

自己組織化マップを用いた衝撃貫通画像の分類と評価

大久保 賢司†

小川 毅彦‡

金田 一‡

拓殖大学大学院電子情報工学専攻†

拓殖大学工学部電子システム工学科‡

1. はじめに

超高速写真システムを用いた貫通破壊過程の解析により材料の特性を評価する研究が行われている[1]. この方法では鋼球を材料試験片に打ち込み、鋼球や試験片の破片の挙動によって材料の特性を評価するが、セラミックス等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. これまでは多層型ニューラルネットワークを用いて教師つき学習を行い、衝撃貫通画像における鋼球を判別し、鋼球の位置を推定する研究が行われてきた[2]. 本研究では競合学習型モデルである自己組織化マップ[3]を用いて貫通破壊画像における鋼球、背景、破片等の分類を行うことを提案する. また、入力データ間の位相関係を保存した写像を行う自己組織化マップの特性を利用し、それぞれの写像結果より画像分類の難易度を判断し、定量的評価することを検討する.

2. 衝撃貫通試験

衝撃貫通試験とは、鋼球などの飛翔体を平板状の材料試験片に打ち込み、その貫通破壊過程を解析するものである. 貫通破壊の過程やメカニズムを知るために、超高速カメラを用いたシステムが構成されている.




図1 衝撃貫通破壊試験装置の概略

図1は衝撃貫通破壊試験装置の概略である. 衝撃試験装置と超高速写真撮影システムから構成されている. 高圧窒素ガスを開放することによって、鋼球を射出し、超高速カメラによって4枚の連続写真を撮影する. このシステムでは、連続写真によって貫通破壊過程の前後の様子を観測することができるが、材料の破片によって鋼球の位置を精密に測定できない場合が多く、画像中から鋼球を判別し正確な位置を推定するための処理が必要となる. 現在のシステムでは、衝撃貫通の画像における鋼球の位置の判別は画像上目視で行われており、材料の破片などによって認識が難しい場合は前後の連続写真から類推する形でされている.

Image Clustering and Evaluation of Impact Perforation Images Using a Self-Organizing Map

†Kenji Okubo, Electronics and Information Science Course, Takushoku University

‡Takehiko Ogawa and Hajime Kanada, Dept. of Electronics and Computer Systems, Takushoku University

3. 自己組織化マップ

自己組織型ニューラルネットワークの1つである自己組織化マップの特徴について説明する. 入力層は結合荷重を通して全ての競合層に接続されている. 学習段階では、ある入力に対して多数のニューロンが応答するが、そのうち最も強い応答を示したニューロンが勝ち残り、そのニューロンと近傍ニューロンについての結合荷重の学習を行う. また、このモデルは競合作用に基づいた学習方式によって教師なしで学習を行う. つまり、入力データごとの分類カテゴリーに属するかは与える必要がなく、入力データの元の空間における相互関係をニューロンの1次元あるいは2次元的なつながりをもつマップに写像し、その相互距離によって類似度を測ることができる. このことからデータ集合をいくつかのグループに分類するクラスタリングに適している[4].

ネットワーク構成を図2に示す. 入力ベクトルは衝撃貫通画像の特徴量と画素値を直接使用したもの2種類を考え、それぞれ学習を行う. 入力層は n 個で n 次元のベクトルを入力する. 競合層は1次元の線形配列を使用する.

学習では、最初にネットワークが勝者ニューロンを識別し、勝者の荷重とその近傍の荷重が表現するベクトルが、各々の学習ステップにおいて入力ベクトルの近くに移動する. 勝者ニューロンの荷重は学習比に比例、近傍ニューロンの荷重は学習比の半分に比例して変更される.

自己組織化マップのニューロンは、入力空間全体で様々な確率を持つ入力ベクトルが与えられた場合、入力ベクトル間のほぼ等しい距離を使って自分自身を順番付ける. また、入力ベクトルが入力空間全体で可変の頻度を使って与えられる場合には、競合層はニューロンを入力ベクトルの頻度に比例する領域を割り当てる. そのため、競合層のマップは入力进行分类するために学習する一方、入力トポロジーと分布も学習する.

画像进行分类するためには、学習済みのネットワークを用いる. 学習済みのネットワークは学習データを表現しているだけであり、競合層のどのニューロンがどの学習画像の入力データを表すのか確認する必要がある.

