

## - 20 SVM と LVQ の橋梁健全度評価への適用性

## Applicability of SVM and LVQ to evaluation of bridge integrity

近田康夫<sup>1</sup>・阿曾克司<sup>2</sup>・亀田淳子<sup>3</sup>・城戸隆良<sup>4</sup>

Yasuo CHIKATA, Katsushi ASO, Junko KAMEDA, and Takayoshi KIDO

**抄録**：既存橋梁の維持管理の重要性が高まり、定期点検結果の総合評価の自動化に関する研究が進められている。専門家による実際の健全度評価から、その判断基準を見つけ出す手法の1つにニューラルネットワークがある。本研究では、パターン認識を得意とする SVM と LVQ の比較により、橋梁の健全度評価への適用性を検討し、SVM の高い識別能力と LVQ のロバスト性を確認した。さらに、SVM と LVQ を統計解析ツールの R 上で使用し、その有用性についても考察する。

**Abstract** : The importance of maintenance of existing bridges rises, and the researches on the automation of the comprehensive evaluation of the visual inspection result have been performed. In some researches, Neural Network is used for finding out the criterion from an actual evaluation of bridge integrity by an expert. In this research, the applicability to the evaluation of bridge integrity is examined by the comparison of SVM and LVQ that is skillful in the pattern recognition. Though it is a result of dependence on the sample data, SVM shows high classification ability with complex parameter setting, and LVQ shows high robustness. In addition, the usability is considered by using SVM and LVQ on R that is statistical analysis tools.

**キーワード**：橋梁健全度評価, SVM, LVQ, R

**Keywords** : evaluation of bridge integrity, SVM, LVQ, R

## 1. はじめに

これまで日本では、経済の成長に伴い多くの橋梁が建設されてきた。特に高度経済成長期には道路施設の整備が本格化し、全橋梁数の約 40% が建設された<sup>1)</sup>。しかし、社会基盤の整備が行き届いてきた近年では、橋梁の新設は減少してきており、それは公共事業費が削減される現状からも明らかである。その一方で、高度成長期に建設されたものを始めとする既存橋梁の老朽化により、更新時期を迎える橋梁数は年々増加している。今後は、これら社会基盤施設の膨大なストックをいかに効率的かつ合理的に維持

していくかということが、益々重大な課題となってくるであろう。

最近では橋梁のアセットマネジメントの一環として、自治体などでは、橋梁を部位単位で評価し、その結果を総合化して健全度 BHI(Bridge Health Index) で表示する方法に類似のものが多く採用されている。BHI は、次式で定義される<sup>2)</sup>。

$$BHI = \sum w_i X_i \dots\dots\dots (1)$$

ここに、 $w_i$  : 部位  $i$  の重み、 $X_i$  : 部位  $i$  の健全度、BHI: 橋梁の健全度、である。

<sup>1</sup> 正会員 工博 金沢大学 教授 大学院自然科学研究科社会基盤工学専攻

(〒 920-1192 石川県金沢市角間町 金沢大学大学院自然科学研究科 Tel:076(234)4634 E-mail:chikata@t.kanazawa-u.ac.jp)

<sup>2</sup> 正会員 工修 金沢大学 大学院自然科学研究科環境科学専攻 (株式会社 日本海コンサルタント)

<sup>3</sup> 株式会社 国土開発センター

<sup>4</sup> 正会員 工博 金沢大学 技術専門員

形式上は、上式で健全度を評価することができ、専門家が介入する必要性がないようにも見える。しかし、個々の部位の健全度評価は、マニュアル整備などによってある程度訓練を受けた技術者ならば、バラツキのない評価が行えるが、総合化する際の各部位の重み(係数)は経験的に、あるいは、その時点でのデータの統計分析により与えており、必ずしも合理的に決定されているとは言えない。その結果、東京都、横浜市など、幾つもの評価方法が紹介されているが、評価部位のまとめ方や各部位への重み係数はかなり異なっている。損傷傾向の地域特性を反映すれば、おのずと集積されたデータに依存することにもなり、管理が進めば、データも蓄積され、当然重みの値の再評価が行われることになる。

最終的には、専門家の判断と、単純な積和計算で求める BHI との整合性が取れるようにしなければならない。こうした際には、係数の与え方を何らかの方法で合理的に検討する必要がある。

このような背景の下で、専門家による実際の健全度評価からその判断基準を見つけ出し、計算機を用いて評価支援を行う研究が進められており、例えば、専門家による橋梁健全度評価結果を逆解析して、部位単位の見視点検結果との関係を数量化理論を用いて部位の重みとして定式化する方法がよく知られている<sup>3)</sup>。

ラフ集合を用いた方法<sup>4)5)</sup>は、専門家が行った評価と同等の評価が下せるような簡潔なルール(極小決定アルゴリズム)を生成するものである。この方法では、全データを信頼してルールを決定するため、信頼性の低いデータや外乱が含まれていた場合のルールでは精度が低下する可能性がある。また、ルールの簡約化には GA (Genetic Algorithm : 遺伝的アルゴリズム) が用いられる場合もあるが、遺伝子列のコディング等の作業は容易ではない。

