

MBSE/MBD連携と生成AI(LLM)活用による e-Axleシステム開発の効率化

勝城 勝* 川島 一訓* 河住 拓郎* 佐藤 正太** 樫谷 純治***

抄 録

e-Axle開発の効率化に向け、ドキュメント中心のシステムズエンジニアリングをデジタル化し、生成とAI連携させる取り組みを行った。デジタル化ではメタ構造を策定し、ツール依存のあいまいさを抑える仕組みを整え構造を統一化。AI連携ではベクトルRAG (Retrieval-Augmented Generation) とグラフRAGを比較し、関係追跡に強いグラフRAGが高精度な情報抽出と、AI回答根拠の可視化による設計者の妥当性検証に有効であることを示した。(1)

1. まえがき

近年、電動車の急速な普及に伴い、e-Axle（電動アクスル）においては、熱の管理や有効利用も含むシステム開発の質の向上と効率化が重要な課題となっている。

従来の設計プロセスでは、システムズエンジニアリング (SE) の概念を導入してR-F-L-P (Requirements, Functions, Logical, Physical) に基づく情報管理を実施していた(2)。しかし、図1のような膨大なSE情報が階層別、システム別に分かれた多数のドキュメントとして管理されているため、設計者は異なる階層のドキュメント間を行き来しながら必要な情報を探し出さなければいけない。例えばある設計値の変更がシステム全体にどのような影響を与えるかを確認するだけでも多大な手間がかかるという問題があった。

一方、昨今生成AI（大規模言語モデル：LLM）が著しく進歩している。SEの分野ではMBSE (Model-Based Systems Engineering) のシステム要求を生成AIに学習させるアプローチ(3)が報告されている。

本研究では、複数階層にわたるR-F-L-PにMBSEを適用し、図2に示すようにMBSEを土台とし、生成AIと連携した情報抽出の効率化と、MBD (Model-Based Development) と連携した解析準備・結果共有の効率化を図り、開発スピードアップと競争力の向上を目指す。

