

【ドクター側管理システムの各画面について：VAS項目グラフ印刷】

問診管理のVAS項目グラフ表示画面、タッチパネルのVAS項目グラフ画面より、出力ボタン押下することにより、本帳票を印刷する。

画面上部には、対象日付範囲のVASグラフを印字。対象問診日付は赤字で印字する。

画面下部には、対象問診日付と問診内容を印字する。

『データ出力方法仕様について』

問診管理のVASグラフ表示画面、タッチパネルのVAS項目グラフ画面より、「出力」ボタン押下により呼び出される。


問診内容部分が1ページの最大行数を超えた時点で改ページとする。

各ページには以下の情報を固定印字する。

ヘッダ部： 医療機関名、出力日付、患者番号、患者名、性別、
生年月日、年齢、VASグラフ

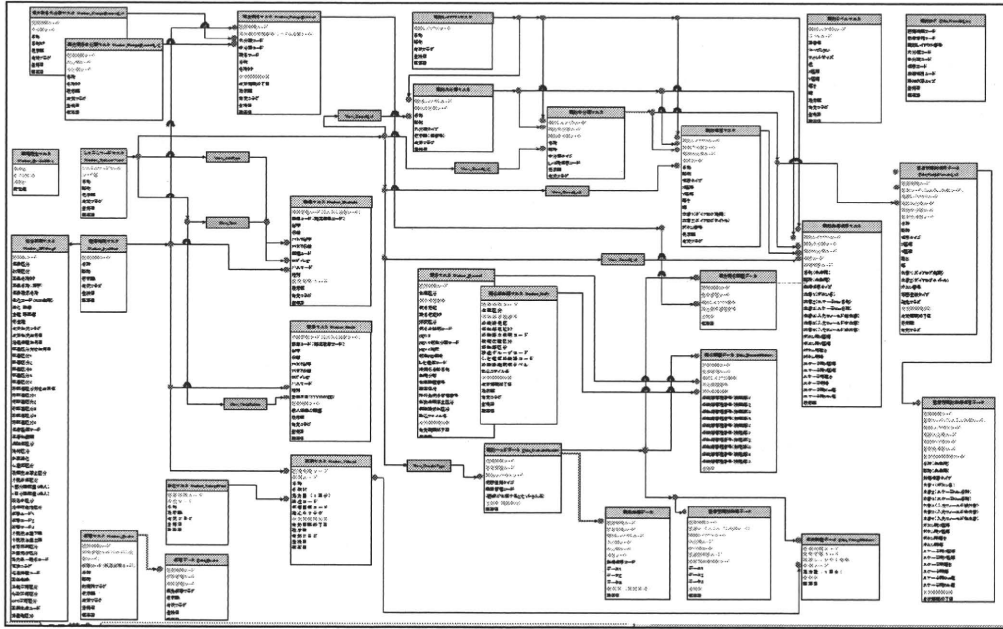
詳細部： 問診日付、問診内容

(印刷サンプル)



【データベース構造図】

自動問診システムのデータ関連を下記の通りとなります。



II. 分 担 研 究 報 告

データマイニングを用いた問診データの評価

研究分担者 宮野 悟 東京大学・医科学研究所・ヒトゲノム解析センター
研究協力者 井元清哉 東京大学・医科学研究所・ヒトゲノム解析センター
山口 類 東京大学・医科学研究所・ヒトゲノム解析センター
片山琴絵 東京大学・医科学研究所・ヒトゲノム解析センター

研究要旨

漢方専門外来を行っている複数の医療施設において集められた問診データから、漢方治療の科学的エビデンスを創出し、そのエビデンスに基づき漢方の特性を生かした診療支援システムを構築することを研究の目的とする。本研究では、患者個人々の自覚症状が記された貴重な診療支援材料である問診データを用いて、データマイニングにより西洋病名診断を高い確率で予測できることを示した。また、施設をまたいで問診データの評価を行うことの可能性についても示唆することができた。ただし、今後、データを増やし、漢方診断と問診データの関連を明らかにすることで、漢方診断のエビデンスを創り出し、その過程で問診票を改善し診療システムを構築することが必要不可欠である。

A. 研究目的

本研究は、慶應義塾大学病院、富山大学病院、千葉大学病院、自治医科大学病院、東北大学病院、東京女子医科大学の漢方専門外来に加えて、鹿島労災病院、秋葉伝統医学クリニック、麻生飯塚病院、亀田総合病院において集められた問診データを、最先端のデータマイニング手法を駆使し解析することにより、漢方診断の科学的なエビデンスを創出し、診療を支援するシステムを構築することを目的とする。

B. 研究方法

慶應義塾大学病院漢方専門外来においては、自動問診システムを設置し、患者各人が自覚症状を入力することで問診データを収集している。登録されているデータの概略を表1にあげる。

まず、慶應義塾大学病院漢方専門外来において設置されている自動問診システムに登録されたデータから、特に、冷え、アトピーという西洋病名診断と関連する問診項目の同定を行う。つまり、ある患者さんの自覚症状が記録された問診データから、その患者さんが冷えであるか否か、アトピーであるか否

かを予測する問題を考え、問診データから「冷え」や「アトピー」である確率を表すように数式によりその関係を表現する。そのけっか、「冷え」、「アトピー」を予測することのできる問診項目を同定する。これは、「冷え」や「アトピー」という診断を患者さんの自覚症状から説明しようという試みとも言える。この解析には、200弱の問診項目から「冷え」、「アトピー」を予測する項目を同定する必要があり、そのために、ロジスティック判別分析に Elastic net と呼ばれる最先端の数理モデルパラメータ推定法を用いた。通常の線形ロジスティック判別モデルは、 i 番目のレコード（患者）の j 番目の問診項目のデータを x_{ij} と表すと

$$\eta_i = a_0 + a_1 x_{i1} + a_2 x_{i2} + \dots + a_m x_{im}$$

として η_i を構成し、 i 番目の患者が冷えである確率は

$$p_i = \frac{1}{1 + \exp(-\eta_i)}$$

で与えられる。ここで、 a_0, \dots, a_m がパラメータであり、通常、最尤法などの統計的手法により想定したモデルがデータにもっともよく当てはまるよう推

