

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

本村 陽一^{†,††} 西田 佳史^{†,††}

日常生活をモニタリングすることによって得られる電子データを用いて知的な情報処理を行う工学の応用が現実的になっている。そのために確率モデルと統計的な学習手法の研究が果たす役割が大きい。とくにベイジアンネットワークや Conditional Random Field のようなグラフ構造を持つ確率モデルを応用した成功事例も数多く報告されるようになってきている。本稿では、複雑な構造を持つグラフィカルモデルを用いることで、実際の環境や対象に内在する因果的な構造や事前知識を表し、データからの学習と統合するベイズ推定の枠組みを紹介し、それを発展させることで人間の認知構造に近い画像理解を実現する応用研究、事前知識を再利用可能な計算モデルとして集積し共有するための取り組みについても紹介する。

Graphical Modeling of Prior Probability in Bayesian Estimation for Behavior Understanding in Real Life

YOICHI MOTOMURA^{†,††} and YOSHIFUMI NISHIDA^{†,††}

Probabilistic models and statistical learning methods are studied for intelligent information processing with real world data. In particular, graphical models that have complex structures can handle prior knowledge involved in target problems. Recently, application of conditional random field models and Bayesian networks are reported as efficient modeling for real world problems like pattern recognition and time series data analysis. In this paper, these graphical models are introduced. As examples to model semantic prior knowledge, human cognitive structures during driving a car and computer simulation for child injury prevention are shown.

1. はじめに

日常的な場面で生成される電子情報は爆発的に増加している。各種のセンサ技術やインターネット技術の発展によって、日常的生活行動の断片として大量の電子的データの集積も進んでいる。そしてこれらを有効に活用することが社会的にも大きな関心を呼んでいる。そこで研究上重要な課題は実生活における情報処理技術を、信号処理やデータ変換のレベルから一歩踏み込んで、意味的な情報処理のレベルに引き上げることである。

実世界の日常において生成されるデータは人間の生活行動や生活環境を背景にしているのであるから、データが発生する状態空間や頻度の偏りなどの性質は当然人間にとって解釈される意味が強く反映したも

のになっている。このようなデータが生成される空間に特有な制約や発生頻度の偏りを事前知識と呼ぶことにする。たとえば単語や文字が生成される確率は言語として我々がよく使うものほど大きくなる。システムが実生活の中で発生する信号を観測し処理する場合には、我々の日常空間にある仮定や制約を利用することが計算量の観点でも必要不可欠である。文字認識の場合であれば、認識対象の候補を日本語という言葉に限定し、手書き文字を書くときの筆順を利用するなどの工夫を行うことは自然なことである。こうした工夫は設計者である人間が事前知識をシステムに反映したものである。

こうした実世界の人間の日常生活や行動に起因する事前知識をさらに積極的に活用することで、情報処理をより効率的なものにすることができる。この事前知識を数理的に定式化し、システムが明示的に扱うためのより効率的な表現はどのようなものであろうか。状態空間は変数として明示化し、その中の制約条件は扱う変数がとりうる値の値域、離散値であれば集合として定義する。また発生頻度の偏りは確率分布として扱

† 産業技術総合研究所デジタルヒューマン研究センター
DHRC, The National Institute of Advanced Industrial
Science and Technology

†† 科学技術振興機構
CREST

うことが自然である．物理法則のようにその世界で成り立っている因果構造をすべて列挙することは記述量の点で困難であるが，その中の重要なものを条件付き確率として表現することは近似的に有効な手段である．

こうした定式化，モデル化は，ベイズ統計やグラフ構造を持つ確率分布（グラフィカルモデル）によって行うことができる．また意味のあるパターン信号をクラスに識別する問題もベイズ推定の枠組みで定式化できる．ベイズ推定の枠組みではデータへのあてはまり具合は尤度で表し，事前知識は事前確率分布によって表される．そしてこの両者の積である事後確率によって最終的な決定を行うことで，データからの学習と事前知識が自然に統合できる．

本稿では，ベイズ推定の枠組みにおいて人間の実生活，日常的な行動をできるだけ反映した事前知識をモデル化し，情報処理で活用するために，グラフ構造を持つ確率分布（ベイジアンネットワーク）を利用する方法について述べる．

2. グラフ構造モデリングによるベイズ推定

2.1 ベイズ推定

複数のクラスラベルを C_i とし，信号パターン (x) に対する尤度 ($P(x|C)$) と事前分布 $P(C)$ の両者を組み合わせた事後確率，

$$P(C_i|x) = P(x|C_i) / \sum_j P(x|C_j)P(C_j)$$

を最大化するクラスラベル C_i を決定することがパターン認識問題におけるベイズ推定である．

事前分布がクラスラベルの存在する確率分布に一致しているときに事後確率最大のクラスに分類することによって，平均的な分類誤り（期待予測誤差）は最小となる．これがベイズ最適な識別と呼ばれる²⁾．しかし，実際の事前確率分布をどのように与えるかという問題は古くからベイズ統計における大きな問題となっており，この事前分布を一義的に与えることが難しい場合には事前分布をできるだけ単純な一様分布と仮定せざるをえないことが多かった．この場合に事後確率を最大化することは尤度を最大化することと一致するので最尤推定ということになる．一様分布を用いる理由は，何の事前知識も仮定しない無情報の事前分布として最も妥当であろうという期待の上に成り立っているのであるが，実際に理論的な意味で無情報事前分布とするのであれば，本来はモデルパラメータ空間の性質を考慮して Jeffreys' prior を適用するべきものである¹⁾．Jeffreys' prior は予測の精度の外れをできるだけ小さくするという min-max 最適ではあるが，真の

事前確率とずれがあれば，当然ベイズ最適の意味で予測精度を高くすることはできない．そこで，期待予測誤差を最小にする意味で実際の問題領域での性能を上げるためには，事前分布をより積極的に利用することが必要である．つまりデータの発生源となる実世界の問題領域の事前知識を反映した事前分布をモデル化することが重要になる．

2.2 グラフ構造モデリング

先にも述べたことから明らかなように，単にデータフィッティングの精度が高い，という尤度を最大化する規準では事後確率を最大化することはできない．そこで事前確率分布をデータの発生源の問題領域の事前知識としてモデル化することが重要になる．さらに事前分布のモデル化においては，データが生成される過程における因果関係や状態空間の制約，頻度の偏りなどの良い近似になっていることが重要である．

観測データに対するデータフィッティングだけでなく，ベイズ推定における事前分布として集約される事前知識の近似精度が重要であるということは，統計的学習理論において経験誤差最小ではなく，未学習データに対する期待誤差の最小性，すなわち汎化性能の高さが重要である，ということとも関係がある．統計的学習理論においては数学的取扱いを容易にするために，データにフィッティングするモデルの構造がデータの発生源自体のモデル（真のモデル）と同種であることを仮定することが多い．そのうえで真のモデルを含むことを仮定したパラメトリックモデルを問題領域の具体的な対象とは無関係に取り上げることになる．そうした背景のため，VC 次元や情報量規準などの研究ではパラメータ推定の不確実性に対する定量的な議論とその原因となるモデルの自由度の評価が主体になり，実問題に適したモデル自体の構造を学習するという問題にはあまり目が向けられていない．つまり統計的学習理論における汎化問題において対象となるモデルは数学的に取扱いの容易なパラメトリックモデルが選ばれることが多く，そのうえでパラメータの推定値の不確かさに対する議論が主流になっている．

しかし，数学的な議論は困難であっても計算可能なモデルとして，隠れマルコフモデル (HMM)，ベイジアンネットワーク (BN)³⁾，Conditional Random Field (CRF)⁵⁾ など複雑な構造を反映できるグラフィカルモデルを適用することが，最近の計算機能力の向上から工学としては十分現実的になり，実生活空間に内在する構造や事前知識をうまく扱える可能性が生まれている．とくにベイジアンネットワークは他のグラフィカルモデルと比べてモデルに因果構造を持ち込

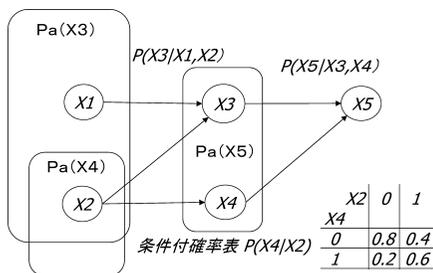


図 1 ベイジアンネットワーク

Fig. 1 Bayesian network.

