

## 【第134回生涯教育講座】

## 機械学習による退院時要約からのDPC分類の推測

木 村 知 広<sup>1)</sup> 津 本 周 作<sup>2)</sup>  
 平 野 章 二<sup>2)</sup>

キーワード：テキストマイニング，退院時要約，DPC，深層学習，Random Forest

## 要旨

電子化した退院時要約からテキストマイニングによって疾患別の重要語を抽出し、これを元に退院時要約の文章から疾患名を特定できるかについて検討した。

キーワードとターゲットとの対応付けが弱く、分類精度がそれほど上がらないという、従来のテキストマイニングによる分類学習の問題に対して、本研究では、対応分析によるDPC毎のキーワード選定を行い、機械学習で用いられる手法を適用、キーワードによるDPCコーディングを行う分類器を構築した。

反復交差検証法により分類の正答率を比較し、その検証結果から、SVM、決定木が最大78%程度の正答率であるのに対し、深層学習が86%以上、Random Forest、XGBoostでは90%以上の正答率を示した。

構築した分類器は高い正答率を示しており、診療文書の記載内容からテキストマイニングにより疾患の予測が可能となることが示唆された。

## 1. 背景および目的

電子カルテシステムに蓄積された診療情報の電子的データを用いて、新たな規則や知識を発見し、診療・研究・病院管理に役立てることが可能となってきている。しかしその研究の多くは、入力・保存や統計処理が容易な数値データや画像

データであり、医師のカルテ記録などの診療文書の解析は、従来の自然言語処理手法が診療文書の特殊性に対応できなかったことなどもあり、その数は少ない<sup>1,2)</sup>。医療文書の分析法を確立することは、医療プロセスの意思決定や予防医療の支援に期待されており、医療の質向上に大きく寄与するものと考える。筆者らは、その分析の一つとして電子化した退院時要約からテキストマイニングによって疾患別の重要語を抽出し、これを元に退院時要約の文章から疾患名を特定できるかについて検討した。

Shusaku TSUMOTO et al.

1) 島根大学医学部医療サービス課

2) 同 医学科医療情報学

連絡先：〒693-8501 島根県出雲市塩冶町89-1

島根大学医学部医学科医療情報学

## 2. 方 法

### 2.1 処理プロセス

電子カルテシステムから退院時要約の抽出を行う。その退院時要約のテキストデータに対し、ラベルとして患者に適用されたDPCコードを付与する。テキストデータに対して、対象となる言語の文法や単語の品詞情報を元に、文章を形態素に分解する形態素解析を行い、分解されたキーワードの出現頻度を集計の上、DPCコード×キーワードの形式で集計した分割表を生成する。次いで、分割表を元に対応分析（2次元）を行って、各キーワードとDPCコードについて布置座標を与える。これらの布置座標について、DPCコードとキーワード間のユークリッド距離を計算し、DPCコード毎に距離の値によって、キーワードのランク付けを行う。ランクに基づいて解析に用いるキーワードを選択し、前述の分割表から対象データを絞り、データ集合を生成する。生成されたデータから、分類学習、ここでは決定木、SVM、深層学習などの機械学習の手法を用いて、分類器を構築する。分類器構築のプロセスを図1に示す。

先行研究においては、鈴木らは文書中の単語の

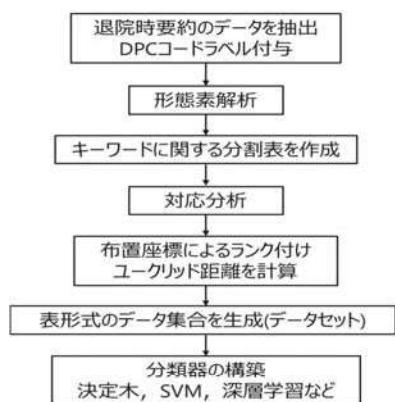


図1 分類器構築プロセス

重要度を、頻度を用いて計算し、作成した文書ベクトルモデルから類似したベクトルを検索してDPCの判別を行っている<sup>3)</sup>。本研究では、頻度だけではキーワードとターゲットとなる概念との対応付けが弱く、分類精度がそれほど上がらないと考え、分析対象となる調査項目と分析の基準したい属性項目等との関係性（類似性）を2次元の同一マップ上に表現する分析手法である対応分析を用いた。分析対象であるDPCと関係性が近い順に属性項目であるキーワードのランク付けを行い、ランク上位のキーワードを分類に必要な変数として選定し、分類器の精度向上を図った。

