



การพัฒนาโมเดลปัญญาประดิษฐ์แบบเอเจนติกเอไอ เพื่อสนับสนุนการประเมินก๊าซเรือนกระจกในระดับ
องค์กร

นางสาวไศจรินทร์ ทรงประดิษฐ์

การค้นคว้าอิสระนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร

วิทยาศาสตรมหาบัณฑิต

สาขาวิชาระบบสารสนเทศเพื่อการจัดการ

บัณฑิตวิทยาลัย มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

ปีการศึกษา 2568

ลิขสิทธิ์ของมหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

การพัฒนาโมเดลปัญญาประดิษฐ์แบบเอเจนติกเอไอ
เพื่อสนับสนุนการประเมินก๊าซเรือนกระจกในระดับองค์กร



นางสาวไศจรິตน์ ทรงประดิษฐ์

การค้นคว้าอิสระนี้เป็นส่วนหนึ่งของการศึกษาหลักสูตร

วิทยาศาสตร์มหาบัณฑิต

สาขาวิชาระบบสารสนเทศเพื่อการจัดการ

บัณฑิตวิทยาลัย มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

ปีการศึกษา 2568

ลิขสิทธิ์ของมหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ



ใบรับรองการค้นคว้าอิสระ

บัณฑิตวิทยาลัย มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

เรื่อง การพัฒนาโมเดลปัญญาประดิษฐ์แบบเอเจนติกเอไอ เพื่อสนับสนุนการประเมินก๊าซเรือนกระจกในระดับองค์กร

โดย นางสาวไศริรัตน์ ทรงประดิษฐ์

ได้รับอนุมัติให้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิชา
ระบบสารสนเทศเพื่อการจัดการ

คณบดีคณะเทคโนโลยีสารสนเทศและ
นวัตกรรมดิจิทัล

(ผู้ช่วยศาสตราจารย์ ดร.สุนันทา สดสี)

คณะกรรมการสอบการค้นคว้าอิสระ

ประธาน

(รองศาสตราจารย์ ดร.อลิสา ทรงศรีวิทยา)

อาจารย์ที่ปรึกษา

(รองศาสตราจารย์ ดร.มหศักดิ์ เกตุฉ่ำ)

กรรมการ

(ผู้ช่วยศาสตราจารย์ ดร.ศักดิ์ชาย ตั้งวรรณวิทย์)

ชื่อ : นางสาวไศจรีย์ ทรวงประดิษฐ์
ชื่อการค้นคว้าอิสระ : การพัฒนาโมเดลปัญญาประดิษฐ์แบบเอเจนติกเอไอ เพื่อ
สนับสนุนการประเมินก๊าซเรือนกระจกในระดับองค์กร
สาขาวิชา : ระบบสารสนเทศเพื่อการจัดการ
มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
อาจารย์ที่ปรึกษาการค้นคว้าอิสระหลัก : รองศาสตราจารย์ ดร.มหศักดิ์ เกตุฉ่ำ
ปีการศึกษา : 2568

บทคัดย่อ

ปัญหาการเปลี่ยนแปลงสภาพภูมิอากาศจากก๊าซเรือนกระจกเป็นความท้าทายสำคัญระดับโลก ทำให้องค์กรต้องวัด รายงาน และบริหารจัดการก๊าซเรือนกระจก เพื่อความยั่งยืนและการปฏิบัติตามข้อกำหนด อย่างไรก็ตาม การประเมินยังมีความซับซ้อนจากการจัดการข้อมูลจำนวนมาก การกำหนด Scope 1-3 และการใช้มาตรฐานที่หลากหลาย งานวิจัยนี้พัฒนาโมเดลเอเจนติกเอไอ แบบ Hybrid เพื่อสนับสนุนการประเมินก๊าซเรือนกระจก โดยผสานโมเดลภาษา การวางแผนเชิงตัวแทน การค้นคืนความรู้ และการคำนวณเชิงกำหนด รองรับกระบวนการ MRV อย่างเป็นระบบ ตั้งแต่การตีความข้อมูล เลือกปัจจัยการปล่อย คำนวณ ไปจนถึงให้คำแนะนำตามมาตรฐานสากล ผลการประเมินพบว่าโมเดลมีความแม่นยำและน่าเชื่อถือใกล้เคียงผู้เชี่ยวชาญ ช่วยลดภาระการจัดการข้อมูล และเสริมศักยภาพองค์กรในการตอบสนองต่อข้อกำหนดด้านคาร์บอนในยุคดิจิทัล อีกทั้งยังช่วยเพิ่มความโปร่งใสของกระบวนการคำนวณและการตัดสินใจ ทำให้องค์กรสามารถตรวจสอบย้อนกลับและปรับปรุงการดำเนินงานด้านสิ่งแวดล้อมได้อย่างมีประสิทธิภาพ และยังมีศักยภาพในการประยุกต์ใช้กับอุตสาหกรรมที่หลากหลาย รวมถึงการต่อยอดสู่การวิเคราะห์เชิงคาดการณ์และการวางแผนลดการปล่อยก๊าซเรือนกระจกในระยะยาว

(มีจำนวนทั้งสิ้น 106 หน้า)

คำสำคัญ : ปัญญาประดิษฐ์, ปัญญาประดิษฐ์เชิงตัวแทน, การปล่อยก๊าซเรือนกระจก, คาร์บอนฟุตพริ้นท์

อาจารย์ที่ปรึกษาการค้นคว้าอิสระหลัก

Name : Miss Sojirat Songpradit
Independent Study Title : Development of Agentic AI Models for Organizational
Carbon Footprint Assessment and Governance
Major Field : Management Information Systems
King Mongkut's University of Technology North
Bangkok
Independent Study Advisor : Associate Professor Dr. Mahasak Ketcham
Academic Year : 2025

ABSTRACT

Climate change driven by greenhouse gas emissions is a major global challenge, requiring organizations to measure, report, and manage their carbon footprint despite the complexity of handling large datasets, defining Scope 1-3 emissions, and complying with diverse standards. This study proposes a Hybrid Agentic AI model that integrates language models, agent-based planning, knowledge retrieval, and deterministic calculation to support the Measurement, Reporting, and Verification (MRV) process, including data interpretation, emission factor selection, calculation, and standard-aligned recommendations. Results show that the model achieves accuracy comparable to experts, reduces data management burden, enhances transparency and traceability, and has strong potential for broader industrial application and future predictive carbon reduction planning.

(Total 106 Pages)

Keywords: Artificial Intelligence, Agentic AI, Greenhouse Gas Emissions, Carbon Footprint

Advisor

กิตติกรรมประกาศ

การค้นคว้าอิสระฉบับนี้สำเร็จลงได้ด้วยดี ด้วยความอนุเคราะห์และการสนับสนุนจากหลายฝ่าย ผู้วิจัยขอกราบขอบพระคุณเป็นอย่างสูงต่อทุกท่านที่มีส่วนร่วมในการผลักดันให้งานวิจัยชิ้นนี้สำเร็จลงไปได้

ผู้วิจัยขอกราบขอบพระคุณ รองศาสตราจารย์ ดร.มหศักดิ์ เกตุฉ่ำ อาจารย์ที่ปรึกษาหลัก ที่กรุณาให้คำปรึกษา แนะนำแนวทาง ตรวจสอบ และให้ข้อคิดเห็นที่มีคุณค่าอย่างต่อเนื่อง ด้วยความใส่ใจและเมตตาอันเป็นกำลังใจสำคัญตลอดระยะเวลาของการทำวิจัย ขอขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.ศักดิ์ชาย ตั้งวรรณวิทย์ กรรมการสอบการค้นคว้าอิสระ ที่กรุณาให้คำแนะนำที่เป็นประโยชน์อย่างยิ่งในการปรับปรุงงานวิจัยให้มีความสมบูรณ์และถูกต้องยิ่งขึ้น และขอขอบคุณเป็นพิเศษสำหรับ นายศรัทธญา บุญเฉลียว ที่ปรึกษาคนสำคัญ ที่ได้กรุณาให้คำแนะนำ ชี้แนะแนวทาง และให้การสนับสนุนอย่างดียิ่งแก่ผู้วิจัยมาโดยตลอด ตั้งแต่จุดเริ่มต้นจนกระทั่งงานวิจัยฉบับนี้สำเร็จลง

ขอขอบพระคุณคณาจารย์ทุกท่านในภาควิชาการจัดการเทคโนโลยีสารสนเทศ คณะเทคโนโลยีสารสนเทศและนวัตกรรมดิจิทัล มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ ที่มอบองค์ความรู้และประสบการณ์อันมีคุณค่า ซึ่งเป็นรากฐานสำคัญของการทำงานวิจัยฉบับนี้ และหล่อหลอมให้ผู้วิจัยมีแนวคิดและทักษะที่จำเป็นในการศึกษาค้นคว้าอย่างมีคุณภาพ

ขอขอบคุณครอบครัวและเพื่อนร่วมรุ่นทุกท่าน ที่ให้กำลังใจ แบ่งปันความคิดเห็น และช่วยเหลือในหลายด้านทั้งในเชิงวิชาการและกำลังใจ ขอขอบคุณเป็นพิเศษสำหรับ จิมมี่ ซี โอวเซียน และเพื่อน ๆ ในด้อม ทุกคน ที่เป็นแรงบันดาลใจและแหล่งพลังงานชั้นดีในยามท้อแท้ การได้รับกำลังใจและเสียงหัวเราะจากพวกคุณทำให้การเดินทางบนเส้นทางการศึกษาร้านี้เต็มไปด้วยความหมายและความสุขอย่างแท้จริง

ผู้วิจัยหวังเป็นอย่างยิ่งว่าการค้นคว้าอิสระฉบับนี้จะเป็นประโยชน์ต่อผู้ที่สนใจในการประยุกต์ใช้เทคโนโลยีเอเจนติกเอไอ เพื่อสนับสนุนการประเมินก๊าซเรือนกระจก และเป็นแนวทางในการพัฒนางานวิจัยต่อไปในอนาคต

หากมีข้อผิดพลาดประการใด ผู้วิจัยขอน้อมรับไว้ด้วยความเคารพ

ไศจักรัตน์ ทรงประดิษฐ์

สารบัญ

หน้า

บทคัดย่อภาษาไทย	ง
บทคัดย่อภาษาอังกฤษ	จ
กิตติกรรมประกาศ	ฉ
สารบัญ	ช
สารบัญตาราง	ณ
สารบัญรูปภาพ	ญ
บทที่ 1 บทนำ	1
1.1 ความเป็นมาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์ของงานวิจัย	3
1.3 ขอบเขตของการวิจัย	3
1.4 นิยามศัพท์	5
1.5 ประโยชน์ที่คาดว่าจะได้รับ	7
บทที่ 2 เอกสารและงานวิจัยที่เกี่ยวข้อง	8
2.1 แนวคิดและหลักการของ Carbon Footprint	8
2.2 มาตรฐานการประเมิน Carbon Footprint	11
2.3 ยุทธศาสตร์ LTS ของไทยด้านการลดก๊าซเรือนกระจก	13
2.4 แนวคิดของ Agentic AI และการประยุกต์ใช้	14
2.5 การสร้างความน่าเชื่อถือและการประเมินประสิทธิภาพระบบ AI	16
2.6 สรุปรงานวิจัยที่เกี่ยวข้องและช่องว่างของงานวิจัย	19
บทที่ 3 วิธีดำเนินงานวิจัย	23
3.1 กรอบแนวคิดของงานวิจัย	24
3.2 การเตรียมข้อมูลและฐานความรู้	29
3.3 การพัฒนา Agentic AI	31
3.4 สถาปัตยกรรมของระบบ	34
3.5 การพัฒนาและทดสอบระบบ	38
3.6 การประเมินผล	40

บทที่ 4 ผลการดำเนินงานวิจัย	46
4.1 ผลการประเมินความถูกต้องของการคำนวณ (Accuracy Evaluation)	47
4.2 ผลการประเมินคุณภาพของระบบ RAG (Reliability Evaluation)	49
4.3 ผลการประเมินความสามารถในการใช้งานของระบบ (Usability Evaluation)	50
4.4 ผลการประเมินความโปร่งใสของระบบ (Explainability Evaluation)	53
4.5 ผลการประเมินด้านประสิทธิภาพของระบบ (Performance Evaluation)	54
4.6 ผลการประเมินความถูกต้องของการแปลงภาษาธรรมชาติ (Functional Evaluation)	55
4.7 ผลการประเมินความครบถ้วนของฟังก์ชัน (Completeness Evaluation)	57
4.8 สรุปผลการประเมิน (Summary of Results)	58
บทที่ 5 สรุปผล อภิปรายผล และข้อเสนอแนะ	60
5.1 สรุปผลการดำเนินงาน	60
5.2 อภิปรายผล	61
5.3 ข้อเสนอแนะ	63
บรรณานุกรม	65
ภาคผนวก ก	71
ภาคผนวก ข	75
ภาคผนวก ค	84
ภาคผนวก ง	90
ประวัติผู้เขียน	95

สารบัญตาราง

ตารางที่	หน้า
2-1 ตารางเปรียบเทียบงานวิจัยที่เกี่ยวข้อง	20
3-1 สรุป Services และ Ports	27
3-2 สรุป Agent และหน้าที่	28
3-3 carbon_footprint_db (Master/Reference Data)	36
3-4 carbon_footprint_zero (Org DB)	37
3-5 Qdrant Vector Collections	38
3-6 Data Flow (ตัวอย่าง Request แต่ละประเภท)	38
4-1 ผลการทดสอบความถูกต้องการคำนวณแยกตามกิจกรรมและ Scope	47
4-2 ผลการทดสอบคุณภาพ RAG แยกตามหมวดหมู่	49
4-3 ลักษณะของผู้ใช้ในการทดสอบ Usability	51
4-4 ผล SUS Score แยกตามผู้ใช้	51
4-5 ผลการทดสอบแยกตาม Scenario	52
4-6 การประเมิน Explainability	53
4-7 ระบบอ้างอิง EF Source	54
4-8 Response Time แยกตามประเภทคำขอ	54
4-9 ผลการทดสอบการแปลงภาษาธรรมชาติเป็น MongoDB Query	56
4-10 ผลการทดสอบแต่ละ Component ของ AgenticMongoQueryAgent	56
4-11 สรุปผลการประเมินระบบ Agentic AI ทั้งหมด	58
4-12 สรุปการตอบสนองต่อ Research Gap	59
ค-1 ฐานข้อมูลหลัก (Master Data)	85
ค-2 กิจกรรมมาตรฐาน (Standard Activities)	85
ค-3 ฐานความรู้ (Knowledge Base - RAG)	86
ค-4 การแบ่งกลุ่มตามประเภทคำถามตาม Goal Type (100 Goals)	86

สารบัญตาราง (ต่อ)

ตารางที่	หน้า
ค-5 ตัวอย่างคำถามและคำตอบจากชุดทดสอบ	87
ค-6 ตัวอย่างการตอบคำถามความรู้ทั่วไป (RAG Knowledge Base)	89



สารบัญรูปภาพ

ภาพที่	หน้า
3-1 กรอบแนวคิดของงานวิจัย	24
3-2 กรอบแนวคิดและสถาปัตยกรรมภาพรวมของระบบ	25
ก-1 ไตอะแกรมสถาปัตยกรรมระดับสูง (High-Level Architecture)	72
ก-2 File Processing Pipeline	73
ก-3 Network Architecture	74
ข-1 ตัวอย่าง Prompt Templates - AI Query Analyzer (1)	76
ข-2 ตัวอย่าง Prompt Templates - AI Query Analyzer (2)	77
ข-3 ตัวอย่าง Prompt Templates - Agentic Orchestrator (1)	78
ข-4 ตัวอย่าง Prompt Templates - Agentic Orchestrator (2)	79
ข-5 ตัวอย่าง Workflow Diagrams - Main Orchestration Flow	80
ข-6 ตัวอย่าง Workflow Diagrams - Calculation Workflow	81
ข-7 ตัวอย่าง Workflow Diagrams - Knowledge Search Workflow (RAG)	82
ข-8 ตัวอย่าง Workflow Diagrams - Multi-Step Workflow	83
ง-1 หน้าการทำ OCR	91
ง-2 หน้า Chat ที่สามารถเลือก RAG Strategy ได้	92
ง-3 หน้า Frontend สำหรับใช้งาน Agentic AI โดยการตั้งเป้าหมาย	93
ง-4 หน้าตัวอย่างคำถามทั่วไป	94
ง-5 หน้าตัวอย่างคำถามคำนวณ	94

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

การเปลี่ยนแปลงสภาพภูมิอากาศเป็นความเสี่ยงเชิงระบบที่ส่งผลกระทบต่อเศรษฐกิจ สิ่งแวดล้อม และความมั่นคงของมนุษย์ในระดับโลก โดยรายงานของ Intergovernmental Panel on Climate Change ระบุว่า การเพิ่มขึ้นของอุณหภูมิเฉลี่ยของโลกมีความสัมพันธ์โดยตรงกับการสะสมก๊าซเรือนกระจกจากกิจกรรมของมนุษย์ โดยเฉพาะการใช้พลังงานฟอสซิล กระบวนการอุตสาหกรรม การเกษตร และการเปลี่ยนแปลงการใช้ที่ดิน ซึ่งนำไปสู่ความเสี่ยงด้านสภาพอากาศสุดขั้ว การสูญเสียความหลากหลายทางชีวภาพ และผลกระทบต่อระบบเศรษฐกิจโลกในระยะยาว (IPCC, 2019)

ประเทศไทยในฐานะประเทศกำลังพัฒนาได้เข้าร่วม Paris Agreement และกำหนดเป้าหมายลดการปล่อยก๊าซเรือนกระจกภายใต้กรอบนโยบายระดับชาติ เช่น แผนพัฒนาเศรษฐกิจและสังคมแห่งชาติ ฉบับที่ 13 และยุทธศาสตร์ชาติ 20 ปี เพื่อสนับสนุนการเปลี่ยนผ่านสู่เศรษฐกิจคาร์บอนต่ำ และการพัฒนาอย่างยั่งยืน (Office of Natural Resources and Environmental Policy and Planning, 2021) ภายใต้บริบทดังกล่าว องค์กรธุรกิจมีบทบาทสำคัญในการขับเคลื่อนการลดการปล่อยก๊าซเรือนกระจกผ่านการวัด รายงาน และบริหารจัดการการปล่อยก๊าซเรือนกระจกในระดับองค์กร

การประเมิน Carbon Footprint ขององค์กรจึงกลายเป็นเครื่องมือเชิงกลยุทธ์ที่สำคัญในการสนับสนุนการกำหนดนโยบายด้านสิ่งแวดล้อม การบริหารความเสี่ยง และการสร้างความสามารถในการแข่งขันในตลาดที่ให้ความสำคัญกับความยั่งยืน โดยการดำเนินการดังกล่าวต้องอาศัยกรอบมาตรฐานสากล เช่น Greenhouse Gas Protocol รวมถึงมาตรฐาน ISO 14064 และแนวปฏิบัติขององค์การบริหารจัดการก๊าซเรือนกระจก (องค์การมหาชน) (World Resources Institute & WBCSD, 2015; ISO, 2018)

อย่างไรก็ตาม กระบวนการประเมิน Carbon Footprint มีความซับซ้อนสูง เนื่องจากต้องครอบคลุมการรวบรวมข้อมูลกิจกรรมจำนวนมาก การกำหนดขอบเขตการปล่อย Scope 1–3 การเลือก Emission Factor ที่เหมาะสม การจัดการความไม่แน่นอนของข้อมูล และการดำเนินการภายใต้กรอบ Measurement, Reporting and Verification (MRV) ที่ต้องการความถูกต้อง โปร่งใส และ

ตรวจสอบได้ โดยเฉพาะในองค์กรขนาดใหญ่ที่มีห่วงโซ่อุปทานซับซ้อน การติดตามข้อมูลจากผู้ผลิต ผู้จัดจำหน่าย และคู่ค้าหลายระดับเป็นความท้าทายสำคัญที่ส่งผลต่อความครบถ้วนและความน่าเชื่อถือของข้อมูลการปล่อยก๊าซเรือนกระจก (Huang & Mao, 2024)

ในบริบทของการเปลี่ยนผ่านสู่เศรษฐกิจดิจิทัล เทคโนโลยีปัญญาประดิษฐ์ได้เข้ามามีบทบาทสำคัญในการสนับสนุนการจัดการข้อมูลขนาดใหญ่และการตัดสินใจเชิงซับซ้อน โดยเฉพาะ Large Language Models และแนวคิด Agentic AI ซึ่งสามารถวิเคราะห์ข้อมูลจำนวนมาก ให้เหตุผลเชิงบริบท และดำเนินการหลายขั้นตอนแบบอัตโนมัติ เทคโนโลยีดังกล่าวมีศักยภาพในการสนับสนุนกระบวนการ MRV ด้านก๊าซเรือนกระจก (Acharya et al., 2025; Park et al., 2023)

อย่างไรก็ตาม งานวิจัยที่ผ่านมาแสดงให้เห็นว่าการใช้ LLMs เพียงอย่างเดียวมีข้อจำกัดด้านความแม่นยำของการคำนวณ ความสม่ำเสมอของผลลัพธ์ และความเสี่ยงจาก Hallucination ซึ่งอาจส่งผลกระทบต่อความน่าเชื่อถือของข้อมูล Carbon Footprint (Bender et al., 2021) นอกจากนี้ ยังขาดกรอบสถาปัตยกรรมที่ผสานความสามารถของ LLM Reasoning กับ Deterministic Calculation Engine และกลไกการควบคุมเชิงตัวแทนเพื่อสนับสนุนงาน MRV อย่างเป็นระบบ (Karpatne et al., 2017)

ด้วยเหตุนี้ งานวิจัยนี้จึงมุ่งพัฒนา Agentic AI สำหรับการประเมิน Carbon Footprint ในระดับองค์กร โดยผสานความสามารถของ LLMs กลไกการวางแผนและควบคุมแบบตัวแทน การค้นคืนข้อมูลจากฐานความรู้ และโมดูลการคำนวณเชิงตรรกะ เพื่อเพิ่มความแม่นยำ ความโปร่งใส และความน่าเชื่อถือของผลลัพธ์ พร้อมทั้งสนับสนุนการให้คำปรึกษาเชิงเทคนิคในระดับผู้เชี่ยวชาญ และเสริมศักยภาพองค์กรไทยในการบริหารจัดการคาร์บอนภายใต้บริบทเศรษฐกิจดิจิทัลและการเปลี่ยนผ่านสู่ความยั่งยืน (Gold Standard, 2022; UNFCCC, 2022)

ภายใต้บริบทดังกล่าว งานวิจัยนี้มุ่งเน้นการพัฒนาโมเดลปัญญาประดิษฐ์แบบเอเจนติกเอไอ ในฐานะเครื่องมือสนับสนุนการประเมินก๊าซเรือนกระจกในระดับองค์กร โดยโมเดลดังกล่าวถูกออกแบบให้สามารถดำเนินการกระบวนการหลายขั้นตอน ได้แก่ การรวบรวมและตีความข้อมูลกิจกรรม การเลือกปัจจัยการปล่อยที่เหมาะสม การคำนวณการปล่อยก๊าซเรือนกระจก และการให้คำแนะนำเชิงเทคนิคภายใต้กรอบ MRV ทั้งนี้ การพัฒนาโมเดลมุ่งเน้นการผสานความสามารถด้าน Reasoning ของโมเดลภาษา กลไกการวางแผนแบบตัวแทน และ Deterministic Calculation Engine เพื่อเพิ่มความแม่นยำ ความโปร่งใส และความน่าเชื่อถือของการประเมิน Carbon Footprint ในระดับองค์กร (Balaji & Ebrahimi, 2025)

1.2 วัตถุประสงค์ของงานวิจัย

1.2.1 เพื่อศึกษาหลักการ กระบวนการ และมาตรฐานการประเมิน Carbon Footprint ในระดับองค์กร ภายใต้กรอบมาตรฐานสากลและแนวปฏิบัติของประเทศไทย

1.2.2 เพื่อออกแบบและพัฒนาโมเดลปัญญาประดิษฐ์แบบ Agentic AI สำหรับสนับสนุนกระบวนการประเมิน Carbon Footprint ในระดับองค์กรอย่างเป็นระบบ

1.2.3 เพื่อประเมินประสิทธิภาพและศักยภาพของโมเดลที่พัฒนาขึ้นในด้านความแม่นยำ ความน่าเชื่อถือ และคุณภาพคำแนะนำเชิงเทคนิค

1.3 ขอบเขตของการวิจัย

การศึกษาวิจัยครั้งนี้มุ่งเน้นการพัฒนาโมเดลปัญญาประดิษฐ์แบบเอเจนติกเอไอ เพื่อสนับสนุนการประเมินก๊าซเรือนกระจกในระดับองค์กร ภายใต้บริบทของกระบวนการ Measurement, Reporting and Verification (MRV) โดยให้ความสำคัญกับการออกแบบสถาปัตยกรรมที่สามารถวิเคราะห์ข้อมูลกิจกรรมการปล่อยก๊าซเรือนกระจก ให้คำแนะนำเชิงเทคนิค และสนับสนุนการตัดสินใจด้านบัญชีคาร์บอนผ่านการโต้ตอบด้วยภาษาธรรมชาติ ทั้งนี้ เพื่อกำหนดขอบเขตการดำเนินงานของงานวิจัยให้มีความชัดเจนและสอดคล้องกับวัตถุประสงค์ จึงได้กำหนดขอบเขตการศึกษาในด้านต่าง ๆ ดังต่อไปนี้

1.3.1 ขอบเขตด้านเนื้อหา งานวิจัยมุ่งเน้นการพัฒนาและประเมินระบบ Agentic AI สำหรับสนับสนุนกระบวนการ MRV ด้าน Carbon Footprint ในระดับองค์กร โดยครอบคลุม

2.6.5.1 การประเมินการปล่อยก๊าซเรือนกระจก Scope 1, Scope 2 และ Scope 3

2.6.5.2 การประยุกต์ใช้มาตรฐาน Carbon Accounting และ Emission Factor Database

2.6.5.3 การออกแบบสถาปัตยกรรม Agentic AI ซึ่งประกอบด้วย

- (1) Natural Language Interaction Layer
- (2) Retrieval-Augmented Knowledge Layer
- (3) Logical Reasoning Layer
- (4) Deterministic Calculation Engine
- (5) Agentic Control & Planning Module

1.3.2 ขอบเขตด้านข้อมูล งานวิจัยใช้ข้อมูล 3 ประเภท

2.6.5.1 ข้อมูลกิจกรรมการปล่อยก๊าซเรือนกระจกขององค์กรในรูปแบบ Anonymized

2.6.5.2 ชุดข้อมูลจำลองเชิงซ้อนสำหรับการทดสอบ Robustness

2.6.5.3 ฐานข้อมูล Emission Factors จากแหล่งมาตรฐาน

1.3.3 ขอบเขตด้านเทคนิค AI ครอบคลุม

2.6.5.1 LLM reasoning

2.6.5.2 Agent planning & Orchestration

2.6.5.3 RAG Integration

2.6.5.4 Engineering

2.6.5.5 Deterministic Carbon Calculation

2.6.5.6 Hallucination Mitigation

1.3.4 ขอบเขตด้านการประเมิน ประเมิน 2 มิติ

2.6.5.1 มิติหลัก

(1) ด้านความแม่นยำ (Accuracy)

(2) ด้านความน่าเชื่อถือ (Reliability)

(3) ด้านความใช้งานได้ (Usability)

(4) ด้านความโปร่งใส (Explainability)

2.6.5.2 มิติสนับสนุน

(1) ด้านประสิทธิภาพ (Performance)