めること、意味的な解釈が容易であることなどから人間が問題領域固有の事前知識を導入しやすいというメリットがある。最近では、ベイジアンネットワークを用いた応用例も多数具体的に示されてきている³⁾。

2.3 ベイジアンネットワーク

ベイジアンネットワークは、各事象をノードで表し、その間の因果関係を矢印で結び、ある領域についての関連知識を非循環性の有向グラフ (Directed Acyclic Graph: DAG) として表すものである。 $X \rightarrow Y$ において、 X を親ノード、 Y を子ノードと呼ぶ。確率分布は各子ノードとそれに結合する親ノードにより決まる条件付き確率表により定義される (図 1)。

ここで領域内のすべての組合せ的な関係を記述するのではなく、明示的な因果関係のない事象間は独立であると仮定し、主要な因果関係だけを抽出したグラフ構造を与えることにより計算量・記述量の爆発が避けられることが計算効率の面で大きなメリットになる。たとえば A, \dots, Z の全状態の中で因果関係が X, Y の間にだけ存在する場合にはすべての事象についての同時確率分布が次式右辺のように簡単化されるので、右辺各項は独立に計算でき、かつその計算量の総和は左辺を直接計算するよりもはるかに小さい。

$$P(A, \dots, X, Y, Z) \\ = P(A) \cdots P(X|Y)P(Y)P(Z)$$

このベイジアンネットワークにより、対象とする世界の状態空間は変数の確率空間として、制約条件や因果構造はグラフ構造の中に、データ発生頻度の偏りは条件付き確率表の中で規定できることから、これを事前知識のモデル化に利用することができる。以下ではこのベイジアンネットワークのモデル構築の概要について述べる。

2.4 ベイジアンネットワークの学習

ベイジアンネットワークモデルを構築するためには

- グラフ構造
- 各確率変数についての条件付き確率

の 2 つを決定する必要がある。グラフ構造が分かっている場合は、条件付き確率の学習だけでよい。条件付き確率の学習は例からの確率分布の推定として考えることができる。とくに確率変数が離散の場合では条件付き確率は一般的には表で与えられるので、その最尤推定値は、ある子ノードとその親ノードとなる変数のクロス集計表を求め、正規化することで簡単に求まる。グラフ構造をデータから学習する問題は統計学におけるモデル選択の問題でもあり、AIC や MDL などの情報量規準によりグラフを探索する方法がある。

2.5 ベイジアンネットワークによる事前分布のモデル化

先に述べたように、パターン認識において、ベイズ事後確率に基づくベイズ識別は理論上最適解を与えるが、事前確率分布を適切に与えることができない場合には、データの発生源における真の事前分布との差異がある分、たとえデータフィッティングが最適であっても、推定精度は理論上の上限から劣化する。たとえば事前分布が、本来特定の状況 (S) において条件付けられ、 $P(C|S)$ のようなものなのであれば、状況をパラメータとして持たない、状況を前提とする条件付き確率で表現しない確率分布 $P(C)$ を用いたベイズ推定は、確率的な近似精度は低下してしまう。条件付き確率 $P(C_i|S)$ を表すためには適切な説明変数 S を見つけ、状況による依存関係をモデル化する必要がある。グラフ構造により変数間の依存関係を表すベイジアンネットワークを用いると、複数の変数の交互作用も含めて多様な依存性を持つ条件付き確率を適切にモデル化することが可能である。

そこで、状況依存性のある事前確率として、重要な説明変数を関係の強さに応じてグラフ状に結合したベイジアンネットワークにより表すという解決方法が自然に考えられる。事前確率をベイジアンネットワークの確率推論から計算し、それと最尤推定に基づく識別器の出力と統合したベイズ解を求めれば、固定した事前分布を用いることと等価な最尤法に比べて性能が向上すると期待できる。さらに、ベイジアンネットワークにより表す識別対象の事前分布が、実際にシステムを適用する問題領域の真の事前分布の良い近似となることがベイズ最適に近づくための条件である。そのためには、実際の問題領域でデータが発生する因果的な構造を反映して事前分布をモデル化する、つまりベイジアンネットワークのグラフ構造を因果的な構造に忠実なモデルとして決定することが重要になる。

こうした複雑なグラフ構造を導入したモデルを用いる例としてはタスクの文脈依存性を利用してアク

ティビジョンの制御を行った例⁸⁾，シーン分割への適用⁹⁾，Conditional Random Field (CRF) を用いて文脈依存の物体認識を行う例などがある⁶⁾．以下では文脈に依存する文字認識においてベイジアンネットワークをラベル空間における事前分布として利用し，識別器としてニューラルネットと組み合わせてベイズ推定を行う例⁷⁾を取り上げ，これまでの議論を具体的な事例で示す．

2.6 英単語中の手書き英字認識の例

クラスラベル C を持つパターン x サンプルセットを学習して識別（分類）器を構成する．理想的な学習後の識別器は近似的に式 (1) の事後確率を最大にするベイズ識別を行うものと見なせる（各クラスのパターン数を同一にするなどして事前分布を一様分布とした場合は最尤推定と等価となる）．

$$P(C_i|x) = \frac{P(x|C_i)P(C_i)}{\sum_j P(x|C_j)P(C_i)} \quad (1)$$

実際に識別を行う場合のパターンの発生頻度が事前分布 $P(C_i)$ と合致している場合にはこのベイズ識別は理論上最適であるが，先にも述べたように実際にはこれが何か別の変数に依存して決まるような自由度の高い分布である場合に，これをどのようにモデル化するが重要になる．たとえばあるパターン x をクラス C_i のどれかに分類するとき，実際にはクラス間の発生頻度が観測時間や観測場所に依存しているような場合，事前分布 ($P(C_i)$) は状況 (S) に依存したものになっている．そこでこれを条件付き確率 $P(C_i|S)$ として考え，別の確率モデルを用いて学習する．これと通常最尤解を学習した識別器から得られる尤度 $P(x|C_i)$ とを統合した式 (2) を最大とするクラスを識別結果とすることが考えられる．

$$P(C_i|x, S) = \frac{P(x|C_i)P(C_i|S)}{\sum_j P(x|C_j)P(C_j|S)} \quad (2)$$

つまり，このように事前分布を，変数 S により条件付けられた条件付き確率 $P(C_i|S)$ として考えることで識別性能を向上させることができる．

2.7 ベイジアンネットワークを事前分布とするベイズ推定

ここでは，‘A’ の上部が開いているあいまいな英字では ‘CAT’ と ‘THE’ とどちらも読めるという文脈依存性についての有名な Selfridge の問題⁴⁾ を例にして，事前知識をモデル化したベイジアンネットワークを事前分布としたベイズ推定の事例を示す．

