Title	熟練技術者の判定に基づいた道路橋における類似点検データの検索
Author(s)	齊藤, 僚汰; 高橋, 翔; 小川, 貴弘; 長谷山, 美紀
Citation	土木学会論文集F3 (土木情報学), 74(1), 67-77 https://doi.org/10.2208/jscejcei.74.67
Issue Date	2018
Doc URL	http://hdl.handle.net/2115/71962
Type	article
File Information	F3_Vol.74_No.1_p67-77_2018-1.pdf

[Instructions for use](#)

熟練技術者の判定に基づいた 道路橋における類似点検データの検索

斉藤 僚汰¹・高橋 翔²・小川 貴弘³・長谷山 美紀⁴

¹非会員 北海道大学大学院情報科学研究科 メディアネットワーク専攻 修士課程
(〒060-0814 北海道札幌市北区北14条西9丁目)

E-mail: ryota@lmd.ist.hokudai.ac.jp

²正会員 北海道大学准教授 大学院工学研究院 北方圏環境政策工学部門 (〒060-8628 北海道札幌市北区北13条西8丁目)
E-mail: stakahashi@eng.hokudai.ac.jp

³非会員 北海道大学准教授 大学院情報科学研究科 メディアネットワーク専攻
(〒060-0814 北海道札幌市北区北14条西9丁目)

E-mail: ogawa@lmd.ist.hokudai.ac.jp

⁴非会員 北海道大学教授 大学院情報科学研究科 メディアネットワーク専攻
(〒060-0814 北海道札幌市北区北14条西9丁目)

E-mail: miki@ist.hokudai.ac.jp

本文では、橋梁やトンネル等の道路構造物の維持管理の効率化を目的として、構造物の点検時に確認された変状に対し、類似する過去の点検データを検索可能とする手法を提案する。提案手法では、熟練技術者の判定に基づいた距離計量学習を導入することで、点検データ間の距離を新たに定義し、高精度な類似点検データの検索を可能とする。提案手法により提示される過去の類似事例を参考として変状の評価を行うことで、評価業務の効率化および技術者の経験の違いによって生じる評価の差を軽減することが期待できる。本文の最後では、実際のデータを用いた実験を行い、その有効性を確認する。

Key Words: road structure inspection, inspection records, retrieval, metric learning, rank-level fusion

1. はじめに

我が国では、高度経済成長期に、道路や橋、上下水道等の社会インフラが大量に整備された。その中でも、道路橋¹に代表される道路構造物は現在、急速に老朽化が進んでおり、効率的な維持管理が喫緊の課題となっている¹⁾。さらに、老朽化する道路構造物の数は今後20年で急激に増加し、それに伴う維持管理や更新に係る費用も増大する見込みであることが報告されている¹⁾。また、道路構造物の維持管理に関わる財政状況が厳しくなると見込まれている一方で、点検を行う技術者の数が年々減少傾向にあることも報告されている¹⁾。したがって、道路構造物を維持していくためには、技術者一人あたりの負担を低減し、維持管理に伴うコストを削減可能な手法が必要である。このような背景から、我が国では、IoT (Internet of Things)、ビッグデータ、人工知能、ロボットの活用によるインフラの維持管理の効率化・高度化の支援を推進しており^{2),3)}、現在、様々な研究開発が進められている⁴⁾。

このようなインフラ維持管理の支援のための研究は我が国のみならず、特に変状検出やロボット等を用い

た自動点検のための手法は種々提案されている^{5),6),7),8)}。これらの手法の多くはこれまで人手で行われてきた点検業務の一部を情報通信技術によって代替的に行う手法である。しかしながら、点検業務にこれらの手法を導入した場合においても、点検箇所に対して必要とされる対策を決定するにあたっての最終的な判断は人間が行うと考えられるが、この過程における直接的な支援の手法は数少ない。その1つとして、類似変状検索^{9),10)}が挙げられる。文献9)では、道路舗装の維持管理を支援するため、変状画像から変状を検出し、データベース化することで、舗装された道路における類似変状検索を実現している。また、文献10)では、道路構造物の維持管理を支援するため、点検時に評価の対象となる変状に対し、類似する過去の点検データを参考事例として提示する変状評価支援システムにより、変状の評価を補助する類似点検データの検索を実現している。

道路橋における点検業務では、国や地方自治体等で作成された点検要領^{11),12)}に基づいて、技術者が変状の評価を行っているが、技術者の経験や知識、さらには変状の種類によっては、評価に差が生じてしまうという問題が存在する。例えば、文献9)の手法を道路橋における点検で採用する場合、類似変状を検索することが可能であるが、変状の画像のみを使用し、変状の検

¹ 道路法第2条第1項に規定される道路における橋長2.0m以上の橋、高架の道路等を示す。

表-1 点検記録の例

ID	変状項目名称	変状判定区分名称	変状部位区分名称	変状部位名称	...	構造細目名称	構造種別名称	構造形式名称	構造物区分名称
1	ひびわれ	A3	高欄・地覆	左・外	...	高欄・地覆	コンクリート製高欄	高架橋	橋梁
2	鉄筋露出	A3	地覆	右・外・下	...	高欄・地覆	地覆	本線橋中小	橋梁
3	遊離石灰	B	上部構造	張出し部(右)	...	コンクリート上部工	RC床版	本線橋中小	橋梁
4	腐食	A3	上部構造	主桁フランジ	...	鋼構造物	鋼桁	本線橋長大	橋梁
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮

※本表の ID1~4 はそれぞれ 図-1 (a)~(d) に示す変状画像に対応する。

(a) ひびわれ (ID 1)

(b) 鉄筋露出 (ID 2)

(c) 遊離石灰 (ID 3)

(d) 腐食 (ID 4)

