

## 模倣学習アルゴリズムを利用した階層構造カテゴリ文書の分類

Hierarchical Category Documents Classification  
Applying Imitation Learning Algorithm

松尾 壮晃<sup>†</sup>      岡崎 威生<sup>‡</sup>      宮川 拓<sup>§</sup>      中山 康弘<sup>§</sup>  
Masaaki Matsuo      Takeo Okazaki      Taku Miyagawa      Yasuhiro Nakayama

## 1. はじめに

文書分類タスクは自然言語処理において重要なタスクの1つである。インターネットの発達とともにアクセスできる文書の数も増えており、SNSでのユーザーの分析や企業での蓄積データを基にしたサービスの開発などその活用は多岐にわたる。分類タスクにおいて重要となるのが、分類先のカテゴリである。最もシンプルな構造の場合、階層構造を持たない2クラス分類または他クラス分類となる。しかし扱うデータの中には上下関係など縦のつながりをもったカテゴリラベルが与えられているものも存在する。そのカテゴリ構造を示したものをカテゴリツリーと呼ぶ。既存の文書分類手法は非階層型 (Flat Model) と階層型 (Tree Model) の大きく2つに分けることができる [1]。Flat Model はカテゴリツリーを用いず、その最下層のみを用い、カテゴリ群から最適なカテゴリに分類する他クラス分類問題として定式化される。Tree Model はカテゴリツリーを利用し、その木構造に従って逐次的に最上層から最下層まで局所的に分類を繰り返し、末端の最適なカテゴリに分類する手法である。Tree Model はカテゴリツリーが与えられており、その構造がデータの関係性を表しているため、カテゴリの関係性を特徴として扱えば分類精度の向上が期待できる。しかし局所的な分類を行うため、上層で誤分類が発生した場合、それが下層に引き継がれる誤り伝播により分類精度の低下も懸念される。

一方で一般的な文書分類タスクは Flat Model によって実現されるため、誤分類の評価が難しい。階層構造を持つ文書の分類を Tree Model で行う場合、どの階層で誤分類が発生しているかが Flat Model に比べ分かりやすい。誤分類が発生したとしても、予測ラベルと正解ラベルの違いを階層上の距離として表現できるため、その結果を手がかりとし分類精度向上への活用が期待される。

本稿の成果は次の通りである。

- 階層構造カテゴリを持つ2つの文書データセットに DAGGER を適用した Tree Model の分類実験を行い、ベースラインを上回る性能を確認した。
- 誤分類の質の評価のため ARL 値だけでなく新たに VRL 値の導入を提案した。VRL 値の導入により異なるデータセットの階層構造カテゴリ分類に

おける誤分類の質が評価でき、分類モデルの安定性が比較できることを示した。

本稿の構成は以下の通りである。2 節では階層型分類、3 節では模倣学習の階層型文書分類への適用法について述べる。さらに 4 節では階層構造文書データへの適用実験とその結果を示す。

## 2. 階層型文書分類

Flat Model は、カテゴリ構造が階層的であったとしても、末端となる葉のラベルのみを使って分類する。一方で一般的に Tree Model はカテゴリ構造を利用し階層ごとに局所的な分類を行う。大規模なデータセットを扱う場合、非常に大きなモデルを作成するよりも、局所的なモデルを組み合わせることにより、モデルの複雑さの解消と計算時間の短縮が期待できる。局所的な分類の方法として、ノードごと (per parent node) と階層ごと (per level) の2つの分類手法に分けることができる。親ノードごとの手法では、分岐が発生するノードごとにその子ノードや葉に対する分類器を作成する。階層ごとの手法では、それぞれの階層ごとに1つ下の階層を予測する分類器を作成する。Tree Model では上層の分類結果を下層の分類に引き継ぐため、上層で誤分類が発生した場合、誤分類を引き継いでしまう。これを誤り伝播という。そのため Flat Model と比べモデルの複雑さや誤り伝播による分類精度の低下から導入コストが高いと考えられている。

## 3. 模倣学習を利用した階層構造文書分類

模倣学習はエキスパートの行動を観察し、その行動を真似ることで、エキスパートと同様の行動ができるように方策を学習する手法である。模倣学習は自動車の運転やビデオゲームの操作をコンピュータに学習させるタスクで取り上げられることが多い。坪井 [2] は固有表現抽出や英語依存構造解析において模倣学習アルゴリズムの1つである DAGGER を適用することで、誤り伝播を抑え、高速かつ高精度な解析ができると報告している。三田ら [3] は、楽天の商品データ (RDC) の階層的な分類に模倣学習を利用した。提案では模倣学習アルゴリズムの1つである DAGGER をツリーモデルに適用させることで、macro-F1 値と独自に導入した ARL (Average Revenue loss) 値が向上したと報告している。

