一般口演

一般口演27
データ活用・解析

2017年11月23日(木) 12:45 ～ 14:15 D会場 (10F 会議室1002)

[4-D-2-OP27-3] ベイズ学習を用いた女性の健康管理スマホアプリの開発

片山 裕加里, 小山 紘明, 土屋 拓海, 田中 昌昭 （川崎医療福祉大学 医療情報学科）

【目的】
スマートフォンの普及に伴って生理管理アプリ等の女性健康管理アプリが開発され利用されている。しかし、そのほとんどは診察時の利用を想定していないため、問診票に記入する項目を入力する機能がない。そのため、せっかくアプリを利用していても必要な時に必要な情報が引き出せない。そこで、本研究では既存の問診票を精査し、必要な項目をアプリで管理できるようにした。また、入力した情報を有効活用するためにアプリに疾患を予測する機能を実装した。
【方法】
無作為に抽出した10病院の問診票の項目を精査して、病院間で一致した割合が8割以上である場合にその項目の重要性が高いと判断してアプリの入力項目に加えた。疾患の予測にはベイズ学習を用いた。その際、医中誌から子宮頸がん、子宮体がん、子宮筋腫、子宮内膜症、卵巣腫瘍の5つの疾患名で検索して得た原著論文の抄録を用いて分類器の学習を行った。疾患毎に抄録を100件から500件まで100件ずつ増やしながら交差検証によって分類精度を確認し、学習に必要な最適な抄録数を調べた。
【結果】
合計で34個あった問診票の項目の中で10病院全てが挙げていたのは8項目であった。それらは、来院の目的、生理について、最近の月経、閉経、生理痛の有無、生理痛がある人はその回数、薬や注射のアレルギー、飲んでいる薬である。また、8割以上が一致する項目は16個あり、全体の48%を占めていた。疾患分類については、学習に用いる疾患毎の抄録数が200件のとき正解率は68.6%となり最も高かった。
【考察】
女性健康アプリを個人健康記録の一形態と捉えた場合、他のアプリやシステムとの連携が必要となる。 HL7 FHIRなどの標準を用いた相互運用性の確保が望まれる。疾患予測については専門的な用語が頻出する学術論文の抄録ではなく、日常的に使われている用語からなるテキストをコーパスに用いて分類器を学習する必要がある。

©一般社団法人 日本医療情報学会

ベイズ学習を用いた女性の健康管理スマホアプリの開発

片山 裕加里[*1], 小山 紘明[*1], 土屋 拓海[*1], 田中 昌昭[*1]
*1 川崎医療福祉大学 医療情報学科

Development of Smartphone Application for Women's Health Management System Using Bayesian Learning

Yukari Katayama[*1] , Hiroaki Koyama[*1], Takumi Tsuchiya[*1], Masaaki Tanaka[*1]
*1 Department of Health Informatics, Kawasaki University of Medical Welfare

With the spread of smartphones, female health management applications have been developed and used. However, most of them do not assume the use at clinical settings, so there is no function to enter items that were included in the medical interview sheet. Therefore, even if we use the application, we cannot extract necessary information when needed. In this research, we surveyed the existing interview sheet so that necessary items can be managed by the application. In addition, in order to make effective use of the accumulated information, we implemented a function to predict disease.

We examined the items of interview sheet of randomly selected 10 hospitals and added it to our smartphone application if it covered 80% or more. In addition, we used Bayesian learning in order to predict disease. Learning of classifier was carried out by using abstracts of the original papers obtained from ICHUSHI, a Japanese medical literature information database, as well as articles retrieved using Google. While increasing the number of abstracts from 100 to 500 by 100 for each disease, we examined the classification accuracy, and identified the optimal number of abstracts necessary. The same examination was carried out for the internet articles, except that the number of articles was increased from 10 to 50 by 10 for each disease.

As a result, eight items out of 34 were covered by all the hospitals. Sixteen items accounting for 48% of the total were covered by over 80% of hospitals. Concerning the disease classification, the accuracy rate was 62.0% when the number of abstracts was 500 for each disease and was 90.8% when the number of articles was 50 for each disease.

The system developed this time has not yet been demonstrated. It is the future task to extract problems unexpected at the development stage, increase accuracy of disease prediction, and improve user experience by doing demonstration experiments.