代表的なニューラルネットワークである BP(Back-Propagation) 法アルゴリズムによる、点検結果の逆解析<sup>6)</sup>では、与えるデータへの依存性が高く、パラメータのチューニングに工夫を要する。

ニューラルネットワークの一種である LVQ (Learning Vector Quantization : 学習ベクトル量子化) では、全データから選び出された信頼性の高いデータにより

決定される結合荷重で評価を行うため、外乱等による影響を受けにくい。また、いくつかのパラメータを設定するだけで自動的に評価を行ってくれるという利点がある。文献<sup>7)</sup>では、LVQ と SOM (Self-Organizing Map : 自己組織化マップ) を組み合わせて各データの評価の妥当性を検討し、データの洗練を行っている。

品質管理の分野で用いられている、正常と異常を分離する方法として、マハラノビス距離を応用する試み<sup>8)</sup>では、取扱いの簡便さに加えて、データの蓄積に伴って劣化曲線を求めることの可能性も示唆されている。

本研究では、実務への適用を検討する上で、多くの提案手法を個別に試すことの煩雑さを考え、統一した環境(ユーザーインターフェイス)における試行や比較の可能性を検討することを試みた。統一した環境としては、フリー・ソフトであるだけでなく、MS-Windows, MacOS, Linux でも利用可能なことも考慮して、統計解析ツール R<sup>9)</sup> を利用することとした。最初の試みとして、ここでは、LVQ の手法の容易さに着目すると共に、その汎化能力の高さで最近注目を集めている SVM<sup>10)</sup> (Support Vector Machine : サポートベクターマシン) に着目した。SVM と LVQ は共にパターン認識を得意とするニューラルネットワークであるが、その考え方には大きな違いがある。そこで、この2つの手法を識別能力のみならず実使用での使用性も含めて比較することで橋梁の健全度評価への適用性を検討した。

## 2. 橋梁点検データ

橋梁点検データには、I 県により作成され、1982 年から 1988 年の間に点検が行われた橋梁 208 橋分の基本的なデータと点検結果と総合評価を用いた。

コンクリート系橋梁と鋼橋系橋梁では損傷パターンが異なることが推測されるので、これらを別々に取り扱うことにし、今回はコンクリート系橋梁でかつ欠値の無い、105 橋分のデータを使用することにした。評価項目は、13 個の点検項目である。橋梁点検データの一部を表-1 に示す。健全度評価が D のものは2つしかないため、今回は除くものとする。

各点検項目の評価基準と橋梁の健全度評価の内容は以下の通りである。

表-1 橋梁点検データの一部

橋梁名	橋面舗装	地覆高欄	床版	床組工	主構	支承	伸縮継手	排水装置	洗掘変動	躯体変動	安定構造	安定材質	耐震性	健全評価
A橋	○	○	△	△	△	○	△	△	○	○	○	○	○	B
B橋	○	△	○	○	○	○	○	○	○	○	△	○	△	D
C橋	○	○	×	×	×	×	×	×	△	○	△	○	△	A
・	・	・	・	・	・	・	・	・	・	・	・	・	・	・
・	・	・	・	・	・	・	・	・	・	・	・	・	・	・
・	・	・	・	・	・	・	・	・	・	・	・	・	・	・
Z橋	○	○	○	△	○	○	○	○	○	○	○	○	○	C

●各点検項目の評価基準

- : ほとんど損傷していない. 危険性はない.
- △ : 損傷している. 危険性はやや高い.
- × : 損傷が激しい. 危険性が高い.

●橋梁の健全度評価

- A : 架け替え, あるいは, 全面的な補修を必要とする.
- B : 早急に補修を必要とする損傷がある.
- C : 軽微な補修を必要とする損傷がある.
- D : 健全であり, 目立った損傷は見られない.

解析の都合上, ○, △, ×をそれぞれ 1, 2, 3 とし, A, B, Cをそれぞれ 1, 2, 3と数値化しておく.

### 3. 使用するニューラルネットワーク

#### (1) SVM (Support Vector Machine)

SVM<sup>(10),(11)</sup> は, 1995年に Vapnik によって統計的学習理論の枠組みで提案されたニューラルネットワークの一種で, ニューロンのモデルとして最も単純な線形しきい素子を用いて 2クラスのパターン識別器を構成する手法である.

予め訓練されたサンプル集合から, 「マージン最大化」という基準で線形しきい素子のパラメータを学習する. 線形しきい素子はニューロンを単純化したモデルで, 入力特徴ベクトル  $x$  に対し, 式 (2) により, 出力値 ( $w, b$ ) を計算する.

$$y = \text{sign}(w^T \cdot x + b) \dots \dots \dots (2)$$

ここで,  $w$  はシナプス荷重に対応するパラメータであり,  $b$  は閾値である. このモデルは, 入力ベクトルと結合荷重の内積が閾値を超えれば +1 を出力し, 超えなければ -1 を出力する. 幾何学的には, 分離超平面により入力特徴空間を 2 つに分けることに相当する.




