

検診結果ビッグデータを用いた構造適応型 Deep Belief Networkの癌予測システムと知識発見 Cancer Prediction of Medical Examination Data and Its Knowledge Extraction by Adaptive Structural Learning of Deep Belief Network

鎌田 真

Shin Kamada

広島市立大学大学院

情報科学研究科

日本学術振興会特別研究員 (DC2)

Email: da65002@e.hiroshima-cu.ac.jp

市村 匠

Takumi Ichimura

県立広島大学

高度人工知能 Project 研究センター

経営情報学部 経営情報学科

Email: ichimura @ pu-hiroshima.ac.jp

原田 俊英

Toshihide Harada

県立広島大学

保健福祉学部理学療法学科

Email: hartoshi @ pu-hiroshima.ac.jp

Abstract—Deep Learning has a hierarchical network architecture to represent the complicated feature of input patterns. We have developed the adaptive structure learning method of Deep Belief Network (DBN) that can discover an optimal number of hidden neurons for given input data in a Restricted Boltzmann Machine (RBM) by neuron generation-annihilation algorithm, and hidden layers in DBN. The proposed adaptive structure DBN was applied to the comprehensive medical examination data for the cancer prediction. The prediction system shows the highest classification accuracy among the traditional DBN. In this paper, the explicit knowledge with respect to the relation between input and output patterns was extracted from the trained DBN network by C4.5. Some characteristics extracted in the form of If-Then rules to find an initial cancer were reported in this paper.

I. はじめに

近年, Deep Learning(深層学習)[1], [2] が人工知能の理論的な研究だけでなく, 産業を中心とした様々な場面で利用され始めている. ILSVRC と呼ばれる画像認識の世界大会では, GoogleNet[3] や ResNet[4] で知られるように, 人間の認識能力を大きく上回る Deep Learning モデルが発表されている. 従来の階層型ニューラルネットワークとは異なり, Deep Learning では事前学習が行われることが大きな特徴の一つである. 各層ごとに学習を行うことで入力データに含まれる特徴を事前学習し, それらの複数の特徴を階層的に組み合わせることで, データ全体の特徴を高い精度で表現することができる.

確率モデルである Restricted Boltzmann Machine(RBM)[5] を事前学習し, その RBM を階層化することで, 高度な分類性能をもつ Deep Belief

Network(DBN)[6]がある. 我々は, 入力データ空間に応じて適切と考えられる隠れニューロン数及び隠れ層数を学習中に自動で求める構造適応型学習法を提案している [7], [8]. 提案手法は, 画像ベンチマークデータセット [9] に対して従来手法よりも高い分類精度を示している [10], [11]. さらに, 提案手法を健康診断における血液検査データや癌検診結果が記録されている医療画像を含む医療検診データ [12] に適用した. 構造適応型 DBN により, 肺や胃等の部位ごとの癌の可能性を高い精度で予測することができた. さらに, システムの予測結果をタブレット端末上に表示し, 医師の診断を支援する医療診断支援システムを構築した [13]. ここでは, 入力データとして医療画像が検査項目に含まれていない場合でも, 血液検査データの異常項目の関係性から癌の可能性を計算することに成功した.

一般に, 学習済みの深層学習ネットワークはブラックボックスと言われている. 学習後の重みや中間層の出力値は人間が見て直感的に理解できる形ではないため, IF-THEN ルールで表現されるような知識獲得を行う手法が必要とされている. このような問題に対して, 本研究では, DBN の各層を構成する RBM が 2 値のニューロンを持っていることを利用して, 学習済みネットワークに実行可能な 2 値の入力パターンを与え, 入力層から出力層に向けて流れる信号の流れを表示するツールを開発している [14]. 文献 [15] では, テストデータにおいて誤って出力するパターンに対する信号の流れを抽出し, 正しく出力するように重みを修正する Fine Tuning 法を開発した. Fine Tuning 法により, 分類精度が数%向上することが実験結果により示されている [16]. 本論文では, 学習済みの構造適応型 DBN に与えられる入力パターンと推論結果である出力パターンを,

1組の入出力パターンとして、C4.5[17]により IF-THEN ルール形式で表現される知識獲得を行った。その結果、癌の可能性が高い場合、癌に関連性があると考えられる血液検査項目の特徴がいくつか見られた。の中には、腫瘍マーカーのような、癌検診で使用されているような特別な検査に関する項目だけでなく、一般的な血液検査項目において、専門的には癌の判定にはそのまま使用できないものの、今後の経過観察において、注意すべき特徴が見られた。本論文では、このような事例について分析した結果を報告する。

