

การจำแนกฐานความผิดในคดียาเสพติดด้วยการเรียนรู้ของเครื่อง

Classification of offences in narcotic cases using machine learning

สุทัศน์ แท่นทอง^{1*} และวารัญญา ปุณณวัฒน์²

Suthat Tanthong^{1*} and Waranya Poonnawat²

Received: 6 February 2025 ; **Revised:** 11 May 2025 ; **Accepted:** 14 July 2025

บทคัดย่อ

การพิจารณาเอกสารคำฟ้องในคดียาเสพติดต้องใช้เวลาและความรอบคอบ ซึ่งเป็นอุปสรรคต่อการทำงานของเจ้าหน้าที่ การนำเทคโนโลยีการเรียนรู้ของเครื่องช่วยจำแนกข้อความในเอกสารคำฟ้อง เพื่อแยกประเภทฐานความผิด สามารถลดภาระการอ่านและเพิ่มประสิทธิภาพการดำเนินงานในกระบวนการยุติธรรมให้รวดเร็วและเป็นอัตโนมัติได้ ด้วยเหตุนี้ งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อพัฒนาและประเมินประสิทธิภาพแบบจำลองการจำแนกฐานความผิดในคดียาเสพติดด้วยการเรียนรู้ของเครื่อง โดยดำเนินการ 5 ขั้นตอน ได้แก่ 1) รวบรวมข้อมูลคดียาเสพติดจากศาลจังหวัดสุพรรณบุรี 1,651 ตัวอย่าง (ม.ค. 2565 – พ.ค. 2567) 2) สำรวจข้อมูล 3) เตรียมข้อมูลด้วย PyThaiNLP และ TF-IDF 4) พัฒนาแบบจำลองการจำแนกฐานความผิด แบ่งเป็น 2 ลำดับชั้น ได้แก่ ลำดับที่ 1 จำแนกชนิดยาเสพติด ใช้วิธีจำแนกประเภทแบบหลายคลาส กลยุทธ์ OneVsRest และลำดับที่ 2 จำแนกลักษณะการกระทำความผิด ใช้วิธีจำแนกประเภทแบบหลายป้าย กลยุทธ์ Classifier Chains 5) ทั้งสองลำดับเปรียบเทียบประสิทธิภาพระหว่าง 3 เทคนิค ได้แก่ SVM, Logistic Regression และ Random Forest โดยทดสอบแบบจำลองด้วยวิธี 5-Fold cross validation พบว่า Random Forest มีประสิทธิภาพและเสถียรภาพสูงสุดในการจำแนกทั้งสองลำดับ โดยลำดับที่ 1 ได้ค่า F1-Score ร้อยละ 99.55 และลำดับที่ 2 ได้ค่า F1-Score ร้อยละ 97.70 พร้อมค่า Hamming loss ร้อยละ 1.58 ซึ่งแสดงให้เห็นว่าแบบจำลองมีศักยภาพสูงและสามารถนำไปประยุกต์ใช้ในการจำแนกฐานความผิดในคดียาเสพติดได้

คำสำคัญ: การเรียนรู้ของเครื่อง, การจำแนกข้อความ, การประมวลผลภาษาธรรมชาติ, คดียาเสพติด

Abstract

The examination of indictments in narcotic cases requires considerable time and attention to detail, posing challenges for judicial officers. This study aimed to reduce such burdens and enhance the efficiency of the justice process. Therefore, the objective of this research was to develop and evaluate the performance of a machine learning model for classifying offences in narcotic cases. The research consisted of five main steps: (1) collecting 1,651 narcotic case samples from the Suphanburi Provincial Court (January 2022 – May 2024), (2) exploring the dataset, (3) preprocessing the data using PyThaiNLP and TF-IDF, (4) developing a two-stage classification model, where stage one classified narcotic types using a multi-class classification with a One-vs-Rest strategy, and stage two classified the nature of the offence using a multi-label classification with a Classifier Chains strategy, and (5) evaluating the model performance using three algorithms (Support Vector Machine, Logistic Regression, and Random Forest) via 5-fold cross-validation. The results indicated that the Random Forest algorithm achieved the highest performance and stability in both stages, with an F1-score of 99.55% for stage one and 97.70% for stage two, along with a Hamming Loss of 1.58%. These findings demonstrate the potential of the proposed model in assisting the classification of offences in narcotic cases.

Keywords: Machine learning, text classification, natural language processing, narcotic cases

¹ แขนงวิชาเทคโนโลยีดิจิทัล สาขาวิชาวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยสุโขทัยธรรมาธิราช

² รองศาสตราจารย์ สาขาวิชาวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยสุโขทัยธรรมาธิราช

¹ Digital Technology Program, School of Science and Technology, Sukhothai Thammathirat Open University

² Associate Professor, School of Science and Technology, Sukhothai Thammathirat Open University

* Corresponding author; E-mail: suthat.tanthong@gmail.com

บทนำ

ประมวลกฎหมายยาเสพติด (2564) มีผลบังคับใช้ตั้งแต่ 9 พฤศจิกายน 2564 โดยปรับปรุงแนวทางแก้ปัญหา ยาเสพติดอย่างเป็นระบบ ส่งเสริมความร่วมมือระหว่างภาครัฐและเอกชน ให้มีความสำคัญกับการบำบัดรักษามากกว่าการลงโทษอย่างเข้มงวด และพิจารณาปัจจัยเฉพาะบุคคลเพื่อให้บทลงโทษสอดคล้องกับลักษณะการกระทำความผิด สำนักงานศาลยุติธรรมจึงได้ปรับปรุงระบบสารสนเทศสำนวนคดีศาลชั้นต้น (CIMS) ให้รองรับการจัดเก็บรายละเอียดคดียาเสพติดที่ครอบคลุม ชัดเจนขึ้น และสอดคล้องกับประมวลกฎหมายยาเสพติด พ.ศ.2564

