

ニューラルネットワークを利用したトンネル坑内のデジタルカメラによる粉じん濃度計測法

山口大学大学院理工学研究科 学生会員 ○岸田 展明
株式会社 間組 学生会員 平野 充剛
飛島建設株式会社 正会員 筒井 隆規
山口大学大学院理工学研究科 正会員 進士 正人

1. はじめに

トンネル坑内では、トンネル施工時に発生する粉じんを作業員が吸引することが原因で、じん肺症になる健康障害を抱えている。そこで、平成20年3月1日より半月ごとに定期的なトンネル坑内の粉じん濃度を計測することが厚生労働省より義務化された¹⁾。現在の粉じん濃度計測には取り扱いの簡易さから一般的に「デジタル粉じん計」が使用されている。しかし、価格が高価で正確な測定に時間もかかることからより安価で簡単な計測方法が望まれている。そこで、樞本はデジタルカメラのフラッシュ撮影を利用した粉じん濃度計測法が考案²⁾し、フラッシュ撮影した画像から抽出した特徴量をニューラルネットワーク（以下、本文中では“NN”と略称する）に入力して粉じん濃度を出力させるシステムの構築を行った。しかし、このシステムは照明変化に弱く、さらにフラッシュの明るさのムラに影響され、粉じんの増減を特徴量として十分に抽出できず、汎用性に欠けていた。

そこで、本研究ではフラッシュ画像を分割し、それぞれの画像の画像ベクトルを作成し、画像ベクトルから抽出したその特徴量を使ったNNの利用による粉じん濃度計測法を提案し、明るさのムラに強い特徴量の比較を行い、最適な特徴量の検討を行った。

2. デジタルカメラによる粉じん濃度計測の原理

トンネル坑内の作業現場において、デジタルカメラを使用してフラッシュ撮影を行うと写真内に粉じんが白く写り込む。この現象を利用して、粉じん濃度計測法を行う。この方法は、現場での測定作業が非常に簡易であり、他の作業の妨げはほとんどない。また、測定機器は市販のデジタルカメラを使用しているため誰でも容易に入手可能であり、加えて撮影画像がデータとして残るため作業時の粉じん濃度計測の証明になるという特徴がある。

3. NNを利用した粉じん濃度計測法



図-1 NNを利用した粉じん濃度計測法

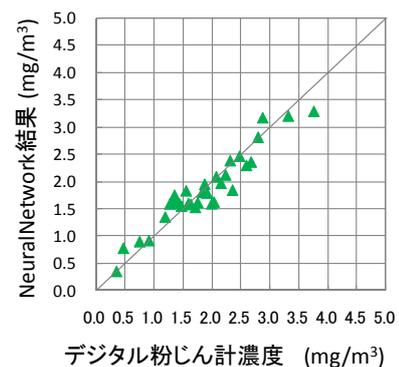


図-2 過去の研究成果



写真-1 現場検証実験

NNは学習するシステムであり、正解値と入力値とをセットで学習させることで、最適な解を導き出すシステムです³⁾。特にNNはノイズに強い特徴を出力するため、ノイズの多い粉じん画像に適していると考えられ用いられた。

フラッシュ撮影した画像を画像処理して特徴量を

抽出する。その特徴量を NN に入力し、粉じん濃度を出力させるシステムである (図-1)。

3. 1 過去の研究成果

フラッシュ撮影した画像をグレースケール化し、その画像の平均値、分散値、標準偏差を特徴量として NN に入力した。その汎用性結果を図-2 に示す。非常に高い相関性を得ることができたことがわかる。

3. 2 検証実験

過去の研究成果の検証を行うため、他の現場においてデジタルカメラを用いた計測を行った。山岳工法により建設中の A トンネル施工において、吹付けコンクリート作業時に切羽から 50m 付近で実験を行った。実験は、撮影方向にブラックボードを設置し、デジタルカメラでブラックボードにフラッシュ撮影をするものであり、1 分間隔でデジタル粉じん計の計測と同期させた (写真-1)。本実験では、設定したデジタルカメラの撮影パラメータを表-1 に示す。あらかじめ、画像処理の高速化をはかるため、画像を 1/10 圧縮した。図-3 において、過去の研究方法を用いて汎用性を評価した結果を示す。過去の研究方法を用いた結果において、高い相関性を得ることができなかった。今回ブラックボードは、過去の実験では固定していたため安定性を得られたが実用的でなかったため、ブラックボードの小型化を図り、持ち運びを簡易にしたため傾きが一定にならなかった。このブラックボードの傾きが要因としてあげられる。

