

# 組合せ最適化に関する一つの仮説

大阪工業大学 工学部 電気電子システム工学科

重弘裕二

# 動機

- 組合せ最適化問題に対する探索手法
  - 単点探索
    - 局所探索法, Simulated Annealing, ...
  - 多点探索
    - 進化的計算手法 (遺伝的アルゴリズム等)

# 動機

- 組合せ最適化問題に対する探索手法
  - 単点探索
    - 局所探索法, Simulated Annealing, ...
  - 多点探索
    - 進化的計算手法 (遺伝的アルゴリズム等)
- 大規模な問題には進化的計算手法！

# 動機

- 組合せ最適化問題に対する探索手法
  - 単点探索
    - 局所探索法, Simulated Annealing, ...
  - 多点探索
    - 進化的計算手法 (遺伝的アルゴリズム等)
- 大規模な問題には進化的計算手法！
- ちゃんと考えた方が良いのでは！？
  - なぜ多点探索ならうまくいくのか？
  - なぜ単点探索ではうまくいかないのか？

なぜ多点探索ならうまくいくのか？

- (単に) 探索点が多いから？

## なぜ多点探索ならうまくいくのか？

- (単に) 探索点が多いから？
  - 解の数は組合せ爆発！  
たかが数百の探索点では焼け石に水？

## なぜ多点探索ならうまくいくのか？

- (単に) 探索点が多いから？
  - 解の数は組合せ爆発！  
たかが数百の探索点では焼け石に水？
- うまくいくメカニズムは？
  - 両親の良いところを受け継いだ子が...？

## なぜ多点探索ならうまくいくのか？

- (単に) 探索点が多いから？
  - 解の数は組合せ爆発！  
たかが数百の探索点では焼け石に水？
- うまくいくメカニズムは？
  - 両親の良いところを受け継いだ子が...？
- 多点である必要はあるのか？
  - 進化的計算手法は実装が面倒  
パラメータ調整が面倒



## 研究内容

組合せ最適化について考える  
なぜ単点探索ではうまくいかないのか？

- **問題**を知り**仮定**をはっきりさせる
- **モデル**を作り**定理**を導く
- **仮説**を立て**理由**を考える

## 問題を知り仮定をはっきりさせる


- 組合せ最適化問題
- 自明な操作
- 暗黙の仮定
- 仮定を使うための操作

## 組合せ最適化問題

- 解 (組合せ的?) の集合  $F$
- $F$  から  $R$  (実数集合) への対応付け  $f$   
→  $f(s)$  を最小化するような  $s \in F$


## 組合せ最適化問題

- 解 (組合せ的?) の集合  $F$
- $F$  から  $R$  (実数集合) への対応付け  $f$   
 $\rightarrow f(s)$  を最小化するような  $s \in F$




## 組合せ最適化問題

- 解 (組合せ的?) の集合  $F$
- $F$  から  $R$  (実数集合) への対応付け  $f$   
→  $f(s)$  を最小化するような  $s \in F$



## 組合せ最適化問題

- 解 (組合せ的?) の集合  $F$
- $F$  から  $R$  (実数集合) への対応付け  $f$   
→  $f(s)$  を最小化するような  $s \in F$



## 自明な操作


問題の定義から自明な操作は以下の通り

- 任意解生成 :  $s \in F$  を一つ求める
- 評価 :  $s$  から  $f(s)$  を求める

## 自明な操作

問題の定義から自明な操作は以下の通り

- 任意解生成 :  $s \in F$  を一つ求める
- 評価 :  $s$  から  $f(s)$  を求める






## 自明な操作

問題の定義から自明な操作は以下の通り

- 任意解生成 :  $s \in F$  を一つ求める
- 評価 :  $s$  から  $f(s)$  を求める



## 自明な操作

問題の定義から自明な操作は以下の通り

- 任意解生成 :  $s \in F$  を一つ求める
- 評価 :  $s$  から  $f(s)$  を求める


この2つだけでは何もできない

もう少し解探索のための手がかりが欲しい

## 暗黙の仮定


通常は暗黙のうちに以下の仮定が置かれる

- 仮定 1 :  $s_1$  と  $s_2$  が似ているとき  
 $f(s_1)$  と  $f(s_2)$  の差は小さい



以下の仮定を見ることも多いが、

- 仮定 2 : 「よい解どうしは似通った構造を持っている」 [1]




