

**MethSense : ไปป์ไลน์การตรวจสอบก๊าซมีเทนอย่างแม่นยำด้วยเทคนิค  
Symbolic Regression เพื่อเพิ่มประสิทธิภาพในการป้องกันและเฝ้าระวังภาวะโลกร้อน  
MethSense: Accurate Methane Gas Detection Pipeline Using Symbolic Regression  
Techniques to Enhance Global Warming Prevention and Monitoring Efficiency**

ชยพนธ์ ดิยะปัญญนิตย์<sup>1</sup>, พิเชษฐ จำเนียรศรี<sup>1</sup>

ขุนทอง คล้ายทอง<sup>1\*</sup> กอบชัย ดวงรัตนเลิศ<sup>2</sup> และชนติ จันทระโชติชัชชาวล<sup>2</sup>

<sup>1</sup>โรงเรียนวิทยาศาสตร์จุฬาภรณราชวิทยาลัย ปทุมธานี, ตำบลบ่อเงิน, อำเภอลาดหลุมแก้ว, จังหวัดปทุมธานี

<sup>2</sup>มหาวิทยาลัยมหิดล, ตำบลศาลายา, อำเภอพุทธมณฑล, จังหวัดนครปฐม, ประเทศไทย

E-mail: turakan@pccp.ac.th

### บทคัดย่อ

ภาวะโลกร้อนที่รุนแรงมากขึ้น ทำให้การตรวจวัดก๊าซเรือนกระจก เพื่อกำหนดทิศทางและการจัดการที่เหมาะสม เป็นสิ่งสำคัญและเร่งด่วนต่อโลกโดยเฉพาะก๊าซมีเทนที่แม้จะสลายตัวได้เร็ว แต่สามารถดักจับความร้อนได้มากกว่าก๊าซ คาร์บอนไดออกไซด์สูงถึง 28 เท่า ในปัจจุบันการตรวจวัดก๊าซมีเทนด้วยดาวเทียมเช่น Sentinel-5P ที่แม้จะใช้เวลา การอัปเดตข้อมูลเพียง 1 วัน แต่มีความละเอียดเชิงพื้นที่ต่ำถึง 5-15 กิโลเมตร ทำให้ไม่สามารถตรวจสอบการรั่วไหลและระบุแหล่งกำเนิดของมีเทนได้อย่างถูกต้องและมีประสิทธิภาพ ส่งผลให้ความน่าเชื่อถือของข้อมูลน้อยลงและไม่สามารถนำไปใช้งานได้จริง MethSense จึงถูกพัฒนาขึ้นเพื่อแก้ไขข้อจำกัดนี้ด้วย Reparameterized Symbolic Regression ซึ่งเป็น Machine Learning ประสิทธิภาพสูงที่ให้ความสำคัญกับความโปร่งใสและไว้วางใจได้มาใช้ในการในการหาความสัมพันธ์ของอัตรา การปล่อยก๊าซมีเทนกับ Spectral Information ของภาพถ่ายดาวเทียมความละเอียดสูง ได้แก่ Sentinel-2, Landsat-8 และ Landsat-9 ผลการทดลองแสดงถึงโมเดลที่มีประสิทธิภาพที่มีค่า Negative Log Likelihood เพียง 8.269 และมีความละเอียดเชิงพื้นที่ถึง 10 เมตร คณะผู้จัดทำเชื่อว่า MethSense จะมีความสำคัญต่อการติดตามและจัดการการเปลี่ยนแปลงสภาพภูมิอากาศ ด้วยข้อมูลที่แม่นยำนี้จะเป็นตัวช่วยสนับสนุนการตัดสินใจการออกแบบนโยบายและกลยุทธ์ด้านสิ่งแวดล้อมได้อย่างมีประสิทธิภาพมากยิ่งขึ้น สามารถลดและป้องกันภาวะโลกร้อนได้อย่างมีประสิทธิภาพ และช่วยขับเคลื่อนความยั่งยืนในระยะยาว