ศาลจังหวัดสุพรรณบุรีเป็นศาลชั้นต้น มีบทบาทสำคัญในการบังคับใช้ประมวลกฎหมายยาเสพติดดังกล่าว กระบวนการดำเนินงานเริ่มจาก เจ้าหน้าที่ศาลรับเอกสารการยื่นฟ้องจากพนักงานอัยการ ตรวจสอบและอ่านคำฟ้องเพื่อวิเคราะห์ฐานความผิดในคดียาเสพติด จากนั้นจึงบันทึกข้อมูลเข้าสู่ระบบ CIMS โดยแบ่งการจำแนกออกเป็น 2 ลำดับ ได้แก่ (1) ชนิดของยาเสพติด เช่น เฮโรอีน กัญชา หรือเมทแอมเฟตามีน และ (2) ลักษณะการกระทำความผิด เช่น การเสพ การครอบครอง หรือการจำหน่าย ข้อมูลนี้มีบทบาทสำคัญต่อกระบวนการพิจารณาคดีและการวิเคราะห์สถิติคดีของศาลยุติธรรม และเพื่อเพิ่มประสิทธิภาพหน่วยงานในกระบวนการยุติธรรม ศาลยุติธรรมได้ร่วมลงนามข้อตกลงความร่วมมือกับสำนักงานอัยการสูงสุด โดยเชื่อมโยงข้อมูลคดีผ่านระบบ CIMS (สำนักส่งเสริมงานตุลาการ, 2566) ทำให้เจ้าหน้าที่ศาลสามารถดาวน์โหลดไฟล์คำฟ้องอิเล็กทรอนิกส์ในรูปแบบเอกสาร Word ได้ทันทีนอกเหนือจากเอกสารฉบับจริงแบบกระดาษ ซึ่งช่วยให้ศาลนำไฟล์ไปใช้ประโยชน์ในด้านอื่นได้ แต่อย่างไรก็ตาม ขั้นตอนการจำแนกฐานความผิดในคดียาเสพติด เจ้าหน้าที่ยังคงต้องอาศัยทักษะ ความชำนาญ และเวลาในการอ่านคำฟ้องที่มีรายละเอียดจำนวนมาก เพื่อวิเคราะห์ผลจำแนกตามเดิม ดัง Figure 1 ขณะที่จำนวนเจ้าหน้าที่มีจำกัดและต้องปฏิบัติงานอื่นควบคู่ไปด้วย เช่น การสอบคำให้การ การเบิกตัวผู้ต้องขัง และการรายงานคดี

จากการศึกษา พบว่าเทคนิคการเรียนรู้ของเครื่องได้รับความนิยมอย่างกว้างขวาง และถูกนำมาใช้เพื่อเพิ่มความสะดวกและประสิทธิภาพในการทำงานมากขึ้น โดยเฉพาะในด้านการจำแนกข้อความ ซึ่งสามารถลดภาระงานที่ต้องใช้เวลามากและงานที่ต้องการความแม่นยำสูงได้ดี (Naseeba *et al.*, 2023)

ดังนั้น งานวิจัยนี้เสนอการพัฒนาแบบจำลองเพื่อจำแนกฐานความผิดในคดียาเสพติด โดยประยุกต์เทคนิคการ

เรียนรู้ของเครื่อง ใช้ข้อมูลจากไฟล์คำฟ้องในการฝึกแบบจำลองให้จำแนกฐานความผิดแบบลำดับขั้นตามระบบ CIMS พร้อมศึกษาและเปรียบเทียบประสิทธิภาพของอัลกอริทึม 3 เทคนิคที่ได้รับการยอมรับว่ามีประสิทธิภาพสูงจากงานวิจัยที่ผ่านมา รวมถึงเลือกกลยุทธ์และพารามิเตอร์ที่เหมาะสมในการจัดการความซับซ้อนของปัญหาการจำแนกชนิดยาเสพติดหลายชนิด และจำแนกลักษณะการกระทำความผิดที่อาจมีหลายความผิด เพื่อพัฒนาแบบจำลองที่มีประสิทธิภาพสูงสุด ซึ่งสามารถนำไปสนับสนุนการดำเนินงานของศาลยุติธรรมให้มีความรวดเร็วและเป็นระบบมากขึ้น ตามแนวคิดที่แสดงใน Figure 2

วัตถุประสงค์ของการวิจัย

1. เพื่อพัฒนาแบบจำลองการจำแนกฐานความผิดในคดียาเสพติดด้วยการเรียนรู้ของเครื่อง
2. เพื่อประเมินประสิทธิภาพแบบจำลองการจำแนกฐานความผิดในคดียาเสพติดด้วยการเรียนรู้ของเครื่อง




Figure 1 Current process of narcotic case filing in court



Figure 2 Conceptual overview of automated narcotic case classification

นิยามศัพท์เฉพาะ

1. ระบบสารสนเทศสำนวนคดีศาลชั้นต้น (Court Information Management System: CIMS) เป็นโปรแกรมจัดการสำนวนคดีของศาลชั้นต้นทั่วประเทศ และรองรับการเชื่อมโยงข้อมูลระหว่างหน่วยงาน

2. การจำแนกฐานความผิดในคดียาเสพติดเป็นการจัดประเภทความผิดอย่างเป็นระบบ แบ่งเป็น การจำแนกชนิดยาเสพติด (เช่น ยาบ้า ยาไอซ์ กัญชา) ซึ่งมีบทลงโทษต่างกัน และการจำแนกลักษณะการกระทำความผิด (เช่น ครอบครอง เสพ จำหน่าย ผลิต) โดยโทษพิจารณาร่วมกับชนิดยาเสพติด

พฤติกรรม และปริมาณ การจัดประเภทนี้ช่วยให้การพิจารณา คติและการกำหนดบทลงโทษเป็นไปอย่างเหมาะสมและ แม่นยำยิ่งขึ้น

