

失敗知識データベースを用いた失敗事象の原因分析

粟納 裕貴[†] 馬 強^{††} 吉川 正俊^{††}

[†] 京都大学工学部情報学科 〒 606-8501 京都市左京区吉田本町

^{††} 京都大学大学院情報学研究科 〒 606-8501 京都市左京区吉田本町

E-mail: [†]awano@db.soc.i.kyoto-u.ac.jp, ^{††}{qiang,yoshikawa}@i.kyoto-u.ac.jp

あらまし プロジェクトや事故の失敗原因の分析は、失敗の予防や再発防止に重要である。本研究では、失敗知識データベースからトピック・文書・原因の関係を LDA(Latent Dirichlet Allocation) および単純パーセプトロンを利用して学習し、新規事象の失敗原因を推定する手法を提案する。提案手法は失敗事象の理解や失敗知識データベースの構築の支援に利用できる。JST 失敗知識データベースを利用した評価実験を行い、提案手法の有効性を確かめた。

キーワード 失敗知識データベース, 機械学習, 原因分析, LDA

1. はじめに

多くの企業や組織において、事故や不祥事などの失敗が再発しないよう過去に発生した事故や問題を集めた事例集が作成されている。それらの中には、発生した事象の記録のみでなく、事象を個別に専門家が分析をし、短い単語や文章により事象の構造や解説を付与しているものもある。それらのデータベースを、本論文中においては、失敗知識データベースと呼ぶ。

失敗知識データベースの多くは企業内や組織内で作成され、アクセスができないが、行政機関などが作成しており、一般の人がアクセスすることができるデータベースも存在する。失敗知識データベースの中で、一般の人がアクセス可能なものとして、JST 失敗知識データベース [1] やベンチャー企業の経営危機データベース [2] などが挙げられる。

しかし、膨大な時間とコストをかけて構築したにも関わらず、その作成に見合う十分な活用はされていない。JST(独立行政法人科学技術振興機構)はその原因が「失敗知識の伝達」がうまくいっていないことであるとし、失敗知識の構造を明らかにすることが重要であるとし、シナリオと呼ぶ失敗知識の構造を付与した JST 失敗知識データベースを構築した。しかしながら、このような人手によって作成された失敗知識データベースは、社会活動における次々と発生する新しい失敗事象への対応が困難である。

そこで、本論文では失敗知識データベースの活用の方法として、既存の失敗知識データベースを利用して、新しく与えられた事象の原因を推定する手法を提案する。新規事象の原因を推定することで、その事象の理解の促進、また、失敗知識データベースに新規登録する支援などが期待できる。

類似する事象には類似する原因が存在する可能性が高い。そこで、新しい事象が与えられたとき、既存の失敗知識データベース内からその類似事象を求め、その原因を返すことで類似する事象の原因を推定する。

しかし、ここで新しい事象に類似する事象を求めることに課題がある。それは、新規事象に類似する求められるべき事象は、「字面として類似している」事象ではなく、「事象の状況や一連

の行動・動作が類似している」事象である必要があるためである。したがって、索引語を作成し TF・IDF などを利用して類似度を求めたとしても、それは字面としての類似度を求めることとなりがちであり、求めるべき類似事象を求めることはできない。

表 1 は JST 失敗知識データベースから取得してきた二つの事例である。両事例ともに、JST 失敗知識データベースの「機械」のカテゴリに分類されている事例である。「機械」カテゴリの全事例を全集合として全事例間の TF・IDF のコサイン類似度を求めた場合、その平均値は 0.0198 である。その中で、事例 e1 と事例 e2 のコサイン類似度は 0.189 であり、平均より高く類似している事象とされる。事例 e1 はクレーンの歯車が疲労により破損した事例である。事例 e2 は歯車の材質が不適当でかみあい騒音が大きくなった事例である。

事例 e1 と事例 e2 はその状況や行動が明らかに異なる。しかし、どちらも TF・IDF においては高い類似度を示している。これは歯車というキーワードを含んでいるためであると考えられる。このように TF・IDF においては類似する単語が出現していると類似していると判断され、字面での類似に引きずられる。

そこで、既存のデータベース内の事象を利用して、新しい事象の原因を求めるにあたって、本論文では各カテゴリごとに事象と原因間の関係性を表現するモデルを作成する。

モデルにより事象と原因間の関係性を表現し、新規事象とモデル内の既存事象の類似度を求め、それを集約することでデータセット全体の事象を考慮して新規事象の原因を与えることを目指す。

