



เว็บแอปพลิเคชันทำนายไฟป่าด้วยปัญญาประดิษฐ์

Wildfire prediction web application using an artificial intelligence

ชนกันต์ ประมะคัง^{1*}, อชิระ ว่องไวริยะ¹

กฤษฎา ทองเชื้อ¹

¹โรงเรียนวิทยาศาสตร์จุฬารามราชวิทยาลัย ชลบุรี, ตำบลหนองขาก, อำเภอบ้านบึง, จังหวัดชลบุรี 20170, ประเทศไทย

*Email: chanakan1q@gmail.com

บทคัดย่อ

โครงการคอมพิวเตอร์นี้มีวัตถุประสงค์เพื่อพัฒนาเว็บแอปพลิเคชันสำหรับคาดการณ์พื้นที่ที่มีโอกาสตรวจพบจุดความร้อนซึ่งอาจเกี่ยวข้องกับการเกิดไฟป่าในประเทศไทยภายใน 3 วันข้างหน้า โดยแบ่งแผนที่ประเทศไทยออกเป็นพื้นที่ย่อยขนาดประมาณ 11 × 11 กิโลเมตร ข้อมูลหลักประกอบด้วยข้อมูลจุดความร้อนจากดาวเทียม VIIRS ผ่านระบบ NASA FIRMS ตั้งแต่วันที่ 20 มกราคม พ.ศ. 2555 จนถึงปัจจุบันประมาณ 4.2 ล้านจุด ข้อมูลสภาพอากาศย้อนหลังประมาณ 280,000 ชุดจาก Open-Meteo ERA5 และข้อมูลพื้นที่ป่าปกคลุมประมาณ 20,000 พื้นที่จาก Global Forest Change โดยจำนวนข้อมูลเป็นค่าประมาณและเพิ่มขึ้นตามการอัปเดตในแต่ละวัน ข้อมูลจะผ่านการตรวจสอบและจัดเตรียมก่อนนำไปฝึกแบบจำลอง LightGBM Classifier เพื่อเรียนรู้ความสัมพันธ์ระหว่างประวัติการเกิดไฟ สภาพอากาศ ฤดูกาล และลักษณะพื้นที่ ระบบหลังบ้านพัฒนาด้วย FastAPI ส่วนหน้าเว็บไซต์พัฒนาด้วย React, TypeScript และ Leaflet.js โดยแสดงระดับความเสี่ยง จุดความร้อนปัจจุบัน และข้อมูลสถิติผ่านแผนที่โต้ตอบ ระบบสามารถช่วยให้หน่วยงานและชุมชนทราบพื้นที่ที่ควรเฝ้าระวัง รวมถึงเตรียมบุคลากร อุปกรณ์ และมาตรการป้องกันได้ล่วงหน้า ระบบจึงเป็นเครื่องมือที่ช่วยสนับสนุนการเฝ้าระวัง การเตรียมความพร้อม และการวางแผนรับมือกับสถานการณ์ไฟป่าได้อย่างมีประสิทธิภาพมากขึ้น

คำสำคัญ: จุดความร้อน, ปัญญาประดิษฐ์, LightGBM, NASA FIRMS, เว็บแอปพลิเคชัน

บทนำ

ทรัพยากรป่าไม้มีความสำคัญอย่างยิ่งต่อระบบนิเวศ ถือเป็นแหล่งต้นน้ำลำธาร แหล่งที่อยู่อาศัยของสัตว์ป่า และมีบทบาทสำคัญในการรักษาสมดุลของสภาพภูมิอากาศ อย่างไรก็ตาม ในช่วงปีที่ผ่านมา ประเทศไทยเผชิญกับปัญหาไฟป่าอย่างต่อเนื่อง โดยสถิติระบุว่ามีการเกิดไฟป่าและการเข้าดับไฟกว่า 6,000 ครั้ง ส่งผลให้พื้นที่ป่าอนุรักษ์ได้รับความเสียหายมากกว่า 200,000 ไร่ ปัญหาไฟป่าไม่เพียงแต่ทำลายทรัพยากรธรรมชาติ แต่ยังเป็นสาเหตุหลักของการเกิดฝุ่นละอองขนาดเล็ก(PM 2.5) และหมอกควัน ซึ่งส่งผลกระทบต่อระบบนิเวศ เศรษฐกิจ และสุขภาพอนามัยของประชาชน ในวงกว้าง

ในปัจจุบัน การเฝ้าระวังและติดตามสถานการณ์ไฟป่าโดยหน่วยงานที่เกี่ยวข้อง มักอาศัยข้อมูลดาวเทียมเพื่อตรวจจับจุดความร้อน (Hotspot) เป็นหลัก ซึ่งวิธีการดังกล่าวเป็นการตรวจจับเหตุการณ์ที่เกิดขึ้นไปแล้ว (Reactive) ทำให้ในหลายกรณีการเข้าระงับเหตุลุกลามของไฟป่าเกิดความล่าช้า ไม่ทันทั่วถึง และก่อให้เกิดความเสียหายเป็นวงกว้างก่อนที่จะเจ้าหน้าที่จะเข้าควบคุมสถานการณ์ได้

ด้วยเหตุนี้ ผู้จัดทำจึงเล็งเห็นถึงความสำคัญของการนำเทคโนโลยีปัญญาประดิษฐ์ (Artificial Intelligence: AI) มาประยุกต์ใช้ในการวิเคราะห์ข้อมูลจุดความร้อนในอดีต ร่วมกับปัจจัยทางสภาพอากาศและ