[1] 柳浦睦憲・茨木俊秀：組合せ最適化 —メタ戦略を中心として—，朝倉書店（2001）

# POP

以下の仮定を見ることも多いが、

- 仮定 2 : 「よい解どうしは似通った構造を持っている」<sup>[1]</sup>

明らかな反例を作ることができる




[1] 柳浦睦憲・茨木俊秀：組合せ最適化 —メタ戦略を中心として—，朝倉書店（2001）

# POP

以下の仮定を見ることも多いが、

- 仮定 2 : 「よい解どうしは似通った構造を持っている」<sup>[1]</sup>

半数以上の枝が異なっている！



[1] 柳浦睦憲・茨木俊秀：組合せ最適化 —メタ戦略を中心として—，朝倉書店（2001）

## 仮定を使うための操作


当然「似ている」解を作る操作を考えたい

- 近傍操作：解の一部を変更して  
似ている解（**近傍解**と呼ぶ）を求める

## 仮定を使うための操作

当然「似ている」解を作る操作を考えたい

- 近傍操作：解の一部を変更して似ている解（近傍解と呼ぶ）を求める





## モデルを作り定理を導く

- ガウス関数
- 何のモデルを考えたいのか
- 近傍解に関する確率分布モデル
- 任意解に関する確率分布モデル
- 話を整理するため概念を導入
- 近傍解に関する定理
- 検証

## ガウス関数

$$A \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right)$$

- $A = 1/\sqrt{2\pi\sigma^2}$  のとき正規分布
  - $\mu$  は平均,  $\sigma^2$  は分散
- 計算しやすい
  - 掛けても畳み込んでもガウス関数

→ モデルを作るのに  
ガウス関数を使いたい

## ガウス関数

$$A \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right)$$

- $A = 1/\sqrt{2\pi\sigma^2}$  のとき **正規分布**
  - $\mu$  は平均,  $\sigma^2$  は分散
- 計算しやすい
  - 掛けても畳み込んでもガウス関数

→ モデルを作るのに  
ガウス関数を使いたい

## ガウス関数

$$A \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right)$$

- $A = 1/\sqrt{2\pi\sigma^2}$  のとき正規分布
  - $\mu$  は平均,  $\sigma^2$  は分散
- 計算しやすい
  - 掛けても畳み込んでもガウス関数

→ モデルを作るのに  
ガウス関数を使いたい

## ガウス関数


$$A \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right)$$

- $A = 1/\sqrt{2\pi\sigma^2}$  のとき正規分布
  - $\mu$  は平均,  $\sigma^2$  は分散
- 計算しやすい
  - 掛けても畳み込んでもガウス関数

→ モデルを作るのに  
ガウス関数を使いたい

# 何のモデルを考えたいのか


近傍解の評価結果の確率分布を知りたい



## 何のモデルを考えたいのか


近傍解の評価結果の確率分布を知りたい

→ ガウス関数でモデルを作りたい!



# 近傍解に関する確率分布モデル

元の解の評価結果を  $\mu_1$  とする






## 近傍解に関する確率分布モデル

元の解の評価結果を  $\mu_1$  とする


- $p_1$  : 平均  $\mu_1$ , 分散  $\sigma_1^2$  のガウス関数



## 近傍解に関する確率分布モデル

元の解の評価結果を  $\mu_1$  とする


- $p_1$  : 平均  $\mu_1$ , 分散  $\sigma_1^2$  のガウス関数  
しかし, 分布は偏っているはず



## 近傍解に関する確率分布モデル

元の解の評価結果を  $\mu_1$  とする


- $p_1$  : 平均  $\mu_1$ , 分散  $\sigma_1^2$  のガウス関数
- $p_2$  : 平均  $\mu_2$ , 分散  $\sigma_2^2$  のガウス関数



## 近傍解に関する確率分布モデル

元の解の評価結果を  $\mu_1$  とする


- $p_1$  : 平均  $\mu_1$ , 分散  $\sigma_1^2$  のガウス関数
- $p_2$  : 平均  $\mu_2$ , 分散  $\sigma_2^2$  のガウス関数
- $p_1 \times p_2$  : これをモデルとしたい



## 近傍解に関する確率分布モデル


元の解の評価結果を  $\mu_1$  とする

- $p_1$  : 平均  $\mu_1$ , 分散  $\sigma_1^2$  のガウス関数
- $p_2$  : 平均  $\mu_2$ , 分散  $\sigma_2^2$  のガウス関数
- $p_1 \times p_2$  : これをモデルとしたい ↓
- $p_3$  : 平均  $\mu_3$ , 分散  $\sigma_3^2$  のガウス関数



