

Vegetation Drought Monitoring in Bangkok, Thailand

Using Satellite Imagery and Machine Learning

Santawat Sukrungsri

Agrometeorological Sub-Division, Meteorological Development Division, Thai Meteorological Department



Core Problem: Rapid urbanization and climate variability are intensifying drought events, threatening the vitality of crucial urban green spaces.

The Gap: Monitoring vegetation drought in complex, heterogeneous urban landscapes like Bangkok requires high-resolution, multi-variable approaches beyond traditional single-index methods.

The Objective: To integrate satellite-derived remote sensing indices with machine learning to predict and map the Temperature Vegetation Dryness Index (TVDI).



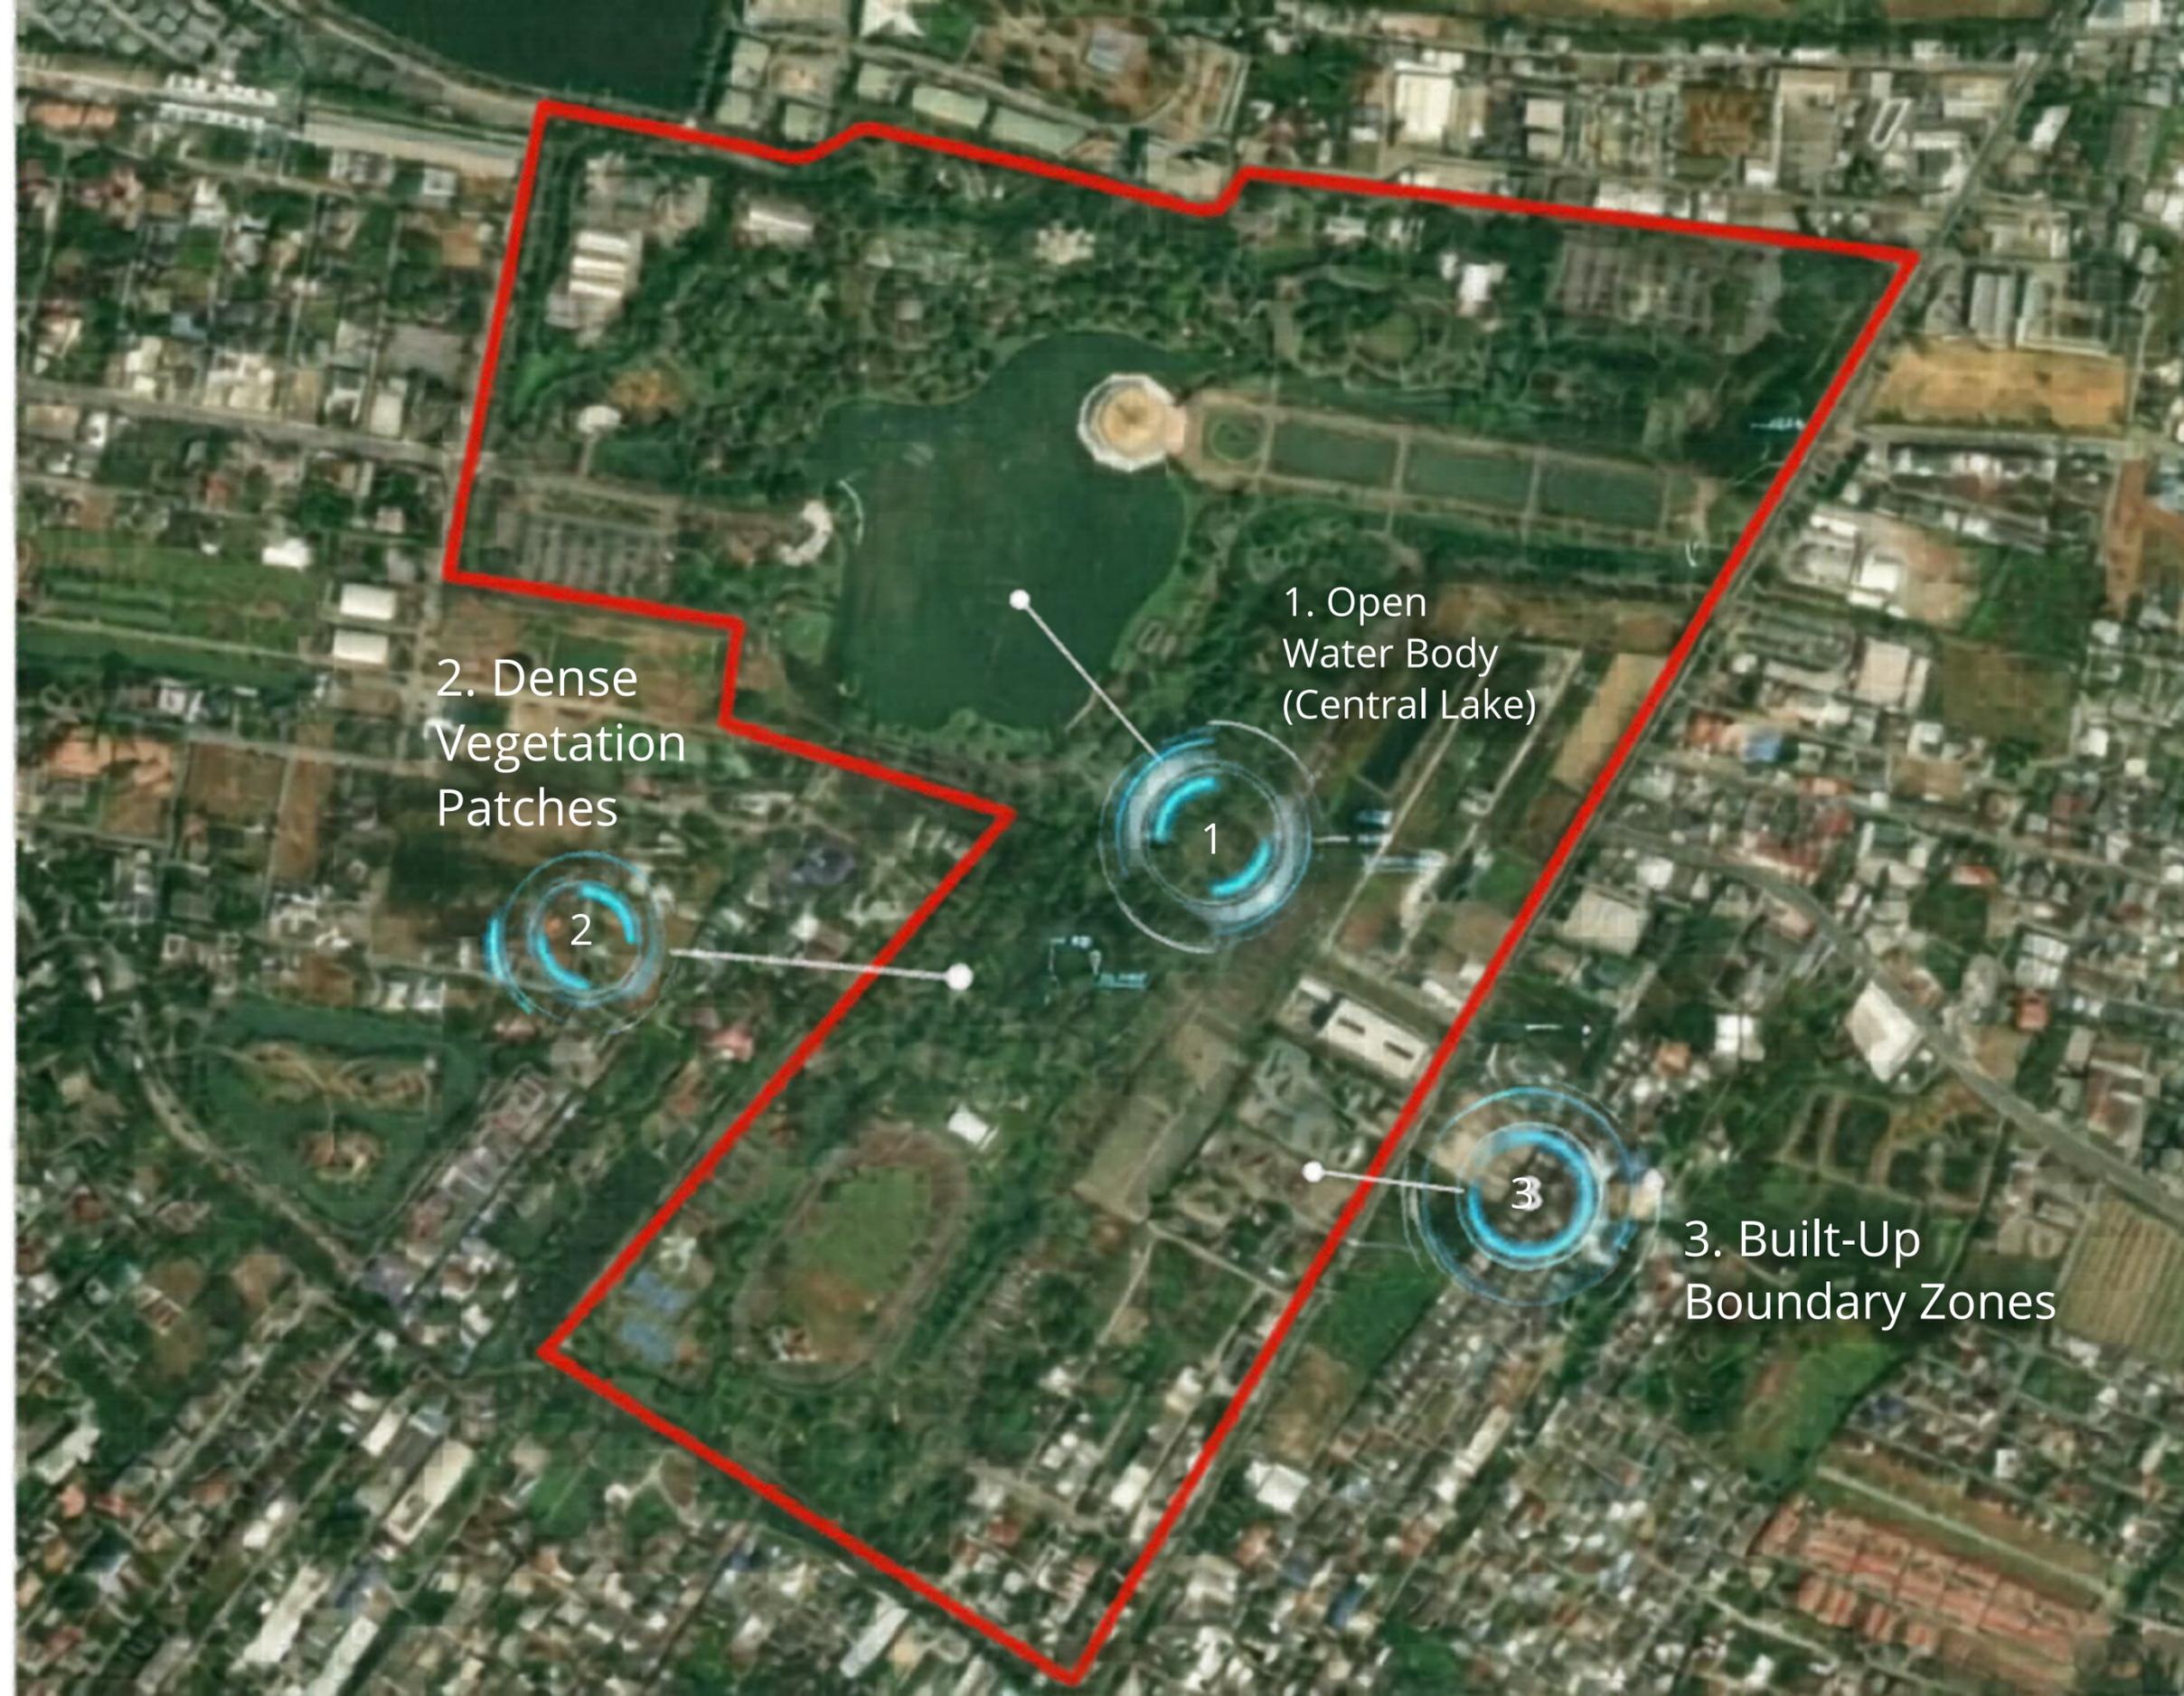
Location:

Suan Luang Rama IX Park, Bangkok, Thailand.

Significance: One of the largest, most critical urban green spaces in a densely populated metropolitan area.

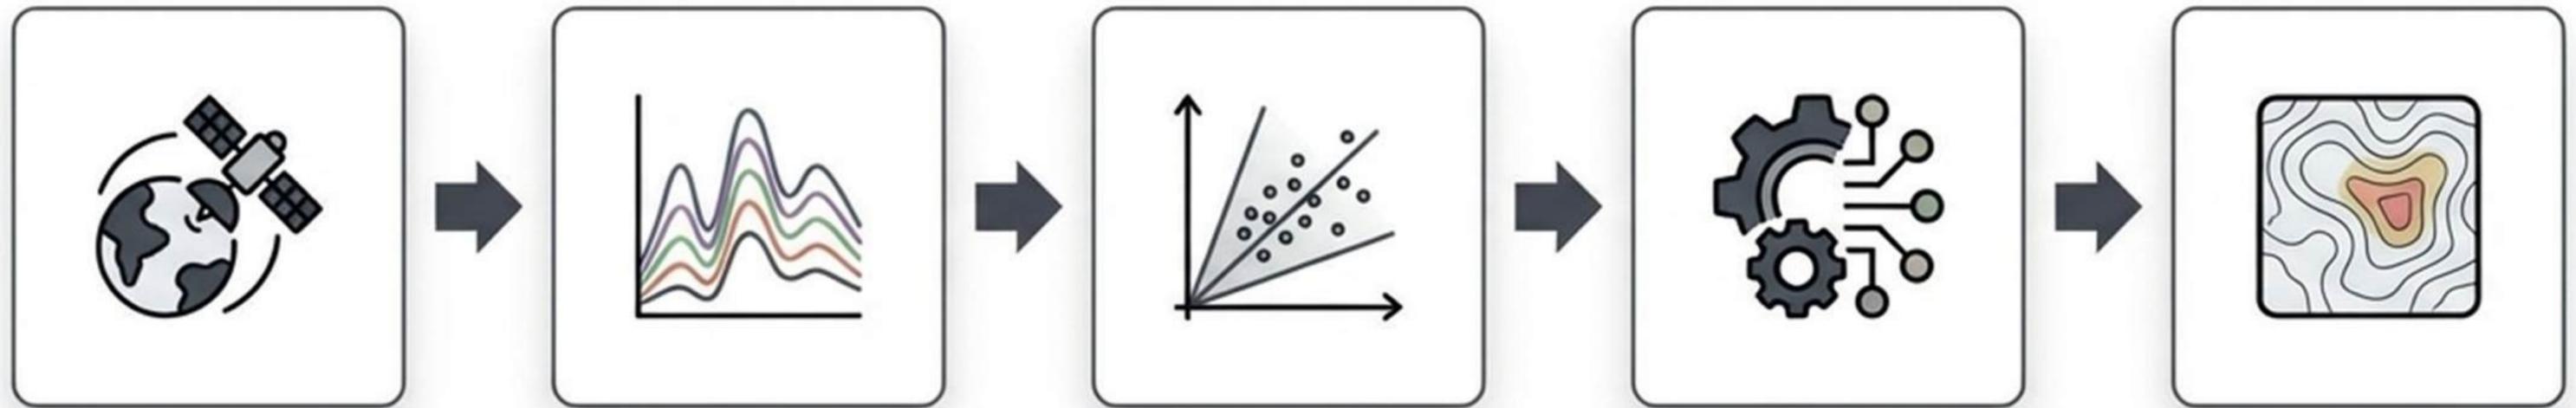
Landscape

Heterogeneity: Features a complex mix of open water bodies, varying vegetation densities, bare soil, and concrete boundaries—an ideal environment for testing robust spatial drought models.



