

腕金錆画像に基づく腕金再利用判定精度の向上

Development of crossarm reuse judgement system based on rust images using support vector machine

山名 美智子*¹ 村田 博士*¹ 小野田 崇*¹ 大橋 徹*² 加藤 誠二*²
 Michiko Yamana Hiroshi Murata Takashi Onoda Tohru Ohashi Seiji Kato

*¹(財) 電力中央研究所 システム技術研究所

Central Research Institute of Electric Power Industry, System Engineering Research Laboratory

*²中部電力(株)本店 販売本部 配電部 技術グループ

Chubu Electronic Power Co., Inc.

Japanese electric power companies currently utilize existing equipments completely and maintain facilities effectively. Human experts presently judge various hardwares whether they are be reusable or not to utilize equipments completely. Especially, this paper considers about crossarm reuse judgement. This judgement is based on rust, which attaches on crossarms, by human experts. However, this judgement depends on human expertise and it is difficult to keep constant judgement accuracy. Electric power companies want to take constant and good judgement accuracy. Therefore, we develop a crossarm reuse judgement system based on rust images using support vector machine. The system consists of commercial microscope and standard note PC to keep the cost. And we estimate the judgement accuracy of our proposed system without the special image processing such as extracting features. The results show that our proposed system can support human judgement hard work.

1. はじめに

電力会社では、近年、電力市場の自由化が進展する中、あらゆる面における徹底したコストダウンを行うなど、さらなる効率化が望まれている。

中部電力(株)配電部では、機材の有効活用に関する取り組みの一環として、撤去機材の再利用拡大を進めている。このような取り組みのひとつとして、配電線の架線に使用する腕金の再利用によるコスト削減を試みている。現在まで、腕金に発生した錆の色と錆の進行程度との分析結果に基づき、「再利用」、「廃棄」の各腕金錆の写真による判定見本を作成して、この判定見本に基づいて視覚、触覚などの感覚により腕金の「再利用」、「廃棄」判定を行ってきた。今後は、「めっき後再利用」判定も導入予定である。しかしながら、拠点ごとに集められた撤去腕金は、各拠点で異なる人間によって、判定見本に基づき「再利用」、「めっき後再利用」、「廃棄」判定されるため、光の当たり具合、判定する人間の色に対するイメージ等に左右され、再利用判定にばらつきが生じる。

一方、最近の情報技術の発展により、デジタル画像データの撮影は、精度良く、安価に、簡単に行えるようになり、大量の設備・機器画像データを収集できる環境を構築しやすくなりつつある。つまり、精度の良い画一的な画像データの収集が簡単にならなくなってきている。また、パターン識別の研究では、識別の難しいパターンの識別のみに注力するサポートベクターマシン(以下 SVM とする)と呼ばれる高精度な学習識別手法が提案され、人間に勝るとも劣らない識別が可能となっている。つまり、精度の良い画一的なパターン識別が計算機にも可能となっている。これが利用できれば、計算機による腕金再利用判定支援が可能となるとともに、各拠点において画一的に判定できるようになる。

そこで、本研究では、市販されている安価な機器構成で腕金

錆画像を収集し、その画像に特別な画像処理を加えることなく、SVMによりどの程度の再利用判定精度が達成できるかを検証することを目的とした。本論文では、計算機による腕金錆画像に基づく再利用可否判定精度を評価するためのテストデータの作成方法、および、そのデータに基づく腕金画像による再利用判定精度の検討結果について報告する。

2. 腕金錆画像データ

中部電力(株)配電部で、錆の発生した腕金の現物をマイクロスコープで約 600 枚撮影し、その約 600 枚の画像に「再利用」のクラス、「めっき後再利用」のクラス、「廃棄」のクラスと判定付けして評価用テストデータを作成した(各クラスごとに約 200 枚ずつ撮影)。

今回用いた画像データは、腕金の一部を可搬型デジタルマイクロスコープ(スカラ社製 USB Microscope M2)により撮影した 640×480 画素のカラー静止画像である。なお、マイクロスコープのレンズ倍率は、市販で容易に入手できる倍率の中から、光源付きで最も低倍率である 30 倍、50 倍の 2 種類を用いた。