ข้อมูลเชิงพื้นที่ เพื่อพัฒนาระบบทำนายความเสี่ยงการเกิดไฟป่าล่วงหน้า (Proactive) ผ่านรูปแบบเว็บไซต์ ซึ่งจะช่วยให้หน่วยงานภาครัฐและประชาชนสามารถรับรู้พื้นที่เสี่ยง วางแผนรับมือ และป้องกันไฟป่าได้อย่างมีประสิทธิภาพและทันทั่วถึงมากยิ่งขึ้น

วัตถุประสงค์

1. เพื่อพัฒนาแบบจำลองปัญญาประดิษฐ์ (AI Model)

ในการวิเคราะห์และพยากรณ์พื้นที่เสี่ยงภัยแล้งและการเกิดไฟป่าล่วงหน้า โดยการผสมผสานข้อมูลเทคโนโลยีอวกาศ (ข้อมูลอินฟราเรด) ร่วมกับปัจจัยทางสภาพอากาศเชิงพื้นที่

2. เพื่อพัฒนาเทคโนโลยีสะอาด (Clean Tech) ในรูปแบบแพลตฟอร์มเว็บไซต์อัจฉริยะ ที่แสดงผลแผนที่พื้นที่เสี่ยงภัยไฟป่าแบบโต้ตอบ (Interactive Map) พร้อมระบบอัปเดตข้อมูลอัตโนมัติรายวันและระบบตรวจสอบความแม่นยำย้อนหลัง เพื่อสร้างความโปร่งใสและน่าเชื่อถือของข้อมูล

3. เพื่อส่งเสริมการบริหารจัดการสิ่งแวดล้อมเชิงรุก (Proactive Approach) โดยใช้เป็นเครื่องมือดิจิทัลช่วยให้หน่วยงานภาครัฐ เจ้าหน้าที่พิทักษ์ป่า และชุมชนสามารถวางแผนจัดสรรกำลังพลลาดตระเวน และเข้าระงับเหตุได้อย่างทันทั่วถึงก่อนที่ไฟจะปะทุขึ้น

4. เพื่อลดผลกระทบทางสิ่งแวดล้อมและเศรษฐกิจ โดยมุ่งเน้นการปกป้องผืนป่า บำรุงรักษาระบบนิเวศ ลดการปล่อยก๊าซเรือนกระจก และบรรเทาปัญหาหมอกพิษทางอากาศ PM2.5 จากการเผาไหม้ได้อย่างยั่งยืน

วิธีการดำเนินงาน

1.การรวบรวมและเตรียมข้อมูล (Data Collection & Preprocessing)

การดึงข้อมูลจุดความร้อน (fetch_firms.py) เขียนชุดคำสั่งเพื่อดึงข้อมูลจุดความร้อนจาก API ของ NASA FIRMS ข้อมูลสะสมหลังการรวบรวม 2 ปี (ม.ค. 2555 – ธ.ค. 2568) มีรายการ Hotspot ทั้งสิ้นประมาณ 4,000,000 แถว เก็บในรูปแบบไฟล์ Parquet เพื่อประหยัดพื้นที่ การดึงข้อมูลสภาพอากาศ (fetch_weather.py) ดึงข้อมูลสภาพอากาศย้อนหลังจาก Open-Meteo ERA5 API ประกอบด้วย 7 ตัวแปรหลัก ได้แก่ อุณหภูมิ, ความชื้นสัมพัทธ์, ปริมาณน้ำฝน, ความเร็วลม, ความชื้นดิน, รังสีดวงอาทิตย์ และการระเหย การทำ Grid Densification ทำการแปลงพิกัด Hotspot ให้กลายเป็นเซลล์กริดขนาด $0.1^\circ \times 0.1^\circ$ (ประมาณ 11×11 กิโลเมตร) จากนั้นสร้างข้อมูลสำหรับทุกเซลล์ในทุกวัน กำหนดให้วันที่มีไฟป่าในเซลล์นั้นเป็นคลาส 1 และวันที่ไม่มีเป็นคลาส 0 ได้แกวข้อมูลรวมหลังจัดทำ 14.4 ล้านแถว

```
def fetch_firms():
    """Fetch FIRMS Hotspot Data"""
    base_dir = os.path.join(BASE_DIR, "data", "firms")
    firms_path = os.path.join(base_dir, "firms_all.parquet")
    weather_cache_path = os.path.join(BASE_DIR, "data", "weather")

    # Check if data exists
    if not os.path.exists(firms_path):
        # Fetch FIRMS data
        # ... (code for fetching FIRMS data) ...

    # Fetch weather data
    # ... (code for fetching weather data) ...

    # Save data
    # ... (code for saving data) ...

    return firms_path, weather_cache_path
```

รูปที่ 1 Source code ในส่วนที่เกี่ยวกับการดึงข้อมูลสภาพอากาศ

2. การสกัดและจัดเตรียมตัวแปรพยากรณ์ (Feature Engineering)

ดำเนินการบน Jupyter Notebook เพื่อดำเนินการและสกัดคุณลักษณะแวดล้อมเพิ่มเติมรวมทั้งสิ้น 38 ตัวแปร เพื่อให้โมเดลจำแนกประเภทเข้าใจบริบทเชิงพื้นที่และเวลา

Lag Features ประวัติจำนวนจุดความร้อนที่เคยเกิดขึ้นในกริดนั้นๆ ย้อนหลัง 1, 2, 3 และ 7 วัน

Rolling Features ค่าเฉลี่ยสะสมของการเกิดไฟป่าในกริดเคลื่อนที่รอบ 7 วัน และ 30 วัน



Neighbor Features การคำนวณผลรวมความเสี่ยงของ
เซลล์กริดรอบข้างแบบ 3x3 เพื่อดูการลุกลาม

