

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

Inference and Construction of Probabilistic Causal Structure Model for Everyday Life Behavior

石川詔三*¹ 本村陽一*² 河田諭志*³ 西田佳史*² 原一之*¹
 Ishikawa Shouzou Motomura Youichi Kawata Satoshi Yoshifumi Nishida Kazuyuki Hara

*¹東京都立産業技術高等専門学校 *²独立行政法人 産業技術総合研究所
 Tokyo Metropolitan College of Industrial Technology National Institute of Advanced Industrial and Technology

*³株式会社 東芝
 TOSHIBA CORPORATION

For understanding in observing human's behavior, I introduce way of assigning behavior's label from moving data in automatic. Children's behavior from sensor's data on observation of children's behavior infers behavior's label using Bayes's theorem. Prior probability distribution in Bayes's theorem uses Bayesian network. Using Bayesian network can give prior probability distribution probabilistic causal structure. Likelihood function in Bayes's theorem uses Naive Bayes classifier. Naive Bayes classifier learns from Behavior's label in assigning by humans and higher order local autocorrelation calculating from moving pictures. Using this way improves inference accuracy in behavior's label, finally, sensor's data assigns behavior's label in automatic.

1. はじめに

現在、室内の各種センサデータから大量情報を取得することが可能になっている。人間の行動を観察して理解・認識することは、子供や高齢者の家庭内の事故予防を考える上でも大きな関心を寄せている。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。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。そのために、動画像から行動ラベルを自動的に付与することを考える [1]。

本研究では室内における幼児の日常生活行動を観測し画像などのセンサデータから、その行動を予測するための行動モデルの統計的学習法を行う事例を紹介する。室内において幼児の行動を観測した動画像および超音波位置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ってモデル化する。

これを事前分布としたベイズ推定を行う。学習により得られたモデルを使用して動画像から幼児の行動を推定し、認識精度を評価する。

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に基づいて行われる。センサデータから得られる特徴量 x から決定されるクラスラベルを $C = c_1 \cdot c_2 \cdots c_n$ とし、事前分布を $P(C)$ 、クラスラベルが与えられた場合の条件付き確率分布を $P(x|C)$ 、事後分布を $P(c|x)$ とする。事後確率を最大にするクラスラベルを $C = c_i$ としたとき、ベイズの定理より事後分布は

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

で与えられる。このとき、右辺の分母はクラスラベルに依存しないため定数とみなすことができる。したがって、式 (1) は

$$P(C = c_i|x) \propto P(x|C = c_i)P(C = c_i) \quad (2)$$

と書き表すことができる。また、右辺第1は特徴量 x が既知でクラスラベル C の関数とみなすと、 C の尤度を示す尤度関数として扱うことができる。尤度関数と事前分布の積から事後分布を計算し、事後分布を最大にするクラスラベル $C = c_i$ を推定する。

これが、パターン認識におけるベイズ推定である。従来、事前分布は決定することが困難な場合には、事前分布には一様分布が用いられる [5]。

2.2 ベイジアンネットワーク

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グラフィカルモデルである。確率変数をノードで表わし、依存関係をリンク（矢線）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内に存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。この構造を用いることで、どちらかのノードの状態を決定することで相手のノードの取りうる状態を確率推論することができる [4]。

3. 子供の日常生活行動計測

3.1 計測環境

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 [2] 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

連絡先: 本村陽一, 産業技術総合研究所デジタルヒューマン研究センター, 東京都江東区青梅 2-41-6-3F, y.motomura@aist.go.jp



図 1: センサールームの概観 .

して撮影できるようになっている . センサールームの概観を図 1 に示す . 撮影された画像の例を図 2 に示す .



図 2: 魚眼カメラにより撮影されたセンサールームの様子 .

さらに , 撮影した画像から人手で 1 秒ごとに行動ラベルを割り当てた . 割り当てた行動ラベルは "Fall down", "Sit", "Stand", "Walk", "Run", "Climb", "climb down", "Crawl" の 8 種類である .