### 2.2 退院時要約のデータ抽出

解析対象となるデータを退院時要約のテキストデータとした。診療文書には医療における用語の標準化がなされていないこともあり、多種多様な用語が混在し、解析しにくいことはよく知られているが、退院時要約は各症例の診断・治療経過を時系列的に必要な情報を記載している。一般の診療記録に比べ、キーワードの冗長性が少なく、文自体も説明文の形式で省略は少なく、文章間の比較を含めて、横断的解析に適している<sup>4-6)</sup>。

対象は島根大学医学部附属病院に2015年度の1年間に蓄積された退院時要約のうち、DPCコードで上位20までの症例データ2,380件である（表1）。データ抽出には、島根大学医学部附属病院の電子カルテシステムで採用されているInterSystemsのデータベースCaché<sup>7)</sup>を使用し、抽出プログラムを作成の後、抽出を行った。

抽出したデータの内、解析対象となるデータは、医師が診療経過を文章で自由記載する診療経過要約の記載欄とし、確定診断名や手術など分類に大きな影響を及ぼす可能性のある定型的データが格納される記載欄は解析対象外とした。

表 1 2015年度上位20症例

No	DPC名称(DPCコード)	件数
1	白内障、水晶体の疾患 手術手術あり 重症度等片眼 (020110xx97xxx0)	445
2	白内障、水晶体の疾患 手術手術あり 重症度等両眼 (020110xx97xxx1)	152
3	2型糖尿病(糖尿病性ケトアシドーシスを除く。) (100070xxxxxxxx)	145
4	肺の悪性腫瘍 手術手術あり 処置等2なし (040040xx97x0xx)	131
5	子宮頸・体部の悪性腫瘍 手術手術なし 処置等24あり 副傷病名なし (12002xxx99x40x)	121
6	肺の悪性腫瘍 手術手術なし 処置等1あり 処置等2なし 副傷病名なし (040040xx99100x)	120
7	子宮の良性腫瘍 手術腹腔鏡下臍式子宮全摘術等 (120060xx02xxxx)	111
8	肺の悪性腫瘍 手術手術なし 処置等1なし 処置等24あり (040040xx9904xx)	110
9	妊娠期間短縮、低出生体重に関連する障害(出生時体重2500g以上) 手術手術なし 処置等2なし 副傷病名なし (140010x199x00x)	110
10	肘、膝の外傷(スポーツ障害等を含む。) 手術腱縫合術等 (160620xx01xxxx)	99
11	全身性器障害を伴う自己免疫性疾患 手術手術なし 処置等2なし (070560xx99x0xx)	96
12	非ホジキンリンパ腫 手術手術なし 処置等24あり 副傷病名なし (130030xx99x40x)	94
13	肺炎、急性気管支炎、急性細気管支炎(15歳以上) 手術手術なし 処置等2なし (040080x099x0xx)	86
14	肺の悪性腫瘍 手術手術なし 処置等1なし 処置等2なし (040040xx9900xx)	85
15	慢性腎炎症候群・慢性間質性腎炎・慢性腎不全 手術手術なし 処置等1なし 処置等2なし 副傷病名なし (110280xx99000x)	83
16	肝・肝内胆管の悪性腫瘍(続発性を含む。) 手術その他の手術あり 処置等2なし (060050xx97x0xx)	82
17	胆管(肝内外)結石、胆管炎 手術限局性腹腔膿瘍手術等 処置等2なし 副傷病名なし (060340xx03x00x)	82
18	脳梗塞(JCS10未満) 手術手術なし 処置等1なし 処置等23あり 副傷病名なし (010060x099030x)	80
19	網膜剥離 手術手術あり 重症度等片眼 (020160xx97xxx0)	75
20	胎児及び胎児付属物の異常 手術子宮全摘術等 (120180xx01xxxx)	73

## 2.3 キーワード選択

抽出した退院時要約のテキストデータに DPC コードのラベルを付与し、解析ツール R のパッケージ RMeCab<sup>8)</sup>を用いて、形態素解析を実施する。形態素解析を行った結果から単語の出現頻度を求め、DPC コード×キーワードの形式で集計した分割表を生成する。

