

# 時系列健康診断データからの未病予測の一手法

山本有紗<sup>†1</sup> 石川由羽<sup>†1</sup> 梅田智広<sup>†2</sup> 城和貴<sup>†1</sup>

**概要:** 本研究では、時系列を考慮した健康診断データからの未病予測および、健康診断項目間の関係性の発見を目的とする提案を行う。手法として、健康診断データに、データマイニングの知識発見アルゴリズムの1手法である SVM を適用することにより、予測対象年の測定値の上下の予測を行う。健康診断データを対象とした実験の結果、2-4 個の特定の健診項目の組み合わせにおいて、予測精度が高くなる組み合わせが確認できた。

## One method of prediction of presymptomatic disease from time series health checkup data

ARISA YAMAMOTO<sup>†1</sup> ISHIKAWA YU<sup>†1</sup>  
TOMOHIRO UMEDA<sup>†2</sup> JOE KAZUKI<sup>†1</sup>

### 1. はじめに

現在の日本の人口約 1 億 2700 万人のうち、65 歳以上の高齢者人口は約 3400 万人であり、高齢化率は 26.7%を記録している。高齢化率は年々増加傾向にあり、2025 年には団塊の世代が 75 歳を超えて後期高齢者となり、国民の 3 人に 1 人が 65 歳以上、5 人に 1 人が 75 歳以上となる[1]。そのため、国民医療費の増大や生活習慣病の増加などの社会問題が深刻化している。平成 26 年度の国民医療費は 40 兆 8071 億円、前年度の 40 兆 610 億円に比べ 7461 億円、1.9%増加している。人口 1 人当たりの国民医療費は 32 万 1100 円、前年度の 31 万 4700 円に比べ 6400 円、2.0%増加している[2]。国民医療費は増加の一途をたどっており、国内総生産や国民所得の比率も年々増加している。また、生活習慣病が占める割合は高齢になるにつれて高くなり、70 歳以上の高齢者における一般診療の医療費の約 50%は生活習慣病にかかっている。これは、69 歳未満に比べると高い割合となっている[2]。このような社会問題による影響で、国民の予防医学への関心が高まっている。予防医学とは、不適切な食生活・運動不足・喫煙などで起こる生活習慣病の予備軍の人が、病気になる前に、病気の進行を抑えることを目的とした治療のことである[3]。病気の予防のために、病気の早期発見が重要であり、特に未病段階での予防と対策が必要とされている。未病とは、臓器など器質的な変化がなく保険診療を必要としないが、病気になりやすいリスクを抱えていて、生活習慣を変えることによって改善される状態のことをいう[4]。そのため、病気の予防のためには、未病段階を予測してその段階で食事療法や運動などの生活改善をすることで、健康な状態を維持することが

重要になる。

自身の現在の健康状態を明らかにし、健康異常に対する早期発見と健康を保持するための指標として、健康診断がある。健康診断は労働安全衛生法により、1 年に 1 回以上受けることが義務付けられている[5]。そのため、職場や自治体などで定期的に行われており、自身の健康状態の変化を時系列で見ることができる。また、健康診断の内容は、糖尿病や高脂血症などの生活習慣病のリスクに関する項目が中心となっている。身体計測、血圧検査、血液検査などがあるため、様々な角度から自身の健康状態を把握することができる。国民全員が、1 年に 1 回以上の頻度で健康診断を受診していることから、膨大な量の健康診断データが蓄積されている。その膨大な量の健康診断データを分析することにより、健康診断データからの未病予測や健康診断項目間の関係性の発見など、新しい知見の発見につなげることが可能と考えられる。

そこで本稿では、健康診断のデータから、健康診断項目間の関係性の発見と未病段階の予測を行う。そのために、大量の健康診断データを分析して、そのデータから時系列を考慮したモデルを作成し、作成した時系列モデルに未知の健康診断データを適用する。

以下、2 章で、データマイニングに関する既存研究を紹介し、3 章では、時系列を考慮した健康診断データからの未病予測のための手法の提案を行い、4 章では、実験と実験結果、考察を述べる。5 章でまとめについて述べる。