The Methodological Pipeline

A data-driven workflow for high-resolution environmental monitoring



Step 1: Satellite Acquisition

Sentinel-2
(Multispectral) +
Landsat 8/9 (Thermal)

Step 2: Feature Extraction

7 Spectral Indices +
Land Surface
Temperature (LST)

Step 3: Target Formulation

TVDI Calculation via
NDVI-LST feature
space

Step 4: ML Prediction

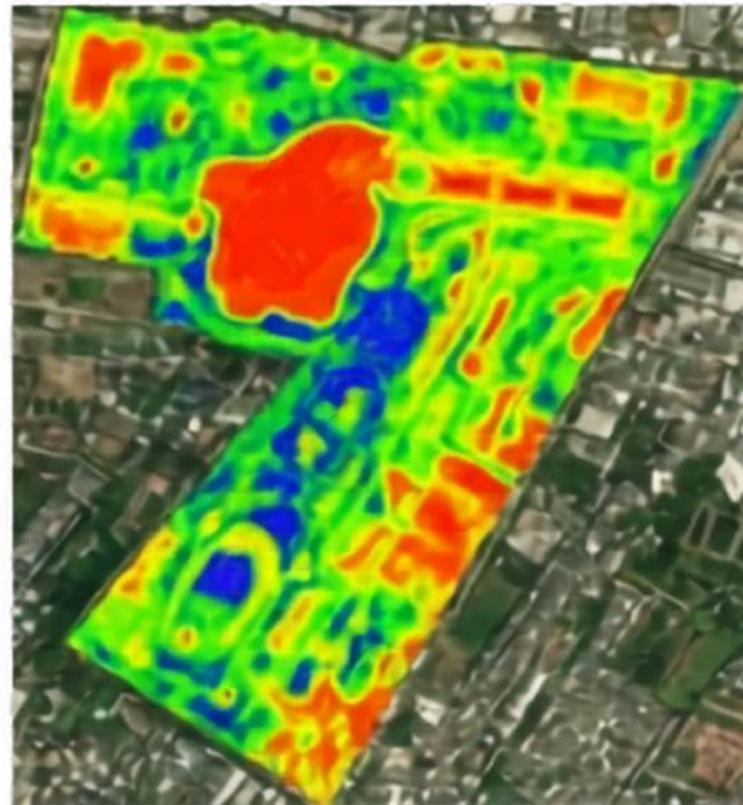
4 Algorithmic Models
(RF, SVM, XGB, GBR)

Step 5: Spatial Mapping

High-resolution
Drought Risk Zones

Spectral Feature Extraction Framework

Pillar 1: Vegetation Condition (Satinel-2 RED/NIR)



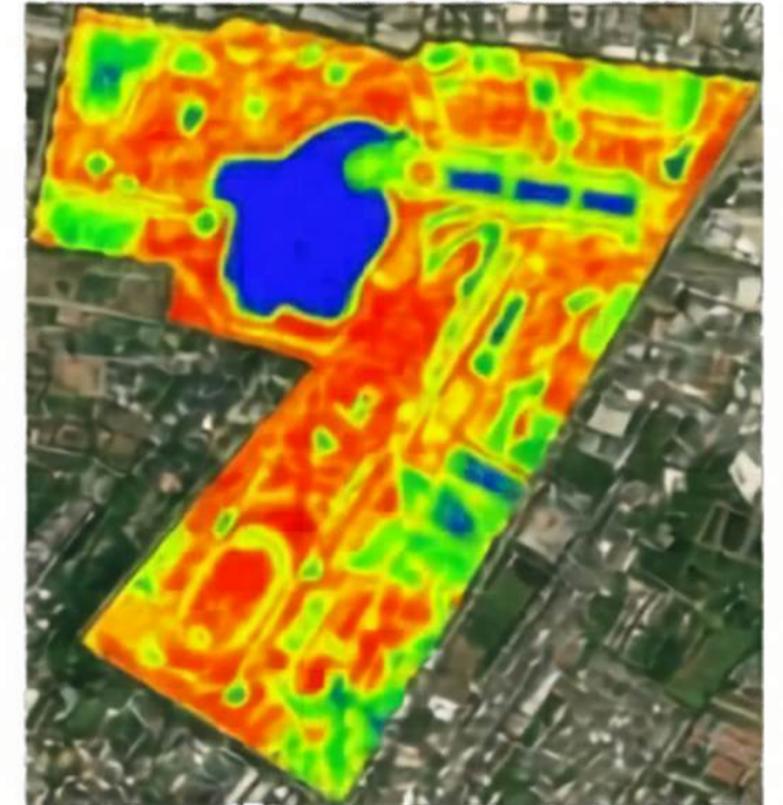
NDVI: Baseline Vegetation Vigor
SAVI: Soil-Adjusted Density
VCI: Historical Condition Context

Pillar 2: Moisture Dynamics (Satinel-2 SWIR)



NMDI: Surface/Soil Moisture
LSWI: Vegetation Water Content
MSI: Moisture Stress Indicator

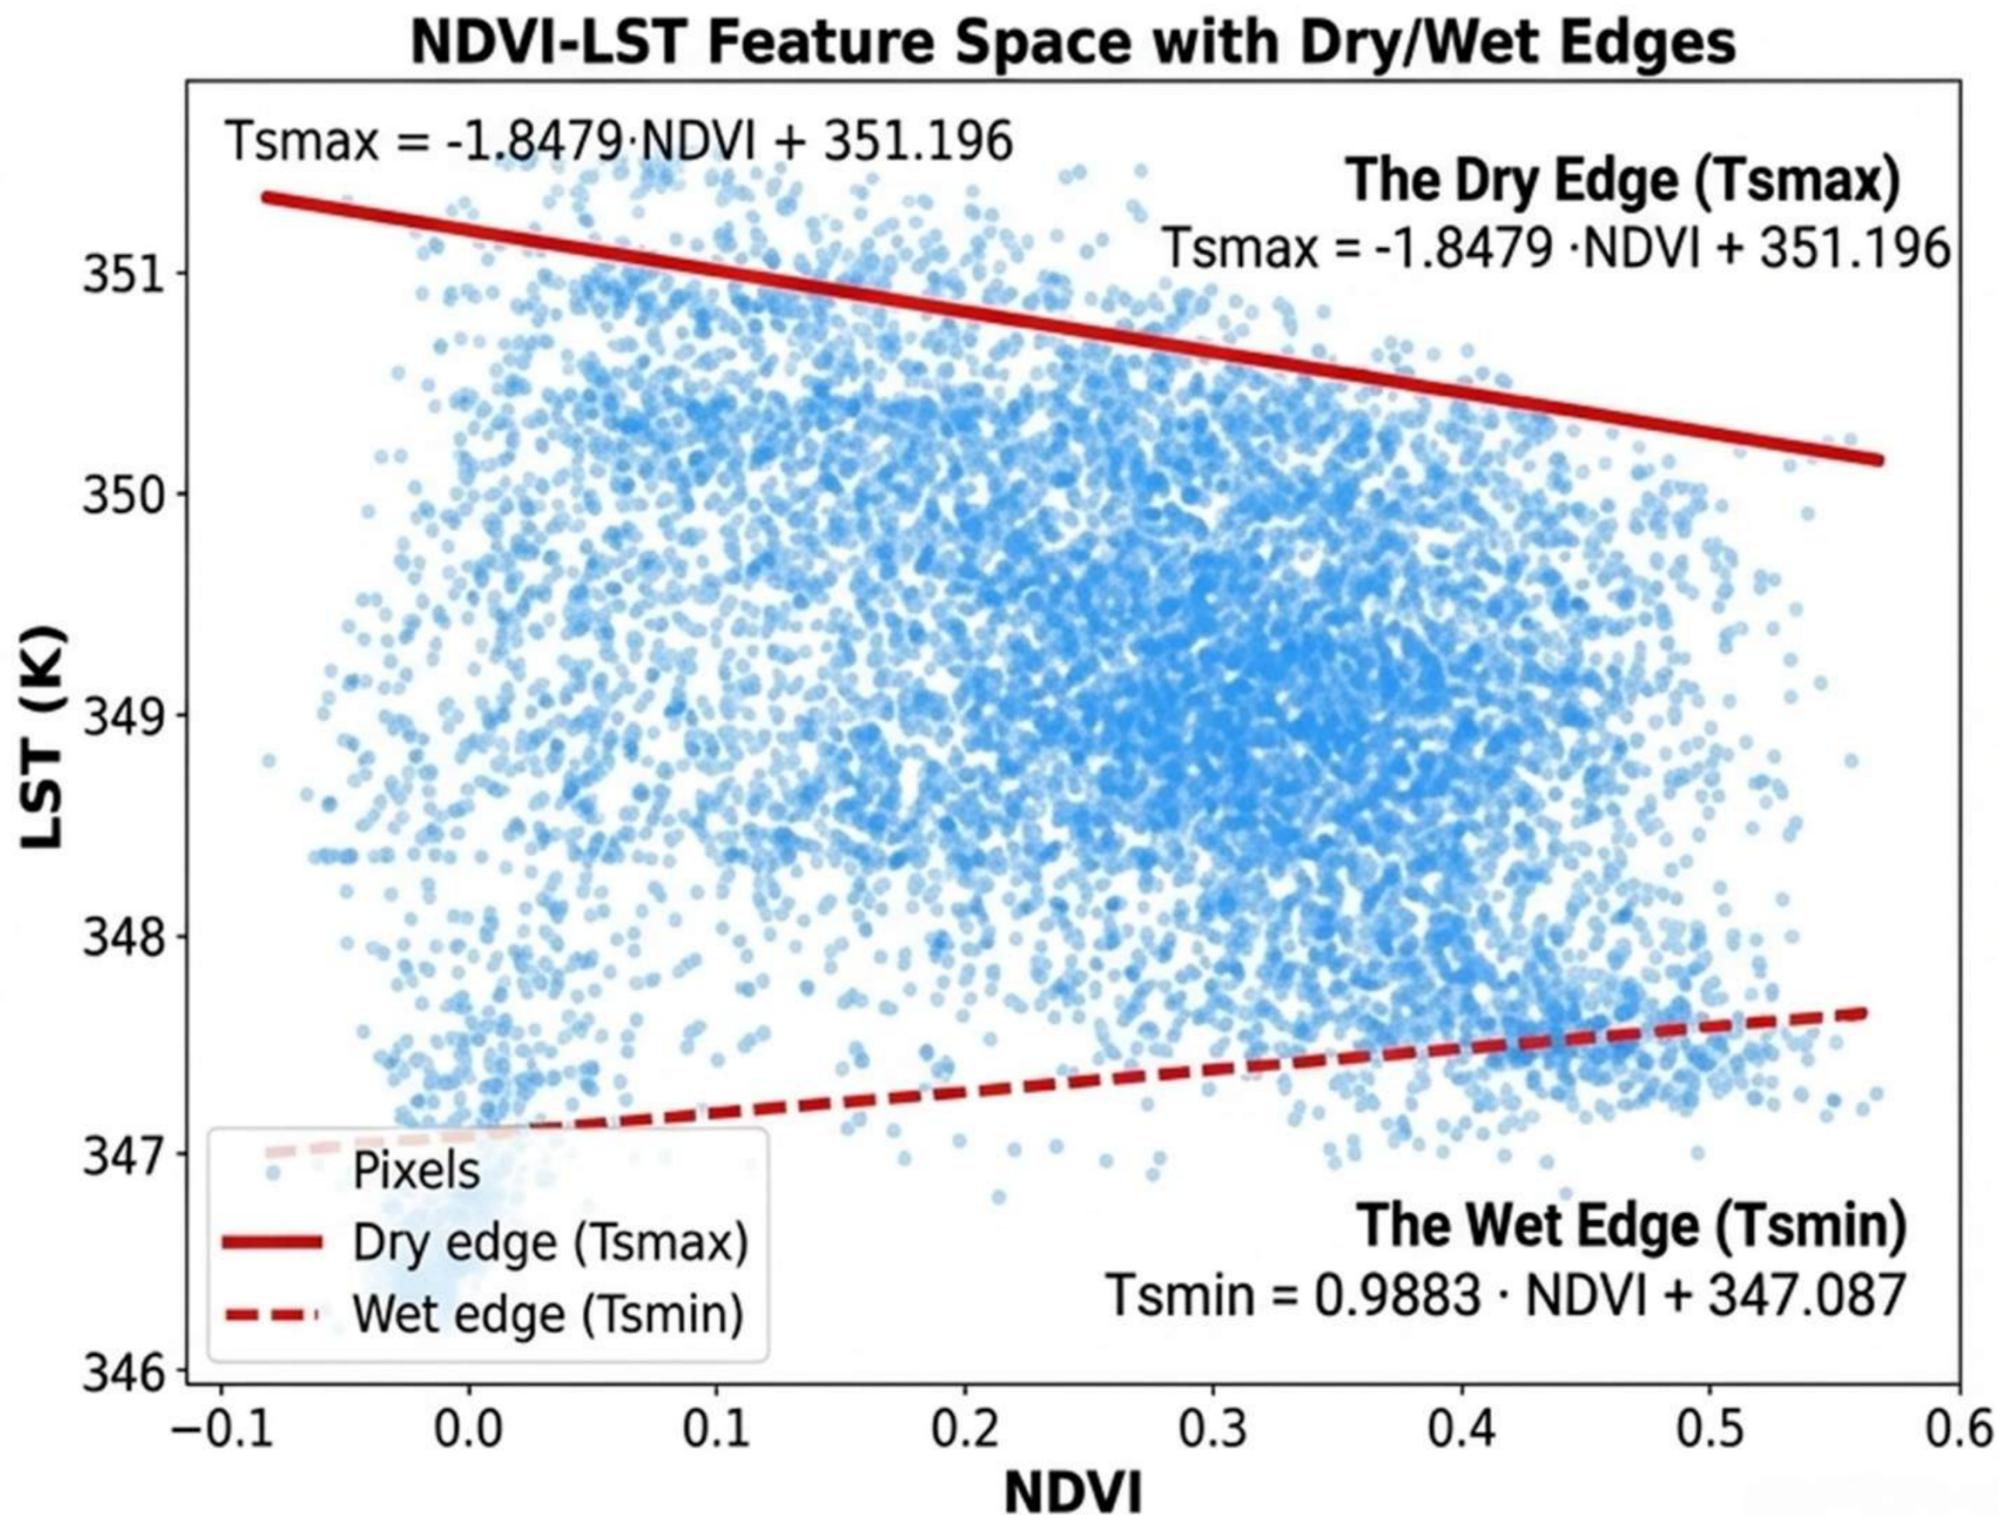
Pillar 3: Surface Water (Satinel-2 GREEN/NIR)