Weather & Temporal Features ข้อมูลสภาพอากาศ
รายวันและดัชนีฤดูกาล ในรอบปี

ตารางที่ 1 รายชื่อตัวแปรพยากรณ์

กลุ่มตัวแปรที่	รายชื่อตัวแปรพยากรณ์	จำนวน
1	fire_count_lag1, lag2, lag3, lag7 (จำนวนประวัติการเกิดไฟป่าย้อนหลัง)	4 ตัวแปร
2	fire_count_roll7, roll14, roll30 (ค่าเฉลี่ยการเกิดไฟป่าเคลื่อนที่)	3 ตัวแปร
3	neighbor_sum_3x3 (ผลรวมการเกิดไฟของ 8 เซลล์รอบข้าง), neighbor_max_3x3	2 ตัวแปร
4	month, day_of_year, week_of_year, is_dry_season (ด.ค.-เม.ย.)	5 ตัวแปร
5	temp, humidity, rain, wind, soil_moisture, radiation, evapotranspiration	7 ตัวแปร
6	lat_grid, lon_grid, is_forest, is_urban, distance_to_road	5 ตัวแปร
7	temp x (1-humidity), cumulative_dry_days, fire_density_30d	3 ตัวแปร
8	wildfire_occurrence (เกิดไฟป่าภายใน 7 วันข้างหน้า = 1, ไม่เกิด = 0)	1 ตัวแปร

3. การพัฒนาและฝึกสอนโมเดลปัญญาประดิษฐ์ (Model Training)

ในขั้นตอนนี้เป็นการนำข้อมูลดิบที่ผ่านการเตรียมเบื้องต้น มาสกัดเป็นตัวแปร ที่เหมาะสม และทำการฝึกสอนตัวแบบจำแนกประเภท (Classifier) เพื่อให้สามารถทำนายโอกาสการเกิดไฟป่าได้อย่างแม่นยำ โดยมีรายละเอียดดังนี้

การแบ่งชุดข้อมูลเพื่อฝึกสอน เพื่อป้องกันความผิดพลาดจากข้อมูลรั่วไหล (Data Leakage) ผู้จัดทำใช้วิธีการแบ่งข้อมูลตามลำดับเวลา (Temporal Split) แทนการสุ่มทั่วไป โดยแบ่งเป็นชุดข้อมูลสำหรับฝึกสอน (Train Set) 60% ชุดข้อมูลสำหรับปรับแต่ง (Validation Set) 20% และชุดข้อมูลสำหรับทดสอบโมเดล (Held-Out Test Set) อีก 20%

การปรับแต่งพารามิเตอร์และการเลือกโมเดล (Model Tuning) ทำการค้นหาไฮเปอร์พารามิเตอร์ที่ดีที่สุดผ่านวิธี Randomized Search Cross-Validation โดยกำหนดเกณฑ์ในการตัดสินใจเลือกโมเดลด้วยค่าพื้นที่

ใต้โค้ง ROC (Scoring metric = 'roc_auc') และทำการเปรียบเทียบประสิทธิภาพร่วมกับอัลกอริทึมอื่นๆ ดังตาราง

ตารางที่ 2 รายการเปรียบเทียบประสิทธิภาพร่วมกับอัลกอริทึมอื่นๆ

รอบการ Train	อัลกอริทึม	Hyperparameters หลัก	Val AUC	Val F1-Score	Val Accuracy
รอบที่ 1 (Baseline)	LightGBM	n_estimators=100, lr=0.1, leaves=31	0.795	0.652	76.50%
รอบที่ 2 (Tuned v1)	LightGBM	n_estimators=300, lr=0.05, leaves=80	0.832	0.652	79.10%
รอบที่ 3 (Tuned v2)	LightGBM	n_estimators=500, lr=0.03, leaves=127	0.854	0.721	81.30%
รอบที่ 4 (Best LGB)	LightGBM	n_estimators=650, lr=0.02, leaves=150	0.871	0.743	82.80%
รอบที่ 5 (XGBoost)	XGBoost	n_estimators=400, lr=0.05, max_depth=8	0.849	0.710	80.50%
รอบที่ 6 (RF)	Random Forest	n_estimators=300, max_depth=12	0.812	0.685	78.20%

```
32 from data_loader import load_and_prepare
33 from features import (
34     DEFAULT_URGENCY_THRESHOLDS, # FIX: BUG 3 - fixed domain thresholds replace
35     MAX_PREDICTION_DAYS,
36     build_features,
37     resolve_features,
38 )
39 from io_utils import resolve_existing, write_table
40 from model import evaluate, select_best
41
42 logging.basicConfig(
43     level=logging.INFO, format="%(asctime)s | %(levelname)s | %(name)s | %(message)s"
44 )
45 log = logging.getLogger("train")
46
47
48 def _resolve(base_dir: str, value: Optional[str]) -> Optional[str]:
49     """Resolve an env-supplied path against the project root if it's relative."""
50     if not value:
51         return value
52     return value if os.path.isabs(value) else os.path.normpath(os.path.join(base_dir, value))
53
54
55 def _paths() -> dict:
56     base_dir = os.path.dirname(os.path.dirname(os.path.abspath(__file__)))
57     output_dir = _resolve(base_dir, os.getenv("OUTPUT_DIR")) or os.path.join(base_dir, "output")
58     weather_dir = _resolve(base_dir, os.getenv("WEATHER_DIR")) or os.path.join(base_dir, "weather")
59     return {
```

รูปที่ 2 Source code ในส่วนที่เกี่ยวกับการฝึกโมเดล

4. การกำหนดเกณฑ์ระดับความเสี่ยง (Probability Threshold Calibration)

นำค่าความน่าจะเป็น (Probability Output) ตั้งแต่ 0.0 ถึง 1.0 ที่ได้จากโมเดล LightGBM มาแบ่งเกณฑ์เพื่อแปรผลเป็นระดับความเร่งด่วนในการแจ้งเตือนบนหน้าเว็บ แอปพลิเคชัน

