

自己組織化マップを用いた歯車表面の 傷検査技術の研究

Study of Inspection Technology for Gear Surface using Self-organizing Map

江口 純 司*

Junji EGUCHI

内田 孝 尚*

Takanao UCHIDA

村上 学*

Manabu MURAKAMI

藤原 欣 哉*

Kinya FUJIWARA

要 旨

歯車表面の傷について、人と同等の精度を持つ検査技術を研究した。検査対象とする歯面について、傷以外の色ムラなどを抽出する過剰検出が問題となった。このため、傷とそれ以外の判別が可能な傷の特徴を、目視の観点に基づいて設定した。さらに、これらを用いて人間的な傷判別をおこなう手法として、ニューラルネットの一種である自己組織化マップを適用した。これによって複数の傷、および表面の色ムラや汚れの特徴を学習させたことにより、人と同等な傷の判別が可能になった。この傷判別技術を適用することで、目視検査を従来の 10%程度に減少させる技術が構築できた。

ABSTRACT

Research was carried out on inspection technology for gear surface imperfection inspection that has the same degree of accuracy as that of a human inspector. Regarding the surface of the tooth which is the object of inspection, over-detection resulting from the extraction of uneven brightness other than that due to imperfections was an issue. For this reason, the features of imperfections that permit imperfections to be discriminated from non-imperfections were set based on visual observation. In addition, a self-organizing map which is a kind of neural network was employed as a method whereby these features are used to identify imperfections in the same way as a human inspector. By using this map to teach the inspection system the features of multiple imperfections and also uneven brightness and dirt on the surface of the gear, it was possible to recognize imperfections to the same degree of accuracy as that of a human inspector. Technology constructed using this imperfection recognition method enabled the work of visual inspection to be reduced to about 10% of that necessitated previously.

1. まえがき

自動車のトランスミッションは多数の歯車から構成されているが、歯車の品質は走行の快適性に大きく影響することが指摘されている⁽¹⁾。歯車同士が噛み合う歯面において、傷などで生じるわずかな盛り上がり騒音の原因となり、乗員に不快感を与える可能性がある。このため、歯面の目視検査がおこなわれてきた。しかし、目視検査は作業員への負担が大きく、個人差による検査精度のバラツキによって品質が一定に保たれない可能性があることから、検査工程の自動化が望まれるようになった。本稿では歯面にお

ける傷の検出手法、およびそれを用いた検査システムについて述べる。

2. 研究の概要

2.1. ねらい

本研究のねらいを、歯車の表面に生じる傷について、目視検査と同等の精度をもつ検査技術の構築とする。歯車の歯面には、Fig. 1に示すような傷(打痕、剥離、引っかき)が生じる。これらの傷に対して、従来の、画像解析で抽出したものを傷とする手法では、以下の理由により、表面の色ムラ

*栃木研究所

や汚れなど、傷以外のものを傷として抽出してしまう過検出現象(以下、過検出)が発生し、検査精度が低下する問題が生じる。

- ・ 照明を均一に当てることが困難：Fig. 1 に示すように、歯面が曲面のため、照明の光量に偏りが生じる。
 - ・ 多様な種類の傷判別：多種類の傷を全て検出する必要があるため、傷の判別基準が複雑化し、設定が困難になる。
- これらに対し、目視では検査する人の傷に対する概念と、過去の記憶に基づいて傷を判別しているため、過検出が少ない。したがって、目視検査と同等な傷検出手法を実現するため、以下の項目を研究の目標に設定した。

- (1) 傷の特徴を定義する技術を構築する(画像解析)。
- (2) 取得した画像部分の特徴を用いて傷を判別する機能を構築する。
- (3) 傷判別精度を向上させる学習機能を構築する。

2.2. 傷検査技術の構築

本研究では、以下に示す三つの要素技術によって、目視と同等の傷検査技術を構成した。

(1) 傷判別技術

目視と同等の傷判別をおこなうため、目視検査で、人




Fig. 1 Imperfection samples




Fig. 2 Image processing to extract imperfection candidate

が傷とそれ以外を見分ける観点を分析した。さらに、これらの観点に基づいて、傷の外観を表す複数の特徴を設定した。

(2) 傷判別技術の実用化

傷判別には、ニューラルネットの一種である自己組織化マップによるデータの分類手法を適用した。これによって、過去に得られた傷と、表面の色ムラなどの過検出成分について、類似したデータ同士をグループ化したテーブルを構成した。これを用いて、画像解析により抽出した傷の可能性のある部分(以下、傷候補)について、傷と過検出成分のどちらとの類似性が高いか、すなわち、傷らしさを判定することで傷判別する。

