

1Q-07

# 傷病と症状の共起関係に基づく初診患者のための診療科判定システムの構築

安永 翼† 高林 徹‡ 村上 優行‡ 伊藤 豪§ 中田 雅也¶ 濱津 文哉¶  
濱上 知樹¶

†横浜国立大学 理工学部 ‡AR アドバンステクノロジー プロフェッショナルサービス統括部  
§横浜国立大学 未来情報通信医療社会基盤センター ¶横浜国立大学 大学院工学研究院

## 1 はじめに

初診患者が診療科を受診するとき受診科判断を誤ると患者自身や関係する医療従事者に余分な負担がかかるが、近年は診療科の細分化により初診患者の受診科判断が困難になっている。そのため主訴(患者の訴える症状)から自動で診療科を判定するシステムの需要が高まっている。診療科判定では直接的な対応がない主訴と診療科をどのように結び付けるかが問題となる。本研究では傷病と症状の共起関係から主訴と診療科を対応付けることを目的とする。本稿では傷病に関する文書を用いて主訴から診療科を判定する方法を提案し、その有効性を示すために傷病文書から抽出した症状を主訴として診療科判定実験を行った。

## 2 提案手法

### 2.1 傷病と症状の共起関係

医師は患者の症状や検査値から傷病を判断し治療方針を決定する。これは症状や検査値の異常が傷病に起因するためである [1]。本研究では傷病が原因となり症状が現れることを傷病と症状が共起すると捉え、提案手法ではこの共起関係を診療科判定に利用する。また近年は医師が情報提供または編集している Web 上の医学・医療情報サイトから傷病に関する文書が容易に得られるようになった。この傷病文書には共起する症状の記述が含まれるため症状からなる主訴との文書類似度を計算可能であり、多くの場合推奨される受診科も記述されているため各傷病文書に診療科ラベルを付与できる。このような傷病文書の性質から提案手法では傷病文書群を学習データとして文書分類手法を適用する。

### 2.2 文書分類手法による診療科判定

文書分類手法の一つにベクトル空間モデルにおける k nearest neighbor(kNN) 法がある [2]。ベクトル空間モデルでは文書を各単語に対して一つの実数値を要素として持つベクトルとして表現する。kNN 法は分類対象文書のベクトルの近傍 k 個の文書ベクトルを持つ教師ラベルで多数決を取り分類する手法である。ベクトル空間モデルでは多数決のための投票を類似度により重み付けすることができる。

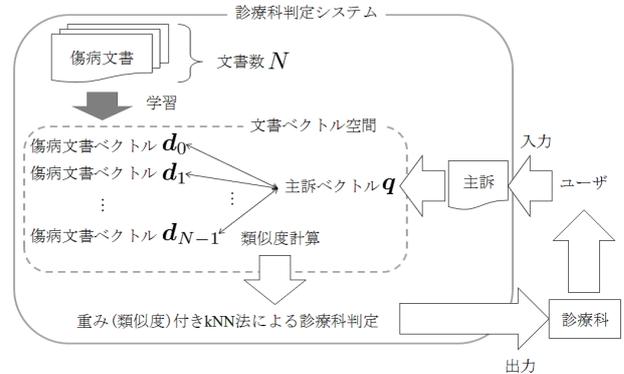


図 1: 診療科判定の流れ

提案手法による診療科判定の流れを図 1 に示す。提案手法では傷病文書群から単語の tf-idf を特徴とする文書ベクトル空間を学習し、tf を特徴としてベクトル化した主訴と各傷病文書との類似度を重みとした重み付き kNN 法によって診療科を判定する。文書ベクトル空間における類似度  $sim(q, d)$  は式 (1) のようにコサイン類似度を用いる。

$$sim(q, d) = \cos \theta = \frac{q \cdot d}{|q||d|} \quad (1)$$

$q$  は主訴ベクトル、 $d$  は傷病文書ベクトル、 $\theta$  は二つのベクトル間の角度を表す。また式 (1) を用いて主訴ベクトル  $q$  に対する診療科  $c$  のスコア  $score(c, q)$  を式 (2) のように計算する。

$$score(c, q) = \sum_{d' \in S_k(q)} I_c(d') sim(q, d') \quad (2)$$

$S_k(q)$  は主訴ベクトル  $q$  の近傍 k 個の文書ベクトル集合である。 $I_c(d')$  は  $d'$  が診療科  $c$  のラベルを持っていれば 1、持っていないならば 0 をとる。式 (2) は診療科  $c$  のラベルを持つ傷病に関して主訴との類似度を重みとした重み付き和である。

### 2.3 追加的処理

後述の実験では用いないが実際のシステム運用時に必要になると考えられる処理について述べる。

#### 2.3.1 傷病の発生確率

傷病によって発生確率は異なるが 2.2 ではその発生確率を考慮していない。傷病の発生確率を考慮した結果を得るために患者数に関する統計 [3] を用いて傷病の発生確率を計算する。患者の性別・年齢によって確率分布は変化すると考えられるため、性別・年齢がわかっている際にはベイズの定理によって確率分布を更

Construction of clinical department decision system for patients based on co-occurrence relation between disease and symptom  
†Tsubasa YASUNAGA ‡Toru TAKABAYASHI ‡Masayuki MURAKAMI §Go ITO ¶Masaya NAKATA ¶Fumiya HAMATSU ¶Tomoki HAMAGAMI  
†Department of Science and Engineering, Yokohama National University  
‡Department of Professional Service, AR Advanced Technology  
§Center for Future Medical Social Infrastructure Based on Information Communication Technology, Yokohama National University  
¶Faculty of Engineering, Yokohama National University