また、本論文では事象と事象の類似度を直接求めるのではなく、事象と事象の間に索引語集合であるトピックを介在させ、その類似度を求めることで、字面によらない事象間の類似度を求める。

本論文の主要な貢献を以下に示す。

(1) モデル §3.2 にて失敗知識データベースの原因、文書、トピックの関係を表すモデルを構築する。失敗知識データベースの構成を反映したモデルを構築することで、モデルにより汎化能力を持つことを期待する。具体的には複数の類似する事象

事例 e1	事例名称	ホイスト式クレーン巻上げ機歯車の疲労破壊
	事例概要	機械工場に設置されていたダブルレール型ホイスト式クレーンで荷をつり上げ中、巻上げが突然出来なくなり、作動不能になった。原因は巻上げ機歯車の一つが、歯元から折損しているためであった。
事例 e2	事例名称	歯車のバックラッシュが大きすぎて噛み合い騒音が大きくなった。
	事例概要	光ファイバ母材合成装置を設計し、運転を開始したところ、80 デシベル以上の騒音となった。光ファイバ母材を回転させる軸（回転数：数百 rpm）に、市販のステンレス製歯車を使用した。歯車等級が JIS4 級のため、金属歯車のバックラッシュが大きく、噛みあい騒音が大きくなった。対策として、一方の歯車の材質を FRP(繊維強化樹脂) に変更した。

表 1 字面は類似しているが状況や一連の動作・行動が異なる例

の原因を統合して推定することなどを期待する。

(2) 状況や行動記述からの事象間の潜在的な関係性分析 §4.1.1 にて LDA を利用してトピックを構築し、トピックを介在させることで事象間の字面によらない潜在的関係を求める方法を説明する。その後、§5. にてトピックを介在させない場合のモデルとトピックを介在させた場合のモデルをそれぞれ評価・比較し、トピックを介在させることが状況や行動記述からの事象間の潜在的な関係性を分析できているかを評価する。

(3) 事象と原因の関係の解明 §3.2.1 にてデータセットをパーセプトロンで学習することに事象と原因の関係を取得する方法を説明する。§5. にて事象と原因の関係をパーセプトロンで学習させた場合と学習させない場合を比較し、提案手法がパーセプトロンの学習により事象と原因の関係を解明できているかを評価する。

2. 関連研究

2.1 JST 失敗知識データベース

JST 失敗知識データベースは JST により失敗事例を分析して教訓を抽出して、知識として活用できるデータベースをめざし開発されたデータベースであり、2005 年 3 月 23 日より一般公開が開始され、2011 年 3 月 31 日にそのサービスを終了し、現在は畑村創造工学研究所の Web サイト上で公開されている。

JST 失敗知識データベースは個々の失敗事例について、「機械」、「化学」、「建設」などのカテゴリが付与されており、各カテゴリごとに失敗事例を見ることができる。

カテゴリについては、「その他」を含め 16 カテゴリあり、全カテゴリで約 1000 件の失敗事例が登録されている。

JST 失敗知識データベースは「失敗知識の伝達」を目的としたデータベースであり、その特徴はシナリオと呼ばれる表現法による「失敗知識の構造化」である。

シナリオは原因・行動・結果の 3 つに分けられ、失敗まんだら (図 1) と呼ばれるあらかじめ定められた失敗構成要素を元に構成されている。

JST 失敗知識データベース内においては、このシナリオが各失敗事例に対して付与されている。

本論文においてはシナリオの中でも原因に注目し、新しく与えられた事例の原因を既存の事例の原因から推定することを行う。

2.2 メタデータの妥当性

伊藤 [4] らは、失敗知識データベース内の事象間における潜在的構造をメタデータを用いずに分析し、潜在的に類似してい

る事象を見つける研究を行なっている。また、メタデータにはメタデータ作成者の視点が入り、意図的に調整されていることを指摘している。この研究では事象本文に対して、単語同士の共起を用いることで、事象間の推移的で連想的な潜在的構造の類似性を取得することを行っている。加えて、それを用い共起を用いない場合では取得できなかったが、共起を用いたために取得できた事例をより詳細に分析し、それらに潜在的構造が存在すること、また、メタデータにおいては類似性がないことを考察している。

これに関して、メタデータはデータ作成者の視点者に基づいて構成されているが、JST 失敗知識データベースが「失敗を生かそうとしている人が頭の中に持っている失敗」知識の構造を明らかにする」ためにメタデータ (シナリオ) を作成している以上、それはメタデータが持つ特性である。

