

論文 / 著書情報
Article / Book Information

題目(和文)	AIを利用した逆解析に関する研究
Title(English)	
著者(和文)	森谷之信
Author(English)	Yukinobu Moriya
出典(和文)	学位:博士(工学), 学位授与機関:東京工業大学, 報告番号:甲第3168号, 授与年月日:1996年3月26日, 学位の種別:課程博士, 審査員:
Citation(English)	Degree:Doctor (Engineering), Conferring organization: Tokyo Institute of Technology, Report number:甲第3168号, Conferred date:1996/3/26, Degree Type:Course doctor, Examiner:
学位種別(和文)	博士論文
Type(English)	Doctoral Thesis

平成7年度 学位論文

AI を利用した逆解析に関する研究

平成7年12月

機械物理工学専攻

森 谷 之 信

目次

1	緒 論	3
1.1	緒 言	3
1.2	従来の研究	4
1.2.1	逆問題	4
1.2.2	ニューラルネットワーク	6
1.2.3	遺伝的アルゴリズム (GA)	8
1.3	本論文の構成	10
2	ニューラルネットワークにおける重みの新しい決定法	19
2.1	緒言	19
2.2	計算手法	20
2.2.1	最終層への結合の重み決定法	20
2.2.2	中間層間の結合の重み決定法	22
2.2.3	計算例—排他的論理和	24
2.3	逆解析への応用—衝撃破壊パラメータ推定	25
2.4	結言	26
3	ニューラルネットワークとウェーブレット変換を用いた予き裂長さの推定	39
3.1	緒言	39
3.2	推定手法	40
3.2.1	ウェーブレット変換	40
3.2.2	推定手順	41
3.3	解析例	42
3.4	結 言	44

4	GA とクラスタリングを併用した最適化手法	94
4.1	緒言	94
4.2	計算手法	95
4.2.1	GA へのクラスタリングの導入	95
4.2.2	解析例	96
4.3	カソード防食電極位置最適化問題への応用	97
4.4	結言	100
5	結論	120

Chapter 1

緒 論

Introduction

Since this book is somewhat unusual, I had better try to explain what it contains and why a person might want to read it.

—D. E. Knuth “Computer Modern Typefaces”

落ち着いて読んでみますとさすがに、精神異常者でなければトテモ書けないと思われるような気味の悪い妖気が全編に横溢しております。

—夢野久作「ドグラ・マグラ」

1.1 緒 言

工学をはじめ、理学、医学といった、自然界のあらゆる分野において見出すことのできる「逆問題」に関する研究は、今世紀、特に1940年代以降、計測技術および電子計算機の発達にともない、急速に進歩してきた。現在では、医療用CTスキャナからパソコン用表計算ソフトの組込み関数などの身近な所にもその応用例をみることができる。

しかし、逆問題の中でも、「解の存在性・解の一意性・解の安定性」の3条件⁽¹⁾が満たされていない、「不適切な (ill-posed)」問題と呼ばれるものの中には、現在でもなお解を得ることが難しいものが存在している。

一方、18世紀のチェス自動人形^{オートマトン}⁽²⁾をはじめ、人類が追い求め続けてきた人工知能 (AI) の理論が、電子計算機の飛躍的な性能向上により、ここ10年ほどの間に広く実用に供されるようになってきた。とりえあず「ニューロ・ファジー」を謳いさえすればよかった1990年代前半のブームの頃に較べれば、AIが世間で話題になることはだいぶ少なくなったが、これはAIの利用が問題解決手段の一つとして根付きつつあるために、それほど騒がれなくなったとみるのが妥当であると思われる。

AIのうちの多くの手法は、「発見的 (heuristic)」であるといわれる。これは従来の逆問題解析に利用されてきた演繹的な数学手法と対極をなすものである。よって、従来の手法が苦手とするような問題に対してAIを適用することは有効であると考えられる。また、この二つをうまく結合させるならば、互いの欠点を補い合うことによって、それぞれを単独で

用いては解を得ることが難しかった問題をも効率的に解析できる手段となることは想像に難くない。

もちろん、AI とて魔法の手段ではなく、何らかの欠点を有している。特に、AI 普及に計算機の数値向上が大きく影響していることからわかるように、長い計算時間を必要とする点は AI 利用を大きく妨げており、AI の逆問題解析への適用のためには、この点を克服することが重要である。

1.2 従来の研究

本節では、本論文の主要テーマである逆問題、ニューラルネットワーク、遺伝的アルゴリズムについて、これまで行われてきた研究を概説する。

1.2.1 逆問題

逆問題を厳密に定義することは難しい。岡本⁽³⁾はこれを

- 結果を観測して原因を推定する問題。
- 順問題とは設定が異なる問題。ここで順問題とは「何らかの微分方程式を指定された初期条件・境界条件の下に解く問題」とする。
- ある種の積分変換を逆変換する問題。

と定義しているが、これらの分類は排他的でなく、上記のいずれにも分類される問題も存在するとも述べている。

このうち、3 番目の積分変換の逆変換、すなわち第 1 種 Fredholm 積分方程式

$$g(x) = \int_a^b K(x, y)f(y)dy \quad (1.1)$$

において $g(x)$ から $f(y)$ を求める問題については古くから研究が進められており、 g および K に誤差が含まれているような場合であっても、

- 式 (1.1) を離散化した後、一般逆行列⁽⁴⁾とランク低減等の不安定性の緩和手法⁽³⁾を組み合わせ適用する
- Radon 変換と何らかの正則化手法を組み合わせ適用する⁽⁵⁾

- 射影フィルタ⁽⁶⁾を適用する

等の手法により、誤差の少ない解を得ることができる。産業界においては、X線CT⁽⁹⁾、資源探査⁽¹⁰⁾、画像再構成⁽¹¹⁾等に応用されている。

一方、上記1番目および2番目の問題においては、観測される量と求めたい量の関係は一般には線形ではない。そのような場合には、有限要素法等の順問題解析手段を用意し、求めるべきパラメータを適当に仮定して順問題を解き、その出力があらかじめ得られている観測量に近付くようにパラメータを修正して再び順問題を解く、というプロセスを繰り返す方法(図1.1)が用いられている。しかし、問題の非線形性の強さ、比較すべき観測量の誤差、遠隔計測における信号減衰、モデル化誤差、離散化誤差等の要因のため、収束に長時間を要したり、場合によっては解そのものが得られないといった状況が発生する。このような問題に対しては、先に述べた不安定性の緩和⁽⁷⁾や、先験情報の利用⁽⁸⁾といった手法により解決が図られているが、それでもなお解を得ることが困難な問題は依然として存在している。

また、逆問題の中でも大きな割合を占めるものとして最適化問題がある。最適化問題は、ある制約条件の下で目的関数 $f(x)$ を x について最小化あるいは最大化する問題に帰着される。すなわち、 F を x の可能領域とすると、

$$\min_x f(x) \quad \text{subject to } x \in F \subset X \quad (1.2)$$

または

$$\max_x f(x) \quad \text{subject to } x \in F \subset X \quad (1.3)$$

という問題を解くことになる。 f および制約条件 $x \in F$ がすべて線形であるものは線形計画問題と呼ばれ、シンプレックス法⁽¹²⁾やアルゴリズム特許として有名な Karmarkar 法⁽¹³⁾等の有名な解析手法が開発されている。一方、少なくとも f か F が非線形であるような非線形計画問題では、ほとんどの場合で降下法による繰り返し計算が必要であり、Newton 法、最急降下法、共役勾配法、非線形シンプレックス法などが用いられている。しかし、例えば先の非線形逆問題中でよく現れるような、 f が多峰性関数である場合や、 f の形状が未知であるような場合には、得られた解が最適解であることを保証するために、降下法の初期値の数を多くし、かつ広く分散させなければならないという問題点がある。

1.2.2 ニューラルネットワーク

ニューラルネットワークとは、生物の脳の構造をミクロ的に模擬した、情報処理のためのシステムである。ニューラルネットワークの概念は、McCulloch と Pitts によって初めて提案され⁽¹⁴⁾、Hebb による結合の変化規則⁽¹⁵⁾を経て、Rosenblatt による Perceptron⁽¹⁶⁾で原型が完成された。その後、Minsky と Papert によって Perceptron 型ニューラルネットワークの限界が指摘された⁽¹⁷⁾ため、その研究は一時下火になったが、Rumelhart らによって考案された誤差逆伝播による学習法⁽¹⁸⁾や、Hopfield のネットワーク⁽¹⁹⁾、Hinton らの Boltzmann Machine⁽²⁰⁾ といった新たな理論により、再び陽の目を見るようになった。現在では、画像解析^{(21)–(23)}、制御⁽²⁴⁾⁽²⁵⁾をはじめ、多くの分野で利用されている⁽²⁶⁾⁽²⁷⁾。

ニューラルネットワークの基本モデルは、図 1.2 に示すような、外部から受けた信号に対して一定のルールに従って出力を行なう、ニューロンをモデル化した“ユニット”を多数結合させたものである。

ニューラルネットワークは、ユニットの結合の状態によって、ユニットが相互に結合している相互結合型ニューラルネットワーク (図 1.3(a)) と、ユニットが層状に並んでいる階層型ニューラルネットワーク (図 1.3(b)) に大別することができる。

相互結合型ニューラルネットワークの方がより本来の脳に近く、複雑な連想記憶等の動作を行なうことも可能である。しかし、学習に必要な時間がきわめて長いため、より簡単な構造で、学習も比較的簡単な階層型ニューラルネットワークが用いられることが多い。

次に、階層型ニューラルネットワークと、その学習メカニズムとしてもっともよく使われているバックプロパゲーション法 (Error Back Propagation Method, 誤差逆伝播法) について説明する。

階層型ニューラルネットワークの構造は、信号を受ける入力層、信号を出力する出力層、入力層と出力層の間の中間層からなっている。以下では、層の数を n とし、入力層を第 1 層、出力層を第 n 層とする。学習を行うときには、入力層と出力層に教師信号を与え、ネットワークの出力が教師出力と等しくなるように、各ユニット間の結合の重さを変更する。

ユニットの動作は、第 k 層第 i 番目のユニットの入力と出力をそれぞれ I_i^k, O_i^k とすると、

$$O_i^k = f(I_i^k) \quad (1.4)$$

$$I_i^{k+1} = \sum_{j=1}^{m_k} O_j^k W_{ji}^k - \theta_i^{k+1} \quad (1.5)$$

である。ここで、 m_k は第 k 層のユニット数、 W_{ji}^k は第 k 層第 j 番目のユニットから第 $k+1$ 層第 i 番目のユニットへの結合の重さ、 θ_i^{k+1} は第 $k+1$ 層第 i 番目のユニットのしきい値

(オフセットともいう), f は入出力関数である.

f としては, ロジスティック関数

$$f(x) = \frac{k}{1 + a \cdot \exp(-bx)} \quad (a, b, k : \text{const.}) \quad (1.6)$$

のような, シグモイド関数がよく用いられる.

バックプロパゲーション法では, 教師入力信号 T_i と教師出力信号 T_o が与えられたとき, 出力誤差の評価関数を

$$E = \sum_j (O_j^n - T_{oj})^2 \quad (1.7)$$

W の修正量 ΔW を

$$\Delta W_{ij}^{k-1} = -\varepsilon_1 \frac{\partial E}{\partial W_{ij}^{k-1}} \quad (\varepsilon_1 \ll 1) \quad (1.8)$$

と定義する. このとき,

$$\frac{\partial E}{\partial W_{ij}^{k-1}} = \frac{\partial E}{\partial I_j^k} \frac{\partial I_j^k}{\partial W_{ij}^{k-1}} = \frac{\partial E}{\partial I_j^k} O_i^{k-1} \quad (1.9)$$

であり, さらに,

• for $k \neq n$

$$\begin{aligned} \frac{\partial E}{\partial I_j^k} &= \frac{\partial E}{\partial O_j^k} \frac{\partial O_j^k}{\partial I_j^k} \\ &= \left(\sum_{\ell} \frac{\partial E}{\partial I_{\ell}^{k+1}} \frac{\partial I_{\ell}^{k+1}}{\partial O_j^k} \right) \frac{\partial O_j^k}{\partial I_j^k} \\ &= \left(\sum_{\ell} \frac{\partial E}{\partial I_{\ell}^{k+1}} W_{j\ell}^k \right) f'(I_j^k) \end{aligned} \quad (1.10)$$

• for $k = n$

$$\frac{\partial E}{\partial I_j^k} = 2(O_j^k - T_{oj}) f'(I_j^k) \quad (1.11)$$

となる. 式 (1.9), (1.10) を式 (1.8) に代入して, $d_j^k = \partial E / \partial I_j^k$ と置くと, 結局

$$d_j^k = \begin{cases} \left(\sum_{\ell=1}^{m_{k+1}} d_{\ell}^{k+1} W_{j\ell}^k \right) f'(I_j^k) & (1 < k < n) \\ 2(O_j^k - T_{oj}) f'(I_j^k) & (k = n) \end{cases} \quad (1.12)$$

$$\Delta W_{ij}^{k-1} = -\varepsilon_1 d_j^k O_i^{k-1} \quad (1.13)$$

ここで、 f が式(1.6)で $a=b=k=1$ としたものであるとすると、 f' は

$$\begin{aligned} f'(x) &= \frac{e^{-x}}{(1+e^{-x})^2} = f(x)(1-f(x)) \\ \therefore f'(I_j^k) &= O_j^k(1-O_j^k) \end{aligned} \quad (1.14)$$