※画像の ID 番号は表-1 に示す点検記録と対応する。

図-1 変状画像 (近景) の例

出を行った上で検索を行う手法であるため、特定の変状の検出に特化したものになってしまう。一方で、変状評価支援システムの検索手法¹⁰⁾では、図-1 および表-1 にそれぞれ例示する変状を撮影した画像 (以降、変状画像) と点検箇所の情報や評価の記録 (以降、点検記録) の組を点検データとして、道路橋における様々な類似変状を提示可能なため、技術者にそれらを参考とした変状の評価を可能とし、道路橋の点検業務において技術者間で生じる評価の差の軽減を図っている。また、変状評価支援システムでは、点検データを表現する特徴量間のユークリッド距離によって、点検データ間の類似度を定義し、距離が小さいほど、類似度が高い点検データとすることで検索を可能としている。しかしながら、ユークリッド距離によって定義される類似度は変状評価の観点に基づいて算出されたものではないため、検索精度に限界がある。また、検索対象によって注目すべき特徴、例えば、画像特徴やテキスト特徴が異なるにも関わらず、これを考慮した類似点検データの検索も実現されていない。

そこで、本文では、熟練技術者の判定に基づいた道路橋における類似点検データの検索手法を新たに提案

する。提案手法では、変状画像および点検記録から算出される画像特徴とテキスト特徴に対し、それぞれ、熟練技術者の判定に基づいた Laplacian Regularized Metric Learning (LRML)¹³⁾ による距離計量学習を行うことで、変状評価に適した距離の算出を可能とする。さらに、変状画像間および点検記録間において算出される距離に基づいて、類似変状のランク付けを行い、それらの Rank-Level Fusion¹⁴⁾ を行うことで、熟練技術者が点検データの類似性の判定を行う上で、変状画像と点検記録それぞれにどれだけ注目したかを考慮した検索結果の提示を可能とする。以上により、熟練技術者の判定を活用した提案手法では、従来研究の問題の解決が可能になるため、高精度な検索結果の取得が可能となる。

以降、本文の構成について述べる。まず、2 章では、変状評価の定義および本研究で用いる点検データについて説明を行う。次に、3 章では、提案手法により点検データ間の距離を算出し、検索順位を決定する方法について説明する。続いて、4 章では、提案手法の有効性を確認するための実験結果を示す。最後に、5 章でまとめとする。

2. 変状評価と本研究で用いる点検データ

(1) 変状評価

本節では、本研究における変状評価の定義について説明する。道路橋の定期点検では、近接目視²⁾による状態の評価が行われる。点検の際、点検を行う技術者は自身の名前や所属、点検場所、表-1 に例示する各項目について記録を行い、変状が生じている箇所の近景および遠景画像を撮影する。最終的に、撮影された変状画像と点検記録より、点検結果を審議し、決定された評価に基づいて、維持管理のための措置が講じられる。

本文では、点検要領の基準に従って行われる“変状項目名称”および“変状判定区分名称”の評価を変状評価と定義する。変状項目名称は変状の種類を表し、構造物の部材に生じる腐食や鉄筋露出、遊離石灰等、変状の名称が記録される。変状判定区分名称は変状の程度を

²⁾ 近接目視は、肉眼により部材の変状等の状態を把握し評価を行うことができる距離まで接近して目視を行うことを指す。

表し、本研究で用いる点検データにおいては、文献 15) に示される判定基準にしたがって、AA, A, A1, A2, A3, B, C の記号が記録される。変状評価は点検要領に沿って行われるが、技術者の経験と知識に基づき判断がなされるため、点検を行う技術者によって、評価に差が生じてしまう問題が存在する。

(2) 本研究で用いる点検データ

本節では、本研究で用いる点検データについて説明する。本研究では、技術者が道路橋の点検時に保存した近景の変状画像と各種点検項目の点検結果を記載した点検記録を用いる。ただし、点検記録は表-1 に例示した変状部位区分名称、変状部位名称、構造細目名称、構造種別名称、構造形式名称、構造物区分名称に加え、構造物名称³ のカテゴリに記録されたデータを使用する。提案手法では、変状画像および点検記録を表現する特徴量を算出することで点検データを定量化する。さらに、変状評価支援システム¹⁰⁾ を用いて類似点検データの検索を行った際に、クエリとなった点検データと検索された点検データの組に対して、その類似性を熟練技術者が判定し、ラベルを付与した表-2 および図-2 に例示する点検データの組を用いる。ただし、クエリは類似点検データの検索時に入力する点検データを指す。また、本文では、“対象の点検箇所の変状評価を行う上で参考となる”点検データを類似した点検データと定義する。クエリと検索結果の 2 つの点検データの組には、変状画像と点検記録の両方を比較し、クエリとなった点検箇所の変状評価を行う上で、検索結果の点検データが参考となるか否かを熟練技術者が判定し、参考になると判定した場合に、“good”, そうでない場合に、“no good” の判定ラベルが付与されている。

提案手法では、熟練技術者により付与された判定ラベルに基づいて、距離計量学習を行うことで、新たな点検箇所の変状評価を行う際に、変状の発生条件等を考慮せずとも、評価の参考となり得る類似点検データを検索可能とする点検データ間の距離が算出可能である。また、“good” の判定ラベルが付与された点検データの組は、必ずしも各カテゴリが同一の内容とは限らないため、提案手法では、カテゴリが同一の点検データをリスト表示するよりも高精度に、評価の参考となる類似点検データを検索することが可能である。

3. 熟練技術者の判定に基づく点検データ間の距離の算出および検索順位の決定

本章では、提案手法による類似点検データの検索を行うために、点検データ間の距離を算出し、検索順位

³ 構造物の所在を表す名称が記録される。

を決定する方法について説明する。図-3 に提案手法による類似点検データ検索のための処理を示す。提案手法では、まず、文献 16) および文献 17) の手法に基づいて、変状画像より画像特徴量を算出する。また、点検記録より、バイナリ表現によるテキスト特徴量を算出する。これらの特徴量算出の詳細については付録 I に示す。次に、算出された画像特徴量およびテキスト特徴量を用いて、距離計量学習を行い、点検データ間の距離を新たに定義する。さらに、画像特徴およびテキスト特徴の重要性を考慮したランク付けを行うことで、最終的な検索順位の決定を可能とする。

以降、点検データ間の距離を定義する方法および検索順位を決定する方法について、それぞれ説明する。まず、(1) 節では、LRML によって、熟練技術者の判定に基づいて点検データ間の距離を算出する方法について説明する。続いて、(2) 節で、画像とテキストそれぞれについて求められた距離に基づいてランクを決定し、Rank-Level Fusion を行うことにより、最終的な検索順位の決定を行う方法について説明する。