งานวิจัยที่เกี่ยวข้อง

จากงานวิจัยเกี่ยวกับการจำแนกข้อความด้วยเทคนิค การเรียนรู้ของเครื่อง พบเทคนิคที่หลากหลายสามารถนำมา ใช้แก้ปัญหาที่มีความซับซ้อนได้อย่างมีประสิทธิภาพ ตัวอย่าง เช่น งานวิจัยของ วรวรรณ วันดี (2564) ซึ่งนำเสนอการจำแนก ข้อความโดยใช้ชื่อเรื่องและสารบรรณของหนังสือ ภายใต้โครงสร้าง การจำแนกแบบลำดับชั้น (Hierarchical Text Classification) ซึ่งแนวทางดังกล่าวสอดคล้องและเหมาะสมกับการจำแนกฐาน ความผิดในคดีอาชญากรรมจากไฟล์คำฟ้องอิเล็กทรอนิกส์ โดย แบ่งวิธีการจำแนกออกเป็นสองลำดับ ได้แก่ ลำดับแรก จำแนก ชนิดของอาชญากรรมในรูปแบบการจำแนกแบบหลายคลาส (Multi-class Classification) โดยอ้างอิงแนวทางของ เทวัญ เทียนวัน (2566) ซึ่งนำเสนอกลยุทธ์ One-vs-Rest (OvR) เพื่อแปลงปัญหาให้เป็นชุดการจำแนกสองคลาส และเลือกตัว จำแนกที่ให้คะแนนความมั่นใจสูงสุดมาใช้ในการตัดสินใจผลลัพธ์ ส่วนลำดับที่สอง จำแนกลักษณะการกระทำความผิดในรูปแบบ การจำแนกแบบหลายป้าย (Multi-label Classification) โดย อาศัยวิธีการแปลงปัญหา (Problem Transformation Methods) ที่มีการนำเสนอโดย จินตริย์ พุทธิพรชัย (2565) และ Morales-Hernández *et al.* (2022) เช่น กลยุทธ์ Classifier Chain เพื่อ เชื่อมโยงและประเมินความสัมพันธ์ระหว่างป้ายในกระบวนการ จำแนกได้อย่างมีประสิทธิภาพ เหมาะสมกับบริบทของงาน วิจัยนี้ เช่น หากลำดับที่ 1 ทำนายชนิดอาชญากรรมเป็นสารตั้ง ต้นสำหรับผิดอาชญากรรม การเชื่อมโยงลำดับที่ 2 ก็จะมีโอกาส เป็นไปได้สูงที่จะทำนายเป็นป้าย ผิด หรือจำแนก ส่วนป้าย เสพ ก็จะมีโอกาสเป็นไปได้น้อย

นอกจากนี้ หลายงานวิจัยยังเน้นย้ำบทบาทของการ ประมวลผลภาษาธรรมชาติ (NLP) ซึ่งเป็นแขนงหนึ่งของ ปัญญาประดิษฐ์ที่ช่วยให้ระบบเข้าใจและจัดการข้อความได้ อย่างมีประสิทธิภาพ (กัญญารัตน์ พูลเพิ่ม และแกมกาญจน์ สมประเสริฐศรี, 2565; Mahdi *et al.*, 2024; Rizqi *et al.*, 2025) โดยกระบวนการนี้ประกอบด้วยการทำความสะอาดข้อมูล เช่น การลบอักขระพิเศษ อีโมจิ คำหยุด การสร้างคลังคำศัพท์และ การตัดคำ ทั้งนี้ สุภัทรรักษ์ณ์ โพธิ์หา (2565) และเทวัญ เทียนวรรณ (2566) ได้นำเสนอการใช้ไลบรารี PyThaiNLP ร่วมกับการปรับ พารามิเตอร์ของอัลกอริทึม newmm (ไพชยนต์ คงไชย, 2565) ซึ่งได้แสดงให้เห็นถึงประสิทธิภาพที่รวดเร็วในการตัดคำภาษา ไทย และขณะเดียวกัน การแปลงข้อความเป็นเวกเตอร์ด้วย

การหาคำนวณน้ำหนักของคำตามความสำคัญด้วยเทคนิค Term Frequency-Inverse Document Frequency (TF-IDF) นั้น ได้รับการยืนยันว่าเป็นเครื่องมือสำคัญที่ช่วยเพิ่มความแม่นยำ ของการจำแนกข้อความ ดังปรากฏในงานวิจัยของ Memoon *et al.* (2024) และ Sinha *et al.* (2022) นอกจากนี้ งานวิจัย ของ ไพชยนต์ คงไชย (2565) ยังแสดงให้เห็นว่า แม้การเรียนรู้ เชิงลึกจะมีความแม่นยำสูงกว่าเล็กน้อย แต่การเรียนรู้ของ เครื่องยังคงมีประสิทธิภาพเพียงพอในการจำแนกข้อความที่ ซับซ้อน และใช้ทรัพยากรในการประมวลผลน้อยกว่ามาก

เมื่อพิจารณาจากข้อจำกัดด้านทรัพยากรและปริมาณ ข้อมูลในครั้งนี้ ผู้วิจัยจึงเลือกพัฒนาแบบจำลองด้วยเทคนิคการ เรียนรู้ของเครื่อง โดยเปรียบเทียบประสิทธิภาพของอัลกอริทึม ที่ได้รับการยอมรับจากงานวิจัยเกี่ยวกับการจำแนกข้อความที่ ผ่านมา 3 เทคนิค ได้แก่ Support Vector Machine (SVM), Logistic Regression และ Random Forest




Figure 3 Overview of research methodology

วิธีดำเนินการวิจัย

การวิจัยนี้เน้นการพัฒนาและประเมินประสิทธิภาพ ของแบบจำลองการจำแนกฐานความผิดในคดีอาชญากรรม โดยประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่องผ่านการพัฒนา

โปรแกรมด้วยภาษา Python และไลบรารีที่เกี่ยวข้อง ได้แก่ Docx2txt สำหรับแปลงไฟล์เอกสาร Word ให้เป็นข้อความ PyThaiNLP สำหรับการประมวลผลข้อความภาษาไทย และ Scikit-learn สำหรับการสร้างและประเมินแบบจำลองกระบวนการดำเนินงานแบ่งออกเป็น 5 ขั้นตอนดัง Figure 3 ได้แก่

