

幼児の行動認識のための Tree Augmented Naive Bayes Model とベイジアンネットワークを組み合わせたベイズ推定の精度比較

石川 詔三^{†1} 本村 陽一^{†2}
西田 佳史^{†2} 庄野 逸^{†3}

近年、センサ技術の発達によって人間の行動を観測することが可能になり、各種センサから大量のデータを取得することが容易になっている。しかし、このセンサデータと行動の意図を結びつけることは容易ではない。そこで、この大量のセンサデータに対して行動ラベルを割り当てることを考える。大量のセンサデータに対して手作業でラベルを割り当てることは困難なのでセンサデータから行動ラベルを推定することを考える。本稿では幼児の事故予防を目的とし、幼児の室内行動に注目して、幼児の行動を記録した動画と超音波センサデータから行動ラベルを推定する。推定の手法にはセンサデータから構築したベイジアンネットワークと TAN 識別器 (Tree Augmented Naive Bayes Classifier) を統合したベイズ推定を使用する。ベイズ推定においては、ベイジアンネットワークの出力を事前分布として用い、尤度関数は、動画における高次局所自己相関特徴量を TAN 識別器にかけた出力を用いる。以上のようなベイズ推定を用いた行動ラベル推定の比較実験を行った。

Bayesian Inference in combination with Tree Augmented Naive Bayes and Bayesian Networks for Infant's Behavior Recognition accuracy comparing

SHOZO ISHIKAWA,^{†1} YOICHI MOTOMURA,^{†2}
YOSHIFUMI NISHIDA^{†2} and HAYARU SHOUNO^{†3}

The purpose of this study is to prevent accident in Infants. Recent years, we can observe human's behavior by gaining sensor technology. We can get easily a lot of observation data from a wide variety of sensors. However, It is not easy for tying this observation data to the intention of the human's behavior. So, we consider behavior label is allocated to a lot of observation data. We pay atten-

tion to the infant's indoor behavior in this paper. We estimate behavior labels from observation data from ultra sonic sensors and a fisheye camera. Inference method is using Bayes inference by combination with Tree Augmented Naive Bayes (TAN) and Bayesian Networks. These models are constructed from observation data. Prior distribution is using Bayesian Networks. Likelihood function is using Tree Augmented Naive Bayes Classifier which is constructed from higher order local autocorrelation features from images in infant surrounding. We estimate behavior labels by this method. Then, we performed a comparison experiment to inference an behavior labels by this method.

1. はじめに

本研究は子供の事故予防を促進することを目的としている。近年の子供の主な死亡原因は不慮の事故であり、多くの命が失われている¹⁾。不慮の事故は発生してからでは手遅れになってしまう場合が多く、事故を未然に防ぎ、事故予防を行うことが望ましいと考えられている²⁾。

近年、センサ技術の発達によって人間の行動を観測することが可能になり、大量情報のセンサデータを取得することが可能になっている。しかし、そのデータと行動の意味を結びつけることは容易ではない。したがって、人間の日常生活行動の理解を進めるためにはまず人が解釈可能な行動ラベルを大量のセンサデータに対応づけることが必要である。しかし、大量のセンサデータに対して人が行動ラベルを割り当てることは困難である。また、行動ラベルを割り当てる基準も人それぞれによって曖昧になりやすい。そのため、センサデータから行動ラベルを自動的に決定する方法が求められている²⁾。

我々は、以前にも3次元超音波センサと魚眼カメラを使用した幼児の室内行動観測データからベイズ推定による行動ラベルを推定する手法を提案した³⁾。本研究では、このベイズ推定による行動ラベルの自動推定方法が、どの程度の性能を持っているのか検討する。ベイズ推定では事前分布と尤度関数を基に推定を行う。しかし、事前分布に対する知識がない場合、事前分布をモデル化し記述することは困難である。

^{†1} 電気通信大学大学院 電気通信学研究科
Graduate School of Electro-Communications, The University of Electro-Communications

^{†2} 産業技術総合研究所デジタルヒューマン研究センター
Digital Human Research Center, AIST

^{†3} 電気通信大学 電気通信学部
Faculty of Electro-Communications, The University of Electro-Communications

