้มต่างๆ ซึ่งช่วยในการทำนายผลลัพธ์ของผู้ป่วย ปรับแผนการรักษาให้เหมาะสมกับแต่ละบุคคลและปรับปรุงการดูแลผู้ป่วยในภาพรวม ในต่างประเทศ การเรียนรู้ทางเครื่องถูกนำมาใช้ในภาวะการถอนพิษสุรา ไม่ว่าจะเป็นการทำนายความรุนแรงของภาวะถอนพิษสุรา การตรวจคัดกรองภาวะถอนพิษสุราตั้งแต่เนิ่นๆ การปรับแผนการรักษา และการพัฒนาการตัดสินใจทางคลินิก (Clinical Decision Support System: CDSS) [5], [6] แต่ในประเทศไทย จำนวนงานวิจัยที่เกี่ยวกับเรื่องดังกล่าวยังมีไม่มากนัก เนื่องจากการวิจัยเกี่ยวกับการทำเหมืองข้อมูลยังอยู่ในช่วงเริ่มต้น เมื่อเทียบกับบางประเทศที่พัฒนาแล้ว [7]

วิวัฒนาการทางการแพทย์ในปัจจุบันมีความเจริญก้าวหน้าหลายโรงพยาบาลในประเทศไทยนำเครื่องมือ เช่น CIWA-AR, MINDS, AWS เป็นต้น เพื่อใช้ประเมินความรุนแรงสำหรับการถอนสุราแต่เครื่องมือเหล่านี้ไม่ได้เฉพาะเจาะจงกับภาวะเพื่อสับสนจากการขาดสุรา [8], [9] อย่างไรก็ตาม การประเมินความเสี่ยงหรือการทำนายผลการเกิดภาวะเพื่อสับสนจากการถอนพิษสุราก็ยังเป็นประโยชน์ต่อการดำเนินการรักษาตามมาตรฐานและการวางแผนป้องกัน เนื่องจากภาวะเพื่อสับสนจากการถอนพิษสุรา ต้องได้รับการดูแลที่เหมาะสมกับความรุนแรงและระยะเวลาที่ผู้ป่วยมีอาการ รวมถึงความล่าช้าในการวินิจฉัยและรักษานำมาสู่ภาวะแทรกซ้อนและอัตราการเสียชีวิตที่สูงขึ้น

จากปัญหาดังกล่าว ผู้วิจัยจึงได้สร้างระบบพยากรณ์การเกิดภาวะเพื่อสับสนจากการถอนพิษสุราขึ้น โดยนำเทคนิคเหมืองมาประยุกต์ใช้วิเคราะห์เพื่อทำนายผลในการเกิดภาวะเพื่อสับสนจากการถอนพิษสุรา ช่วยให้นักวิชาการทางการแพทย์ทราบความเสี่ยงและสามารถพยากรณ์การเกิดภาวะดังกล่าวได้ โดยการพยากรณ์โรคที่มีความแม่นยำย่อมสามารถทำให้ดำเนินการตามมาตรการและป้องกันภาวะแทรกซ้อนจากการขาดสุราได้อย่างเหมาะสมและนำไปสู่การใช้ทรัพยากรอย่างมีประสิทธิภาพ

## วัตถุประสงค์

เพื่อสร้างแบบและเปรียบเทียบสมรรถนะของแบบจำลองสำหรับพยากรณ์การเกิดภาวะเพื่อสับสนจากการขาดสุรา

## การสนทวนวรรณาน

### 3.1 ภาวะเพื่อสับสนจากการขาดสุรา (Delirium Tremens: DTs)

**ระบาดวิทยา:** อุบัติการณ์ของอาการเพ้อคลั่งจากพิษสุราเรื้อรังแตกต่างกันไปตามประชากร ขึ้นอยู่กับรูปแบบการ

บริโภคแอลกอฮอล์และความพร้อมในการเข้าถึงทรัพยากรทางการแพทย์ คาดว่าประมาณ 3-5% ของผู้ป่วยที่ติดสุราจะมีภาวะเพื่อสับสนจากการขาดสุรา (Delirium Tremens) เมื่อเกิดการถอนพิษสุรา [2] อาการนี้มักเริ่มภายใน 48 ถึง 96 ชั่วโมงหลังจากการหยุดดื่มสุรา แต่ในบางกรณีอาจเกิดล่าช้าได้ ภาวะเพื่อสับสนจากการขาดสุรา (Delirium Tremens) มักเกิดในผู้ที่มีประวัติการดื่มสุรานาน ผู้ที่มีภาวะแทรกซ้อนจากการถอนสุรามาก่อน และผู้ที่มีโรคทางกายร่วมด้วย

**ปัจจัยเสี่ยง:** ปัจจัยเสี่ยงที่ทำให้เกิดภาวะเพื่อสับสนจากการถอนสุรา (Delirium Tremens) [1] ได้แก่ การดื่มสุราหนักเป็นเวลานาน ประวัติเพื่อสับสนจากการขาดสุรา (Delirium Tremens) หรือชักระหว่างการถอนสุรา ก่อนหน้านี้ การมีโรคทางกายร่วมด้วย เช่น การติดเชื้อ การบาดเจ็บทางร่างกาย หรือโรคกลุ่มเมตาบอลิก อายุมาก (Advanced Age) ระดับแอลกอฮอล์ในเลือดสูงในขณะหยุดดื่มสุรา รอยโรคในสมอง (Structural Brain Lesion) ภาวะบกพร่องทางปัญญา (Cognitive Impairment) เป็นต้น

**การวินิจฉัย:** การวินิจฉัยภาวะเพื่อสับสนจากการถอนสุรา (Delirium Tremens) เป็นการวินิจฉัยเชิงคลินิก โดยอิงจากประวัติการดื่มสุราและลักษณะอาการ เกณฑ์การวินิจฉัยที่สำคัญ [10] ประกอบด้วย:

1. หยุดหรือลดการดื่มแอลกอฮอล์อย่างหนักเมื่อไม่นานมานี้
2. การเกิดอาการเพื่อสับสน
3. มีหลักฐานของระบบประสาทอัตโนมัติทำงานมากเกินไป (เช่น หัวใจเต้นเร็ว เหงื่อออก)

**การพยากรณ์โรค:** หากไม่ได้รับการรักษาภาวะเพื่อสับสนจากการขาดสุรา (Delirium Tremens) อาจมีอัตราการเสียชีวิตสูงถึง 15-20% เนื่องจากภาวะแทรกซ้อน เช่น ภาวะหัวใจเต้นผิดจังหวะ ระบบหายใจล้มเหลว และการติดเชื้อ อย่างไรก็ตาม หากได้รับการรักษาอย่างเหมาะสม อัตราการเสียชีวิตจะลดลงเหลือไม่ถึง 5% [3] การวินิจฉัยและรักษาอย่างรวดเร็วจะช่วยให้พยากรณ์โรคดีขึ้น