まず識別器として 20×20 のドットマトリクス上の手書き英字 10 文字（大文字）{A, B, C, D, E, H, I, J, K, T} を 2×2 の受容野を持つ入力素子 100 個，中間素子

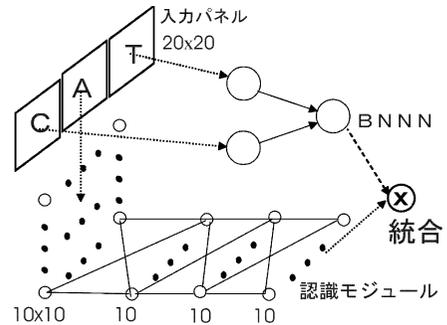


図2 英字認識のための事前分布を表した構造モデル（図中の BNN）

Fig. 2 Bayesian network for character recognition.

10 個の隠れ層 2 層，出力素子 10 個の 4 層の神経回路網， $g(x)$ を用いて平均二乗誤差が 0.01 以下になるまで学習した．この出力を英字パターン x を与えたときの文字 i に対応する出力ラベルの尤もらしさ（近似的な尤度）として $f_i(x)$ と書く．

一方，状況に依存する事前確率として，隣接する英字 C^{-1}, C^{+1} が与えられたときに挟まれた英字 C^0 に関する条件付き確率（26 次元確率ベクトル） $P(C^0|C^{-1}, C^{+1})$ を考える．この文字認識の例では英字ラベル間の隣接関係を辞書などから数え上げることができ，条件付き確率表を英字パターンとは独立に求めることができる．4 万 3 千語からなる英単語辞書のデータを教師信号としてニューラルネットにより条件付き確率を表したベイジアンネットワークを学習した． $S = (C^{-1}, C^{+1})$ を与えたときの C_0 の 26 次元確率ベクトルのうち英字 i に対応するものを $g_i(S)$ と書き，この確率値を出力するようにモデルを学習する（図 2）．

モデルを学習後に判読の困難な認識対象（図 3 の最下段 2 文字目の ‘A’）を与え，次の I.（最尤推定），II.（式 (2) に基づくベイズ推定）の二者の比較を行った．

$$\text{I. } P(x|C_i) = f_i(x) / \sum_i f_i(x)$$

$$\text{II. } P(C_i|x, S) = P(x|C_i) \cdot g_i(S) / \sum_j (P(x|C_j) \cdot g_j(S))$$

$C^{-1} = 'C'$ ， $C^{+1} = 'T'$ と認識したときの 2 文字目に関する I.，II. の推定結果とその事後確率値は表 1 のようになる（事後確率の高いほうから推定クラスと事後確率を I.，II. のそれぞれ 3 位まで示す）．

ここで取り上げた問題は，A の上部が欠けているために H と認識されてしまうパターンはいかに詳細に個別パターンを単独で分析しても，A とは認識できない問題であるという有名な例であるが，前後の文脈を事前知識として学習したベイジアンネットワークを導

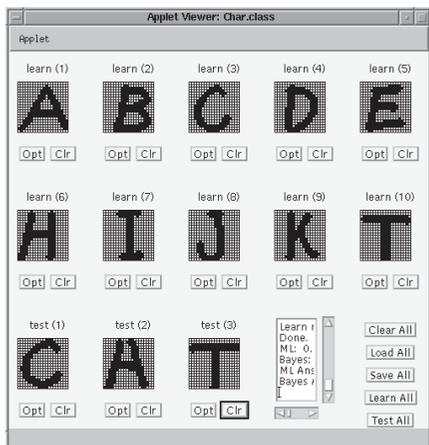


図 3 上 2 段：学習パターン，下 1 段：テストパターン
Fig. 3 Learning pattern and test pattern.

表 1 認識結果（事後確率：％）

Table 1 Recognition result (posterior probability: %).

1st: I		2nd: I		3rd: I	
II	II	II	II	II	II
'H'	'A'	'C'	'T'	'A'	'H'
22.1	75.2	17.9	12.7	15.6	4.7

入したベイズ推定により，事前分布を導入した II. では信号空間では判読困難な 2 文字目の文字であっても正しく 'A' と推定されている．一方，事前分布を用いない I. では 'H' と誤認識されていることが分かる．

この例では英単語文字列の隣接関係を英和辞書中の単語セットから学習し，事前分布として利用した．一方，実生活空間で物体認識を行う場合には，家屋の中でその物体がよく使われる位置座標や存在確率により事前分布を学習するようなことが考えられる．家屋中の物体のデータについては我々が実際に収集している例を 6 章で述べる．

実生活における支援システムの実現のためには，より複雑な意味を持つ事前確率分布をモデル化することが必要であり，そのために，事前分布を構造的に規定するための説明変数 (S) を抽出し，それによる依存関係を構築するという手順が必要になる．先の例ではある空間の中で物体を観測し続け，その際，クラスラベルを位置座標と合わせて記録しておき，このデータの中から構造を抽出したものを事前知識として，事前分布のモデル化を行う．この事前確率分布の構造はベイズネットワークの構造を探索する問題に帰着されるが，これは NP 困難であることから，この構造の獲得をデータだけからの統計的学習だけで実行することはかなり難しい．そこで，人間が持つ事前知識を積極的に持ち込んで説明変数とベイズネットワークの構造を求めることが実的な解決になる．

そこで，以降では，実生活空間において，人が暗黙的に持っている事前知識をベイズネットワークの構造として反映したモデル構築の方法と，これを用いた実生活情報処理の事例について述べる．

3. ベイズネットワークによる認知構造のモデリング

ある問題領域において発生するパターンをシステムが理解するためにベイズ推定の枠組みを考えた場合に，その問題領域における事前知識を事前分布として導入することを先に述べた．この事前分布をモデル化するうえでも単に表層のデータフィッティングの意味で近似するだけでは不十分である．有限個のデータしかない場合に未学習のデータを含む期待誤差を最小化する汎化のためにはモデルの構造を適切に決定することが重要であるから，実際の問題領域の対象の背景にある因果的な構造を反映して事前分布をモデル化することが必要である．

したがって実生活空間で人間の認知的な判断の代用としてシステムを考えるのであれば，システムが利用する事前分布の構造も人間の認知的な構造に近いものにしていくことが重要となる．そこで，我々はユーザ固有の認知構造を抽出することを目的として，個人の認知構造を反映した行動モデルを構築するために Personal construct theory (PCT)¹⁰⁾ に基づいて認知・心理機能を定量的にモデル化する方法を提案した¹¹⁾．

3.1 PCT に基づく認知構造の定量的モデリング

Personal construct theory (PCT) では，人間の行動を理解するうえで，「個人が固有の認知構造 (Construct system) によって，外部の情報を認知し，理解し，その結果を最適化するような選択や行動をとっている」として考える．さらに認知構造とは「部屋の中が静か」などのヒトが感覚器を通じて得た情報を意味のある事象として理解する認知項目と，『「部屋の中が静か」であると「その空間では他人と話しやすい」』などのように関連する認知項目間の間に存在する因果関係が構成する階層的な構造であるとしている．

