

進化論に基づくニューラルネットワークの 構造適応学習アルゴリズムの構成

大 枝 真 一[†] 市 村 匠^{††} 寺 内 睦 博^{†††}
高 濱 徹 行^{††} 磯 道 義 典^{††}

工学的側面から GA とニューラルネットワークの融合に関する研究がなされてきたが、学習期間中に教師信号に変化が及ぶ、“動的性質”を持つ実験環境上での議論が乏しいのが現状であった。そこで本論文では、自然界の生物が進化と学習によって様々に変化する環境に適応する過程を模倣した、進化論に基づく構造適応学習アルゴリズムを提案する。提案する手法は、学習中に教師信号に変化が及んだ場合でも、学習を初期状態から行うのではなく、ネットワーク構造や結合荷重ベクトル、学習パラメータ値の継承を考慮する適応的な学習を可能とするものである。提案した手法の有効性を検証するために、1 変数関数の同定および 10 bits 問題に適用した結果をここに報告する。

A Synthesis of Structural Adaptive Learning Algorithm in Neural Network Based on the Theory of Evolution

SHINICHI OEDA,[†] TAKUMI ICHIMURA,^{††} MUTSUHIRO TERAUCHI,^{†††}
TETSUYUKI TAKAHAMA^{††} and YOSHINORI ISOMICHI^{††}

From the point of view of engineering, many researchers have been engaged in the combination of neural networks and genetic algorithms. However, their discussion has been limited to an environment of fixed training data during learning phase. In this paper, we propose a structural adaptive learning algorithm in neural network based on the theory of evolution. Our proposed method imitates the processes that living things adapt their structures according to the various of environments by evolution and learning. In this method, once teaching data change during learning under dynamic environments, the learning doesn't start to train from the initial state again. This method is useful for adaptive learning which can take into account inheritance of the network structure, the connection weights vector, and the learning parameters. To verify the effectiveness of our proposed method, we applied the method to an identification of a Gauss function and a 10 bits problem where an output is determined according to 10 input signals in an environment.

1. はじめに

自然界の生物は環境の変化に適応しながら生存している。そこでは生物である各個体が環境との相互作用をもとに学習を行い、生存に有利に働く行動を選択している。その生物の持つきわめて柔軟な適応能力に着想を得て、その生物学的知見をコンピュータ上で実現

する理論的研究がなされてきた。なかでも学習と進化に関する研究はさかに行われている。

たとえば、ニューラルネットワークの学習法として BP (Back Propagation) 学習や GA (Genetic Algorithms) は広く知られている。BP 学習では、ネットワークに入出力のペアとなる教師信号ベクトルが繰り返し与えられ、期待される値を出力するように訓練される。また、GA は生物進化の原理に着目したアルゴリズムであり、学習・最適化の一手法であると考えられている。

ところで工学的側面から、局所探索を行う BP 学習と大域サンプリングを中心とした手法である GA を相互補完的なものとしてとらえ、2 つの手法を融合した研究がなされている。Whitely ら¹⁾や Montana ら²⁾は、GA を用いたニューラルネットワークのトレーニング

[†] 東京都立科学技術大学大学院工学研究科
Graduate School of Engineering, Tokyo Metropolitan
Institute of Technology

^{††} 広島市立大学情報科学部
Faculty of Information Sciences, Hiroshima City
University

^{†††} 広島国際大学人間環境学部
Faculty of Human Environmental Studies, Hiroshima
International University

を行っている。どちらの研究においても、ニューラルネットワークの各結合荷重を1次元で表された染色体の遺伝子として符号化している。このとき Whitely らは二値表現を、Montana らは実数値表現をとっている。GA によるニューラルネットワークのトレーニングには、遺伝子表現からニューラルネットワークの結合荷重へ復号化し、そのネットワークの平均二乗誤差の逆数を適合度として用いている。そして、遺伝的作用素である、選択、交叉、突然変異を施し、次世代の子を生成する。Kitano はニューロジェネティックラーニング理論³⁾を提唱し、グラフ生成文法を用いて染色体からニューラルネットワークを生成する文法エンコード法を提案している。また、生物学的側面からでは、Ackley ら⁴⁾がニューラルネットワークの出力に応じて行動を決定するエージェントを定義し、それらが2次元格子平面状の人工世界に配置されるシミュレーション実験を行っている。実験における人工世界では、餌、捕食動物、隠れ場所などが存在する。各個体は、“動作ネットワーク”と“評価ネットワーク”と呼ばれる2つのニューラルネットワークを持つ。エージェントの遺伝子型は、これら2つのニューラルネットワークの結合荷重を符号化したビット列である。エージェントの生涯において、評価ネットワークの結合荷重は固定である。しかし、動作ネットワークの結合荷重は、評価ネットワークから正か負の信号を受け取ると、強化学習によって修正される。エージェントは交叉を行い、子孫を残す。このとき学習によって修正された動作ネットワークの結合荷重は遺伝子型に符号化されない。これは自然界の生物が、親の学習した結果を子へ遺伝することがないという考えを再現しようとしたものである。

ここで、入力データに対し教師信号がつねに一定である訓練事例を“静的環境”とし、逆に入力データに対し教師信号が変化する訓練事例を“動的環境”としたとき、前述の研究のほとんどが“静的環境”で評価されているにすぎず、“動的環境”での議論が乏しいのが現状である。

実世界のように、様々な要因が複雑に絡み合うことで動的な挙動を示す環境において、未知の事象に対して正しく動作するシステムを構築することは困難である。先に述べた動的環境を扱った問題に対しては、環境に応じてシステムを短時間で修正するアプローチが有効であると考えられる。動的環境と時系列データとの違いは、時系列データは過去から現在までのデータに見られる時系列性を学習し、未来のデータを予測することに対し、我々が扱う動的環境は過去のデータに

影響を受けないものとする。

動的環境におけるエージェントの進化と学習のシミュレーション実験として、佐々木らの研究がある^{5),6)}。ここでは進化論からの類推に基づき、個体における生涯での「学習」と、集団における世代をまたいだ「進化」といった、2つの異なる適応過程を相互補完的なものとしてとらえ、「学習」にはBP学習、「進化」にはGAを適用し、モデル上でのシミュレーション評価を行う研究がなされている。特にダーウィン型とラマルク型と呼ばれる2種類の遺伝機構を提案している。文献5),6)では、この2つの遺伝機構の違いから静的および動的環境への適応性を調査するための実験が行われている。その結果より静的環境ではラマルク型、動的環境ではダーウィン型に優れた適応性があると述べている。

