บทความประเภทผลลัพธ์จากการนำการจัดการความรู้ (KM) ไปใช้ประโยชน์

เรื่อง “Generative AI ยุคใหม่กับความท้าทายด้านข้อมูล และบทบาทของ NotebookLM ในการยกระดับการจัดการความรู้เชิงองค์กร”

มหาวิทยาลัยมหามกุฏราชวิทยาลัย วิทยาเขตล้านนา

บทคัดย่อ

บทความวิชาการนี้นำเสนอกรอบแนวคิดและแนวปฏิบัติสำหรับการยกระดับการจัดการความรู้เชิงองค์กรในยุคที่ข้อมูลท่วมท้นและไม่เป็นโครงสร้าง โดยผสานเทคนิค Retrieval-Augmented Generation (RAG) และ Source-grounding เข้ากับการใช้งาน NotebookLM เพื่อให้การสรุป วิเคราะห์ และอ้างอิงมีความแม่นยำและตรวจสอบย้อนกลับได้ ผลงานชี้ให้เห็น (1) กรอบ KM ที่แปลงแฟ้มงานกระจัดกระจายสู่ “คลังสมองส่วนกลาง” ผ่านกระบวนการ 5 ขั้น ได้แก่ Ingest, Index & Chunk, Grounding Policy, Retrieval-before-Generation, และ Central Knowledge Base (2) แนวคิด AI-Augmented Work (IAW) ที่ใช้ AI เป็น “ส่วนขยาย” ของสติปัญญามนุษย์ โดยมนุษย์ยังเป็นผู้ตัดสินใจหลัก และ (3) กรอบ Self-Directed Learning (SDL) ที่อาศัย Notebook Guide และ Audio Overview เพื่อสร้างเส้นทางการเรียนรู้เฉพาะบุคคล พร้อมตัวชี้วัดผลลัพธ์ ได้แก่ การลดเวลาในการค้นพบความรู้ (time-to-insight) การเพิ่มความแม่นยำของสรุป และการยกระดับอัตราการอ้างอิง/การตรวจสอบแหล่งที่มา นอกจากนี้ ยังเสนอเกณฑ์ธรรมาภิบาลความรู้ (คุณภาพแหล่งข้อมูล เวอร์ชันนิง และการทบทวน) เพื่อคงความน่าเชื่อถือและลดความเสี่ยงจากการหลอนของข้อมูล (AI hallucination) ในการใช้งานจริงของหน่วยงานคณะสงฆ์ ภาครัฐ และภาคเอกชน

คำสำคัญ: การจัดการความรู้, การค้นคืนก่อนสังเคราะห์, การยึดโยงกับแหล่งข้อมูล, การเรียนรู้ด้วยตนเอง, เส้นทางการเรียนรู้เฉพาะบุคคล, ธรรมาภิบาลความรู้

Abstract

This article proposes an integrated framework and practice guide for organizational knowledge management under conditions of information overload and unstructured data. We combine Retrieval-Augmented Generation (RAG) with source-grounding and operationalize it via NotebookLM to ensure accurate, evidence-anchored, and traceable summarization and analysis. The contribution includes: (1) a KM pipeline that transforms scattered files into a central knowledge base through five steps—ingest, index & chunk, grounding policy, retrieval-before

-generation, and central KB; (2) an AI-Augmented Work (IAW) model that treats AI as an intelligence-augmentation partner while preserving human primacy in decision-making; and (3) a Self-Directed Learning (SDL) framework leveraging Notebook Guide and Audio Overview to enable personalized learning paths. Outcome indicators demonstrate show shorter time-to-insight, improved summary accuracy, and higher citation/verification rates, while a knowledge-governance checklist (source quality, versioning, periodic review) mitigates AI hallucination risks across the monastic, public, and private sectors. The framework offers a practical route to align large-context LLM capabilities with reliable organizational knowledge workflows.

Keywords: Knowledge Management; Retrieval-Augmented Generation (RAG); Source-grounding; NotebookLM; AI-Augmented Work; Self-Directed Learning (SDL); Personalized Learning Path; Knowledge Governance

บทนำ

ในยุคที่เทคโนโลยีปัญญาประดิษฐ์เชิงสร้างสรรค์ (Generative Artificial Intelligence: Generative AI) พัฒนาอย่างรวดเร็วและก้าวกระโดด องค์กรในทุกภาคส่วน ได้แก่ คณะสงฆ์ หน่วยงานภาครัฐ เช่น อบจ. หรือเทศบาล ตลอดจนภาคเอกชน ต่างต้องเผชิญกับความท้าทายทางสารสนเทศที่ซับซ้อนมากขึ้น โดยเฉพาะปัญหาข้อมูลท่วมท้น (information overload) อันเป็นผลจากการเพิ่มขึ้นของข้อมูลที่มีความหลากหลาย ทั้งในรูปแบบเอกสารทางราชการ รายงานการประชุม ฐานข้อมูลวิจัย และข้อมูลดิจิทัลที่ไม่เป็นโครงสร้างจำนวนมาก (unstructured data) (Gandomi & Haider, 2015)

