

補足メモ

先週

1. 問題の説明した .
2. 動的計画法 (Dynamic Programming) を利用し解決する方法を説明した .
3. その他, 必要な数理的知識:
正規分布, 条件付き確率, 同時確率, ベイズの公式, 事後確率最大化

今週, 来週: 基礎知識を復習しコードを書く

1. もとのデータ (x_0, \dots, x_{499}) をマルコフ過程により生成する .
2. 標準正規分布 (ガウス分布) にしたがうデータをコンピュータで生成し, y_0, \dots, y_{499} を生成する .
これは何のためか → 自分で問題を作って解き, どれくらい正しく復元できるか試すため .
3. コード作成の際の注意点: データ構造とアルゴリズム
データ構造を決めてコードを書く . 原理ももちろん理解する (裏面参照) .
以下は単なる例:

```
int X[500];  
double Y[500];  
double C[500][2];  
int S[500][2];
```


変数の説明:
C[10][1]: 状態遷移を繰り返し $x_{10} = 1$ という状態にたどり着いた系列のうち, 最も尤もらしい系列の発生確率 (正確には, のようなもの) .
S[10][1]: $x_{10} = 1$ であると仮定した場合に求めた x_9 の最適な値 .
4. コードが完成したら, 講義の web ページにあるデータを入力し, 復元結果が, 望ましい値と一致しているか確かめる .
5. データは 500 個ある .
6. この課題は「分かった」か「分からない」かはっきり区別が付きます! 「分かったような気がする」というのはありません! 「分かった」人に聞いてよいので, 必ず自分で「わかった」と納得できるまで考えてください .

目的： ノイズを含んだデータ y_0, y_1, \dots から，もとの波形 x_0, x_1, \dots を復元する

与えられているもの

1. データ： $\vec{y} = (y_0, y_1, \dots, y_{499})$

2. もとのデータ x_0, x_1, \dots の発生機構： $p_0 = 0.5, p_{00} = 0.99, p_{01} = 0.01, p_{11} = 0.97, p_{10} = 0.03$.

問題： これをもとに，最ももっともらしい解 $\vec{x}_{\text{MAP}} = (x_0, x_1, \dots, x_n)$ を探す

$$\vec{x}_{\text{MAP}} = \underset{\vec{x}}{\operatorname{argmax}} \operatorname{Prob}(\vec{x} | \vec{y}) \quad (1)$$

記号 argmax の使用例： $f(x) = -(x-1)^2$ を考える . $\tilde{x} = \operatorname{argmax}_x f(x) = 1$

$$\operatorname{Prob}(x_0, \dots, x_T | y_0, \dots, y_T) = \frac{\operatorname{Prob}(x_0, \dots, x_T, y_0, \dots, y_T)}{\operatorname{Prob}(y_0, y_1, \dots, y_T)} \quad (2)$$

分母は \vec{y} のみに関する確率 . これは与えられているもので変えようがない \rightarrow 分母は定数 . 最大値を求めるのには関係がない . したがって

$$\vec{x}_{\text{MAP}} = \underset{\vec{x}}{\operatorname{argmax}} \operatorname{Prob}(\vec{x} | \vec{y}) = \underset{\vec{x}}{\operatorname{argmax}} \operatorname{Prob}(x_0, \dots, x_T, y_0, \dots, y_T) \quad (3)$$

$$= \underset{x_0, x_1, \dots, x_T}{\operatorname{argmax}} \prod_{n=0}^T \operatorname{Prob}(y_n | x_n) \operatorname{Prob}(x_0) \prod_{n=1}^T \operatorname{Prob}(x_n | x_{n-1}) \quad (4)$$

これは以下の絵をイメージして考えると理解しやすい .




図 1: 確率変数の依存性 . y_0, y_1, \dots , は与えられている . $x_0, x_1, \dots \in \{0, 1\}$ の値を決めれば枝の値は決まる . n 個のノードがあれば 2^n とおりある . n が大きい場合は...

目的と解決策

1. 各枝には正の値がついている . 値は枝の両端のノードの値に依存して決まる .
2. グラフを構成する枝すべてについて , 枝の値を掛け算した結果を最大にしたい
3. 水平方向の枝の値 : $\operatorname{Prob}(x_n | x_{n-1}) \geq 0$, 具体的には $p_{00}, p_{01}, p_{11}, p_{10}$ の値 .
4. 垂直方向の枝の値 : $\operatorname{Prob}(y_n | x_n) = \frac{1}{\sqrt{2\pi}\sigma} \exp \left\{ -\frac{(y_n - x_n)^2}{2\sigma^2} \right\} \Delta y \geq 0$
5. 初期状態の確率は $\operatorname{Prob}(x_0) = 0.5$ つまり $p_0 = p_1 = 0.5$ にしておく .
6. 実際に動的計画法を用いて最も尤もらしい値をもとめるときは \log をとって計算する .
7. 大小を判定することだけが重要な場合 , 無駄なことを計算しない効率のよいコードを書く .
8. x_n に関係ない項は共通なので無視できる .

$$\log \left(\frac{1}{\sqrt{2\pi}\sigma} \exp \left\{ -\frac{(y_n - x_n)^2}{2\sigma^2} \right\} \Delta y \right) = -\log(\sqrt{2\pi}\sigma) - \frac{(y_n - x_n)^2}{2\sigma^2} + \log(\Delta y)$$