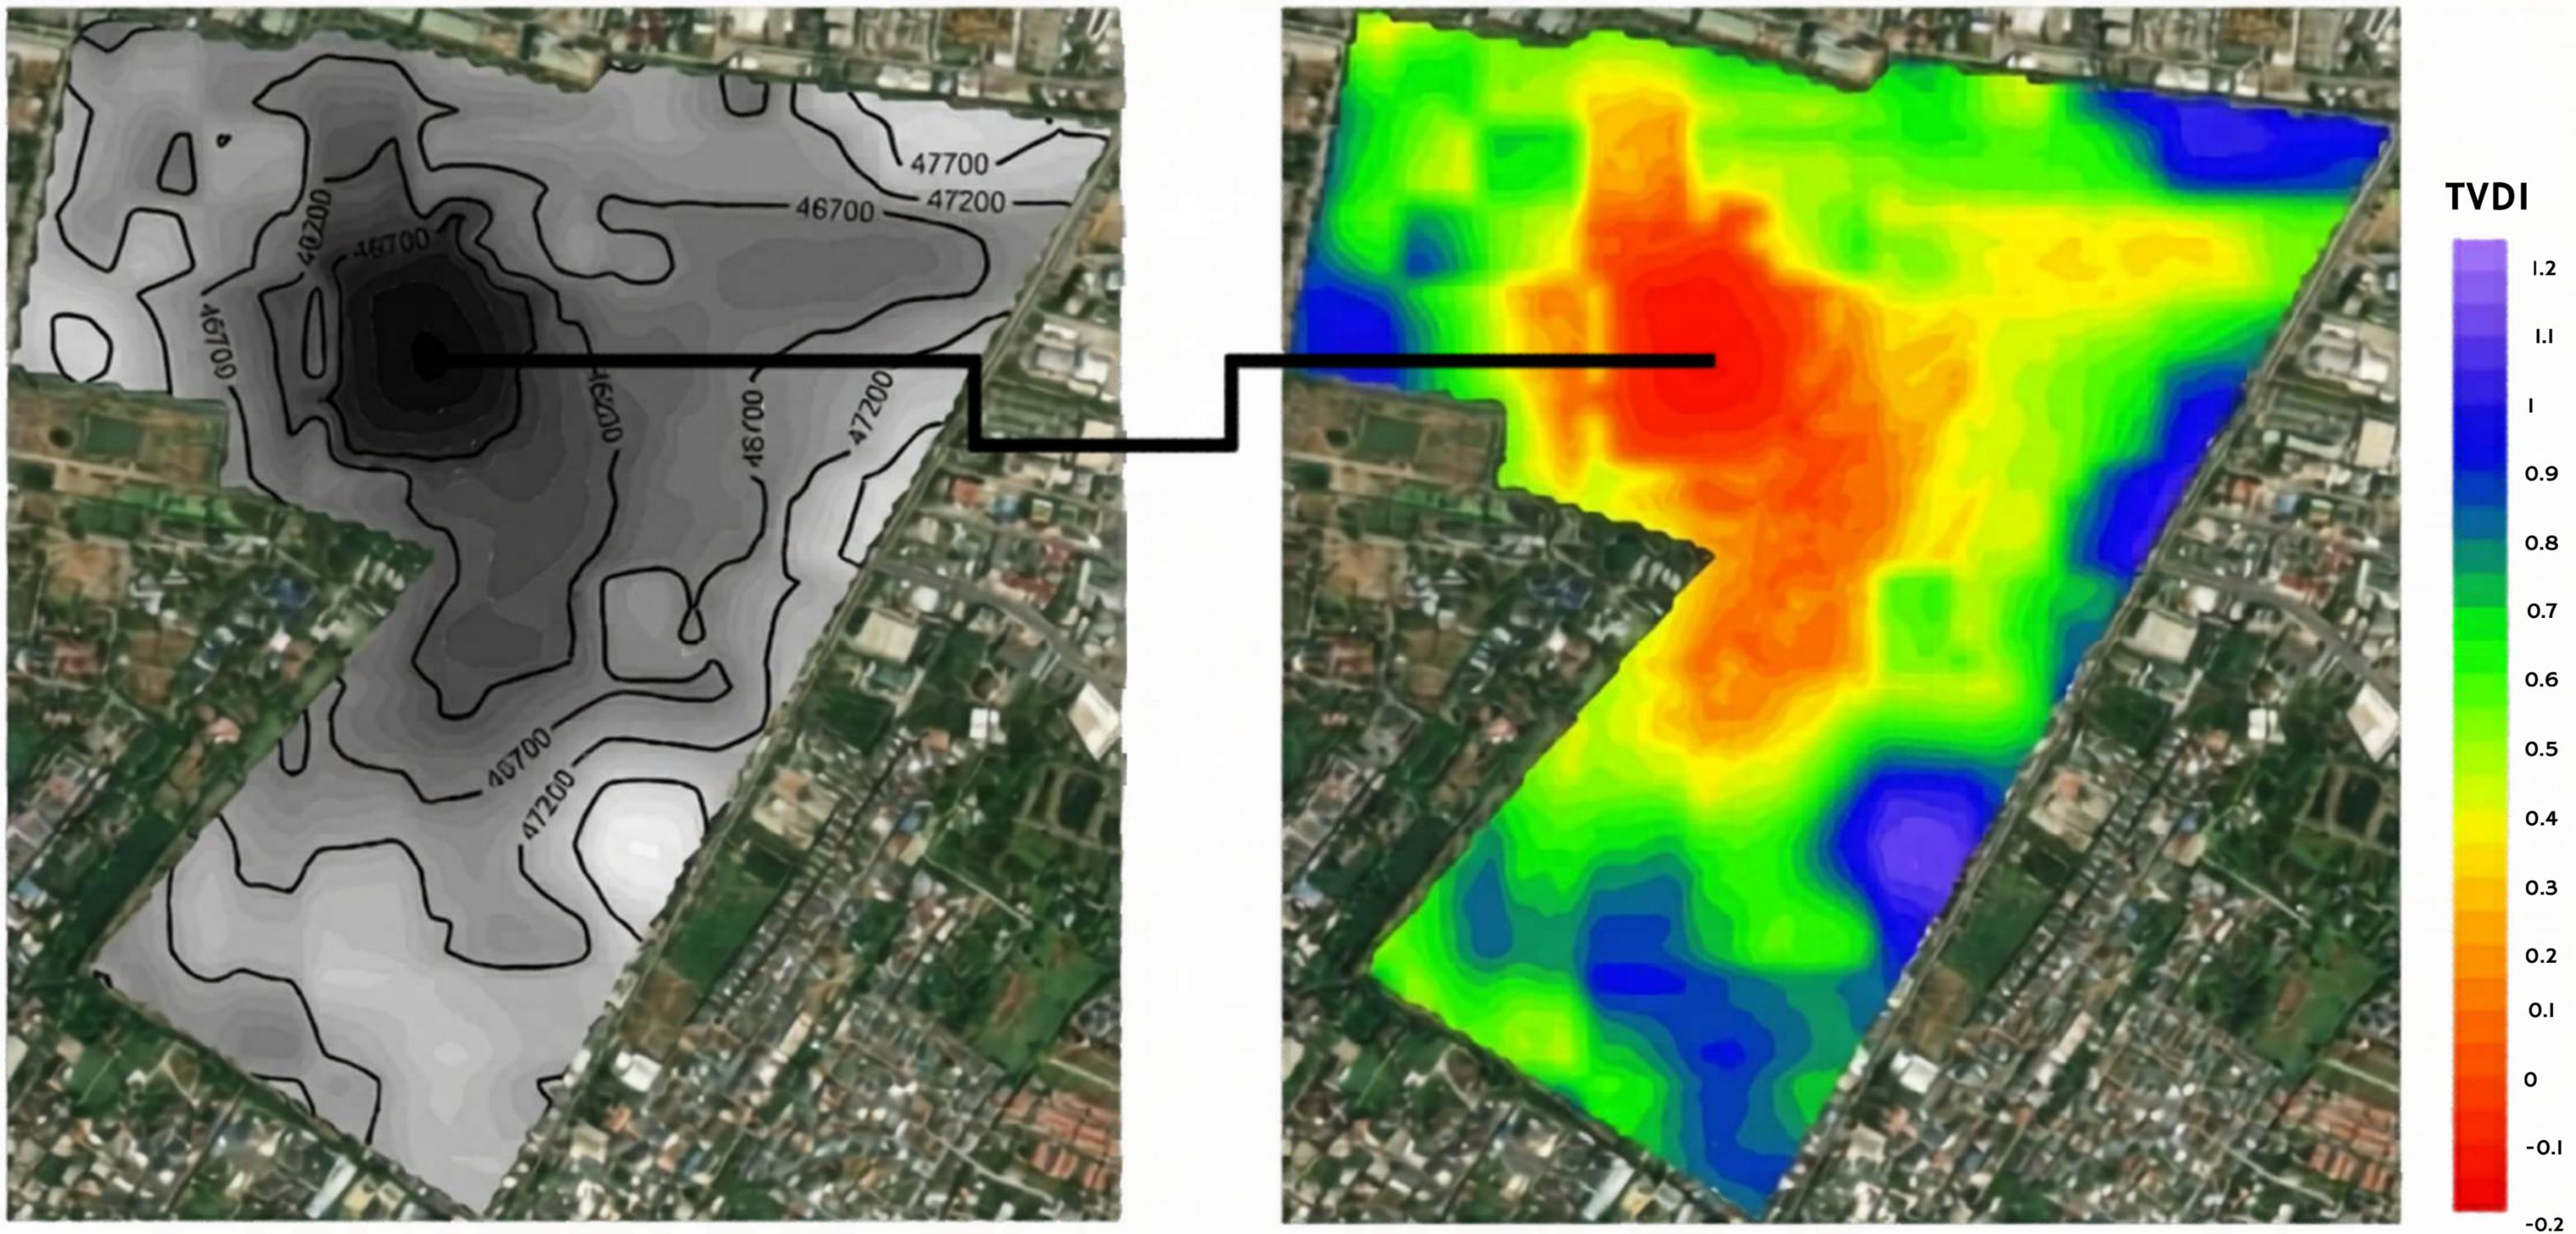
NDWI: Open Water Body Detection

Conceptualizing TVDI (The Core Indicator)

- **The Framework:** TVDI integrates Land Surface Temperature (LST) with Vegetation density (NDVI) to estimate surface moisture.
- **The Dry Edge (T_{max}):** High temperatures & sparse vegetation = High water stress.
- **Formula:** $T_{\text{max}} = -1.8479 \times \text{NDVI} + 351.196$
- **The Wet Edge (T_{min}):** Cool temperatures & dense vegetation = Maximum evapotranspiration.
- **Formula:** $T_{\text{min}} = 0.9883 \times \text{NDVI} + 347.087$
- **The Metric:** Output ranges from 0 (Wet/No Drought) to 1.0+ (Severe Drought).



Thermal Signature & TVDI



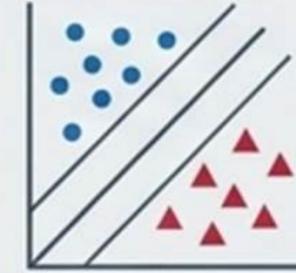
Thermal Imprint: The large central water body acts as a localized cooling feature, represented by the deep dark thermal signature. **Drought Translation:** This cool thermal signature directly translates to low TVDI values (wet conditions, shown in red), while the hotter peripheral built-up areas map directly to high TVDI (severe water stress, shown in blue/green).

The Machine Learning Engine



Random Forest (RF)

Ensemble bagging approach; highly robust to noise and multicollinearity among spectral indices



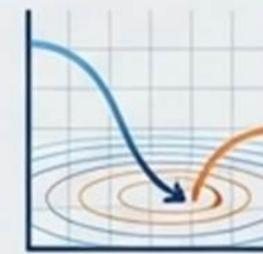
Support Vector Machine (SVM)

Maximizes decision margins; utilizes an RBF kernel to capture complex, nonlinear environmental relationships



XGBoost (XGB)

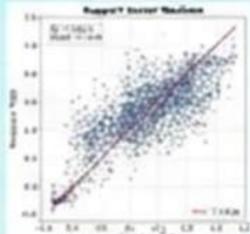
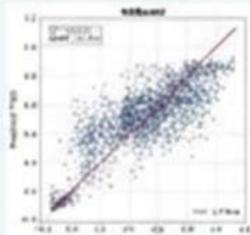
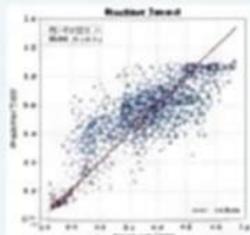
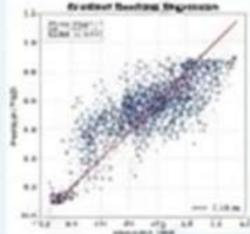
Sequential gradient boosting; minimizes residual errors iteratively for high predictive accuracy.



