

ヒューマンエラー事象のテキストマイニング技術

A Text Mining Method for Human Error Events

ヒヤリハットのビッグデータを有効活用

ヒヤリハット事例は、ヒューマンエラーの発生傾向、因果関係、背景要因等の各種分析において有用性が高い。これまでにグループ会社全体で約50万件の膨大な事例が蓄積されているが、これらビッグデータを有効活用するための分析手段が十分検討されていない。そこで、本研究ではヒヤリハット事例を知識資産として活用するためのテキストマイニング技術を検討した。



執筆者
先端技術応用研究所
情報技術グループ
瀬川 修

1 背景と目的

テキストマイニング (Text Mining) とは、構造化されていない曖昧な言語情報から有用な知識を抽出する分析技術である。具体的には、文書に含まれる単語の統計量や意味的な関連性に基づき、カテゴリ分類、トピック抽出、キーワード分析などを実現する自然言語処理技術である。我々は、これまで顧客意見や学術情報を対象とした独自のテキストマイニング技術の開発を行い、ビッグデータの分析支援ツールとしての有効性を確認している。本稿では、最新の取り組みとして、ヒューマンエラー事象を対象とした分析手法の概要と有効性評価について述べる。

2 ヒヤリハット事例の分析

「ヒヤリハット」とは事故や災害につながりそうな事例を収集し、ヒューマンエラー防止に寄与する情報を共有する取り組みである。蓄積された事例データは、ヒューマンエラーの発生傾向、因果関係、背景要因等の各種分析において有用性が高い。これまでにグループ会社全体で約50万件の膨大な事例が蓄積されているが、ビッグデータを有効活用するための分析手段が十分検討されていない。そこで、本研究ではヒヤリハット事例を知識資産として活用するためのテキストマイニング技術を検討した (第1図)。以下、本稿では各種分析手法の中で、キーワード分析、対策立案、要約について主に大規模言語モデル (Large Language Model: LLM) に基づく手法について検討した結果を述べる。



第1図 ヒヤリハット事例のテキストマイニング技術

3 分析手法の概要

(1) 関連キーワード推定

特定の状況 (シチュエーション) を「交差点+危険+死角」のように単語の意味ベクトルの加減算によって合成し、当該文脈における関連キーワードを推定する手法を考案した。具体的には、何らかのシチュエーションを Word2Vec など自己教師あり学習に基づく言語モデルを用いて「単語分散表現」のベクトルで表現し、当該ベクトルに類似したキーワードを近傍検索することにより意味的に関連の深いキーワードを推定する。

(2) 因果関係分析

言語モデル BERT で用いられている Masked Language Model (MLM) を応用し、入力されたトークン系列のマスク箇所を推定することによって因果関係にある概念を推定する手法を考案した。複数のマスクがある場合は、ビームサーチによりマスク箇所のトークン系列を推定する。

(3) 対策立案

ヒヤリハットデータの約6割には、再発防止のための対策が記述されており、これらの情報は危険予知や対策立案などに有用な情報である。この約27万件の「事象と対策のペア」を知識源として、LLMの一種である T5 の事前学習モデルのファインチューニングを行い、検索質問の事象に対し適切な対策文を生成する手法を考案した。

(4) 要約

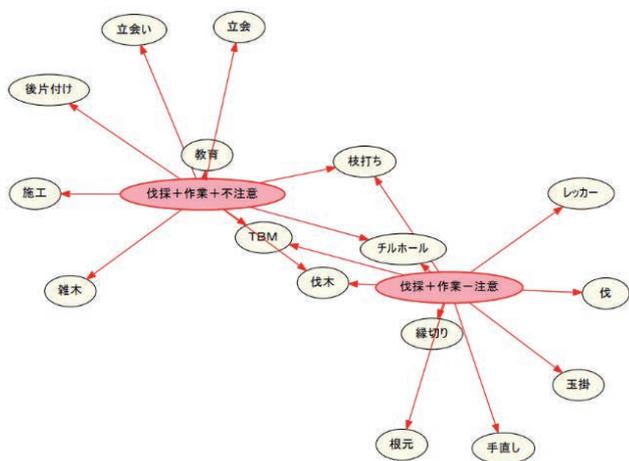
Transformer に基づく自己回帰型 LLM を用いた生成型要約手法について初期検討を行った。今回用いた LLM はオープンソースとして公開されている Llama2 の日本語モデル (ELYZA-Japanese-Llama-2-7b、パラメータ数70億)、および GPT-NeoX の日本語モデル (rinna/japanese-gpt-neox-3.6b、パラメータ数36億) である。

