

## 学習対象の性質解析による学習アルゴリズムの研究

疋田 聡

hikita@flab.fujitsu.co.jp

富士通研究所ヒューマンインタフェース研究部

### 概要

近年、さまざまな学習アルゴリズムが用いられるようになってきたが、学習アルゴリズムと学習対象の性質とが合わないと効果的な学習ができない。

そこで本研究では、学習アルゴリズムで利用する学習対象の性質の測定と解析を行った。一つ目として、遺伝的アルゴリズムにおける巡回セールスマン問題の性質を、近傍構造とモジュール構造の面から測定した。二つ目に、山登り学習における動作学習ロボットの性質を荷重と評価値空間を測定し、ウェーブレット解析を行った。

その結果、①遺伝子コード化方式と近傍構造の関係②遺伝子長とモジュール構造の関係③ロボットの動作と不連続性に関する測定値が得られた。

このような方法により、学習アルゴリズムの理解が深まると考えている。

## Research of Learning Algorithm by Object Properties Analysis

Satoshi HIKIDA

hikita@flab.fujitsu.co.jp

Fujitsu Laboratories LTD. Human Interface Laboratory

### Abstract

Recently, many learning algorithm has been using. But it cannot work effective if learning algorithm and object properties don't match.

Therefore we measured the object properties, and analyzed them. First, we measured properties of the travelling salesperson problem in genetic algorithm. The properties were the neighborhood structure and the module structure. Second, we measured properties of the learning robot in hill-climbing algorithm. And we analyzed them by wavelets analysis.

We got three results, ①the relationship of genetic coding to neighborhood structure ②the relationship of gene length to module structure ③the relationship of robot action to discontinuity.

This method helps to understand learning algorithm.

## 1. はじめに

近年、遺伝的アルゴリズム、ニューラルネットワーク、強化学習などのさまざまな学習アルゴリズムが用いられるようになってきた。しかし、教科書に載っている問題はうまく解けても、自分が抱えている問題に適用しても必ずしもうまくいかないことが多い。

なぜうまくいかないのかを理解するため、学習アルゴリズムを、二つの側面に分けて考える。一つは、統計的な解析の技術としての側面であり、もう一つは、学習対象の性質の適切な利用技術という側面である。統計的解析技術の例としては、遺伝的アルゴリズムにおけるスキーマ定理[1]などがある。また、学習対象の性質利用技術の例としては、山登り法[2]における学習パラメータ超平面の凸性の利用、遺伝的アルゴリズムにおける遺伝子コード化や交叉オペレータの工夫[3]などがある。統計的解析技術は対象から独立して開発可能であり、学習対象の性質利用技術は対象を調査して開発する必要がある。この学習アルゴリズムにおける性質利用の側面と学習対象の性質とが合わないと効果的な学習ができないと考えられる。

そこで本研究では、学習アルゴリズムにおける性質利用の側面と学習対象の性質との関係を調べるための第一歩として、学習アルゴリズムで利用する学習対象の性質の測定と解析を行った。一つ目として、遺伝的アルゴリズムにおける巡回セールスマン問題の性質を、近傍構造とモジュール構造の面から測定した。二つ目に、山登り学習における動作学習ロボットの性質を荷重と評価値空間を測定し、ウェーブレット解析を行った。

## 2. 巡回セールスマン問題の性質の分析

まず始めに、学習対象の性質分析のサンプルとして、遺伝的アルゴリズムにより巡回セールスマン問題を解く場合を調べてみる。遺伝的アルゴリズムにおける学習能力は、突然変異と交叉の二つの機能によって得られている。突然変異は局所的な探索能力と遺伝子パターンの多様性の維持に役立っている。また、交叉はスキーマ定理を通じて、適応度の高いスキーマを生成してこれらをうまく組み合わせることで効率的に探索を行うこと（積み木仮説）に役立っていると考えられる[1,4]。

### 2.1. 近傍構造の測定、分析

突然変異の局所的な探索能力は、近い場所に近い値の密度が高いという性質を利用していると考えられるので、学習対象の性質として遺伝子コードの近傍構造を調べることにする。

