

日常生活行動の計算論的理のための確率的構造モデル

本 村 陽 一[†] 西 田 佳 史[†]
川 上 悟 郎[‡] 溝 口 博[‡]

日常の実空間中の行動を計算論的に理解するために、各種のセンサデータを統合し、統計的学習によって、構造的な確率モデルを構築し活用する方法について述べる。日常で観測される様々なセンサやラベルデータを含む非定常な大規模データから確率的構造モデルを構築するためには、次元圧縮と変数変換が必要である。これを適切に行うため一般化時空間写像を導入する。この空間上での分布をベイジアンネットで構造化することで、制御変数が行動に与える条件付き分布として再利用性が高いモデルとして構築することができる。

Probabilistic Structure Models for Everyday Life Computing

YOICHI MOTOMURA[†], YOSHIFUMI NISHIDA[†], GORO KAWAKAMI^{††}
and HIROSHI MIZOGUCHI^{††}

Everyday life computing that means human behavior understanding in everyday life is promising but not established research field. In these years, many sensor homes and robotic room projects have been studied and sensing and network technology have been established. However, still we have problems to realize practical application of everyday life computing. There are two major problems. The first one is re-usability of computational model in everyday life. The second one is we don't have a good way to reduce variables and dimensions of observations. In this paper, we propose a method to use generalized spatio-temporal mapping and Bayesian network structural learning to overcome these problems.

1. はじめに

計算機の小型化やセンサ技術や通信技術の発展にとどまらない、ユビキタス情報処理、センサネットワーク技術を用いた日常生活行動の観測が可能になってきた。そこで、日常生活を支援するための情報技術への期待が高まっている。多数のセンサを日常生活空間に持ち込みデータを大量に収集することは、国内外のプロジェクトですでに行われている。例えば、センサからの情報取得と抽出に特化するもの、高齢者などの特定のユーザを対象とするもの、技術実験のための実験装置、生活者支援を目指すものなどがある¹⁾。つまり、住居として利用できる実験施設において実際の日常生活行動を各種のセンサにより観測し、それらセンサデータを統合するためのネットワークとミドルウェアにより、数週間程度の実験期間で生活行動を各種のセ

ンサデータの履歴として記録しそれを使った情報処理ができるようになっている。

しかし、その一方でいくつかの課題が指摘されてきている。例えば、人間の生活は多様であり、設計者が想定する統一的な生活支援は不可能であること、使っているうちに利用者に応じて最適化する個人適応、つまり機械学習技術が重要であることが具体的に指摘されている¹⁾。一方で機械学習分野における人間の行動理解を行う研究では、とくにグラフ構造を持つ確率モデルを用いる研究事例がある²⁾。人間行動のモデル化についてはHMMやその拡張モデルの適用例^{3),4)}があるが、音声認識などの場合と異なり、自由度の高い生活行動を対象とした場合には、最適なネットワーク構造を決定することが困難であり、既知の時系列構造以外への適用が難しく、さらにつれてこれまでの研究でも日常生活行動における未知の依存関係の構造発見は実現できていない。グラフ構造を比較的容易に学習できる確率モデルとしてベイジアンネット⁵⁾がある。ベイジアンネットは離散有限状態の値を持つ離散確率変数間の確率的依存関係をネットワークとして表したもので、離散データについては多くの成功事例があるが、

[†] 産業技術総合研究所 デジタルヒューマン研究センター
National Institute of Advanced Industrial Science and
Technology, DHRC
[‡] 東京理科大学
Tokyo University of Science

実空間上における人間の行動などをそのまま連続確率分布を扱うと確率推論や学習の実行が困難であるため、連続値変数や時間的状態を適切に離散化することが必要である。この変数変換はこれまで非明示的に個別のノウハウとして扱われることが多く、十分に検討されてきたとは言えなかつた。

本稿では日常生活を様々なセンサにより包括的に観測し、収集したデータから計算論的な行動モデルを統計的学習アプローチにより構築することを目的として、モダリティの異なるセンサデータを一般化時空間写像に散布した確率分布を経由して、ベイジアンネットを構築することで、日常生活行動を再利用性の高い計算論的モデルとして構築する方法について述べる。本研究では、観測空間にはよらない時空間意味情報における変数空間の設計や、時空間意味情報に内在する時間(状態)の扱いも考慮した確率分布を考える。既存の多くの確率モデルがセンサデータを単に書き取り尤度を判定するだけで、学習時の対象以外の用途に再利用することが困難であったのにたいし、対象中にある変数を一般化し、その間の関係性を定量的に表したベイジアンネット上で確率推論を実行することで、日常生活支援システムのために再利用できるものになる。