สำหรับศิษย์เก่ามหาวิทยาลัยมหามกุฏราชวิทยาลัย วิทยาเขตล้านนา การประยุกต์ทักษะ “Smart Learning” ที่ได้รับระหว่างการศึกษา ให้ต่อยอดเป็น “Smart Working” จึงมีความสำคัญอย่างยิ่ง ไม่เพียงแต่จะช่วยเพิ่มประสิทธิภาพในการปฏิบัติงาน แต่ยังยกระดับความแม่นยำ ความรวดเร็ว และคุณภาพการตัดสินใจเชิงบริหาร โดยเฉพาะผ่านเทคโนโลยีเพื่อการจัดการความรู้ส่วนบุคคล (Personalized Knowledge Management) ที่ช่วยเชื่อมโยงการเรียนรู้กับการทำงานจริงอย่างเป็นระบบ (Eppler & Mengis, 2004)

ดังนั้น Generative AI ยุคใหม่จึงเป็นความท้าทายของนักศึกษาเมื่อสำเร็จการศึกษาจากรั้วมหาวิทยาลัยแล้ว ต้องเข้าสู่ระบบการทำงานยุคใหม่ที่จำเป็นอย่างยิ่งจะต้องมีความรู้ความเข้าใจ Generative AI หลากหลายประเภท โดยเฉพาะบทบาทของ NotebookLM ซึ่งปัจจุบันใน พ.ศ. 2569 นับว่าเป็น Generative AI ที่มีบทบาทสำคัญในการทำงานยุคสมัยใหม่ในการยกระดับการจัดการความรู้เชิงองค์กร เพื่อให้เข้าใจสาระสำคัญของบทความวิชาการนี้ ผู้เขียนได้แบ่งเนื้อหาสาระทั้งสิ้น 4 ภาค ดังนี้

ภาคที่ 1 วิกฤตด้านข้อมูลในยุคดิจิทัลและผลกระทบต่อการตัดสินใจเชิงบริหาร

ปัจจุบันสังคมไทยขับเคลื่อนด้วยข้อมูลปริมาณมหาศาล ส่งผลให้เกิดภาวะ “Data Explosion” ที่สะท้อนทั้งศักยภาพและข้อจำกัดของสังคมสารสนเทศร่วมสมัย ข้อมูลทั้งที่เป็นทางการและไม่เป็นทางการ เช่น ไฟล์ PDF รายงานการประชุม บันทึกภาคสนาม หรือบทความวิจัย มีแนวโน้มถูกนำไปใช้ประโยชน์เพิ่มสูงขึ้น ผู้ใช้สามารถเข้าถึงข้อมูลเหล่านี้ได้อย่างง่ายดาย (Hilbert & López, 2011) แต่ปัญหากลับไม่ได้อยู่ที่การเข้าถึงแหล่งข้อมูล ปัญหาที่แท้จริงกลับพบว่า เมื่อนักศึกษาของวิทยาเขตล้านนาสำเร็จการศึกษาและต้องเข้าสู่ระบบการทำงาน สิ่งที่นักศึกษาต้องประสบ คือ ปัญหาการคัดกรอง การวิเคราะห์ และการสกัดข้อมูลจำนวนมหาศาลเหล่านี้ มาใช้ให้ตรงกับความต้องการของหน่วยงานตนเอง และทันต่อการเปลี่ยนแปลงของข้อมูลข่าวสารที่มีความรวดเร็ว ซึ่งกลายเป็นโจทย์ที่ท้าทายมากกว่าเดิม เมื่อภาวะข้อมูลท่วมท้นส่งผลกระทบต่อความเร็วในการทำงานจริง ส่งผลให้คุณภาพการวิเคราะห์ข้อมูลเพื่อนำไปใช้ กลายเป็นสถานการณ์ที่ลดทอนประสิทธิภาพการตัดสินใจของบุคลากรขององค์กรเท่านั้นทันที

แม้ Generative AI จะมีบทบาทสำคัญในการประมวลผลข้อมูลจำนวนมากและสนับสนุนการสรุปข้อมูล แต่ยังคงมีข้อจำกัดที่สำคัญ นั่นคือ ปัญหาการสร้างข้อมูลที่ขาดความน่าเชื่อถือและไม่ตรงตามข้อเท็จจริงหรือการสร้างแหล่งอ้างอิงที่ไม่มีความน่าเชื่อถือ (AI Hallucination) (Ji et al., 2023; Maynez et al., 2020) ความคลาดเคลื่อนดังกล่าวอาจสร้างความเสี่ยงต่อความน่าเชื่อถือของผลลัพธ์ ทั้งในเชิงวิชาการและการบริหารองค์กร ด้วยเหตุนี้ เทคโนโลยี Retrieval-Augmented Generation (RAG) จึงถูกพัฒนาขึ้นเพื่อผสานการสืบค้นข้อมูลจริงก่อนการสร้างคำตอบ ทำให้ผลลัพธ์มีหลักฐานรองรับ ลดภาวะหลอน และเพิ่มความสามารถในการตรวจสอบย้อนกลับ (Lewis et al., 2020; Karpukhin et al., 2020)