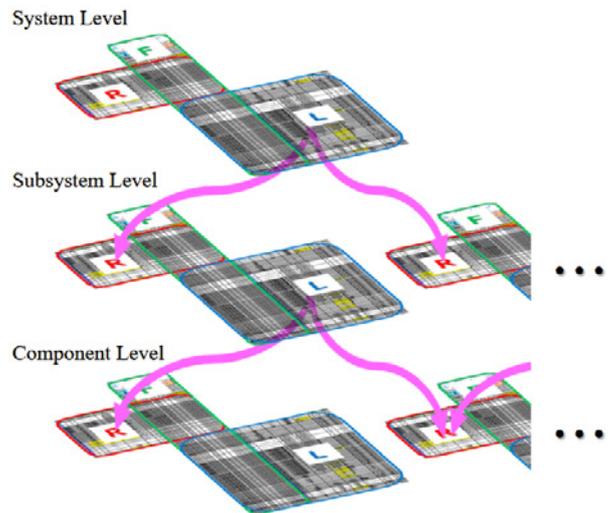


Fig. 1 SE Management form

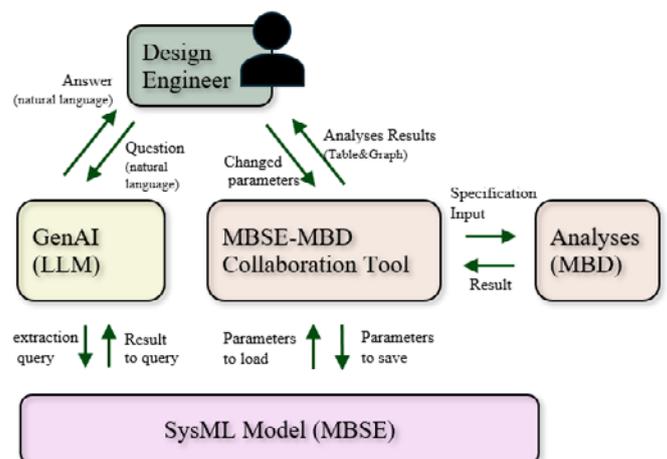


Fig. 2 Overview of this research initiative

2. MBSE の構築

MBSEはデジタルモデルを中心にシステムズエンジニアリングを行うアプローチで、SysML (Systems Modeling Language) を使ってモデル化される。従来のドキュメント形式のSE情報をもとに本研究の土台となるMBSEモデルを構築する際、SysMLツールの自由度や設計者の個人差によって土台のMBSEモデルの構造が統一されていない場合、生成AIと連携しても得られる回答が不正確になってしまう懸念がある。このためMBSEモデルの構造に統一性を持たせるルールとしてメタ構造を定義し、それに従ったモデル構築を可能とする実装手法を提案する。メタ構造は、公開情報⁴⁾を参照しつつ、従来のSE管理帳票の運用に沿うようR-F-L-Pを階層ごとに管理している点を考慮し、階層間の受渡しを上位Pと下位Rを接点とし、図3のような階層構造とした。

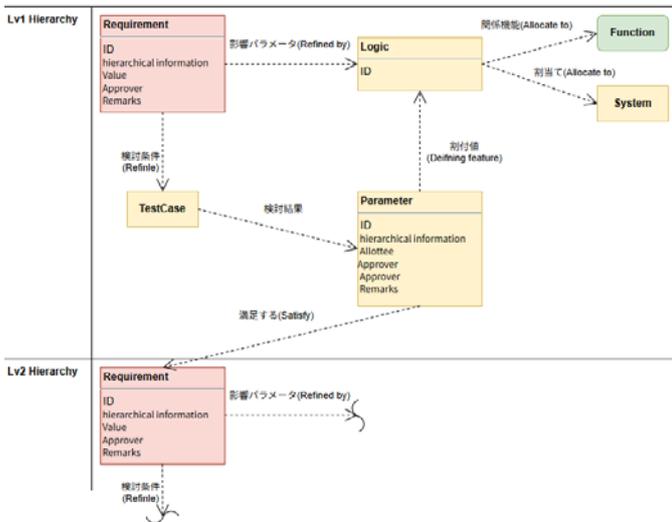


Fig. 3 MBSE Meta Structure

またメタ構造に従ったモデルの実装手法はフレームワークとバリデーションルールの2つで構成する。

- フレームワーク：あらかじめ用意された馴染みのある図表に順に情報を入力していくと、メタ構造に沿った要素間の関係性が自動的に定義され、MBSEモデルの構造が形成される仕組み。図4に一例を示す。
- バリデーションルール：各要素が持つ関係性を確認し、抜けや誤りがあれば検出して通知する仕組み。表1に一例を示す。

これらの実装手法によって、効率化の土台となる統一性をもったMBSEモデルの構築が可能となった。

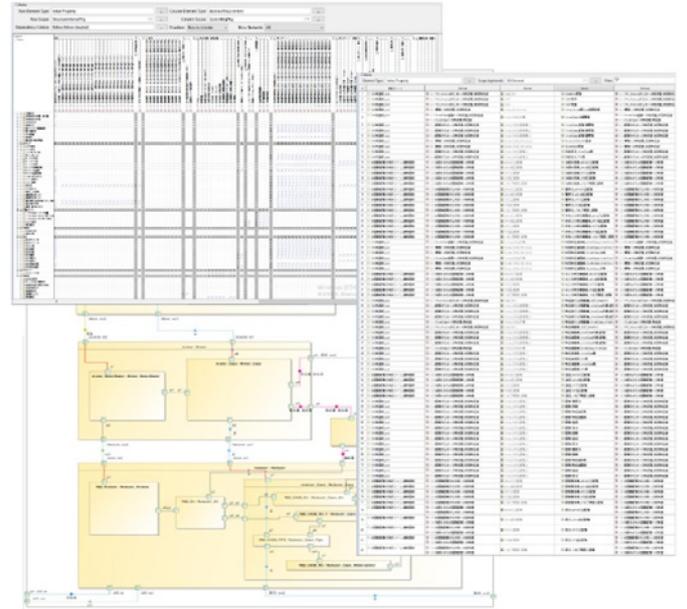


Fig. 4 Example of MBSE modeling Framework

Table 1 Example of MBSE Validation Rule

#	Element	ValidationRule
1	Requirement	Requirementの Refine 先はTestCaseのみであること
2	Requirement	Requirementを Refine するのはLogic, TestCaseのみであること
3	Requirement	RequirementはLogicから satisfy されている必要がある
4	Requirement	RequirementはLogicから Refine されている必要がある
5	TestCase	TestCaseの Refine 先はRequirementのみであること
6	TestCase	TestCaseを Refine するのはRequirement, TestCaseのみであること
7	Function	Functionを Refine する要素はないこと