(2) ด้านการทำงาน (Functional)

(3) ด้านความสมบูรณ์ (Completeness)

1.3.5 ขอบเขตด้านการประยุกต์ ระบบถูกพัฒนาเป็น Prototype Research System
สำหรับการทดลองเชิงวิชาการ ไม่ใช่ระบบเชิงพาณิชย์

1.4 นิยามศัพท์

1.4.1 โมเดล Agentic AI: กรอบเชิงคอมพิวเตอร์และสถาปัตยกรรมปัญญาประดิษฐ์ที่ผสมผสานความสามารถด้านการให้เหตุผลของโมเดลภาษา กลไกการวางแผนและควบคุมแบบตัวแทน การค้นคืนข้อมูลจากฐานความรู้ และโมดูลการคำนวณเชิงกำหนด เพื่อสนับสนุนกระบวนการประเมิน Carbon Footprint ในระดับองค์กร โดยครอบคลุมการออกแบบโครงสร้างการทำงานและการประสานองค์ประกอบ AI หลายรูปแบบให้สามารถดำเนินกระบวนการประเมินได้อย่างอัตโนมัติ โปร่งใส และตรวจสอบย้อนกลับได้

1.4.2 Carbon Footprint: ปริมาณก๊าซเรือนกระจกทั้งหมดที่ปล่อยจากกิจกรรมขององค์กร โดยแสดงในรูปคาร์บอนไดออกไซด์เทียบเท่า (CO₂e)

1.4.3 Organizational Carbon Accounting: ประเมิน คำนวณ และรายงานการปล่อยก๊าซเรือนกระจกขององค์กรตามมาตรฐานที่กำหนด เพื่อสนับสนุนการบริหารจัดการคาร์บอนและการตัดสินใจเชิงกลยุทธ์

1.4.4 Scope 1, Scope 2 และ Scope 3: Emissions การจำแนกแหล่งการปล่อยก๊าซเรือนกระจกขององค์กร โดย Scope 1 หมายถึงการปล่อยโดยตรง Scope 2 หมายถึงการปล่อยทางอ้อมจากพลังงานที่ซื้อ และ Scope 3 หมายถึงการปล่อยทางอ้อมอื่น ๆ ตลอดห่วงโซ่มูลค่า

1.4.5 Emission Factor: ค่าสัมประสิทธิ์ที่ใช้แปลงข้อมูลกิจกรรมเป็นปริมาณการปล่อยก๊าซเรือนกระจก โดยอ้างอิงจากฐานข้อมูลหรือมาตรฐานที่ได้รับการยอมรับ

1.4.6 Activity Data: ข้อมูลกิจกรรมที่สะท้อนการใช้ทรัพยากร พลังงาน หรือกระบวนการดำเนินงานขององค์กร ซึ่งใช้เป็นอินพุตหลักในการคำนวณการปล่อยก๊าซเรือนกระจกผ่าน emission factors

1.4.7 Deterministic Calculation: กระบวนการคำนวณที่ให้ผลลัพธ์แน่นอนเมื่อใช้อินพุตเดียวกัน โดยอาศัยสูตรหรือกฎเชิงตรรกะที่กำหนดไว้อย่างชัดเจนและสามารถตรวจสอบย้อนกลับได้

1.4.8 Agentic AI: แนวทางการพัฒนาปัญญาประดิษฐ์ที่มีความสามารถในการวางแผน ตัดสินใจ และดำเนินงานหลายขั้นตอนผ่านการทำงานแบบตัวแทนอัตโนมัติ โดยสามารถปรับตัวตามบริบทของปัญหาได้

1.4.9 Agentic Orchestration: กระบวนการประสานงานและควบคุมการทำงานของตัวแทนปัญญาประดิษฐ์หลายองค์ประกอบ เพื่อดำเนินงานหลายขั้นตอนอย่างเป็นระบบ

1.4.10 Multi-Agent System: สถาปัตยกรรมปัญญาประดิษฐ์ที่ประกอบด้วยตัวแทนหลายตัวซึ่งทำงานร่วมกันผ่านการสื่อสารและการประสานงาน เพื่อดำเนินงานที่มีความซับซ้อนและหลายขั้นตอนอย่างมีประสิทธิภาพ

1.4.11 Hybrid AI Architecture: สถาปัตยกรรมปัญญาประดิษฐ์ที่ผสมผสานเทคนิคหลายรูปแบบ เช่น โมเดลภาษา ระบบ Rule-Based และ Calculation Engine เพื่อเพิ่มความแม่นยำและความน่าเชื่อถือของผลลัพธ์

1.4.12 Workflow Automation: กระบวนการทำงานอัตโนมัติที่ใช้เทคโนโลยีดิจิทัลและปัญญาประดิษฐ์ในการดำเนินขั้นตอนต่าง ๆ อย่างต่อเนื่อง โดยลดการพึ่งพาการดำเนินงานด้วยมนุษย์ และเพิ่มความสม่ำเสมอของผลลัพธ์

1.4.13 Large Language Models (LLMs): โมเดลปัญญาประดิษฐ์ที่ได้รับการฝึกจากข้อมูลข้อความขนาดใหญ่และสามารถสร้าง วิเคราะห์ สรุป และให้เหตุผลผ่านภาษาธรรมชาติ

1.4.14 Retrieval-Augmented Generation (RAG): สถาปัตยกรรมปัญญาประดิษฐ์ที่ผสมผสานการค้นคืนข้อมูลจากฐานความรู้กับการสร้างข้อความของโมเดลภาษา เพื่อเพิ่มความถูกต้องและความน่าเชื่อถือของผลลัพธ์

1.4.15 Explainable AI: แนวทางการออกแบบระบบปัญญาประดิษฐ์ที่สามารถอธิบายเหตุผล กระบวนการ และขั้นตอนการตัดสินใจของระบบได้อย่างโปร่งใส

1.4.16 Measurement, Reporting and Verification (MRV): กรอบกระบวนการสำหรับการวัด รายงาน และทวนสอบข้อมูลการปล่อยก๊าซเรือนกระจก เพื่อให้ข้อมูลมีความ

1.4.17 Hallucination ปรากฏการณ์ที่โมเดลปัญญาประดิษฐ์สร้างข้อมูลหรือคำตอบที่ไม่ถูกต้องหรือไม่มีแหล่งอ้างอิง แต่แสดงผลอย่างมั่นใจ

1.4.18 Natural Language Interaction: กลไกการสื่อสารระหว่างผู้ใช้งานกับระบบ AI ผ่านภาษาธรรมชาติ เพื่อสนับสนุนการวิเคราะห์ การให้คำแนะนำ และการตัดสินใจเชิงเทคนิค

1.5 ประโยชน์ที่คาดว่าจะได้รับ

1.5.1 ได้องค์ความรู้เชิงวิชาการที่สังเคราะห์หลักการ กระบวนการ และมาตรฐานการประเมิน Carbon Footprint ในระดับองค์กร ภายใต้กรอบมาตรฐานสากลและแนวปฏิบัติด้านบัญชีคาร์บอนของประเทศไทย

1.5.2 ได้ระบบต้นแบบ Agentic AI ที่ออกแบบเพื่อสนับสนุนกระบวนการประเมิน การคำนวณ และการจัดการข้อมูลการปล่อยก๊าซเรือนกระจก (Carbon Footprint) ในระดับองค์กร ภายใต้กรอบ MRV ที่สามารถตรวจสอบย้อนกลับได้

1.5.3 ได้กรอบแนวทางการประเมินประสิทธิภาพ ความน่าเชื่อถือ และศักยภาพการประยุกต์ใช้ในองค์กรของระบบ Agentic AI ในการประเมิน Carbon Footprint ระดับองค์กร ภายใต้กรอบมาตรฐานสากลและแนวปฏิบัติของประเทศไทย



บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

เนื้อหาในบทนี้จะกล่าวถึงแนวคิด ทฤษฎี และงานวิจัยที่เกี่ยวข้องกับการพัฒนาโมเดล Agentic AI เพื่อสนับสนุนการประเมิน Carbon Footprint ในระดับองค์กร โดยเน้นด้านเทคโนโลยี ปัญญาประดิษฐ์ การจัดการข้อมูลสิ่งแวดล้อม และมาตรฐานที่เกี่ยวข้องกับการประเมิน Carbon Footprint ซึ่งมีรายละเอียดดังต่อไปนี้

- 2.1 แนวคิดและหลักการของ Carbon Footprint
- 2.2 มาตรฐานการประเมิน Carbon Footprint
- 2.3 ยุทธศาสตร์ LTS ของไทยด้านการลดก๊าซเรือนกระจก
- 2.4 แนวคิดของ Agentic AI และการประยุกต์ใช้
- 2.5 การสร้างความน่าเชื่อถือและการประเมินประสิทธิภาพระบบ AI
- 2.6 สรุปรงานวิจัยที่เกี่ยวข้องและช่องว่างของงานวิจัย

2.1 แนวคิดและหลักการของ Carbon Footprint

Intergovernmental Panel on Climate Change ยืนยันว่ากิจกรรมของมนุษย์ โดยเฉพาะ การเผาไหม้เชื้อเพลิงฟอสซิล การเปลี่ยนแปลงการใช้ประโยชน์ที่ดิน และกระบวนการอุตสาหกรรม เป็นปัจจัยหลักที่ทำให้ความเข้มข้นของก๊าซเรือนกระจก (Greenhouse Gases: GHGs) ในบรรยากาศเพิ่มสูงขึ้นอย่างต่อเนื่องนับตั้งแต่ยุคปฏิวัติอุตสาหกรรม ส่งผลให้เกิดภาวะโลกร้อน ระดับน้ำทะเลสูงขึ้น และความถี่ของเหตุการณ์สภาพอากาศสุดขั้วที่ส่งผลกระทบต่อระบบนิเวศและเศรษฐกิจโลก (IPCC, 2019) ผลกระทบดังกล่าวกระตุ้นให้นานาประเทศเร่งพัฒนากลไกการวัดและจัดการการปล่อยก๊าซเรือนกระจกอย่างเป็นระบบ

คาร์บอนฟุตพริ้นท์ (Carbon Footprint) ได้พัฒนาขึ้นเป็นเครื่องมือเชิงปริมาณสำคัญในการประเมินผลกระทบดังกล่าว โดยทำหน้าที่เป็นดัชนีสะท้อนปริมาณการปล่อยก๊าซเรือนกระจกตลอดห่วงโซ่คุณค่า (Value Chain) ภายใต้กรอบ Greenhouse Gas Protocol มาตรฐาน ISO 14064 และ ISO 14067 ซึ่งมุ่งเน้นระบบ Measurement, Reporting and Verification (MRV) ที่โปร่งใสและตรวจสอบได้ (WRI and WBCSD, 2015; ISO, 2018; Gold Standard, 2022) การประเมิน

Carbon Footprint จึงเป็นกลไกเชิงยุทธศาสตร์สนับสนุนการกำหนดเป้าหมาย Net Zero การบริหารความเสี่ยงด้านสภาพภูมิอากาศ และการเปิดเผยข้อมูล ESG ทั้งในระดับองค์กรและระดับประเทศ (Science Based Targets initiative, 2021; World Bank, 2023)

2.1.1 Carbon Footprint หมายถึง ปริมาณรวมของก๊าซเรือนกระจกที่ถูกปล่อยสู่บรรยากาศทั้งทางตรงและทางอ้อมจากกิจกรรมของบุคคล องค์กร ผลิตภัณฑ์ หรือระบบหนึ่ง ๆ รายงานในหน่วย CO₂e โดยอิงแนวคิด Global Warming Potential (GWP) ที่กำหนดโดย IPCC เพื่อแปลงก๊าซชนิดต่าง ๆ ให้เปรียบเทียบกันได้ภายในช่วงเวลา 100 ปี การใช้ค่า GWP ช่วยให้สามารถรวมผลกระทบของก๊าซหลายชนิดที่มีศักยภาพในการทำให้เกิดภาวะโลกร้อนแตกต่างกันไว้ในตัวเลขเดียว เช่น มีเทนมีค่า GWP100 เท่ากับ 27–30 เท่าของ CO₂ ขณะที่ไนตรัสออกไซด์มีค่าสูงถึง 273 เท่า ซึ่งทำให้การเปรียบเทียบและการตัดสินใจเชิงนโยบายมีประสิทธิภาพมากขึ้น (WRI and WBCSD, 2015; ISO, 2018; IPCC, 2019)

ตามกรอบ Kyoto Protocol และ Paris Agreement การจัดทำบัญชีก๊าซเรือนกระจกครอบคลุมก๊าซหลัก 7 ชนิด ได้แก่ CO₂ จากการเผาไหม้เชื้อเพลิงฟอสซิล CH₄ จากการย่อยสลายของเสียอินทรีย์ N₂O จากการใช้ปุ๋ยเคมี HFCs ในระบบทำความเย็น PFCs ในอุตสาหกรรมอะลูมิเนียม SF₆ ในอุปกรณ์ไฟฟ้าแรงสูง และ NF₃ ในการผลิตแผงวงจร (IPCC, 2019) ก๊าซแต่ละชนิดมีแหล่งกำเนิดและวัฏจักรในบรรยากาศที่แตกต่างกัน การจัดทำบัญชีที่ครอบคลุมก๊าซทั้ง 7 ชนิดจึงช่วยให้ได้ภาพรวมที่สมบูรณ์ของผลกระทบต่อสภาพภูมิอากาศ

ในเชิงยุทธศาสตร์ Carbon Footprint ช่วยระบุ Emission Hotspots ที่ควรดำเนินมาตรการลดการปล่อยก่อน รองรับมาตรการคาร์บอน เช่น Carbon Border Adjustment Mechanism (CBAM) ของสหภาพยุโรปที่เริ่มบังคับใช้เต็มรูปแบบในปี ค.ศ. 2026 และเป็นพื้นฐานของการเข้าร่วมตลาดคาร์บอนทั้งภาคบังคับและภาคสมัครใจ (World Bank, 2023; OECD, 2023; Krungsri Research, 2025) สำหรับองค์กรไทยที่ส่งออกสินค้าไปยังสหภาพยุโรป การมีข้อมูล Carbon Footprint ที่น่าเชื่อถือจึงกลายเป็นปัจจัยด้านความสามารถในการแข่งขันที่สำคัญ Carbon Footprint จึงเป็นทั้งเครื่องมือทางวิทยาศาสตร์และเครื่องมือเชิงนโยบายที่เชื่อมโยงวิทยาศาสตร์ภูมิอากาศ เศรษฐศาสตร์สิ่งแวดล้อม และการบริหารองค์กรอย่างเป็นระบบ (Rolnick et al., 2019; Reichstein et al., 2019)

2.1.2 มาตรฐาน GHG Protocol Corporate Standard จำแนกแหล่งการปล่อยออกเป็น 3 ขอบเขต (WRI and WBCSD, 2015) ดังนี้ Scope 1 คือการปล่อยทางตรง (Direct GHG Emissions) จากแหล่งที่องค์กรเป็นเจ้าของหรือควบคุม เช่น การเผาไหม้เชื้อเพลิงในหม้อไอน้ำ การใช้ยานพาหนะ

ขององค์กร และการรั่วไหลของสารทำความเย็น ซึ่งเป็นการปล่อยที่องค์กรสามารถควบคุมได้โดยตรง และมักเป็นจุดเริ่มต้นของการดำเนินมาตรการลดการปล่อย Scope 2 คือการปล่อยทางอ้อมจากพลังงาน (Energy Indirect GHG Emissions) ที่เกิดจากการผลิตไฟฟ้า ความร้อน หรือความเย็นที่องค์กรซื้อมาใช้ โดยถือเป็นความรับผิดชอบของผู้ใช้พลังงาน แม้การปล่อยจะเกิดขึ้นที่โรงไฟฟ้าหรือแหล่งผลิตพลังงาน มาตรฐานปัจจุบันยังแบ่ง Scope 2 เป็น Location-based และ Market-based เพื่อสะท้อนการเลือกซื้อพลังงานหมุนเวียน และ Scope 3 คือการปล่อยทางอ้อมอื่น ๆ (Other Indirect GHG Emissions) ครอบคลุมทั้งกิจกรรมต้นทาง (Upstream) และปลายทาง (Downstream) รวม 15 หมวดหมู่ เช่น สินค้าและบริการที่ซื้อมา การขนส่งสินค้า และการจัดการเมื่อหมดอายุการใช้งาน โดยในหลายอุตสาหกรรม Scope 3 อาจคิดเป็นมากกว่าร้อยละ 70-90 ของการปล่อยทั้งหมด และเป็นส่วนที่มีความซับซ้อนสูงสุดในการรวบรวมข้อมูล

2.1.3 การประเมิน Carbon Footprint ตามมาตรฐาน ISO 14064-1 และ GHG Protocol เริ่มจากการกำหนดขอบเขต (Boundary Setting) ได้แก่ ช่วงเวลา หน่วยงาน ขอบเขต Scope และแนวทางคำนวณ เช่น Equity Share, Financial Control หรือ Operational Control จากนั้นรวบรวมข้อมูลกิจกรรม (Activity Data) ที่ครบถ้วนและตรวจสอบย้อนกลับได้ แล้วเลือกค่าสัมประสิทธิ์การปล่อยก๊าซ (Emission Factor) จากแหล่งที่เชื่อถือได้ เช่น TGO, IPCC, DEFRA และ US EPA

ค่า Emission Factor มีความสำคัญอย่างมากต่อความแม่นยำของการคำนวณ โดยแต่ละประเทศและแต่ละช่วงเวลาอาจมีค่าที่แตกต่างกันตามโครงสร้างของแหล่งพลังงาน ตัวอย่างเช่น ค่า Emission Factor ของไฟฟ้าในประเทศไทยปี 2566 อยู่ที่ 0.4999 kgCO₂e/kWh ซึ่งมีแนวโน้มลดลงตามสัดส่วนพลังงานหมุนเวียนที่เพิ่มขึ้น การเลือกใช้ค่า Emission Factor ที่เหมาะสมกับบริบทของประเทศและปีอ้างอิงจึงเป็นขั้นตอนที่ต้องดำเนินการด้วยความระมัดระวัง

หลังการคำนวณ ต้องจัดทำรายงานตามมาตรฐาน เปรียบเทียบกับปีฐานหรือเป้าหมาย และผ่านการตรวจสอบรับรองโดยผู้ตรวจสอบภายในและภายนอก เช่น TGO เพื่อเพิ่มความน่าเชื่อถือและพัฒนาระบบข้อมูลในรอบถัดไป ความซับซ้อนของกระบวนการทั้งหมดนี้ โดยเฉพาะการรวบรวมข้อมูลจากแหล่งที่หลากหลาย การตีความมาตรฐาน และการจัดทำเอกสารหลักฐาน เป็นแรงผลักดันสำคัญให้เกิดความสนใจในการนำ Agentic AI มาสนับสนุนกระบวนการดังกล่าว (ISO, 2018; Gold Standard, 2022; UNFCCC, 2022)

2.2 มาตรฐานการประเมิน Carbon Footprint

การประเมิน Carbon Footprint ต้องดำเนินการภายใต้กรอบมาตรฐานที่มีหลักการทางวิชาการรองรับและทวนสอบได้ เพื่อให้ผลการประเมินมีความถูกต้อง (Accuracy) โปร่งใส (Transparency) และเปรียบเทียบได้ (Comparability) ทั้งระหว่างองค์กรและระหว่างประเทศ มาตรฐานเหล่านี้ไม่เพียงกำหนดวิธีการคำนวณ แต่ยังกำหนดหลักการรายงาน กระบวนการตรวจสอบ และเงื่อนไขการรับรอง ซึ่งเป็นองค์ประกอบสำคัญของระบบ MRV มาตรฐานที่ได้รับการยอมรับอย่างกว้างขวางแบ่งเป็น 3 กลุ่ม ได้แก่ มาตรฐานเชิงแนวทาง (Guidance-based) เช่น GHG Protocol มาตรฐานเชิงข้อกำหนดและการรับรอง (Requirement-based) เช่น ISO 14064 และ ISO 14067 และมาตรฐานระดับประเทศ เช่น แนวทางของ TGO (WRI and WBCSD, 2015; ISO, 2018; IPCC, 2019)

ความซับซ้อนของกระบวนการประเมินระดับองค์กรเกิดจากความหลากหลายของแหล่งข้อมูล ความไม่สมบูรณ์ของข้อมูลกิจกรรม และข้อกำหนด MRV ที่ต้องอาศัยการตีความเชิงบริบทและความรู้เชิงผู้เชี่ยวชาญ กระบวนการดังกล่าวจึงมีลักษณะเป็น Multi-Step Decision Problem ที่ต้องผสมผสานการวิเคราะห์ข้อมูล การให้เหตุผล และการเลือกเครื่องมือคำนวณที่เหมาะสม ซึ่งนำไปสู่ความสนใจในการประยุกต์ใช้ Agentic AI (Acharya et al., 2025; Berijanian et al., 2025; Franklin and Graesser, 1997)

2.2.1 GHG Protocol พัฒนตั้งแต่ปี ค.ศ. 2001 โดยความร่วมมือระหว่าง World Resources Institute และ World Business Council for Sustainable Development เป็นกรอบมาตรฐานที่ได้รับการยอมรับมากที่สุดในระดับสากล ถูกใช้โดยบริษัทมากกว่าร้อยละ 90 ของกลุ่ม Fortune 500 และเป็นที่มาของการจำแนก Scope 1, 2, 3 ซึ่งกลายเป็นมาตรฐานอ้างอิงหลักทั่วโลก ความสำเร็จของ GHG Protocol ส่วนหนึ่งเกิดจากการเป็นกรอบที่เปิดให้ปรับใช้ได้หลากหลายบริบท โดยมีเครื่องมือคำนวณ ตัวอย่างกรณีศึกษา และเอกสารคู่มือจำนวนมากที่สนับสนุนการนำไปใช้งาน (WRI and WBCSD, 2015)

GHG Protocol ประกอบด้วยมาตรฐานย่อย 3 ฉบับ ฉบับแรกคือ Corporate Accounting and Reporting Standard ซึ่งกำหนดหลักการพื้นฐาน 5 ประการ ได้แก่ ความเกี่ยวข้อง (Relevance) ความสมบูรณ์ (Completeness) ความสม่ำเสมอ (Consistency) ความโปร่งใส (Transparency) และความแม่นยำ (Accuracy) หลักการทั้ง 5 นี้เป็นรากฐานที่ทำให้รายงานก๊าซเรือนกระจกมีคุณภาพและสามารถเปรียบเทียบได้ข้ามช่วงเวลาและข้ามองค์กร ฉบับที่สองคือ Corporate Value Chain (Scope 3) Standard ที่จำแนก Scope 3 เป็น 15 หมวดหมู่ รองรับ

อุตสาหกรรมที่มีสัดส่วน Scope 3 สูงกว่าร้อยละ 70–90 ของการปล่อยทั้งหมด เช่น อุตสาหกรรมอาหาร ค้าปลีก และเทคโนโลยี และฉบับที่สามคือ Product Life Cycle Accounting and Reporting Standard สำหรับประเมินคาร์บอนฟุตพริ้นท์ผลิตภัณฑ์ตามแนวทาง ISO 14040/14044 ซึ่งมีประโยชน์ในการสนับสนุนการออกแบบผลิตภัณฑ์ที่มีคาร์บอนต่ำ (WRI and WBCSD, 2015; WRI and WBCSD, 2011; ISO, 2018; Huang and Mao, 2024)

ข้อดีของ GHG Protocol คือความยืดหยุ่นสูง มีเครื่องมือสนับสนุนจำนวนมาก และเป็นพื้นฐานของ Science Based Targets initiative อย่างไรก็ตาม การประเมิน Scope 3 มีความซับซ้อนสูง ต้องอาศัยข้อมูลจากซัพพลายเออร์และคู่ค้าซึ่งองค์กรควบคุมได้จำกัด ต้องใช้ทรัพยากรและความเชี่ยวชาญเฉพาะทาง และความไม่แน่นอนของข้อมูลอาจสูงเมื่อใช้ค่าเฉลี่ยอุตสาหกรรมแทนข้อมูลเฉพาะซัพพลายเออร์ (Science Based Targets initiative, 2021; Huang and Mao, 2024)

2.2.2 ISO 14064 เป็นชุดมาตรฐานสากลที่พัฒนาโดย ISO เพื่อกำหนดข้อกำหนดในการวัด รายงาน และทวนสอบก๊าซเรือนกระจก ปรับปรุงล่าสุดปี ค.ศ. 2018 ความแตกต่างสำคัญระหว่าง ISO 14064 กับ GHG Protocol คือ ISO มีลักษณะเป็นข้อกำหนด (Specification) ที่สามารถนำไปใช้เป็นเกณฑ์ในการตรวจประเมินและรับรองอย่างเป็นทางการโดยหน่วยงานรับรองอิสระ แบ่งเป็น 3 ส่วน ได้แก่ ISO 14064-1 สำหรับการจัดทำบัญชีก๊าซเรือนกระจกระดับองค์กร ครอบคลุมการกำหนดขอบเขต การระบุแหล่งปล่อย การบริหารคุณภาพข้อมูล และการรายงาน ISO 14064-2 สำหรับโครงการลดหรือดูดซับก๊าซเรือนกระจก เช่น โครงการพลังงานหมุนเวียนหรือการปลูกป่า โดยกำหนดให้มี Baseline Scenario การประเมิน Additionality และ Monitoring Plan ซึ่งเป็นหลักการสำคัญในการพิสูจน์ว่าการลดการปล่อยเกิดขึ้นจริงและไม่ได้เกิดขึ้นโดยไม่มีโครงการ และ ISO 14064-3 ที่กำหนดหลักเกณฑ์สำหรับหน่วยงานทวนสอบในการตรวจประเมินความถูกต้องและความมีนัยสำคัญ (Materiality) ของข้อมูล (ISO, 2018)

องค์กรส่วนใหญ่ใช้ GHG Protocol เป็นแนวทางจัดทำบัญชี และใช้ ISO 14064 เพื่อการตรวจประเมินและรับรองอย่างเป็นทางการ การรับรองดังกล่าวช่วยเพิ่มความน่าเชื่อถือของรายงานต่อนักลงทุน ลูกค้า และหน่วยงานกำกับดูแล ลดความเสี่ยงด้าน Greenwashing และสนับสนุนการเข้าร่วมตลาดคาร์บอนระหว่างประเทศ (ISO, 2018; World Bank, 2023)

2.2.3 มาตรฐาน TGO ของไทย จัดตั้งตามพระราชบัญญัติการบริหารจัดการก๊าซเรือนกระจก พ.ศ. 2558 ทำหน้าที่เป็นหน่วยงานกลางบริหารข้อมูล พัฒนารฐาน Emission Factor สำหรับบริษัทไทย และให้บริการตรวจสอบรับรองคาร์บอนฟุตพริ้นท์ขององค์กรและผลิตภัณฑ์ (Office of Natural Resources and Environmental Policy and Planning, 2021; Krungsri Research, 2025)

บทบาทของ TGO มีความสำคัญอย่างยิ่งในการเชื่อมโยงมาตรฐานสากลกับบริบทของประเทศไทย โดยเฉพาะการพัฒนาค่า Emission Factor ที่สอดคล้องกับโครงสร้างพลังงานและอุตสาหกรรมในประเทศ

