

福祉支援施設の支援記録からの インシデントの予兆検出の一手法

松本 典久^{1,a)} 上野 史^{1,b)} 太田 学^{1,c)}

概要: 近年、高齢者や障がい者に対する福祉支援施設の重要性が大きくなっている一方、入所者が起こすインシデントへの対応の負荷が増している。しかし、ベテランの支援員にとってもインシデントの発生を事前に察知することは困難である。そこで、本研究では福祉支援施設の支援記録からインシデントの予兆を検出するための手法を提案し、実験により有効性を検証する。具体的には過去の支援記録から支援記録の本文と日付情報や支援者情報などの付随情報を利用するモデルを作成し、支援記録にインシデントの予兆があるかないか2クラスに分類する。10人の支援記録を用いた分類実験の結果、記録本文のみを用いて記録を分類した場合10人の平均でF値約0.89、1日分の記録をまとめて日ごとに分類した場合10人の平均でF値約0.87となった。また記録本文に付随情報のいずれかを与えることで、10人中9人は本文のみ与える場合と比較してF値が上昇した。

A Method for Detecting Predictive Signs of Incidents in Support Records of Welfare Support Facilities

1. はじめに

近年、高齢者や障がい者に対する介護や支援は需要が増しており、高齢者や障がい者に対する福祉支援施設の重要性が増している。しかし、福祉支援施設では被支援者の人数に対して支援員の数は限られており、支援には限度がある。また、被支援者がインシデントを起こすとそれに余分に対応する必要があるため、入所者のインシデントは少ないことが望ましい。したがって、入所者が起こすインシデントを予見し可能ならば未然に防止することが求められる。しかし、インシデントの発生を事前に察知することはベテランの支援員でも困難である。

そこで本研究では、福祉支援施設の支援記録からインシデントの発生と関連のある予兆を検出する^{*1}。具体的には、福祉支援施設の支援記録を対象データとし、記録本文に加えて日付データなどを入力とする予兆の分類器を

作成して、対象の支援記録が予兆か否かを分類することで予兆を検出する。また、検出には自然言語処理モデルの一つである Bidirectional Encoder Representations from Transformers (BERT) [1] を利用する。BERT の特徴の一つは文脈を考慮することが可能なことである。本研究では BERT に支援記録の本文の文脈を学習させることで、文章の特徴を取り出すことができる。さらに取り出した文章の特徴と日付などの付随情報を合わせて利用することで予兆を検出する。

本稿の構成を述べる。第2節では、関連研究を紹介する。第3節では、提案する予兆検出モデルについて説明する。第4節では、評価実験として行う支援記録分類実験の内容と結果を示し、考察を述べる。第5節では、まとめと今後の課題について述べる。

2. 関連研究

2.1 BERT

BERT[1] は Devlin らが提案した自然言語処理技術であり、双方向 Transformer[2] というニューラルネットワークを利用した言語モデルである。これは大規模テキストコーパスで事前学習を行ったモデルに対して個々のタスクに合

¹ 岡山大学

Okayama University, 3-1-1 Tsushima-naka, Kita-ku, Okayama-shi, Okayama 700-8530, Japan

a) piia6ope@s.okayama-u.ac.jp

b) uwano@okayama-u.ac.jp

c) ohta@okayama-u.ac.jp

*1 本研究は、岡山大学の研究倫理審査専門委員会の承認を得て実施された。(研 2104-005)

表 1 支援記録の例

利用者 ID	処理日付	支援者 ID	記録本文	予兆ラベル
012345	yyyy/mm/dd	111111	舎活動：廊下や居室で穏やかに過ごされている。(14:00~15:00) 職員が入れ替わったことからか、靴下を流したり服を破ったりされる。	予兆 (高)
		222222	波があるが基本穏やかに過ごされている。	予兆 (低)
012346	yyyy/mm/dd	111111	AM：リング通し スーパーボール PM: ○○建築までの歩行。	予兆なし