Keywords: Women's Health Management System, Smartphone, Bayesian Learning,

1. はじめに

1.1 背景

近年，スマートフォンの普及に伴って生理管理アプリ等の女性健康管理アプリが開発され，利用されている。女性健康管理アプリには，生理周期管理，基礎体温管理，体重管理等の体調を管理・記録する機能がある。これにより，女性は自分の体調について詳しく管理できるようになった。

しかし，既存のアプリの多くはただ体調を管理するだけに留まっている。2013 年度の日本子宮内膜症啓発会議では，2011 年度における有経女性の約 230 万人が子宮内膜症にかかっているが，受療しているのは約 63 万人に過ぎないという報告があった[1)]。この受療患者数は潜在患者数の約 27%に過ぎず，受療を拒む理由には，「月経痛は我慢するのが当たり前」，「婦人科に行きたくない」などの意見があった。女性が生理痛の重大性を理解できていないゆえに我慢してしまうことが受診の妨げになっており，治療を放置しておくと不妊やガンへの発展の危険も明らかになっている。平成 28 年国民生活基礎調査でも女性の子宮がん検診は約 4 割と，婦人科系の受診率が低い傾向にあると分かっている[2)]。このことから，女性は婦人科への受診に対して抵抗感や生理痛は痛くても我慢するものと思っており，現状を改善するためには受診しやすい環境を整備することが重要だと考察した。

1.2 研究の目的

そこで，我々は，現状の改善を行うために，受診を促進して診療に役立つアプリ開発を目指した。既存のアプリの多くは診察時の利用を想定していないため，受診の際に必要な項目がなく，アプリを利用していても必要な時に必要な情報を引き出せない。そこで，受診時のストレスを軽減することで受診を促進できるのではないかと考え，本アプリでは問診票に記入する項目を入力する機能を実装した。また，症状を入力することで疾患名を予測する機能を実装した。この機能により，生理痛を我慢していると重大な病気に繋がる恐れがあると促し，受診の促進を目指す。しかし，この機能はあくまでも女性健康管理及び受診促進が目的であり，疾患予測機能はスマホアプリに蓄積したライフログを有効活用する手段の一つである。

1.3 研究の範囲

今回の研究では，スマホアプリを開発するところまでとし，実証実験にまで至っていないが，受診時に役立てるために問診票に記入する項目を入力できる機能やライフログから疾患を予測する疾患予測機能を試行的に実装し，その問題点や有効性について考察を行った。

1.4 先行研究

女性健康アプリに関する先行研究としては，江川らによるスマートフォンアプリを用いて月経随伴症状などを記録することで月経前症候群（PMS）の管理を行うシステムの開発がある[3)]。彼らは，PMS を正しく診断し適切に治療するには患者が症状を自ら記録することおよび症状の変調を医師との間で共有することが重要だとし，それを簡便化，効率化するためにこのシ

ステムを開発した。開発したシステムを評価するために，被検者をアプリ記録群と紙記録群に分け，84 日間の症状記録を実施した。その結果，アプリ記録群には主治医とのつながりを感じる傾向があり，開発したアプリは従来の紙媒体への記録法に劣らない症状記録法であると報告している。

ベイズ分類に関する先行研究としては，インターネット上の一般ユーザから入手した健康に関するデータが，自動診断システムを作成するための機械学習に利用できるのではないかという仮説のもと，簡易健康情報サイトを独自に立ち上げ，そこから何らかの疾患のために医療機関を受診したユーザの情報を収集し，それを使ってナイーブベイズによる機械学習を行った結果，医師国家試験の臨床実地過去問題を 70%前後の正答率で解くことができたと報告している [4]。

その他，医師が胸部 CT 画像上の肺結節像を読影して入力した画像所見から，ナイーブベイズ分類器を使って診断名を推論するシステムを構築し，医師の正答率を上回る性能を達成したという報告もある [5]。

2. 方法

2.1 入力項目の選定方法

まず初めに，女性疾患関連の診療科で扱う問診票に必要な項目を文献調査した [6]。また，実際に使用されている問診票の項目の分析をした。インターネットの検索エンジンを使って「婦人科　問診票」とキーワードを入力して得られた結果から 10 病院※1 の問診票の項目を精査し，8 割以上の病院にある項目を重要性が高いと判断してアプリに導入した。

また，既存のアプリで管理する項目も必要だと考え，無作為に選んだ 12 のアプリ※2 から項目を拾い出し，それらもアプリに取り入れた。

2.2 疾患予測

2.2.1 ナイーブベイズ

疾患予測とは，アプリに入力されたライフログから罹患している可能性が高い疾患を予測する機能である。この機能を実現するために，機械学習のひとつであるナイーブベイズを用いた。これは収集した情報から疾患の事後確率（つまり，条件付確率）を計算し，それを使って疾患を予測するというものである。ナイーブベイズの元となっているのは，ベイズの定理である。ベイズの定理は，以下の式で表される [7]。

$$P(D|\boldsymbol{W}) = P(D) \cdot P(\boldsymbol{W}|D) / P(\boldsymbol{W})$$

ここで，$P(D|\boldsymbol{W})$ は，文書中に語 $\boldsymbol{W}$ があるとき，それが疾患 D（を記述した文書）である確率で，事後確率と呼ばれる。$P(D)$ は，疾患 D（を記述した文書）である確率で，事前確率と呼ばれる。そして，$P(\boldsymbol{W}|D)$ は，疾患 D（を記述した文書）に語 $\boldsymbol{W}$ がある確率で，尤度と呼ばれる。