ดังนั้น การให้คำปรึกษาการใช้ NotebookLM แก่นักศึกษาภายหลังจากสำเร็จการศึกษาจากสถาบันไปแล้ว จึงได้รับความนิยมเพิ่มขึ้น โดยเฉพาะในกลุ่มนักศึกษาสายรัฐศาสตร์ทั้งบรรพชิตและคฤหัสถ์ ที่ต้องปฏิบัติหน้าที่เป็นทั้งพระสังฆาธิการ ผู้ช่วยเลขานุการเจ้าคณะจังหวัดเชียงใหม่ สมาชิกสภาเทศบาล ผู้ใหญ่บ้าน รวมไปถึงเจ้าของธุรกิจการท่องเที่ยวในจังหวัดเชียงใหม่ เป็นต้น NotebookLM จึงเป็นหนึ่งในเครื่องมือที่ยึดหลักการ source-grounding โดยจำกัดให้โมเดลภาษาขนาดใหญ่ (LLM) สร้างคำตอบบนฐานของแหล่งข้อมูลที่ผู้ใช้ระบุ ส่งผลให้การสรุป การวิเคราะห์เชิงเปรียบเทียบ และการจัดทำรายงานมีความแม่นยำยิ่งขึ้น ลดความเสี่ยงจากความคลาดเคลื่อน พร้อมเพิ่มความสามารถในการตรวจสอบย้อนกลับ (traceability) ตามแนวทางของระบบค้นคืน–ก่อน–สร้างในงาน NLP ฟีเจอร์เชิงเทคนิคที่เกี่ยวข้องกับการเพิ่มศักยภาพด้านการจัดการความรู้ อาทิ

การบริหารจัดการ context window ขนาดใหญ่เพื่อรองรับข้อมูลจำนวนมาก ระบบการอ้างอิง (citation system) ที่แม่นยำและตรวจสอบได้ ซึ่งสอดคล้องกับแนวปฏิบัติเรื่องการอิงแหล่งข้อมูลเพื่อคุณภาพการสืบค้นและการเรียกคืนสารสนเทศ และศักยภาพของ RAG ในการลดความคลาดเคลื่อนของ AI และเพิ่มความน่าเชื่อถือของคำตอบในงานที่ต้องใช้ความรู้เฉพาะทางมากยิ่งขึ้น (Press et al., 2021)

ภาคที่ 2 แนวคิดการจัดการความรู้ (KM): จาก Unstructured Data สู่คลังสมองส่วนกลางด้วย Source-Grounding และ Retrieval

พื้นฐานเชิงทฤษฎีจาก Information Overload สู่ Knowledge Extraction

วรรณกรรมด้านข้อมูลชี้ให้เห็นว่า ภาวะข้อมูลท่วมท้น สามารถบ่อนทำลายประสิทธิภาพในการทำงานได้ เพราะขาดข้อมูลที่น่าเชื่อถือเพื่อเป็นกรอบในการตัดสินใจ หากไร้กลไกคัดกรองและสรุปรวบยอดอย่างเป็นระบบจะยิ่งส่งผลต่อประสิทธิภาพในการตัดสินใจเชิงข้อมูลขององค์กรทางสังคมทันที (Eppler & Mengis, 2004) ดังนั้นในเชิงเทคนิค กระบวนการประมวลผลความรู้จำนวนมหาศาลจากฐานข้อมูลที่แนบไปในระบบให้กับ NotebookLM จึงเป็นขั้นตอนสำคัญอันเป็นหัวใจหลักของการจัดการความรู้สมัยใหม่ของระบบดังกล่าวนี้

หลักการ Source-Grounding และ Retrieval ในกรอบ KM

Source – grounding กำหนดให้ระบบสร้างคำตอบโดยอ้างอิงเฉพาะจากแหล่งข้อมูลที่กำหนดเพื่อเพิ่มความแม่นยำ ความสามารถตรวจสอบ และลดการสร้างข้อมูลหลอนของ AI ได้ในงานสรุป วิเคราะห์ และรายงาน ส่วน retrieval ทำหน้าที่ค้นคืนเอกสาร/ส่วนข้อความที่เกี่ยวข้องสูง (relevance) ก่อนส่งให้ตัวสร้างภาษา (generator) สังเคราะห์ เป็นสถาปัตยกรรมที่รู้จักในชื่อ Retrieval-Augmented Generation (RAG) และได้รับแรงหนุนจากความก้าวหน้าด้าน dense retrieval เช่น DPR (Karpukhin et al., 2020)

กรอบกระบวนการแปลง Unstructured Data

กระบวนการเชิงระบบสามารถสรุปเป็น 5 ขั้นตอนหลัก ดังนี้

ขั้นตอนที่ 1 รวบรวม (Ingest) คือ การรวมไฟล์/แหล่งข้อมูลที่กระจัดกระจาย เช่น ไฟล์ประเภท PDF, รายงาน, บันทึก หรือข้อมูลอื่นๆ เช่น วันที่, เจ้าของงาน, หน่วยงาน ฯลฯ เพื่อสร้างรายงานตามรูปแบบคำสั่งที่ป้อนกลับและแสดงผลรองรับการติดตามย้อนกลับ (Gandomi & Haider, 2015)