(3) 傷判別精度の向上

傷判別精度の向上が必要とされた場合、それまでの検査で得られた傷および過検出成分を比較用のテーブルに追加し、学習することで傷の判別精度を向上させる。

2.3. 画像解析による傷候補の抽出

本研究の前提技術となる傷候補の抽出手法について述べる。この手法では、検査対象とする歯面(検査画像)を他の歯面(比較画像)と比較することにより、その差異部分を傷候補として抽出する。歯面同士の比較は、以下の式から求められる差分画像を用いておこなう(Fig. 2: Step1)。

$$\text{差分画像} = \text{検査画像} - \text{比較画像}$$

傷を含む二つの画像の差異は、差分画像の輝度変化が大きい部分となる。このため、差分画像の輝度変化部分を強調したエッジ画像と元の差分画像を比較し、差分画像から輝度変化の大きい部分を抽出する(Fig. 2: Step2)。これを傷候補とする。傷候補の中には、傷以外にも表面の汚れや色ムラなどの過検出成分が含まれるが、この処理では、傷を確実に抽出することを最優先とする。

以降では、傷候補の特徴分類による傷判別手法に重点をおいて説明する。

3. 傷判別技術の構築

3.1. 目視検査の観点

傷候補について、その外観を表す特徴パラメータを複数個設定し、傷判別に用いる。この特徴の選定にあたっては、人が傷判別をおこなう際の着目点を参考にした。Fig. 3は、傷と過検出成分(表面の汚れなど)を差分画像より抽出した例である。これらについて、人が傷と表面の色ムラや汚れなどを見分けるのに手がかりとしていることは、傷本体の形状と、傷周囲の輝度分布特性から生じる模様と考えられる。したがって、目視と同じように歯面の傷を判別するために、以下の二つの観点からアプローチをおこなった。

- (1) 傷の幾何学的な特徴
- (2) 傷周囲の輝度分布による特徴

3.2. 傷の特徴取得

1：傷の幾何学的な特徴

目視の観点において、傷の外観を表す幾何学的な特徴は、傷の大きさ(面積)、向き(角度)、形状(円形度)であることから、これらを傷の外観を表す特徴パラメータに設定した (Fig. 4)。

(1) SA : 面積

(2) θA : 角度

(3) CA : 円形度 ($CA = SA/C$, C : 傷の外接円面積)




Fig. 3 Images of imperfections and over-detection elements




Fig. 4 Geometrical features of imperfection

2：傷周囲の輝度分布による特徴

同様に、傷周囲の模様を表す、輝度分布による特徴として、画像の乱雑性(エントロピ)、輝度分布の対称性(アニソトロピ)、輝度の変化(エッジ画像の平均輝度)を特徴パラメータに設定した。

(4) $entB$: 乱雑性(エントロピ)

(5) $ansB$: 対称性(アニソトロピ)

(6) $edgB$: 輝度の変化(エッジ画像の平均輝度)

以上によって傷の外観を、6個の特徴に方向性をもたせた特徴ベクトルとして表現した。したがって、傷の外観を数式として、特徴ベクトル： x

$$x = (SA, \theta A, CA, entB, ansB, edgB)$$

と表す。

3.3. 特徴ベクトルの例

傷候補から抽出した特徴ベクトルの例として、傷(打痕)と過検出成分(表面の色ムラ)を Fig. 5 に示す。これらと比較すると、円形度： CA 、乱雑度： $entB$ 、および変化度： $edgB$ に大きな差が生じている。これらの特徴によって、傷と過検出成分の判別が可能になる。すなわち、傷候補を傷判別するための、傷特徴の定義技術が構築できたことになる。