その後、作成した分割表を元に、R パッケージ MASS を用いて、対応分析（2 次元）を行って、各キーワードと DPC コードについて布置座標を与える。対応分析結果の散布図を図 2 に示す。

これらの布置座標について、DPC コードとキーワード間のユークリッド距離を計算し、DPC コード毎に距離の値によって、キーワードのランク付けを行う。このランクに基づいて解析に用いるキーワードを選択するが、DPC コード間で重複

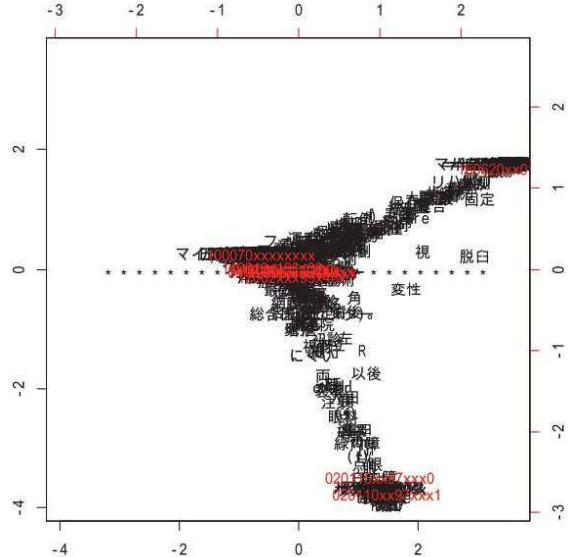


図2 対応分析結果（散布図）

したキーワードについては重複削除を行った。

## キーワードのランク付けにおける対応分析と

表2 キーワードのランク付けにおける対応分析とTF-IDFの比較（上位4症例）

順	1. 白内障(片眼)		2. 白内障(両眼)		3. 2型糖尿病		4. 肺悪性腫瘍	
	対応分析	TF-IDF	対応分析	TF-IDF	対応分析	TF-IDF	対応分析	TF-IDF
1	in	IOL	眼	IOL	ケトン	mg	陰部	GIA
2	VA	PEA	(+),	PEA	CTR	ml	離床	Endo
3	下方	サンベタゾン	成熟	(Dr名)	hr	時	バック	ics
4	DC	左	アバスチン	+	亢進	g	腫	葉
5	点眼	+	硝子	白内障	FDP	血糖	閉創	purple
6	硝子	右	Allergy	施行	雜音	性	グレード	Min
7	成熟	ジクロード	下方	trouble	跳痛	症	size	後
8	アバスチン	ベガモックス	In	視力	降圧	歴	growth	Lung
9	(+),	白内障	VA	退院	脾炎	入院	蒸留	肺
10	#,	月	The	左	閉経	病	キング	diag

TF-IDFの比較の一部を表2に示す。キーワードが全く違う選択となっていることが分かる。

## 2.4 機械学習アルゴリズムの適用

分類器の構築には、以下の機械学習の方法を使用した。

- ・決定木
- ・SVM（サポートベクターマシン）
- ・BNN（Backpropagation Network）
- ・RandomForest
- ・XGBoost
- ・深層学習（Deep Learning）

分類器構築のプラットフォームとして、R3.4.4を用い、決定木には rpart<sup>9)</sup>、SVMには kernlab<sup>10)</sup>、BNNには nnet<sup>11)</sup>、Random Forestには Random Forest<sup>12)</sup>、XGBoostには xgboost<sup>13)</sup>、深層学習については darch<sup>14)</sup>を用い、darch のパラメータとしては、中間層（10）および中間層（10, 5）、中間層（20）、中間層（20, 10）、中間層（40, 10）、中間層（40, 20）、中間層（40, 30）、中間層（80, 20）、中間層（80, 30）、反復学習回数を100とした。今回はどのパッケージについても、中間層を2層にした場合以外は、デフォルトのパラメータ

設定を利用した。

次に、構築した分類器の性能評価については、データ集合をランダムに2分割し、片方を訓練標本、もう一方をテスト標本として正答率を算出することを100回繰り返し、平均正答率を算出した（repeated 2-fold cross validation<sup>15)</sup>）。

使用するキーワード選択数は1位のみから1,000位までそれぞれデータセットを用意し、性能を評価した。

## 2.5 動作環境

対応分析、分類器構築、性能評価については、Fujitsu PRIMERGY RX2530 M2（Xeon プロセッサー E5-2690v4 (2.60 GHz), 32 GB メモリ）を用いた。