ขั้นตอนที่ 2 แสดงลำดับการสืบค้น (Indexing & Chunking) คือ การแปลงเอกสารเป็นหน่วยข้อมูลย่อย (chunks) ที่เหมาะกับ context window ของโมเดล และทำดัชนีด้วยวิธีเวกเตอร์หรือเชิงสัญลักษณ์ (Press et al., 2021)

ขั้นตอนที่ 3 กำกับด้วยแหล่งอ้างอิง (Source-Grounding Policy) คือ การกำหนด scope ของแหล่งที่อนุญาต (approved sources) และผูกการอ้างอิง citation/เลขหน้า/ลิงก์ เพื่อให้คำตอบตรวจสอบได้ ขั้นตอนนี้จะช่วยลดความเสี่ยงการหลอนข้อมูลของ AI เพราะคำตอบที่ได้จะมาจากแหล่งข้อมูลที่ผู้ใช้เพิ่มในแหล่งอ้างอิงของระบบเท่านั้น (Ji et al., 2023)

ขั้นตอนที่ 4 ค้นคืนก่อนสังเคราะห์ (Retrieval before Generation) คือ การใช้ dense passage retrieval หรือวิธีผสม (hybrid retrieval) ดึงส่วนที่เกี่ยวข้องสูงสุด ส่งเข้าโมเดลเพื่อสรุป วิเคราะห์ เปรียบเทียบ พร้อมอ้างอิงอัตโนมัติ (Lewis et al., 2020)

ขั้นตอนที่ 5 บันทึกเป็นคลังสมองส่วนกลาง (Central Knowledge Base) คือ การจัดเก็บผลสรุป/สารสนเทศเชิงความรู้ พร้อมการตรวจสอบย้อนกลับได้ (traceability) เช่น แหล่งที่มา, เวอร์ชั่นของคำตอบ, หมายเหตุ, แหล่งอ้างอิงอื่นๆ เพื่อการนำกลับใช้ซ้ำและการเรียนรู้เชิงองค์กร

ธรรมาภิบาลความรู้ (Knowledge Governance) และคุณภาพข้อมูล

เพื่อให้คลังสมองส่วนกลาง มีความน่าเชื่อถือ ผู้ใช้จะต้องกำหนด นโยบายการคัดกรองแหล่งข้อมูล, เกณฑ์คุณภาพ (completeness, accuracy, timeliness), วงจรทบทวน และเวอร์ชันนิงของเอกสาร/สรุปความรู้ โดยอาศัยหลักการสืบค้นที่พิสูจน์แล้วและกระบวนการตรวจสอบแหล่งอ้างอิง ซึ่งจะช่วยลดอคติจากโมเดลของ AI ที่กำลังใช้งานอยู่ในปัจจุบัน เป็นการช่วยลดข้อผิดพลาดจากการหลอนของ AI ในการให้คำตอบที่ต้องการความถูกต้องแม่นยำสูงเพื่อเป็นส่วนหนึ่งของการตัดสินในในระดับองค์กรอย่างมีประสิทธิภาพ (Maynez et al., 2020)

ดังนั้น แนวคิดนี้ จึงมีผลลัพธ์ที่คาดหวังและการต่อยอดการใช้งานจาก KM แบบ source-grounded and retrieval-first ได้แก่

1. เวลาในการค้นพบความรู้ (time-to-insight) ที่สั้นลง และความแม่นยำของข้อสรุปที่สูงขึ้น
2. อัตราการอ้างอิง/ตรวจสอบแหล่งที่มา ในเอกสารสรุป/รายงานที่เพิ่มขึ้น
3. การนำกลับใช้ซ้ำของความรู้ (reuse) และ คุณภาพการตัดสินใจ ที่ดีขึ้นในระดับนโยบายขององค์กรที่นักศึกษากำลังทำงาน

ภาคที่ 3 แนวคิดการออกแบบ IAW

IAW (Design Principles) หมายถึง หลักการออกแบบการทำงานแบบ AI-Augmented Work เพื่อใช้ AI เป็นส่วนขยาย (augmentation) ของความสามารถมนุษย์ โดยมนุษย์ยังเป็นผู้ตัดสินใจหลัก หลักการของ **IAW** ที่ดี มีส่วนช่วยให้การนำไปใช้จริงในองค์กรมีความโปร่งใส และตรวจสอบได้ ซึ่งมีหลักการออกแบบ (Lane, J., 2026) ดังนี้

1) **การจัดสรรบทบาท (Role Allocation)** หมายถึง การกำหนดบทบาทระหว่างมนุษย์และ AI ให้ชัดเจน เช่น หน้าที่ของมนุษย์ คือ กำหนดกรอบคำสั่งให้ชัดเจน ได้แก่ นิยามปัญหา/บริบท, กำหนดเกณฑ์ตัดสินใจ, ตรวจรับรองผลลัพธ์ ในขณะที่หน้าที่ของ AI คือ การสืบคืนหลักฐาน การสรุป การเปรียบเทียบ การเสนอทางเลือก ตัวอย่างเช่น เจ้าของงานตั้งคำถาม+เกณฑ์ แล้วให้ AI ดึงหลักฐานและสรุป ***แต่การอนุมัติสุดท้ายมนุษย์เป็นผู้ทำ***

