

Think-on-Graph を用いた故障分析支援手法の検討

Investigation of Failure Analysis Support Method Using Think-on-Graph

○石川達将（日立製作所）^{*1} 宮田康志（日立製作所）^{*2} 湯田晋也（日立パワーソリューションズ）^{*3}

^{*1} Tatsumasa Ishikawa, Hitachi, Ltd., 1-280 Higashikoigakubo, Kokubunji City, Tokyo, Japan, 185-8601, tatsumasa.ishikawa.ge@hitachi.com

^{*2} Yasushi Miyata, Hitachi, Ltd., 1-280 Higashikoigakubo, Kokubunji City, Tokyo, Japan 185-8601, yasushi.miyata.bz@hitachi.com

^{*3} Shinya Yuda, Hitachi Power Solutions Co.,Ltd., 3-2-2, Saiwai-cho, Hitachi-shi, Ibaraki, Japan, 317-0073, shinya.yuda.cv@hitachi.com

キーワード: Graph RAG, 知識グラフ, 故障分析支援, Design 知識, AI・IoT デザイン

1. 緒 言

近年, 少子高齢化による熟練作業員の引退や人材流動化, 高学歴化等の背景を受け, 保守人員の必要量に対し供給量が不足している⁽¹⁾⁽²⁾. このような状況下では, 少ない人材で効率よく保守作業を進めるための支援システムの構築が重要と考えられる. 特に, 保守業務で頻発するアラートや故障の原因分析業務では, 機械工学, 電気工学, 制御工学などの幅広い知識や製品の構造に関する知識が必要なことに加え, 1 つの故障が連鎖的に他の部品の故障を引き起こすことや, 機械, 電気, 制御, 環境要因が複雑に絡み合うことがあり, 故障の原因特定に困難を伴うことがある. このように, 故障分析業務は原因特定の困難さ故に分析作業を効率よく進めることが難しく, 支援システムの構築が重要な業務だと考えられる.

上記のような原因特定の困難さを解決するため, 従来はエキスパートシステムやベイズネットワークなどの知識ベースシステムが用いられてきた⁽³⁾⁽⁴⁾. また, 機械学習を用いた故障診断手法も提案されている⁽³⁾⁽⁴⁾. しかし, これらの手法は事前に故障パターンを定義する必要があり, 複雑で多様な故障シナリオに対応することが困難である. また, 新たな故障パターンが発生した場合, システムの再構築や再学習が必要となるため, 保守現場での迅速な対応が難しい⁽⁴⁾.

大規模言語モデル (LLM) の登場により, テキスト理解と推論能力が飛躍的に向上した. LLM は事前学習により幅広い知識を保有しており, 新たなタスクに対しても柔軟に対応できる⁽⁵⁾. さらに, Retrieval-Augmented Generation (RAG) と組み合わせることで, 外部知識を動的に参照しながら回答を生成することが可能になる⁽⁶⁾. 特に, Graph RAG の一手法である Think-on-Graph (ToG)⁽⁷⁾は, 知識グラフ上で LLM が動的にパス検索を進める手法であり, 複雑なシステムの構成や因果関係を効果的に検索・分析できると考えられる.

そこで本研究では, 機器やシステムの配管図, 単線結線図, 機能ブロック図, 流体の流れや動力の伝達関係をグラフ構造で表現した知識グラフと, ToG を組み合わせた故障

分析支援チャットシステムを提案する. 提案手法では, ユーザが入力した故障状況をクエリとして, LLM が知識グラフ上に表現された機器構成や接続関係を理解しながら動的にパスを検索し, 故障の根本原因を推定する, あるいは原因候補を列挙することが可能である. この手法により, 事前の故障パターン定義なしに, 多様な故障シナリオへ柔軟に対応できると期待される.

本論文では, 提案手法を風車保守, 特にドライブトレイン回りの故障分析に適用し, 実際の保守作業員による 5 段階評価を通じて, その有効性を検証した結果について報告する.