であるので、式(1.12), (1.13)は、

$$d_j^k = \begin{cases} \left(\sum_{\ell=1}^{m_{k+1}} d_{\ell}^{k+1} W_{j\ell}^k \right) O_j^k(1-O_j^k) & (1 < k < n) \\ 2(O_j^k - T_{O_j}) O_j^k(1-O_j^k) & (k = n) \end{cases} \quad (1.15)$$

$$\Delta W_{ij}^{k-1} = -\varepsilon_1 d_j^k O_i^{k-1} \quad (1.16)$$

この ΔW と W の和を新たな W として、再び誤差を評価し、誤差が所定の値以下になるまで、この過程を繰り返す。

しきい値 θ についても、同様の方法で修正量を求めることができるが、図3に示すように、 $-\theta$ を常に1を出力する特殊なユニットの重さと考えると、その取り扱いが簡単になる。

教師信号の組 (T_i, T_o) は複数個与えられるのが一般的であり、このとき、1組の教師ごとに W を修正する方法は逐次修正法、各々の教師の組から修正量を計算し、その修正量の和の平均値を真の修正量とする方法は一括修正法と呼ばれている⁽²⁸⁾。一括修正法の方が学習効率が良いが、修正量が平均化されてしまうために微妙な修正を行ないにくく、複雑な問題には向かないことがある⁽²⁸⁾。

式(1.8)からわかるように、バックプロパゲーション法は最急降下法に基づいた学習手法である。そのため、学習が完了するまでに長い時間を必要とし、ニューラルネットワーク利用における弱点の一つとなっている。そこで、収束性を高めるため、共役勾配法⁽³¹⁾、カルマンフィルタ⁽³⁰⁾、遺伝的アルゴリズム⁽²⁹⁾等の手法を組み込んだ学習則も提案されているが、いずれも基本的には収束計算であるため、ユニット数の増加や、重みの初期値によっては学習に時間がかかるという問題は依然として残っていると思われる。

1.2.3 遺伝的アルゴリズム (GA)

遺伝的アルゴリズム (Genetic Algorithm, 以下 GA と表記する) とは、生物の進化より案を得た確率的最適化手法のひとつである。GA は Holland によって初めて提唱され⁽³²⁾、その後、Goldberg⁽³³⁾らによって広められた。現在では、制御⁽³⁴⁾⁽³⁵⁾、グラフ分割⁽³⁶⁾、組合せ最適化問題⁽³⁷⁾⁽³⁸⁾、最適構造設計⁽³⁹⁾⁻⁽⁴¹⁾などをはじめ、さまざまな分野で応用されている。

次に、GA の計算法について概説する。

GA 中の生物に相当するものを個体 (individual) と呼び、各個体は、最適化すべきシステムの制御変数を遺伝子 (gene) としてコード化した染色体 (chromosome) を有する (図 1.4)。図 1.4 は 1 倍体の有性生殖モデルであるが、通常の生物と同様に染色体を m 倍体 ($m \geq 2$) とする、あるいは、無性生殖とする等のモデル化も可能である。

GA の基本操作としては、選択 (selection)、交差 (crossover)、突然変異 (mutation) の 3 種類がある。選択では、ある世代において、個体の持つ遺伝子情報に基づいて目的関数を評価し、その評価値に応じた確率を定め、その確率に対して現世代の集団 (population) から次世代に生き残ることができる個体を選び出す。

交差とは、図 1.5 に示すように、二つの親個体の染色体を任意の箇所で切断し、組み換えて子個体を作成する手続きである。交差箇所を 2 箇所以上とすることも可能である。

突然変異とは、染色体上の任意の遺伝子を選び、あらかじめ定めた確率でそれを他の対立遺伝子 (変数のコーディングの仕方でその種類は変わる) で置き換えるものである。図 1.6 に、変数をバイナリコーディングした場合の突然変異の例を示す。

GA の基本的な流れは、

- 1) 初期集団を発生させる。
- 2) 集団中の全個体の適応度計算。
- 3) 2) の適応度に応じた確率で個体を選択し、交差させて子を作る。
- 4) 突然変異させる。
- 5) 終了条件を満足しなければ 2) へ戻る。

となる (図 1.7)。

目的関数の最小 (または最大) 値が不明である場合には、様々な終了条件が考えられる。たとえば、最大適応度を示す個体の値と、全体の平均値との差が既定値より小さくなったら終了とする、などが挙げられる。

GA では、多くの個体について少しずつ情報を変化させながら何度も (順問題の) 計算を繰り返すため、必然的に長い計算時間を必要とする。特に、局所解の近傍に個体が集まりだしてから収束するまでの時間が長いことが知られており⁽⁴²⁾、GA を利用する上での大きなネックになっている。

1.3 本論文の構成

以上の観点から，本研究では従来の逆解析手法では解を得ることが困難，あるいは長い計算時間を必要とするような逆問題に対し，人工知能分野における手法を改良し，また従来手法とうまく結びつけることによって，簡単に，あるいは短時間で解を求めることができるような手法の開発を目的とする．

第2章では，ニューラルネットワークにおいて，従来は長い時間を必要としていた重みの決定を短時間で行うことができる手法の開発と，それを用いた一点曲げ衝撃試験のパラメータ推定逆問題解析について述べる．

第3章では，第2章で開発した手法とウェーブレット変換を組み合わせることで，試験片の破断面画像から予き裂長を推定するシステムの開発と，例としてアルミ/アルミナ複合材料の試験片に適用した結果について述べる．

第4章では，GA とクラスタリングおよび降下法を組み合わせることにより，多次元の高次元関数の極値をより短時間で求める手法の開発と，その手法をカソード防食システム最適化問題に適用した結果について述べる．

第5章では，第2章～第4章で得られた結論について総括する．




Figure 1.1: 非線形逆問題の反復解法




Figure 1.2: ニューロンユニットモデル




Figure 1.3: ニューラルネットワーク




Figure 1.4: 変数の染色体へのコード化




Figure 1.5: 交差




Figure 1.6: 突然変異




Figure 1.7: GA のアルゴリズム

参考文献

- (1) 久保司郎, 「逆問題」, 培風館, 1992.
- (2) 松田道弘, 「奇術のたのしみ」, ちくま文庫, 1985.
- (3) 武者利光監修, 岡本良夫著, 「逆問題とそのとき方」, オーム社, 1992.
- (4) 例えば, 柳井晴夫, 竹内啓, 「射影行列・一般逆行列・特異値分解」, 東京大学出版会, 1983.
- (5) 田中博, 「医学における逆問題」, 数理科学, 274, pp.38-44, 1986.
- (6) 小川英光, 「信号と画像の復元 [III] —最適復元のための射影フィルタ族—」, 電子情報通信学会誌, 71-7, pp.739-748, 1988.
- (7) 日本機械学会編, 「逆問題のコンピュータアナリシス」, コロナ社, 1991.
- (8) 天谷賢治, 青木繁, 「解集合と先験情報を利用した逆解析手法」, 日本機械学会論文集 (A 編), 61-587, pp.1651-1656. 1995.
- (9) 田中博, 岡部政之, 鈴木貴, 「逆問題」, 岩波書店, 1993.
- (10) H.D.Bui 著, 青木繁他訳, 「材料力学における逆問題」, 裳華房, 1994.
- (11) 小川英光, 原昌司, 「部分射影フィルタによる画像復元」, 電子情報通信学会論文誌 A, J71-A, 2, pp.519-526, 1988.
- (12) George B. Dantzig, *Linear Programming and Extensions*, Princeton University Press, 1963.
- (13) N.Karmarkar, "A new polynomial time algorithm for linear programming," *Combinatorica*, 4, pp.373-395, 1984.

- (14) Warren S. McCulloch and Walter Pitts, "A logical calculus of the ideas immanent in nervous activity," *Bulletin of Mathematical Biophysics*, 5, pp.115–133, 1943.
- (15) Donald O. Hebb, *The Organization of Behavior*, Wiley, 1949.
- (16) F. Rosenblatt, "The perceptron: a probabilistic model for information storage and organization in the brain," *Psychological Review*, 65, pp.386–408, 1958.
- (17) Marvin Minsky and Seymour Papert, *Perceptrons*, MIT Press, 1969.
- (18) David E. Rumelhart, Geoffrey E. Hinton and Ronald J. Williams, "Learning representations by back-propagating errors," *Nature*, 323-9, pp.533-536, 1986.
- (19) J. J. Hopfield, "Neural networks and physical systems with emergent collective computational abilities," *Proceedings of the National Academy of Sciences*, 79, pp.2554–2558, 1982.
- (20) David H. Ackley, Geoffrey E. Hinton, and Terrence J. Sejnowski, "A learning algorithm for Boltzmann machines," *Cognitive Science*, 9, pp.147–169, 1985.
- (21) Minoru Fukumi, Shigeru Omatu, Fumiaki Takeda, and Toshihisa Kosaka, "Rotation-Invariant Neural Pattern Recognition System with Application to Coin Recognition," *IEEE Transactions on Neural Networks*, 3-2, pp.272–279, 1992.
- (22) Anastasios Delopoulos, Andreas Tirakis, and Stefanos Kollias, "Invariant Image Classification Using Triple-Correlation-Based Neural Networks," *IEEE Transactions on Neural Networks*, 5-3, pp.392–408, 1994.
- (23) 棟安実治, 辻井訓, 雛元孝夫, 「2次元 IIR ニューラルハイブリッドフィルタによる画像処理」, 電子情報通信学会誌 A, J76-A, 10, pp.1440–1449, 1993.
- (24) Richard E. Nordgren and Peter H. Meckl, "An Analytical Comparison of a Neural Network and a Model-Based Adaptive Controller," *IEEE Transactions on Neural Networks*, 4-4, pp.685–694, 1993.
- (25) Thomas Parisini and Riccardo Zoppoli, "Neural Networks for Feedback Feedforward nonlinear Control Systems," *IEEE Transactions on Neural Networks*, 5-3, pp.436–449, 1994.

- (26) James A. Anderson, Andras Pellionisz, and Edward Rosenfield, *Neurocomputing2*, MIT Press, 1988.
- (27) 麻生英樹, 「ニューラルネットワーク情報処理」, 産業図書, 1988.
- (28) 中野馨監修, 飯沼一元編, ニューロンネットグループ+桐谷滋著, 「入門と実習ニューロコンピュータ」, 技術評論社, 1989.
- (29) Etienne Barnard, "Optimization for Training Neural Nets," *IEEE Transactions on Neural Networks*, 3-2, pp.232-240, 1992.
- (30) Samir Shah, Francesco Palmieri, and Michael Datum, "Optimal Filtering Algorithms for Fast Learning in Feedforward Neural Networks," *Neural Networks*, 5, pp.779-782, 1992.
- (31) 馬場則夫, 最上義夫, 丸目雅行, 伊藤健, 「ニューラルネットの新しい学習アルゴリズムとその応用」, 第2回 FAN シンポジウム講演論文集, 920-87, pp.113-116, 1992.
- (32) John Holland, *Adaptation in Natural and Artificial Systems*, The University of Michigan, 1975. and MIT Press, 1992.
- (33) David E. Goldberg, *GENETIC ALGORITHMS in Search, Optimization & Machine Learning*, Addison Wesley, 1989.
- (34) K. Krishnakumar and David E. Goldberg, "Control System Optimization Using Genetic Algorithms," *Journal of Guidance, Control, and Dynamics*, 15-3, pp.735-740, 1992.
- (35) 畝見達夫, 「GA の制御への応用」, 計測と制御, 32-1, pp.58-62, 1993.
- (36) 丸山勉, 小長谷明彦, 小西弘一, 「遺伝的アルゴリズムを用いた並列グラフ分割アルゴリズム」, 情報処理学会論文誌, 34-4, pp.556-567, 1993.
- (37) James P. Cohoon, and William D. Paris, "Genetic Placement," *IEEE Transactions on Computer-Aided Design*, 6-61987, pp.956-964, 1987.
- (38) 山村雅幸, 小野貴久, 小林重信, 「形質の遺伝を重視した遺伝的アルゴリズムに基づく巡回セールスマン問題の解法」, 人工知能学会誌, 7-6, pp.1049-1059, 1992.

- (39) 荒川雅生, 山川宏, 「2次元構造物の遺伝的アルゴリズムを用いた最適トポロジーに関する研究(第1報 基礎的アルゴリズムの提示)」, 日本機械学会第5回計算力学講演会講演論文集, 920-92, pp.287-292, 1992.
- (40) 坂本二郎, 尾田十八, 「遺伝的アルゴリズムを利用した最適トラス形態決定法」, 日本機械学会論文集(A編), 59-562, pp.156-161, 1993.
- (41) 轟章, 渡辺究, 「オブジェクト指向有限要素法上のGAを用いた複合材料構造最適化」, 日本機械学会第6回計算力学講演会講演論文集, 930-71, pp.55-56, 1993.
- (42) 和田健之介, 田中真一, 「GAは生き残れるか?」, 計測と制御, 32-1, pp.17-23, 1993.
- (43) 中村正行, 田中正隆, 望月雅一, 「境界要素法を用いた動弾性逆解析による欠陥同定(遺伝的アルゴリズムの導入)」, 境界要素法論文集, 10, pp.125-130, 1993.