定される。しかしながら、このモデルは、個々の問診項目が冷えであるか否かに独立に関わるという前提に従って構築されている。すなわち、ある問診項目と別の問診項目が同時に該当する患者は特に冷えであることが多いという問診項目間の交互作用は表現されない。そこで、問診項目間の交互作用を考慮に入れたロジスティック判別モデルを構築した。例えば、1番と5番の問診項目が同時に選ばれた時の効果を考慮したい際には、

$$a_{1,5}x_{i1}x_{i5}$$

という項を追加することになる。もし、より多数の問診項目の交互作用をモデルに取り込みたければ、対象となる問診項目の積を取ることで交互作用を表現できる。例えば、1、4、5、10番目の問診項目の交互作用は

$$a_{1,4,5,10}x_{i1}x_{i4}x_{i5}x_{i10}$$

の項を加えることになる。しかしながら、一律に例えば5個の問診項目の交互作用をモデルに取り込むとなると、問診項目が N 個あるとすると、 N 個の中から5個を選ぶ組み合わせの数

$$\binom{N}{5}$$

の項をモデルに取り込む必要がある。5個までの交互作用を全て考慮するならば

$$\binom{N}{1} + \binom{N}{2} + \binom{N}{3} + \binom{N}{4} + \binom{N}{5}$$

個の項を加えることになる。慶應問診データの場合には、 $N=146$ であるため、

$$\binom{146}{5} = 515,853,624$$

という膨大な数になってしまい、これらを全てモデルに取り込みパラメータを推定するのは不可能である。現実的には

$$\binom{146}{2} = 10,585$$

なので、サンプル数が約 10,000 であることを考慮すると、2つの問診項目の交互作用を全てモデルに取り込むのが限界のように思われる。しかしながら、実際の診断においては、医師が冷え性やアトピーと言った疾患に対して、たった2つまでの問診項目の状態を考慮に入れながら診断を下しているとは限らない。より複雑な診断プロセスを考慮するためには、より高次の交互作用をモデルに取り込む必要がある。そこで、我々は、事前にある程度多くのサンプルにおいて出現する問診項目の交互作用をデータマイニング手法 Eclat によって抽出し、それらのみをモデルに取り込むことにした。Eclat はサブセットマイニングと呼ばれるデータ解析を行うことができる方法であり、ここでは、約 10,000 件のサンプルにおいて、同時に高頻度で選ばれている問診項目の集合を抽出する目的で用いる。この前処理により、ややもすると一人の患者もマッチしない問診項目の交互作用を事前に排除することが可能となり、また、ある程度の頻度で出現する問診項目の交互作用のみを考慮することができる。もし、この中に冷えやアトピーに対して高い予測能力を有する問診項目の交互作用があれば、その交互作用にマッチするサンプル数の最低数が保証されているため、かなり大きな意味を持つ交互作用であることも同時に期待できる。

ロジスティック判別モデルのパラメータ推定は、通常は最尤法を用いて行われる。すなわち、モデルのパラメータを並べたベクトルを \mathbf{a} と置くと尤度関数 $L(\mathbf{a})$ を最大化する \mathbf{a} の値を決める方法である。最尤法は、推定されたパラメータの一致性など統計的には好ましい性質を持つ優れた方法であるが、ここで問題なのがどの問診項目が冷えの予測に対して有意な能力を有しているかという判定である。そのためには、一般には全ての問診項目をモデルに取り込み、一つずつ不必要と思われる項目を外し、モデルの予測能力が改善されるか否かを判定しながらモデルに残す項目を選ぶ変数減少法や、空のモデルからスタートし、一つずつ問診項目を追加しながらモデルの予測能力を評価し、もっとも予測能力が高くなる問診項目の集合を構築する変数増加法が考え

られる。モデルの予測能力は、赤池の情報量規準 AIC (Akaike's Information Criterion) やベイズ型モデル評価基準 BIC (Bayesian Information Criterion) などが用いられる。しかしながら、今回、考慮する問診項目は、それらの交互作用まで考慮に入れるため 10,000 以上となる。そのような超多数の候補から変数減少法や変数増加法に基づき意味のある問診項目を選ぶのは極めて困難であり、すでに一般の統計科学の枠組みにおいてその方法はあまり有効ではないことが示されている。そこで、我々は、パラメータ推定に Elastic net と呼ばれる最尤法を拡張した方法を用いた。この Elastic net では、全ての変数をモデルに取り込んだフルモデルから推論を開始し、パラメータ推定を行う。パラメータ推定の際に、最尤法と異なる点は、予測の観点から意味がないと判定される変数にかかる係数は、0 と推定する点である。この性質により、パラメータ推定と、意味のある問診項目の抽出が同時に行えることが Elastic net の利点であり、前述した変数減少法や変数増加法と比較して超多数の候補からの変数選択では大きくその結果を改善することが知られている。具体的な Elastic net の推定方法は、

$$L_E(\mathbf{a}) = L(\mathbf{a}) - \sum_j \lambda |a_j| - \frac{\nu}{2} \sum_k a_k^2$$

を最大にするパラメータ値 \mathbf{a} を推定する。ここで、 λ は Lasso パラメータと呼ばれ、この値の大小によりどの程度の変数をモデルから除外するかが決定される。また、 ν は Ridge パラメータと呼ばれ、問診項目間のグループ構造を捉えることに寄与する。Lasso パラメータ、Ridge パラメータはともにモデルの性能に大きく影響を与えるパラメータであるが、本解析の中では全てベイズ型モデル評価基準 BIC によって最適な値を選び用いている。