### 3.2 การสร้างโมเดลในเหมืองข้อมูล (Data Mining)

การสร้างโมเดลในเหมืองข้อมูลเป็นกระบวนการที่สำคัญในการใช้เทคนิคต่างๆ เพื่อสร้างแบบจำลองที่สามารถคาดการณ์หรือจำแนกประเภทข้อมูลได้อย่างแม่นยำ ช่วยให้เราสามารถค้นพบรูปแบบและความสัมพันธ์ในข้อมูลที่ซับซ้อน และนำไปใช้ในการตัดสินใจหรือการวิเคราะห์ข้อมูล

ในงานวิจัยนี้ เลือกใช้แบบจำลองการเรียนรู้แบบมีผู้สอน (Supervised Learning Models) ซึ่งมีความเหมาะสมอย่างยิ่งสำหรับการใช้ในการพยากรณ์การเกิดโรค เพราะมีความสามารถในการเรียนรู้จากข้อมูลที่มีคำตอบหรือผลลัพธ์กำกับ

ทำให้สามารถสร้างความสัมพันธ์ระหว่างปัจจัยเสี่ยง หรือคุณลักษณะทางการแพทย์ต่าง ๆ กับโอกาสในการเกิดโรคได้อย่างแม่นยำ โดยเมื่อพิจารณาจากประเภทผลลัพธ์ที่ต้องการ คือการพยากรณ์การเกิดหรือไม่เกิดโรค จึงมีความเหมาะสมในการใช้แบบจำลองชนิดการจำแนกประเภท (Classification) มากกว่าแบบจำลองชนิดการพยากรณ์เชิงเส้น (Regression)

แบบจำลองชนิดการจำแนกประเภท (Classification) ที่ใช้ในงานทั้งหมด 10 อัลกอริทึม(11,12) ได้แก่

3.2.1 อัลกอริทึมแบบ Naive Bayes เป็นอัลกอริทึมสำหรับการจำแนกประเภทที่มีพื้นฐานจากทฤษฎีความน่าจะเป็น (Bayes' Theorem) โดยเฉพาะในการจำแนกประเภทข้อมูล ใช้หลักการที่เรียกว่า "สมมติฐานพื้นฐาน" (Naive Assumption) ซึ่งหมายถึงการที่แต่ละฟีเจอร์ของข้อมูลจะมีความเป็นอิสระจากกันเมื่อพิจารณาจากคลาสที่กำหนด

3.2.2 อัลกอริทึมแบบ Support Vector Machine เป็นเทคนิคการเรียนรู้ของเครื่องที่ใช้ในการจำแนกประเภทข้อมูลและการถดถอย (Regression) โดยมีจุดมุ่งหมายเพื่อค้นหาขอบเขต (Boundary) ที่ดีที่สุดในการแยกข้อมูลในกลุ่มต่างๆ อัลกอริทึมนี้ถูกนำมาใช้ในหลายปัญหาของการเรียนรู้ของเครื่องเนื่องจากมีประสิทธิภาพในการจัดการกับข้อมูลที่ซับซ้อนและมีมิติสูง

3.2.3 อัลกอริทึมแบบ Decision Trees เป็นอัลกอริทึมที่ใช้ในการจัดหมวดหมู่และการทำนายผล ซึ่งมีลักษณะเป็นโครงสร้างที่คล้ายกับต้นไม้ โดยการตัดสินใจแต่ละครั้งจะมีการแบ่งออกเป็นกิ่งๆ จนกระทั่งถึงผลลัพธ์สุดท้าย ซึ่งเป็นค่าคาดการณ์หรือการตัดสินใจที่ต้องการ

3.2.4 อัลกอริทึมแบบ Random Forest เป็นอัลกอริทึมสำหรับการจัดหมวดหมู่และการถดถอยที่ใช้กลยุทธ์ของการรวมหลายต้นไม้ตัดสินใจ เพื่อให้ผลลัพธ์ที่แม่นยำและเสถียรยิ่งขึ้น โดยการสร้าง "ป่า" ของต้นไม้ตัดสินใจหลายๆ ต้นแล้วรวมผลลัพธ์เพื่อทำการตัดสินใจ

3.2.5 อัลกอริทึมแบบ Gradient Boosted Trees เป็นเทคนิคการเรียนรู้ของเครื่องที่มีประสิทธิภาพสูงในการสร้างโมเดลโดยการรวมกันของหลายๆ ต้นไม้การตัดสินใจ เทคนิคนี้เป็นส่วนหนึ่งของกลุ่มวิธีการที่เรียกว่า เทคนิคการเรียนรู้ร่วมกัน (Ensemble Learning) ซึ่งมุ่งเน้นในการรวมหลายๆ โมเดลเพื่อเพิ่มความแม่นยำของการคาดการณ์

3.2.6 อัลกอริทึมแบบ Boosting Decisional Trees เป็นเทคนิคที่ใช้ในการปรับปรุงสมรรถนะของโมเดลการเรียนรู้ของเครื่อง โดยการรวมโมเดลที่หลายๆ ตัวเข้าด้วยกันเพื่อให้ผลลัพธ์ที่ดียิ่งขึ้น เทคนิคนี้จะทำงานโดยการฝึกโมเดลที่เรียกว่า Weak Decision Trees หรือโมเดลที่มีความสามารถจำกัดแล้วรวมผลลัพธ์เพื่อสร้างโมเดลที่แข็งแกร่งและมีความแม่นยำสูงขึ้น

3.2.7 อัลกอริทึมแบบ Bagged Decisional Trees เป็นเทคนิคการเรียนรู้ของเครื่องที่ช่วยเพิ่มความแม่นยำของโมเดลโดยการรวมผลลัพธ์จากโมเดลหลายๆ ตัว เทคนิคนี้มักใช้กับต้นไม้ตัดสินใจเพื่อสร้าง "ป่า" ของต้นไม้ตัดสินใจและรวมผลลัพธ์เพื่อให้ผลลัพธ์ที่มีความเสถียรและแม่นยำสูงขึ้น

3.2.8 อัลกอริทึมแบบ K-Nearest Neighbor: K-NN เป็นอัลกอริทึมที่ใช้ในการจัดหมวดหมู่และการถดถอย ซึ่งมีลักษณะเรียบง่ายและเข้าใจง่าย โดยวิธีการทำงานของ K-NN คือการพิจารณาความใกล้เคียงของจุดข้อมูลในชุดข้อมูลเพื่อทำการตัดสินใจหรือคาดการณ์ค่า