#### 2.1.1. 測定方法

遺伝子型へのコード化の違いにより、どのような性質の違いが出てくるかを見るために、都市の順列をそのまま用いるコードと Grefenstette のコードの二つを用いて測定し、比較してみた。

Grefenstette のコード化の方法は、都市を適当な順序で並べたリストから訪問する都市を選択し、その都市のリスト中での位置を遺伝子型での値とし、選択した都市を元のリストから取り除いて同様の操作をリスト中の都市がなくなるまで行うことにより遺伝子型を得る方法である。この方法は、多点交叉が可能であり、交叉演算子の設計自由度が高いという特徴がある[4]。

近傍構造を測定、分析するために次のように距離を定義する。

都市の順列をそのまま用いるコードでの距離は、図1のように2点で切断して繋ぎかえる操作により距離を定義する。この操作を一回行うと距離1となる。




図1 距離1の操作

Grefenstette コードでの距離は、遺伝子コード中から1点をランダムに選択し、その点で可能な値の範囲内でランダムに変更する操作により定義する。

測定条件は、都市の数は16都市、都市のxy座標は0以上1.0未満でランダムに設定、評価値は(都市数÷巡回路長)で行った。

サンプル方法は、まず基準となる遺伝子をと、基準遺伝子から距離1となる遺伝子をランダムにサンプリングを行う。今回は、基準となる遺伝子を評価値2.0に取ったものと3.0に取ったものの二つを用意し、それぞれサンプル数10000で行った。

### 2.1.2. 測定結果

図2は、そのままのコード化の測定結果グラフである。




図2 そのままのコード近傍/評価値分布

このグラフでは、2.0を基準とした分布では基準点を中心としてほぼ対称に分布しているが、3.0を基準とした分布では3.0の度数が最も多くなっている点の左側に分布の崩れが見られる。これは評価値の高い点を中心とした分布が平均的な分布に引きずられるために起こると考えられる。

次に図3に Grefenstette コードでの測定結果を示す。




図3 Grefenstette コード近傍/評価値分布

このグラフでは、3.0を基準とした分布において先のそのままのコードでの測定結果より大きな崩れが見られる。これから、Grefenstette コードは、交叉設計の自由度が高いという性質の反面、評価値の近傍分布構造の保存性がそのままのコードに比較すると悪いという性質を持っていると考えられる。

さらによく比較するために先の二つのグラフを重ね合わせたものを図4に示す。




図4 近傍/評価値分布の比較

二つの分布を比較すると、評価値が3.0の点よりも大きい部分の面積がそのままのコードの方が大きいことが読み取れる。これから、Grefenstette コードよりもそのままのコードの方が山登り法的な処理においては、基準遺伝子より高い評価値の遺伝子が見つかる確率が高く、学習の進行速度が速いと考えられる。

このように、近傍構造を比較することにより、突然変異による山登り的な側面が学習対象によってどのくらい寄与するかを測定することができる。

## 2.2. モジュール性の測定、分析

交叉の積み木仮説のような働きは、遺伝子コードの一部が部品として働くような性質を利用しているため、学習対象の性質として遺伝子の部分コードのモジュール性を調べることにする。

### 2.2.1. 測定、分析方法

交叉の学習効率への寄与度は、そのために部分コードのモジュール性を測定する。ここでモジュール性とは、外部の変化に対してモジュールの評価値があまり影響を受けず、内部の変形に対しては外部環境にかかわらず同じようなモジュールの評価値の変化をするという性質と定義しておく。




図5 遺伝子リスト中のモジュール

測定条件は、都市の数は 16 都市、都市の xy 座標は 0 以上 1.0 未満でランダムに設定、評価値は (都市数 ÷ 巡回路長) であり、モジュール部分の都市の数は 5 都市と 4 都市で行った。

モジュール部分の変形はモジュール内都市の全ての順列パターンについて評価値を測定し、それを一つのベクトルとみなしている。

同一モジュールの測定では、モジュール部分を同一にしてその他の部分をランダムに設定したものを作り、それぞれについて上記のモジュール部分の変形を行い変形評価値のベクトルを得た。これをモジュール以外の部分を毎回ランダムに設定しながら 8 回測定した。