**คำสำคัญ:** ภาวะโลกร้อน, ก๊าซมีเทน, การตรวจวัดก๊าซมีเทน, Reparameterized Symbolic Regression

#### 1. บทนำ

ในช่วงทศวรรษที่ผ่านมา โลกกำลังเผชิญกับวิกฤตการเปลี่ยนแปลงสภาพภูมิอากาศอย่างรุนแรง ซึ่งเป็นปัญหาระดับโลกที่ส่งผลกระทบอย่างลึกซึ้งต่อทั้งสิ่งแวดล้อม เศรษฐกิจ และสังคมมนุษย์ ภาวะอากาศสุดขั้ว ภัยพิบัติทางธรรมชาติที่ถี่และรุนแรงขึ้น รวมถึงการสูญเสียความหลากหลายทางชีวภาพ กำลัง

กลายเป็นความปกติใหม่ (NASA, 2022) สถานการณ์ดังกล่าวเรียกร้องให้มีการดำเนินการเชิงรุกและความร่วมมือในระดับนานาชาติเพื่อบรรเทาและปรับตัวต่อวิกฤตนี้ (United Nations Environment Programme, 2021)

หนึ่งในสาเหตุสำคัญของการเปลี่ยนแปลงสภาพภูมิอากาศคือการสะสมของก๊าซเรือนกระจก



โดยเฉพาะ “ก๊าซมีเทน” ซึ่งแม้จะมีปริมาณน้อยกว่าคาร์บอนไดออกไซด์ แต่กลับมีศักยภาพในการกักเก็บความร้อนมากกว่าถึง 28 เท่าในช่วงเวลา 100 ปี (Saunio et al., 2020) อีกทั้งมีเทนยังทวีความสำคัญมากยิ่งขึ้น เนื่องจากมีอายุในชั้นบรรยากาศสั้นกว่าก๊าซชนิดอื่น จึงเป็นเป้าหมายที่มีศักยภาพในการลดภาวะโลกร้อนอย่างเร่งด่วนและเห็นผลในระยะสั้น

ด้วยเหตุนี้ผู้จัดทำโครงการงานจึงเสนอแนวทางการประยุกต์ใช้เทคโนโลยี Symbolic Regression เพื่อเชื่อมโยงข้อมูลจากดาวเทียมหลายประเภทเข้าด้วยกัน สร้างแหล่งข้อมูลการปล่อยมีเทนที่มีความละเอียดทั้งเชิงพื้นที่และเวลาในระดับสูง ด้วยสมการทางคณิตศาสตร์ที่สามารถเห็นการทำงานได้อย่างชัดเจน เป้าหมายคือการพัฒนาระบบที่สามารถตรวจสอบพื้นที่ที่มีการปล่อยมีเทนได้อย่างแม่นยำ พร้อมรายงานข้อมูลรายวัน เพื่อช่วยในการเฝ้าระวังแนวโน้ม ปรับปรุงนโยบาย และสนับสนุนการตัดสินใจด้านสิ่งแวดล้อมอย่างมีข้อมูลรองรับ โครงการนี้จึงไม่เพียงเป็นการพัฒนาทางเทคโนโลยี แต่ยังเป็นกลไกสำคัญในการเร่งรัดการแก้ปัญหาภาวะโลกร้อนอย่างตรงจุด มีศักยภาพในการสร้างผลกระทบในระดับนโยบาย และช่วยขับเคลื่อนความยั่งยืนในระยะยาว

## 2. วิธีดำเนินการ

### 2.1 การเก็บรวบรวมและเตรียมข้อมูล

การศึกษาเริ่มต้นด้วยการเตรียมชุดข้อมูลพหลุมมีเทนจาก Carbon Mapper ตั้งแต่ปี 2016-2024 ในรูปแบบ DataFrame โดยคัดเลือกคุณลักษณะที่สำคัญ ได้แก่ plume\_id, plume\_latitude, plume\_longitude, datetime, gas, emission\_auto และ emission\_uncertainty\_auto พร้อมกรองเฉพาะพหลุมมีเทนและกำจัดแถวที่มีค่าสูญหายเพื่อรักษาความสมบูรณ์ของข้อมูล จากนั้นสร้างดัชนีเชิงพื้นที่ด้วยระบบ H3 ที่ความละเอียดระดับ 7 (พื้นที่ประมาณ 5.16 ตารางกิโลเมตรต่อเซลล์) และแบ่งชุดข้อมูลเป็นชุดฝึก ตรวจสอบ และทดสอบในสัดส่วน 80:10:10 โดยสุ่มกำหนดเซลล์ H3 ให้กับแต่ละชุดย่อย ซึ่งการแบ่งข้อมูลตามพื้นที่ทางภูมิศาสตร์แบบนี้ช่วยป้องกันปัญหา Data Leakage และทำให้การประเมินประสิทธิภาพของโมเดลมีความน่าเชื่อถือมากขึ้น