個人の認知構造を抽出するために評価グリッド法¹⁶⁾ に基づく調査を行う．従来の評価グリッド法では，結果として得られる認知構造モデルはある特定の個人の定性的なモデルとなり，調査結果は複数の認知項目を相互に接続した階層的なネットワーク図として得られる．この階層図は主に人間が見て解釈するためのものであり，モデルを計算機上で利用することはあまり考えられていない．

これに対して我々は個人性を反映しながらもより一

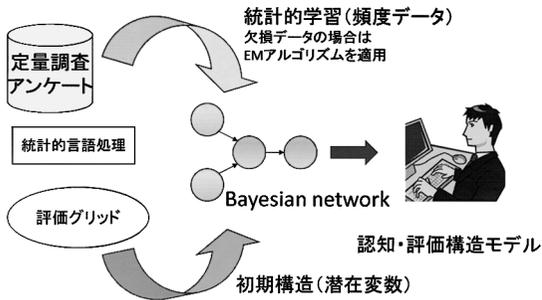


図 4 認知・評価構造の定量化モデリング

Fig. 4 Quantitative modeling of cognitive-evaluation structure.

一般的に適用できる定量的な認知構造モデルを構築することを目的としている。以下では、定性モデルとして得られた結果を基に項目を設計したアンケートを大量の被験者に対して実施し、その回答である統計データからベイジアンネットワークを定量的なモデルとして構築する提案手法について述べる(図4)。基本的なアイデアは評価グリッド法により認知構造モデルのスケルトンとなる変数群と主要なグラフ構造を求め、それを使って構築したベイジアンネットワークを用いて定量的なモデルの統計的学習、確率推論などを実行するものである。

対象の選択

まず評価対象となるモノや情報を選択する。たとえば運転中の走行シーンの画像を複数用意しておき、選択する候補とする。このとき、被験者認知し、区別するために重要な属性を網羅的に含むような候補集合を用意しておくことが重要である。

認知項目の抽出

先の候補集合から対象を選び、各認知項目を抽出するために評価グリッド法を適用する。このとき、個別の被験者から異なる表現で表されるが意味的に同一と思われる認知項目を適切に判断する必要がある。そのために意味解析を行いやすい文型に統一して表記する。我々は認知項目についてそれぞれ主語と述語を明示した $[S, V, O/C]$ 型の表現を採用する。これはヒトがある対象を観測したとき、対象が S に関係があり、かつその S が $[V, O/C]$ となっているという事象 (event) である。またその事象をどの程度の確信度を持って支持しているかを主観確率 $P([S, V, O/C])$ によって表す。またこの確率は多数の被験者からのアンケート結果などにより頻度から求める場合には頻度確率である。各認知項目の確率を定義したが、これをさらに別の認知項目による影響を受ける条件付き確率として考える。ある認知項目を X_i と書くと、認知項目間の定量的な

影響は条件付き確率 $P(X_i|X_j)$ により表せる。認知主体であるヒトの個人属性によっても認知・評価構造が強く影響を受ける場合がある。たとえば女性と男性で評価構造が大きく違う場合などである。こうした個人属性となる重要な変数も認知項目として書く。したがって、これらの属性が与える各認知項目への影響の強さも先の条件付き確率により自然にモデル化することができる。また各認知項目が暗黙的に条件付けられている場合がある。こうした状況依存性は重要であるため、モデルの中に状況が成立している事象をやはり1つの認知項目として導入する。

スケルトンモデルの作成

複数人の被験者(必要な人数は対象によって異なる)による評価グリッド法を実行した後に、主要な認知項目とそれに隣接する上位、または下位の認知項目の候補を整理する。上位または下位の項目は大まかに属性と機能的ベネフィット、情緒的ベネフィット、総合評価の各クラスに分類しておく。こうして列挙された主要な認知項目をすべて事前に列挙し、以後の定量調査の回答により頻度を数えられるようにしておく。

定量調査

各対象ごとに主要な認知項目についての質問表を作成し、幅広い被験者層に対して定量調査(アンケート)を実施する。回答は先にあげた各認知項目の頻度、および隣接認知項目の共起頻度として集計する。評価グリッドの被験者数が十分であり、各認知項目の頻度と認知項目間の共起頻度が十分な数であれば、この結果から頻度確率として利用してもよい。

ベイジアンネットワークの統計的学習

先に作成したスケルトンモデルから各認知項目の接続順序や、隣接可能性を考慮して変数の順序化と子ノードごとの親ノード候補の絞り込みを行う。一般にグラフ構造の探索空間は指数的爆発を引き起こすが、スケルトンモデルから探索範囲を限定することで探索空間と計算時間を大幅に低減させることができる。これを制約条件としてベイジアンネットワークのモデル構築を行う。制約条件と定量調査により集計した各認知項目ごとの頻度、および共起頻度データからモデル構造の学習と、条件付き確率パラメータの統計的学習を実行する。こうして構築したモデルが Personal construct theory に基づく認知・評価構造の確率的定量化モデルである。

認知・評価構造の確率的定量化モデルはベイジアンネットワークとして構築されるので、ある状況や対象を証拠 (Evidence) として与え、確率推論を実行することで、個人の意図や評価の推定値を得ることができ

る．これをユーザのモデルとして様々な用途ごとに用意しておき，各種の情報システムで，ユーザの意図推定などを高速に行うことが可能になる．

提案手法¹¹⁾では評価グリッドインタビューから抽出したスケルトン構造を基に説明変数を設計し，それをノードとして含むベイジアンネットワークを認知・評価構造の定量化モデルとして構築した．これにより認知・評価において重要な要因を説明変数として適切な構造として組み込むことが可能である．以降ではこのグラフ構造を用いた事前知識のモデルを実生活における行動理解に適用する枠組みを事例に基づき説明していく．

3.2 運転シーンの認知構造とモデリング

1つの例として，以下では人間が自動車を運転中に見る走行シーンについて危険性を判断する場合を考える¹⁷⁾．ドライバと協調した運転支援システムを考えるためには運転中の状況や運転者の認知過程や意図を理解することが必要である．従来の運転システムの多くはドライバの認知構造とは無関係に，システムに知的な判断をさせるものが多い．しかし，一般的に熟練ドライバと初心者ドライバでは運転中の目の前の走行シーンに対して，危険性をどのように判断しているか，という認知構造が大きく異なっていることが知られている．熟練ドライバは効率的に最も重要なポイントを認知しているのに対して初心者ドライバは非常に高い緊張状態で，注意をしている．しかし，重要なポイント以外における認知負荷が高く，これが運転中の疲労や緊張による他のポイントへの注意不足や操作ミスの原因ともなっていると思われる．そこで，初心者ドライバの運転行動支援の可能性の1つとして，走行シーンの危険性を自動的に判断する，という問題設定が考えられる．

初心者ドライバを支援するための，認識システムは熟練ドライバの認知構造を模範とすべきであろう．そこで，初心者ドライバと熟練ドライバの走行シーンにおける認知構造の違いを検証し，熟練ドライバの認知構造をシステム上でモデル化し，走行シーンの安全性，危険性を定量的に評価できるようにしたい．そこで人の認知構造のモデル化と確率推論について考える．

図5，図6のような走行シーンの画像20枚を被験者（運転歴15年の熟練ドライバや運転歴3年程度の初心者ドライバら）に提示し，評価グリッドインタビュー¹⁶⁾を実施し，結果を主語，述語ごとに分類し，その解釈が同一である認知項目を変数として人手でまとめ，因果関係をリンクとして結合してネットワークの構築を行った．評価対象は走行シーンの画像，評価



図5 走行シーン 1
Fig. 5 Driving scene 1.