4. 傷判別技術の実用化

傷特徴の定義技術が構築できたことから、傷候補の特徴ベクトルを、既存の傷および過検出成分のデータと比較して傷判別をおこなう。このため、Fig. 6 に示す二次元格子 (a) によって傷判別テーブルを構成した。このテーブルの各格子点 (b) に、打痕などのデータの画像と、前述した特徴ベクトルをもたせる。さらに、これらに傷または過検出成分の判断を入力する。これにより、傷候補に対して、目視と同等の傷または過検出成分の判断が可能になる。




Fig. 5 Feature vector

4.1. 傷判別テーブルの作成

傷判別テーブルの作成には、多次元データの分類手法の一つであり、ニューラルネットの一種である自己組織化マップを用いる⁽²⁾。これは、複数のデータについて類似したもの同士を寄り集め、グループ化するアルゴリズムである。これによって Fig. 7 に示すように、3章で定義した傷の外観を表す特徴に基づいて、打痕や汚れなど類似性の高いデータ同士を二次元格子上でグループ化することができる。検査実行時には、傷候補がどのグループに類似しているかを求めることで傷判別をおこなう。

しかし、データの中には剥離と類似した汚れなど、傷判別において紛らわしいものが存在する。このため、自己組織化マップのみでは、このようなグループ相互の境界付近にあるデータに対して、グループ分けが不正確となる可能性がある。また、この段階では、類似したデータ同士をグルー

プ化したに過ぎず、傷判別テーブルは傷判断を有していない。したがって、各グループを構成する全てのデータに対して、傷または過検出成分の目視判断を入力することで、不正確なデータのグループ分けを修正し、各グループに目視と一致した傷判断をもたせる。これによって、目視と同等の傷判別テーブルが実現する。

傷判別テーブルの作成を、Fig. 7 に示すとおり、以下の手順で実行する。

(1) データ間の類似性の算出

(2) 自己組織化マップによる類似データのグループ化

(3) 目視判断の入力

4.1.1. データ間の類似性の算出

傷判別テーブルにおけるデータ同士の類似性は、特徴ベクトル間距離として求めることができる。すなわち、特徴ベクトル間距離が小さいほど、特徴ベクトルの要素値が近く、類似性が高い。このため、以下に示す傷候補の特徴ベクトル： X (1)と、座標 (i, j) の格子点の特徴ベクトル： x_{ij} (2)について、(3)式によって、特徴ベクトル間距離： d_{ij} を算出する。

$$X = (SA, \theta A, CA, entB, ansB, edgB) \quad (1)$$

$$x_{ij} = (SA_{ij}, \theta A_{ij}, CA_{ij}, entB_{ij}, ansB_{ij}, edgB_{ij}) \quad (2)$$

$$d_{ij} = \sqrt{(SA - SA_{ij})^2 + \dots + (edgB - edgB_{ij})^2} \quad (3)$$

4.1.2. 自己組織化マップによる類似データのグループ化

自己組織化マップによって、類似性の高いデータ同士を二次元格子上でグループ化する。その手順を以下に示す。

Step1：データの類似関係を表す格子点の選択

二次元格子上でデータ間の類似関係を表すのに、その時点で最適な格子点(以下、最適格子点)を選択する。最適格子点は、各データと最も類似した特徴ベクトルをもつ格子点とする(Fig. 8: Step1)。

Step2：データのグループ化

最適格子点、およびその周囲の格子点の特徴ベクトルを、それぞれのデータに類似するように更新する。このときの更新量は、最適格子点に近い格子点ほど大きく、離れるほど




Fig. 6 Construction of recognition table




Fig. 7 Sequence of making recognition table




Fig. 8 Grouping data by self-organizing map

小さくする。また、分類の進行につれて、更新する格子点範囲を小さく絞り込んでゆく。これによって、各データに類似した特徴ベクトルをもつ格子点領域が形成される (Fig. 8: Step2)。

この Step1, 2 を繰り返すことで、類似性の高いデータの最適格子点が、相互に近い位置に集合する。これによって、各データのグループ化は、Fig. 9に示すように、それぞれに類似した特徴ベクトルをもつ格子点領域の位置関係で表現される。

