

テキストマイニングによる 退院サマリー自動分類の試み

長瀬 永遠

富山県立大学 情報基盤工学講座

December 4, 2020

本研究の目的

電子化され、大量に蓄積された医療文書に対してテキストマイニングを行うことで、医療文書の2次利用可能性を示す。

研究のながれ

- ① 医療文書に対してテキストマイニングを行うための索引の作成
- ② 各疾患における退院サマリーの特徴抽出
- ③ 抽出した特徴をもとに、退院サマリーから疾患名が特定できるかを検証
- ④ 特定した例に対してデンドログラムを作成し、分類を視覚化

はじめに

対象と方法

実際の実験と結果

おわりに

千葉大学附属病院病院情報システムに保存されている 36,335 症例の退院サマリー

⇒ 症例数が 100 以上ある 50 疾患を算出

⇒ 各臓器の代表的疾患である 13 疾患を選定

Table 1: 各臓器の代表 13 疾患とその症例数

疾患名	臓器	ICD-9	症例数
胃悪性新生物	消化器	151	524症例
肝、肝内胆管の悪性新生物	肝臓・胆	155	483症例
気管・気管支の悪性新生物	呼吸器	162	687症例
乳房の悪性新生物	乳房	174	363症例
前立腺悪性腫瘍	男性器	185	340症例
腎臓の悪性新生物	腎臓	189	158症例
リンパおよび組織球組織の悪性新生物	血液	202	153症例
糖尿病	内分泌	250	293症例
統合失調症	精神	295	104症例
白内障	眼	366	777症例
喘息	アレルギー	493	114症例
癰疽拘縮	皮膚	709	133症例
変形性関節症	運動器	715	188症例

形態素解析

- 使用したシステム：「茶筌」（奈良先端科学技術大）
- 追加した辞書：MEID 辞書（医学辞書）

辞書の再構築

臨床現場にて作成された文書には、略語が多用される。



退院サマリーを形態素解析し、MEID 辞書にない単語から各疾患における出現頻度上位 50 位までの用語を辞書に追加。

退院サマリーベクトル

D : 対象とする文書集合, $d_1, d_2, \dots, d_j, \dots, d_n$: 退院サマリー,
 $w_1, w_2, \dots, w_i, \dots, w_m$: D から抽出された索引語,
 α_{ij} : ある退院サマリー d_j におけるある索引語 w_i の重み

$$\vec{d}_j = [\alpha_{1j} \ \alpha_{2j} \ \dots \ \alpha_{ij} \ \dots \ \alpha_{mj}]^T \quad (1)$$

⇒ 退院サマリーベクトル

索引語文書行列

$$\vec{D} = [\vec{d}_1 \ \vec{d}_2 \ \dots \ \vec{d}_n] = \begin{pmatrix} \alpha_{11} & \alpha_{12} & \dots & \alpha_{1n} \\ \alpha_{21} & \alpha_{22} & \dots & \alpha_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \alpha_{m1} & \alpha_{m2} & \dots & \alpha_{mn} \end{pmatrix} \quad (2)$$

⇒ 索引後文書行列

tf×idf 法

α_{ij} : 重み,

$$\alpha_{ij} = \frac{l_{ij}g_i}{n_j} \quad (3)$$

f_{ij} : w_i の d_j における出現頻度

n : 対象とする退院サマリーの症例数

n_i : 対象の退院サマリーにおける w_i を含む症例数

$$l_{ij} = \log(1 + f_{ij}) \quad (4)$$

$$g_i = \log\left(\frac{n}{n_i}\right) \quad (5)$$

$$n_j = \sqrt{\sum_{i=1}^m (l_{ij}g_i)^2} \quad (6)$$

最大木問題

各ノード（今回は疾患）をつなぐ木の重み（今回は類似度）の総和が最大となる木を求める問題。




図 1: デンドログラムの例

13 疾患の重要語の抽出

8/11

索引語の抽出

茶笥を用いて 13 疾患の退院サマリーの形態素解析

↓ 結果

7,918 語の索引語が抽出

Table 2: 重み上位 10 位の索引語 1

	胃腸		肝臓		肺臓		乳腺		前立腺臓	
	索引語	α	索引語	α	索引語	α	索引語	α	索引語	α
1	前庭	0.104	エタノール	0.092	右中葉	0.082	乳癌	0.195	サドルブロック	0.154
2	胃体	0.101	PIHA	0.09	扁平上皮癌	0.078	C領域	0.172	前立腺	0.149
3	フード	0.099	コイル	0.088	気管分岐部	0.075	乳癌症	0.164	前立腺全摘術	0.146
4	胃鏡視	0.092	前枝	0.086	肺腫	0.071	肺病	0.159	骨髄リンパ節	0.134
5	SE	0.089	Fc	0.083	人口	0.069	アルパデックス	0.141	PRC	0.121
6	胃全摘術	0.089	食道静脈瘤	0.08	肺腫瘍	0.068	上肢至上	0.139	肺手術	0.117
7	GFS	0.087	門脈	0.079	遠隔	0.067	マモグラフィー	0.125	ホムベン	0.109
8	非全摘	0.083	アミロレバン	0.077	ブラシ	0.067	癌腫	0.121	タンデム	0.104
9	胃切除術	0.081	右枝	0.077	壁側肺腫	0.067	大動脈	0.112	側肺腫	0.104
10	最終	0.079	完全壊死	0.077	腹膜部	0.067	乳房	0.111	直腸出血	0.104