(1) LRML に基づく点検データ間の距離の算出

本節では、点検データより算出された特徴量に対して、LRML を用い、熟練技術者の判定に基づいて点検データ間の距離を算出する方法について説明する。今、変状画像より算出される画像特徴量を並べた画像特徴ベクトル $\mathbf{x}_i^{\text{image}} (i = 1, 2, \dots, N; N \text{ はラベルが付与された点検データの総数})$ 、点検記録より算出されるテキスト特徴量を並べたテキスト特徴ベクトル $\mathbf{x}_i^{\text{text}} (i = 1, 2, \dots, N)$ が与えられているとする。次に、特徴ベクトル $\mathbf{x}_i^k (k \in \text{image, text})$ に対して、技術者により付与された“good”および“no good”の判定ラベルを基に、LRML による距離計量学習を行うことで、“good”と判定された点検データの組において特徴ベクトル間の距離が小さくなり、“no good”と判定された点検データの組において特徴ベクトル間の距離が大きくなるような距離を定義する。このとき、熟練技術者の判定ラベルが付与された点検データの組を教師データとして用いて、次式に示す最適化問題を解くことで、熟練技術者の判定ラベルに基づいた距離の算出を可能とする重み行列 $\mathbf{A}^k$ が求められる。

$$\min_{\mathbf{A}^k} m(\mathbf{A}^k) + \gamma \mathcal{V}_g(\cdot) - (1.0 - \gamma) \mathcal{V}_{ng}(\cdot), \quad (1)$$

$$s.t. \mathbf{A}^k \succeq 0, \log \det(\mathbf{A}^k) \geq 0, 0 \leq \gamma \leq 1.0$$

ただし、

$$\mathcal{V}_g(\cdot) = \sum_{(\mathbf{x}_i^k, \mathbf{x}_j^k) \in \mathcal{S}_{\text{good}}} \|\mathbf{x}_i^k, \mathbf{x}_j^k\|_{\mathbf{A}^k}^2 \quad (2)$$

$$\mathcal{V}_{ng}(\cdot) = \sum_{(\mathbf{x}_i^k, \mathbf{x}_j^k) \in \mathcal{S}_{\text{no good}}} \|\mathbf{x}_i^k, \mathbf{x}_j^k\|_{\mathbf{A}^k}^2 \quad (3)$$

表-2 技術者によりラベルが付与された点検データの例

判定ラベル	変状の画像		構造種別名称		変状項目名称		変状部位名称		変状判定区分名称	
	クエリ	検索結果	クエリ	検索結果	クエリ	検索結果	クエリ	検索結果	クエリ	検索結果
no good	画像: ID 1	画像: ID 2	RC 床版	RC 床版	遊離石灰	遊離石灰	張出し部 (右)	主版部 (右)	B	A3
good	画像: ID 1	画像: ID 3	RC 床版	RC 床版	遊離石灰	遊離石灰	張出し部 (右)	主版部	B	B

※変状画像は図-2に示す。

図-2 クエリ画像と検索結果の画像

※図中の紫枠は変状画像、赤枠は点検記録に対する処理を表す。

図-3 提案手法のダイアグラム

$$\|x_i^k, x_j^k\|_{A^k} = \sqrt{(x_i^k - x_j^k)^T A^k (x_i^k - x_j^k)} \quad (4)$$

である。このとき、 γ は“good”と判定された点検データの組と“no good”と判定された点検データの組の影響力を定めるパラメータであり、0.05 刻みで更新を行う。 $\mathcal{V}_g(\cdot)$ および $\mathcal{V}_{ng}(\cdot)$ はそれぞれ“good”および“no good”

と判定された点検データの組における特徴ベクトル間の距離の総和を表す。ただし、特徴ベクトル間の距離は式 (4) で定義されるマハラノビス距離で表される。また、集合 $\mathcal{S}_{\text{good}}$ および $\mathcal{S}_{\text{no good}}$ は以下のように定義される。

$$\mathcal{S}_{\text{good}} = \{(x_i^k, x_j^k) | \text{点検データ } i \text{ と } j \text{ の組が“good”}\}$$

$S_{\text{no good}} = \{(\mathbf{x}_i^k, \mathbf{x}_j^k) \mid \text{点検データ } i \text{ と } j \text{ の組が “no good”}\}$
 さらに, $\mathbf{A}^k$ は対称行列であり, 式 (1) の正則化項 $m(\mathbf{A}^k)$ は次式で定義される.

$$m(\mathbf{A}^k) = \frac{1}{2} \sum_{i,j=1}^N \{(\mathbf{x}_i^k - \mathbf{x}_j^k)^T \mathbf{A}^k (\mathbf{x}_i^k - \mathbf{x}_j^k)\} W_{ij}^k \quad (5)$$

$$= \text{tr}(\mathbf{X}^k \mathbf{L}^k (\mathbf{X}^k)^T \mathbf{A}^k) \quad (6)$$

ここで, $\mathbf{X}^k = [\mathbf{x}_1^k, \mathbf{x}_2^k, \dots, \mathbf{x}_N^k]$ と表すことができ, $\mathbf{L}^k = (\mathbf{D}^k)^{-\frac{1}{2}} (\mathbf{D}^k - \mathbf{W}^k) (\mathbf{D}^k)^{-\frac{1}{2}}$ である. また, $\mathbf{D}^k$ は対角行列であり, その対角成分 D_{ii}^k は $\sum_j W_{ij}^k$ である. tr は行列のトレースを表す. さらに, $\mathbf{W}^k \in \mathbb{R}^{N \times N}$ は要素 W_{ij}^k を持ち, 以下で定義される.

$$W_{ij}^k = \begin{cases} 1 & \mathbf{x}_i^k \in \mathcal{N}(\mathbf{x}_j^k) \text{ or } \mathbf{x}_j^k \in \mathcal{N}(\mathbf{x}_i^k) \\ 0 & \text{otherwise} \end{cases} \quad (7)$$

ここで, $\mathcal{N}(\mathbf{x}_i^k)$ は $\mathbf{x}_i^k$ の近傍のデータを含む集合である.