DAGGER [4] とは Data Aggregation のことであり、決定論的方策を訓練するための反復アルゴリズムである。坪井 [2] や三田 [3] の研究では自然言語処理タスクにおける誤り伝播を低減させるため提案手法に組み込まれている。DAGGER では、方策を現在の状態  $s \in S$

<sup>†</sup> 琉球大学大学院理工学研究科情報工学専攻, Graduate School of Engineering and Science, University of the Ryukyus

<sup>‡</sup> 琉球大学工学部工学科知能情報コース, Computer Science and Intelligent System, University of the Ryukyus

<sup>§</sup> (株) タップ ホスピタリティサービス工学研究所 沖縄研究室, TAP Co., Ltd

から次の行動  $a \in A$  への写像  $\pi: S \rightarrow A$  と定義し、 $\pi$  が訪れた状態を  $S_\pi$  と表す。一般的に方策は分類器で近似される。

#### DAGGER Algorithm

```

Initialize  $\mathcal{D} \leftarrow \emptyset$ .
Initialize  $\hat{\pi}_1$  to any policy in  $\Pi$ .
for  $i = 1$  to  $N$  do
  Let  $\pi_i = \beta_i \pi^* + (1 - \beta_i) \hat{\pi}_i$ .
  Sample  $T$ -step trajectories using  $\pi_i$ .
  Get dataset  $\mathcal{D}_i = \{(s, \pi^*(s))\}$  of visited states
  by  $\pi_i$ 
  and actions given by expert.
  Aggregate datasets:  $\mathcal{D} \leftarrow \mathcal{D} \cup \mathcal{D}_i$ .
  Train classifier  $\pi_{i+1}$  on  $\mathcal{D}$ .
end for
Return best  $\hat{\pi}_i$  on validation.
  
```

正しい行動を返すオラクル  $\pi^*$  とする。DAGGER は、各反復においてオラクルとそれまでに学習済みのすべての方策が訪れた状態の下で新たな方策を学習する。DAGGER の最初の反復では、既存の教師あり学習と同じようにオラクルが既に訪れた状態を訓練データとして方策を学習する。次の反復以降では、オラクルが既に訪れた状態に加えて学習した方策が新たに訪れた状態も訓練データに加えて方策を学習する。ただし  $\beta_i$  は状態遷移時に用いるオラクルと訓練している方策との混合方策の混合率で  $N \rightarrow \infty$  のとき  $\frac{1}{N} \sum_k \beta_k \rightarrow 0$  を満たす数列である。混合率は  $\beta_k = 1, \beta_k = 0 (k > 1)$  が経験的に良いことが報告されている [4]。これは初回ではオラクル  $\pi^*$  を用い、2回目以降は現在の方策を用いるということである。

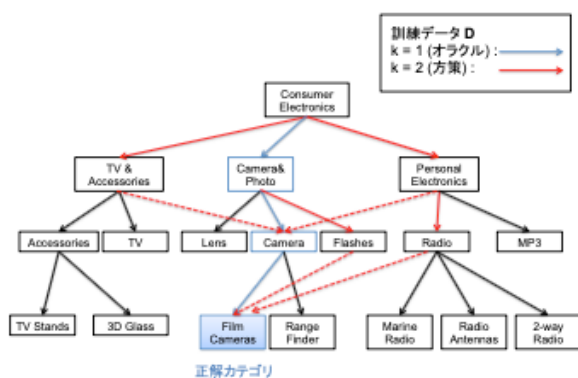


図 1: 方策が訪れる状態のサンプリング例

DAGGER は各反復ごとにその時の方策でデータを収集し、集めたデータをデータセットに加え、その足し合わされたデータセットで次の方策を学習する。そのため学習データに誤りがあった場合でも反復中に新たな方策を学習するため、過去に誤りがあった場合でもそ

れ以降の行動が誤らないことが期待できる。図 1<sup>1</sup>では、青線がオラクルで示されたカテゴリパスであり、赤線が反復により追加されたカテゴリパスである。正解カテゴリパスはオラクルで示された 1 通りではなく、オラクルが間違っていたとしても反復中に新たなカテゴリパスをサンプリングするため過去の予測の誤りを考慮できるようになっている。