疾患予測は，症状を表す語 $\boldsymbol{W}$ を特徴量として入力し，疾患 D を言いあてる多値クラス分類問題（$\boldsymbol{W}\rightarrow D$）として定式化できる。つまり，疾患 D について記述された文書を学習データとして用い，文書を形態素解析して得られた語 $\boldsymbol{W}$ と疾患 D の関係 $P(\boldsymbol{W}|D)$ を学習する。次いで，ベイズの定理から，語 $\boldsymbol{W'}$が与えられたとき，それが疾患 D について記述された文書である確率（事後確率）$P(D|\boldsymbol{W'})$ を求め，それがもっとも大きくなるような疾患 D を正解とする。

使用する学習データは，医学中央雑誌および Google から収集した。この 2 種類を用いた理由は，医学中央雑誌からは専門的な視野から，ネット記事からは一般的な視野からのテキスト情報を収集し，疾患分類性能にどのような違いがあるのかを比較するためである。

また，本研究では，予測対象の疾患を，代表的な女性疾患である「子宮内膜症」，「子宮頸がん」，「子宮体がん」，「子宮筋腫」，「卵巣腫瘍」の 5 つとした。この 5 疾患の学習データを以下に述べる方法で収集し，ナイーブベイズ学習モデルを構築した。

2.2.2 医中誌抄録の収集方法

医中誌 Web[8]を使用して，上述の 5 疾患を検索キーワードとして入力し，抽出された文献の抄録などの文献情報をダウンロードした。その際，絞り込み条件として「原著論文」，「症例報告」，「抄録あり」にチェックを入れた。ダウンロードした文献情報を管理するために，Microsoft Access 2016 を用いて，疾患データベースを構築した。また，異なる疾患名で検索したにも関わらず，同じ文献がヒットする場合があったので，医中誌文献番号が重複するものは分析対象から除外した。

2.2.3 ネット記事の収集方法

インターネットの検索エンジン「Google」を用い，5 疾患の検索を行い，得られた検索結果から症状の記述のみを抽出して学習データを作成した。

その際，例えば「子宮筋腫の症状は？」といった見出しを見つけ，手作業で該当箇所を抽出した。明確な見出しがない場合は，「・・・といった症状がみられる」といった箇所を目視で確認し，該当箇所を抽出した。

また，収集する際には記述の信頼性を確保するため，出典が医療機関のものか，そうでないかで区分した。

なおこの作業は 3 名で基準を統一して行った（作業者は医療情報技師 and/or 診療情報管理士取得者）。その基準は下記のとおりである。

i. 症状について記載されている項目，文章を全て抽出する。文章の題名は抽出しない。
ii. その疾患について細かく分類をしている場合，それらの疾患名，項目，文章を全て抽出する。
iii. 出典が医療機関のものかそうでないかは，そのホームページの運営団体を見て判断する。
iv. 文字数等の制限は特にしない。

2.2.4 疾患予測 KHcoder を用いた分類方法

収集した 2 種類の学習データは，KHcoder の「ベイズ学習による分類」機能を使って分類実験を行った。KHcoder とは，テキストマイニング（通常の文章からなるデータを単語や文節で区切り，それらの出現の頻度や共出現の相関，出現傾向，時系列などを解析することで有用な情報を取り出す，テキストデータの分析方法）を行えるフリーソフトである。「ベイズ学習による分類」とは，KHcoder の機能のひとつであり，ベイズの定理を用いた分析方法である。このベイズ学習では，特徴語として使用する単語の品詞は制限せず，すべての品詞を用いた。また，疾患名自体を特徴語にしてしまうことを防ぐために，ストップワード（特徴語から除外する語）として「子宮内膜症，子宮頸がん，子宮体がん，子宮筋腫，卵巣腫瘍，がん，癌，子宮，膜，頸，体，筋腫，卵巣，腫瘍」を指定した。さらに，形態素解析による過分割を防ぐために，KHcoder に備わっている TermExtract を利用した複合語の抽出機能を利用して「下腹部痛」や「不正性器出血」などの専門用語を抽出し，それらを特徴語として使用するようにした。この同一条件下で医中誌抄録とネット記事に対してベイズ学習を行い，それぞれ

に用いる学習データの件数を増やすことで，分類性能がどのように推移するか調査した。分類性能の評価方法については，10-folds 交差検証テストで正確度（Accuracy）を評価した。

2.3 スマホアプリの開発

アプリ開発では，問診票の項目や疾患予測機能を実現した。開発環境として，画面遷移図を作成するスマホ画面設計ツールの『Cacoo』[9]と HTML5 ハイブリッドスマホアプリ開発ツールの『Monaca』[10]を使用した。まず Cacoo で画面遷移図を描き，それをもとに詳細な画面設計を行った。画面設計が完成したら Monaca を使って HTML5 で画面を作成し，JavaScript でプログラミングを行った。

2.4 疾患予測サーバの構築

疾患予測サーバ（CPU Intel Core i5-4250U, 16GB RAM, 125GB SSD, OS CentOS 6.8）は，PHP で開発したベイズ分類器を Apache 2.2.15 上で Web サービスとして実装した [11]。なお，ベイズ分類器は，形態素解析エンジンとして MeCab 0.996 を，DBMS として MySQL 5.1.73 を用いた。