また、山崎⁷⁾らは、ラマルク型とダーウィン型との集団で適応過程に違いが生じるメカニズムを考察している。ここでは、環境変化の速度と進化および学習の速度を比較し、環境変化の速度が学習と進化の速度の中間にある場合、ダーウィン型には動的環境に対して優れた適応性があると述べている。

これらのシミュレーション実験では、隠れニューロンの数や、学習パラメータ値を設計者の経験に基づいて決定していた。さらに、集団内の各個体のネットワークは同一構造であり、全世代を通じて隠れ層数や隠れニューロン数は固定であった。

ところが進化論では、生物が進化の過程で形態を様々なに変化させることで、環境に適応していったことが知られている。本論文では、ネットワーク構造や結合荷重ベクトル、そして学習パラメータ値を環境の変化に応じて決定する手法を提案する。この提案手法を「進化論に基づいた構造適応学習アルゴリズム」と呼ぶ。

以下、2章では、ラマルク型、ダーウィン型の遺伝機構に関する研究例について述べる。3章では、進化論に基づく構造適応学習アルゴリズムについて述べる。4章、5章では、1変数関数の同定および10bits問題に対して提案した手法を適用した実験を行い、その結果について考察する。最後に6章でまとめを行う。

2. GA によるニューラルネットワークの進化

進化をめぐる論争は現在でもさかんに行われている。その中でも、生物が生存中、学習によって得た知識を獲得形質と呼び、それが遺伝すると唱えるラマルクの進化論がある。また、逆に獲得形質は遺伝しないと唱えるダーウィンの進化論が存在する。分子遺伝学から、ラマルクの進化論は否定されており、現在の進化論の

主流はダーウィンの進化論となっている⁸⁾。

生物の環境への適応には2つの側面がある。それは、「生涯内に行われる個体レベルでの学習」という適応と「世代をまたぐ集団レベルでの進化」という適応である。

遺伝情報が保存されているDNAには、生物個体が生存中に獲得した形質を符号化して保存するメカニズムが発見されていない。このため学習を通じて得られた知識は、次世代へ遺伝的に継承されることはないというのが生物学者の見解である。この見解は、学習が進化に対し影響を及ぼさないことを意味する。

しかしながら、環境が静的であれば、すなわち生存に必要な知識が不変である環境では、改めて学習を行うよりも、あらかじめ学習済みの状態で生まれてくる方が有利であると考えるのが必然的であろう。一方、環境が動的であれば、すなわち生存に必要な知識が変化する環境では、先代の学習した知識は有効ではなく、その個体が生存中におかれた環境に適した知識を獲得した方がよいと考えられるであろう。

佐々木らは、獲得形質が遺伝するラマルク型と、獲得形質は遺伝しないダーウィン型と呼ばれる2つの遺伝機構を提案し、静的および動的環境でのシミュレート実験を行った^{5),6)}。そこでは、集団内の各個体はニューラルネットワークで構成されており、BP学習により結合荷重ベクトルを修正する。次に、学習後の個体を評価し、適合度を割り当て、親を決定する。そして、ラマルク型およびダーウィン型の集団は、それぞれの遺伝機構に従って、GAの遺伝的操作が加えられる。つまり、図1に示すラマルク型の個体では、学習により修正された結合荷重ベクトルが次世代へそのまま遺伝する。一方、図2に示すダーウィン型では、修正された結合荷重ベクトルを次世代へ伝えることはない。つまりダーウィン型は、自分が誕生したときの遺伝子を次世代の子を作る際の遺伝子としてGAの遺伝的操作を行うものである。ただし、ダーウィン型においても学習によって修正された結合荷重に基づいて親を決定しているため、間接的には学習の影響を受けている。佐々木らのシミュレーション実験では、個体を構成するニューラルネットワークの構造は、設計者が初期世代で与えたものであり、環境の変化に応じて、その構造に変化を及ぼす手法を用いていなかった。

本論文では、「生物が進化途上で様々な形態に変化させることで環境に適応する」という進化論の仮説に着眼した。現在、地球上に存在する生物は、長い年月を経て単細胞生物から多細胞生物へと進化し、その進化過程の中で徐々に形態を変えてきた。その歴史のなか

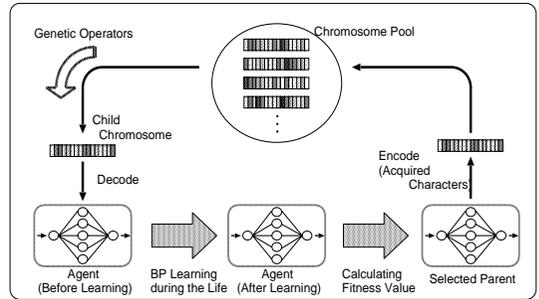


図1 ラマルク型の遺伝機構^{5),6)}

Fig. 1 Hereditary mechanism of Lamarckian type.

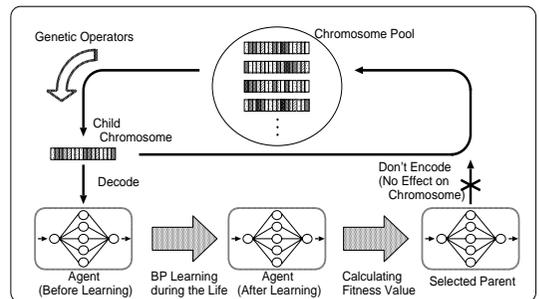


図2 ダーウィン型の遺伝機構^{5),6)}

Fig. 2 Hereditary mechanism of Darwinian type.

