

計算限界

確率伝播法とその可能性について¹
渡辺 治 (東京工業大学)

本日の話題

1. 確率伝播法 (Belief Propagation Method)
2. メッセージ伝播アルゴリズムの特徴と可能性について
3. アルゴリズムの平均的解析のモデル (Planted Solution Model)

例題として：グラフの二分割問題 Graph Bisection Problem

¹このファイルは発表時に使用したプレゼンテーション用ファイルをA4版に変更したものです。スタイル等が悪くて見にくい部分がありますがご勘弁下さい。

1 . 確率伝播法 (Belief Propagation Method) について

一言でいうと

確率変数 X_1, \dots, X_n (各々の定義域を A_1, \dots, A_n とする) により決まる系 G において , 次のような周辺確率を求める方法である .

$$p(a) = \Pr_G[X_1 = \boxed{a}] = \sum_{a_2 \in A_2, \dots, a_n \in A_n} \Pr[X_1 = \boxed{a} \wedge X_2 = a_2 \wedge \dots \wedge X_n = a_n].$$

ただし

確率変数間の依存関係が単純で , 同時確率分布を分解して表わすことができる場合に限る \implies ベイジアン・ネットワーク

歴史


- AI の分野で Pearl が 1982 年に提唱したもの .
- 統計力学の研究者 MacKay らが LDPC 符号の復号法に使用して注目を集めた . それ以後 , 統計力学 & 情報理論を中心に研究が進んでいる .
- 最近では survey propagation なるものも登場している .

上記の周辺確率よりも , もっと一般的には次のような確率を求める (求めたい) ことが多い .

$$\begin{aligned} & \Pr_G[X_1 = a \mid X_n = b] \\ &= \frac{\sum_{a_2 \in A_2, \dots, a_{n-1} \in A_{n-1}} \Pr[X_1 = \boxed{a} \wedge X_2 = a_2 \wedge \dots \wedge X_n = b]}{\sum_{a_1 \in A_1, a_2 \in A_2, \dots, a_{n-1} \in A_{n-1}} \Pr[X_1 = a_1 \wedge X_2 = a_2 \wedge \dots \wedge X_n = b]} \end{aligned}$$

ベイジアン・ネットワーク :

同時確率分布の分解法を示した確率変数間の依存グラフ



$$p(a_1, a_2, a_3, a_4, a_5) = p(a_1)p(a_2)p(a_3|a_1)p(a_4|a_1, a_2)p(a_5|a_3, a_4)$$

ただし, たとえば次のように略記する :


$$\Pr_G[X_2 = a_2 \& X_4 = a_4] = p(a_2, a_4)$$

注意! (矢印がない関係はすべて独立)

$$\begin{aligned} p(a_1, a_2, a_3, a_4, a_5) &= \underline{p(a_1)}p(a_2)\underline{p(a_3|a_1)}p(a_4|a_1, a_2)p(a_5|a_3, a_4) \\ &= p(a_2)p(a_1, a_3)p(a_4|a_1, a_2)p(a_5|a_3, a_4) \\ &= p(a_1, a_2, a_3, a_4)p(a_5|a_3, a_4) \\ &= p(a_1, a_2, a_3, a_4, a_5) \end{aligned}$$

BP の計算方法 :

確率変数間のメッセージ伝播により各確率変数の belief を計算する .



毎ステップ , 各頂点において , 次のような計算を行う :

以下 , 頂点 Y_1 と , Y_1 の取りうる値 a に注目 .

(準備)

- $\pi_{Y_1}(a) = \sum_{\mathbf{b}} \Pr[Y_1 = a | \mathbf{X} = \mathbf{b}] \cdot (\pi_{X_1 \rightarrow Y_1}(b_1) \cdot \pi_{X_2 \rightarrow Y_1}(b_2) \cdot \pi_{X_3 \rightarrow Y_1}(b_3))$.
- $\lambda_{Y_1}(a) = \lambda_{Z_1 \rightarrow Y_1}(a) \cdot \lambda_{Z_2 \rightarrow Y_1}(a)$.

(メッセージの計算)

親へ (例 : $Y_1 \rightarrow Z_1$) : $\pi_{Y_1, Z_1}(a) = \pi_{Y_1}(a) \cdot \lambda_{Z_2 \rightarrow Y_1}(a)$.