この「冷え性」「アトピー」を予測することのできる問診項目を発見するための解析の結果を利用して、「冷え」を予測する問診項目たちの関連をネットワークとして表現することを試みた。具体的には、各問診項目をノードとして表現し、冷えの予測について有意と判定された問診項目交互作用を構成する問

診項目たちはエッジ（線）で結ぶことで問診項目のネットワークが得られる。特に、冷えに対して予測能力を持つ問診項目によって問診項目ネットワークは構築されるため、このネットワークにおいてエッジで結ばれた問診項目の状態を調べることで冷えを予測するという診療支援を行える一つの地図を作成していると言える。また、「アトピー」を予測する問診項目たちについても同様に、その関連をネットワークとして表現することを試みた。

次に、同様に「冷え」、「アトピー」がどのような漢方診断（証）によって表現されるかについて解析を行った。自覚症状を表す問診データと同様のロジスティック判別に Elastic net を組み合わせた方法を用いて解析した。問診項目と同様、もしくはそれ以上に漢方の証に関してもその組み合わせが重要になってくることが想定されるため、漢方診断（証）の交互作用を考慮に入れて「冷え」、「アトピー」の予測モデルを構築した。また、漢方診断（証）の関連をネットワークとして表現した。このネットワークにおいて強く結びついている漢方診断（証）のグループは、「冷え」、「アトピー」を説明する証のクラスとも言う。

次に、慶應義塾大学病院漢方専門外来において集められた問診データを用いて、問診項目間の関連を調べた。まず、前述した西洋病名「冷え」に直接関連する（直接「冷え」の有無を問うている問診項目）と思われる問診項目は、表 2 にあげたものがある。すなわち、冷えを感じる部分を問うており、全身、手、足、腰の 4 つの部位において、手、足については右、左を分けた問診項目が準備されている。ここでは、右、左の差は無視し解析を行った。解析の目的は、全身、手、足、腰の冷えに何らかの意味での順序が見いだせないかと言うことである。例えば、手が冷えている人は足も冷えているなど。このような順序が見いだせれば、どの部分が冷えているかが症状の進行度と見なすことができ、治療支援に対する重要な情報になり得る。また、VAS とは、症状が自覚されたとき、その強さを 1 から 100 までの数値で表すものであり、ビジュアル・アナログ・スケ

ールと呼ばれる。今回は、この VAS 値は直接使わず、症状の有無だけをデータとして使用した。しかしながら、VAS 値を用いて、軽度な症状は無視するなど様々な使用が VAS 値には考えられる。個々人の VAS 値の入力の差(ある人は大きな VAS 値を付けがちであるが、別の人はあまり大きな VAS 値の項目はほんのわずかなど)を何らかの方法で補正するなどのデータ処理が VAS 値の解析では必要になってくると思われるが、それらは今後の課題としたい。

次に、「冷え」、「アトピー」など特定の疾患にとらわれず広く問診項目間の関連を探索した。この解析の目的は、漢方外来に来院する患者の症状がどのような関連になっているかを明らかにすることである。また、多すぎる問診項目は患者の負担になり、データのクオリティ低下に繋がるため、問診項目の整理的な意味も本解析は有する。例えば、問診項目 1 と問診項目 2 はほとんど同じ患者に該当しているだけならば、問診項目 1 と問診項目 2 はどちらかを残すと言うことが考えられる。この基本的な考え方に従い、データマイニング手法の一つである apriori を用いた。apriori は、ルールマイニングと呼ばれる方法であり、マーケティングの分野で発達してきた。別名、バスケット分析とも呼ばれる。例えば、あるスーパーマーケットにおいて、ある客が購入した商品を記録する。数万の客のデータから、商品 A を購入したら商品 B も購入することが多いといったルールを抽出する方法である。この方法を利用し、問診項目 1 や問診項目 1 と問診項目 2 に該当する患者は、問診項目 3 に該当するといったルールを抽出する。

最後に、慶應義塾大学病院、千葉大学病院、富山大学病院、鹿島労災病院、麻生飯塚病院の 5 施設から得られた問診データの比較解析を行う。この解析は、異なる施設で集められた問診データの性質がどの程度異なるかを検証することを目的としている。

C. 研究結果

まず、問診データからの西洋病名「冷え」の予測結果について述べる。表 3 に予測精度のまとめを載せた。結果として、「冷え」があるか否かの予測は

91.1%の確率で正解できることが分かった。また、この予測は、233 個の問診項目、および問診項目の組み合わせ(複数の問診項目の交互作用項)によるモデルにより達成された。表 4 と表 5 には、実際に「冷え」の予測に対して寄与が大きかった(ロジスティック判別モデルにおいて、問診項目にかかる係数が大きい(負の場合小さい)ことに対応する)問診項目の組みあわせを示した。表 4 にあげたものは、係数が正の問診項目の組みあわせであり、これらの問診項目に該当した患者は西洋病名診断において「冷え」と判断される傾向にある。1 位、2 位をみると、問診項目において直接「冷え」に関わるものが選ばれている。これは全く自然である。しかしながら、3 位、4 位は直接「冷え」を尋ねた問診項目ではない項目であった。3 位は、「食事の早さが早い」と「気分が憂鬱になる」の交互作用であり、そのサポートは 0.1 である。ここで、サポートとは、2 つの問診項目「食事の早さが早い」と「気分が憂鬱になる」の両方に該当するサンプルが全体の 0.1(10%)ということである。サンプル数は約 10,000 ということから、この 2 つの問診項目に同時に該当するサンプルは約 1,000 ということになる。4 位は、3 位と同様に 2 つの問診項目の交互作用であり、「イライラする」と「目のクマができる」であった。サポートは約 13%であった。なお、9 位にも冷えを直接は尋ねていない「目が疲れる」と「足がふらつく」の交互作用が現れる。このサポートは約 10%である。これらの結果から、身体的に疲れており、かつ、精神的に不安定であることが「冷え」に対して正に関連していることが示唆される。