Chapter 2

ニューラルネットワークにおける 重みの新しい決定法

Novel Method for Determining Weights in Neural Network

*'Now, Watson, confess yourself utterly taken aback,'
said he.
'I am.'
'I ought to make you sign a paper to that effect.'
'Why?'
'Because in five minutes you will say that it is
so absurdly simple.'
—A. C. Doyle "The Dancing Men"*

驚くうちは^{たのしみ} 楽があるもんだ。
—夏目漱石「虞美人草」

2.1 緒言

ニューラルネットワーク、とくに階層型ニューラルネットワークは、以前から人工知能というまでもなく、パターンマッチング、認知科学といった分野において広く用いられてきた⁽¹⁾⁽²⁾が、これらに加えて、最近では工学的最適化問題および逆問題の分野への適用も試みられている⁽³⁾⁻⁽⁷⁾。

しかし、一般にニューラルネットワークの学習には長時間を必要とする。これは、階層型ニューラルネットワークについていえば、現在もっとも広く用いられている学習則であるバックプロパゲーション法が、一次元探索を行なわない最急降下法に基づいていることに一因があると思われる。この点を改善するため、共役勾配法、カルマンフィルタ、遺伝的アルゴリズム等の手法を組み込んだ学習則も提案されている⁽⁸⁾⁻⁽¹¹⁾が、基本的には収束計算を行うため、ニューラルネットワークに含まれるユニット数が増加した場合や、あるいは、ユニット間の重みの初期値の取り方によっては学習に長い時間がかかってしまうという問題は依然として残っていると思われる。

そこで、本章では、階層型ニューラルネットワーク中の1つのユニットの入出力に着目することによって、収束計算を行わずに短時間でユニット間の重みを決定する方法を開発し、一点曲げ衝撃シミュレーションの逆問題に適用した結果について述べる。

2.2 計算手法

2.2.1 最終層への結合の重み決定法

第1章で述べたように、一般的な階層型ニューラルネットワーク (総階層数を n とする) では、人間の神経細胞の働きを模擬したユニットが層状に配置され、さらにそれらが feedforward 的に結合されている。

個々のユニットの入力と出力の関係を再掲すれば、第 k 層第 i 番ユニットの入力および出力をそれぞれ I_i^k および O_i^k とすると、

$$I_i^{k+1} = \sum_{j=1}^{m_k} O_j^k W_{ji}^k - \theta_i^{k+1} \quad (2.1)$$

$$O_i^{k+1} = f(I_i^{k+1}) \quad (2.2)$$

である。ここで、 m_k は第 k 層に属するユニットの数、 W_{ji}^k は第 k 層第 j 番のユニットから第 $k+1$ 層第 i 番のユニットへの結合の重み、 θ_i^k は第 k 層第 i 番ユニットのしきい値を表し、 f はユニットの入出力関数である。

階層型ニューラルネットワークにおいては、教師信号の組合せは複数与えられるのが一般的であり、その個数を n_T とすると、1つのユニット (例えば第 $k+1$ 層第 i 番ユニット) についてそれぞれ n_T 本の式 (2.1) および式 (2.2) が得られる。左肩添字で教師の番号を表すとすると、式 (2.1) は、

$$\begin{bmatrix} {}^1O_1^k & {}^1O_2^k & \dots & {}^1O_{m_k}^k & -1 \\ {}^2O_1^k & {}^2O_2^k & \dots & {}^2O_{m_k}^k & -1 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ {}^{n_T}O_1^k & {}^{n_T}O_2^k & \dots & {}^{n_T}O_{m_k}^k & -1 \end{bmatrix} \begin{bmatrix} W_{1i}^k \\ W_{2i}^k \\ \vdots \\ W_{m_k i}^k \\ \theta_i^{k+1} \end{bmatrix} = \begin{bmatrix} {}^1I_i^{k+1} \\ {}^2I_i^{k+1} \\ \vdots \\ {}^{n_T}I_i^{k+1} \end{bmatrix} \quad (2.3)$$

のようにマトリクス表示される。

ここで、第1層のすべてのユニットから、第2層第 i 番ユニットへの結合に着目すると、式 (2.3) の入出力関係は

$$\begin{bmatrix} {}^1O_1^1 & {}^1O_2^1 & \cdots & {}^1O_{m_1}^1 & -1 \\ {}^2O_1^1 & {}^2O_2^1 & \cdots & {}^2O_{m_1}^1 & -1 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ {}^{n_T}O_1^1 & {}^{n_T}O_2^1 & \cdots & {}^{n_T}O_{m_1}^1 & -1 \end{bmatrix} \begin{bmatrix} W_{1i}^1 \\ W_{2i}^1 \\ \vdots \\ W_{m_1i}^1 \\ \theta_i^2 \end{bmatrix} = \begin{bmatrix} {}^1I_i^2 \\ {}^2I_i^2 \\ \vdots \\ {}^{n_T}I_i^2 \end{bmatrix} \quad (2.4)$$

となる. 式 (2.4) において, 第 1 層のユニットの出力 ${}^\ell O_j^1 (j = 1, 2, \dots, m_1, \ell = 1, 2, \dots, n_T)$ は, ${}^\ell I_j^1$ が入力側教師として与えられており, これから入出力関係式 (2.2) により計算されるため, すべて既知となる. しかしながら, W_{ji}^1 および θ_i^2 が未知であるため, ${}^\ell I_i^2$ を求めることはできない. そこで, W_{ji}^1 および θ_i^2 を何らかの形で定めてしまえば, 式 (2.4) から ${}^\ell I_i^2$ を得ることができる.

この操作を第 2 層のすべてのユニットに対して行なうと, 式 (2.4) の右辺である ${}^\ell I_i^2 (i = 1, 2, \dots, m_2, \ell = 1, 2, \dots, n_T)$ がすべて得られ, これより, 入出力関数によって第 2 層の出力 ${}^\ell O_j^2$ を求めることができる. すると, 今度は第 2 層と第 3 層の間でこれと同様の操作を行なうことができ, 順次これを繰り返すことによって, 出力層の一つ手前の中間層 (すなわち, 第 $n-1$ 層) の出力 ${}^\ell O_j^{n-1}$ まで求まる.

第 $n-1$ 層のすべてのユニットから第 n 層第 i 番ユニットへの結合の関係式

$$\begin{bmatrix} {}^1O_1^{n-1} & {}^1O_2^{n-1} & \cdots & {}^1O_{m_{n-1}}^{n-1} & -1 \\ {}^2O_1^{n-1} & {}^2O_2^{n-1} & \cdots & {}^2O_{m_{n-1}}^{n-1} & -1 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ {}^{n_T}O_1^{n-1} & {}^{n_T}O_2^{n-1} & \cdots & {}^{n_T}O_{m_{n-1}}^{n-1} & -1 \end{bmatrix} \begin{bmatrix} W_{1i}^{n-1} \\ W_{2i}^{n-1} \\ \vdots \\ W_{m_{n-1}i}^{n-1} \\ \theta_i^n \end{bmatrix} = \begin{bmatrix} {}^1I_i^n \\ {}^2I_i^n \\ \vdots \\ {}^{n_T}I_i^n \end{bmatrix} \quad (2.5)$$

においては, ${}^\ell O_j^{n-1}$ はそれまでの操作により既知, また ${}^\ell I_i^n$ は, ${}^\ell O_j^n$ が出力側教師として与えられ, これより入出力関数の逆変換で計算されるので既知となるため, 結局, 式 (2.5) は, W_{ji}^{n-1} および θ_i^n を未知数とする連立方程式とみることができる. しかし, このままでは, 式 (2.5) を満たす W_{ji}^{n-1} および θ_i^n が必ず存在するとは限らない. そこで, 方程式の数が変数の数より多くなるように $(m_{n-1} + 1 \geq n_T)$, すなわち, 出力層の一つ前の中間層のユニット数が (教師数 - 1) と等しいか, それよりも多くなるようにあらかじめネットワークを設計しておけば, 式 (2.5) を満たす W_{ji}^{n-1} および θ_i^n を簡単に決定することが可能となる.

より厳密に言えば, 上記の条件は, 式 (2.5) の連立方程式のうち, 独立なものの本数が変数の数より多くなるようにする, ということになるが, 次節で述べる中間層の重み決定法では, 第 $n-1$ 層の出力を得るまでの操作において, 式 (2.5) 中に独立でない式が現れる可

能性はほとんど無視してよいと考えられる。

なお、上記の説明においては、条件を設定する層を第 $n-1$ 層としたが、第 $n-1$ 層と第 n 層第 i 番ユニットの関係式において、 ${}^l I_i^n$ が既知であることから ${}^l O_j^{n-1}$ を任意に定め、それに対して W_{ji}^{n-1} および θ_i^n を求め、次に ${}^l O_j^{n-1}$ より ${}^l I_i^{n-1}$ を求めるというように、順次層をさかのぼっていくこともできる。したがって、実際には、 $m_{n-1} + 1 \geq n_T$ という条件は、 m_{n-1} に対してではなく、最低限どこか 1 つの層のユニット数 m_k で満足されていれば良い。

2.2.2 中間層間の結合の重み決定法

前節では、中間層間の結合の重みが何らかの形で決定されているという仮定のもとに、最終層への重みを決定する方法について述べた。この中間層間の重みは、乱数等により任意に決定することも可能であるが、解の安定性に問題が生ずる可能性がある。そこで本節では、中間層間の結合の重みをより合理的に決定する方法について述べる。

まず、第 k 層の全ユニットと第 $k+1$ 層の一つのユニットとの間の重みとしきい値を決定する場合を考える。第 k 層の全ユニットからの出力 $O_j^k (j = 1 \sim m_k)$ が作る m_k 次元の空間 $\mathbb{R}^{m_k}$ を考えると、第 t 番目 ($t = 1 \sim n_T$) の教師入力に対する第 k 層の出力 (${}^t O_1^k, {}^t O_2^k, \dots, {}^t O_{m_k}^k$) は、空間 $\mathbb{R}^{m_k}$ 内の一点に対応する (以下、この点を ${}^t O^k$ と表記する)。

一方、第 $k+1$ 層 i 番目 ($i = 1 \sim m_{k+1}$) のユニットの入力 I_i^{k+1} は次式

$$I_i^{k+1} = \sum_{j=1}^{m_k} O_j^k W_{ji}^k - \theta_i^{k+1} \quad (2.6)$$

で表される。ここで、 $\sum_{j=1}^{m_k} O_j^k W_{ji}^k - \theta_i^{k+1} = 0$ は空間 $\mathbb{R}^{m_k}$ 内の一平面に対応する。また、第 t 番目の教師に対する第 $k+1$ 層 j 番目のユニットの入力 I_j^{k+1} は、前記の点 ${}^t O^k$ がこの平面からどちら側にどの程度外れているかを示す指標になる。

第 k 層から第 $k+1$ 層のすべてのユニットへの重み W およびしきい値 θ を決める操作は、 m_{k+1} 個の平面を用いて、 n_T 個の点 ${}^t O_j^k$ を含む空間 $\mathbb{R}^{m_k}$ を分割するという事に相当する。以上を模式的に表したのが図 2.1 である。すなわち、同図左のように $m_k = 2$, $m_{k+1} = 3$, $n_T = 5$ なるニューラルネットワーク (の一部) は、同図右側に示されるように、5 点を含む 2 次元空間を 3 本の平面 (ここでは直線) が分割していることに対応する。

ニューラルネットワークにおいては、各々の教師が場合分けされるように重みを決定する必要があるので、上で述べた分割は、各区画に 2 つ以上の点が含まれず、かつ点が含まれない区画が存在しないように行われることが望ましい。しかし、いかなる教師の組合せに対してもそれが可能であるような万能な分割手法を考えることは難しい。そこで、本研

究では入力を2つのパターンに分類するパターンマッチングの問題を想定し、以下のような分割法を考えた。

まず、同じパターンが続かないような順序で教師を与える。すると、いずれの層においても点 ${}^tO^k$ と ${}^{t+1}O^k$ は異なる教師出力パターンに属するようになるため、 ${}^1O^k$ と ${}^2O^k$ 、 ${}^2O^k$ と ${}^3O^k$ 、...の間に分割面が位置すれば、2つのパターンが近似的に分離されることになる。両パターンに対する教師の数が等しい場合には、 ${}^{n_T}O^k$ と ${}^1O^k$ の間も分割する。よって、前節(2.2.1節)の最後において、最低一つ以上の層で $m_k + 1 \geq n_T$ という条件を導入したが、これを、“すべての中間層において $m_k \geq n_T$ ”と拡張する必要がある。

点 ${}^tO^k$ と ${}^{t+1}O^k$ を分割する面を、これら2点から等距離にある面とすれば、この面を表す方程式は

$$\sum_{j=1}^{m_k} ({}^tO_j^k - {}^{t+1}O_j^k) O_j^k - \sum_{j=1}^{m_k} ({}^tO_j^k - {}^{t+1}O_j^k) \left(\frac{{}^tO_j^k + {}^{t+1}O_j^k}{2} \right) = 0 \quad (2.7)$$

(ただし、 $t = n_T$ のときは $t + 1 \rightarrow 1$)

となり、式(2.6)右辺と比較することにより、

$$W_{ji}^k = {}^tO_j^k - {}^{t+1}O_j^k \quad (2.8)$$

$$\theta_i^k = \sum_{j=1}^{m_k} ({}^tO_j^k - {}^{t+1}O_j^k) \left(\frac{{}^tO_j^k + {}^{t+1}O_j^k}{2} \right) \quad (2.9)$$

(ただし、 $t = i$ 。また、 $t = n_T$ のときは $t + 1 \rightarrow 1$)

を得る。

ただし、このままでは

- 複数の分割面が同一となる場合には、前章で述べた最終層の連立方程式が縮退することがある
- 出力 O の範囲は $0 < O < 1$ とすることが多いため、出力が0.5に近い値しか取らなくなる