我々の今までの研究では、事前分布のモデルとして、室内での幼児の行動を観測した動画像および超音波センサデータから行動の時系列に関する確率的因果構造を、ベイジアンネットワークによりモデル化したものを考えた。さらに、魚眼カメラにより撮影された画像の高次局所自己相関特徴量から Naive Bayes 識別器を構成し、モデル化したベイジアンネットワークを事前分布、Naive Bayes 識別器を尤度関数とするベイズ推定を行うことで、従来の機械学習の手法を用いた最尤推定に比べて、行動ラベルの識別率を大きく向上させることができた⁴⁾。さらに、モデル化したベイジアンネットワークに幼児と室内のモノとの関係性を導入することにより、行動ラベルの識別率が向上した。加えて未知のセンサデータに対しても精度よく識別することができた⁵⁾。また、尤度関数には Naive Bayes 識別器を使用してきたが、Naive Bayes 識別器では特徴量間で条件付き独立が仮定されているため、特徴量間の相互作用を表現することができなかった。そこで、Naive Bayes 識別器の条件を緩和したモデルの1つである TAN(Tree Augmented Naive Bayes)⁶⁾を導入し、行動ラベルの識別率を向上させることに成功した⁷⁾。

本稿では今までに導入した TAN 識別器に対して異なる幼児のセンサデータから正しい行動ラベルを推定できるかを評価する。さらに、離散値で計算していた尤度関数の計算を連続値を使用して行う。連続値で計算することによって、離散値で計算するより識別率が高くなることが期待できる。連続値と離散値の2つの場合で TAN 識別器を構築し、識別率の比較を行った、

2. グラフ構造を用いたベイズ推定

2.1 ベイズ推定

ベイズ推定はベイズの定理を基に行う。行動ラベルを $C = \{c_1, c_2, \dots, c_n\}$ 、特徴量 $\mathbf{x} = \{x_1, x_2, \dots, x_m\}$ とする。ここで推定したいのは、特徴量 \mathbf{x} を観測したときの行動ラベルの事後分布 $p(C|\mathbf{x})$ であり、これは以下のベイズの定理から導かれる。

$$p(C = c_i|\mathbf{x}) = \frac{p(\mathbf{x}|C = c_i)p(C = c_i)}{\sum_j p(\mathbf{x}|C = c_j)p(C = c_j)} \quad (1)$$

式(1)右辺の $p(\mathbf{x}|C = c_i)$ が尤度関数、 $p(C = c_i)$ が事前分布である。尤度関数と事前分布の確率分布の積をとり、最も確率の高い行動ラベルを与えられたセンサデータの行動ラベルとして推定する。この行動ラベルの分布を求めることがベイズ推定である。

2.2 ベイジアンネットワーク (Bayesian Networks, BN)

ベイジアンネットワークは離散確率変数と確率変数間の依存関係から構築される非循環有

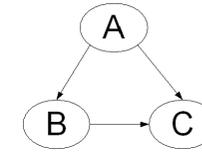


図1 ベイジアンネットワークの例。
Fig. 1 Example of Bayesian Networks.

向グラフである。確率変数をノードで表わし、依存関係をリンク(矢印)で表す。確率変数間の依存関係を表現できるため、確率変数間に内在する因果関係を表現することができる。依存関係にあるノード間では、影響を与える側を親ノード、影響を受ける側を子ノードと呼ぶ。子ノードには親ノードを条件とする条件付き確率が割り当てられる。ベイジアンネットワークではノードとリンクを使って変数間の関係を表現することによって、同時分布を簡単に表現することができる。例えば、図1では同時分布 $p(A, B, C)$ は図1のグラフの構造から式(2)で表現できる。

$$p(A, B, C) = p(A)p(B|A)p(C|A) \quad (2)$$

このように、リンクの無いノード間では確率変数の評価を行わないため、確率変数や状態数が多い場合でも高速に計算することができる。確率変数の状態を決定することによって、任意の確率変数についての確率分布を求める確率推論をすることができる⁸⁾。

2.3 TAN 識別器 (Tree Augmented Naive Bayes Classifier)

TAN 識別器は Naive Bayes 識別器を基にしたモデルである。Naive Bayes(NB) 識別器はクラスラベルが与えられている場合に観測データの条件付き独立を仮定したモデルである。Naive Bayes 識別器をグラフィカルモデルで表現すると条件付き独立の仮定から図2となる。また、これを式で表現すると式(3)となる。

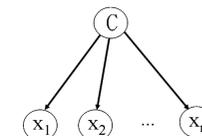


図2 Naive Bayes 識別器。
Fig. 2 Naive Bayes Classifier.

$$p(C = c_j | \mathbf{x}) \sim \prod_i^m p(x_i | C_j) p(C = c_j) \quad (3)$$

Naive Bayes 識別器では特徴量間の条件付き独立を仮定したが、この条件付き独立を軽減するモデルが考えられている。その1つに TAN(Tree Augmented Naive Bayes) 識別器がある。TAN 識別器では特徴量間での条件付き独立を仮定しない。そのかわり、TAN 識別器は必ず木構造をとる。TAN 識別器では Naive Bayes 識別器とは異なり、特徴量間での依存関係を持たせることができる。TAN 識別器をグラフィカルモデルで表すと図3となる。

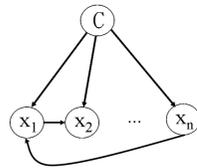


図3 Tree Augmented Naive Bayes 識別器。
 Fig. 3 Tree Augmented Naive Bayes Classifier.