(1) データ同士の類似性が高い場合

打痕Aの格子点領域と類似性が高い打痕Bの格子点領域は、互いに近い位置に形成され、同一グループとなる。

(2) データ同士の類似性が低い場合

打痕A, Bの格子点領域と類似性が低い、汚れCの格子点領域は、互いに遠い位置に形成され、打痕A, Bとは異なるグループとなる。

また、各データの格子点領域の形状、および他の格子点領域との境界は、最適格子点の位置関係によって、自動的に決定される。

4.1.3. 目視判断の入力

傷判別テーブル上の各グループと目視による判断を一致させるため、Fig. 9に示すような、グループを構成する各データの格子点領域に対して、傷または過検出成分の目視判断を入力する。このとき、格子点領域毎に入力をおこなうため、格子点全てに入力する必要はなく、短時間で入力をおこなうことができる。

4.1.4. 作成した傷判別テーブルの特徴

これまで述べた手法によって、傷判別テーブルを作成した例を Fig. 10に示す。これは100個のデータを、 $40 \times 40 = 1600$ 個の格子点によって、グループ化した傷判別テーブルである。これより、ねらい通り、打痕や汚れなど類似した特徴をもつデータ同士が、それぞれグループを形成していることがわかる。




Fig. 9 Result of data grouping

傷判別テーブルは以下に示す利点をもつ。

(1) 人間的な判断

自己組織化マップによって、複数の多次元データが、予備的な知識を必要とすることなく、相互の類似関係のみでグループ化される。このため、人の直感に近い判断が可能になる⁽³⁾。

(2) 安定した傷判別

データを格子点領域として表現することで、各グループ間の隙間を補うことができる。このため、比較的少ないデータ数でも、傷候補の多様性に対して安定した傷判別が可能になる。

(3) データの類似関係を視覚的に表現

人にとって、直感的に理解し難い多次元データの類似関係を、二次元格子点上で、視覚的に表現することができる。このため、データの類似関係が理解しやすくなる。

以降、この Fig. 10に示す傷判別テーブルを用いて、傷判別手法について説明する。

4.2. 傷判別テーブルを用いた傷判別

傷判別は、傷判別テーブルで、傷候補と類似した特徴ベクトルをもつ格子点によっておこなうが、正確を期すため、傷候補と類似した1個の特徴ベクトルと比較せずに、類似した複数の特徴ベクトルと比較する。このため、傷候補に類似した特徴をもつ複数の傷判別データから類似領域を設定し、その類似領域の特徴から、傷か傷でないかを判別する。

4.2.1. 類似領域の算出

類似領域を決定する要素は、以下に示す二つとなる。

(1) 大きさ(格子点数)

類似領域の大きさは傷候補によって異なり、類似領域が




Fig. 10 Groups of data on recognition table

過度に大きい場合でも傷判別を誤る可能性がある。したがって、類似領域の大きさに上限を設定する。類似領域の格子点数が上限を超える場合には、より類似性の高い格子点の絞り込みをおこなう。この傷判別テーブルでは、上限とする格子点数を 100 個に設定した。

(2) 傷候補との特徴ベクトル間距離

類似領域は、傷候補との特徴ベクトル間距離が、設定したしきい値以下となる格子点領域とする。このため、傷候補の特徴ベクトル： X と、全ての格子点の特徴ベクトル： x について、Fig. 11 に示す各特徴ベクトル間距離： d となる格子点数の分布を算出する。この分布で、しきい値(a)を、特徴ベクトル間距離の平均値(b)から最小距離(c)(最適格子点)の50%の値に設定し、それより小さい特徴ベクトル間距離をとる格子点領域(d)を、類似領域(e)とする。

4.2.2. 傷判別処理

傷候補の傷判別は、以下に示す類似領域に含まれる、傷判別された格子点(以下、傷格子点)の割合によっておこなう。

- ・ 傷格子点の割合： $F = \text{傷格子点数} / \text{類似領域の格子点数}$
- ・ 傷判別しきい値： D

傷判別条件は、以下に示すとおり、傷候補に対して、 $F \geq D$ となる場合は傷判別、

$F < D$ となる場合は過検出成分判別

とした。また、今回は $D = 0.5$ に設定した。

Fig. 12に、傷判別例(打痕)を示す。類似領域内の全格子点(80 個)の構成は以下のとおりである。

- ・ 傷格子点の数(79 個)
- ・ 傷以外の格子点の数(1 個)