逆に、該当すると冷えがないと判定される傾向にある問診項目については、その傾向の強いものから順に表 5 にあげた。興味深いのは、表 4 と同様に「イライラする」が出現することである。しかしながら、表 4 の結果とは異なり、「イライラする」に「ものを忘れる」や「のどが渇く」といった身体的な疲れとはことなる性質を有する問診項目との交互作用が表 5 には見られる。また、7 位には、「足の冷え」という「冷え」を直接尋ねている問診項目が出現する。

一見、これは矛盾のように思えるが、「足の冷え」だけを訴える患者というわけではなく、「足の冷え」に加えて「首のこり」や「目の疲れ」に同時に該当するという非常に特異的な患者を対象にしている。また、後の解析で詳しくデータを用いて示すが、足の冷えは、「冷え」に対する直接的な質問における該当部位「手」、「足」、「腰」、「全身」の中ではもっとも初期に現れる症状であると考えられる。したがって、比較的「冷え」の症状の軽い患者がこの交互作用に該当していると考えられる。

冷えに正に関連する問診項目のネットワークを図1にあげる。ネットワークの構築法は、研究方法で説明した方法を用いた。つまり、冷えに対して予測能力があると判定された問診項目の交互作用を構成する問診項目同士をエッジ（線）で結ぶことでネットワークは得られる。ここで、赤い色を付けた問診項目は、「冷え」に対して正の影響のある問診項目群にだけ出現する（負の影響のある問診項目群には出現しない）問診項目である。かなり複雑なネットワークを問診項目は構成していることが分かる。このなかで、例えば、「目が疲れる」のように様々な問診項目に繋がっている、いわゆるネットワーク上のハブになっているような問診項目は重要な意味があると考えられる。「冷え」に対して負の影響のある問診項目のネットワークは図2にあげた。図1と同様に、赤のノードで示した問診項目は、負の影響のある問診項目のネットワークにしか出現しないものである。

問診項目と同様に、「冷え」を漢方診断（証）から予測する数理モデルを構築した。問診項目と同様に、5つまでの証の交互作用を Eclat を用いて高頻度サブセットマイニングを行い抽出し、それらをモデルに取り込み、どの証、証の組み合わせが「冷え」を予測する能力を有するかを Elastic net を用いて評価した。問診項目と同様に、冷えを予測する能力を有する証のネットワークを、正に関連する証と負に関連する証に分け、可視化したものをそれぞれ図4、5にあげる。

慶應義塾大学病院漢方専門外来問診システムにお

いては、冷えのあるなしを「全身」、「手」、「足」、「腰」に分けて尋ねている。ここでは、これら4つの部位における冷えに何らかの順序情報を与えるための解析を行う。表6は、「全身」、「手」、「足」、「腰」の各組みあわせにおいて冷えがあるか否かを 2×2 の分割表で表したものである。例えば、a の表は、「手」と「足」の冷えの関係を表しているが、手に冷えを感じている人は、2430人が足にも冷えを感じているが、足には冷えを感じていない人はわずか314人ということがわかる。逆に、手に冷えを感じていない人は、足に冷えを感じる人が2598人、足に冷えを感じない人が4667人である。逆に、足に冷えを感じているひとが手に冷えを感じるかどうかは、手にも冷えあり相手には冷えなしで2430対2598となり、五分五分であることが分かる。従って、手に冷えを感じている人は、足にも冷えを感じているが、足に冷えを感じている人は手にも冷えを感じているとは言えないという論理を得る。また、「腰」と「足」の冷えについても、足に冷えを感じるからと言って腰にも冷えを感じるとは言えないが、腰に冷えを感じている人は足にも冷えを感じているということが見て取れる。すなわち、冷えは多くの場合、足よりその症状を自覚している人が多いと言うことがこのデータでは示されている。

次に、西洋病名「アトピー」を予測する問診項目、漢方診断（証）を明らかにするための解析を行った。

「冷え」と同様に、問診項目間の交互作用を捉えるために、まず、サブセットマイニングを Eclat により実行し、頻度が10%以上の問診項目の組みあわせに絞り込んだ。その上で、ロジスティック判別モデルを Elastic net を用いて推定し、「アトピー」に対して予測能力を有する問診項目を同定した。予測精度は91.9%という高い精度を達成し、個々のサンプルに対する予測確率（アトピーである確率）は図6に示した。黒で示した患者はデータによるとアトピーがない患者であり、赤で示した患者はデータによりアトピーの患者である。黒の患者に着目すると、これらの患者はアトピーがない訳なので、アトピーである確率は低い方が望ましい。結果は確率が

低い順に患者を並び替えているが、大部分の患者は正しくアトピーがないと言うことを高い確率で（アトピーがあると言うことを低い確率で）予測できている。この正答率は、83個の問診項目の組み合わせにより達成されている。

「アトピー」に対して予測能力を有する問診項目は、表8、9にその影響の強いものを示した。表8にあげたものは「アトピー」に対して正の関係のある問診項目である。これらの問診項目に該当する患者はアトピーであると診断される傾向にあると予測される。また、表9にあげた問診項目は、アトピーに対して負の関係があるものである。表8の結果から、「かゆみ」、「ふけが出やすい」、「かさかさする」といったいわゆるアトピー特有の症状のものが上位に来ており、これらは驚くべき結果ではもちろんないが、データの信頼性を保証するものではある。表9にはアトピーと負の関連のある問診項目が挙げられているが、アトピー以外というグループは基本的にはヘテロな集団であり、あまりまとまった意味をこれらの問診項目から見いだすことはできなかった。アトピーと負の関連を有する問診項目をより意味のある形で見いだすのであれば、アトピーと対比させることに意味のあるような疾患をアトピーではないグループとして用い、ロジスティック判別モデルによって問診項目を選び出すという解析が必要になると考えられる。