II. 構造適応型 DEEP BELIEF NETWORK による学習法

A. Restricted Boltzmann Machine

RBM[5] は、可視層と隠れ層の2層から構成されるネットワーク構造を持ち、確率分布に基づいて入力データに含まれる特徴を隠れニューロン上で学習することができる。RBMの学習では、与えられた入力データに対して、式(1)のエネルギー関数を最小にするパラメタ $\theta = \{b, c, W\}$ が最尤推定により求められる。

$$E(\mathbf{v}, \mathbf{h}) = - \sum_i b_i v_i - \sum_j c_j h_j - \sum_i \sum_j v_i W_{ij} h_j, \quad (1)$$

$$p(\mathbf{v}, \mathbf{h}) = \frac{1}{Z} \exp(-E(\mathbf{v}, \mathbf{h})), \quad (2)$$

$$Z = \sum_{\mathbf{v}} \sum_{\mathbf{h}} \exp(-E(\mathbf{v}, \mathbf{h})) \quad (3)$$

ここで、 v_i は i 番目の可視ニューロン、 h_j は j 番目の隠れニューロンである。 b_i は v_i に対するパラメタ、 c_j は h_j に対するパラメタ、 W_{ij} は v_i と h_j 間の重みである。 $\mathbf{v} \in \{0, 1\}^I$ と $\mathbf{h} \in \{0, 1\}^J$ はそれぞれ可視層と隠れ層のベクトルであり、 I と J は可視ニューロン数、隠れニューロン数である。式(2)は入力 \mathbf{v} と \mathbf{h} の確率分布である。式(3)の Z は分配関数 (partition function) であり、 \mathbf{v} と \mathbf{h} の全ての2値のパターンの組み合わせに対するエネルギーを示す。一般的に、RBMでは計算量の観点から Contrastive Divergence(CD)法[18]による学習が行われる。

B. Deep Belief Network

Deep Belief Network(DBN)は、事前学習を行ったRBMを複数積み重ねることで、入力データの特徴を階層的に学習することができる Deep Learning 手法である[6]。DBN自体はRBMを積み重ねたモデルであるため教師なし学習モデルであるが、最上位層に出力層を加え、ソフトマック法等により計算された出力値と教師信号との誤差を最小化することで、教師あり学習として分類することができる。

C. ニューロン生成/消去アルゴリズム

我々は文献[19]で示されている、階層型ニューラルネットワークにおけるニューロン生成/消去アルゴリズムに基づき、RBMの学習中において最適な隠れニューロン数を自動で求める構造適応型学習手法を提案している[7]。ニューロン生成は、学習中におけるパラメタの変分に基づいて行われる。例えば、学習データに対して十分な数の隠れニューロンがあれば、一般的に学習が進むにつれて重みベクトルの変分は小さな値になる。一方で、パラメタの変分が収束しない場合は、学習データに対するネットワークの表現能力が不足しており、データが持つ特徴(確率分布)を隠れニューロンによって独立した分布に分離できていないことが原因だと考えられる。このような場合、関連する位置に新しい隠れニューロンを挿入することで、多次元のデータを低次元の部分空間に分解して表現でき、それぞれのデータ部分空間で学習が収束することで、全体的に収束する状態に導く。我々の調査では、RBMの3つのパラメタ $\theta = \{b, c, W\}$ のうち、CD法による学習の収束に関係しているパラメタを c と W とした[20]。この2つのパラメタの関連性から、ニューロン生成条件を式(4)に示すように定義した[21]。

$$WD_{c_j} \cdot WD_{W_j} > \theta_G \quad (4)$$

ここで、 WD_{c_j} 、 WD_{W_j} はそれぞれ j 番目の隠れニューロンのパラメタと重みに関するWDであり、その計算方法については文献[19]に示されている。 θ_G は閾値であり、予め小さな値が与えられる。学習中に式(4)を満たす隠れニューロンが存在する場合、図1(a)のように、該当する隠れニューロンの近傍に新しいニューロンがその属性(パラメタや重みの値)を継承するように挿入される。