3. 結果

3.1 選定した入力項目

文献調査の結果からは，「初経年齢」，「閉経年齢」，「最終月経」，「月経周期」，「持続期間」，「経血量（凝血の有無）」，「不正出血の有無」，「月経困難症状の有無」を取り入れた。

問診票からは，「生理について」や「最近の月経について」，「閉経」，「生理痛の有無」，「薬や注射のアレルギー」，「飲んでいる薬」，「初潮」，「月経周期について」，「出血量」，「性交渉の経験」などを取り入れた※3。

また，既存のアプリからは「生理日管理」，「基礎体温の管理」，「生理周期」，「体調」や「予定」を取り入れた。

3.2 作成したスマホアプリ

作成したスマホアプリの画面構成を図 3.2.1 に示す。

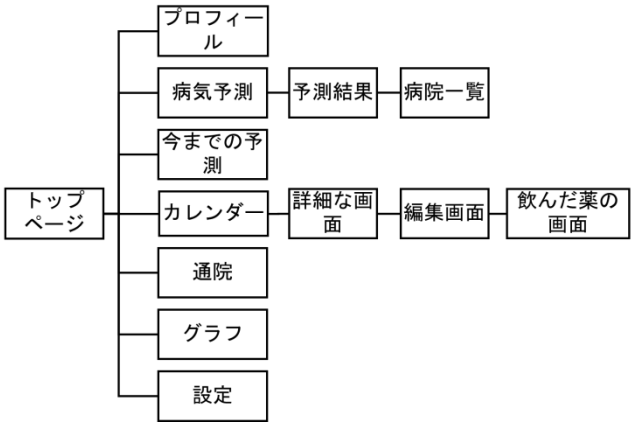

図 3.2.1 スマホアプリの画面構成図

トップページでスクリーンをスワイプすることでスライディングメニューが現れるので，実行したい機能を選択すると，各ページに遷移する。またトップページには，その日の体調を入力できる詳細な画面や疾患予測の画面に移動できるショートカットを設けているので，いちいちメニューを出さなくても直接遷移できるように操作性を工夫した。

アプリ起動直後に表示される設定画面で入力したデータはプロフィールの画面に反映されるようになっており，医療機関を受診して問診票を記入する際に，このプロフィール画面を見ることで，記入する際の参考になるようにした。

疾患予測を選択すると図 3.2.2 の左側に示す画面が表示される。この画面で入力された情報は過去に入力した情報とマージされて疾患予測サーバに送られる。サーバで稼働する疾患予測エンジンは，アプリから送られてきた情報を分類器にかけて予測を行い，疾患名と確度が対になった結果をスマホに返す。結果を受け取ったスマホアプリは図 3.2.3 の右側に示すような予測結果をユーザに提示する。

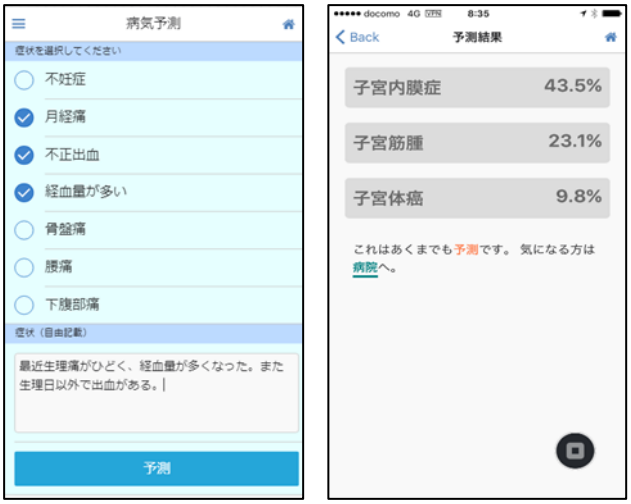

図 3.2.2 疾患予測画面

3.3 疾患予測の結果

3.3.1 医中誌抄録による疾患予測の結果

医学中央雑誌から抽出した 5 疾患の論文数は，「子宮内膜症:1,562 件」，「子宮頸がん:3,549 件」，「子宮体がん:1,521 件」，「子宮筋腫:2,049 件」，「卵巣腫瘍:4,412 件」の合計 11,044 件であった。この学習データから，文献番号の順に 100 件，200 件，300 件，･･･と 100 件ずつ増やしながらデータを抽出し，100 件～500 件までの実験用学習データを作成した。それぞれに対して分類実験を行い，分類性能を求めた。学習データが 500 件のときの結果（混同行列）を表 3.3.1.1 に示す。このようにして 100 件～500 件までの学習データに対して分類実験を行い，分類性能の学習データ数依存性をグラフにしたのが図 3.3.1.1 である。