比較のためにモジュール部分をランダムに作った遺伝子間の測定も行った。異なるモジュールの測定では、上記の 8 回の操作において、1 回毎にモジュール部分もランダムに設定して行った。

相関係数は、8 個の変形/評価値ベクトルそれぞれの間で計算した。

### 2.2.2. 測定、分析結果

図 6 に、モジュール部分が 5 都市の場合のモジュール変形と評価値の関係を示す。




図 6 モジュール長 5 の変形/評価値グラフ

このグラフより、同一モジュールと異なるモジュールでは、明らかに同一モジュールの方が相関係数が大きく類似性が高いことがわかる。

また、相関係数の平均値をとると、同一モジュール間では 0.75、異なるモジュール間では 0.058 となった。

モジュール部分の長さがモジュール変形と評価値の関係にどのような影響を与えるか比較するため図 7 に、モジュール部分が 4 都市の場合の測定値を示す。




図 7 モジュール長 4 の変形/評価値グラフ

5 都市と同様に相関係数の平均値をとると、同一モジュール間では 0.34、異なるモジュール間で 0.0022 となり、5 都市に比べて 4 都市の場合は、相関係数が低くなっている。これは、モジュール部分とその他の部分の接続をモジュールのインタフェースと捉えたと、モジュール長が短くなるとモジュール以外の部分の変動に影響されるインタフェース部分の寄与が大きくなるためと考えられる。

このように、同一のモジュールのモジュール変形に対する評価値の類似性と異なるモジュールにおける類似性の測定結果を比較すると、巡回セールスマン問題におけるモジュール性という性質が見えてくる。

巡回セールスマン問題におけるモジュール性は部分パスの構造から考えて自明に近いが、モジュール性が分かりづらい問題においては有効であると考えられる。

## 3. 動作学習ロボットの性質の測定、分析

巡回セールスマン問題には多くも研究があるので、上記の性質の測定、分析が自明に感じられるかもしれないので、より自明でないものとして動作学習ロボットの測定、分析を行った。

このロボットは、図 8 のように 4 個のノードと 3 本のリンクからなる構造をしており、ロボットが制御するのは二つの角度  $\theta_0$  と  $\theta_1$  である。評価値は、右方向へ動くスピードにより決まる。




図 8 動作学習ロボットの構造

それぞれの角の動きは、以下のような周期関数の足し合わせにより近似し、各周期関数にかかる荷重  $w$  を変化させて学習を行う。1 周期は 20 分割してシミュレーションする。

$$\theta_i = \sum_j w_{i,j} x_j(t) \quad (i = 0, 1)$$

$$x_0(t) = 1$$

$$x_1(t) = \sin(\omega t)$$

$$x_2(t) = \cos(\omega t)$$

$$x_3(t) = \sin(2\omega t)$$

$$x_4(t) = \cos(2\omega t)$$

荷重  $w$  の学習方法は初期値をランダムに決め、そこからの山登り法で行う。

さらに詳細については参考文献[5]を参照。

### 3.1. 荷重と評価値の関係の測定

この動作学習ロボットにおいて、荷重と評価値の関係を測定した。

まず始めに、荷重の初期値をランダムに設定した点の近傍での測定グラフを示す。

このグラフは、10 個の荷重  $w$  の中から 1 個を選んで、-2.0 から 2.0 まで変化させて、そのときの評価値を測定したものである。すなわち、10 個の荷重変数と 1 個の評価値で作られる 11 次元空間中の超平面を、ある 1 個の変数の軸に沿って切った切断面を表している。




図 9 初期状態の荷重/評価値グラフ

図 9 では、あまり大きな変化はみられないが、ぎざぎざとした細かな変動がみられることがわかる。

次に、ある程度学習が進んだ状態の荷重と評価値の関係のグラフを示す。




図 10 学習進行状態の荷重/評価値グラフ 1

このグラフでは、0 付近と -0.8 付近に二つの山がみられ面白い形状を示している。

学習が進んだパターンについても一つ別のものを見てみる。




図 11 学習が進行状態の荷重/評価値グラフ 2

このグラフでは、0.0 から 1.0 の間で不連続な変化が見られる。この状態を実際の動きで見ると、動作が最適なバランスを越えてしまつて逆向きに進むような動きをしている。すなわち、動作の最適化を行った結果、バランスを崩しぎりぎりのところに最適点があったのだと考えられる。このように、不連続面の縁に最適点があるというような性質は、リアルワールドの学習対象でもよく見られる性質であろうと予想される。