一方、入力データに対して十分な数の隠れニューロンが生成された後、出力に寄与していない、すなわち冗長な隠れニューロンが存在する場合がある。構造適応型RBMでは、一定の学習の後、式(5)を満たす隠れニューロンが存在すれば、ニューロン消去アルゴリズムを適用し、該当する隠れニューロンを図1(b)のように消去する。式(5)では、すべての入力データに対する隠れニューロンの出力値の平均を観察し、その値が一定の閾値以下のニューロンを冗長なニューロンとし、これを削除する。

$$\frac{1}{N} \sum_{n=1}^N p(h_j = 1 | \mathbf{v}_n) < \theta_A, \quad (5)$$

$$p(h_j = 1 | \mathbf{v}_n) = \sigma(b_j + \sum_i W_{ij} v_i) \quad (6)$$

ここで、 \mathbf{v}_n は N 個の入力データセットに含まれる入力データである。 $p(h_j = 1 | \mathbf{v}_n)$ はRBMの可視層に入力データ \mathbf{v}_n が与えられたときの隠れニューロン $h_j \in \{0, 1\}$ の発火確率を示している。ここで、 $\sigma()$ はシグモイド関数で $[0, 1]$ を出力する関数である。 θ_A は、予備

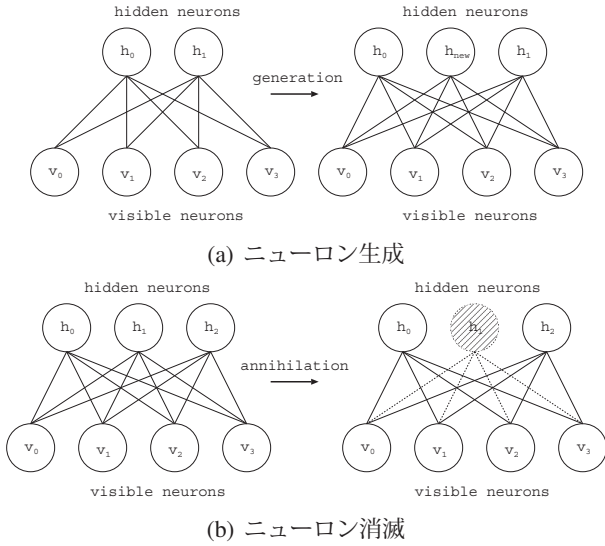


図 1. 構造適応型 RBM

実験における分類精度と削除するニューロンの活性化値をもとに閾値として予め与えた。

D. 層の生成条件

構造適応型 RBM におけるニューロン生成アルゴリズムでは、学習中の WD (パラメタ c と W の変分) を観察したが、構造適応型 DBN [10] では、個々の RBM ではなく、ネットワーク全体の WD とエネルギーを式 (7) と式 (8) で観察した。

$$\sum_{l=1}^k (\alpha_{WD} \cdot WD^l) > \theta_{L1}, \quad (7)$$

$$\sum_{l=1}^k (\alpha_E \cdot E^l) > \theta_{L2} \quad (8)$$

ここで、 $WD^l = \sum_{j=1}^J (WD_{c_j}^l \cdot WD_{W_j}^l)$ であり、 $WD_{c_j}^l$ と $WD_{W_j}^l$ はそれぞれ l 層目の RBM における c_j と W_j に関する WD を示している。 E^l はエネルギー関数である。 θ_{L1} , θ_{L2} は閾値で、予め与えられる。 ある k 層の RBM において式 (7) 及び式 (8) を同時に満たす場合、入力データに対するネットワーク全体の表現能力が不足していると考え、 k 層の学習が終了した時点で、 $k+1$ 層の RBM を生成し、学習を行う。

III. 構造適応型 DBN からの知識獲得

Deep Learning 学習では、学習後のネットワークはブラックボックスであると考えられている。学習後の重みや中間層の出力値は人間が見て直感的に理解できる形ではないため、これらの構造や Deep Learning が行う推論の仕組みを、多段的で表現された IF-THEN ルールのように、明示的な知識構造として表現する手法が必要とされている。

