

機関番号：12608
研究種目：基盤研究（B）
研究期間：2008～2010
課題番号：20300053
研究課題名（和文） 確率知識モデルによる不確定性推論の研究
研究課題名（英文） Uncertainty inference by probabilistic models

研究代表者
佐藤 泰介（TAISUKE SATO）
東京工業大学・大学院情報理工学研究科・教授
研究者番号：90272690

研究成果の概要（和文）：

現在データマイニングなど多量且つノイズを含むデータからの知識獲得のため、機械学習に於けるグラフィカルモデルや、統計的自然言語処理に於ける確率文法などの技術が各分野で使われているが、素性を利用するため関係をうまく表現できないなどさまざまな制約があり、複雑な確率モデリングを困難にしている。我々は確率と論理を融合し、論理型言語に基づく確率モデリング言語 PRISM を開発した。PRISM は確率モデルの記述と計算・学習を完全に分離することにより、論理の記述力を活かした効率的な確率モデリングを可能にしている。

研究成果の概要（英文）：

Currently techniques from machine learning and statistical natural language processing are popular in various fields including data-mining and bioinformatics. However they are feature-based and it is difficult to capture interdependent relationships in real data. We have developed a logic-based modeling language PRISM which unifies logical semantics and statistical parameter learning. It separates model description by logical formulas from their probability computation and parameter learning, thereby enabling an expressive yet efficient complex probabilistic modeling.

交付決定額

(金額単位：円)

	直接経費	間接経費	合計
2008年度	3,300,000	990,000	4,290,000
2009年度	3,300,000	990,000	4,290,000
2010年度	3,500,000	1,050,000	4,550,000
年度			
年度			
総計	10,100,000	3,030,000	13,130,000

研究分野：総合領域

科研費の分科・細目：情報学・知能情報学

キーワード：学習と知識獲得

1. 研究開始当初の背景

近年バイオデータや Wikipedia などデータ・知識の大量集積が行われており、データマイ

ニング等による有効利用が諸方面から期待されている。しかしながら同時にそれらは誤りのあるデータであったり、不完全な知識であったりすることも多い。このような不確定

性を含むデータに対する情報処理モデルとしては以前から人工知能におけるベイズネット、音声認識・バイオインフォマティクスにおける隠れマルコフモデル、統計的自然言語処理における確率文脈自由文法などが典型的なものとしてあるが、どれも個体や関係が表現できず論理的知識の処理能力を欠いていた。2000年代初頭からこのような欠点を補い、統計的手法と論理概念を結合する事によりC4.5やSVMのような素性のみに頼る既存のデータマイニング手法を越える、関係に基づく不確性情報処理を目指す動きが欧米を中心に高まって来た。代表例として主としてアメリカ西海岸で発展しつつあるSRL(統計関係学習)と西ヨーロッパを中心に発展しつつあるPLL(確率論理学習)がある。

SRLはベイズネットの研究から発展したものである。ベイズネットが命題論理レベルの表現であるのに対し、論理変数や関係表現を採り入れる事により、より複雑な確率事象を容易に取り扱えるようにしている。但し確率推論や学習はベイズネットのアルゴリズムを流用している。SRLの枠組ですでに関係データベースへの確率的拡張やWebデータのリンク解析などが行われている。一方PLLは帰納推論をコンピュータ上に実現しようとする帰納論理プログラミングの研究に確率を採り入れる形で発展して来たものである。論理的表現に強い一方、統計的処理は未発達であり、ベイズネットの統計処理と組み合わせる方式が提唱されている。

我々はこれまでSRLやPLLの動きと同調しつつ、述語論理による知識表現と最尤推定によるパラメータ学習を分布意味論と呼ばれる確率的プログラム意味論の下に統合した確率知識モデル用言語PRISMを独自に開発して来た。PRISMは第一階述語論理に基づく確率的プログラムにより確率モデルを記述、実行、学習するが、Turing完全な計算能力と観測データからのパラメータ学習能力を備えているという意味で世界最初の学習能力を持ったプログラミング言語である。PRISMは上記の3大モデル(ベイズネット、隠れマルコフモデル、確率文脈自由文法)だけでなく、確率文脈自由グラフ文法などこれまで取扱われなかった確率モデルも統一して扱う事ができる汎用の確率計算機構とEMアルゴリズムに基づく汎用のパラメータ学習機構を備えており、その記述の柔軟性と計算の効率性が評価されて音楽やバイオインフォマティクスなど諸方面に適用されている。

PRISMは汎用の確率知識モデリング用言語であるが、一方でデータの確率的生成過程を

Horn節と呼ばれる含意の形をした論理式から成るプログラムで記述することを要請している。そのため定義可能な分布のクラスがいわゆる生成的(generative)なモデルに限定されており、またプログラムにも種々の数学的条件が課されている。更にプログラムが書けないと分布が定義出来ないことから、例えばバイオインフォマティクスにおける遺伝子ネットワーク推定問題のように、対象データの知識が不完全な状況では、プログラムを書けず何も推論出来ない場合があるという問題があった。