3.2 計測データを使ったベイズ推定

計測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 . センサデータから与えられる特徴量 x と一秒ごとに人手で割り当てられた行動ラベル $C(t)$ とのセットを学習して識別器を構成する . 識別器によって事後確率を最大にする行動ラベル $C(t)$ を推定する .

行動ラベルの推定には式 (2) を用いる . 事前分布 $P(C = c_i)$ と尤度関数 $P(x|C = C_i)$ の与え方について説明する .

● 事前分布

通常 , 式 (2) では事前分布 $P(C = C_i)$ が一様分布であると仮定して , 行動ラベルを推定している . しかし , 実際の行動は観測時間や観測場所のようなその場の状況に依存して発生頻度が異なっている . したがって , 事前分布 $P(C(t))$ は状況 S に依存していると考えられる . 式 (2) 式のように事前分布 $P(C(t))$ に一様分布を使用しているベイズ推定では , 理論的な上限により精度が劣化してしまう . そこで , 事前分布を状況 S に依存する条件付き確率 $P(C(t)|S)$ として表す . この条件付き事前分布 $P(C(t)|S)$ をベイジアンネットワークによって学習し , 事前分布とする . 子供の位置情報や事前に行っていた行動など状況 S を表す確率変数として利用する .

● 尤度関数

画像から行動を識別するためには有効な特徴量 x を抽出する必要がある . 撮影動画から超音波センサの位置情報を基に子供の周辺の画像を切り出し , 切り出した画像を高次元局所自己相関特徴 [6] を使用して 35 次元の特徴ベクトル x に圧縮する . 尤度関数 $P(x|C = c_i)$ には人手に割り振られた行動ラベル $C(t)$ と特徴量 x をセットで学習した Naive Bayes 識別器を用いて教師あり学習により構成した . Naive Bayes 識別機はクラスラベル C が条件付き独立であるとした場合に使用することができる . 今 , クラスラベル C は 8 種類与えられている . この識別機では事前分布を一様分布として学習を行う .

以上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を推定する .

$$P(C(t) = c_i|x) \propto P(x|C(t) = c_i)P(C(t) = c_i|S) \quad (3)$$

4. 確率的因果構造のモデル化

4.1 観測した室内環境における因果構造モデル

ベイジアンネットワークはリンクによって , 依存関係を表現することができる . これは親ノードが子ノードに影響を与えることを示している . すなわち , 親ノードと子ノード間には因果関係がある . ベイジアンネットワークを使用することで , 事前分布に確率的因果構造を持たせることができる . 以前の研究では状況 S の確率変数として以下の変数を使用してきた [7] .

$C(t-1)$: 1 つ前の時刻の推定結果 .

$R(t)$: 時刻 t に幼児のいる場所 . センサにより観測された xy 座標データを基にセンサールーム全体をメッシュに区切って利用する .

$Z(t)$: 時刻 t にセンサにより観測された z 座標データ (高さ) .

$V_{x,y}(t)$: 時刻 t の xy 平面上での幼児の速度 .

$V_z(t)$: 時刻 t の z 方向の幼児の速度 .

実際の幼児のいる場所と確率変数 $R(t)$ の取り方を図 3 に示す . 部屋を 8×6 の領域に分割し , 領域ごとに 1 ~ 4 8 までの値




図 3: 幼児のいる場所と確率変数 $R(t)$ の対応 .

をとる . 幼児がいる領域の値をを時刻 t における $R(t)$ の値として使用する .

以上の確率変数と行動ラベルから図 4 の構造を持つベイジアンネットワークが最適であるという結果が得られている .




図 4: 行動ラベルに関する事前知識の確率的因果構造 .




図 5: モノと幼児の距離関係 .