わせてファインチューニングをすることで、幅広いタスクに適用できる。

BERT の特徴としては、同一のモデル内で双方向から単語の周囲の文脈を学習できることが挙げられる。単語列に対する双方向での学習は、単方向での学習をそのまま双方向に適用すると学習時に予測すべき単語を先読みしてしまうため実現できなかったが、BERT では事前学習の際に二つのタスクを用いて学習することで予測する単語の先読みを防いでいる。このタスクの一つは Masked Language Model (MLM) と呼ばれ、入力シーケンスにある単語の 15% を [MASK] トークンに置き換え、[MASK] トークンに置き換えられた単語を予測するタスクである。もう一つは Next Sentence Prediction (NSP) と呼ばれ、文のペアを受け取り、ペアにおいて 2 つ目の文が元の文章において後続の文になっているかを予測するタスクである。

BERT は公開時、General Language Understanding Evaluation (GLUE) ベンチマーク [3] の 8 つのタスクと、Stanford Question Answering Dataset (SQuAD)[4] の v1.1 と v2.0 を用いる 2 つのタスク、Situations With Adversarial Generations (SWAG)[5] の 1 つのタスク、合計 11 の自然言語処理タスクで最高記録を達成した。

2.2 文書分類に関する研究

文書分類は分類タスクの一種であり、教師あり学習を用いることが有効とされ、従来より数多くの研究がされている [6], [7].

例えば田中らは、BERT が出力する単語埋め込み表現列の平均ベクトルと Bag-of-Words モデルによる特徴ベクトルをそれぞれ連結したベクトルを文書の特徴ベクトルとする手法を提案した [8]. BERT を分類問題に適用する場合、特殊トークンである [CLS] の埋め込み表現を用いる手法が一般的であるが、田中らは提案手法を用いて Amazon レビューの文書データセットをポジティブかネガティブか 2 クラス分類し、他の手法より高い正解率 0.82 を示した。

また我々は [9] で、BERT による支援記録からのインシデントの発生検出を行った。本稿と同じ福祉支援記録の本文や、日付情報や入力者 ID を本文に連結したものをを用いて BERT の学習済みモデルをファインチューニングした。支援記録から被支援者ごとのモデルを作成しインシデントの発生の有無を分類した結果、記録ごとの分類で最大の F

値 0.88, 1 日分の記録をまとめた日ごとの分類で最大の F 値 0.78 となった。

本研究は、[8] と同様に BERT を利用して文書分類を行うが、[8] では使用する特徴量がレビュー本文から得られるものだけなのに対し、本稿では日付情報など支援記録の他の付随情報も用いる点が異なる。また、分類対象の文書の種類や分類クラスも異なる。[9] は我々が支援記録からのインシデントの発生検出に取り組んだものであるが、本稿では支援記録を利用したインシデントの予兆の検出という異なるタスクに取り組む。また、[9] では支援記録の付随情報を本文と連結した文字列として与えていたが、本稿では本文と付随情報を区別して与えるモデルを提案する。

3. 予兆検出

3.1 支援記録

支援記録の例を表 1 に示す。表 1 の通り、支援記録は記録本文のみ自由記述の文章となっており、それ以外は定型である。表 1 では、2 つ目の記録は普通の文章の記述だが、1 つ目の記録は「(14:00~15:00)」として文中に時間が記述されている。また 1 つ目と 3 つ目の記録には「舎活動：」「AM：」「PM：」のような見出しがつけられている。このように記録本文は文字数が 0 文字以上ということ以外に決まりがなく、多いものでは 1 つの記録本文が 1000 文字以上となることもある。また支援記録の分類は、個々の記録の分類と同一日付の記録をまとめたものの分類の両方を行う。後者の分類を行うのは、日ごとに予兆を検出することで、その翌日の支援業務において支援者に注意喚起することを考えているためである。

3.2 予兆の定義

本研究では、支援記録本文に施設利用者の衝動性が高い、あるいはネガティブな心理状態が現れているものを予兆として定義する。文脈から判断して衝動性やネガティブな感情の高まりと言えない場合は予兆としない。また、予兆には基準に従って「予兆 (低)」「予兆 (高)」の 2 種類がある。「予兆 (低)」は、衝動性が高い、あるいはネガティブな心理状態が現れていると判断できること、「予兆 (高)」は衝動性あるいはネガティブな感情を抑えることができず、結果として周囲へ影響が出てしまった状態であると定義している。「予兆 (低)」の例としては、自傷行為、情緒が乱れ