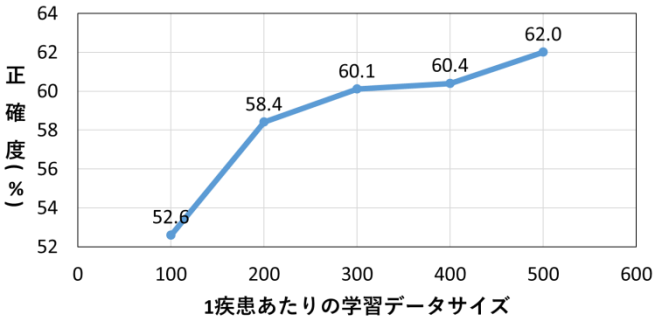

図 3.3.1.1 抄録データによるベイズ学習の学習曲線

ここで，分類性能は，分類器が正解した抄録の数を学習に用いた抄録の数で割った正確度（Accuracy）を用いた。横軸

は疾患ごとの学習データの件数で，縦軸は分類性能を表す正確度である。このように学習データが増加するにつれて，分類性能も向上し，500 件のときに 62.0%に達した。

なお，分類器は，正確度が高ければ高いほど性能が良いとは限らない。正確度が高くても分類器としては役に立たない場合がある。たとえば病気の有無を分類する問題で，有病率（事前確率）が低い場合は，いくら正確度が高くても適合率（precision：分類器が病気と分類したケースで，本当に病気である割合）が低い場合があり得る。一般に分類器は 2 つの指標（再現率と適合率）で評価すべきである。ただし，今回のように疾患ごとのデータ数を揃えている場合は，事前確率がすべて同じなので，正確度で性能を評価しても問題ない。

表 3.3.1.2 は，KHcoder が出力する学習結果ファイルの一部を示したものである（1 疾患当たりの学習データサイズが 500 件の場合）。この表から分類器がどのような分類基準を学習したのかを確認できる。たとえば 1 行目の「気胸」という抽出語に注目すると，もしもある文書中に「気胸」という語が1つ出現していれば，「子宮内膜症」カテゴリのスコアが 4.85 加算されるのに対して，「子宮頸がん」カテゴリのスコアは 0.83，「子宮体がん」カテゴリのスコアは 2.40，・・・といった具合に加算され，学習用に用いたあらゆる語に対してスコア加算を行い，最もスコアの高いカテゴリが分類先として選択される。このようにカテゴリ別のスコアでソートを行うと，どのような語がカテゴリに高いスコアを与えるのかを確認することができる。「分散」の列には，カテゴリ別のスコアばらつき，すなわち分散が表示されている。分散が大きい抽出語ほど疾患の識別能力が高い語と言え，分散が大きくカテゴリ内のスコアが高いほど，その疾患の特徴語を表していると考えられる。

3.3.2 ネット上データによる疾患予測の結果

インターネットから収集したデータの件数を表 3.3.2.1 に示す。子宮内膜症は医療機関からのデータが 64 件，それ以外が 13 件と他の疾患に比べて医療機関に偏っていた。

表 3.3.2.1 インターネットから収集したデータ

全件	医療機関	その他	合計
子宮筋腫	24	44	68
子宮内膜症	64	13	77
子宮頸がん	31	33	64
子宮体がん	24	32	56
卵巣腫瘍	35	31	66
合計	178	153	331

収集したこれらのデータから各々の疾患に対してランダムに 10 件ずつ増やしながら 10 件～50 件までの実験用学習データを作成し，ベイズ学習を行った。

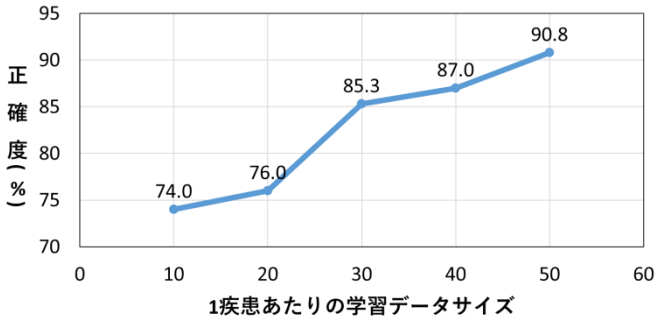

図 3.3.2.1 ネット上のデータによるベイズ学習の学習曲線

ベイズ学習の結果をもとに，学習曲線を作成したのが図 3.3.2.1 である。1 疾患当たりの学習データサイズが 50 件の場合の混同行列を表 3.3.2.2 に示す。また，その時の学習結果ファイルの内容を表 3.3.2.3 に示す。