4.2 再利用可能なベイジアンネットワークのモデル化

おもちゃや家具などのモノが幼児の行動に影響を与えることは容易に想像ができる．そこでモノが幼児の行動に影響を与えることについて考える．モノが幼児の行動に影響を与えることから，幼児の行動はモノの位置によっても影響を受ける．図 4 のモデルではモノの位置情報は $R(t)$ に内包されていると考えられる．モデルに使用してきた $R(t)$ では座標系への依存度が高いため，部屋の構成やモノの配置が異なると正しく行動を推定することが困難になる．また，部屋の領域をメッシュ状に区切っているため確率変数の状態数が多くなり，完全データとして取得することが困難になる．

本稿では幼児の行動とモノとの関係に着目して x, y 座標系を取り除き，代わりに位置情報として，幼児とモノとの相対距離を導入した．相対距離を導入することで，モノの配置が異なる場合にも対応することができる．状況 S として以下の確率変数を使用した．

- $P(t)$: 1 つ前の時刻の推定結果 (行動ラベル) .
- $V_{x,y}(t)$: 時刻 t の xy 平面上での幼児の速度 .
- $Z(t)$: 時刻 t にセンサにより観測された z 座標データ (高さ) .
- $Wall_N(t)$: 撮影画像を見て上側の壁からの幼児の距離 .
- $Wall_L(t)$: 撮影画像を見て左側の壁からの幼児の距離 .
- $table(t)$: 撮影画像中央のテーブルからの幼児の距離 .
- $Red(t)$: 撮影画像左下の赤いクッションからの幼児の距離 .
- $W_N(t)$: 撮影画像右上の白いクッションからの幼児の距離 .
- $W_S(t)$: 撮影画像右下の白いクッションからの幼児の距離 .

1 秒前の行動 $P(t)$ には事前に推定された行動ラベル $C(t-1)$ を使用した．天井からの高さ $V(t)$ と平面方向の速度 $V_{x,y}$ には超音波センサからの x, y, z 座標から求めた．モノとの距離も同様に超音波センサの座標データから求めた．例としてテーブルと幼児の距離の関係を図 5 に示す．テーブルを中心とした円が幼児からのモノの距離を表している．図 5 の例ではテーブルからの幼児の距離は 'near' となる．

4.3 再利用可能なモデルの構築

前節で示した確率変数と現在の行動 $C(t)$ とを実験により集めたセンサデータと人手に割り振られた行動ラベルから集計する．集計したデータを基に産総研の本村 [3] の開発したベイジアンネットワークソフトウェア "BayoNet" [8] を使用して，赤池情報量基準 (AIC) を最小にするという基準でモデルを探索する．BayoNet でのモデル構築の様子を図 6 に示す．




図 6: BayoNet のモデル構築 .

探索により図 7 の構造を持つベイジアンネットワークが最適であるという結果が得られた．

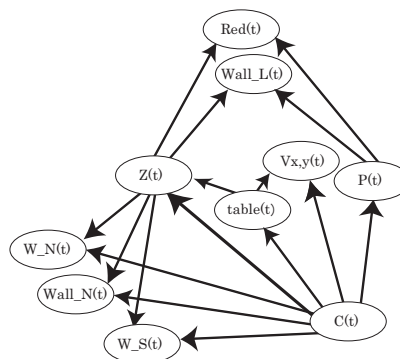


図 7: 相対距離を利用した確率的因果構造 .

得られたモデルから一部のモノ，幼児の高さ，幼児の速度，一つ前の幼児の行動は現在の幼児の行動との間に因果関係があることがわかった．クッションを例にとれば，クッションの近くでは幼児はクッションによじ登る，座る，クッションから降りるなどの特定の行動を取りやすいためである．その行動を

受けて幼児の高さが変化するため、高さともノの間にリンクが引かれたと考えられる。また、歩くや走るや立つなどの動作によって幼児の速度が変化するため、幼児の速度と行動には因果関係がある。

$C(t)$ を除くすべてのノードにセンサデータの値を与えることで事前分布 $P(C(t))$ を決定する。

5. モデルの評価

5.1 Cross Validatuion 法による評価

得られたセンサデータを基に識別精度を k-fold Cross Validation 法で検証した。k-fold Cross Validation 法では取得したデータを k 個のグループに分割し、1 つのグループを評価用のデータとし、残りの k-1 個のグループを学習用のデータとして使用する。学習によって得られたモデルを評価用のデータを使って識別率を評価する。この手順を k 回繰り返し、モデルの識別率を評価する。k=100 としてモデルの評価を行った。1 歳 11 か月の女児のセンサデータをデータ 1、1 歳 3 か月の男児のセンサデータをデータ 2 にとり、それぞれ評価した。推定結果と正解との一致率の平均を識別率として、識別率の結果を表 1 に示す。