2) ความโปร่งใสและอ้างอิงได้ (Transparency & Citations) หมายถึง ผลลัพธ์จาก AI ทั้งหมดจะต้องแจ้งแหล่งที่มา เลขหน้า ลิงก์ต้นทาง (citation) เพื่อให้ตรวจสอบย้อนกลับได้ (traceability) ตัวอย่างเช่น

การสร้างคำสั่งว่า “ช่วยค้นคว้าเรื่อง.... พร้อมทั้งแนบแหล่งอ้างอิงที่เชื่อถือได้จากฐานข้อมูล TCI1-2 มาด้วย” เป็นต้น และควรกำหนดนโยบาย “ไม่รับคำตอบที่ไร้หลักฐานอ้างอิง”

3) ยึดหลัก Source-Grounding และ Retrieval-before-Generation หมายถึง การบังคับให้โมเดลอ้างอิงเฉพาะชุดแหล่งข้อมูลที่อนุญาตเท่านั้น (approved sources) ตัวอย่างเช่น “ช่วยสร้างแหล่งข้อมูลการค้นคว้าเรื่อง.... มาให้พิจารณาตรวจสอบความถูกต้องของข้อมูล โดยยังไม่สร้าง (ร่าง) ข้อมูลจริงก่อน เพราะฉันต้องการ retrieval” แล้วค่อยยืนยันให้ระบบสรุป/วิเคราะห์ เพื่อลดความเสี่ยงการหลอนข้อมูลจาก AI

4) การจัดการบริบท (Context Management & Chunking) หมายถึง การแบ่งเอกสารเป็น chunks ที่สมดุลกับ context window ของโมเดลโดยใส่ metadata (ที่มา, วันที่, เจ้าของงาน) เพื่อเพิ่มคุณภาพการค้นคืนและการตรวจสอบย้อนกลับ

5) การทบทวนโดยมนุษย์ในวงรอบการทำงาน และการควบคุมความเสี่ยง (Human-in-the-Loop Review & Risk Controls) หมายถึง การจัดขั้นตอน peer/owner review สำหรับผลลัพธ์ที่สำคัญ เพื่อใช้รายการตรวจ (checklist) เช่น ความครบถ้วนของแหล่งอ้างอิง ความถูกต้องและ ตรงประเด็นของเนื้อหา และความมีอคติในการตอบของ AI รวมถึงข้อจำกัดอื่นๆ ที่ได้รับคำตอบไม่ตรงกับชุดคำถาม

6) ธรรมาภิบาลด้านข้อมูลและโมเดล (Data/Model Governance) หมายถึง กรอบนโยบาย กระบวนการ มาตรฐาน และบทบาทความรับผิดชอบที่องค์กรกำหนดขึ้นเพื่อให้ข้อมูล (Data) มีคุณภาพ ความปลอดภัย ความเป็นส่วนตัว และการใช้ที่ถูกต้องตามกฎหมาย/ข้อบังคับ และโมเดลปัญญาประดิษฐ์ (Model) ถูกพัฒนา ใช้งาน เฝ้าระวัง และปรับปรุงอย่างโปร่งใส เป็นธรรม ตรวจสอบย้อนกลับได้ และสอดคล้องกับเป้าหมายทางธุรกิจ/ภารกิจขององค์กร

7) การวัดผลและการปรับปรุงอย่างต่อเนื่อง (Measurement & Continuous Improvement) หมายถึง กระบวนการที่องค์กรใช้ ตัวชี้วัด (KPIs/Metrics) เพื่อตรวจสอบประสิทธิภาพของระบบ เช่น ระบบความรู้ (KM), เวิร์กโฟลว์ AI-Augmented Work (IAW), โมเดล RAG/Source-grounding แล้วนำผลลัพธ์นั้นไปปรับปรุงกระบวนการอย่างสม่ำเสมอ

8) หลักจริยธรรม การคุ้มครองข้อมูลส่วนบุคคล และความเสมอภาคในการเข้าถึงประโยชน์ของระบบ (Ethics, Privacy & Equity) หมายถึง หลักการคุ้มครองผู้ใช้และการใช้ AI อย่างรับผิดชอบ ครอบคลุม 3 มิติสำคัญ ได้แก่

1. Ethics (จริยธรรม) คือ การใช้ AI อย่างโปร่งใส ตรวจสอบได้ ไม่สร้างอคติหรือผลเสียต่อผู้ใช้
2. Privacy (ความเป็นส่วนตัว) คือ การปกป้องข้อมูลส่วนบุคคลและข้อมูลอ่อนไหวให้ปลอดภัยตามมาตรฐาน
3. Equity (ความเท่าเทียม) คือ การทำให้ทุกคนมีโอกาสเข้าถึงประโยชน์จาก AI อย่างเป็นธรรม ไม่เลือกปฏิบัติ

9) ประสบการณ์ผู้ใช้ที่ออกแบบอย่างชัดเจน เป็นระบบ และใช้งานง่าย (A Clear and Well-Designed User Experience: UX) หมายถึง การออกแบบขั้นตอนการใช้งาน AI ให้เป็นระบบ เข้าใจง่าย และสอดคล้องกับเป้าหมายของผู้ใช้ เพื่อให้สามารถโต้ตอบกับระบบได้อย่างถูกต้องและเกิดผลลัพธ์ที่สม่ำเสมอ UX ที่ดีจะต้องประกอบด้วย *คำสั่งตัวอย่าง (prompt templates)* แนวปฏิบัติที่ชัดเจน เมนูที่เป็นมิตร และเส้นทางการทำงานที่ลดความสับสน ช่วยให้ผู้ใช้สามารถใช้ AI ได้อย่างมั่นใจ โปร่งใส และลดความเสี่ยงจากข้อผิดพลาดของโมเดล