3.2.9 อัลกอริทึมแบบ Deep Learning Model เป็นสาขาย่อยของการเรียนรู้ของเครื่องที่มุ่งเน้นการสร้างและฝึกสอนโครงข่ายประสาทเทียมที่มีหลายชั้น เพื่อให้สามารถเรียนรู้และทำการคาดการณ์จากข้อมูลที่ซับซ้อนและมีความหลากหลายได้อย่างมีประสิทธิภาพ

3.2.10 อัลกอริทึมแบบ Neural Networks เป็นโมเดลที่ได้รับแรงบันดาลใจจากการทำงานของสมองมนุษย์ ใช้ในการประมวลผลข้อมูลและเรียนรู้จากข้อมูลเพื่อทำการคาดการณ์หรือการจำแนกประเภท เครือข่ายประสาทเป็นส่วนสำคัญของการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก

#### IV. วัตถุประสงค์งานวิจัย

การทำวิจัยครั้งนี้เป็นการวิจัยแบบประยุกต์ (Applied Research) ซึ่งมีการนำข้อมูลทฤษฎีของผู้ป่วยที่มีภาวะติดสุรา (Alcohol Dependence) มาประยุกต์ใช้งานกับเทคนิคการทำเหมืองข้อมูล ซึ่งจะสร้างแบบจำลองพยากรณ์การเกิดภาวะสับสนจากการขาดสุรา (Delirium Tremens) เป็นการศึกษาแบบย้อนหลัง (Retrospective Study) ผู้วิจัยได้ดำเนินการตามขั้นตอนและกรอบแนวคิด (Conceptual Framework) แสดงดังภาพที่ 1

No.	Attribute	Detail	Value of attribute
1	SEX	เพศ	Nominal Scale M: ผู้ชาย F: ผู้หญิง
2	AGE	อายุ (ปี)	Numerical Scale
3	OCCUPATION	อาชีพ	Nominal Scale 0: ไม่ประกอบอาชีพ 1: อาชีพรับจ้าง 2: อาชีพอื่นๆ
4	PR	ค่าซีพจร (ครั้ง/นาที)	Numerical Scale
5	TEMP	ค่าอุณหภูมิร่างกาย (°C)	Numerical Scale
6	RR	ค่าอัตราการหายใจ (ครั้ง/นาที)	Numerical Scale
7	POTASSIUM	ค่าโพแทสเซียมในเลือด (mmol/L)	Numerical Scale
8	MAGNESIUM	ค่าแมกนีเซียมในเลือด (mmol/L)	Numerical Scale
9	BICARB	ค่าไบคาร์บอเนตในเลือด (mmol/L)	Numerical Scale
10	PLATELET	ค่าเกร็ดเลือด ( $\times 10^3/UL$ )	Numerical Scale
11	AST	ค่าแอสปาร์เตททรานสเฟอเรสในเลือด (U/L)	Numerical Scale
12	CREATININE	ค่าครีเอตินินในเลือด (mg/dl)	Numerical Scale
13	CLASS	ผลการวินิจฉัยภาวะสับสนจากขาดสุรา	Nominal Scale 0: ไม่มีภาวะสับสนจากการขาดสุรา 1: มีภาวะสับสนจากการขาดสุรา

ภาพที่ 1 กรอบแนวคิดในการวิจัย

วิธีการดำเนินงานวิจัยสำหรับการแบ่งกลุ่มผู้ป่วยติดสุราเรื้อรังที่มีและไม่มีภาวะสับสนจากการขาดสุรา ใช้เทคนิคการทำเหมืองข้อมูล โดยอ้างอิงตามกระบวนการมาตรฐานในการทำเหมืองข้อมูล (The Cross-Industry Standard Process for Data Mining: CRISP-DM) ทั้ง 6 ขั้นตอน<sup>[11]</sup> ได้แก่

4.1 การทำความเข้าใจเกี่ยวกับธุรกิจ (Business Understanding) ผู้วิจัยได้ศึกษาข้อมูลเกี่ยวกับการเกิดภาวะสับสนจากการขาดสุรา พบปัญหาที่เกิดขึ้น คือความล่าช้าในการวินิจฉัยและให้การรักษาสภาวะสับสนจากการขาดสุรา ซึ่งนำมาสู่ภาวะแทรกซ้อนทางกายและอัตราการเสียชีวิตที่เพิ่มสูงขึ้น ดังนั้นงานวิจัยนี้จึงจัดทำขึ้นเพื่อสร้างแบบจำลองสำหรับการพยากรณ์โอกาสการเกิดภาวะสับสนจากการขาดสุรา เพื่อหาแนวทางป้องกันให้กับผู้ที่มีโอกาสเสี่ยงเกิดภาวะสับสนจากการขาดสุราและลดภาวะแทรกซ้อนที่เกิดขึ้น

4.2 การทำความเข้าใจเกี่ยวกับข้อมูล (Data Understanding) งานวิจัยนี้ใช้ชุดข้อมูลจริงเกี่ยวกับผู้ป่วยโรคติดสุรา (Alcohol Dependence) ที่เข้ารับการรักษา ณ โรงพยาบาลปากช่องนานา จังหวัดนครราชสีมา ตั้งแต่ปี พ.ศ. 2556-2566 จำนวน 2,357 แถว และมีจำนวน 12 แอตทริบิวต์ ได้แก่ รหัสผู้ป่วย เพศ อายุ อาชีพ อุณหภูมิร่างกาย ซีพจร อัตราการหายใจ ค่าโพแทสเซียมในเลือด ค่าแมกนีเซียมในเลือด ค่าไบคาร์บอเนตในเลือด จำนวนเกร็ดเลือด ค่าแอสปาร์เตททรานซามิเนสในเลือด และค่าครีเอตินินในเลือด ซึ่งจัดเก็บอยู่ในรูปแบบไฟล์ CSV

4.3 การเตรียมข้อมูล (Data Preparation) การเก็บรวบรวมข้อมูลในการวิจัยนี้ เป็นการทบทวนเวชระเบียนผู้ป่วยที่มีภาวะติดสุรา ที่เป็นผู้ป่วยในของโรงพยาบาลปากช่องนานา ตั้งแต่ปีพ.ศ. 2557-2567 ได้แบ่งขั้นตอนการเตรียมข้อมูลออกเป็น 4 ขั้นตอน