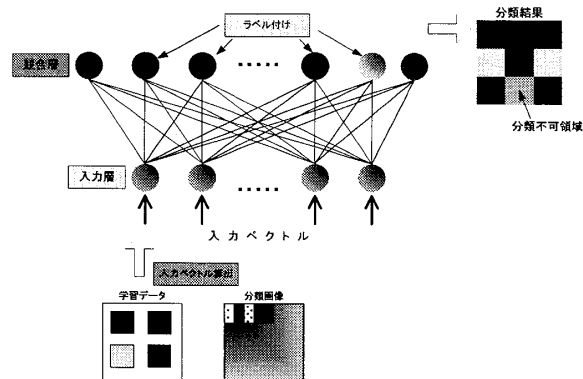


図2 ネットワークの構成

4. シミュレーション

本研究では図3に示すPC(ポリカーボネート)、 Al_2O_3 (アルミナ)試験片の衝撃貫通画像を用いる。画像は4枚の連続写真であり、撮影順序は図中の数字の順である。図3の衝撃貫通画像から分類画像と学習画像を切り取る。学習画像はPC画像ならば2番目に撮影された画像から鋼球、背景、2組の材質画像を切り出す。 Al_2O_3 画像ならば3番目に撮影された画像から鋼球、背景、2組の破片画像を切り出す。この画像に対して分類を行う。図3の画像からPC画像は判別が容易である。また、 Al_2O_3 画像は破片により判別が困難である。学習時には学習画像の特徴量および画素値を直接取り出した2通りの入力値としてネットワークに入力して分類を行う。方法としては、特徴量と画素値の2通りの方法で分類シミュレーションを行い、競合層の出力状況から画像の難易度や分類の正確性等を評価する。

ネットワークパラメータを表1に示す。使用したネットワークパラメータは、入力ベクトルと分類する画像によって異なる。特徴量を入力とするネットワークの入力層を使用する特徴量の数によって決定した。画素値の入力ベクトルの場合は、入力層を5とした。




図3 衝撃貫通画像

表1 ネットワークパラメータ

使用画像	PC	Al_2O_3
入力層	3 or 4 or 5	4 or 5 or 7
競合層	11	
順序付けステップ数	1000	
順序付け学習比	0.9	
調整学習比	0.01	
近傍ニューロン距離	1	
学習回数	500	

5. 結果

PCと Al_2O_3 衝撃貫通画像の特徴量と画素値入力による分類および分類難易度の定量評価の確認のためにシミュレーションを行った。競合層の発火状況を図4に示す。




図4 競合層の発火状況

それによると、学習後のネットワークは、入力ベクトルに最も近いニューロンのみが反応し○となる。その他のニューロンの出力は●となっている。つまり、図4の(a)は鋼球のデータが挿入されたとき反応したニューロンは

○で示されるように11番目の競合層ニューロンである。11番目のニューロンの荷重が最も鋼球の特徴量に類似していることになる。また、各パターンにおける競合層ニューロン間との距離関係を図5と6に示す。




図5 PC各パターンにおける競合層発火ニューロン位置




図6 Al_2O_3 各パターンにおける競合層発火ニューロン位置

図5の(a)と(c)より、各学習画像に対して各パターンが明確に分離していることがわかる。鋼球と材質のパターン間距離がかなり大きいので判別が容易であることがわかる。特徴量の抽出法としては、(a)と(b)を見ると、(a)は明確に分離しているのに対して、(b)は鋼球と材質が重なっていることがわかる。また、図6の(a)と(c)を見ると各学習画像に対して各パターンが隣り合っていることがわかる。鋼球と破片のパターン間距離が小さいため判別が困難であることがわかる。特徴量の抽出法としても、(a)と(b)を見ると、(a)は分離しているのに対して、(b)は鋼球と破片が重なっていることがわかる。

6. まとめ

本研究では、ニューラルネットワークによる画像認識問題の1つとして、衝撃貫通画像の分類を自己組織化マップを用いて分類することを提案し、シミュレーションを行い効果を確認した。また、自己組織化マップは入力データ間の位相関係を保存した写像を行う。その特性を利用し、それぞれのネットワークより画像分類の難易度を判断し、定量的に評価することについても検討した。

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] 小川, 橋本, 金田, 笠野 "ニューラルネットを用いた衝撃貫通画像における鋼球位置の推定", 計測自動制御学会論文集, Vol.39, No8, pp.789-791, 2003.
- [3] T.コホネン, 中谷和夫訳 "自己組織化と連想記憶" Springer.
- [4] 徳高平蔵, 藤村喜久朗, 山川烈 "自己組織化マップ応用事例集" 海文堂.