Gradient Boosting Regression (GBR)

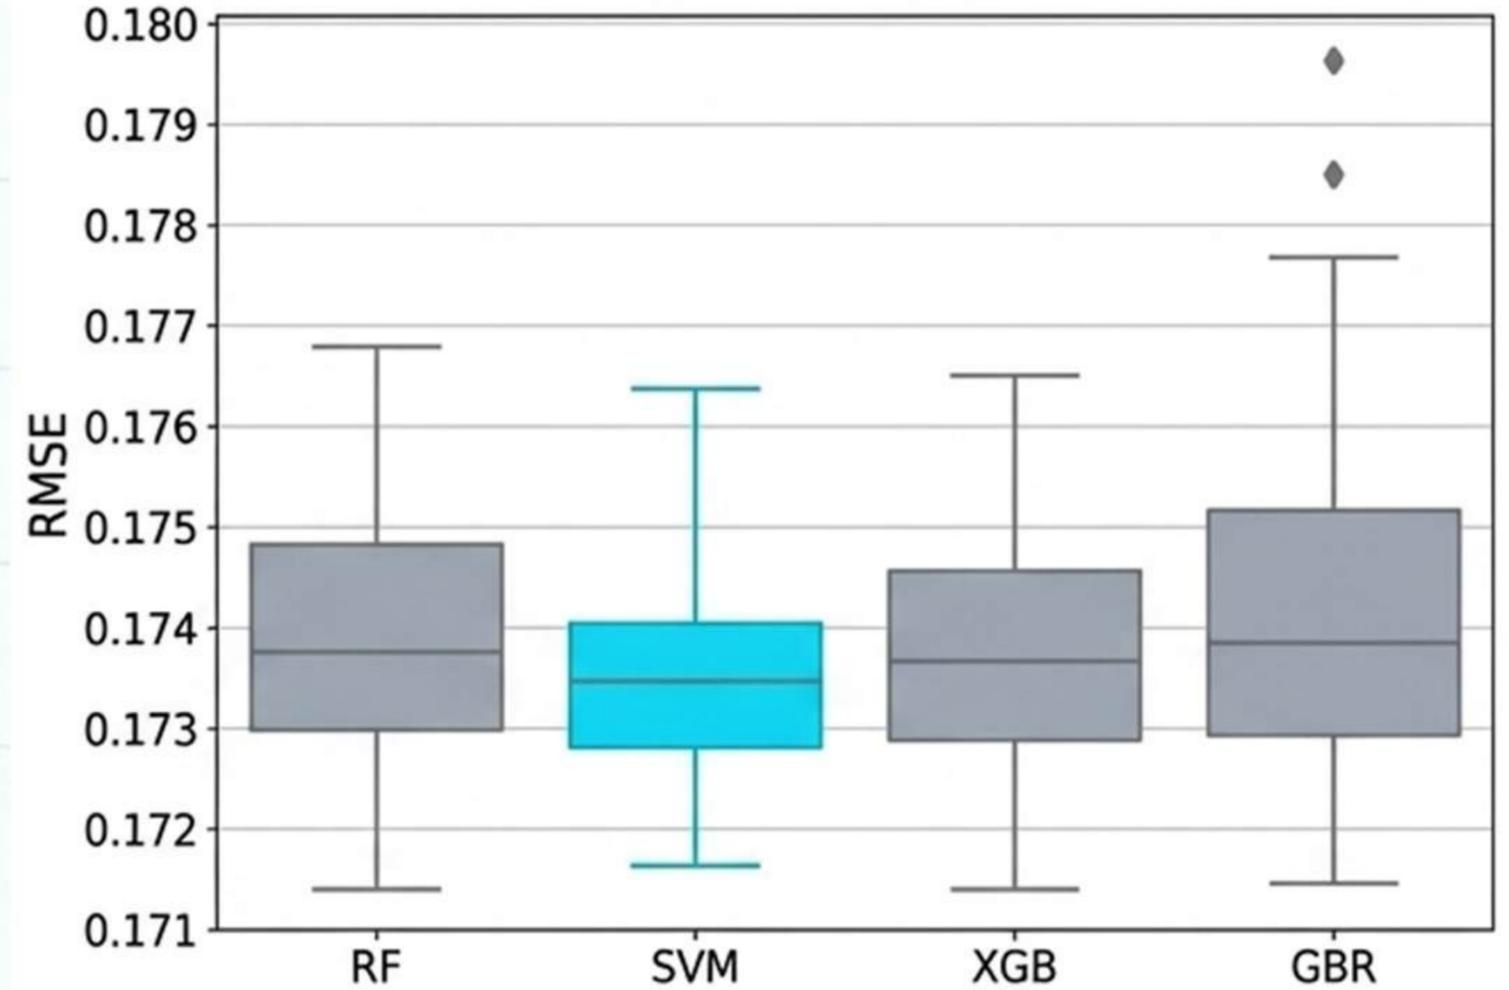
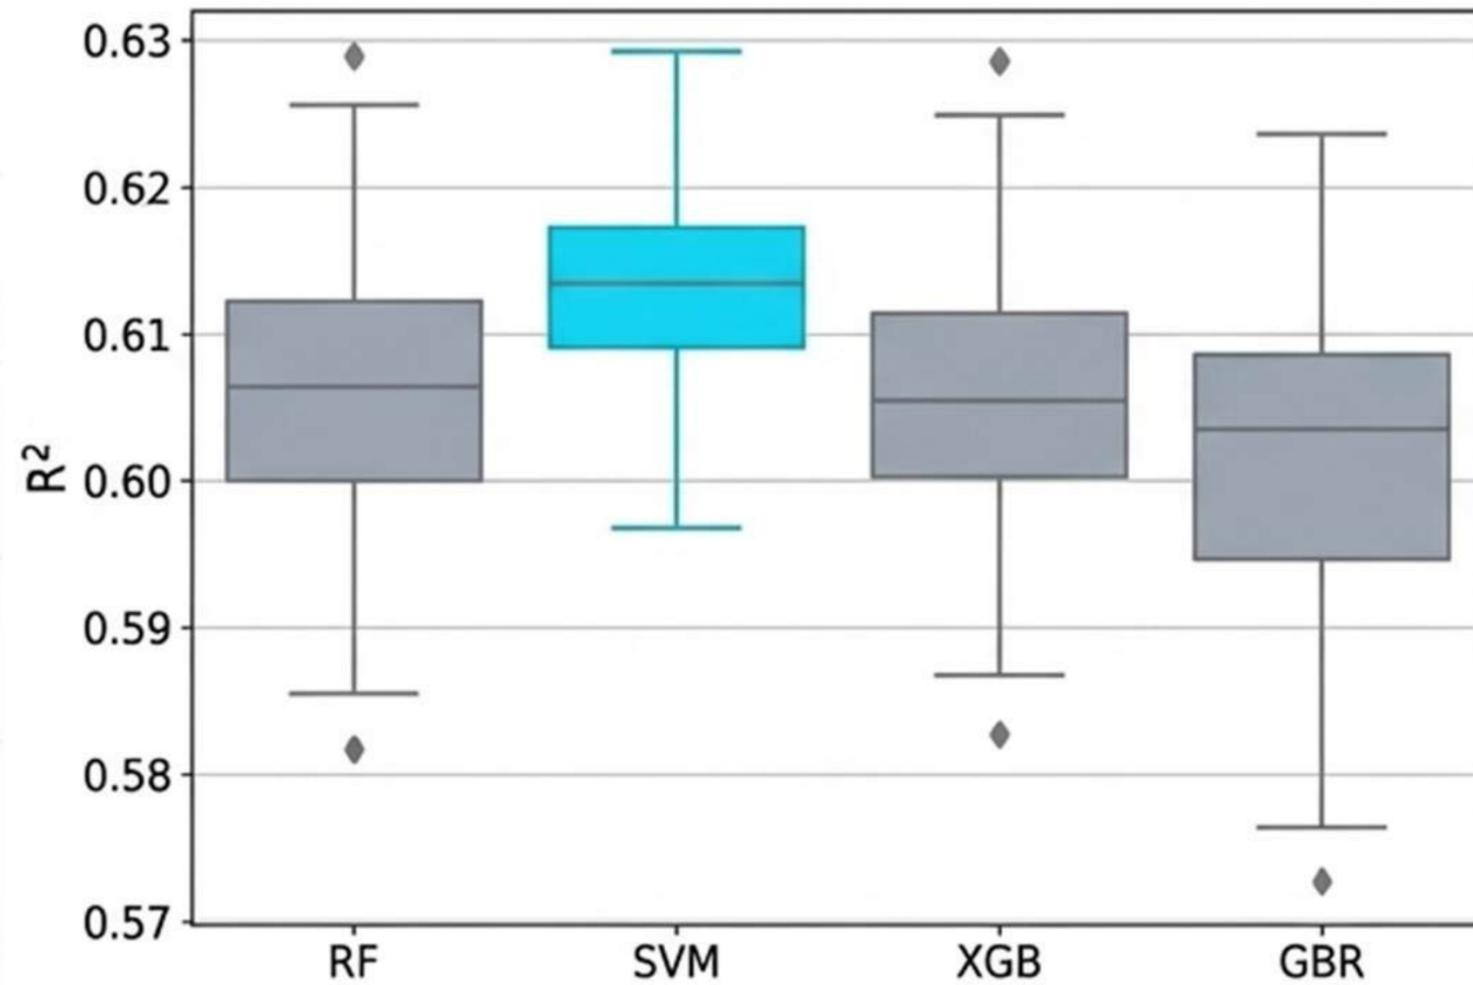
Optimizes via gradient descent in function space to handle interacting geospatial variables.

Model Performance Matrix

Algorithm	R ² Score	RMSE Score	1:1 Line Fit
Support Vector Machine (SVM)	0.631	0.174	
XGBoost	0.623	0.176	
Random Forest	0.620	0.177	
Gradient Boosting (GBR)	0.620	0.177	

Insight: All models show strong 1:1 agreement and slightly underestimate extreme conditions, but SVM proved most capable of capturing complex nonlinear data patterns.