ตารางที่ 3 รายการเกณฑ์เพื่อแปรผลเป็นระดับความ เร่งด่วนบนหน้าเว็บแอปพลิเคชัน

ระดับความ เร่งด่วน	ช่วงค่าความ น่าจะเป็น (Probability)	สีที่แสดงบน แผนที่	ความหมาย
CRITICAL	> 85%	สีแดงเข้ม (#FF0000)	ความเสี่ยงสูงมาก คาดว่าจะเกิดไฟป่าใน พื้นที่แน่นอน
HIGH	65% – 85%	สีส้ม (#FF6600)	ความเสี่ยงสูง สภาพแวดล้อมแห้ง แล้งจัดและมีประวัติ ไฟ
MEDIUM	40% – 65%	สีเหลือง (#FFCC00)	ความเสี่ยงปานกลาง ควรติดตาม สถานการณ์ใกล้ชิด
LOW	< 40%	สีเขียว (#00CC00)	ความเสี่ยงต่ำ สภาพ อากาศมีความชื้น เพียงพอ

5. การพัฒนาเว็บแอปพลิเคชัน (Web Application Development)

การออกแบบหน้าตาใช้งาน (UI Design)
ออกแบบระบบด้วย HTML/CSS และ JavaScript เน้น
แสดงแผนที่ประเทศไทย ผ่านไลบรารี Leaflet.js เพื่อ
ความสะดวกในการโต้ตอบ (Interactive Map) มีปุ่มเลือก
ดูผลทำนายล่วงหน้าแยกเป็นรายวัน (Day 1 - Day 7)

การเชื่อมต่อข้อมูล (Backend API)
พัฒนาสคริปต์หลังบ้านด้วย FastAPI เพื่อทำหน้าที่ดึง
พิกัดกริดและความน่าจะเป็น ที่คำนวณไว้จากโมเดล
ปัญญาประดิษฐ์มาแปลงเป็นข้อมูล GeoJSON ส่งต่อไป
แสดงผลเป็นมาร์กเกอร์สีตามระดับความเสี่ยงบนหน้าเว็บ
พร้อมทั้งสร้างระบบตั้งเวลาทำงานอัตโนมัติ (Cron Job)
เพื่อรันโมเดลทำนายผลอัปเดตใหม่ในทุกๆ วัน

การแสดงผลบนแผนที่ได้ (Interactive Map)
หน้าเว็บแอปพลิเคชันจะใช้ไลบรารี Leaflet.js ในการรับ
ข้อมูล GeoJSON มาวาดเป็นแผนที่ภาพความร้อน
(Heatmap) หรือบล็อกสีตามระดับความเสี่ยง พร้อม
ระบบสไลด์เพื่อเลือกดูผลการทำนายล่วงหน้าตั้งแต่
เป้าหมายวันที่ 1 จนถึงวันที่ 7 ช่วยให้ผู้ใช้สามารถ
วิเคราะห์แนวโน้มการเกิดไฟป่าเชิงพื้นที่ได้อย่างสะดวก

```

1 <!DOCTYPE html>
2 <html lang="en">
3 <head>
4 <meta charset="UTF-8" />
5 <meta name="viewport" content="width=device-width, initial-scale=1.0" />
6 <title> Fire Date Prediction Dashboard</title>
7
8 <!-- Leaflet CSS -->
9 <link rel="stylesheet" href="https://unpkg.com/leaflet@1.9.4/dist/leaflet.css"
10 <link rel="stylesheet" href="https://unpkg.com/leaflet.markercluster@1.5.3/dist
11 <link rel="stylesheet" href="https://unpkg.com/leaflet.markercluster@1.5.3/dis
12
13 <!-- Custom CSS -->
14 <link rel="stylesheet" href="style.css?v=7" />
15 </head>
16 <body>
17
18 <!-- Sidebar -->
19 <div id="sidebar">
20 <div class="header">
21 <h1> Fire Date Predictor</h1>
22 <p class="subtitle">NASA FIRMS - real-time wildfire forecasting</p>
23 </div>
24
25 <!-- Date Info -->
26 <div class="info-card">
27 <div class="info-label">Base Date <span class="freshness-badge" id="freshness


```

รูปที่ 3 Source code ในส่วนที่เกี่ยวข้องกับ user
interface

ผลและอภิปรายผล

1. ผลการพัฒนาเว็บแอปพลิเคชันแสดงผลและทำนาย ไฟป่า

ผลการจัดสร้างคลังข้อมูลเชิงพื้นที่และเวลา
(Spatiotemporal Database) ในรูปแบบ กริดครอบคลุม
ประเทศไทย มีข้อมูลรวมทั้งสิ้น 4,472,145 แถวข้อมูล
(Cell-day rows) โดยแบ่งชุดข้อมูลตามลำดับเวลา
(Chronological Split) ในสัดส่วน 60/20/20 ซึ่งชุด
ข้อมูลสถิติดังกล่าวถูกนำไปประมวลผลและจัดแสดงผล
ร่วมกับค่าความคลาดเคลื่อนบนหน้าเว็บไซต์ ดังภาพ



รูปที่ 4 ค่าความคลาดเคลื่อนที่แสดงบนเว็บไซต์



2. ผลการประเมินประสิทธิภาพของโมเดล ปัญญาประดิษฐ์

เมื่อนำโมเดล LightGBM ที่ผ่านการปรับแต่งพารามิเตอร์แล้ว มาทดสอบกับชุดข้อมูลทดสอบ (Test Set) ที่โมเดลไม่เคยเห็นมาก่อน และทำการประเมินผลด้วยวิธีสุ่มซ้ำ (Bootstrap) จำนวน 1,000 ครั้ง เพื่อหาช่วงความเชื่อมั่น 95% (95% Confidence Intervals) ได้ผลลัพธ์ดัชนีชี้วัดประสิทธิภาพ ดังนี้