その上で、一人のデータ作成者の視点に基づいて構成されたメタデータを利用することが妥当であるかについて、本論文では事象を集合として扱うため、意図的に調整されているデータがあったとしても、それらは集合の中では大きなノイズとはならないのではないかと考えている。


また、一視点者では事象を一つの側面からしか見ていないことがあることについては、提案手法を用いることで、見つけられなかったシナリオを、既存のデータセットから推定して提示することもできる。従って、本研究はメタデータにデータ作成者の視点が入り、意図的に調整されていることを改善することにも貢献できる。

2.3 要因検索

青野 [5] らは、手がかり表現を基に Web 文書から要因を検索、抽出してさらに因果関係ネットワークを構築する研究を行なっている。この研究では与えられた事象を、事象間の因果関係を見つける手がかり表現とともに検索し、与えられた事象に対する原因を取得する。また、取得した原因を手がかり表現とともに再検索し、因果関係ネットワークを構築する。その後、取得した因果関係よりネットワークを構築し、部分構造に分類し因果関係ネットワークを分析している。

野島 [6] らは、手がかり表現を基に新聞記事から原因と結果を抽出する手法を提案している。この研究では新聞記事の主題には結果が記述されているという結果・主題一致仮説を提唱し、結果・主題一致仮説を利用することで、一文中に結果と原因の両方が現れない因果関係を新聞記事より取得することができる。

これらの手法においては、手がかり表現を用いるため、原因と結果または原因が一文で記述される必要がある。新しい事象



JST畑村委員会作成 2002

図 1 原因まんだら

の原因を推定する場合，事象間の関係を取得する必要がある．しかし，失敗知識データベースに登録される事象は，事象が複文で構成される．従って，本研究で扱う問題に対して，この研究での手法を直接適用することはできない．

データベース内の特定のカテゴリにおいて，既に固有名詞や通称が与えられている事柄間の因果関係の取得や，複文で構成される事象内における因果関係の取得は行える可能性がある．そこで，それらの取得できる因果関係を提案手法で取得する原因の詳細化などに利用できないか，今後の課題として検討を行いたい．

2.4 事象の表現方法

石井 [7] らは Topic-Event Cause モデル (TEC モデル) 及び増分的な因果関係ネットワークの構築手法を提案した．TEC モデルにおいては事象は語集合ではなく SVO の組として表現される．石井らは実験において，語集合を用いる手法に比較して提案手法が事象の同一性判定において良い結果を得られることを示した．

3. 文書原因モデル

新規事象の原因を求めるため，文書と原因の関係を表現・分析する文書原因モデルを提案する．

3.1 入力と出力

失敗知識データベースには様々なデータ構造が考えられ，また，存在するが，本論文ではデータセットとして JST 失敗知識データベースを利用する．

提案手法の入力は，学習データセットの非構造化テキスト及び構造化されたテキストによるシナリオ，およびクエリとなる非構造化テキストで構成される新規事象である．

また，出力は新規事象に関連する原因のリストである．

3.2 文書原因モデル (DC モデル)

文書原因モデルにおいては，データセットより文書と原因の関係を表現するネットワークを構築し，与えられた文書をネットワーク内の文書の類似度と比較することで，原因を求める．

文書は失敗知識データベース内のデータであり，事象の状況・行動を表現している文字列である．JST 失敗知識データベース内においては，事例名称や事例概要が相当する．

原因は事象の失敗構成要素である．JST 失敗知識データベース内においては，事例の主シナリオの原因部分を利用する．

最も類似する文書の原因を返す手法に比べ，複数の文書と原因の関係を考慮することができ，データセット内にある事象と原因の関係をより正確に反映できることを期待する．

このモデルは文書・原因間の 1 層で構成される．

以降の説明においてネットワークの重み付きエッジを行列を用いて表現する．エッジが張られていない部分については，その値を 0 であるとする．

文書数を N ，原因数を M とした場合，文書・原因間の関係は行列 A で表現できる．

3.2.1 文書・原因間層の構築

現実の世界においてどのような事象においてどのような原因が起きるのかをデータセットなしにあらかじめモデルとして与えることはできない．したがって，文書・原因間の層においては，既存のデータセットを観測し，各事象における原因の関係を割り当てることとする．