階層構造文書分類における Tree Model への DAGGER を適用させる方法を述べる。文書分類は、与えられた文書  $d$  に対して、最適なラベル  $y \in Y$  を予測する問題である。ここで  $y$  は事前に定義されたカテゴリラベルの集合であり、階層構造化されているとする。Tree Model による階層的文書分類は、カテゴリツリーを最上層から最下層まで逐次的に分類器を適用させることで最終的に末端の  $y_T$  を予測する。階層を逐次的に分類する際、閾値より高い枝だけ残し、それ以外を削除する枝切り法は適用せず、誤り伝播の回避に有効であることを確認するために最も高い確率値を持つ枝のみ保持することにする。エキスパート役であるオラクルは、状態とは独立に正解カテゴリパスを参照し、現在着目する階層  $t$  のカテゴリを返す。これは  $\pi^*(s_t = y_t)$  である。カテゴリパスは各カテゴリの親カテゴリを辿ることで、現在着目するカテゴリまでのパスを一意に得ることができる。DAGGER の最初の反復では、オラクル  $\pi^*$  を用いるため、通常の教師あり学習と同じように正解カテゴリパスのみで学習を行う。2回目の反復以降は学習した方策で訪れた新たな状態もオラクルが訪れた状態に加えて学習する。オラクルにあるカテゴリへのパスが 1 通りしかない場合でも、反復を経ることで新たなカテゴリパスが学習され、誤った分類をした際もカテゴリパスの軌道修正がされる。

## 4. 階層構造文書分類比較実験

階層的文書分類における Tree Model への DAGGER の適用の有効性を調べるためベースラインとの性能比較実験を行った。

### 4.1. Web of Science データセット

2017 年に Kamran[5] らの階層型深層学習によるテキスト分類の研究で作成されたものである。今回使用するのは、その中の WOS-46985 と呼ばれる 46,985 件のデータを含むデータセットである。このデータセットはアブストラクト、大カテゴリラベル、中カテゴリラベル、小カテゴリラベルで構成されている。カテゴリは研究分野ごとに分けられており、大カテゴリラベルは 7 個であり、中カテゴリラベルが 133 個、小カテゴリラベルは 134 個である。アブストラクトは英語で書かれた自然文の論文のアブストラクトであり、平均長は 200.7 単語である。

### 4.2. ホテルシステムデータセット

ホテルシステムとは、システム提供先のホテルの業務を効率化するためのソフトウェアであり、顧客からシステムの使い方や要望などの問い合わせをシステム

<sup>1</sup>三田雅人, 村上浩司, 模倣学習を用いた階層的商品分類, 言語処理学会 第 22 回年次大会 発表論文集 (2016 年 3 月), P.1142

の機能ごとにラベル付け対応したものが問い合わせ文データセットである。このデータセットは問い合わせ文、大カテゴリラベル、小カテゴリラベルで構成されている。データ件数は 1,425 件で日本語で書かれた問い合わせ文の平均長は 55.8 文字であり、大カテゴリラベルが 3 個、小カテゴリラベルが 9 個である。

### 4.3. 実験の方法

入力文章を単語の頻度を元にした共起行列に変換した。方策の実装にはロジスティック回帰を用い、階層ごとに分類器を作成した。また今までの予測を下層の分類器に引き継ぐため、親カテゴリまでの予測履歴を特徴ベクトルに加えた。使用するデータは学習データ・開発データ・検証データの 3 種類に分割した。学習データは方策  $\pi_1$  の初期化のため、開発データは方策  $\pi_k$  の選択のために用いた。検証データによって方策の性能を評価した。開発データを用いて  $\pi_k$  を選択する場合も問題設定を考えると必ずしもオンライン学習で実現する必要はないため、バッチ学習で方策を選択させた。モデルで使用される語彙ベクトルを作成させるためのコーパスはデータセット全体を使用し、学習データ、開発データと検証データの割合は 3:1:1 とした。提案手法である Tree Model + DAGGER をベースライン 1 である Flat Model、ベースライン 2 である Tree Model と比較した。