3. MBSE と生成 AI の連携による設計支援図

従来の異なる階層のドキュメント間での情報抽出を効率化するため、前章で構築したMBSEモデルを生成AIと連携させる。検索に基づく連携手法として、以下に示す二つのアプローチで検証を行った。

一つ目はベクトルRAG (Retrieval-Augmented Generation) と呼ばれる手法である。この手法では、MBSEモデルを適切な単位で区分し、各区分を数値ベクトルに変換する。設計者のクエリも同様にベクトル化し、両者の類似度に基づいて関連性の高い情報を上位n件の範囲で検索・取得する。文脈や意味の類似性に基づいて検索が行えるため、汎用性の高さが特徴である。

二つ目はグラフRAGと呼ばれる手法であり、検索対象をナレッジグラフとして表現する。情報の実体をノード、各情報間の関係性をエッジで表現することにより、類似度のみに基づくベクトルRAGと比較して、情報間の関係性の捕捉や網羅性の観点で検索精度の向上が期待できる。本研究で構築したMBSEモデルにおいては、メタ構造が維持されるようにナレッジグラフへの変換を行った。図5にグラフRAGの構成を示す。設計者が質問を行うと、生成AIは回答に必要な情報を取得するためのクエリを自動生成し、ナレッジグラフへ照会する。ナレッジグラフから得られた情報と質問内容を照合した上で、最終的に生成AIが適切な回答を生成する。なお、クエリ生成の精度向上のため、質問と適正なクエリのセットを訓練データとして学習させるFew-Shot Learningを後述するパターンごとに実施している。

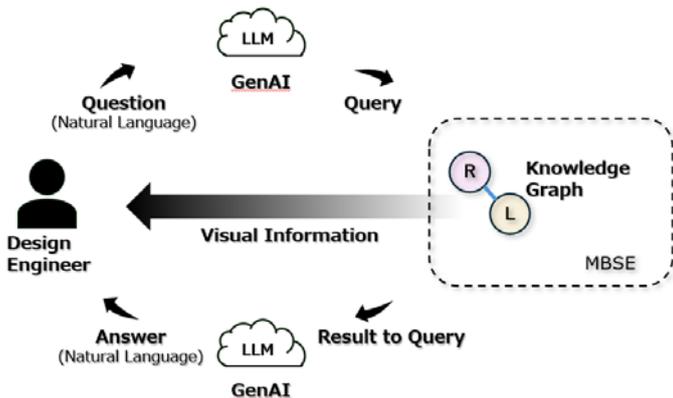


Fig. 5 Configuration of Knowledge Graph RAG

両設計支援手法の効果を検証するため、実際の設計現場を想定した質問集を用意し（表2）、4つの質問パターン（A～D）ごとに回答精度を評価した。その結果を図6に示す。ベクトルRAGではパターンAについてのみ正答が得られたが、パターンB, C, Dでは正答に至らなかった。一方、グラフRAGではすべてのパターン（A, B, C, D）において高い正答率を示した。

Table 2 Question Pattern Classification for Generative AI Response

パターン	分類	質問例
A	特定の要素の情報抽出	モータコイル温度[℃]の要求値は？
B	特定のサブシステム、部品内での関係性抽出	〇〇部品のA寸法を決めている要求をすべて抽出して
C	階層を跨いだ関係性の抽出	〇〇部品のA寸法を変更した場合影響を受ける他部品の寸法は？
D	影響度の高い要素の抽出	e-Axleユニットにおいて最も影響度が高い要求の上位3位を教えてください