### 2. データマイニングに関する既存研究

IoT の発展により、様々なものがインターネットと繋がっており、医療分野以外にも幅広い分野で注目されている。具体的には、マーケティングなどの金融分野や、消費者購買行動パターンの分析や商品の売れ行き要因分析などといった流通・小売分野がある。その他にも、インターネットの顧客マーケティングや電話網管理などの通信分野などに

<sup>†1</sup> 奈良女子大学  
Nara Women's University  
<sup>†2</sup> 奈良県立医科大学  
Nara Medical University

においても、膨大な量のデータの取得が可能である[6]。IoTにより膨大な量のデータが蓄積している現代社会において注目されているのが、データマイニングである。データマイニングとは、膨大な量のデータを整理して、整理したデータからパターンを抽出し、抽出したパターンを解釈・評価することで、膨大な量のデータから有用な知識を獲得することができる技術のことをいう。データマイニングの手法として、知識発見アルゴリズムには、クラスタリングやK-meansなどの、機械学習の手法などが用いられる。また、SVM(Support Vector Machin)を回帰分析に用いて将来予測などを行うという研究もされている。このような知識発見アルゴリズムを用いたデータマイニングによる知識獲得や、SVMを用いた回帰分析による予測に関する研究は、医療分野だけではなく、マーケティングや小売分野や通信分野などの様々な分野で盛んにおこなわれている。[6]

金融分野においてデータマイニング手法を用いた研究[7]では、SVMを用いて株価指数の日々の価格変動の方向性の予測をしている。用いるデータマイニング手法として、ニューラルネットワーク、事例ベース推論、SVMに関して比較実験を行っている。実験結果としては、事例ベース推論、ニューラルネットワーク、SVMの順に予測精度が良いという結果となり、SVMが、金融分野における時系列予測にとって有望な手法であることを示している。医療分野においてデータマイニング手法を用いた予測に関する研究[8]では、性別や血圧やコレステロールなどの13項目と、肥満度や喫煙の有無の項目を用いて、将来心臓病を患う可能性を予測している。データマイニング手法として、機械学習であるナイーブベイズや決定木、ニューラルネットワークを用いて予測実験を行っている。実験の結果、ナイーブベイズは予測精度が最も高く100%で、次いで決定木が99.62%、ニューラルネットワークを用いた場合、90.74%という結果となった。よって、実験で用いた3つのデータマイニング手法の中で、ナイーブベイズを用いた場合が最も心臓病を患う確率の予測精度が高いという結果となった。

同じく医療分野でデータマイニング手法を用いた研究[9]では、一般的な2つのデータマイニング手法であるニューラルネットワークと決定木および、一般的に統計手法であるロジスティック回帰を用いて乳がんの生存可能性の予測モデルの作成を行っている。200000件以上のデータを使用して3つの手法を比較しながら実験を行った結果、決定木を用いた際に93.6%の精度を出し、ニューラルネットワークやロジスティック回帰と比較して最良の結果となった。また、SVMを用いて時系列分析を行った関連研究[10]では、時系列データにSVMを用いて分析を行うことについての正当性を述べている。データマイニング手法を用いた予測に関する研究[11]では、冠状動脈性心疾患(CHD)の患者の生存予測を行っている。1000例を用いてSVMとニューラルネットワークと決定木の3つのデータマイニング手法

