

A6 Iterative Algorithms

樋口さぶろお

龍谷大学大学院理工学研究科数理情報学専攻

理論物理学特論 L14(2020-12-23 Wed)

最終更新: Time-stamp: "2021-01-06 Wed 07:45 JST hig"

今日の目標

- 確率的/決定的反復法のそれぞれの特徴が説明できる



ここまで来たよ

14 A6 Iterative Algorithms

- 反復法による最小化
- 勾配法
- Simulated Annealing
- パラメタ分割法
- 補助関数法

(多次元連続) 最小化 (最適化) 問題

$$\theta_{\min} = \operatorname{argmin}_{\theta} \phi(\theta) = ?$$

解法の分類

数理計画法

- 厳密解 θ_{\min} が計算可能な式で書ける
 - ▶ explicit solution, closed expression
- 近似解
 - ▶ 決定的反復法 iterative methods. Loop をまわると, だんだん θ_{\min} に近づいていく KA MDA A.6.1
 - ★ パラメタ分割法 parameter partition algorithms ♠
 - ★ 補助関数法 auxiliary function algorithms
EM=Expectation-Maximization Algorithm, 途中で MCMC も ♡
 - ★ 勾配法 gradient algorithms KA MDA A.6.2, A.6.3 最急降下法 gradient descent
 - ▶ 近似的確率的反復法
 - ★ 焼き鈍し法 Simulated Annealing ← Markov Chain Monte Carlo ♡ ∼
Gibbs sampler ♠

implicit solution 解き方はわからないけど, 厳密な代数/超越方程式の解として表現できる

二分法やニュートン法じゃだめ?

$\nabla\phi(\theta_{\min}) = \mathbf{0}$ を二分法やニュートン法で解けばいい?

1次元の場合の困難

- 二分法やニュートン法では, 初期条件次第で 零点のうちの1個がみつかるのだった

2次元以上の場合の困難

- 二分法 (そのままの形の) 中間値の定理はない
- ニュートン法 \rightsquigarrow 勾配法

高次元の二分法と似た?アプローチ 'grid search'? 計算量 $(\frac{L}{\Delta x})^d$.
安易に頼ってはいけない.

決定的反復法の一般論

Step1 $\theta_{[0]} :=$ 適当な初期値


Step2 $\theta_{[t]}$ を小さく変更して $\theta_{[t+1]} = \dots$ に '改善' する local search

- '改善': $\phi(\theta_{[t+1]}) \leq \phi(\theta_{[t]})$ となるように \rightsquigarrow 単調減少列

Step3 実質的に '収束' したなら $\theta_{[t+1]}$ を出力して終了, そうでなければ, $t := t + 1$ して Step2 にもどる

- '収束' 判定はさまざまなものがありうる.

$\phi(\theta_{[t]}) - \phi(\theta_{[t+1]}) \geq 0$ が小さい, 何らかの距離 $d(\theta_{[t]}, \theta_{[t+1]})$ が小さい, など.



ここまで来たよ

14 A6 Iterative Algorithms

- 反復法による最小化
- 勾配法
- Simulated Annealing
- パラメタ分割法
- 補助関数法

勾配法 Gradient Algorithms

‘改善’(Update): $\theta_{[t+1]} = \theta_{[t]} - s \nabla \phi(\theta_{[t]})$ KA MDA A.6.7


ベクトル解析

s の決定は自明でない. $\phi:m, \theta:g, s:g^2/m$ のように次元が異なる.

Step2.1 $s := 1$


Step2.2 $\theta_{[t+1]} = \theta_{[t]} - s \nabla \phi(\theta_{[t]})$

Step2.3 もし $\phi(\theta_{[t+1]}) \leq \phi(\theta_{[t]})$ なら Step2 終了, そうでなければ,
 $s := s/\sqrt{2}$ して Step2.2 にもどる



勾配法の弱点

- Local minimum にとらわれて global minimum を見つけられないことがある
- s の設定に考察が必要



ここまで来たよ

14 A6 Iterative Algorithms

- 反復法による最小化
- 勾配法
- **Simulated Annealing**
- パラメタ分割法
- 補助関数法

Simulated Annealing

エネルギー ϕ , 外部パラメタ (逆温度) $\beta : 0 \rightarrow +\infty$.

Step1 $\theta_{[0]} :=$ 適当な初期値

Step2.2 $\theta_{[t+1]} = \theta_{[t]} +$ ランダムな小さいベクトル

Step2.3 もし $\phi(\theta_{[t+1]}) \leq \phi(\theta_{[t]})$ なら Step2 終了,
そうでなければ,


Step2.3.1 $R \sim U(0, 1)$ ($[0, 1)$ 連続型一様乱数)

Step2.3.1

$$R < e^{-\beta \cdot (\phi(\theta_{[t+1]}) - \phi(\theta_{[t]}))}$$

なら $\theta_{[t+1]}$ を返す. そうでなければ元の $\theta_{[t+1]} := \theta_{[t]}$ を返す.