図7に、アトピーと正の関係を有する問診項目の関連ネットワークを示した。赤で示した項目は、正の関係のネットワークにのみ出現する問診項目である。冷えのネットワークに比べて項目数が少なく、問診項目間のつながり方も簡潔であることが見て取れる。図8には負の関係を持つ問診項目のネットワークを参考としてあげた。しかしながら、このネットワークに強い意味を持たせるためには、アトピーと比較することに意味のある疾患を用いた再解析が必要である。

表10は、「アトピー」を漢方診断（証）によって予測した精度を表している。漢方診断を用いても、問診項目を用いるときと遜色ない高い正答率(91.1%)

を達成することに成功した。この正答率は、証の214個の組み合わせにより達成された。図9は、証の情報を用いたアトピーである確率の予測値である。問診項目を用いた場合（図6）と比較するとアトピーではない患者のアトピーである確率が若干高めに推定してしまっていることが分かる。この点から言うと、問診項目を利用したアトピーの予測の方が、漢方診断を利用したアトピーの予測よりも安定しているということが推測される。ただし、最終的な正答率は特に大きな違いはなく、両方ともに極めて高い正答率を達成できていることに注意されたい。

表11、12にアトピーと正に関連する漢方診断、負に関連する漢方診断をあげた。ここで注意いただきたいことは、アトピーに正に関連する漢方診断に「寒熱：熱証」、「寒熱：寒証」と相反する証が含まれていることである。一見矛盾するように思えるが、アトピーには熱を伴う症状や逆に冷たく感じる症状があり、その相反する症状が数理モデルの中で表現されているものと思われる。

図10、11は、アトピーに正に関連する漢方診断の関連ネットワーク、アトピーに負に関連する漢方診断の関連ネットワークを示している。今まで問診項目の関連ネットワークと比べて顕著な特徴は、正に関連する、または負に関連するノードが少ないことである。これは、漢方診断（証）が他の証との組み合わせにより、患者の体の様々な状態を表現していることが示唆される。実際、問診項目に比べて、漢方診断（証）の数は少なく、その組み合わせが重要であることは疑いようもない。

次に、慶應大学病院漢方専門外来において集められた問診データの特徴を「冷え」や「アトピー」といった特定の疾患に限ることなく見ていくことにする。図12-1から図12-4に渡って棒グラフで表したのは、慶應漢方問診データにおける各問診項目にどの程度の割合の患者が該当するかを表した問診項目の頻度分布である。もっとも該当する患者の多かった問診項目は、「日常生活：食欲：普通」であり、80%近い患者が該当した。「食欲が普通」というのは特に特徴のない項目であるが、食欲に関しては、慶

應の漢方外来にはそれほど多くの人には問題を抱えていないことが単純な頻度分布からも分かる。2位は「肩のこり」、3位は「疲れやすい」と続く。比較的頻度が高い問診項目は図1 2-1であり、図1 2-2の途中から頻度は20%以下になる。ただし、頻度が低い問診項目が重要度の低い問診項目ではないことに注意されたい。頻度が低くとも、前述したような「冷え」や「アトピー」のような特定の疾患を精度高く予測することのできる問診項目は重要であろう。逆に考えれば頻度が非常に高い問診項目は、それに該当する人はかなりヘテロな集団であることが明らかであるため、それ自体にはあまり意味がないことが想定される。しかしながら、例えば、疲れやすいは7割近い患者が該当するが、逆に疲れやすいという自覚症状を示していない患者がどのような特徴を持っているかを解析することが重要となる。

次に、ルールマイニング法である apriori を用いて問診項目間のルールを抽出した。apriori においては support、confidence、lift という3つの量が結果の評価において重要となる。ルール「A→B」のサポート (support) とは、問診項目 A と B の両方に該当する患者数を全患者数で割ったものである。どの程度の患者がこのルールに該当するか、いわばルールの一般性を表す。ルール「A→B」の信頼度 (confidence) とは、ルール「A→B」のサポートを問診項目 A のサポートで割ったものである。つまり、問診項目 A に該当する患者のどの程度が問診項目 B に該当するかを表し、いわばルールのクオリティである。最後にルール「A→B」のリフト (lift) とは、ルール「A→B」の信頼度を問診項目 B のサポートで割ったものであり、これは

$$\frac{\Pr(B|A)}{\Pr(B)}$$

と等価な量である。もし、問診項目 A と B が独立ならば、 $\Pr(B|A) = \Pr(B)$ であるため、

$$\frac{\Pr(B|A)}{\Pr(B)} > 1$$

であるならば、問診項目 A は問診項目 B の意味のある説明であり、ルール「A→B」は意味を持つと言え

る。

表1 3が慶應問診データから apriori を用いて抽出した問診項目間のルールである。サポートが高いものから順に並べている。「こり」、「疲れ」、「冷え」に関する項目が多く、慶應大病院漢方専門外来に来院する患者の多くはこれらの症状をもって来院しているものと考えられる。

次に、慶應義塾大学病院、千葉大学病院、富山大学病院、鹿島労災病院、麻生飯塚病院の5施設から得られた問診データの比較解析を行う。各施設の問診項目数は、表1 4にまとめた。慶應の問診項目が多いが、これは、慶應は症状の有無に加え、症状があった際にはその自覚症状としての強さを VAS 値で尋ねているため、VAS 値を尋ねる項目については2個とカウントしているためである。富山大学病院と鹿島労災病院とは、同一の問診票を用いているため問診項目数は同数となっている。明らかに千葉大学病院の問診項目は少ないことがわかる。