子へ (例 : $Y_1 \rightarrow X_1$) : $\lambda_{Y_1 \rightarrow X_1}(b) \approx \Pr[X_1 = b]$ の一部

(Y_1 への X_1 以外の情報により得られる値)


(現時点での $Y_1 = a$ に対する belief の計算)

$$\text{Bel}_{Y_1}(a) = \alpha \cdot \lambda_{Y_1}(a) \pi_{Y_1}(a).$$


これまでにわかっていること :

定理 .

1. 依存グラフに閉路がなければ正しく周辺確率を計算する .
2. その場合の計算時間は $\mathcal{O}(n)$ (n は頂点数) である .



閉路あり



閉路なし

でも , 経験的に ... 閉路があっても大抵うまくいく場合がある !

1. LDPC 符号 (Gallager 符号) の復号化
2. Turbo 符号の復号化
3. 画像修復 , 様々な制約充足問題

2 . B P (メッセージ伝播法) の特徴と可能性

私の直感 :

確率伝播法 \iff 乱択局所探索アルゴリズム

補足

- 乱択局所探索アルゴリズムにもいろいろあり, その性質も大きく異なる. 上記の対応は「貪欲型」に対するもの (もっと正確には, 決定にランダム性を入れて多少ソフト化したもの.)
- 単純に乱択化しても効率が悪くなってしまう場合がある.

比ゆ: 5回サイコロを投げた和が15の元で, すべて3が出る確率 P_0

$$P_0 = \dots \iff P_0 = \frac{\text{すべて3の回数}}{\text{和が15の回数}}$$

計算で求まる \iff 多量のサンプルが必要

- 「貪欲型」が有効な場合に使える?(収束性がよい場合)
- もちろん(?) 最悪時はダメ, 平均的によい \implies 平均時解析

3 . 平均時解析の例


例題 : グラフの二分分割問題 Graph Bisection Problem

Graph Bisection Problem

Input: An undirected graph $G = (V, E)$, where $|V| = 2n$ for some n .

Task: Find an *equal size* partition V_0 and V_1 of V with min. # of cut edges.

Remark. Find one of them if there are several solutions.



知られていること :

- この問題はNP-困難 .
- 平均で多項式時間のアルゴリズムが知られている .
その入力グラフのモデルとして planted solution model が導入された .
 - > (Boppana, 1987): deterministic polynomial-time but not so simple
 - > (Jerrum and Sorkin, 1998): randomized $\mathcal{O}(n^2)$ time
 - > (Condon and Karp, 2001): randomized $\mathcal{O}(n + m)$ time
 - > (F. McSherry, 1999, etc): simplified spectral method

B P によるアルゴリズムの導出

確率変数

C_i ($1 \leq i \leq 2n$): 頂点 v_i が V_0, V_1 のどちらに属するか?

$E_{i,j}$ ($1 \leq i < j \leq 2n$): $E_{i,j} = 1 \Leftrightarrow v_i, v_j$ 間に辺が存在する .

計算の目標


与えられたグラフ G に対し, B P を用いて次の周辺確率を求める .

$$p_i = \Pr[C_i = 1 \mid C_1 = 1 \wedge \bigwedge_{i,j} E_{i,j} = e_{i,j}]$$

$$\text{ただし, } e_{i,j} = \begin{cases} 1, & G \text{ は辺 } (v_i, v_j) \text{ を持つ,} \\ 0, & G \text{ は辺 } (v_i, v_j) \text{ を持たない.} \end{cases}$$

その $p_i > 0.5$ か否かで C_i を決める .

ベイジアン・ネットワーク



得られたアルゴリズム


非常に単純なメッセージ伝播アルゴリズム

```
program PseudoBP( $G = (V, E), p, r$ );
  set all  $x_i$  to 0;
  repeat MAXSTEP times do {
     $x_1 \leftarrow +\infty$ ;
    for each  $i \in V$ ,
       $x_i \leftarrow \sum_{j \in N(i)} f_1(x_j) + \sum_{j \notin N(i)} f_0(x_j)$ ;
    if all beliefs are stabilized then break;
  }
  output( $x_1, \dots, x_{2n}$ ); // Classification is ( $\text{sign}(x_1), \dots, \text{sign}(x_{2n})$ ).
```

end-program

補足：

1. 関数 f_0, f_1 の定義：



$$f_1(z) = \begin{cases} h_1 \cdot \theta_1, & \text{if } \theta_1 < z, \\ h_1 \cdot z, & \text{if } -\theta_1 \leq z \leq \theta_1, \\ h_1 \cdot (-\theta_1), & \text{if } z < -\theta_1; \end{cases} \quad f_0(z) = \begin{cases} -h_0 \cdot \theta_0, & \text{if } \theta_0 < z, \\ -h_0 \cdot z, & \text{if } -\theta_0 \leq z \leq \theta_0, \\ -h_0 \cdot (-\theta_0), & \text{if } z < -\theta_0, \end{cases}$$