以上により得られた画像とテキストそれぞれに対応する重み行列 $\mathbf{A}^k$ を用いて, 新たな点検箇所のデータ (クエリ) q と過去に作成された点検データ r の距離 $d_{q,r}^k$ を以下の式により算出する.

$$d_{q,r}^k = \|\mathbf{x}_q^k, \mathbf{x}_r^k\|_{\mathbf{A}^k} \quad (8)$$

式 (8) により算出される点検データ間の距離 $d_{q,r}^k$ は熟練技術者が付与した判定ラベルに基づいた最適化によって, 熟練技術者が “good” と判定する, すなわち「2つの点検データが変状評価を行う上で互いに参考になる」と判定する点検データの組の距離が小さくなるように算出される. したがって, LRML による距離計量学習により, 変状評価に最適な距離の定義が可能になる.

(2) Rank-Level Fusion による検索順位の決定

本節では, (1) 節で算出される画像とテキストそれぞれの距離から最終的な検索順位を決定する方法を説明する. まず, 前節で算出した新たな点検データ q に対するデータベース内の過去の点検データ r について, 点検データ q と r の距離 $d_{q,r}^k$ を昇順に並べ, q に対する r のランク $c_{q,r}^k$ を得る. つまり, $c_{q,r}^{\text{image}}$ と $c_{q,r}^{\text{text}}$ の2種類のランクをそれぞれ求める. 次に, 画像とテキストのランクについて, Rank-Level Fusion を行い, 最終的な検索順位を決定する. ここで, 技術者が判定ラベルを付与する際, 変状の種類によって, 注目すべき特徴 $k(k \in \text{image, text})$ が異なる. LRML では, 変状画像と点検記録それぞれ, 熟練技術者の判定に基づいて新たに定義された距離が算出されるが, 最終的な検索順位は変状の種類ごとにそれらを効果的に統合することで決定される必要がある. そのため, 次式による Rank-Level Fusion を用いることで, 画像とテキストそれぞれのランクに対して, 注目すべき特徴を考慮した統合を可能とする.

表-3 データの内訳

変状	クエリ数	“good”	“no good”	合計
腐食	29	39	220	259
鉄筋露出	30	20	275	295
遊離石灰	32	80	181	261

$$C_{q,r} = w c_{q,r}^{\text{image}} + (1.0 - w) c_{q,r}^{\text{text}} \quad (9)$$

$$0 \leq w \leq 1.0$$

このとき, 提案手法における Rank-Level Fusion では, 式 (9) 中の重みパラメータ w を $w = 0$ から $w = 1.0$ まで 0.1 刻みで順次更新を行いながら, ランク $c_{q,r}^k$ 統合後のランク $C_{q,r}$ を算出する. w の更新に伴い, 順次決定される $C_{q,r}$ に基づいて, 変状ごとに教師データとして与えたクエリの点検データに類似する点検データの検索精度を算出し, 検索精度が最大となる重み w を求める. 最適な重み w により決定された $C_{q,r}$ を最終的な検索順位として採用する.

以上より提案手法では, 式 (9) の w によって, 画像とテキストの距離に基づく順位を統合し, 最終的な検索精度が最も高くなるような検索順位 $C_{q,r}$ を決定する. 検索順位 $C_{q,r}$ は LRML により決定された変状画像間と点検記録間それぞれの距離について, 注目すべき特徴を考慮した統合を行ったものである. 提案手法では, 最終的に得られる順位 $C_{q,r}$ を検索順位として採用することで, 新たな点検データに類似する点検データの高精度な検索を可能とする.

4. 実験

本章では, 実際の点検データに対して, 提案手法を適用した際の結果を示すことで, その有効性を確認する. 本実験では, 2章で説明した点検データについて, 勤続30年以上の技術者が判定ラベルを付与した点検データの組のうち, 変状項目名称が “腐食”, “鉄筋露出”, “遊離石灰” である点検データをクエリとして使用した. なお, 実験に用いた点検データは変状評価支援システム¹⁰⁾に保存されているものであり, 変状画像の解像度は 640×480 画素である. データの内訳を表-3に示す. また, 検索精度の評価には情報検索システムの精度評価に一般的に用いられる Mean Average Precision (MAP) を用いており, 以下に示す式により定義される.

$$\text{MAP} = \frac{1}{M} \sum_{q=1}^M \text{AP}_q \quad (10)$$

$$AP_q = \frac{1}{N_q^{\text{good}}} \sum_{l=1}^{N_q^{\text{good}}} \text{Precision}_q(l) \quad (11)$$

$$\text{Precision}_q = \frac{\text{検索された“good”の点検データ数}}{q \text{ に対して検索された点検データ数}} \quad (12)$$

ここで、式(11)の AP_q はあるクエリ q に対し、“good”が付与された検索結果が提示された時点での Precision^4 の平均、MAPは全クエリに対する AP_q の平均である。また、 M はクエリの総数、 N_q^{good} はクエリ q に対する“good”の点検データの総数を表し、 $\text{Precision}_q(l)$ は l 番目に“good”の判定ラベルが付与された点検データが検索された時点での Precision_q を表す。なお、MAPの値が大きいほど、“good”の判定ラベルが付与される点検データが上位に検索されることを意味し、より高精度に検索が行われていることを示す。すなわち、MAPの値が大きいほど、変状評価の際に参考となり得る類似点検データがより多く検索されることを表す。

以降、(1)節にLRMLによる熟練技術者の判定に基づいた距離計量学習の有効性を確認するための実験結果を示し、(2)節に提案手法によるRank-Level Fusionの有効性を示すための実験結果を示す。さらに、(3)節に実験を行った実装環境を示す。

(1) LRMLによる熟練技術者の判定に基づく距離計量学習を導入した類似点検データの検索(実験1)

本節では、LRMLによる熟練技術者の判定に基づいた距離計量学習の導入に関する有効性を確認する。本実験では、表-3に示した各クエリに類似する点検データを検索し、その精度を確認する。検索精度の評価には、式(10)-(12)で定義されるMAPを用いた。比較手法として、変状評価支援システムで用いられているユークリッド距離に基づいた検索に加え、LRMLに代えて代表的な距離計量学習の手法を用いた場合の検索も行った。具体的に、提案手法および比較手法では、以下の距離に基づいた類似点検データの検索を行い、その際の検索精度を算出した。