という問題があるため、

- 計算によって得られた W および θ に微小な乱数を加える

- ロジスティックス関数 $f = k/(1 + a \cdot \exp(bx))$ の k を 1 より大きな値とする

という操作をする必要がある。

なお、この手法は、出力のパターンが 3 以上の場合にも容易に拡張することが可能である。

また、前節および本節で述べた手法においては、従来のバックプロパゲーション法と比較して中間層のユニット数が増えることは否めないが、昨今の計算機事情を考慮すると、この点に関しては実用上特に支障はないと思われる。

2.2.3 計算例—排他的論理和

本手法の有効性を示す例題として、表 2.1 に示すような教師信号、すなわち、排他的論理和の入力と出力を用いて、図 2.2 に示すようなニューラルネットワークの重みの決定を行った。実際の計算においては、しきい値 θ_i^k の取り扱いを簡単にするため、入力がなく、出力が常に -1 であるようなユニットを作り、このユニットからの重みが θ_i^k であるとしてモデル化した⁽¹²⁾。ユニットの入出力関数 $f(x)$ としては、第 1 章でも示したロジスティック関数

$$f(x) = \frac{k}{1 + a \cdot \exp(-bx)} \quad (k, a, b : \text{const.}) \quad (2.10)$$

を用い、 $k = 10$, $a = b = 1$, $f^{-1}(1) = 10$, $f^{-1}(0) = -10$ とした。

本手法によって得られた重みの一例を表 2.2 に示す。また、その重みを用いて、教師入力に対する出力を再度計算した結果を表 2.3 に示す。比較のため、従来のバックプロパゲーション法 (修正パラメータ $\varepsilon = 0.5$, 収束条件: 出力誤差の r.m.s. が 0.05 以下) によって同じネットワークに同じ教師信号を学習させ、その重みを用いて出力を再度計算させた結果も示した。式 (2.10) の出力が完全に 0 または 1 をとることはないため、本手法の結果においてわずかに誤差が生ずるが、この誤差は $f^{-1}(1)$ および $f^{-1}(0)$ の値を変えることにより、任意に制御することが可能である。

なお、重み決定に要した計算時間は、Sun Microsystems 社のワークステーション SPARCstation10 Model 30 で 0.1 秒未満であった。一方、バックプロパゲーション法においては、学習の所要時間は平均して約 3 秒であり、本手法によって 10 倍以上の計算時間短縮が図られた。

2.3 逆解析への応用—衝撃破壊パラメータ推定

本節では、前節において述べた手法の逆解析への応用として、一点曲げ衝撃破壊試験シミュレーションのパラメータ推定問題⁽¹³⁾に適用した結果について述べる。

まず、図 2.3 に順問題の概要を示す。すなわち、細い糸で吊り下げられたき裂入り試験片を、上方から衝撃棒を落下させて破壊し、衝撃棒に貼付したひずみゲージの出力から衝撃力、さらには衝撃破壊靱性値を算出する一点曲げ衝撃破壊試験に対して、Euler-Bernulli 梁理論および Hertz の接触理論を適用すると、衝撃力 F を、時間 t 、き裂進展開始時刻 t_0 、き裂進展速度 v 、衝撃速度 v_0 、および衝撃棒先端の曲率半径 R の関数として得ることができる。このシミュレーションによって得られた衝撃力 F の時刻歴の一例を図 2.4 に示す。

この衝撃力時刻歴のみが与えられたとして、上記のパラメータを推定するのが本逆問題の骨子である。

そこで、得られている衝撃力 F の時刻歴を一定時間毎にサンプリングしたデータ (例えば、図 2.4 に●印で示したようなデータ) を入力したときに、各パラメータを出力するようなニューラルネットワークを作成することを考え、そのニューラルネットワークの重みの決定を行った。

用いたニューラルネットワークの層の数は 3 層であり、各層のユニット数は、

入力層 : 72 + しきい値ユニット 1
 中間層 : 20 + しきい値ユニット 1
 出力層 : 2

とした。教師信号は、表 2.4 に示すように、入力側が $t = 0 \sim 35 \times 10^{-6}(\text{sec})$ の間の、 $1 \times 10^{-6}(\text{sec})$ 毎の t と F の値 (一教師につき合計 72 個)、出力側が t_0 および v の値とした。 R および v_0 については本例題では既知であるものとし、出力とはしなかった。なお、実際の計算においては、ユニットの出力が $(0, 1)$ であることと、計算精度を考慮して、 t, t_0 は $t_N = 50 \times 10^{-6}(\text{sec})$ 、 F は $F_N = 500(\text{N})$ 、 v は $v_N = 500(\text{m/s})$ によって正規化した値を用いた (F の有効数字は 7 桁)。教師信号数は、表 2.4 に示すような 16 通りの (t_0, v) の組合せとした。ユニットの入出力関数については、前節の例題と同様に式 (2.10) をを用い、 $k = 10$ 、 $a = b = 1$ 、 $f^{-1}(1) = 10$ 、 $f^{-1}(0) = -10$ とした。

表 2.5 に、本手法によって計算された重みのうちの 10 例を用いて、教師入力に対する出力を再計算させた結果の、1 例あたりの平均値を示す。与えられた教師信号に対しては、完全に正しい値を出力していることがわかる。重み決定に要した計算時間は、平均で約 0.34 秒であった。比較のため、バックプロパゲーション法 ($\epsilon = 0.5$ 、収束条件：出力誤差の r.m.s. が 0.01 以下) によって同じ教師信号を学習させたところ、所要時間は平均して約 5800 秒で

あった(試行回数 10 回). その学習結果を利用して, 教師入力に対する出力を再計算させた結果の平均も表 2.5 に示した. この表より, 本手法による結果は教師信号と一致していることがわかる.

また, 表 2.6 に示すような, 教師信号にない 15 通りの (t_0, v) の組合せ (No.1' ~ No.15') から F と t の入力データを作り, 上で得られた 10 通りの重みを用いて (t_0, v) を推定させたところ, 1 例あたりの平均値として表 2.7 のような結果を得た. 比較のため, バックプロパゲーション法による学習結果を用いて同様の推定を行った結果の平均値も同時に示した. 表 2.7 より, 本手法によって重みを決定されたニューラルネットワークは, 推定能力の点では, バックプロパゲーション法により学習を行ったニューラルネットワークに対しては, 少なくとも同等程度の能力を有していると言える.

さらに, 測定誤差を模擬するために F の有効数字 3 桁とした教師信号 $((t_0, v)$ の組み合わせは表 2.4 と同じ) により学習を行わせ, その重みを用いて, 未学習の F と t のデータ $((t_0, v)$ の組み合わせは表 2.6 と同じ. F の有効数字 3 桁) から (t_0, v) を推定させた. その結果(試行 10 回の平均)を表 2.8 に示す. 比較のため, バックプロパゲーション法によって同様の操作を行った結果(試行 10 回の平均)も同時に示した. 表 2.8 より, 本手法によって重みを決定されたニューラルネットワークは, 教師信号が誤差を含む場合でも, バックプロパゲーション法により学習を行ったニューラルネットワークとほぼ同程度の推定を行うことができると言える.

2.4 結言

本章においては, ニューラルネットワーク中の一つのユニットの入出力の関係に着目し, ネットワークに対して, すべての層のユニット数を教師信号数と等しいか, それよりも大きくなるようにするという条件をつけることによって, 収束計算を行わずに短時間(従来手法の $10^{-1} \sim 10^{-4}$ 以下)でユニット間の重みを決定する方法を開発し, 例題によってその有効性を示した. また, この手法を衝撃破壊パラメータ推定の逆問題に適用し, よい推定結果を得ると同時に, ニューラルネットワークとしての機能が従来手法と同等であることも示した.




Figure 2.1: 重み決定による空間の分割

Table 2.1: 排他的論理和教師信号

Input		Output
0	0	0
1	0	1
0	1	1
1	1	0




Figure 2.2: 用いたニューラルネットワーク

Table 2.2: 得られた重みの一例

Layer1 to Layer2	$W_{11}^1 = -2.29488 \times 10^0$	$W_{21}^1 = 2.22657 \times 10^0$	$\theta_1^1 = -5.44892 \times 10^0$
	$W_{12}^1 = 4.90137 \times 10^{-2}$	$W_{22}^1 = -2.35650 \times 10^0$	$\theta_2^1 = -1.64071 \times 10^1$
	$W_{13}^1 = 2.24766 \times 10^0$	$W_{23}^1 = 2.20451 \times 10^0$	$\theta_3^1 = 2.27791 \times 10^1$
	$W_{14}^1 = -3.11673 \times 10^{-2}$	$W_{24}^1 = -2.27716 \times 10^0$	$\theta_4^1 = -1.63980 \times 10^1$
Layer2 to Layer3	$W_{11}^2 = -8.12393 \times 10^1$	$W_{21}^2 = -7.06696 \times 10^1$	$W_{31}^2 = -6.80556 \times 10^1$
	$W_{41}^2 = 4.086376 \times 10^{-1}$	$\theta_1^2 = -1.74879 \times 10^3$	

Table 2.3: 出力結果比較

Input		Output		
		Teacher	New Method	Back Prop.
0	0	0	0.000045	0.047749
1	0	1	0.999955	0.963611
0	1	1	0.999955	0.938872
1	1	0	0.000045	0.051297




Figure 2.3: 一点曲げ衝撃破壊シミュレーションの概略




Figure 2.4: 衝撃力時刻歴

Table 2.4: 教師入力および教師出力

Teacher Input: $t/t_N, F/F_N$ $(t = 0, 1.0 \times 10^{-6}, 2.0 \times 10^{-6}, \dots, 35.0 \times 10^{-6})$

Teacher Output:

No.	t_0/t_N	v/v_N	No.	t_0/t_N	v/v_N
1	0.100	0.400	9	0.260	0.400
2	0.120	0.400	10	0.280	0.400
3	0.140	0.400	11	0.300	0.400
4	0.160	0.400	12	0.320	0.400
5	0.180	0.400	13	0.340	0.400
6	0.200	0.400	14	0.360	0.400
7	0.220	0.400	15	0.380	0.400
8	0.240	0.400	16	0.400	0.400

 $(t_N = 50 \times 10^{-6} \text{sec}, F_N = 500\text{N}, v_N = 500\text{m/s})$

Table 2.5: 得られた重みによる教師出力の再計算

No.	t_0/t_N			v/v_N		
	Teacher	New Method	Back Prop.	Teacher	New Method	Back Prop.
1	0.100	0.100	0.131	0.400	0.400	0.404
2	0.120	0.120	0.139	0.400	0.400	0.403
3	0.140	0.140	0.151	0.400	0.400	0.403
4	0.160	0.160	0.164	0.400	0.400	0.402
5	0.180	0.180	0.181	0.400	0.400	0.401
6	0.200	0.200	0.200	0.400	0.400	0.399
7	0.220	0.220	0.218	0.400	0.400	0.398
8	0.240	0.240	0.239	0.400	0.400	0.398
9	0.260	0.260	0.256	0.400	0.400	0.399
10	0.280	0.280	0.277	0.400	0.400	0.398
11	0.300	0.300	0.297	0.400	0.400	0.398
12	0.320	0.320	0.317	0.400	0.400	0.398
13	0.340	0.340	0.339	0.400	0.400	0.398
14	0.360	0.360	0.367	0.400	0.400	0.399
15	0.380	0.380	0.387	0.400	0.400	0.400
16	0.400	0.400	0.400	0.400	0.400	0.400

 $(t_N = 50 \times 10^{-6} \text{sec}, v_N = 500 \text{m/s})$

Table 2.6: 推定させた (t_0, v) の組合せ

No.	t_0/t_N	v/v_N	No.	t_0/t_N	v/v_N
1'	0.110	0.400	9'	0.270	0.400
2'	0.130	0.400	10'	0.290	0.400
3'	0.150	0.400	11'	0.310	0.400
4'	0.170	0.400	12'	0.330	0.400
5'	0.190	0.400	13'	0.350	0.400
6'	0.210	0.400	14'	0.370	0.400
7'	0.230	0.400	15'	0.390	0.400
8'	0.250	0.400			

$$(t_n = 50 \times 10^{-6} \text{sec}, v_N = 500 \text{m/s})$$

Table 2.7: (t_0, v) の推定結果

No.	t_0/t_N			v/v_N		
	Exact	New Method	Back Prop.	Exact	New Method	Back Prop.
1'	0.110	0.108	0.146	0.400	0.399	0.403
2'	0.130	0.130	0.158	0.400	0.399	0.402
3'	0.150	0.151	0.172	0.400	0.400	0.401
4'	0.170	0.171	0.190	0.400	0.400	0.400
5'	0.190	0.191	0.210	0.400	0.397	0.400
6'	0.210	0.211	0.225	0.400	0.401	0.400
7'	0.230	0.231	0.241	0.400	0.401	0.400
8'	0.250	0.250	0.259	0.400	0.402	0.400
9'	0.270	0.274	0.264	0.400	0.400	0.400
10'	0.290	0.291	0.273	0.400	0.401	0.400
11'	0.310	0.305	0.294	0.400	0.398	0.400
12'	0.330	0.335	0.324	0.400	0.398	0.400
13'	0.350	0.350	0.360	0.400	0.400	0.399
14'	0.370	0.368	0.389	0.400	0.401	0.399
15'	0.390	0.392	0.401	0.400	0.402	0.400