## 任意解に関する確率分布モデル


任意解の評価結果の確率分布も考える  
(全ての解を評価した結果の分布)



# 任意解に関する確率分布モデル

任意解の評価結果の確率分布も考える


- $p_0$  : 平均  $\mu_0$ , 分散  $\sigma_0^2$  のガウス関数



# 任意解に関する確率分布モデル

任意解の評価結果の確率分布も考える

- $p_0$  : 平均  $\mu_0$ , 分散  $\sigma_0^2$  のガウス関数
- 各解の近傍解を考える






# 任意解に関する確率分布モデル

任意解の評価結果の確率分布も考える

- $p_0$  : 平均  $\mu_0$ , 分散  $\sigma_0^2$  のガウス関数
- 全ての解の近傍解を考える




# 任意解に関する確率分布モデル

任意解の評価結果の確率分布も考える

- $p_0$  : 平均  $\mu_0$ , 分散  $\sigma_0^2$  のガウス関数
- 全ての解の近傍解を考える


合わせると



# 任意解に関する確率分布モデル

任意解の評価結果の確率分布も考える

- $p_0$  : 平均  $\mu_0$ , 分散  $\sigma_0^2$  のガウス関数
- 全ての解の近傍解を考える  
合わせると  $\rightarrow p_0$  になるはず




# 任意解に関する確率分布モデル

任意解の評価結果の確率分布も考える

- $p_0$  : 平均  $\mu_0$ , 分散  $\sigma_0^2$  のガウス関数
- 全ての解の近傍解を考える  
合わせると  $\rightarrow p_0$  になるはず


$$\rightarrow \mu_1 - \mu_3 \simeq -(\mu_0 - \mu_1) \sigma_3^2 / (2\sigma_0^2)$$



## 話を整理するため概念を導入

元の解の評価結果を  $\mu_1$  としている  
近傍解の評価結果を  $f(s)$  とする


- 偏差 :  $D = \mu_0 - \mu_1$  (元の解の良さ)
- 近傍解改善量 :  $I = \mu_1 - f(s)$   
(近傍操作による改善量)



## 話を整理するため概念を導入

元の解の評価結果を  $\mu_1$  としている  
近傍解の評価結果を  $f(s)$  とする


- 偏差 :  $D = \mu_0 - \mu_1$  (元の解の良さ)
- 近傍解改善量 :  $I = \mu_1 - f(s)$   
(近傍操作による改善量)



## 話を整理するため概念を導入

元の解の評価結果を  $\mu_1$  としている  
近傍解の評価結果を  $f(s)$  とする

- 偏差 :  $D = \mu_0 - \mu_1$  (元の解の良さ)
- 近傍解改善量 :  $I = \mu_1 - f(s)$   
(近傍操作による改善量)




## 近傍解に関する定理

- **定理 1 : (分布モデルの成立が前提)**

偏差の分散が  $\sigma_D^2$ , 元の解の偏差が  $D$   
近傍解改善量の平均が  $\mu_I$ , 分散が  $\sigma_I^2$


$$\rightarrow \mu_I \simeq -\frac{\sigma_I^2}{2\sigma_D^2}D \quad \left( \begin{array}{l} D = \mu_0 - \mu_1 \\ \mu_I = \mu_1 - \mu_3 \end{array} \right)$$






## 近傍解に関する定理

- 定理 1 : (分布モデルの成立が前提)  
偏差の分散が  $\sigma_D^2$ , 元の解の偏差が  $D$   
近傍解改善量の平均が  $\mu_I$ , 分散が  $\sigma_I^2$   
$$\rightarrow \mu_I \simeq -\frac{\sigma_I^2}{2\sigma_D^2}D \quad \left( \begin{array}{l} D = \mu_0 - \mu_1 \\ \mu_I = \mu_1 - \mu_3 \end{array} \right)$$




## 近傍解に関する定理

- 定理 1 : (分布モデルの成立が前提)  
偏差の分散が  $\sigma_D^2$ , 元の解の偏差が  $D$   
近傍解改善量の平均が  $\mu_I$ , 分散が  $\sigma_I^2$   
$$\rightarrow \mu_I \simeq -\frac{\sigma_I^2}{2\sigma_D^2} D \quad \left( \begin{array}{l} D = \mu_0 - \mu_1 \\ \mu_I = \mu_1 - \mu_3 \end{array} \right)$$