図-1 線形 SVM の概念図

#### a) 線形 SVM

今, 2つのクラスを  $C_1, C_2$  とし, 各クラスのラベルを +1 と -1 に数値化しておくとする. また, 訓練サンプル集合として,  $l$  個の特徴ベクトル  $x_1, \dots, x_l$  と, それぞれのサンプルに対する正解のクラスラベル  $y_1, \dots, y_l$  が与えられており, この訓練サンプル集合は線形分離可能であるとする.

訓練サンプル集合が線形分離可能であるとしても, 一般には, 訓練サンプル集合を誤りなく分けるパラメータは一意には決まらない. SVM では, マージン (最も近い訓練サンプルとの余裕) が最大となるようにパラメータを設定し, 識別平面を求める. 訓練サンプル集合が線形分離可能であるとき, 式 (3) を満たすようなパラメータが存在する.

$$y_i(w^T \cdot x_i + b) \geq 1 \quad (i = 1, \dots, l) \dots \dots \dots (3)$$

これは,  $w^T \cdot x + b = +1$  と  $w^T \cdot x + b = -1$  の 2枚の超平面で訓練サンプルが完全に分離されており, 2枚の超平面の間にはサンプルが 1 つも存在しないことを示している. このとき, 識別平面とこれら 2枚の超平面との距離 (マージンの大きさ) は,  $1/\|w\|$  となる.

従って, マージンを最大とするパラメータ  $w, b$  を求める問題は, 式 (3) の条件の下で, 式 (4) で表される目的関数を最小とするパラメータを求める問題と等価になる.

$$L(w) = \frac{1}{2} \|w\|^2 \rightarrow \min \dots \dots \dots (4)$$

ここで, Lagrange 乗数  $\alpha_i (\geq 0, i = 1, \dots, l)$  を導入すると,

$$\sum_{i=1}^l \alpha_i y_i = 0 \quad (0 \leq \alpha_i, i = 1, \dots, l) \dots \dots \dots (5)$$




図-2 ソフトマージン




図-3 カーネルトリック

の制約条件の下で、目的関数

$$L_D(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \cdot \mathbf{x}_j \rightarrow \max \dots (6)$$

の双対問題に帰着することができる。その解  $\alpha_i^*$ のうち、 $\alpha_i^* > 0$  となる訓練サンプル  $\mathbf{x}_i$  は、2つの超平面  $\mathbf{w}^T \cdot \mathbf{x} + b = +1$ ,  $\mathbf{w}^T \cdot \mathbf{x} + b = -1$  のどちらかの上にある。この解(サポートベクターと呼ぶ)のみを用いて線形しきい素子のパラメータを決定する。最適なパラメータ  $\mathbf{w}^*$ ,  $b^*$  は、

$$\mathbf{w}^* = \sum_{i \in S_V} \alpha_i^* y_i \mathbf{x}_i \dots (7)$$

$$b^* = y_s - \mathbf{w}^{*T} \cdot \mathbf{x}_s \dots (8)$$

により求まる。  $S_V$  はサポートベクターに対する添え字の集合、  $\mathbf{x}_s (s \in S_V)$  は任意のサポートベクターである。

実問題で線形分離可能な場合は稀であるので、線形分離不可能な場合にも対応できるようにするために「ソフトマージン」という方法を用いる。これは、多少の識別誤りは許すように制約を緩めるものである。

スラッグ変数  $\xi_i (\geq 0, i = 1, \dots, l)$  を制約条件に導入することによって、制約を緩めることを考える。また、 $\xi_i$  はできるだけ小さいこと望ましい。これらの条件から最適な識別面を求める問題は、制約条件

$$y_i(\mathbf{w}^T \cdot \mathbf{x}_i + b) \geq 1 - \xi_i \quad (\xi_i \geq 0, i = 1, \dots, l) \dots (9)$$

の下で、目的関数

$$L(\mathbf{w}, \xi) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^l \xi_i \rightarrow \min \dots (10)$$

のパラメータを求める問題に帰着される。ここで、パラメータ  $C$  は、式(10)の第1項と第2項のバランスを決める正の定数である。線形分離可能な場合と同様に、Lagrange 乗数  $\alpha_i$  及び  $\beta_i$  を導入すると、式(10)は、

$$L(\mathbf{w}, b, \alpha, \beta) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^l \xi_i - \sum_{i=1}^l \alpha_i \{y_i(\mathbf{w}^T \cdot \mathbf{x}_i - b) - (1 - \xi_i)\} - \sum_{i=1}^l \beta_i \xi_i \dots (11)$$

と表すことができ、

$$\sum_{i=1}^l \alpha_i y_i = 0 \quad (0 \leq \alpha_i \leq C, i = 1, \dots, l) \dots (12)$$