 $(t_N = 50 \times 10^{-6} \text{sec}, v_N = 500 \text{m/s})$

Table 2.8: 誤差を含むデータからの (t_0, v) の推定結果

No.	t_0/t_N			v/v_N		
	Exact	New Method	Back Prop.	Exact	New Method	Back Prop.
1'	0.100	0.110	0.137	0.400	0.399	0.403
2'	0.130	0.131	0.148	0.400	0.400	0.402
3'	0.150	0.151	0.161	0.400	0.400	0.401
4'	0.170	0.170	0.177	0.400	0.400	0.400
5'	0.190	0.192	0.196	0.400	0.400	0.400
6'	0.210	0.212	0.214	0.400	0.399	0.400
7'	0.230	0.232	0.232	0.400	0.401	0.400
8'	0.250	0.247	0.250	0.400	0.399	0.399
9'	0.270	0.275	0.270	0.400	0.400	0.400
10'	0.290	0.289	0.289	0.400	0.399	0.400
11'	0.310	0.310	0.307	0.400	0.402	0.400
12'	0.330	0.330	0.328	0.400	0.399	0.400
13'	0.350	0.350	0.350	0.400	0.401	0.401
14'	0.370	0.371	0.376	0.400	0.400	0.401
15'	0.390	0.391	0.397	0.400	0.400	0.400

 $(t_N = 50 \times 10^{-6} \text{sec}, v_N = 500 \text{m/s})$

参考文献

- (1) James A. Anderson, Andras Pellionisz, and Edward Rosenfield, *Neurocomputing2*, MIT Press, 1988.
- (2) 麻生英樹, 「ニューラルネットワーク情報処理」, 産業図書, 1988.
- (3) Gene A. Tagliarini, J. Fury Christ, and Edward W. Page, "Optimization Using Neural Networks," *IEEE Transactions on Computers*, 40-12, pp.1347-1358, 1991.
- (4) Peter W. Protzel, Daniel L. Palumbo, and Michael K. Arras, "Performance and Fault Tolerance of Neural Networks for Optimizaton," *IEEE Transactions on Computers*, 4-4, pp.600-614, 1993.
- (5) James Ting-Ho, "Synthetic Approach to Optimal Filtering," *IEEE Transactions on Computers*, 5-5, pp.803-811, 1994.
- (6) 尾田十八, 水上孝之, 服部誠, 「ニューラルネットワークによる弾性接触応力分布の推定法」, 日本機械学会論文集 (A 編), 58-552, pp.238-243, 1992.
- (7) Arun D. Kulkarni, "Solving Ill-Posed Problems With Artificial Neural Networks," *Neural Networks*, 4, pp.477-484, 1991.
- (8) Etienne Barnard, "Optimization for Training Neural Nets," *IEEE Transactions on Neural Networks*, 3-2, pp.232-240, 1992.
- (9) Martin G. Bello, "Enhanced Training Algorithms, and Integrated Training/Architecture Selection for Multilayer Perceptron Networks," *IEEE Transactions on Neural Networks*, 3-6, pp.864-875, 1992.
- (10) Samir Shah, Francesco Palmieri, and Michael Datum, "Optimal Filtering Algorithms for Fast Learning in Feedforward Neural Networks," *Neural Networks*, 5, pp.779-782, 1992.

- (11) 馬場則夫, 最上義夫, 丸目雅行, 伊藤健, 「ニューラルネットの新しい学習アルゴリズムとその応用」, 第2回 FAN シンポジウム講演論文集, 920-87, pp.113-116, 1992.
- (12) 中野馨監修, 飯沼一元編, ニューロンネットグループ+桐谷滋著, 「入門と実習ニューロコンピュータ」, 技術評論社, 1989.
- (13) 青木繁, 水谷隆之, 「衝撃一点曲げ試験における逆問題解析」, 応用力学連合講演会講演予稿集, 42, pp.463-464, 1993.

Chapter 3

ニューラルネットワークとウェーブレット変換を用いた予き裂長さの推定

Estimation of pre-crack length using neural network and wavelet transform

ただその芸術性は、たった一つの物が欠けているために完全に破壊され、無価値になっていた—現実の事件である。

—連城三紀彦「戻り川心中」

Nevertheless, many people, like yourself, would like to know how this all works.

—K. Lunde "Understanding Japanese Information Processing"

3.1 緒言

破壊靱性試験においては、予き裂の長さを測定する必要がある。試験後の破面から予き裂長さを測定する場合には、光学顕微鏡等を用いた肉眼での観察により行われることが多い。しかし、目視観察は測定者への肉体的負担や個人差による測定精度の低下の問題が指摘されている⁽¹⁾。処理すべき試験片の本数が多い場合や、予き裂の先端が肉眼でははっきり観察できない場合においては、上記の問題はより顕著となる。

近年の画像処理技術の発達にともない、これを破面観察やき裂長の自動計測に利用しようという試みが行われている⁽²⁾⁻⁽⁷⁾。しかし、それらの手法ではSEMや高価な画像処理装置が必要であったり、データベースの構築が必要であったりすることが多く、簡単に利用するというわけにはいかない。

一方、信号処理・波形処理の分野において、ウェーブレット変換⁽⁸⁾が注目を集めている。ウェーブレット変換を用いると、不確定性関係の範囲内で時間と周波数両方の情報を得る

ことができるため、途中で周波数成分が変化するような問題の解析には有効である。

そこで本章では、試験による破断面と予き裂面に含まれる周波数成分の違いに着目し、ウェーブレット変換とニューラルネットワークを用いて、予き裂長さを簡便に推定できる手法について述べる。例として衝撃破壊靱性試験片を取り上げ、本手法を適用した結果と、目視観察による結果との比較についても述べる。

3.2 推定手法

本節では、まずウェーブレット変換について簡単に説明し、次にニューラルネットワークと組み合わせた推定手法について述べる。

3.2.1 ウェーブレット変換

ウェーブレット変換は、ある波形に含まれる周波数の成分が途中で変化する場合に、変化が起きた場所(または時間)を求めるための有効な手法である。ウェーブレット変換は資源探査の際の人工地震波の解析のために初めて導入され⁽⁸⁾⁻⁽¹⁰⁾、その後急速に各方面へ応用されるようになった。

時間(あるいは位置) t の関数 $f(t)(\in L^2(\mathbb{R}))$ のウェーブレット変換は、周波数に関するパラメータ a と時間(位置)に関するパラメータ b を用いて、次式

$$(\mathcal{W}_\psi f)(a, b) \equiv \frac{1}{|a|^{1/2}} \int_{-\infty}^{\infty} f(t) \bar{\psi} \left(\frac{t-b}{a} \right) dt \quad (3.1)$$

で定義される⁽¹¹⁾。 $\bar{\psi}$ は ψ の複素共役を表す。また、 ψ は基本ウェーブレットと呼ばれ、次式で示されるアドミッシブル条件 (Admissibility condition)

$$\int_{-\infty}^{\infty} \frac{|\hat{\psi}(\omega)|^2}{|\omega|} d\omega < \infty, \quad \psi \in L^2(\mathbb{R}) \quad (3.2)$$

を満たすような関数である。ここで、 $\hat{\psi}$ は ψ の Fourier 変換を表す。

本研究においては、基本ウェーブレットとして、次式で示される Gabor 関数⁽¹²⁾

●時間空間

$$\psi(t) = \frac{1}{\pi^{1/4}} \sqrt{\frac{\omega_0}{\gamma}} \exp \left(-\frac{(\omega_0/\gamma)^2}{2} t^2 + i\omega_0 t \right) \quad (3.3)$$

●周波数空間

$$\hat{\psi}(\omega) = \frac{\sqrt{2\pi}}{\pi^{1/4}} \sqrt{\frac{\gamma}{\omega_0}} \exp \left[-\frac{(\gamma/\omega_0)^2}{2} (\omega - \omega_0)^2 \right] \quad (3.4)$$

を用いた。式 (3.3) および (3.4) を図示すると図 3.1 のようになる。Gabor 関数は、時間-周波数解析における不確定性関係

$$\Delta_w \Delta_{\hat{w}} \geq \frac{1}{2} \quad (3.5)$$

$$\left[\begin{array}{l} \Delta_w \equiv \frac{1}{\|w\|_2} \left\{ \int_{-\infty}^{\infty} (t - t_w)^2 |w(t)|^2 dt \right\}^{1/2} \\ t_w \equiv \frac{1}{\|w\|_2^2} \int_{-\infty}^{\infty} t |w(t)|^2 dt \end{array} \right]$$

において、不確定性が最小 ($\Delta_w \Delta_{\hat{w}} = 1/2$) となる。また、Gabor 関数は厳密にはアドミッシブル条件 (3.2) を満たさないが、 $\gamma = \pi\sqrt{2/\ln 2}$ とおくと実質上問題ない程度に満たすとみなせることが知られている⁽¹³⁾。 ω_0 は $\hat{\psi}(\omega)$ の中心周波数であり、本研究では 2π とした⁽¹⁴⁾。

3.2.2 推定手順

測定される波形をウェーブレット変換した結果は漠然としたものになることが多いため、大略の傾向をつかむことはできるが、変化が現れた時間あるいは位置を人間が判断することは難しい。そこで本節においては、前章で開発したニューラルネットワークを用いて、ウェーブレット変換の結果の評価を行い、予き裂長さの推定を行う手法について述べる (図 3.2)。

まず、破面画像より、試験による破断面および予き裂面の双方を含む一列の画素を切り出す。この際、画像にノイズ等の影響があると考えられる場合には、数列分の画素をを平均したものを用いる。

次に、切り出した画素列を離散波形とみなして、これにウェーブレット変換を適用する。

得られたウェーブレット変換の結果は前述のようにパラメータ a および b の関数となる (ここでは実際には離散関数)。ここで、どちらかの破面に属していることが明らかな b を適当な数だけ選択し、ひとつの b における $(W_\psi f)(a, b)$ の値 (a を離散化した個数だけ得られる) を一組の教師入力とし、 b が予き裂位置であれば出力教師を (例えば) 0、試験破断面位置であれば出力教師を (例えば) 1 とし、ニューラルネットワークの重みを決定する。

そして、この重みを使って、すべての b におけるニューラルネットワークの出力を計算し、1 および 0 の出力の累積度数をプロットする。グラフの傾きが急変する位置を予き裂先端位置であると推定する。

3.3 解析例

本手法の有効性を示すため、一点曲げ衝撃破壊試験片に適用した。

供試材料は、エー・エム・テクノロジー社製 Al_2O_3 パウダー/ Al 複合材料 (Al_2O_3 60%: Al 40%, パウダー径約 $2\mu m$, 以下アルミナパウダー材と呼ぶ) および Al_2O_3 ファイバー/ Al 複合材料 (Al_2O_3 20%: Al 80%, ファイバー径約 $3\mu m$, 長さ約 $60\mu m$, ランダム配向, 以下アルミナファイバー材と呼ぶ) である。試験片形状は、断面 $8mm \times 6mm$, 長さ $50mm$ である。中央にストレートノッチ ($4mm$) および疲労予き裂 ($2mm$ を目安) を導入した後、衝撃破壊試験によって破断させた試験片⁽¹⁵⁾の破断面を、256 階調モノクロ CCD カメラ (プロテックジャパン (株) 製 CV-31SHE, (株) モリテックス製マクロレンズ ML-5010 使用) により撮像した。撮像した画像は、画像入力ボード (カノーパス (株) 製 VIDEOPAQ-98) を介してパーソナルコンピュータ (日本電気 (株) 製 PC-9801RA2) に取り込んだ後、ワークステーションへ転送して PGM 形式に変換した。

図 3.3 に試験片断面および撮像範囲の概略を示す。座標は画像左上を原点とし、縦に x 軸、横に y 軸をとった。また、従来の目視観察では、断面の中央および左右両端での予き裂長さを計測しているので、本研究においても、各試験片についてそれぞれ中央および両端の 3 箇所について推定を行った。

初めに、アルミナパウダー材について解析した結果を示す。使用した試験片の破断面画像を図 3.4 に示す。図 3.4 において推定を行った具体的な y 座標位置は、表 3.1 に示す通りである。ノイズ低減のために各位置とも 3 列の平均値を用いた。目視観察による測定値、およびその図 3.4 における x 座標値を表 3.2 に示す。

表 3.1 の 3 つの位置における平均 pixel 値の分布を図 3.5~図 3.7 に示す。いずれも、 x の小さい方が試験片画像の上方側である。これらの図からは疲労予き裂先端位置を直接推定することは困難である。例えば、図 3.6 より波形の一部 (40pixel 分) をいくつか切り出し、それを直接ニューラルネットワークの教師として決定した重みを用いて、 $x = 0$ から順に 40pixel 分を入力したときの出力を計算したところ、図 3.8 のように、目視観察の結果と全く違った位置 ($x = 314$) を推定してしまった。これは、波形を直接利用した場合には、周波数情報よりも pixel 値の情報が優先されてしまうためと考えられる。

そこで、各位置 x における周波数の情報を得るため、図 3.5~図 3.7 の波形をウェーブレット変換した結果が図 3.9~図 3.11 である。Gabor 関数によるウェーブレット変換の結果は複素数となるため、いずれの図においても (a) に絶対値、(b) に位相を示してある。これらの図より、図 3.9(a) では $b (= x) < 185$ の部分 (衝撃による破断面側) と $b > 210$ の部分 (疲労による断面) の間、図 3.10(a) では $b < 160$ の部分と $b > 200$ の部分の間、図 3.11(a) では