## 3. 結果

### 3.1 正答率

各手法のキーワード数別正答率のプロットを図3に示す。

キーワード選択数の増加に伴い、どの手法も単調に増加しているが、キーワード選択数150付近でほぼ横ばいとなった。キーワード選択数4以上

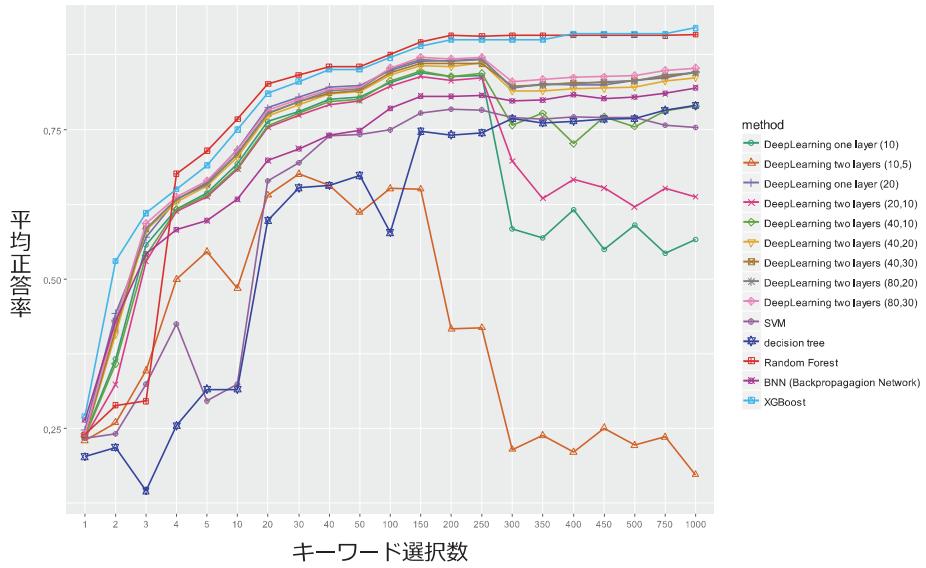


図3 各手法のキーワード数別による性能評価結果

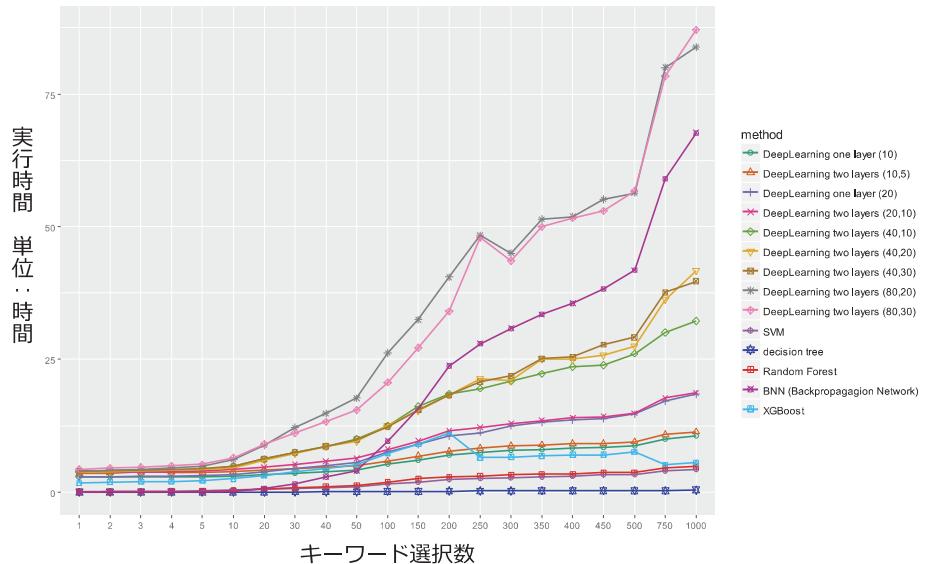


図4 各手法のキーワード数別による実行速度

では、XGBoost, Random Forest の正答率が同程度に高く、他の手法よりも高い分類精度を示した。次いで、深層学習の精度が高いが、2層（10, 5）は1層に比べて性能が劣っていた。その他の決定木、SVM、BNNは、キーワード選択数の増加とともに、精度が上昇していくものの、XGBoost, Random Forest, 深層学習などの精度