1. การประเมินประสิทธิภาพด้วยพื้นที่ใต้เส้นกราฟ ROC

ค่า AUC เป็นดัชนีชี้วัดความสามารถของแบบจำลองในการจำแนกความเสี่ยงการเกิดไฟฟ้า (Positive Class) ออกจากพื้นที่ที่ไม่เสี่ยง (Negative Class) โดยทางคณิตศาสตร์ ค่า AUC คือพื้นที่ใต้เส้นโค้งที่เกิดจากการอินทิเกรตความสัมพันธ์ระหว่าง อัตราผลบวกจริง (True Positive Rate: TPR) และอัตราผลบวกปลอม (False Positive Rate: FPR) ดังสมการต่อไปนี้

$$AUC = \int_0^1 TPR(FPR) d(FPR)$$

ในการคำนวณจริงจากชุดข้อมูลทดสอบเชิงสถิติ (Discrete Dataset) จะคำนวณผ่านสถิติจัดอันดับของ Wilcoxon-Mann-Whitney ซึ่งมีสูตรการคำนวณดังนี้

$$AUC = \frac{\sum R_i - \frac{n_1(n_1 + 1)}{2}}{n_1 \times n_0}$$

โดยที่ตัวแปรในสมการมีความหมายดังต่อไปนี้:

AUC คือ ค่าพื้นที่ใต้เส้นกราฟประสิทธิภาพการทำนาย (มีค่าระหว่าง 0 ถึง 1)

$\sum R_i$ คือ ผลรวมของลำดับอันดับ (Sum of Ranks) ของคะแนนความน่าจะเป็นในกลุ่ม

พิกัดกริดที่เกิดไฟฟ้าจริง

n_1 คือ จำนวนข้อมูลพิกัดกริดทั้งหมดที่เกิดไฟฟ้าจริง (จำนวนตัวอย่างกลุ่ม Positive)

n_0 คือ จำนวนข้อมูลพิกัดกริดทั้งหมดที่ไม่เกิดไฟฟ้าจริง (จำนวนตัวอย่างกลุ่ม Negative)

ตารางที่ 4 ผลการประเมินประสิทธิภาพของโมเดลผ่านเมทริกซ์การจำแนกประเภท

ตัวชี้วัดประสิทธิภาพ	ค่าที่วัดได้ (Point Estimate)	ช่วงความเชื่อมั่น 95% (Lower - Upper)
ROC-AUC	0.8271	0.8257 - 0.8286
Recall (Sensitivity)	67.21%	66.70% - 67.77%
Specificity	81.23%	-
Precision (PPV)	11.40%	11.26% - 11.54%
F1 Score	0.1949	0.1928 - 0.1971

ผลการวิเคราะห์เมทริกซ์ความสับสน

(Confusion Matrix) ณ จุดตัด DeploymentThreshold จากการทำนายข้อมูลทดสอบทั้งหมด 894,429 รายการ โมเดลสามารถจำแนกผลลัพธ์

ได้ดังนี้

True Negative (ทำนายว่าไม่เกิด และไม่เกิดจริง): 701,331 กรณี (78.41%)

True Positive (ทำนายว่าเกิด และเกิดไฟฟ้าจริง): 20,853 กรณี (2.33%)

False Positive (ทำนายว่าเกิด แต่ไม่เกิดจริง - False Alarm): 162,070 กรณี (18.12%)



False Negative (ทำนายว่าไม่เกิด แต่เกิดไฟป่าจริง - Missed): 10,175 กรณี (1.14%)

สรุปผลการประเมิน โมเดลมีค่า ROC-AUC ที่ 0.8271 แสดงถึงความสามารถในการแยกแยะพื้นที่เสี่ยงและไม่เสี่ยงได้ดีมาก ถึงแม้ค่า Precision จะค่อนข้างต่ำ (11.40%) ซึ่งเป็นธรรมชาติของชุดข้อมูลที่มีความไม่สมดุล สูงมาก (Imbalanced Data / Rare Events) แต่โมเดลมีค่าความไว (Recall) สูงถึง 67.21% และมีอัตราการพลาดเป้า (False Negative) เพียง 1.14% ซึ่งตอบโจทย์การพัฒนาาระบบแจ้งเตือนภัยพิบัติที่ต้องการเน้นดักจับเหตุการณ์ให้ครอบคลุมที่สุด (ยอมให้มีการเตือนภัยผิดพลาดได้บ้าง เพื่อแลกกับการไม่พลาดเหตุการณ์ไฟป่าของจริง)

3. ความเสถียรของโมเดลเมื่อทดสอบข้ามเวลา (Model Stability over Time)

จากการประเมินค่า AUC แบบ Rolling ตลอดระยะเวลา 17 เดือน (มกราคม 2568 ถึง พฤษภาคม 2569) พบว่าโมเดลมีความเสถียรในการพยากรณ์สูง โดยมีค่า AUC เฉลี่ย (Mean) อยู่ที่ 0.915 และมีค่าความเบี่ยงเบนมาตรฐาน (STD) เพียง 0.070 (ต่ำสุด 0.784 และสูงสุด 0.984) ซึ่งพิสูจน์ให้เห็นว่าโมเดลสามารถปรับตัวรับมือกับความผันผวนของฤดูกาลในแต่ละเดือนได้ดีและไม่เกิดภาวะ Overfitting

4. การวิเคราะห์ปัจจัยสำคัญที่มีผลต่อการทำนาย (Feature Importance)

ระบบได้ทำการจัดอันดับตัวแปรนำเข้า (Features) ที่โมเดล LightGBM ให้น้ำหนักความสำคัญสูงสุดในการแยกแยะการเกิดไฟป่า พบว่า 5 อันดับแรก ได้แก่