新する。性別・年齢を  $X$  としたとき傷病  $Y$  である確率はベイズの定理より式 (3) のように求められる。

$$P(Y|X) = \frac{P(X|Y)P(Y)}{P(X)} \quad (3)$$

統計 [3] では傷病が傷病分類として扱われているため、学習データとして用いた傷病を各傷病分類に割り当てる必要がある。傷病分類と名称が一致する傷病はその傷病分類に割り当て、一致しない傷病は傷病分類名を文書ベクトル化したときに最も類似度が大きくなるものに割り当てた。また傷病分類名に「その他」を含むものは比較的多数の傷病がまとめられ患者数が多くなる。この傷病分類に割り当てられた傷病は発生確率が実際より大きくなってしまふと考えられる。したがって重み付き多数決を取る際にはその傷病文書ベクトルを除外する。

### 2.3.2 結果改善のための主訴への症状追加

ある診療科のスコアに最も大きな影響を与えるのはその診療科ラベルを持つ傷病文書ベクトルのうち主訴ベクトルの最近傍にあるベクトルであり、この傷病文書の特徴付ける症状を主訴に加えればその診療科のスコアは向上する。それぞれの診療科にスコアを向上させる症状を割り当て提示することでユーザによる判定結果の改善が期待できる。主訴との類似度が 0 でない傷病について tf-idf を再計算し、ある診療科ラベルを持つ主訴ベクトルの最近傍にある傷病文書ベクトルについて tf-idf が最大の単語を含む症状をその診療科に割り当てる。該当する症状が複数ある場合にはスコアの向上幅が大きい症状を採用する。

## 3 実験

### 3.1 設定

学習データには Web サイト [4] からスクレイピングにより取得した 1,406 件の傷病に関する文書を用いた。診療科は 30 種類であった。テストデータには学習データから症状を抽出した文書を用いた。ただし症状は 1 つ以上の単語で構成されるため、本稿では人手により症状として扱うフレーズ群を学習データから作成し、その種類は 1,017 種類となった。テストデータを作成する際に症状フレーズの抽出処理のみでは同じ症状が重複して抽出される可能性がある。実際の運用時には同じ症状は重複して入力されない想定のためこの重複をなくした。さらに症状フレーズがないテストデータと正解診療科ラベルがないテストデータは除外した。

形態素解析には医療用語辞書 Comejisyo を組み込んだ Mecab を使用し、名詞・動詞・形容詞を特徴語として特徴語辞書を作成した。特徴語の種類 (文書ベクトルの次元数) は 16,602 となった。診療科判定に用いた kNN 法の  $k$  は文書数 1,406 の場合と 1 (最近傍法) の場合、5 の場合それぞれについて実験した。正解率は使用したテストデータ数に対する正解したテストデータ数の比として計算した。

スコア最大の診療科が正解診療科ラベルに含まれれば正解とする。スコア最大の診療科が複数ある場合はそのいずれかが正解診療科ラベルに含まれれば正解とする。

主訴であるテストデータとテストデータ作成元の傷病の類似度が大きいほど診療科を正しく判定しやすく

表 1: 正解率

	正解率 [%]
診療科判定 ( $k = 1406$ )	49.31
診療科判定 ( $k = 5$ )	<b>52.55</b>
診療科判定 ( $k = 1$ )	52.47
傷病推定	20.66

なるという観点から傷病推定実験も行った。主訴との類似度が最大の傷病がテストデータの作成元である傷病と一致すれば正解とする。傷病推定実験では正解の診療科ラベルがないテストデータも使用した。

### 3.2 結果と考察

正解率を表 1 に示す。傷病推定に対して診療科判定の正解率が高い。傷病推定実験と  $k = 1$  の診療科判定実験の結果から、主訴との類似度が最大の傷病が正解の傷病と一致しなくても診療科判定は正解する可能性があることがわかる。このことから傷病の特徴付ける症状には診療科ごとにある程度の偏りがあると言える。

診療科判定実験において  $k = 5$  では  $k = 1$  より正解率が向上している。これは類似度最大の傷病だけでなく類似度の高い複数の傷病から重み付き多数決を取った影響である。しかし  $k = 1,406$  のときには正解率が低下した。これにより多数決を取る診療科を過剰に増加させると正解でない診療科ラベルを持つ傷病の影響が大きくなることがわかった。これらの結果から判定精度を向上させるためには最適な  $k$  の値を設定する必要がある。

診療科は 30 種類であり一般的な文書分類問題よりカテゴリ数が多く、また分類対象文書 (主訴) は学習データに対して単語数が少ないため、本実験の診療科判定は文書分類としては困難なタスクである。これを踏まえると診療科判定の正解率が約 50 % であることは提案手法の有効性を示していると言える。

## 4 おわりに

本稿では傷病と症状の共起関係に基づき診療科判定に文書分類手法を適用することを提案し、実験によりその有効性を示した。文書分類は既に多くの研究がされているためさらなる性能の向上が期待できる。

### 参考文献

- [1] 鬼頭昭三編：病気の成立ちと仕組み，放送大学教育振興会 (1997)。
- [2] Christopher D Manning, Prabhakar Raghavan, Hinrich Schütze.: *Introduction to Information Retrieval*, Cambridge University Press (2008)。
- [3] ”上巻第 63 表 総患者数，性・年齢階級 × 傷病小分類別”，平成 26 年患者調査上巻 (全国)，厚生労働省，〈<http://www.e-stat.go.jp/SG1/toukeidb/GH07010102Forward.do>〉 (参照 2016-10-12)。
- [4] オンライン病気事典 MEDLEY, 〈<https://medley.life/diseases>〉 (参照 2016-7-25)。