### 2.2 การสร้างโมเดล Symbolic Regression

ระบบ MethSense ใช้เทคนิค Symbolic Regression ผ่านไลบรารี PySR เพื่อสร้างแบบจำลองที่แม่นยำในการตรวจจับการรั่วไหลของก๊าซมีเทนจากภาพถ่ายดาวเทียม Sentinel-2, Landsat-8 และ Landsat-9 โดยประยุกต์ใช้ Reparameterization Trick ให้โมเดลเรียนรู้ทั้งค่าเฉลี่ย ( $\mu$ ) และส่วนเบี่ยงเบนมาตรฐาน ( $\sigma$ ) ของการแจกแจงแบบ Gaussian ซึ่งถูกเข้ารหัสรวมกันเป็นค่าทำนายเดี่ยวด้วย Cantor Pairing Function แล้วถอดกลับมาใช้ในฟังก์ชันการสูญเสียแบบ Negative Log-Likelihood (NLL) โมเดลค้นหาฟังก์ชันหลักสองฟังก์ชันพร้อมกัน คือ  $f(x)$  ที่แปลงข้อมูลการสะท้อนแสงจากดาวเทียมเป็นสัญญาณที่เกี่ยวข้องกับก๊าซมีเทน และ  $g(x)$  ที่ควบคุมความแปรปรวนของการทำนาย โดยค่าเฉลี่ย ( $\mu$ ) ถูกจำลองด้วยสมการที่คล้ายจลนศาสตร์ Michaelis-Menten เพื่อสะท้อนปรากฏการณ์การอิ่มตัวของสัญญาณ ขณะที่ส่วนเบี่ยงเบนมาตรฐาน ( $\sigma$ ) ถูกกำหนดให้เป็นสัดส่วนกับค่าเฉลี่ย เพื่อให้ความไม่แน่นอนขึ้นอยู่กับข้อมูลอินพุต

### 2.3 การฝึกโมเดล

เนื่องจากแบบจำลอง PySR ต้องการทรัพยากรการประมวลผลสูง จึงเลือกดำเนินการฝึกบน Google Cloud Console โดยใช้ VM instance ประเภท e2-highcpu-4 (4 vCPUs, 4 GB RAM) ที่ภูมิภาค asia-southeast1 (Singapore) ซึ่งเน้นประสิทธิภาพของ CPU เหมาะกับอัลกอริทึม Symbolic Regression ที่ต้องการการประมวลผลทางคณิตศาสตร์สูงและการค้นหาสมการในพื้นที่ขนาดใหญ่ ทำให้ระบบสามารถค้นพบสมการที่แสดงความสัมพันธ์ระหว่างค่าการสะท้อนแสงในช่วงคลื่นต่าง ๆ กับความเข้มข้นของก๊าซมีเทนในบรรยากาศได้อย่างแม่นยำ

## 3. ผลการทดลอง

### 3.1 การเก็บรวบรวมและเตรียมข้อมูล

การเก็บและเตรียมข้อมูลพหลุมมีเทนจาก Carbon Mapper ให้ชุดข้อมูลที่มีความสมบูรณ์ 100% หลังการกรอง โดยไม่มีค่าสูญหายหรือข้อมูลไม่ครบถ้วน ซึ่งเป็นปัจจัยพื้นฐานสำคัญต่อความน่าเชื่อถือของผลการวิเคราะห์ (Wang et al., 2020) การสร้างดัชนีเชิงพื้นที่ด้วยระบบ H3 ระดับ 7 และการแบ่งข้อมูลแบบสุ่มตามเซลล์ในสัดส่วน 80:10:10 ช่วยแยกข้อมูลทางภูมิศาสตร์อย่างชัดเจน ป้องกัน spatial data leakage (Meyer et al., 2018) และทำให้แบบจำลองสามารถประเมินผลในพื้นที่ใหม่ได้อย่างน่าเชื่อถือ



