

事情通口ロボットにおけるニューラルベイジアンネットの学習

Learning of Neural Bayesian Network for Office-Conversant Robot

本村 陽一[†] 麻生 英樹[†] 原 功[†] 赤穂昭太郎[†] 松井俊浩[†]
Yoichi Motomura[†] Hideki Asoh[†] Isao Hara[†] Shotaro Akaho[†] Toshihiro Matsui[†]

[†] 電子技術総合研究所 新情報計画室

[†] Real World Computing Project Team, Electrotechnical Lab, MITI.

Abstract: Bayesian network system using neural networks for representation of conditional probabilities is introduced. In order to apply Bayesian network to real world applications, for example office-conversant robot, continuous real value or discrete multi-value should be treated easily in the system. Then we propose neural-bayesian network modeling, which uses multi-layer perceptrons to represent conditional probability in each node. In this paper, learning scheme is also shown through mobile robot navigation task.

1 はじめに

我々は実環境における柔軟な情報処理を行うことを目的としてオフィス環境における自律移動ロボットの対話学習システム(事情通口ロボット)の構成的研究を行っている[1][2][3]。この中では実環境におけるセンサ情報の不確実性や対話のための実時間応答性の制約などを考慮し、複数のセンサ、モーダルの情報を統合する必要がある。確率的知識を有向グラフと条件付き確率で表し、不確実な観測情報を伝播することで確率的推論を行なうモデルとしてベイジアンネットワークがある。特に実環境におけるロボティクスに応用するために離散多値、連続値を自然に取扱えること、またパラメータとなる条件付き確率についてはロボット自身の経験を通じてこれを学習する枠組が重要である。これらを実現するためにニューラルネットを適用したニューラルベイジアンネットワークモデルを提案し、事情通口ロボットにおける学習と情報統合を行なう仕組みについて述べる。

2 事情通口ロボット計画

我々は「所内事情通口ロボット計画」[1]として研究所内の建物内部を自由に移動し、必要な情報収集、学習による環境理解、ユーザーとの対話による案内等の知的機能の自律的獲得を最終的な目標とし自律移動ロボット上の知的統合システムの構成的研究を行っている。この中で実環境の不確実な観測情報と経験を通じた確率的知識を統合することで推論を行なうメカニズムとしてベイジアンネットを適

用している。タスクとしては部屋の名前を聞いて案内をしたり、人の名前を聞いてその人を探したりすることが考えられている。このような場合には取扱う変数として物の名前(離散多値)、センサの観測値(連続値)を取り扱う必要がある。また変数の間の関係(条件付き確率)はロボットが経験を通じてはじめて明らかになるため事前に人間が与えるのではなく、経験から学習していく枠組が必要となる。

3 モデル

3.1 ベイジアンネットワーク

ある事象を表す確率変数を X, Y のように書きそれぞれの実現値を x, y とする。 X, Y の間に If X then Y なる因果関係がある時、これを $X \rightarrow Y$ で表す。この因果関係が非決定的な不確実性を含む場合には条件付き確率 $P(Y|X)$ を考えればよい。事象をノード、その間の確率的な関係を有向グラフで表現してネットワークを構成したものがベイジアンネットワーク(Bayesian network)である[4]。このネットワークのいくつかの事象が観測可能な事実である場合、これらのノード集合 E は確定値(Evidence)をとる。その条件のもとでの未知の事象 U に関する確率的推論は事後確率 $P(U|E)$ から U の具体的な値に対する確信度を推定することであり、ベイジアンネットワークではノード間の局所的な情報伝播としてこれを計算する。以降では X, Y の間の局所的な確率計算について考える。

Evidence $X = x_e$ が得られた時、 Y の各実現値に関する確信度 $B(Y)$ の推定は次のように行なわれる。

$$B(Y) = P(Y|X = x_e)$$

連絡先: 〒 305 つくば市梅園 1-1-4 電子技術総合研究所
情報科学部 情報数理研究室, 本村 陽一, E-mail: motomura@etl.go.jp,
Tel: (0298)58-5836, Fax: (0298)58-5841

X が Evidence ではなく不確実性を含んでいる場合、 $X = x$ の確率 $P(x)$ により Y の確信度 $B(Y)$ の推定は次の条件付き確率で行う。

$$B(Y) = \int_{x \in X} P(Y|X = x) dP(x) \equiv q_Y(X) \quad (1)$$

逆に Y に関する情報 $P(y)$ が得られている場合、 X の確信度 $B(X)$ についての推定は次の逆確率で行う。

$$\begin{aligned} B(X) &= \alpha \int_{y \in Y} P(X|Y) dP(y) \\ &= \alpha \int_{y \in Y} P(Y|X) dP(Y)P(X) \equiv \alpha r_Y(X)P(X) \quad (2) \end{aligned}$$