4. 考察

4.1 疾患予測に対する評価

学習データに医中誌抄録を用いた場合（図 3.3.1.1）とネット記事を用いた場合（図 3.3.2.1）で分類性能に大きな差が出た。これについて考察を行う。

図 4.1.1 は，表 3.3.1.2 や表 3.3.2.3 に示す抽出語の分散を 0.1 ごとに刻んだデータでヒストグラムを描いたものである。

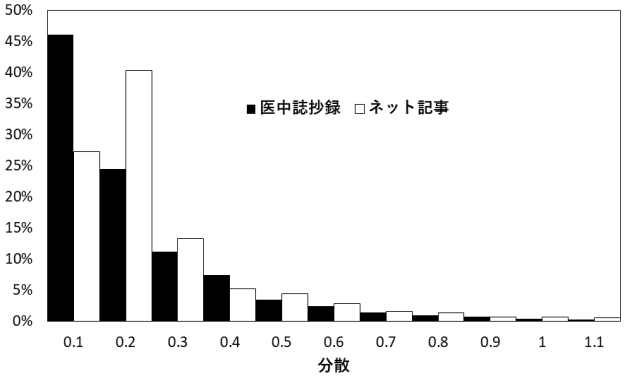

図 4.1.1 スコア分散のヒストグラム

図で，黒色のバーは医中誌抄録，白色のバーはネット記事である。なお，抽出語数は医中誌抄録では 8,979 語，ネット記事では 1,939 語と大きな差があるので，縦軸は語数ではなく出現比率にしている。この図から，ネット記事は，医中誌抄録に比べて分散の大きい語が多いことがわかる。ここで分散は，抽出語が各疾患への分類にどの程度寄与するかを表すスコアのばらつきであったことを思い出すと，分散が大きいほど疾患の識別能力が高い語と言えるので，ネット記事は医中誌抄録に比べ，そのような識別能力の高い語を相対的に多く含んでいることがわかる。

ここでは詳細は省くが，識別能力の高い語の比率が高い学習データセットから取り出された文書は，そうでないデータセットの文書に比べて，正しいカテゴリ（疾患）に分類される確率がより高くなることが示される [12]。すなわち，識別能力の高い語を相対的に多く含んでいるネット記事の学習データで学習した分類器は，医中誌抄録で学習した分類器に比べて分類性能が高くなる傾向がある。これが，分類性能に大きな差が出た原因の一つであると考える。

4.2 先行研究との比較

今回開発したアプリの大きな特徴は，医師が診察時に必要とする問診内容をアプリで管理できるようにしたことと，ユーザのライフログから疾患を予測できる機能を実装したことである。前者については，最近になってようやく電子カルテと連携して医師が利用することを前提としたアプリ [13] が現れてきたものの，従来のアプリには医師との情報共有を意図した問診内容を記録する機能はあまり見られなかった。これは，女性健康管理アプリはあくまでも個人健康記録（PHR）のツールで，診療支援を目的としていなかったためである。今回，我々が開発したアプリは個人健康記録の域を脱するものではないが，従

来あまり顧みられなかった問診情報を記録する機能を付加し，診察時に医師に見てもらえるようにしたという点で活用の場が広がり，ひいては受診を促進し診療に役立つアプリになるものと考える。疾患予測機能については，医師の診断を支援する本格的なものではなく，利用者の参考程度につけたアクセサリ的な機能である。ただ，アプリに入力したライフログをこのような形で二次利用する発想はこれまでなかった。その点で今回開発したシステムの新規性はあるものと考えている。

4.3 限界

石川らは，患者の予診・問診情報と生活・環境情報をもとに，総合診療医の経験知を反映し、人工知能を応用して双方向対話型に病名候補を探し出し，医師の診療を支援する AI システムを開発している[14]。推論エンジンには本研究と同じベイズ分類が使われているが，彼らは教科書，文献などテキスト情報だけでなく，検査結果など日常の診療現場から得られる診療情報も学習データとして用いている。一方，我々の研究は医中誌抄録あるいはネットから収集したテキストデータのみを学習しているに過ぎない。より予測の精度を上げるためにはバイタルサイン，検査結果，生理周期など，テキスト以外のデータも学習することが必要で，テキストマイニングだけで疾患予測をする手法には限界がある。

4.4 今後の課題

今回実装した疾患予測機能は，予測できる疾患を特定の 5 疾患に限定しているため，これ以外の疾患は予測できないだけでなく，健康体であってもいずれかの疾患を回答してしまい，およそ実用的とは言い難い。したがって，予測できる疾患数を増やしたり，一定の基準を満たさない（例えば確率が基準以下の）疾患は表示しないなどの工夫が必要である。

また，今回疾患予測の手法に用いたナイーブベイズモデルは，文書を単語の集合として捉える BOW（bag-of–words）モデルのため，単語の順序や否定が考慮されていない。例えば，「不正性器出血がある」と「不正性器出血がない」のいずれの場合も「不正性器出血」という語が特徴語として抽出され，疾患分類に用いられる。これは単語を捉えているだけであり意味を捉えていないので，正確な分類が行えない。この問題は，語の係り受け関係を解析する構文解析を利用することで改善できる可能性がある。

さらに，学習に用いたネット記事の文書数が少ない点も課題である。図 3.3.2.1 を見ると学習曲線は上昇傾向にあり，まだ分類性能が向上する可能性がある。学習データを増やすことで更なる性能向上が見込めるが，手作業でネット記事を集めることにも限界があるため，学習データの収集方法の自動化を考えるべきであろう。