CNN と異なり、DBN の各層を構成する RBM は、2 値のニューロンで表現されている。我々は、学習後の構造適応型 DBN から知識獲得を行うため、学習後の

Algorithm 1 C4.5 によるルール抽出の手順

- 1: 入力データを $X(\mathbf{x}_1, \dots, \mathbf{x}_p, \dots, \mathbf{x}_N)$ とする。 N は入力データ数であり、各入力 \mathbf{x}_p は I 次元の要素を持つベクトルである。学習済みの DBN ネットワークを、 $L(1 \leq l \leq L)$ 層の構造を持つネットワークとし、与えられた X に対し、出力 $Y(y_1, \dots, y_p, \dots, y_N)$ を出力する関数を $Net()$ とする。各出力 y_p は、最終層のソフトマックスのクラスラベルに対応するインデックス番号の値を持つ。
- 2: 入力データ X を学習済み DBN ネットワークの推論関数である $Net()$ に与え、推論結果として Y を得る。
- 3: 入力を X 、教師信号を Y としたデータ (図 2) を C4.5 に与え、ルール抽出を行う。

DBN に理論的に可能なすべての 2 値の入力パターンを与え、入力層から出力層に至るまでの信号の流れを表示するツールを開発した [14]。与えられたデータに対して発火するニューロン間のパスのうち、出現頻度が高いものを検出している。文献 [15] では、テストデータに対して誤った出力を生じる信号の流れから出現率が高い特徴的なパターンを発見し、その信号の流れを正しく正答するように修正する Fine Tuning 手法を開発した。Fine Tuning 法により、ネットワークを再学習することなく、分類精度が数%向上することが実験結果から示されている [16]。

本論文では、上記の Fine Tuning 法とは異なり、構造適応型 DBN に与えられる入力パターンと、推論結果である出力パターンの関連性を IF-THEN ルールで表現することを試みた。ルール抽出を行うために、決定木を生成する学習アルゴリズムである C4.5 [17] を用いた。C4.5 における入力信号と出力信号は、それぞれ構造適応型 DBN に与えられる入力と構造適応型 DBN の推論結果とし、ルール抽出を試みた。Algorithm 1 は、C4.5 によるルール抽出の手順を示している。図 2 は、C4.5 に与えるデータの例を示している。図 2 の記号は、Algorithm 1 に記載されているように、“ x_{p_i} ” は、 p 番目の入力の i 番目の要素を示し、最終列の “ y_p ” は、 p 番目の出力を示す。なお、文献 [22], [23] でも、C4.5 を用いて構造適応型 DBN が実行する推論に関するルールを抽出しているが、ここでは、GPU 装置がない安価なタブレット端末等でも、Deep Learning より精度は劣るが同等な精度で推論可能なルールを抽出した。本論文では、得られたルールに対し、検診データの入力である血液検査項目と出力である癌の可能性の関連性について、考察を行った。

IV. 実験

A. 構造適応型 DBN による癌予測システムの開発

我々は、提案手法である構造適応型 DBN を用いて、癌の可能性を予測するシステムを開発している [13]。

表 I
検診データにおける検査項目

Category	Name	Data type	Range
Basic test	Patient ID	Integer	
	Age	Integer	(10 - 134)
	Sex	Code	[Male, Female]
	Date	Integer	
	Height	Float	(117 - 196.7)
	Weight	Float	(27.6 - 175)
	BMI	Float	(11.9 - 57.3)
	Abdomen	Float	(53 - 157)
	Eye sight(right)	Float	(0 - 9,915)
	Eye sight(left)	Float	(0 - 9,915)
	Hearing(right, 1000)	Code	[Normal, Abnormal]
	Hearing(right, 4000)	Code	[Normal, Abnormal]
	Hearing(left, 1000)	Code	[Normal, Abnormal]
	Hearing(left, 4000)	Code	[Normal, Abnormal]
Blood pressure	Blood pressure(Max)	Integer	(70 - 257)
	Blood pressure(Min)	Integer	(26 - 148)
Urine	Protein	Code	[(-),(±),(1+),(2+),(3+)]
	Occult blood	Code	[(-),(±),(1+),(2+),(3+)]
	Urobilinogen	Code	[(-),(±),(1+),(2+),(3+)]
Blood analysis	WBC	Integer	(1200 - 26000)
	RBC	Integer	(234 - 672)
	Hb	Float	(5.5 - 22.3)
	Ht	Float	(20.6 - 65.2)
	PLT	Float	(2.7 - 112.6)
Lipid	LDL	Integer	(4 - 357)
	HDL	Integer	(17 - 205)
	TG	Integer	(17 - 2628)
	Sugar urine	Code	[(-),(±),(1+),(2+),(3+)]
Diabetes	Blood sugar	Integer	(41 - 441)
	HbA1c	Float	(4.7 - 12.7)
	Uric acid	Integer	[1, 3, 4, 6, 7]

