

CBNセグメント砥石の接着検査の自動化

○ 電通大 本間恭二、 電通大大学院 高田篤人

要旨

本研究は砥石セグメントとコアとの接着面を超音波で探傷しこれを自動化することを目指す。予め任意の人工剥離欠陥を作ったセグメント砥石を用いてその探傷波形を教師波形としてニューラルネットワークで学習し、未知欠陥に対しその有無や形状を検出する。例として中央に円形剥離形状を持つものを探傷した結果、89%の正解率を得た。

1. はじめに

セグメント砥石において、砥石とコアの接着面に生じる剥離などの接着不良を予め検出できれば、製品の品質管理や使用前の検査に貢献することが多い。しかし、砥石は不均質構造であるため接着面不良を非破壊的に調べることが難しい。本研究では経験のないオペレータでもこうした検査が行えるシステムを作るために、ニューラルネットワークを用いた知的探傷システムを構築することを目指す。

2. 超音波探傷

2.1 試験体

使用したCBN 1号平型砥石(100×20×15.88)は砥石セグメントを接着剤でリムを介してスチールのコアに貼りつけている。探触子は周波数5MHz、焦点距離50mm、焦点径0.5mm、探傷機はクワットレーマ社製(USIP-12)を使用した。図1は砥石専用に開発した水浸垂直反射法による治具で、マイクロヘッドにより1回転(1ピッチ1mm)当たり200点、18ピッチ合計3600点を計測した。試験体は予め想定した任意形状の剥離(未接着部)を持つセグメント10種類と剥離のないもの1つで構成される(図2にその一部を示す)。

2.2 探傷結果

砥石表面から超音波を入射して接着部の約2倍(5μsec)までの反射エコーをデジタルレコーダによって10nsec単位でサンプリングして波形処理

を行った。サンプリング点数は500点とした。実際の接着部(2.21μsec)から前後1.5μsecの範囲について矩形フィルターで抽出した(図3)。

接着面付近で剥離のないものと、剥離しているもののエコーの特徴をそれぞれ図4、5に、また異なる10ヶ所を測定してそれらを重ね合わせたものを図6、7に示す。

単独のエコーでは接着状況の特徴が現れて見えるが、重ね合わせると位相が異なっている。これは砥石構造の不均質に起因する。しかしながら剥離しているか否かについては、エコーの特徴から目視によってもある程度判別可能である。そこで、図8に示すように、波形の特徴となる隣接する3つのエコーのピークの差を計測して、剥離の有無を判定するため、

(a)剥離なし： $(2)-(1) \leq (3)-(1)$

(b)剥離あり： $(2)-(1) > (3)-(1)$

の条件で100個の標本中でいくつ該当したかを調べた。その結果、(b)の条件は容易に判別可能であるが、(a)に対しては不十分であることがわかった。




Fig.1 Ultrasonic flaw detection jig in segment wheel




Fig.2 Configuration of several kinds of exfoliations




Fig.3 Waveform from surface to bonding periphery

3. ニューラルネットワーク

3.1 ネットワークの構造

反射エコーから剥離の有無を判定するため、図9に示すネットワークを構成した。ネットワークを小型化するため、波形の特徴を損なわないよう反射波形の振幅値を時系列順に160個のユニットに入力した。出力層は欠陥の有無を判定するため2個とし、中間層は15個のユニットを配置した。なお、ここではLVQネットワーク⁽¹⁾を使用した。

3.2 ネットワークの学習

ここでは、すべての剥離形状を学習したものでなく、中央に円形の剥離を持つもので学習した。




Fig.4 Waveform of integrity bonding at bonding periphery




Fig.5 Waveform of exfoliation near bonding periphery




Fig.8 Measurement of peak to peak

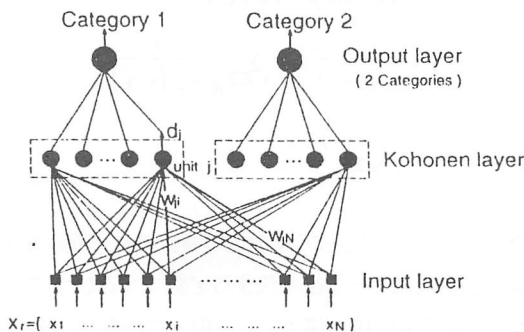


Fig.9 Neural network structure

ネットワークの学習には2つの領域(剥離あり、剥離なし)から測定されたそれぞれ60個(計120度)を検討するために用いた。ネットワークへの入力データはサンプリングされた波形の振幅値をそれぞれ60個(計120個)を学習後のネットワークの精のままベクトルの各要素としている。ネットワークの学習はLVQ1アルゴリズム⁽¹⁾で行った。学習係数の初期値 $\alpha = 0.03$ 、学習回数は3000回とした。

3.3 ネットワークによる認識

各測定点でネットワークが剥離であると判定した点を黒丸で示し、欠陥の配置を示した図上にマッピングしたものを図10に示す。黒丸が散らばっており、正しく認識しているように見えないが、《剥離あり、剥離なし》という観点からは89%の正解率が得られている。

4. おわりに

現在のシステムの認識率は未だ不十分であり、より確実な特徴量を見いだす必要がある。砥石の構造不均質性に起因する超音波の伝播速度の補正などを考慮することで精度の向上が期待できる。

参考文献

- (1)E. McDermott, et al. IEEE Trans..SP 396(1991) 1398




Fig.6 Superposing of 10 points waveform data for integrity




Fig.7 Superposing of 10 points waveform data for exfoliation




Fig.10 Discrimination result of defects by neural network