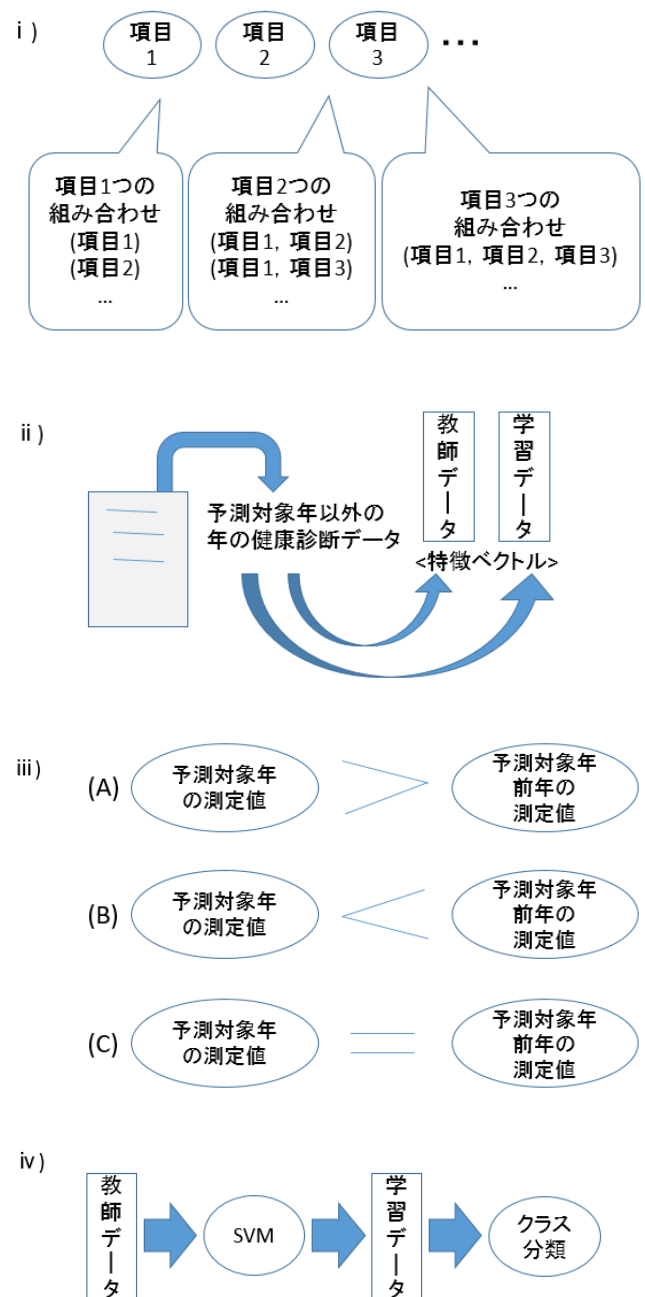


図1:提案手法の流れ

を用いて予測精度を比較している。実験の結果として、ニューラルネットワークを用いた場合、91%の予測精度となり、決定木を用いた場合は89.6%で、SVMを用いた場合92.1%の予測精度が確認できる。よって、CHDの患者の生存予測には、SVMが最も適しているということが示されている。上記で述べた関連研究では、SVMの時系列分析が正当なものであることが述べられており、特に株価の予測など、マーケティング分野において、将来予測を行う研究が多くなされている。また、医療分野においても生存予測などにSVMが用いられている。また、SVMが他の手法と比較して予測精度が良くなっているという結果も確認することができる。以上のことから、時系列健康診断データに

に対するデータマイニングと値の上下予測に SVM を用いることとする。

### 3. 時系列を考慮した健康診断データからの未病予測

本章では、時系列を考慮した健康診断データからの未病予測を目的とした提案手法について述べる。健康診断データに、データマイニングの知識発見アルゴリズムの 1 手法である SVM を適用することにより、予測対象年の測定値の上下の予測を行う。未病予測を行うにあたり、その提案手法について説明する。提案手法の流れを図 1 に示す。

- i) 健康診断項目の全ての組み合わせを求める。
- ii) 健康診断項目の全ての組み合わせに対して、教師データ、テストデータともに、予測対象年以外の年の測定値を特徴ベクトルとして与える。
- iii) 特徴ベクトルに対応するクラス分け
- iv) SVM を用いて教師データを学習させ、テストデータに適用してクラス分類

上記の手順で健康診断の測定値の上下予測を行っていく。i) において、健康診断項目に対し、項目 1 個の組み合わせ、項目 2 個の組み合わせ、項目 3 個の組み合わせというように、全通りの項目の組み合わせを求める。また、2 個以上の組み合わせの場合、どの健康診断項目を予測するかを考慮して組み合わせを考える。次に、ii) において、特徴ベクトルに関しては、健康診断項目間で単位が異なるため、予測結果の偏りを防ぐためにデータの正規化を行う。正規化の手法としては、平均値 0、標準偏差 1 になるように補正する。以下に式を示す。