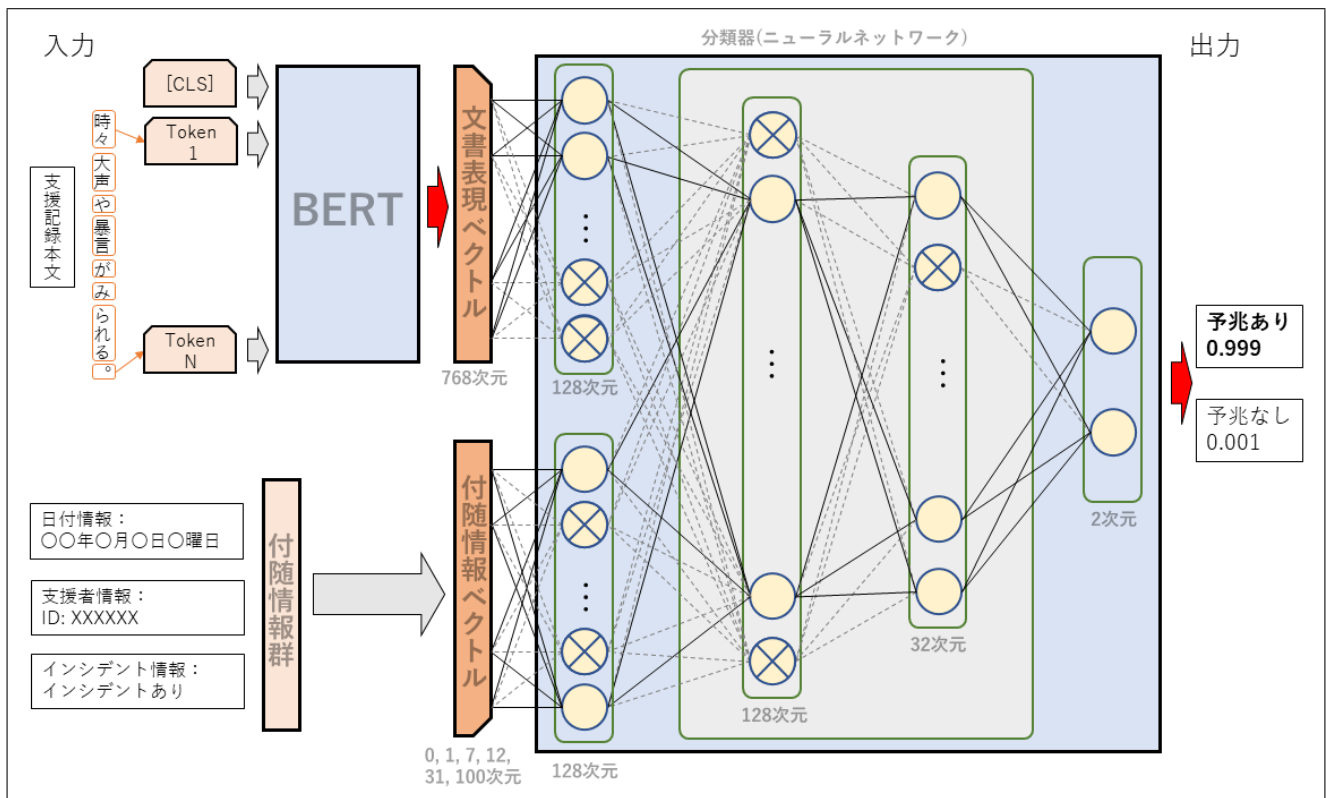


図 1 予兆検出モデルの概略図

ている、大声を発する、などが、「予兆(高)」の例としては、他者への暴力、器物損壊などのインシデントや、物に当たる行為などが挙げられる。一方で、やる気がない、暴言、騒ぐ、などはそれだけでは予兆とはしない。記述の内容によっては文脈から予兆か予兆でないかを判断する。例えば、気分が悪い、つらそうな表情、などは精神面の話であれば「予兆(低)」であるが、体調面の話であればこれらは「予兆なし」となる。

また一つの記録に対して「予兆(低)」と「予兆(高)」の予兆ラベルが同時に付与されることもある。なお本稿では、各記録は予兆ラベルの有無で分類し、2クラス分類を行う。