Evaluating Model Stability

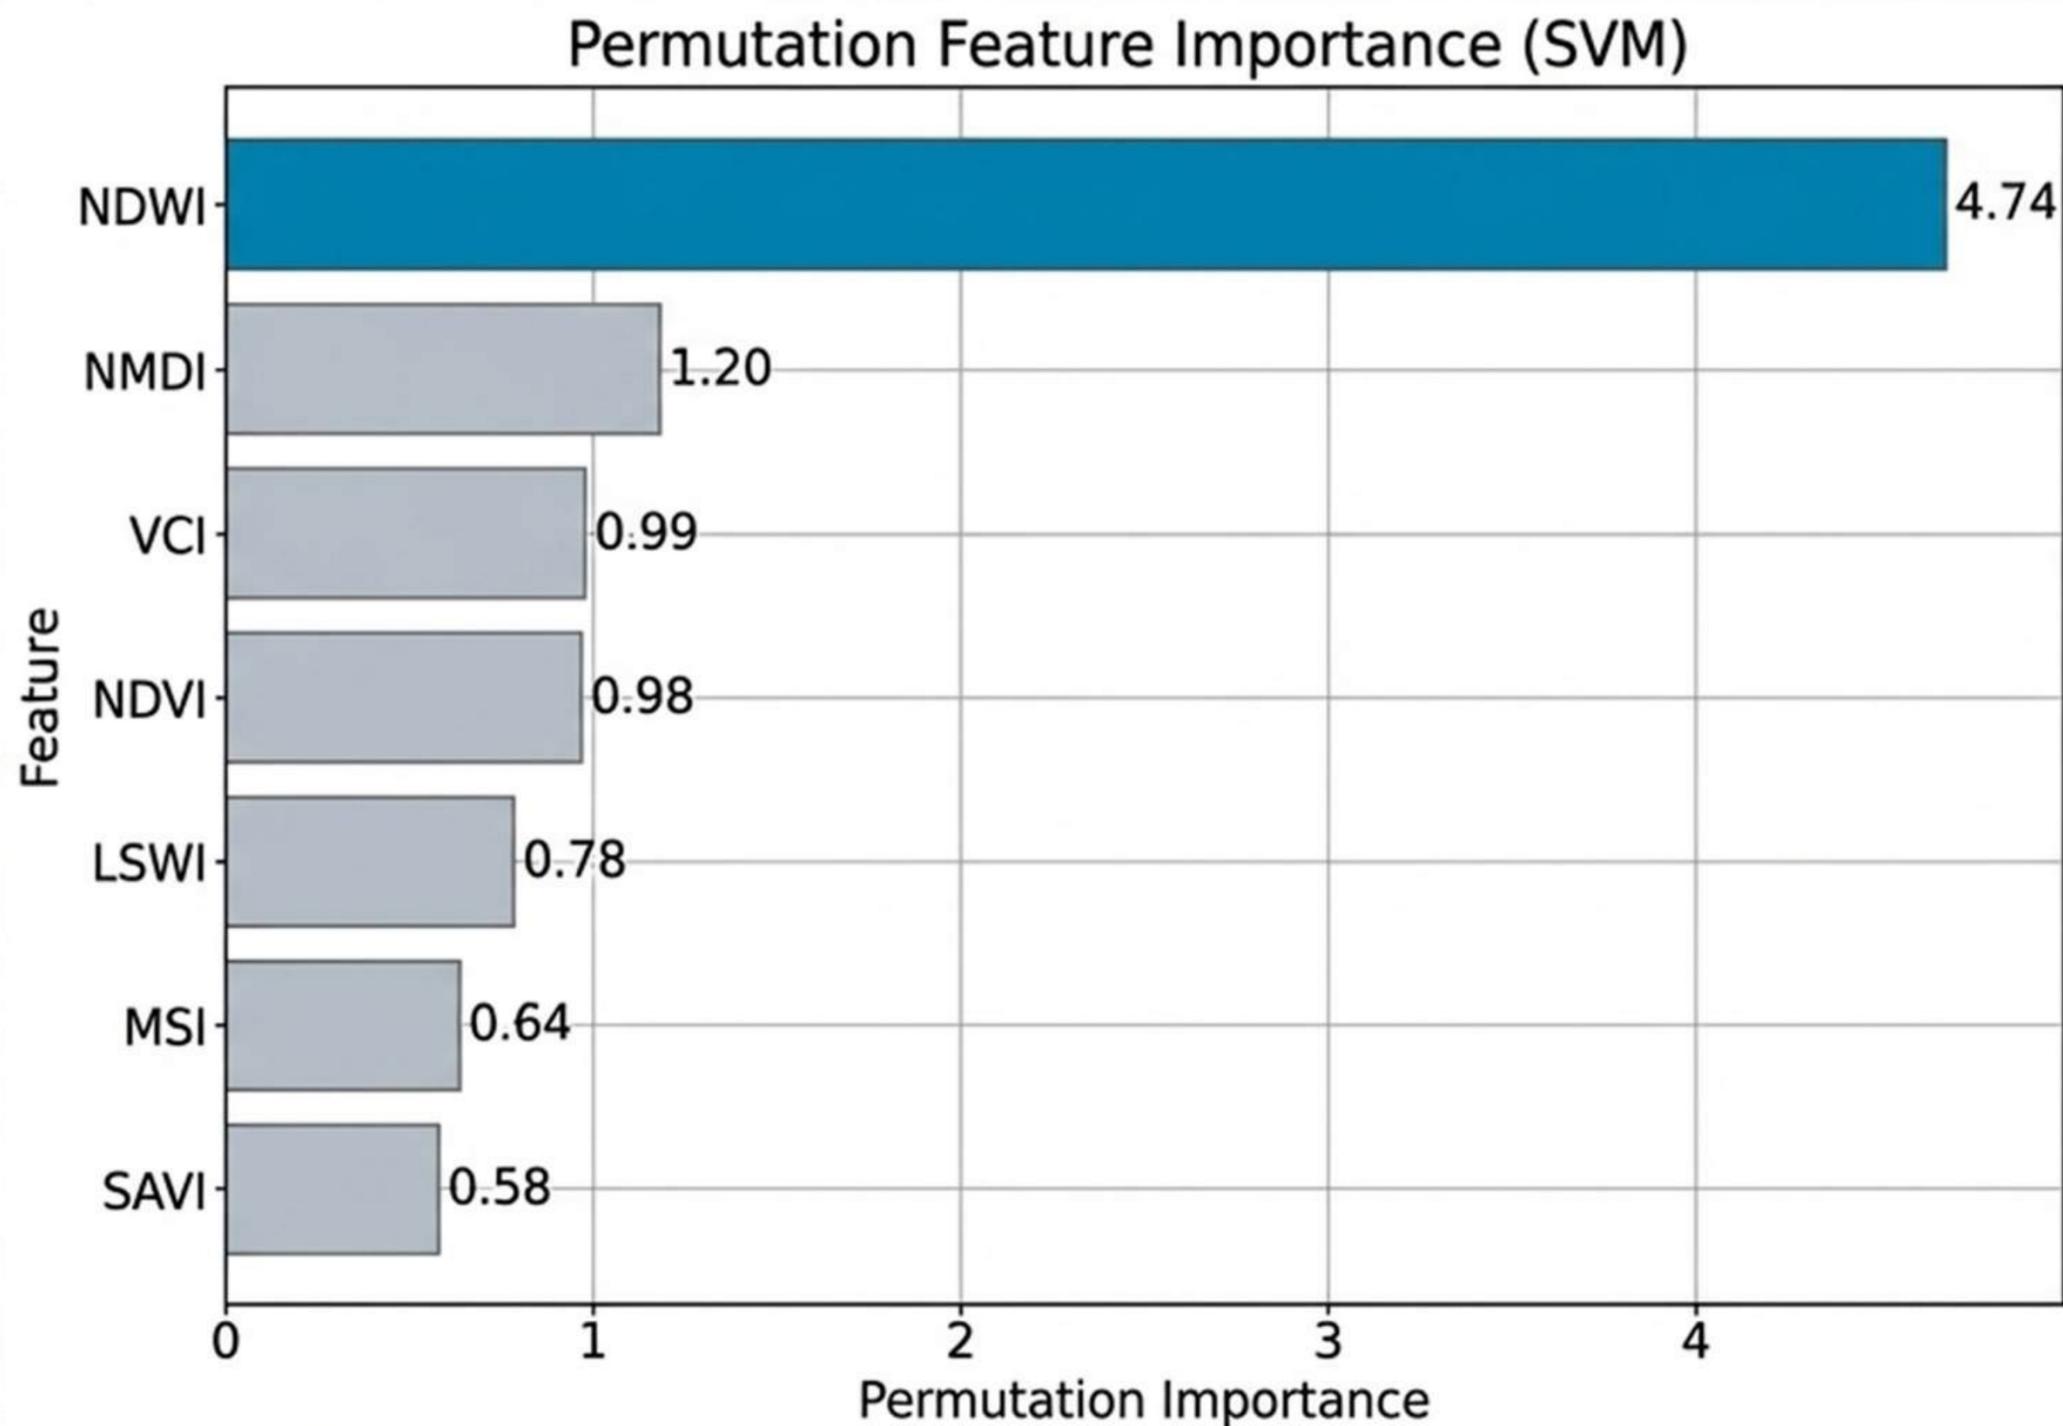


Accuracy vs. Consistency: While R^2 metrics were close across the board, model stability varied significantly.

The SVM Advantage: SVM exhibited the highest median R^2 , the lowest median error (RMSE), and the most stable performance across validation samples (narrow IQR).

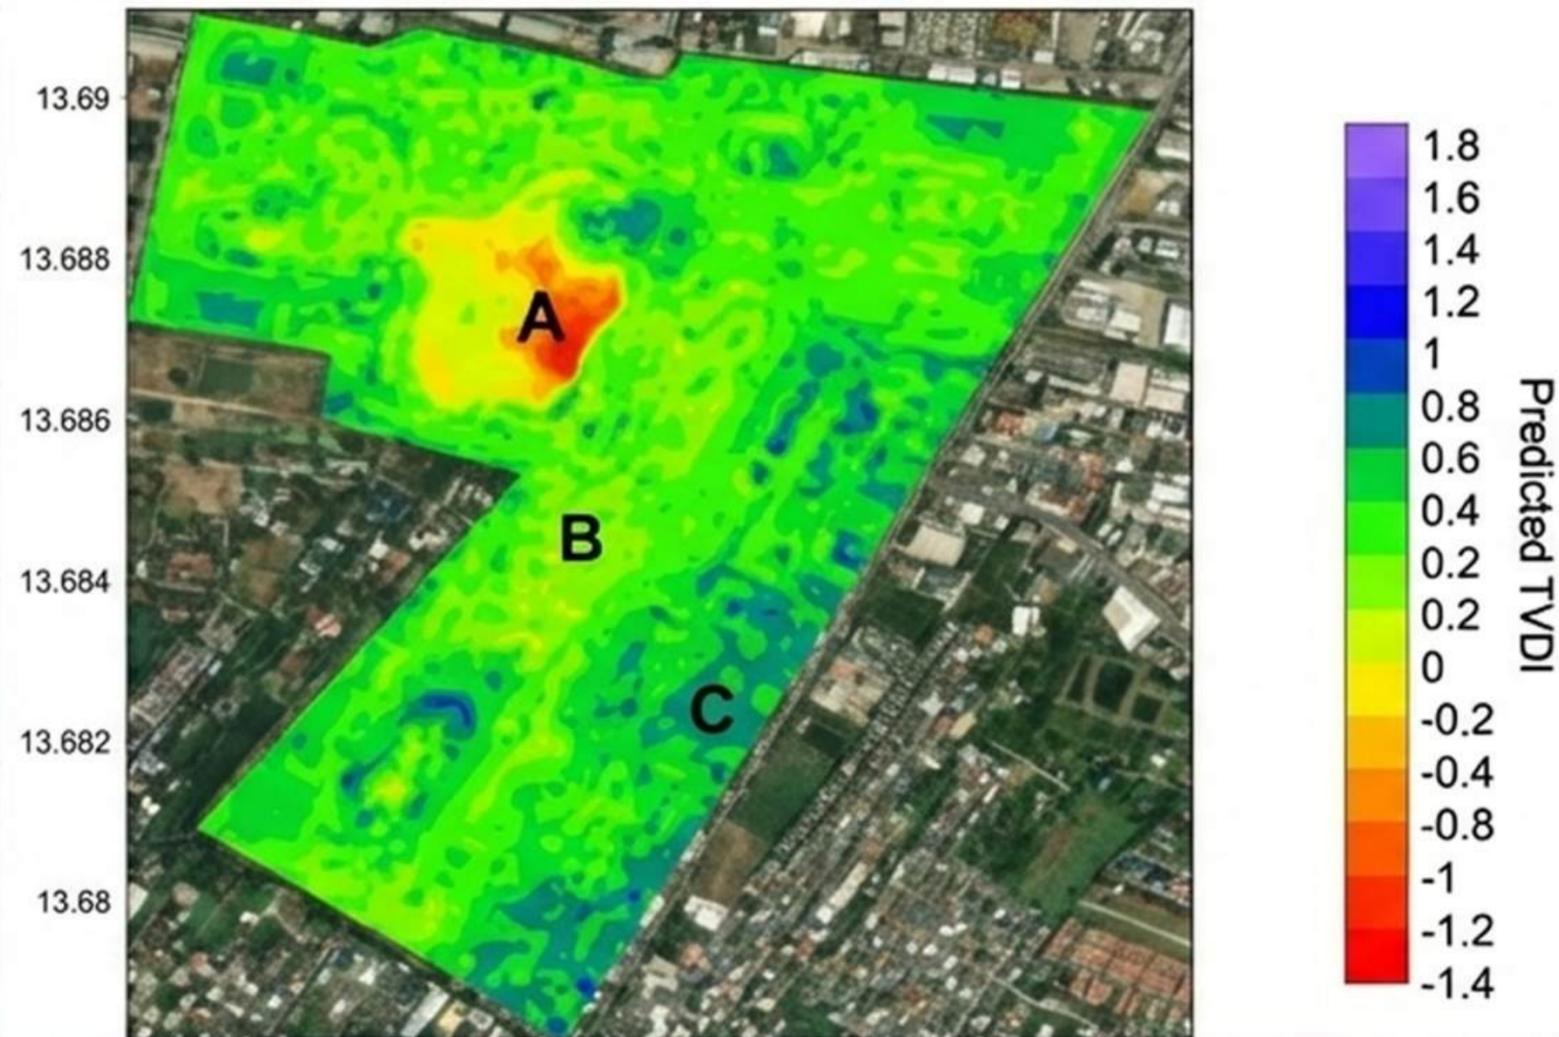
Ensemble Variance: GBR showed a much wider spread in error, indicating less consistency compared to the tight predictions of SVM and XGB.

Feature Importance (What drives the model?)



- **The Dominance of Surface Water:** NDWI (4.74) overwhelmingly controls the SVM model's predictive accuracy, far outpacing all other indices.
- **Secondary Drivers:** NMDI (1.20) and VCI/NDVI (~0.99) provide vital complementary data on vegetation moisture and greenness.
- **Takeaway:** In this heterogeneous urban environment, the physical presence of surface water signals drives drought mapping much more strongly than vegetation greenness alone.

The Predictive Spatial Drought Map



Predictive TVDI Output: The spatial distribution of drought conditions generated by the optimized SVM model.

Insight: The model successfully outputs a stark, high-resolution gradient mapping physical land covers to moisture realities, effectively identifying both highly stable zones and severe drought-prone hotspots.

Zonal Anatomy of Urban Drought

13.68

13.688

13.686

13.684

13.682

13.68

100.658

100.66

100.658

100.66

100.662

100.664

100.666

100.668

100.670

100.668

100.667

Zone A (Wet/Cool):

TVDI -1.2 to -0.4

Centered on the main water body. Very high surface moisture availability and negligible water stress.

Zone B (Transitional):

TVDI 0.2 to 0.6

Moderate moisture. Vegetation experiencing mild drought or early-stage moisture deficit.

Zone C (Severe Stress):

TVDI 0.8 to 1.2.

Built-up surfaces and bare soil. Low moisture retention, high thermal signature, high risk.

Predicted TVDI

1.8

1.6

1.4

1.2

1

0.8

0.6

0.4

0.2

0

-0.2

-0.4

-0.6

-0.8

-1

-1.2

-1.4

Conclusions & Environmental Applications



1. Methodological Success: SVM combined with multi-index remote sensing is a highly stable, effective approach for high-resolution TVDI drought prediction.

2. The Water Imperative: Surface water features (mapped via NDWI) are the primary anchors of moisture stability in urban parks.

3. Actionable Management: This framework enables city planners to move from reactive to proactive—precisely identifying micro-drought hotspots (like Zone C) for targeted irrigation and urban climate resilience planning.

การพยากรณ์ความสมบูรณ์ของพืช ด้วยข้อมูลภาพถ่ายดาวเทียมและการเรียนรู้ของเครื่อง

Forecasting Vegetation Health using Satellite Imagery and Machine Learning Techniques

STEP

01



Data Collection

กำหนดพื้นที่ศึกษาเป็นสวน
สาธารณะ 5 แห่ง และ
รวบรวมข้อมูลปริมาณน้ำ
ฝนเพื่อใช้ในการวิเคราะห์

STEP

02

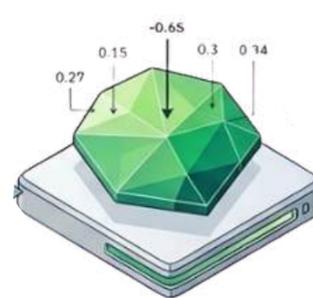


Cloud Removal

ทำการตัดเมฆจากภาพถ่าย
ดาวเทียม Sentinel-2 โดยใช้
ข้อมูล SCL (Scene
Classification Layer)

STEP

03

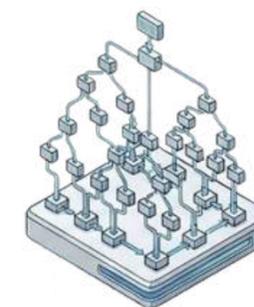


NDVI Calculation

คำนวณค่า NDVI และหาค่า
เฉลี่ยในแต่ละพื้นที่
(Polygon) เพื่อนำไปใช้เป็น
ข้อมูลสำหรับการวิเคราะห์

STEP

04

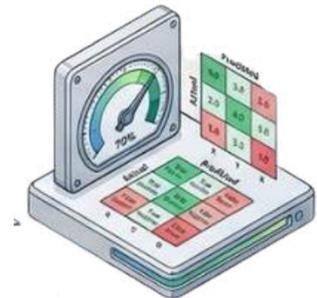


Modeling

สร้างโมเดลในการพยากรณ์
ค่า NDVI โดยใช้ Machine
Learning ประเภท Random
Forest

STEP

05



Evaluation

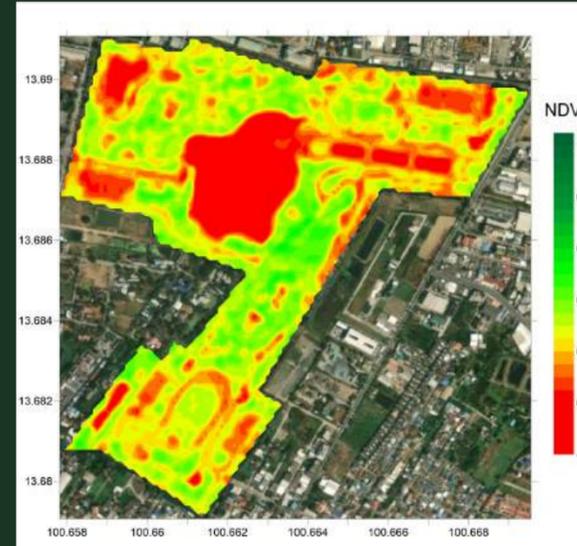
ประเมินประสิทธิภาพของแบบ
จำลองโดยใช้ Classification
Evaluation เพื่อวัดความ
แม่นยำของผลการพยากรณ์