表1 5には、これら5施設において共通と思われる問診項目を取り上げた。ただし、慶應問診項目では、例えば、「冷え」に関して手において症状を尋ねるとき、「右手」なのか「左手」なのかを分けて尋ねているが、他の施設では左右の区別はない。そこで、慶應においては、右手左手の上位項目である「手の冷え」だけを対象とした。また、しびれに関しても慶應では右手左手と分けて尋ねているが、他施設にあわせるため「手のしびれ」という上位項目を解析には用いた。鼻汁に関しては、慶應では白黄色と分けて尋ねているが、これも他の施設と統一を行うため上位項目を解析には用いた。これらの対応付けにより、5施設で共通な20の問診項目を抽出した。まずは、これら20の問診項目に各施設において患者がどの程度該当しているのか、その頻度分布を調べることとする。

表1 6-1に慶應義塾大学病院、千葉大学病院、麻生飯塚病院の問診データ20共通問診項目の頻度分布を、表1 6-2に富山大学病院、鹿島労災病院、および5施設を統合した問診データの頻度分布をあげた。ここで、5施設を統合した問診データとは、5

施設の間診データから共通20問診項目のデータを抜き出して連結させたものである。しかしながら、各施設のサンプル数は同一ではなく、慶應がずば抜けて多いため、単純に連結したのでは、慶應問診データに含まれるルールだけが抽出されてしまうことになる。そこで、5施設のサンプル数がほぼ同一になるように、慶應以外の施設のサンプルを倍化して連結した。他の連結の手段としては、例えば慶應から他の施設と比較可能なくらいのサンプルをランダムに抽出して連結することも考えられる。今回採用した前者の方法には、慶應以外の4施設のデータのばらつきを過小評価する問題があり、採用しなかった後者の方法には、サンプル数が少なくなるため有意なルールの抽出が困難になるという欠点がある。

表16-1、16-2にある6つの表を比較すると、上位3つの問診項目は「全身症状：その他：疲れやすい」、「手足の冷え」、「個別症状②：腹部：ガスがよく出る」であり、その順序も全ての施設で同一であった。また、下位に注目すると、「個別症状②：腹部：嘔気」は多くの施設で最下位（もっとも該当する患者が少ない）であった。このことも5施設に渡って共通の性質と言える。他の問診項目も施設間で大きくことなる頻度のものは少ない。では、定量的にどれくらい、この20共通問診項目が5施設の頻度分布でどの程度共通かを見積もる。

表17には、施設間における20共通問診項目の頻度順位相関を上のマトリックスに、順位相関が0か否かの検定を行った際のp-値を下のマトリックスに表した。上のマトリックスから説明する。マトリックス内の数字は20共通問診項目の各施設における順位を用いてSpearmanの順位相関を計算した値である。例えば、5施設を統合した「総合」と千葉、飯塚、富山、鹿島、慶應の順位相関はそれぞれ0.8558、0.9244、0.9322、0.8898、0.9248であることがわかり、飯塚、富山、慶應は統合したデータとかなり近いが千葉、鹿島は少々類似度は下がるといことが見て取れる。富山と鹿島は同一の問診票を使用しているが、順位相関も0.9250と高い値を示している。一方、富山と千葉、富山と慶應、慶應と

鹿島は順位相関の値が0.7程度と決して低くはないがそれほど高くはない。この順位相関係数に対して、帰無仮説H0：順位相関はゼロである。対立仮説Ha：順位相関はゼロではないという統計的仮説検定をおこなって得られたp-値をまとめたものが下のマトリックスになる。総じて極めて高い有意性を持って帰無仮説を棄却し対立仮説Ha：順位相関はゼロではないを採択する。これは、各施設間において、少なくとも20共通問診項目の頻度分布は、その順位情報においてかなり類似性が高いとすることを表している。

次に、各施設における20共通問診項目にルールマイニングaprioriを適用した結果について述べる。慶應問診データに対してaprioriを適用し、問診項目間のルールを抽出した結果を表18にあげた。ここで、ルールは、サポートが10%以上のものを全て表示している。顕著な特徴としては、ルールの帰結部分には、一つのルールを除いて全てに「全身症状：その他：疲れやすい」が来ていることである。その原因部分には「腹が張る」、「立ちくらみ」、「めまい」、「胸部動悸」、「腹がゴロゴロなる」などが出現している。これらを漢方医学的に解釈することにより問診項目間の関連を整理し、より診療の支援になるような問診項目立案に繋がる可能性がある。

表19には、千葉大学病院において集められた問診データから20共通問診項目におけるルールをaprioriにより抽出した結果をあげる。千葉大学問診データからはあまり多くのルールは見いだすことはできず、サポートが10%のルールは14個にとどまった。しかしながら、帰結部分は前出の慶應よりも若干ながらバリエーションがあり、「疲れやすい」に加え「めまい」、「手足の冷え」が現れる。

表20は、飯塚の問診データからのルール抽出の結果であるが、帰結部分は全て「疲れやすい」となっており抽出されたルールは他の施設とかなり似ていることも分かる。もっとも、20共通問診項目に絞ったルールマイニングを行っているため、抽出されるルールは似通っていることは当然想定される。ここでは、似ているという結論よりも、施設は異な

っていても、問診項目の関係は大きく異なることはないという結論に至る方が自然であると考え。

富山大問診データからのルールマイニングからは非常に多くのルールを抽出できたため、表2 1-1と2 1-2の二つに分けて示している。多くのルールを抽出できたということも富山大問診データの大きな特徴ではあるが、それに加え、富山大から抽出されたルールのサポートは比較的大きいことがわかる。もっともサポートの大きいルールのサポートは38.7%であり、例えば、千葉大の問診データから抽出されたルールでもっともサポートの大きかったルールのサポートが16.4%であったことを考えてもいかに大きいサポートを有するかが分かる。また、多数のルールを抽出できたと言うことは、大きなサポートを持つ問診データばかりだと確信度やリフトが大きくなることから、患者は多様なグループに分割されるような構造を有している可能性が示唆される。