の高さは出でていない。

### 3.2 実行速度

100回試行の実行速度の比較を図4に示す。深層学習で平均正答率ピークであったキーワード選択数250に対して、決定木が13分、SVMが2時間36分、Random Forestが3時間3分であったのに対し、深層学習（中間層（10））では7時間24

分であった。今後、特に実行時間の長い深層学習は中間層を含めたパラメータの設定等で高速化を図れるかどうか検討する必要がある。BNN は27時間59分と他の手法と比べて実行時間の長さが突出している。XGBoost はキーワード数に応じて単調に処理時間が延びておらず、手法の特性によるものと考えられるが、さらなる検証が必要となる。

#### 4. 考察

##### 4.1 性能評価

アンサンブル学習である XGBoost と Random Forest の正答率の高さが他の手法に比べて、極めて高かった。アンサンブル学習のバギングを用いる Random Forest よりブースティングを用いる XGBoost の方がわずかであるが高い精度を示している。キーワード選択数による正答率の変化については、SVM、深層学習ともにキーワード選択数250がピークで、SVM の正答率が78.3%，深層学習が86.8%となり、10%近い性能の差が得られた。深層学習は、キーワード選択数250までは、中間層の違いがあっても、同様の分類精度の推移を示している。これは中間層ニューロン数の調整によって精度が高くなることを示している。この実験条件下では、中間層が増加した方が精度は上昇し、中間層のニューロン数を増加させることで、Random forest の正答率を越える可能性があるか検証を進める必要がある。表3にその結果の一部を示した。正答率の高いキーワード選択数を250と固定し、同様の交差検証法で正答率を評価している。

以上のごとく、高次の関係性を想定することで性能が上がる可能性があるが、その性能向上は数パーセント程度にとどまっている。このあたり、

表3 中間層ニューロン数による正答率変化

中間層	キーワード選択数	平均正答率
1層(10)	250	0.840
1層(20)	250	0.868
2層(10,5)	250	0.418
2層(20,10)	250	0.836
2層(40,20)	250	0.862
2層(40,30)	250	0.860
2層(80,20)	250	0.867
2層(80,30)	250	0.871
3層(80,40,20)	250	0.850
3層(160,80,40)	250	0.870

中間層の設定に試行錯誤しているが、中間層を適切に調整し、Pooling, DropOut と言ったフィルタリングを用いることで、Random forest と同等の性能あるいはそれ以上が期待できるのかもしれない。

##### 4.2 分類正誤表

実際に分類器がどのように誤判別しているかを、高い正答率を示したキーワード選択数250での結果を表4、表5に示す。網掛けの項目が誤判別を起こしている箇所である。深層学習の分類正誤表を見ると、白内障の片眼（020110xx97xxx0）と両眼（020110xx97xxx1）で誤りが一番多く、誤判別が際立っている。白内障と他の疾患の分類が大きく効いているため、片眼と両眼の区別がついていないことが考えられる。

XGBoost と深層学習の分類正誤表を比較すると、XGBoost は類似症例で誤判別しているのに対し、深層学習では、誤判別は類似症例の他にも広範囲に散在していることが分かった。

誤判別表の中で誤判別の頻度が高いケース（頻度3以上）をピックアップし、表6に示した。白内障や肺の悪性腫瘍など同じ病状内で誤判別となっており、DPC コードの3層目（図5参照）で主に誤判別となっていることが分かる。記載内