Category	Name	Data type	Range
Liver function	GOT	Integer	(5 - 1134)
	GPT	Integer	(4 - 1909)
	Gamma GTP	Integer	(4 - 2329)
	ALP	Integer	(39 - 1758)
	LDH	Integer	(77 - 620)
	ChE	Integer	(103 - 621)
	ZTT	Float	(1 - 43.8)
	Total Bilirubin	Float	(0.1 - 4.8)
	TP	Float	(5.6 - 9.3)
	Alb	Float	(3.3 - 5.4)
	A/G	Float	(0.6 - 2.8)
	TC	Integer	(94 - 418)
Uric acid	Creatinine	Float	(0.28 - 13.68)
Kidney function	BUN	Integer	(5 - 59)
	eGFR	Float	(3.9 - 224.7)
	CRP	Code	[(-),(±),(1+),(2+),(3+)]
Infection	Hbs antigen	Code	[(-),(+)]
	Hbs antibody	Code	[(-),(+)]
	Hbc antibody	Code	[(-),(+)]
	Hcv antibody	Code	[(-),(±),(1+),(2+)]
	Pepsinogen	Code	[(-),(+)]
Additional test	Pylori	Code	[(-),(+)]
	Amylase	Float	(27 - 1335)
	ASO	Float	(10 - 393)
	CEA	Float	(0.2 - 10)
	CA15-3	Float	(4,600-19,400)
	TTT	Float	(0.3 - 10.6)
	Fecal occult blood	Code	[(-),(+)]
Other	Health questionnaire	Code	[1, 2]

表 II
検診データに対する分類精度

Model	Accuracy	
	Ave.	Std.
Traditional RBM	0.833	0.011
Adaptive RBM	0.854	0.011
Traditional DBN	0.911	0.010
Adaptive DBN	0.955	0.010

x_1_1, x_1_2, x_1_3, ..., x_1_I, y_1
x_2_1, x_2_2, x_2_3, ..., x_2_I, y_2
x_3_1, x_3_2, x_3_3, ..., x_3_I, y_3
...
x_p_1, x_p_2, x_p_3, ..., x_p_I, y_p
...
x_N_1, x_N_2, x_N_3, ..., x_N_I, y_N

図 2. C4.5 に与えるデータの例

ここで構築されたネットワークは、広島県環境保健協会 [12] の定期健康診断データ (214,683 件) を用いて学習したものである。データは、2012 年から 2015 年の 4 年間で、118,165 人の記録であり、表 I に示す検査項目から構成されている。また、血液検査データに加えて、健康診断における簡易検査である胸部 X 線画像 (106,664 件)、癌検診である胸部 CT 画像 (224,677 件)、胃部 X 線画像 (88,970 件)、マンモ画像 (23,962 件) があり、医師による判定結果として、ラベル“正常”、“異常”がそれぞれに与えられている。

上記の検診データを構造適応型 DBN により学習した。学習パラメタとして、最適値探索には Stochastic Gradient Descent (SGD)、学習係数を 0.01、バッチサイズを 100、学習の最大反復回数を 500 回、初期隠れニューロン数を 300 とした。構造適応型 RBM のパラ

メタとして、 $\theta_G = 0.050, \theta_A = 0.100$ とし、構造適応型 DBN のパラメタとして、 $\theta_{L1} = 0.1, \theta_{L2} = 0.1$ とした。これらのパラメタの値は、予備実験より最良の結果を示した値を用いている。

表 II は、テストデータに対する分類精度を示している。構造適応型 DBN は、従来の RBM や DBN の中で最も高い分類精度 (95.5%) を示している。ここで得られた学習済みネットワークを用いて、図 3 に示すように、入力された検診データから癌の可能性を予測するタブレットインターフェースを開発し、その結果を医師に提供するシステムを構築している。

B. 知識抽出

IV 節で構築した予測システムを用いて、知識獲得を試みた。評価のためのテストデータは、クリニック A から提供を受けたデータであり、これらは医療画像がない 403 件 (男性: 172 件, 女性: 231 件) の血液検査データであった。データをシステムに与え、システムによる計算結果と入力データを 1 組のデータとして、