(ただし α は $B(X)$ を確率化するための正規化係数。)

$q_Y(X), r_Y(X)$ が形式的に X, Y 間で受渡しされる局所的な確率情報であり、これをネットワーク上で大域的に伝播させ、未知の事象の事後確率分布を計算することで推定が行える (図 1)。

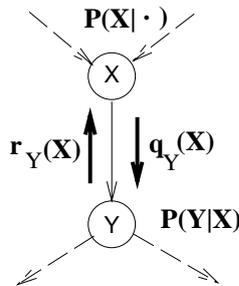


図 1: 確率伝播

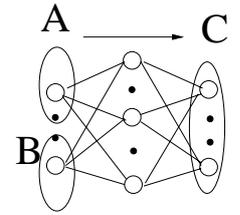
3.2 多層パーセプトロンによる確率表現

ベイジアンネットワークによる確率的推論を実際に行うには事象間の条件付き確率をどのように表現するかが重要である。従来は全ての組み合わせについての確率を表として与える方法が多く用いられているが、確率変数が離散多値、連続値の場合巨大な表が必要となることが問題となる。本研究では確率変数の次元に応じた入出力素子数を用意した一層の隠れ層を持つ次のような 3 層パーセプトロン (MLP), $f(x)$ を用いて条件付き確率を表現するモデルを提案する (図 2)。

Y が離散多値の確率変数 $Y = (y_1, y_2, \dots, y_k)$ の場合、 k 個のニューロン (クラスター) により Y の確率ベクトル $P(Y = y_1), P(Y = y_2), \dots, P(Y = y_k)$ を表す。各確率変数に対応したニューロンクラスターを入力層、出力層として 1 つの隠れ層を持つ 3 層パーセプトロンを用いて $X = x$ のもとでの条件付き確率 $P(Y|X = x)$ を次のよう

A	B	C	P(C A,B)
1	2	1	0.7
:			
:			

Data Base



Neural Network

図 2: ニューラルネットワークによる確率表現

に表現する。

$$f_k(x) = g \left(\sum_j v_{jk} g \left(\sum_i w_{ij} x_i + b_j \right) + b_k \right)$$

$$g(x) = \frac{1}{1 + \exp(-x)}$$

$$P(Y = y_k | X = x) = f_k(x) / \sum_k f_k(x)$$

Y が連続値の確率変数の場合、この確率分布を μ, σ でパラメタライズしたガウス分布と考えると次のように表す。

$$f_\mu(x) = \sum_j v_j g \left(\sum_i w_{ij} x_i + b_j \right) + b_\mu, (f_\sigma \text{ も同様})$$

$$P(Y = y | X = x) = \frac{1}{\sqrt{2\pi}f_\sigma(x)} \exp \left(-\frac{(y - f_\mu(x))^2}{2f_\sigma(x)^2} \right)$$

統計的に獲得した x, y のデータセットから定まる条件付き確率を教師信号として与えることで、 $P(X)$ を入力した時に $q_Y(X)$ が得られるように MLP, $f(x)$ を BP 法により学習する。推論時の確率計算は、式 (1) については親ノード X の確率を MLP に流すことで行う。離散多値の確率変数 X の具体的な実現値の種類数を $|X|$ と書くと、親ノード $X_i (i = 1, \dots)$ と子ノード Y の間の条件付き確率に必要な記憶容量、確率計算のオーダーは従来の表参照によるものでは

$$\prod_i |X_i| \cdot |Y|$$

であるが、本方式では次のようになる。

$$\left(\sum_i |X_i| + |Y| \right) \cdot |H|$$

ここで隠れ素子の個数 $|H|$ は対象の複雑さと近似精度のトレードオフにより決められ、これがそれほど大きくない場合には確率計算が効率化される。

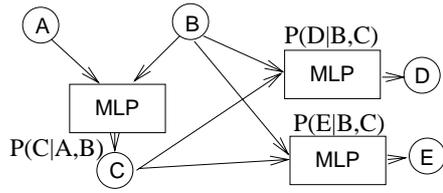


図 3: モデル概念図

3.3 準モンテカルロ法による近似的確率計算

式(2)については X をサンプリングして MLP から得られる値を用いた準モンテカルロ計算により行うことができる。確率変数 x についての全定義域についての積分、下式をあきらめて