それぞれの画像に対応する実際の腕金などの品位クラス(「再利用」、「めっき後再利用」、「廃棄」の各クラス)になっているかの判定は、定量的手法で詳細に分析した結果に基づく判定基準により行い、対応する錆画像データに「再利用」、「めっき後再利用」、「廃棄」のラベルを付けるという手順で行った。このラベルが評価テストにおける正解となる。

3. 錆画像に基づく再利用判定方法

3.1 サポートベクターマシン

まず腕金錆画像に基づく再利用判定方法に用いる、SVM について紹介する [1, 2]。1995 年に Vapnik らによって確立された SVM は、現在知られているパターン識別手法の中で最も優秀なパターン識別能力を有する方法の一つであり、文字認識や画像認識において高い判別性能を示している [3, 4, 5]。SVM は、事前に与えられた例題(サンプルデータ $\mathbf{x}_i \in \mathbf{R}^d$ とその

連絡先: 山名美智子, (財) 電力中央研究所 システム技術研究所, 〒 201-8511 東京都狛江市岩戸北 2-11-1, TEL:03-3480-2111, FAX:03-5497-0318, E-mail:yamana@criepi.denken.or.jp

クラス $y_i \in \{-1, 1\}$, ($i = 1, \dots, n$) を学習し、以下の形式で表される識別関数を求める。

$$f(\mathbf{x}) = \text{sgn}(\mathbf{w} \cdot \mathbf{x} + b) \quad (1)$$

ここで、 $\mathbf{w} \in \mathbf{R}^d$, $b \in \mathbf{R}$ で、 \cdot は内積を表す。また $\text{sgn}(\)$ は符号関数である。 $\mathbf{w} \cdot \mathbf{x} + b = 0$ が識別面となり、すべてのサンプルデータに対して正しいラベルが出力されるような \mathbf{w} と b の組み合わせが存在するとき、その例題集合は線形分離可能であるという。しかし、常にそのような \mathbf{w}, b の組み合わせが存在することは保証されない。また線形分離可能であっても、線形分離を実現する超平面は一つには決まらない。SVM では、識別面から各クラスの端までの距離をマージンと呼び、マージンを最大にするように識別面を決め、誤判定が最も生じにくくなるようにしている。

線形分離可能であれば全てのサンプルデータが、次の制約式を満たすようにできる。

$$y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1, \quad (i = 1, \dots, n) \quad (2)$$

このときマージンの大きさは $1/\|\mathbf{w}\|$ と表されるので、これを最大にする問題は、制約式 (2) の下で、目的関数: $\|\mathbf{w}\|^2/2$ の最小値を求める問題と等価になる。

一般に、特徴空間の次元数 d が、例題サンプルの数 n よりも大きければ、例題サンプルは超平面によって線形分離可能である。線形分離可能でない場合には、二つの方法がある。一つは、多少の識別の誤りは許すように制約を緩めるという方法で、ソフトマージン法と呼ばれる。誤分類を許容する度合いを表す変数 $\xi_i \geq 0$ ($i = 1, \dots, n$) と、誤分類とマージン最大化の関係を調節するパラメータ C を導入し、最小化問題は以下のように変更される。パラメータ C の設定は実験的に決める。

$$\min \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i \quad (3)$$

$$\text{subject to } y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1 - \xi_i, (i = 1, \dots, n) \quad (4)$$

制約条件付きの最適化問題は、ラグランジュの乗数法を用いると簡単になる。ラグランジュ乗数 $\alpha(\geq 0)$ を導入すると、最適解における条件が $\mathbf{w} = \sum_{i=1}^n \alpha_i y_i \mathbf{x}_i$ と求められ、以下の双対問題へ帰着される。

$$\max \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j \mathbf{x}_i \cdot \mathbf{x}_j \quad (5)$$

$$\text{subject to } 0 \leq \alpha_i \leq C, (i = 1, \dots, n), \sum_{i=1}^n \alpha_i y_i = 0 \quad (6)$$