$b < 190$ の部分と $b > 220$ の部分の間において含まれる周波数成分に違いがあることがわかる。しかし、その境界ははっきりしていない。

次に、表 3.3 に示す b におけるウェーブレット変換の値 (一つの b に対して 31 個の成分をもつ) を入力側教師、衝撃破壊破面に対する出力側教師を 1、疲労き裂面に対する出力教師を 0 として、入力層ユニット数 41、中間層ユニット数 32、出力層ユニット数 1 の 3 層ニューラルネットワークの重みを決定し、その重みを用いてすべての $b (= 0 \sim 479)$ におけるウェーブレット変換の値を入力したときの出力値を求めた。その結果を図 3.12~図 3.14 に示す。

さらに、0.7 以上の値を 1、0.3 以下の値を 0 とみなし、その中間の値は除外して、 $b = 0$ より順に累積度数をプロットすると、図 3.15~図 3.17 のようになった。いずれも実線が衝撃破壊面と判定された度数、破線が疲労予き裂面と判定された度数である。これらの図より、疲労き裂の先端は一点鎖線で示した位置、すなわち左端で $b = 201$ 、中央で $b = 172$ 、右端で $b = 195$ のところにあると推定され、これは、表 3.2 の肉眼による測定結果 (図中の矢印位置) とほぼ一致する。

次に、アルミナパウダー材の他の試験片について、同様の解析を行った結果を示す。用いた試験片の破断面画像は図 3.18 である。

この画像から、表 3.4 に示した y 座標におけるピクセル値列を取り出した。取り出した 3 個のピクセル値列を図 3.19~図 3.21 に示す。また、目視観察によるき裂先端位置を表 3.5 に示す。

これらの波形をウェーブレット変換した結果が図 3.22~図 3.24 である。いずれの図においても (a) に $(W_\psi f)(a, b)$ の絶対値、(b) に位相を示してある。これらの図より、図 3.22(a) では $b (= x) < 200$ の部分 (衝撃による破断面側) と $b > 235$ の部分 (疲労による断面) の間、図 3.23(a) では $b < 190$ の部分と $b > 225$ の部分の間、図 3.24(a) では $b < 200$ の部分と $b > 235$ の部分の間において含まれる周波数成分に違いがあることがわかるが、その境界ははっきりしていない。

次に、表 3.6 に示す b におけるウェーブレット変換の値 (一つの b に対して 31 個の成分をもつ) を入力側教師、衝撃破壊破面に対する出力側教師を 1、疲労き裂面に対する出力教師を 0 として、第 1 の試験片の解析で用いたのと同じニューラルネットワークの重みを決定し、その重みを用いてすべての $b (= 0 \sim 479)$ におけるウェーブレット変換の値を入力したときの出力値を求めた。その結果を図 3.25~図 3.27 に示す。

さらに、0.7 以上の値を 1、0.3 以下の値を 0 とみなし、その中間の値は除外して、 $b = 0$ より順に累積度数をプロットすると、図 3.28~図 3.30 のようになった。いずれも実線が衝

撃破壊面と判定された度数，破線が疲労予き裂面と判定された度数である．これらの図より，疲労き裂の先端は一点鎖線で示した位置，すなわち左端で $b = 216$ ，中央で $b = 196$ ，右端で $b = 212$ のところにあると推定され，これは，表 3.5 の肉眼による測定結果（図中の矢印位置）とほぼ一致する．

最後に，アルミナファイバー材の試験片について，同様の解析を行った結果について述べる．図 3.31 に使用した試験片の破断面画像を示す．

この画像に対して，表 3.7 の y 座標におけるピクセル値列を取り出した．取り出した 3 個のピクセル値列を図 3.32～図 3.34 に示す．また，目視観察によるき裂先端位置を表 3.8 に示す．

これらの波形をウェーブレット変換した結果が図 3.35～図 3.37 である．いずれの図においても (a) に $(W_\psi f)(a, b)$ の絶対値，(b) に位相を示してある．これらの図より，図 3.35(a) では $b(=x) < 175$ の部分（衝撃による破断面側）と $b > 205$ の部分（疲労による断面）の間，図 3.36(a) では $b < 170$ の部分と $b > 205$ の部分の間，図 3.37(a) では $b < 170$ の部分と $b > 205$ の部分の間において含まれる周波数成分に違いがあることがわかるが，その境界ははっきりしていない．


次に，表 3.9 に示す b におけるウェーブレット変換の値（一つの b に対して 31 個の成分をもつ）を入力側教師，衝撃破壊破面に対する出力側教師を 1，疲労き裂面に対する出力教師を 0 とし，第 1 の試験片の解析で用いたのと同じニューラルネットワークの重みを決定し，その重みを用いてすべての $b(= 0 \sim 479)$ におけるウェーブレット変換の値を入力したときの出力値を求めた．その結果を図 3.38～図 3.40 に示す．

さらに，0.7 以上の値を 1，0.3 以下の値を 0 とみなし，その中間の値は除外して， $b = 0$ より順に累積度数をプロットすると，図 3.41～図 3.43 のようになった．いずれも実線が衝撃破壊面と判定された度数，破線が疲労予き裂面と判定された度数である．これらの図より，疲労き裂の先端は一点鎖線で示した位置，すなわち左端で $b = 192$ ，中央で $b = 206$ ，右端で $b = 208$ のところにあると推定され，これは，表 3.8 の肉眼による測定結果（図中の矢印位置）とほぼ一致する．


3.4 結 言

本章では，破壊靱性試験における測定者の疲労を軽減するため，ウェーブレット変換と前節で述べたニューラルネットワークを用いた，試験片の破断面画像から予き裂の先端位置を推定する手法の開発について述べた．また，その有効性を示すため，同手法を実際の

衝撃破壊試験片に適用して、肉眼による予き裂長の測定値とほぼ一致する結果が得られたことを示した。



(a) 時間空間



(b) 周波数空間

Figure 3.1: Gabor 関数




Figure 3.2: 予き裂長推定の手順




Figure 3.3: 試験片断面と撮像範囲の概略




Figure 3.4: 試験片破断面画像 (アルミナパウダー材 1)

Table 3.1: 推定を行った pixel 列の y 座標値 (アルミナパウダー材試験片 1)

Left	$y=19, 20$ and 21
Center	$y=319, 320$ and 321
Right	$y=619, 620$ and 621

Table 3.2: 目視観察による予き裂長

	Measured length (mm)	x in fig.3.4
Left	5.997	202
Center	6.273	175
Right	6.052	197




Figure 3.5: 平均 pixel 値の分布 (アルミナパウダー材試験片 1, 左端)




Figure 3.6: 平均 pixel 値の分布 (アルミナパウダー材試験片 1, 中央)




Figure 3.7: 平均 pixel 値の分布 (アルミナパウダー材試験片 1, 右端)

第1層(入力層)ユニット数 : 40
 第2層(中間層)ユニット数 : 12
 第3層(出力層)ユニット数 : 1

●教師入力

$x = 20, 40, 60, 80, 100, 120$ (衝撃破断面) }
 $x = 210, 240, 270, 300, 330, 370$ (疲労予き裂面) }
 から 40pixel 分 (計 12 組)

●教師出力

衝撃破断面 $\rightarrow 1$
 疲労予き裂面 $\rightarrow 0$






Figure 3.8: 波形から予き裂長を直接推定した例




(a) Intensity




(b) Phase

Figure 3.9: ウェーブレット変換結果 (アルミナパウダー材試験片 1, 左端)




(a) Intensity




(b) Phase

Figure 3.10: ウェーブレット変換結果 (アルミナパウダー材試験片 1, 中央)



(a) Intensity



(b) Phase

Figure 3.11: ウェーブレット変換結果 (アルミナパウダー材試験片 1, 右端)

Table 3.3: 入力側教師の位置 b (アルミナパウダー材試験片 1)

	Dynamic Fracture	Fatigue Pre-crack
Left	30 ~ 180 (every 10)	220 ~ 445 (every 15)
Center	5 ~ 155 (every 10)	205 ~ 430 (every 15)
Right	30 ~ 180 (every 10)	225 ~ 450 (every 15)




Figure 3.12: ニューラルネットワークによるウェーブレット変換結果の分類
(アルミナパウダー材試験片 1, 左端)




Figure 3.13: ニューラルネットワークによるウェーブレット変換結果の分類
(アルミナパウダー材試験片1, 中央)




Figure 3.14: ニューラルネットワークによるウェーブレット変換結果の分類
(アルミナパウダー材試験片 1, 右端)




Figure 3.15: 累積度数分布 (アルミナパウダー材試験片 1, 左端)




Figure 3.16: 累積度数分布 (アルミナパウダー材試験片 1, 中央)




Figure 3.17: 累積度数分布 (アルミナパウダー材試験片 1, 右端)




Figure 3.18: 試験片破断面画像 (アルミナパウダー材試験片 2)

Table 3.4: 推定を行った pixel 列の y 座標値 (アルミナパウダー材試験片 2)

Left	$y=29, 30$ and 31
Center	$y=319, 320$ and 321
Right	$y=609, 610$ and 611

Table 3.5: 目視観察による予き裂長

	Measured length (mm)	x in fig.3.18
Left	5.823	220
Center	5.984	204
Right	5.796	222




Figure 3.19: 平均 pixel 値の分布 (アルミナパウダー材試験片 2, 左端)




Figure 3.20: 平均 pixel 値の分布 (アルミナパウダー材試験片 2, 中央)






Figure 3.21: 平均 pixel 値の分布 (アルミナパウダー材試験片 2, 右端)




(a) Intensity




(b) Phase

Figure 3.22: ウェーブレット変換結果 (アルミナパウダー材試験片 2, 左端)




(a) Intensity




(b) Phase

Figure 3.23: ウェーブレット変換結果 (アルミナパウダー材試験片 2, 中央)



(a) Intensity



(b) Phase

Figure 3.24: ウェーブレット変換結果 (アルミナパウダー材試験片 2, 右端)

Table 3.6: 入力側教師の位置 b (アルミナパウダー材試験片 2)

	Dynamic Fracture	Fatigue Pre-crack
Left	40 ~ 190 (every 10)	240 ~ 465 (every 15)
Center	30 ~ 180 (every 10)	230 ~ 455 (every 15)
Right	40 ~ 190 (every 10)	240 ~ 465 (every 15)




Figure 3.25: ニューラルネットワークによるウェーブレット変換結果の分類
(アルミナパウダー材試験片 2, 左端)




Figure 3.26: ニューラルネットワークによるウェーブレット変換結果の分類
(アルミナパウダー材試験片 2, 中央)




Figure 3.27: ニューラルネットワークによるウェーブレット変換結果の分類
(アルミナパウダー材試験片 2, 右端)




Figure 3.28: 累積度数分布 (アルミナパウダー材試験片 2, 左端)




Figure 3.29: 累積度数分布 (アルミナパウダー材試験片 2, 中央)




Figure 3.30: 累積度数分布 (アルミナパウダー材試験片 2, 右端)



Figure 3.31: 試験片破断面画像 (アルミナファイバー材試験片)

Table 3.7: 推定を行った pixel 列の y 座標値 (アルミナファイバー材試験片)

Left	$y=29, 30$ and 31
Center	$y=319, 320$ and 321
Right	$y=609, 610$ and 611

Table 3.8: 目視観察による予き裂長

	Measured length (mm)	x in fig.3.31
Left	6.102	196
Center	6.080	198
Right	5.998	206




Figure 3.32: 平均 pixel 値の分布 (アルミナファイバー材試験片, 左端)




Figure 3.33: 平均 pixel 値の分布 (アルミナファイバー材試験片, 中央)






Figure 3.34: 平均 pixel 値の分布 (アルミナファイバー材試験片, 右端)




(a) Intensity




(b) Phase

Figure 3.35: ウェーブレット変換結果 (アルミナファイバー材試験片, 左端)




(a) Intensity




(b) Phase

Figure 3.36: ウェーブレット変換結果 (アルミナファイバー材試験片, 中央)



(a) Intensity



(b) Phase

Figure 3.37: ウェーブレット変換結果 (アルミナファイバー材試験片, 右端)

Table 3.9: 入力側教師の位置 b (アルミナファイバー材試験片)

	Dynamic Fracture	Fatigue Pre-crack
Left	20 ~ 170 (every 10)	210 ~ 435 (every 15)
Center	15 ~ 165 (every 10)	210 ~ 435 (every 15)
Right	15 ~ 165 (every 10)	210 ~ 435 (every 15)




Figure 3.38: ニューラルネットワークによるウェーブレット変換結果の分類
(アルミナファイバー材試験片, 左端)




Figure 3.39: ニューラルネットワークによるウェーブレット変換結果の分類
(アルミナファイバー材試験片, 中央)




Figure 3.40: ニューラルネットワークによるウェーブレット変換結果の分類
(アルミナファイバー材試験片, 右端)




Figure 3.41: 累積度数分布 (アルミナファイバー材試験片, 左端)




Figure 3.42: 累積度数分布 (アルミナファイバー材試験片, 中央)




Figure 3.43: 累積度数分布 (アルミナファイバー材試験片, 右端)

参考文献

- (1) 河野嗣男, 「表面欠陥検査の展望」, 精密工学会誌, 53-8, pp.1141-1143, 1987.
- (2) 箕島弘二, 尾嶋正樹, 駒井謙治郎, 「高強度鋼の SCC き裂進展に及ぼす応力繰返し速度・波形効果と粒界・粒内破面の自動判別」, 日本機械学会論文集 (A 編), 54-500, pp.670-678, 1988.
- (3) 箕島弘二, 長崎達夫, 駒井謙治郎, 「コンピュータ画像処理技術を用いた破面性状の自動判別」, 日本機械学会論文集 (A 編), 56-525, pp.1318-1323, 1990.
- (4) 西川出, 森川自, 藤原広次, 三好良夫, 小倉敬二, 「画像処理援用き裂進展試験システムの開発と中高温下 K 値制御疲労試験への応用」, 材料, 40-449, pp.235-241, 1991.
- (5) 石井明, 佐々木茂美, 越智保雄, 田崎憲司, 「材料強度研究における表面微小き裂検出への画像処理技術」, 材料試験技術, 34-1, pp.11-18, 1989.
- (6) 加藤雄平, 奥村孝章, 糸賀興右, 原田鉄造, 杉本幸治, 道場康二, 井内貞夫, 「放射線透過写真の自動合否判定システムの開発 (第 1 報) —画像処理による欠陥像の抽出—」, 非破壊検査, 41-4, pp.186-195, 1994.
- (7) 加藤雄平, 奥村孝章, 糸賀興右, 原田鉄造, 杉本幸治, 道場康二, 川野征志郎, 「放射線透過写真の自動合否判定システムの開発 (第 2 報) —溶接欠陥の種類識別機能の開発—」, 非破壊検査, 41-4, pp.196-206, 1994.
- (8) J. Morlet, G. Arens, I. Fourceau and D. Giard, "Wave propagation and sampling theory," *Geophysics*, 47, pp.203-236, 1982.
- (9) A. Grossmann and J. Morlet, "DECOMPOSITION OF HARDY FUNCTIONS INTO SQUARE INTEGRABLE WAVELETS OF CONSTANT SHAPE," *SIAM Journal of Applied Mathematics*, 15, pp.723-736, 1984.