で、陸上に進出した両生類や、空を舞う鳥類など多様な生物が出現した。本論文では、このような生物の進化過程における形態の変化を、ニューラルネットワークで形成されるネットワーク構造の変化としてとらえ、ニューラルネットワークの結合荷重ベクトルのみならず、そのネットワーク構造もGAによって探索する。

3. 構造適応学習アルゴリズム

本論文では、ニューラルネットワークの結合荷重ベクトルをBP学習により更新し、学習パラメータ値およびネットワーク構造をGAにより探索する。特に動的環境において、適応的に構造を変化させる手法を提案する。

3.1 GA (遺伝的アルゴリズム)

ニューラルネットワークの学習に影響を与えるパラメータとして、隠れ層数、各隠れ層のニューロン数、結合荷重ベクトル、学習係数、シグモイド関数の傾き、慣性係数が考えられる。訓練事例を再現する空間を構築するために、ネットワークのパラメータの組合せが重要な問題となる。この問題のために、最適化手法の1つであるGAを用い、ネットワーク構造や学習パラメータ値を決定する方法が提案されている^{9),10)}。本論

表 1 ニューラルネットワークの学習パラメータ値
Table 1 Learning parameters of neural network.

η	$0.0 < \eta \leq 1.0$	$\eta \in R$
ε	$0.0 < \varepsilon \leq 1.0$	$\varepsilon \in R$
α	$0.0 \leq \alpha \leq 1.0$	$\alpha \in R$
n_k	$2 \leq n_k \leq 20$	$n_k \in N$
h	$1 \leq h \leq 3$	$h \in N$

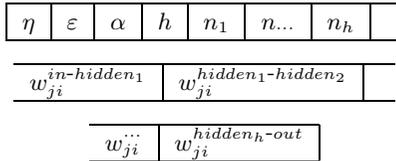


図 3 遺伝子型
Fig. 3 Genotype.

文では GA により、隠れ層数 h 、各隠れ層のニューロン数 $n_k(k = 1, \dots, h)$ 、結合荷重ベクトル W 、学習係数 η 、シグモイド関数の傾き ε 、慣性係数 α を探索する (表 1)。

3.1.1 遺伝子型

図 3 のように、遺伝子型には、BP 学習で用いる学習パラメータ値とネットワーク構造および結合荷重を持ち、1 つのネットワークに含まれる情報を 1 つの個体の遺伝子型として定義する。したがって、遺伝子には学習パラメータ値として $\eta, \varepsilon, \alpha$ がある。また、隠れ層数を h 、各隠れ層のニューロン数を n_k とし、各層間の結合荷重は $w_{ji}^{s(s+1)}$ として、それぞれ遺伝子として持つ。ここで、 s は階層を示す。また、各遺伝子のとりうる値は実数値とした。

初期個体の各遺伝子の値は乱数で決定する。 $\eta, \varepsilon, \alpha$ は、区間 $[0.0, 1.0]$ で実数乱数値を与える。 h は区間 $[1, 3]$ 、 n_k は区間 $[2, 20]$ で整数乱数値を与える。各層間の結合荷重 $w_{ji}^{s(s+1)}$ は、区間 $[-1.0, 1.0]$ で実数乱数値を与える。

また、 $\eta, \varepsilon, \alpha$ が負の値をとったときは、その遺伝子を致死遺伝子とする。さらに、隠れニューロンの数が 1 個の層では、ニューラルネットワークの性質上、線形分離しできないため、 n_k が 1 以下の値をとったとき、致死遺伝子とする。これら各パラメータ値のとりうる値の範囲を表 1 に示す。

3.1.2 遺伝的操作

本論文で用いる遺伝的操作について述べる。

3.1.2.1 選択

全個体を、適合度の高い上位 10% の個体と、残り 90% の個体に分ける。

適合度の高い上位 10% の個体は、交叉、突然変異の操作を行わず、次世代へ残すエリート戦略を用いた。

表 2 局所突然変異
Table 2 Local mutation.

$\{\eta, \varepsilon, \alpha\} \leftarrow \{\eta, \varepsilon, \alpha\} + r_1$	$-0.1 \leq r_1 \leq 0.1$	$r_1 \in R$
$n_k \leftarrow n_k + r_2$	$-5 \leq r_2 \leq 5$	$r_2 \in Z$
$h \leftarrow h + r_3$	$-1 \leq r_3 \leq 1$	$r_3 \in Z$
$w_{ji}^{s(s+1)} \leftarrow w_{ji}^{s(s+1)} + r_4$	$-1.0 \leq r_4 \leq 1.0$	$r_4 \in R$

表 3 大域突然変異
Table 3 Global mutation.

$\{\eta, \varepsilon, \alpha\} \leftarrow r_5$	$0.0 \leq r_5 \leq 1.0$	$r_5 \in R$
$n_k \leftarrow r_6$	$2 \leq r_6 \leq 20$	$r_6 \in N$
$h \leftarrow r_7$	$1 \leq r_7 \leq 3$	$r_7 \in N$
$w_{ji}^{s(s+1)} \leftarrow r_8$	$-5.0 \leq r_8 \leq 5.0$	$r_8 \in R$

これは、適合度の高い個体が、交叉や突然変異によって破壊されることを避けるためである。

残り 90% の個体では、各個体の適合度に比例した確率で選択する手法とされるルーレット選択を用いて、交叉する親 2 個体を選択した。

3.1.2.2 交叉

交叉には各遺伝子ごとに交叉する一様交叉を用いた。2 つの親の各遺伝子ごとに、交叉率 P_c で親 1 と親 2 の遺伝子を入れ替えて 2 つの子を作る。

3.1.2.3 突然変異

交叉後の子個体に突然変異率 P_m で突然変異を行う。また、大域突然変異と局所突然変異を定義し、それぞれ $P_m/2$ の確率で突然変異を行う¹⁰⁾。局所突然変異は、遺伝子に微小振動の幅で変異を加えることを目的としており、探索空間内の現在点の近傍で変異する。一方、大域突然変異は、局所突然変異の範囲を越えた変異を目的としており、大きく探索空間を広げることが可能である。局所突然変異、大域突然変異は表 2、3 で与えられる。

突然変異を行った後、生成した個体が致死遺伝子を持つ場合、その個体を集団から排除する。

3.2 情報量基準 AIC に基づく適合度関数

ここでの GA による探索は、環境に適したネットワーク構造を探索することにほかならない。したがって、ネットワーク構造の優劣に応じた適合度を割り当てる必要がある。そこで、ネットワーク構造を評価するために情報量基準 AIC を用いる^{11)~13)}。

3.2.1 情報量基準 AIC によるニューラルネットワーク評価

AIC は対数尤度の期待値を、訓練データから計算される平均対数尤度に基づいて推定する。

対数尤度を l 、自由パラメータ数を F としたとき、AIC は式 (1) で与えられる。

$$AIC = -2l + 2F \tag{1}$$

評価対象となるニューラルネットワークの入力層のニューロン数を M , 出力層のニューロン数を K とする .