サンプルが線形分離不可能な場合に行う、もう一つの方法は、 \mathbf{x} を非線形変換 $\phi(\mathbf{x})$ によって、より高次元の空間に写像するという方法である。すると線形分離可能な状態となり、最適な分離超平面を求めることができる。普通は次元の増加とともに計算量が増え計算が困難となるが、SVM ではカーネル関数 $K(\mathbf{x}, \mathbf{x}')$ を使って高次元空間での複雑な計算を避ける方法が用いられる。代表的な例として以下のような RBF カーネル (Gaussian radial basis function)(7) や p 次の多項式カーネル (8) を用いる。

$$K(\mathbf{x}, \mathbf{x}') = \exp(-\gamma \|\mathbf{x} - \mathbf{x}'\|^2) \quad (7)$$

$$K(\mathbf{x}, \mathbf{x}') = (\mathbf{x} \cdot \mathbf{x}' + 1)^p \quad (8)$$

カーネル関数を用いて目的関数 (5) は以下のように書き換えられる。

$$\max \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j) \quad (9)$$

また識別関数は、次式で表される。

$$f(\mathbf{x}) = \text{sgn} \left(\sum_{i,j=1}^n \alpha_i y_i K(\mathbf{x}_i, \mathbf{x}_j) + b \right) \quad (10)$$

一方、データの特徴数 d より、例題サンプル数 n の方が過多の場合には、クラスを分ける識別面がいくらでも書けてしまう。そのため、決めた識別面が適当でないことが多く、汎化誤差が大きくなってしまいう傾向がある。そのため、性能の良いパターン識別器を作るためには、SVM に与える例題サンプルの数とデータの特徴数を同程度にするのが望ましいとされる。

3.2 特徴数の削減

今回用いた腕金鍍画像は 640×480 画素のカラー画像である。このデータは、0 から 255 までの画素値からなる R、G、B の 3 枚で構成されている。SVM に、R、G、B の画素値をデータとして与えると、データの特徴数は、 $640 \times 480 \times 3 = 921,600$ となる。今回用いた評価用データの総数は、3 クラス全部を合わせても約 600 枚であり、特徴数の方が大きすぎる。前節で述べたように、SVM が学習するデータ数に比べて特徴数が大きすぎないように、各画像のサイズ「 640×480 」をデータ圧縮し、画像サイズを小さくする方法を用いる。例えば画像データサイズを「 4×3 」にすると、 640×480 画素を図 1 のように、縦に 4 分割し、横に 3 分割し、分割したブロックの内部について画素値の平均をとることである。最適な画像サイズを見つけるために、実験では複数の画像サイズについて調べた。

4. 実験条件および結果

ここでは、2 章で紹介した腕金鍍画像の評価用テストデータについて、再利用判定が「再利用」と「廃棄」データだけ約 400 枚を用いて 2 クラスの判定を行う場合と、「再利用」、「めっき後再利用」、「廃棄」のすべての約 600 枚のデータを用いて 3 クラスの判定を行う場合について、計算機での判定精度を評価した。また、画像データに対応した判定ラベルは、「再利用」と判定した場合には「1」、「廃棄」と判定した場合は「-1」、「めっき後再利用」と判定した場合には「0」として与える。

評価は、評価用テストデータから各クラスごとにランダムに 50 枚を抽出し、残りの約 150 枚ずつをそれぞれ学習データとして計算機に学習させる。その後、各クラスで残しておいた 50 枚ずつをテストデータとして評価を行うという試行を 10 回行い、その平均で判定精度を評価した。

4.1 実験条件

カーネル関数

評価用テストデータを用いて SVM による判定精度を求めた。ここでは、代表的な二つのカーネル関数を適用して実験を行った。以下の実験 1)、2) とともに、カーネル関数に多項式カーネルと RBF カーネルを適用して実験を行った。まず初めに、表 1 のようなパラメータ設定を調べた。

多項式カーネルの次数は 1 次から 4 次までとし、ソフトマージン法において、誤判別を考慮する度合いを表すパラメータ C は、大きな値 1000 で固定した。

表 1: 調べた実験条件

カーネル (パラメータ)		画像データサイズ
多項式	p	1, 2, 3, 4
	C	1000
RBF	γ	0.1, 1, 10, 100, 1000
	C	1, 10, 100, 1000, 10000