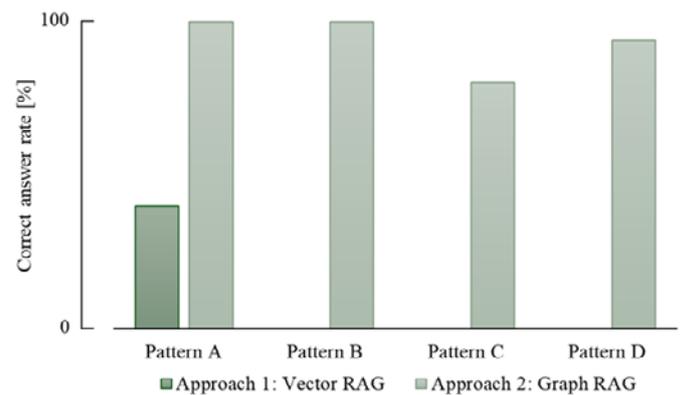


Fig. 6 Generative AI Response Accuracy Evaluation Results

特に、パターンDのようなモデルの目視だけでは把握しにくい影響度の大小の観点で設計パラメータを容易に抽出できることが確認された。実際の質問およびグラフRAGにおける回答例を図7に示す。この回答例では、ナレッジグラフからはノードの固有ベクトル中心性を計算した結果が返されている。

質問
e-Axleユニットにおいて最も影響度が高い要求の上位3位を教えてください

回答
影響度が大きい要求を上位3つ挙げます。同じ順位で複数存在する場合はむれなく抽出します。

1. **性能 (Score: aaa)
1. **性能 (Score: aaa)
2. **周波数 (Score: bbb)
3. **性能 (Score: ccc)
3. **条件 (Score: ccc)

これらの要求が影響度の大きい要求として挙げられます。

Fig. 7 Practical Example of Q&A in the Graph RAG Approach

また、生成AIによる回答結果と併せて、設計者が直接ナレッジグラフを参照することで、複雑な依存関係の視覚的な把握とともに、回答結果の検証が可能となる。ナレッジグラフ全体から回答に用いた参照先を抽出して可視化した例を図8に示す。

以上の結果より、メタ構造が重要な要素であるMBSEモデルにおいては、グラフRAGの手法を用いることで情報抽出を高精度で効率的に行えることが確認された。

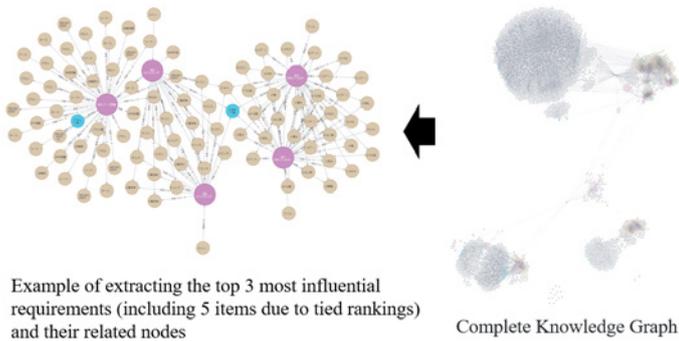


Fig. 8 Example Visualization of the Queried Knowledge Graph

4. MBSE モデル構築による解析の効率化

図1のような情報の分散は解析にも影響しており、具体的には最新情報の確認、解析の入力や結果の整理などに多大な手間がかかるという問題があった。これに対し統一構造化されたMBSEモデルを構築することで、MBSE-MBD連携ツールを介した解析とシームレスな接続が可能となった。この連携により設計者の手間が軽減され、効率化できるようになる。