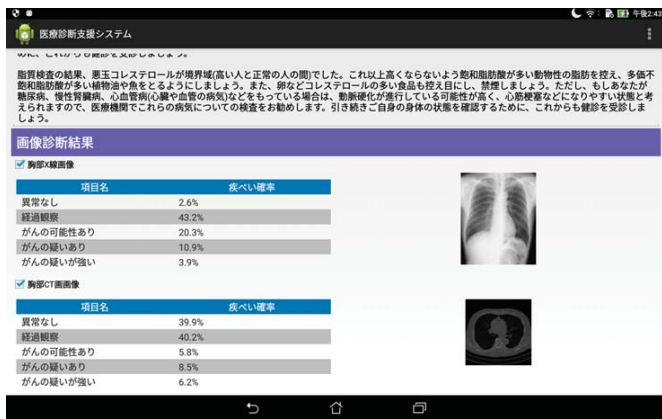



図 3. 医療診断支援システム


C4.5 を用いて知識獲得を行った。血液検査データの項目は、表 I に示す通りである。構築したネットワークの入力には、血液検査データだけでなく、医療画像も必要となるが、ここでは医療画像がないため、画像の平均的な特徴画像(異常のない画像)を与え、血液検査データの異常項目の関係性のみから癌の可能性を予測した。学習済みの構造適応型 DBN に上記のテストデータを与えたところ、肺癌と胃癌について、図 4 に示すような分布が得られた。図 4 の横軸は癌の可能性の階級を示しており、縦軸は各階級に属している度数を示している。それぞれの癌の可能性は、高くても 50% 程度で、60% 以上の事例は見られなかった。また、女性の方が男性よりもデータ数が多く、全体的に高齢であったこともあり、出力される癌の可能性は女性の方が高い傾向が見られた。

さらに、入力である血液検査データと、システムの計算結果である癌の可能性を 1 組のデータとして、C4.5 を用いて知識獲得を行った。図 5 は、C4.5 により生成された決定木の一部を示している。表 III は、C4.5 から得られた計 18 個のルールを示している。これらのルールを用いて予測したところ、分類精度は 98.2% であった。この結果から、得られたルールは構造適応型 DBN の入出力パターンを概ね正しく表現できていると考えられる。

表 III から、全体的な特徴として、癌のリスクが高まるにつれて、白血球数が基準値よりも高くなる傾向が見られた。肺癌のリスクがある被験者に対する検査項目のうち、白血球、アルブミン、総蛋白に異常の症状が見られた。アルブミンや総蛋白は、直接癌とは関係ないが、癌の進行が進んだ場合、血液中の蛋白質が減少するケースが報告されている [24]。ルール“A-6”の白血球、BMI、ヘモグロビン、eGFR 等の異常は、高齢者で、肺癌のリスクが高い場合に見られた症状である [25]。また、胃癌のリスクがある被験者には、GPT、GOT、 γ GTP 等の検査項目に異常の症状が見られた。これらは肝臓に関する検査項目であるが、肝臓癌を発症している場合で、胃等の他の部位に癌が転移しているケースが報告されている [24]。これらの結果は、すぐ



(a) 肺癌



(b) 胃癌

図 4. 出力された癌の可能性の分布

に再検査の必要性があるとは言えないが、発見された知識のいくつかは、Web サイトでも同様な特徴があることが報告されている。このような傾向をもとに、経過観察によって癌の早期発見が可能になるのではないかと考えられる。

V. おわりに

我々は、尤度の概念を用いた統計的なモデルである RBM, DBN に着目し、学習中にニューロンの生成/消去及び階層化を行うことで最適な構造を求める構造適応型 DBN を提案している。提案したモデルを医療検診データに適用し、癌の可能性を予測する深層学習システムを開発し、タブレット端末上で予測結果を医師に提供するシステムを開発した。本論文では、出力された癌の可能性と、入力である血液検査データの関連性に関する知識を C4.5 を用いて抽出した。分析の結果、癌に関連性があると考えられる血液検査項目の特徴がいくつか見られた。さらに、専門的には癌の判定にはそのまま使用できないものの、今後の経過観察

```

gamma_gtp <= 78 :
| egfr <= 92 :
| | age <= 48 :
| | | got <= 17 : 5 (9.0/1.0)
| | | got > 17 : 3 (25.0/1.0)
| | age > 48 :
| | | plt > 17 : 3 (250.0)
| | | plt <= 17 :
| | | | tg <= 162 : 3
(57.0/1.0)
| | | | tg > 162 : 5 (3.0)
| egfr > 92 :
| | plt <= 18 : 5 (4.0)
| | plt > 18 :
| | | tp > 7 : 5 (3.0/1.0)
| | | tp <= 7 :
| | | | urea_nitrogen > 10 : 3
(18.0/1.0)
| | | | urea_nitrogen <= 10 :
| | | | | uric_acid <= 4 : 3
(4.0/1.0)
| | | | | uric_acid > 4 : 6
(2.0)
gamma_gtp > 78 :
| age <= 50 : 6 (10.0)
| age > 50 :
| | plt <= 18 : 5 (3.0)
| | plt > 18 : 3 (13.0)