このネットワークの結合荷重は式 (2) で表される数だけ存在する .

$$Mn_1 + \sum_{a=1}^{h-1} n_a n_{a+1} + n_h K \quad (2)$$

また、閾値も式 (3) で表される数だけ存在する .

$$\sum_{a=1}^h n_a + K \quad (3)$$

したがって、 F は式 (4) となる .

$$F = \left(Mn_1 + \sum_{a=1}^{h-1} n_a n_{a+1} + n_h K \right) + \left(\sum_{a=1}^h n_a + K \right) \quad (4)$$

BP 学習は、平均二乗誤差を最小とするようなニューラルネットワーク内部の結合荷重空間を決定すると考えられる . このために、最急降下法を用いて結合荷重の修正量を求める方法により履行されている . したがって、AIC をニューラルネットワークの評価として用いるために、最尤推定の観点から考察する .

教師信号ベクトル t_p とニューラルネットワークの出力 z_p との誤差 $e_p = t_p - z_p$ が、互いに独立な正規分布 $N(0, \sigma^2 M)$ に従うとする . ここで、 P は教師信号の総数、 p は教師信号の番号、 σ は分散を示している . このとき、訓練データ集合に対する教師信号と、ニューラルネットワーク出力の誤差の尤度は、式 (5) となる¹²⁾ .

$$L = \prod_{p=1}^P (2\pi\sigma^2)^{-\frac{K}{2}} \exp \left\{ -\frac{1}{2\sigma^2} e_p^t e_p \right\} \quad (5)$$

したがって、その対数尤度は式 (6) となる .

$$l = -\frac{KP}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{p=1}^P e_p^t e_p \\ = -\frac{KP}{2} \log(2\pi\sigma^2) - \frac{1}{\sigma^2} E(\mathbf{W}) \quad (6)$$

ここで、

$$E(\mathbf{W}) = \sum_{p=1}^P (t_p - z_p)^2 \quad (7)$$

とする .

l を最大にすることは、式 (6) の第 2 項 $E(\mathbf{W})$ を最小化することになるため、BP 学習は最急降下法に

よりニューラルネットワークの結合荷重を最尤推定していると思なすことができる .

よって、式 (1) は BP 学習を行うニューラルネットワークの評価式として用いることが可能であるといえる . 以後、本論文では式 (1) の AIC を得られたネットワークの評価式として用いる .

3.2.2 適合度関数

式 (1) の AIC を用いると、ニューラルネットワークの出力と教師信号との誤差が大きい場合には、第 1 項に大きな差が現れ、最もよくあてはまるモデルが選ばれる . 一方、第 1 項に差がない場合には、第 2 項が作用して少数のパラメータを持つようなモデルが選ばれる . よって、式 (1) で求められる AIC の値が小さいネットワークほど、環境に適したネットワークといえる . したがって、GA の遺伝的操作で用いる各個体の適合度を式 (8) と定義する . ただし、 i は個体番号である . ここで、 λ_{\max} 、 λ_{\min} はそれぞれ各世代での AIC の最大値と最小値である .

$$Fitness(i) = \frac{\lambda_{\max} - AIC_i}{\lambda_{\max} - \lambda_{\min}} \quad (8)$$

3.3 集団平均二乗誤差 (MSEP)

各世代ごとの集団の優劣を比較するため、集団の平均二乗誤差 (Mean Squared Error in Population: 以下、MSEP と略す) を算出する . すなわち、個体 i の二乗誤差 MSE (Mean Squared Error) を MSE_i 、集団内の個体数の総数を S としたとき、MSEP は式 (9) となる .

$$MSEP = \frac{\sum_{i=1}^S MSE_i}{S} \quad (9)$$

4. 計算機実験 1 (1 変数関数の同定)^{4),15)}

1 変数関数を定義し、提案する構造適応学習アルゴリズムを用いて関数同定を行う .

4.1 1 変数関数

学習環境として式 (10) で示されたガウス関数を定義する . さらに式 (10) における関数 $T(g)$ によって、動的環境を決定する . なお、 g は世代を示す変数である .

$$f(x) = \exp(-(x - T(g))^2) \\ + \exp(-10(x - 1.2)^2) \\ - \exp(-10(x - 2.8)^2) \quad (10)$$

4.2 動的環境

動的環境は、学習中に教師信号が変化する環境とする . このため、世代数に応じてとりうる値を式 (11) のように、 $T(g)$ を用いて変化させる .

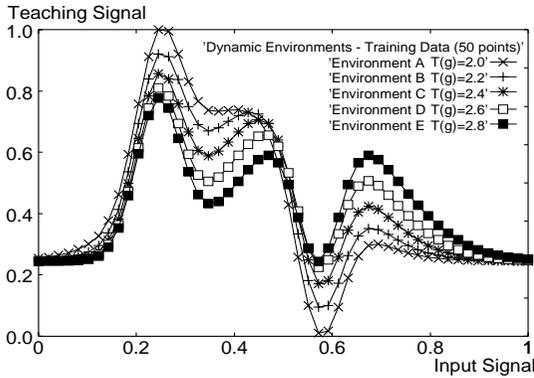


図4 動的環境の訓練データ

Fig.4 Training data in dynamic environments.

$$T(g) = \begin{cases} 2.0, & 0 \leq g < 20 \dots A \\ 2.2, & 20 \leq g < 40 \dots B \\ 2.4, & 40 \leq g < 60 \dots C \\ 2.6, & 60 \leq g < 80 \dots D \\ 2.8, & 80 \leq g < 100 \dots E \end{cases} \quad (11)$$

4.3 訓練データ

学習を行う際に用いる訓練データを図4に示す。動的環境は、式(10)の定義域 [0.0, 4.0] において、 $x = 0.00, 0.08, 0.16, \dots, 4.00$ で与えられる $f(x)$ を求め、50個のデータを採取した。そして値域、定義域ともに正規化して訓練データとした。

4.4 実験設定

実験では世代数を100世代、集団の個体数を30個体、1世代における各個体の学習回数を50回とした。また、交叉率 $P_c = 0.5$ 、突然変異率 $P_m = 0.05$ とし、 $P_m/2$ の確率で、それぞれ局所突然変異および大域突然変異を行う。入力層、出力層のニューロン数は訓練データに依存するため、1入力1出力となり全世代を通じて固定である。