2. 研究の目的

本研究では柔軟で高度の確率情報処理を実現するため、上記のPRISMの問題点に対処しつつPRISMの計算能力および学習能力を強化する。

3. 研究の方法

具体的には以下の研究を行う。PRISMでは背反性条件と呼ばれる条件をプログラムに課している。背反性条件はプログラムの実行過程が複数ある場合、それらが確率的に背反である事を要請している。この条件はPRISMのモデル記述における一番きつい制約となっており、廃止によりモデリングの自由度を飛躍的に上げる事が出来る。一方背反性条件は確率計算における $P(A \vee B) = P(A) + P(B)$ の成立を保証し、効率的確率計算を可能にしている条件である。従ってその廃止は意味論的には問題ないものの、計算効率の低下を招く恐れがある。我々はここにBDD(2分決定グラフ)を使って背反性を回復しつつ効率的な確率計算の実現を目指す。BDDによる確率計算、パラメータ学習はこれまで世界的に見ても余り手が付けられていない未知の領域であり、BDDへのencoding法、確率計算のためのBDDの構造化、パラメータ学習アルゴリズムの導出など数多くの課題がある。またPRISMには統計的モデリングに不可欠のパラメータ学習の機能があるが、学習の際多量のデータに対して、全解探索を行うため、メモリが不足がちであった。この問題解決するため、近似的な確率計算や近似的なパラメータ学習を開発実装する。

4. 研究成果

2008年度はPRISMプログラムに課されている背反性条件を除くため、BDDによる確率計算および統計パラメータの学習のアルゴリズムの開発を行った。BDDはブール式をコンパクトに表現する有向グラフである。我々は確率的命題変数からなる任意のブール式を表

す BDD に対し、隠れマルコフモデルの確率計算で使われる内側確率および外側確率の概念を適用することにより、動的プログラミングに基づいて効率的に確率計算を行う一般化内側・外側確率アルゴリズムを導出した。さらにこのアルゴリズムを使い、BDD から確率的命題変数に付随する確率を推定する BDD-EM アルゴリズムと呼ばれる EM 学習アルゴリズムを導出した。BDD と EM 学習アルゴリズムを結びつけた研究は今までになく、BDD が広く使われている現状からして、BDD-EM アルゴリズムは広い応用が期待される。また、PRISM による統計的アブダクション（統計的仮説推論）に使われる論理式を確定節から一般の節に拡大するため、独立の確率的命題変数からなる一般の節を考え、そのような節の集合を条件部に持つ条件付き分布についてその性質を調べた。その結果、このような条件付き分布により任意の離散結合分布が表現できるとこと、および PRISM プログラムにより表現される（無限の）分布もある数学的条件のもとに表現できることを証明した。

2009 年度では前年度末に導出した BDD-EM アルゴリズムをバイオインフォマティクスの一分野である代謝経路のモデリングに適用し、有効性を確認した。BDD-EM アルゴリズムは本研究プロジェクトで開発している確率知識モデリング言語である PRISM に於ける背反性制約を除くための中核的アルゴリズムであり、任意の率命題論理で記述された確率モデルのパラメータを学習できる。具体的には大腸菌の代謝経路をアブダクション（仮説推論）により実験データから論理的に推論し、可能な代謝経路（仮説）を得た後、それらを確率的命題論理により記述し BDD-EM アルゴリズムに与えることにより、代謝経路の各ステップを表す命題が真である確率を推論した。この確率にもとづき、候補となる代謝経路の確率を計算して最尤のものから順位付けを行ったところ、専門家の目から見て妥当な順に付けを得ることができた。この結果は将来バイオインフォマティクスなどの科学実験を行う際、半自動的に仮説を発見し評価する科学発見の自動化に繋がるものである。

PRISM の学習機能強化に関しては、統計的推論で重要な機能を果たすベイズ推論を取り入れる枠組みとして変分ベイズ法を採用し、PRISM の実行メカニズムである命題化計算と組み合わせることにより汎用の変分ベイズ法を実現できることを証明し、PRISM に実装した。このような汎用の変分ベイズ法はこれまでなく、変分ベイズ法の適用範囲を広げるものである。また変分ベイズ法により確率モデリングで重要なモデルの構造探索に於ける