2. 計算論的日常生活行動理解

これまでに行われている日常生活行動研究の中で実現されている代表的な応用例は異常検知である⁸⁾が、さらに応用を広げるためには、恒常的な定常分布のモデル化だけでは不十分である。日常生活行動をモデル化する一つの動機は、過去の記録データから将来も成り立つ関係性を獲得することで、現在の状況に基づいて想定される将来の結果を予測し、あるいはその予測を最適化するように、現在とるべきアクションを決定したいということである。つまり日常における現象を制御可能なものとして考えて、大量データからの統計的学習により妥当な制御変数を見つけ、それを含んだ条件付き分布のモデル化を行い、ある状況と対象の変化に応じて結果である目的変数の変化を予測する高次の推論が必要になる。

大量の実データからモデルを構築するために、我々の研究グループでは多様な行動をセンシングする装置として、日常生活空間内の複数点の位置をcmオーダーで計測可能な超音波位置計測装置を開発してきた⁷⁾。これは人の手足や移動物体に非常に小型の超音波発信器タグを装着し、室内や屋外の環境側に測位用の超音波受信機を複数設置することで、タグを装着した人の手足の位置や物の位置情報を各時刻(1秒単位)の3

次元座標値として時間空間的に表現するものである。結果としての行動観測データとしては(id, t, x, y, z)の系列が得られる。 id は該当するタグを装着した人や部位、物の属性などと関連づけるために用いる。

次に、ある時刻のイベントについて意味的な情報や主観的な解釈を時間に同期して幅広く収集することで、先の行動観測データにラベル情報を付加していく。これは(id, t, L_i)のように記録される。 L_i は多値の離散変数(カテゴリカル変数)である。先の行動観測データとは id, t により対応づけられるが、ただし観測頻度は同一ではない。現在はカメラによる映像をセンサデータと同期して記録しておき、これを人が見ながら行動ラベルやイベントの解釈をラベル化する。また人が付与するラベル L_i の代わりに目的に応じたセンサを追加し、その値 S_i を行動観測データと同期させる。例えば筋電センサにより握力が発生したイベントを時空間に対応づけることができる¹²⁾。ただし、 S_i は連続値なので後述の構造的モデル化のためには識別器によりカテゴリ化して($id, t, L_i(S_i)$)のようにする。時間 t の解釈(午前、午後、曜日、季節など)についても $L_i(t)$ のようなラベルとして扱う。同様に場所のラベルについても $L_i(x, y, z)$ を定義することで、その位置はリビングであるといったラベル化を行う。また $L_i(id1, x1, y1, z1, id2, x2, y2, z3)$ のように複数の位置から相対的距離をラベル化する場合もある。

また日常生活行動にはマルコフ性が見られることが多い。そこで行動現象の説明変数として、現在の状態(説明変数群の現在の値)だけでなく、直前の状態(説明変数の過去の値)も含むものを考える。過去のどの時刻の値が目的変数に影響を与えることになるかは、生成メカニズムによって異なるため、時間の分節は個別に行う。その上で現在の時刻 t における、前の状態を次のように追加する。 L_i について $t-1$ での値を L_i^{t-1} としてこれも時刻 t のデータとしてデータベースに追加する。

このようにして観測頻度が異なるセンサや主観的な解釈、位置などを id, t により対応づけながら集積する。こうして特定のタスクに限らない幅広い日常生活行動を包括的に記録でき、長期にわたり生活可能なセンサハウス¹⁴⁾や、保育園や病院などにおいてデータ収集を進めている。

3. 一般化時空間写像

日常生活行動の計算論的理解においては「どの変数についての計算を行っているのか」という変数選択が大きな問題である。また目的変数に対する予測だけで

なく、制御を考えると、目的変数に対する直接の説明変数だけでなく、制御可能な説明変数の間の関係も重要である。そこで、先に述べた行動の「目的」や「結果」となる変数と、それを実現する手段や結果に影響する状況の間の因果構造に注目し、その構造における主要な変数をモデルの構成要素としたベイジアンネットを構築する。以降ではそのための一般化時空間写像について述べる。