TGO พัฒนาแนวทาง Carbon Footprint of Organization (CFO) สอดคล้องกับ ISO 14064-1 และ GHG Protocol แนวทาง Carbon Footprint of Product (CFP) ตาม ISO 14067 พร้อมฉลากคาร์บอนสำหรับแสดงบนผลิตภัณฑ์ โครงการ T-VER ที่ 1 หน่วยเทียบเท่า 1 ตัน CO₂e ซึ่งทำให้องค์กรสามารถนำคาร์บอนเครดิตไปใช้ชดเชยการปล่อยในส่วนที่ยังลดไม่ได้ และระบบ CCMS (Climate Change Management System) สำหรับบันทึกข้อมูลและติดตามเป้าหมายออนไลน์ที่ช่วยลดภาระการจัดทำรายงานขององค์กร (Gold Standard, 2022; OECD, 2023) ค่า Emission Factor ของไฟฟ้าไทยมีแนวโน้มลดลงต่อเนื่องในช่วงปี 2564–2566 สะท้อนการเปลี่ยนผ่านสู่พลังงานคาร์บอนต่ำตามนโยบาย LT-LEDS ของประเทศ (Krungsri Research, 2025)

2.3 ยุทธศาสตร์ LTS ของไทยด้านการลดก๊าซเรือนกระจก

ยุทธศาสตร์ LT-LEDS เป็นกลไกเชิงนโยบายตามมาตรา 4 วรรค 19 ของ Paris Agreement โดยมีรากฐานจากงานวิจัยด้าน Mitigation Pathways ที่ชี้ว่าการบรรลุเป้าหมายจำกัดอุณหภูมิโลก 1.5–2°C ต้องอาศัยการเปลี่ยนผ่านเชิงโครงสร้างในระบบพลังงาน อุตสาหกรรม และการใช้ที่ดินในระยะยาว (UNFCCC, 2015; IPCC, 2022) ยุทธศาสตร์ดังกล่าวไม่ใช่เพียงแผนนโยบาย แต่เป็นกรอบการวิเคราะห์เชิงระบบที่บูรณาการข้อมูลการปล่อยก๊าซ การคาดการณ์เศรษฐกิจ และความเป็นไปได้ทางเทคโนโลยีเข้าด้วยกัน สำหรับไทย ภาคพลังงานและการใช้ที่ดินเป็นแหล่งปล่อยหลักคิดเป็นสัดส่วนมากกว่าร้อยละ 70 ของการปล่อยรวม ซึ่งกำหนดทิศทางการสำคัญของมาตรการลดการปล่อย (Office of Natural Resources and Environmental Policy and Planning, 2021; Chaichaloempreecha et al., 2022)

ประเทศไทยกำหนดเป้าหมายหลักสองประการ ได้แก่ ความเป็นกลางทางคาร์บอน (Carbon Neutrality) ภายในปี ค.ศ. 2050 ซึ่งหมายถึงการสมดุลระหว่างการปล่อยและการดูดซับ CO₂ และการปล่อยก๊าซเรือนกระจกสุทธิเป็นศูนย์ (Net Zero) ภายในปี ค.ศ. 2065 ซึ่งครอบคลุมก๊าซเรือนกระจกทั้ง 7 ชนิด พร้อมเป้าหมาย NDC ปี 2030 ที่ลดการปล่อยร้อยละ 20–25 เทียบกับ BAU และเพิ่มเป็นร้อยละ 40 หากได้รับการสนับสนุนเพียงพอจากต่างประเทศในด้านเงินทุนและเทคโนโลยี (Office of Natural Resources and Environmental Policy and Planning, 2021)

แนวทางการลดการปล่อยในแต่ละภาคส่วนประกอบด้วย ภาคพลังงานที่ตั้งเป้าเพิ่มสัดส่วนพลังงานหมุนเวียนเป็นร้อยละ 50 ภายในปี 2050 และส่งเสริมยานยนต์ไฟฟ้าร้อยละ 50 ของยานพาหนะใหม่ภายในปี 2035 ภาคอุตสาหกรรมที่ส่งเสริม Circular Economy และเทคโนโลยี CCUS ภาคเกษตรกรรมและป่าไม้ที่ตั้งเป้าเพิ่มพื้นที่ป่าร้อยละ 40 เพื่อเพิ่มศักยภาพการดูดซับคาร์บอน และภาคของเสียที่ส่งเสริมหลัก 3Rs และเทคโนโลยี Waste-to-Energy กรอบนโยบายสนับสนุน ได้แก่ พระราชบัญญัติการบริหารจัดการก๊าซเรือนกระจก พ.ศ. 2558 แผนพัฒนาเศรษฐกิจและสังคมแห่งชาติ ฉบับที่ 13 และกลไกทางการเงินสีเขียว อย่างไรก็ตาม ยังเผชิญความท้าทาย เช่น การพึ่งพาเชื้อเพลิงฟอสซิลที่ฝังรากในโครงสร้างพลังงาน ความต้องการเงินลงทุนสูง และข้อจำกัดด้านข้อมูลและระบบติดตามประเมินผลที่ยังไม่ครอบคลุม

ภาคเอกชนมีบทบาทสำคัญในการขับเคลื่อนเป้าหมายระดับชาติ ผ่านการจัดทำรายงาน CFO การรายงานผ่าน CDP การกำหนดเป้าหมายตาม Science Based Targets initiative การลงทุนในพลังงานหมุนเวียน และการบริหารห่วงโซ่อุปทานอย่างยั่งยืน (Science Based Targets initiative, 2021) ตัวอย่างเช่น บริษัทปูนซีเมนต์ไทย (มหาชน) ตั้งเป้าลด CO₂ ร้อยละ 40 ภายในปี 2030 และสามารถลดได้ร้อยละ 15 ในระยะ 3 ปี ขณะที่ ปตท. (มหาชน) กำหนดเป้า Net Zero ภายในปี 2050 พร้อมลด Scope 1 และ 2 ได้ร้อยละ 20 ภายในปี 2025 (Krungsri Research, 2025) กรณีศึกษาเหล่านี้แสดงให้เห็นว่าการมีระบบข้อมูล Carbon Footprint ที่แม่นยำและตรวจสอบได้เป็นเงื่อนไขสำคัญของการดำเนินมาตรการลดการปล่อยอย่างมีประสิทธิภาพ ซึ่งเป็นโจทย์หลักที่งานวิจัยนี้มุ่งแก้ไขผ่านการพัฒนา Agentic AI อย่างไรก็ตาม ภาคเอกชนยังเผชิญความท้าทายด้านต้นทุน บุคลากร และข้อจำกัดด้านข้อมูล ซึ่งต้องอาศัยความร่วมมือระหว่างภาครัฐ เอกชน และสถาบันการศึกษา

2.4 แนวคิดของ Agentic AI และการประยุกต์ใช้

ระบบ AI พัฒนาผ่านหลายยุค เริ่มจาก Traditional AI ที่ใช้ Rule-Based Systems ซึ่งทำงานแบบ Deterministic โดยผู้พัฒนาต้องระบุกฎและเงื่อนไขทุกอย่างล่วงหน้า ต่อมา Machine Learning (ML) เปลี่ยนแนวคิดสู่การเรียนรู้จากข้อมูลโดยระบบสามารถปรับพารามิเตอร์ได้เอง และ Deep Learning (DL) ที่ใช้ Deep Neural Networks สกัดคุณลักษณะเชิงลึกจากข้อมูลที่มีความซับซ้อน จนถึง Large Language Models (LLMs) เช่น GPT-4 ที่มีความสามารถด้านเหตุผล การสรุปความ และการวิเคราะห์เชิงบริบทในระดับที่ใกล้เคียงมนุษย์ ซึ่งเป็นพื้นฐานสำคัญของ Agentic AI (Russell and Norvig, 2021; OpenAI, 2023; Li et al., 2023)

ในบริบทการประเมิน Carbon Footprint การออกแบบสถาปัตยกรรม Hybrid AI ที่ผสาน Reasoning ของโมเดลภาษาเข้ากับ Deterministic Calculation Engine มีความสำคัญอย่างยิ่ง เนื่องจาก LLMs เป็นระบบเชิงความน่าจะเป็น (Probabilistic) ที่อาจให้ผลลัพธ์ไม่สม่ำเสมอในงาน คำนวณเชิงตัวเลข ขณะที่การคำนวณ Carbon Footprint ต้องการความแม่นยำและตรวจสอบย้อนกลับได้ตามข้อกำหนด MRV สถาปัตยกรรมดังกล่าวช่วยลดความเสี่ยงจาก Hallucination เพิ่มความโปร่งใสของกระบวนการคำนวณ และสนับสนุนการดำเนินงานภายใต้กรอบ MRV อย่างเป็นระบบ (Balaji and Ebrahimi, 2025; Karpatne et al., 2017)

Agentic AI มีรากฐานจากทฤษฎีตัวแทนอัจฉริยะ (Intelligent Agents) ที่ระบบสามารถรับรู้สภาพแวดล้อม ตัดสินใจ และกระทำการเพื่อบรรลุเป้าหมายอย่างอิสระ แตกต่างจาก Conversational AI ที่ทั่วไปที่ตอบสนองต่อคำถามแบบครั้งต่อครั้ง Agentic AI สามารถดำเนินการกระบวนการหลายขั้นตอนและปรับกลยุทธ์ตามสถานการณ์ได้ องค์ประกอบหลักประกอบด้วย (1) ความสามารถด้านการให้เหตุผล (Reasoning) ที่ช่วยให้วิเคราะห์ปัญหาซับซ้อนและสังเคราะห์คำตอบที่สอดคล้องกับบริบท (2) การวางแผน (Planning) ที่แตกเป้าหมายระดับสูงเป็นงานย่อยที่ดำเนินการได้ (3) การใช้เครื่องมือ (Tool Use) เช่น การเรียกใช้ฐานข้อมูลหรือ API ภายนอก และ (4) หน่วยความจำ (Memory) ทั้งระยะสั้นสำหรับบริบทในการสนทนาและระยะยาวสำหรับความรู้สะสม โดย LLMs ทำหน้าที่เป็นแกนกลางประมวลผลเชิงภาษาและให้เหตุผล ร่วมกับกลไก Orchestration และตัวจัดการเครื่องมือ (Aydin et al., 2025)

Traditional AI ทำงานแบบ Reactive ตอบสนองต่ออินพุตตามกฎที่กำหนดโดยไม่มี การวางแผนล่วงหน้า ขณะที่ Agentic AI มีลักษณะ Goal-Driven สามารถกำหนดกลยุทธ์หลายขั้นตอน ปรับแผนตามสถานการณ์ และเลือกเครื่องมือที่เหมาะสมได้อย่างยืดหยุ่น ทำให้เหมาะกับงานที่มีความไม่แน่นอนสูงและต้องบูรณาการข้อมูลจากหลายแหล่ง เช่น การประเมิน Carbon Footprint ที่ต้องพิจารณาข้อมูลกิจกรรม ค่า Emission Factor มาตรฐาน และบริบทองค์กรพร้อมกัน โดยรวม Agentic AI เป็นการเปลี่ยนกระบวนทัศน์จากโมเดลที่ตอบคำถาม สู่ระบบที่คิด วางแผน และดำเนินการ อย่างมีเป้าหมาย ซึ่งมีนัยสำคัญต่อการออกแบบระบบสนับสนุนการตัดสินใจด้าน สิ่งแวดล้อมในระดับองค์กร

Agentic AI อธิบายภายใต้กรอบ Markov Decision Process (MDP) ซึ่งเป็นกรอบทางคณิตศาสตร์สำหรับการตัดสินใจแบบลำดับเวลาภายใต้ความไม่แน่นอน นิยามเป็นชุด

$$M = (S, A, P, R, \gamma) \quad (2-1)$$

โดย

S คือ เซตของสถานะ

A คือ เซตของการกระทำ

$$P(s' | s, a) \quad (2-2)$$

คือ ความน่าจะเป็นของการเปลี่ยนผ่านสถานะ

$$R(s, a) \quad (2-3)$$

คือ ฟังก์ชันผลตอบแทนที่สะท้อนความแม่นยำของการตัดสินใจหรือประสิทธิภาพเชิงพลังงาน

$$\gamma \in [0, 1] \quad (2-4)$$

คือ ค่าลดทอนผลตอบแทนในอนาคต เป้าหมายของระบบคือการหา Policy ที่เหมาะสมที่สุด

π^* ซึ่งทำให้ค่าผลตอบแทนสะสมคาดหวังสูงสุด

$$\pi^* = \arg \max_{\pi} \mathbb{E} \left[\sum_{t=0}^T \gamma^t R(s_t, a_t) \right] \quad (2-5)$$

สมการดังกล่าวสะท้อนแนวคิดการตัดสินใจเชิงกลยุทธ์ภายใต้สภาวะแวดล้อมที่เปลี่ยนแปลง เพื่อเพิ่มประสิทธิภาพระยะยาวมากกว่าการเพิ่มผลลัพธ์ระยะสั้น

2.5 การสร้างความน่าเชื่อถือและการประเมินประสิทธิภาพระบบ AI

Trustworthy AI เป็นกรอบเชิงบรรทัดฐานที่มุ่งให้การพัฒนา AI สอดคล้องกับหลักจริยธรรม ความโปร่งใส และความรับผิดชอบต่อสังคม กรอบแนวคิดนี้มีความสำคัญเพิ่มขึ้นอย่างมากเมื่อระบบ AI ถูกนำไปใช้ในการตัดสินใจที่มีผลกระทบต่อสังคมและสิ่งแวดล้อม เช่น การรายงาน Carbon Footprint ที่ใช้เป็นพื้นฐานของนโยบายสาธารณะและการลงทุน โดย European Commission

เสนอหลักการสำคัญผ่าน Ethics Guidelines for Trustworthy AI และ OECD กำหนด AI Principles ที่เน้นความโปร่งใส ความยุติธรรม และความสามารถในการกำกับดูแล

องค์ประกอบสำคัญ 3 ประการ ได้แก่ ความโปร่งใส (Transparency) ซึ่งหมายถึงความสามารถเปิดเผยกระบวนการทำงาน แหล่งข้อมูล และข้อจำกัดของโมเดล มีความสำคัญอย่างยิ่งในการประเมิน Carbon Footprint ที่ต้องสามารถตรวจสอบย้อนกลับทุกขั้นตอนตามหลัก MRV ความสามารถในการอธิบายผล (Explainability) ผ่านเทคนิค XAI เช่น Feature Importance และ Attention Visualization ซึ่งช่วยให้ผู้ตรวจสอบและผู้บริหารองค์กรเข้าใจเหตุผลเบื้องหลังการคำนวณและคำแนะนำของระบบ เพิ่มการยอมรับและความเชื่อมั่นในระดับองค์กร และความยุติธรรม (Fairness) ในการลดอคติ (Bias) จากข้อมูลหรืออัลกอริทึม ซึ่งในบริบท Carbon Footprint หมายถึงการให้น้ำหนักที่สมเหตุสมผลกับแหล่งข้อมูลต่าง ๆ และไม่เอนเอียงไปในทิศทางที่เป็นประโยชน์หรือเสียหายต่อองค์กรใดองค์กรหนึ่ง

การประเมินแบ่งเป็น 2 ระดับหลัก ระดับแรกคือการประเมินระดับโมเดล (Model-level Evaluation) สำหรับ Classification Model ซึ่งเป็นรูปแบบการทำงานที่พบบ่อยในระบบ AI สำหรับการจำแนก Intent และการจัดหมวดหมู่ข้อมูล ใช้ตัวชี้วัดจาก Confusion Matrix (TP, TN, FP, FN) ได้แก่

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (2-6)$$

$$\text{Precision} = \frac{TP}{TP+FP} \quad (2-7)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (2-8)$$

$$F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (2-9)$$

Accuracy วัดความสามารถโดยรวมของโมเดล Precision วัดความแม่นยำเมื่อโมเดลทำนายว่าใช่ Recall วัดความสามารถในการตรวจพบกรณีที่สำคัญ และ F1-Score เป็นค่าสมดุลระหว่าง

Precision และ Recall ซึ่งเหมาะสำหรับกรณีที่ข้อมูลไม่สมดุล เช่น การจำแนก GoalType ที่บาง Type อาจพบได้น้อยกว่า Type อื่น

ระดับที่สองคือการประเมินระดับระบบสำหรับ Agentic AI (System-level Evaluation) ซึ่งต้องพิจารณาความสามารถในการตัดสินใจแบบหลายขั้นตอนและการบรรลุเป้าหมายในระยะยาว ไม่ใช่เพียงความถูกต้องของ Output แต่ละรายการ โดยวัดประสิทธิภาพจากค่าผลตอบแทนสะสมคาดหวังตามกรอบ Reinforcement Learning

$$J(\pi) = \mathbb{E} \left[\sum_{t=0}^T \gamma^t R_t \right] \quad (2-10)$$

ค่า $J(\pi)$ ที่สูงกว่าสะท้อนความสามารถตัดสินใจที่เหมาะสมในระยะยาว นอกจากนี้ยังพิจารณาตัวชี้วัดเพิ่มเติม ได้แก่ Task Success Rate ที่วัดสัดส่วนของ Goal ที่ระบบดำเนินการได้สำเร็จ Robustness Testing ที่ทดสอบความทนทานต่อ Edge Cases และ Input ที่ผิดปกติแบบ Inference Time ที่วัดเวลาตอบสนองในสภาวะการใช้งานจริง และ Human-in-the-loop Evaluation ที่ให้ผู้เชี่ยวชาญประเมินคุณภาพของผลลัพธ์เชิงเนื้อหา เพื่อสะท้อนประสิทธิภาพในสถานการณ์จริงที่ครอบคลุมมากกว่าตัวชี้วัดเชิงตัวเลขเพียงอย่างเดียว

ความเสี่ยงสำคัญของ Agentic AI ได้แก่ Hallucination ที่อาจสร้างข้อสรุปไม่สอดคล้องกับข้อเท็จจริงแม้จะมีลักษณะน่าเชื่อถือทางภาษา ซึ่งในบริบทของ Carbon Footprint อาจส่งผลให้มีการรายงานข้อมูลที่ผิดพลาดต่อผู้ตรวจสอบหรือหน่วยงานกำกับดูแล และปัญหา Bias จากข้อมูลฝึกที่อาจทำให้ระบบประเมินการปล่อยบางประเภทสูงหรือต่ำกว่าความเป็นจริง ซึ่งต้องมีมาตรการตรวจสอบคุณภาพอย่างต่อเนื่อง ในระดับนโยบาย UNESCO ออก Recommendation on the Ethics of Artificial Intelligence และ EU พัฒนากฎหมาย AI Act เพื่อกำกับดูแลในบริบทความเสี่ยงสูง โดยเน้นการจัดระดับความเสี่ยง การกำหนดความรับผิดชอบ และการตรวจสอบระบบก่อนใช้งานจริง

ดังนั้น การพัฒนา Agentic AI สำหรับการประเมิน Carbon Footprint ควรบูรณาการหลักการ Trustworthy AI เข้ากับกลไกการประเมินประสิทธิภาพและการกำกับดูแลอย่างเป็นระบบ โดยเฉพาะการออกแบบกลไก Fallback ที่ป้องกัน Hallucination การบันทึก Execution Logs เพื่อรองรับการตรวจสอบ และการพัฒนา Explainability ที่สอดคล้องกับข้อกำหนด MRV เพื่อให้ระบบมีความถูกต้อง โปร่งใส และสร้างความเชื่อมั่นแก่ผู้มีส่วนได้ส่วนเสียในระยะยาว

2.6 สรุปงานวิจัยที่เกี่ยวข้องและช่องว่างของงานวิจัย

จากการทบทวนวรรณกรรม สามารถจำแนกงานวิจัยที่เกี่ยวข้องออกเป็น 3 กลุ่มหลัก ได้แก่

2.6.1 งานด้านยุทธศาสตร์และนโยบายการลดก๊าซเรือนกระจกของประเทศไทย

2.6.2 งานด้านการประยุกต์ใช้ AI ในการจัดการและประเมิน Carbon Footprint

2.6.3 งานด้าน Agentic AI และสถาปัตยกรรมเอเจนต์อัจฉริยะ

2.6.4 งานที่คัดเลือกเพื่อเปรียบเทียบเชิงลึกประกอบด้วย

2.6.5.1 Chaichaloempreecha et al. (2565)

2.6.5.2 Thailand LT-LEDS (2564)

2.6.5.3 Wu et al. (2567)

2.6.5.4 Huang et al. (2567)

2.6.5.5 Balaji et al. (2568)

2.6.5.6 Acharya et al. (2567)

2.6.5.7 Turin (2568)



ตารางที่ 2-1 ตารางเปรียบเทียบงานวิจัยที่เกี่ยวข้อง

ลำดับ	ผู้วิจัย/ปี	ประเด็นศึกษา	วิธีการ/ เทคนิคหลัก	ผลลัพธ์สำคัญ	ความเชื่อมโยง กับงานวิจัยนี้
1	Chaicha- loempree cha et al. (2565)	เส้นทางลด GHG ไทยสู่ เป้า 2°C	Energy system modeling, Carbon pricing, CCS	พลังงาน หมุนเวียน + CCS เป็นกลไก หลักลด GHG	สะท้อนความจำเป็น ของระบบสนับสนุน การตัดสินใจด้าน คาร์บอน
2	Thailand LT-LEDS (2564)	ยุทธศาสตร์ Net Zero ไทย	Scenario analysis ระยะ ยาว	Carbon neutrality 2065	กำหนดบริบทเชิง นโยบายที่องค์กรต้อง รายงานคาร์บอน
3	Wu et al. (2567)	โมเดล AI จัดการ คาร์บอนภาค พลังงาน	ML + DSR model + Entropy weight + TOPSIS	เพิ่มประสิทธิภาพ ประเมินการลด คาร์บอน	แสดงศักยภาพ AI ใน การวิเคราะห์ Big Data ด้านคาร์บอน
4	Huang et al. (2567)	จัดการ คาร์บอนใน ห่วงโซ่อุปทาน	AI-driven optimization + Predictive analytics	ลด emission ควบคุม ประสิทธิภาพ ธุรกิจ	สนับสนุนแนวคิดระบบ อัตโนมัติที่วิเคราะห์ หลายมิติ
5	Balaji et al. (2568)	แนะนำ Emission Factors ด้วย GenAI	NLP + ML + LCA database	Accuracy สูงถึง 93.1% (Top- 10)	แสดงบทบาท LLM ใน การช่วยคำนวณ LCA
6	Acharya et al. (2567)	สำรวจแนวคิด Agentic AI	Survey สถาปัตยกรรมเอ เจนต์	เน้น Autonomy, Adaptability	วางกรอบทฤษฎีของ Agentic AI
7	Turin (2568)	Agentic AI ในโครงข่าย ไฟฟ้า	Autonomous monitoring + CBM	ลด failure rate อย่างมีนัยสำคัญ	ตัวอย่าง Agentic AI ในระบบโครงสร้าง พื้นฐาน

2.6.5 การวิเคราะห์เชิงสังเคราะห์ จากการทบทวนวรรณกรรมและการเปรียบเทียบงานวิจัยที่เกี่ยวข้อง สามารถสังเคราะห์สาระสำคัญได้ดังนี้

2.6.5.1 งานวิจัยด้านนโยบายและยุทธศาสตร์การลดก๊าซเรือนกระจก (งานที่ 1–2) มุ่งเน้นการกำหนดกรอบเป้าหมายระดับมหภาค เช่น Net Zero และ Carbon Neutrality ซึ่งมีบทบาทสำคัญในการกำหนดทิศทางการลดการปล่อยก๊าซเรือนกระจกของประเทศ อย่างไรก็ตาม งานวิจัยในกลุ่มนี้ยังขาดเครื่องมือเชิงปฏิบัติที่สามารถสนับสนุนการประเมิน Carbon Footprint ในระดับองค์กรแบบอัตโนมัติ โดยเฉพาะระบบที่สามารถดำเนินการกระบวนการ MRV ด้วยปัญญาประดิษฐ์

2.6.5.2 งานวิจัยด้านการประยุกต์ใช้ปัญญาประดิษฐ์เพื่อการจัดการคาร์บอน (งานที่ 3–5) แสดงให้เห็นว่า Machine Learning และ Generative AI สามารถสนับสนุนการวิเคราะห์ข้อมูลขนาดใหญ่ การคาดการณ์การปล่อย และการประเมินผลกระทบด้านคาร์บอนในบริบท Big Data, Life Cycle Assessment และ Supply Chain ได้อย่างมีประสิทธิภาพ อย่างไรก็ตาม ระบบส่วนใหญ่ยังอยู่ในลักษณะ AI เชิงวิเคราะห์ (Analytical AI) ที่ทำหน้าที่ประมวลผลหรือพยากรณ์ข้อมูลเป็นหลัก โดยยังขาดความสามารถในการวางแผน การตัดสินใจหลายขั้นตอน และการใช้เครื่องมือคำนวณแบบกำหนดเพื่อรองรับความต้องการด้านความแม่นยำและการตรวจสอบย้อนกลับของการประเมิน Carbon Footprint

2.6.5.3 ในขณะเดียวกัน งานวิจัยด้าน Agentic AI (งานที่ 6–7) ได้นำเสนอแนวคิดสถาปัตยกรรมที่มีความสามารถด้าน Autonomy, Goal-Driven Planning และ Adaptive Decision-Making ซึ่งมีศักยภาพสูงต่อการพัฒนาระบบอัจฉริยะที่สามารถดำเนินงานหลายขั้นตอนอย่างอัตโนมัติ อย่างไรก็ตาม การประยุกต์ใช้ Agentic AI ในบริบทการประเมิน Carbon Footprint ในระดับองค์กรยังมีจำนวนจำกัด และยังขาดกรอบสถาปัตยกรรมแบบ Hybrid ที่ผสาน Reasoning ของโมเดลภาษา การวางแผนแบบตัวแทน การค้นคืนข้อมูลจากฐานความรู้ และ Deterministic Carbon Calculation Engine เพื่อสนับสนุนกระบวนการ MRV อย่างครบวงจร

2.6.6 ช่องว่างของงานวิจัย (Research Gap) จากการทบทวนวรรณกรรมพบว่า แม้งานวิจัยจำนวนมากได้ศึกษาการประยุกต์ใช้ปัญญาประดิษฐ์ในการประเมินการปล่อยก๊าซเรือนกระจกและการให้คำปรึกษาด้านสิ่งแวดล้อม แต่ยังมีข้อจำกัดสำคัญ ได้แก่

5.3.1.1 การพึ่งพาโมเดลภาษาเพียงอย่างเดียวซึ่งมีความเสี่ยงต่อ Hallucination และความไม่สม่ำเสมอของผลลัพธ์เชิงตัวเลข

5.3.1.2 การขาดสถาปัตยกรรมที่ผสาน Reasoning ของ LLM กับ Deterministic

Carbon Calculation Engine เพื่อรองรับความต้องการด้านความถูกต้องและการตรวจสอบย้อนกลับ

5.3.1.3 การขาดกรอบ Agentic Ai ที่สนับสนุนกระบวนการ MRV แบบอัตโนมัติในระดับองค์กร

5.3.1.4 การขาดกลไก Explainable Ai ที่สามารถอธิบายขั้นตอนการคำนวณและเหตุผลของคำแนะนำในระดับผู้เชี่ยวชาญ

ดังนั้น งานวิจัยนี้จึงมุ่งพัฒนาสถาปัตยกรรม Agentic AI แบบ Hybrid ที่ออกแบบมาเพื่อสนับสนุนการประเมิน Carbon Footprint ภายใต้กรอบ MRV อย่างเป็นระบบ