1.doy_sin / doy_cos ทำหน้าที่แปลงค่าวันที่ให้อยู่ในลักษณะวัฏจักรต่อเนื่อง ช่วยให้แบบจำลองปัญหาประติสฐ์สามารถจดจำและตรวจจบบัวิเคราะห์ "รูปแบบเชิงฤดูกาล" (Seasonal Patterns) ได้อย่าง

แม่นยำ แบบจำลองจะใช้น้ำหนักจากตัวแปรนี้ในการคัดกรองช่วงเดือนที่มีความแห้งแล้งสูง (เช่น ช่วงมกราคม - เมษายนของทุกปี) ส่งผลให้ค่าความน่าจะเป็นในการเกิดไฟป่าเพิ่มสูงขึ้นอย่างมีนัยสำคัญเมื่อเข้าสู่กรอบเวลาดังกล่าว เมื่อเปรียบเทียบกับช่วงฤดูฝน

2.tree_cover_pct_2000 ตัวแปรนี้เป็นดัชนีชี้วัด "ปริมาณมวลชีวภาพหรือเชื้อเพลิงธรรมชาติ" (Fuel Load Availability) ในแต่ละพิกัดกริด โดย โมเดลจะประมวลผลว่าพื้นที่ที่มีเปอร์เซ็นต์ความหนาแน่นของป่าไม้สูง ย่อมมีโอกาสสะสมของเศษใบไม้และกิ่งไม้แห้งซึ่งเป็นเชื้อเพลิงหลักมากกว่า ส่งผลให้กริดที่มีค่าตัวแปรนี้สูง ถูกประเมินว่ามีความเสี่ยงและโอกาสเกิดไฟป่ารุนแรงกว่าพื้นที่เปิดโล่งหรือพื้นที่เกษตรกรรม

3.days_since_last_fire ตัวแปรนี้ส่งผลต่อการคำนวณ "รอบการสะสมเชื้อเพลิงใหม่และความแห้งแล้งสะสม" ของโมเดล โดย โมเดลจะวิเคราะห์ความสัมพันธ์แบบย้อนหลัง หากพิกัดใดมีจำนวนวันที่ผ่านไปนับจากไฟป่าครั้งล่าสุดยาวนานในระดับที่พอดี (เช่น ผ่านไปแล้วหลายเดือนในฤดูแล้ง) แบบจำลองจะคาดการณ์ว่าพื้นที่นั้นมีเชื้อเพลิงสะสมกลับมาสมบูรณ์และพร้อมติดไฟสูงในทางกลับกัน หากพิกัดนั้นเพิ่งเกิดไฟป่าไปไม่กี่วันก่อนหน้า (ค่าวันต่ำ) โมเดลจะลดค่าน้ำหนักความเสี่ยงลงเนื่องจากเชื้อเพลิงถูกเผาไหม้ไปแล้ว

4.distance_to_nearest_city_km ตัวแปรการรับรู้และประเมิน "อิทธิพลจากกิจกรรมของมนุษย์" (Human-induced Risk) ซึ่งเป็นสาเหตุหลักของการจุดไฟป่าในประเทศไทย โดยโมเดลจะตรวจจบบัความสัมพันธ์เชิงระยะทาง ยิ่งค่าระยะห่างจากตัวเมืองหรือชุมชนมีค่าน้อย (อยู่ใกล้เขตกิจกรรมมนุษย์ เช่น การหาของป่า หรือการเผาเศษวัชพืชใกล้แนวป่า) แบบจำลองจะปรับค่าความน่าจะเป็นในการทำนายโอกาสเกิดไฟป่าให้สูงขึ้นตามความใกล้ชิดของพิกัดนั้น

5.week_sin / lat_grid สองตัวแปรนี้คือ "ระบุตำแหน่งและเวลาแบบเฉพาะเจาะจง"



(Spatiotemporal Localization) โดยละติจูด (lat_grid) ช่วยให้โมเดลแยกแยะพฤติกรรมการเกิดไฟป่าที่ต่างกันระหว่าง+ภาคเหนือและภาคใต้ของประเทศไทย (เนื่องจากสภาพภูมิอากาศและช่วงเวลาแล้ง ไม่พร้อมกัน) เมื่อผสมกับสัปดาห์ของปี (week_sin) ทำให้แบบจำลองสามารถบ่งชี้เวลา การพยากรณ์ให้แคบลงและระบุช่วงสัปดาห์ที่วิกฤตที่สุดของแต่ละภูมิภาคได้อย่างแม่นยำ ยกย่องความละเอียดในการทำนายบนหน้าเว็บไซต์

5. ผลการแสดงผลและการเชื่อมต่อบนเว็บแอปพลิเคชัน (Dashboard & Web Integration)

หน้าเว็บแอปพลิเคชัน Free Wild Fire Thailand ได้ถูกออกแบบให้แสดงผลข้อมูลเชิงวิทยาศาสตร์แบบ Real-time และสรุปข้อมูลออกมาให้ผู้ใช้งานเข้าใจได้ง่าย โดยมีผลการทำงาน ดังนี้

1.ระบบแจ้งเตือน (Alert Dispatch) ระบบสามารถจัดกลุ่มพื้นที่เซลล์กริดตามระดับความเร่งด่วน (Urgency) พร้อมระบุรายชื่อจังหวัด พิกัด และค่าความน่าจะเป็น (Probability) ในระดับรายวัน เพื่อส่งต่อให้หน่วยงานที่เกี่ยวข้อง เช่น ตรวจสอบความเสี่ยงระดับ MEDIUM ที่ จ.สุพรรณบุรี และ จ.แม่ฮ่องสอน