1. การรวบรวมข้อมูล

เก็บข้อมูลจากระบบ CIMS ของศาลจังหวัดสุพรรณบุรี โดยเลือกคดียาเสพติดที่มีฐานความผิดเกี่ยวกับยาเสพติดชนิดเดียวต่อคดี เนื่องจากคดีที่มีข้อหาหลายชนิดพบจำนวนน้อย และการจำแนกลำดับที่ 1 (ชนิดยาเสพติด) มีผลต่อการจำแนกลำดับที่ 2 (ลักษณะการกระทำความผิด) เนื่องจากลักษณะคำตอบของป้ายแต่ละชนิดยาเสพติดมีความคล้ายคลึงกัน จึงจำเป็นต้องใช้ปริมาณคดีที่เพียงพอในการจำแนกที่มีความซับซ้อนมากขึ้น ข้อมูลที่ใช้ในการศึกษารวบรวมระหว่างวันที่ 1 มกราคม 2565 ถึง 31 พฤษภาคม 2567 ซึ่งประกอบด้วยข้อมูล 2 ส่วน ได้แก่

- 1) ข้อมูลคดียาเสพติดในรูปแบบไฟล์ JSON จำนวน 1 ไฟล์ มีข้อมูลคดี 1,651 ระเบียบ ซึ่งได้คิวรีและส่งออกไปไฟล์จากฐานข้อมูลโอราเคิลของระบบ CIMS
- 2) เอกสารคำฟ้องในรูปแบบไฟล์เวิร์ด (Word) จำนวน 1,651 ไฟล์ ดาวน์โหลดจากระบบ CIMS

```

{} ExportFile.json X
D: > python3 > project > AGO > json_files > {} ExportFile.json > ...
16 {
18   "AGO_FILE_LINK": "3260_248_234_2566_106_1_20230217",
19   "LABEL_H1": [
20     {
21       "ALLEGATION_NAME": "ประมวลกฎหมายยาเสพติด (เฮโรอีน)",
22       "LABEL_H2": [
23         {
24           "SUB_TYPE_NAME": "ครอบครอง"
25         },
26         {
27           "SUB_TYPE_NAME": "เสพ"
28         },
29         {
30           "SUB_TYPE_NAME": "จำหน่าย"
31         }
32       ]
33     }
34   ]

```

Figure 4 Example of JSON data

Table 1 Description of attributes in the JSON file

Attribute name	Description
AGO_FILE_LINK	Document Link
ALLEGATION_NAME	Main charge
SUB_TYPE_NAME	Alternative charge



Figure 5 Example of file content in a narcotic case official document (Word)

จาก Figure 4 แสดงตัวอย่างข้อมูลคดีจากไฟล์ JSON ส่วน Table 1 สรุปคุณลักษณะของข้อมูล และ Figure 5 แสดงตัวอย่างเอกสารคำฟ้องจากไฟล์ Word

การรวมข้อมูลดำเนินการโดยใช้ไลบรารี Pandas อ่านข้อมูลคดีจากไฟล์ JSON และไลบรารี Docx2txt อ่านข้อความจากเอกสาร Word เพื่อแปลงและจัดเก็บข้อมูลเป็นดาต้าเฟรม (Data frame) โดยใช้ความสัมพันธ์ระหว่างแหล่งข้อมูลทั้งสองผ่านรหัสชื่อไฟล์คำฟ้องและรหัส AGO_FILE_LINK ซึ่งประกอบด้วย 3 คุณลักษณะสำคัญที่ใช้ในการศึกษาดังแสดงใน Table 2

Table 2 Description of attributes in the data frame

Attribute name	Data source
DOCX_TEXT	Word (Text document)
LABEL_LEVEL1	JSON (ALLEGATION_NAME)
LABEL_LEVEL2	JSON (SUB_TYPE_NAME)

2. การสำรวจข้อมูล

ทำความเข้าใจลักษณะข้อมูลและตรวจสอบโครงสร้างและข้อมูลพื้นฐาน หมวดหมู่ และการกระจายตัวของข้อมูล เพื่อหาข้อมูลที่ผิดปกติและความสัมพันธ์ระหว่างข้อมูล

จากตารางอาศัยค่าพื้นฐาน ได้แก่

True Positive (TP: ทำนายผลบวกถูกต้อง)

True Negative (TN: ทำนายผลลบถูกต้อง)

False Positive (FP: ทำนายผลบวกผิด)

False Negative (FN: ทำนายผลลบผิด)

เพื่อประเมินค่า Accuracy, Precision, Recall และ

F1-Score โดยคำนวณได้ตั้งสมการที่ 4, 5, 6 และ 7 ตามลำดับ

$$\text{Accuracy} = \frac{TP+TN}{TP+FP+TN+FN} \quad (4)$$

$$\text{Precision} = \frac{TP}{TP+FP} \quad (5)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (6)$$

$$\text{F1-Score} = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (7)$$

ทั้งนี้ ตัวชี้วัดหลักที่ใช้ในการประเมิน ได้แก่ ค่าคะแนนของ F1-Score ซึ่งเหมาะสมกับลักษณะข้อมูลที่มีการกระจายตัวไม่สมดุล เนื่องจากสามารถสะท้อนความสมดุลระหว่าง Precision และ Recall ได้ดีกว่า Accuracy เพียงค่าเดียว (Naseeba *et al.*, 2023) นอกจากนี้ ยังได้ประเมินค่าความแปรปรวนของผลลัพธ์ เพื่อวิเคราะห์เสถียรภาพและความน่าเชื่อถือของแบบจำลอง โดยการประเมินแบ่งเป็น 2 ลำดับ ได้แก่ (1) การจำแนกชนิดยาเสพติด และ (2) การจำแนกลักษณะการกระทำความผิด ทั้งนี้ ในลำดับที่ 2 ได้ประเมินค่าชี้วัด Hamming Loss ร่วมด้วย เพื่อวัดสัดส่วนของป้ายที่ทำนายผิดพลาด ซึ่งค่าจะอยู่ระหว่าง 0 ถึง 1 โดยค่าที่ใกล้เคียง 0 แสดงถึงความแม่นยำและประสิทธิภาพที่สูงของแบบจำลองในการจัดการกับข้อมูลหลายป้าย

5.2 การค้นหาค่าพารามิเตอร์ที่เหมาะสมที่สุด งานวิจัยนี้ได้นำแนวคิดจากงานของ Sinha *et al.* (2022) ซึ่งศึกษาเทคนิคการแปลงข้อความเป็นเวกเตอร์ด้วย TF-IDF ร่วมกับการปรับค่า N-gram พบว่าการเปลี่ยนขนาดของ N-gram มีผลกระทบต่อประสิทธิภาพของแบบจำลองอย่างมีนัยสำคัญ