の制約条件の下で、式(6)を求める問題に帰着することができる。

### b) 非線形 SVM

本質的に非線形な問題に対応するための方法として、「カーネルトリック」がある。これは、写像

$$\Phi: R^n \mapsto \mathcal{H} \dots (13)$$

を用いて、特徴ベクトルをより高次元の空間  $\mathcal{H}$  に写して、 $\mathcal{H}$  上で線形分離を行うもので、実質的に元の空間で非線形分離を行っていることになる<sup>12)</sup> (図-3)。

一般に、非線形写像によって変換した特徴空間の次元は非常に大きくなる傾向があるが、SVMでは、目的関数や識別関数が入力パターンの内積のみに依存した形になっており、内積が計算できれば最適な識別関数を構成することが可能である<sup>10)</sup>。もし、内積  $\phi(\mathbf{x}_1) \cdot \phi(\mathbf{x}_2)$  が、 $\mathbf{x}_1, \mathbf{x}_2$  のみから計算できるなら、計算が非常に簡略化できる。すなわち、

$$\phi(\mathbf{x}_1)^T \cdot \phi(\mathbf{x}_2) = K(\mathbf{x}_1, \mathbf{x}_2) \dots (14)$$

となるようなカーネル関数  $K(\mathbf{x}_1, \mathbf{x}_2)$  から最適な非線形写像を構成できる。カーネル関数を用いると、式 (6) は、

$$\begin{aligned}
 L_D(\alpha) &= \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j \phi(\mathbf{x}_i)^T \cdot \phi(\mathbf{x}_j) \\
 &= \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j) \\
 &\dots\dots\dots (15)
 \end{aligned}$$

のように内積をカーネルで置き換えた形に書ける。

本研究では、この非線形 SVM を組み合わせて、多クラス分類にも対応できるように拡張されたものを用いる。また、カーネル関数にはガウスクーネルを使用する。

**(2) LVQ (Learning Vector Quantization)**

LVQ は、Kohonen により 1986 年に発表された、パターン認識を目的とする 2 階層のネットワークである。教師あり競合学習則に基づいて結合荷重の更新を行い、バイズ識別境界の形成を目指している。文献<sup>13)</sup>では、結合荷重のことをコードブックベクトルとしているので、この表現に合わせることにする。

**a) コードブックベクトルの初期化**

コードブックベクトルは、常にそれぞれのクラス領域に留まるべきである<sup>13)</sup>ので、信頼できるデータの中から選らばなければならない。今回使用する統計解析ツール **R** におけるパッケージ **class** では、Leave-one-out cross validation 法に k-NN(k-Nearest Neighbour : k 最近傍) 識別則を採り入れた方法を利用して初期化を行っている。その方法について簡単に説明する。

今、訓練サンプル集合として、クラス  $C_i$  から  $N_i$  個の特徴ベクトルが得られたとする。また、全学習データ数は、 $N = \sum_{i=1}^l N_i$  とする。点  $\mathbf{x}$  を中心とする超球を考え、その中にちょうど  $k$  個の学習データを含むまで超球の半径を大きくしたときの超球の体積を  $V(\mathbf{x})$  とする。また、その超球内には、クラス  $C_i$  のデータが  $k_i$  個含まれているとする。

このとき、クラス  $C_i$  の条件付き確率密度関数を  $\tilde{p}(\mathbf{x}|C_i)$ 、 $\mathbf{x}$  の確率密度関数を  $\tilde{p}(\mathbf{x})$ 、事前確率を  $\tilde{P}(C_i)$




図-4 LVQ の構造

とすると、事後確率

$$\tilde{P}(C_i|\mathbf{x}) = \frac{\tilde{P}(C_i)\tilde{p}(\mathbf{x}|C_i)}{\tilde{p}(\mathbf{x})} = \frac{k_i}{k} \dots\dots\dots (16)$$

が最大となるクラスに、 $\mathbf{x}$  を識別する方法が k-NN 識別則である<sup>14)</sup>。

一方、Leave-one-out cross validation 法は、 $N$  個のサンプルのうち 1 個を除き、残りの  $N-1$  個でモデルを作製し、予め除いた 1 個が正しく識別されるかどうかの検定を  $N$  回繰り返すものである。この方法を前述の k-NN 識別則を用いて行い、正しく識別されたもの(元のクラスと一致したもの)を信頼できるデータとする。その中から、サンプル全体のクラス毎の数の比を崩さないように任意のサンプルを選ぶことで、コードブックベクトルの初期化が行われる。

**b) 学習アルゴリズム**

**Step 1 ネットワークの初期化**

入力層と出力層間のコードブックベクトルを初期化する。

**Step 2 入力ベクトルの入力**

入力層に入力ベクトル  $\mathbf{x} = (x_1, x_2, \dots, x_l)$  を入力する。

**Step 3 コードブックベクトルと入力ベクトルの距離**

入力ベクトルに対する出力層のノード  $i$  のコードブックベクトル  $\mathbf{w}_i = (w_{i1}, w_{i2}, \dots, w_{il})$  と入力ベクトルとの距離

$$\|\mathbf{x} - \mathbf{w}_i\| = \sqrt{\sum_{j=1}^l (x_j - w_{ij})^2} \dots\dots\dots (17)$$