表 1: 識別率の評価

	サンプル数	最尤推定	モデル 1	モデル 2
データ 1	3147	33.97%	67.48%	69.74%
データ 2	3089	31.27%	79.93%	81.50%

表 1 の 2 列目が事前分布を一様分布とした場合の最尤推定の結果である。3 列目のモデル 1 が観測した室内環境における因果構造モデルを使用した推定結果である。4 列目のモデル 2 が再利用可能なベイジアンネットワークのモデル化により構築したモデルを使用した推定結果である。事前分布にベイジアンネットワークを使用した場合では、データセットによるばらつきを抑えられていることがわかる。最尤推定に比べてモデル 1、モデル 2 は共に識別率が大きく向上している。

5.2 モデルの再利用性の評価

1 歳 11 か月の女児のセンサデータからモデルを構築し、そのモデルを使用して異なる幼児の行動を推定した。Naive Bayes 識別器についても同様に女児のセンサデータで教師あり学習を行った結果を使用して推定を行った。入手に振られた行動ラベルを正解としてそれぞれの推定結果と比較し、正解と一致した個数から識別率を求める。推定結果を表 2 に示す。

表 2: 再利用性の評価

	サンプル数	最尤推定	モデル 1	モデル 2
データ 2	3089	49.33%	65.98%	75.17%
データ 3	2328	37.20%	51.37%	59.54%

データ 2 は 1 歳 3 か月の男児、データ 3 は 1 歳 2 か月の男児のセンサデータである。表 2 において 2 列目が最尤推定の

結果である。つまり、Naive Bayes 識別機のみでの推定結果になる。3 列目のモデル 1 が観測した室内環境における因果構造モデルを使用した推定結果である。4 列目のモデル 2 が再利用可能なベイジアンネットワークのモデル化により構築したモデルを使用した推定結果である。モデル 1 に比べてモデル 2 は高い推定精度を出していることがわかった。モデル 2 は幼児の位置情報に空間座標系を使用せず、部屋内のモノとの相対距離を位置情報として使用している。そのため、推定対象が変わった場合にもモノと行動の関係性を重視したモデルであるため推定結果がモデル 1 に比べて良くなったと考えられる。この結果からモデル 2 は再利用性の高いモデルであるといえる。

6. まとめ

人間の行動を理解・認識することは子供や高齢者の事故予防を考える上で重要である。本稿では人間の日常生活行動の理解のために、人間の行動を計測した大量のセンサデータに対して人が解釈可能な行動ラベルを自動的に付与する手法について提案した。ベイジアンネットワークを使用してモデル化を行い、因果構造を持った事前分布と機械学習の手法をあわせることによって幼児の日常生活行動に対する行動ラベルの推定精度を向上させた。

また、モデルの再利用性を向上させるため事前分布のベイジアンネットワークから座標系をとり除き、室内のモノとの相対距離を使用したモデルを作成した。モノとの相対距離を使用したモデルでは以前までの座標系を使用したモデルに比べ、推定精度がほぼ変わらぬまま、他のセンサデータに対しても高い識別精度があることがわかった。

今後はさらに屋外などで観測した子供の遊び行動分析などにおいても再利用可能な因果構造知識のモデル化を目指し、日常生活の計算論的理解研究を進める。

参考文献

- [1] 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 - 子供の事故予防への応用を例にして -, 人工知能学会誌, vol. 20, no. 5, pp.587-594 (2005).
- [2] 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).
- [3] 本村陽一, 岩崎弘利: ベイジアンネットワーク技術, 東京電機大学出版局, (2006).
- [4] 繁樹算男, 植野真臣, 本村陽一 共著: ベイジアンネットワーク概説, 培風館 (2006).
- [5] 中妻照雄: 入門ベイズ統計学, 朝倉書店, (2007).
- [6] 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).
- [7] 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 年度)
- [8] 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/>)