● 提案手法

3章(1)節で述べた距離計量学習による距離を用いる。熟練技術者の判定ラベルに基づいたLRMLによって、距離を定義し、点検データ間の類似度を決定する。

● ユークリッド距離(L2)を用いた手法

変状評価支援システム¹⁰⁾において、採用されているユークリッド距離を用いる。ユークリッド距離を用いた手法は学習は行わずに、ユークリッド空間において距離を算出する手法であり、各点検データを表現する特徴ベクトル間のユークリッド距離

によって、点検データ間の類似度を決定する。ユークリッド距離では、2つのベクトル間の距離を算出する際に、最もベンチマーク的に用いられるものであるものの、点検データに最適化されたものではない。

● Information Theoretic Metric Learning (ITML)¹⁸⁾を用いた手法

文献18)に基づく距離を用いる。ITMLは情報理論的アプローチによる学習に基づいたマハラノビス距離を算出する手法であり、学習を行う際、 $\log \det$ ダイバージェンスの最小化により、学習データの組について同一のラベルをもつデータの組の距離を小さくするような学習を行うことで、距離を定義し、点検データ間の類似度を決定する。ITMLは、カーネルを用いた学習により、多クラスへの最適化が可能であるが、パラメータの選び方が学習精度に大きく影響してしまう。本実験では、変状項目名称をラベルにもつ点検データを学習に用いている。

● Large Margin Nearest Neighbor (LMNN)¹⁹⁾を用いた手法

文献19)に基づく距離を用いる。LMNNは k 近傍法による学習に基づいたマハラノビス距離を算出する手法であり、学習を行う際、任意の学習データとその近傍にある同一のラベルをもつデータの組の距離を小さくするような距離の学習を行うことで、距離を定義し、点検データ間の類似度を決定する。LMNNは、局所的に距離計量を学習し、大域的に統合を行うことにより、効率的に多クラスへの最適化が可能であるが、高次元の場合、過学習が生じやすい。本実験では、変状項目名称をラベルにもつ点検データを学習に用いている。

ただし、検索順位を決定するためのRank-Level Fusionは3章(2)節で述べた方法を用いており、重み w の学習においては5分割交差検定を採用する。5分割交差検定では、学習データを5分割し、その1つをテストデータ、残りを教師データとする試行を組み合わせを変えて5回行い、各試行の平均精度を学習精度とすることで、学習データが少ない場合でもテストデータの選び方による精度の誤差を軽減することが可能である。なお、検索精度の評価は式(10)-(12)で定義されるMAPを用いた。

以上に説明した距離を用いて、表-3のデータに対して検索を行った結果のMAPを表-4に示す。ただし、表中の“平均”は腐食、鉄筋露出、遊離石灰の3つの変状の検索精度の平均値である。本文では、表中の“平均”に示すMAPの値により手法ごとの有効性を評価する。表-4より、3つの変状のMAPの平均は提案手法が最も

⁴ 検索結果に適合データが含まれる割合を表す。

表-4 各距離定義に基づいた検索の MAP

手法	腐食	鉄筋露出	遊離石灰	平均
提案手法	0.53	0.73	0.66	0.64
L2	0.40	0.70	0.60	0.57
ITML	0.36	0.69	0.59	0.55
LMNN	0.40	0.61	0.62	0.54

高い値を示すことが確認できる。特に、腐食は従来手法の MAP が 0.5 未満であったが、提案手法により、0.1 以上の精度向上が見られる。この要因として、腐食が様々な形状の金属部材に生じる変状であるため、コンクリート部材の表面に現れる鉄筋露出や遊離石灰に比べ、点検データ間の相違度がユークリッド距離を用いた手法よりも、提案手法では適切に表現されたためと考えられる。MAP の差による検索結果の違いについて、説明を容易にするため、付録 II にシミュレーションを行った結果を示す。また、あるクエリに対して、類似点検データを検索した結果の例を図-4 に示す。図-4 では、図中に示すクエリの点検データに対して、類似点検データを検索した際の上位 5 件の検索データと各手法において、“good” の判定ラベルが検索された順位を示している。ただし、点検記録は評価項目の一部のみを示しており、“good” の判定ラベルは事前に熟練技術者が付与したものである。図-4 より、提案手法では、ID: 0 の点検箇所の変状評価を行うにあたって、熟練技術者が“参考となる”と判定した ID: 1 の点検データが 1 位に検索されていることが確認できる。さらに、図-4 下部に示すように、クエリに対して“good” のラベルが付与されている点検データが検索された順位に注目すると、提案手法では比較手法よりも上位に検索されていることが分かる。

(2) Rank-Level Fusion を導入した類似点検データの検索 (実験 2)

本節では、Rank-Level Fusion を導入した類似点検データの検索の有効性を確認する。本実験においても、実験 1 と同様の検索精度の評価方法を用いた。提案手法および比較手法では、以下の手法による Rank-Level Fusion を導入した類似点検データの検索を行った。

- 提案手法

3 章 (2) 節で述べた方法による Rank-Level Fusion ただし、重み w の学習の評価には 5 分割交差検定を採用し、検索精度の評価は式 (10)-(12) で定義される MAP を用いた。

- 従来手法

式 (9) 中の重み w を次式により算出することで、検

表-5 各 Rank-Level Fusion 手法における MAP

手法	腐食	鉄筋露出	遊離石灰	平均
提案手法	0.53	0.73	0.66	0.64
従来手法	0.41	0.71	0.66	0.59
Borda Count	0.51	0.65	0.67	0.61
Highest Rank	0.36	0.73	0.52	0.54

索順位 $C_{q,r}$ を決定する Rank-Level Fusion

$$w = \frac{\text{MAP}^{\text{image}}}{\text{MAP}^{\text{image}} + \text{MAP}^{\text{text}}} \quad (13)$$

ただし、 $\text{MAP}^{\text{image}}$, MAP^{text} はそれぞれ教師データの変状画像の点検記録のみで類似点検データを検索した際の MAP を表す。