を計算する。

**Step 4 距離  $\|\mathbf{x} - \mathbf{w}_i\|$  が最小となるノードの選択**

この競合によって選ばれたノードを勝者ノードとし、添え字  $c$  によって表す。

$$\|\mathbf{x} - \mathbf{w}_c\| = \min_i \{\|\mathbf{x} - \mathbf{w}_i\|\} \dots\dots\dots (18)$$

## Step 5 コードブックベクトルの更新

勝者ノードが正しく識別された場合は、そのノードのコードブックベクトルを入力ベクトルに近付くように修正する。逆に、誤って識別された場合は、遠くなるように修正する。

- 正しく識別された場合

$$w_c(t+1) = w_c(t) + \alpha(t)[x(t) - w_c(t)] \quad (19)$$

- 誤って識別された場合

$$w_c(t+1) = w_c(t) - \alpha(t)[x(t) - w_c(t)] \quad (20)$$

$$(w_i(t+1) = w_i(t), i \neq c)$$

ここで、 $\alpha(t)$  ( $0 < \alpha(t) < 1$ ) は学習率であり、通常、時間と共に減少するように作られる<sup>13)</sup>。

## Step 6 2に戻る。

コードブックベクトルには信頼性の高いデータのみが選ばれるが、学習においては、信頼性が低いと判断されたデータも使われる。今回は、パターン認識器として使用するという目的から、信頼性の低いデータが学習されたモデルとなってしまうのを防ぐため、初期化されたコードブックベクトルを用いて識別を行うものとする。

## 4. 解析

解析は、ベンチマークデータを用いて性能を確認後、橋梁点検データに対してパラメータの最適化を行った。橋梁点検データは学習用と検証用に分け、認識精度について検証用データの場合は汎化性、学習用データの場合は再現性と定義した。

データ数の内訳を表-2に示す。ここでは、検証用データを各クラスで全データの1/3を目安に設定した。予備計算ではこれ以上検証用データ数を増やすと、学習用のデータが不足して認識精度が下がる。また、学習用と検証用のデータの入れ替えは結果に顕著な影響は出なかった。

### (1) ベンチマークデータの分類

R環境上でのSVM・LVQの実用性の確認と、データの特徴の違いによる解析結果の変化の考察を行うために、ベンチマークデータの解析を行った。

ベンチマークデータには、Fisherのアヤメ(Iris)のデータ<sup>15)</sup>を使用した。これは、萼片の長さ、花弁の長さ、幅の4つの特徴を計測した、各種類50個

表-2 データ数の内訳

クラス	学習用	検証用	合計
1	8	3	11
2	49	17	66
3	21	7	28
合計	78	27	105

表-3 ベンチマークデータの解析結果

	汎化性	再現性
SVM	0.973	1.000
LVQ	0.932	0.960

ずつ3種類(3クラス)のアヤメの花のデータである。その3種類は、setosa, versicolor, virginicaであるが、それぞれ1, 2, 3と数値化しておく。また解析では、クラス毎に半数ずつに分け、学習用(75個)、検証用(75個)として用いる。クラス1とクラス2・3は完全に線形分離可能、クラス2とクラス3は線形分離不可能である。

表-3にベンチマークデータの解析結果をまとめたが、SVM・LVQ共に高い精度が得られていることが分かり、SVMおよびLVQの識別機としての実用性を確認することができた。再現性、汎化性ともに認識率100%を1.00としている。


### (2) パラメータの最適化

より良い解析のために、SVM・LVQそれぞれについてパラメータの最適化を行う。


#### a) SVMでの最適化

SVMにより複雑なデータを解析する際、分離超平面が複雑に入り組んだ形状になり、特にクラス毎のデータ数に偏りがある場合には、最もデータ数の多いクラスに分類されやすくなる傾向がある。

図-5は、SVMによる橋梁点検データの検証結果である。図では横に検証用データを並べ、それぞれがどのクラスとして判別されたかを縦軸に示している。□と●が重なっているデータが、専門家による判断を再現できていることになる。パラメータ設定がうまくいった図-5(a)に比べて適切なパラメータを設定していない図-5(b)では最もデータ数の多いクラス2にほとんどのデータが分類されてしまっていることが分かる。橋梁点検データを用いた場合、このような状態になるようなパラメータがほとんどであった



(a) 最適なパラメータによる検証結果



(b) 最適でないパラメータによる検証結果




図-5 SVM での検証結果の例




図-6 LVQ での解析結果の例

ため、最適化の際には注意が必要である。

この対策として、今回は「検証用データの1つのクラスに含まれるデータの検証結果のうち半数以上が専門家による評価と一致していなければならない」という条件を設け、条件を満たすものの中で汎化性が最も高くなるものを最適なパラメータとした。

### b) LVQ での最適化

図-6 は、LVQ により橋梁点検データの解析を 100 回行ったときの結果を横軸に汎化性 (検証用データの認識精度) をとったヒストグラムである。

LVQ では、信頼性の高いデータの中から任意にコードブックベクトルを選択するので、同じパラメータを設定しても図-6 のように結果がばらつく。そこで、今回は同じパラメータで解析を 100 回行ったときの平均値と標準偏差を求め、平均値をそのパラメータでの認識精度とした。また、標準偏差が小さいもの、すなわち、結果のばらつきが小さいものの方がモデ