- (10) P. Goupillaud, A. Grossmann and J. Morlet, "CYCLE-OCTAVE AND RELATED TRANSFORMS IN SEISMIC SIGNAL ANALYSIS," *Geoexploration*, 23, pp.85-102, 1984.
- (11) 例えば, Ingrid Daubechies, *Ten Lectures on Wavelets*, SIAM, 1992.
- (12) D.Gabor, "THEORY OF COMMUNICATION," *Journal of the Institution of Electrical Engineers*, 93(III), pp.429-457, 1946.
- (13) 佐藤雅昭, 「ウェーブレット理論の数学的基礎 第I部—非直交ウェーブレット—」, 日本音響学会誌, 47-6, pp.405-423 1991.
- (14) 井上裕嗣, 岸本喜久雄, 中西智明, 渋谷壽一, 「ウェーブレット変換による分散性応力波の時間-周波数解析 (群速度の同定と超音波材料評価への応用)」, 日本機械学会論文集 (A 編), 61-581, pp.153-160, 1995.
- (15) 高橋伸一郎, 青木繁, 「セラミック強化金属の高温衝撃破壊靱性」, 日本機械学会論文集 (A 編), 57-532, pp.1073-1078, 1991.

Chapter 4

GA とクラスタリングを併用した 最適化手法

Optimization Method Using Genetic Algorithm and Clustering

'Their heads are gone, if it please your Majesty!'
—L. Carroll "Alice's Adventures in Wonderland"

すべての創られたるものに恵みあれ。
死なざるもののめぐし子に幸いあれ。
—倉田百三「出家とその弟子」

4.1 緒 言

さまざまな分野に存在する最適化の問題において、対象となる目的関数が多峰性を持つ場合がしばしば現れる。このような問題に対して、共役勾配法や Newton-Raphson 法のような降下法を適用するとすれば、異なったいくつかの初期値から探索を行い、それぞれの計算から得られた解を比較して最適解を探すという作業が必要となる。さらに、得られた解が最適であることを保証するために、初期値の数を多くし、なおかつ広く分散させる必要がある。また、降下法では変数の数が多くなるにつれて、勾配を求めるためなどの計算量が膨大になる可能性もある。

近年、そのような最適化問題に対して、遺伝的アルゴリズム (Genetic Algorithms, 以下 GA) ⁽¹⁾⁽²⁾ が注目を集めており、制御 ⁽³⁾⁽⁴⁾、組合せ最適化問題 ⁽⁵⁾⁽⁶⁾、をはじめ、さまざまな分野の研究に応用されている。しかし、GA は大域収束性に優れているが局所収束には時間がかかるという特徴があり ⁽¹⁰⁾、厳密な正解を得るためにはかなりの計算時間を必要とする。中村らは GA の結果を降下法等の初期値とすることによって、この問題の解決をはかっている ⁽¹¹⁾。

本章では、GA にクラスタリングと降下法を組み合わせることにより、多峰性目的関数を有する多次元の最適化問題をより効率的に行うことが可能な手法の開発について述べる。

4.2 計算手法

4.2.1 GA へのクラスタリングの導入

第1章で述べたように、GA とは生物の進化をモデル化したシステムである。GA での個体の進化(すなわち収束)過程を大まかに表すと図 4.1 のようになる。GA では、図 4.1(a)→(b) の過程(大域的収束)にはそれほど時間を必要としないが、(b)→(c)→(d) の過程(局所的収束)には多くの計算時間を要することが知られている。

そこで、本研究では GA の大域的収束性のよさに着目して、大域的に収束した時点の GA の個体分布にクラスタリングを施し、得られたクラスタの中心を降下法の初期値とすることによって、多峰性目的関数を持つ最適化問題の解を短時間で得ることを考えた。すなわち、まず、図 4.2(a) のように、適当な世代まで GA の計算を行う。このとき、完全に収束するまで計算を続ける必要はない。次に、GA によって得られた個体の分布に対して、後述するクラスタリングを適用し(図 4.2(b))、各クラスタの中心を求める(図 4.2(c))。そして、得られたクラスタ中心を初期値として、共役勾配法などの降下法により最適解を求める(図 4.2(d))。

多次元問題におけるクラスタリングを行う場合には、人間があらかじめクラスタの数を判断することが困難である。そのため、本研究においては、あらかじめクラスタ数を知っておく必要のない階層的クラスタリング⁽¹²⁾を用いた。階層的クラスタリングとは、まずクラスタ数を適当に定めて非階層的クラスタリングを行い、最も接近している二つのクラスタを統合し、クラスタ数を一つ減らして再び非階層的クラスタリングを行うという作業を、全てのクラスタ間距離があらかじめ定めた値よりも大きくなるまで繰り返すものである。非階層的クラスタリングの部分には ISODATA⁽¹³⁾を用いた。これは、クラスタ数があらかじめ分かっているとき、適当なクラスタ中心初期位置を与えてクラスタリングを行い、その結果から新たなクラスタ中心を計算し、その中心を用いて再びクラスタリングを行うという作業を、中心位置が動かなくなるまで繰り返す方法である。

結局、クラスタリングの手順は以下のようなになる。

- 1) GA の対象集団中の各個体の持つデータを初期クラスタ中心とする(個体数=クラスタ数となる)。
- 2) 最も近い二つのクラスタを統合し、そのクラスタに属するデータより新たな中心を計算する。統合によりクラスタ数が1になる場合には計算終了とする。
- 3) 2) で求めた中心位置を初期値として ISODATA によりクラスタリングを行う。

4) クラスタの中心間距離が既定値以上になるまで 2), 3) を繰り返す。

なお、距離としてはユークリッドノルムを、クラスタ中心としては重心を用いた。

本手法においては、図 4.1(b) のような状況からクラスタリングを行うので、結果として複数のクラスタが得られることがある。その場合には、降下法による最適化をクラスタの数だけ行わなければならないが、ランダムに初期値を定めて計算を行う場合よりも効率的に最適解を得ることができると思われる。

4.2.2 解析例

本手法の有効性を示すため、例題として次式で与えられる関数 $f(x_1, x_2)$ の最小化問題⁽¹⁾ に対して適用を行った。

$$f(x_1, x_2) = \frac{1}{1 + \sum_{j=1}^{25} \left[1 / \left\{ j + \sum_{i=1}^2 (x_i - a_{ji})^6 \right\} \right]} \quad (4.1)$$

$$a_{j1} = \{-32, -16, 0, 16, 32, \\ -32, -16, 0, 16, 32, \\ -32, -16, 0, 16, 32, \\ -32, -16, 0, 16, 32, \\ -32, -16, 0, 16, 32\}$$

$$a_{j2} = \{-32, -32, -32, -32, -32, \\ -16, -16, -16, -16, -16, \\ 0, 0, 0, 0, 0, \\ 16, 16, 16, 16, 16, \\ 32, 32, 32, 32, 32\}$$

$$-35 \leq x_i \leq 35 \quad (i = 1, 2)$$

式 (4.1) が表す面を図示すると図 4.3 のようになり、25 個の極値を持つような 3 次元曲面であることがわかる。最小値は $(-32, -32)$ にあり、そのとき $f = 0.5$ である。

本例題に適用した GA の諸元は以下の通りである。

- x_1, x_2 とも 8bit に量子化。

- 個体 i の適応度を $F_i = 1/f(x_1, x_2)$, 選択確率を $p_i = F_i / \sum_i F_i$ とした.
- 集団中の個体数は 100.
- 突然変異の確率は 0.02.

図 4.4 に, 500 世代まで計算を行った結果を示す. 50 世代程度でいくつかの極値に個体が集まっているが, 500 世代目においても最小値以外のところに集まっている個体が少ないことがわかる.

そこで, 50 世代目の集団に対してクラスタリングを行った. クラスタリングの終了条件は, 各クラスタ間の中心距離が 3 以上とした. その結果を図 4.5 に示す. 図中の 6 つの○印が得られたクラスタの中心である.

次に, 得られた 6 つのクラスタ中心を初期値として, Downhill Simplex Method⁽¹⁴⁾⁽¹⁵⁾により極値の探索を行った. その結果を図 4.6 に示す. 収束条件は, シンプレックスの各頂点における目的関数値の差の合計が 1×10^{-10} 以下とした. また, 収束時の目的関数の値を表 4.1 に示す. これらの図表より, 最小値が得られていることが確かめられる.

計算に要した時間は, Sun Microsystems 社製 SPARCstation10 model30 を用いて約 30 秒であった. 参考のため, GA を 500 世代で打ち切って, そのときの最大適応度の個体を初期値としてシンプレックス法により解を求めた場合には約 60 秒であった. GA のみで完全に最小値に収束させる計算は行わなかったが, もし行った場合にはこの数倍の時間がかかると考えられる.

4.3 カソード 防食電極位置最適化問題への応用

本節では, カソード防食における電極位置および電流密度の最適化問題に本手法を適用した結果について述べる.

まず, カソード防食システムについて簡単に説明する.

図 4.7 に示すように, 電解物質領域 Ω の表面が $\Gamma (= \Gamma_d + \Gamma_n + \Gamma_m)$ によって囲まれているとする. ここで, Γ_d においては電位 $\phi = \phi_0$ が, Γ_n においては電流密度 $q = q_0$ がそれぞれ与えられている. Γ_m は金属表面であり, 分極曲線 $\phi = f(q)$ と防食条件

$$-\phi \leq E_p \quad (4.2)$$

が与えられている. 電極 e は Ω に較べて充分小さいとする.

このとき, Ω 中の電位 $\phi (= -E)$ はポアソン方程式に従う.

$$\kappa \nabla^2 \phi = \sum_{i=1}^{m_e} Q_{e_i} \delta(\mathbf{x} - \mathbf{x}_{e_i}) \quad (4.3)$$

ここで、 κ は電導度、 $\delta(\cdot)$ はDiracのデルタ関数、 m_e は電極の数、 Q_{e_i} および $\mathbf{x}_{e_i}$ はそれぞれ i 番目の電極の印加電圧および位置である。境界条件は以下ようになる。

$$\phi = \phi_0 \quad \text{on } \Gamma_d \quad (4.4)$$

$$q = q_0 \left(\equiv \kappa \frac{\partial \phi}{\partial n} \right) \quad \text{on } \Gamma_n \quad (4.5)$$

$$-\phi = f(q) \quad \text{on } \Gamma_m \quad (4.6)$$

最適な印加電流は、防食条件を満たし、かつ電力が最小となるようなものとした。すなわち、式(4.2)~(4.6)の条件の下に、目的関数

$$P = \sum_{i=1}^{m_e} \int_{\Gamma_{e_i}} \{ \phi_{e_i} + f_{e_i}(q_{e_i}) \} q_{e_i} d\Gamma \quad (4.7)$$

を最小にするような q_{e_i} を最適な電流(密度)値とする。

次に、実際に解析を行った結果について述べる。

解析に用いたモデルは、図4.8に示される、大きさが縦 $0.5a$ 横 a で、凹部および絶縁部を有する2次元金属容器である。防食に用いる電極は3個とした。電極1個あたりの変数は位置 (x, y) および電流密度 q の3個であるので、全体では $(x_1, y_1, q_1, x_2, y_2, q_2, x_3, y_3, q_3)$ の9個となる。目的関数の概形を把握することは難しく、したがって降下法の初期値を直観的に定めることは困難である。

GAにおいては、上記の9変数をそれぞれ6bitで量子化し、遺伝子とした。染色体の長さは54bitとなる。 x, y, q の最小値、最大値は表4.2の通りとした。