Naive Bayes 識別器に比べて表現できる状態数が増加するため Naive Bayes 識別器よりも良い識別結果を出すことが期待できる。特徴量間での依存関係の決定は相互情報量を使って行われる。ノード x_i, x_j 間の条件付相互情報量は式(4)で表される。

$$I(x_i, x_j | C) = p(x_i, x_j, C) \log \frac{p(x_i, x_j | C)}{p(x_i | C)p(x_j | C)} \quad (4)$$

この相互情報量をエッジとする最大全域木を求めることによって TAN 識別器の構造を決定する。

3. 幼児の室内行動計測

現在、産業技術総合研究所デジタルヒューマン研究センターの人間行動観測用センサルームにおいて、日常生活環境での幼児の行動を観測して実験データを収集している。このセンサルームは壁面に超音波受信機が埋め込まれており、産総研の西田⁹⁾の開発による超音波センサを部屋の中の人や物体に取り付けることで、その各時刻における位置情報を x, y, z の座標データとして取得できる。また部屋の天井部分に魚眼カメラが設置されており、部屋の中の様子をリアルタイムに動画像として撮影できるようになっている。センサルームで撮影された画像の例を図4に示す。

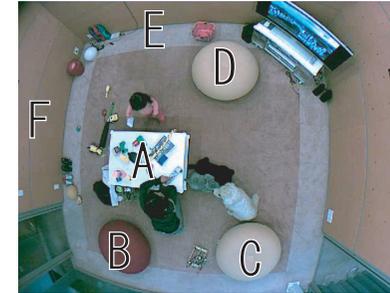


図4 魚眼カメラにより撮影されたセンサルームの様子。
 Fig. 4 Capturing of sensor's room by fishEye camera.

表1 注目した行動と対応する行動ラベル
 Table 1 Correspondence table of behavior labels and action we paid attention.

番号	行動
0	Fall down
1	Sit
2	Stand
3	Walk
4	Run
5	Climb
6	Climb down
7	Crawl

表2 被験者のデータ
 Table 2 Test subject's data.

	性別	年齢	データ数
被験者 1	女兒	1 歳 11 か月	3147
被験者 2	男兒	1 歳 3 か月	3089
被験者 3	男兒	1 歳 2 か月	2329
被験者 4	男兒	1 歳 2 か月	2638
被験者 5	男兒	1 か月	2912
被験者 6	女兒	2 歳 7 か月	2641
被験者 7	女兒	2 歳 7 か月	3038
被験者 8	男兒	1 歳 9 か月	3470
被験者 9	女兒	2 歳 7 か月	3994
被験者 10	女兒	1 歳 3 か月	3002

観測したデータに対して1秒ごとに行動ラベルを記録する。行動ラベルの一覧を表1に示す。今回の行動計測ではセンサルーム内での幼児と母親の行動を約90分間にわたって計測した。計測した被験者の年齢と性別と観測したデータ数を表2に示す。表2の観測したデータ数とは観測したデータの中から、母親が幼児を抱っこをしている状態など行動ラベルを付けることが困難なデータを除いた実験に使用できるデータの数である。

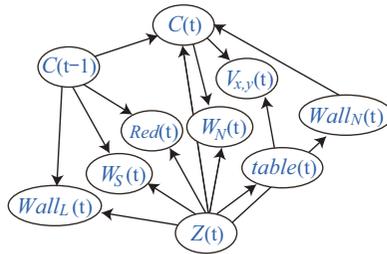


図 5 事前知識モデル.
 Fig. 5 Model of prior knowledge.

4. センサデータを使用したベイズ推定

センサデータから超音波センサの位置情報と魚眼カメラの撮影動画を使用して幼児の行動を推定する. センサデータから得られる特徴量 \mathbf{x} と 1 秒ごとに手作業で割り当てられた行動ラベル C とのセットを学習して識別器を構成する.