### 4.4. 評価方法

一般的な他クラス分類の分類指標は micro-F1 値である。micro-F1 値はマルチクラス・マルチラベルに対応しているが、カテゴリクラスごとの距離の近さなどを考慮することはできない。そのため Tree Model における誤分類の質を評価することができない。階層構造カテゴリを持つ文書の分類の場合、より上位階層での誤分類は正解カテゴリと関係の小さいカテゴリパスを選択してしまうため、誤分類の質への影響が大きくなってしまふ。そこで三田 [3] の商品階層分類にも用いられた Revenue Loss の概念を導入し、誤分類の質を評価できるようにした。RL (Revenue Loss) 値は Chen ら [6] によって提言され、三田の商品分類でも RL 値の平均をとる ARL 値が使用されている。RL 値は階層構造カテゴリを持つデータの分類問題における経営的売上を考慮した指標であり、次の 2 つの仮定に基づき、式 (1) で表現される。

- 商品が本来所属するべき最適なカテゴリに分類されたとき、ユーザーはその商品を支障なく見つけることができるため、店舗はその利益を十分に得ることができる。
- 商品が誤ったカテゴリに分類された場合、ユーザーはその商品を見つけて購入することが難しくなることから、その店舗は正解カテゴリと誤分類カテゴリとの階層上の距離に比例する損失コストを被る。

$$RL \text{ 値} = v(x) \cdot L_{yy'} \quad (1)$$

$$L_{yy'} = 1 - \sum_{k=1}^n w(k) \cdot y_k y'_k \quad (2)$$

$n$  は全階層数であり、カテゴリツリーの階層上の距離に比例するように重み  $w$  を設定する。 $y$  と  $y'$  はそれぞれ正解カテゴリ、誤分類カテゴリを示している。 $v(x)$  は商品  $x$  に対する重みを表しているが、今回の実験では全ての商品を等しく扱っているため  $v(x)=1$  としている。 $L_{yy'}$  は損失率であり、 $y$  と  $y'$  とのカテゴリツリーにおける階層上の距離  $k$  に比例している。今回の実験では  $w(k) = \frac{2k}{n}$  として計算している。ARL 値は RL 値の平均をとったものである。 $m$  は全商品数であり、文書分類のため商品は文書として考える。

$$ARL \text{ 値} = \frac{1}{m} \sum_{(x,y,y') \in D} v(x) \cdot L_{yy'} \quad (3)$$

RL 値は予測カテゴリパスと正解カテゴリパスの不一致度であり、ARL 値は平均不一致度である。ARL 値は同一ドメインにおいては誤分類の質の評価に用いることができるが、異なるドメインの比較では、ドメインごとにデータの分布が異なっているため、そのスコアの大小による比較には向かない。そのため RL 値の分散である VRL 値 (Variance Revenue Loss) を導入した。VRL 値は RL 値と ARL 値から計算され、階層構造分類モデルの安定性を表す。VRL 値が大きくなるとカテゴリツリー上位層での誤分類の影響が大きくなり、結果として分類性能が安定していないことを示す。これは RL 値がカテゴリツリーの階層に対し重みをつけて計算されているためである。よって ARL 値・VRL 値がともに小さいほど階層分類モデルの性能が良いと期待できる。

$$VRL \text{ 値} = \frac{1}{m} \sum_{i=1}^m (RL_i - ARL)^2 \quad (4)$$

RL 値は全てのカテゴリラベルを正しく予測できたとき、 $RL_i = 0$  となるように設定した。micro-F1 値は小カテゴリの予測ラベルと正解ラベルから算出した。Flat Model の大・中カテゴリは予測した小ラベルと階層構造を対応させて割り出した。

### 4.5. 実験結果

WOS データセットを用いた実験は、46,985 件のデータからランダムな 30,000 件のデータを用いた分類実験を 100 回行い、その結果の平均値を表 1 に示す。

表 1: WOS データセットの実験結果

	micro F1 値	ARL 値	VRL 値
ベースライン 1	0.649643	0.265594	0.150883
ベースライン 2	0.639712	0.272109	0.131380
提案手法	0.648672	0.264395	0.130186

ホテルシステムデータセットを用いた実験は、全データをランダムに並び替え分類する実験を 100 回行い、その結果の平均値を表 2 に示す。

表 2: ホテルシステムデータセットの実験結果

	micro F1 値	ARL 値	VRL 値
ベースライン 1	0.913270	0.0424912	0.0258285
ベースライン 2	0.913649	0.0419766	0.0245431
提案手法	0.918526	0.0384094	0.0220314