- Borda Count

次式により、検索順位 $C_{q,r}$ を決定する Rank-Level Fusion

$$C_{q,r} = c_{q,r}^{\text{image}} + c_{q,r}^{\text{text}} \quad (14)$$

例えば、ある点検データについて、変状画像のみを用いた類似変状画像の検索では 2 番目に検索され、点検記録のみを用いた類似点検記録の検索では 3 番目に検索されるとき、その検索順位は $C_{q,r} = 2 + 3 = 5$ となる。

- Highest Rank

次式により、検索順位 $C_{q,r}$ を決定する Rank-Level Fusion

$$C_{q,r} = \min(c_{q,r}^{\text{image}}, c_{q,r}^{\text{text}}) \quad (15)$$

例えば、ある点検データについて、変状画像のみを用いた類似変状画像の検索では 2 番目に検索され、点検記録のみを用いた類似点検記録の検索では 3 番目に検索されるとき、その検索順位は $C_{q,r} = \min(2, 3) = 2$ となる。

ただし、点検データ間の距離は 3 章 (1) 節で述べた距離計量学習により定義される距離を用いた。

各 Rank-Level Fusion の手法を用いて、表-3 のデータに対して検索を行った結果の MAP を表-5 に示す。表-5 より、3 つの変状の MAP の平均は提案手法が最も高い値を示すことが確認できる。(1) 節と同様に、MAP の差による検索結果の違いについては、付録 II にシミュレーションを行った結果を示す。Borda Count では、遊離石灰の MAP は最も高い値を示しており、Highest Rank では、鉄筋露出の MAP は提案手法と同様に、最も高い値を示している。一方で、提案手法では、3 つの変状とも MAP が高く、比較手法よりも MAP の平均も高いことから高精度な検索が可能であることが確認された。これは変状によって変状画像および点検記録のどちらに

表-6 提案手法の処理における点検データ 1 つあたりの処理時間

処理	処理時間 (s)
特徴量の算出	1.85
点検データ間の距離の算出	1.46
検索順位の決定	0.22

どれだけ注目すべきかが異なるため、提案手法による Rank-Level Fusion が有効であったことに起因していると考えられる。例えば、腐食の場合、点検記録が類似していても、変状画像では金属部材における腐食の広がり方が大きく異なる場合が多く、変状画像への重みを大きくした統合が有効であると考ええる。一方で、鉄筋露出や遊離石灰では、変状画像では変状の現れ方に大きな差異が見られない場合であっても、点検記録上では構造物が異なっている場合が多く、点検記録への重みを大きくした統合が有効であると考ええる。また、図-4 の検索結果の例より、実験 1 と同様に、提案手法における“good”の点検データが検索された順位は比較手法よりも上位であることが分かる。

(3) 実装環境

本節では、実験を行った実装環境について説明する。実験では 8.0 GB RAM, および Intel Core i5-6500 3.20 GHz を搭載したコンピュータを使用した。また、OS は Ubuntu 14.04, 開発言語は Python 2.7.6 を使用した。表-6 に各手順の処理時間を示す。表-6 より、提案手法は処理時間を考慮しても、実用上有効な類似点検データ検索を実現可能であることが分かる。したがって、提案手法により、実際の変状評価において、効率的かつ効果的な支援が可能であるといえる。

5. まとめ

本文では、道路構造物の維持管理の効率化を目的として、熟練技術者の判定に基づいた類似点検データの検索手法を提案した。提案手法では、熟練技術者の判定に基づいた距離の定義により、変状の評価に適した距離の算出を可能とした。さらに、変状画像と点検記録のどちらにどれだけ注目すべきかを考慮した Rank-Level Fusion によって、変状画像間の距離に基づいて決定されたランクと点検記録間の距離に基づいて決定されたランクを統合可能とした。実験の結果、提案手法の有効性が確認され、従来手法に比べ、高精度な類似点検データの検索が実現可能であることが示された。

謝辞: 本研究の一部は、JSPS 科研費 JP17H01744 の助成により行われた。また、本研究では東日本高速道路株式会社よりご提供頂いた点検データを使用した。

付録 I 特徴量の算出

本章では、点検データを表現する画像特徴量およびテキスト特徴量を算出する方法について説明する。

(1) 変状識別モデルの構築と画像特徴量の算出

本節では、変状画像の特徴量抽出に用いる変状識別モデルの構築について説明する。変状識別モデルの構築は図-3 のダイアグラムにおける畳み込みニューラルネットワーク (CNN)²⁰⁾ の学習により行われる。構築される変状識別モデルは、変状画像を入力として与えると、その画像の変状項目名称を識別することが可能である。ネットワークの内部では、入力の変状画像の輝度値と変状項目名称のラベルを基に、変状項目名称を識別するための重みパラメータの計算が行われ、中間層の出力値は変状画像を有効に表現した特徴量として用いることが可能である^{21),22)}。したがって、点検記録より算出するテキスト特徴量と変状識別モデルより得られる変状画像の特徴量を用いて点検データを表現することで、高精度な類似点検データの検索を実現可能とする。

提案手法で用いる画像特徴量は変状画像の中央部分に重み付けをした顕著性マップ²³⁾に基づいて生成された重み付きの変状画像より算出される。これにより、変状画像に写りこんでいる空や植物等の変状そのものに関係がない背景の影響を軽減し、変状を表現するのに有効な特徴量の算出が可能となる。提案手法では、まず、一般画像で学習済みの AlexNet²⁴⁾ に対して、変状項目名称それぞれのラベルが付与された変状画像を学習データとして用いて Fine-tuning を行い、変状識別モデルを構築する。ただし、本文において、学習データに用いる変状画像は 640×480 画素の変状画像の中央部から CNN の入力層のサイズとなるように、225×225 画素でクロップした画像を用いる。したがって、提案手法では 225×225 画素以上の変状画像を要する。また、これらの画像の中には変状が正面から撮影されていない画像を含んでおり、変状画像の撮影方法に影響されない識別モデルの構築を行っている。