โดยการกำหนดขนาดของกลุ่มคำในข้อความ เช่น N-gram (n_1 , n_2) หมายถึง n_1 เป็นขนาดของแกรมเริ่มต้น และ n_2 เป็นขนาดของแกรมสูงสุด ตัวอย่างของ N-gram แต่ละขนาด ได้แก่

Unigram (N=1): [ครอบครอง], [เพื่อ], [เสพ]

Bigram (N=2): [ครอบครอง เพื่อ], [เพื่อ เสพ]

Trigram (N=3): [ครอบครองเพื่อเสพ]

จากตัวอย่างข้อมูล เห็นได้ว่า คำว่า “ครอบครองเพื่อเสพ” “ครอบครอง” และ “เสพ” ทางงานกฎหมายอาจมีความหมายการใช้งานที่แตกต่างหรือเป็นคนละคลาสกัน การเพิ่มขนาดของ N จะช่วยให้แบบจำลองเข้าใจความสัมพันธ์ของคำในข้อความได้ดีขึ้นซึ่งมากขึ้นและนำไปสู่การจำแนกประเภทข้อความที่แม่นยำขึ้น แต่ทั้งนี้จะส่งผลให้จำนวนคุณลักษณะ (Features) เพิ่มขึ้นด้วยเช่นกัน การทดลองครั้งนี้ จึงใช้เทคนิคการลดมิติข้อมูลตามแนวทางของ เทวัญ เทียนวัน (2566) โดยอาศัยสถิติ Chi-square ช่วยคัดเลือกเฉพาะกลุ่มคำที่มีความสัมพันธ์กับคลาสของป้าย ซึ่งลดความซับซ้อนของข้อมูลโดยตัดคำที่มีคุณค่าน้อยออกไป การทดสอบดำเนินการผ่านกระบวนการ GridSearchCV จากไลบรารี Scikit-learn โดยกำหนดค่าพารามิเตอร์ ngram_range ภายในฟังก์ชัน TfidfVectorizer() และใช้ฟังก์ชัน SelectKBest () ร่วมกับ Chi2 ในการเลือกค่าที่เหมาะสมที่สุดสำหรับการเรียนรู้ของแบบจำลอง การกำหนดช่วงพารามิเตอร์และตัวจำแนก แสดงดัง Table 4

5.3 การประเมินประสิทธิภาพของแบบจำลอง ด้วย Receiver Operating Characteristic (ROC) Curve และ Area Under the Curve (AUC) ผ่านกราฟที่แสดงความสัมพันธ์ระหว่างอัตราการทำนายค่าบวกถูกต้อง (True positive rate) และอัตราการทำนายค่าบวกผิดพลาด (False positive rate) ภายใต้ระดับ Threshold ต่างๆ แบบจำลองที่ดีจะมีเส้นโค้ง ROC เข้าใกล้มุมซ้ายบน และค่าพื้นที่ใต้กราฟ AUC สูง ซึ่งแสดงให้เห็นถึงความสามารถในการจำแนกประเภทได้อย่างแม่นยำ (เอกชัย ฉัตรพงศ์เลอเลิศ, 2567) การวิเคราะห์ค่า AUC จึงเป็นปัจจัยสำคัญในการยืนยันความน่าเชื่อถือของแบบจำลองการจำแนกฐานความผิดในคดียาเสพติด

Table 4 Hyperparameter configurations for GridSearchCV

Models	TF-IDF (ngram-range)	Chi-2(k)	Classifier (C/n_estimators)
SVM	(1,1), (1,2), (1,3), (1,4)	500, 1000, 2000, 3000, 5000	C = 0.1, 1, 10
Logistic Regression	(1,1), (1,2), (1,3), (1,4)	500, 1000, 2000, 3000, 5000	C = 0.1, 1, 10
Random Forest	(1,1), (1,2), (1,3), (1,4)	500, 1000, 2000, 3000, 5000	n_estimators = 100, 200

ผลการวิจัย

1. ผลลัพธ์การจำแนกลำดับที่ 1 ชนิดยาเสพติด

ผลทดสอบจากการเปรียบเทียบ 3 เทคนิค แบ่งผลเป็น 1) พารามิเตอร์ตั้งต้น และ 2) ปรับพารามิเตอร์ที่ดีที่สุด จาก Figure 13 การทดลองแรกด้วยค่าตั้งต้นพบว่า SVM มีประสิทธิภาพสูงสุดในทุกตัวชี้วัด ได้แก่ ค่า Accuracy 98.79%, Precision 97.90%, Recall 98.79% และ F1-Score 98.29% ซึ่งสูงกว่า Logistic Regression และ Random Forest ชัดเจน แต่หลังจากค่าปรับพารามิเตอร์ที่ดีที่สุด (N-gram (1,3), Chi-square (500) และ n_estimators = 100) พบว่าผลคะแนน

Random Forest มีประสิทธิภาพเพิ่มขึ้น และสูงที่สุดในทุกตัวชี้วัด โดย Accuracy เพิ่มขึ้นเป็น 99.70%, Precision 99.40%, Recall 99.70% และ F1-Score 99.55% ขณะที่ SVM มีประสิทธิภาพลดลงเล็กน้อย ส่วน Logistic Regression ได้ค่าคงเดิมไม่เปลี่ยนแปลง และมีประสิทธิภาพต่ำที่สุดในการทดลอง และจาก Figure 14 แสดงผลค่าความแปรปรวนของตัวชี้วัด โดยจากหลังปรับพารามิเตอร์ที่ดีที่สุด พบว่า Random Forest กลายเป็นโมเดลที่มีความแปรปรวนต่ำที่สุดในทุกตัวชี้วัด ส่วน SVM มีความแปรปรวนเพิ่มขึ้นเล็กน้อย และ Logistic Regression มีความแปรปรวนสูงที่สุดในทั้งสองการทดลอง




Figure 13 The results of comparison model performance evaluation (Level 1)




Figure 14 The results of comparison model stability evaluation (Level 1)