4.3.1 การคัดเลือกข้อมูล (Data Selection) ผู้วิจัยได้ตัดแอตทริบิวต์อาชีพของผู้ป่วย (Occupation) ที่ไม่สามารถอธิบายค่าข้อมูลอื่นๆ ซึ่งจะเหลือแอตทริบิวต์ที่ใช้ในการวิเคราะห์ทั้งหมดมีจำนวน 11 แอตทริบิวต์ จำนวน 2,357 ระเบียบ

4.3.2 กำหนดหน้าที่ให้กับแอตทริบิวต์รหัสผู้ป่วย (ID) ให้มีหน้าที่เป็น "ID" เพื่อใช้ระบุกับข้อมูลที่มีความเป็นเอกลักษณ์ หรือไม่ซ้ำกับข้อมูลในแถวอื่นๆ ดังนั้น "รหัสผู้ป่วย" จึงไม่ได้ใช้สำหรับการวิเคราะห์ในครั้งนี้ และกำหนดหน้าที่ให้กับแอตทริบิวต์สรุปผลการมีภาวะสับสนจากการขาดสุราให้มีหน้าที่เป็น "Label" เพื่อใช้ระบุกับข้อมูลที่เป็นคลาสคำตอบ

4.3.3 การแปลงรูปข้อมูล (Data Transformation) ผู้วิจัยใช้โปรแกรม Microsoft Excel ในการจัดการข้อมูลที่ได้จากฐานข้อมูล HOSxP ของโรงพยาบาลปากช่องนานา ทำการรวมและคิวรีข้อมูลจากไฟล์ข้อมูลที่ได้มา และบันทึกข้อมูลจัดเก็บอยู่ในรูปแบบนามสกุล CSV เพื่อนำไปใช้วิเคราะห์ข้อมูลต่อไป

4.3.4 การทำความสะอาดข้อมูล (Data Cleaning) หลังจากสำรวจข้อมูล (Explore Data) นำข้อมูลทั้งหมด 2,357 ราย นำมาทำความสะอาดด้วยการขจัดข้อมูลที่ผิดพลาด (Missing value) ข้อมูลที่ไม่สมบูรณ์ (Incomplete Data) และข้อมูลที่มีค่าของคุณลักษณะบางอย่างที่ขาดหาย ตัดทิ้งจำนวน 392 ราย เหลือข้อมูลที่มีความสมบูรณ์จำนวน 1,960 ราย ที่ประกอบด้วยทั้งหมด 11 แอตทริบิวต์นำเข้า (Input) จำนวน 10 แอตทริบิวต์ และแอตทริบิวต์ผลลัพธ์ (Class) จำนวน 1 แอตทริบิวต์ แบ่งเป็นข้อมูลผู้ป่วยที่มีภาวะเพื่อสับสนจากการถอนสุรา (Delirium Tremens) จำนวน 1,114 ราย และไม่มีภาวะเพื่อสับสนจากการถอนสุรา (Delirium Tremens) จำนวน 845 ราย แสดงดังตารางที่ 1

4.4 การสร้างแบบจำลอง (Modeling) แบ่งออกเป็น 2 ขั้นตอน ได้แก่

4.4.1 การสร้างแบบจำลองการทำนายการเกิดภาวะสับสนจากการขาดสุรา โดยใช้อัลกอริทึมเหมือนข้อมูล ได้แก่ ได้แก่ Naive Bayes, Deep Learning Model, Decision Trees, Bagged Decisional Trees, Boosting Decisional Trees, Random Forest, K-Nearest Neighbor, Support Vector Machines, Gradient Boosting Trees และ Neural Networks ด้วยโปรแกรม RapidMiner Studio และได้ทดลองกำหนดพารามิเตอร์ต่างๆในโปรแกรม ดังแสดงในภาพที่ 2 จนได้ผลลัพธ์ที่เหมาะสมและให้ค่าสมรรถนะดีที่สุด

4.4.2 ใช้ อัลกอริทึมการจำแนกข้อมูล (Data Classification) จำนวน 10 วิธีพร้อมการเลือกคุณสมบัติของแอตทริบิวต์ (Attribute Selection) ด้วยโปรแกรม RapidMiner Studio โดยเทคนิคในการเลือกแอตทริบิวต์ ใช้โอเปอเรเตอร์ Optimize Weights (Evolutionary) เป็นการใช้สำหรับคำนวณค่าน้ำหนักของแอตทริบิวต์ต่างๆ ของแต่ละแอตทริบิวต์และเลือกแอตทริบิวต์ที่เหมาะสม โดยมีค่าน้ำหนักอยู่ระหว่าง 0-1 ซึ่งค่าน้ำหนัก 0 หมายถึง ไม่มีความสำคัญ และค่าน้ำหนัก 1 หมายถึง สำคัญที่สุด

ตารางที่ 1 แอตทริบิวต์ของผู้ป่วยที่มีภาวะติดสุรา (Attribute Detail)

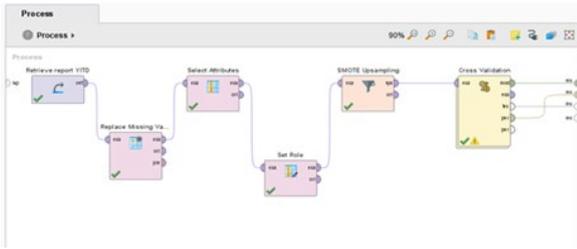
No.	Attribute	Detail	Value of attribute
1	SEX	เพศ	Nominal Scale M: ผู้ชาย F: ผู้หญิง
2	AGE	อายุ (ปี)	Numerical Scale
3	OCCUPATION	อาชีพ	Nominal Scale 0: ไม่ประกอบอาชีพ 1: อาชีพรับจ้าง 2: อาชีพอื่นๆ
4	PR	ค่าชีพจร (ครั้ง/นาที)	Numerical Scale
5	TEMP	ค่าอุณหภูมิร่างกาย (°C)	Numerical Scale
6	RR	ค่าอัตราการหายใจ (ครั้ง/นาที)	Numerical Scale
7	POTASSIUM	ค่าโพแทสเซียมในเลือด (mmol/L)	Numerical Scale
8	MAGNESIUM	ค่าแมกนีเซียมในเลือด (mmol/L)	Numerical Scale
9	BICARB	ค่าไบคาร์บอเนตในเลือด (mmol/L)	Numerical Scale
10	PLATELET	ค่าเกร็ดเลือด (x10 <sup>9</sup> /UL)	Numerical Scale
11	AST	ค่าแอสปาร์เทททรานสเฟอเรสในเลือด (U/L)	Numerical Scale
12	CREATININE	ค่าครีเอตินินในเลือด (mg/dl)	Numerical Scale
13	CLASS	ผลการวินิจฉัยภาวะสับสนจากขาดสุรา	Nominal Scale 0: ไม่มีภาวะสับสนจากการขาดสุรา 1: มีภาวะสับสนจากการขาดสุรา