次に、新たに構築されたモデルに重み付きの変状画像を入力した際の第 6 層の出力値を画像特徴量として抽出する。

クエリの点検データ

ID: 0 (点検記録)

ID	変状	構造種別名称	変状部位名称	変状判定区分名称
0	鉄筋露出	RC床版	主版部	B

ID: 0 (変状画像)

検索結果

上位5件の点検データ

提案手法

1位

2位

3位

4位

5位

ID: 1

ID: 3

ID: 4

ID: 5

ID: 6

実験 1

L2

ID: 4

ID: 1

ID: 3

ID: 7

ID: 8

ITML

ID: 4

ID: 3

ID: 1

ID: 7

ID: 8

LMNN

ID: 9

ID: 10

ID: 7

ID: 3

ID: 11

従来手法

ID: 4

ID: 1

ID: 7

ID: 3

ID: 11

実験 2

Borda Count

ID: 4

ID: 7

ID: 9

ID: 11

ID: 8

Highest Rank

ID: 4

ID: 1

ID: 3

ID: 7

ID: 9

点検記録

ID	判定ラベル	変状項目名称	構造種別名称	変状部位名称	変状判定区分名称
1	"good"	鉄筋露出	RC床版	張出し部(右)	B
2	"good"	鉄筋露出	RC桁	横桁	B
3	"no good"	鉄筋露出	RC床版	主版側面	A3
4	"no good"	遊離石灰	RC床版	張出し部(左)	B
5	"no good"	鉄筋露出	PC床版	主版側面	B
6	"no good"	鉄筋露出	PC床版	張出し部(左)	B
7	"no good"	遊離石灰	RC床版	主版下面	A3
8	"no good"	遊離石灰	RC床版	張出し部(右)	B
9	"no good"	鉄筋露出	橋台	橋台パラペット	A3
10	"no good"	鉄筋露出	地覆	右・外・下	B
11	"no good"	鉄筋露出	橋台	橋台パラペット	A3

実験 1	手法	"good" の点検データが検索された順位	クエリ(ID: 0) に対して, "good" の判定ラベルをもつ点検データ
	提案手法	1位 (ID: 1), 8位 (ID: 2)	
	L2	2位 (ID: 1), 19位 (ID: 2)	
	ITML	3位 (ID: 1), 20位 (ID: 2)	
	LMNN	3位 (ID: 1), 20位 (ID: 2)	
実験 2	手法	"good" の点検データが検索された順位	クエリ(ID: 0) に対して, "good" の判定ラベルをもつ点検データ
	提案手法	1位 (ID: 1), 8位 (ID: 2)	
	従来手法	2位 (ID: 1), 17位 (ID: 2)	
	Borda Count	8位 (ID: 1), 10位 (ID: 2)	
	Highest Rank	2位 (ID: 1), 15位 (ID: 2)

ID: 1

ID: 2

図-4 実験 1 および実験 2 における検索結果の例

表-7 検索数を 15 とした場合の検索シミュレーション結果

	検索例	AP	AP の差	上位 10 件中の “good” の差
検索例 1	1-1: [1 1 1 1 1 1 1 1 1 0 0 0 0 0 1]	0.644	0.07	3 件
	1-2: [1 1 1 1 1 1 0 0 0 0 1 1 0 1 1]	0.574		
検索例 2	2-1: [1 1 1 1 1 1 1 1 1 0 0 0 0 0 1]	0.644	0.035	2 件
	2-2: [1 1 1 1 1 1 1 0 0 0 1 1 0 0 1]	0.609		

(2) テキスト特徴量の算出

本節では、テキスト特徴量を算出する方法について説明する。まず、各点検項目について過去の点検データにおける点検結果の種類を算出し、次元数が各点検項目に現れる点検結果の種類の総和となるようにバイナリ値を割り当てた特徴量を定義する。例えば、ある点検項目について、過去の点検データに 10 種類の記録が現れている場合、“0000000000”の 10 桁のうちの 1 桁のみが対象項目の記録に対応して“1”となる。ただし、新たな点検箇所の点検記録より特徴量を算出する際、過去の点検データに現れていなかった記録すなわち 11 種類目の記録が現れた場合は全て“0”とする。以上のように、各点検項目についてバイナリ表現による特徴量を定義し、全ての点検項目の特徴量を連結したものをテキスト特徴量とする。

付録 II MAP の差による検索結果の違い

本章では、MAP の差によって生じる最終的な検索結果の違いについて説明する。ここでは、説明を容易にするため、例として検索数を 15 とした場合のシミュレーション結果を表-7 に示す。ただし、1 は “good”、0 は “no good” を表し、AP は式 (11) で定義される Average Precision である。検索例 1 では、AP の差は 0.07 であるが、検索例 1-1 では、上位 10 件に 9 件の “good” が検索されているのに対し、検索例 1-2 では、上位 10 件に 6 件の “good” が検索されており、技術者が上位 10 件を参照した際には、参考となり得るデータに 3 件の差が現れることになる。また、検索例 2 では、AP の差は 0.035 であるが、検索例 2-1 では、上位 10 件に 9 件の “good” が検索されているのに対し、検索例 2-2 では、上位 10 件に 7 件の “good” が検索されており、技術者が上位 10 件を参照した際には、参考となり得るデータに 2 件の差が現れることになる。したがって、例示した MAP の差によって検索結果に上記のような差が現れることから、4 章に示した実験において、MAP の差がわずかな場合でも検索結果に有意な差が現れるといえる。