4. フラッシュの明るさのムラ

4. 1 明るさの強度画像

写真-2 は、前方に約 30° 傾けたフラッシュ撮影写真である。そして、その写真-3 から、フラッシュの明るさが最も強い場合を赤、最も弱い場合は青としてフラッシュの明るさの強度画像を図-4 に示す。前方に約 30° 傾けただけでも、ブラックボードの上側にフラッシュが集中していることがわかる。

4. 2 フラッシュの明るさのムらの影響

図-5 は、粉じん画像を 3 次元化した画像であり、ピーク値を示しているのが粉じんであり、このピーク値の大きさが粉じん量である。また、3 次元化の図において、下の面から曲面までの範囲すべてにおいてがフラッシュのムラとすると、「画像全体の明るさ」は「フラッシュの明るさ」と「粉じん量」を足

表-1 デジタルカメラの撮影パラメータ

デジタルカメラ	PENTAX k-m
記画素数	400×267ピクセル
レンズF値	F8.0
レンズの焦点距離	40mm
ISO感度	800
フラッシュ	発光
ホワイトバランス	手動

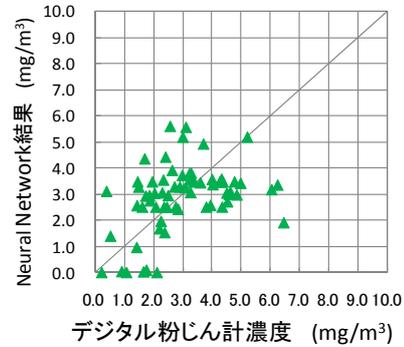


図-3 過去の研究方法を用いた汎用性結果



写真-2 約 30° 傾けたフラッシュ撮影写真

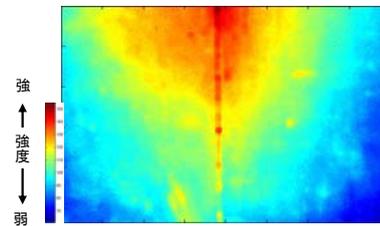


図-4 明るさの強度画像

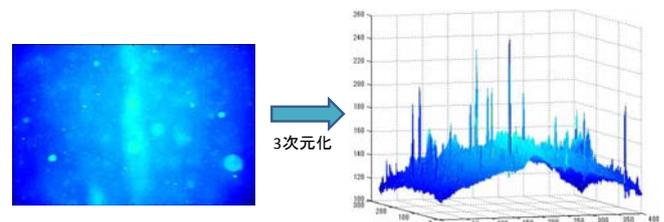


図-5 粉じん抽出画像

したものになる。フラッシュの明るさの増減量に影響が大きいため、粉じん量の増減量の変化が抽出できず画像全体の平均値、分散値に強く影響した。この原因をフラッシュの明るさのムラとし、フラッシュの明るさをなくす特徴量を抽出することが必要

となる。

5. フラッシュの明るさのムラに強い特徴量

本研究では、フラッシュの明るさの影響を受にくい特徴量を検討し NN に適用する。その結果の比較し最適な粉じん濃度計測システムの構築を行う。

フラッシュの明るさのムラに強い特徴量抽出方法として、画像データを小ブロックに分割し、各小ブロックごとに明るさを考慮した画像ベクトルを利用した。特徴量の算出手順は以下に示す通りである。
 ステップ①：フラッシュ撮影した画像を過去の研究と同様にグレースケール化し、その画像を図-6 に示すように $N \times N$ 画素のブロックに細分化し、 N^2 次元ベクトルの小ブロックを作成する。細分化することで、画像の背景と粉じんの輝度値を明確に分けることができ、小ブロック内の背景の輝度値は一定となる。本研究では、微小な粉じんをより多く抽出するために、 N を 3 とした。