ルの信頼性が高いと判断することにし、この平均値と標準偏差を比較して、パラメータの最適化を行った。

### (3) 解析結果の考察

#### a) パラメータの最適化

(2) で述べた方法で、パラメータの最適化を行ったところ、LVQ では、橋梁点検データを用いた解析では、信頼性の高いデータをできるだけ多くコードブックベクトルとして用いた方が、モデルの信頼性・汎化性が共に高い識別器になると推察される。

一方、SVM での解析ではそのような傾向が現れにくく、最適なパラメータの設定には膨大な試行錯誤が必要であった。よって、パラメータの最適化のし易さという点では、LVQ の方が優れていると言える。

#### b) データの特徴の影響

解析結果を図-7 に示す。図では、ベンチマークデータの結果は表-3 と同一であり、橋梁点検データは表-2 のデータの解析結果である。再現性と汎化性はそれぞれ、学習用データの認識精度および検証用データの認識精度を意味する。

まず汎化性では、SVM・LVQ 共に橋梁点検データを用いた場合に精度がかなり低下していることが分かる。橋梁点検データの主な特徴として次の3点があり、これらが汎化性を下げる原因になっていると考えられる。

**特徴 1** : クラス 1 のデータが不足している。

**特徴 2** : クラス毎のデータ数に偏りがある。

**特徴 3** : 評価する項目 (点検項目) 数が多い。

次に再現性では、LVQ での精度が橋梁点検データを用いた場合に低下していることが分かる。これは、LVQ がパラメトリックな手法、つまりクラス毎のデータに何らかの分布形を具体的に仮定する手法であるため、特にデータ数の少ないクラス 1・3 において、仮定した分布に実際の分布との誤差が多く含まれてしまったことが原因としてあげられる。

#### c) データの重複の影響

多くの橋梁の点検結果を集積した橋梁点検データには全く同じデータが重複して存在する可能性があることから、その影響を検討してみた。

表-2 の橋梁点検データを対象とした解析結果を図-8 に示す。表-2 のデータにおける重複データは、学習用データにそれぞれ、クラス 1 では 0 組、クラス 2 で

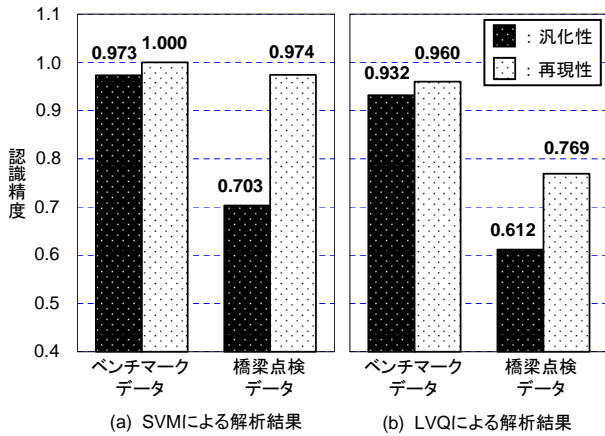


図-7 データの特徴の影響

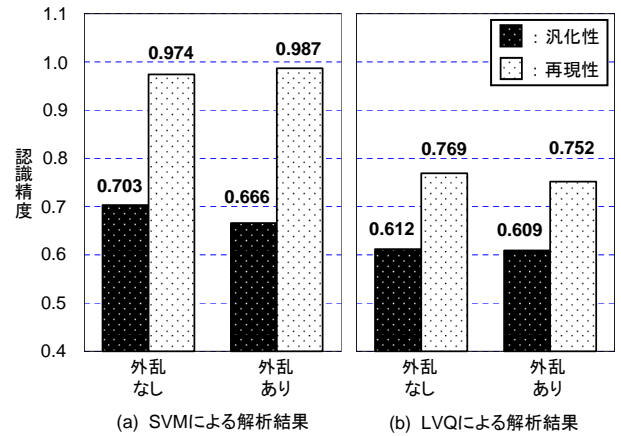


図-9 外乱の影響




図-8 データの重複の影響

は4組、クラス3では3組が存在する。検証用データには重複はない。

図-8 から、SVM・LVQ 共に重複データを除くことによる汎化性・再現性の変化はほとんど見られないことが分かる。橋梁点検データは項目の数が多く、データの重複を除く作業は非常に手間である。よって、重複データを除かないで解析を行っても結果に影響が出にくいということは、その手間を省け、健全度評価に要する時間を短縮できるという利点となる。

#### d) 外乱の影響

橋梁点検データには、データの重複も生じるが場合によっては矛盾(同一の点検結果で健全度評価のみが異なる)や、点検結果と健全度評価が不自然なものも含まれることもある。事前に点検データをチェックするとかなりの時間と労力を要することになる。そこで、このような不自然なデータを外乱として追加したときの解析結果を検討してみた。なお、外乱として表-4 に示す2つのデータを用いた。