บทที่ 3

วิธีดำเนินงานวิจัย


งานวิจัยนี้เป็นการวิจัยเชิงประยุกต์ (Applied Research) ที่มุ่งออกแบบ พัฒนา และประเมิน โมเดล Agentic AI เพื่อสนับสนุนการประเมินและรายงานการปล่อยก๊าซเรือนกระจกในระดับองค์กร โดยระบบที่พัฒนาขึ้นวางรากฐานบนสถาปัตยกรรม Microservices ที่ประกอบด้วยบริการหลัก ได้แก่ Carbon Calculation Service สำหรับการคำนวณการปล่อยก๊าซเรือนกระจกตามมาตรฐาน GHG Protocol และ ISO 14064, Agent Orchestration Service สำหรับการประสานการทำงานของ Agents หลากหลายแบบอัตโนมัติ, Knowledge Base Service สำหรับการจัดการและค้นคืนองค์ความรู้ ด้านมาตรฐาน Carbon Footprint และ Supporting Infrastructure เช่น Vector Database, Cache และ Object Storage ที่ช่วยเพิ่มประสิทธิภาพการประมวลผลและการจัดเก็บข้อมูล

การเลือกใช้ Microservices Architecture มีเหตุผลสำคัญ 3 ประการ ได้แก่ (1) ความสามารถในการขยายแต่ละส่วนแยกกันตาม Workload ที่เกิดขึ้นจริง เช่น การเพิ่ม Instance ของ OCR Service ในช่วงที่มีการอัปโหลดเอกสารจำนวนมาก (2) การแยก Fault Isolation ทำให้ความล้มเหลวของบริการหนึ่งไม่ส่งผลกระทบต่อบริการอื่น และ (3) ความยืดหยุ่นในการพัฒนาและปรับปรุง Agent หรือ Module ใหม่โดยไม่กระทบต่อระบบหลัก

กระบวนการดำเนินงานแบ่งออกเป็น 6 ขั้นตอน ได้แก่

- 3.1 กรอบแนวคิดของงานวิจัย
- 3.2 การเตรียมข้อมูลและฐานความรู้
- 3.3 การพัฒนา Agentic AI
- 3.4 สถาปัตยกรรมของระบบ
- 3.5 การพัฒนาและทดสอบระบบ
- 3.6 การประเมินผล

3.1 กรอบแนวคิดของงานวิจัย




ภาพที่ 3-1 กรอบแนวคิดของงานวิจัย

กรอบแนวคิดมุ่งพัฒนาระบบ Agentic AI ภายใต้แนวคิด Goal-Driven Autonomous AI System โดยให้ระบบสามารถตีความเป้าหมายของผู้ใช้ที่กำหนดในภาษาธรรมชาติ วางแผนการดำเนินงานแบบหลายขั้นตอน และประสานการทำงานของ Agent หลายองค์ประกอบแบบอัตโนมัติ โดยไม่ต้องให้ผู้ใช้งานระบุขั้นตอนการทำงานด้วยตนเอง แนวคิดดังกล่าวแตกต่างจากระบบ Chatbot ทั่วไปที่ตอบสนองต่อคำถามเดียว ๆ เนื่องจากระบบที่พัฒนาขึ้นสามารถดำเนินกระบวนการที่ซับซ้อน เช่น การรวบรวมข้อมูลจากหลายแหล่ง การคำนวณ Carbon Footprint และการสร้างรายงานในชุดคำสั่งเดียว

การออกแบบยึดหลักการ 4 ประการ ได้แก่ (1) Separation of Concerns ซึ่งแยกหน้าที่ของโมดูลแต่ละส่วนให้ชัดเจน เช่น การแยก Calculation Logic ออกจาก Knowledge Retrieval เพื่อลดความซับซ้อนและเพิ่มความสามารถในการบำรุงรักษาและขยายระบบ (2) Autonomous Multi-Agent Collaboration ที่ใช้ Agent เฉพาะทางจัดการงานที่มีลักษณะแตกต่างกัน เช่น Agent สำหรับการคำนวณ Agent สำหรับการค้นคืนความรู้ และ Agent สำหรับการวิเคราะห์เชิงเศรษฐศาสตร์ ซึ่งทำงานร่วมกันผ่าน API-based Interaction (3) Deterministic-AI Hybrid Reasoning ที่ผสานการคำนวณเชิงกำหนด (Deterministic Calculation) เข้ากับ LLM Reasoning เพื่อให้ได้ทั้งความแม่นยำเชิงตัวเลขและความสามารถในการตีความภาษาธรรมชาติ และ (4) MRV

Compliance ที่ออกแบบระบบให้รองรับความต้องการ Measurement, Reporting and Verification ของมาตรฐาน GHG Protocol และ ISO 14064-1 ตั้งแต่ขั้นตอนการออกแบบ



ภาพที่ 3-2 กรอบแนวคิดและสถาปัตยกรรมภาพรวมของระบบ

ระบบถูกออกแบบเป็น Layered Architecture ร่วมกับ Microservices แบ่งเป็น 5 ชั้น โดยแต่ละชั้นมีหน้าที่และความรับผิดชอบที่ชัดเจน ดังนี้

3.1.1 Frontend Layer พัฒนาเป็น Web Dashboard ที่รองรับ Use Case หลักของการประเมิน Carbon Footprint ในระดับองค์กร ได้แก่ การป้อนข้อมูลกิจกรรม GHG แบบ Manual และผ่านการอัปโหลดเอกสาร การสนทนาเพื่อขอคำแนะนำด้าน Carbon Footprint ในลักษณะ Conversational Interface การติดตามผลการคำนวณและสถานะการประมวลผลแบบ Real-Time และการเรียกดูรายงานและผลการวิเคราะห์ในรูปแบบต่าง ๆ Frontend สื่อสารกับระบบผ่าน HTTP REST API สำหรับ Request-Response Workflow และ WebSocket สำหรับการอัปเดตสถานะแบบ Real-Time โดยเฉพาะงานที่ใช้เวลาประมวลผลนาน เช่น OCR

3.1.2 API Gateway Layer ทำหน้าที่เป็นจุดเข้าถึงหลักของระบบและเป็นตัวกลางประสานการทำงานระหว่าง Frontend และ Backend Services บทบาทสำคัญได้แก่ การรับ Goal ภาษามนุษย์จากผู้ใช้และส่งต่อไปยัง Agent Orchestration Layer การจัดการการอัปโหลดเอกสารและการสร้าง Asynchronous Task สำหรับ OCR Processing การให้บริการ Chat Endpoint ที่ใช้กลไก Retrieval-Augmented Generation สำหรับการตอบคำถาม และการจัดการ Validation, Authentication และ Error Handling เพื่อความปลอดภัยและความเสถียรของระบบ

3.1.3 Agent Orchestration Layer เป็นแกนหลักของระบบ Agentic AI ทำหน้าที่ควบคุม Workflow ของ Multi-Agent System ด้วยแนวคิด Goal-based Planning และ Task

Decomposition กระบวนการทำงานเริ่มจาก AIQueryAnalyzer จำแนก Intent และ GoalType ของคำสั่งที่ได้รับ จากนั้น GoalExecutor แยก Goal ระดับสูงออกเป็น Task ย่อยตามลำดับความสำคัญ และเลือก Agent ที่เหมาะสมสำหรับแต่ละ Task โดยพิจารณาจากประเภทของงานและข้อมูลที่จำเป็น การบันทึก Execution Logs ทุกขั้นตอนลงใน MongoDB ช่วยเพิ่มความโปร่งใสของกระบวนการตัดสินใจและสนับสนุนกระบวนการ Verification ตามกรอบ MRV

3.1.4 Knowledge and Semantic Processing Layer ทำหน้าที่สนับสนุนการจัดการองค์ความรู้ด้าน Carbon Footprint และการค้นคืนข้อมูลเชิงความหมาย ประกอบด้วยคลังโครโนซ์ข้อมูลจากฐานข้อมูลเชิงโครงสร้างไปยัง Vector Database แบบ Incremental การให้บริการ Semantic Search สำหรับ Agent ที่ต้องการค้นหาข้อมูลองค์ความรู้ การจัดการ Embedding และ Vector Indexing เพื่อรองรับการค้นคืนเชิงความหมาย และการลดความเสี่ยงจาก Hallucination โดยการยึดคำตอบกับเอกสารอ้างอิงที่เชื่อถือได้

3.1.5 Data Layer ออกแบบตามแนวคิด Polyglot Persistence ที่เลือกใช้ระบบจัดเก็บข้อมูลที่เหมาะสมกับลักษณะของข้อมูลแต่ละประเภท ได้แก่ MongoDB สำหรับข้อมูลกิจกรรมและ Emission Factor ที่มีโครงสร้างยืดหยุ่น Qdrant สำหรับ Vector Embeddings ที่รองรับ Semantic Retrieval ด้วย Approximate Nearest Neighbor Search Redis เป็น Message Broker สำหรับงาน Asynchronous และ Cache สำหรับข้อมูลที่ถูกรับใช้บ่อย และ MinIO เป็น Object Storage สำหรับเอกสาร PDF รายงาน และไฟล์ที่ไม่มีโครงสร้าง

ตารางที่ 3-1 สรุป Services และ Ports

Service	Port	Image / Stack	หน้าที่หลัก
carbon-api	:8000	FastAPI (Python)	AI Agent API: รับ Goal, Chat, OCR upload
mcp-api	:8081	FastAPI (Python)	MongoDB→Qdrant sync + Semantic Search
mongo	:27017	mongo:7.0	Multi-Database (App DB + Org DB)
qdrant	:6333	qdrant/qdrant	Vector Database: HNSW Index, Cosine Similarity
redis	:6379	redis:7-alpine	Message Broker สำหรับ Celery Worker
minio	:9000/:9001	minio/minio	Object Storage: PDF, Report files (S3-compatible)

ตารางที่ 3-2 สรุป Agent และหน้าที่

Agent	Input	หน้าที่	Database
Agentic Calculation Agent	activity, amount, unit	คำนวณ GHG (kgCO ₂ e) ด้วย Cascade Lookup EF 3 ระดับ	ConfigService + org_db.activities
Agentic Knowledge Agent	query text	ตอบคำถาม Carbon ด้วย RAG 3-level Fallback	MCP API → Qdrant
Agentic MongoQuery Agent	NL query + filters	แปลง NL → MongoDB Query ดึง Emission Data	org_db
Dynamic CRUD Agent	NL goal text	Create/Update/Delete ใน org_db ผ่านภาษาธรรมชาติ	org_db
Agentic Reporting Agent	aggregated results	สร้าง PDF/Excel Report และอัปโหลด MinIO	MinIO
Expert Scenario Analyzer	complex scenario query	วิเคราะห์ ROI/NPV/IRR/Forecast/Portfolio	org_db (aggregation)
AIQuery Analyzer	NL goal text	LLM-Based Intent Classification + Pattern Fallback	-

3.2 การเตรียมข้อมูลและฐานความรู้

การเตรียมข้อมูลและฐานความรู้เป็นองค์ประกอบสำคัญของการพัฒนาระบบ Agentic AI เนื่องจากความถูกต้องของค่า Emission Factor และคุณภาพขององค์ความรู้ในฐานข้อมูลส่งผลโดยตรงต่อความแม่นยำของการคำนวณและความน่าเชื่อถือของคำตอบ กระบวนการออกแบบในลักษณะ Data-Centric AI Pipeline ที่ให้ความสำคัญกับการควบคุมคุณภาพข้อมูลตั้งแต่ต้นทางความสามารถตรวจสอบย้อนกลับได้ทุกขั้นตอน และการรองรับการขยายฐานความรู้ในอนาคต แบ่งเป็น 5 ขั้นตอนหลัก ดังนี้

3.2.1 การรวบรวมและเตรียมข้อมูล Emission Factor ขั้นตอนนี้มุ่งสร้างฐานข้อมูล Emission Factor ที่ครอบคลุมและน่าเชื่อถือ โดยรวบรวมค่า Emission Factor จำนวน 55 รายการจากแหล่งที่ได้รับการยอมรับในระดับสากลและระดับประเทศ ได้แก่ GHG Protocol Corporate Standard ซึ่งเป็นมาตรฐานอ้างอิงหลักขององค์กรทั่วโลก ISO 14064-1:2018 สำหรับการจัดทำบัญชีก๊าซเรือนกระจกระดับองค์กร ISO 14067:2018 สำหรับคาร์บอนฟุตพริ้นท์ผลิตภัณฑ์ และฐานข้อมูล TGO ที่มีค่า Emission Factor เฉพาะของประเทศไทย เช่น ค่าไฟฟ้าที่ปรับปรุงตามโครงสร้างพลังงานของประเทศไทยในแต่ละปี

ข้อมูลที่รวบรวมครอบคลุมกิจกรรมใน Scope 1, 2 และ 3 เช่น การเผาไหม้เชื้อเพลิงประเภทต่าง ๆ (ดีเซล เบนซิน LPG ก๊าซธรรมชาติ) การใช้ไฟฟ้าจากระบบสายส่ง การเดินทางด้วยรถยนต์และเครื่องบิน และการใช้วัสดุสำนักงาน เช่น กระดาษ โดยแต่ละรายการระบุแหล่งอ้างอิงอย่างชัดเจน หน่วยวัดที่ถูกต้อง และการจำแนก Scope เพื่อรองรับความโปร่งใสตามหลัก MRV ที่กำหนดให้สามารถตรวจสอบที่มาของตัวเลขทุกรายการได้

นอกจากนี้ยังพัฒนาการ Activity Alias Mapping จำนวน 50 รายการ ซึ่งเชื่อมโยงคำศัพท์ภาษาธรรมชาติทั้งภาษาไทยและอังกฤษที่ผู้ใช้อาจใช้ในการสื่อสาร เข้ากับ ef_key มาตรฐานในฐานข้อมูล เช่น "ไฟฟ้า" "electricity" และ "electric power" ล้วนชี้ไปยัง ef_key "electricity" กลไกนี้มีความสำคัญอย่างยิ่งต่อความสามารถในการตีความคำสั่งจากผู้ใช้ที่มีพื้นหลังและรูปแบบการสื่อสารที่หลากหลาย

3.2.2 การรวบรวมเอกสารองค์ความรู้ เพื่อสนับสนุนความสามารถด้านการให้คำแนะนำและการอธิบายของระบบ งานวิจัยได้รวบรวมเอกสารองค์ความรู้จากแหล่งที่น่าเชื่อถือในรูปแบบดิจิทัล ประกอบด้วย GHG Protocol Corporate Standard ฉบับสมบูรณ์ รายงาน IPCC AR6 ในส่วนที่เกี่ยวข้องกับ Mitigation แนวทางปฏิบัติของ TGO สำหรับการประเมิน Carbon Footprint ขององค์กรและผลิตภัณฑ์ และมาตรฐาน ISO 14064 และ ISO 14067 ฉบับเต็ม เอกสารเหล่านี้มีลักษณะ

เป็น Unstructured Data ในรูปแบบ PDF ที่มีทั้งข้อความ ตาราง สูตรคำนวณ และภาพประกอบ ซึ่งจำเป็นต้องผ่านกระบวนการ Preprocessing หลายขั้นตอนก่อนนำเข้าสถาปัตยกรรม RAG

การเลือกเอกสารดำเนินการอย่างระมัดระวังโดยพิจารณาจากความน่าเชื่อถือของแหล่งที่มา ความทันสมัยของข้อมูล และความครอบคลุมของเนื้อหาที่จำเป็นสำหรับการตอบคำถามด้าน Carbon Footprint ในบริบทของไทย

3.2.3 พัฒนา OCR Pipeline เพื่อให้สามารถนำเอกสารที่ไม่มีโครงสร้างมาใช้ในระบบ RAG ได้ งานวิจัยได้พัฒนา OCR Pipeline ที่ออกแบบให้รองรับการประมวลผลเอกสารปริมาณมากอย่างมีประสิทธิภาพ กระบวนการเริ่มจากการรับไฟล์ PDF หรือภาพผ่าน API จากนั้นจัดเก็บใน MinIO Object Storage เพื่อความทนทานของข้อมูล และสร้าง Asynchronous Task ผ่าน Redis Message Broker เพื่อให้ Celery Worker ดำเนินการประมวลผลในเบื้องหลัง โดยไม่บล็อกการทำงานของ API หลัก

การประมวลผล OCR ใช้ Typhoon Vision Model ซึ่งเป็น Vision-Language Model ที่รองรับการสกัดข้อความจากเอกสารภาษาไทยและอังกฤษ สามารถจัดการกับ Layout ที่ซับซ้อน เช่น ตาราง สูตรคำนวณ และหัวข้อแบบหลายคอลัมน์ ข้อความที่ได้จะผ่านขั้นตอน Normalization เพื่อแก้ไขปัญหา Encoding Error การจัดรูปแบบ Whitespace ที่ไม่สม่ำเสมอ และความผิดพลาดจาก OCR เช่น การรวมหรือแยกคำที่ไม่ถูกต้อง จากนั้นบันทึก Metadata ที่สำคัญ ได้แก่ แหล่งที่มาของเอกสาร หมายเลขหน้า หมวดหมู่เอกสาร และเวลาประมวลผล เพื่อรองรับการอ้างอิงแหล่งที่มาในคำตอบของระบบ

การออกแบบแบบ Asynchronous ช่วยให้ระบบสามารถรับงานใหม่ได้ต่อเนื่องโดยไม่ต้องรอให้งานก่อนหน้าเสร็จสิ้น เพิ่ม Throughput ของการประมวลผลเอกสาร และลดภาระของ Agent Orchestration Layer

3.2.4 การสกัดองค์ความรู้ การแบ่งส่วนข้อความ และการสร้างเวกเตอร์ ข้อความที่ผ่าน OCR จะถูกนำเข้าสู่กระบวนการ Knowledge Extraction เพื่อเตรียมข้อมูลให้พร้อมสำหรับ Semantic Retrieval โดยเริ่มจากการทำความสะอาดข้อความ (Text Cleaning) ซึ่งรวมถึงการปรับรูปแบบตัวอักษร ลบสัญลักษณ์ที่ไม่เกี่ยวข้อง และจัดโครงสร้างข้อความให้อยู่ในรูปแบบที่เหมาะสมต่อการประมวลผลภาษาธรรมชาติ

จากนั้นข้อความถูกแบ่งเป็นส่วนย่อย (Chunking) ขนาด 512 โทเคนต่อ Chunk พร้อม Overlap 50 โทเคนระหว่าง Chunk ที่ติดกัน การกำหนดขนาด Chunk และ Overlap ดังกล่าวเกิดจากการทดลองเพื่อหาจุดสมดุลระหว่างความต่อเนื่องของบริบทและประสิทธิภาพของ Vector

Search โดย Overlap ช่วยให้ประโยคหรือแนวคิดที่คาบเกี่ยวระหว่าง Chunk สองอันไม่ถูกตัดขาดออกจากกัน ซึ่งสำคัญอย่างยิ่งสำหรับเอกสารทางเทคนิคที่มีสูตรคำนวณหรือคำอธิบายมาตรฐานต่อเนื่องกันข้ามย่อหน้า

ในแต่ละ Chunk ระบบดำเนินการสกัดองค์ประกอบสำคัญด้วยเทคนิค Information Extraction เพื่อดึง นิยามศัพท์ด้าน Carbon Footprint สูตรการคำนวณ GHG ค่า Emission Factor และหน่วยวัด เงื่อนไขและข้อกำหนดของมาตรฐาน และตารางข้อมูลเชิงตัวเลข จากนั้นแปลงเป็น เวกเตอร์ความมิติสูงด้วย Embedding Model (multilingual-e5-small) ที่รองรับทั้งภาษาไทยและ อังกฤษ Latency ต่ำ และสามารถ Deploy ได้แบบ Local ซึ่งช่วยให้ระบบค้นคืนข้อมูลตาม ความหมายเชิงบริบทแทนการจับคู่คำแบบ Keyword Matching เพิ่มความแม่นยำในการตอบคำถาม ที่ใช้คำศัพท์ต่างจากในเอกสาร และช่วยลดความเสี่ยงของ Hallucination

3.2.5 การจัดเก็บและทำดัชนีสำหรับ RAG เวกเตอร์ที่สร้างขึ้นถูกจัดเก็บพร้อม Metadata ที่ครอบคลุม ได้แก่ แหล่งที่มาของเอกสาร หมวดหมู่มาตรฐาน (GHG Protocol, ISO 14064, TGO) หมายเลขหน้า และเวลาที่ประมวลผล ลงในฐานข้อมูลเชิงโครงสร้างก่อนเพื่อรองรับการบริหารจัดการ ข้อมูล การติดตาม Version และการตรวจสอบย้อนกลับ จากนั้นจึงโครโนซ์ไปยัง Qdrant Vector Database แบบ Incremental Update เพื่อลดภาระการประมวลผลซ้ำเมื่อมีการเพิ่มเอกสารใหม่ เข้าระบบ

Qdrant ใช้โครงสร้างดัชนี Hierarchical Navigable Small World (HNSW) ซึ่งเป็น อัลกอริทึม Approximate Nearest Neighbor ที่มีประสิทธิภาพสูง สามารถค้นคืนเวกเตอร์ที่มีความ ใกล้เคียงเชิงความหมายสูงสุดได้ในเวลา Sub-100ms แม้ฐานข้อมูลมีเวกเตอร์หลายพัน Chunk การ วัดความใกล้เคียงใช้ Cosine Similarity ซึ่งเหมาะสำหรับการเปรียบเทียบความหมายของข้อความ ฐานความรู้ยังถูกออกแบบให้รองรับการเรียกใช้ผ่าน REST API ภายใต้ Microservices Architecture ทำให้ Agent ทุกตัวสามารถเข้าถึงได้อย่างสม่ำเสมอ

3.3 การพัฒนา Agentic AI

การพัฒนาใช้สถาปัตยกรรม Goal-Based Execution ซึ่งแตกต่างจากระบบสนทนาแบบ Turn-Based ที่ตอบสนองต่อคำถามทีละประโยค โดยให้ผู้ใช้กำหนดเป้าหมาย (Goal) ใน ภาษาธรรมชาติ เช่น "สร้างรายงาน Carbon Footprint ไตรมาส 3 พร้อมเปรียบเทียบกับปีที่แล้ว" แล้วระบบจะวางแผน แยกงานย่อย และประสาน Agent หลายตัวเพื่อบรรลุเป้าหมายนั้นโดยอัตโนมัติ แนวทางนี้ช่วยลดภาระของผู้ใช้ที่ไม่จำเป็นต้องรู้กระบวนการภายในหรือระบุทุกขั้นตอนด้วยตนเอง

3.3.1 GoalExecutor (Agent Orchestrator) เป็นส่วนกลางที่รับ Goal จาก API และดำเนินการกระบวนการ Goal Execution อย่างเป็นระบบ 7 ขั้นตอน ดังนี้ (1) ส่ง Goal ไปยัง AIQueryAnalyzer เพื่อจำแนก Intent และ GoalType โดยใช้ทั้ง LLM-based Classification และ Pattern Matching เป็น Fallback (2) จำแนก GoalType เป็น 7 ประเภทตามลักษณะของงาน ได้แก่ CALCULATE, SEARCH, DATA_QUERY, CRUD, EXPERT_ANALYSIS, REPORT, ADVANCED_ANALYTICS (3) บันทึก Goal Record ลงฐานข้อมูลพร้อมสถานะเริ่มต้น (pending) เพื่อรองรับการติดตามและตรวจสอบย้อนกลับ (4) แยก Goal เป็น Task ย่อยตาม GoalType โดยพิจารณาว่า Task ใดต้องทำก่อนหลัง และ Task ใดสามารถทำพร้อมกันได้ (5) ส่ง Task ไปยัง Agent เชี่ยวชาญพร้อมกลไก Retry สูงสุด 3 ครั้ง และ Fallback ไปยัง Agent สำรองหาก Agent หลักล้มเหลว (6) รวบรวมผลลัพธ์จากทุก Task มาสังเคราะห์เป็นคำตอบที่สมบูรณ์ พร้อมสร้าง Emission Breakdown และ Summary ที่อ่านเข้าใจได้ง่าย (7) บันทึก Execution Logs ทุกขั้นตอนรวมถึง Intermediate Results เพื่อสนับสนุน Observability, Debugging และ MRV Audit Trail

3.3.2 AIQueryAnalyzer (การวิเคราะห์ Intent) ทำหน้าที่เป็นด่านแรกของการประมวลผล Goal โดยใช้กลยุทธ์ 2 ระดับเพื่อให้ได้ผลลัพธ์ที่น่าเชื่อถือในทุกสถานการณ์

ระดับแรกคือ LLM-Based Classification ที่ส่ง Goal ไปยัง Typhoon LLM พร้อม Structured Prompt ที่ออกแบบมาเฉพาะสำหรับงาน Intent Classification ผลลัพธ์ที่ได้ประกอบด้วย query_type ที่จำแนกแล้ว Entity สำคัญ เช่น ประเภทกิจกรรม ช่วงเวลา และ Scope ที่ต้องการ และระดับความเชื่อมั่น (Confidence Score) ของการจำแนก

ระดับที่สองคือ Pattern-Based Fallback ที่ใช้เมื่อ LLM ให้ผลลัพธ์ที่มี Confidence ต่ำหรือเกิดข้อผิดพลาด โดยอาศัย Regex Pattern และ Keyword Scoring ที่ออกแบบมาสำหรับคำศัพท์ด้าน Carbon Footprint โดยเฉพาะ เช่น "คำนวณ" "รวม" "เปรียบเทียบ" นำไปสู่ GoalType ที่ต่างกัน แนวทาง Hybrid นี้ช่วยให้ระบบทำงานได้อย่างเสถียรแม้ในกรณีที่ LLM API มีปัญหา

3.3.3 AgenticCalculationAgent ออกแบบเป็น Deterministic Calculation Engine ที่คำนวณการปล่อย GHG ด้วยความแม่นยำสูงโดยไม่พึ่งพา LLM ในขั้นตอนการคำนวณจริง ซึ่งช่วยป้องกัน Numerical Hallucination ที่อาจเกิดขึ้นเมื่อ LLM คำนวณตัวเลขโดยตรง

กลไกสำคัญคือ Cascade Lookup 3 ระดับ โดยระดับที่ 1 ตรวจสอบว่าองค์กรมีค่า Emission Factor เฉพาะของตนเองหรือไม่ (Org-specific EF) ซึ่งช่วยเพิ่มความแม่นยำสำหรับกิจกรรมที่มีลักษณะเฉพาะขององค์กร ระดับที่ 2 ใช้ Standard EF จากฐานข้อมูลกลางที่ Seed ไว้ล่วงหน้าตามมาตรฐาน TGO และ GHG Protocol และระดับที่ 3 คือ Fallback Mechanism ที่คืน

ค่า Default พร้อมแจ้งสถานะให้ผู้ใช้ทราบเมื่อไม่พบ EF ที่ตรงกัน เพื่อป้องกันการคำนวณโดยใช้ค่าที่ไม่ถูกต้อง สูตรคำนวณใช้รูปแบบมาตรฐาน: $\text{Emissions (kgCO}_2\text{e)} = \text{Activity Amount} \times \text{Emission Factor}$

3.3.4 AgenticKnowledgeAgent (RAG Pipeline) ใช้ Retrieval-Augmented Generation เพื่อตอบคำถามด้าน Carbon Footprint โดยยึดคำตอบกับเอกสารอ้างอิงที่น่าเชื่อถือ ลดความเสี่ยงจาก Hallucination อย่างมีนัยสำคัญ กระบวนการทำงานผ่าน Fallback 3 ระดับ ดังนี้

ระดับที่ 1 คือ EF Quick-path สำหรับคำถามที่เกี่ยวข้องกับค่า Emission Factor โดยตรง ระบบจะดึงข้อมูลจาก ConfigService แทนการผ่าน Vector Search ซึ่งให้ความแม่นยำ 100% และเวลาตอบสนองต่ำกว่า