ステップ②：小ブロックについて、ブロック内の最小値で差を求めることで、小ブロックに対する明るさのムラを消去する。すなわち、画像ベクトル (\vec{a}) に変換し、式(1)より画像ベクトルの大きさ、式(2)より画像ベクトルの平均値をそれぞれ算出する。

$$|\vec{a}_{(x,y)}| = \sqrt{\sum_{i=1}^{N^2} \{a_i - \min(\vec{a})\}^2} \quad (1)$$

$$|\vec{a}_{(x,y)}| = \frac{\sum_{i=1}^{N^2} \{a_i - \min(\vec{a})\}}{i} \quad (2)$$

$\min(\vec{a})$: 画像ベクトル \vec{a} の最小値

ステップ③：次に、Canny 法を用いたエッジ検出法を行う。Canny 法は、数学的に考えられる、広範囲において対象物を見つけ、複数のステージアルゴリズムを使用する方法である⁴⁾。エッジ検出により、画像中の対象物と背景を分離することでノイズ除去を行うことができる。フラッシュ撮影した画像を以上に示す手順で処理した画像を図-7 (右) に示す。
 ステップ④：この画像から平均値、分散値の特徴量を抽出し、NN に入力を行い、粉じん濃度を算出する。

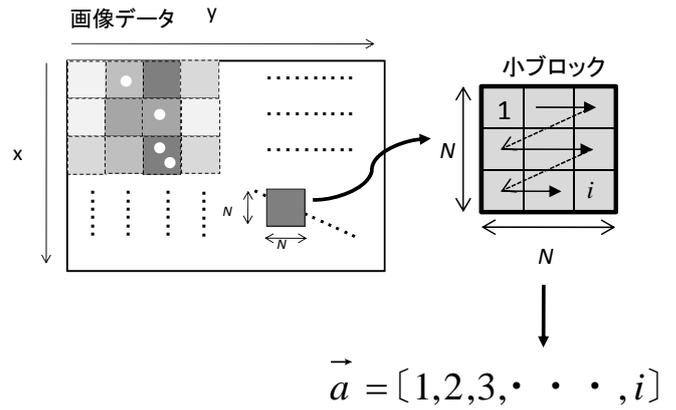


図-6 画像データ中の小ブロックと画像ベクトル

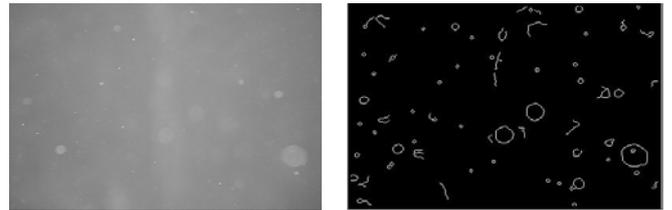


図-7 (左) フラッシュ撮影画像, (右) 画像処理画像

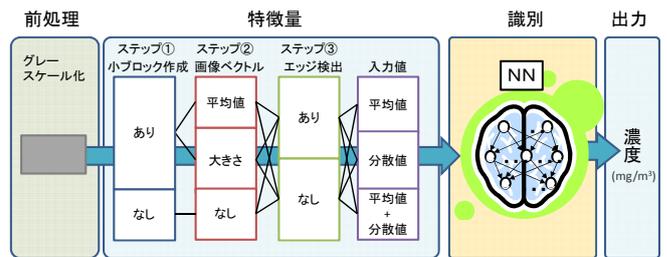


図-8 最適な特徴量の選定

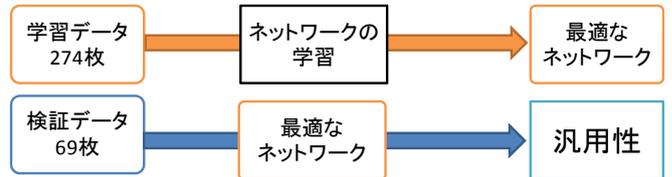


図-9 ネットワークの構築

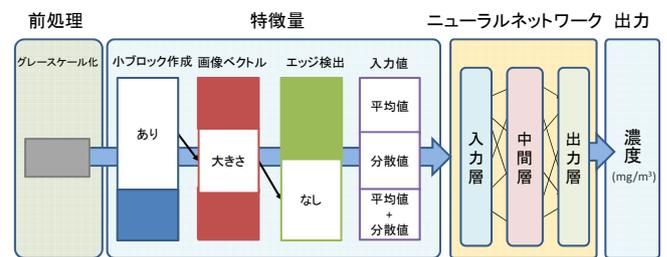


図-10 最適な粉じん濃度計測システム

6. 最適な特徴量の検討

以上の算出手順から図-8 に示すように、最適な特徴量の選定を行う。ステップ①～③の特徴量の組み合わせを NN に入力させ、最適な解を算出する特徴

量を本研究で用いる特徴量とする。また、ステップ①～③のすべてに「なし」であるのが過去の研究方法と同様の組み合わせである。

6. 1 ネットワークの構築

図-9に示すように、全データ 343 枚のうち、学習データ 274 枚を教師データとして学習として使用し、最適なネットワークの構築を行った。そして、学習に使用していない残りの 69 枚を検証データとして構築した最適なネットワークによって汎用性を評価する。