### 3.2 การสร้างโมเดล Symbolic Regression

จากการปรับแต่งพารามิเตอร์ทั้ง 7 ประเภทของแบบจำลอง PySR พบว่าค่าที่เหมาะสมที่สุด ได้แก่ populations = 25, population\_size = 100, topn = 20, weight\_optimize = 1, weight\_randomize = 0.1, crossover\_probability = 0.2 และ max\_complexity = 200 โดยค่าความผิดพลาด (loss) อยู่ใน ช่วงแคบระหว่าง 8.304 ถึง 8.370 สะท้อนถึงความเสถียรและความน่าเชื่อถือของกระบวนการค้นหาสมการเชิงสัญลักษณ์ (Schmidt & Lipson, 2009) ดังแสดงในตารางที่ 1

| พารามิเตอร์           | ค่าที่เหมาะสมที่สุด | ค่าความผิดพลาด (NLL) |
|-----------------------|---------------------|----------------------|
| populations           | 25                  | 8.322                |
| population_size       | 100                 | 8.324                |
| topn                  | 20                  | 8.304                |
| weight_optimize       | 1                   | -                    |
| weight_randomize      | 0.1                 | -                    |
| crossover_probability | 0.2                 | -                    |

ตารางที่ 1

ผลการค้นหาค่าพารามิเตอร์ที่เหมาะสมที่สุดสำหรับแบบจำลอง PySR

### 3.3 การฝึกโมเดล

แบบจำลองที่ดีที่สุดที่ค้นพบมีค่า Negative Log Likelihood เท่ากับ 8.269 ระดับความซับซ้อน (Complexity) เท่ากับ 155 ค่าพารามิเตอร์เริ่มต้น ( $U_0$ ) เท่ากับ 23.058 และมีความละเอียดเชิงพื้นที่ถึง 10 เมตร ซึ่งถือเป็นผลลัพธ์ที่สมดุลระหว่างความแม่นยำและความสามารถในการตีความ เมื่อทำการวิเคราะห์และแยกองค์ประกอบของสมการ (Deconstruction) ตามหลักการทางกายภาพของการสำรวจระยะไกล (Remote Sensing) พบว่าแบบจำลองที่ PySR ค้นพบสะท้อนหลักการทำงานของเทคนิค Differential Optical Absorption Spectroscopy (DOAS) ซึ่งเป็นวิธีมาตรฐานในการตรวจวัดก๊าซในชั้นบรรยากาศจากดาวเทียม โดยฟังก์ชัน  $f$  ทำหน้าที่เสมือนไปป์ไลน์การประมวลผลสัญญาณหลายขั้นตอนเพื่อแยกและขยายสัญญาณการดูดกลืนของมีเทนผ่านการสร้างสัญญาณอ้างอิงจากย่านคลื่นที่ไม่มีการดูดกลืน การปรับแก้ผลกระทบจากบรรยากาศและเรขาคณิต ซึ่งสอดคล้องกับงานวิจัยของ Varon et al. (2021) ขณะที่ฟังก์ชัน  $g$  ทำหน้าที่ประมาณค่าความไม่แน่นอนของการวัด โดยพิจารณาปัจจัยรบกวนหลัก เช่น ความสว่างของภาพและปริมาณเมฆปกคลุม

### 4. สรุปและอภิปรายผล

#### 4.1 อภิปรายผลการทดลอง

ผลลัพธ์นี้แสดงให้เห็นว่า PySR ไม่เพียงสามารถสร้างแบบจำลองที่แม่นยำ แต่ยังสามารถกลไกทางฟิสิกส์และเคมีของการดูดกลืนมีเทนในบรรยากาศได้อย่างมีนัยสำคัญ (Udrescu & Tegmark, 2020) ซึ่งเป็นจุดแข็งเหนือแบบจำลอง machine learning ทั่วไปที่เน้นผลลัพธ์มากกว่าความเข้าใจเชิงกลไก อย่างไรก็ตาม ความซับซ้อนของสมการอาจเป็นข้อจำกัดในบริบทการใช้งานจริงที่ต้องการความเรียบง่ายและการตีความที่ชัดเจน ซึ่งในอนาคตอาจแก้ไขได้ด้วยเทคนิคการลดความซับซ้อนของโมเดล เช่น regularization, pruning หรือ symbolic distillation เพื่อให้ได้สมการที่สมดุลระหว่างความแม่นยำและความสามารถในการตีความ