WOS データセットとホテルシステムデータセットともに提案手法が Flat Model と Tree Model のベースラインと比較して ARL 値・VRL 値ともに小さくなっていることが確認できた。micro-F1 値では、提案手法は Flat Model のベースラインと比べ同じようなスコアを得たことや、ARL 値で提案手法が Flat Model と Tree Model のベースラインをともに上回っていることから誤り伝播の回避に成功していると考えられる。また WOS データセットとホテルシステムデータセットの実験結果を比較すると、VRL 値に大きな差ができています。これはデータセットのカテゴリツリーの複雑さとデータへのモデルの適合具合を反映していると考えられる。WOS データセットのカテゴリツリーは 3 階層であり、ホテルシステムデータセットと比べ各階層での分類先も多く、分類が難しくなっていると考えられる。上位階層での誤分類は RL 値が大きくなり結果として VRL 値が大きくなり分類性能が安定しない。そのため WOS データセットの分類はホテルシステムデータセットに比べ分類が難しいと言える。

提案手法は Flat Model と Tree Model のベースラインと比較して WOS データセットとホテルシステムデータセットの両方において micro-F1 値・ARL 値で大きな向上は見られなかった。

WOS データセットにおける ARL 値の比較ではベースライン 1 よりもベースライン 2 の ARL 値が大きくなっており、誤り伝播の影響があったと考えられる。提案手法では ARL 値がベースライン 1 と比較して小さくなっていることから DAGGER による誤り伝播が回避がされたと理解できる。VRL 値では Flat Model に比べ Tree Model の値が小さくなっており、RL 値の安定性では Tree Model が Flat Model より優れていると判断できる。Tree Model のベースラインに比べ提案手法が VRL 値も小さくなっており、RL 値の安定性という観点からも提案手法が有効であると推測できる。

ホテルシステムデータセットでは、比較した全ての評価値で提案手法、Tree Model のベースラインそして Flat Model のベースラインの順のスコアとなった。カテゴリツリーの階層数が WOS データセットと比較して少ないことが影響していると考えられる。Tree Model のベースラインと提案手法を比較すると、このデータセットでも ARL 値と VRL 値が両方とも改善されているため、誤り伝播や RL 値の安定という観点でも DAGGER の適用は有効であった。

2 つのデータセットの比較では、VRL 値に大きな差があった。micro-F1 値の違いからホテルシステムデー

タセットの VRL 値が WOS データセットと比べ小さいことも妥当である。階層構造カテゴリ分類における誤りの質を複数のドメインで見ることによりカテゴリツリーとデータの適合度の比較ができる。ホテルシステムデータセットは人為的に与えられたカテゴリツリーに対しデータをより安定的に階層カテゴリ分類できていると考えられる。

## 5. おわりに

本稿では、模倣学習手法の 1 つである DAGGER を Tree Model 用いた階層構造文書分類を提案した。これまで商品名より長い文書データセットへの DAGGER を Tree Model に適用するモデルの実験は行われておらず、提案手法が文章の階層構造カテゴリ分類に対し DAGGER の適用が誤り伝播回避し分類性能の向上に効果的であることを示した。また誤分類の質の評価のため ARL 値だけでなく VRL 値の導入を提案した。VRL 値の導入により異なるデータセットの階層構造カテゴリ分類における誤分類の質が評価でき、分類モデルの安定性が比較できることを示した。

## 参考文献

- [1] Carlos Silla and Alex Freitas. A survey of hierarchical classification across different application domains. *Data Mining and Knowledge Discovery*, Vol. 22, pp. 31–72, 2011.
- [2] 坪井祐太. 模倣学習による決定的解析での誤り伝播の回避. 言語処理学会第 19 回年次大会発表論文集, 2013.
- [3] 三田雅人, 村上浩司. 模倣学習を用いた階層的的商品分類. 言語処理学会第 22 回年次大会発表論文集, 2016.
- [4] Stéphane Ross, Geoffrey J. Gordon, and Drew Bagnell. A reduction of imitation learning and structured prediction to no-regret online learning. In Geoffrey J. Gordon, David B. Dunson, and Miroslav Dudík, editors, *AISTATS*, Vol. 15 of *JMLR Proceedings*, pp. 627–635. JMLR.org, 2011.
- [5] Kamran Kowsari, Donald E Brown, Mojtaba Heidarysafa, Kiana Jafari Meimandi, Matthew S Gerber, and Laura E Barnes. Hdltext: Hierarchical deep learning for text classification. In *Machine Learning and Applications (ICMLA), 2017 16th IEEE International Conference on*. IEEE, 2017.
- [6] Jianfu Chen and David Warren. Cost-sensitive learning for large-scale hierarchical classification. In *Proceedings of the 22nd ACM International Conference on Information & Knowledge Management, CIKM '13*, p. 1351–1360, 2013.