使用的センサが増えたり、同じ情報源であってもその解釈であるラベルを追加していくので、前節で述べた観測データの次元はすぐに増大し、モデル化のための計算量と記憶容量が問題になる。また各変数の観測頻度は同一とは限らないので、時間軸に全変数の値を並べたテーブルは欠損を多く含む非常にスパースなものになってしまいます。そのため、収集したデータ表現のままで全ての変数を対象としたベイジアンネットの構造学習を行うことは、欠損データや探索空間の増大のために現実的には実行困難である。そこで収集した日常生活観測情報から条件付き確率分布を容易に構成できるような写像を考える。

まず、Sliced Inverse Regression(SIR)⁹⁾などで用いられている層別の次元圧縮を考える。SIRは連続区分的に主成分分析を用いる教師なしの次元圧縮であるがこれを教師付に拡張することもできる¹⁰⁾。これらの手法は連続値変数のものであるが、離散変数について同様に考えて対象とする目的変数に対する教師付の次元圧縮を考える。その基準としては各変数 L_i の状態数がそれぞれ異なるため自由度も考慮した情報量規準を用いる。

次に具体的な方法を説明する。まず日常生活中の観測データは定常性を持つとは限らない。そこで条件付き確率分布によるモデル化を行うために変数空間 R の中で、目的変数 L_T に対する定常性を満たす分割領域 $r_i \in R, (i = 1, \dots)$ を設定し、その各領域内のそれにおいて、目的変数 L_T についての条件付き分布

$$P(L_T | Pa(L_T)) \quad (1)$$

を導入する。目的変数としては行動予測や意図推定の場合の推定対象となる変数を選ぶ。 $Pa(L_T)$ は目的変数 L_T に対する説明変数の集合であり、データ中の他の離散変数から選ばれる。この時 t に対してある幅 δt をもうけ、 $t - \delta t/2 < t' < t + \delta t/2$ であれば (t', L_i) は (t, L_T) と同時に生起した事象とみなす。こうして時間軸方向でのスパースネスを解消し、条件付き分布を実データから構成可能にする。

次に条件付き確率式(1)の情報量規準に基づく次元圧縮を行う。これは式(1)分布の説明変数である

$Pa(L_T)$ の変数集合を各領域 r_i ごとに限定することで次元圧縮を行う。変数集合の限定は複数変数の交互作用についても考慮するために以下の探索アルゴリズムを用いる。

- 全ての変数から一つずつ目的変数に対する情報量規準値を計算し、良いものから k 個選ぶ
- k 個の説明変数から最大 m 個の組み合わせに対して完全探索し、情報量規準値の最も良いものを $Ps(L_t)$ とする

これにより各領域毎に目的変数 L_T とその説明変数の集合からなる $m+1$ 次元以下の部分空間が得られる。これを元の連続的時空間データの性質を情報量の意味でできる限り保ちながら離散化と次元圧縮したということから、一般化時空間写像と呼ぶ。

4. 確率的構造モデル

一般化時空間写像の部分空間は比較的低次元で、これを構成する変数は全て離散化されているので、この部分空間上の行動観測データの頻度分布は容易に得ることができる。この頻度分布に基づき定常性を満たす各領域 r_i ごとにベイジアンネットの構造学習を行うことで確率的構造モデルを構築する。ベイジアンネットの構造学習には筆者らが開発した BayoNet¹¹⁾ を用いる。

所沢市の桑の実保育園の協力を得て、2007年9月から園庭に設置した石崖を登る遊具で遊ぶ子供の行動を一週間分観測したデータをそのまま使って構築したモデル¹²⁾を図1に、この観測データを一般化時空間写像により変換してから構築した確率的構造モデルの例を図2に示す。変数は子供の属性(Age, Body height, Body weight, Grasping power:子供の握力), 手足の間の相対距離位置(L1:右手と左手, L2:右手と右足, L3:右足と左足, L4:左手と左足, L5:左手と右足, L6:右手と左足, それぞれ現状態:nowと前の状態:oldの2種), 筋電センサの値(EMG), 環境属性(Depth:掴んでいる位置の石の深さ2値)を示す。またリンクの太さは各説明変数の目的変数に対する寄与率(部分モデルの相互情報量を各変数の個別の相互情報量に比例して配分したもの)を示している。図1の構造は身長、体重、年齢と握力の関係と、筋電センサの値がつかむ位置の石の滝みの深さと子供の握力の影響から決まる事を示している。それに対して図2では石崖の深さに加えて足の位置も関係していることと、それによりEMGへの情報量が高いことを示している。つまりEMGに対する尤度は図2のモデルの方がより高くなっている。