動的環境における提案手法の実験結果と、その考察を以下に示す。本論文では2種類の遺伝機構、すなわちラマルク型とダーウィン型について、パラメータ値を変更せずに実験を行った。

4.5 実験結果

図5, 6は、ラマルク型およびダーウィン型について、学習前後のMSEPを示している。なお、乱数で与えられる初期値を変更して実験を数回行い、どの実験においても同様の結果を得ている。それぞれ学習前のMSEPを点線で、学習後のMSEPを実線で示している。

まず、ラマルク型とダーウィン型の学習前のMSEP

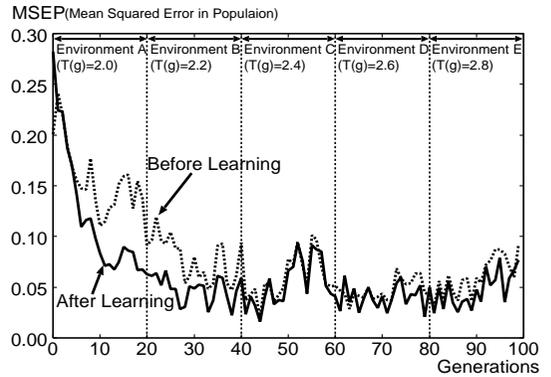


図5 学習前と学習後における集団平均二乗誤差 (ラマルク型)

Fig.5 Average of mean squared errors in population before and after learning (Lamarckian type).

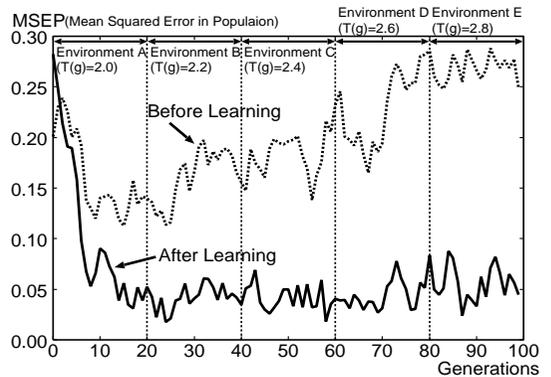


図6 学習前と学習後における集団平均二乗誤差 (ダーウィン型)

Fig.6 Average of mean squared errors in population before and after learning (Darwinian type).

を比較する。0世代から20世代までは、ラマルク型とダーウィン型の差はほとんどみられない。しかし、環境が最初に変動する20世代目以降は、2つの遺伝機構の間に違いがみられる。ラマルク型は20世代以降も徐々にMSEPが小さくなるものの、逆にダーウィン型は徐々にMSEPが大きくなる。

次に、学習後のMSEPを比較する。40世代から60世代まではラマルク型では0.05から0.10付近まで大きくなっていることに対し、ダーウィン型は0.05付近で小さいMSEPを保持している。60世代以降は両者の差はほとんどみられない。また、図5のラマルク型だけを見ると、40世代目以降では、学習前と学習後のMSEPが、ほぼ同値をとっていることが分かる。これは、ラマルク型では獲得形質の遺伝が行われ、各個体は学習済みの状態で誕生するためだと考えられる。

表4は、初期世代と学習終了世代における各学習パラメータ値と隠れニューロン数の平均値を示したものである。初期世代では、ラマルク型とダーウィン型

表 4 初期世代と学習終了世代の各学習パラメータと隠れニューロン数の平均値

Table 4 Average of learning parameters and the number of hidden neurons in an initial generation and in a final generation.

	$\bar{\eta}$	$\bar{\varepsilon}$	$\bar{\alpha}$	\bar{n}	
初期世代	0.45	0.47	0.52	10.2	
終了世代	ラマルク型	0.13	0.33	0.87	4.1
	ダーウィン型	0.11	0.69	0.71	3.9

表 5 10 bits 問題

Table 5 10 bits problem.

Input Signal	Environments					
	A	B	C	D	E	F
000*****	0	0	0	0	1	0
001*****	0	0	0	1	0	1
010*****	0	0	1	0	1	1
011*****	0	1	0	0	1	0
100*****	1	0	0	0	1	1
101*****	1	1	1	1	0	0
110*****	1	1	1	1	0	0
111*****	1	1	1	1	0	1

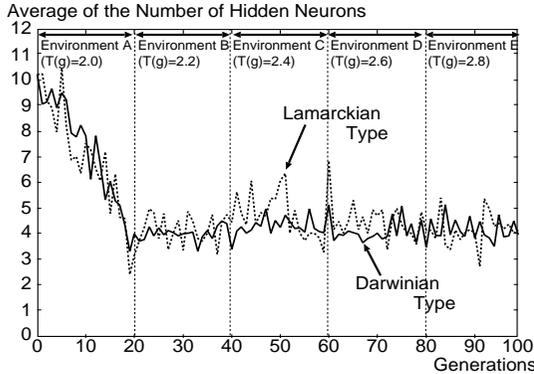


図 7 ラマルク型およびダーウィン型の平均隠れニューロン数
Fig. 7 Average of the number of hidden neurons in Lamarckian and Darwinian types.

の各遺伝子は同じものであった。また、図 7 は各世代の平均隠れニューロン数を示している。それぞれの平均隠れニューロン数は初期世代では 10.2 であったが、20 世代までは徐々に小さくなり 4.0 付近で収束した。終了世代ではラマルク型およびダーウィン型で、それぞれ 4.1, 3.9 と小さい値をとっている。これは AIC を用いてネットワークを評価することにより、教師信号が変化する動的環境においても学習可能で、より小さいネットワーク構造を適応的に獲得したものと考えられる。

獲得形質が行われるラマルク型では、変動前の環境を学習した状態で誕生するため、変動後の環境への適応が難しい。しかし、式 (11) で定義した動的環境は、各環境間の変動量が小さかったため、ラマルク型であっても環境変動時に振動することなく、学習を行うことが可能であったと考えられる。したがって、環境の変動量が小さければ、ラマルク型とダーウィン型との遺伝機構の違いによる環境への適応能力に差が出にくいと、この実験から述べる事ができる。