このため、傷格子点の割合： $F = 0.99$ となる。したがって、上記の傷判別条件： $F \geq D$ が成立し、傷として判別された。

4.3. 傷判別精度の向上

傷判別精度を向上させるため、既存の傷判別テーブルを、

新規に取得したデータ(以下、新規データ)と既存データの類似関係を学習し、それを反映した新しいテーブルに更新する。この処理は、Fig. 13に示すとおり、傷判別処理とは別に、オフラインで実行する。

傷判別テーブルの更新処理について説明する。更新は、新規に取得した傷候補の特徴ベクトル(以下、新規データ)を既存の傷判別テーブルに追加し、自己組織化マップによるグループ化を再び実行することで実現する。これによって、




Fig. 12 Result of imperfection recognition




Fig. 13 Sequence of inspection for imperfection candidate




Fig. 11 Distribution of distance between feature vectors

新規データと既存データの類似性を見なおし、データの並べ替えをおこなう。

Fig. 14 に 10 種類の新規データを追加して更新した傷判別テーブルの例を示す。更新後には、新規データの格子点領域が追加された。

5. 検査システム

これまでに述べた傷判別手法を実行する検査システムを構築した。その主な構成は、Fig. 15 に示す通り、検査対象とする歯面を撮像位置に位置決めする (a) 回転式検査台と、撮像する (b) ワイドダイナミックレンジ CMOS カメラ⁽⁴⁾、(c)LED 照明、および検査用 PC とした。

6. 試行結果

本検査技術の検査精度の検証テストをおこなった。その結果について述べる。1 歯あたりの検査精度について、歯面の検査に傷判別処理を適用した場合と、しない場合の比較を Table 1 に示す。いずれの場合も、傷の抽出精度は目視と同等であった。一方、過検出については、40:1の精度差が生じた (a) (b)。この結果より求められる歯車 1 個あたりの検査精度を、40 歯をもつ歯車を例として説明する。傷判別処理を適用した場合は、適用しない場合と比較して検査精度には 180:1 の差が生じる (c) (d)。これより、傷判




Fig. 14 Add new data to recognition table




Fig. 15 Gear inspection setup

Table 1 Inspection accuracy

Recognition	Rate of over-detection: α	Inspection accuracy for one gear: A $A=100 \cdot (1 - \alpha/100)^N$
No use	12.4% (a)	0.5% (c)
Use	0.3% (b)	90% (d)

N : Number of teeth on one gear
 $N = 40$

別処理を適用することで、検査対象とする全歯車の 90% を正しく検査できることになる (d)。したがって、傷判別が困難な、残りの 10% を、目視などで再検査すればよい。

以上によって、本研究で構築した検査技術を適用することで、目視と同等な傷の判別が可能になった。ゆえに、人の負担を軽減することが可能であるといえる。

7. まとめ

歯車の歯面検査について、以下の技術構築をおこなった。


- (1) 傷の特徴を定義し、傷を判別する技術を構築した。これにより、傷を目視と同等な精度で抽出することが可能になった。
- (2) 既存の傷および過検出成分の特徴を学習した傷判別テーブルにより、目視検査が必要な歯車の割合が従来の 10% 程度に減らすことができた。
- (3) 検査によって取得した傷、および過検出成分の特徴ベクトルを用いて傷判別テーブルを更新することで、傷判別精度を向上させることを可能とした。

以上の技術を検査システムに適用した結果、目視検査の負担を減少させ、歯車の品質を向上させる技術が構築できた。


参考文献

- (1)小森, 久保, 高橋, 田中, 市原, 小宮山:歯車の歯の側端や歯先稜の接触による損傷(第1報, 歯側端部のチップングと歯の折損への進展), 日本機械学会論文集(C編), Vol.69, No.685, p.273-280(2003)
- (2) Kohonen, T.: Self-Organizing Maps, Springer-Verlag (1995)
- (3)紙本, 王, 大松:SOM を用いた BP 法の教師選択によるインターフォンの良否識別, 電気学会論文誌C, Vol.122, No.10, p.1742-1747(2002)
- (4)関, 中島, 北村, 大塚, 新井:ワイドダイナミックレンジ視覚センサによる溶接現象の観察, 溶接学会誌, Vol.70, No.7, p.8-11(2001)

■著 者■




江口純司



村上 学



内田孝尚



藤原欣哉