$$\frac{x_i - \bar{x}}{SD_x}$$

ここで、 $i$  は健康診断を受診した人数とし、 $x_i$  は各人の健康診断項目の測定値とする。また、 $\bar{x}$  は各健康診断項目の 1 年分の平均値を表し、 $SD_x$  は各健康診断項目の 1 年分の標準偏差を表す。そうして正規化した健康診断データの各健康診断項目を特徴ベクトルとする。値の上下予測を行う年度を予測対象年とし、予測対象年以外の年度における各健康診断項目の特徴ベクトルを教師データとテストデータに分割して与える。また、iii) においては、教師データ、テストデータともに予測対象年の値が前年の値と比較して、値が高くなっている健康診断受診者を A、低くなっている受診者を B、前年と比べて予測対象年の値が同じ受診者を C とクラス決定する。つまり、教師データには、予測対象年以外の年度の、正規化した各健康診断項目の特徴ベクトルと、上記で述べた A~C のクラスが含まれる。また、テストデータには、正規化した各健康診断項目の特徴ベクトルのみが含まれる。最後に、iv) においては、i) で求めた

健康診断項目全ての組み合わせに対して、教師データに SVM を適用させ、A と B と C の識別面を学習する。それをテストデータに適用してクラス分類を行うことにより、予測対象年における各健康診断項目の値の上下予測を行う。

本稿では、時系列健康診断データに SVM を適用させてデータマイニングを行い、予測対象年の各健康診断項目の測定値の上下予測の予測精度の確認及び、健康診断項目間の関係性の抽出が目的である。そのため、全ての健康診断データを教師データとテストデータに分割して上下予測を行い、テストデータの予測精度について検討する。そして、予測精度が高くなる健康診断項目の組み合わせを確認する。ここでいう予測精度とは、予測対象年の上下予測を行ったデータ数に対し、予測したクラスと実際の測定値からクラス分類したものとを比較して、一致している数の割合を示すものとする。また、予測精度を求める際には、10 分割交差検定法を用いる。

## 4. 実験

### 4.1 実験データ

本実験では、以下の健康診断データを使用する。健康診断は 1 年に 1 回の頻度で実施されており、2005 年～2009 年の 5 年分で、165 人分のデータがある。より多くの人数の測定結果を確保するため、測定人数の少ない LDL コレステロールと空腹時血糖と HbA1c は実験データから除外する。除外した結果、実験で使用する健康診断データの項目は、収縮期血圧[mmHg]・拡張期血圧[mmHg]・中性脂肪[mg/dl]・HDL コレステロール[mg/dl]・GOT (AST) [U/L]・GPT (ALT) [U/L]・ $\gamma$ -GTP ( $\gamma$ -GT) [U/L]・ヘマトクリット[%]・ヘモグロビン (血色素量) [g/dl]・赤血球数[10<sup>6</sup> $\mu$ L]の全 10 項目を使用する。

各健康診断項目の内容は以下のとおりである。収縮期血圧と拡張期血圧は、それぞれ、最高血圧と最低血圧と呼ばれ、血圧値は血管の硬さと血液量によって決定される。中性脂肪は、生きていくために必要なエネルギー源であるが、血中の中性脂肪値が高くなりすぎると脂質異常症という状態になり、血管の動脈硬化が進む原因となる。また、HDL コレステロールは、善玉コレステロールともよばれている。HDL コレステロールは動脈硬化の防止につなげるため、値が低すぎると異常と診断される。次に、GOT(ALT)・GPT(ALT)・ $\gamma$ -GTP( $\gamma$ -GT)について説明する。この 3 つは肝機能値を表しており、急性肝炎などの肝臓病の有無や、脂肪肝など肝臓の状態を調べるための指標となっている。肝細胞の破壊が進むにつれて GOT と GPT の値は上昇し、 $\gamma$ -GTP は、特にアルコール性肝障害などが原因で数値が上昇する。ヘマトクリット・ヘモグロビン・赤血球数は、3 つの測定データから、血液中の赤血球の状態を調べるもので、貧血の診断のために行われ、3 つの検査結果を総合し、赤血球の状態を判断する。赤血球数は、血液中の赤血球の