ここで，既存のデータセットから割り当てる場合に次の二通りの方法を考える．

(1) バイナリ データセット内で事象に対して原因として割り当てられている原因に対しては 1 を重みとして与え，エッジを張る．

(2) パーセプトロン 前述のバイナリを初期状態とし，識別




図 2 システムの概要




図 3 文書原因モデル

関数の単純パーセプトロンを利用してデータセットを学習データとして投入し、事象と原因の間の重みを標準デルタ則により学習させる。

エッジが張られていないノード間に重み 0 のエッジが張られていると考えると、バイナリは 0 か 1 の値しか取らないのに対して、パーセプトロンは 0 から 1 の間を取りうる。従って、パーセプトロンの方が表現能力が高く、パーセプトロンの方がバイナリより高い性能を示すことを期待している。この評価については §5. にて行う。

3.2.2 クエリ文書の原因の求め方

クエリ文書 D_q が与えられた場合、 D_q とデータセット内の各文書の類似度のベクトル $\mathbf{d}_q(d_{qi} = \text{Sim}(D_q, D_i))$ を TF-IDF を利用して求める。

次に

$$\mathbf{c}_q = \mathbf{A} \cdot \mathbf{d}_q$$

を計算し、 D_q の原因ベクトル $\mathbf{c}_q$ を求める。 D_q における原因 C_i に対する原因は c_{qi} である。

新規事象の原因推定を行いたい場合は、求められた $\mathbf{c}_q$ より関係性が高い順に原因を並び替え、例えば、その上位 3 件を返すことで、新規事象に関係する可能性が高い原因を推定することができる。

また、失敗知識データベースへの登録時には事象を理解する必要があるが、原因が推定されていることによりユーザーは、その原因を元に事象を見ることができるため、事象の理解を支援することができる。

加えて、手法より推定される原因は一つではなくリストで返されるため、一つの原因でなく複数の原因を見ることができ、データ登録者が考えなかった原因についても考慮し、データ登

録者の視点を通した側面のみしか見ることができなかった問題を解決することもできる。

推定された原因の提示方法については、一定の閾値を持って、それ以上の値を示したものを回答として利用する。

4. トピック文書原因モデル

§3.2 の文書原因モデルを発展させたものとして、トピック文書原因モデルを提案する。

4.1 トピック文書原因モデル (TDC モデル)

トピック文書原因モデルにおいては、文書・文書間の類似度を直接求めるのではなく、文書・文書間に単語集合であるトピックを介在させる。これにより文書の字面に引きづられない、事象間の類似度を求めることができる。

TDC モデルにおける文書と原因の定義は DC モデルと同じである。

トピックは文書に含まれる単語から構成される単語集合であり、各単語に対して確率が割り当てられている。トピックは文書を利用して LDA により求める。

トピック文書原因モデルはトピック・文書間および文書・原因間にエッジが張られたネットワークモデルであり、それぞれのエッジには重みが割り当てられている。トピック・文書間の重みについては、その文書とトピックの関係を表しており、値が大きいほど、そのトピックがその文書に関係があることを表す。また、文書・原因間の重みについては、その文書と原因の関係を表しており、値が大きいほど、その文書においてその原因が関係があることを表す。

このモデルはトピック・文書間の層、文書・原因間の層の 2 層で構成されている。




図 4 トピック文書原因関係モデルの構造

文書の数 N 、トピックの数 M 、原因の数 L とした場合、トピック・文書間のエッジは NM 行列の行列 A を用いて、文書・原因間のエッジは LM 行列の行列 B を用いて表現できる。

4.1.1 各層の構築

トピック・文書間については、文書に関する生成モデルである LDA [3] を用いることで、その相関関係を割り当てる。LDA では文書は単語集合が混在したトピックの集合であると仮定する。本提案手法内においては、トピックが「失敗を引き起こした状況・行動」を示すことを期待し、この層に LDA を利用することで単語の字面に引きづられない事象間の類似度を割り当てる。

LDA を利用する場合、そのトピック数を割り当てる必要がある。これはその文書集合において、トピックが「失敗を引き起こした状況・行動」を表現するに十分なトピック数を指定する必要がある。

文書・原因間については、DC モデルと同じ手法で構築する。

4.1.2 クエリ文書の原因の求め方

クエリ文書 D_q が与えられた場合、 D_q とトピックの関係性のベクトル t_q を LDA より求める。

次に

$$c_q = BA \cdot t_q$$

を計算し、 D_q の原因のベクトル c_q を求める。 D_q における原因 C_i に対する原因は c_{qi} である。

c_q よりユーザーへ返す C_i を取得する方法については、DC モデルと同じである。

5. 実 験

5.1 概 要

新規事象に対して提案手法で原因を推定した場合、提案手法が新規事象に関連があると推定する原因のリストより手法を評価する。

データセットとしては、JST 失敗知識データベースをクロールし 1175 件のデータからタイトル、URL、事象、主シナリオを取得したものを利用して行う。

JST 失敗知識データベースにおいては、すべての事象に対して主シナリオと呼ばれるメタデータが割り当てられている。主シナリオは原因・行動・結果に分けられており、それらはあら