事前分布はセンサデータから確率的因果構造を構築する. 今, 推定しようとしている行動ラベルは幼児の場所や周囲の状態によって行動の発生頻度が異なっているはずである. そこで, 事前分布 $p(C)$ は周囲の状況 S に依存した条件付き確率分布 $p(C|S)$ であると考え. この条件付き確率分布 $p(C|S)$ をベイジアンネットワークで構築する. 上記の尤度関数と事前分布を掛け合わせ, 事後確率が最大になる行動ラベル C を推定する.

$$p(C = c_i | \mathbf{x}) = \frac{p(\mathbf{x}|C = c_i)p(C = c_i|S)}{\sum_j p(\mathbf{x}|C = c_j)p(C = c_j|S)} \quad (5)$$

4.1 事前分布

センサデータから確率的因果構造をモデル化する. モデルの構築には BayoNet¹⁰⁾ を使用した. 幼児に取り付けた超音波センサから与えられた 3 次元座標データを使用してベイジアンネットワークを構築する.

我々は以前の研究から幼児の行動と室内のモノとの間に因果関係があると考えた⁵⁾. その考えの下で構築したベイジアンネットワークを図 5 に示す. 図 5 のノードとセンサデータの対応を以下に示す.

- $C(t)$: 今の時刻の分類結果 (行動ラベル)
- $C(t-1)$: 1 つ前の時刻の分類結果 (行動ラベル)
- $V_{x,y}(t)$: 時刻 t の x, y 平面上での幼児の速度



図 6 切り出した周辺領域の画像.
 Fig. 6 An image of capturing infant surrounding.

- $Z(t)$: 時刻 t にセンサにより観測された z 座標データ (高さ)
- $table(t)$: 図 4 の A からの幼児の距離
- $Red(t)$: 図 4 の B からの幼児の距離
- $W_S(t)$: 図 4 の C からの幼児の距離
- $W_N(t)$: 図 4 の D からの幼児の距離
- $Wall_N(t)$: 図 4 の E(壁) からの幼児の距離
- $Wall_L(t)$: 図 4 の F(壁) からの幼児の距離

4.2 尤度関数

尤度関数は画像の特徴量を使用して構成する. 超音波センサを使用して幼児の周辺領域を 48×48 の画像に切り出し, グレースケール化を行う. 切り出した画像の例を図 6 に示す. この画像に対して高次局所自己相関特徴¹¹⁾ を求める. 高次局所自己相関特徴によって周辺画像から回転やシフトの影響の受けない 35 次元の特徴量を得ることができる. この 35 次元の特徴量を使用して識別器を構成して尤度関数とする.

4.2.1 TAN 識別器の構築

高次局所自己相関特徴データを用いて TAN 識別器を構築するために, 前節で示した相互情報量 (式 (4)) から最大全域木を求める方法を用いた.

ただし, 最大全域木の規準で識別木を構成すると必要以上にリンクが張られてしまう可能性がある. そこで, 必要以上にリンクを引かせないために構成されたモデルを情報量規準を使用して評価する. 評価に使用する情報量規準には赤池情報量規準 (AIC) を使用する. さらに, 観測できるデータ数が限られることから, 特徴量の親ノードの数を 2 つに制限した. 以上の議論から, 次のような手順で TAN 識別器を構成する.

- (1) 画像から得られる高次局所自己相関特徴量を離散化する.
- (2) 離散化した値を使用して, 相互情報量を計算する.
- (3) 相互情報量を元に最大全域木を求める.
- (4) 構成されたモデルから赤池情報量規準を元にモデルを選択する.

以上の条件の下で AIC を最小にする TAN 識別器を構築して行動推定を行う。TAN 識別器に与える高次局所自己相関特徴は離散値のデータを与える。

5. 行動ラベルの識別率の評価

Naive Bayes 識別器と TAN 識別器を使用して学習データ、未学習データに対する識別率を評価する。さらに、Naive Bayes 識別器、TAN 識別器を尤度関数、センサデータから構築したベイジアンネットワークを事前分布とするベイズ推定を行った場合の識別率を評価する。

まず、Naive Bayes 識別器、TAN 識別器を構成する際に高次局所自己相関特徴を離散化して使用する。ゆえに、離散化数が重要な要素となる。そこで、最適な離散化数を決定するためにいくつかの離散化数で離散化を行い、最も良い識別率を出せる離散化数を見つける。最も良い識別率の離散化数を使用して未学習データの行動ラベルの識別を行う。

学習データに対する識別率を評価には k -fold Cross validation を用いた¹²⁾。

未学習データに対する識別率の評価は、学習データに対して最も良い識別率を出した離散化数で未学習データを離散化し識別率を評価する。学習データを使用して学習した識別器を使用して未学習データを推定する。正解数を全データ数で割った平均正解率を識別率とする。