モデル選択基準である周辺尤度を効率良く計算できるので、PRISM による確率モデルの構造探索が可能になった。

2010 年度では BDD-EM アルゴリズムを更に拡張した shared BDD-EM アルゴリズムを導出し実装した。shared BDD-EM アルゴリズムは、複数の BDD を構造化した shared-BDD を使い、従来 BDD を使った確率計算で仮定されていた単一データに対する確率計算を、統計的学習では必須の数百、数千の iid（独立同分布）データに対する確率計算に拡張したもので、複数のデータに対する確率計算の共有を行うつつ、パラメータ学習を行うものである。計算機実験の結果、その有効性が確認された。また論理に基づいた確率モデリングにおいては確率モデルは命題論理式に変換されるが、その際命題変数を順序付けした上で order-encoding と呼ばれる手法を使うことにより、より効率的に変換できることを理論的且つ実験的に確認した。一方 PRISM の推論機能強化に関しては、統計的推論で重要な機能を果たす Viterbi 推論の実験的実装を行った。Viterbi 推論は最尤の解を与える統計パラメータを推論するが、EM アルゴリズムに比べて、計算が簡単になり、より多量のデータを扱えるようになるという特徴がある。我々は PCFG などの確率文法に於いてこのようにして得た統計パラメータが EM アルゴリズムより得た統計パラメータより高い精度で正解構文木を与えることを初めて実験的に確認した。

5. 主な発表論文等

（研究代表者、研究分担者及び連携研究者には下線）

〔雑誌論文〕（計 12 件）

1. Sato, T., Ishihata, M. and Inoue, K., Constraint-based probabilistic modeling for statistical abduction, Machine Learning, 2010, 査読有
2. 佐藤泰介, 湊真一, ベイジアンネットワークと離散構造処理系, 人工知能学会誌, Vol. 25, No. 6, pp. 796-802, 2010, 査読無
3. Sneyers, J., Meert, W., Vennekens, J., Kameya, Y. and Sato, T., CHR(PRISM)-based probabilistic logic learning, Theory and Practice of Logic Programming, Vol. 10, pp. 433-447, 2010, 査読有
4. 佐藤泰介,

統計的アブダクション,
人工知能学会誌, Vol. 25, No. 3, pp. 400-407,
2010, 査読無

5. 石島正和, 亀谷由隆, 佐藤泰介, 湊真一,
BDD上の命題化計算に基づくEMアルゴリズム,
人工知能学会論文誌, Vol. 25, No. 3,
pp. 475-484, 2010, 査読有

6. Sneyers, J., Meert, W., Vennekens, J.,
Kameya, Y. and Sato, T.,
CHR (PRISM)-based probabilistic logic
learning,
Theory and Practice of Logic Programming,
Vol. 10, No. 4-6, pp. 433-447, 2010, 査読有

7. Sato, T., Kameya, Y., Kurihara, K.,
Variational Bayes via propositionalized
probability computation in PRISM,
Annals of Mathematics and Artificial
Intelligence, Vol. 54, No. 1-3, pp. 135-158,
2009, 査読有

8. 佐藤泰介,
記号的統計モデリングの世界を探る,
コンピュータソフトウェア, Vol. 25, No. 3,
pp. 33-36, 2008, 査読無

9. Sato, T.,
A glimpse of symbolic-statistical
modeling by PRISM,
Journal of Intelligent Information
Systems, Vol. 31, No. 2, pp. 161-176, 2008,
査読有

10. Sato, T. and Kameya, Y.,
New advances in logic-based probabilistic
modeling by PRISM,
In Probabilistic Inductive Logic
Programming, LNCS 4911, Springer,
pp. 118-155, 2008, 査読有

11. Zhou, N.-F., Sato, T. and Shen, Y.-D.,
Linear tabling strategies and
optimization,
Theory and Practice of Logic Programming,
Vol. 8, No. 1, pp. 81-109, 2008, 査読有

[学会発表] (計6件)

1. Ishihata M. (Sato, T.),
An EM algorithm on BDDs with order encoding
for logic-based probabilistic models,
ACML-2010, 2010/11/09, Tokyo.

2. Kameya, Y. (Sato, T.),
A Bayesian hybrid approach to unsupervised
time series discretization,
TAAI-2010, 2010/11/18, Hsinchu.

3. Zhou, N.-F. (Sato, T.),
Mode-directed tabling for dynamic
programming, machine learning, and
constraint solving,
ICTAI-2010, 2010/11/19, Hsinchu.

4. Inoue, K. (Sato, T.),
Evaluating abductive hypotheses using an
EM algorithm on BDDs,
IJCAI-2009, 2009/07/15, Pasadena.

5. Sato, T.,
Generative modeling by PRISM,
ICLP-2009, 2009/07/14, Pasadena.

6. Sato, T.,
Logic-based probabilistic modeling,
WoLLIC-2009, 2009/07/21, Tokyo.

[その他]

ホームページ等

<http://sato-www.cs.titech.ac.jp>

6. 研究組織

(1) 研究代表者

佐藤 泰介 (TAISUKE SATO)

東京工業大学・大学院情報理工学研究科・教授

研究者番号：90272690

(2) 研究分担者

亀谷 由隆 (YOSHITAKA KAMEYA)

東京工業大学・大学院情報理工学研究科・助教

研究者番号：60361789