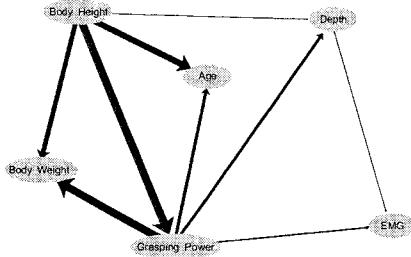


図 1 元の時空間写像から構築した確率的構造モデル

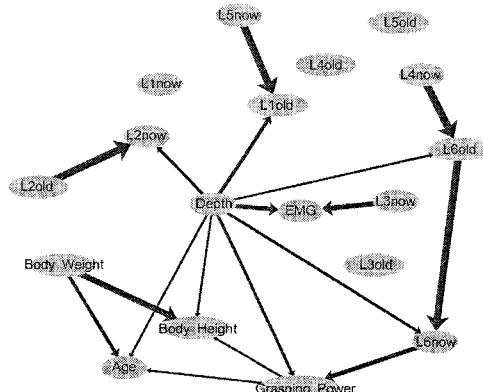


図 2 一般化時空間写像から構築した確率的構造モデル

ここで獲得された構造は、ある具体的な状況(子供、石崖遊具)の中で、どのような各事象(EMG や手足の位置)が発生したのか、という各事象間の関係を観測データから構造的にモデル化したものである。

5. おわりに

実生活空間内の環境や人間の行動のモデル化は非常に幅広く有望な分野であるが、これまでの人間行動をモデル化する先行研究の多くが、対象となる観測データの定常分布にモデルをフィッティングしたものであり、観測データに強く依存し再利用性の欠如が日常生活支援技術への適用を大きく阻むものになっている。また、日常生活空間を取り扱うためには、観測データの変数空間の次元は増大し、欠損データも増えモデル構築が困難になる。

そこで本研究ではこの 2 つの問題を解消するために、再利用性のためには単なる定常分布の近似ではなく、制御可能な変数を導入した条件付き確率分布としてのモデル化を行い、次元の増大については一般化時空間写像の導入を行った。これにより日常生活行動データから適切な確率的構造モデルを構築する方法を示した。

今後、日常的な生活行動全般をさらに包括的に観測

し、そこで得られたデータやモデルを、その利用方法も含めたりソースとして集積し、研究者で共有するための研究基盤として整備する活動も進めていく¹³⁾。

参考文献

- 1) 美濃導彦, :ユビキタスホームにおける生活支援, 人工知能学会誌, vol.20, no.5, pp.579-586, (2005).
- 2) Chris L. Baker, Joshua B. Tenenbaum, Rebecca R. Saxe, Bayesian models of human action understanding, Advanced Neural Information Processing Systems, 2005.
- 3) Yang, J., Xu, Y. , Chen, C. S., Human action learning via hidden Markov model. IEEE Trans. Systems, Man, and Cybernetics, 27, 34 –44, 1997.
- 4) Alex Pentland, Andrew Liu, Modeling and Prediction of Human Behavior, Neural Computation, 11, 229-242, 1999.
- 5) 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).
- 6) D.Marr: Vision, Freeman Publishers, (1982).
- 7) Y. Nishida, H. Aizawa, T. Hori, N.H. Hoffman, T. Kanade, M. Kakikura: 3D Ultrasonic Tagging System for Observing Human Activity, in Proceedings of IEEE International Conference on Intelligent Robots and Systems (IROS2003), pp.785-791 (2003) .
- 8) 松岡克典, :生活行動の計測と理解, ヒューマンインターフェース学会誌, vol.9, no.4, pp.299-304.(2007).
- 9) Li, K.C., Sliced inverse regression for dimension reduction. J. Am. Stat. Assoc., 86, 316–327, 1991.
- 10) N.Vlassis, Y.Motomura, B.Krose, Supervised Dimension Reduction of Intrinsically Low-Dimensional Data, Neural Computation, 14, 1, 191-216, 2002.
- 11) 本村陽一, ベイジアンネットソフトウェア BayoNet, 計測と制御, vol.42, no.8, pp.693–694 , (2003).
- 12) 西田, 本村, 川上, 松本, 溝口「日常生活行動理解のための時空間意味情報」, 第 21 回人工知能学会全国大会 2C5-10, 2007.
- 13) 本村, 西田佳史: 日常生活環境における人間の行動理解の研究基盤:オープンライスマトリックス, 人工知能学会全国大会 (2006).
- 14) 白石, 保川, 西田, 本村, 溝口, 日常生活行動情報収集管理システム, 人工知能学会全国大会, 2008.