4.5 การประเมินผล (Evaluation) เพื่อเปรียบเทียบหาสมรรถนะของแบบจำลองการพยากรณ์การเกิดภาวะสับสนจากการขาดสุรา ด้วยวิธี 10-Fold Cross Validation ได้ทำการแบ่งข้อมูลออกเป็น 10 ชุดเท่าๆ โดยแต่ละชุดมีจำนวนข้อมูลเท่ากัน และใช้ข้อมูลสำหรับการสร้างแบบจำลองเป็นชุดการเรียนรู้ (Training Data) จำนวน 9 ชุด และข้อมูลสำหรับทดสอบแบบจำลองเป็นชุดทดสอบ (Testing Data) จำนวน 1 ชุด หลังจากนั้นทำการวนรอบจำนวน 10 รอบ แล้ววัดค่าสมรรถนะของการจำแนกประเภทข้อมูล ด้วยค่าความแม่นยำ (Accuracy) ค่าความเที่ยง (Precision) ค่าประสิทธิภาพโดยรวม (F-measure) และค่าความไว (Sensitivity)

ตารางที่ 2 แสดงค่าพารามิเตอร์ของแบบจำลอง (Parameter Setting Detail)

No.	Algorithm	Parameter setting
1	Decisional Trees	Criterion gain_ratio Maximal depth = 10 Confidence 0.1 Minimal gain = 0.01 Minimal leaf size = 2
2	Bagged Decisional Trees	Sample ratio = 0.9 Iterations = 10
3	Boosting Decisional Trees	Iterations = 10
4	K-Nearest Neighbors	k = 5 Measure type = MixedMeasures Mixed measure = MixedEuclidean Distance
5	Random forest	Number of trees = 100 Criterion gain_ratio Maximal depth = 10 Voting Strategy Confidence vote
6	Naive Bayes	Laplace correction
7	Support Vector Machines	Epsilon 0.0 Complexity 0.0 Kernel type dot
8	Gradient Boosted Trees	Number of Trees=5 Maximal Depth=5 Min rows=10 Number of bins=20 Learning rate=0.01 Sample rate=1.0
9	Deep Learning Model	Activation Ractifer Hidden layer sizes = 50 Epochs=10.0
10	Neural Networks	Hidden layer sizes = 2 Training cycles = 200 Learning rate =0.01 Momentum = 0.9

4.6 การนำไปใช้งาน (Deployment) เมื่อทำการวิเคราะห์ตามกระบวนการมาตรฐานในการทำเหมืองข้อมูลทั้ง 5 ขั้นตอนแล้ว ผู้วิจัยจะเลือกตัวแบบที่ให้ค่าความแม่นยำ และค่าประสิทธิภาพโดยรวมสูงสุด ซึ่งเหมาะสำหรับการนำไปใช้สร้างตัวแบบในการพยากรณ์การเกิดภาวะสับสนจากการขาดสุราในผู้ป่วยที่มีปัญหาติดสุราเรื้อรังที่เข้ารับการรักษาแบบผู้ป่วยในของโรงพยาบาลปากช่องขนานา



ภาพที่ 2 ขั้นตอนการสร้างต้นแบบและการวัดสมรรถนะของต้นแบบด้วยโปรแกรม RapidMiner Version 9.10

**ผลการวิจัย**

**A. ข้อมูลพื้นฐานและข้อมูลทางคลินิกของกลุ่มตัวอย่าง**

กลุ่มตัวอย่างเป็นผู้ป่วยติดสุรา จำนวน 1,960 ราย แบ่งเป็นเพศชายจำนวน 1,682 ราย (ร้อยละ 85.9) และเพศหญิงจำนวน 278 ราย (ร้อยละ 14.1) มีอายุเฉลี่ย 44.25 ปี (S.D.=11.41) ประกอบอาชีพรับจ้างจำนวน 1,419 ราย (ร้อยละ 72.4) ไม่ประกอบอาชีพจำนวน 272 ราย (ร้อยละ 13.9) และอาชีพอื่นๆ จำนวน 266 ราย (ร้อยละ 13.6) กลุ่มตัวอย่างที่ได้รับการวินิจฉัยว่ามีภาวะสับสนจากการขาดสุรา จำนวน 1,114 ราย (ร้อยละ 56.9) และไม่มีภาวะสับสนจากการขาดสุรา จำนวน 845 ราย (ร้อยละ 43.1) ข้อมูลสัญญาณชีพและผลตรวจทางห้องปฏิบัติการแรกรับ แสดงในตารางที่ 3

ตารางที่ 3 ข้อมูลทางคลินิกของกลุ่มตัวอย่าง

ข้อมูลทางคลินิก	Mean	SD
Temperature (°C)	36.9	3.7
Pulse rate (ครั้ง/นาที)	98.93	18.85
Respiratory rate (ครั้ง/นาที)	20.34	9.93
Platelet count (x10 <sup>3</sup> /UL)	191.25	104.02
Serum Potassium (mmol/L)	3.58	0.74
Serum Magnesium (mmol/L)	1.66	0.53
Serum Bicarbonate (mmol/L)	24.40	5.90
SGOT (U/L)	145.08	137.05
Serum Creatinine (mg/dl)	20.84	0.96

**B. ผลการเปรียบเทียบสมรรถนะของแบบจำลอง**

ผลการเปรียบเทียบสมรรถนะของอัลกอริทึมทั้ง 10 แบบ แสดงดังตารางที่ 4 โดยการเปรียบเทียบสมรรถนะการจำแนกประเภทข้อมูลด้วยค่าความแม่นยำ (Accuracy) พบว่า อัลกอริทึมแบบ Neural Networks อัลกอริทึมแบบ Naïve Bayes และอัลกอริทึมแบบ Gradient Boosting Trees ให้ค่าความแม่นยำในการพยากรณ์สูงสุด เท่ากับ 74.28%, 74.24%, 74.14% ตามลำดับ

ตารางที่ 4 ผลการเปรียบเทียบสมรรถนะของแบบจำลอง

Model with attribute selection	Accuracy	Precision	Sensitivity	F-measure
Decisional Trees	71.23	76.85	61.13	67.9
Bagged Decisional Trees	71.5	76.59	62.02	68.49
Boosting Decisional Trees	71.23	76.85	61.13	67.9
Gradient Boosted Trees	74.14	72.56	78.02	75.09
K-NN	68.71	69.81	67.68	68.35
Support Vector Machine	73.48	77.15	66.59	71.45
Random Forrest Model	72.35	76.62	64.37	69.86
Naïve Bayes	74.24	74.84	73.16	73.96
Neural Network	74.28	74.5	73.89	74.16
Deep Learning Model	73.61	71.31	79.62	75.11