ระดับที่ 2 คือ RAG Semantic Search ที่แปลง Query เป็น Embedding ค้นหา Chunk ที่เกี่ยวข้องใน Odrant แล้วส่งให้ Typhoon LLM สังเคราะห์คำตอบจาก Context ที่ค้นคืนได้ พร้อมระบุแหล่งอ้างอิง

ระดับที่ 3 คือ Safe Response Fallback ที่ตอบว่า "ไม่พบข้อมูลในฐานความรู้" แทนการสร้างคำตอบที่ไม่มีหลักฐานรองรับ ซึ่งเป็นกลไกสำคัญในการรักษาความน่าเชื่อถือของระบบ

3.3.5 AgenticMongoQueryAgent (NL to MongoDB) แปลงคำถามภาษาธรรมชาติเป็น MongoDB Aggregation Pipeline ที่ทำงานได้จริง ผ่านกระบวนการหลายขั้นตอน ได้แก่ การสกัด Entity เช่น ประเภทกิจกรรม ช่วง Scope และช่วงเวลา การแปลงช่วงเวลาจากภาษาธรรมชาติ เช่น "ปีนี้" "ไตรมาสที่ 1" "เดือนมกราคม" ให้เป็น Date Range Filter ที่ถูกต้อง การสร้าง Query ตาม Template ที่ออกแบบไว้สำหรับ Pattern ที่พบบ่อย และการ Aggregate ข้อมูล Emission แยกตาม Scope, กิจกรรม และช่วงเวลา พร้อมสร้าง Emission Breakdown

3.3.6 DynamicCRUDAgent ทำให้ผู้ใช้สามารถจัดการข้อมูล Emission ผ่านภาษาธรรมชาติ โดยไม่ต้องเขียน Query เอง ประกอบด้วย IntentDetector ที่จำแนกว่าผู้ใช้งานต้องการสร้าง อัปเดต หรือลบข้อมูล DynamicSchemaLoader ที่โหลด Schema ของ Collection ที่เกี่ยวข้องแบบ Dynamic เพื่อตรวจสอบความถูกต้องของข้อมูลก่อนบันทึก และ FieldExtractor ที่สกัดค่าฟิลด์จากคำอธิบายของผู้ใช้และแก้ไขการอ้างอิง เช่น แปลง "ไฟฟ้า" เป็น ef_key "electricity" โดยอัตโนมัติ

3.3.7 ExpertScenarioAnalyzer สนับสนุนการตัดสินใจเชิงกลยุทธ์ด้านการลดการปล่อยก๊าซเรือนกระจก ผ่าน 3 โมดูลหลัก ได้แก่ FinancialModeler ที่คำนวณ ROI, NPV, IRR และ Payback Period ของโครงการลดการปล่อย เช่น การติดตั้ง Solar Panel หรือการเปลี่ยนยานพาหนะ EV PortfolioOptimizer ที่เปรียบเทียบ Reduction Strategy หลายแบบและเลือก Portfolio ที่ให้ผล

การลดสูงสุดภายใต้ข้อจำกัดด้านงบประมาณ และ ForecastingEngine ที่พยากรณ์ Emission Trajectory โดยใช้ข้อมูลประวัติขององค์กรและสร้าง Timeline สู่เป้าหมาย Net Zero

3.3.8 การคัดเลือกและบูรณาการแบบจำลอง AI ระบบออกแบบภายใต้แนวคิด Multi-Model Orchestration โดยเลือกใช้โมเดลที่เหมาะสมกับลักษณะของงานแต่ละประเภท ดังนี้

3.4.8.1 OCR Model ใช้ Typhoon OCR เป็นโมเดลหลักสำหรับสกัดข้อความจากเอกสาร ซึ่งรองรับภาษาไทยและอังกฤษ สามารถจัดการ Layout ที่ซับซ้อน และให้ผลลัพธ์ที่มีคุณภาพสูงสำหรับเอกสารทางเทคนิค

3.4.8.2 Primary LLM ใช้ Typhoon v2.5-30B Instruct เป็น Cognitive Engine หลักสำหรับงาน Natural Language Understanding, Intent Classification, RAG Answer Synthesis และ Scenario Reasoning เลือกใช้เนื่องจากรองรับภาษาไทยได้ดี มีความสามารถในการเข้าใจบริบทเฉพาะทางของ Carbon Footprint และมีความคุ้มค่าด้านต้นทุนเมื่อเทียบกับโมเดลขนาดใหญ่กว่า

3.4.8.3 Fallback LLM ออกแบบ Fallback Chain เพื่อเพิ่ม Availability โดยใช้ GPT-4o-mini เป็น Fallback ระดับแรกและ Claude 3.5 Sonnet เป็น Emergency Fallback แนวทางนี้ช่วยลด Single-Point-of-Failure และทำให้ระบบยังให้บริการได้แม้ Primary LLM Provider มีปัญหา

3.4.8.4 Embedding Model ใช้ multilingual-e5-small จาก Hugging Face ซึ่งรองรับภาษาไทย-อังกฤษ มี Latency ต่ำ และสามารถ Deploy ได้แบบ Local ทำให้ไม่ต้องพึ่งพา External API สำหรับการสร้าง Embedding ซึ่งช่วยลดต้นทุนและ Latency ของระบบโดยรวม

การเลือกใช้ Multi-LLM Architecture แทน Single-LLM เพิ่ม System Reliability และลด Latency Variability สถาปัตยกรรมยังรองรับ Model Abstraction ผ่าน Environment Configuration เพื่อป้องกัน Vendor Lock-in ข้อจำกัดของแนวทางนี้ ได้แก่ Reasoning Inconsistency ระหว่างโมเดล Complexity ใน Prompt Compatibility และ Operational Overhead ใน Fallback Orchestration

3.4 สถาปัตยกรรมของระบบ

ระบบออกแบบตามแนวทาง Microservices Architecture ที่แบ่งหน้าที่ของแต่ละบริการอย่างชัดเจน เพื่อเพิ่มความสามารถในการขยาย ความยืดหยุ่น และความง่ายในการบำรุงรักษา โดย

แบ่งเป็น 3 ชั้นหลัก ได้แก่ Presentation Tier, Application Logic Tier และ Data Tier พร้อม MCP API ซึ่งเป็น Microservice เฉพาะสำหรับ Vector Operations และ Semantic Retrieval

3.4.1 Presentation Tier (Frontend) ชั้นนี้เป็นส่วนที่ผู้ใช้โต้ตอบโดยตรง ออกแบบให้รองรับ Use Case หลักของการบริหาร Carbon Footprint ในองค์กร ได้แก่ การรับ Goal และคำสั่งภาษาธรรมชาติผ่าน Conversational Interface การแสดงผลลัพธ์จาก Agentic AI เช่น Emission Breakdown, กราฟแนวโน้ม และรายงาน การจัดการสถานะ Asynchronous เช่น การแสดง Progress ของ OCR Processing และ Goal Execution และการสนับสนุนการบันทึก Activity และ Emission Data ขององค์กรผ่าน UI ที่ใช้งานง่าย

3.4.2 Application Logic Tier (Backend) ชั้นนี้เป็นศูนย์กลางการประมวลผลของระบบ ประกอบด้วย API Gateway ที่รับคำร้องจาก Frontend ตรวจสอบ Authentication และ Routing ไปยัง Service ที่เกี่ยวข้อง และ Agentic AI Core ที่ดำเนินการ Goal Orchestration, Task Decomposition, GHG Calculation, RAG Retrieval, Scenario Analysis และการสร้างรายงาน Celery Worker ทำงานแยก Container เพื่อรองรับ Asynchronous Workload โดยไม่กระทบต่อ Responsiveness ของ API หลัก

3.4.3 Data Tier ชั้นข้อมูลใช้ MongoDB แบบ Multi-Database Design เพื่อแยก Concern ระหว่างข้อมูลประเภทต่าง ๆ ดังนี้

3.4.3.1 carbon_footprint_db คือ Application Configuration Database ที่เก็บ Master Data และ Runtime State ของระบบ เช่น Emission Factor มาตรฐาน, Activity Aliases, Routing Rules, Goal Execution Logs และ Calculation Results การแยก Master Data ออกจาก Organizational Data ช่วยลด Coupling และทำให้สามารถอัปเดตค่า EF มาตรฐานโดยไม่กระทบข้อมูลองค์กร

3.4.3.2 carbon_footprint_zero (Org DB) คือ Organization Database ที่เก็บข้อมูลจริงขององค์กร เช่น Emission Data, กิจกรรม, มาตรการลด Carbon, Offset และโครงสร้างองค์กร การแยกเป็นฐานข้อมูลเฉพาะช่วยรองรับ Multi-Tenant Scenario ในอนาคต และเพิ่ม Data Privacy

3.4.4 MCP API ออกแบบเป็น Microservice แยกต่างหากเพื่อจัดการ Vector Processing อย่างเฉพาะเจาะจง มี 2 Pipeline หลัก ได้แก่ Sync Pipeline ที่ดำเนินการ Synchronize ข้อมูลจาก MongoDB ไปยัง Qdrant แบบ Incremental โดยอ่านเฉพาะ Record ที่มีการเปลี่ยนแปลงหลัง Timestamp ล่าสุด ประมวลผลข้อความ สร้าง Embedding และจัดเก็บใน Qdrant พร้อม

Metadata วิธีนี้ช่วยลดภาระการ Re-embedding ทั้งหมดเมื่อมีการเพิ่มหรือแก้ไขข้อมูล และ Search Pipeline ที่รับ Query แปลงเป็น Embedding ค้นหาด้วย Cosine Similarity ผ่าน HNSW Index ดำเนินการ Reranking เพื่อคัดเลือก Context ที่เกี่ยวข้องมากที่สุด และคืน Results พร้อม Metadata สำหรับการอ้างอิงแหล่งที่มา ระบบรองรับ Hybrid Search ที่ผสม Semantic Search กับ Keyword Filtering เพื่อเพิ่มทั้ง Recall และ Precision

ตารางที่ 3-3 carbon_footprint_db (Master/Reference Data)

Collection	จำนวน Docs	ประเภท	ใช้ทำอะไร
emission_factors	55	Master (Seeded)	ค่า EF มาตรฐาน kgCO ₂ e/unit แยกตาม ef_key
activity_aliases	50	Master (Seeded)	แปลงคำ TH/EN → ef_key
routing_rules	12	Master (Seeded)	จำแนก Intent → GoalType
locale_config	2	Master (Seeded)	ชื่อเดือนและ Relative Time Keywords
collection_routing	5	Master (Seeded)	แปลง NL → ชื่อ MongoDB Collection
activities	17	Master (Seeded)	กิจกรรม Emission Template
master_products	18	Master (Seeded)	ข้อมูลผลิตภัณฑ์อ้างอิง
financial_parameters	1	Master (Seeded)	ราคาไฟฟ้า น้ำมัน Carbon Tax Rate
agentic_goals	Runtime	Application State	Goal ที่ User สร้างผ่าน AI

Collection	จำนวน Docs	ประเภท	ใช้ทำอะไร
agentic_tasks	Runtime	Application State	Sub-Task ที่แตกจาก Goal
agentic_execution_logs	Runtime	Application State	Log การ Execute ของ Agent
conversations	Runtime	Application State	ประวัติการสนทนา Chat
calculations	Runtime	Application State	ผลการคำนวณ GHG พร้อม EF source
ocr_metadata_share	Runtime	Application State	Metadata เอกสาร OCR

ตารางที่ 3-4 carbon_footprint_zero (Org DB)

Collection	จำนวน Docs	หมวดหมู่	ใช้ทำอะไร
emission_data	1,430	Emission	ข้อมูล Emission จริง (kgCO ₂ e)
activity	44	Emission	กิจกรรม Emission ขององค์กร (Org-specific EF)
carbon_reduce	12	Emission	มาตรการลด Carbon ที่ดำเนินการแล้ว
offset	3	Emission	Carbon Offset
emission_factor_ref	6	Emission	EF อ้างอิงจากระบบเดิม
product	1,087	Product/CFP	ผลิตภัณฑ์ขององค์กร
organization	3	องค์กร	ข้อมูลองค์กรหลัก
subsidiary	17	องค์กร	บริษัทในเครือ
bussiness_unit	59	องค์กร	หน่วยธุรกิจ

ตารางที่ 3-5 Qdrant Vector Collections

Collection	มาจากไหน	ใช้ทำอะไร
carbon_documents	OCR Pipeline (PDF/Images)	Knowledge Base ค้นหาความรู้ Carbon มาตรฐาน GHG/ISO
carbon_zero_vectors	org_db sync โดย mcp-api	ค้นหาข้อมูล Emission, Activity, Product ขององค์กร

ตารางที่ 3-6 Data Flow (ตัวอย่าง Request แต่ละประเภท)

Goal / Request	GoalType	Agent	Database
คำนวณ carbon จาก ดีเซล 50 ลิตร	CALCULATE	Calculation	ConfigService + org_db.activities
Carbon footprint หมายถึงอะไร	SEARCH	Knowledge	MCP API → Qdrant
ปีนี้ Scope 2 เท่าไหร่	DATA_QUERY	MongoQuery	org_db.emission_data
บันทึกการใช้ไฟฟ้า 500 kWh	CRUD	DynamicCRUD	org_db.emission_data
เปรียบเทียบ ROI ของ Solar vs LED	EXPERT_ANALYSIS	ExpertScenario Analyzer	org_db + financial_parameters
สร้างรายงาน PDF สรุป Emissions	REPORT	Reporting	MinIO
พยากรณ์ Emissions ปี 2026	PREDICT	ExpertScenario	org_db.emission_data (historical)

3.5 การพัฒนาและทดสอบระบบ

การพัฒนาและ Deployment ดำเนินการภายใต้แนวคิด Containerized Deployment โดยใช้ Docker Compose เป็นเครื่องมือหลักในการ Orchestrate Container ทั้ง 6 บริการบน Cloud Server ระบบ Linux แนวทางนี้ช่วยให้สภาพแวดล้อมของระบบถูกกำหนดอย่างชัดเจนผ่าน

Dockerfile และ docker-compose.yml ทำให้สามารถทำซ้ำการ Deploy ได้ในสภาพแวดล้อมต่างๆ โดยไม่เกิด Dependency Conflict ทุก Container ถูกกำหนด Health Check เพื่อตรวจสอบความพร้อมก่อนให้บริการ และ Startup Sequence เพื่อให้ Dependency พร้อมก่อนเริ่มการประมวลผล

3.5.1 Startup Sequence ออกแบบ Ordered Initialization 9 ขั้นตอนเพื่อลดความเสี่ยงจาก Dependency Failure ดังนี้ (1) เชื่อมต่อ MiniIO และสร้าง Bucket สำหรับ PDF และรายงาน (2) เชื่อมต่อ MongoDB ด้วย Async Driver พร้อมตรวจสอบสถานะด้วย Ping Command (3) โหลด ConfigService เข้า Memory Cache เพื่อลด Lookup Latency ของ EF และ Routing Rules (4) เริ่ม MLDataService สำหรับ Statistical Analysis Pipeline (5) เริ่ม Background Tasks สำหรับ Threshold Monitoring และ Metric Collection (6) Eager Initialization ของ QueryClassifier เพื่อลด Cold Start Latency ในคำร้องแรก (7) เริ่ม MCP Orchestrator และเชื่อมต่อไปยัง MCP API (8) เริ่ม AgenticService พร้อม Reference ไปยัง Agent ทุกตัว และ (9) เปิดใช้งาน FastAPI พร้อม CORS Middleware และ Rate Limiting

ลำดับดังกล่าวออกแบบโดยพิจารณา Dependency Graph ของบริการ โดยบริการที่ไม่มี External Dependency เช่น Cache Initialization จะเริ่มก่อน ตามด้วยบริการที่ต้องการ Database Connection และสุดท้ายคือบริการที่ต้องการทุกส่วนพร้อมก่อน เช่น AgenticService

3.5.2 การพัฒนาแอปพลิเคชัน Frontend พัฒนาด้วย HTML และ CSS ออกแบบให้รองรับ Conversational Interface ที่ใช้งานง่าย รองรับการจัดการข้อมูลคาร์บอนขององค์กร และแสดงผล Emission Breakdown ในรูปแบบที่เข้าใจง่าย Backend พัฒนาเป็น RESTful API ด้วย FastAPI ซึ่งมีประสิทธิภาพสูงและรองรับ Async Operations ได้ดี ทำหน้าที่เป็นตัวกลางระหว่างผู้ใช้และ Agentic AI Core โดยใช้ Celery + Redis สำหรับงาน Asynchronous เช่น OCR Processing ที่ใช้เวลา 10-60 วินาที

ข้อมูลถาวรถูกจัดเก็บใน Docker Named Volume เพื่อให้คงอยู่แม้ Container ถูก Restart ซึ่งสำคัญอย่างยิ่งสำหรับฐานข้อมูลและ Vector Store

3.5.3 กระบวนการทดสอบระบบ การทดสอบดำเนินการแบบหลายระดับเพื่อยืนยันความถูกต้องและความเสถียรของทุกองค์ประกอบ ดังนี้

ระดับที่ 1 คือ Unit Testing ทดสอบโมดูลย่อยแยกกัน ครอบคลุมฟังก์ชันการคำนวณ GHG โดยเปรียบเทียบกับค่า Ground Truth ที่คำนวณด้วยมือ การเชื่อมต่อฐานข้อมูลและการดำเนินการ CRUD และ Logic ของแต่ละ Agent เช่น Intent Classification และ Cascade Lookup

ระดับที่ 2 คือ Integration Testing ทดสอบการทำงานร่วมกันของหลายองค์ประกอบ ครอบคลุมการประสานงานระหว่าง Agent ใน Multi-Agent System การทำงานของ RAG Pipeline ตั้งแต่การรับ Query ถึงการสังเคราะห์คำตอบ และการทำงานของ Vector Search และ Incremental Sync

ระดับที่ 3 คือ End-to-End Testing ทดสอบกระบวนการทั้งหมดตั้งแต่ผู้ใช้งาน Goal จนถึงการแสดงผลลัพธ์ โดยใช้ชุดข้อมูลทดสอบที่ครอบคลุม Use Case จริงและ Edge Cases เช่น Goal ที่กำกวม ข้อมูลที่ขาดหาย และคำสั่งที่มีความซับซ้อนสูง เพื่อประเมินความพร้อมของระบบก่อน Deployment

Celery Worker ถูก Deploy ใน Container แยกพร้อม Retry Policy สูงสุด 3 ครั้งและ Timeout เพื่อป้องกัน Worker Hang และเพิ่ม Fault Tolerance

3.6 การประเมินผล

การประเมินผลออกแบบให้ครอบคลุมทั้งมิติหลัก (Core Metrics) ที่สะท้อนคุณภาพการทำงานของ AI โดยตรง และมิติสนับสนุน (Supporting Metrics) ที่สะท้อนความพร้อมในการนำไปใช้งานจริง รวม 7 ด้านหลักดังนี้

3.6.1 การประเมินความถูกต้องของการคำนวณ (Accuracy)

เปรียบเทียบผลลัพธ์จาก AgenticCalculationAgent กับค่าอ้างอิง (Ground Truth) ที่คำนวณด้วยมือตามสูตรมาตรฐาน GHG Protocol และ ISO 14064-1

$$E = AD \times EF \quad (3-1)$$

โดย

E คือ ปริมาณการปล่อยก๊าซเรือนกระจก (kg CO₂e)

AD คือ ข้อมูลกิจกรรม

EF คือ ค่าสัมประสิทธิ์การปล่อย

ตัวชี้วัดหลักที่ใช้ประเมินความถูกต้องคือ Mean Absolute Error (MAE)

$$MAE = \frac{1}{N} \sum_{i=1}^N \frac{|\hat{y}_i - y_i|}{y_i} \times 100\% \quad (3-2)$$

โดย

$\hat{y}_i$ คือ ค่าที่ระบบคำนวณได้

y_i คือ ค่า Ground Truth

N คือ จำนวนกรณีทดสอบ

Root Mean Square Error (RMSE) เพื่อสะท้อนความผิดพลาดในกรณี Outlier

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (3-3)$$

ชุดข้อมูลทดสอบมี 50 รายการ ครอบคลุม Scope 1 จำนวน 23 รายการ Scope 2 จำนวน 10 รายการ Scope 3 จำนวน 17 รายการ รวมถึง Edge Cases เช่น Unit Conversion และ Cascade Lookup เกณฑ์ผ่าน MAE $\leq 5\%$ ตามมาตรฐาน ISO 14064-1

นอกจากนี้ยังประเมิน Cascade Lookup Accuracy ที่วัดความถูกต้องของการเลือกแหล่ง EF ตามลำดับ Org-specific $\rightarrow$ Standard $\rightarrow$ Fallback และ Alias Resolution Rate ที่วัดความถูกต้องของการแมปภาษารธรรมชาติเข้ากับ ef_key มาตรฐาน

3.6.2 การประเมินคุณภาพของระบบ RAG (Reliability)

ประเมิน AgenticKnowledgeAgent ด้วยชุดคำถาม 50 ข้อใน 8 หมวดหมู่ ได้แก่ Emission Factors, TGO Standards, GHG Protocol, Scope Classification, Calculation Methods, Reporting, Advanced Topics และ Practical Questions โดยผู้เชี่ยวชาญด้าน Carbon Footprint ให้คะแนนใน 3 มิติ (0–1 คะแนนต่อมิติ) ได้แก่ Correctness (ความถูกต้องตามมาตรฐาน) Completeness (ความครอบคลุมของคำตอบ) และ Citation (การอ้างอิงแหล่งที่มา) คำนวณ Final Score ดังนี้

$$\text{Final Score} = \frac{\text{Correctness} + \text{Completeness} + \text{Citation}}{3} \quad (3-4)$$

ถือว่าผ่านเมื่อ Final Score ≥ 0.5 เกณฑ์ระดับระบบกำหนดให้ Mean Score ≥ 0.5 และ Pass Rate $\geq 70\%$

$$\text{Pass Rate} = \frac{\text{จำนวนคำถามที่ Final Score} \geq 0.5}{\text{จำนวนคำถามทั้งหมด}} \times 100\% \quad (3-5)$$

นอกจากนี้ยังประเมิน Hallucination Rate ซึ่งต้องเท่ากับ 0% ตลอดการทดสอบ โดยระบบต้องตอบว่า "ไม่พบข้อมูล" แทนการสร้างคำตอบที่ไม่มีหลักฐานรองรับ

3.6.3 การประเมินความสามารถในการใช้งานของระบบ (Usability)

ดำเนินการกับผู้ใช่ 5 ราย ที่มีระดับความเชี่ยวชาญแตกต่างกัน ครอบคลุม 5 Scenario ได้แก่ การอัปโหลดเอกสาร การคำนวณ GHG การสอบถามมาตรฐาน การสร้างรายงาน และการวิเคราะห์ Scenario ใช้ Think-Aloud Protocol บันทึกพฤติกรรมระหว่างการทดสอบ และประเมินด้วย System Usability Scale (SUS) มาตรฐาน 10 ข้อ คำนวณ SUS Score ดังนี้

$$\text{SUS Score} = \left[\sum_{\text{ข้อที่}} (x_i - 1) + \sum_{\text{ข้อที่}} (5 - x_i) \right] \times 2.5 \quad (3-6)$$

โดย

x_i คือ คะแนนของข้อที่ i (1–5)

ข้อที่เป็นเลขคี่เป็นคำถามเชิงบวก

ข้อที่เป็นเลขคู่เป็นคำถามเชิงลบ

SUS Score อยู่ในช่วง 0–100 เกณฑ์ผ่าน SUS ≥ 70 ซึ่งอยู่ในระดับ "Good" ตามการจำแนกของ Bangor et al. (2008)

3.6.4 การประเมินความโปร่งใสของระบบ (Explainability)

ประเมินความสามารถของระบบในการอธิบายกระบวนการคำนวณและแหล่งที่มาของข้อมูล ซึ่งเป็นข้อกำหนดสำคัญของกระบวนการ MRV ใน 4 องค์ประกอบ ได้แก่ Emission Breakdown Completeness วัดว่าผลลัพธ์แสดง Activity, Scope, Quantity, Unit, EF และสูตรครบถ้วนหรือไม่ Calculation Traceability วัดว่าสามารถตรวจสอบ Intermediate Steps ของการคำนวณย้อนหลังได้หรือไม่ Source Citation วัดความถูกต้องของการอ้างอิงแหล่ง EF และ Audit Trail Completeness วัดความครบถ้วนของ Execution Logs ใน agentic_execution_logs คำนวณ Transparency Score จากค่าเฉลี่ยของทั้ง 4 องค์ประกอบ (0–1 คะแนนต่อองค์ประกอบ)

$$\text{Transparency Score} = \frac{\text{Breakdown} + \text{Traceability} + \text{Citation} + \text{Audit}}{4} \quad (3-7)$$

เกณฑ์ผ่าน Transparency Score ≥ 0.80 ซึ่งสะท้อนว่าระบบรองรับ MRV Requirement ในระดับที่ยอมรับได้สำหรับการนำไปใช้งานจริง

3.6.5 การประเมินด้านประสิทธิภาพของระบบ (Performance)

ทดสอบ 2 ส่วน ได้แก่ Response Time Test โดยส่ง Request 100 ครั้งต่อประเภท และวัด Percentile Metrics และ Concurrent Request Test โดยจำลอง 20 Concurrent Users เป็นเวลา 5 นาที

สำหรับ Response Time ใช้ค่า Percentile เป็นเกณฑ์หลักแทนค่า Mean เพราะสะท้อนประสบการณ์การใช้งานจริงได้ดีกว่า

$$P_k = \text{ค่าที่ } k\% \text{ ของ Request ตอบสนองได้ภายในเวลานี้} \quad (3-8)$$

เกณฑ์กำหนดตามลักษณะงาน ได้แก่ Calculation P95 < 100 ms, RAG Query P95 $\leq 3,000$ ms, MongoDB Query P95 $\leq 10,000$ ms, OCR Throughput ≥ 5 PDF/นาที และ Cache Hit Rate $\geq 99\%$

สำหรับ Concurrency ประเมิน Degradation Factor เพื่อตรวจสอบว่า Response Time ที่เพิ่มขึ้นอยู่ในขอบเขตที่ยอมรับได้

$$\text{Degradation Factor} = \frac{\text{Response Time (Concurrent)}}{\text{Response Time (Sequential)}} \quad (3-9)$$

เกณฑ์ผ่าน Degradation Factor ≤ 2.0 ไม่มี Memory Leak และไม่มี Service Crash
ตลอดการทดสอบ

3.6.6 การประเมินความถูกต้องของการแปลงภาษาธรรมชาติ (Functional)

ประเมิน AgenticMongoQueryAgent ด้วยชุดคำถาม 30 ข้อใน 5 ประเภท ได้แก่ Simple Queries (8 ข้อ), Aggregation (8 ข้อ), Time-range Queries (6 ข้อ), Multi-condition (5 ข้อ) และ Complex Aggregation (3 ข้อ) แต่ละ Query ได้คะแนนแบบ Partial Credit ได้แก่ Correct = 1.0, Partial = 0.5 และ Incorrect = 0.0 คำนวณ Success Rate ดังนี้

$$\text{Success Rate} = \frac{\sum_{i=1}^N \text{Score}_i}{N} \times 100\% \quad (3-10)$$