Step2.4 β を少し増やす.




Simulated Annealing の統計力学的意味

マルコフ連鎖 は極限分布=定常分布を持つことがある.

極限分布=定常分布がボルツマン分布 $\frac{1}{Z}e^{-\beta\phi(\theta)}$ に従うように設計.

一様分布 \rightarrow 最低エネルギー状態に集中した分布, as $\beta : 0 \rightarrow +\infty$.



Simulated Annealing の弱点

- 収束の判定が難しい
- β の増加スケジュールに考察が必要
- **local minimum** につかまらないうらいゆっくり β を増加させると、計算時間がかかる (たりないと **local minimum** につかまる)

ここまで来たよ

14 A6 Iterative Algorithms

- 反復法による最小化
- 勾配法
- Simulated Annealing
- パラメタ分割法
- 補助関数法

パラメータ分割法 Parameter partition algorithms

$$\theta_{[t]} = [\theta_1^{[t]}, \theta_2^{[t]}].$$

Step 2.1. $\theta_2^{[t]}$ を固定して, $\theta_1^{[t+1]} = \operatorname{argmin}_{\theta_1} \phi(\theta_1, \theta_2^{[t]})$.


Step 2.2. $\theta_1^{[t+1]}$ を固定して, $\theta_2^{[t+1]} = \operatorname{argmin}_{\theta_2} \phi(\theta_1^{[t+1]}, \theta_2)$.

分割されたパラメータについて, 最小化までできなくても, 改善するだけでもいい.

MCMC, Simulated Annealing の文脈では 'Gibbs sampling'.

パラメタ分割法の弱点

- Local minimum にとらわれて global minimum を見つけれないことがある



$$\operatorname{minarg}_{\theta_1, \theta_2} \phi(\theta_1, \theta_2) = \operatorname{minarg}_{\theta_1} \operatorname{minarg}_{\theta_2} \phi(\theta_1, \theta_2)$$

じゃないの? \rightsquigarrow 自明じゃないし, この書き方じゃ両辺の型がそろってない...

正しくは,

$$\begin{aligned} \min_{\theta_1, \theta_2} \phi(\theta_1, \theta_2) \\ &= \min_{\theta_1} (\min_{\theta_2} \phi(\theta_1, \theta_2)) \\ &= \min_{\theta_1} \phi(\theta_1, \theta_2^{\min}(\theta_1)) \end{aligned}$$

パラメタ分割法では $\theta_2(\theta_1)$ を考えてない.

ここまで来たよ

14 A6 Iterative Algorithms

- 反復法による最小化
- 勾配法
- Simulated Annealing
- パラメタ分割法
- 補助関数法


補助関数法 Auxiliary function algorithms

$\phi(\theta)$ と別の補助関数 $\eta(\theta)$ をもってくる. ただし,

$$\begin{aligned}\phi(\theta_{[t]}) &= \eta(\theta_{[t]}), \\ \phi(\theta) &\leq \eta(\theta)\end{aligned}$$

Step2 (ϕ を気にせず) η を減少させる $\theta_{[t+1]}$ を作る.

$$\phi(\theta_{[t]}) = \eta(\theta_{[t]}) \geq \eta(\theta_{[t+1]}) \geq \phi(\theta_{[t+1]})$$



補助関数法の別の記述方法

$\phi(\theta)$ と別の補助関数 $\eta(\theta, \xi)$ をもってくる。ただし,

$$\phi(\theta) = \min_{\xi} \eta(\theta, \xi).$$

すると,

$$\text{Step2.1 } \xi_{[t+1]} = \operatorname{argmin}_{\xi} (\eta(\theta_{[t]}, \xi))$$

$$\text{Step2.2 } \theta_{[t+1]} = \operatorname{argmin}_{\theta} (\eta(\theta, \xi_{[t+1]}))$$

で, $\phi(\theta_{[t+1]}) \geq \phi(\theta_{[t]})$ となる.

Hunter, D. R., Lange, K. A tutorial on MM algorithms. The American Statistician, 58(1), 30-37, 2004.

補助関数法の例: EM Algorithm

EM=Expectation-Maximization KA MDA Note12.1

log likelihood: $\phi(\theta) = \ell(\theta, X_0) = \log P(X_0, X_1|\theta)$

X_0 : 未測定 (因子分析における latent factor), X_1 : 測定済

$$\text{E-Step } Q(\theta) = E_{X_0}[\ell(\theta_{[t]}, X_0)]$$

$$\text{M-Step } \theta_{[t+1]} = \operatorname{argmax}_{\theta}(Q(\theta))$$

Q, ℓ は, 変数 $p(X_0)$ を追加した補助関数と思える.

補助関数法の弱点

- よい補助関数を発見し, アルゴリズムの振舞いを証明するのは容易でない.