## 近傍解に関する定理

- 定理 1 : (分布モデルの成立が前提)  
偏差の分散が  $\sigma_D^2$ , 元の解の偏差が  $D$   
近傍解改善量の平均が  $\mu_I$ , 分散が  $\sigma_I^2$   
 $\rightarrow \mu_I \simeq -\frac{\sigma_I^2}{2\sigma_D^2}D$        $\left( \begin{array}{l} D = \mu_0 - \mu_1 \\ \mu_I = \mu_1 - \mu_3 \end{array} \right)$




## 近傍解に関する定理

- 定理 1 : (分布モデルの成立が前提)  
偏差の分散が  $\sigma_D^2$ , 元の解の偏差が  $D$   
近傍解改善量の平均が  $\mu_I$ , 分散が  $\sigma_I^2$   
$$\rightarrow \mu_I \simeq -\frac{\sigma_I^2}{2\sigma_D^2}D \quad \left( \begin{array}{l} D = \mu_0 - \mu_1 \\ \mu_I = \mu_1 - \mu_3 \end{array} \right)$$



## 近傍解に関する定理

- 定理 1 : (分布モデルの成立が前提)  
偏差の分散が  $\sigma_D^2$ , 元の解の偏差が  $D$   
近傍解改善量の平均が  $\mu_I$ , 分散が  $\sigma_I^2$   
$$\rightarrow \mu_I \simeq -\frac{\sigma_I^2}{2\sigma_D^2}D \quad \left( \begin{array}{l} D = \mu_0 - \mu_1 \\ \mu_I = \mu_1 - \mu_3 \end{array} \right)$$



## 定理の意味

$$\mu_I \simeq -\frac{\sigma_I^2}{2\sigma_D^2}D$$

以下に理論的/定量的な説明を与える

- (経験的知識?)

解探索が進むと ( $D$ が大きくなると)

解を大きく変化させても

( $\sigma_I^2$ が大きい近傍操作を適用しても)

良い解が見つかる可能性は低い

( $\mu_I$ が小さい)

## 定理の意味

$$\mu_I \simeq -\frac{\sigma_I^2}{2\sigma_D^2}D$$

以下に理論的/定量的な説明を与える

- (経験的知識?)

解探索が進むと ( $D$ が大きくなると)

解を大きく変化させても

( $\sigma_I^2$ が大きい近傍操作を適用しても)

良い解が見つかる可能性は低い

( $\mu_I$ が小さい)

## 定理の意味

$$\mu_I \simeq -\frac{\sigma_I^2}{2\sigma_D^2}D$$

以下に理論的/定量的な説明を与える

- (経験的知識?)

解探索が進むと ( $D$ が大きくなると)

解を大きく変化させても

( $\sigma_I^2$ が大きい近傍操作を適用しても)

良い解が見つかる可能性は低い

( $\mu_I$ が小さい)



## 定理の意味

$$\mu_I \simeq -\frac{\sigma_I^2}{2\sigma_D^2}D$$

以下に理論的/定量的な説明を与える

- (経験的知識?)

解探索が進むと ( $D$ が大きくなると)

解を大きく変化させても

( $\sigma_I^2$ が大きい近傍操作を適用しても)

良い解が見つかる可能性は低い

( $\mu_I$ が小さい)

## 定理の意味

$$\mu_I \simeq -\frac{\sigma_I^2}{2\sigma_D^2}D$$

以下に理論的/定量的な説明を与える

- (経験的知識?)

解探索が進むと ( $D$ が大きくなると)

解を大きく変化させても

( $\sigma_I^2$ が大きい近傍操作を適用しても)

良い解が見つかる可能性は低い

( $\mu_I$ が小さい)

## 検証

- 実験

- 10,000 都市の巡回セールスマン問題
- 任意解生成 10,000 回  $\rightarrow \mu_0, \sigma_D^2$
- 3 つの解  $\rightarrow \mu_1, D = \mu_0 - \mu_1$   
それらに 2 つの近傍操作 10,000 回ずつ  
 $\rightarrow \mu_3, \sigma_I^2, \mu_I = \mu_1 - \mu_3, \alpha = -\frac{\sigma_D^2 \mu_I}{\sigma_I^2 D}$

- 結果

- 実際の分布はモデルとは異なる
  - $D$  や  $\mu_I$  が 2 桁異なっても  
 $\alpha$  は 0.40~1.16 (定理成立なら 0.5)
- $\rightarrow$  考え方は間違っていないだろう