2.การแสดงจุดไฟป่าปัจจุบัน (Live Fires) ระบบมีการเปรียบเทียบจุดความร้อนที่ตรวจพบแบบเรียลไทม์ ระหว่างเซนเซอร์ GISTDA VIIRS และ NASA FIRMS เพื่อให้ผู้ใช้งานสามารถนำมาเทียบกับผลพยากรณ์ล่วงหน้าได้

3.การประเมินผลในสถานการณ์จริง (Past Predictions - Track Record) ระบบมีฟังก์ชันตรวจสอบย้อนหลัง โดยนำผลที่โมเดลเคยพยากรณ์ไว้ไปเทียบกับข้อมูลดาวเทียม FIRMS ที่เกิดขึ้นจริงในรอบเวลา 1 วัน เพื่อประเมินความแม่นยำและ Hit Rate แบบโปร่งใส (ตรวจสอบได้แบบ Open-source)

สรุปผล

จากการพัฒนาระบบและทดสอบกับข้อมูลจุดความร้อนและสภาพอากาศแบบกริด จำนวน 4.47 ล้านรายการ ผู้จัดทำได้เลือกใช้แบบจำลอง LightGBM Classifier ซึ่งสามารถทำนายการเกิด ไฟป่าได้สำเร็จ โดยประเมินผลผ่านชุดข้อมูลทดสอบ (Test Set) พบว่าแบบจำลองมีประสิทธิภาพโดยรวมอยู่ในเกณฑ์ดีเยี่ยม มีค่าพื้นที่ใต้โค้ง ROC (ROC-AUC) อยู่ที่ 0.8271 นอกจากนี้ระบบ เว็บแอปพลิเคชันที่พัฒนาขึ้นสามารถทำงานได้ตามวัตถุประสงค์ โดยสามารถรับข้อมูลจาก การพยากรณ์ล่วงหน้า 7 วัน มาแสดงผลเป็นรูปแบบแผนที่ความร้อน (Heatmap) จัดแบ่งระดับ ความเสี่ยง (Critical, High, Medium, Low) ได้อย่างชัดเจน พร้อมทั้งมีระบบตรวจสอบจุดความร้อนแบบ Real-time จากดาวเทียม เปรียบเทียบกับผลพยากรณ์ย้อนหลังเพื่อติดตามความแม่นยำของระบบได้โดยอัตโนมัติ

จากผลการดำเนินงาน มีประเด็นสำคัญที่สามารถนำมาอภิปรายผลได้ดังนี้

1.ประสิทธิภาพการจำแนกประเภทกับความไม่สมดุลของข้อมูล (Imbalanced Data) จากผลการทดสอบพบว่า โมเดลมีค่า Precision อยู่ที่ 11.40% ซึ่งดูเหมือนน้อย แต่มีค่า Recall (ความไว) สูงถึง 67.21% และมีอัตราพลาดเหตุการณ์จริง (False Negative) เพียง 1.14% สาเหตุที่เป็นเช่นนี้เพราะเหตุการณ์ไฟป่าถือเป็น "เหตุการณ์ที่เกิดขึ้นยาก (Rare Event)" เมื่อเทียบกับพื้นที่ป่าทั้งหมดในประเทศไทย ทำให้ชุดข้อมูลมีความไม่สมดุลสูง การที่โมเดลยอมให้มีอัตราการเตือนภัยผิดพลาด (False Positive) อยู่บ้าง เพื่อแลกกับการดักจับและเตือนภัยเหตุการณ์ไฟป่าที่จะเกิดขึ้นจริงให้ได้มากที่สุด ถือเป็นการตัดสินใจ (Trade-off) ที่เหมาะสมและตอบโจทย์ที่สุดสำหรับระบบแจ้งเตือนภัยพิบัติ

2.ปัจจัยที่มีอิทธิพลต่อการเกิดไฟป่า (Feature Importance) ผลการวิเคราะห์ตัวแปรพบว่า "ดัชนีวันในรอบปี (Day of Year)" เป็นตัวแปร ที่มีอิทธิพลต่อโมเดล



มากที่สุด สอดคล้องกับบริบทของประเทศไทยที่ไฟป่ามักเกิดขึ้นตามฤดูกาลอย่างชัดเจน (โดยเฉพาะช่วงฤดูแล้ง) นอกจากนี้ ปัจจัยด้าน "เปอร์เซ็นต์พื้นที่ป่าปกคลุม" และ "ระยะห่างจากเมือง" ยังสะท้อนให้เห็นว่าลักษณะทางภูมิศาสตร์และการเข้าถึงของมนุษย์ เป็นตัวแปรสำคัญที่ทำให้สภาพแวดล้อมนั้นๆ มีความเสี่ยงในการเกิดไฟป่า

3. ความเสถียรของแบบจำลอง ผลการทดสอบค่า AUC ย้อนหลังแบบ Rolling ตลอดช่วงระยะเวลา 17 เดือน พบว่าโมเดล มีค่า AUC เฉลี่ยสูงถึง 0.915 และมีความผันผวนน้อยมาก (ความเบี่ยงเบนมาตรฐาน 0.070) แสดงให้เห็นว่าการใช้ตัวแปรแบบสเก็ด (Feature Engineering) เช่น ค่าเฉลี่ยสะสม 7 วัน (Rolling Days) หรือประวัติการเกิดไฟ ช่วยให้โมเดลมีความทนทาน (Robustness) ต่อการเปลี่ยนแปลงของสภาพอากาศในแต่ละปีได้เป็นอย่างดี

ข้อเสนอแนะ

1. การเชื่อมต่อระบบแจ้งเตือนอัตโนมัติ (Alert Dispatch): ปัจจุบันระบบแจ้งเตือนในฝั่งหลังบ้าน (Backend) ยังทำงานในรูปแบบจำลองการคิวข้อความ (Stub Mode) ในอนาคตสามารถ นำ API ของผู้ให้บริการ เช่น LINE Messaging API หรือ SMS Gateway มาเชื่อมต่อ เพื่อส่งข้อความแจ้งเตือนพื้นที่เสี่ยงสูงไปยังเจ้าหน้าที่พิทักษ์ป่าในแต่ละเขตพื้นที่ได้แบบทันที