2. ผลลัพธ์การจำแนกลำดับที่ 2 ลักษณะการกระทำความผิด

ผลเปรียบเทียบประสิทธิภาพอัลกอริทึมทั้ง 3 เทคนิค แบ่งผลเป็น 2 ครั้งเช่นกัน 1) พารามิเตอร์ตั้งต้น 2) ปรับพารามิเตอร์ที่ดีที่สุด จาก Figure 15 พบว่า Random Forest มีประสิทธิภาพดีที่สุดในทั้งสองครั้ง โดยครั้งแรก พารามิเตอร์ตั้งต้น ให้ค่า Accuracy 89.70%, F1-Score 95.24%, Precision 94.93%, Recall 96.47% และค่า Hamming loss 0.279 และเมื่อปรับพารามิเตอร์ที่ดีที่สุด (N-gram (1,3), Chi-square (5000), n_estimators = 100) พบว่าครั้งที่สอง Random Forest มีประสิทธิภาพเพิ่มสูงขึ้น

อย่างมาก โดยค่าคะแนน Accuracy สูงถึง 93.33%, F1-Score 97.70%, Precision 97.08%, Recall 98.57% และ Hamming loss ลดเหลือ 0.0158 ซึ่งให้ผลลัพธ์ที่ดีที่สุดเมื่อเทียบกับ Logistic Regression และ SVM โดยที่ Figure 16 แสดงผลการเปรียบเทียบความแปรปรวนพบว่าการทดลองเริ่มต้น Random Forest มีความแปรปรวนต่ำที่สุดทุกตัวชี้วัด และหลังปรับพารามิเตอร์ที่ดีที่สุด Random Forest ยังคงมีความแปรปรวนต่ำที่สุดเช่นกัน ขณะที่ Logistic Regression มีความแปรปรวนเพิ่มขึ้นเล็กน้อย ส่วน SVM มีค่าความแปรปรวนสูงที่สุดในทั้งสองการทดลอง




Figure 15 The results of comparison model performance evaluation (Level 2)




Figure 16 The results of comparison model stability evaluation (Level 2)




Figure 17 Confusion matrix of Random Forest (Level 1)




Figure 18 Confusion matrix of Random Forest (Level 2)

3. ผลลัพธ์การประเมิน Confusion matrix

จาก Figure 17 ผลการทดลองพบว่า Random Forest สามารถจำแนกลำดับที่ 1 ชนิดยาเสพติดได้ไม่มีผิดพลาด แสดงความแม่นยำและมีประสิทธิภาพในการจำแนกยาเสพติด 4 ชนิด แม้ข้อมูลมีความไม่สมดุล และ Figure 18 การจำแนกลำดับที่ 2 มีความแม่นยำเฉลี่ยสูง โดยพบข้อผิดพลาดเล็กน้อย ในประเภท “เสฟ” ที่มีผลทำนายคลาดเคลื่อน 13 ตัวอย่าง ซึ่งเป็นกรณีที่ไม่สามารถระบุความผิดฐานเสฟได้ถูกต้อง

4. ผลลัพธ์การประเมินประสิทธิภาพ ROC Curve และ AUC

จากการประเมินโมเดลโดยใช้ ROC และ AUC โดยที่ค่าของ AUC จะอยู่ระหว่าง 0 - 1 โดยที่ค่าใกล้ 1 หมายถึงโมเดลมีความแม่นยำสูง ซึ่งในการประเมินครั้งนี้โมเดลการจำแนกฐานความผิดในคดียาเสพติด ลำดับที่ 1 และลำดับที่ 2 มีค่า Micro-Average AUC เท่ากับ 1.0 (Figure 19 และ Figure 20) แสดงให้เห็นว่าโมเดลทั้งสองลำดับสามารถทำนายผลได้ในระดับที่ดีมาก ส่งผลต่อความเหมาะสมในการนำไปใช้ในสถานการณ์จริง




Figure 19 ROC performance of level 1 multi-label classifier




Figure 20 ROC performance of level 2 multi-label classifier

5. ผลลัพธ์การประยุกต์ใช้แบบจำลองผ่านเว็บแอปพลิเคชันต้นแบบ

ผลการทดลองนำแบบจำลองไปใช้ในเชิงประยุกต์ผ่านเว็บแอปพลิเคชันต้นแบบ โดยจัดเก็บโมเดลด้วยคำสั่ง `joblib.dump()` และส่งออกแบบจำลองที่พัฒนาขึ้นไปทดสอบการใช้งาน ซึ่งแอปพลิเคชันสามารถรับไฟล์เอกสารคำฟ้องในรูปแบบ Word เป็นข้อมูลนำเข้า และประมวลผลด้วยแบบจำลองที่ได้รับการฝึกฝน โดยแสดงผลการจำแนกชนิดของยาเสพติดและลักษณะการกระทำความผิดได้โดยอัตโนมัติ ทั้งนี้ ผลการประมวลผลแสดงให้เห็นว่าระบบสามารถดำเนินการได้อย่างถูกต้อง มีประสิทธิภาพ และสอดคล้องกับผลการประเมินโมเดลจากการทดสอบเชิงสถิติ ดังแสดงใน Figure 21




Figure 21 Sample in a simulated web application

ผลการศึกษาและอภิปรายผล

ผลการศึกษาแสดงให้เห็นว่าการเรียนรู้ของเครื่องเทคนิค Random Forest มีประสิทธิภาพและความเสถียรสูงในการจำแนกฐานความผิดในคดียาเสพติด ด้วยค่า F1-Score สูงกว่า 90% ทั้งในการจำแนกชนิดของยาเสพติด (99.55%) และลักษณะการกระทำความผิด (97.70%) ซึ่งเป็นไปในทิศทางเดียวกันกับรายงานของ กัญญารัตน์ พูลเพิ่ม และ แกมกาญจน์ สมประเสริฐศรี (2565), Buntoro *et al.* (2021) และ Memoon *et al.* (2024)