表-4 外乱

外乱	橋面舗装	地覆高欄	床版	床組工	主構	支承	伸縮継手	排水装置	洗掘変動	躯体変動	安定構造	安定材質	耐震性	健全度評価
A*	1	1	1	1	1	1	1	1	1	1	1	1	1	1
B**	3	3	3	3	3	3	3	3	3	3	3	3	3	3

\*点検結果は非常に良いが、健全度評価が悪いデータ。

\*\*点検結果は非常に悪いが、健全度評価が良いデータ。

解析結果を図-9 に示す。

図-9 から、SVM による解析結果では外乱を追加した場合に汎化性が若干低くなっていることが分かる。これは、データの質に関わらず入力した全てのデータに影響を受けて分離超平面が決定されるためであると考えられる。

一方、LVQ による解析結果では、汎化性・再現性共にほとんど変化していないことが分かる。これは、コードブックベクトルの初期化の際に、外乱のデータの信頼性が低いと判断され、コードブックベクトルに選ばれないためである。

これらの結果から、LVQ の方が外乱の影響を受けにくく、ロバスト性が高いことが分かる。

## 5. おわりに

### (1) SVM, LVQ の橋梁評価への適用性

本研究では、SVM と LVQ を比較することにより、これらのニューラルネットワークの橋梁健全度評価への適用性の検討を試みた。

以下に、使用したデータに依存する結果ではあるが、解析結果から得られた特徴を簡単にまとめておく。

- 認識精度に関しては、全体的に SVM が LVQ を

上回っている。

- SVM では、パラメータの最適化が LVQ に比べて困難であるが、ノンパラメトリックな手法であることから、データの分布に対するロバスト性が高い。
- LVQ では、パラメータの最適化は比較的容易であるものの、結果がばらつくという問題点がある。しかし、信頼性の高いデータのみを用いるため、外乱に対するロバスト性が高い。

上記の特徴から、これら 2 つの手法の実使用に際しては一長一短があることが分かる。またパターン識別器として使用するという目的から、汎化性が高いことが望ましいが、今回の解析結果からは、明確にどちらが優れていると言える成果が得られなかった。

しかし橋梁点検データでは、その性質上、健全度評価が A のものや今回使用できなかった D のもののデータ数が不足することが多い。その点では、ノンパラメトリックな手法、つまり、データの分布に対するロバスト性が高いという特徴を持つ SVM の方が、橋梁健全度評価に適していると考えられる。

さらに、今回 SVM, LVQ を統計解析ツールの R 上で用いたことで、以下の利点がある。

- 多くのパラメータによる繰り返し計算を、ループを用いて短時間で行うことができる。
- データを行列として扱っており、重複データの削除・外乱の追加等の作業が容易に行える。
- プログラムを組むことなく、SVM, LVQ のみならず多くの統計解析手法が同じ GUI で誰にでも利用できる。特にこの点は、様々な技法の報告がある中で、個別のプログラムを入手して試すのではなく、一つの環境 (R 上) で比較検討が実施できる点でも特筆に値する。

## (2) SVM, LVQ の使用性

SVM と LVQ の学習の方法を比較すると、学習用データの信頼性の考慮に関して大きな違いがあると言える。

LVQ が信頼性の高いデータをコードブックベクトルとするのに対して、SVM ではどのデータも同様に学習してサポートベクターを決定する。このため、パラメータを巧く設定したとしても、信頼性の低いデータも学習してしまう可能性を常に疑わなければなら

ない。

この点を考慮すれば、SVM は単独での使用には適さず、例えば、文献<sup>7)</sup>での SOM/LVQ を援用する方法のように、学習用データの信頼性を高めてから使用するという工夫が必要である。

## (3) 今後の課題

本研究における今後の課題として、次の 2 点があげられる。

- 適切な特徴選択
- 交差検定法の導入

今回、13 の点検項目を全て用いて解析を行った。しかし、専門家が健全度評価を行う際には、全てを考慮していない可能性もある。ニューラルネットワークにおいて多くの項目を考慮するという事は、データの特徴空間の次元が高くなるということに等しく、複雑な解析を要する。このことは認識精度を下げる原因として十分に考えられるので、適切な特徴選択を行い、使用する項目を最小限に絞る必要がある。

また、使用した橋梁点検データはデータ数が少なく、学習用と検証用に分ける際に特徴の偏りが予想される。このような場合に有効な手段として、交差検定法がある。この方法の導入により、少ないデータの有効な活用、モデルの認識精度の信頼性の向上が期待される。

解析対象のデータは、絶対量の少なさは点検サイクルがある程度進めば改善すると考えられるが、事象空間のすべてのサンプルが揃うことはなく、量的にも偏る傾向が強い点は依然として解決しないであろう。実データとして不足する部分を、実際に生じそうな部位と損傷レベルの組み合わせに対して補って解析することも検討に値するが、組合せの選択などマン・パワーに依存することになる。なぜなら、損傷の因果関係や地域特性など考慮すべき点が多く、すべての部位と損傷レベルの組合せを機械的に検討しても工学的な意味をなさないと考えられるからである。