個体の適応度 F は、個体を持つ電極位置および電極電流密度の情報から境界要素法を用いて場を解析し、電極の電力(式(4.7))と、防食すべき金属表面上で電位が防食電位 E_p を越えた場合のペナルティ

$$b = k \sum_{j=1}^n (\phi_j + E_p) u(-\phi_j - E_p) \quad (4.8)$$

の和の逆数

$$F = \frac{1}{P + b} \quad (4.9)$$

とした。ここで、 k は正の大きな定数(ペナルティ係数)、 n は防食すべき境界の要素分割数、 ϕ, ϕ_e は要素および電極の電位、 Γ_e は電極表面境界、 $u(\cdot)$ は単位ステップ関数である。ただし、本解析では電極表面での分極は無視できるとして、電力 P の計算式は

$$P = \sum_{i=1}^3 \int_{\Gamma_{e_i}} \phi_{e_i} q_{e_i} d\Gamma \quad (4.10)$$

を用いた。

また、個体が容器右上の凹部に入った場合には、その適応度は極めて 0 に近い値とした。

その他のパラメータは、集団中の個体数 200、突然変異の確率 0.1 とした。また、防食電位は $E_p = -1$ 、電導度 $\kappa = 0.01$ 、ペナルティ係数 $k = 10^3$ とし、金属の分極曲線は $-\phi = q$ を用いた。

まず、500 世代まで GA の計算を行い、図 4.9~4.11 に個体の (x_1, y_1) , (x_2, y_2) および (x_3, y_3) の分布の変化、すなわち、9 個の設計変数を作る 9 次元空間の (x_1, y_1) 平面、 (x_2, y_2) 平面および (x_3, y_3) 平面への投影図を示す。これらの図より、数十世代程度で大まかなクラスタが形成され、その後はクラスタの大きさが狭まっていくだけであるが、500 世代目でもまだ完全には収束していないことがわかる。

そこで、30 世代目の集団に対してクラスタリングを行い、その結果 3 個のクラスタを得た。得られたクラスタ中心の位置は表 4.3 の通りであり、 (x_1, y_1) , (x_2, y_2) および (x_3, y_3) の分布とともに示すとそれぞれ図 4.12(a)~(c) となる。

得られた 3 個のクラスタ中心を初期値として共役勾配法を用いて最適化を行ったところ(収束条件：勾配ベクトルの大きさが 1×10^{-5} 以下)、表 4.4 のようにいずれもほぼ同じ値に収束した。 (x_1, y_1) , (x_2, y_2) および (x_3, y_3) 平面で示すと図 4.13(a)~(c) のようになる。

また、このときの金属表面の電位および電流密度分布をそれぞれ図 4.14、図 4.15 に示す。これらの図より、金属表面全域で防食条件が満足されていることがわかる。

本例題の計算に要した時間は、Sun Microsystems 社製 SPARCstation10 model30 を用いて約 40 分であった。参考のために、GA500 世代の計算時間は約 80 分、GA を 500 世代で打ち切り、そのときの最大適応度の個体を初期値として共役勾配法によって解を求めた場合には合計で約 120 分であった。適当に初期値を定めて共役勾配法のみで最適化を行った場合には、一つの初期値に対して約 40 分~数時間(初期値に依存)を必要とし、また、計算が収束しない初期値もあった。

4.4 結 言

本章においては、遺伝的アルゴリズム (GA) の大域収束性のよさに着目し、クラスタリングおよび降下法と組み合わせることによって、単に GA のみを用いた場合、および GA を降下法を組み合わせた場合よりも短時間で、多峰性目的関数を有する最適化問題の最適解を求める手法を開発した。その手法を、多峰性関数最適化の例題およびカソード防食最適化問題に適用し、降下法のみ、および GA と降下法の組み合わせの数分の一以下の時間で最適解を得ることにより、本手法の有効性を示した。




Figure 4.1: GA の収束の概略







Figure 4.2: GA とクラスタリングの併用


Figure 4.3: 関数 $f(x_1, x_2)$ の形状




(a) 第 0 世代



(a) 第 50 世代



(a) 第 100 世代



(a) 第 500 世代

Figure 4.4: 各世代における個体の分布




Figure 4.5: 第 50 世代における個体とクラスタ中心




Figure 4.6: シンプレックス法による最終探索

Table 4.1: 収束点と関数値

Initial			Results			Theoretical		
x_1	x_2	f	x_1	x_2	f	x_1	x_2	f
-32.44	-32.15	0.502	-31.99	-32.00	0.500	-32.00	-32.00	0.500
-18.78	-32.41	0.998	-15.98	-31.97	0.667	-16.00	-32.00	0.667
-14.86	-32.19	0.809	-16.00	-31.97	0.667			
3.000	-32.47	0.999	0.007	-31.97	0.750	0.000	-32.00	0.750
0.228	-32.13	0.750	-0.009	-31.97	0.750			
16.21	-32.31	0.800	16.00	-31.95	0.800	16.00	-32.00	0.800




Figure 4.7: カソード防食システム




Figure 4.8: カソード防食最適化問題解析モデル

Table 4.2: x_e, y_e, Q_e の範囲

	x_e/a	y_e/a	$Q_e/8\varepsilon$
Min.	-0.49	0.01	8.00
Max.	0.49	0.49	16.0





Figure 4.9: 各世代における (x_{e1}, y_{e1}) の分布

Figure 4.10: 各世代における (x_{e_2}, y_{e_2}) の分布






Figure 4.11: 各世代における (x_{e3}, y_{e3}) の分布

Table 4.3: クラスタ中心 (第 30 世代)


	x_{e_1}/a	y_{e_1}/a	$Q_{e_1}/8\varepsilon$
Cluster 1	-0.345	0.284	13.66
Cluster 2	-0.336	0.292	14.00
Cluster 3	-0.365	0.297	13.99
	x_{e_2}/a	y_{e_2}/a	$Q_{e_2}/8\varepsilon$
Cluster 1	0.268	0.116	12.49
Cluster 2	0.371	0.168	12.52
Cluster 3	0.350	0.102	12.59
	x_{e_3}/a	y_{e_3}/a	$Q_{e_3}/8\varepsilon$
Cluster 1	0.044	0.254	13.11
Cluster 2	0.027	0.290	13.21
Cluster 3	0.081	0.343	13.43



(a) (x_1, y_1)



(b) (x_2, y_2)



(c) (x_3, y_3)

Figure 4.12: 第 30 世代における個体とクラスタ中心

Table 4.4: 最適電極位置および電流密度

	x_{e_1}/a	y_{e_1}/a	$Q_{e_1}/8\varepsilon$
Cluster 1	-0.353	0.279	15.25
Cluster 2	-0.353	0.279	15.24
Cluster 3	-0.352	0.279	15.26
	x_{e_2}/a	y_{e_2}/a	$Q_{e_2}/8\varepsilon$
Cluster 1	0.377	0.147	9.097
Cluster 2	0.377	0.147	9.116
Cluster 3	0.377	0.147	9.101
	x_{e_3}/a	y_{e_3}/a	$Q_{e_3}/8\varepsilon$
Cluster 1	0.111	0.330	11.82
Cluster 2	0.111	0.330	11.81
Cluster 3	0.111	0.330	11.81






Figure 4.13: 最適電極位置




Figure 4.14: 金属表面における最適電位分布




Figure 4.15: 金属表面における最適電流密度

参考文献

- (1) David E. Goldberg, *Genetic Algorithms in Search, Optimization & Machine Learning*, Addison-Wesley, 1989.
- (2) 北野宏明編, 「遺伝的アルゴリズム」, 産業図書, 1993.
- (3) K. Krishnakumar and David E. Goldberg, "Control System Optimization Using Genetic Algorithms," *Journal of Guidance, Control, and Dynamics*, 15-3, pp.735-740, 1992.
- (4) 畝見達夫, 「GA の制御への応用」, 計測と制御, 32-1, pp.58-62, 1993.
- (5) James P. Cohoon, and William D. Paris, "Genetic Placement," *IEEE Transactions on Computer-Aided Design*, 6-61987, pp.956-964, 1987.
- (6) 山村雅幸, 小野貴久, 小林重信, 「形質の遺伝を重視した遺伝的アルゴリズムに基づく巡回セールスマン問題の解法」, 人工知能学会誌, 7-6, pp.1049-1059, 1992.
- (7) 荒川雅生, 山川宏, 「2次元構造物の遺伝的アルゴリズムを用いた最適トポロジーに関する研究(第1報 基礎的アルゴリズムの提示)」, 日本機械学会第5回計算力学講演会講演論文集, 920-92, pp.287-292, 1992.
- (8) 坂本二郎, 尾田十八, 「遺伝的アルゴリズムを利用した最適トラス形態決定法」, 日本機械学会論文集(A編), 59-562, pp.156-161, 1993.
- (9) 轟章, 渡辺究, 「オブジェクト指向有限要素法上のGAを用いた複合材料構造最適化」, 日本機械学会第6回計算力学講演会講演論文集, 930-71, pp.55-56, 1993.
- (10) 和田健之介, 田中真一, 「GAは生き残れるか?」, 計測と制御, 32-1, pp.17-23, 1993.
- (11) 中村正行, 田中正隆, 望月雅一, 「境界要素法を用いた動弾性逆解析による欠陥同定(遺伝的アルゴリズムの導入)」, 境界要素法論文集, 10, pp.125-130, 1993.

- (12) 田村秀行監修, 「コンピュータ画像処理入門」, 総研出版, 1985.
- (13) Geoffery H. Ball and David J. Hall, "A CLUSTERING TECHNIQUE FOR SUMMARIZING MULTIVARIATE DATA," *Behavioral Science*, 12, pp.153-155, 1967.
- (14) J. A. Nelder and R. Mead, "A simplex method for function minimization," *Computer Journal*, 7, pp.308-313, 1965.
- (15) William H. Press, Saul A. Teukolsky, William T. Vetterling, Brian P. Flannery, *NUMERICAL RECIPES in C Second Edition*, CAMBRIDGE UNIVERSITY PRESS, 1992.

Chapter 5

結 論

Conclusion

*I've paid my dues
Time after time
I've done my sentence
But committed no crime
And bad mistakes
I've made a few
I've had my share of sand
Kicked in my face
But I've come through
But we must go on, on, on.
—Queen "WE ARE THE CHAMPIONS"*

あの人の思考によると、一つの恐ろしい解答が出て来ます。

—泡坂妻夫「DL2号機事件」

本研究においては、従来の解析手法では解を得ることが難しい、あるいは解を得るためには長い計算時間を要するような逆問題を解くことを目的として、AI(人工知能)の理論を利用・改良した逆問題解析の手法の開発と、それらの手法を実際の逆問題へ適用することを行った。

本研究で得られた結果は以下のように総括される。

第2章

従来の階層型ニューラルネットワークでは、学習(重みの決定)のアルゴリズムとしてバックプロパゲーション法が用いられていたが、重み決定に長時間を要していた。その問題点を解決するため、第2章では、一つのユニットの入力と出力の関係を用いて、短時間でニューラルネットワークの重みを決定する手法を開発した。その手法を、衝撃破壊試験シミュレーションのパラメータ推定逆問題に適用し、良好な推定結果を得ると同時に、従来の学習法を用いたニューラルネットワークに較べて $10^{-1} \sim 10^{-4}$ 程度の計算時間しか必要としないことも示した。

第3章

破壊靱性試験において、試験片破面から予き裂長を測定する作業は肉眼で行われることが多いが、これは、測定者の疲労や測定誤差の原因となる。そこで、第3章では、第2章で開発した重み決定法を用いたニューラルネットワークとウェーブレット変換を組み合わせることにより、試験片の破断面画像から予き裂長を推定する手法を開発した。実際の衝撃破壊試験に用いた Al_2O_3 パウダー/ Al 複合材料の試験片 (アルミナパウダー試験片×2, アルミナファイバー試験片×1) に本手法を適用した結果、いずれの試験片においても、本手法による推定値は肉眼による測定結果とよく一致した。

第4章

遺伝的アルゴリズム (GA) は、多次元の高次元関数の最大・最小値を求めるための有効な手段であるが、収束までに長い計算時間を要するという問題があった。そのため、第4章では、遺伝的アルゴリズムとクラスタリングおよび降下法を組み合わせることにより、高次元目的関数をもつ多変数システムの最適化を効率よく行える手法を開発した。その有効性を示す例として、カソード防食システムの電極最適化問題に本手法を適用し、従来の手法、および単に GA を用いたのみの場合に較べて数分の一以下の時間で解が求められたことを示した。

謝 辞

本研究を行うにあたり，終始変わらぬ御指導，御鞭撻を賜りました東京工業大学情報理工学研究科情報環境学専攻 青木繁教授に深く感謝の意を表します。

また，多くの貴重な御助言をいただきました東京工業大学工学部機械知能システム学科 岸本喜久雄教授に深く感謝致します。さらに，数々の御教示を賜りました東京工業大学情報理工学研究科情報環境学専攻 吉野雅彦助教授に心より感謝致します。

本研究の実施にあたり，ご支援をいただきました東京工業大学情報理工学研究科情報環境学専攻 天谷賢治氏，工学部機械知能システム学科 井上裕嗣氏，納富充雄氏に心より御礼申し上げます。また，御助言をいただきました State University of New York at Stony Brook の Toshio Nakamura 先生，株式会社新潟鐵工所 吉田勉氏，日本酸素株式会社 新井一成氏，渡辺章正氏，日産自動車株式会社 穂場亨氏，株式会社神戸製鋼所 高橋伸一郎氏に御礼申し上げます。

最後に，有形無形の御協力をいただきました高原弘樹氏，岩本紀子女史，鈴木民子女史，早瀬仁則氏，浦郷正隆氏，青木研究室・吉野研究室の諸氏に感謝致します。

平成7年12月吉日

森 谷 之 信