ผลการศึกษา

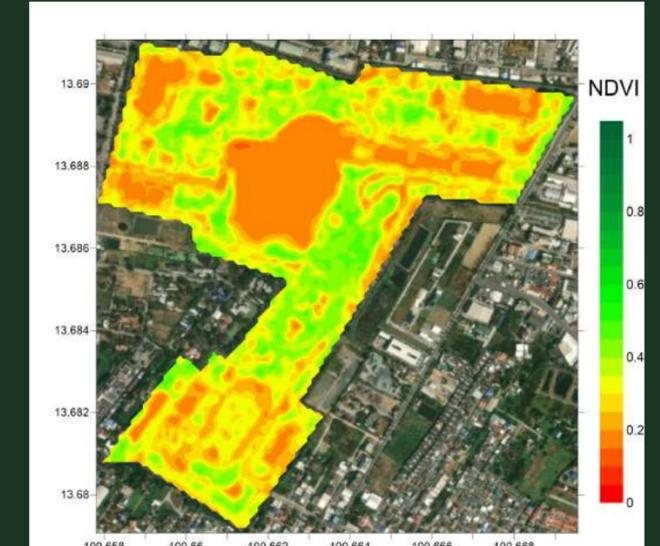
Classification Report

	precision	recall	f1-score	support
0	1.000000	0.230769	0.375000	26.000000
1	0.693878	0.918919	0.790698	74.000000
2	0.684211	0.565217	0.619048	23.000000
accuracy	0.707317	0.707317	0.707317	0.707317

แผนที่เปรียบเทียบค่า NDVI จากข้อมูลจริงและค่าพยากรณ์

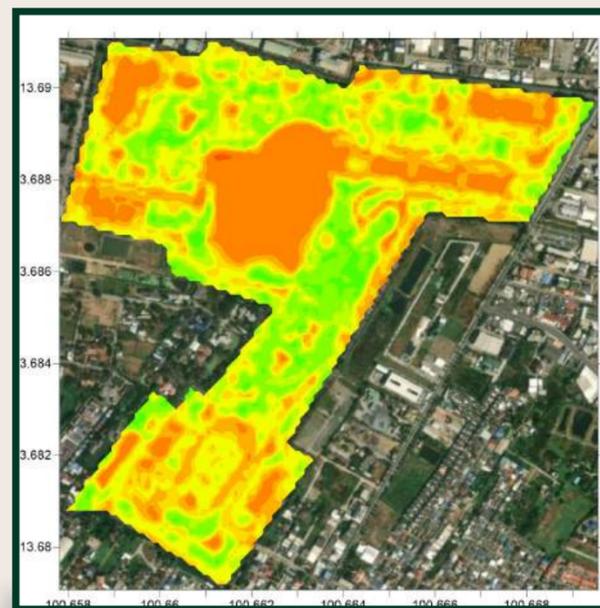


ค่า NDVI จากข้อมูลจริง

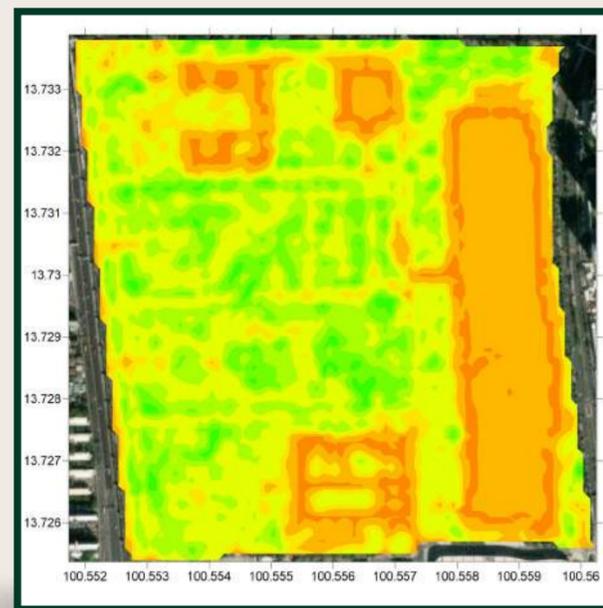


ค่า NDVI ที่ได้จากการพยากรณ์

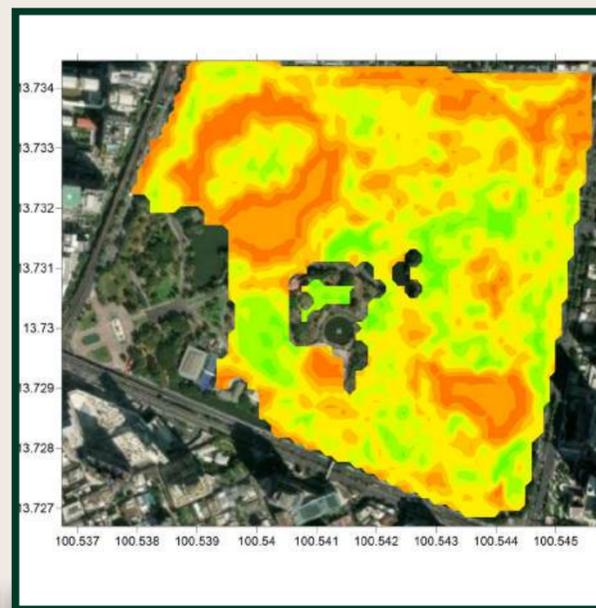
ผลการพยากรณ์ค่า NDVI เชิงพื้นที่ของวันที่ 19 กุมภาพันธ์ พ.ศ. 2569



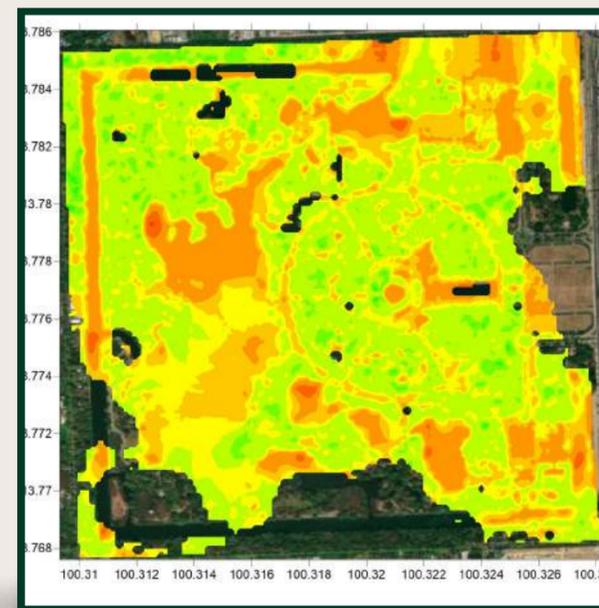
สวนหลวง ร.9



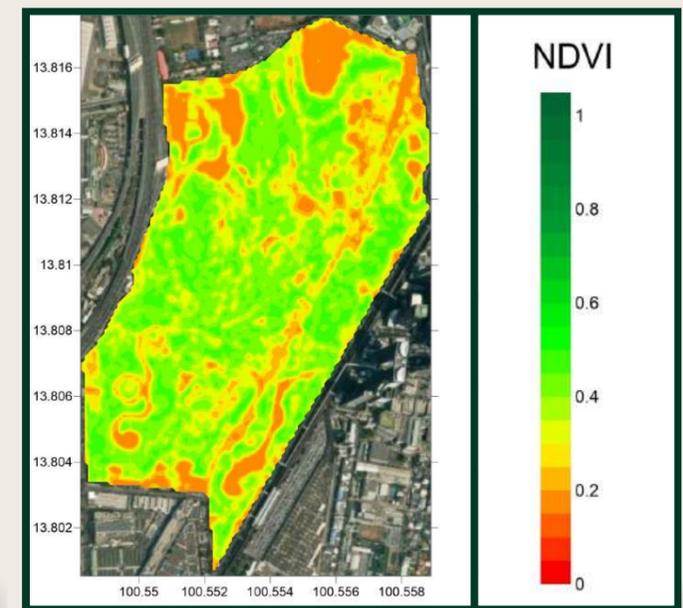
สวนเบญจกิติ



สวนลุมพินี



สวนพุทธมณฑล

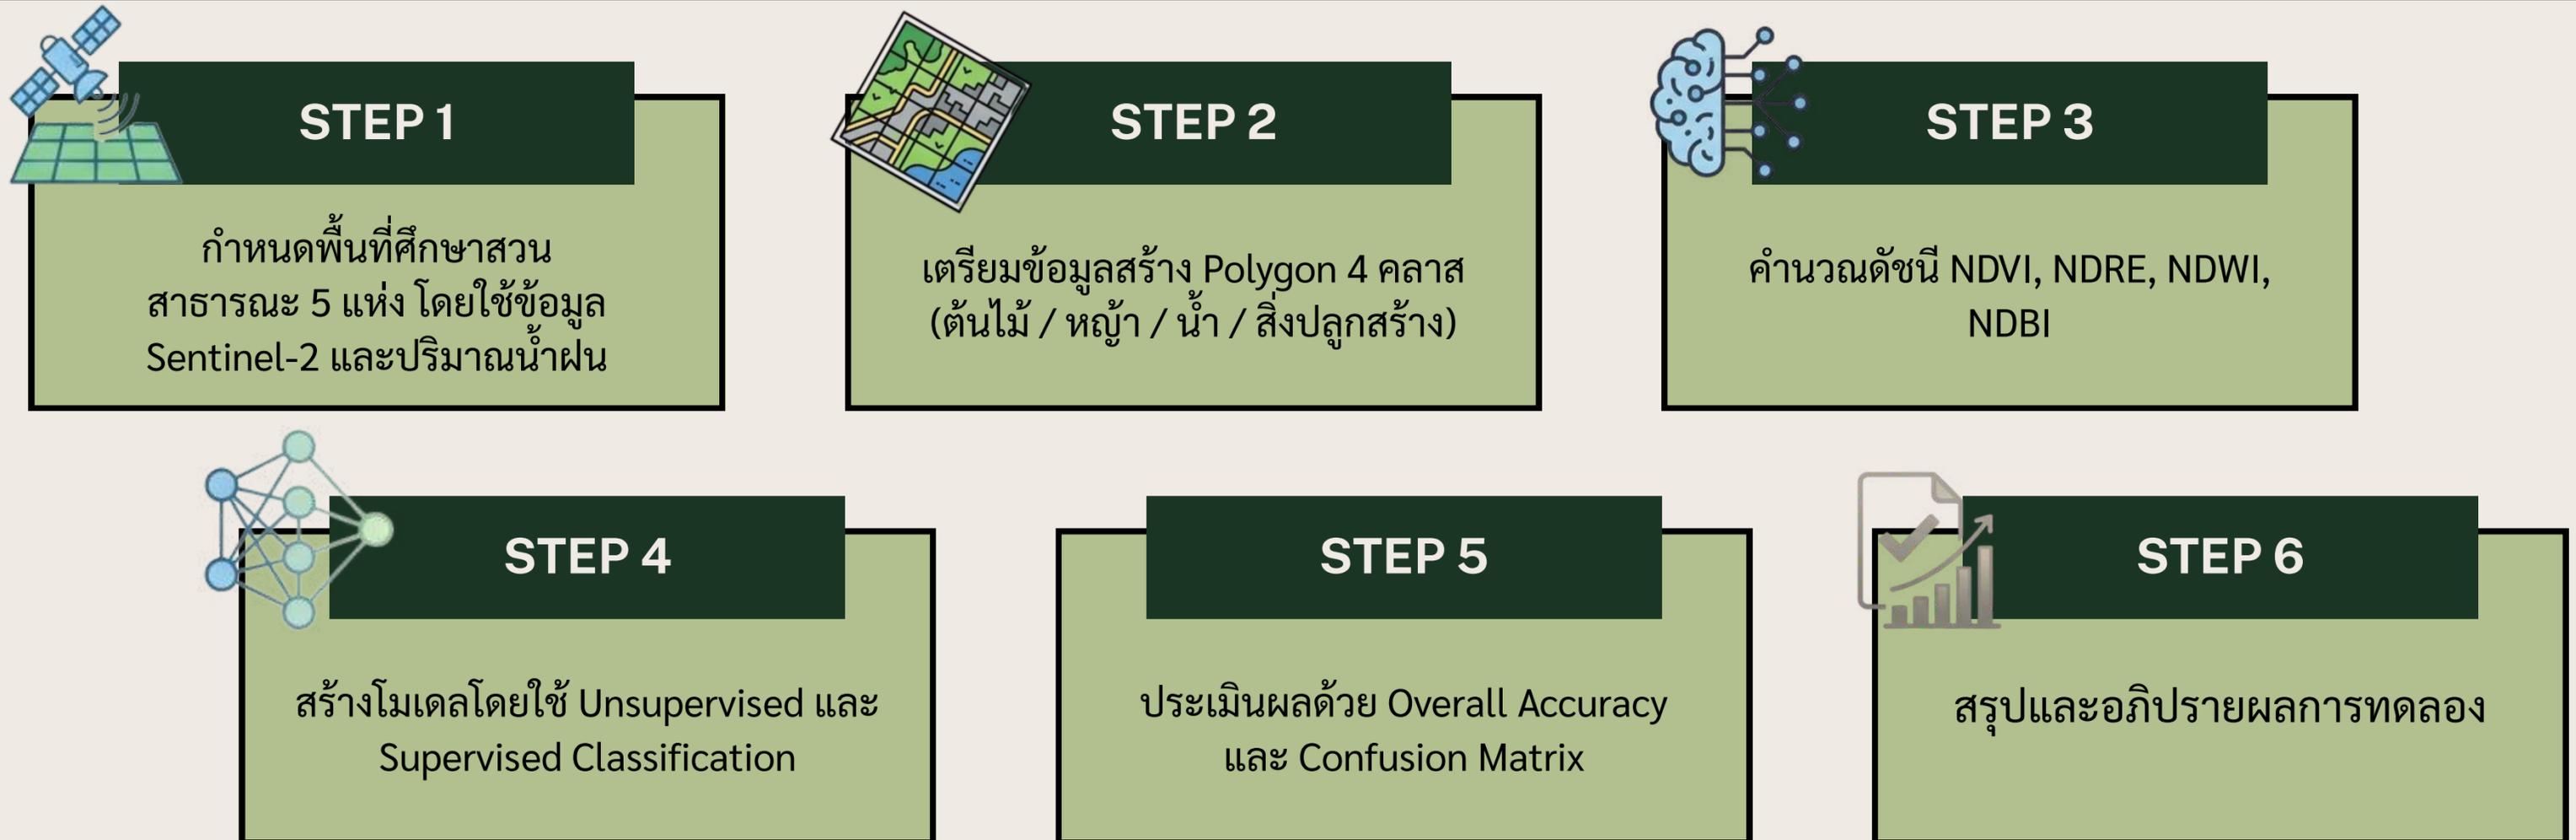


สวนวชิรเบญจทัศ (สวนรถไฟ)



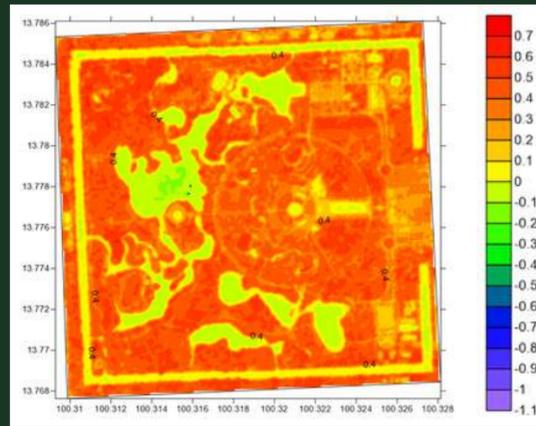
การจำแนกพื้นที่เพาะปลูก โดยใช้ข้อมูลภาพถ่ายดาวเทียมและการเรียนรู้ของเครื่อง