3.3 予兆検出モデル

図 1 に提案する予兆検出モデルの概略図を示す。

このモデルではまず、記録本文を BERT により文書表現ベクトルに変換する。また、支援記録から支援者 ID や日付情報などの本文以外の付随情報を取り出し、付随情報ベクトルに変換する。

次に、これらの文書表現ベクトルと付随情報ベクトルを入力とする分類器によって支援記録の予兆の有無を分類する。

図 1 の右側で示す分類器は 4 層のニューラルネットワークである。具体的には各層は全結合層であり、順に 256 次元、128 次元、32 次元、2 次元ベクトルへと線形変換される。活性化関数にはシグモイド関数、出力層には softmax

表 2 付随情報と次元

付随情報	ベクトルの次元
月	12 次元
日	31 次元
曜日	7 次元
支援者 ID	100 次元
インシデントの発生の有無	1 次元

関数を用いている。損失関数は交差エントロピー誤差を採用し、Adam によって最適化する。分類器のエポック数は 20、バッチサイズは 32 とした。

分類器の 1 層目では、文書表現ベクトルと付随情報ベクトルをそれぞれ 128 次元の全結合層へ入力することでどちらも 128 次元に変換し、2つのベクトルを合わせて 256 次元のベクトルとする。また各層間では Dropout[10]を行っている。Dropout はニューラルネットワークの過学習防止のための手法の一つで、一定確率でランダムにニューロンを無視して学習を進める。

分類器による出力結果は各ラベルに対して 0 から 1 の範囲で正規化された確率であり、その総和は 1 になる。そのため、本稿の 2 クラス分類では「予兆あり」「予兆なし」の 2 つのラベルに対する確率が出力され、入力に対する各ラベルの確率が最大のクラスに分類する。本研究では、入力を正しく「予兆あり」に分類できればその予兆を検出できたことになる。

本研究ではモデルの BERT の部分は事前学習済みモデ

表 3 支援記録の統計情報

人物	性別	記録件数			日数		
		予兆あり (割合)	予兆なし	合計	予兆あり (割合)	予兆なし	合計
A	女性	897(37.1%)	1519	2416	752(54.3%)	632	1384
B	女性	1232(35.8%)	2207	3439	858(61.9%)	527	1385
C	女性	1470(44.5%)	1830	3300	918(70.8%)	378	1296
D	女性	413(21.5%)	1508	1921	317(42.4%)	430	747
E	男性	997(26.3%)	2800	3797	746(39.2%)	1157	1903
F	男性	621(18.7%)	2702	3323	547(28.6%)	1364	1911
G	男性	823(24.3%)	2564	3387	652(34.1%)	1261	1913
H	男性	406(11.8%)	3034	3440	386(20.2%)	1526	1912
I	男性	599(15.7%)	3216	3815	541(28.3%)	1370	1911
J	男性	559(14.4%)	3320	3879	490(25.7%)	1420	1910

ルをファインチューニングしたもので、利用者ごとに分類器を作成する。また本研究では、BERT 日本語 Pretrained モデル^{*2}を利用する。

本研究では表 2 に示す 5 種類の付随情報をそれぞれ入力として記録本文に加えて実験により比較する。この際、日付情報として利用する月、日、曜日はそれぞれ 12 次元、31 次元、7 次元の、支援者 ID は 100 次元の、インシデントの発生の有無は 1 次元の One-hot ベクトルで表現する。

4. 評価実験

4.1 実験の概要

4.1.1 実験に用いるデータ

実験には福祉支援施設に入所する利用者の男性 6 名、女性 4 名、計 10 名分の支援記録を用いる。実験では利用者ごとに図 1 のモデルでファインチューニングおよび分類を行う。その際、記録そのものと、記録を日ごとにまとめたものを用いてそれぞれ分類実験を行う。

各利用者の支援記録の統計情報を表 3 にまとめる。表中の「予兆あり (割合)」とは、記録件数、日数それぞれの対象データに対して何らかの予兆ラベルが付与されているものの件数または日数とその割合である。これより、いずれの人物も記録の半分以上が「予兆なし」であるが、日で見ると人物 A, B, C の 3 名は半分以上の日数が「予兆あり」であることが分かる。