2. 提案する故障支援手法

2.1. 知識グラフの設計

知識グラフとは, ノードとエッジの集合で構成されるグラフの 1 種である. 知識グラフでは, 物体や人物, 事象といったエンティティ e をノードで表す. さらに, 関係 r をエッジで表現することで, 2 つのエンティティ e_1, e_2 間の関係 (e_1, r, e_2) を記述する.

提案手法では, LLM が故障分析対象の製品の部品構成を認識できるよう, 知識グラフに部品 e の関係 r を記述する. ここで, 部品同士の関係とは, 機器やシステムのアセンブリ図, 配管図, 単線結線図, 機能ブロック図などに記述されるような, 部品間の情報やエネルギー, 力のやり取りである.

表 1 関係 r のリスト

関係名	内容
FIX	締結する, 固定する
PROPAGATE_POWER_TO	動力を伝える
DYNAMICALLY_FIXES	制動する
DETECT_STATE_OF	状態検知する
SEND_SIGNAL_TO	信号を送る
SUPPLY_OIL_TO	潤滑油を供給する
HAS_ERROR_CODE	エラーコードを持つ

本論文では、発電用風車のドライブトレイン周りで発生するアラートをを用いて検証するため、表 1 の関係を用いて知識グラフを構築した。また、図 1 に構築した知識グラフの模式図を示す。なお、問合せで良く出現すると考えられるエラーコードと、対応するセンサー関連のコンポーネントとの対応を記述するため、エラーコードとセンサーの対応関係を HAS_ERROR_CODE で記述した。

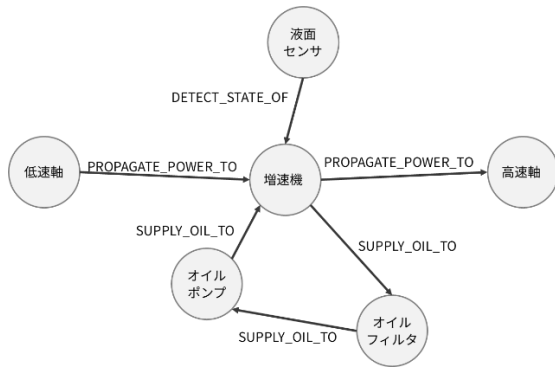


図 1 構築した知識グラフの模式図（一部）

2. 2. Think-on-Graph による故障分析

ToG は与えられた質問を基に、質問と関連する知識グラフ上のパスを検索し、回答を生成する技術である。提案する ToG を用いた故障分析の流れを以下に示す：

- Step 1 ユーザが入力した質問からキーワードを抽出する。抽出したキーワードを基に知識グラフのノードをベクトル検索し、探索の起点となるノードを決定し、検索パスとして設定する。
- Step 2 検索パスの末端ノードから距離 1 hop のパスを取得して、候補パスとする。
- Step 3 候補パスと質問を LLM に入力し、質問を回答するのに有益なパスを LLM に選択させる。選択されたパスを基に、検索パスを更新する。
- Step 4 現時点の検索パスで回答生成可能か LLM に判定させる。事前に設定したループ回数未満かつ、回答生成不可能の場合、Step 2 に戻る。
- Step 5 得られた検索パスを基に、ユーザが入力した質問に対する回答を生成する。

上記のように、LLM が知識グラフ上で推論し、パスを辿っていくことで、複雑なシステムの構成や因果関係を効果的に検索・分析できる。なお、Step 3 では、現論文を参考に、以下のプロンプトで LLM にパスを選択させた。

あなたは優秀な保守作業者です。あなたの仕事は、与えられた質問から、機器の部品構成とその関係が記述された知識グラフを参照して、故障原因を特定することです。

グラフデータベースから取得された各ノードについて、質問に対する回答を生成するのに有益なノードを選択してください。

質問：{query}

パス：{paths}

ここで、{query} はユーザから入力された質問、{paths} は

Chpher のパス表記で表記された候補パスである。また、Step 4 の回答生成可否判断では、以下のプロンプトを入力した。

あなたは優秀な保守作業者です。あなたの仕事は、与えられた質問から、機器の部品構成とその関係が記述された知識グラフを参照して、故障原因を特定することです。

ナレッジグラフから取得されたトリプレットから得られた知識のみに基づいて、質問に回答に答えることができるか判断してください。

質問：{query}

パス：{paths}

3. 実験条件

発電用風車で発生するドライブトレイン関連のアラーム 10 個に関する問い合わせを ToG に入力し、回答を生成した。さらに、生成した回答を 7 名の風車保守員に評価いただいた。評価は、各質問に対し表 2 の 5 項目を用いた 5 段階リッカート尺度を集計し、各項目の平均点を比較する。