ดังนั้น แนวคิดนี้จึงมุ่งใช้ปัญญาประดิษฐ์เป็นเพียงส่วนขยายของสติปัญญามนุษย์ (intelligence augmentation) ไม่ใช่การทดแทนมนุษย์โดยสิ้นเชิง ซึ่งยังคงให้มนุษย์มีบทบาทเป็นผู้ตัดสินใจหลักและใช้ AI เป็นผู้ช่วยด้านการค้นคืน สังเคราะห์ และตรวจสอบหลักฐาน เพื่อเพิ่มประสิทธิภาพการทำงาน (efficiency) และคุณภาพข้อสรุป (quality) ท่ามกลางข้อจำกัดของเวลาและข้อมูลที่มีมากมายมหาศาลในปัจจุบัน โดยในเชิงเทคนิค IAW ยังคงยึดฐานของ source-grounding และ retrieval-before-generation เพื่อให้คำตอบที่ AI เสนอมีหลักฐานอิงแหล่งข้อมูลจริง ลดความเสี่ยงจาก AI hallucination และเพิ่มความสามารถตรวจสอบย้อนกลับได้ ซึ่งกลไกการสืบค้นดังกล่าวนี้ ได้รับการพิสูจน์แล้วว่าสามารถเรียกคืนสารสนเทศที่สร้างเป็นแหล่งอ้างอิงได้ ทำให้การคัดกรองหลักฐานมีความแม่นยำและมีความน่าเชื่อถือในระดับสูง

ภาคที่ 4 แนวคิดการเรียนรู้ด้วยตนเอง (Self-Directed Learning: SDL): Personalized Learning Path ด้วย Notebook Guide และ Audio Overview

การเรียนรู้ด้วยตนเอง (Self-Directed Learning: SDL) หมายถึง กระบวนการที่ผู้ใช้งานเป็นผู้กำหนดเป้าหมายการเรียนรู้ของตนเอง โดยมีการวางแผน การคัดเลือกทรัพยากรแหล่งข้อมูลอ้างอิง การดำเนินการหรือการสร้างชุดคำสั่งที่มีประสิทธิภาพเพื่อให้ได้ผลลัพธ์ที่ถูกต้องตรงกับความต้องการ และการประเมินผลการเรียนรู้ โดยมีระดับความเป็นอิสระและความรับผิดชอบสูง ในบริบทดิจิทัลร่วมสมัย SDL เชื่อมโยงกับแนวคิด personalized learning ที่เน้นความแตกต่างระหว่างบุคคลด้านจังหวะ (pace) เส้นทาง (path) และความสนใจ (preference) ของผู้เรียน ซึ่งเครื่องมืออย่าง NotebookLM สามารถทำหน้าที่เป็นตัวเร่ง SDL ผ่านฟีเจอร์ เช่น Notebook Guide และ Audio Overview ซึ่งช่วยให้ผู้เรียนสรุป วิเคราะห์ และสำรวจแหล่งข้อมูลตามเป้าหมายของตนเองได้ โดยยังคงการยึดโยงกับหลักฐาน (source-grounding) และการค้นคืนก่อนสังเคราะห์ (retrieval-before-generation) เพื่อลดความคลาดเคลื่อนของโมเดลและเพิ่มความสามารถตรวจสอบย้อนกลับ (Roe & Perkins, 2025)

ซึ่งพื้นฐานเชิงทฤษฎีของ SDL แบบสามมิติของ Garrison (1997) เน้นการควบคุมตนเอง (self-management) แรงจูงใจภายใน (self-motivation) และการติดตามความก้าวหน้า/สะท้อนคิด (self-monitoring) ซึ่งสัมพันธ์อย่างใกล้ชิดกับแนวคิดการกำกับตนเองในการเรียนรู้ (self-regulated learning) ที่เน้นทักษะการวางแผน การติดตาม และการควบคุมกลยุทธ์ (Zimmerman, 2002) การนำ AI ที่มีการยึดโยงกับ

แหล่งข้อมูลจริงมาสนับสนุนทั้งสามมิตินี้สามารถช่วยให้ผู้ใช้งานสามารถตั้งโจทย์ คัดเลือกทรัพยากร และตรวจสอบคุณภาพความรู้อย่างมีประสิทธิภาพมากขึ้น (Lewis et al., 2020) นอกจากนี้ หลักการออกแบบ SDL บนฐาน Source-Grounding ผสานกับ Retrieval มีแนวทางกำหนดไว้ชัดเจน (AIGN Global, 2026) ได้แก่