かじめ定義された失敗構成要素により構成される。

また、JST 失敗知識データベースの事象は「機械」、「化学」、「建設」などの 16 の業種のカテゴリに分類されており、本実験においては各カテゴリごとの集合内において提案手法を評価する。ある事象がどの業種に属するかを考えることは容易に行える。したがって、クエリ文書のカテゴリがあらかじめ定まっていることは前提として十分に要求可能であり適切である。

5.2 ベースライン

ベースラインとして「類似している文書には類似している原因がある」という考えに従い、TF・IDF を利用してクエリ文書に最も類似する文書を求め、その文書に付与されている原因を原因として返す手法をベースラインとする。

5.3 確信度・精度・F 値の評価

カテゴリごとの事象の集合において、事象の集合を学習用の事象と評価用の事象へ分け、学習用の事象を手法内における文書とみて、モデルを構築する。各カテゴリのデータにおいて先頭 10 件を評価用の事象とし、残りの事象を学習用の事象として評価を行う。また、JST 失敗知識データベースの事象に割り当てられている主シナリオの原因を、その事象に割り当てられている原因とする。

評価においては、評価用の事象をクエリ文書として投入し、その事象に関連する原因を求め、JST 失敗知識データベース内のその事象に割り当てられている主シナリオの原因を正解データとし、精度、再現率、及び F 値を用いて評価する。

$$\begin{aligned} \text{精度} &= \frac{\text{返答された原因のうち正解の原因数}}{\text{返答された原因数}} \\ \text{再現率} &= \frac{\text{返答された原因のうち正解の原因数}}{\text{正解の原因数}} \\ F \text{ 値} &= \frac{2 \cdot \text{精度} \cdot \text{再現率}}{\text{精度} + \text{再現率}} \end{aligned}$$

また、TDC モデルにおいて LDA に利用するトピック数はどのカテゴリにおいても 50 とした。加えて、提案手法において原因を回答とするかの閾値については 0.1 とした。

これらの下で、表 2 に示す 5 つの組み合わせにおいて各カテゴリにおいて評価し、精度、再現率、F 値のそれぞれについて表 3、表 4、表 5 の通りとなった。

5.4 トピック数の変化の評価

TDC-B、TDC-P においては LDA を利用するため、トピッ

TF・IDF	ベースライン
DC-B	DC モデル (バイナリ)
DC-P	DC モデル (パーセプトロン)
TDC-B	TDC モデル (バイナリ)
TDC-P	TDC モデル (パーセプトロン)

表 2 手法の省略表記とその内容

カテゴリ	TF・IDF	DC-B	DC-P	TDC-B	TDC-P
その他	0.233	0.242	0.254	0.287	0.302
化学	0.250	0.185	0.148	0.200	0.196
機械	0.000	0.150	0.133	0.182	0.230
金属	0.267	0.224	0.197	0.266	0.258
建設	0.275	0.244	0.232	0.249	0.220
原子力	0.300	0.190	0.187	0.207	0.192
航空・宇宙	0.317	0.160	0.185	0.183	0.175
自然災害	0.292	0.202	0.175	0.196	0.196
自動車	0.133	0.205	0.199	0.233	0.220
食品	0.200	0.200	0.203	0.207	0.207
石油	0.167	0.150	0.138	0.157	0.157
石油化学	0.467	0.240	0.261	0.302	0.302
船舶・海洋	0.217	0.137	0.134	0.158	0.138
鉄道	0.275	0.179	0.176	0.206	0.192
電気・電子・情報	0.300	0.210	0.239	0.240	0.237
電力・ガス	0.200	0.144	0.130	0.158	0.170