表 2 アンケートの評価項目

項目	内容
1.	全て正しい (5) / 誤りが含まれている (1)
2.	重要な不具合原因がきちんと含まれている (5) / 含まれていない (1)
3.	これまでの事例としてであったことは無いが、自分の知識と照らし合わせて、あり得る故障や分析を提示していると感じる (5) / 一般的な事柄が多い (1)
4.	理由や部品間の関係が提示されていて納得感がある・理解しやすい (5) / 納得感がない・理解しにくい (1)
5.	現地作業や保守準備にあたって必要な情報が示されている (5) / 示されていない (1)

表 2 の項目番号 1 は出力の正確さを、2 は保守で頻発する重要な故障原因を示せたかを、3 は減多に表れないがありうる故障原因を提示できたか（未知の故障原因を示せるか）を、4 は理解しやすさを、5 は保守準備に必要な情報が提示できるかを評価する。

比較のため、AWS Kendra⁽⁸⁾を用いた RAG による回答生成も実施した。RAG の検索ソースにはアラームの対処要領や過去事例が書かれた文書を格納した。

実験には提案手法、RAG ともに、LLM として Anthropic Claude 3.5 Sonnet⁽⁹⁾を用いた。

4. 実験結果及び考察

図 2 に 5 段階リッカート尺度による各項目の平均点を示す。なお、図 2 横軸の項目番号は表 2 の項目番号と対応する。まず、項目 1 に関しては提案手法が 3.9 点、RAG が 4.1 点、項目 2 では提案手法が 3.9 点、RAG が 3.8 点と同程度であった。したがって、内容の正しさや、頻発する重要な

故障原因を示す能力は、提案手法は RAG と同程度と示唆される。一方、項目 3 は提案手法が 3.5 点、RAG が 2.7 点と得点差が見られた。これは、提案手法が RAG と比較し、様々な故障原因を提示可能であることを示唆するものと考ええる。また、わかりやすさを示す項目 4 は提案手法が 3.6 点、RAG が 2.8 点、保守に必要な情報を示したかを評価する項目 5 は提案手法が 3.4 点、RAG が 2.8 点となった。

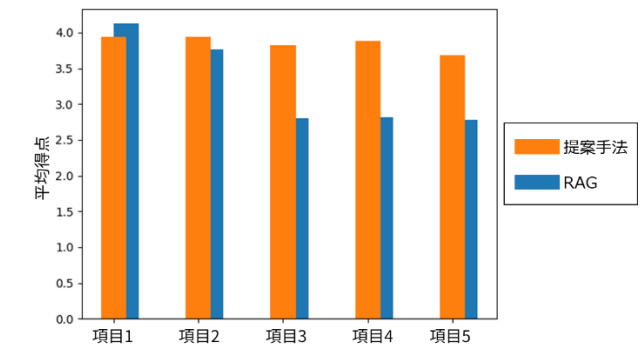


図 2 5 段階リッカート尺度による各項目の平均点

項目 4 及び 5 においても提案手法が RAG より高い得点を示した理由を考察するため、保守員による評価と同時に取得した自由記述によるコメントを表 3 にまとめる。

表 3 評価時に収集した提案手法に対するコメント

番号	コメント
1	言葉の補完や順序立てがされており、わかりやすい文章になっていた
2	図示等があるとさらにわかりやすいと感じた
3	制御盤図等で調査ケーブルの位置が分かりやすいと感じた
4	センサの場所、写真 (正常状態のもの) が欲しい
5	解説や点検提案が部品ごとに行われるため、理解しやすい
6	部品の特定がしやすい文章になっていた
7	手順に違いを感じた (増速機のシャフト点検のあとケーブル確認等、一般的な保守手順と違う)