数を数えるもので、ヘマトクリットは、全血液中の赤血球の容積率を示し、ヘモグロビンは全血液中のヘモグロビンの量を測るものである。なかでも重要なのがヘモグロビンで、ヘモグロビンが少ないと、酸素が各細胞の組織に充分供給されないため、赤血球数が正常でも貧血症状を起こす場合がある。 [12]

以上の項目を含む健康診断データを用いて実験を行う。

#### 4.2 実験方法

本稿では、予測精度を確認するために、全データを教師データとテストデータに分けて実験を行う。ここでいう予測精度とは、全予測対象データに対し、学習データの特徴ベクトルから予測した A-C のクラスと、4 年目と 5 年目の実際の測定値からクラス分類したものとを比較して、一致している割合とする。

教師データは全データ数の 8 割とし、テストデータは全データ数の 2 割とする。教師データとテストデータの特徴ベクトルは共に、組み合わせた各健康診断項目の 4 年分の測定値とし、その実際の測定値に対して正規化を行った値を与える。また、教師データには、5 年目と 4 年目とを比較して、予測対象年である 5 年目の方の値が大きければ A、小さければ B、同じならば C としてクラス分類を行った結果を与える。

10 個の健康診断項目の全ての組み合わせに対して教師データを作成するため、全部で 5120 通りの教師データの作成を行う。健康診断項目の全ての組み合わせ方の計算式は以下のとおりである。

$$10C_1 * 1 + 10C_2 * 2 + 10C_3 * 3 + 10C_4 * 4 + 10C_5 * 5 * 5 \\ + 10C_6 * 6 + 10C_7 * 7 + 10C_8 * 8 + 10C_9 * 9 + 10C_{10} * 10$$

健康診断項目の全ての組み合わせの教師データそれぞれを SVM で学習し、それぞれのテストデータに適用させて特徴ベクトルからのクラス予測を行い、予測精度の確認を行う。予測精度は、汎化能力の不足がないように、10 分割交差検定法を用いて計算する。

#### 4.3 結果と考察

実験で行った予測精度の結果について述べる。健康診断項目の全組み合わせについてクラスの予測を行い、予測精度を確認した結果、他の健康診断項目の組み合わせと比較した際に、5 年目の上下予測の精度が高い組み合わせを表 1 に示す。また、予測精度が高い項目の組み合わせ全てにおいて、7 割以上の予測精度が確認できる。

1~10 個まで全ての組み合わせを試した結果、2~4 個の項目の組み合わせの時に予測精度が高い組み合わせが確認できる。項目が 1 個の時、または項目が 5~10 個の組み合わせの時は 50% 台もしくはそれ以下の予測精度となる。

特徴ベクトル	予測対象
収縮 中性脂肪 GTP	中性脂肪
収縮 中性脂肪 ヘマトクリット	中性脂肪
収縮 中性脂肪 AST ALT	中性脂肪
収縮 中性脂肪 ALT ヘマトクリット	中性脂肪
収縮 中性脂肪	中性脂肪
中性脂肪 GTP	中性脂肪

表 1:実験結果

このことから、項目単体で予測するよりも、いくつかの項目を組み合わせで予測する場合に予測精度が上がる事が確認できる。しかし、5 個以上の項目を組み合わせる場合、特徴ベクトルが増えすぎてしまい、その結果予測精度が下がってしまうということが分かる。

2 個の項目の組み合わせの場合、収縮期血圧と中性脂肪から中性脂肪の予測をする場合に 75%、中性脂肪と GTP から中性脂肪を予測する場合に 78% の予測精度となり、この 2 組で予測精度が高いという結果となる。2 個の項目を組み合わせた場合では、収縮期血圧と中性脂肪から中性脂肪を予測できるという結果から、収縮期血圧と中性脂肪との関係性があるということが示されている。また、中性脂肪の値が高くなると収縮期血圧の値も上昇するという関係性が既知のこととされており、この結果が正当であることが確認できる [13]。収縮期血圧と中性脂肪ともに、それぞれ単独、もしくは他の項目との組み合わせでは予測精度が高くない。そのため、収縮期血圧と中性脂肪の組み合わせが、予測するためにはより良い組み合わせであり、より関係性の高い組み合わせであると考えられる。また、中性脂肪と GTP から中性脂肪が予測できるという結果から、中性脂肪と GTP の関係性も確認することができる。GTP と中性脂肪のどちらの項目に関しても、それぞれ単独、もしくは他の項目との組み合わせの場合では予測精度が高くない。そのため、中性脂肪と GTP の組み合わせが、予測するためには関係性のより高い組み合わせであると考えられる。また、GTP が脂肪肝などを引き起こすパラメータである肝臓値を示すこと、また、中性脂肪が肝細胞に蓄えられることで脂肪肝へと近づいていくということから、中性脂肪と GTP の関係性は高いものであることがわかる [14]。