表 3 精度の評価

カテゴリ	TF・IDF	DC-B	DC-P	TDC-B	TDC-P
その他	0.134	0.469	0.516	0.478	0.503
化学	0.233	0.550	0.317	0.683	0.650
機械	0.000	0.333	0.167	0.383	0.383
金属	0.350	0.650	0.600	0.567	0.617
建設	0.433	0.775	0.783	0.775	0.725
原子力	0.300	0.483	0.483	0.467	0.500
航空・宇宙	0.253	0.540	0.610	0.540	0.540
自然災害	0.192	0.483	0.500	0.533	0.567
自動車	0.167	0.542	0.542	0.517	0.517
食品	0.233	0.417	0.417	0.267	0.267
石油	0.267	0.500	0.433	0.500	0.500
石油化学	0.417	0.600	0.625	0.775	0.775
船舶・海洋	0.300	0.450	0.450	0.500	0.500
鉄道	0.258	0.717	0.717	0.717	0.717
電気・電子・情報	0.200	0.500	0.567	0.467	0.467
電力・ガス	0.153	0.357	0.357	0.353	0.373

表 4 再現率の評価

ク数を与える必要がある。機械カテゴリのデータを利用し、トピック数を変えた場合に精度、再現率、F 値がどのように変化するかを調べ、表 6 の通りとなった。

5.5 考 察

提案手法の DC モデル、TDC モデルの両モデルについて F 値において、ベースラインを上回り提案手法が優れていることが示せた。

DC モデル、TDC モデルともに特に再現率が改善している。精度を維持したまま、再現率が改善したということは、提案手法を用いることでユーザーは従来発見することができなかった

カテゴリ	TF・IDF	DC-B	DC-P	TDC-B	TDC-P
その他	0.150	0.286	0.313	0.329	0.349
化学	0.237	0.274	0.200	0.307	0.299
機械	0.000	0.205	0.142	0.245	0.280
金属	0.287	0.322	0.290	0.352	0.354
建設	0.323	0.363	0.348	0.364	0.329
原子力	0.283	0.256	0.251	0.268	0.259
航空・宇宙	0.275	0.239	0.274	0.257	0.251
自然災害	0.199	0.255	0.248	0.276	0.282
自動車	0.130	0.277	0.270	0.293	0.282
食品	0.207	0.244	0.249	0.231	0.231
石油	0.197	0.226	0.203	0.234	0.234
石油化学	0.420	0.335	0.358	0.429	0.429
船舶・海洋	0.243	0.206	0.203	0.239	0.215
鉄道	0.230	0.271	0.269	0.302	0.289
電気・電子・情報	0.223	0.288	0.330	0.305	0.300
電力・ガス	0.140	0.182	0.169	0.187	0.202

表 5 F 値の評価

手法 (トピック数)	精度	再現率	F 値
TDC-B(25)	0.173	0.383	0.236
TDC-B(50)	0.182	0.383	0.245
TDC-B(100)	0.195	0.383	0.257
TDC-B(500)	0.182	0.383	0.246
TDC-P(25)	0.198	0.333	0.247
TDC-P(50)	0.230	0.383	0.280
TDC-P(100)	0.208	0.283	0.239
TDC-P(500)	0.145	0.167	0.154

表 6 トピック数の変化による影響の評価

原因を見つけることができたということである。実際にシステムが返した例として、金属カテゴリ内の「製鉄所のガスホルダーの爆発・火災」への適用例 (表 7) を示す。どちらも精度については 0.333 であるが、再現率についてはベースラインが 0.5 で提案手法が 1.0 である。この例においてユーザーはベースラインの回答であれば、この事例に安全意識不良があったことに気づかないかもしれない。

また、このことは前述していたメタデータがデータ登録者の視点を介しており一視点から見がちであるという指摘に対する解決にもなる。なぜなら、データ登録者はシステムが提示していた原因を基に事例の原因を検討することができるので、その過程で複数の視点から見ることができるからである。従って、再現率が改善したことはシステムの利用目的を考えた場合、有意である。

一方、提案手法の 4 つの手法の中には精度、再現率、F 値に大きな差は見受けられなかった。以降については提案手法内での DC モデルと TDC モデルの比較、及び、バイナリとパーセプトロンの比較を行いたい。

5.5.1 TDC モデルと DC モデル

表 5 より TDC モデルが DC モデルより高い性能を示すことはできなかった。また、§5.3 に用いたトピック数が不適切である場合を考え、表 6 においてトピック数を変化させたが、TDC モデルの性能は変化しなかった。

手法	返答された原因
TF・IDF	不注意-注意・用心不足 組織運営不良-管理不良 調査・検討の不足-仮想演習不足
提案手法 (DC-B)	組織運営不良-管理不良 価値観不良-安全意識不良 不注意-注意・用心不足 調査・検討の不足-仮想演習不足 不注意-理解不足 誤判断-状況に対する誤判断
正解	価値観不良-安全意識不良 不注意-注意・用心不足