図6 走行シーン 2
Fig. 6 Driving scene 2.

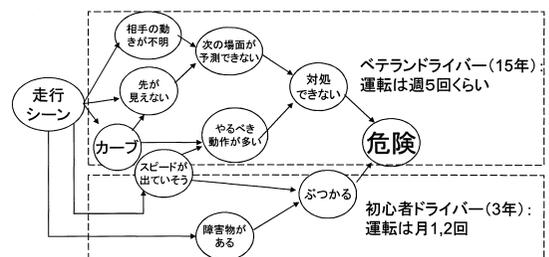


図7 運転手の認知構造モデル
Fig. 7 Driver's cognitive structure.

項目は「危険」と「安全」である．結果として作成した熟練ドライバと初心者ドライバの認知構造を重ねて表示したものを図7に示す．

この結果から，初心者ドライバは走行シーン画像の中から，進行中の自転車にとって障害物となるオブジェクトについての認知負荷が非常に高いことが分かった．また目立った障害物が複数存在する画像についてはとくに高い危険性を認知する傾向も見られる．またスピードが出ていそうな走行シーンについても熟練ドライバよりも危険性を高く評価する傾向があり，その理由は熟練ドライバと異なり「ぶつかりそうだから」というものであった．一方，熟練ドライバの場合には，

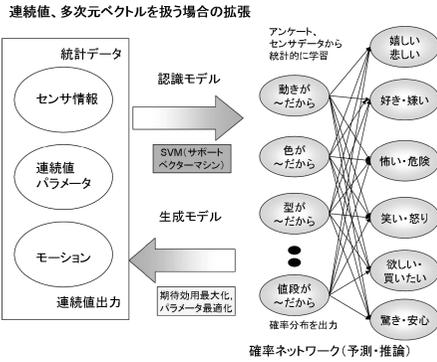


図 8 特徴抽出・SVM 識別器と接続したベイジアンネットワーク

Fig. 8 Bayesian network connected with feature extraction and SVM.

ブラインドカーブなどの走行シーンを「先が見えない」ので、「次の場面が予測できない」から「自分で対処できない」ので危険、と判断している。また、同様に自転車やバイクなどが目視で自車を確認していないときに強く「相手の動きが不明」であるとし、「次の場面が予測できない」ので同様に危険であると評価した。このような判定、およびこれに該当する走行シーンの危険度の評価は初心者ドライバーには見られないものであり、通常よく言われる初心者の過度の認知負荷による本質的に危険な場面での注意不足を示す結果とも見なせる。また、熟練ドライバーは自らの運転スキルを自覚し、これを越えた操作を要求される状況での危険性の認知に優れ、同じような対向車であった場合でも、カーブや上り坂のように自車の運転でやるべき操作が多く、自分の負荷が高くなりそうな状況では、そうでない場合よりも危険性を高いと評価した。

さらに多数の被験者から認知項目と認知構造の抽出を行うことで、得られた統計データから確率モデルが構築できる。多数の被験者により網羅的に認知項目を洗い出した後で、アンケート結果を整理することでベイジアンネットワークの統計的学習として認知構造をモデリングする。各認知項目のクロス集計から条件付き確率表が求まるので、アンケート結果からベイジアンネットワークの条件付き確率を学習できる。構築したベイジアンネットワークは様々な条件を入力した場合に、その状況下での危険性をベイズ的に推定するものになっている。このベイジアンネットワークの入力は『「相手の動きが不明」な対象がある』というような事象を表す離散変数であるため、走行中の画像からこれを判断する場合には、特徴抽出器と識別器を通して画像パターン (x) をクラスラベルへ離散化する必要がある。そこで識別器を用いて教師ラベルを付けたパターン群により学習する。この特徴抽出器と識別器

を経由することで、パターン x はクラスラベル C_i へと変換され、この離散変数群の間の関係を表すベイジアンネットワークに入力することで、走行シーンの危険性(危険というクラスラベルの事後確率)の判定は、ベイジアンネットワーク上の確率推論によって実行できるようになる。

この枠組みを実現するために我々は OpenCV¹²⁾ による特徴抽出, SVMlight¹³⁾ による識別器, 確率伝搬法による確率推論¹⁴⁾ と統合的に扱えるソフトウェア環境を整備し、画像からの行動認識に適用している¹⁵⁾ (図 8)。

4. 実生活情報処理における事前知識の応用

実生活における事前知識は多様な依存性を持ちうるため、ベイジアンネットワークの条件付き確率分布として構造的にモデル化し、ベイズ推定を行う例を見てきた。しかし、こうした事前知識の利用はパターン識別への応用だけにとどまるものではない。ここでモデル化された実生活に関する事前知識は、実生活空間の中の様々な依存関係や対象についての性質を反映したのものになっている。たとえば、物体認識の場合の事前知識として、物体が生活空間の中のどの位置に分布しているか、という事前分布と、物体の持つ「事故の危険性」を合わせて利用することで、室内で子供がある行動をとる場合の危険性などが評価できる。つまり、これまで述べたような事前分布のグラフ構造モデリングは画像の識別などのベイズ推定問題以外にも再利用することができる。画像の識別で用いられるモデルは認識モデル (cognitive model) と呼ばれるものであるが、一方、逆に確率的にパターンを生成するようなモデル (generative model) もある。人間の行動を近似した生成モデルによって、発生する可能性の高い行動パターンや、事象などの確率を評価し順位づけることなどができる。以降では、日常生活空間の事前知識をグラフ構造を持つ確率分布を再利用可能なモデルとして利用することで、日常生活空間中での人間行動の理解研究を進め、子供の事故予防などへも応用できることを我々の研究事例を通じて概観する。

4.1 日常生活における行動理解

情報システムが人間の日常生活を支援するものとなるためには実生活の日常環境の中で人がとる行動の深い意味の理解が重要になる。システムにより人の日常生活を支援しようとする、人間が何を意図してどのように行動しようとしているかをシステムが理解できなければ、適切な動作を行うことはできない。人間がどのような行動をとるのかを理解し、そのうえでその

行動がよりよくできるような支援方法を工学的に実現することが必要なのである。しかし、実際に動いている多くの情報システムでは、こうした人間の行動や意図を理解する問題を巧妙に回避することで工学的実現を容易にしている。

たとえば自動ドアは目の前のドアを開けたいという意図や建物に入ろうとしている行動を理解する代わりに、赤外線や重力を検知することで実現している。ところが、重力センサは『近くにあった傘立てが倒れたところ、ドアが開けっ放しになる』ことや『小さな子供は体重が軽すぎて開かない』ことを防げない。センサを赤外線に変えても『センサの角度と人の入る方向によっては思ったとおりに開かない』こともあり、人間の意図や行動と、コンピュータ側での解釈の間のずれが埋まることはない。

この問題を解決するためには、日常生活における人間の行動や意図を適切にモデル化し、システムが解釈できるようにする必要がある。そのためには人間の行動を単なる表層的なセンサデータとして扱うだけではなく、日常生活の中で人が行動をとった理由や環境、状況の中での必然性などと結び付け、これにより人間が行動するメカニズムの計算論的なモデルを構築することが重要である。