図 1: 画像データサイズの圧縮の様子

RBF カーネルでは、モデルの複雑さを表すパラメータ γ とソフトマージン法におけるパラメータ C について、表 1 のように大まかに調べた後、最も精度の良かったパラメータ値周辺を詳しく調べて、パラメータ調整を行った。この際、10 分割交差検定法で与えられた学習データに対する最適なパラメータセットを見つけ出し、そのときの判定精度をテストデータによって評価した。

画像データサイズ

SVM が学習するデータ数に比べて特徴数が大きすぎないように、前章 3.2 節で説明した方法を用いて画像サイズ「640×480」をデータ圧縮し、画像サイズを小さくして特徴数を減らす。最適な画像サイズを調べるために、表 1 に示す「4×3」から「32×24」までの複数の画像データサイズについて実験を行った。

実験 1) 再利用判定が「再利用」、「廃棄」の 2 クラスの場合：

実験に使用する画像の枚数は 30 倍、50 倍ともに「再利用」203 枚、「廃棄」204 枚とした。

どちらの倍率についても、「再利用」、「廃棄」のそれぞれの評

価用データから、ランダムに 50 枚ずつ抽出しておき、残りの学習用データ 153+154=307 枚を用いて SVM で学習する。学習した SVM を、抽出しておいたテスト用データ 50+50=100 枚でテストし、判定精度を評価する。この試行を 10 回行い平均の判定精度を求めた。

実験 2) 再利用判定が「再利用」、「めっき後再利用」、「廃棄」の 3 クラスの場合：

実験に使用する画像の枚数は 30 倍、50 倍ともに「再利用」203 枚、「めっき後再利用」202 枚、「廃棄」204 枚とした。

2 クラスの場合と同様に、30 倍、50 倍ともに「再利用」、「めっき後再利用」、「廃棄」のそれぞれの評価用データからランダムに 50 枚ずつ抽出しておき、残りの学習用データを用いて SVM で学習する。後に、抽出しておいたテスト用データ 150 枚でテストし、判定精度を評価する。この試行を 10 回行い平均の判定精度を求める。

3 クラスの場合の判定方法は、総当りの組み合わせ（「再利用」対「めっき後再利用」、「めっき後再利用」対「廃棄」、「廃棄」対「再利用」）による判定結果を用いる。つまり、あるデータに対して、3 通りの組み合わせで、判定結果が重複している場合はそのクラスを答えとし、判定結果が全くかみ合わなかった場合は、識別面からの距離が最も大きいクラスを答えとした。

4.2 実験結果

実験 1)、2) とともに多項式カーネルより、RBF カーネルによって得られた判定精度の方が高かった。

多項式カーネルを用いた場合に得られた判定精度を表 2 に示す。画像データサイズは小さい方が精度が高かったため、4×3 についてのみ結果を示す。30 倍と 50 倍では、30 倍の方が精度が高い。2 クラス 30 倍では、カーネルの次数が 2 次と 3 次の場合に判定精度が高く、81%、3 クラス 30 倍では 3 次と 4 次のカーネルを用いた際に判定精度が高く、66% であった。

RBF カーネルを用いた場合には、学習データに 10 分割交差検定法を適用して最適なパラメータセットと最適な画像データサイズを求めた。表 1 のように、画像データサイズを 4×3 から 32×24 まで調べた結果、30 倍、50 倍ともに 4×3 より画像データサイズが大きくなるにつれて判定精度が上がり、30 倍では 20×12、20×15、32×24 でほぼ同じ高い判定精度が得られ、50 倍では 10×8、20×12、20×15 でほぼ同じ高い判定精度が得られた。図 2 に 2 クラスで最も判定精度の高かったデータサイズ 20×15 へ画像を圧縮した例を示した。パラメータ γ は画像データサイズが大きくなるにつれ、小さくなる傾向にあったが、 C の値は無関係であった。その理由としては、本実験での学習データには、識別の誤りが含まれていないため、ソフトマージンを考慮して導入される C には無関係であったと考えられる。そこで、 $\gamma = 0.1, 0.5, 1, 5, 10$ についてさらに調べた。10 分割交差検定法により調べた最も最適なパラメータと、画像データサイズの状態に、テストデータを用いて得られた判定精度を表 3 に示した。表 3 より、多項式カーネルの

表 2: p 次多項式カーネルを用いた場合に精度の最も高かった結果 ($C=1000$ 、画像データサイズ 4×3)