5. 計算機実験 2 (10 bits 問題)⁶⁾

世代によって教師信号が変化する動的環境を表 5 で与えた。入力は {0, 1} の 10 ビットからなり世代を適

じて変化しない。教師信号は入力信号の左端 3 ビットによって作成され、その他 7 ビットはドントケア、すなわち {0, 1} のどちらの値でもよい。表 5 で “*” はドントケアを示している。

たとえば、環境 A では入力信号が “011*****” のとき教師信号は “0” であるが、環境 B へ変動したときは同じ入力信号に対し、教師信号の出力が “1” と変化する。

本論文で仮定した環境は A から F の順に 5 世代ごとに変動し、環境 F の後は再び環境 A に戻る。また、環境 A から D までは環境の変動量を小さく、環境 D から E へは環境の変動量を大きく設定した。ここで、

$$U \equiv (u_1, u_2, \dots, u_b)$$

$$V \equiv (v_1, v_2, \dots, v_b)$$

のとき、U と V のハミング距離は、式 (12) となる。

$$d(U, V) = \sum_{i=1}^b u_i \otimes v_i \tag{12}$$

ここで、 \otimes は排他的論理和を示している。また、 b は、本論文では環境の教師信号の数になる。したがって、 $b = 2^3 = 8$ となる。

環境 A から D までは、各環境間の教師信号のハミング距離 $d(A, B)$, $d(B, C)$, $d(C, D)$ がそれぞれ 2 となるように、環境の変動量を小さく設定し、環境 D から E への変動では、教師信号をすべて反転させ、ハミング距離 $d(D, E)$ が 8 と環境の変動量を大きく設定した。また環境 F は XOR にみられるような非線形問題に設定した。これは、入力信号の左端 3 ビットのうち、“1” の数をカウントして奇数個であれば教師信号を “1” に、偶数個であれば “0” とするものである。

前実験として一般に用いられる BP 学習を 10 bits 問題に適用した。パラメータ値は、学習係数 $\eta = 0.001$ 、シグモイド関数の傾き $\varepsilon = 0.5$ 、慣性係数 $\alpha = 0.8$ であり、隠れニューロン数が 10 個からなる 3 層のニューラルネットワークを用いた。各環境に対して 50 回の学習を行い、環境 A から F へ合計 300 回の学習を行っ

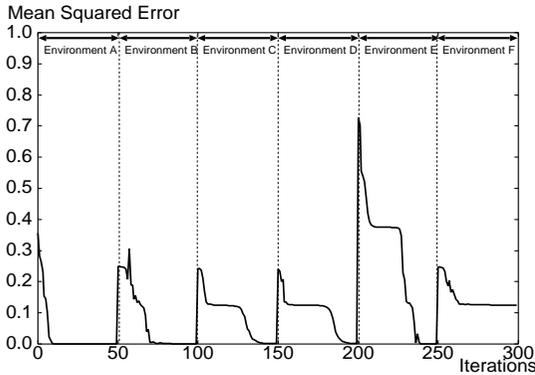


図8 通常のBP学習の誤差曲線(10bits問題)

Fig. 8 Mean squared error in BP learning (10 bits problem).

た．結合荷重ベクトルの初期値は乱数で与え、その後は環境が変動した時点でも初期化させることなく継続して学習を行っている．

このときの誤差曲線が図8である．これを見ると通常のBP学習では環境が変動するたびに振動し、ハミング距離が8となる環境DからEへ変動したとき誤差が大きくなっている．また、非線形問題である環境Fでは誤差が収束しなかった．したがって、定義した10bits問題は通常のBP学習では学習が困難であることが分かる．

5.1 実験設定

実験では、終了世代数120世代、集団数50個体とした．訓練データの数は、入力信号が10ビットで与えられるため、すべての組合せは $2^{10} = 1024$ となり、これらすべてを学習したとき1回と数え、世代における各個体の学習回数は50回とした．また実験1と同様に、交叉率 $P_c = 0.5$ 、突然変異率 $P_m = 0.05$ とし、 $P_m/2$ の確率で、それぞれ局所突然変異および大域突然変異を行う．入力層および出力層のニューロン数は、それぞれ10個、1個となる．

5.2 実験結果

図9は、ラマルク型における学習前後のMSEPを示している．学習前のMSEPを点線で、学習後のMSEPを実線で示している．これを見ると環境変動の周期である5世代ごとにMSEPが振動している．特に環境の変動量が小さい環境AからDまでの各環境間では小さい振幅で振動し、環境の変動量が大きい環境DからEでは大きく振動している．さらに非線形問題の環境Fから環境Aへと変化したときも大きく振動している．

ラマルク型の遺伝機構では、獲得形質の遺伝が行われる．つまり親個体が学習で修正した結合荷重ベクト

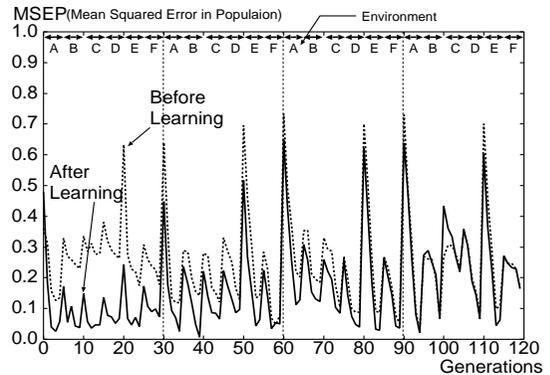


図9 学習前後における集団平均二乗誤差(ラマルク型)

Fig. 9 Average of mean squared errors in population before and after learning (Lamarckian type).

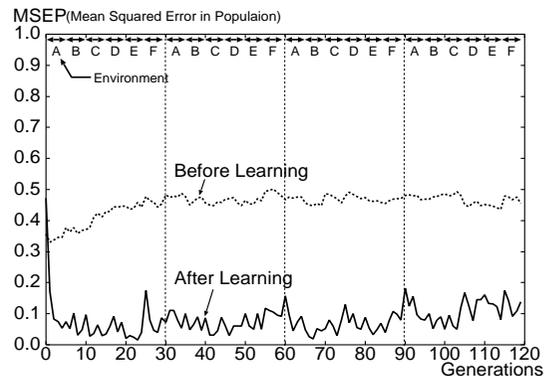


図10 学習前後における集団平均二乗誤差(ダーウィン型)

Fig. 10 Average of mean squared errors in population before and after learning (Darwinian type).