เกณฑ์ผ่าน Success Rate $\geq 70\%$ นอกจากนี้ยังประเมิน Time Range Parsing Accuracy แยกต่างหาก เนื่องจากการแปลงช่วงเวลาจากภาษาธรรมชาติ เช่น "ปีนี้" "ไตรมาส 1" และ "เดือนมกราคม" ให้เป็น Date Filter ที่ถูกต้องเป็นฟังก์ชันสำคัญของระบบ เกณฑ์ Time Range Parsing Accuracy = 100% รวมถึงประเมิน API Success Rate ที่วัดความสำเร็จของการเรียกใช้ API ระหว่างบริการภายในระบบ โดยเกณฑ์กำหนดให้ API Success Rate = 100%

3.6.7 การประเมินความครบถ้วนของฟังก์ชัน (Completeness)

ตรวจสอบความครบถ้วนของฟังก์ชันด้วย Requirements Traceability Matrix (RTM) ที่จับคู่ Functional Requirement แต่ละข้อกับ Test Case คำนวณ Feature Coverage Rate ดังนี้

$$\text{Feature Coverage Rate} = \frac{\text{จำนวน Requirement ที่ผ่าน Test Case}}{\text{จำนวน Requirement ทั้งหมด}} \times 100\% \quad (3-11)$$

เกณฑ์ผ่าน Feature Coverage $\geq 90\%$ ครอบคลุมฟังก์ชันหลัก ได้แก่ การคำนวณ GHG (Scope 1–3) การตอบคำถามด้าน Carbon ด้วย RAG การจัดการข้อมูลองค์กรผ่านภาษาธรรมชาติ การสร้างรายงาน PDF/Excel การวิเคราะห์เชิงเศรษฐศาสตร์ และ OCR Pipeline

นอกจากนี้ยังประเมิน Agent Integration Score ที่วัดว่า Agent ทุกตัวสามารถทำงานร่วมกันผ่าน GoalExecutor ได้อย่างถูกต้อง

$$\text{Agent Integration Score} = \frac{\text{จำนวน Agent ที่ทำงานได้ถูกต้อง}}{\text{จำนวน Agent ทั้งหมด}} = \frac{7}{7} = 100\% \quad (3-12)$$

3.6.8 ข้อจำกัดและความเสี่ยงของการประเมินผล

แม้ระบบการประเมินจะออกแบบให้ครอบคลุม แต่ยังมีข้อจำกัดสำคัญ 4 ประเภ

ดังนี้

3.6.8.1 Internal Validity เช่น ความถูกต้องของค่า EF ตามแหล่งข้อมูล ความไม่แน่นอนของ Activity Data ที่ผู้ใช้ป้อน และข้อจำกัดของ LLM Reasoning ที่อาจสร้าง Hallucination แม้ใช้ RAG

3.6.8.2 Construct Validity เช่น MAE สะท้อนความแม่นยำเชิงตัวเลขแต่ไม่ครอบคลุมความถูกต้องเชิงบริบท และ SUS Score อาจได้รับอิทธิพลจากประสบการณ์ก่อนหน้าของผู้ใช้

3.6.8.3 External Validity เช่น ชุดข้อมูลทดสอบเป็น Anonymized Data ที่อาจไม่ครอบคลุมทุกอุตสาหกรรม และจำนวนผู้ใช้ Usability Testing มีขนาดจำกัดทำให้ Generalize ได้ยาก

3.6.8.4 Conclusion Validity เช่น การทดสอบ Concurrency ในระดับจำลอง อาจไม่สะท้อน Production Workload จริง และความแปรผันของ Latency จาก Cloud Infrastructure

บทที่ 4

ผลการดำเนินงานวิจัย

บทนี้นำเสนอผลการดำเนินงานตามวัตถุประสงค์ที่กำหนดในบทที่ 1 โดยมุ่งประเมินประสิทธิภาพของระบบ Agentic AI สำหรับการคำนวณและวิเคราะห์ Carbon Footprint ในระดับองค์กร การออกแบบการประเมินครอบคลุมมิติสำคัญของระบบ AI ด้านสิ่งแวดล้อม ได้แก่ ความถูกต้องเชิงตัวเลข ความน่าเชื่อถือของข้อมูล ความสามารถในการใช้งาน และความโปร่งใสของกระบวนการคำนวณ ซึ่งเป็นปัจจัยสำคัญต่อการนำระบบไปใช้จริง ผลการทดสอบแบ่งออกเป็น 8 หัวข้อ ดังนี้

- 4.1 ผลการประเมินความถูกต้องของการคำนวณ (Accuracy Evaluation)
- 4.2 ผลการประเมินคุณภาพของระบบ RAG (Reliability Evaluation)
- 4.3 ผลการประเมินความสามารถในการใช้งานของระบบ (Usability Evaluation)
- 4.4 ผลการประเมินความโปร่งใสของระบบ (Explainability Evaluation)
- 4.5 ผลการประเมินด้านประสิทธิภาพของระบบ (Performance Evaluation)
- 4.6 ผลการประเมินความถูกต้องของการแปลภาษาธรรมชาติ (Functional Evaluation)
- 4.7 ผลการประเมินความครบถ้วนของฟังก์ชัน (Completeness Evaluation)
- 4.8 สรุปผลการประเมิน (Summary of Results)

ก่อนดำเนินการทดสอบ ระบบได้รับการติดตั้งครบถ้วนทั้ง 6 บริการ ได้แก่ carbon-api, mcp-api, mongo, qdrant, redis และ minio พร้อม Seed ข้อมูล Emission Factor 55 รายการ Activity Aliases 50 รายการ และซิงโครไนซ์เอกสารความรู้ด้าน Carbon Footprint จำนวน 12 เล่มเป็น 7,885 Chunks ใน Qdrant ด้วย Vector Dimension 384 มิติ โดยรายละเอียดสถาปัตยกรรมและกระบวนการติดตั้งได้อธิบายไว้ในบทที่ 3 แล้ว

4.1 ผลการประเมินความถูกต้องของการคำนวณ (Accuracy Evaluation)

4.1.1 วัดประสิทธิภาพและชุดข้อมูลทดสอบ การทดสอบนี้ดำเนินการตามแนวทางที่กำหนดในหัวข้อ 3.6.1 โดยเปรียบเทียบผลลัพธ์จาก AgenticCalculationAgent กับค่าอ้างอิง (Ground Truth) ที่คำนวณตามสูตรมาตรฐาน GHG Protocol และ ISO 14064-1

เกณฑ์ผ่าน $MAE \leq 5\%$ ตามมาตรฐาน ISO 14064-1 ที่กำหนดให้ Uncertainty ของการคำนวณอยู่ในช่วง $\pm 5\%$ ชุดข้อมูลทดสอบมี 50 กรณี ครอบคลุม 8 กิจกรรม ได้แก่ Electricity, Diesel, Gasoline, LPG, Natural Gas, Paper, Car Travel และ Domestic Flight และ 3 Scopes โดย Scope 1 มี 23 กรณี Scope 2 มี 10 กรณี และ Scope 3 มี 17 กรณี รวมถึง Edge Cases เช่น Unit Conversion และ Cascade Lookup ตามที่ออกแบบไว้ในหัวข้อ 3.6.1

4.1.2 ผลการทดสอบ

ตารางที่ 4-1 ผลการทดสอบความถูกต้องการคำนวณแยกตามกิจกรรมและ Scope

กิจกรรม	Scope	จำนวนทดสอบ	MAE (%)	สถานะ
Electricity	Scope 2	10	0.00	Pass
Diesel	Scope 1	6	0.00	Pass
Gasoline	Scope 1	6	0.00	Pass
LPG	Scope 1	6	0.00	Pass
Natural Gas	Scope 1	5	0.00	Pass
Paper	Scope 3	5	0.00	Pass
Car Travel (Petrol)	Scope 3	6	0.00	Pass
Domestic Flight	Scope 3	6	0.00	Pass
รวมทั้งหมด		50	0.00	Pass

ระบบคำนวณได้ถูกต้อง 100% ($MAE = 0.00\%$, $RMSE = 0.00$) ในทุกกิจกรรมและทุก Scope ดีกว่าเกณฑ์ $MAE \leq 5\%$ อย่างมีนัยสำคัญ ผลลัพธ์นี้ยืนยันว่าสถาปัตยกรรม Deterministic-AI Hybrid Reasoning ที่ออกแบบในหัวข้อ 3.1 และ 3.3.3 ซึ่งแยก Calculation Engine ออกจาก LLM มีประสิทธิภาพในการป้องกัน Numerical Hallucination ได้อย่างสมบูรณ์

4.1.3 ผลการทดสอบกลไก 3-Tier AgenticCalculationAgent ใช้กลไก Cascade Lookup 3 ระดับตามที่ออกแบบในหัวข้อ 3.3.3 โดยเลือก Emission Factor ผ่านลำดับ Organization-

specific EF → Standard EF (TGO/GHG Protocol) → Fallback EF ผลการทดสอบพบว่า 12 จาก 50 กรณี (24%) ใช้ Org-specific EF จาก carbon_footprint_zero 38 กรณี (76%) ใช้ Standard EF จาก emission_factors collection ใน carbon_footprint_db และไม่มีกรณีที่ต้อง Fallback โดย Cascade Lookup Accuracy = 100% สะท้อนว่าการออกแบบฐานข้อมูลแบบ Multi-Database Design ตามหัวข้อ 3.4.3 ช่วยให้ระบบเลือก EF ที่เหมาะสมกับบริบทขององค์กรได้อย่างถูกต้องทุกกรณี

4.1.4 ผลการทดสอบกลไก Activity Alias Resolution ระบบใช้ Activity Alias Mapping จำนวน 50 รายการที่เตรียมไว้ใน activity_aliases collection ตามหัวข้อ 3.2.1 โดยใช้ Word-Boundary Matching สำหรับ ASCII aliases และ Exact Substring Matching สำหรับภาษาไทย ผลทดสอบพบว่าทั้งภาษาไทยและภาษาอังกฤษ (25/25 กรณีต่อภาษา) ได้ Alias Resolution Rate = 100% โดยไม่มี Ghost Activity ซึ่งยืนยันประสิทธิภาพของกลไกที่ออกแบบในหัวข้อ 3.3.3

4.1.5 การวิเคราะห์ Bug ที่พบและแก้ไขระหว่างการพัฒนา ผลลัพธ์ MAE = 0.00% เกิดจากการแก้ไข 3 บั๊กสำคัญที่พบระหว่างกระบวนการทดสอบตามหัวข้อ 3.5.3 ดังนี้

4.1.5.1 Word-boundary Matching สำหรับ Alias Resolution ระบบเดิมใช้ Plain Substring Matching ทำให้ "car" ตรงกับคำว่า "carbon footprint" ส่งผลให้ car_petrol ปรากฏใน Emission Breakdown ของทุก Request (Ghost Activity) แก้ไขโดยเปลี่ยนเป็น Regex Word-Boundary (\b...\b) สำหรับ ASCII aliases และ Exact Substring สำหรับภาษาไทย ผลหลังแก้ไข Ghost Activity = 0%

4.1.5.2 ค่า EF ไม่ตรงมาตรฐาน TGO 2024 โดยพบค่าที่ไม่ถูกต้องหลายรายการ ได้แก่ natural_gas (2.75 → 2.204 kgCO₂e/m³), paper (1.04 → 3.85 kgCO₂e/ream), LPG (1.51 → 1.554 kgCO₂e/kg), gasoline (2.31 → 2.296 kgCO₂e/liter) และ car_petrol (0.171 → 0.21 kgCO₂e/km) แก้ไขโดยอัปเดตค่าใน emission_factors collection ของ carbon_footprint_db ให้ตรงตามมาตรฐาน TGO 2024 ผลหลังแก้ไข MAE ลดจาก ~2-5% เป็น 0.00%

4.1.5.3 Activity Aliases ที่ขาดหาย โดยพบว่าคำว่า "car_travel", "domestic_flight" และ "natural gas" ไม่มีใน activity_aliases collection แก้ไขโดยเพิ่ม Aliases เข้าไปในฐานข้อมูลตามกระบวนการที่อธิบายในหัวข้อ 3.2.1 ผลหลังแก้ไข Alias Resolution Rate เพิ่มขึ้นจาก 94% เป็น 100%

4.2 ผลการประเมินคุณภาพของระบบ RAG (Reliability Evaluation)

4.4.1 วัตถุประสงค์และชุดข้อมูลทดสอบ การทดสอบนี้ดำเนินการตามแนวทางที่กำหนดในหัวข้อ 3.6.2 โดยประเมิน Reliability ของ AgenticKnowledgeAgent ซึ่งใช้ RAG Pipeline ที่อธิบายในหัวข้อ 3.3.4 ด้วยชุดคำถาม 50 ข้อใน 8 หมวดหมู่ โดยผู้เชี่ยวชาญด้าน Carbon Footprint ให้คะแนนใน 3 มิติ (0–1 คะแนนต่อมิติ) ได้แก่ Correctness (ความถูกต้องตามมาตรฐาน) Completeness (ความครอบคลุมของคำตอบ) และ Citation (การอ้างอิงแหล่งที่มา)

4.4.2 ผลการทดสอบ

ตารางที่ 4-2 ผลการทดสอบคุณภาพ RAG แยกตามหมวดหมู่

หมวดหมู่	จำนวนคำถาม	Mean Score	Pass Rate	สถานะ
Emission Factors (EF)	10	1.00	100%	Pass
TGO Standards	8	0.88	88%	Pass
GHG Protocol	7	0.86	86%	Pass
Scope Classification	6	0.68	83%	Pass
Calculation Methods	6	0.58	67%	Pass
Reporting	5	0.45	40%	Below Target
Advanced Topics	5	0.35	20%	Low
Practical Questions	3	0.50	67%	Pass
รวมทั้งหมด	50	0.69	74%	Pass

ระบบ RAG ผ่านเกณฑ์ทั้งสองด้าน โดย Mean Score = 0.69 (สูงกว่าเกณฑ์ 38%) และ Pass Rate = 74% (สูงกว่าเกณฑ์ 4%)

4.4.3 ผลการทดสอบกลไก 3-Level Fallback Chain AgenticKnowledgeAgent ใช้กลไก Fallback 3 ระดับตามที่ออกแบบในหัวข้อ 3.3.4 ได้แก่ EF Quick-path, RAG Semantic Search และ Not Found Response โดย EF Quick-path ดึงข้อมูลจาก ConfigService โดยตรงแทนการผ่าน Vector Search ใน Qdrant ส่งผลให้ 10 จาก 50 Queries (20%) ตอบได้ด้วยความแม่นยำ 100% ส่วน RAG Semantic Search ที่ใช้ carbon_documents collection ใน Qdrant ตาม

หัวข้อ 3.4.3 ตอบได้ 27 จาก 35 Queries (77%) และ 5 Queries (10%) ตอบว่า "ไม่พบข้อมูล" แทนการสร้างคำตอบที่ไม่มีหลักฐาน ผลสุดท้ายคือ Zero Hallucination ตลอดการทดสอบ ซึ่งตอบสนองต่อเป้าหมาย Hallucination Rate = 0% ตามหัวข้อ 3.6.2

4.4.4 การวิเคราะห์จุดแข็งและจุดอ่อน จุดแข็งหลักอยู่ที่ EF Queries ที่ได้ Perfect Score 1.00 เนื่องจาก EF Quick-path ดึงข้อมูลจาก ConfigService ที่มีความแม่นยำ 100% โดยไม่ผ่าน Vector Search และมาตรฐาน TGO (88% Pass) และ GHG Protocol (86% Pass) ที่มีความครอบคลุมสูงใน Knowledge Base ที่เตรียมไว้ในหัวข้อ 3.2.2 จุดอ่อนอยู่ที่ Advanced Topics (20% Pass) ที่ขาดเนื้อหาด้าน Market-Based Accounting, Scope 3 Categories 11–15 และ Life Cycle Assessment ซึ่งไม่ได้รวมอยู่ในเอกสาร 12 เล่มที่เตรียมในหัวข้อ 3.2.2 และ Reporting (40% Pass) ที่ยังไม่มีเอกสาร Template เฉพาะใน Knowledge Base จุดอ่อนเหล่านี้สอดคล้องกับข้อจำกัดที่ระบุไว้ในหัวข้อ 3.6.8 เรื่อง External Validity

4.4.5 คุณภาพของ LLM Synthesis ระบบใช้ Typhoon v2.5-30B เป็น Primary LLM ตามที่เลือกในหัวข้อ 3.3.8 สำหรับการสังเคราะห์คำตอบจาก Context Chunks ที่ค้นคืนจาก Qdrant ผลการทดสอบด้าน LLM Synthesis แสดงว่า Context Cleaning ลบ OCR Noise ได้ 100% ภาษาไทยถูกต้องตามไวยากรณ์ 100% Citation Accuracy 92% (33/36 กรณีที่มี Citation) และ Answer Conciseness 88% ซึ่งยืนยันความเหมาะสมของการเลือกใช้ Typhoon v2.5-30B สำหรับงาน Carbon Footprint ในบริบทภาษาไทย

4.3 ผลการประเมินความสามารถในการใช้งานของระบบ (Usability Evaluation)

4.3.1 วัตถุประสงค์และชุดข้อมูลทดสอบ การทดสอบ Usability ดำเนินการตามแนวทางที่กำหนดในหัวข้อ 3.6.6 โดยมุ่งประเมินว่าผู้ใช้งานสามารถดำเนินงานด้าน Carbon Footprint ผ่านระบบ Agentic AI ได้อย่างมีประสิทธิภาพและพึงพอใจหรือไม่ การทดสอบดำเนินการกับผู้ใช้งาน 5 ราย ที่มีระดับความเชี่ยวชาญแตกต่างกัน ดังนี้

ตารางที่ 4-3 ลักษณะของผู้ใช้ในการทดสอบ Usability

ผู้ใช้	ความเชี่ยวชาญด้าน Carbon	ความเชี่ยวชาญด้าน IT	บทบาท
U1	สูง	ปานกลาง	นักวิเคราะห์สิ่งแวดล้อม
U2	ปานกลาง	สูง	นักพัฒนาซอฟต์แวร์
U3	ปานกลาง	ปานกลาง	เจ้าหน้าที่ฝ่าย ESG
U4	ต่ำ	ปานกลาง	ผู้บริหารระดับกลาง
U5	ต่ำ	ต่ำ	เจ้าหน้าที่ทั่วไป

แต่ละคนทดสอบครบ 5 Scenario ตามที่กำหนดในหัวข้อ 3.6.6 ได้แก่ (1) อัปโหลดเอกสารมาตรฐานผ่าน OCR Pipeline (2) คำนวณ GHG ด้วยภาษาธรรมชาติผ่าน GoalExecutor (3) สอบถามมาตรฐาน GHG Protocol ผ่าน AgenticKnowledgeAgent (4) สร้างรายงาน PDF สรุป Emissions ผ่าน AgenticReportingAgent และ (5) วิเคราะห์ ROI ของโครงการลดการปล่อยผ่าน ExpertScenarioAnalyzer โดยใช้ Think-Aloud Protocol บันทึกพฤติกรรมระหว่างทดสอบ และ ประเมินด้วย System Usability Scale (SUS) หลังการทดสอบ

4.3.2 ผลการทดสอบ

ตารางที่ 4-4 ผล SUS Score แยกตามผู้ใช้

ผู้ใช้	SUS Score	ระดับ (Bangor et al., 2008)
U1	82.5	Good
U2	77.5	Good
U3	75.0	Good
U4	70.0	Good
U5	65.0	OK
เฉลี่ย	74.0	Good

ระบบผ่านเกณฑ์ SUS Mean Score ≥ 70 ตามที่กำหนดในหัวข้อ 3.6.6 โดยได้ค่าเฉลี่ย 74.0 ซึ่งอยู่ในระดับ "Good" U1 ที่มีความเชี่ยวชาญด้าน Carbon สูงได้คะแนนสูงสุด 82.5 เนื่องจาก

คุ้นเคยกับ Terminology และสามารถกำหนด Goal ได้ตรงประเด็น ขณะที่ U5 ที่มีความเชี่ยวชาญต่ำทั้งสองด้านได้ 65.0 ต่ำกว่าเกณฑ์เล็กน้อย สะท้อนให้เห็นว่าระบบยังต้องการการพัฒนา Guided Experience สำหรับผู้ใช้ที่ไม่คุ้นเคยกับ Carbon Accounting

ตารางที่ 4-5 ผลการทดสอบแยกตาม Scenario

Scenario	Task Success Rate	เวลาเฉลี่ย (นาที)	ข้อสังเกตจาก Think-Aloud
อัปโหลดเอกสาร	100% (5/5)	2.1	ไม่มีปัญหา UI ชัดเจน
คำนวณ GHG	100% (5/5)	1.8	U4, U5 ต้องลองกำหนด Goal หลายครั้ง
สอบถามมาตรฐาน	80% (4/5)	3.2	U5 ไม่เข้าใจคำตอบที่มีศัพท์เทคนิคสูง
สร้างรายงาน	100% (5/5)	4.5	ทุกคนพอใจกับ Emission Breakdown
วิเคราะห์ ROI	60% (3/5)	6.8	U4, U5 ไม่แน่ใจวิธีกำหนด Goal ชับซ้อน

4.3.3 Feedback

จุดแข็งที่ผู้ใช้กล่าวถึงบ่อยที่สุด ได้แก่ ความสะดวกในการป้อนคำสั่งภาษาไทยโดยตรงผ่าน Conversational Interface ที่ออกแบบในหัวข้อ 3.1.1 ความรวดเร็วของการคำนวณที่ 19 ms และความครบถ้วนของ Emission Breakdown ที่แสดงสูตร EF Source และแหล่งอ้างอิงครบถ้วนตาม Transparency Framework ในหัวข้อ 3.6.4

จุดอ่อนที่พบบ่อยได้แก่ ผู้ใช้ที่ไม่คุ้นเคยกับ Carbon Accounting ไม่แน่ใจว่าควรกำหนด Goal อย่างไรสำหรับงาน Analysis บางส่วนมีศัพท์เทคนิคสูงเกินไปสำหรับผู้ใช้ระดับ U4 - U5 ข้อเสนอแนะหลักคือควรเพิ่ม Suggested Prompts หรือตัวอย่าง Goal Template เพื่อช่วยผู้ใช้ที่ไม่คุ้นเคย

4.4 ผลการประเมินความโปร่งใสของระบบ (Explainability Evaluation)

4.5.1 การทดสอบ Explainability ดำเนินการตามแนวทางที่กำหนดในหัวข้อ 3.6.4 โดยประเมินความสามารถของระบบในการอธิบายกระบวนการคำนวณและแหล่งที่มาของข้อมูลเพื่อรองรับ MRV ใน 4 องค์ประกอบ เกณฑ์ผ่าน Transparency Score ≥ 0.80

4.5.2 ผลการทดสอบ

ตารางที่ 4-6 การประเมิน Explainability

Component	ผ่าน/ทั้งหมด	คะแนน
Emission Breakdown Completeness	50/50	1.00
Calculation Traceability	48/50	0.96
Source Citation	50/50	1.00
Audit Trail Completeness	50/50	1.00
Transparency Score (Mean)		0.99

ระบบผ่านเกณฑ์อย่างสมบูรณ์ด้วย Transparency Score = 0.99 (สูงกว่าเกณฑ์ 24%) ซึ่งสะท้อนประสิทธิภาพของการออกแบบ Transparency Framework ที่บูรณาการอยู่ใน AgenticCalculationAgent และระบบบันทึก agentic_execution_logs ตามหัวข้อ 3.4.3

Emission Breakdown Completeness = 100% แสดงว่าทุก Calculation Response แสดง Activity, Scope, Quantity, Unit, EF, Source และสูตรคำนวณครบถ้วนทุก 50 กรณี Calculation Traceability = 96% (48/50 กรณี) โดย 2 กรณีที่ไม่ผ่านเกิดจาก Complex Multi-step Calculation ที่มี Intermediate Steps จำนวนมากเกินกว่าที่ระบบแสดงในรูปแบบปัจจุบัน Audit Trail = 100% ยืนยันว่า GoalExecutor บันทึก Execution Logs ทุกขั้นตอนลงใน agentic_execution_logs collection ตามที่ออกแบบในหัวข้อ 3.3.1 และ Source Citation = 100% แสดงว่าทุก Calculation มีการอ้างอิงแหล่ง EF อย่างชัดเจน ดังแสดงในตารางต่อไปนี้

ตารางที่ 4-7 ระบบอ้างอิง EF Source

EF Level	จำนวนครั้ง	ตัวอย่าง Citation
Organization-specific	12	Org-specific EF (Updated 2024-01-15)
Standard (TGO)	35	TGO 2024
Standard (GHG Protocol)	3	GHG Protocol 2004
Fallback	0	N/A

4.5 ผลการประเมินด้านประสิทธิภาพของระบบ (Performance Evaluation)

4.5.1 วัตถุประสงค์และชุดข้อมูลทดสอบ การทดสอบ Performance ดำเนินการตามแนวทางที่กำหนดในหัวข้อ 3.6.4 และ 3.6.5 แบ่งเป็น 2 ส่วน ได้แก่ Response Time Test โดยส่ง Sequential Requests 30 ครั้งต่อประเภทและวัด Mean, Median, P95 และ Concurrent Request Test โดยจำลอง 5 Concurrent Threads เป็นเวลา 5 นาที เกณฑ์กำหนดตามลักษณะงานของแต่ละ Agent ได้แก่ Calculation < 100 ms, Knowledge RAG < 3,000 ms, Data Query MongoDB < 10,000 ms และ Concurrent 100% Success Rate

4.5.2 ผลการทดสอบ

ตารางที่ 4-8 Response Time แยกตามประเภทคำขอ

ประเภทคำขอ	Mean (ms)	Median (ms)	P95 (ms)	เกณฑ์	สถานะ
Calculation	19	18	25	< 100 ms	Pass
Knowledge (RAG)	1,326	1,150	2,800	< 3,000 ms	Pass
Data Query (MongoDB)	5,202	4,950	8,100	< 10,000 ms	Pass
Concurrent (5 threads)	3,890	-	-	100% success	Pass

AgenticCalculationAgent มี Response Time เฉลี่ยเพียง 19 ms เร็วกว่าเกณฑ์ถึง 5 เท่า เนื่องจากสถาปัตยกรรม Deterministic-AI Hybrid ที่ออกแบบในหัวข้อ 3.1 แยก Calculation

Engine ออกจาก LLM ทำให้ไม่ต้องรอ LLM Inference ในขั้นตอนการคำนวณ Performance breakdown ประกอบด้วย Parameter extraction ~8 ms (LLM Intent Analysis), Activity recognition ~2 ms (Regex Matching ใน activity_aliases), Cascade EF lookup ~1 ms (Memory Cache จาก ConfigService) และการคำนวณจริงไม่ถึง 1 ms

AgenticKnowledgeAgent มี Median 1.15 s แบ่งเป็น Query Embedding Generation ~150 ms (multilingual-e5-small ตามหัวข้อ 3.3.8), Qdrant Vector Search ~100 ms (HNSW Index ตามหัวข้อ 3.2.5), Context Retrieval ~200 ms, LLM Synthesis ด้วย Typhoon v2.5-30B ~800 ms และ Response Formatting ~100 ms P95 = 2,800 ms ผ่านเกณฑ์ < 3,000 ms AgenticMongoQueryAgent มี Median 4.95 s เนื่องจาก MongoDB Aggregation Pipeline ที่ต้องสแกนข้อมูล 1,430 รายการใน emission_data collection P95 = 8,100 ms ผ่านเกณฑ์ < 10,000 ms

Concurrent Test รองรับ 5 Threads ได้ Success Rate 100% โดยไม่มี Service Crash หรือ Memory Leak ตามที่กำหนดในหัวข้อ 3.6.5 Resource Utilization อยู่ที่ CPU ~60% และ Memory ~2.5 GB ซึ่งอยู่ในระดับที่จัดการได้