2. การเพิ่มความละเอียดของข้อมูล (Data Resolution): หากสามารถเข้าถึงข้อมูลสภาพอากาศระดับจุลภาค (Microclimate) หรือข้อมูลจากสถานีตรวจวัดทางภาคพื้นดิน (IoT Sensors) ที่มีความละเอียดของขนาดกริดเล็กกว่า $0.1^\circ \times 0.1^\circ$ จะช่วยเพิ่มความแม่นยำในเชิงพื้นที่ (Spatial Accuracy) ได้ดียิ่งขึ้น

3. การเพิ่มฟีเจอร์รายงานไฟป่าจากประชาชน: สามารถพัฒนาฟังก์ชันบนหน้าเว็บ แอปพลิเคชัน เพื่อให้ประชาชนในพื้นที่ร่วมรายงานจุดที่พบเห็นกลุ่มควันหรือไฟ

ป่า (Crowdsourcing) เพื่อนำมาเป็นข้อมูลเสริมยืนยันร่วมกับข้อมูลดาวเทียม ซึ่งจะช่วยลดข้อจำกัดของดาวเทียมในวันที่สภาพอากาศปิดหรือมีเมฆหนาได้

กิตติกรรมประกาศ

เว็บไซต์ทำนายไฟป่าด้วยปัญญาประดิษฐ์ ได้รับการสนับสนุนจากผู้อำนวยการโรงเรียน ดร.ทวีศักดิ์ เจริญเตี้ย ที่ได้กรุณาเอื้อเฟื้อสถานที่ในการศึกษาและทดลอง รองผู้อำนวยการกลุ่มบริหารงานวิชาการ นายจาตุรนต์ พันธวาส ที่ได้ให้คำแนะนำต่างๆ ตลอดจนได้รับความอนุเคราะห์จากคุณครูกลุ่มสาระการเรียนรู้วิทยาศาสตร์และเทคโนโลยี ครูฤกษ์ญา ทองเชื้อ ครูที่ปรึกษาโครงการที่ได้ให้คำแนะนำในการทำโครงการ ตลอดจนเอกสารและตำราต่างๆ ที่ให้ประโยชน์สำหรับ การศึกษาค้นคว้า ขอขอบคุณ คณะครูกลุ่มสาระการเรียนรู้วิทยาศาสตร์ที่ได้ให้คำแนะนำในการทดลองและ สนับสนุนด้านอุปกรณ์เครื่องมือในการทำโครงการ และ ขอขอบคุณผู้ปกครองที่ให้คำแนะนำและการสนับสนุนใน การทำโครงการตั้งแต่เริ่มจนโครงการเสร็จสิ้น

เอกสารอ้างอิง

ปาริฉัตร สุขศรี, ศิริมา ปัญญาเมธิกุล, กฤตยาภรณ์ เจริญผล, พิชญ รัชฎาวงศ์, & กัมปนาท ดีอุดม จันทร์. (2567). การใช้ข้อมูลการสำรวจระยะไกลและระบบสารสนเทศภูมิศาสตร์ในการ ประเมินพื้นที่เสี่ยงไฟป่าในเขตพื้นที่ป่าโรงเรียนนายร้อยพระจุลจอมเกล้าและพื้นที่ใกล้เคียง จังหวัดนครนายก. วารสารวิชาการโรงเรียนนายร้อยพระจุลจอมเกล้า, 22(1), 111-130.

Schroeder, W., Oliva, P., Giglio, L., & Csiszar, I. A. (2014). *The New VIIRS 375 m active fire detection data product: Algorithm description and initial assessment.*



- Remote Sensing of Environment, 143, 85-96.
- Hansen, M. C., Potapov, P. V., Moore, R., Hancher, M., Turubanova, S. A., Tyukavina, A., & Townshend, J. R. (2013). *High-resolution global maps of 21st-century forest cover change*. science, 342(6160), 850-853.
- Vitolo, C., Di Giuseppe, F., Barnard, C., Coughlan, R., San-Miguel-Ayanz, J., Libertá, G., & Krzeminski, B. (2020). *ERA5-based global meteorological wildfire danger maps*. Scientific data, 7(1), 216.
- Vadrevu, K. P., Lasko, K., Giglio, L., Schroeder, W., Biswas, S., & Justice, C. (2019). *Trends in vegetation fires in south and southeast Asian countries*. Scientific reports, 9(1), 7422.
- Tanpipat, V., McCarty, J. L., Davies, D., Schroeder, W., & Elvidge, C. (2023). *Active Fire Monitoring of Thailand and Upper ASEAN by Earth Observation Data: Benefits, Lessons Learned, and What Still Needs to Be Known*. In *Vegetation Fires and Pollution in Asia* (pp. 139-153). Cham: Springer International Publishing.
- Bihari, E., Dyson, K., Johnston, K., Torre, D. M. G., Chaiyana, A., Tenneson, K., & Saah, D. (2025). *Modeling Seasonal Fire Probability in Thailand: A Machine Learning Approach Using Multiyear Remote Sensing Data*. Remote Sensing, 17(19), 3378.
- Li, Y., Li, G., Wang, K., Wang, Z., & Chen, Y. (2023). *Forest fire risk prediction based on stacking ensemble learning for Yunnan Province of China*. Fire, 7(1), 13.
- Eaturu, A., & Vadrevu, K. P. (2025). *Evaluation of machine learning and deep learning algorithms for fire prediction in Southeast Asia*. Scientific Reports, 15(1), 18807.