5.1 学習データに対する TAN 識別器の評価実験

K-menas 法を使用して高次局所自己相関特徴を離散化した場合の識別率について最も良い離散化数を見つける。K-means 法を行う際の初期値に次の 2 つを使用し、100fold-Cross-Validation 法を使用して識別率を評価する。

- (1) 等度数分割：それぞれのクラスターに含まれるデータの個数を等しくする点を初期値とする。
- (2) 等幅分割：最大値と最小値の区間を等しい幅で分割し、分割する点を初期値とする。学習に使用するデータは被験者 1 のデータを使用する。

それぞれの識別器の識別率を表 3,4 に示す。TAN, Naive Bayes 識別器のみで推定を行った場合、識別率は離散化数を上げていくほど識別率が良くなる傾向にあることがわかる。これは離散化数を増加させることによって表現できる状態数が増加したためであると考えられる。TAN 識別器のほうが Naive Bayes 識別器に比べて識別率が高いことがわかった。

また、事前分布のベイジアンネットワークと組み合わせることによって識別率の向上が見られた。Naive Bayes 識別器の場合では Naive Bayes 識別器の離散化数が高いほうが識別

表 3 離散の場合の Naive Bayes 識別器と TAN 識別器の識別率。

Table 3 Presumption accuracy of Naive Bayes classifier and TAN classifier in discrete.

離散化数	NB 識別器		TAN 識別器	
	等幅分割 [%]	等度数分割 [%]	等幅分割 [%]	等度数分割 [%]
5	16.94	18.06	41.71	41.71
6	19.01	16.87	43.39	43.39
7	19.01	19.42	43.65	43.65
8	21.23	19.94	43.77	43.81
9	21.32	21.9	44	44.58
10	23.77	21.35	44.94	45.94

表 4 離散の場合のベイズ推定の識別率。

Table 4 Presumption accuracy of Bayes inference in discrete.

離散化数	NB+BN		TAN+BN	
	等幅分割 [%]	等度数分割 [%]	等幅分割 [%]	等度数分割 [%]
5	51.81	51.68	68.39	68.61
6	51.39	50.94	68.26	68.26
7	51.39	51.87	68.32	68.39
8	52.29	51.45	67.74	68.45
9	51.97	52.35	68	67.71
10	51.94	52.9	68.26	68.35

率が高くなり、TAN 識別器では離散化数が少ないほうが識別率が高くなった。TAN 識別器では離散化数が 5 で等度数分割を行ったときに最も良い識別率が出た。

5.2 未学習データに対する TAN 識別器の評価実験

前節の実験結果から最も識別率の良かった等度数分割、離散化数 5 としたときの TAN 識別器の識別率を評価する。学習データに被験者 1 のデータを使用し、テストデータのは被験者 2~10 のデータを使用する。

それぞれの被験者に対する識別率を表 5 に示す。未学習のデータに対しては識別率に大きな差がでている。

6. 連続値の識別器

前節で高次局所自己相関特徴を離散化して Naive Bayes, TAN 識別器を構築した。本節では離散値によって構築した Naive Bayes, TAN 識別器の構造を使用して、高次局所自己相関特徴を連続値として扱って、識別を行う。連続値として扱う場合に識別器をマルコフ確率場

表 5 未学習データに対する TAN 識別器の識別率.

Table 5 Presumption accuracy of TAN classifier in discrete for unknown data.

被験者	TAN 識別器 [%]	TAN+BN[%]
2	24.89	70.93
3	32.35	61.68
4	37.20	60.72
5	29.77	58.61
6	37.03	51.00
7	31.99	57.83
8	40.85	60.14
9	32.70	47.50
10	33.04	58.93

として考える.

6.1 連続値の Naive Bayes 識別器

まず, Naive Bayes 識別器について考える. Naive Bayes 識別器では式 (3) の $p(\mathbf{x}|C)$ に次式のガウス分布を仮定する.

$$p(x_i|C = c_j, \alpha) = \sqrt{\frac{\alpha}{2\pi}} \exp\left(-\frac{\alpha}{2}(c_j - x_i)^2\right) \quad (6)$$

α は分布を決定するハイパーパラメータである. ここで α の意味を考えると α は隣接ノードへの影響度を表している. このとき入力される値の最大値が 1 になるように正規化して使用する.