Classification of Agricultural Areas using Satellite Image and Machine Learning

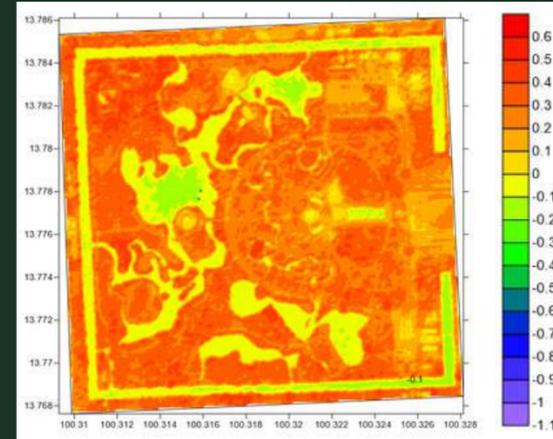


ผลการศึกษา (PHUTTHA MONTHON)

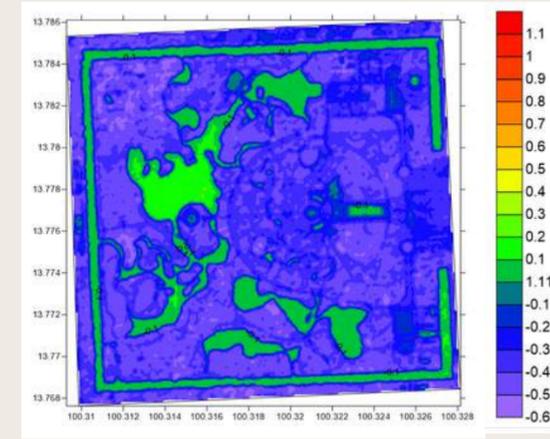
NDVI



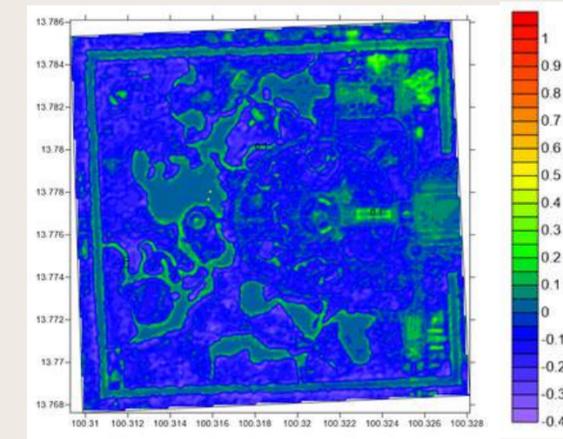
NDRE



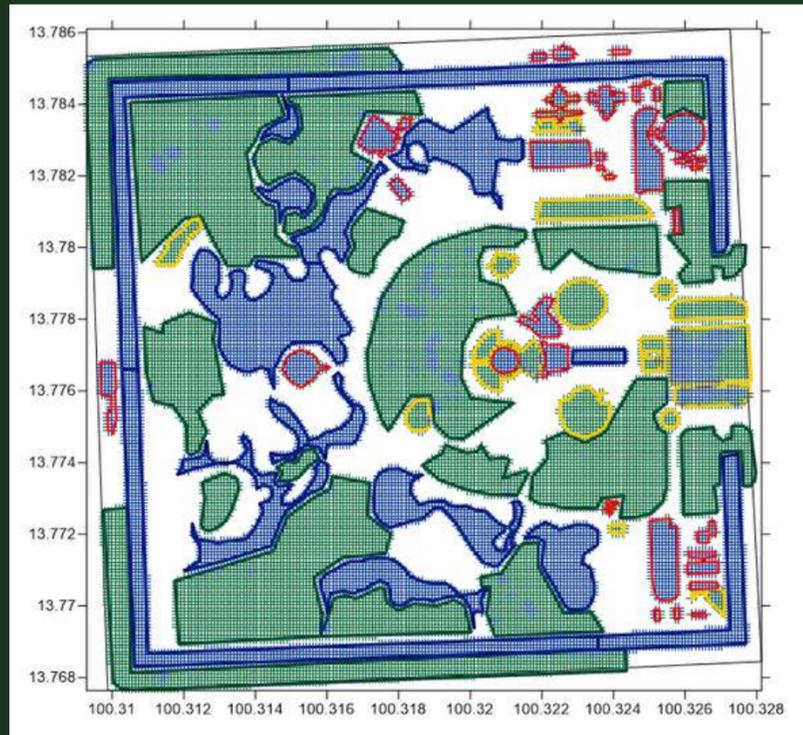
NDWI



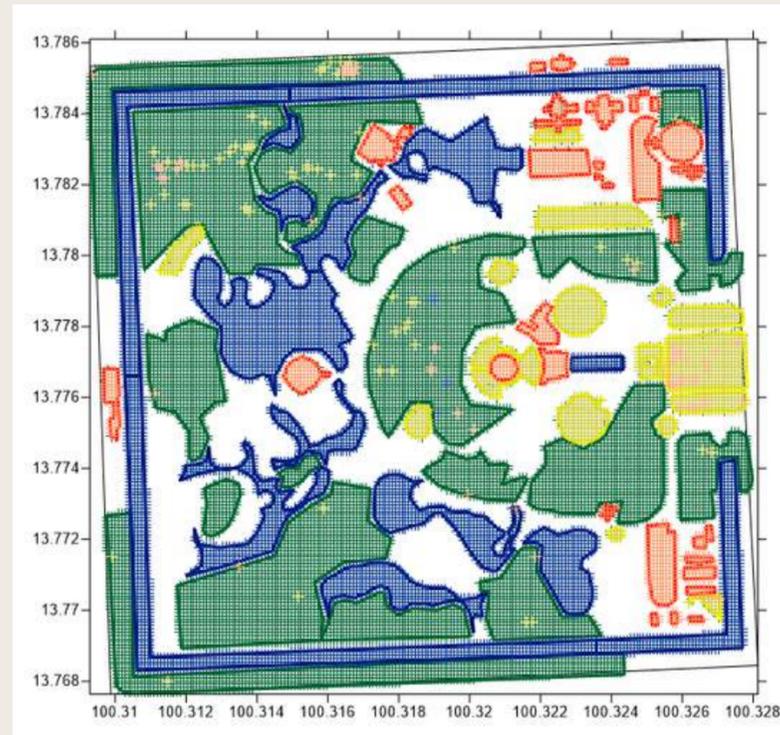
NDBI



UNSUPERVISED



SUPERVISED



ประเมินความแม่นยำ

	precision	recall	f1-score	support
1	0.93	0.97	0.95	3822
2	0.72	0.45	0.55	473
3	0.99	0.99	0.99	1872
4	0.85	0.85	0.85	414
accuracy			0.93	6581

การติดตามความแห้งแล้ง โดยใช้ภาพถ่ายดาวเทียม และการเรียนรู้ของเครื่อง

Drought Monitoring using Satellite Imagery and Machine Learning Techniques



Data Collection

- รวบรวมข้อมูล: ภาพถ่ายดาวเทียม
- เลือกพื้นที่ศึกษา: สวนสาธารณะ 5 แห่ง

STEP 1



Cloud Removal

- การตัดเมฆ ออกจากภาพเพื่อให้ข้อมูลแม่นยำมากขึ้น

STEP 2



Index Calculation

- การคำนวณดัชนี จากดาวเทียม Sentinel-2
- ใช้สะท้อนความชื้นและสุขภาพของพืช

STEP 3



Modeling

- สร้างโมเดล โดยใช้ Random Forest
- พยากรณ์ค่าดัชนีความแห้งแล้ง (TVDI)

STEP 4

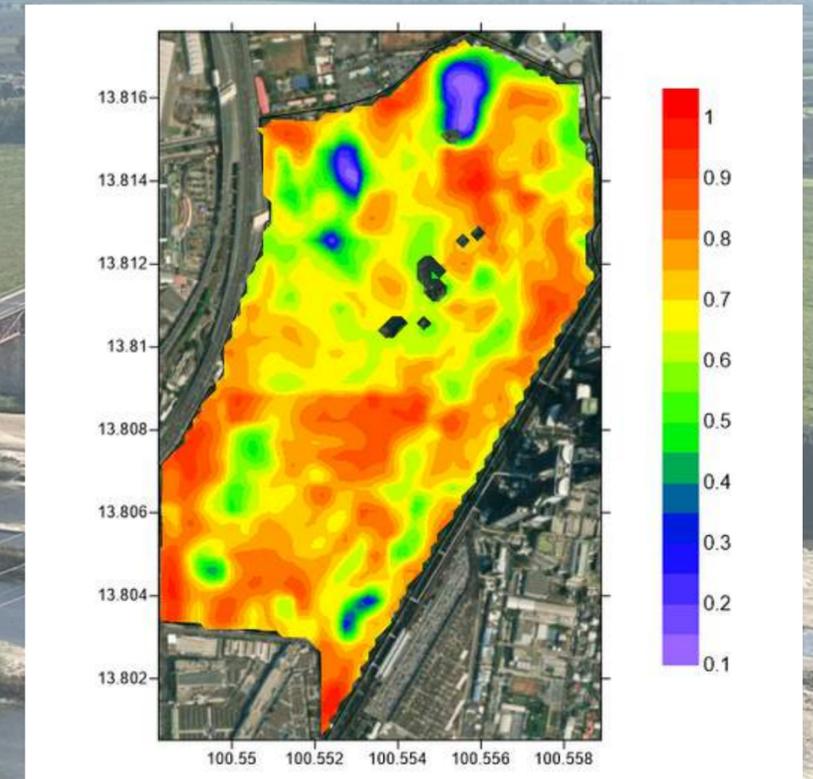
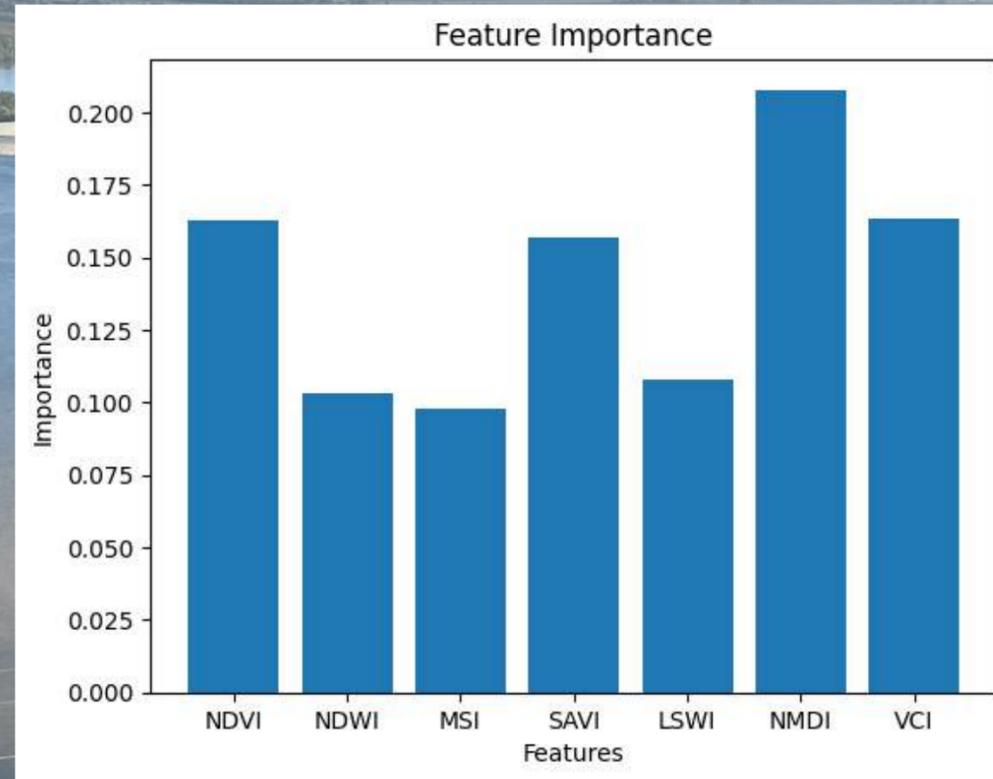
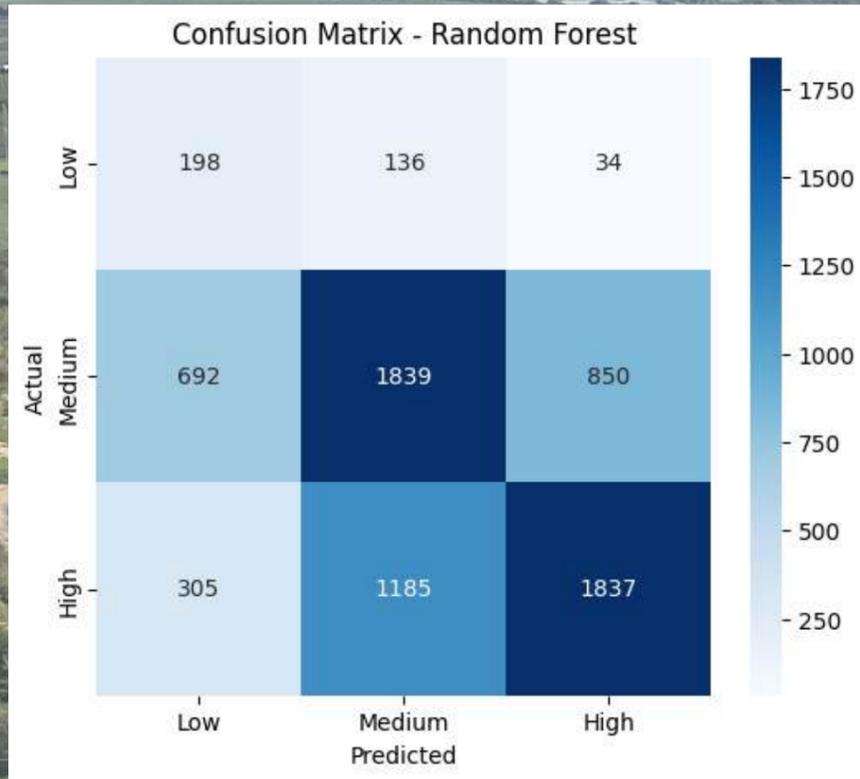