```

図 5. C4.5 により生成された決定木の例

が必要なケースが発見できた。しかしながら、抽出したルールに対する確信度を考慮するなど、精度の向上を図る必要があり、解決が急がれるところである。

謝辞

本研究開発は JSPS 科研費 (課題番号: JP17J11178) の助成を受けたものです。

参考文献

- [1] Y.Bengio, *Learning Deep Architectures for AI*, Foundations and Trends in Machine Learning archive, vol.2, no.1, pp.1–127 (2009)
- [2] V.Le.Quoc, R.Marc's Aurelio, et.al., *Building high-level features using large scale unsupervised learning*, Proc. of 2013 IEEE International Conference on Acoustics, Speech and Signal Processing, pp.8595–8598 (2013)
- [3] C.Szegedy, W.Liu, et.al., *Going Deeper with Convolutions*, 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.1–9 (2015)
- [4] K.He, X.Zhang, S.R en, J.Sun, *Deep residual learning for image recognition*, Proc. of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.770–778 (2016)
- [5] G.E.Hinton, *A Practical Guide to Training Restricted Boltzmann Machines*, Neural Networks, Tricks of the Trade, Lecture Notes in Computer Science (LNCS, vol.7700), pp.599–619 (2012)
- [6] G.E.Hinton, S.Osindero and Y.Teh, *A fast learning algorithm for deep belief nets*, Neural Computation, vol.18, no.7, pp.1527–1554 (2006)

- [7] S.Kamada and T.Ichimura, *An Adaptive Learning Method of Restricted Boltzmann Machine by Neuron Generation and Annihilation Algorithm*, Proc. of 2016 IEEE International Conference on Systems, Man, and Cybernetics (IEEE SMC 2016), pp.1273–1278 (2016)
- [8] S.Kamada and T.Ichimura, *A Structural Learning Method of Restricted Boltzmann Machine by Neuron Generation and Annihilation Algorithm*, Neural Information Processing, vol.9950 of the series Lecture Notes in Computer Science, pp.372–380 (2016)
- [9] A.Krizhevsky, *Learning Multiple Layers of Features from Tiny Images*, Master of thesis, University of Toronto (2009)
- [10] 鎌田真, 市村匠, *忘却機能を持った Deep Belief Network による構造適応型学習*, 計測自動制御学会第 9 回コンピュータショナル・インテリジェンス研究会講演論文集, pp.92–97 (2016)
- [11] S.Kamada and T.Ichimura, *An Adaptive Learning Method of Deep Belief Network by Layer Generation Algorithm*, Proc. of IEEE TENCON2016, pp.2971–2974 (2016)
- [12] 広島県環境保健協会, <http://www.kanhokyo.or.jp/>, (2017 年 12 月 2 日閲覧)
- [13] 鎌田真, 市村匠, *学習率変化と忘却効果を取り入れた構造適応型 Deep Belief Network 学習による検診データの分類*, 計測自動制御学会システム・情報部門学術講演会 2017 講演論文集 (SSI2017), pp.119–124 (2017)
- [14] 鎌田真, 市村匠, *構造適応型 Deep Belief Network からの知識獲得に関する一考察*, 2016 IEEE SMC Hiroshima Chapter Young Researchers WorkShop, pp.61–66(2016)
- [15] S.Kamada and T.Ichimura, *Fine Tuning of Adaptive Learning of Deep Belief Network for Misclassification and its Knowledge Acquisition*, International Journal Computational Intelligence Studies, vol.6, no.4, pp.333–348 (2017)
- [16] 市村匠, 鎌田真, *構造適応型 Deep Belief Network 事前学習を考慮した知識獲得の検討*, 2017 IEEE SMC Hiroshima Chapter Young Researchers WorkShop (to appear in 2018)
- [17] J.R.Quinlan, *Improved use of continuous attributes in c4.5*, Journal of Artificial Intelligence Research, No.4, pp.77–90 (1996)
- [18] G.E.Hinton, *Training products of experts by minimizing contrastive divergence*, Neural Computation, vol.14, no.8, pp.1771–1800 (2002)
- [19] T.Ichimura and K.Yoshida Eds., *Knowledge-Based Intelligent Systems for Health Care*, Advanced Knowledge International (ISBN 0-9751004-4-0) (2004)
- [20] 鎌田真, 市村匠, 原章, *ニューロン生成/消滅アルゴリズムによる構造適応型 Restricted Boltzmann Machine*, 計測自動制御学会第 8 回コンピュータショナル・インテリジェンス研究会講演論文集, pp.90–96 (2015)
- [21] 鎌田真, 市村匠, *リカレント構造適応型 Deep Belief Network による時系列データの学習*, 計測自動制御学会論文集 (to appear in 2018)
- [22] 鎌田真, 市村匠, *リカレント構造適応型 Deep Belief Network 学習における事前知識の分析*, 第 44 回知能システムシンポジウム講演論文集, SY004/17/B2-2 (2017)
- [23] S.Kamada and T.Ichimura, *Knowledge Extracted from Recurrent Deep Belief Network for Real Time Deterministic Control*, Proc. 2017 IEEE International Conference on Systems, Man, and Cybernetics (IEEE SMC 2017), pp.825–830 (2017)
- [24] SINGA 宝塚クリニック, <http://singa-clinic.jp/terminology/terminology-144.html> (2018 年 2 月 20 日閲覧)
- [25] 国立研究開発法人 日本医療研究開発機構, *EGFR 変異陽性肺がんに対する新規耐性克服療法を発見*, https://www.amed.go.jp/news/release_20170313.html (2018 年 6 月 29 日閲覧)