一方で, 3 次元超音波センサデータを使用して幼児の周辺領域を切り出しているがセンサの具合によってうまく位置情報を観測できない場合がある. 位置情報の観測によって高次局所自己相関特徴量に誤差が生じる. そこで, 高次局所自己相関特徴量にノイズが乗ることを考える. 今まで考えていた高次局所自己相関特徴量 \mathbf{x} を真の高次局所自己相関特徴量の値とし, \mathbf{y} を実際に観測される高次局所自己相関特徴量とする. このノイズを式 (7) のガウス分布と仮定し, $p(\mathbf{y}|\mathbf{x})$ で表す. ここで β は分布を決定するハイパーパラメータである. β の意味を考えると観測されたデータの推定結果に与える影響度を表している.

$$p(y_n|x_n, \beta) = \sqrt{\frac{\beta}{2\pi}} \exp\left(-\frac{\beta}{2}(y_n - x_n)^2\right) \quad (7)$$

以上の議論の下で Naive Bayes 識別器は式 (8) となる.

$$p(C = c_j|\mathbf{x}, \mathbf{y}, \alpha, \beta) \sim \prod_n^m p(y_n|x_n, \beta) \prod_i^m p(x_i|C_j, \alpha)p(C = c_j) \quad (8)$$

6.2 連続値の TAN 識別器

連続値の場合の TAN 識別器を図 7 に示す. 図 7 において, \mathbf{x} が真の高次局所自己相関

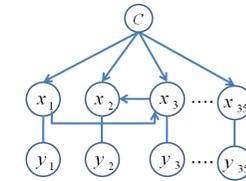


図 7 連続値の TAN 識別器.

Fig. 7 TAN classifier in sequence.

特徴量, \mathbf{y} が実際に観測される高次局所自己相関特徴量, C が行動ラベルである. 高次局所自己相関特徴にノイズが発生しない場合の事後確率分布 $p(C = c_j|\mathbf{x})$ は次式で表わされる.

$$p(C = c_j|\mathbf{x}) \sim \prod_{ik \in \mathcal{L}} p(x_i|x_k, C = c_j, \alpha)p(C = c_j) \quad (9)$$

ここで \mathcal{L} はリンクの集合, $p(x_i|x_k, C)$ が特徴量間の相互作用を表す. $p(x_i|x_k, C)$ には式 (10) のガウス分布を仮定する.

$$p(x_i|x_k, C = c_j, \alpha) = \sqrt{\frac{\alpha}{2\pi}} \exp\left(-\frac{\alpha}{2}(x_k - x_i)^2 + (c_j - x_i)^2\right) \quad (10)$$

同様に高次局所自己相関特徴にノイズが発生する場合を考える. この考えの下で事後確率分布 $p(C = c_j|\mathbf{x}, \mathbf{y}, \alpha, \beta)$ は次式になる.

$$p(C = c_j|\mathbf{x}, \mathbf{y}, \alpha, \beta) \sim \prod_n^m p(y_n|x_n, \beta) \prod_{ik \in \mathcal{L}} p(x_i|x_k, C = c_j, \alpha)p(C = c_j) \quad (11)$$

式 (11) の確率を最大にするラベル $C = c_j$ を推定結果とする.

7. 連続値モデルによる行動ラベルの推定

高次局所自己相関特徴を離散化して構造を決定した TAN 識別器と Naive Bayes 識別器の構造を連続値モデルとして扱い, 行動ラベルの推定を行う. 連続値モデルで行動ラベルを推定するためにはハイパーパラメータを決定する必要がある. そこで, まずハイパーパラメータを決定するために適当に α, β の値を変えて最も良い識別率を得られるハイパーパラメータを探す. ハイパーパラメータを決定した後, 未学習データに対する識別率を評価する.

7.1 ハイパーパラメータの決定

連続値モデルを使用して推定を行う場合にモデルの形を決定するハイパーパラメータを決定する必要がある. そこで, 予備実験としてハイパーパラメータを決定するために適当に α, β の値を変えて最も良い識別率を得られるハイパーパラメータを決定する. ハイパーパラメータをそれぞれ 0.01~0.49 まで変更したときの TAN 識別器と Naive Bayes 識別器の

表 6 被験者 1 に対する TAN 識別器の識別率.

Table 6 Presumption accuracy of the behavior labels of test subject1 by TAN classifier.

α	β	識別率 [%]
0.44	0.04	36.5
0.1	0.05	36.1
0.49	0.04	36.0
0.32	0.04	36.0
0.38	0.04	36.0
0.48	0.04	35.9

表 7 被験者 1 に対する Naive Bayes 識別器の識別率.

Table 7 Presumption accuracy of the behavior labels of test subject1 by Naive Bayes classifier.

α	β	識別率 [%]
0.01	0.46	20.7
0.01	0.34	20.1
0.01	0.48	20.0
0.01	0.44	19.9
0.01	0.39	19.9
0.01	0.47	19.7

表 8 未学習データに対する連続値の TAN 識別器の識別率.

Table 8 Presumption accuracy of TAN classifier in sequence for unknown data.