また、3 個の項目の組み合わせの場合、収縮期血圧と中性脂肪と GTP の組み合わせから中性脂肪を予測する場合に 81%、収縮期血圧と中性脂肪とヘマトクリットの組み合わせから中性脂肪を予測するという組み合わせの場合に 75% となり、高い予測精度となる。このことから、3 個の項目を組み合わせた場合では、収縮期血圧と中性脂肪と GTP 間や、収縮期血圧と中性脂肪とヘマトクリットの項目

間に関係性があるのではないかと考えることができる。この3個の項目の組み合わせに関しても、収縮期血圧と中性脂肪とGTP、または、収縮期血圧と中性脂肪とヘマトクリットにおいて、それぞれの項目単独、もしくは他の項目の組み合わせた際の予測精度は低い。このことから、この組み合わせ同士の関係性が他の項目の組み合わせよりも高いものと考えられる。

4個の項目組み合わせの場合、収縮期血圧と中性脂肪とASTとALTの組み合わせから中性脂肪を予測する場合に75%、収縮期血圧と中性脂肪とALTとヘマトクリットから中性脂肪を予測する場合に78%という高い予測精度が得られる結果となった。このことから、4個の項目を組み合わせた場合では、収縮期血圧と中性脂肪とASTとALTの項目間、または、収縮期血圧と中性脂肪とALTとヘマトクリットの項目間に関係性があるのではないかと考えることができる。この4個の組み合わせに関しても、収縮期血圧と中性脂肪とASTとALT、または、収縮期血圧と中性脂肪とALTとヘマトクリットに関して、それぞれの項目単独、もしくは他の項目の組み合わせた際の予測精度は低い。このことから、この組み合わせ同士の関係性が他の項目の組み合わせと比べて高いものと考えられる。

## 5. まとめ

本稿では、データマイニングの手法を用い、時系列を考慮した健康診断のデータから、各健康診断項目の測定値の上下予測と、健康診断項目間の関係性の発見を行った。予測手法として、数年分の測定値を特徴ベクトルとして与え、これを健康診断項目の全ての組み合わせに対して行う。そして、予測対象年の値が前年の値と比較して、値が高くなっている健康診断受診者、低くなっている受診者、前年と比べて値が同じ受診者の3クラスに分類する。数年分の測定値の特徴ベクトルと、その特徴ベクトルに対するクラス分類を教師データとして与えて学習し、未知のデータに適用してクラス予測を行う。

実験では、健康診断項目として、収縮期血圧[mmHg]・拡張期血圧[mmHg]・中性脂肪[mg/dl]・HDL コレステロール[mg/dl]・GOT (AST) [U/L]・GPT (ALT) [U/L]・ $\gamma$ -GTP ( $\gamma$ -GT) [U/L]・ヘマトクリット[%]・ヘモグロビン(血色素量) [g/dl]・赤血球数[10<sup>6</sup> $\mu$ L]の全10項目を使用した。各項目の4年分の健康診断データを特徴ベクトルとしてSVMを用いて学習し、予測対象年である5年目の値の上下予測を行った。実験の結果、1個または5個以上の項目の組み合わせの場合には予測精度は低くなり、2~4個の組み合わせで高い予測精度が確認できた。2個の組み合わせでは、収縮期血圧と中性脂肪から中性脂肪の予測、中性脂肪とGTPから中性脂肪の予測、3個の組み合わせでは収縮期血圧と中性脂肪とGTPの組み合わせから中性脂肪を予測、