表 3 の番号 1, 5 及び 6 より、部品間の関係や、部品の補足情報 (〇〇部に取り付けられた××部品など、部品を補足するような情報) が、わかりやすさや保守に必要な情報を示したと感じる要因であることが示唆される。

一方、表 3 から、図表を出力してほしいといったコメントや手順に違いがあるといったコメントが見られた。このことから、分析調査の手順を保守員が実際に実施しているものに近づける工夫や、回答生成時に図を提示する仕組みの構築が今後の課題と言える。

5. 結 言

本論文では ToG を用いた故障分析手法を提案した。また、提案した手法の初期調査として、提案手法の出力結果を 5 段階リッカート尺度による感性で評価した。評価の結果、既存の RAG と比べ、提案した手法は未知の故障を提示し

たり、保守員にとってわかりやすい分析結果を提示する能力が高いことが示唆された。このことから、ToG を用いた提案手法は、複雑なシステムの構成や因果関係を効果的に分析し、多様な故障シナリオへ柔軟に対応可能な故障分析支援システムになりうると思われる。

今後の課題としては、提案手法が生成する分析手順を実際の保守手順に近づけるための調整や、回答生成時に図表や写真を提示する仕組みを導入することで、理解性と納得感を一層高めることがあげられる。また、本論文の初期評価は故障事例 10 件、保守員 7 名という限定的な規模での感性評価を実施した。よって、故障事例及び評価者人数を拡大した感性評価の実施や、故障原因特定の精度評価、診断時間短縮効果の測定といった定量評価の実施も、今後の課題としてあげられる。

文 献

(1) 経済産業省：電気保安体制を巡る現状と課題：
https://www.meti.go.jp/shingikai/sankoshin/hoan_shohi/denryoku_anzen/hoan_jinzai/pdf/001_03_00.pdf (参照日 2025 年 10 月 16 日)

(2) 大和総研：人手不足の構造要因：
https://www.dir.co.jp/report/research/economics/japan/20231121_024096.pdf (参照日 2025 年 10 月 16 日)

(3) Leite, D., Andrade, E., Rativa, D., & Maciel, A. M. A.: Fault Detection and Diagnosis in Industry 4.0: A Review on Challenges and Opportunities. *Sensors*, Vol. 25(1), No. 60, 2025.

(4) Cao, Y., Tang, J., Shi, S., Cai, D., Zhang, L., and Xiong, P.: Fault Diagnosis Techniques for Electrical Distribution Network Based on Artificial Intelligence and Signal Processing: A Review, *Processes*, Vol. 13(1), No. 48, 2025.

(5) Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., Agarwal, S., Herbert-Voss, A., Krueger, G., Henighan, T., Child, R., Ramesh, A., Ziegler, D., Wu, J., Winter, C., Hesse, C., Chen, M., Sigler, E., Litwin, M., Gray, S., Chess, B., Clark, J., Berner, C., McCandlish, S., Radford, A., Sutskever, I., and Amodei, D. : Language models are few-shot learners, In *Proceedings of the 34th International Conference on Neural Information Processing Systems*, No. 159, 25, 2020.

(6) 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.: Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks. In *Advances in Neural Information Processing Systems*, Vol. 33, 9459–9474, 2020.

(7) Sun, J., Xu, C., Tang, L., Wang, S., Lin, C., Gong, Y., Ni, L., Shum, H., and Guo, J.: Think-on-Graph: Deep and Responsible Reasoning of Large Language Model on Knowledge Graph, In *Proceedings of the International Conference on Representation Learning*, 3868-3898, 2024.

(8) AWS : Amazon Kendra : <https://aws.amazon.com/jp/kendra/> (参照日 2025 年 10 月 16 日)

(9) Anthropic : Claude 3.5 Sonnet : <https://www.anthropic.com/news/claude-3-5-sonnet> (参照日 2025 年 10 月 16 日)