鹿島問診データからのルール抽出の結果は表2 2にまとめた。帰結部分は全て「疲れやすい」となっている。1位、2位のルールは、富山でも抽出されている。このように他施設で共通に見いだされるルールは、一つ一つの施設でのサポート、確信度、リフトの数値以上の意味があると思われる。これは、研究結果のエビデンスを統合するための統計的メタ・アナリシスと同様な考え方である。

最後に、5施設を統合した問診データから問診項目間のルールを抽出した結果を表2 3にあげた。各施設からの結果では、帰結部分はいくつかのバリエーションが見られたが、統合したデータからは「疲れやすい」のみが帰結部分となった。この原因の一つは、「疲れやすい」は非常に頻度の高い問診項目であり、このような高頻度のものはルールマイニングにおいては帰結部分になる傾向にあるというのは事実である。しかしながら、これは、漢方専門外来を受診される患者の大きな特徴も表していると考えられる。

D. 考察

慶應義塾大学病院をはじめ、千葉大学病院、富山大学病院、鹿島労災病院、麻生飯塚病院の5施設から得られた問診データの解析を行った。特にサンプル数の多い慶應大問診データ、および漢方診断(証)のデータを用い、西洋病名診断「冷え」、「アトピー」の予測を試みた。その結果、極めて高精度にこれら2つの疾患を予測することができるとわかった。しかしながら、「冷え」か否か、「アトピー」か否かを問う際には、その比較対象を適切に設定することが抽出される問診項目、証の意味づけには極めて大切であり、どのような疾患を選んでモデルを構築していくかは今後の課題と言える。また、今回は、症状のあるなしを2値と考え解析を行ったが、慶應大問診データの大きな特徴は、症状の強さをVAS値で患者が記録していることである。このVAS値は極めて重要な情報であり、有効に使用する方策が必要となる。

また、患者が問診票を答える際の傾向(ある問診項目に該当している患者は他のある問診項目にも該当するというルール)を問診データからルールマイニング手法aprioriを用いて抽出した。その結果、高頻度なルールに関しては、各施設でかなり多くは共通しており、各施設の問診データの共通性を示していた。しかしながら、今後の課題としては、低頻度であるが高確度であるルールに着目して各施設のばらつきを評価していく必要がある。

ルールマイニングを行ったもう一つの理由は、問診項目の精査である。高頻度な問診項目に絞った見方では、各施設の傾向は高い類似性を示した。従って、高頻度の問診項目については施設をまたいだ判断を下しても良いと思われる。ただし、今回の解析を行う際に、5施設の問診票に共通の問診項目を最初に抽出し、20問診項目が共通であるという結果を得たが、これは千葉を除く4施設のおおよそ10%に過ぎなかった。もっとも、千葉の問診項目数が50と、他の施設よりもかなり少ないということもその理由としてあげられる。患者個人個人の自覚症状をより反映させ、診療の強力な支援となる問診票を作

成するためには各施設の間診票の見直しが必要となるであろう。

E. 結論

漢方専門外来において集められた問診データは、患者個人々の自覚症状が記された貴重な診療支援材料である。実際、この問診データを用いてデータマイニングの手法を用いることで西洋病名診断を高い確率で予測できることを示した。また、この問診データを施設をまたいでの評価を行うことの可能性についても示唆することができた。ただし、今後よりデータを増やし、漢方診断と問診データの関連を明らかにすることで、漢方診断のエビデンスを創り出し、その過程で問診票を改善し診療システムを構築することが必要不可欠である。

F. 健康危険情報

特になし

G. 研究発表

1. 論文発表

1. K. Katayama, R. Yamaguchi, S. Imoto, H. Tokunaga, Y. Imazu, K. Matuura, K. Watanabe and S. Miyano: Symbolic hierarchical clustering for visual analogue scale data, KES-Springer Smart Innovations, Systems and technologies series, Springer-Verlag, (掲載確定)

H. 知的所有権の取得状況

該当無し

漢方病名	レコード数	9496
	漢方病名数	52
西洋病名	レコード数	9573
	西洋病名数	729
問診項目	レコード数	10010
	問診項目数	362
(1)漢方病名(2)西洋病名(3)問診項目の3種のデータが揃っているレコード数		9479

表1:慶應義塾大学漢方医学センター問診システムのデータ

痛み・冷え等	5 冷え	1 全身	
痛み・冷え等	5 冷え	1 全身	1 VAS
痛み・冷え等	5 冷え	2 手()	
痛み・冷え等	5 冷え	2 手()	1 右手
痛み・冷え等	5 冷え	2 手()	1 VAS
痛み・冷え等	5 冷え	2 手()	2 左手
痛み・冷え等	5 冷え	2 手()	2 VAS
痛み・冷え等	5 冷え	3 足()	
痛み・冷え等	5 冷え	3 足()	1 右足
痛み・冷え等	5 冷え	3 足()	1 VAS
痛み・冷え等	5 冷え	3 足()	2 左足
痛み・冷え等	5 冷え	3 足()	2 VAS
痛み・冷え等	5 冷え	4 腰	
痛み・冷え等	5 冷え	4 腰	1 VAS