収縮期血圧と中性脂肪とヘマトクリットの組み合わせから中性脂肪を予測、そして、4個の組み合わせでは、収縮期血圧と中性脂肪とASTとALTの組み合わせから中性脂肪の予測、収縮期血圧と中性脂肪とALTとヘマトクリットから中性脂肪の予測をした際に予測精度が高いという結果が得られた。以上のように、健康診断項目単独ではなく、2~4個の項目で、特定の組み合わせの時により良い予測精度が得られた。

今後の課題としては、今回はデータが少なかつたため実験で使用できなかった健康診断項目についても考慮していくこと、実験に使用するデータの数を増やすこと、他のデータマイニング手法を用いることがあげられる。また、今後は深層学習(Deep Learning)をデータマイニングの知識発見アルゴリズムとして用い、より多くの測定人数による健康診断データを用いて予測をすることで、また新たな知見が得られることも期待できる。

## 参考文献

- 1) 厚生労働省, “H26 年度概況,” [オンライン]. <http://www.mhlw.go.jp/toukei/saikin/hw/k-iryohi/14/dl/kekka.pdf> (2017/2/10 アクセス)
- 2) 厚生労働省, “厚生白書(平成9年版)” [オンライン]. [http://www.mhlw.go.jp/toukei\\_hakusho/hakusho/kousei/1997/](http://www.mhlw.go.jp/toukei_hakusho/hakusho/kousei/1997/) (2017/2/10 アクセス)
- 3) 厚生労働省, “平成18年度医療制度改革関連資料II 安心・信頼の医療の確保と予防の重視” [オンライン]. <http://www.mhlw.go.jp/bunya/shakaihosho/iryouseido01/taikou03.html> (2017/2/10 アクセス)
- 4) 株式会社ヤクルト, “ヘルシスト231” [オンライン]. [http://www.yakult.co.jp/healthist/231/img/pdf/p02\\_07.pdf](http://www.yakult.co.jp/healthist/231/img/pdf/p02_07.pdf) (2017/2/10 アクセス)
- 5) 厚生労働省, “労働安全衛生法に基づく健康診断の概要” [オンライン]. <http://www.mhlw.go.jp/shingi/2009/01/dl/s0119-4h.pdf> (2017/2/10 アクセス)
- 6) 元田浩, 山口高平, 津本周作 (2006) “データマイニングの基礎” オーム社
- 7) Kyoung-jae Kim “Financial time series forecasting using support vector machines”(2003) Neurocomputing Volume 55, Issues 1-2, Pages 307-319
- 8) Sellappan Palaniappan, Rafiah Awang “Intelligent heart disease prediction system using data mining techniques”(2008) IEEE Xplore Computer Systems and Applications Conference
- 9) DursunDelen ,GlennWalker, AmitKadam “Predicting breast cancer survivability: a comparison of three data mining methods”(2005)Artificial Intelligence in Medicine Volume 34, June Issue 2, , Pages 113-127
- 10) Sayan Mukherjee, Edgar Osuna, Federico Girosi “Nonlinear Prediction of Chaotic Time Series Using Support Vector Machines” (1997)Proc of IEEE NNSP pages 24-26
- 11) “Yanwei Xing, Jie Wang, Zhihong Zhao, “Combination Data Mining Methods with New Medical Data to Predicting Outcome of Coronary Heart Disease”(2007)Convergence Information Technology. International Conference

- 12) 一般社団法人日本衛星検査所協会 “検査項目と疾患(2)”  
[http://www.jrcla.or.jp/atoz/rexm/rexm\\_02\\_01.html](http://www.jrcla.or.jp/atoz/rexm/rexm_02_01.html)[オンライン]  
(2017/8/23 アクセス)
- 13) Geriatrics Research Institute, Maebashi, Gunma Health  
Foundation(1995) “STUDIES ON THE NUTRITIONAL  
STATUS OF THE ELDERLY” The KITAKANTO Medical  
Journal Vol. 45 No. 4 P 307-319
- 14) <http://www.skincare-univ.com/article/006925/>[オンライン]  
(2017/8/23 アクセス)