4.1.2 実験の内容

評価実験として提案モデルを 4.1.1 項で説明したデータで学習し、その分類精度を評価する。実験では、全データの 8 割を学習、2 割をテストに用いる。また評価指標は 5 分割交差検証によって算出する。

実験では表 2 に示した付随情報の種類を変えて記録本文に加えて分類精度を比較する。

4.1.3 評価指標

分類精度として、以下に定める再現率 (Recall)、適合率 (Precision)、F 値 (F-measure)、正解率 (Accuracy) を利用

する。

$$\text{Recall} = \frac{TP}{TP + FN} \quad (1)$$

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2)$$

$$\text{F-measure} = \frac{2\text{Recall} \cdot \text{Precision}}{\text{Recall} + \text{Precision}} \quad (3)$$

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + TN + FN} \quad (4)$$

TP : 予兆ありに分類された予兆ありの記録

FP : 予兆ありに分類された予兆なしの記録

FN : 予兆なしに分類された予兆ありの記録

TN : 予兆なしに分類された予兆なしの記録

なお、再現率はすべての予兆ありの記録のうち、実際に分類器が予兆ありに分類したものの割合であり、適合率は分類器が予兆ありに分類した記録のうち、実際に予兆ありの記録であるものの割合である。F 値は式 (3) に示すように再現率と適合率の調和平均である。

予兆の検出という観点では、再現率はどれだけ予兆を見逃さないか、適合率はどれだけ誤検出を防げるかを示しており、F 値はそれらを総合的に評価した指標となる。また、正解率は予兆ありと予兆なしの両方に関わる指標であるが、本研究では予兆の検出に重きを置くため、F 値を重視する。

4.2 実験結果と分析

4.2.1 記録本文のみによる分類実験

図 1 の提案モデルにおいて支援記録の本文のみを用いて支援記録を分類した結果を表 4 に示す。なおこれは図 1 で付随情報ベクトルを 0 次元とする場合に相当する。

表 4 より記録ごとの分類の場合、正解率は人物 C 以外の 9 人は 0.900 以上となっている。一方日ごとの分類の場合、人物 A, B, C, D 以外の 6 人の正解率が 0.900 以上となっ

*2 <http://nlp.ist.i.kyoto-u.ac.jp/index.php?ku>

表 4 支援記録の本文のみを用いた分類の精度

人物	記録ごと				日ごと			
	正解率	再現率	適合率	F 値	正解率	再現率	適合率	F 値
A	0.936	0.915	0.915	0.914	0.891	0.916	0.889	0.901
B	0.941	0.929	0.908	0.918	0.873	0.897	0.898	0.897
C	0.894	0.876	0.886	0.881	0.831	0.910	0.860	0.884
D	0.930	0.840	0.835	0.837	0.819	0.783	0.791	0.782
E	0.955	0.913	0.914	0.913	0.915	0.915	0.871	0.892
F	0.955	0.871	0.890	0.880	0.927	0.895	0.862	0.876
G	0.963	0.931	0.917	0.924	0.933	0.918	0.888	0.903
H	0.964	0.828	0.861	0.843	0.937	0.827	0.858	0.842
I	0.969	0.896	0.903	0.899	0.936	0.879	0.893	0.886
J	0.960	0.863	0.863	0.862	0.919	0.818	0.864	0.840




図 2 付随情報を変えた記録ごとの支援記録の分類結果の F 値

ている。最大の正解率は記録ごとの場合、人物 I の 0.969、日ごとの場合、人物 H の 0.937 となっている。そのため、人物 I でも少なくとも 3% の支援記録は正しく分類されていないことになる。

また、再現率は記録ごとと日ごとのどちらも人物 G が最大でそれぞれ 0.931 と 0.918 となっており、適合率は記録ごとの場合、人物 G の 0.917、日ごとの場合、人物 B の 0.898 が最大となっている。つまり人物 G でも予兆ありの支援記録の約 7% を正しく検出できておらず、また予兆ありと分類したうちの約 8% は誤分類している。

さらに、分類の F 値 0.900 以上の人物は記録ごとの分類の場合 4 人、日ごとの分類の場合 2 人となっており、全体的に見ても日ごとの分類は記録ごとの分類よりも F 値がわずかに小さくなっている。