การที่ Random Forest แสดงประสิทธิภาพสูงกว่าเทคนิคอื่น เช่น SVM และ Logistic Regression สามารถอธิบายได้จากความสามารถในการจัดการข้อมูลซับซ้อนและไม่เป็นเชิงเส้น รวมถึงการลด Overfitting ผ่านการเรียนรู้แบบหลายต้นไม้ม ทั้งนี้ งานของ Buntoro *et al.* (2021) และ Costa *et al.* (2024) ยังชี้ว่ากลยุทธ์ Classifier Chain ช่วยเสริมประสิทธิภาพของ Random Forest ในงานจำแนกแบบหลายป้ายได้อย่างชัดเจน ขณะที่ SVM แม้เหมาะกับข้อมูลมิติสูง แต่

มีข้อจำกัดเมื่อต้องรับมือกับข้อมูลที่มี Noise หรือโครงสร้างซับซ้อน และ Logistic Regression มักประสบปัญหาเมื่อต้องจำแนกข้อมูลที่ไม่เป็นเชิงเส้น

กระบวนการเตรียมข้อมูลที่มีคุณภาพเป็นปัจจัยสำคัญต่อความสำเร็จของแบบจำลองนี้ การใช้ไลบรารี PyThaiNLP ในการประมวลผลข้อความ ได้แก่ การตัดคำ การสร้างคลังคำศัพท์เฉพาะ การลบคำไม่สำคัญ และการแปลงข้อความเป็นเวกเตอร์ด้วยเทคนิค TF-IDF ร่วมกับการปรับพารามิเตอร์ N-gram และการคัดเลือกคุณลักษณะด้วยเทคนิค Chi-square แนวทางดังกล่าวสอดคล้องกับผลการศึกษาของสุภัทรลักษณ์ โพธิ์หา (2565), เทวัญ เทียนวัน (2566) และไพชยนต์ คงไชย (2565) ที่ยืนยันประสิทธิภาพของ PyThaiNLP ในการเตรียมข้อมูลข้อความภาษาไทย ตลอดจนสอดคล้องกับงานวิจัยของ Sinha *et al.* (2022) ซึ่งสนับสนุนความเหมาะสมของการใช้เทคนิค TF-IDF ในการแปลงข้อความเพื่อการจำแนกที่รวดเร็วแม่นยำ

การใช้กลยุทธ์ที่เหมาะสม เช่น การจำแนกแบบลำดับขั้นที่สอดคล้องกับแนวทางของ วรวรรณ วันดี (2564) โดยลำดับแรก จำแนกชนิดของยาเสพติด ซึ่งเมทแอมเฟตามีนพบมากที่สุด โดยใช้กลยุทธ์ One-vs-Rest ซึ่งเหมาะกับข้อมูลหลายคลาสและไม่สมดุล สอดคล้องกับ เทวัญ เทียนวัน (2566) ส่วนลำดับที่สอง จำแนกลักษณะการกระทำความผิดโดยใช้กลยุทธ์ Classifier Chain นำผลจากลำดับแรกมาเป็นคุณลักษณะเสริม ช่วยเพิ่มความแม่นยำในการจำแนกหลายป้าย สอดคล้องกับงานของ จินตริย์ พุทธิพรชัย (2565) และ Morales-Hernández *et al.* (2022)

นอกจากนี้ ผลการศึกษายังสามารถนำไปเป็นต้นแบบสำหรับประยุกต์ใช้ในกระบวนการยุติธรรม โดยเฉพาะการบูรณาการเข้ากับระบบสารสนเทศสำนักงานคดีศาลชั้นต้น (CIMS) เพื่อสนับสนุนการวิเคราะห์และจำแนกฐานความผิดในคดียาเสพติดจากไฟล์คำฟ้องที่จัดเก็บในรูปแบบเอกสารอิเล็กทรอนิกส์ ซึ่งปัจจุบันยังต้องอาศัยการอ่านและวิเคราะห์โดยเจ้าหน้าที่ศาล การนำแบบจำลองที่มีความแม่นยำสูงในการจำแนกชนิดของยาเสพติดและลักษณะการกระทำความผิดเข้ามาประยุกต์ใช้งาน จึงถือเป็นแนวทางที่สามารถลดภาระงานด้านการวิเคราะห์ข้อมูล เพิ่มประสิทธิภาพและความเร็วในการตรวจสอบเบื้องต้น ตลอดจนส่งเสริมการจัดเก็บข้อมูลคดีอย่างเป็นระบบและมีมาตรฐาน

ข้อเสนอแนะ

จากผลการศึกษาพบว่าเทคนิค Random Forest มีประสิทธิภาพดีที่สุด แต่อย่างไรก็ตาม เพื่อเพิ่มความแม่นยำและความสามารถในการประยุกต์ใช้ในวงกว้าง ควรขยายขอบเขตของข้อมูลโดยนำข้อมูลคดีจากศาลหรือแหล่งอื่นเข้ามาเพิ่มเติม อีกทั้งการวิเคราะห์ Learning Curve จะช่วยประเมินความเหมาะสมของขนาดข้อมูลและพฤติกรรมของแบบจำลองได้ชัดเจนยิ่งขึ้น นอกจากนี้ การจัดการข้อมูลที่ไม่สมดุลด้วยเทคนิคเช่น SMOTE อาจช่วยเพิ่มความสามารถในการจำแนกคลาสที่มีข้อมูลจำนวนน้อยได้มีประสิทธิภาพมากกว่า รวมถึงการพัฒนาในอนาคตอาจพิจารณาปรับปรุงโครงสร้างของแบบจำลองให้เหมาะสมกับลักษณะข้อมูลที่มีความซับซ้อนมากขึ้น หรือการประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึก เช่น LSTM หรือโมเดลภาษาอย่าง BERT เพื่อเสริมศักยภาพในการเข้าใจบริบทของข้อมูลที่ซับซ้อนมากยิ่งขึ้น

กิตติกรรมประกาศ

ขอขอบคุณ สำนักงานศาลยุติธรรมที่สนับสนุนทุนการศึกษา และขอขอบคุณศาลจังหวัดสุพรรณบุรีที่อนุญาตให้ใช้ชุดข้อมูลจากโปรแกรมสารสนเทศสำนักงานคดีศาลชั้นต้นสำหรับนำมาศึกษาในงานวิจัยนี้