#### 4.2 สรุปผลการทดลอง

ระบบ MethSense สามารถพัฒนาแบบจำลอง Symbolic Regression ด้วยไลบรารี PySR ที่ตรวจจับความเข้มข้นของก๊าซมีเทนจากภาพถ่ายดาวเทียมได้อย่างแม่นยำ โดยชุดข้อมูลจาก Carbon Mapper ที่มีความสมบูรณ์ 100% ร่วมกับการสร้างดัชนีเชิงพื้นที่ด้วยระบบ H3 ระดับ 7 และการแบ่งข้อมูลในสัดส่วน 80:10:10 เป็นรากฐานสำคัญของแบบจำลอง แบบจำลองที่ดีที่สุดมีค่า Negative Log Likelihood เท่ากับ 8.269 ความซับซ้อน 155 และความละเอียดเชิงพื้นที่ 10 เมตร ซึ่งเมื่อวิเคราะห์แล้วพบว่าสอดคล้องกับหลักการ DOAS ในการตรวจวัดก๊าซในชั้นบรรยากาศ ระบบ MethSense จึงมีศักยภาพในการเป็นเครื่องมือเฝ้าระวังและตรวจจับการรั่วไหลของก๊าซเรือนกระจกได้อย่างแม่นยำและทันทั่วทั้ง สนับสนุนการตัดสินใจเชิงนโยบายด้านสิ่งแวดล้อมและการขับเคลื่อนความยั่งยืนในระยะยาว

#### ข้อเสนอแนะ

ควรทดสอบแบบจำลองกับข้อมูลจากดาวเทียมดวงอื่นและเซ็นเซอร์หลากหลายแหล่ง รวมถึงปัจจัยสิ่งแวดล้อม เช่น อุณหภูมิ ความชื้น และความเร็วลม เพื่อเพิ่มความแม่นยำและความครอบคลุม ควรสำรวจพารามิเตอร์และตัวดำเนินการทางคณิตศาสตร์ชุดใหม่ของ PySR รวมถึงการตีความองค์ประกอบของสมการในเชิงฟิสิกส์และเคมีเพิ่มเติม เพื่อเสริมความน่าเชื่อถือทางวิทยาศาสตร์ให้กับแบบจำลอง

#### กิตติกรรมประกาศ

คณะผู้จัดทำขอขอบพระคุณ นายขุนทอง คล้ายทอง อาจารย์ที่ปรึกษา ดร.กอบชัย ดวงรัตนเลิศ และ ดร.ชนติ จันทโรตติชชาวล อาจารย์ที่ปรึกษาพิเศษ ที่คอยให้คำแนะนำสำหรับปัญหาทางเทคนิคต่าง ๆ รวมถึงชี้แนะและให้กำลังใจตลอดการ



ดำเนินงาน ขอขอบพระคุณ ดร.สมร ปาโท ผู้อำนวยการโรงเรียนวิทยาศาสตร์จุฬาราชวิทยาลัย ปทุมธานี ที่อนุญาตให้ทำโครงการและใช้สถานที่ ขอขอบคุณบิดา มารดา และผู้ปกครองที่คอยสนับสนุนและให้กำลังใจเสมอ และขอขอบคุณสมาคมวิทยาศาสตร์แห่งประเทศไทยในพระบรมราชูปถัมภ์ ร่วมกับคณะวิทยาศาสตร์ มหาวิทยาลัยบูรพา ที่จัดการประกวดโครงการวิทยาศาสตร์ขั้น