ผลการเปรียบเทียบสมรรถนะการจำแนกประเภทข้อมูลด้วยค่าความเที่ยง (Precision) พบว่า การใช้อัลกอริทึมแบบ Support Vector Machines อัลกอริทึมแบบ Decisional Trees และ อัลกอริทึมแบบ Gradient Boosting Trees ให้ค่าความเที่ยงในการพยากรณ์สูงสุดเท่ากับ 77.15%, 76.85%, 76.85% ตามลำดับ

ผลการเปรียบเทียบสมรรถนะการจำแนกประเภทข้อมูลด้วยค่าประสิทธิภาพโดยรวม (F-measure) พบว่า การใช้อัลกอริทึมแบบ Gradient Boosting Trees อัลกอริทึมแบบ Neural Networks และอัลกอริทึมแบบ Deep Learning Model ให้ค่าความประสิทธิภาพโดยรวมในการพยากรณ์สูงสุดเท่ากับ 75.09%, 74.16%, 73.96% ตามลำดับ

ผลการเปรียบเทียบสมรรถนะการจำแนกประเภทข้อมูลด้วยความไว (Sensitivity) พบว่า การใช้อัลกอริทึมแบบ Deep Learning Model อัลกอริทึมแบบ Gradient Boosting Trees และอัลกอริทึมแบบ Neural Networks ให้ค่าความไวในการพยากรณ์สูงสุดเท่ากับ 79.62%, 78.02%, 73.89% ตามลำดับ

### อภิปรายผล

จากผลการเปรียบเทียบสมรรถนะของแบบจำลอง พบว่า อัลกอริทึมแบบ Gradient Boosting Trees และ อัลกอริทึมแบบ Neural networks ต่างก็ให้ค่าความแม่นยำ (Accuracy) และค่าประสิทธิภาพโดยรวม (F-measure) ในระดับสูงใกล้เคียงกัน แต่เมื่อพิจารณาจากชุดข้อมูลที่ใช้ในงานวิจัยซึ่งมีขนาดเล็ก และเป็นข้อมูลที่มีโครงสร้าง (Structural Data) การเลือกใช้อัลกอริทึมแบบ Gradient Boosting Trees จึงมีความเหมาะสมกว่า เนื่องด้วยคุณสมบัติของแบบจำลองดังกล่าวซึ่งมีความสามารถในการเข้าใจ (Interpretability) ที่ดีกว่า ใช้เวลาการฝึกแบบจำลอง (Training Speed) ที่เร็วกว่า การควบคุมปัญหาการเกิด Overfitting และการปรับแต่งค่าไฮเปอร์พารามิเตอร์ (Hyperparameter Tuning) ทำได้ง่ายกว่า รวมถึงความสามารถของแบบจำลองเองในการรักษาสมรรถนะของการทำนายแม้จะมีข้อมูลที่มีผิดพลาด (Noise) ซึ่งทำได้ดีกว่า [12], [13]

ผลการศึกษามีความสอดคล้องกับงานวิจัยก่อนหน้านี้ โดยผลการศึกษาของ Gupta et al. (2022) ซึ่งสรุปว่า แบบจำลองการเรียนรู้จากเครื่องโดยเฉพาะแบบจำลองแบบ Gradient Boosting Trees มีความแม่นยำสูง สามารถนำมาใช้ระบุผู้ป่วยที่มีความเสี่ยงสูงในการเกิดภาวะเพื่อสับสนจากการขาดสุรา (Delirium Tremens) และช่วยในการตัดสินใจทางคลินิกเพื่อลดการเกิดภาวะดังกล่าวได้ดี [14] เช่นเดียวกับการศึกษาของ Weinreb et al. (2021) ซึ่งสรุปว่า แบบจำลองแบบ Gradient Boosting Trees มีความแม่นยำสูงที่สุดในการจัดกลุ่มผู้ป่วยตามความเสี่ยงในการเกิดภาวะเพื่อสับสนจากการขาดสุรา (Delirium Tremens) [15] ซึ่งค่าแม่นยำของแบบจำลองในงานวิจัยนี้ที่มีความแตกต่างจากการศึกษาก่อนหน้านี้ อาจเป็นจากปัญหาเรื่องคุณภาพข้อมูลเวชระเบียนในโรงพยาบาล ซึ่งประกอบด้วยความไม่สมบูรณ์ของข้อมูล (Data Completeness) ความไม่ถูกต้องของข้อมูล (Data Accuracy) และความผิดพลาดจากการป้อนข้อมูล (Data Entry Errors) นำมาสู่ขั้นตอนการเตรียมข้อมูลทางการแพทย์และเวชระเบียน (Data Preparation) ที่ยังขาดความแม่นยำและความน่าเชื่อถือเท่าที่ควร นอกจากนี้ การวิจัยในอนาคตที่พัฒนาตัวแบบโดยศึกษาตัวแปรบางตัวที่ไม่ได้รับคัดเลือกให้เป็นตัวแปรพยากรณ์ในงานวิจัยนี้ แต่ได้รับการพิสูจน์จากการศึกษาก่อนหน้านี้ว่า

เป็นปัจจัยเสี่ยงในการเกิดภาวะเพื่อสับสนจากการขาดสุรา (Delirium Tremens) เช่น ปริมาณและระยะเวลาของการดื่มสุรา รอยโรคในสมอง (Structural Brain Lesion) ภาวะบกพร่องทางปัญญา (Cognitive impairment) เป็นต้น [16], [17] อาจช่วยเพิ่มค่าความแม่นยำ (Accuracy) และค่าประสิทธิภาพโดยรวม (F-measure) ของแบบจำลองให้มากขึ้น