ただし，

$$a_0 = \frac{1-p}{1-r}, \quad a_1 = \frac{p}{r}, \quad h_0 = \left| \frac{a_0 - 1}{a_0 + 1} \right|, \quad h_1 = \left| \frac{a_1 - 1}{a_1 + 1} \right|, \quad \theta_0 = \left| \frac{\ln a_0}{h_0} \right|, \quad \theta_1 = \left| \frac{\ln a_1}{h_1} \right|.$$

2. 本当のBPではない！

- $\Pr[C_i = 1]$ と $\Pr[C_i = 0]$ の比の対数を求めることにした。
- メッセージの伝播で大きな簡単化を1つ行った。

実際動かしていると非常にうまく働く。 何とか証明したい！

そこで

- アルゴリズムの平均的解析 \implies Planted Solution Model
- $\text{MAXSTEP} = 2 \leftarrow$ それでも結構よく働く

平均時計算量のモデル


Planted Solution Model = 入力グラフを生成する手法

アルゴリズムの平均的解析のモデルとしてお勧め？

今回用いた Planted Solution Model

パラメータ n (頂点数 $2n$) , $p, r, 0 < r < p < 1$ に対し ,
次のようにグラフ $G = (V, E)$ を生成する .

1. $V_0 = \{1, \dots, n\}$, $V_1 = \{n + 1, \dots, 2n\}$, and $V = V_0 \cup V_1$.
2. Put an edge (i, j) into E
 - with probability p if $C_i = C_j$, and
 - with probability r if $C_i \neq C_j$,where $C_i = 0 \iff i \in V_0$ and $C_i = 1 \iff i \in V_1$.



要するに

答えを作り , それを元に問題を (ランダムに) 作成する方法 .

重要な性質

定理 . パラメータ n, p, r の間に

$$p - r = \Omega\left(\frac{1}{\sqrt{n}}\right)$$

という関係があるとき , 埋め込んだ解 (planted solution) が , 生成したグラフに対する Bisection Problem の唯一の解となる .

↓

Planted Solution Model のもとでは , アルゴリズムの正当性は , 生成したグラフに対し , 埋め込んだ解が正しく見出せるか否かを調べればよい .

得られた結果

定理 . Planted Solution Model のもとでアルゴリズムを実行させたとき ,

$$\Pr[\text{ the algorithm yields the planted solution }] \geq 1 - 2n \cdot e^{-\epsilon_1 n \cdot \frac{(p-r)^4}{p^2}}.$$

系 .

For any $\delta > 0$ and any p and r , $cp < r < p < 1$,

$$p - r \geq c_2 n^{-1/2} \log(1/(\delta(p-r)))$$

\Rightarrow the algorithm answers correctly with probability $> 1 - \delta$.

これまでのアルゴリズムとの比較 :

(Boppana, 1987) $p - r = \Omega(n^{-1/2})$ (almost!?)

(Dyer and Frieze, 1989) $p - r = \Omega(n^{-1/2})$ when p is large, e.g., $\Omega(1)$

(Jerrum and Sorkin, 1998) $p - r = \Omega(n^{-1/6})$

(Condon and Karp, 2001) $p - r = \Omega(n^{-1/2+\epsilon})$

その他にも ...

- Most Likely Partition 問題 (with Onsjoe)
- MAX-2SAT 問題に対する同様のアプローチ (with 山本)
- 固有値を求める手法にできないか ?

未解決問題 : 本当の B P の妥当性 ?

参考文献

R. McEliece, D. MacKay, and J.F. Cheng, Turbo decoding as an instance of Pearl's "Belief Propagation" algorithm, *IEEE J. on Selected Areas in Communications*, 16(2):140-152, 1998.