表 7 製鉄所のガスホルダーの爆発・火災

TDC モデルと DC モデルにおいてほとんど差が見られなかった原因は、LDA により構築するトピックが「行動・状況」を適切に表現することができなかった故であると考えられる。

ここで「機械」カテゴリにおける TDC モデルのネットワークを逆に見て、各原因に対して最もその原因に強い関係があるトピックを求め、表 8 にまとめた。一つのトピックが複数の原因において最も関連があるとされている箇所があり、これはトピック数が 50 であることを考えると、一部のトピックが支配的な地位を示していると言え、モデルが上手く機能していないと考えられるが、これについては §5.5.2 にて述べる。

本論文においては、トピックが「行動・状況」を示すことを期待していた。しかし、実際に構成されたトピックを確認すると、「歯 鋼 歯車 ステンレス」や「チェーン ガラス 駆動 光 ファイバ」などとなっており、行動や状況を示す単語集合ではなく、カテゴリをより細かく表現する単語集合になっていると考えられる。この下でトピックを介在させたとしても、それは細かなカテゴリで同一カテゴリの事象を見つけることと同じであり、これは TF・IDF が行なっている単語が類似してる文書を探していることに近い。従って TDC モデルと DC モデルの間において差がうまれなかったのではないかと考えている。

これを改善する方法として、トピックが「行動・状況」を示すように利用する単語を品詞や出現頻度に基づいて選別し単語の素性を変更する、また、トピックは単語の語順を考慮しない素性であるが、トピックではなく別に単語の語順を考慮する行動や状況を示すのに適した素性を考える必要があると考えている。

5.5.2 パーセプトロンとバイナリ

次に「機械」カテゴリにおけるデータセット内での原因に対する事象の分布を調べ、表 9 にまとめた。また、表 8 において 4 つの原因に最も関連があるとされたトピック番号 0 については、それに関連がある原因を太字で示した。

まず、表 9 を見ると、「調査・検討の不足-事前検討不足」や「調査・検討の不足-仮想演習不足」などに、それぞれ 115 件、64 件の事象が割り当てられており、特定の原因が多くの事象において出現し、偏りがあることが分かる。

また、その一方で少数の事象にしか割り当てられていない原因も存在する。先ほどのトピック番号 0 を見ると、これは少数の事象に対して割り当てられている原因に強い関連を示しており、学習データの偏り故に、一部のトピックが支配的な地位を

示すこととなったと考えられる。

パーセプトロンがバイナリに対して優位にならなかったこともこの偏りより説明ができる。そもそも、学習データセットが強い偏りがあるデータであるから、データセットからバイナリで構築した時点で、データセットの特徴（偏り）を表現できており、パーセプトロンで学習を行なっても、その偏りを学習するのみで、学習が意味をなさなかったためであると考えられる。

その上で、これはデータセットの特性であり適切に学習できていると考えるか否かの検討を含め今後改善の方法を考える必要がある。

組織運営不良-管理不良	7
無知-知識不足	48
不注意-注意・用心不足	33
調査・検討の不足-仮想演習不足	64
価値観不良-安全意識不良	11
価値観不良-組織文化不良	1
組織運営不良-運営の硬直化	5
手順の不遵守-連絡不足	2
手順の不遵守-手順無視	5
誤判断-誤った理解	19
調査・検討の不足-事前検討不足	115
環境変化への対応不良-経済環境変化	1
企画不良-戦略・企画不良	2
誤判断-誤認知	1
環境変化への対応不良-使用環境変化	25
調査・検討の不足-環境調査不足	4
誤判断-狭い視野	4
未知-異常事象発生	1
未知-未知の事象発生	2
不注意-理解不足	19
組織運営不良-構成員不良	2
企画不良-組織構成不良	1
誤判断-状況に対する誤判断	1

表 9 原因の分布

6. おわりに

本論文では、JST 失敗知識データベースを対象とし、既存の失敗知識データベースを利用して、新しく与えられた事象の原因を推定する方法を提案し、評価した。

単純に類似する手法から原因を求める手法に比べ、提案手法のモデルを利用した手法は評価において優れた性能を示し、提案手法のモデルを構築することの有効性を示すことができた。

一方で LDA を利用し学習用の文書とクエリ文書の間にトピックを介在させることで、字面にとらわれない文書間の類似度を求めることで、トピックを介在させない場合に比べ、高い性能を示す期待していたがその優位性を示すことはできなかった。