1. Goal-First Prompting กำหนดให้ผู้เรียนระบุเป้าหมาย/ผลลัพธ์การเรียนรู้ (learning outcomes) ก่อน เพื่อให้ระบบชี้นำเส้นทางส่วนบุคคลได้แม่นยำ
2. Guide-Driven Exploration กำหนดให้ใช้ Notebook Guide เพื่อเสนอคำถามชี้นำ แผนสำรวจแหล่งข้อมูล และตรวจสอบการประเมินความเข้าใจ โดยทุกข้อเสนอสามารถอ้างอิงเอกสารต้นทางได้
3. Audio Overview กำหนดให้เป็นการเรียนรู้แบบหลายโมดัล (multimodal) เพื่อให้ผู้ใช้งานเกิดภาพรวมเชิงมโนทัศน์เพื่อทบทวน หรือเรียนรู้เพิ่มเติมควบคู่กับลิงก์การอ้างอิงกลับยังแหล่งที่มา
4. Retrieval-before-Synthesis กำหนดให้ระบบดึงข้อความ/หน้า/หลักฐานที่เกี่ยวข้องสูงสุด โดยแสดงผลแบบเปรียบเทียบหรือสรุปเป็นภาพรวมได้
5. Progress-Monitoring & Reflection กำหนดให้ระบบสามารถตรวจสอบรายการเพื่อให้ผู้เรียนสามารถสร้างสรุปเป็นประเด็นย่อยๆ พร้อมการอ้างอิงได้

ดังนั้น แนวคิดนี้จึงมุ่งหวังให้ผู้ใช้งานสามารถกำหนดเป้าหมาย วางแผน และปรับแผนการเรียนรู้ได้ด้วยตนเอง พร้อมหลักฐานอ้างอิง (citations) เชื่อมกลับไปยังแหล่งข้อมูลจริงในทุกขั้นตอนของการใช้งาน เพื่อเป็นการพัฒนาทักษะวางแผน-ติดตาม-สะท้อนคิดของผู้ใช้งาน โดยเฉพาะช่วงตั้งเป้าหมาย/วางแผน ที่ AI จะมีส่วนช่วยเป็นพี่เลี้ยงในการสร้างเค้าโครงการค้นคว้า การสืบค้นข้อมูล รวมถึงการช่วยในการวิเคราะห์ข้อมูลอย่างมีระบบมากยิ่งขึ้น ทั้งนี้เพื่อเป็นลดเวลาค้นหาและเพิ่มความคล่องตัวในการทำความเข้าใจประเด็นหลักของเอกสาร/คลังข้อมูลขนาดใหญ่ และสุดท้าย คือ การสร้างกรอบธรรมาภิบาลในการใช้งานที่วัดได้ ถือเป็นความจำเป็นมากในงานใช้งาน AI ในยุคปัจจบัน เพราะตัวชี้วัด คือ กระบวนการติดตามที่เชื่อมกับกรอบกำกับดูแลสมัยใหม่ เช่น citation/verification rate, audit trail ของการเรียนรู้ด้วยตนเอง และมีส่วนช่วยให้การทำงานของผู้ใช้งานมีประสิทธิภาพและมีความน่าเชื่อถือของข้อมูล

บทสรุป (Conclusion)

บทความวิชาการนี้ ชี้ให้เห็นแนวทางบูรณาการการจัดการความรู้เชิงองค์กร (KM) กับขีดความสามารถของโมเดลภาษา (LLM) ผ่านเทคนิค Retrieval-Augmented Generation (RAG) และ Source-grounding เพื่อรับมือกับข้อมูลท่วมท้น และข้อมูลไม่เป็นโครงสร้างอย่างเป็นระบบ ผลลัพธ์ที่คาดหวังและตรวจวัดได้จริง คือ การลดเวลาในการเข้าถึงแก่นความรู้ (time-to-insight) ความแม่นยำของสรุปและการอ้างอิงที่สูงขึ้น และอัตราการตรวจสอบแหล่งที่มาที่ดีขึ้น ทั้งในระดับงานวิชาการและการตัดสินใจเชิงบริหารขององค์กรภาครัฐ เอกชน และหน่วยงานคณะสงฆ์

กรอบ KM แบบ 5 ขั้น (Ingest ⟶ Index & Chunk ⟶ Grounding Policy ⟶ Retrieval-before-Generation ⟶ Central KB) ทำหน้าที่แปลงแฟ้มงานกระจัดกระจายให้เป็นคลังสมองส่วนกลาง ที่เข้าถึง-ค้นคืน-สังเคราะห์-ตรวจสอบย้อนกลับได้ พร้อมควบคุมด้วยธรรมาภิบาลความรู้ เพื่อลดความเสี่ยงจาก AI hallucination ขณะเดียวกัน แนวคิด AI-Augmented Work (IAW) ย้ำบทบาทของ AI ในฐานะส่วนขยายของสติปัญญามนุษย์ โดยมนุษย์ยังเป็นผู้ตัดสินใจหลัก และใช้ AI เป็นผู้ช่วยด้านการค้นคืนหลักฐาน สังเคราะห์ และจัดกรอบทางเลือกอย่างโปร่งใส