1 次		判定精度 ($p=1$)	判定精度 ($p=2$)	判定精度 ($p=3$)	判定精度 ($p=4$)
2 クラス	30 倍	78%	81%	81%	79%
	50 倍	69%	73%	73%	73%
3 クラス	30 倍	54%	64%	66%	66%
	50 倍	53%	56%	54%	51%

表 3: RBF カーネルを用いた場合に精度の最も高かった結果

RBF カーネル		判定精度	パラメータ	画像データサイズ
2 クラス	30 倍	89%	$\gamma=0.5, (C=1)$	20×15
	50 倍	84%	$\gamma=0.1, (C=100)$	20×15
3 クラス	30 倍	71%	$\gamma=0.1, (C=10000)$	32×24
	50 倍	58%	$\gamma=1, (C=100)$	20×12

場合と同じく 30 倍と 50 倍では、30 倍の方が精度が高いことがわかる。2 クラスでは、データサイズを 20×15 程度に圧縮するのが最も精度が高いと言える。このとき特徴ベクトルの次元は $20 \times 15 \times 3 = 900$ 次元となっている。今回の実験では、学習データの数は 2 クラスで約 300、3 クラスで約 450 であり、入力画像サイズが 10×8 よりも大きい場合には、特徴数が大きすぎる状態となる。ところが RBF パラメータでは、パラメータ γ が小さくなることにより、画素数過多の問題を緩和していると考えられる。結果として、2 クラス 30 倍で約 90% の判定精度、3 クラス 30 倍では約 70% の判定精度となり、人間の再利用判定を支援するには十分な判定精度を達成できる可能性が高いことが確認できた。

今回用いた腕金鍍画像は 640×480 画素のカラー画像であり、R、G、B の画素値すべてをデータとして用いると、データの特徴数が評価用データの総数に比べて大きすぎるため、画像データを圧縮するという方法を用いて特徴数を減らした。今後は画像データの枚数を増やして、判定精度向上をはかる。

また、今回の測定では、市販マイクロ스코プのレンズとして最も倍率の低い 30 倍と 50 倍を用いた。これでは局所的な部分 (30 倍レンズでは $8.2\text{mm} \times 6.1\text{mm}$ 、50 倍レンズでは $6\text{mm} \times 4.5\text{mm}$) だけしか見ることができない上に、拡大された画像のため SVM が人間の見ている情報と異なる情報を使って判定してしまう可能性がある。今後は、人間の見た目と同じ画像となるように、等倍レンズを用いたデータ収集を行い、そのデータを使用した再利用判定精度を評価する予定である。




図 2: 腕金鍍画像データサイズ圧縮の例

5. まとめと今後の展望

腕金鍍画像に基づく再利用可否判定評価用テストデータについて、サポートベクターマシンを用いて、計算機による判定精度を評価した。本論文では、市販のマイクロ스코プの倍率をそのまま用い、特徴抽出などの特別な画像処理を施さない場合の腕金鍍画像に基づく判定精度として、次の結果を報告した。

- 「再利用」、「廃棄」の 2 クラスの再利用判定の場合、約 90% の判定精度を達成できる。
- 「再利用」、「めっき後再利用」、「廃棄」の 3 クラスの再利用判定の場合、約 70% の判定精度を達成できる。

参考文献

- [1] V. N. Vapnik. *The Nature of Statistical Learning Theory*, Springer, 1995.
- [2] 津田 宏治, “サポートベクターマシンとは何か”, 電子情報通信学会誌, **83**, 460-466, 2000.
- [3] B. Scholkopf, K. Sung, C. Bruges, F. Girosi, P. Niyogi, T. Poggio and V. Vapnik., “Comparing Support Vector Machines with Gaussian Kernels to Radial Basis Function Classifiers”, *IEEE Trans. Signal Process.* **45**, 2758-2765, 1997.
- [4] D. Roobaert and M.M. Van Hulle, “View-based 3D Object Recognition with Support Vector Machines”, *IEEE Neural Networks for Signal Processing Workshop*, 1999.
- [5] M. Pontil and A. Verri, “Support Vector Machines for 3-D Object Recognition”, *IEEE Trans. PAMI*, **20**, 637-646, 1998.