表 4 XGBoost による分類正誤表

## XGBoost予測のDPCコード

表 5 深層学習による分類正誤表

## DeepLearning予測のDPCコード

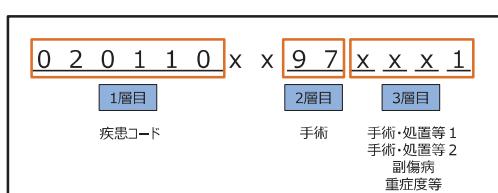


図5 DPCコード14行の構造

容が似通ってしまっており、誤判別となっていると推測される。

さらなる検証のため、1層目・2層目のDPCコード先頭10桁で症例データをまとめた上で解析を行った。その結果の一部を表7に示す。

表6 DeepLearningの誤判別の頻度が高いケース

正解	予測	誤判別頻度
白内障、水晶体の疾患 手術手術あり 重症度等片眼 (020110xx97xxxx)	白内障、水晶体の疾患 手術手術あり 重症度等両眼 (020110xx97xxxx)	17
白内障、水晶体の疾患 手術手術あり 重症度等両眼 (020110xx97xxxx)	白内障、水晶体の疾患 手術手術あり 重症度等片眼 (020110xx97xxxx)	25
肺の悪性腫瘍 手術手術なし 处置等1あり 处置等2なし 副傷病名なし (040040xx99100x)	肺の悪性腫瘍 手術手術なし 处置等1なし 处置等2なし (040040xx9900xx)	3
肺の悪性腫瘍 手術手術なし 处置等1なし 处置等2あり (040040xx9901xx)	肺の悪性腫瘍 手術手術なし 处置等1なし 处置等2なし (040040xx9900xx)	3
全身性臓器障害を伴う自己免疫性疾患 手術手術なし 处置等2なし (070560xx99x0xx)	全身性臓器障害を伴う自己免疫性疾患 手術手術なし 处置等2なし (070560xx99x0xx)	8
肺炎、急性気管支炎、急性細気管支炎(15歳以上) 手術手術なし 处置等2なし (040080xx0990xx)	全身性臓器障害を伴う自己免疫性疾患 手術手術なし 处置等2なし (070560xx99x0xx)	7
肺炎、急性気管支炎、急性細気管支炎(15歳以上) 手術手術なし 处置等2なし (040080xx0990xx)	慢性腎炎症候群・慢性間質性腎炎・慢性腎不全 手術手術なし 处置等1なし 处置等2なし 副傷病名なし (110280xx9900xx)	3
肺の悪性腫瘍 手術手術なし 处置等1なし 处置等2なし (040040xx9900xx)	肺の悪性腫瘍 手術手術なし 处置等1なし 处置等2あり(040040xx9904xx)	5
慢性腎炎症候群・慢性間質性腎炎・慢性腎不全 手術手術なし 处置等1なし 处置等2なし 副傷病名なし (110280xx9900xx)	2型糖尿病(糖尿病性ケトアシドーシスを除く。) (100070xxxxxxxx)	5
肝・肝内胆管の悪性腫瘍(続発性を含む。) 手術その他の手術あり 处置等2なし (060050xx970xx)	肺の悪性腫瘍 手術手術なし 处置等1なし 处置等2なし (040040xx9900xx)	3
肝・肝内胆管の悪性腫瘍(続発性を含む。) 手術その他の手術あり 处置等2なし (060050xx970xx)	胆管(肝内外)結石、胆管炎 手術限局性腹腔鏡手術等 处置等2なし 副傷病名なし (060340xx03xx00xx)	8
脛梗塞(CS10未満) 手術手術なし 处置等1なし 处置等23あり 副傷病名なし (010060xx099030xx)	慢性腎炎症候群・慢性間質性腎炎・慢性腎不全 手術手術なし 处置等1なし 处置等2なし 副傷病名なし (110280xx9900xx)	3

表7 DPCコード先頭10桁でまとめたデータでの解析結果

手法	キーワード選択数	平均正答率
深層学習1層(10)	250	0.909
深層学習1層(20)	250	0.922
RandomForest	250	0.935
XGBoost	250	0.942

分類精度が高かった深層学習、Random Forest, XGBoost の手法を試みたが、いずれも平均正答率が90%を越えており、一番高いXGBoostが94%を示している。同症例内の判別精度を上げることが、分類器の精度向上につながることが判明した。

#### 4.3 tf-idfとの比較

本研究では、対応分析を用いてキーワード選択を行ったが、比較としてtf-idfにてキーワード選択したデータセットで、分類器適用の検証を行った。その結果を図6に示す。

適用した機械学習の手法として、決定木、SVM、Random Forest、深層学習の中間層(10)、中間層(20)および中間層(20, 10)で検

証を行った。深層学習は想定した通り、10~20%程度の低調な結果を示しているが、Random ForestやXGBoost、決定木は対応分析のデータセットを使用した時と同等の正答率を示している。これは、Random Forestなどが、解析に使用するデータ中に分類に有効なキーワードが含まれていると高い正答率を示すことが考えられる。

Random Forestにおける属性の重要度を取り出すことが出来るため、対応分析とtf-idfのデータについて、それぞれの一部を表8に示す。重要度ランクの全体の10%内で重複しているキーワードを網掛けしている。重要度が高い属性は、対応分析とtf-idfであり大きく違いが無く、同じキーワードが効いているという点で対応分析とtf-idfが同じように高い正答率が出しているものと考える。