モデル化する際にまったく何の制約もないと、論理的にありうるすべての状態を考えなければならず、自由度が極端に増大しモデル化と計算が困難になる。これは決定的なアプローチによる人工知能が直面してきた根源的な問題（フレーム問題）である。また先に述べた事前分布を導入しない場合に識別が困難になる、信号のみによる最尤法の問題とも共通している。

そこで、ここでもやはり問題対象となる事前知識のモデル化によって、状態空間の制約や確率的な重み付けが重要な役割を果たす。実際のところ日常的な環境での人間の行動を考えると、それが何らかの目的を有する限り、無限のバリエーションを持つものとは思えない。挙動としての「行動」は無限の状態があっても、その行動の意図が明確なものがあっても、またその意図が状況に強く依存していれば対応する目的の種類もたかだか数えられる範囲だろう。そこで、システムが支援する場面と、そこにおける人間の行動の目的の間の関係性を限られた状態空間における事前知識としてモデル化して工学的に利用できるようにすることが1つの解決方法になりうる。

まずシステムが考慮すべき実生活内における人間の行動の「目的」が何であり、それはどのような状況や文脈に影響されるかを明らかにすることが必要であ

る。そのためには、観測された行動の計測データに含まれる複数の属性の間の依存関係を交互作用を含めて抽出することが重要で、ここにベイジアンネットワークの構造学習のアルゴリズムが適用できる。

また、データが観測された状況でのみ意味を持つその場限りのものであっては適用範囲は狭いので、再利用できる形にモデル化することが有効であるから、できる限り共通に使える変数を用いたベイジアンネットワークを構築することも重要である。異なる状況においても同じ意味や機能を持つように人間の行動をモデル化し、様々な応用のために再利用するためには、状況依存性も合わせて、利用される場面に応じて計算可能なモデルとすることを考慮すべきである。たとえばモーションキャプチャで人間の行動をデータとして記録しても、まったく同じシーンを再生することはできるが、それ以上の応用は難しいのが現実である。人間の行動を認識・生成するモデルを考える場合には、再利用性を考慮した技術を確立することが必要とされている。

そのために「どの変数についての計算を行うべきか」という変数選択が行動理解研究におけるモデル化の大きな問題である。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影響する条件の間の因果構造に注目し、主要な因果構造に関連する主要な確率変数をモデルの構成要素として抽出することを考える。たとえば、事故予防のための応用であれば、危険な事故と評価される事象を「結果」とすると、それが起きたのはなぜか、という因果的な構造をたどって、トップダウンに結果に影響を与える変数のみを抜き出す。以降では、こうした行動モデリングを行った事例に基づいて説明する。

5. 子供の行動モデリングと事故予防

実生活の場で実際に新しい技術による解決が望まれている問題として子供の事故予防がある。現在わが国では0歳以外の子供（1～19歳）の死亡原因の1位が依然として不慮の事故である²⁰⁾。たとえば日本中毒情報センターで子供の誤飲事故の件数などが報告されているが相談の75%から80%は5歳以下の子供の誤飲であり、ここ数年まったく改善される傾向が見られない。さらに過去に事故歴のある報告例も多く見られ、同様の事故が繰り返されているという現実がある²¹⁾。死亡率で比較するとわが国では欧米と比較して高い率となっているため、子供の事故を予防するための何らかの手段を講じることは現在の日本において国家的、社会的にも急務である。日常的に発生している事故事

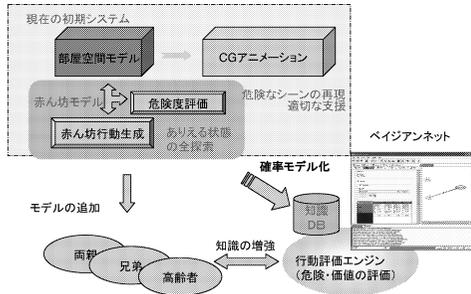


図 9 事故予防のための応用

Fig. 9 Application for childhood injury prevention.

例データを収集し、その結果得られた統計データから予防のために活用できる有用な事前知識を抽出し、子供の行動や事故の関係性を表す確率モデルとして表すことで、事故の発生状況の再現や定量的な評価、コンピュータグラフィックでのシミュレーションによる知識の伝達といった波及効果の高い応用を可能する。

子供の発達と環境との相互作用の結果、様々な現象が重なりあい、ある確率で不幸にして事故が発生する。この確率的に発生するリスクをコントロールするために、事故の発生の原因とメカニズムや条件などを重要な説明変数としてモデル化することが必要であり、さらに事故を予測しやすい説明変数を選択し明示的に表すことも重要な課題になる。それにより事故の確率やダメージの期待値を最小限に抑えられるような条件の判定や、実際の予防策の選択などが可能になる。

事故状況における時間や場所、子供の行動と事故の種類などの事例を収集する事故サーベイランスシステム、事例データに基づいて構築したベイジアンネットワークによる確率推論。また事前知識や子供の実験から構築した確率的な行動モデル、これらによる事故を再現する計算モデルとシミュレーションを実現する技術を開発した¹⁸⁾(図9)。さらに実際の事故シーンを動画として再生し、予防対策を適切に提示するサービスの運用も行っている。この情報提供サービスを通じてさらに大量の統計調査を実施することが可能になり、この統計データを再利用可能なモデルとして子供に関する実生活における事前知識として活用することができる。

ここでは、大量の事故事例データから得られた知識を活用して事故を再現できるコンピュータグラフィックシミュレーションを作成する方法について紹介する。まず、事故事例データを収集し、ある状況での事故の種類や危険性を評価できるベイジアンネットワークを構築した(図10)。次に確率推論結果から危険性と日常性などの観点から、注目すべき重要な事故シーンを

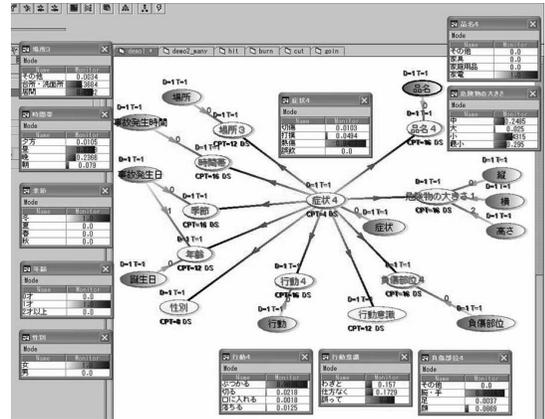


図 10 事故事例から構築したベイジアンネットワーク

Fig. 10 Bayesian network constructed from childhood injury data.

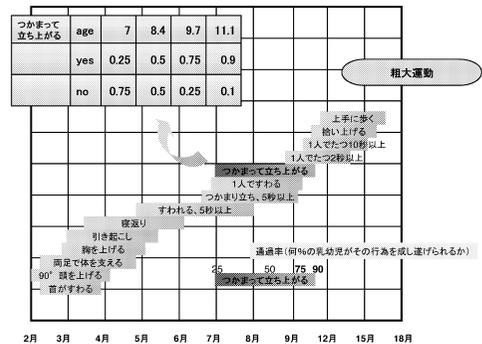


図 11 子供の発達行動に関する事前分布

Fig. 11 Prior probability about childhood developing behavior.