	腎臓		悪性リンパ腫		糖尿病		統合失調症		白内障	
	索引語	α	索引語	α	索引語	α	索引語	α	索引語	α
1	腎臓癌	0.167	PUVA	0.108	精食	0.11	幻聴	0.122	点眼液	0.211
2	腎炎	0.144	可溶性	0.102	腎症	0.091	形質	0.107	眼	0.205
3	尿管腫瘍	0.132	結注	0.1	尿子体出血	0.089	尿毒症	0.101	ミリンP	0.173
4	右腎全	0.128	幹細胞	0.097	神経伝導速度	0.087	尿糖	0.098	水晶体乳化	0.168
5	腎臓癌	0.121	下腹	0.095	ケトン	0.086	検査薬	0.095	内服	0.156
6	右尿管口	0.112	悪性リンパ腫	0.092	グルカゴン	0.082	変換	0.094	乳化	0.148
7	腎臓手術	0.11	リンパ腫	0.087	ケトン体	0.081	行為	0.093	眼内レンズ	0.142
8	腎部分切除術	0.104	右腎臓	0.083	止血療法	0.079	尿	0.089	吸引術	0.137
9	尿大率	0.103	尿管	0.083	マイクロゾーム	0.077	変換状態	0.087	右眼	0.136
10	上極	0.103	上咽頭	0.079	肥満度	0.072	ターゲル	0.089	左眼	0.132

Table 3: 重み上位 10 位の索引語 2

	喘息		歯肉歯痛		悪性腎臓癌	
	索引語	α	索引語	α	索引語	α
1	インテール	0.192	歯肉腫瘍	0.189	腎臓	0.14
2	陥凹	0.12	エキスベンダー	0.179	下咽頭腫	0.125
3	スキ	0.118	プロテーゼ	0.146	内反	0.12
4	ダニ	0.118	歯肉術	0.143	前葉	0.118
5	歯肉上窩	0.112	シリコン	0.142	骨髄形成	0.113
6	呼吸性喘鳴	0.11	腫瘍	0.134	左肺	0.112
7	持続吸入	0.108	ケロイド	0.118	CE角	0.11
8	大発作	0.105	左上咽頭	0.118	外反	0.11
9	ブタクサ	0.103	全層縮皮	0.116	肥満度	0.11
10	湿性	0.101	修正	0.112	動悸性	0.11

退院サマリーからの疾患の特定

9/11

はじめに
対象と方法
実際の実験と結果
おわりに

特徴抽出に用いたのとは別の 13 疾患の退院サマリーを各 30 症例、計 390 症例無作為に抽出し、既出の 13 疾患における退院サマリーベクトルとの内積を計算。
⇒13 疾患に対する類似度を、症例ごとにレーダーチャートで表現。

Table 4: 各疾患の正診率

疾患名	臓器	ICD-9	診断と一致	複数疾患の疑いあり	診断と異なる判定	判定不明
胃癌	消化器	151	24 / 30	4 / 30	0 / 30	2 / 30
肝臓	肝臓・胆嚢	155	20 / 30	2 / 30	0 / 30	8 / 30
肺癌	呼吸器	162	19 / 30	3 / 30	0 / 30	8 / 30
乳癌	乳房	174	19 / 30	1 / 30	1 / 30	9 / 30
前立腺癌	男性器	185	25 / 30	3 / 30	0 / 30	2 / 30
腎臓	腎臓	189	21 / 30	2 / 30	1 / 30	6 / 30
悪性リンパ腫	血液	202	17 / 30	6 / 30	1 / 30	6 / 30
糖尿病	内分泌	250	19 / 30	7 / 30	2 / 30	2 / 30
統合失調症	精神	295	28 / 30	1 / 30	0 / 30	1 / 30
白内障	眼	366	28 / 30	2 / 30	0 / 30	0 / 30
喘息	アレルギー	493	27 / 30	0 / 30	0 / 30	3 / 30
癰疽拘縮	皮膚	709	13 / 30	0 / 30	4 / 30	13 / 30
変形性関節症	運動器	715	30 / 30	0 / 30	0 / 30	0 / 30
計			290 / 390 (74%)	31 / 390 (8%)	9 / 390 (2%)	60 / 390 (15%)

13疾患のデンドログラム

10/11

はじめに
対象と方法
実際の実験と結果
おわりに




図 2: 13 疾患の類似度の最大全域木によるデンドログラム

- 胃癌と肝癌の類似度が最も高い。
⇒ 両疾患とも悪性腫瘍ということから妥当。
- 変形性関節症と癱瘓拘縮のグループの類似度が最も低い。

今後の課題

- 解析に用いる辞書の改良
- 扱うデータを増やすことによる, 退院サマリーベクトルの改善
- 重み付け方法の再考
- より多数の疾患を適用したデンドログラムの妥当性の確認

今後の展望

- 既存の疾患の退院サマリーベクトルとの類似度をもとにした, 新たな疾患の発見 (退院サマリーベクトル)
- 合併症の可能性の示唆 (レーダーチャート)
- 疾患群同士の相関関係の視覚化による新たな知見の誘発 (デンドログラム)