参考文献

- 1) 国土交通省: 平成 27 年度 国土交通白書, Technical report, 2015 (online), available from <http://www.mlit.go.jp/en/statistics/white-paper-mlit-index.html> (accessed 2017-2-13)
- 2) 経済産業省, ロボット革命実現会議: ロボット新戦略, 2015 (online), available from <http://www.meti.go.jp/press/2014/01/20150123004/2150123004b.pdf> (accessed 2017-2-13)
- 3) 内閣府, 日本経済再生本部: 日本再興戦略 2016 ー第 4 次産業革命に向けてー, 2016 (online), available from http://www.kantei.go.jp/jp/singi/keizaisaisei/pdf/2016_zentaihombun.pdf (accessed 2017-2-13)
- 4) 内閣府: 戦略的イノベーション創造プログラム (SIP) インフラ維持管理・更新・マネジメント技術 研究開発計画, 2016 (online), available from http://www8.cao.go.jp/cstp/gaiyo/sip/keikaku/7_infura.pdf (accessed 2017-2-13)
- 5) Nguyen, H. N., Kam, T. Y. and Cheng, P. Y.: An automatic approach for accurate edge detection of concrete crack utilizing 2D geometric features of crack, *Journal of Signal Processing Systems*, Vol.77, No.3, pp.221–240, 2014.
- 6) Zou, Q., Cao, Y., Li, Q., Mao, Q. and Wang, S.: CrackTree: Automatic crack detection from pavement images, *Pattern Recognition Letters*, Vol.33, No.3, pp.227–238, 2012.
- 7) Fujii, H., Yamashita, A. and Asama, H.: Automated diagnosis of material condition in hammering test using a boosting algorithm, *Proceedings of 2014 IEEE Workshop on Advanced Robotics and its Social Impacts (ARSO)*, pp. 101–107, IEEE, 2014.
- 8) Murphy, R. R., Steimle, E., Hall, M., Lindemuth, M., Trejo, D., Hurlebaus, S., Medina-Cetina, Z. and Slocum, D.: Robot-assisted bridge inspection, *Journal of Intelligent & Robotic Systems*, Vol.64, No.1, pp.77–95, 2011.
- 9) Oliveira, H. and Correia, P. L.: Identifying and retrieving distress images from road pavement surveys, *Proceedings of the International Conference on Image Processing (ICIP)*, pp. 57–60, IEEE, 2008.
- 10) Takahashi, S., Ogawa, T. and Haseyama, M.: Retrieval system of similar inspection records for support of maintenance inspection in expressway and discussions of evaluation by experienced inspectors, *Proceedings of the International Conference on Civil and Building Engineering Informatics (ICCBEI) in conjunction with 2017 Conference on Computer Applications in Civil and Hydraulic Engineering (CCACHE)*, pp. 190–193, 2017.
- 11) 国土交通省 道路局 国道・防災課: 橋梁定期点検要領, 2014 (online), available from http://www.mlit.go.jp/road/ir/ir-council/pdf/yobo3_1_6.pdf (accessed 2017-8-10)
- 12) 橋梁マネジメント研究会: 道路橋マネジメントの手引き,

- (財) 海洋架橋・橋梁調査会, 2009.
- 13) Hoi, S. C., Liu, W. and Chang, S.: Semi-supervised distance metric learning for collaborative image retrieval and clustering, *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, Vol.6, No.3, pp.18, 2010.
 - 14) Kumar, A.: *Fusion, Rank-Level*, pp. 607–611, Springer US, 2009.
 - 15) 鈴木裕二: 高速道路構造物の維持管理体系—NEXCO 東日本 関東支社を例として—, *コンクリート工学*, Vol.48, No.5, pp.17–20, 2010.
 - 16) Saito, R., Takahashi, S., Ogawa, T. and Haseyama, M.: Retrieval of similar inspection records based on metric learning using experienced inspectors' evaluation, *Proceedings of the Global Conference on Consumer Electronics (GCCE)*, pp. 48–49, IEEE, 2016.
 - 17) Saito, R., Takahashi, S., Ogawa, T. and Haseyama, M.: Retrieval of similar inspection records using deep learning based image features in expressway, *Proceedings of the International Conference on Civil and Building Engineering Informatics (ICCBEI) in conjunction with 2017 Conference on Computer Applications in Civil and Hydraulic Engineering (CCACHE)*, pp. 186–189, 2017.
 - 18) Davis, J. V., Kulis, B., Jain, P., Sra, S. and Dhillon, I. S.: Information-theoretic metric learning, *Proceedings of the International Conference on Machine Learning*, pp. 209–216, ACM, 2007.
 - 19) Weinberger, K. Q. and Saul, L. K.: Distance metric learning for large margin nearest neighbor classification, *Journal of Machine Learning Research*, Vol.10, pp.207–244, 2009.
 - 20) LeCun, Y., Bottou, L., Bengio, Y. and Haffner, P.: Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, Vol.86, No.11, pp.2278–2324, 1998.
 - 21) Donahue, J., Jia, Y., Vinyals, O., Hoffman, J., Zhang, N., Tzeng, E. and Darrell, T.: Decaf: A deep convolutional activation feature for generic visual recognition, *Proceedings of the International Conference on Machine Learning*, pp. 647–655, 2014.
 - 22) Sharif Razavian, A., Azizpour, H., Sullivan, J. and Carlsson, S.: CNN features off-the-shelf: an astounding baseline for recognition, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, pp. 806–813, 2014.
 - 23) Takahashi, S., Ogawa, T. and Haseyama, M.: Feature extraction for road structure assessment based on visual saliency of distress image, *Proceedings of the International Workshop on Advanced Image Technology (IWAIT)*, pp. P.2B–6, 2016.
 - 24) Krizhevsky, A., Sutskever, I. and Hinton, G. E.: ImageNet classification with deep convolutional neural networks, *Proceedings of Advances in Neural Information Processing Systems*, pp. 1097–1105, 2012.

(2017. 10. 17 受付)

A RETRIEVAL METHOD OF SIMILAR INSPECTION RECORDS BASED ON EXPERIENCED INSPECTORS' EVALUATION

Ryota SAITO, Sho TAKAHASHI, Takahiro OGAWA and Miki HASEYAMA

This paper presents a retrieval method of similar inspection records based on experienced inspectors' evaluation in order to realize more efficient maintenance inspection for road structures such as bridges and tunnels. The proposed method introduces distance metric learning based on experienced inspectors' evaluation, and enables calculation of distances suitable for the retrieval of inspection records. Furthermore, the proposed method performs rank-level fusion that can successfully integrate retrieval results obtained from different aspects, i.e., image and text information. Consequently, inspectors can evaluate distresses referring to past similar records by our retrieval method. Therefore, since it is possible to reduce the differences of evaluation between inspectors for distress assessment, more efficient and accurate maintenance inspection becomes feasible. The effectiveness of the proposed method is verified by several experiments with actual inspection records.