ผลการศึกษานี้ยังมีความแตกต่างกับการศึกษาก่อนหน้านี้ของ Malec et al. (2020) ซึ่งสรุปว่า Random Forest Classifiers สามารถทำนายความรุนแรงของกลุ่มอาการเนื่องจากการขาดสุราได้อย่างแม่นยำสูง โดยอิงจากลักษณะของผู้ป่วยที่ได้จากเวชระเบียนอิเล็กทรอนิกส์ (EHRs) [18] รวมถึงการศึกษาของ Gupta et al. (2022) ซึ่งสรุปว่า แบบจำลองชนิด Recurrent Neural Networks (RNNs) สามารถทำนายความรุนแรงของอาการถอนสุราแบบพลวัต นำมาสู่การปรับวิธีการรักษาที่เหมาะสม และสามารถช่วยลดความจำเป็นในการใช้ยากกลุ่ม Benzodiazepines ในระยะเวลาสั้นได้ [14] โดยความแตกต่างของผลลัพธ์อาจเป็นจากความไม่เป็นเอกพันธ์ (Heterogeneity) และปัญหาคุณภาพของข้อมูล เนื่องจากข้อมูลของกลุ่มตัวอย่างในแต่ละงานวิจัยมีที่มาจากแหล่งข้อมูลต่างกัน เช่น เวชระเบียนอิเล็กทรอนิกส์ (EHRs), อุปกรณ์สวมใส่บนร่างกาย (Wearable Devices) ข้อมูลเชิงเจตพิสัย (Subjective Data) เป็นต้น อีกทั้งแบบจำลองส่วนใหญ่ในแต่ละงานวิจัย มักถูกฝึกจากชุดข้อมูลที่มาจกศูนย์การแพทย์เพียงแห่งเดียว ซึ่งอาจเป็นข้อจำกัดที่สำคัญในเรื่องความสามารถของการนำแบบจำลองไปประยุกต์ใช้กับกลุ่มประชากรที่มีความหลากหลาย (Generalization)

เนื่องจากขนาดตัวอย่างและจำนวนแอตทริบิวต์ที่นำมาวิเคราะห์ของงานวิจัยนี้มีจำนวนไม่มาก จึงมีข้อจำกัดในการนำผลสรุปของงานวิจัยไปใช้กับข้อมูลที่มีแอตทริบิวต์อื่น ๆ ที่ไม่ได้ปรากฏในงานวิจัยนี้ ดังนั้นเพื่อให้ได้ผลการวิจัยมีความครอบคลุมและน่าเชื่อถือยิ่งขึ้น งานวิจัยในอนาคตอาจพิจารณาเพิ่มขนาดของกลุ่มตัวอย่าง และเพิ่มการเปรียบเทียบสมรรถนะของอัลกอริทึมการทำเหมืองข้อมูลชนิดอื่น โดยเฉพาะเทคนิคการเรียนรู้ร่วมกัน (Ensemble Learning) เช่น Voting, Stacked Generalization (Stacking) เป็นต้น [19] เพื่อให้แบบจำลองมีสมรรถนะที่ดีกว่าการใช้แบบจำลองที่ใช้ต้นไม่เพียงลำพัง สามารถลดความแปรปรวนและลดอคติได้ นอกจากนี้ควรมีการศึกษาเพิ่มเติมเพื่อวิเคราะห์และระบุปัจจัยเสี่ยงที่สำคัญต่อการเกิดภาวะเพื่อสับสนจากการขาดสุรา (Delirium Tremens) โดยอาศัยแบบจำลองที่พัฒนาขึ้นจากการวิจัยนี้ ซึ่งอาจใช้เทคนิคการวิเคราะห์ความสำคัญของคุณลักษณะ (Feature Importance) เพื่อแสดงผลกระทบของแต่ละตัวแปร เช่น ค่า Gini Importance หรือ Mean Decrease in

Impurity, ค่า Permutation Importance, SHAP Values เป็นต้น ซึ่งช่วยในการปรับปรุงการตีความแบบจำลอง ลดการเกิดปรากฏการณ์ Overfitting ลดข้อมูลที่มีข้อผิดพลาด (Noise) ทำให้การฝึกแบบจำลองทำงานได้รวดเร็วขึ้น และมีผลการทำนายที่ดีขึ้น<sup>[20]</sup> ผลลัพธ์ที่ได้จะช่วยให้เกิดความเข้าใจที่ลึกซึ้งเกี่ยวกับปัจจัยเสี่ยงของภาวะเพื่อสับสนจากการขาดสุรา (Delirium Tremens) ซึ่งจะเป็นประโยชน์ต่อวางแผนการป้องกันภาวะดังกล่าวต่อไป

การนำแบบจำลองที่พัฒนาขึ้นจากการศึกษานี้ไปใช้ในการพยากรณ์การเกิดภาวะเพื่อสับสนจากการขาดสุรา (Delirium Tremens) ควรมีการติดตามและประเมินผลอย่างต่อเนื่องเพื่อปรับปรุงสมรรถนะของแบบจำลอง ให้สอดคล้องกับบริบทและความต้องการของแต่ละสถานพยาบาล รวมถึงการฝึกอบรมบุคลากรทางการแพทย์ที่เกี่ยวข้องให้สามารถใช้งานและแปลผลแบบจำลองได้อย่างถูกต้องและมีประสิทธิภาพ

### สรุปผลการวิจัย

จากการเปรียบเทียบสมรรถนะของอัลกอริทึมของการทำเหมืองข้อมูลสำหรับการพยากรณ์การเกิดภาวะสับสนจากการขาดสุราครั้งนี้ ด้วยเกณฑ์การวัดสมรรถนะทั้ง 4 ค่า ได้แก่ ค่าความแม่นยำ (Accuracy) ค่าความเที่ยง (Precision) ค่าประสิทธิภาพโดยรวม (F-measure) และค่าความไว (Sensitivity) พบว่า อัลกอริทึมแบบ Gradient Boosting Trees เป็นอัลกอริทึมที่มีความเหมาะสมที่สุดในการสร้างแบบจำลองสำหรับการพยากรณ์การเกิดภาวะสับสนจากการขาดสุรา โดยให้ค่าความแม่นยำสูงสุดประมาณ 74.14% ค่าประสิทธิภาพโดยรวมประมาณ 75.09% และค่าความไว เท่ากับ 78.02% ซึ่งแบบจำลองดังกล่าวสามารถใช้จัดการกับข้อมูลที่มีหลายตัวแปรได้เป็นอย่างดี ไม่มีความซับซ้อนในการวิเคราะห์ และอ่านผลลัพธ์ได้ง่าย

การใช้แบบจำลองการทำนายภาวะสับสนจากการขาดสุราช่วยเพิ่มประสิทธิภาพในการดูแลผู้ป่วยที่มีความเสี่ยงสูง เพิ่มความปลอดภัยในการรักษา และลดโอกาสเกิดภาวะแทรกซ้อนที่รุนแรง ทำให้การรักษาภาวะติดสุรามีประสิทธิภาพและความปลอดภัยมากยิ่งขึ้น