再現するシナリオを再構築する。

事故再現シナリオを再現する場合、これまでに収集されている事故事例の記録は事故が起こった後に静的に記述された情報が中心となっており、事故の起こった環境や環境の変化、きっかけとなった子供の行動など、事故時の状況を完全に再現するのに十分な情報は含まれていないことが多い。子供の月齢ごとにとりうる行動は Denver-II²²⁾ からベイジアンネットワークとして知識化することができ(図11)、月齢ごとの事故の内容、関連するモノや原因となった環境については病院における事故事例収集データにあるものや、同様の事例を再調査することで獲得した。

しかし、事故時の環境や事故を起こした行動のきっかけについては、病院で聞き取る事故事例には含まれていないため、考えられる典型的な例について医療・保育関係の専門家のアドバイスに従い妥当と思われるものを採用することとした。現在人手に依存している部分をできるだけ自動的に実行可能にすることが今

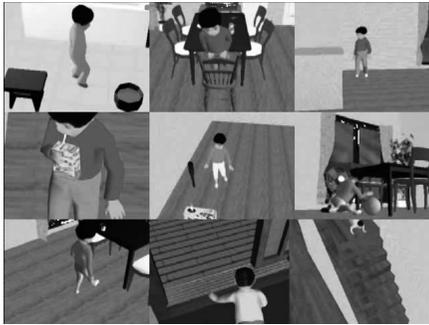


図 12 事故予防のための動画コンテンツ

Fig. 12 CG animations for safety promotion.

後の重要な技術的課題であり、そこで事故を再現するために必要な事前知識（たとえば原因となるモノの存在確率や子供のとる行動の確率）もまた、ベイジアンネットワークとして構築・推論することができれば、先の事故事例情報から構築できたベイジアンネットワークモデルの推論結果と自然に統合することで、モデルを精緻化することが可能になる。

事故時のシーンを再現するためには、事故の原因となるモノ（たとえば「炊飯器の蒸気によるヤケド」などにおける「炊飯器」）の位置や子供がそれにどのように接近し、接触に至る過程をコンピュータグラフィックとして再現するために、オブジェクト指向、イベント駆動で3次元動画を作成するソフトウェア Virtools を用いて、事故シーンの生成を行っている（図 12）。これにより我々は様々な月齢の子供、様々な環境、様々な事故に関する事故を再現するシミュレーションを100種類以上作成した²³⁾。またシミュレーションを構成するモノや、行動、環境変化などをさらに体系的に分類して、さらに多くの事故シーンを構成要素の組合せによって再現するライブラリの開発を進めている。現在わが国では事故事例自体の収集が組織的には行われていないため、事故シミュレーションがどれだけの範囲をカバーしているかについての評価を行うことは不可能である。我々はこの点についても、国立成育医療センターとの共同研究や経済産業省や自治体からの要請にこたえて実際の事故事例を大規模に収集する活動もあわせて行っている。

また作成した100種以上の動画コンテンツを多数の会員を保有する企業のWebによって子供の保育者に提示するサービスを実現した。これまでの冊子による事故予防アドバイスを配布するのと違い、アクセスしてきたユーザに合わせて適切なWebコンテンツを見せることで、子供の年齢や生活環境に応じた適切なアドバイスを選択的に提示し、さらに、単にコンテンツ

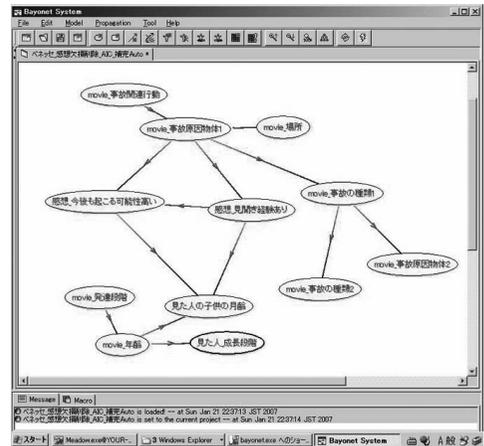


図 13 親からのアンケート結果から構築したモデル

Fig. 13 Bayesian network constructed from parents' feedback data.

を提示するだけでなく、提示した後に「この種の事故を見聞きした経験があるか」、「この種の事故が起きる可能性は高いと思うか」というアンケートを同時に実施した。このインターネットを利用したサービス提供とアンケート調査を連携させることにより、これまでは難しかった膨大な被験者数の調査結果を短期間で得ることが可能となった。4カ月の間に各事例に対して約8,590件のアンケート回答を1,900人の利用者から収集できた。このようにして得られた統計データの中から重要な説明変数や依存関係を抽出することで、さらに新しい実生活における事前知識をモデル化することができる。利用者の回答から得られた統計データによりベイジアンネットワークを構築して依存関係を分析した結果、「見た人の子供の月齢」、「事故の原因物体」、「見聞き経験あり」、「今後も起こる可能性高い」の間に存在する確率構造が得られた（図 13）。

これは現時点の実際の社会における、事故に対する認知と保育者の予測能力に関する事前知識を表したものと見える。このベイジアンネットワークに対する確率推論によって、どのような事故を優先的に保育者に教育すべきかが確率的に評価できるので、これに基づく安全教育（Safety promotion）が可能になる。こうした安全教育への応用についてはチャイルドシートの着用意識の向上のためのアンケート分析も行っている²⁵⁾。

6. 実生活情報処理のための研究基盤

人の生活空間において知的システムが様々な役割を果たすことが強く要請されてきているが、実用レベルのシステムが人間の行動を理解することは現在もなお



図 14 モノデータベース
Fig. 14 Objects database.

難しく、意図や行動の深い理解よりも、システムが端的に判断できるものに実用的な技術は限られている。しかし、設計者が想定できない子供の行動による事故を防いだり、高齢者や介護を必要とする弱者に対する支援を代替したり、運転手と協調して車を制御したりするためには、状況依存性の高い人間の行動や意図を包括的に理解し、そのうえで人と協調してシステムが最適に動作することが必要であり、日常生活環境における人間行動理解の研究がますます重要になっている。こうした研究を広く展開し、多様な生活環境で利用者に密着して機能する知能システムを実現するために、我々は人間の多様な生活環境、行動と意図などを計算モデルとして表現し、そのモデルをシステムが利用できるような基盤技術として整備することが必要である。

また各事例研究を個々に進めながらも、人間と生活環境の視点から状態空間や観測データなどを網羅的にマッピングし、それを様々な機能実現、アプリケーション設計のために活用するものとして情報を共有することが人間の生活環境全般における問題解決のためには不可欠となる。具体的にはセンサ、データ、モデル、学習アルゴリズムなどのリソースの管理と、研究コミュニティの整備、情報交換である。現在、子供の事故予防のための行動モデリング・事故シミュレーションの生成や生活支援システムのユーザビリティ評価などのために、人間の行動履歴を移動履歴や各部位の動作については各時刻の3次元座標値として、また環境情報については間取りや、室内に存在し生活に利用している物体約1,000点についての属性(サイズ、画像、利用頻度など)付データベース(図14)、人と物体との相互作用としての現象(怪我などの物理的相互作用、欲求の充足などの認知心理的な作用など)、アンケー

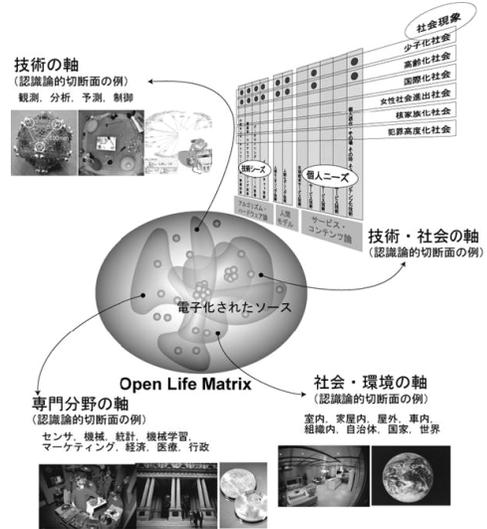


図 15 実生活行動理解のための研究基盤
Fig. 15 Research repository of everyday living human activity.