最後に，今回開発したシステムは実証実験には至っていない。実証実験を行うことで，開発段階では想定していなかった問題点を抽出し，疾患予測の精度を上げ，ユーザーエクスペリエンスの向上を図るのが今後の課題である。

5. 結語

本研究では，女性の健康管理及び女性疾患の治療促進を支援するために，ベイズ学習を用いた女性の健康管理スマホアプリを開発した。開発したアプリの有効性を検証するには実証実験を待たねばならないが，当初の目的である問診票の項目を取り入れ，疾患予測機能を実装したスマホアプリの開発は達成できた。

参考文献

1) 百枝幹雄．日本子宮内膜症啓発会議の現況．エンドメトリオーシス会誌 2013; **34**: 101.
2) 厚生労働省．平成 28 年 国民生活基礎調査の概況, 2017. [http://www.mhlw.go.jp/toukei/saikin/hw/k-tyosa/k-tyosa16/index.html (cited 2017-Aug-23)].
3) 江川美保，岡本和也，西村史朋，森野佐芳梨，粂直人，青山朋樹，小西郁生．月経前症候群の管理におけるスマートフォンアプリを用いた症状記録システムの開発と臨床使用．女性心身医学 2016; **21**(1): 105-113.
4) 高田英明，野川裕記，田中博．インターネット経由で集めた症例を利用した機械学習による診断システム．IT ヘルスケア 2008; **3**(1): 62-65.
5) 吉川秀夫．結核接触者におけるナイーブベイズ分類による発症予測の試み．保健医療科学 2014; **63**(2): 176-178.
6) Yukiko SHIMIZU．産婦人科の問診方法および医療面接 How to Take Medical History of the Patient with Gynecologic and Obstetric Complaints．日本産科婦人科学会雑誌 2009; **61**(12)：N617-N624. [http://www.jsog.or.jp/PDF/61/6112-617.pdf (cited 2017-Aug-14)]
7) 樋口耕一．社会調査のための計量テキスト分析—内容分析の継承と発展を目指して．ナカニシヤ出版, 2014: 169-179.
8) NPO 医学中央雑誌刊行会．医中誌 Web. [http://login.jamas.or.jp/ (cited 2017-Aug-30)].
9) Cacoo（カクー）：アイデアを今すぐこのキャンバスに. [https://cacoo.com/lang/ja/home (cited 2017-Aug-23)]
10) 永井勝則．Monaca 公式ガイドブック「クラウドでできる HTML5 ハイブリッドアプリ開発」．翔泳社, 2015
11) 斉藤常治，高橋佑幸．PHP による機械学習入門．リックテレコム，2014.
12) 田中昌昭．疾患予測に対する評価．2017. [http://hustler307.softether.net/~mtanaka/docs/BayesClassifier.pdf (cited 2017-Aug-31)].
13) 大下淳一．ルナルナ，ついに医師が使うアプリに—産婦人科向け機能を提供，電子カルテとも連携—．日経デジタルヘルス, 2017. [http://techon.nikkeibp.co.jp/atcl/news/16/053107773/?ST=health (cited 2017-Aug-14)]
14) 石川鎮清．双方向対話型人工知能による総合診療支援システムの開発（通称：ホワイト・ジャック）．2016. [http://www.kantei.go.jp/jp/singi/keizaisaisei/miraitoshikaigi/suishinkaigo_iryokaigo_dai2/siryou5.pdf (cited 2017-Aug-30)].

※1 (1) めぐみクリニック [http://www.megumi.or.jp/images/img/monshinhyo.pdf (cited 2017-Aug-23)], (2) 水島協同病院 [http://www.mizukyo.jp/pdf/sanf_monshin.pdf (cited 2017-Aug-23)], (3) 長門クリニック [https://www.nagato-clinic.or.jp/pdf/S_monsin.pdf (cited 2017-Aug-23)], (4) のりこレディースクリニック [http://www.noricli.com/interviewSheets.pdf (cited 2017-Aug-23)], (5) やすこレディースクリニック [http://www.yasuko-clinic.com/library/58c8bd74e5d6b0557ed7ee22/58e7111faf632e333c7c1bec.pdf (cited 2017-Aug-23)], (6) てらにしレディースクリニック [http://www.teranishiladiesclinic.com/uploads/1/4/1/7/14175993/ippann.pdf (cited 2017-Aug-23)], (7) あさぎり病院 [http://www.asagiri-hp.or.jp/media/sinryouka/sanhuzinka/yoyaku/doc/sanfujinka-monshin_001.pdf (cited 2017-Aug-23)], (8) 倉敷平成病院 産婦人科 [http://www.heisei.or.jp/beauty/assets/pdf/monshin_fujin.pdf (cited 2017-Aug-23)], (9) フォレストベルクリニック [http://www.forestbell.jp/pdf/monshin_01_1610.pdf (cited 2017-Aug-23)], (10) ウィメンズクリニック かみむら [http://www.wck-ok.jp/form/form_img/form_syoshin.pdf (cited 2017-Aug-31)]