ルを子個体へそのまま遺伝し、その子個体が受け継いだネットワークにより学習を行う．このため、同じ入力信号に対する教師信号が異なってしまうと、正常に学習を行うことができない．したがって、環境が変動すると誤差が大きくなり、図9で示すように環境変動時に振動すると考えられる．

図10は、ダーウィン型における学習前後のMSEPを示している．ラマルク型と異なり、ダーウィン型では大きく振動することはない．特に学習後のMSEPは小さい振幅で振動するものの、どの世代においても0.1付近まで小さくなっている．

ダーウィン型の遺伝機構は、ラマルク型とは異なり獲得形質の遺伝が行われない．ダーウィン型の遺伝機構では、その世代の各個体が学習した結果を評価基準として親個体を選択する．しかしながら、選択された個体自身が、学習によって修正した結合荷重を、子個体へ遺伝することではなく、その個体が親から受け継いだ遺伝情報を子へ継承する．学習前のMSEPが0.4

表6 初期世代と学習終了世代の各学習パラメータと隠れニューロン数の平均値

Table 6 Average of learning parameters and the number of hidden neurons in an initial generation and in a final generation.

		$\bar{\eta}$	$\bar{\varepsilon}$	$\bar{\alpha}$	\bar{n}
初期世代		0.47	0.55	0.49	9.8
終了世代	ラマルク型	0.05	0.88	0.90	2.3
	ダーウィン型	0.06	0.78	0.92	15.6

と比較的大きいのは、未学習の状態の子個体が誕生するためだと考えられる。そして子個体が学習を行った結果を評価基準として、親個体を選択するため、学習によって誤差を小さくすることが可能な個体が、親個体として選択されることになる。よって、5世代ごとの短い周期で変動する動的環境においても、学習可能な個体群を持つ集団が形成されるものと考えられる。

したがって、実験1と異なり実験2のような環境の変動量が大きい動的環境では、ラマルク型は環境変動への適応が困難であるが、ダーウィン型では動的環境への適応性を持つといえる。

表6は、初期世代と学習終了世代での各学習パラメータと隠れニューロン数の平均値を示したものである。また、図11は各世代の平均隠れニューロン数を示している。それぞれの平均隠れニューロン数は初期世代で9.8であった。ラマルク型は環境が変動しない5世代の間に4.0付近まで小さくなるが、環境が変動するたびに振動した。一方、ダーウィン型は25世代までは徐々に大きくなり、その後は環境変動の影響を受けることなく15.0付近で収束した。終了世代では、ラマルク型、ダーウィン型は、それぞれ2.3、15.6となっている。

実験1では、ダーウィン型の隠れニューロン数は初期世代よりも徐々に少なくなったことに対し、逆に実験2では世代を経るにつれて初期世代よりも多くなっている。ネットワークの評価基準として使用したAICは、前述の式(1)となっており、第2項よりも第1項がAICの値に大きく影響する。すなわち、大きい誤差を出力するネットワークでは、そのネットワーク構造がいくら小さくても、結果的にAICの値は大きくなり評価値は悪くなる。図10で示したようにダーウィン型の学習後のMSEPが小さい値で安定しているのは、AICの評価から学習によって誤差を小さくすることが可能なネットワークを探索した結果によるものだと考えられる。

すなわち、提案した手法は動的環境であっても学習によって誤差を小さくすることが可能なネットワーク構造を、隠れニューロン数を増減させることで適応的

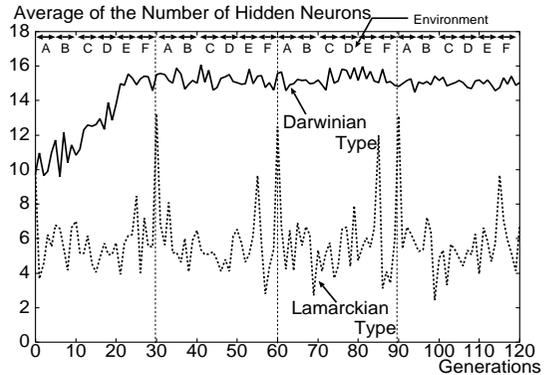


図11 ラマルク型およびダーウィン型の平均隠れニューロン数
Fig. 11 Average of the number of hidden neurons in Lamarckian and Darwinian types.

に探索することが可能であるといえる。このとき、ラマルク型は環境変動の影響を受け平均隠れニューロン数も振動するが、ダーウィン型は大きく振動することなく、適切な隠れニューロン数を探索することに優れていると述べる事ができる。

6. おわりに

本論文では、学習中に教師信号が変化する動的環境を対象とし、進化論に基づく構造適応学習アルゴリズムを提案した。提案手法は、BP学習によりニューラルネットワークの結合荷重ベクトルを更新し、GAの探索によりニューラルネットワークの学習パラメータ値およびネットワーク構造、結合荷重ベクトルを継承し、環境の変化に対して適応的な学習を可能としたものである。

実験1のような環境の変動量が比較的少ない動的環境では、獲得形質の遺伝を行うラマルク型であっても学習することが可能であり、ダーウィン型との遺伝機構の差が出にくい。一方、環境の変動量が大きい実験2では、ラマルク型は環境が変動するたびに振動し適応が困難である。提案した構造適応学習アルゴリズムに、ダーウィン型の遺伝機構を適用した場合は、動的環境であっても与えられる環境に適したネットワーク構造を適応的に獲得するとともに、学習を行うことが可能であることが分かった。また、ダーウィン型はラマルク型より環境変動の影響を受けることなく、適切な隠れニューロン数の探索にも優れていることが分かった。

本論文では、ラマルク型およびダーウィン型集団のどちらとも1集団とした。したがって、生物種概念を導入していない。しかしながら、生物学的観点では形態の異なる生物種間において交叉はできない。この

点を考慮すると、本論文ではネットワーク構造の異なる個体どうしても交叉させる実験を行ったが、ネットワーク構造が異なる個体群を 1 つの種と見なした実験も必要である。また、生物種概念を導入することにより、自然界に見られる棲み分け¹⁷⁾などの現象をシミュレートできるとも考えられる。これらについては今後の課題として検討していきたい。