#### 4.4 年度データ別での訓練とテスト

分類器の実用化に向けて、年度毎のデータを用いての分類器の精度検証も行った。学習データを2016年度のDPC症例上位20(症例データ2,401件)とし、テストデータを学習データで選択した20症

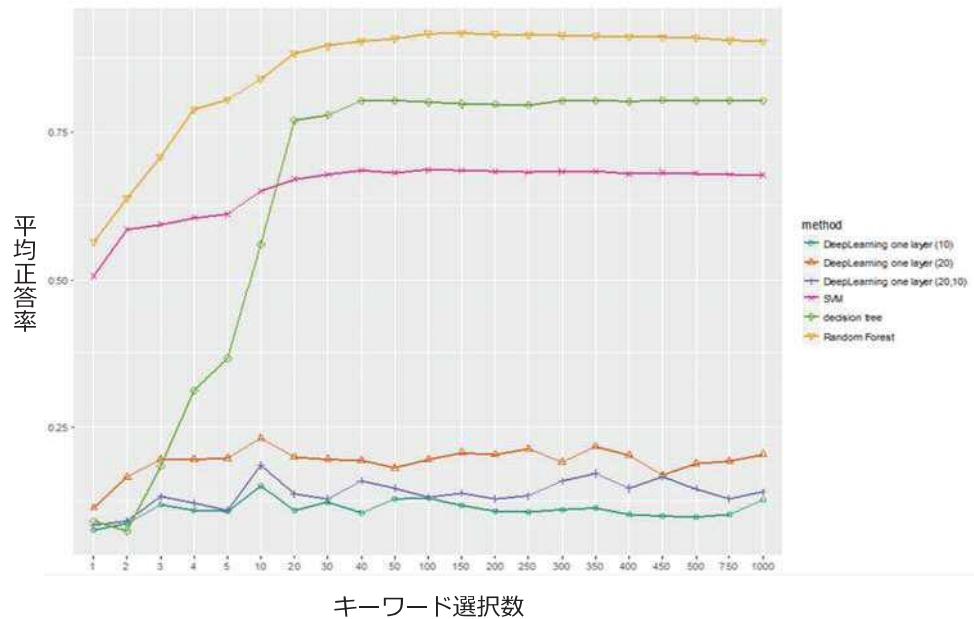


図6 tf-idf のデータセットを使用した性能評価結果

表8 Random Forestにおける属性の重要度

Keyword	重要度
IOL	23.1530
PEA	20.0548
白内障	14.9895
性	10.3934
時	9.8148
入院	9.5360
筋腫	9.1217
子宮	9.0723
TC	8.3702
既往	8.0082
+	7.8548
呼吸	7.5840
施行	7.5825
R	7.4382
CT	7.0948
管	6.9223
日	6.3882
コース	6.3673
腹部	6.2281
剥離	6.0819
出生	5.7628
肺	5.5474
気管支	5.4993
帝王切開	5.4515
尿	5.2419

Keyword	重要度
IOL	18.0187
PEA	12.7238
子宮	9.2338
白内障	9.0422
に	8.5200
TC	7.9378
筋腫	7.6881
を	6.8372
は	6.6894
の	6.6521
病歴	6.2933
と	6.2885
ない	6.2482
/	5.3351
出生	5.3047
2	5.2634
BOM	5.0317
所見	4.9640
気管支	4.9082
+	4.8415
mg	4.8181
が	4.7481
1	4.7134
で	4.6558
-	4.6215

対応分析

tf-idf

例を2017年度から抽出（症例データ2,574件）し、分類を試みた。年度間で重複するキーワードのみを解析対象とした。キーワード選択数を250に

し、決定木、SVM、BNN、Random Forest、XGBoost、深層学習の1層（10）、1層（20）、および2層（40、20）を試した。解析結果を表9

表9 2016年データで学習、2017年度データでテストを行った分類器精度

手法	キーワード選択数	正答率
決定木	250	0.203
SVM	250	0.483
BNN	250	0.612
深層学習1層(10)	250	0.280
深層学習1層(20)	250	0.731
深層学習2層(40,20)	250	0.680
RandomForest	250	0.813
XGBoost	250	0.815