# 検証

- 実験

- 10,000 都市の巡回セールスマン問題

- 任意解生成 10,000 回  $\rightarrow \mu_0, \sigma_D^2$

- 3 つの解  $\rightarrow \mu_1, D = \mu_0 - \mu_1$

それらに 2 つの近傍操作 10,000 回ずつ

$\rightarrow \mu_3, \sigma_I^2, \mu_I = \mu_1 - \mu_3, \alpha = -\frac{\sigma_D^2 \mu_I}{\sigma_I^2 D}$

- 結果

- 実際の分布はモデルとは異なる

- $D$  や  $\mu_I$  が 2 桁異なっても

$\alpha$  は 0.40~1.16 (定理成立なら 0.5)

$\rightarrow$  考え方は間違っていないだろう

# 検証

- 実験

- 10,000 都市の巡回セールスマン問題
- 任意解生成 10,000 回  $\rightarrow \mu_0, \sigma_D^2$
- 3 つの解  $\rightarrow \mu_1, D = \mu_0 - \mu_1$   
それらに 2 つの近傍操作 10,000 回ずつ  
 $\rightarrow \mu_3, \sigma_I^2, \mu_I = \mu_1 - \mu_3, \alpha = -\frac{\sigma_D^2 \mu_I}{\sigma_I^2 D}$

- 結果

- 実際の分布はモデルとは異なる
  - $D$  や  $\mu_I$  が 2 桁異なっても  
 $\alpha$  は 0.40~1.16 (定理成立なら 0.5)
- $\rightarrow$  考え方は間違っていないだろう

# 検証

- 実験

- 10,000 都市の巡回セールスマン問題
- 任意解生成 10,000 回  $\rightarrow \mu_0, \sigma_D^2$
- 3つの解  $\rightarrow \mu_1, D = \mu_0 - \mu_1$   
それらに 2 つの近傍操作 10,000 回ずつ  
 $\rightarrow \mu_3, \sigma_I^2, \mu_I = \mu_1 - \mu_3, \alpha = -\frac{\sigma_D^2 \mu_I}{\sigma_I^2 D}$

- 結果

- 実際の分布はモデルとは異なる
  - $D$  や  $\mu_I$  が 2 桁異なっても  
 $\alpha$  は 0.40~1.16 (定理成立なら 0.5)
- $\rightarrow$  考え方は間違っていないだろう

# 検証

- 実験

- 10,000 都市の巡回セールスマン問題
- 任意解生成 10,000 回  $\rightarrow \mu_0, \sigma_D^2$
- 3 つの解  $\rightarrow \mu_1, D = \mu_0 - \mu_1$   
それらに 2 つの近傍操作 10,000 回ずつ  
 $\rightarrow \mu_3, \sigma_I^2, \mu_I = \mu_1 - \mu_3, \alpha = -\frac{\sigma_D^2 \mu_I}{\sigma_I^2 D}$

- 結果

- 実際の分布はモデルとは異なる
  - $D$  や  $\mu_I$  が 2 桁異なっても  
 $\alpha$  は 0.40~1.16 (定理成立なら 0.5)
- $\rightarrow$  考え方は間違っていないだろう

# 検証

- 実験

- 10,000 都市の巡回セールスマン問題
- 任意解生成 10,000 回  $\rightarrow \mu_0, \sigma_D^2$
- 3 つの解  $\rightarrow \mu_1, D = \mu_0 - \mu_1$   
それらに 2 つの近傍操作 10,000 回ずつ  
 $\rightarrow \mu_3, \sigma_I^2, \mu_I = \mu_1 - \mu_3, \alpha = -\frac{\sigma_D^2 \mu_I}{\sigma_I^2 D}$

- 結果

- 実際の分布はモデルとは異なる
  - $D$  や  $\mu_I$  が 2 桁異なっても  
 $\alpha$  は 0.40~1.16 (定理成立なら 0.5)
- $\rightarrow$  考え方は間違っていないだろう



# 検証

- 実験

- 10,000 都市の巡回セールスマン問題
- 任意解生成 10,000 回  $\rightarrow \mu_0, \sigma_D^2$
- 3 つの解  $\rightarrow \mu_1, D = \mu_0 - \mu_1$   
それらに 2 つの近傍操作 10,000 回ずつ  
 $\rightarrow \mu_3, \sigma_I^2, \mu_I = \mu_1 - \mu_3, \alpha = -\frac{\sigma_D^2 \mu_I}{\sigma_I^2 D}$