4.2.2 付随情報の比較実験

支援記録の本文に加えて表 2 の付随情報を利用した支援記録の分類実験の結果を図 2, 3 に示す。図 2 が記録ごとの、図 3 が日ごとの分類結果である。横軸が人物、縦軸が

F 値、棒は利用する付随情報の種類を表し、赤点は各人物の最大の F 値の棒を示す。

まず図 2 より記録ごとの分類の場合、人物 D, G, H を除くと、いずれかの付随情報を与えた場合に分類の F 値が最大となっている。人物 B と J は月情報、人物 E は日情報、人物 I は曜日情報、人物 A は支援者 ID、人物 C, F はインシデントの発生の有無を与えた時にそれぞれ最大の F 値を示している。しかし、付随情報を加えることで F 値が減少することもあり、すべての付随情報が常に有効とは限らない。10 人のうちそれぞれの付随情報で F 値が向上した人数は、月情報は 3 人、日情報は 3 人、曜日情報は 3 人、支援者 ID は 4 人、インシデントの発生の有無は 4 人であった。

一方図 3 より日ごとの分類の場合、人物 A を除いていずれかの付随情報を与えた場合に分類の F 値が最大となっている。人物 C は月情報、人物 I は曜日情報、人物 D と J は支援者 ID、残りの人物 B, E, F, G, H はインシデントの発生の有無を与えた時にそれぞれ最大の F 値を示してい




図 3 付随情報を変えた日ごとの支援記録の分類結果の F 値

表 5 人物 A の誤って分類された支援記録の例

	記録本文	正解	予測
(1)	機嫌がよくなりずっと暴言を吐かれている。	予兆 (低)	予兆なし
(2)	朝は機嫌よく過ごされている。最近帰園してから、なかなか職員が本人と関わっていない為、拗ねて暴言をはくことが多い。	予兆 (低)	予兆なし
(3)	AM: 来られてすぐ素材をなげる。時間はかかったが落ち着かれる。 PM: ○○建築への歩行穏やかに過ごされている。	予兆 (高)	予兆なし
(4)	とてもご機嫌で過ごされる。時折暴言をばそぼそつぶやいておられると思えば、急に一人で笑い出したりされる。	予兆なし	予兆あり
(5)	穏やかに過ごされていたが、花粉症の影響か鼻声がひどくどこかしんどそうだった。	予兆なし	予兆あり

る。しかし、記録ごとの分類と同様に、付随情報を加えることで F 値が減少することもあり、すべての付随情報が常に有効とは限らない。10 人のうちそれぞれの付随情報で F 値が向上した人数は、月情報は 6 人、日情報は 5 人、曜日情報は 7 人、支援者 ID は 6 人、インシデントの発生の有無は 8 人であった。

そのため、付随情報は日ごとの分類において記録ごとの分類よりも効果を発揮していると言える。

4.2.3 事例分析

4.2.2 項の実験において人物 A の誤分類された日の例を表 5 に、正しく分類された日の例を表 6 に示す。

まず全体的に「暴言」という単語が見られるが、3.2 節で説明したように「暴言」のみでは予兆とはならない。表 5 の (1) は「機嫌がよくなり」が予兆だが正しく分類されていない。(2) は全体的な内容から予兆であるとしているが、これも正しく分類されていない。(3) は「素材をなげる」の部分「予兆 (高)」に該当しているが、誤って「予兆なし」に分類されている。(4) は (2) と似て全体的に情緒が安定していないように見える内容であるためか「予兆あり」に分類されているが、正しくは「予兆なし」である。(5) は「しんどそう」が一見予兆に見えるが、体調面のつらそう

な様子は予兆ではないので「予兆なし」が正しい。しかし誤って「予兆あり」に分類されている。

一方で表 5 の (1) と似た文章である表 6 の (1) は「波がある」が予兆であり、これは正しく「予兆あり」に分類されている。また、表 6 の (2) は「情緒が悪い」が予兆でありこれも正しく分類されている。表 6 の (3) は表 5 の (3) と似て「予兆 (高)」に該当する「物を投げられる」の記述があり、これは正しく分類されている。表 6 の (4) は表 5 の (5) の後半部分を除いたような記述であり、こちらは正しく「予兆なし」に分類されている。表 6 の (5) は表 5 の (1) と似た内容であるが、「暴言」そのものは予兆ではなく、他に予兆となる要素もないため「予兆なし」であり、正しく分類されている。