に示す。

ここでも XGBoost, Random Forest が、前述の交差検証法で行った実験ほどではないが、81%と高い精度を示しており、実用化に向けてさらなる検証を行っていきたい。

## 5. おわりに

本研究では、テキストに形態素解析を適用した後、対応分析による DPC 毎のキーワードの選定を行い、選ばれたキーワードに機械学習を適用し、キーワードによる DPC コーディングを行う分類器を構築した。

退院時要約を用いた検証結果から、SVM、決定木が最大78%程度の正答率であったのに対し、

XGBoost, Random Forest が90%以上の正答率を上げ、深層学習では86%以上の精度を上げることができた。

本データでは実行速度、性能の点を考えれば、Random Forest を分類器構築方法として選択するのが最適であるかもしれないが、深層学習についてはまだパラメータ調整の余地がある。さらに、同症例内の分類を正しく行う事が出来れば、さらなる精度向上を見込めると考える。

構築した分類器は高い正答率を示しており、診療文書の記載内容からテキストマイニングにより疾患の予測が可能となることが示唆された。本研究での検証を行っていく中で、実際に付与されたDPC コードに誤りがあり、分類器の結果の方が正しいというケースが存在することも確認された。年度毎のデータを用いた検証も行い、平均正答率80%と、ある程度の結果も得られた。この結果を踏まえて、退院時要約の記載内容から DPC コードが推定できるとすれば、退院患者に付与された DPC コードが正しいかどうかチェックを行うなど、実際に診療支援に役立てることが可能となると考える。

## 参考文献

- Eric J Topol. High-performance medicine: the convergence of human and artificial intelligence.: Nature Medicine, 2019.: 44-56. vol. 25.
- 津本周作, 矢入郁子, 古崎晃司. 医用人工知能研究会, 人工知能 (特集: 研究会紹介) 34(5) : 644-647, 2019.
- 鈴木隆弘, 土井俊祐, 木村隆, 嶋田元, 畠山豊, 本多正幸, 松村泰志, 横井英人, 島井健一郎: 退院サマリーサーチを支援する DPC 判定アプリケーション. 第38回医療情報学連合大会, pp.786-787, 2018.
- 三浦康秀, 荒牧英治, 大熊智子, 外池昌嗣, 杉原大悟, 増市博, 大江和彦: 電子カルテからの副作用関係の自動抽出. 言語処理学会第16回年次大会, pp 78-81, 2010.
- 荒牧英治, 三浦康秀, 外池昌嗣, 大熊智子, 増市博, 大江和彦: 退院サマリ文章可視化システムの構築. 言語処理学会第15回年次大会, pp.348-351, 2009.
- 小野大樹, 高林克己, 鈴木隆弘, 橋井英人, 井宮淳, 里村洋一: テキストマイニングによる退院時要約自動分類の試み. 医療情報学24(1), p.35-44, 2004.
- InterSystems: InterSystems Caché, <https://www.intersystems.com/jp/products/cache/> (2019)

- 8) 石田基広 : RMeCab, <http://rmecab.jp/wiki/index.php?RMeCabFunctions> (2016)
- 9) Therneau, T.M. and Atkinson, E. J.: An Introduction to Recursive Partitioning Using the RPART Routines (2015)
- 10) Karatzoglou, A., Smola, A., Hornik, K., and Zeileis, A.: kernlab -- An {S4} Package for Kernel Methods in {R}, Journal of Statistical Software, Vol.~11, No.~9, pp. 1-20 (2004)
- 11) W. N. Venables and B. D. Ripley, Modern Applied Statistics with S, 4 th ed. NewYork: Springer, 2002, ISBN 0-387-95457-0.[Online]. Available: <http://www.stats.ox.ac.uk/pub/MASS4>
- 12) Liaw,~A. and Wiener,~M.: Classification and Regression by randomForest, R News, Vol.2, No.3, pp. 18-22 (2002)
- 13) Tianqi Chen, Tong He, Michaël Benesty.: XGBoost, <https://xgboost.readthedocs.io/en/latest/>
- 14) Drees,M.: Implementierung und Analyse von tiefen Architekturen in R, Master's thesis, Fachhochschule Dortmund (2013)
- 15) Ji-Hyun Kim, Estimating classification error rate: Repeated cross-validation, repeated hold-out and bootstrap, Computational Statistics & Data Analysis, 53(11), p.3735-3745, 2009.