- 結果

- 実際の分布はモデルとは異なる
- $D$  や  $\mu_I$  が 2 桁異なっても  
 $\alpha$  は 0.40~1.16 (定理成立なら 0.5)

$\rightarrow$  考え方は間違っていないだろう

# 検証

- 実験

- 10,000 都市の巡回セールスマン問題
- 任意解生成 10,000 回  $\rightarrow \mu_0, \sigma_D^2$
- 3 つの解  $\rightarrow \mu_1, D = \mu_0 - \mu_1$   
それらに 2 つの近傍操作 10,000 回ずつ  
 $\rightarrow \mu_3, \sigma_I^2, \mu_I = \mu_1 - \mu_3, \alpha = -\frac{\sigma_D^2 \mu_I}{\sigma_I^2 D}$

- 結果

- 実際の分布はモデルとは異なる
- $D$  や  $\mu_I$  が 2 桁異なっても  
 $\alpha$  は 0.40~1.16 (定理成立なら 0.5)


→ 考え方は間違っていないだろう

## 仮説を立て理由を考える

- 近傍解に関する仮説
- もし仮説が成立するのであれば
- 仮説からわかること
- なぜ単点探索ではうまくいかないのか？
- 多点探索がうまくいくメカニズムは？
- 多点である必要はあるのか？

## 近傍解に関する仮説


- 仮説 1 : 大規模な問題に対し  
近傍解改善量の平均  $\mu_I (< 0)$  は  
元の解の偏差  $D (> 0)$  と  
近傍解改善量の分散  $\sigma_I^2 (> 0)$  に  
概ね比例する



## 近傍解の分布モデルを描画してみる


$D (= \mu_0 - \mu_1)$  と  $\sigma_I^2$  を 3 通りずつ  
 $\times 2$ 、 $\times 4$  は  $\sigma_I^2$  が 2 倍、4 倍

- $D$  小  $\rightarrow \times 4$  の方が改善量大
- $D$  大  $\rightarrow \times 1$  の方が改善する確率大



もし仮説が成立するのであれば


$D$  に対して最適な  $\sigma_I^2$  があるだろう



もし仮説が成立するのであれば

$D$  に対して最適な  $\sigma_I^2$  があるだろう


- $D$  : 解探索が進むと大きくなる  
制御不可能



もし仮説が成立するのであれば

$D$  に対して最適な  $\sigma_I^2$  があるだろう


- $D$  : 解探索が進むと大きくなる  
制御不可能
- $\sigma_I^2$  : 近傍操作の方法次第  
ある程度制御可能！





## 仮説からわかること

- 大規模な問題では  $\sigma_I^2$  を制御すべき！
  - 探索の進行 ( $D$  の増大) に合わせて  $\sigma_I^2$  を 大  $\rightarrow$  小 とするしかない
- 解探索の効率には上限がある
  - $D$  に対して最適な  $\sigma_I^2$  を選び続ける



## なぜ単点探索ではうまくいかないのか？

(仮説の立場から言うと)

- 通常の単点探索法 (局所探索法等)  
近傍操作が 1 種類

→  $\sigma_I^2$  を制御できない

- $\sigma_I^2$  が小さい：  
大規模な問題では解探索が遅すぎる
- $\sigma_I^2$  が大きい：  
 $D$  が大きくなると解探索が止まる

## 多点探索がうまくいくメカニズムは？

(仮説の立場から言うと)

- 遺伝的アルゴリズムの交叉は  $\sigma_I^2$  が変化する近傍操作に相当？  
→  $\sigma_I^2$  が適応的に制御される
  - 2つの親個体が大きく異なっている場合  
→ 子個体も大きく異なる  
 $\sigma_I^2$  が大きい近傍操作に相当？
  - 2つの親個体が小さく異なっている場合  
→ 子個体も小さく異なる  
 $\sigma_I^2$  が小さい近傍操作に相当？

## 多点である必要はあるのか？

(仮説の立場から言うと)

- $\sigma_I^2$  を調整すれば良いのでは？
  - 例えば  $\sigma_I^2$  を制御する  
局所探索法はいかがでしょう？
  - 例えば  $\sigma_I^2$  と温度  $T$  を制御する  
Simulated Annealing はいかがでしょう？

## まとめ

- 組合せ最適化問題における暗黙の仮定を明確化
- 近傍操作に関するモデルを構築、定理を導出・検証、仮説を提案
- 最適化手法について考察
  - $\sigma_I^2$  を制御すれば良いのでは？