6. 2 特徴量の比較方法

最適な特徴量の比較方法は、正解値をデジタル粉じん計濃度と学習によって得られた NN による粉じん濃度の相関性を評価し、相関係数を求め比較を行う。相関係数の最も高い特徴量を本研究で用いる特徴量とする。相関係数は式(3)より算出する。

$$\rho = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (3)$$

ここで、 $\bar{x}, \bar{y}, \sigma_x, \sigma_y$ はそれぞれデジタル粉じん計を用いて計測した粉じん濃度 x と本研究で求めた NN による粉じん濃度 y の標本平均と標本標準偏差である。

7. 最適な特徴量の決定

図-10において、最も学習による相関係数が高い値となった、ステップ①～③を示す。小ブロックを作成し、画像ベクトルの大きさを求める。その画像ベクトルの大きさから特徴量を抽出する。また、NN に入力には、平均値が最も高い相関係数となった。その再現性による結果を図-11に示す。x 軸は正解値であるデジタル粉じん計濃度、y 軸には NN による粉じん濃度を示している。またよりわかりやすく評価するために表-2 に再現性による相関係数表を示す。すべてにおいて相関係数が高い結果となったことがわかる。

8. まとめ

本研究において、フラッシュの明るさのムラに強い特徴量の検討を行えたことができ、学習による高い再現性を得ることができた。よって最適なネットワークの構築ができた。

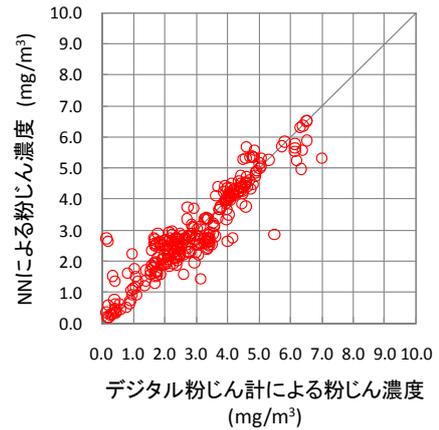


図-11 再現性の相関図

表-2 再現性による相関係数表

入力値	相関係数
平均値	0.93
分散値	0.90
平均値+分散値	0.87

今後の課題として、本研究で得た特徴量の汎用性の比較し、最も良い汎用性の評価を行うことが必要となる。

参考文献

- 1) 厚生労働省, 粉じん防止障害規則, 平成 21 年 3 月 30 日 改正
- 2) 樫本陽史: デジタルカメラを用いたトンネル坑内の粉じん濃度計測へのニューラルネットワークの適用, 山口大学工学部社会建設工学科建設基礎工学講座, 平成 20 年度卒業論文
- 3) 田辺和俊: NEUROSIM/L によるニューラルネットワーク入門, p7,75
- 4) John Canny, A Computational Approach to edge Detection, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.PAMI-8, No.6, November 1986