実際に、このMBSE-MBDの連携を小規模な設計プロセスに適用して効果を確認した。熱マネジメント解析での仕様決めにて運用した流れを図9に示す。

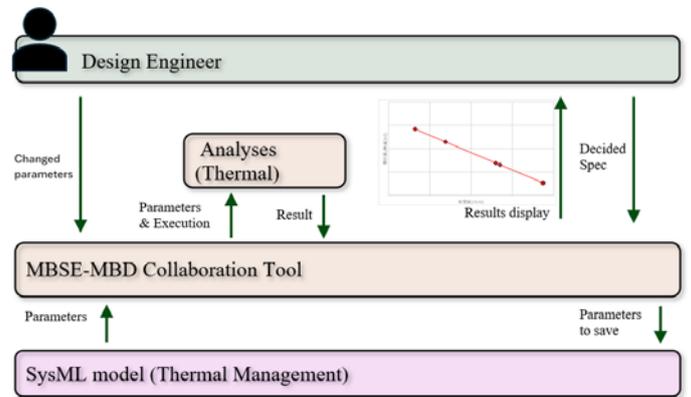


Fig. 9 Example of applying MBSE-MBD collaboration

MBSE-MBD連携により設計者は入力条件設定と結果整理の作業を自動化でき、解析業務を通して3割の時間削減ができることが確認できた（図10）。

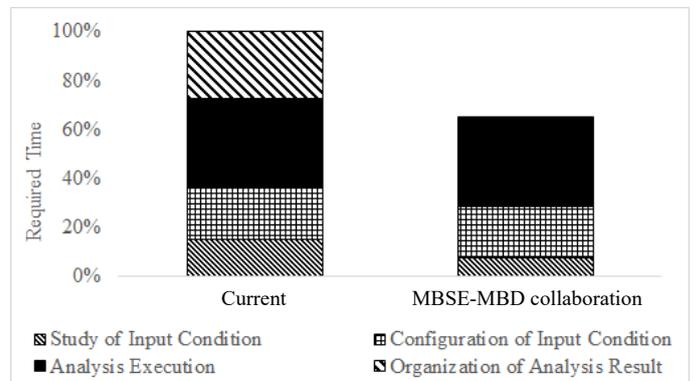


Fig. 10 Efficiency from MBSE-MBD collaboration

5. まとめ

本研究では、ドキュメント形式のSE情報をMBSEモデルとして再構築し、これを活用することで解析（MBD）や生成AIによる情報抽出の効率化を行った。特に生成AIとの連携においては、ベクトルRAGと比較して、ナレッジグラフを用いるグラフRAGの優位性が示された。グラフRAGにより、高精度かつモデルの構造を反映した情報抽出が可能になることを確認した。また、MBSEモデル構築を通じてMBDと連携することで、解析作業自体も効率的に実施できることを示した。

今後は、階層間を跨ぐ関係性の経由数が多い質問など、現状では正確な回答が得られない質問に対する精度向上を目指す。さらには、設計者からの質問に直接回答するだけでなく、関連する品質課題情報や過去の設計知見を設計者に提供したり、潜在的なリスクを予測したりするなど、設計者の思考を補完・拡張する、より能動的な支援ツールへと発展させていく。また、MBD連携ツールの操作など、現状では人手による作業が残されている領域にも生成AIの適用範囲を拡大し、設計プロセス全体のさらなる効率化を実現する。

将来的には、設計者の意図を理解し、自律的にパラメータ選定や最適化の解析を実行して結果を解釈し、次のアクションを提案できるAIエージェントへと進化させることで、設計者がより創造的な業務に集中できる環境の構築を目指す。

6. 参考文献

- (1) 勝城勝, 川島一訓, 河住拓郎, 佐藤正太, 樫谷純治: MBSE/MBD連携と生成AI (LLM) 活用によるe-Axleシステム開発の効率化, 2025年春季大会 学術講演会予稿集 (春), (公社)自動車技術会, 2025年, pp.1-4, 許諾を得て転載
- (2) 望月勉, 道岡浩文: トランスミッション開発におけるシステムズエンジニアリングの導入～MBSE活用への取り組み～, ジヤトコテクニカルレビュー, No.19, p.19-28 (2020)
- (3) Braxton VanGundy, Nipa Phojanamongkolkij, Ramana Polavarapu, Barclay Brown, Joshua Bonner: Requirement Discovery Using Embedded Knowledge Graph with ChatGPT, 34th Annual INCOSE international symposium, p.2011-2027 (2024)
- (4) Aistė Aleksandravičienė, Aurelijus Morkevičius: MagicGrid® BOOK OF KNOWLEDGE A Practical Guide to Systems Modeling using MagicGrid from Dassault Systèmes 2nd edition, Lithuania, Vitae Litera, UAB, 2021, 350p

■ 著者 ■



勝城 勝



川島 一訓



河住 拓郎



樫谷 純治