情報システム工学科
伊達 章

神経回路網特論
2005 年 7 月 14 日

課題 3

- 目的： Bottom-up と Top-down 処理の絶妙な関係（鶏と卵）を味わう
  - Bottom-up 的手法： data driven （モデルなし，ニューラルネットなど）
  - Top-down 的手法: model-based （テンプレートマッチングなど）
  - 通常はどちらか一方． それぞれ弱点がある．
  1. この課題で使うモデルは両方を合わせたもの．
  2. 生成モデル：対象を的確に生成できるモデルを作っておけば，正確な認識ができる．
  3. モデルのパラメータは例題のデータから学習することができる．
- 課題 3.1 （必須）
  - ノイズを含んだデータ 2 例 `r1234567obs`, `r221obs` を講義のホームページからダウンロードし，自分の作ったプログラムを使い，もとの値の推定を試みる．
    `http://www.cs.miyazaki-u.ac.jp/~date/lectures/2005neural/index.html`
    自分の作ったプログラムが正しくもとの値の推定をできているかは．チェック用データ `r1234567obs` を使い，その結果が `r1234567map` となっているか確認することでチェックできる (`map` はデータの値+3 になっていることに注意)．
- 課題 3.2 （自由課題）
  - パラメータ (p_{ij}) の値が未知だとして，データから推定みる（EM アルゴリズム）．
  - 並列処理で近似解を求める （講義で説明した Gibbs Sampler という手法を使う）．
  - 状態数を 10〜50 値にして，音声データ，画像をモデル化する．音声データのサンプルは講義のページに `a200p50s6.dat` などを置いてある．
  - 自由にいろいろなデータを学習させることを試してみる．
  - ...
- 提出物：プログラムとレポート．
  - 何を試して，どういう結果になったか．
  - このモデルでイメージできた点，不満足な点．
  - レポート提出だけでなく，口頭による説明（特に動的計画法について）を求めます．
- レポートは電子メール (宛先：`date@cs.miyazaki-u.ac.jp`) または紙で提出．
- プログラムは自分のやりやすい言語で実験してよい．プログラムの書き方などがわからなければ早めに相談にくること．
- 提出期日を 7 月 28 日（木）と設定します．

情報システム工学科 伊達 章
神経回路網特論 2005 年 7 月 14 日

1 Gibbs Sampler

一般的に確率モデルを用いて認識システムの設計をおこなう場合，認識対象の規則性を，いかに埋め込むかが問題になる．これはシステムの内部状態を $\vec{x}$，観測できる部分を $\vec{y}$ とすると確率分布 $P(\vec{x})$ と $P(\vec{y}|\vec{x})$ の設計にあたる．$P(\vec{x})$ は生成モデル，$P(\vec{y}|\vec{x})$ はデータモデルと呼ばれたりする．例えば，音声認識の場合では $\vec{y}$ は音声信号の生データ，$\vec{x}$ は音素や単語などの各概念に相当する．認識過程は，具体的な入力 $\vec{y}$ に対し，全体としてまとまりのある，事後確率を最大にする解

$$\vec{x}_{\mathrm{MAP}} = \arg\max_{\vec{x}} \ P(\vec{x}|\vec{y}) \tag{1}$$

を計算する最適化問題として定式化できる．

動的計画法を使えば，$\vec{x}_{\mathrm{MAP}}$ を正確に計算できることを既に紹介した．ここでは動的計画法を使わず，$\vec{x}_{\mathrm{MAP}}$ の近似解を計算する手法を紹介する．

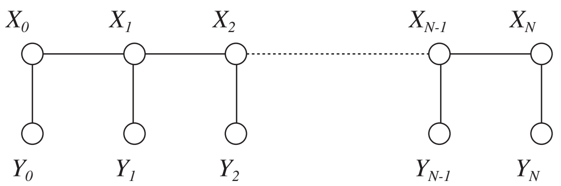

図 1: 確率変数の依存性：1 次元の隠れマルコフモデル

$y_0, y_1, \cdots, y_N$ が与えられているとする．求めたいのは

$$\begin{aligned}
\mathrm{Prob}(x_0, \cdots, x_T \mid y_0, \cdots, y_T) &= \frac{\mathrm{Prob}(x_0, \cdots, x_T,\ y_0, \cdots, y_T)}{\mathrm{Prob}(y_0, y_1, \cdots, y_T)} && (2)\\
&= c\ \mathrm{Prob}(x_0, \cdots, x_T,\ y_0, \cdots, y_T) && (3)\\
&= c \prod_{n=0}^{T} \mathrm{Prob}(y_n|x_n) \mathrm{Prob}(x_0) \prod_{n=1}^{T} \mathrm{Prob}(x_n|x_{n-1}) && (4)
\end{aligned}$$

を最大にする $x_0, x_1, \cdots, x_N$ であった．

1. 初期値として $x_0, x_1, \cdots, x_N$ に 0,1 をランダムに割り当てる．

2. 0 から N までの数から一つをランダムに選び，それを i とし，x_i に着目する．

3. 式 (4) を最大にすることを考えた場合, x_i に関係するのは, $\mathrm{Prob}(x_i|x_{i-1}), \mathrm{Prob}(x_{i+1}|x_i)$, $\mathrm{Prob}(y_i|x_i)$ の 3 項である．図で考えると 3 本のリンクに対応している．x_i の値が 0 の場合と，1 の場合について，これらの 3 項の値を計算し掛け算した値をそれぞれ h_0, h_1 とする．[0:1] の一様乱数を出力し，それが $h_0/(h_0 + h_1)$ より小さければ，x_i を 0 に設定し，そうでなければ 1 に設定する（$h_0 > h_1$ なら $x_i = 0$ そうでなければ 1 というのでもおそらくうまくいく）．

4. 2. にもどり繰り返す.

（この方法で，どうして近似解が得られるのかという議論が必要．ここでは省略）

2 次元格子型の MRF の場合，動的計画法が実質使えなくなるので，この方法が有効となる．