表2:「冷え」の症状を直接尋ねた問診項目

		データ	
		冷え有	冷え無し
予測	冷え有	785	452
	冷え無し	396	7846

正しい予測
予測の誤り

予測正答率 91.10%

233個の問診項目、問診項目の組みあわせによって予測される

表3: 西洋病名「冷え」を問診項目から予測した際の精度

問診番号				問診番号							係数	Support
148	痛み・冷え等	冷え	全身	0							0.897698	0.178394
2	日常生活	食欲	ふつう	0	160	痛み・冷え等	冷え	腰			0.621715	0.108978
6	日常生活	食事の速さ	速い	0	50	全身症状	精神状態	気分が憂うつになる			0.483668	0.101171
54	全身症状	精神状態	イライラする	0	204	個別症状①	目	目のクマができる			0.466241	0.132292
5	日常生活	食事の速さ	ふつう	0	159	痛み・冷え等	冷え	足()	204	個別症状①	目	目がしょぼしょぼする
159	痛み・冷え等	冷え	足()	0							0.430167	0.505117
38	日常生活	大便	普通	0	74	全身症状	その他	汗をかきやすい	62	全身症状	その他	寒がり
22	日常生活	小便	1回量が()	普通	38	日常生活	大便	普通	62	全身症状	その他	寒がり
200	個別症状①	目	目が震れる	0	28	個別症状②	手足	足がふらつく			0.324017	0.106657

表4: 西洋病名「冷え」を予測できる問診項目。これらの項目に該当すると冷えがあると判定される傾向になる。

			問診番号			問診番号			問診番号			係数	support			
日常生活	小便	夜間に()回位	054	全身症状	精神状態	イライラする	227	個別症状①	口腔		のどが渇く	-0.61414	0.104758			
日常生活	食欲	ふつう	018	日常生活	小便	夜間に()回位	70	全身症状	皮膚		爪がもろい	-0.44703	0.121215			
日常生活	小便	1回量が()	普通	52	全身症状	精神状態	ものを忘れる	54	全身症状	精神状態	イライラする	-0.43602	0.100433			
日常生活	大便	毎日	038	日常生活	大便	普通	186	個別症状①	あたま		頭痛	-0.38	0.101382			
日常生活	食欲	ふつう	072	全身症状	その他	疲れやすい	74	全身症状	その他	汗をかきやすい	268	個別症状②	腹部	ガスがよく出る	-0.37339	0.108134
日常生活	小便	夜間に()回位	052	全身症状	精神状態	ものを忘れる	204	個別症状①	目		目がしょぼしょぼする	-0.33181	0.125119			
痛み・冷え等	こり	首	010	痛み・冷え等	痛み	肩()	153	痛み・冷え等	冷え	足()	200	個別症状①	目	目が寝れる	-0.30789	0.107184
全身症状	精神状態	イライラする	021	個別症状①	鼻	鼻づまり									-0.30763	0.111404
日常生活	睡眠・夢	よく見る	038	日常生活	大便	普通									-0.2869	0.159511

表5: 西洋病名「冷え」を予測できる問診項目。これらの項目に該当すると冷えがないと判定される傾向になる。




図1: 西洋病名「冷え」に正に関連する問診項目のネットワーク。




図2: 西洋病名「冷え」に負に関連する問診項目のネットワーク。




図3: 西洋病名「冷え」の予測確率(問診項目で予測)

a

		手	
		冷えあり	冷えなし
足	冷えあり	2430	2598
	冷えなし	314	4667

d

		全身	
		冷えあり	冷えなし
足	冷えあり	1047	3981
	冷えなし	741	4240

b

		手	
		冷えあり	冷えなし
全身	冷えあり	785	1003
	冷えなし	1959	6262

e

		腰	
		冷えあり	冷えなし
足	冷えあり	1139	3889
	冷えなし	284	4697

c

		手	
		冷えあり	冷えなし
腰	冷えあり	710	713
	冷えなし	2034	6552

f

		腰	
		冷えあり	冷えなし
全身	冷えあり	560	1228
	冷えなし	863	7358

表6: 症状の包含関係。手・足・腰の冷え




図6: 西洋病名「アトピー」の予測確率

		データ	
		アトピー有	アトピー無し
予測	アトピー有	839	624
	アトピー無し	143	7873

正しい予測
予測の誤り

予測正答率 91.90%

83個の問診項目、問診項目の組みあわせによって予測される

表7:西洋病名「アトピー」を問診項目から予測した際の精度

問診項目1	問診項目2	問診項目3	係数	サポート
全身症状 皮膚 かゆみ			1.769458	0.4276822
個別症状 ① あたま ふけがやすい			1.369868	0.1201604
全身症状 皮膚 カサカサする	全身症状 皮膚 かゆみ		1.001925	0.2818863
全身症状 皮膚 カサカサする			0.4704487	0.4421352
日常生活 睡眠 眠れない()	全身症状 皮膚 カサカサする	全身症状 皮膚 かゆみ	0.3773254	0.11689
日常生活 大便 普通	全身症状 皮膚 かゆみ	全身症状 その他 暑がり	0.2778058	0.1042304
日常生活 大便 普通	全身症状 皮膚 かゆみ		0.2428441	0.2630024
日常生活 睡眠 よい	日常生活 大便 毎日	全身症状 皮膚 かゆみ	0.2288626	0.1220593
日常生活 睡眠 よい	痛み・冷え ぼてり 顔		0.1840425	0.1114042
日常生活 小便 普通	全身症状 皮膚 カサカサする	全身症状 皮膚 かゆみ	0.1780473	0.1289166
全身症状 皮膚 かゆみ	全身症状 その他 寝汗		0.1625548	0.102226
日常生活 食欲 ふつう	全身症状 皮膚 かゆみ		0.113887	0.333896
日常生活 食事の速さ 速い	日常生活 大便 普通		0.08797881	0.1352463
全身症状 皮膚 カサカサする	全身症状 皮膚 かゆみ	痛み・冷え 冷え 手()	0.07782108	0.1043359
全身症状 その他 疲れやすい	個別症状 ① 鼻 鼻汁()	個別症状 ② 腹部 食後眠くなる	0.07064595	0.1046524
個別症状 ① 目 目がしょぼしょぼする	個別症状 ② 腹部 ガスがよく出る	個別症状 ② 腹部 食後眠くなる	0.07012683	0.1023315

表8:西洋病名「アトピー」を予測できる問診項目。これらの項目に該当するとアトピーがあると判定される傾向になる。