謝辞 本研究を遂行するにあたり、東京都立科学技術大学の山下利之先生より貴重なご助言をいただきました。心から感謝いたします。

参考文献

- 1) Whitley, D. and Hanson, T.: Optimizing Neural Networks Using Faster, More Accurate Genetic Search, *Proc. 3rd International Conference on Genetic Algorithms and their applications (ICGA-89)*, pp.391–396 (1989).
- 2) Montana, D. and Davis, L.: Training Feedforward Neural Networks Using Genetic Algorithms, *Proc. 11th International Conference on Artificial Intelligence (IJCAI-89)*, pp.762–767 (1989).
- 3) Kitano, H.: Designing Neural Networks using Genetic Algorithms with Graph Generation System, *Complex System*, Vol.4, No.4, pp.461–476 (1990).
- 4) Ackley, D. and Littman, M.: Interactions Between Learning and Evolution, *Artificial Life II*, Addison Wesley (1992).
- 5) 佐々木貴宏, 所真理雄: 進化的エージェント集団の動的環境への適応, *コンピュータソフトウェア*, Vol.14, No.4, pp.33–46 (1997).
- 6) Sasaki, T. and Tokoro, M.: Adaptation toward Changing Environments: Why Darwinian in Nature?, *Proc. 4th European Conference on Artificial Life (ECAL-97)*, pp.145–153 (1997).
- 7) 山崎和子, 関口益照: 動的環境下での進化学習システムの特徴と適応メカニズム, *コンピュータソフトウェア*, Vol.17, No.6, pp.26–42 (2000).
- 8) Berg, P. and Singer, M. (著), 岡山博人 (監訳): 分子遺伝学の基礎, 東京化学同人 (1994).
- 9) 高橋裕樹, 中嶋正之: 遺伝的アルゴリズムを用いた最適な階層型神経回路網の構造決定法に関する一考察, *電子情報通信学会論文誌 (D-II)*, Vol.J79-DII, No.11, pp.1920–1928 (1996).
- 10) Takahashi, H. and Nakajima, M.: Evolutional Design and Training Algorithm for Feedforward Neural Networks, *IEICE Trans. Information & Systems*, Vol.E82-D, No.10, pp.1384–1392 (1999).
- 11) Akaike, H.: A new look at the statistical model identification, *IEEE Trans. Automatic Control*, Vol.AC-19, No.6, pp.716–723 (1974).
- 12) 栗田多喜夫, 本村陽一: 階層型ニューラルネットワークとその周辺, *応用統計学*, Vol.22, No.3, pp.99–115 (1993).
- 13) 栗田多喜夫: 情報量基準による 3 層ニューラルネットワークの隠れ層のユニット数の決定法, *電子情報通信学会論文誌 (D-II)*, Vol.J73-DII, No.11, pp.1872–1878 (1990).
- 14) Oeda, S., Ichimura, T., Terauchi, M., Takahama, T. and Isomichi, Y.: Adaptive Evolutionary Learning Method of Neural Networks using Genetic Algorithms under Dynamic Environments, *Proc. Knowledge-Based Intelligent Engineering Systems & Allied Technologies (KES'2000)*, pp.742–745 (2000).
- 15) 大枝真一, 市村 匠, 寺内睦博, 高濱徹行, 磯道義典: 学習環境の変化に適応可能な GA によるニューラルネットワークの構造決定法, *情報処理学会第 61 回全国大会 (平成 12 年後期) 講演論文集*, Vol.2, pp.55–56 (2000).
- 16) Oeda, S., Ichimura, T., Terauchi, M., Takahama, T. and Isomichi, Y.: Darwinian Inheritance Genetic Learning Method of Neural Networks Under Dynamic Environment, *International Joint Conference on Neural Networks (IJCNN'01)*, pp.2235–2240 (2001).
- 17) 木村資生: 生物進化を考える, 岩波書店 (1988).
(平成 13 年 7 月 16 日受付)
(平成 14 年 5 月 15 日採録)



大枝 真一 (学生会員)

2001 年広島市立大学大学院情報科学研究科知能情報システム工学専攻修士課程修了。修士 (情報科学)。現在、東京都立科学技術大学大学院工学研究科博士後期課程 2 年に在学。進化論に基づくニューラルネットワークの構造学習法について研究。さらに、マルチエージェントを用いた生体における免疫システムに関するアルゴリズムの開発研究に従事。日本ファジィ学会、バイオメディカルファジィシステム学会学生会員。



市村 匠

1997年桐蔭横浜大学大学院工学研究科博士後期課程修了。博士(工学)。同年広島市立大学情報科学部助手,現在に至る。ニューラルネットワーク,遺伝的アルゴリズム,ファ

ジィ理論による学習アルゴリズムを開発,医療診断システムに応用した研究で博士を取得。現在,ニューラルネットワークによる知識獲得,意思決定,感情工学に関心を持つ。電子情報通信学会,日本ファジィ学会,人工知能学会,ヒューマンインタフェイス学会,日本人間工学会,日本教育工学会,日本医療情報学会,バイオメディカルファジィシステム学会,IEEE,INNS等の会員。



寺内 睦博(正会員)

1989年広島大学大学院博士課程後期単位取得退学。同年同大学工学部助手。1994年広島市立大学情報科学部助手,2001年広島国際大学人間環境学部講師。現在,画像理解と学

習,ノンバーバルインタフェイス,ロボット制御等の研究に従事。IEEE,人工知能学会,ACM等各会員。



高濱 徹行(正会員)

1982年京都大学工学部電気第二工学科卒業。1987年同大学大学院博士課程研究認定退学。同年福井大学工学部助手。1994年同大学講師。1998年より広島市立大学情報科学部

知能情報システム工学科助教授。非線形最適化,ファジィ制御を対象とした学習,機械学習,推論,CAI,自然言語処理等に関する研究に従事。電子情報通信学会,人工知能学会,教育システム情報学会,言語処理学会,IEEE各会員。工学博士。



磯道 義典(正会員)

1962年東京大学工学部電気工学科卒業。通商産業省電子技術総合研究所入所。パターン情報等を研究。1978年広島大学総合科学部助教授。1982年同教授。人工知能等を教育研究。

1994年より広島市立大学情報科学部教授。現在相互意思決定論,ゲーム論,進化的計算論等を研究。「情報理論」(コロナ社)「情報化革命」(共立出版)「情報学概論」(共立出版)等を執筆。工学博士。電子情報通信学会,人工知能学会,日本神経回路学会,数理社会学会等の会員。