ด้าน การเรียนรู้ด้วยตนเอง (SDL) การใช้ Notebook Guide และ Audio Overview ช่วยให้ผู้เรียนสร้างเส้นทางการเรียนรู้เฉพาะบุคคล (Personalized Learning Path) ที่สอดคล้องเป้าหมายและจังหวะของตนเอง โดยยังยึดโยงกับแหล่งข้อมูลจริงผ่าน RAG/Source-grounding จึงช่วยยกระดับทักษะกำกับตนเอง และคุณภาพผลลัพธ์การเรียนรู้ได้อย่างมีนัยสำคัญ ทั้งหมดนี้ทำให้กรอบงานในบทความเป็น ทางเดินปฏิบัติ (operational pathway) ที่เชื่อมศักยภาพ context window ยาวของ LLM เข้ากับเวิร์กโฟลว์ความรู้ที่ตรวจสอบได้ในองค์กรอย่างเป็นรูปธรรม

อย่างไรก็ตาม ความสำเร็จของการใช้งานจริงยังขึ้นกับคุณภาพแหล่งข้อมูลและการกำกับดูแล หากขาดนโยบายแหล่งอ้างอิงที่ชัดเจน มาตรฐานการจัดทำดัชนี/แบ่งส่วนเอกสาร (chunking) ที่เหมาะสม และกระบวนการทบทวน ก็อาจลดทอนความน่าเชื่อถือของผลสรุปลงได้ ข้อเสนอแนะคือให้เดินหน้าตามแผนสามชั้น ได้แก่ (ก) พื้นฐานโครงสร้างจัดทำชุดแหล่งข้อมูลอนุญาต (Approved Sources) ผสานกับมาตรฐานเมทาดาตา (ข) เครื่องมือและเวิร์กโฟลว์ การตั้งค่า RAG/Source-grounding ผสานกับการเปิดใช้การอ้างอิงอัตโนมัติและนิยามบทบาทมนุษย์-AI ใน IAW และ (ค) ธรรมาภิบาลและตัวชี้วัด การกำหนดตัวชี้วัด (time-to-insight, accuracy, citation/verification rate, reuse, decision quality) ควบคู่การทบทวนคุณภาพอย่างสม่ำเสมอ เพื่อให้ระบบความรู้มีความยั่งยืนและตรวจสอบได้ในระยะยาว

เอกสารอ้างอิง

AIGN Global. (2026). *ASGR Outlook 2026: The global signal for AI governance readiness*.

Eppler, M. J., & Mengis, J. (2004). The concept of information overload: A review of literature from organization science, accounting, marketing, MIS, and related disciplines. The Information Society, 20(5), 325–344. https://doi.org/10.1080/01972240490507974

Gandomi, A., & Haider, M. (2015). Beyond the hype: Big data concepts, methods, and analytics. International Journal of Information Management, 35(2), 137–144. https://doi.org/10.1016/j.ijinfomgt.2014.10.007

Garrison, D. R. (1997). Self-directed learning: Toward a comprehensive model. Adult Education Quarterly, 48(1), 18–33. https://doi.org/10.1177/074171369704800103

Hilbert, M., & López, P. (2011). The world's technological capacity to store, communicate, and compute information. Science, 332(6025), 60–65. https://doi.org/10.1126/science.1200970

Ji, Z., Lee, N., Frieske, R., Yu, T., Su, D., Xu, Y., Ishii, E., Bang, Y., Madotto, A., & Fung, P. (2023). Survey of hallucination in natural language generation. ACM Computing Surveys, 55(12), 1–38. https://doi.org/10.1145/3571730

Karpukhin, V., Oguz, B., Min, S., Lewis, P., Wu, L., Edunov, S., Chen, D., & Yih, W.-T. (2020). Dense passage retrieval for open-domain question answering. In Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP) (pp. 6769–6781). Association for Computational Linguistics. https://doi.org/10.18653/v1/2020.emnlp-main.550

Lane, J. (2026). *A possible approach for evaluating AI standards development* (NIST GCR 26-069). National Institute of Standards and Technology. https://doi.org/10.6028/NIST.GCR.26-069

Lewis, P., Perez, E., Piktus, A., Petroni, F., Karpukhin, V., Goyal, N., Küttler, H., Lewis, M., Yih, W.-T., Rocktäschel, T., Riedel, S., & Kiela, D. (2020). Retrieval-augmented generation for knowledge-intensive NLP. Advances in Neural Information Processing Systems, 33, 9459–9474. https://proceedings.neurips.cc/paper/2020/hash/6b493230205f780e1bc26945df7481e5-Abstract.html

Maynez, J., Narayan, S., Bohnet, B., & McDonald, R. (2020). On faithfulness and factuality in abstractive summarization. In Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics (ACL 2020) (pp. 1906–1919). Association for Computational Linguistics. https://doi.org/10.18653/v1/2020.acl-main.173

Press, O., Smith, N. A., & Levy, O. (2021). Shortformer: Better language modeling using shorter inputs. In Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics (ACL 2021) (pp. 5493–5505). Association for Computational Linguistics. https://doi.org/10.18653/v1/2021.acl-long.426

Roe, J., & Perkins, M. (2025). *Generative AI in self-directed learning: A thematic scoping review.* Interactive Learning Environments. https://doi.org/10.1080/10494820.2025.2603431

Zimmerman, B. J. (2002). Becoming a self-regulated learner: An overview. Theory Into Practice, 41(2), 64–70. https://doi.org/10.1207/s15430421tip4102_2