$$BEL(y) = \int_{x \in R_x} P(Y = y|x)P(x)dx$$

適当なサンプリング $x_{i(i=1, \dots, n)} \sim S_x$ を導入し、

$$BEL(y) \approx \frac{1}{n} \sum_{i=1}^n P(Y = y|x_i)$$

によって近似する。たとえば $BEL(y)$ を求める場合、各ノードでは常に x_i をサンプリングし、逐次

$$Z_y = \sum_i P(Y = y|x_i)$$

を計算する。 S_x のサンプリングはノード X の確信度 $P(x)$ に依存しているため、親ノードへの問い合わせにより行う。 Y についての確信度を要求された所でサンプリングを打ち切り $BEL(y) \approx Z_y/n$ を返す。 $BEL(x)$ についても同様である。これらの計算は隣接ノード間の局所計算で行われるため、自然な並列実装が容易である。

以上の近似的計算手法により計算時間と計算精度のトレードオフを考慮した即応的な処理が可能になる。

4 確率的推論を行うシミュレーター

前節までで説明したモデルを実験的に評価するためのシミュレーター(図4)を JAVA 言語のマルチスレッド機能を用いて開発した。

4.1 統計データからの学習

本システムでは下のような統計実データから得られる頻度確率をベイジアンネットの条件付き確率としてネットワークに与えることでパラメーターの学習を行う。

<http://www.etl.go.jp/etl/suri/motomura/BN/>

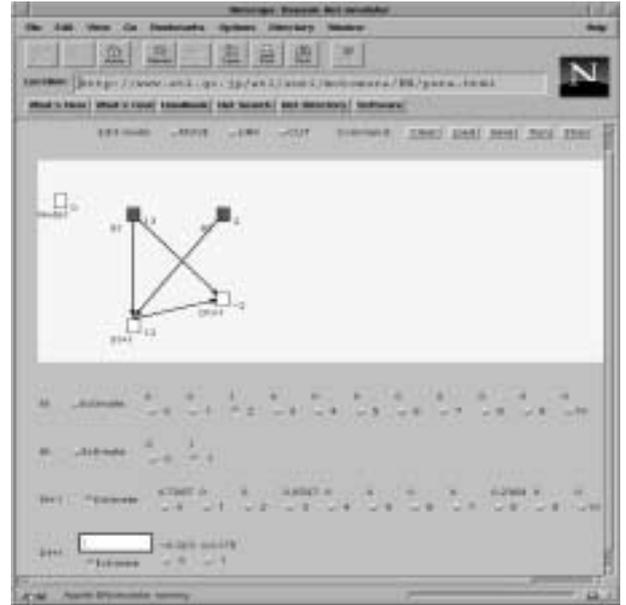


図 4: ベイジアンネットシミュレーター

これらの処理は統計データベースモジュールに対する問い合わせにより実現しており、任意のタイミングでそれまで得られたデータによる条件付き確率に更新することができる。

4.2 ナビゲーションタスクへの適用

ロボットは下位の行動モジュールとしてポテンシャル法による障害物回避などを組み込んでいるため、必ずしも事前に予期した通りに行動するとは限らない。また距離計、角度計の計測値は不正確なものである。これらの不確実性を含む情報と対話による言語情報をベイジアンネットにより統合することで適切なナビゲーションを行う。

ネットワークの構成は図3に示したものをを用い、次の手順により学習を行なう。

1. ユーザーの発話により現在地点、目的地点、移動のための行動が指示される。
2. 目的地点への移動が成功したらそのときの距離センサの値をデータベースへ記録する。
3. 同一現在地点、目的地点、行動毎の試行回数、成功回数を記録する。
4. 十分に多くの試行を繰り返した後、(成功回数 / 試行回数)により頻度確率が求まる。
5. ベイジアンネットの親ノード、子ノードの関係に対応するニューラルネットを作り、データベースから