※2　(1) Moon interspace (開発元:Co.,Ltd.), (2) ルナルナ (開発元:株式会社エムティーアイ), (3) Mememo (開発元:ayumi), (4) セレネ (開発元:Yahoo Japan Corp), (5) いつかな生理 (開発元:Healthcare & Fitness), (6) 女性カレンダー (開発元:Nihon Enterprise Co.,Ltd.), (7) My Calender (開発元:), (8) つづけるミカタ (開発元:Bayer Group), (9) ラルーン (開発元:Ateam Inc), (10) 女子カレ (開発元:ICE Inc.), (11) リズム手帳 (開発元:Nihon Enterprise Co.,Ltd.), (12) Moon (開発元:P-NEST INC.)

※3　来院の目的, 生理について(最近の月経, 閉経, 生理痛の有無(ある人は回数), 薬や注射のアレルギー, 飲んでいる薬, 初潮, 月経周期, 出血量), あなたの結婚・妊娠について(妊娠したことはあるか, 性交渉の経験), 病気・手術について(手術経験)

表 3.3.1.1 医中誌抄録の各疾患 500 件の学習データに対するベイズ学習の分類結果(混同行列)

	子宮頸がん	子宮内膜症	子宮体がん	子宮筋腫	卵巣腫瘍	再現率
子宮頸がん	**312**	28	91	55	14	0.62
子宮内膜症	5	**388**	51	53	3	0.78
子宮体がん	54	36	**336**	68	6	0.67
子宮筋腫	30	101	92	**267**	10	0.53
卵巣腫瘍	41	46	85	80	**248**	0.50
適合率	0.71	0.65	0.51	0.51	0.88	**0.62**

※太字は正しく分類された抄録の数で, 表中の右下の欄の 0.62 は正確度(accuracy)を表す。

表 3.3.1.2 医中誌抄録の各疾患 500 件の学習データに対するベイズ学習結果ファイルの内容(分散の上位 10 件を抜粋)

抽出語	子宮頸がん	子宮内膜症	子宮体がん	子宮筋腫	卵巣腫瘍	分散
気胸	0.83	**4.85**	2.40	2.32	0.49	2.38
アミラーゼ	0.14	0.10	0.00	0.12	**3.85**	2.27
前立腺	1.24	0.10	**4.09**	0.12	0.49	2.25
チョコレート	0.14	**4.59**	1.95	2.89	2.10	2.08
放射線	**5.60**	1.48	4.08	2.52	2.57	2.07
Look	0.14	0.10	1.79	0.12	**3.58**	1.90
未熟	0.14	0.10	0.69	0.81	**3.78**	1.87
虫垂	0.14	**4.40**	2.64	2.32	2.57	1.84
重量	0.14	1.71	0.00	**3.12**	3.05	1.82
IB	**3.14**	0.10	3.09	0.81	0.49	1.73

※太字は抽出語のスコアの最大値で, その語がどのカテゴリへ最も寄与しているかを表す。

表 3.3.2.2　ネット上の各疾患 50 件の学習データに対するベイズ学習の分類結果(混同行列)

	子宮頸がん	子宮内膜症	子宮体がん	子宮筋腫	卵巣腫瘍	再現率
子宮頸がん	**40**	0	9	1	0	0.80
子宮内膜症	0	**45**	0	3	2	0.90
子宮体がん	3	0	**46**	1	0	0.92
子宮筋腫	0	1	0	**47**	2	0.94
卵巣腫瘍	1	0	0	0	**49**	0.98
適合率	0.91	0.98	0.84	0.90	0.92	**0.91**

※太字は正しく分類されたネット記事の数で, 表中の右下の欄の 0.91 は正確度(accuracy)を表す。

表 3.3.2.3 ネット上の各疾患 50 件の学習データに対するベイズ学習結果ファイルの内容(分散の上位 10 件を抜粋)

抽出語	子宮頸がん	子宮内膜症	子宮体がん	子宮筋腫	卵巣腫瘍	分散
おりもの	4.41	0.51	**4.55**	2.30	1.45	2.57
大きい	0.48	2.30	1.53	4.26	**4.38**	2.34
不妊	0.48	**3.81**	0.43	3.09	0.36	2.25
月経痛	0.48	**4.15**	0.43	3.30	2.44	2.23
頻る	1.87	0.51	0.43	3.66	**3.79**	2.13
便秘	0.48	1.20	0.43	**3.5**8	3.49	2.00
過多月経	0.48	2.46	0.43	**3.78**	0.36	1.93
尿	2.56	0.51	1.12	**3.8**9	3.69	1.82
初期	**3.70**	1.61	3.07	0.00	2.15	1.63
排便痛	0.48	**3.88**	0.43	1.39	1.05	1.61

※太字は抽出語のスコアの最大値で, その語がどのカテゴリへ最も寄与しているかを表す。