予兆の有無の判別が困難な理由の一つとしては、このように似たような記述内容に対して必ずしも同じ予兆ラベルが付与されるわけではないことが挙げられる。例えば、「しんどそう」は精神面の話であれば「予兆 (低)」であるが、表 5 の (5) のように体調面の話であれば「予兆なし」となる。したがって、予兆の有無を正しく分類するためにはそのような曖昧な部分を正しく区別する必要がある。

表 6 人物 A の正しく分類された支援記録の例

	記録本文	正解	予測
(1)	波がある。基本穏やかだが、暴言を吐くことが何度かあった。	予兆 (低)	予兆あり
(2)	夕食前は情緒が悪い。	予兆 (低)	予兆あり
(3)	奇声などはないが、物を投げられることが多い。	予兆 (高)	予兆あり
(4)	穏やかに過ごされている。	予兆なし	予兆なし
(5)	他者の声に反応して暴言を吐くことが多い。	予兆なし	予兆なし

表 7 日ごとにまとめた支援記録における予兆ありの曜日の割合

	月曜日	火曜日	水曜日	木曜日	金曜日	土曜日	日曜日
A	56.6%	59.6%	62.6%	53.5%	55.1%	43.7%	49.2%
B	67.7%	62.1%	61.6%	66.2%	67.2%	57.4%	51.5%
C	74.6%	76.2%	75.7%	72.6%	74.6%	56.2%	65.9%
D	38.3%	41.1%	47.7%	42.1%	47.2%	39.6%	41.1%
E	58.3%	53.8%	40.1%	39.8%	44.7%	21.6%	15.3%
F	25.3%	37.4%	36.9%	31.4%	29.8%	23.7%	15.8%
G	38.7%	36.5%	33.9%	35.4%	41.2%	25.9%	26.7%
H	23.8%	21.2%	18.6%	21.5%	20.4%	18.3%	17.3%
I	25.2%	28.5%	33.2%	28.2%	37.8%	25.9%	19.2%
J	27.4%	29.9%	30.7%	30.0%	24.8%	17.0%	19.6%
平均	43.6%	44.6%	44.1%	42.1%	44.3%	32.9%	35.2%




図 4 人物 E の日ごとの分類結果の F 値

4.3 付随情報に関する考察

4.2.2 項の実験で効果を比較した付随情報について考察する。まず、インシデントの発生の有無の情報については、「インシデントの発生」は「予兆あり」としているため、「予兆あり」の検出に対しては一定の効果が見込まれる。実際、日ごとの分類では 8/10 名の支援記録に対して分類の F 値が改善した。

次に、偏りが目立った付随情報として曜日情報を取り上げる。実際に曜日情報は、日ごとの分類で 10 人中 7 人の支援記録分類に効果があった。表 7 に各曜日の出現日数に対する「予兆あり」の日の割合を示す。表 7 より 10 人の平均を見ると、月曜日から金曜日の平日は約 43%、土曜日と日曜日の休日は約 34%となっており、休日の予兆の割合は

平日の予兆の割合と比較して 10%程度小さくなっている。したがって全体的な傾向としては平日の方が休日と比べて予兆が発生しやすいことが分かる。

また、支援記録の本文の文書表現ベクトルと付随情報ベクトルの次元について考察する。3.3 節で説明したように、図 1 の提案モデルの分類器部分では 1 層目で文書表現ベクトルと付随情報ベクトルをともに 128 次元に変換し、これらを合わせて 256 次元ベクトルにしている。ここでは、この 256 次元は変えずに、2つのベクトルの次元数を「文書表現ベクトル:付随情報ベクトル=128:128」から変更して分類実験を行う。