## 附録 統計解析ツール R について

R は統計計算とグラフィックスのための言語及び環境で、完全にフリーであり、現在も開発され続けているオープンソース方式のデータ解析・処理専用ソフトである<sup>9)</sup>。

S 言語に基づくソフトウェアと関数などについての操作が似ており、R は S を別個に実装したものと考えられる。「環境」という言葉が使われるのは、R が完全に計画され一貫性を持ったシステムであるという特徴を示すためである。

R は多様な統計手法とグラフィックスを提供し、広範な拡張が可能である。パッケージと呼ばれる追加のライブラリ (関数群) の充実により商用ソフトと遜色ない機能が利用できる。また、ユーザーは新しい関数を定義して新しい機能を追加できるようになっている。

R は Free Software Foundation の GNU General Public License の条項の下で、ソースコードの形で入手できる。

本研究では、SVM にはパッケージ kernlab(カーネル手法ラボ) の中の関数 ksvm を、LVQ にはパッケージ class(各種の分類用関数) の中の関数 lvqinit を使用した。

パラメータの最適化を行う際に、パラメータを変更しつつ繰り返し処理をさせるためのスクリプトを記述して処理の効率化を図った。SVM の場合を以下に示す。

```
### パッケージ「kernlab」の呼び出し ###
library(kernlab)
### 基本の関数 ###
SVM_optimize <- function() {
  on.exit(rm(list=ls(all=TRUE)))
  model <- ksvm(class~,data=train,
    type="C-svc",C=a,kernel=rbfdot(sigma=b))
  nERR <- error(model)
  pred <- predict(model,test)
  correct <- (pred == cl_test)
  num <- 0
  for(i in 1:m) {num <- num + correct[i]}
  result <- c(a,b,nERR,pred,num)
  return(result)
}
### 繰り返し計算 ###
result1 <- c(0,0,0,rep(1,3),rep(2,17),rep(3,7),0)
for(j in 0:2) {
  a <- 10^j
  for(k in 1:3) {
    b <- 0.001*k
    result2 <- SVM_optimize()
    result1 <- rbind(result1,result2)
  }
}
```

## 参考文献

1) 中谷昌一:国土交通省における道路アセットマネジメントの考え方, 土木学会誌, Vol.89 no.8, p.24, 2004.8.

2) 例えば, 横浜市道路局が以下の URL でアセットマネジメントの取り組みに関して公開している中で BHI を定義している。  
<http://www.city.yokohama.jp/me/douro/kyouryou/assestomanegimento/assetomanegimento.html>

3) 森弘, 大島俊之, 三上修一, 天野政一, 井上実: コンピュータグラフィックスと数量化理論を応用した橋梁の維持点検評価法, 土木学会論文集, No.501/I-29, pp.113-121, 1994.10.

4) 古田均, 広兼道幸, 田中成典, 三雲是宏: 橋梁の損傷要因診断事例からのラフ集合を用いたルール型知識の獲得方法, 構造工学論文集, Vol.44A, pp.521-528, 1998.3.

5) 広兼道幸, 古田均, 原川浩一, 政森理恵子: あいまいさを考慮した知識獲得手法, 第7回システム最適化に関するシンポジウム 講演論文集, pp.173-178, 2001.12.

6) 近田康夫, 辻岡信也, 城戸隆良: NN による橋梁損傷度判定の精度向上に関する研究, 鋼構造工学年次論文報告集, Vol.6, pp.451-456, 1998.11.

7) 近田康夫, 廣瀬智士, 城戸隆良: SOM/LVQ を援用した橋梁点検データの見直し, 構造工学論文集, Vol.44A, pp.503-510, 1998.3.

8) 阿曾 克司, 近田 康夫: 拡張したマハラノビス距離の橋梁総合健全度評価への適用, 構造工学論文集, Vol.52A, pp.151-162, 2006.3.

9) 舟尾暢男: The R Tips データ解析環境 R の基本技・グラフィックス活用集, 九天社, 2005.3.

10) Nello Cristianini・John Shawe-Taylor 著, 大北剛 訳: サポートベクターマシン入門, pp.129-194, 共立出版, 2007.

11) 杉本博之, 阿部淳一, 古川浩平: 近似法支援のための SVM に関する基礎的研究, 構造工学論文集, Vol.53A, 4-5, 2007.3. (CD-ROM)

12) 山口貴大: サポートベクターマシンによる倒産予測, 京都大学学士学位論文, 2001.1.

13) T.Kohonen 著, 徳高・大藪・堀尾・藤村・大北 監修: 自己組織化マップ 改訂版, シュプリンガー・フェアラーク東京, 2005.6.

14) 栗田多喜夫: パターン認識とニューラルネットワーク, パターン認識・画像処理手法の解説, 2001.2.

15) R.A. Fisher: The use of multiple measurements in taxonomic problems, Annals of Eugenics, Vol.7-II, pp.179-188, 1936.

(2007.5.16受付)