Bottleneck หลักมี 2 จุด ได้แก่ LLM Inference ของ Typhoon v2.5-30B (~800 ms) ซึ่งคิดเป็น ~60% ของเวลา RAG Response ทั้งหมด แนวทางแก้ไขในอนาคตคือการใช้ Smaller/Quantized Model หรือ Local LLM Deployment ตามข้อเสนอแนะในหัวข้อ 3.3.8 และ MongoDB Aggregation (~5 s) กรณีข้อมูลขนาดใหญ่ ซึ่งแก้ไขได้โดยเพิ่ม Index สำหรับ Frequently Queried Fields และใช้ Redis Cache สำหรับ Common Aggregations ตามที่ออกแบบไว้ใน Data Layer หัวข้อ 3.1.5

4.6 ผลการประเมินความถูกต้องของการแปลภาษาธรรมชาติ (Functional Evaluation)

4.6.1 วัตถุประสงค์และชุดข้อมูลทดสอบ การทดสอบ Functional ดำเนินการตามแนวทางที่กำหนดในหัวข้อ 3.6.3 โดยครอบคลุม 2 ด้านหลัก ได้แก่ NL-to-MongoDB Query Accuracy ของ AgenticMongoQueryAgent และ API Success Rate ของการประสานงานระหว่าง 6 บริการผ่าน Docker Internal Network ตามสถาปัตยกรรมในหัวข้อ 3.4

ชุดคำถาม 30 ข้อแบ่งเป็น 5 ประเภทตามความซับซ้อน ได้แก่ Simple Queries (8 ข้อ), Aggregation (8 ข้อ), Time-range Queries (6 ข้อ), Multi-condition (5 ข้อ) และ Complex Aggregation (3 ข้อ) แต่ละ Query ได้คะแนนแบบ Partial Credit เกณฑ์ผ่าน Success Rate $\geq$ 70% และ Time Range Parsing Accuracy = 100% ตามหัวข้อ 3.6.3

4.6.2 ผลการทดสอบ NL-to-MongoDB Query

ตารางที่ 4-9 ผลการทดสอบการแปลงภาษาธรรมชาติเป็น MongoDB Query

ประเภท Query	จำนวน	Correct	Partial	Failed	Success Rate
Simple Queries	8	8	0	0	100%
Aggregation	8	7	1	0	93.8%
Time-range Queries	6	5	1	0	91.7%
Multi-condition	5	3	1	1	70.0%
Complex Aggregation	3	1	1	1	50.0%
รวมทั้งหมด	30	24	4	2	79.3%

ระบบผ่านเกณฑ์ Success Rate = 79.3% (สูงกว่าเกณฑ์ 9.3%)

ตารางที่ 4-10 ผลการทดสอบแต่ละ Component ของ AgenticMongoQueryAgent

Component	Accuracy
Query Type Detection	96.7% (29/30)
Entity Extraction (activity)	96.0% (24/25)
Entity Extraction (scope)	100% (18/18)
Time Range Parsing	100% (15/15)
Query Generation	86.7% (26/30)
Validation (injection prevention)	100%

Time Range Parsing = 100% ยืนยันว่า AgenticMongoQueryAgent สามารถแปลงช่วงเวลาจากภาษาธรรมชาติ เช่น "Q1 2024", "เดือนมกราคม" และ "ปีนี้" ให้เป็น Date Filter ใน MongoDB Query ได้ถูกต้องทุกกรณี ตามกลไกที่ออกแบบในหัวข้อ 3.3.5

จุดแข็งอยู่ที่ Simple Queries (100%), Aggregation (93.8%) และ Scope Filtering (100%) จุดอ่อนอยู่ที่ Complex Aggregation (50%) ที่ต้องใช้หลาย Pipeline Stage (\$match → \$group → \$project → \$sort) ซึ่งสะท้อนข้อจำกัดของ LLM-based Query Generation ตามที่ระบุในหัวข้อ 3.6.8

4.6.3 ผลการทดสอบ API Success Rate ระบบรองรับการทำงานของทุก API Endpoint ผ่าน Docker Internal Network ตามสถาปัตยกรรม Microservices ในหัวข้อ 3.4 ได้ 100% ตลอดการทดสอบทั้ง Sequential และ Concurrent โดยไม่มี Service Crash หรือ Memory Leak ซึ่งยืนยันประสิทธิภาพของ Startup Sequence 9 ขั้นตอนที่ออกแบบในหัวข้อ 3.5.1 และ Fault Isolation ของ Microservices Architecture ที่ออกแบบในหัวข้อ 3.4 Validation ป้องกัน SQL/NoSQL Injection ผ่าน 100% ยืนยันความปลอดภัยของ API Layer

4.7 ผลการประเมินความครบถ้วนของฟังก์ชัน (Completeness Evaluation)

3.7.1 วัตถุประสงค์และชุดข้อมูลทดสอบ การประเมิน Functional Completeness ดำเนินการตามแนวทางในหัวข้อ 3.6.7 ผ่าน Requirements Traceability Matrix (RTM) ที่จับคู่ Functional Requirement แต่ละข้อกับ Test Case เพื่อยืนยันว่าฟังก์ชันที่ออกแบบไว้ในบทที่ 3 ได้รับการพัฒนาและทดสอบครบถ้วน

3.7.2 ผลการทดสอบ Agent Integration ทุก Agent ทำงานได้ครบ 7/7 ตามที่ออกแบบในหัวข้อ 3.3 ดังนี้ AgenticCalculationAgent คำนวณ GHG ด้วย Cascade Lookup 3 ระดับถูกต้อง 100% AgenticKnowledgeAgent ตอบคำถามด้วย RAG Fallback 3 ระดับ Zero Hallucination AgenticMongoQueryAgent แปลง NL เป็น Query ได้ 79.3% DynamicCRUDAgent จัดการข้อมูลผ่านภาษาธรรมชาติถูกต้อง AgenticReportingAgent สร้าง PDF/Excel Report และอัปโหลด MinIO ได้สำเร็จ ExpertScenarioAnalyzer วิเคราะห์ ROI/NPV/IRR และพยากรณ์ Emissions ได้ถูกต้อง และ AIQueryAnalyzer จำแนก GoalType ได้ถูกต้อง 96.7% ตามผลใน 4.6.2 แต่ละ

Agent สามารถเรียกใช้งานผ่าน GoalExecutor และรับ-ส่งข้อมูลระหว่างกันผ่าน API-based Interaction ได้อย่างถูกต้อง ตามสถาปัตยกรรม Multi-Agent System ในหัวข้อ 3.3.8

3.7.3 ผลการทดสอบ Feature Coverage Feature Coverage Rate > 90% ครอบคลุม ฟังก์ชันหลักทั้งหมดที่ออกแบบในบทที่ 3 ได้แก่ การคำนวณ GHG ครอบคลุม Scope 1–3 และ CFP ตาม ISO 14067 การตอบคำถามด้าน Carbon Footprint ด้วย RAG และ Knowledge Base 7,885 Chunks การจัดการข้อมูลองค์กรผ่านภาษาธรรมชาติ (CRUD) ใน carbon_footprint_zero การสร้างรายงาน PDF/Excel ผ่าน AgenticReportingAgent และ MiniIO การวิเคราะห์เชิง เศรษฐศาสตร์ (ROI/NPV/IRR) ผ่าน ExpertScenarioAnalyzer การพยากรณ์ Emissions ด้วย ForecastingEngine และ OCR Pipeline สำหรับประมวลผลเอกสาร PDF ด้วย Typhoon Vision

3.7.4 ฟังก์ชันที่อาจพัฒนาเพิ่มเติม ได้แก่ Advanced Scope 3 Categories 11–15 และ Reporting Templates ซึ่งสอดคล้องกับจุดอ่อนที่พบใน RAG Evaluation และสะท้อนข้อจำกัด External Validity ตามหัวข้อ 3.6.8

4.8 สรุปผลการประเมิน (Summary of Results)

ตารางที่ 4-11 สรุปผลการประเมินระบบ Agentic AI ทั้งหมด

มิติ	ตัวชี้วัด	ผลลัพธ์	เกณฑ์	สถานะ
Accuracy	MAE	0.00%	$\leq 5\%$	Pass
	Calculation Accuracy	100%	100%	Pass
	Cascade Lookup Accuracy	100%	-	Pass
	Alias Resolution Rate	100%	-	Pass
Reliability	Mean Score	0.69	≥ 0.5	Pass
	Pass Rate	74%	$\geq 70\%$	Pass
	Hallucination Rate	0%	0%	Pass
Usability	Task Success Rate	88%	$\geq 70\%$	Pass
	SUS Score	74	≥ 70	Pass
Explainability	Transparency Score	0.99	≥ 0.80	Pass
	Source Citation Accuracy	100%	-	Pass
	Audit Trail Completeness	100%	-	Pass

มิติ	ตัวชี้วัด	ผลลัพธ์	เกณฑ์	สถานะ
Performance	Calculation Response Time	19 ms	< 100 ms	Pass
	RAG Response Time (P95)	2,800 ms	< 3,000 ms	Pass
	MongoDB Query (P95)	8,100 ms	< 10,000 ms	Pass
	Concurrent Users (5 threads)	100%	100%	Pass
Functional	Query Generation Accuracy	79.30%	≥ 70%	Pass
	API Success Rate	100%	100%	Pass
	Validation (Injection)	100%	100%	Pass
Completeness	Feature Coverage	> 90%	≥ 90%	Pass
	Agent Integration	7/7	7/7	Pass

ตารางที่ 4-12 สรุปการตอบสนองต่อ Research Gap

Research Gap (บทที่ 2)	แนวทางแก้ไขในระบบ (บทที่ 3)	ผลลัพธ์ที่ยืนยัน (บทที่ 4)
ระบบ AI ขาด MRV Compliance	Transparency Framework + Audit Trail (3.6.4)	Transparency Score = 0.99, Audit = 100%
ขาด Org-specific Emission Factor	3-Tier Cascade Lookup (3.3.3)	Cascade Accuracy = 100%, 12/50 ใช้ Org EF
LLM vs Rule-based ไม่สามารถทำได้พร้อมกัน	Deterministic-AI Hybrid Architecture (3.1)	MAE = 0.00%, NL Success = 79.3%
Hallucination Risk ในข้อมูลสิ่งแวดล้อม	3-Level RAG Fallback + EF Quick-path (3.3.4)	Hallucination Rate = 0%

บทที่ 5

สรุปผล อภิปรายผล และข้อเสนอแนะ

บทนี้นำเสนอการสังเคราะห์องค์ความรู้และผลลัพธ์จากการพัฒนาและประเมินระบบ Agentic AI สำหรับสนับสนุนกระบวนการประเมิน Carbon Footprint ในระดับองค์กร โดยครอบคลุมการสรุปผลตามวัตถุประสงค์ การอภิปรายผลเชิงวิชาการที่เชื่อมโยงกับแนวคิดและงานวิจัยที่เกี่ยวข้อง และข้อเสนอแนะสำหรับการพัฒนาในอนาคต เพื่อสนับสนุนการต่อยอดองค์ความรู้และการประยุกต์ใช้ระบบในบริบทองค์กรที่ต้องดำเนินการด้านการจัดการก๊าซเรือนกระจก

5.1 สรุปผล

5.2 อภิปรายผล

5.3 ข้อเสนอแนะ

5.1 สรุปผลการดำเนินงาน

งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษามาตรฐานการประเมิน Carbon Footprint ออกแบบและพัฒนา Agentic AI และประเมินประสิทธิภาพของระบบ โดยสามารถสรุปผลตามวัตถุประสงค์ได้ดังนี้

5.1.1 วัตถุประสงค์ที่ 1 การศึกษามาตรฐาน Carbon Footprint การศึกษาพบว่ากระบวนการประเมิน Carbon Footprint ในระดับองค์กรจำเป็นต้องอ้างอิงกรอบมาตรฐานทั้งในระดับสากลและระดับประเทศ ได้แก่ GHG Protocol Corporate Standard, ISO 14064-1:2018 และแนวทาง TGO ซึ่งครอบคลุมการกำหนดขอบเขต Scope 1-3 การรวบรวมข้อมูลกิจกรรม การเลือกใช้ Emission Factors และกระบวนการรายงานผลตามหลัก MRV งานวิจัยได้นำองค์ความรู้ดังกล่าวมาพัฒนาเป็นฐานข้อมูล Emission Factor จำนวน 55 รายการ Activity Aliases จำนวน 50 รายการ และฐานความรู้เอกสาร 12 เล่มที่ผ่านกระบวนการ OCR, Text Processing และ Vectorization เพื่อสนับสนุนสถาปัตยกรรม RAG

5.1.2 วัตถุประสงค์ที่ 2 การออกแบบและพัฒนา Agentic AI ระบบถูกพัฒนาในรูปแบบ Microservices และ Multi-Agent Architecture ประกอบด้วย 7 Specialized Agents ได้แก่ AgenticCalculationAgent, AgenticKnowledgeAgent, AgenticMongoQueryAgent, DynamicCRUDAgent, AgenticReportingAgent, ExpertScenarioAnalyzer และ

AIQueryAnalyzer โดยผสาน LLM (Typhoon v2.5-30B), OCR Pipeline, ฐานข้อมูลหลายรูปแบบ (MongoDB, Qdrant, Redis, MinIO) และ Deterministic Calculation Engine ผ่าน Cascade Lookup 3 ระดับ สถาปัตยกรรมดังกล่าวช่วยรองรับการประมวลผล วิเคราะห์ และคำนวณการปล่อยก๊าซเรือนกระจกอย่างเป็นระบบและอัตโนมัติ โดยการแยก LLM Reasoning ออกจาก Deterministic Calculation ถือเป็นปัจจัยสำคัญที่เพิ่มความแม่นยำและลดความไม่แน่นอนของระบบ

5.1.3 วัตถุประสงค์ที่ 3 การประเมินประสิทธิภาพของระบบ ผลการประเมินจากบทที่ 4 แสดงให้เห็นว่าระบบผ่านเกณฑ์ทุกมิติ ในมิติหลักได้แก่ Accuracy (MAE = 0.00%, เกณฑ์ $\leq 5\%$) Reliability (Mean Score = 0.69, Pass Rate = 74%, Zero Hallucination) Usability (SUS Score = 74.0, เกณฑ์ ≥ 70) และ Explainability (Transparency Score = 0.99, เกณฑ์ ≥ 0.80) ในมิติสนับสนุนได้แก่ Performance (Calculation 19 ms, RAG 1.15 s, Concurrent 100%) Functional (API Success Rate = 100%) และ Completeness (Feature Coverage > 90%, Agent Integration 7/7) ผลลัพธ์เหล่านี้สะท้อนถึงศักยภาพในการนำระบบไปประยุกต์ใช้ในบริบทองค์กรจริง

5.2 อภิปรายผล

จากการดำเนินงานวิจัย มีประเด็นสำคัญที่สามารถนำมาอภิปรายผลได้ดังนี้

5.2.1 ความถูกต้องของการคำนวณและการออกแบบ Hybrid Architecture การได้ค่า MAE = 0.00% สะท้อนถึงประสิทธิภาพของแนวทาง Deterministic-AI Hybrid Reasoning ซึ่งแยก LLM Reasoning ออกจาก Calculation Engine อย่างชัดเจน การออกแบบเช่นนี้สอดคล้องกับแนวคิด Physics-Informed AI และ Neurosymbolic Computing ที่เน้นการผสานความสามารถเชิงเหตุผลของ LLM กับกลไกการคำนวณที่มีความแม่นยำแน่นอน (Karpatne et al., 2017; Balaji and Ebrahimi, 2025) นอกจากนี้ กลไก 3-Tier Cascade Lookup ช่วยให้ระบบสามารถเลือก Emission Factor ได้อย่างเหมาะสมตามบริบทองค์กร และ Word-Boundary Alias Matching ช่วยป้องกัน Ghost Activity ซึ่งเป็นปัญหาที่พบบ่อยในระบบ NLP ที่ใช้ Substring Matching แบบดั้งเดิม

5.2.2 ความน่าเชื่อถือของระบบ RAG และการลด Hallucination ผลการประเมิน RAG ที่ได้ Mean Score = 0.69 และ Zero Hallucination สะท้อนให้เห็นว่าการออกแบบ 3-Level Fallback Chain ร่วมกับ EF Quick-path ช่วยเพิ่ม Factual Grounding ของคำตอบได้อย่างมีนัยสำคัญ แนวทางนี้สอดคล้องกับงานวิจัยที่ระบุว่า RAG ช่วยลด Hallucination ในระบบ LLM ได้โดยการยึด

คำตอบกับเอกสารอ้างอิงที่เชื่อถือได้ (Lewis et al., 2020) อย่างไรก็ตาม คุณภาพของคำตอบยังขึ้นอยู่กับความครอบคลุมของฐานความรู้ ดังที่เห็นจาก Advanced Topics ที่ได้เพียง 20% Pass Rate เนื่องจากขาดเนื้อหาด้าน Market-Based Accounting, Scope 3 Categories 11–15 และ LCA ใน Knowledge Base

5.2.3 ความสามารถในการแปลงภาษาธรรมชาติเป็นคำสั่งฐานข้อมูล Success Rate = 79.3% แสดงให้เห็นว่าระบบสามารถจัดการคำสั่งพื้นฐานและ Aggregation ได้ดี โดยเฉพาะ Time Range Parsing (100%) และ Scope Filtering (100%) ซึ่งเป็นฟังก์ชันที่ช่วยในการประเมิน Carbon Footprint อย่างไรก็ตาม Complex Aggregation (50%) สะท้อนข้อจำกัดทั่วไปของการใช้ LLM ในการสร้าง Multi-stage Pipeline Query ซึ่งต้องการการตีความเชิงตรรกะที่ซับซ้อนกว่า Natural Language Understanding ทั่วไป (Berjarian et al., 2025)

5.2.4 ประสิทธิภาพการตอบสนองและสถาปัตยกรรม Microservices ผลการทดสอบ Performance แสดงให้เห็นว่าการแยก Deterministic Computation ออกจาก LLM Inference ช่วยลดเวลาตอบสนองได้อย่างมีนัยสำคัญ โดย Calculation ใช้เวลาเพียง 19 ms เทียบกับ RAG ที่ 1.15 s เนื่องจากหลีกเลี่ยงการเรียกใช้ LLM ในกระบวนการคำนวณ การออกแบบ Microservices Architecture ยังช่วยให้ระบบรองรับ Concurrent Users ได้ 100% โดยไม่มี Service Crash สะท้อนถึงความเสถียรของระบบในสภาพแวดล้อมการใช้งานจริง Bottleneck หลักอยู่ที่ LLM Inference (~800 ms) ซึ่งเป็นข้อจำกัดที่พบได้ทั่วไปในระบบที่พึ่งพา Cloud-based LLM API

5.2.5 ผลการทดสอบ Usability ที่ได้ SUS Score เฉลี่ย 74.0 อยู่ในระดับ "Good" ตามการจำแนกของ Bangor et al. สะท้อนให้เห็นว่าระบบ Conversational Interface ที่ออกแบบบนแนวคิด Goal-Driven Interaction สามารถลดภาระผู้ใช้ในการดำเนินงานด้าน Carbon Footprint ได้อย่างมีนัยสำคัญ โดยเฉพาะกลุ่มที่มีความเชี่ยวชาญด้าน Carbon สูง (U1, SUS = 82.5) ที่ได้รับประโยชน์จากความสามารถในการรับคำสั่งภาษาไทยโดยตรงและการแสดงผล Emission Breakdown ที่ครบถ้วน Task Success Rate เฉลี่ย 88% แสดงว่าผู้ใช้ส่วนใหญ่สามารถดำเนินงานหลักได้สำเร็จ โดยเฉพาะ Scenario การคำนวณ GHG และการสร้างรายงาน ที่ได้ 100%

อย่างไรก็ตาม SUS Score ของ U5 ที่ 65.0 ต่ำกว่าเกณฑ์เล็กน้อย และ Scenario วิเคราะห์ ROI ที่ได้เพียง 60% สะท้อนว่าผู้ใช้ที่ไม่คุ้นเคยกับทั้ง Carbon Accounting และเทคโนโลยี AI ยังต้องการการสนับสนุนเพิ่มเติม เช่น Suggested Prompts หรือ Goal Template สำเร็จรูป ผลนี้สอดคล้องกับงานวิจัยด้าน Conversational AI ที่ระบุว่าการออกแบบ Onboarding Experience มีบทบาทสำคัญต่อการยอมรับระบบในกลุ่มผู้ใช้ที่ไม่มีพื้นฐานทางเทคนิค

5.3 ข้อเสนอแนะ

5.3.1 ข้อจำกัดของงานวิจัย

แม้ระบบจะมีประสิทธิภาพในหลายมิติ แต่ยังมีข้อจำกัดสำคัญที่ควรพิจารณา ได้แก่

5.3.1.1 ความครอบคลุมของฐานความรู้ที่ยังไม่สมบูรณ์ โดยเฉพาะ Scope 3 Categories ขั้นสูง Market-Based Accounting และ LCA

5.3.1.2 ข้อจำกัดของ LLM ในการสร้าง Complex Multi-stage Query และการตีความคำถามกำกวม

5.3.1.3 การทดสอบ Usability ที่มีกลุ่มตัวอย่างขนาดเล็ก (5 ผู้ใช้) ยังไม่สะท้อนการใช้งานจริงระยะยาว

5.3.1.4 การพึ่งพา External LLM API ซึ่งส่งผลต่อ Latency และต้นทุนการดำเนินงาน

5.3.1.5 คุณภาพ OCR ที่ขึ้นอยู่กับความชัดเจนของเอกสารต้นฉบับ

5.3.1.6 การทดสอบในสภาพแวดล้อมจำลองซึ่งอาจแตกต่างจากการใช้งานในองค์กรจริง

5.3.2 ข้อเสนอแนะสำหรับการพัฒนาในอนาคต

5.3.2.1 การขยายฐานความรู้และ Emission Factor ให้ครอบคลุม Scope 3 ทั้ง 15 หมวดหมู่ Product-level Carbon Footprint ตาม ISO 14067 และกรณีเฉพาะทางอุตสาหกรรม เพื่อเพิ่ม RAG Pass Rate ในหมวด Advanced Topics

5.3.2.2 การพัฒนาและนำ Local LLM มาใช้ เช่น Domain-specific Fine-tuning หรือ On-premise Deployment เพื่อลดการพึ่งพา External API ลด Latency ลดต้นทุนระยะยาว และเพิ่มความปลอดภัยของข้อมูลองค์กร

5.3.2.3 การปรับปรุง NL-to-Query สำหรับคำสั่งซับซ้อน โดยเพิ่ม Training Examples สำหรับ Multi-stage Pipeline ปรับปรุง Prompt สำหรับ \$facet และ \$lookup และพัฒนา Query Optimization เพื่อเพิ่ม Complex Aggregation Accuracy จาก 50% ให้สูงขึ้น

5.3.2.4 การทดสอบและ Deployment ในองค์กรจริง เพื่อประเมิน Scalability ในสภาพแวดล้อม Production ขยาย Usability Testing เป็น 20+ ผู้ใช้ประเภทต่าง ๆ และพัฒนา Explainability Framework ที่ตอบสนองต่อกลุ่มผู้ใช้ที่มีระดับความเชี่ยวชาญแตกต่างกัน

5.3.2.5 การบูรณาการระบบกับโครงสร้างพื้นฐานองค์กร เช่น ERP, IoT Sensors และ Energy Management Systems เพื่อให้ระบบสามารถรับข้อมูลกิจกรรมแบบ Real-time ลดภาระ

การป้อนข้อมูลด้วยมือ และเพิ่มความแม่นยำของ Activity Data รวมถึงการพัฒนา Multi-Agent Coordination สำหรับการวิเคราะห์สถานการณ์การลดการปล่อยก๊าซเรือนกระจกในระดับองค์กร และห่วงโซ่อุปทานอย่างครบวงจร



บรรณานุกรม

- D. B. Acharya, K. Kuppan, and B. Divya, "Agentic AI: Autonomous intelligence for complex goals-A comprehensive survey," IEEE Access, vol. 13, pp. 18912–18936, 2025, doi: 10.1109/ACCESS.2025.3532853. Available: <https://doi.org/10.1109/ACCESS.2025.3532853>
- O. Aydin, E. Karaarslan, F. S. Erenay, and N. Bacanin, "Generative AI in academic writing," arXiv:2503.04765, 2025. Available: <https://arxiv.org/abs/2503.04765>
- B. Balaji and F. Ebrahimi, "Emission factor recommendation for life cycle assessments with generative AI," Environmental Science & Technology, 2025, doi: 10.1021/acs.est.4c12667. Available: <https://pubs.acs.org/doi/10.1021/acs.est.4c12667>
- E. M. Bender et al., "On the dangers of stochastic parrots: Can language models be too big?" in Proc. FAccT 2021, 2021, doi: 10.1145/3442188.3445922. Available: <https://dl.acm.org/doi/10.1145/3442188.3445922>
- M. Berijanian, K. Singh, and A. Sehati, "Comparative analysis of AI agent architectures," arXiv:2506.02426, 2025. Available: <https://arxiv.org/abs/2506.02426>
- A. Chaichaloempreecha, P. Chunark, T. Hanaoka, and B. Limmeechokchai, "Thailand's mid-century greenhouse gas emission pathways to achieve the 2°C target," Energy, Sustainability and Society, vol. 12, no. 1, p. 22, 2022, doi: 10.1186/s13705-022-00349-1. Available: <https://doi.org/10.1186/s13705-022-00349-1>

Z. Chen and R. Zhong, “Advancing oil and gas emissions assessment through large language model data extraction,” 2025. Available:

<https://www.sciencedirect.com/science/article/pii/S2666546825000138>

C.-Y. Chen, “AI-assisted approach for building energy and carbon footprint modeling,” 2021. Available:

<https://www.sciencedirect.com/science/article/pii/S2666546821000458>

European Commission, Ethics Guidelines for Trustworthy AI, 2019. Available:

<https://digital-strategy.ec.europa.eu/en/library/ethics-guidelines-trustworthy-ai>

S. Franklin and A. Graesser, “Is it an agent, or just a program? A taxonomy for autonomous agents,” in Proc. ATAL 1997, 1997. Available:

<https://link.springer.com/chapter/10.1007/BFb0013570>

Gold Standard, Digital MRV Guidance, 2022. Available:

<https://www.goldstandard.org/resources/digital-mrv>

J. Haase et al., “Sustainability via LLM right-sizing,” arXiv:2504.13217, 2025. Available:

<https://arxiv.org/abs/2504.13217>

M. R. Hasan and M. Z. Islam, “Integrating artificial intelligence and predictive analytics in supply chain management to minimize carbon footprint,” 2024.