ここで、オープンソースの LLM を利用するメリットであるが、分野やタスクに特化した独自の学習 (ファインチューニング) が可能なこと。また、クローズドな環境で運用の内製化が可能ななどの点が挙げられる。

4 評価

(1) 関連キーワード推定

前述の手法により合成したシチュエーションに関連するキーワード推定の例を第2図に示す（ベクトル表現はWord2Vecを使用、上位10件を表示）。同図より「伐採+作業+不注意」と「伐採+作業-注意」では共通のキーワードが見られる。3種の言語モデル（Word2Vec, GloVe, BERT）について、前記2つのベクトル表現から得られる関連キーワード上位100件を調査したところ、Word2Vecでは63件が一致していた（第1表）。これより、「不注意」と「-注意」は潜在意味ベクトル空間で近接した位置にマッピングされていることが示唆される。



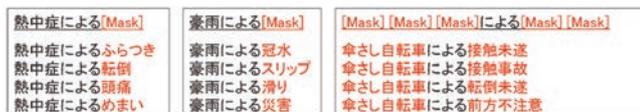
第2図 意味的なベクトル演算による関連キーワード推定例

第1表 関連キーワード上位100件の一致数
「伐採+作業+不注意」と「伐採+作業-注意」

Word2Vec	63
GloVe	35
BERT (文脈非依存)	52

(2) 因果関係分析

前述の手法により、因果関係にある概念を推定した例を第3図に示す。同図より、MLMの文脈による回帰予測によって因果関係にある概念を推定できることが確認された。



第3図 BERTのMLMに基づく因果関係分析の例

(3) 対策立案

前述の手法により、T5で生成した対策文の例を第4図に示す。LLMモデルの回帰予測によって、多様な対策（注意点）をまとめた文を生成できることが確認された。

検索質問:「運搬作業の準備」

重量物は二人以上で運搬する。
運搬前に運搬経路の確認を行う。
重量物は複数人で運搬する。
台車を活用する。
「かもしれない」を常に意識して行動する。
カバン等を活用して運搬する。
事前に運搬ルートを確認しておく。

第4図 T5で生成した対策文の例

(4) 要約

初期実験として、前記2種類のLLMの事前学習モデルに対し、ファインチューニングの有無、およびプロンプトの与え方（第5図）の条件を変えて性能評価を行った。ファインチューニングではヒヤリハット事例の発生概要（要約）と発生状況（原文）のペアを用いた。評価データはヒヤリハット10事例の「発生状況」について各5文の要約を生成し、正解の「発生概要」と比較した。

評価指標は要約タスクで標準的に用いられているROUGEを用いた。ROUGE-1, 2は、生成文と正解文の間のN-gramの一致率を表し、ROUGE-Lは、一致した単語系列のうち最も長い系列の一致率である。評価結果を第2表に示す。

同表より、まずファインチューニングの有無に着目すると、両モデルともにヒヤリハットデータで学習した方が良好な性能が得られており、事前学習モデルに対し要約タスク、ドメインへの最適化がなされている。また、プロンプトについては、Llama2 (ELYZA) で要約の例示なし (Zero-shot) と例示あり (Few-shot、2件例示) を比較したところ、Few-shotのほうが、より想定に近い要約文を生成できることが確認された。モデルの比較では、全般にLlama2 (ELYZA) が良好な性能を示した。

(Zero-shot)	### 指示: 以下の文章を要約して下さい。
(Few-shot)	### 指示: 以下に示す入力と応答の例を参考にして、原文を要約して下さい。 ### 入力: 9月の週末に外出した際、想定以上の暑さで… ### 応答: 残暑による熱中症に注意。 … (以下、例示の繰り返し) ### 原文: 帰宅のため自転車で変則型の小さな交差点に…

第5図 プロンプトの例

第2表 LLMによる要約性能の評価

Model	Fine-tuning	Prompt	ROUGE-1	ROUGE-2	ROUGE-L
Llama2 (ELYZA)	なし	Zero-shot	20.2	6.4	16.8
GPT-NeoX (rinna)	なし	Zero-shot	10.1	1.1	8.4
Llama2 (ELYZA)	ヒヤリハット	Zero-shot	20.3	12.0	18.8
Llama2 (ELYZA)	ヒヤリハット	Few-shot	38.0	19.0	36.7
GPT-NeoX (rinna)	ヒヤリハット	Zero-shot	20.2	3.3	19.0

5 まとめ

本研究では、大規模言語モデルなどに基づくテキストマイニング手法を用いて、ヒヤリハットのビッグデータ分析技術の検討と実データによる有効性評価を行った。提案手法はグループ会社における安全管理などへの活用が期待される。（本研究は(株)中電シーティーアイとの共同研究として実施した）