เอกสารอ้างอิง

- กัญญารัตน์ พูลเพิ่ม, และเกมกาญจน์ สมประเสริฐศรี. (2565). การจำแนกโครงการตามแผนแม่บทภายใต้ยุทธศาสตร์ชาติโดยใช้เทคนิคเหมืองข้อความ. *วารสารวิชาการ การจัดการเทคโนโลยี มหาวิทยาลัยราชภัฏมหาสารคาม*, 9(2), 54–65.
- จินตริย์ พุทธิพรชัย. (2565). *การจำแนกประเภทแบบหลายผลจากของบทความในฐานข้อมูลวารสารวิชาการไทยจากบทความย่อ* [ปริญญาหมหาบัณฑิต, จุฬาลงกรณ์มหาวิทยาลัย]. Chulalongkorn University Theses and Dissertations (Chula ETD). <https://digital.car.chula.ac.th/chula-etd/6481>
- เทวัญ เทียนวรรณ. (2566). การประเมินข้อความทวีตเตอร์ที่เกี่ยวกับทัศนคติด้านสุขภาพในสถานการณ์การแพร่ระบาดของโควิด-19 เพื่อวิเคราะห์ความรู้สึกโดยใช้อัลกอริทึมการเรียนรู้ของเครื่องแบบมีผู้สอน. *วารสารเภสัชกรรมไทย มหาวิทยาลัยสงขลานครินทร์*, 16(3), 769–786.
- ประมวลกฎหมายยาเสพติด. (2564). *ประมวลกฎหมายยาเสพติด พ.ศ. 2564. ราชกิจจานุเบกษา*, เล่ม 138 ตอนที่ 73 ก, หน้า 1–80.

- ไพชยนต์ คงไชย. (2565). การสร้างแบบจำลองโดยใช้การเรียนรู้เชิงลึกเพื่อจำแนกข้อความการสนทนาจากแอปพลิเคชันไลน์. *วารสารวิทยาศาสตร์และเทคโนโลยีมหาวิทยาลัยมหาสารคาม*, 43(1), 16–24.
- วรวรรณ วันดี. (2564). การจำแนกประเภทแบบมัลติเลเบลสำหรับหัวเรื่องหนังสือทางบรรณารักษศาสตร์ [ปริญญาโท]. มหาบัณฑิต, มหาวิทยาลัยธรรมศาสตร์. Thammasat University Digital Collections. <https://doi.org/10.14457/TU.the.2021.478>
- สำนักส่งเสริมงานตุลาการ. (2566, 27 ตุลาคม). การเรียกข้อมูลจากสำนักงานอัยการสูงสุดเข้าสู่ระบบสารสนเทศสำนักงานคดีศาลชั้นต้นโดยอัตโนมัติ. สำนักงานศาลยุติธรรม. <https://oja.coj.go.th/th/content/category/detail/id/21/iid/379504>
- สุภัทลักษณ์ โพธิ์หา. (2565). แบบจำลองวิเคราะห์ความรู้สึกผู้ใช้บริการที่มีต่อการให้บริการของโรงพยาบาลมาตรฐาน JCI ในประเทศไทย [ปริญญาโท]. มหาบัณฑิต, มหาวิทยาลัยธรรมศาสตร์. Thammasat University Digital Collections. <https://doi.org/10.14457/TU.the.2022.1519>
- เอกชัย จิตรพงศ์เลอเลิศ. (2567). การจำแนกข้อความตามทฤษฎีการวิเคราะห์การสื่อสารสัมพันธ์ระหว่างบุคคลด้วยเทคนิคการเรียนรู้ของเครื่อง [ปริญญาโท]. มหาบัณฑิต, มหาวิทยาลัยธรรมศาสตร์. Thammasat University Digital Collections. <https://doi.org/10.14457/TU.the.2024.52>
- Buntoro, G. A., Wibawa, A. D., & Purnomo, M. H. (2021). Text mining in healthcare for disease classification using machine learning algorithm. *IEEE Access*, 9, Article 9593998. <https://doi.org/10.1109/IES53407.2021.9593998>
- Costa, J. A. F., Silva, S. O., Silva, E. D. S. A., & Dantas, N. C. D. (2024). Multi-label classification of legal cases according to the Sustainable Development Goals using machine learning algorithms. In *2024 IEEE Latin American Conference on Computational Intelligence (LA-CCI)*. IEEE. <https://doi.org/10.1109/LA-CCI62337.2024.10814740>
- Mahdi, Z. M., Istiqomah, R. F., Alfarelzi, Astuti, S., Asror, I., & Mayasari, R. (2024). Text classification using NLP by comparing LSTM and machine learning method. In *2024 10th International Conference on Wireless and Telematics (ICWT)*. IEEE. <https://doi.org/10.1109/ICWT62080.2024.10674679>
- Memoon, M., Umar, M., Rani, S., Khalid, M., & Shaheen, S. (2024). Twitter news classification using machine learning. In *2024 International Conference on Engineering & Computing Technologies (ICECT)*. IEEE. <https://doi.org/10.1109/ICECT61618.2024.10581173>
- Morales-Hernández, R. C., Gutiérrez Jagüey, J., & Becerra-Alonso, D. (2022). A comparison of multi-label text classification models in research articles labeled with sustainable development goals. *IEEE Access*, 10, 123534–123547. <https://doi.org/10.1109/ACCESS.2022.3223094>
- Naseeba, B., Challa, N. P., Doppalapudi, A., Chirag, S., & Nair, N. S. (2023). Machine learning models for news article classification. In *2023 5th International Conference on Smart Systems and Inventive Technology (ICSSIT)*. IEEE. <https://doi.org/10.1109/ICSSIT55814.2023.10061095>
- Rizqi, F. N., Bijaksana, M. A., & Bunyamin. (2025). Multi-label classification of Al-Qur'an verses using ensemble method and BERT. In *2025 International Conference on Advancement in Data Science, E-learning and Information System (ICADEIS)*. IEEE. <https://doi.org/10.1109/ICADEIS65852.2025.10933388>
- Sinha, A., Nazma, M., Naskar, B. J., Pandey, M., & Rautaray, S. S. (2022). IMDB movie review text classification model using different weighting techniques and classifiers. In *2022 OITS International Conference on Information Technology (OCIT)* (pp. 1–6). IEEE. <https://doi.org/10.1109/OCIT56763.2022.00029>