トなどを実際の生活空間において収集して蓄積している。これらの多変量データの間にある関係性をページアンネットワークとしてモデル化することによって、実生活空間の事前分布をモデル化し、観測対象のベイズ推定や予測に適用できる。また、これを使って、起こりやすい事故やその際の子供の行動などを3次元CGとして生成したり、人間の認知・心理的な事象(意図や欲求充足度)の予測を行ったりすることができる。

個々の人間行動理解研究を一般化可能なものにするために必要なことは、モデルやデータ、アルゴリズムなど研究を通じて得られる知的リソースを、日常生活環境における様々な応用目的のために再利用可能なものとして異分野の研究者が共有することである。具体的な取扱いを可能とするために、場面や環境を限定し、扱う情報を特定のものに限定することがあるが、その弊害として、個々の研究がかなり個別的になり、利用するセンサ、モデル、システムのどれもが一致しない限りは研究上の知見を共通に議論することが難しく、研究者間の連携や評価、研究成果の普及に大きな障害となる。そこで、我々自身の人間行動理解研究を進める中で生まれる様々な知的リソースを見通し良く俯瞰できるように、これをWebを通じて実生活の行動理解研究基盤として公開する²⁴⁾(図15)。

7. 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。こうした実生活情報処理を、固有のアプリケーションとして場当たりに開発

するのではなく、利用者である人間の視点から体系的づけて考え、再利用性の高いリソースをソフトウェアや手法として活用することが人間を中心とした情報処理技術の発展のためには重要と考えている。本稿ではそうしたリソースの1つとして、再利用性の高いモデルという考え方が成立し、これを我々の日常生活環境における事前知識のモデルとしてグラフ構造を持つ確率分布、ベイジアンネットワークとして構築する方法について述べた。これを展開するためには日常的な生活行動全般を包括的に観測し、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リ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重要になるだろう。現在、我々はそのためにインターネットを通じて、人間行動の観測データやソフトウェア環境、分析結果やモデルなどを共有する枠組みの提案も行っている²⁴⁾。

謝辞 有益なご議論をいただいた金出武雄 CMU 全学教授/産総研 DHRC センター長、子供の事故予防 Web サービスを共同で開発しましたベネッセコーポレーションに感謝いたします。

参 考 文 献

- 1) Box, Tiao: *Bayesian Inference in Statistical Analysis*, John Wiley & Sons Canada (1992).
- 2) 松原 望: *意思決定の基礎*, 朝倉書店 (2001).
- 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) マービンミンスキー (著), 安西祐一郎 (訳): *心の社会*, 産業図書 (1990).
- 5) Lafferty, J., McCallum, A. and Pereira, F.: *Conditional Random Field: Probabilistic Models for Segmenting and Labeling sequence data*, pp.282–289, ICML (2001).
- 6) Torralba, A., Murphy, K.P. and Freeman, W.T.: *Contextual Models for Object detection using boosted random fields*, *Uncertainty in Artificial Intelligence* (2003).
- 7) Motomura, Y.: *Integration of situated prior probability and neural network classifier in a handwriting recognition task*, *International Conference on Neural Information Processing*, pp.283–286 (1998).
- 8) Rimey, R. and Brown, C.: *Task-oriented vision with multiple bayes nets*, *Active Vision*, B. A. and Y. A. (Eds.), The MIT Press (1992).
- 9) Feng, X., Williams, C.K.I. and Felderhof, S.: *Combinating Belief Networks and Neural Networks for Scene Segmentation*, *IEEE Trans. PAMI*, Vol.24, pp.467–483 (2002).
- 10) Kelly, G.A.: *A Theory of Personality — The Psychology of Personal Constructs*, W.W. Norton & Company (1955).
- 11) Motomura, Y. and Kanade, T.: *Probabilistic Human Modeling based on Personal Construct Theory*, *Journal of Robotics and Mechatronics*, Vol.17, No.6, pp.689–696 (2005).
- 12) <http://tech.groups.yahoo.com/group/OpenCV/>
- 13) <http://svmlight.joachims.org/>
- 14) 本村陽一: *ベイジアンネットによる確率推論技術, 計測と制御*, Vol.42, No.8, pp.649–654 (2003).
- 15) 河田諭志, 本村陽一, 西田佳史, 田中和之: *確率的構造モデリングによる画像からの行動認識*, 人工知能学会全国大会 (2007).
- 16) 讚井純一郎: *レパトリートリッド発展手法による住環境評価構造の抽出*, *日本建築学会計画系論文報告集*, pp.15–22 (1986).
- 17) 本村陽一: *走行シーンにおけるドライバーの認知構造のモデル化, システム・情報部門学術講演会 2005 講演論文集*, pp.137–149, 計測自動制御学会 (2005).
- 18) 本村, 西田, 山中, 北村, 金子, 柴田, 溝口: *知識循環型事故サーベイランスシステム, 統計数理*, Vol.54, No.2, pp.299–314 (2006).
- 19) 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).
- 20) 田中哲郎: *新子どもの事故防止マニュアル, 診断と治療社* (2003).
- 21) *日本中毒情報センター* (2005). <http://www.j-poison-ic.or.jp/>
- 22) *日本小児保健協会: DENVER-II デンバー発達判定法*, 日本小児医事出版 (2002).
- 23) Kitamura, K., Nishida, Y., Matsumoto, N., Motomura, Y., Yamanaka, T. and Mizoguchi, H.: *Development of infant behavior simulator: Modeling grasping achievement behavior based on developmental behavior model and environmental interest induction model*, *Journal of Robotics and Mechatronics*, Vol.17, No.6, pp.705–716 (2005).
- 24) 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: オープンライフマトリックス*, 人工知能学会全国大会 (2006).
- 25) Motomura, Y., Kakefuda, I. and Yamanaka, T.: *Bayesian network modeling and analysis of child restraint seat use and attitude*, *Int. Meeting of the Psychometric Society* (2007).

(平成 18 年 10 月 3 日受付)

(平成 19 年 3 月 20 日採録)

(担当編集委員 蔵田 武志)



本村 陽一

1993年電気通信大学大学院修士課程修了。1993年電子技術総合研究所入所，2001年産業技術総合研究所情報処理研究部門主任研究員，2003年より同研究所デジタルヒューマン研究センター主任研究員。人工知能学会ベストプレゼンテーション賞，研究奨励賞等受賞。電子情報通信学会，日本人工知能学会，日本神経回路学会，日本認知科学会，日本行動計量学会，マーケティングサイエンス学会，IEEE各会員。



西田 佳史

1998年東京大学大学院機械工学専攻博士課程修了。1998年電子技術総合研究所入所，2001年産業技術総合研究所デジタルヒューマンラボ研究員，2003年より同研究所デジタルヒューマン研究センター人間行動理解チームリーダー。ロボット学会論文賞，研究奨励賞等を受賞。