### 3.2. ウェーブレットによる解析

上記測定値をより詳しく解析するためにウェーブレット解析を行った。ウェーブレット解析には Daubechies8 を使用した。ウェーブレット解析の詳細については参考文献[6]を参照。

図 11 の測定値をウェーブレット解析したものを示す。ただし、グラフを見やすくするためにレベル-2,-3,-4のみをプロットした。

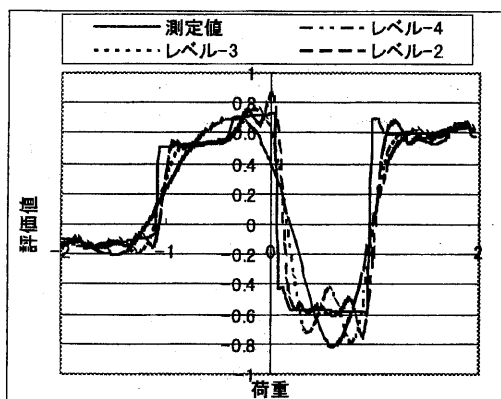


図 12 荷重/評価値のウェーブレット解析

ウェーブレット解析の結果の利用方法として、大まかな近似により、概形を掴むのに使用することなどが考えられる。

### 3.3. ウェーブレットによる不連続性検出

図 10,11 などの測定結果より、荷重変数と評価変数の作る超平面は不連続構造を持ち、また、最適値はその不連続構造と関係が強いと考えられる。そこで、ウェーブレット解析を使って不連続性の検出を行った。

ウェーブレット解析による不連続性の検出は、ウェーブレット分解したときの差分部分係数の高周波成分にピーク値が現れることにより検出できる。

図 11 の測定値に対してウェーブレット解析による不連続性検出を行ったグラフを示す。




図 13 ウェーブレット解析による不連続性検出

このグラフでは、-1.0,0.2,1.0 の付近にピーク値が現れており、この付近に不連続性があると推測される。

このような不連続性検出の応用として、ウェーブレット解析により検出された不連続面を利用して領域を分割し、離散的な学習をするために強化学習などを適用することなどが考えられる。

## 4. まとめ

本研究では、一つ目に遺伝的アルゴリズムにおける巡回セールスマン問題の性質を測定した。評価値/近傍分布の測定では、Grefenstette コードは、そのままのコードに比べ近傍分布に大きな崩れがあり、交叉設計の自由度が高いという性質の反面、評価値の近傍分布構造の保存性が比較的悪いという性質を持っていた。モジュール構造に関する測定では、5 都市に比べて 4 都市の場合は、モジュール長が短くなるためモジュール以外の部分の変動に影響される部分の寄与が大きくなるのが分かった。二つ目に、山登り学習における動作学習ロボットの性質を測定した。不連続な変化が見られ不連続面の縁に最適点があるという性質があった。また、ウェーブレット解析によりこのような不連続構造を見つけることができた。

このような学習対象を解析してみると学習アルゴリズムの理解が深まる。そして今後、学習対象の研究を進めることにより、性質の測定、分析から学習アルゴリズムの適用範囲の選定、複数アルゴリズムの系統だった使い分けに役立つと考えている。

## 5. 参考文献

- [1]Melanie Mitchell: “遺伝的アルゴリズムの方法”,東京電機大学出版局,1997.
- [2]Stuart J. Russell, Peter Norvig: “エージェントアプローチ人工知能”,共立出版,1997.
- [3]北野宏明: “遺伝的アルゴリズム”,産業図書,1993.
- [4]電気学会 GA 等組合せ最適化手法応用調査専門委員会: “遺伝アルゴリズムとニューラルネット”,コロナ社,1998.
- [5]中野馨: “Cでつくる脳の情報システム”,近代科学社,1995.
- [6]榊原進: “ウェーブレットビギナーズガイド”,東京電機大学出版局,1995.