

4M-8

自己組織化マップを用いた衝撃貫通画像の解析

堀内 崇弘[†] 小川 毅彦[†] 金田 一[†]拓殖大学大学院電子情報工学専攻[†]

thoriuch@es.takushoku-u.ac.jp

1. はじめに

飛翔体が衝突する構造物の設計において、材料の貫通限界速度や残存速度を評価しておくことは重要である。そのため超高速度写真システムによる貫通破壊過程の画像より特性評価する研究が行われている^{[1][2]}。この方法では、鋼球を材料試験片に打ち込み、鋼球や試験片の挙動により特性を評価するが、セラミックなどの試験片では破片の散乱により、鋼球の挙動の観測が難しい場合がある。

一方、画像認識の手法としてニューラルネットワークがしばしば用いられている。ニューラルネットワークではそのロバスト性により不完全な画像からでも正しい認識ができると期待できる^[3]。本研究では衝撃貫通画像の鋼球、背景、破片の分類のために自己組織化マップ(SOM)^[4]を適用することを提案する。SOMは教師値なしでクラスタリングできることから、特定の教師値なしで衝撃貫通画像の鋼球、背景、破片を区別することができる。本研究では画素値と特徴量の2種類のネットワーク入力を使用し、ポリメチルメタクリレート(PMMA)とアルミナ試験片の衝撃貫通画像の分類効果を示す。

2. 自己組織化マップ

自己組織化マップは競合作用に基づいた学習を行う。SOMでは入力データの相互関係を保ったままニューロンの1次元または2次元領域に写像することができ、順所性と類似性を表現できることからクラスタリングに適している^[4]。本研究ではSOMを衝撃貫通画像における鋼球、背景、破片を分類するために使用する。入力は画素値をそのまま使用したものと画像の特徴量を算出したものの2種類で考えそれぞれネットワークに入力してシミュレーションを行った。特徴量は入力画像を10×10ピクセルに分割したものの画素値の標準偏差、最大頻度の画素値、コントラスト、最大値、最小値、平均値の6つを算出したものを用いた。

学習ネットワークをFig.1に示す。ネットワークは入力層と競合層の2層から成り立っている。入力層は6つで、6次元の入力ベクトルをネットワークに入力する。競合層は1次元線形配列とする。SOMで

Hachiouji, Tokyo, 193-0985, Japan

は衝撃貫通画像の鋼球のようにまばらな入力データの場合マッピングに十分なデータ領域が確保されない。したがって鋼球画像などの頻度の低い入力データを強調するために入力ベクトルに鋼球のデータを繰り返し挿入する。




Fig.1 学習ネットワーク

SOMの認識ネットワークをFig.2に示す。衝撃貫通画像を分割したものの画素値または特徴量を算出しネットワークの入力とする。そして反応した競合層のニューロンの番号を色の濃淡で表現し等高線を利用して出力する。分類が行われたデータにラベリングを行う。これは競合層のニューロンは学習時のデータを表現しており、どのニューロンが画像のどの部分であるかははっきりしない。そこで鋼球と背景、破片のサンプル画像を入力し、どのニューロンがなにを現しているのかを確認する。




Fig.2 分類ネットワーク

Analysis of Impact Perforation Images using Self-Organizing Map

[†]T.Horiuchi, T.Ogawa and H.Kanada, Graduate School of Engineering, Electronics and Information science Course, Takushoku University, 815-1, Tatemachi,

Table 1 ネットワークパラメータ

分割画像サイズ(pixels)	10 × 10
サンプル画像分割サイズ(pixels)	10 × 10
鋼球ベクトル挿入回数	300
入力層	6
競合層	30
順序付けフェーズステップ数	1000
順序付けフェーズ学習比	0.9
調整フェーズ学習比	0.01
学習回数	10

4. シミュレーション

本研究で使用する衝撃貫通画像は 4 枚の連続写真である。画像サイズ,その他のパラメータは Table 2 に示す通りである。

Fig.3 に示す PMMA の 2 番目に撮影された画像とアルミナの 3 番目に撮影された画像を分類画像としてシミュレーションを行った。PMMA の 1 番目の画像とアルミナの 4 番目の画像から鋼球,背景,破片のサンプル画像を取り出した。学習時には,分類画像の画素値または特徴量を取り出し,鋼球サンプル画像のデータを無作為順に十分な回数を挿入しネットワークに入力する。分類時には,鋼球サンプルのデータを挿入せず分類画像データのみでシミュレーションを行う。出力ニューロンはニューロンの番号で表示し,それを等高線で表示する。そしてサンプル画像を用いてニューロンのラベル付けを行う。




Fig.3 衝撃貫通画像

- (a)PMMA の 2 番目の画像
(b)アルミナの 3 番目の画像

Table 2 試験片パラメータ

	PMMA	アルミナ
画像サイズ(pixels)	1000 × 656	1172 × 770
使用画像サイズ(pixels)	300 × 300	
試験片サイズ(mm)	80 × 60	80 × 80
試験片厚さ(mm)	3.0	1.5
衝撃速度(m/s)	309	224.6
写真間隔(μ/s)	150	50

5. 結果

PMMA の分類結果を Fig.4 に示す。シミュレーションは,画素値入力と特徴量入力の 2 種類で行った。

鋼球を表すニューロンは白で表示されている。カラーバーはニューロンの番号を濃淡で示している。ラベル付けの結果はヒストグラムを用いて行った。丸が鋼球を表しており,三角は背景,四角は破片を表している。

分類結果によると,PMMA 試験片衝撃貫通画像は,特徴量を利用した方では鋼球,背景,破片の分類を正確に行われた。画素値入力では鋼球を正確に分類することができなかった。アルミナ衝撃貫通画像でも特徴量入力の方が正確な分類が可能であった。したがって,特徴量に基づく入力ベクトルの方が SOM による衝撃貫通画像の分類に有効である。




Fig.4 分類結果

- (a) 画素値入力 (b)特徴量入力

6. まとめ

本研究では,画像の認識に SOM を使用し,衝撃貫通画像の分類を行うことを提案した。そして PMMA とアルミナ試験片の衝撃貫通画像を用いて分類シミュレーションを行った。画素値と特徴量の 2 種類の入力によるシミュレーション結果として,特徴量は鋼球,背景,破片の分類を正確に行うことができた。以上より SOM が衝撃貫通画像の分類に有効であることを示した。

参考文献

- [1] H. Kasano "Recent Advances in High-Velocity Impact Perforation of Fiber Composite Laminates", JSME Int'l Journal A, Vol.42-2, pp.147-157, 1999.
- [2] J. A. Zukas "High Velocity Impact Dynamics", John Wiley & Sons, 1990.
- [3] T. Ogawa, Y. Hashimoto, H. Kanada and H. Kasano "Localization of steel Ball in Impact Perforation Images by Neural Network", Trans. of SICE, Vol.29, No.8, pp.789-791, 2003.
- [4] T. Kohonen "Self-Organization and Associative Memory", Springer, 1987.