被験者	NB 識別器 (連続)[%]	TAN 識別器 (連続)[%]	NB(連続)+BN[%]	TAN(連続)+BN[%]
2	21.10	7.96	75.78	75.98
3	21.26	23.15	43.12	44.07
4	20.70	23.30	57.00	71.70
5	20.10	9.62	58.93	58.83
6	20.00	24.84	27.00	49.68
7	19.78	12.8	63.17	63.23
8	20.40	15.48	53.00	52.88
9	20.73	16.12	45.79	45.97
10	21.45	8.73	62.66	62.66

識別率を評価し、ハイパーパラメータを決定する。入力するデータは被験者 1 のセンサデータを使用する。

TAN 識別器, Naive Bayes 識別器のハイパーパラメータを変えたときの識別率の上位 5 件のパラメータを表 6,7 に示す。TAN 識別器, Naive Bayes 識別器ではハイパーパラメータの傾向がまったく異なることがわかった。この結果から TAN 識別器はノード間の相互作用が識別に大きな影響を与えていることがわかる。また, Naive Bayes 識別器では観測されるデータが識別に大きな影響を与えていることがわかる。

7.2 未学習データに対する連続値の TAN 識別器の評価実験

前節の最も識別率の高いハイパーパラメータを使用して、事前分布のベイジアンネットワークと組み合わせた場合の識別率について評価する。TAN 識別器では $\alpha = 0.44, \beta = 0.04$, Naive Bayes 識別器では $\alpha = 0.01, \beta = 0.45$ を採用する。このパラメータを使用したときに被験者 1~3 の行動ラベルを推定する。ここで、被験者 1 は学習に使用したデータ、被験者 2~10 は未学習データである。

実験結果を表 8 に示す。表 8 より、未知のデータに対して Naive Bayes 識別器に比べて TAN 識別器のほうが全体として識別率が高いことがわかる。

8. 考 察

TAN 識別器を高次元局所自己相関特徴から構造を決定し、行動ラベルの推定を行ってきた。行動ラベルの推定を行った結果、離散値では Naive Bayes 識別器に比べて TAN 識別器のほうが識別率が高かった。また、連続値の場合では Naive Bayes 識別器のほうが TAN 識別器に比べて識別率が高かった。TAN 識別器の識別率が最も低かった被験者 2 の場合の連続値の TAN 識別器と Naive Bayes 識別器の推定結果を表 9, 10 に示す。左側の行動ラベル

が正解のラベル、上側の行動ラベルが識別器が推定した行動ラベルである。TAN 識別器では Sit, Stand のラベルを Walk ラベルに間違えていることによって識別率が低下している。Naive Bayes 識別器では半分のラベルが Fall down のラベルに識別されている。TAN 識別器では識別しているラベルのほとんどが Walk であり、Naive Bayes 識別器では各ラベルをまんべんなく出力している。これはハイパーパラメータの値の違いによって表れていると考えられる。 α が大きいほど、推定された確率分布の分散が小さくなる傾向にある。したがって、TAN 識別器では推定するラベルの幅が狭くなった。

また、連続値と離散値の 2 つの場合で TAN 識別器の計算を行った。連続値と離散値の場合の識別率を表 8 に表す。離散値の TAN 識別器のほうが良い識別率であった。しかし、ベイジアンネットワークと組み合わせた場合には識別率の差はあまり見られなかった。この結果からベイジアンネットワークの識別の影響が最終的な識別の結果に強く影響していることが考えられる。今後の識別率の目標として、最も多いラベルの頻度よりも高い識別率を得られるようにしたいと考えている。

9. 結 論

人間の行動を観察して理解・認識することは、事故予防を考える上で重要である。

本稿ではベイズ推定を用いる際に尤度関数に TAN 識別器と事前分布にベイジアンネットワークを導入することによって、従来の手法に比べて行動ラベルの識別率が向上することを実験的に評価した。評価の結果、TAN 識別器を導入することによって特徴量間の相互作用を表現することができるため Naive Bayes 識別器に比べて識別率が向上した。また、TAN 識別器の計算を行う際に、離散値、連続値の 2 つの場合について評価を行った。識別器単体

表 9 被験者 2 に対する TAN 識別器 (連続) の推定結果.
 Table 9 Inferred result of TAN classifier for test subject2.