図 4 に人物 E の日ごとの分類結果の F 値を示す。ここでは付随情報としてインシデントの発生の有無を用いた。

図 4 では、ベクトルの次元をどのようにしても付随情報を加えることで F 値が上昇し、「文書表現ベクトル:付随情報ベクトル=16:240」の時に F 値が最大となった。「インシデントの発生」はただちに「予兆あり」と定義しているため、この付随情報の価値は大きいと考えられる。ただし、人物 E について文書表現ベクトルを用いずインシデントの発生の有無のみを利用して分類を行った場合、インシデントの発生した日の予兆はすべて正しく分類し適合率は 1 となったが、インシデントの発生した日が 144 回と全日数の約 7.5%しか存在しなかったため、インシデントの発生していない日の予兆については正しく分類できず再現率が 0.195 となり、F 値は 0.325 となった。

一方で、付随情報ベクトルの次元を大きくすることがすべての人や付随情報で有効というわけではなく、次元を大きくすることで F 値が減少する付随情報もあった。そのた

め、文書表現ベクトルと付随情報ベクトルの組み合わせについてより詳細な分析が必要であると考えている。

5. まとめ

本稿では、インシデントの予兆の有無の検出のため、BERTを組み込んだモデルにより支援記録を分類する手法を提案し、その分類性能を実験により評価した。提案手法は、支援記録の本文や日付情報などの付随情報を入力として、支援記録の予兆の有無を2クラスに分類する。

実験ではまず提案手法により福祉支援施設利用者10人の支援記録の分類モデルを利用者ごとに作成し、記録本文のみを用いて支援記録を分類した。その結果、記録ごとの分類で10人の平均のF値約0.89、日ごとの分類で10人の平均のF値約0.87となった。次に提案手法に用いる付随情報の種類を変えて分類実験を行った。その結果、記録ごとの分類では支援者IDやインシデントの発生の有無の情報を与えることで利用者10人の支援記録のうち4人のF値が上昇し、日ごとの分類ではインシデントの発生の有無の情報を与えることで10人中8人、曜日情報を与えることで10人中7人の支援記録の分類のF値が上昇した。また、分類された支援記録を調べたところ、一部の「予兆あり」と「予兆なし」の記録本文に似た記述が存在し、分類が困難な支援記録があることが分かった。

今後は、インシデントの予兆分類精度の向上のために、記録本文と付随情報の統合的な利用方法についてさらに検討する予定である。

謝辞 本研究は株式会社岡山システムサービスとの共同研究である。本研究で使用したデータは同社より提供を受けた。

参考文献

- [1] Devlin, J., Chang, M.-W., Lee, K. and Toutanova, K.: Bert: Pre-training of deep bidirectional transformers for language understanding, *arXiv preprint arXiv:1810.04805* (2018).
- [2] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L. and Polosukhin, I.: Attention is all you need, *Advances in neural information processing systems*, Vol. 30 (2017).
- [3] Wang, A., Singh, A., Michael, J., Hill, F., Levy, O. and Bowman, S. R.: GLUE: A multi-task benchmark and analysis platform for natural language understanding, *arXiv preprint arXiv:1804.07461* (2018).
- [4] Rajpurkar, P., Zhang, J., Lopyrev, K. and Liang, P.: Squad: 100,000+ questions for machine comprehension of text, *arXiv preprint arXiv:1606.05250* (2016).
- [5] Zellers, R., Bisk, Y., Schwartz, R. and Choi, Y.: Swag: A large-scale adversarial dataset for grounded commonsense inference, *arXiv preprint arXiv:1808.05326* (2018).
- [6] Sebastiani, F.: Machine learning in automated text categorization, *ACM computing surveys (CSUR)*, Vol. 34, No. 1, pp. 1–47 (2002).
- [7] Ikonomakis, M., Kotsiantis, S. and Tampakas, V.: Text classification using machine learning techniques., *WSEAS transactions on computers*, Vol. 4, No. 8, pp. 966–974 (2005).
- [8] 田中裕隆, 曹類, 白静, 馬ブン, 新納浩幸ほか: BERTによる単語埋め込み表現列を用いた文書分類, 情報処理学会研究報告, Vol. 2019-NL-240, No. 16, pp. 1–5 (2019).
- [9] 松本典久, 上野史, 太田学: 福祉支援施設の支援記録を利用したインシデントの発生検出の一手法, 第14回データ工学と情報マネジメントに関するフォーラム, A34-1 (2022).
- [10] Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R.: Dropout: a simple way to prevent neural networks from overfitting, *The journal of machine learning research*, Vol. 15, No. 1, pp. 1929–1958 (2014).