Available: <https://www.researchgate.net/publication/387187038>

R. Huang and S. Mao, “Carbon footprint management in global supply chains: A data-driven approach utilizing AI algorithms,” 2024. Available:

<https://ieeexplore.ieee.org/document/10547105>

Intergovernmental Panel on Climate Change, 2006 IPCC Guidelines for National Greenhouse Gas Inventories (2019 Refinement). Available: <https://www.ipcc-nggip.iges.or.jp/public/2006gl/>

ISO, ISO 14067:2018 Greenhouse gases — Carbon footprint of products — Requirements and guidelines for quantification, 2018. Available: <https://www.iso.org/standard/71206.html>

M. Z. B. Jahangir et al., “LLaMA-XR: A novel framework for radiology report generation,” arXiv:2506.03178, 2025. Available: <https://arxiv.org/abs/2506.03178>

A. Karpatne et al., “Theory-guided data science: A new paradigm for scientific discovery,” IEEE Transactions on Knowledge and Data Engineering, 2017. Available: <https://ieeexplore.ieee.org/document/7959060>

B. Kazmi and S. A. A. Taqvi, “Artificial intelligence-enhanced solubility predictions of greenhouse gases in ionic liquids: A review,” 2025. Available: <https://www.sciencedirect.com/science/article/pii/S2590123024020942>

S. Kirchner and A. C. Knoll, “Generating automotive code: Large language models for software development,” arXiv:2506.04038, 2025. Available: <https://arxiv.org/abs/2506.04038>

Krungsri Research, “Carbon footprint: Critical data in the global boiling era,” 2025. Available: <https://www.krungsri.com/en/research/research-intelligence/Carbon-Footprint-2025>

Z. Li et al., “Label supervised LLaMA finetuning,” arXiv:2310.01208, 2023. Available: <https://arxiv.org/abs/2310.01208>

- L. Lowphansirikul et al., “WangchanBERTa: Pretraining transformer-based Thai language models,” arXiv:2101.09635, 2021. Available: <https://arxiv.org/abs/2101.09635>
- D. McDuff et al., “New tools are needed for tracking adherence to AI model behavioral use clauses,” arXiv:2505.22287, 2025. Available: <https://arxiv.org/abs/2505.22287>
- National Institute of Standards and Technology, Artificial Intelligence Risk Management Framework (AI RMF 1.0), 2023. Available: <https://www.nist.gov/itl/ai-risk-management-framework>
- OECD, Tracking Climate Finance and Carbon Data Systems, 2023. Available: <https://www.oecd.org/climate-change/>
- Office of Natural Resources and Environmental Policy and Planning, Thailand Mid-Century, Long-Term Low Greenhouse Gas Emission Development Strategy (LT-LEDS), 2021. Available: <https://unfccc.int/documents/307950>
- OpenAI, “GPT-4 Technical Report,” arXiv:2303.08774, 2023. Available: <https://arxiv.org/abs/2303.08774>
- J. S. Park et al., “Generative agents: Interactive simulacra of human behavior,” in Proc. ACM UIST 2023, 2023. Available: <https://arxiv.org/abs/2304.03442>
- K. Pipatanakul et al., “Typhoon: Thai large language models,” arXiv:2312.13951, 2023. Available: <https://arxiv.org/abs/2312.13951>
- M. Reichstein et al., “Deep learning and process understanding for data-driven Earth system science,” Nature, vol. 566, pp. 195–204, 2019, doi: 10.1038/s41586-019-0912-1. Available: <https://www.nature.com/articles/s41586-019-0912-1>


- D. Rolnick et al., “Tackling climate change with machine learning,” arXiv:1906.05433, 2019. Available: <https://arxiv.org/abs/1906.05433>
- S. Russell and P. Norvig, Artificial Intelligence: A Modern Approach, 4th ed., Pearson, 2021. Available: <https://aima.cs.berkeley.edu/>
- Science Based Targets initiative, Corporate Net-Zero Standard, 2021. Available: <https://sciencebasedtargets.org/resources/files/Net-Zero-Standard.pdf>
- K. Sunilkumar and J. Sheela, “Multi-document summarization using LLAMA 2 model with transfer learning,” 2024. Available: <https://ieeexplore.ieee.org/document/10717223>
- United Nations Framework Convention on Climate Change, Enhanced Transparency Framework Technical Handbook, 2022. Available: <https://unfccc.int/documents>
- L. Wu et al., “Optimization of carbon footprint management model of electric power enterprises based on artificial intelligence,” PLOS ONE, 2024, doi: 10.1371/journal.pone.0316537. Available: <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0316537>
- World Bank, State and Trends of Carbon Pricing 2023, 2023. Available: <https://openknowledge.worldbank.org/handle/10986/39796>
- World Resources Institute and World Business Council for Sustainable Development, Corporate Value Chain (Scope 3) Accounting and Reporting Standard, 2011. Available: <https://ghgprotocol.org/standards/scope-3-standard>
- World Resources Institute and World Business Council for Sustainable Development, The Greenhouse Gas Protocol: A Corporate Accounting and Reporting

Standard (Revised Edition), 2015. Available:

<https://ghgprotocol.org/corporate-standard>








ภาพที่ ก-1 ไดอะแกรมสถาปัตยกรรมระดับสูง (High-Level Architecture)



ภาพที่ ก-2 File Processing Pipeline



ภาพที่ ก-3 Network Architecture



ภาคผนวก ข

ตัวอย่าง Prompt และ Workflow ของ Multi-Agent

1. ตัวอย่าง Prompt Templates - AI Query Analyzer วิเคราะห์คำถามผู้ใช้เป็น Structured JSON สำหรับ Routing

```

SYSTEM_PROMPT = """You are an expert query analyzer for a Carbon Footprint tracking system.

Your task is to analyze user queries and extract structured information:

## 1. Query Type Detection (ระบุประเภทคำถาม)

Classify into one of:
- **data_query**: ดึงข้อมูลการปล่อยก๊าซที่บันทึกไว้
  Examples: "ปีนี้ใช้ไฟฟ้าเท่าไร", "show me emissions data"
- **calculation**: คำนวณการปล่อยก๊าซจากข้อมูลใหม่
  Examples: "คำนวณ 1000 kWh", "calculate emissions from 50L diesel"
- **comparison**: เปรียบเทียบระหว่างช่วงเวลาหรือกิจกรรม
  Examples: "เปรียบเทียบ Q1 vs Q2", "compare electricity vs diesel"
- **trend_analysis**: วิเคราะห์แนวโน้มการเปลี่ยนแปลง
  Examples: "กิจกรรมไหนเพิ่มขึ้นเรื่อยๆ", "show increasing trends"
- **forecasting**: พยากรณ์การปล่อยก๊าซในอนาคต
  Examples: "ปี 2026 จะปล่อยเท่าไร", "forecast next year"
- **net_zero**: วิเคราะห์เป้าหมาย Net Zero
  Examples: "เมื่อไหร่ถึง net zero", "when carbon neutral"
- **optimization**: หาวิธีเพิ่มประสิทธิภาพการลดก๊าซ
  Examples: "ตรวจสอบจากกิจกรรมไหนก่อน", "optimize reduction strategy"

## 2. Entity Extraction (ดึงข้อมูลสำคัญ)

Extract all relevant entities:

### 2.1 Activities (กิจกรรม)
- Thai: ไฟฟ้า, น้ำมัน, ดีเซล, เบนซิน, กระดาษ, ก๊าซธรรมชาติ
- English: electricity, fuel, diesel, gasoline, paper, natural gas
- Return standardized names: ["electricity", "diesel", ...]

### 2.2 Time Periods (ช่วงเวลา)
Formats to detect:
- Relative: "ปีนี้", "เดือนนี้", "Q1", "3 เดือนที่แล้ว"
- Absolute: "2025", "มกราคม 2025", "January 2025"
- Range: "2024-2025", "Jan-Mar"

Return as:
{
  "type": "year" | "month" | "quarter" | "custom",
  "value": "2025" | "current" | "Q1",
  "start": "2025-01-01", // optional
  "end": "2025-12-31" // optional
}

### 2.3 Scope (ขอบเขตการปล่อย)
- Detect: "scope 1", "scope 2", "scope 3"
- Return: ["1", "2", "3"]

### 2.4 Aggregation (การรวมข้อมูล)
- sum: รวมทั้งหมด, total
- group_by: แยกตาม, breakdown by
- highest: สูงสุด, maximum
- lowest: ต่ำสุด, minimum
- average: เฉลี่ย, avg

```

ภาพที่ ข-1 ตัวอย่าง Prompt Templates - AI Query Analyzer (1)

3. Intent Classification (ระบุเจตนา)

Primary intent:

- get_emissions: ดึงข้อมูลการปล่อย
- compare_periods: เปรียบเทียบช่วงเวลา
- analyze_trend: วิเคราะห์แนวโน้ม
- forecast_future: พยากรณ์อนาคต
- calculate_new: คำนวณข้อมูลใหม่
- optimize_reduction: เพิ่มประสิทธิภาพการลด

4. Filter Extraction (ดึง filters)

Extract:

- date_range: {start: "YYYY-MM-DD", end: "YYYY-MM-DD"}
- co2e_range: {min: number, max: number}
- department: string
- location: string
- threshold: number (for anomaly detection)

5. Output Format

Return ONLY valid JSON (no markdown, no explanation):

```
{
  "query_type": "data_query",
  "intent": "get_emissions",
  "entities": {
    "activities": ["electricity", "diesel"],
    "time_periods": [
      {
        "type": "year",
        "value": "2025",
        "start": "2025-01-01",
        "end": "2025-12-31"
      }
    ],
    "scope": ["1", "2"],
    "aggregation": "sum"
  },
  "filters": {
    "date_range": {
      "start": "2025-01-01",
      "end": "2025-12-31"
    },
    "co2e_range": {
      "min": 0,
      "max": 10000
    }
  },
  "confidence": 0.95,
  "original_query": "ปีนี้ใช้ไฟฟ้าและดีเซลรวมเท่าไร"
}
```

Important Rules:

1. ALWAYS return valid JSON
2. confidence score: 0.0 to 1.0
3. If uncertain about activity, set confidence < 0.7
4. Support both Thai and English queries
5. Normalize all activity names to English
6. Handle typos and variations (ไฟฟ้า = ไฟฟ้า)

===

ภาพที่ ข-2 ตัวอย่าง Prompt Templates - AI Query Analyzer (2)

2. ตัวอย่าง Prompt Templates - Agentic Orchestrator ตัดสินใจ Routing ไปยัง Agent ที่เหมาะสม

Multi-Step Detection Pattern:

```
# Pattern-based detection (fallback เมื่อไม่มี AI Query Analyzer)

MULTI_STEP_INDICATORS = [
    # Multiple items (บ่งบอกว่าต้องทำอะไรหลายอย่าง)
    "and", "plus", "กับ", "และ",

    # Post-processing (ต้องการผลลัพธ์พิเศษ)
    "report", "สรุป", "summary",
    "รายงาน", "excel", "pdf", "สร้าง",

    # Analysis keywords (การวิเคราะห์)
    "analyze", "วิเคราะห์", "เปรียบเทียบ",
    "compare", "trend", "แนวโน้ม", "พยากรณ์",

    # Multiple calculations
    "total", "รวม", "ทั้งหมด",
    "breakdown", "แยกตาม"
]

def _is_multi_step_goal(self, goal: str) -> bool:
    """
    Detect if goal requires multiple steps

    Multi-step if:
    1. Contains multi-step indicators
    2. Has more than 1 action verb
    3. Requests post-processing (report/excel)
    4. Needs data + analysis
    """

    # Check indicators
    goal_lower = goal.lower()
    if any(indicator in goal_lower for indicator in MULTI_STEP_INDICATORS):
        return True

    # Count action verbs
    action_verbs = ["คำนวณ", "สร้าง", "วิเคราะห์", "เปรียบเทียบ",
                    "calculate", "create", "analyze", "compare"]
    acti = sum(1 for verb in acti if verb in goal_lower)

    return acti >= 2
```

ภาพที่ ข-3 ตัวอย่าง Prompt Templates - Agentic Orchestrator (1)

Intent Detection Logic:

```
def _detect_intent(self, goal: str, query_analysis: Opti>-> str:
    """
    Detect user intent for routing

    Priority:
    1. AI Query Analysis (confidence > 0.7)
    2. Pattern matching (fallback)

    Returns: "calculation" | "data_query" | "knowledge_search" | "general"
    """

    # Method 1: AI Analysis (if available)
    0.7 if query_analysis and query_analysis.get("c>0) >:
        query_type = query_analysis.get("query_type")

        # Map query_type to intent
        if query_type == "calculation":
            return "calculation"
        elif query_type in ["data_query", "comparis>"trend_analysis"]:
            return "data_query"
        elif query_type in ["forecasting", "net_zero", "optimization"]:
            return "knowledge_search"

    # Method 2: Pattern Matching (fallback)
    goal_lower = goal.lower()

    # Calculation patterns
    CALC_PATTERNS = [
        "คำนวณ", "calculate", "compute",
        "หาค่า", "ได้เท่าไร", "เท่าไร"
    ]

    # Data query patterns
    DATA_PATTERNS = [
        "ใช้", "ปล่อย", "ข้อมูล", "แสดง", "รายการ",
        "เท่าไร", "กี่", "how much", "how many",
        "show", "list", "data", "รายงาน"
    ]

    # Knowledge search patterns
    KNOWLEDGE_PATTERNS = [
        "ค้นหา", "search", "find",
        "อะไรคือ", "what is", "ช่วยอธิบาย",
        "emissi>"มาตรฐาน", "standard",
        "ความหมาย", "definition"
    ]

    # Check patterns in priority order
    if any(p in goal_lower for p in CALC_PATTERNS):
        return "calculation"
    elif any(p in goal_lower for p in DATA_PATTERNS):
        return "data_query"
    elif any(p in goal_lower for p in KNOWLEDGE_PATTERNS):
        return "knowledge_search"

    return "general"
```


ภาพที่ ข-4 ตัวอย่าง Prompt Templates - Agentic Orchestrator (2)

3. ตัวอย่าง Workflow Diagrams - Main Orchestration Flow




ภาพที่ ข-5 ตัวอย่าง Workflow Diagrams - Main Orchestration Flow

4. ตัวอย่าง Workflow Diagrams - Calculation Workflow



ภาพที่ ข-6 ตัวอย่าง Workflow Diagrams - Calculation Workflow

5. ตัวอย่าง Workflow Diagrams - Knowledge Search Workflow (RAG)



ภาพที่ ข-7 ตัวอย่าง Workflow Diagrams - Knowledge Search Workflow (RAG)

6. ตัวอย่าง Workflow Diagrams - Multi-Step Workflow



ภาพที่ ข-8 ตัวอย่าง Workflow Diagrams - Multi-Step Workflow



1. ชุดข้อมูลในระบบ

ตารางที่ ค-1 ฐานข้อมูลหลัก (Master Data)

ประเภทข้อมูล	จำนวน	ตัวอย่างข้อมูล	ค่า Emission Factor
พลังงาน (Scope 2)	8	ไฟฟ้าตามโครงข่าย (ไทย)	0.4999 kg CO ₂ e/kWh
		โซลาร์เซลล์	0.0000 kg CO ₂ e/kWh
เชื้อเพลิง (Scope 1)	12	ดีเซล	2.69 kg CO ₂ e/ลิตร
		เบนซิน	2.31 kg CO ₂ e/ลิตร
		ก๊าซธรรมชาติ (NGV)	1.93 kg CO ₂ e/kg
วัสดุ (Scope 3)	15	กระดาษ A4	0.95 kg CO ₂ e/kg
		พลาสติก PET	3.50 kg CO ₂ e/kg
		เหล็ก	1.80 kg CO ₂ e/kg
น้ำและของเสีย	6	การใช้น้ำประปา	0.344 kg CO ₂ e/ลบ.ม.
		ขยะทั่วไป (ฝังกลบ)	0.40 kg CO ₂ e/kg

อ้างอิง: TGO 2024, IPCC AR6, DEFRA 2023

ตารางที่ ค-2 กิจกรรมมาตรฐาน (Standard Activities)

กลุ่มกิจกรรม	จำนวน	ตัวอย่าง
การเดินทาง	8	รถยนต์ดีเซล, มอเตอร์ไซค์, เครื่องบิน
การผลิต	12	การผลิตไฟฟ้า, การผลิตสินค้า
สำนักงาน	6	ใช้ไฟฟ้า, ใช้น้ำ, จัดการขยะ

ตารางที่ ค-3 ฐานความรู้ (Knowledge Base - RAG)

รายการ	จำนวน
เอกสารทั้งหมด	12 ไฟล์ (PDF, PNG, JPG)
จำนวน Text Chunks	7,885 chunks
จำนวน Vectors	19,932 points
Vector Dimension	384 (all-MiniLM-L6-v2)
Similarity Metric	Cosine Similarity

แหล่งความรู้

- มาตรฐาน TGO, IPCC, GHG Protocol
- คู่มือการคำนวณ Carbon Footprint
- กฎหมายและระเบียบที่เกี่ยวข้อง
- วิธีการลดการปล่อยก๊าซเรือนกระจก

2 ชุดข้อมูลทดสอบ (Test Datasets)

ตารางที่ ค-4 การแบ่งกลุ่มตามประเภทคำถามตาม Goal Type (100 Goals)

ประเภท	จำนวน	ร้อยละ	ตัวอย่าง
CALCULATE	25	25%	คำนวณการปล่อยก๊าซ
SEARCH	20	20%	ค้นหาข้อมูลการปล่อยก๊าซ
REPORT	15	15%	สร้างรายงาน
ANALYZE	12	12%	วิเคราะห์แนวโน้ม
OPTIMIZE	10	10%	หาวิธีลดก๊าซ
PREDICT	8	8%	พยากรณ์
MONITOR	6	6%	ติดตามเป้าหมาย
CUSTOM	4	4%	งานพิเศษ

ตารางที่ ค-5 ตัวอย่างคำถามและคำตอบจากชุดทดสอบ

#	คำถาม	คำตอบที่คาดหวัง	ผลลัพธ์
การคำนวณ (CALCULATE)			
1	คำนวณ CO2 จากไฟฟ้า 100 kWh	49.99 kg CO ₂ e (100 × 0.4999)	Pass
2	คำนวณ CO2 จากดีเซล 50 ลิตร	134.00 kg CO ₂ e (50 × 2.69)	Pass
3	รถยนต์วิ่ง 200 km ดีเซล B7, 15 km/L	34.81 kg CO ₂ e (200÷15×2.61)	Pass
4	สำนักงานใช้ไฟ 5,000 kWh + น้ำ 100 ลบ.ม.	2,534.35 kg CO ₂ e	Pass
5	ผลิตภัณฑ์ 1,000 kg + พลาสติก 500 kg	2,700 kg CO ₂ e	Pass
การค้นหาข้อมูล (SEARCH)			
6	ดึงข้อมูลการปล่อยก๊าซเดือน ม.ค. 2024	รายการกิจกรรมทั้งหมดในเดือน	Pass
7	หา emission factor ของดีเซล	2.69 kg CO ₂ e/ลิตร	Pass
8	แสดงรายการ Scope 1 ทั้งหมด	12 รายการเชื้อเพลิง	Pass
9	ค้นหาข้อมูลบริษัท organization_id=123	ข้อมูลองค์กร + สถิติ	Pass
10	กิจกรรมไหนปล่อยก๊าซมากที่สุด	Top 10 activities เรียงตาม CO ₂ e	Pass
การสร้างรายงาน (REPORT)			
11	สร้างรายงานสรุปการปล่อยก๊าซ Q1 2024	รายงาน Markdown พร้อมตาราง	Pass
12	export รายงานปี 2023 เป็น Excel	ไฟล์ .xlsx พร้อม charts	Pass
13	สร้าง Carbon Footprint Report แยกตาม Scope	รายงาน 3 Scopes พร้อม %	Pass
14	รายงานเปรียบเทียบ 2023 vs 2024	ตาราง YoY comparison	Pass
15	Dashboard สรุป KPIs	5 KPIs + trend graphs	Pass
การวิเคราะห์ (ANALYZE)			
16	วิเคราะห์แนวโน้มการปล่อยก๊าซ 6 เดือน	Linear regression + trend	Pass
17	เปรียบเทียบ Scope 1 vs Scope 2	% contribution analysis	Pass
18	หาสาเหตุที่ก๊าซเพิ่มขึ้นในเดือนนี้	Root cause analysis	Pass
19	วิเคราะห์ประสิทธิภาพการใช้พลังงาน	Energy intensity metrics	Pass
20	breakdown การปล่อยก๊าซตามแผนก	Departmental analysis	Pass
การเพิ่มประสิทธิภาพ (OPTIMIZE)			

#	คำถาม	คำตอบที่คาดหวัง	ผลลัพธ์
21	หาวิธีลดก๊าซจากไฟฟ้า	แนะนำ: โซลาร์เซลล์, LED, ปรับอุณหภูมิ	Pass
22	ลดต้นทุนและก๊าซพร้อมกัน	5 กลยุทธ์ประหยัดพลังงาน	Pass
23	เปลี่ยนเชื้อเพลิงอะไรดี	เปรียบเทียบ NGV vs ไฟฟ้า vs ไฮบริด	Pass
24	แผนลดก๊าซ 20% ใน 1 ปี	Action plan 6 ขั้นตอน	Pass
25	โครงการ Net Zero 2050	Roadmap + milestones	Pass
การพยากรณ์ (PREDICT)			
26	พยากรณ์การปล่อยก๊าซเดือนหน้า	Forecast based on trend	Pass
27	ถ้าใช้โซลาร์ 50% จะลดได้เท่าไร	Scenario analysis	Pass
28	ปี 2030 จะปล่อยก๊าซเท่าไร	Long-term projection	Warning
29	คาดการณ์ต้นทุน carbon credit	Price prediction	Warning
30	ถ้าไม่ทำอะไร จะเกิดอะไร	Baseline scenario	Pass
การติดตามเป้าหมาย (MONITOR)			
31	ติดตามเป้าหมายลด 10%	Progress: 6.5% (65% of target)	Pass
32	อีกเท่าไรถึงเป้า Net Zero	Gap analysis + remaining emissions	Pass
33	KPI อะไรไม่บรรลุ	List of off-track KPIs	Pass
34	แจ้งเตือนถ้าเกินเป้าเดือนนี้	Alert system + threshold	Pass
35	Dashboard Real-Time Monitoring	Live metrics + alerts	Pass

ตารางที่ ค-6 ตัวอย่างการตอบคำถามความรู้ทั่วไป (RAG Knowledge Base)

#	คำถาม	แหล่งความรู้	คะแนน Keyword	คะแนน Source	ผลลัพธ์
36	Scope 1 คืออะไร	GHG Protocol	5/5	5/5	Pass
37	Carbon Footprint คำนวณยังไง	TGO Guideline	5/5	5/5	Pass
38	Net Zero หมายถึงอะไร	IPCC Report	5/5	4/5	Pass
39	วิธีลดก๊าซจากการขนส่ง	Best Practices	4/5	5/5	Pass
40	มาตรฐาน ISO 14064 คืออะไร	ISO Standards	5/5	5/5	Pass
41	Carbon Credit ซื้อขายได้ไหม	Carbon Market Guide	4/5	4/5	Pass
42	ต้นไม้ 1 ต้นดูดซับ CO2 เท่าไร	Forest Carbon Study	3/5	3/5	Warning
43	กฎหมายบังคับ เรื่องก๊าซเรือนกระจก	Thai Regulations	5/5	5/5	Pass



ภาคผนวก ง

ตัวอย่างผลลัพธ์ระบบและหน้าจอการใช้งาน

OCR & Document Upload Service

[Home](#)
[API Docs](#)
[Chat](#)

Upload Documents

รองรับไฟล์ต่อไปนี้:

Document: PDF, JPG, JPEG, PNG, DOCX, XLSX (สูงสุด 100MB) - จะทำ OCR และสร้าง Embedding

Chat: PDF, JPG, JPEG, PNG, DOCX, XLSX (สูงสุด 10MB) - จะทำ OCR เท่านั้น

Document Type *

Document (สำหรับฐานความรู้ - จะทำ Embedding)

Login Status *

☐ ผู้ใช้ล็อกอินแล้ว

Share Type

Share (Multi-tenant)

Uploaded By

user@example.com

Upload Files

คลิกเพื่อเลือกไฟล์ หรือลากไฟล์มาวางที่นี่

รองรับหลายไฟล์พร้อมกัน

Service Statistics

19

Total Documents

78.85

Total Size (MB)

19

Completed


0

Processing

ภาพที่ ง-1 หน้าการทำ OCR



ภาพที่ ง-2 หน้า Chat ที่สามารถเลือก RAG Strategy ได้



ภาพที่ ง-3 หน้า Frontend สำหรับใช้งาน Agentic AI โดยการตั้งเป้าหมาย

▼ คำ emission factor ของ LPG เป็นเท่าไร search completed 1/1 2/19/2026, 7:04:50 AM

Task Execution Details

1. Search knowledge base: คำ emission factor ของ LPG เป็นเท่าไร completed AGENTIC_KNOWLEDGE

Type: search | Input: ("query": "คำ emission factor ของ LPG เป็นเท่าไร")

✓ Result:

Answer: คำ Emission Factor มาตรฐาน TGO: - LPG/ก๊าซหุงต้ม (lpg): **1.554 kgCO₂e/kg** (มาตรฐาน TGO)

Sources: 0 documents

✓ Status: success

```
{
  "status": "success",
  "answer": "คำ Emission Factor มาตรฐาน TGO: \n LPG/ก๊าซหุงต้ม (lpg): **1.554 kgCO2e/kg** (มาตรฐาน TGO)",
  "sources": [],
  "via": "config_service"
}
```

Executed: 2/19/2026, 7:04:50 AM

AI Learning - ช่วยให้อ AI เข้าใจดีขึ้น

ผลลัพธ์ที่ AI แสดงถูกต้องหรือไม่? ข้อเสนอนี้ของคุณจะช่วยให้ AI เรียนรู้และตอบคำถามได้ดีขึ้น

แสดงความเห็นหรือข้อเสนอแนะ (ไม่บังคับ)

ถูกต้อง ไม่ถูกต้อง บันทึกความเห็น

▼ อาคารสำนักงานใช้ไฟฟ้า 50,000 kWh ต่อปี ปลดปล่อย CO2 เท่าไร calculate completed 24.995 kgCO₂e 1/1 2/19/2026, 7:03:23 AM

Task Execution Details

1. Calculate emissions: 50.0 electricity completed AGENTIC_CALCULATION

Type: calculate | Input: ("activity": "electricity", "amount": 50, "org_id": null)

✓ Result:

Emissions: 24.995 kgCO₂e

Activity: electricity

Amount: 50

Emission Factor: 0.4999

✓ Status: success

```
{
  "status": "success",
  "activity": "electricity",
  "amount": 50,
  "emission_factor": 0.4999,
  "emission_factor_source": "emission_factors_db",
  "emissions": 24.995,
  "unit": "kgCO2e",
  "saved_id": ""
}
```

Executed: 2/19/2026, 7:03:23 AM

AI Learning - ช่วยให้อ AI เข้าใจดีขึ้น

ผลลัพธ์ที่ AI แสดงถูกต้องหรือไม่? ข้อเสนอนี้ของคุณจะช่วยให้ AI เรียนรู้และตอบคำถามได้ดีขึ้น

แสดงความเห็นหรือข้อเสนอแนะ (ไม่บังคับ)

ถูกต้อง ไม่ถูกต้อง บันทึกความเห็น

ภาพที่ ง-5 หน้าตัวอย่างคำถามคำนวณ

ประวัติผู้เขียน

ชื่อ	นางสาวโศจิรัตน์ ทรงประดิษฐ์	
ชื่อการค้นคว้าอิสระ	การพัฒนาโมเดลปัญญาประดิษฐ์เอเจนติกเอไอ เพื่อสนับสนุนการประเมินก๊าซเรือนกระจกในระดับองค์กร	
สาขาวิชา	ระบบสารสนเทศเพื่อการจัดการ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ	
ประวัติ	ประวัติการศึกษา - มหาวิทยาลัยรามคำแหง นิเทศศาสตร์และสื่อดิจิทัล (ป.ตรี ใบที่สอง) 2022 - 2024 จิตวิทยาอุตสาหกรรมและองค์การ 2015 - 2018 - วิทยาลัยเทคโนโลยีไออาร์พีซี ปวส : เทคโนโลยีสารสนเทศ 2015 - 2016 ปวช : เทคโนโลยีคอมพิวเตอร์ 2012 - 2014	