	Fall down	Sit	Stand	Walk	Run	Climb	Climb down	Crawl	合計
Fall down	0	0	0	2	1	0	0	0	3
Sit	0	0	57	1822	41	0	0	0	1920
Stand	0	0	49	803	39	0	0	0	891
Walk	0	0	23	197	1	0	0	0	221
Run	0	0	0	0	0	0	0	0	0
Climb	0	0	0	3	0	0	0	0	3
Climb down	0	0	0	1	0	0	0	0	1
Crawl	0	0	6	44	0	0	0	0	50
合計	0	0	135	2872	82	0	0	0	3089

表 10 被験者 2 に対する NB 識別器 (連続) の推定結果.
 Table 10 Inferred result of Naive Bayes classifier for test subject2.

	Fall down	Sit	Stand	Walk	Run	Climb	Climb down	Crawl	合計
Fall down	0	1	0	2	0	0	0	0	3
Sit	486	415	415	411	185	8	0	0	1920
Stand	218	170	200	187	107	9	0	0	891
Walk	70	45	55	37	14	0	0	0	221
Run	0	0	0	0	0	0	0	0	0
Climb	0	1	0	0	2	0	0	0	3
Climb down	0	0	0	0	1	0	0	0	1
Crawl	13	13	9	8	7	0	0	0	50
合計	787	645	679	645	316	17	0	0	3089

表 11 連続値と離散値の TAN 識別器の識別率.
 Table 11 Presumption accuracy of TAN classifier in sequence and discrete.

被験者	TAN(離散)[%]	TAN(連続)[%]	TAN(離散)+BN[%]	TAN(連続)+BN[%]	行動頻度 [%]
2	26.12	7.96	62.16	75.98	62.16(sit)
3	32.60	23.15	38.23	44.07	46.31(stand)
4	37.20	23.30	60.72	71.70	55.61(stand)
5	29.77	9.62	58.61	58.83	71.53(sit)
6	37.03	24.84	51.00	49.68	50.43(sit)
7	31.99	12.80	57.83	63.23	52.53(sit)
8	40.85	15.48	60.14	52.88	58.53(stand)
9	32.70	16.12	47.50	45.97	53.73(stand)
10	33.04	8.73	58.93	62.62	49.40(sit)
平均識別率	33.48 ± 4.11	15.78 ± 6.24	55.01 ± 7.46	58.33 ± 10.5	55.58 ± 7.22

の識別率では離散値のほうが識別率が良かったが、ベイジアンネットワークと組み合わせた場合には識別率にあまり差がなかった。この結果から、ベイジアンネットワークの識別が最終的な識別に大きな影響を与えているのではないかと考えられる。また、今後の目標として最も多いラベルの頻度よりも高い識別率を得られるようにしたいと考えている。

参考文献

- 厚生労働省. 平成 20 年人口動態統計月報年計 (概数) の概況.
- 本村陽一, 西田佳史. 日常環境における支援技術のための行動理解-子供の事故予防を応用を例にして-. 人工知能学会誌, Vol.20, No.5, pp. 587-594, 2005.
- 本村陽一, 西田佳史. ベイズ推定における事前分布のグラフ構造モデリングと実生活行動理解. 情報処理学会論文誌:コンピュータビジョンとイメージメディア, Vol.48, No. SIG9, pp. 43-56, 2007.
- 河田諭志, 本村陽一, 西田佳史, 石川詔三, 田中和之. 室内における幼児の行動予測のための確率的因果構造モデルの学習と推論. 電子情報通信学会ニューロコンピューティング研究会, 2007.
- 石川詔三, 本村陽一, 西田佳史, 河田諭志, 原一之. 日常生活行動における確率的因果構造モデルの構築と行動推論. 人工知能学会全国大会, 2008.
- Nir Friedman and Moises Goldszmidt. Building classifiers using bayesian networks. *Thirteenth National Conf. on Artificial Intelligence (AAAI96)*, 1996.
- 石川詔三, 本村陽一, 西田佳史, 河田諭志, 原一之. Tree argued naive bayes とベイジアンネットワークを組み合わせたベイズ推定による幼児の室内行動認識. 電子情報通信学会ニューロコンピューティング研究会, 2009.
- 本村陽一, 岩崎弘利. ベイジアンネットワーク技術. 東京電機大学出版社, 2006.
- 西田佳史, 堀俊夫, 金出武雄. 超音波 3 次元タグを用いた日常環境のセンサ化とその応用. ケミカルエンジニアリング, Vol.50, No.7, pp. 520-526, 2005.
- ベイジアンネットワーク構築支援システム BayoNet. <http://www.msi.co.jp/BAYONET/>.
- N.Otsu and T.Kurita. A new scheme for practical. *flexible and intelligent vision systems, Proc. IAPR Workshop on Computer Vision*, pp. 431-435, 1988.
- 小西貞則, 北川源四郎. 情報量基準. 予測と発見の科学 2. 朝倉書店, 2004.