## เอกสารอ้างอิง

- Cranmer, M., Sanchez-Gonzalez, A., Battaglia, P., Xu, R., Cranmer, K., Spergel, D., & Ho, S. (2020). Discovering symbolic models from deep learning with inductive biases. *Advances in Neural Information Processing Systems*, 33, 17429–17442.
- Cusworth, D. H., Duren, R. M., Thorpe, A. K., Olson-Duvall, W., Heckler, J., Chapman, J. W., Eastwood, M. L., Helmlinger, M. C., Green, R. O., Asner, G. P., Dennison, P. E., & Miller, C. E. (2022). Multi-satellite imaging of a gas well blowout enables quantification of total methane emissions. *Geophysical Research Letters*, 49, e2021GL096576. <https://doi.org/10.1029/2021GL096576>
- European Centre for Medium-Range Weather Forecasts. (2023). Copernicus Atmosphere Monitoring Service (CAMS). <https://atmosphere.copernicus.eu>
- European Space Agency. (2023). Sentinel-5P: Monitoring air quality and climate. [https://www.esa.int/Applications/Observing\\_the\\_Earth/Copernicus/Sentinel-5P](https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-5P)
- GHGSat. (2023). High-resolution satellite data for methane monitoring. <https://www.ghgsat.com>
- Koza, J. R. (1992). Genetic programming: On the programming of computers by means of natural selection. MIT Press.
- Kuze, A., Suto, H., Nakajima, M., & Hamazaki, T. (2009). Thermal and near infrared sensor for carbon observation Fourier-transform spectrometer on the Greenhouse Gases Observing Satellite for greenhouse gases monitoring. *Applied Optics*, 48(35), 6716–6733. <https://doi.org/10.1364/AO.48.006716>
- Lacava, T. (2023). PySR: Fast and parallelized symbolic regression in Python/Julia. Python Package Index. <https://pypi.org/project/pysr/>
- Meyer, H., Reudenbach, C., Hengl, T., Katurji, M., & Nauss, T. (2018). Improving performance of spatio-temporal machine learning models using forward feature selection and target-oriented validation. *Environmental Modelling & Software*, 101, 1–9. <https://doi.org/10.1016/j.envsoft.2017.12.001>
- National Oceanic and Atmospheric Administration (NOAA). (2023). Methane and climate change. <https://www.noaa.gov/education/resource-collections/climate/methane-and-climate-change>
- NASA. (2022). Global climate change: Vital signs of the planet. <https://climate.nasa.gov/>
- NASA. (n.d.). Methane: Vital signs of the planet. NASA Climate Change. <https://climate.nasa.gov/vital-signs/methane/>
- Radman, A., Mahdianpari, M., Varon, D. J., & Mohammadimanesh, F. (2023). S2MetNet: A novel dataset and deep learning benchmark for methane point source quantification using Sentinel-2 satellite imagery. *Remote Sensing of Environment*, 295, 113708. <https://doi.org/10.1016/j.rse.2023.113708>
- Rouet-Leduc, B., & Hulbert, C. (2024). Automatic detection of methane emissions in multispectral satellite imagery using a vision transformer. *Nature Communications*, 15(1). <https://doi.org/10.1038/s41467-024-47754-y>
- Saunio, M., Stavert, A. R., Poulter, B., Bousquet, P., Canadell, J. G., Jackson, R. B., ... & Zheng, B. (2020). The Global Methane Budget 2000–2017. *Earth System Science Data*, 12(3), 1561–1623. <https://doi.org/10.5194/essd-12-1561-2020>
- Schmidt, M., & Lipson, H. (2009). Distilling free-form natural laws from experimental data. *Science*, 324(5923), 81–85. <https://doi.org/10.1126/science.1165893>



- Udrescu, S. M., & Tegmark, M. (2020). AI Feynman: A physics-inspired method for symbolic regression. *Science Advances*, 6(16), eaay2631. <https://doi.org/10.1126/sciadv.aay2631>
- United Nations Environment Programme. (2021). Global methane assessment: Benefits and costs of mitigating methane emissions. <https://www.unep.org/resources/report/global-methane-assessment-benefits-and-costs-mitigating-methane-emissions>
- Varon, D. J., Jacob, D. J., McKeever, J., Jervis, D., Durak, B. O. A., Xia, Y., & Huang, Y. (2021). High-frequency monitoring of anomalous methane point sources with multispectral Sentinel-2 satellite observations. *Atmospheric Measurement Techniques*, 14(4), 2771–2785.
- Veefkind, J. P., Aben, I., McMullan, K., Förster, H., de Vries, J., Otter, G., ... & Levelt, P. F. (2012). TROPOMI on the ESA Sentinel-5 Precursor: A GMES mission for global observations of the atmospheric composition for climate, air quality and ozone layer applications. *Remote Sensing of Environment*, 120, 70–83. <https://doi.org/10.1016/j.rse.2011.09.027>
- Wang, H., Fan, X., Jian, H., & Yan, F. (2024). Exploiting the matched filter to improve the detection of methane plumes with Sentinel-2 data. *Remote Sensing*, 16(6), 1023. <https://doi.org/10.3390/rs16061023>
- Wang, J., Yang, Y., Wang, Y., Wu, Z., & Gao, F. (2020). A review of data quality assessment in environmental monitoring. *Environmental Science and Pollution Research*, 27(28), 34699–34717. <https://doi.org/10.1007/s11356-020-09867-2>