このことに関しては、§5.5 に示した通り、データセットの特性や構成されたトピックの特性などが原因として考えられ、これを改善することを今後の課題としたい。

原因名	トピック番号	トピックに関連のある上位 10 単語
組織運営不良-管理不良	6	減速 切断 伝達 折損 ロボット 軸 油 搬送 ゆるむ 値
無知-知識不足	8	歯 鋼 歯車 進行 水素 脆い 割れる ステンレス 強度 製
不注意-注意・用心不足	27	ボルト 締結 固定 穴 ナット 軸 脱落 座 塗装 しまう
調査・検討の不足-仮想演習不足	10	設計 位置 取付 ステップ しまう 繰り返す ガタ 考慮 当る 方向
価値観不良-安全意識不良	17	折損 車体 油圧 設計 試験 機械 建設 位置決め スプリング 車輪
価値観不良-組織文化不良	0	不良 動作 大切 ビット 発電 ドア 回路 設置 傾く 扉
組織運営不良-運営の硬直化	6	減速 切断 伝達 折損 ロボット 軸 油 搬送 ゆるむ 値
手順の不遵守-連絡不足	46	亀裂 ブラケット 疲労 剛性 破壊 集中 試作 荷重 ドラム アール
手順の不遵守-手順無視	38	チェーン ガラス 駆動 光 ファイバ 母 軸 変動 管内 伝動
誤判断-誤った理解	7	給油 位置 フロー バケット 設置 トランス 角度 スプール ミッション 働く
調査・検討の不足-事前検討不足	48	ねじ 動 ガイド 摺 摩耗 シリンダ レール 設計 スライダ 硬い
環境変化への対応不良-経済環境変化	0	不良 動作 大切 ビット 発電 ドア 回路 設置 傾く 扉
企画不良-戦略・企画不良	0	不良 動作 大切 ビット 発電 ドア 回路 設置 傾く 扉
誤判断-誤認知	0	不良 動作 大切 ビット 発電 ドア 回路 設置 傾く 扉
環境変化への対応不良-使用環境変化	48	ねじ 動 ガイド 摺 摩耗 シリンダ レール 設計 スライダ 硬い
調査・検討の不足-環境調査不足	43	制御 盤 アンモニア 変更 端子 黄銅 削る 扉 密閉 梱包
誤判断-狭い視野	11	ケーブル 曲 許容 率 破断 自転車 リコール 脚立 不能 考慮
未知-異常事象発生	9	軸 タービン キー 端 溝 駆動 位置 ゲート 開く 平行四辺形
未知-未知の事象発生	26	加工 方向 シール ケース 高い 痕 吸い込む センサ 角 曲げる
不注意-理解不足	27	ボルト 締結 固定 穴 ナット 軸 脱落 座 塗装 しまう
組織運営不良-構成員不良	33	機械 溜まる リブ 変更 紙 補強 構造 アーム 検知 先端
企画不良-組織構成不良	33	機械 溜まる リブ 変更 紙 補強 構造 アーム 検知 先端
誤判断-状況に対する誤判断	9	軸 タービン キー 端 溝 駆動 位置 ゲート 開く 平行四辺形

表 8 各原因に最も関連のあるトピック

7. 謝 辞

本研究の一部は科研費 (No.20300042 , No.20300036) による .

文 献

- [1] 失敗知識データベース (畑村創造工学研究所), <http://www.sozogaku.com/fkd/>, (2010)
- [2] ベンチャー企業の経営危機データベース, <http://www.meti.go.jp/policy/newbusiness/kikidatabase/>, (2010).
- [3] David M. Blei, Andrew Y. Ng, Michael I. Jordan, “Latent Dirichlet Allocation”, Journal of Machine Learning Research vol.3, pp.993-1022, (2003).
- [4] 伊藤 公一, 堀口 由貴男, 中西 弘明, 榎木 哲夫, 失敗事例へのテキストマイニング手法の適用に基づく過誤の潜在的構造分析, 23rd Fuzzy System Symposium, pp.527-532, (2007).
- [5] 青野壮志, 太田学. 要因検索による因果関係ネットワークの構築と因果知識の獲得. DEIM Forum 2010 B9-1, 2010.
- [6] 野島 裕輔, 馬 強, 吉川 正俊 . ニュース記事の内容と構造特徴を考慮した因果関係マイニング. DEIM Forum 2011 F4-4 , 2011 .
- [7] Hiroshi Ishii, Qiang Ma, Masatoshi Yoshikawa, Incremental Construction of Causal Network from News Articles, Journal of Information Processing, Vol. 20, No.1, pp.207-215, 2012.1.