Evaluation

- ประเมินประสิทธิภาพของโมเดลโดยใช้ค่าและ Confusion Matrix

STEP 5

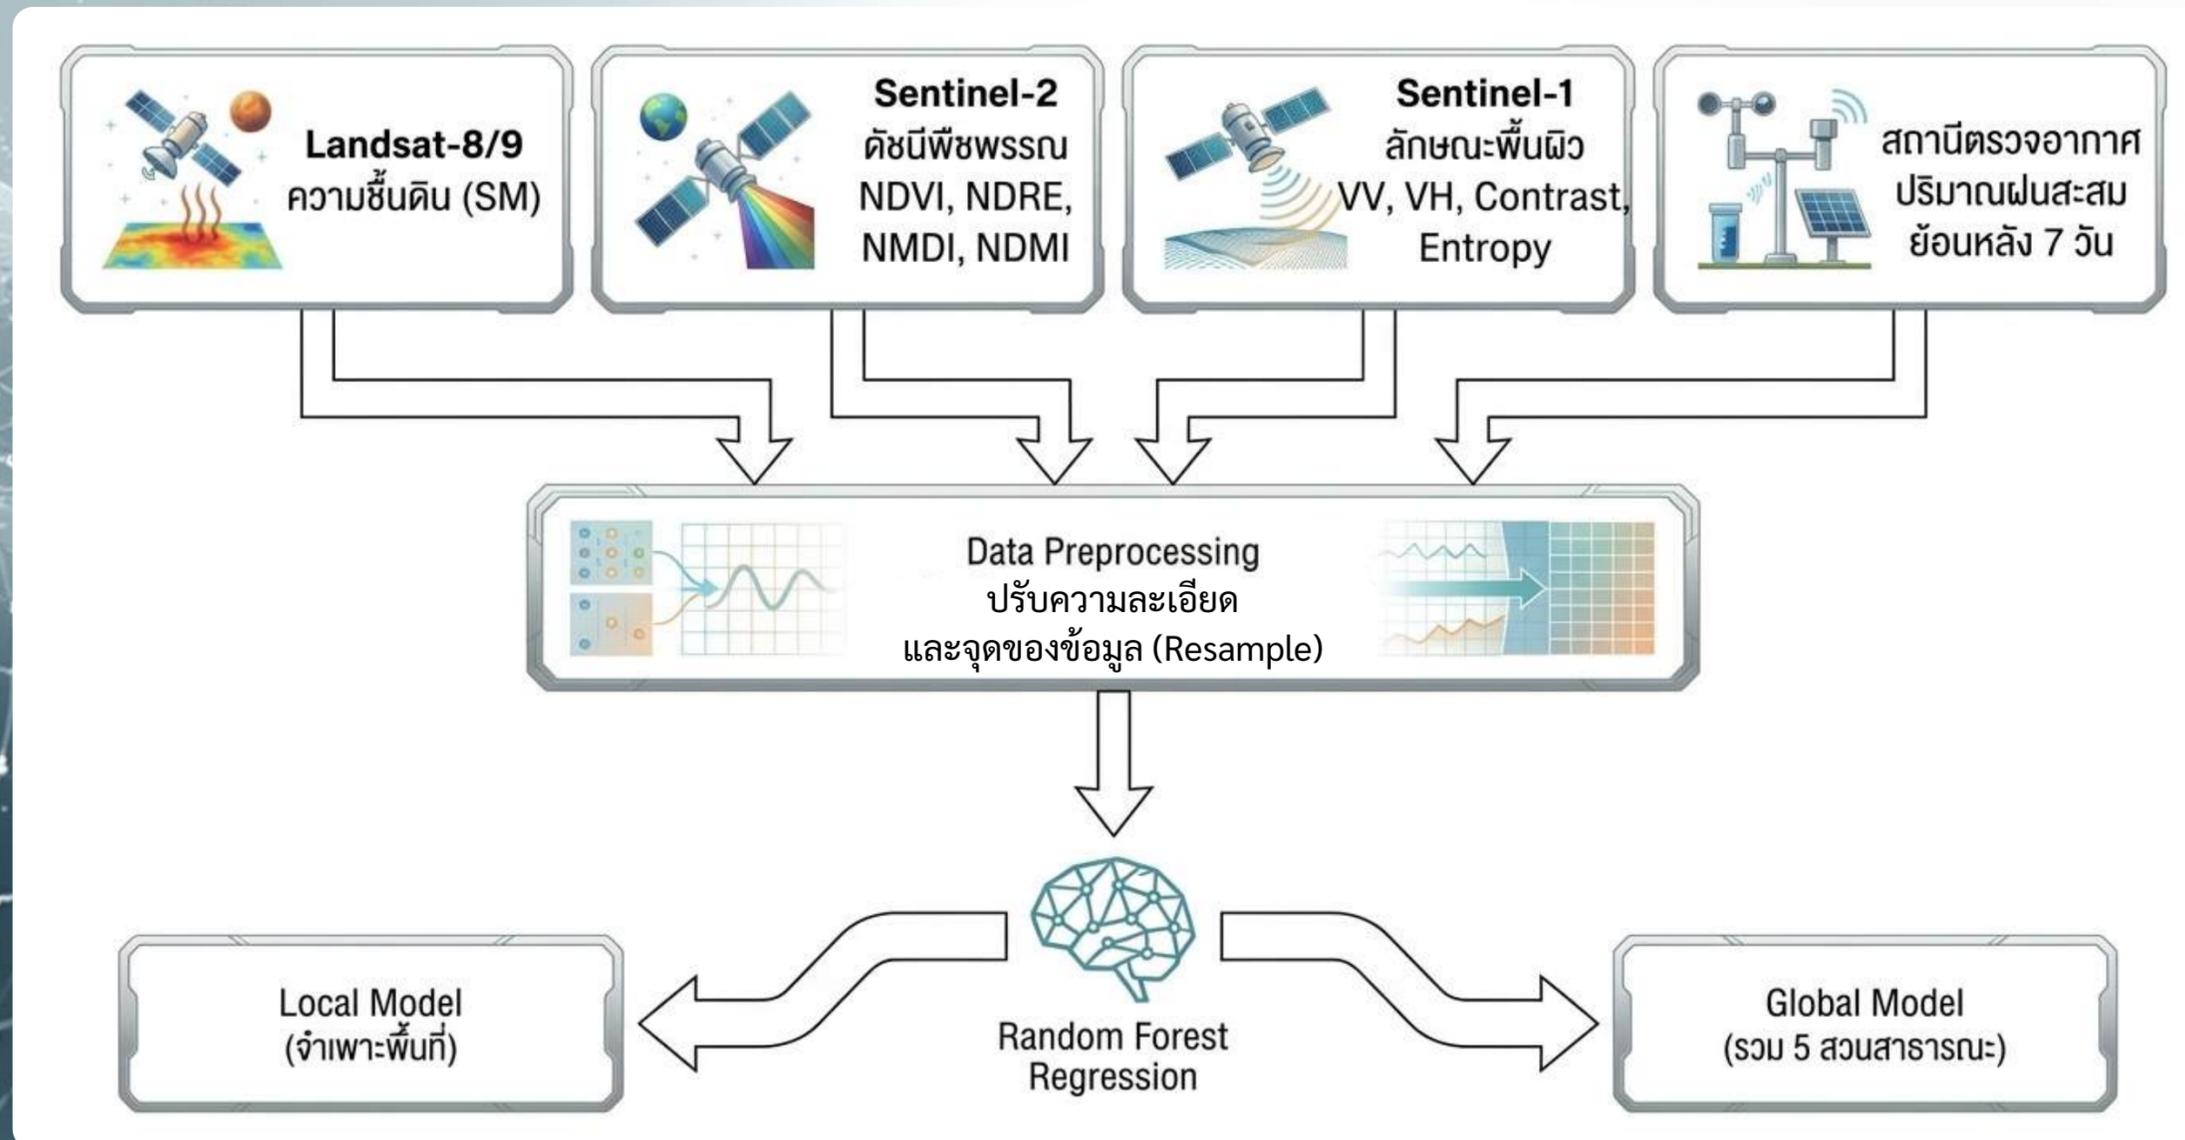
ผลการศึกษา



สวนวชิรเบญจทัศ

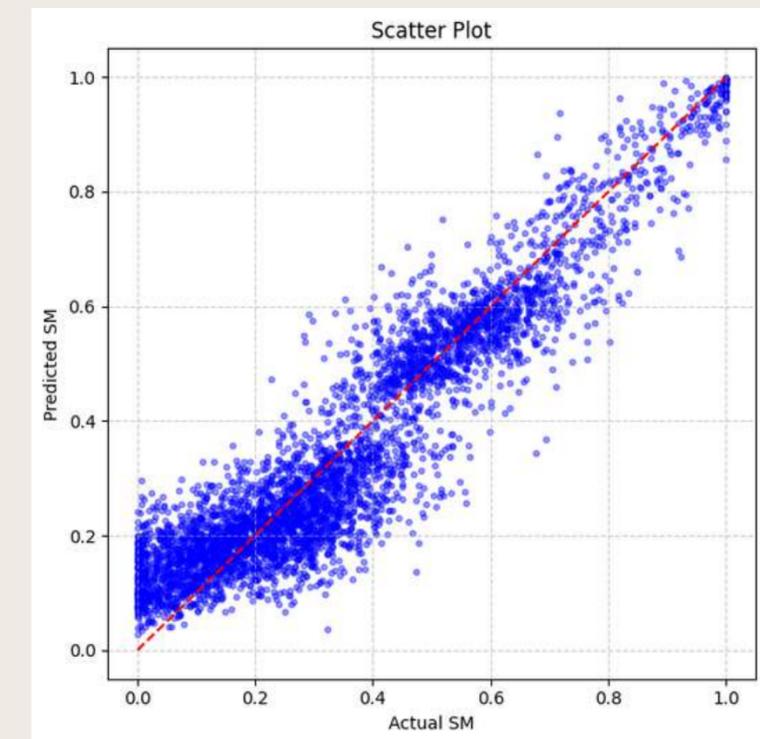
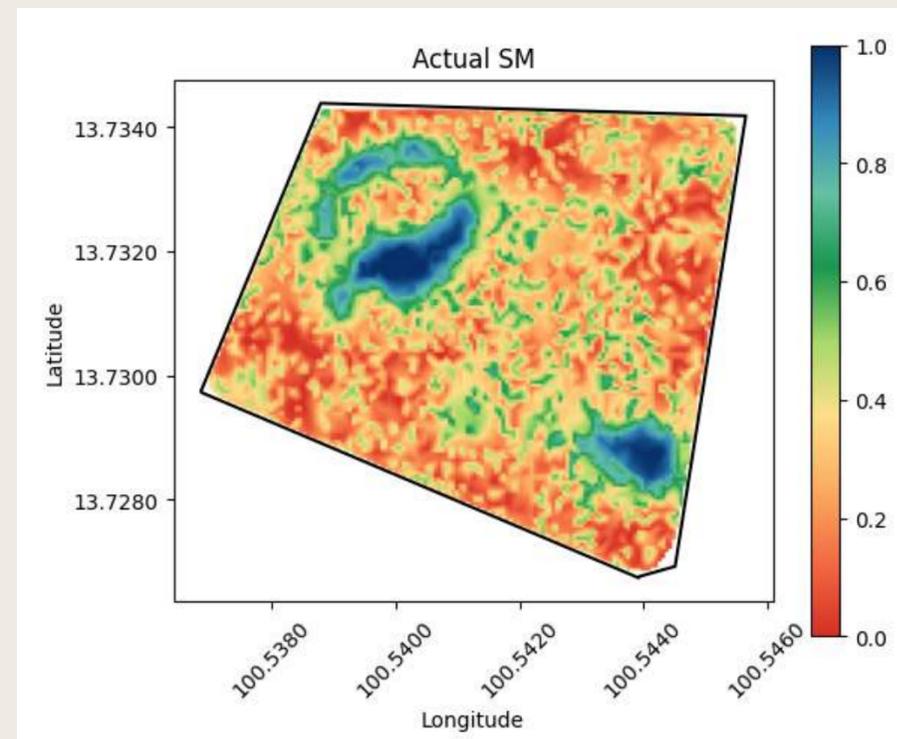
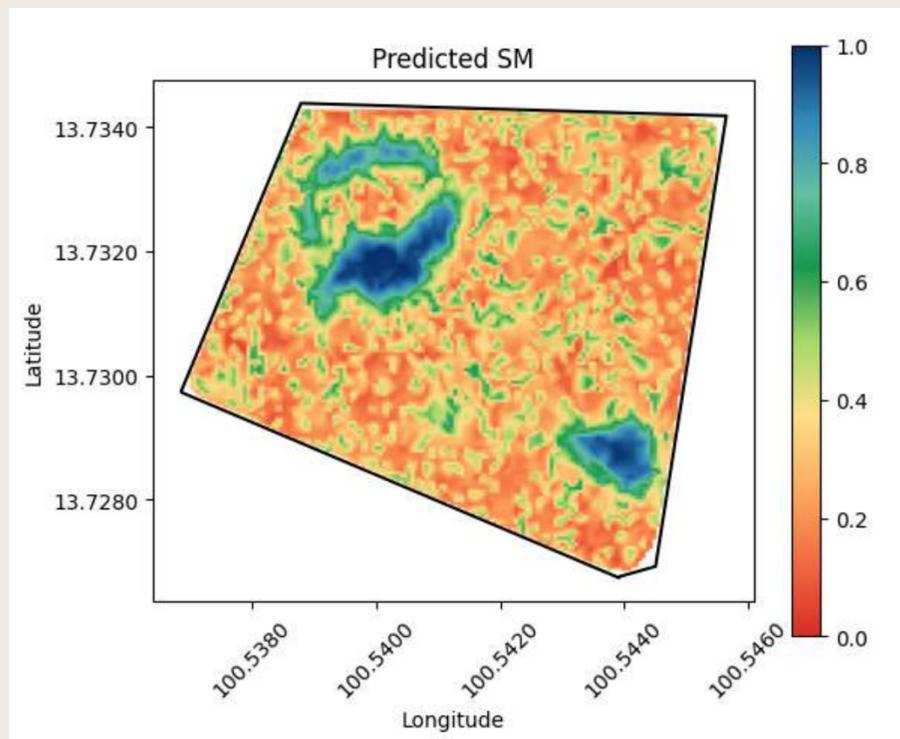
การทำนายความชื้นดินโดยใช้ข้อมูล Landsat-8 Sentinel-1 และ Sentinel-2 ด้วยการเรียนรู้ของเครื่อง

Prediction of Soil Moisture using Landsat-8 Sentinel-1 and Sentinel-2 Data with Machine Learning Techniques



ผลการศึกษา

รูปแบบแบบจำลอง	R^2	RMSE
1. สวนเบญจกิติ (Local)	0.9061	0.0957
2. สวนหลวง ร.9 (Local)	0.8465	0.0921
3. พุทรมณฑล (Local)	0.8096	0.1050
4. สวนลุมพินี (Local)	0.7851	0.1012
5. สวนวชิรเบญจทัศ (Local)	0.5680	0.1300
แบบจำลองรวม (Global Model)	0.6677	0.1135



สวนลุมพินี