表 III
C4.5 により抽出されたルール

ルール番号	部位	前件部	後件部
A-1	肺	年齢が 50 歳以下, AND 白血球が基準値	癌の可能性が 20%未満
A-2	肺	年齢が 50 歳より高い, AND 白血球, BMI, ヘモグロビン, ALP, eGFR, が基準値	
A-3	肺	白血球数が基準値より高い	癌の可能性が 20%以上 35%未満
A-4	肺	白血球数が基準値より高い, AND アルブミン, 総蛋白が基準値よりも低い	癌の可能性が 35%以上 50%未満
A-5	肺	白血球数が基準値より高い, AND 赤血球数が基準値より低い	癌の可能性が 50%以上
A-6	肺	年齢が 80 歳以上, AND 白血球数, BMI, ALP が基準値より高い, AND アルブミン, ヘモグロビン, egfr が基準値より低い	
B-1	胃	年齢が 50 歳以下, AND 白血球が基準値	癌の可能性が 20%未満
B-2	胃	年齢が 50 歳より高い, AND BMI, ヘモグロビン, ALP, eGFR, が基準値	
B-3	胃	白血球数が基準値より高い	癌の可能性が 20%以上 35%未満
B-4	胃	白血球数, GPT, GOT が基準値よりも高い	癌の可能性が 35%以上 50%未満
B-5	胃	白血球数, γ GTP の値が基準値よりも高い	
B-6	胃	白血球数, ASO が基準値よりも高い	癌の可能性が 35%以上 50%未満
B-7	胃	白血球数, GPT, GOT, γ GTP, クレアチニンが基準値より高い	
B-8	胃	年齢が 80 歳以上, AND 白血球数, BMI, HbA1c が基準値より高い, AND アルブミン, egfr が基準値より低い	癌の可能性が 50%以上
B-9	胃	白血球数, ピロリ菌が基準値より高い	
B-10	胃	白血球数, ca19_9 が基準値よりも高い	
B-11	胃	白血球数, アミラーゼが基準値よりも高い	
B-12	胃	白血球数, エラスターゼが基準値よりも高い	

問い合わせ先

〒 734-8558

広島県広島市南区宇品東一丁目 1 番 71 号

県立広島大学

高度人工知能プロジェクト研究センター長

市村 匠