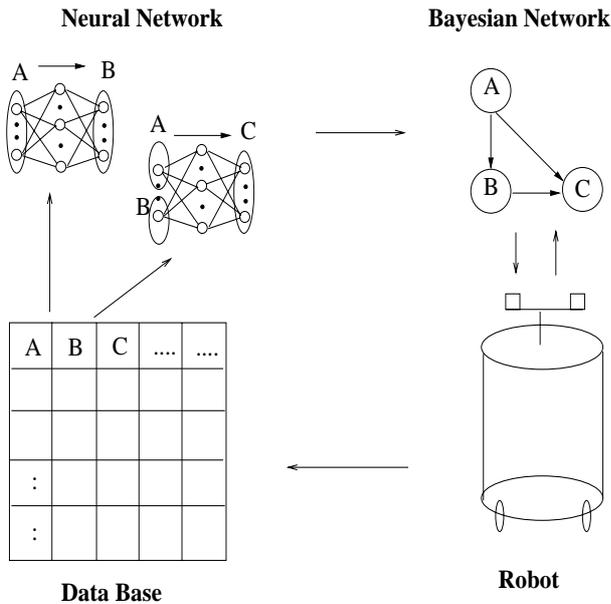


図 5: 学習における情報の流れ

条件付き確率を切り出したものを教師信号として BP 法で学習する。

- 学習が完了したニューラルネットをベイジアンネットが読み込み確率推論を行なう。

4.3 実験

Nomad200 を稼働させて 100 回程度の試行により得た実験結果をデータとし、隠れ素子数 10 個のニューラルネットを学習した結果、BP 法で 5,000 回 -10,000 回の繰り返しで学習は収束した。このニューラルネットをベイジアンネットに読み込ませて次のような確率推論を行なった。

結果

S_t (現在地点), A_t (行動), S_{t+1} (移動地点), D_{t+1} (移動距離: 連続値)

- $P(S_{t+1}|S_t, A_t)$... 到達地点の予測
- $P(D_{t+1} = d|S_t, S_{t+1})$... 距離センサの観測値 (d) の尤度
- $P(S_{t+1} = s|S_t, D_{t+1} = d)$... 到達地点 (s) の確からしさ

- $S_t = a, A_t = 1$ (go straight)
- $P(S_{t+1}|S_t, A_t) = (S_{t+1} = b : 0.2, S_{t+1} = c : 0.8)$

$$3. \arg \max_D P(D_{t+1}|S_t, S_{t+1} = b) = 1375.0$$

$$4. \arg \max_D P(D_{t+1}|S_t, S_{t+1} = c) = 98.7$$

5. $P(S_{t+1}|S_t, D_{t+1})$: D_{t+1} の観測値を代入して S_{t+1} を推定

6. $D_{t+1} = 100$ の時 ($S_{t+1} = c : 0.99 \dots$)

5 まとめ

確率推論を行うベイジアンネットを階層型ニューラルネット構成するモデルを提案し、シミュレーターを実装した。これにより従来実装上問題となる確率変数が離散多値や連続値の場合を自然に取り扱うことができ、BP 法により統計データからのベイジアンネットを学習することが可能となった。その中で不確実性を含む情報 (現在の状態、センサ入力)、過去の確率的知識、言語情報の間の情報統合を自然な形で実現している。確率的な推論方法は他にもいろいろ考えられるが、特に本研究のベイジアンネットモジュールによる実現は汎用的なものになっている。そのため今回示した自己位置同定だけでなく別の事象のノードを外部のモジュール、センサと接続し別のネットワークを構成することでさらに高次のタスクにも容易に拡張可能であり、「事情通口ロボット計画」では対話機能を活用したより知的なタスクを行わせる予定である。この場合にはネットワークを動的に構成するメタな制御方式の検討が重要であり、その場合のシステムの構成、実験的評価などは今後の課題である。

謝辞

本研究は Real World Computing Program の一環として行われた。電総研大津知能情報部長、速水主任研究員を始めとする新情報処理計画室員の方々に感謝します。

参考文献

- [1] 松井, 速水, 麻生, 原, 本村: 学習型所内事情通口ロボットの計画, 日本ロボット学会大会 (1995).
- [2] 麻生, 本村, 松井, 速水, 原: 対話ベース学習によるオフィス環境での自律ロボットナビゲーション, 人工知能学会研究会, AI シンポジウム'95, SIG-J-9501-7 (1995).
- [3] H.Asoh, Y.Motomura, T.Matsui, S.Hayamizu, I.hara: Acquiring a Probabilistic Map with Dialogue-Based Learning, Proc. of ROBOLEARN-96 (1996).
- [4] J.Pearl: Probabilistic Reasoning in Intelligent Systems, Morgan Kaufmann Publishers(1988).
- [5] 本村, 麻生, 原, 赤穂, 松井: "ベイジアンネットによる情報統合を用いた自律移動ロボットの自己位置同定", 人工知能学会全国大会 (1996).