อย่างไรก็ตาม ก่อนนำแบบจำลองไปใช้งานจริง ควรมีการศึกษาเพิ่มเติมเกี่ยวกับการเป็นไปได้ในการพัฒนาและการบูรณาการเข้ากับระบบสารสนเทศของสถานพยาบาล รวมถึงการฝึกอบรมบุคลากรทางการแพทย์ ให้สามารถใช้ระบบและอ่านผลลัพธ์ได้อย่างถูกต้อง นอกจากนี้ ควรมีการติดตามและประเมินสมรรถนะของผลการใช้ระบบในสถานการณ์จริงอย่างต่อเนื่อง เพื่อสามารถปรับปรุงและพัฒนาระบบให้ตอบสนองต่อบริบทและความต้องการของสถานพยาบาลได้

### กิตติกรรมประกาศ

ขอขอบพระคุณ รศ.ดร.นพ. วรวิภา เปาอินทร์ สำหรับคำสอน คำแนะนำ ให้คำปรึกษาในการเขียนบทความนี้ และขอขอบพระคุณ นพ.รังชัย เขมรัตน์ตระกูล ผู้อำนวยการโรงพยาบาลปากช่องนานา ที่ให้การสนับสนุน และทีมบุคลากรจากศูนย์เทคโนโลยีสารสนเทศที่ช่วยจัดหาข้อมูลเพื่อมาใช้ในการศึกษาครั้งนี้

**เอกสารอ้างอิง**

- [1] A. D. Kaye et al., "Delirium Tremens: A Review of Clinical Studies," *Cureus*, vol. 16, no. 4, p. e57601, doi: 10.7759/cureus.57601.
- [2] A. Rahman and M. Paul, "Delirium Tremens," in *StatPearls*, Treasure Island (FL): StatPearls Publishing, 2024. Accessed: Sep. 14, 2024. [Online]. Available: <http://www.ncbi.nlm.nih.gov/books/NBK482134/>
- [3] "Mortality and alcohol-related morbidity in patients with delirium tremens, alcohol withdrawal state or alcohol dependence in Norway: A register-based prospective cohort study - Bramness - 2023 - Addiction - Wiley Online Library." Accessed: Sep. 14, 2024. [Online]. Available: <https://onlinelibrary.wiley.com/doi/10.1111/add.16297>
- [4] J. Han and M. Kamber, *Data mining: concepts and techniques*, 2nd ed. in *The Morgan Kaufmann series in data management systems*. Amsterdam ; Boston : San Francisco, CA: Elsevier ; Morgan Kaufmann, 2006.
- [5] G. Burkhardt et al., "A machine learning approach to risk assessment for alcohol withdrawal syndrome," *Eur. Neuropsychopharmacol.*, vol. 35, pp. 61–70, Jun. 2020, doi: 10.1016/j.euroneuro.2020.03.016.
- [6] M. L. Kolling et al., "Data Mining in Healthcare: Applying Strategic Intelligence Techniques to Depict 25 Years of Research Development," *Int. J. Environ. Res. Public Health*, vol. 18, no. 6, p. 3099, Mar. 2021, doi: 10.3390/ijerph18063099.
- [7] Kawasaki, Y., "Trends and Challenges in Data Mining Research in Southeast Asia," *Asian J. Data Min.*, vol. 3, no. 2, pp. 45–49, 2021.
- [8] D. C. To et al., "Alcohol Withdrawal Severity Measures for Identifying Patients Requiring High-Intensity Care," *Crit. Care Explor.*, vol. 6, no. 3, p. e1066, Mar. 2024, doi: 10.1097/CCE.0000000000001066.
- [9] J. R. Maldonado, "Delirium in the acute care setting: characteristics, diagnosis and treatment," *Crit. Care Clin.*, vol. 24, no. 4, pp. 657–722, vii, Oct. 2008, doi: 10.1016/j.ccc.2008.05.008.
- [10] S. Grover and A. Ghosh, "Delirium Tremens: Assessment and Management," *J. Clin. Exp. Hepatol.*, vol. 8, no. 4, pp. 460–470, Dec. 2018, doi: 10.1016/j.jceh.2018.04.012.
- [11] "Ensuring the Robustness and Reliability of Data-Driven Knowledge Discovery Models in Production and Manufacturing - PMC." Accessed: Sep. 14, 2024. [Online]. Available: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC8236533/>
- [12] L. B. Iantovics, "Comparative Study of Random Forest, Gradient Boosted Trees, Feedforward Neural Networks and Convolutional Neural Networks using Fingerprints and Molecular Descriptors for Adverse Drug Reaction Prediction," Jan. 2024.
- [13] S. Gupta, K. Saluja, A. Goyal, A. Vajpayee, and V. Tiwari, "Comparing the performance of machine learning algorithms using estimated accuracy," *Meas. Sens.*, vol. 24, p. 100432, Dec. 2022, doi: 10.1016/j.measen.2022.100432.
- [14] Gupta et al., "Personalized treatment of alcohol withdrawal syndrome using machine learning: A case study," *Artif. Intell. Med.*, vol. 127, no. 102163, 2022.
- [15] Weinreb et al., "Machine learning to predict risk of alcohol withdrawal syndrome in hospitalized patients," *J. Subst. Abuse Treat.*, vol. 120, no. 108201, 2021.
- [16] "Predisposing and Precipitating Factors Associated With Delirium: A Systematic Review | Neurology | JAMA Network Open | JAMA Network." Accessed: Sep. 15, 2024. [Online]. Available: <https://jamanetwork.com/journals/jamanetworkopen/fullarticle/2800112>
- [17] S. Sarkar, S. Choudhury, G. Ezhumalai, and J. Konthoujam, "Risk factors for the development of delirium in alcohol dependence syndrome: Clinical and neurobiological implications," *Indian J. Psychiatry*, vol. 59, no. 3, pp. 300–305, 2017, doi: 10.4103/psychiatry.IndianJPsychiatry\_67\_17.
- [18] Malec et al., "Machine learning in the prediction of alcohol withdrawal syndrome severity," *J. Med. Toxicol.*, vol. 16, no. 2, pp. 165–171, 2020.
- [19] A. Mohammed and R. Kora, "A comprehensive review on ensemble deep learning: Opportunities and challenges," *J. King Saud Univ. - Comput. Inf. Sci.*, vol. 35, no. 2, pp. 757–774, Feb. 2023, doi: 10.1016/j.jksuci.2023.01.014.
- [20] T. Parr, J. Hamrick, and J. D. Wilson, "Nonparametric feature impact and importance," *Inf. Sci.*, vol. 653, p. 119563, Jan. 2024, doi: 10.1016/j.ins.2023.119563.