

スパースPCAを用いた低解像度ナンバープレート数字の識別

大江凌太郎, 藤田和弘, 四宮康治

あらまし 監視ビデオにキャプチャされたアブストラクト・ライセンス・プレートは解像度が不十分であることが多く、数値を認識することが困難である。本論文では、スパースPCA係数とナイーブベイズ分類器を用いたナンバープレート番号認識のための新しい手法を提案する。提案手法を低解像度ナンバープレート画像に適用し、その性能を従来の2つの手法と比較する:ベイズ分類器によるモーメント特徴量とナイーブベイズ分類器によるPCA係数。第1候補の認識率、第2候補までの認識率、分類クロスエントロピーを含む評価結果は、提案手法が最高の性能を達成することを示している。

キーワード: ナンバープレート数字識別、低解像度画像、スパースPCA、ナイーブベイズ識別

1. まえがき

犯罪捜査では、監視カメラで撮影されたナンバープレートは小型で、解像度の低いナンバーキャラクターであることが多く、人間が識別することが困難である。具体的には、数字文字あたりの画素数が垂直方向に4画素、水平方向に2画素と少ないため、認識が困難である。従来の認識手法¹⁾は、十分な解像度と良好な撮像条件を前提としている。しかし、これらの方法は、文字固有の幾何学的特徴が弱まるため、低解像度ナンバープレート画像には有効ではない。吉川ら²⁾は、低解像度ナンバープレート番号認識のためのファジィ推論に基づく手法を提案した。しかし、この方法では、低解像度の曖昧さから「0」、「1」、「8」を区別せず、単一のグループに分類している。この方法は、犯罪捜査の要件を満たしていない。Shinomiyaら³⁾は、低解像度ナンバープレート番号認識のためのモーメント特徴量を用いた手法を提案した。本手法は、低解像度ナンバープレート番号の幾何学的特性を表す5つの特徴量、すなわち、水平方向と垂直方向の両方における歪度と平坦度、水平方向と垂直方向における標準偏差の比を抽出する。これらの特徴はベイズ分類に使用される。

しかし、この方法は、実験結果で示されたように、4番目の候補で「3」と正しく識別される前に、「3」が「9」、「7」、「5」と誤って分類されたという限界がある。辻ら⁴⁾は、識別精度を向上させるために、低解像度ナンバープレート上の数字の代わりにひらがな文字を識別する研究を行った。

本研究では、顔認識⁵⁾への応用に成功した固有画像を用いた手法を提案する。固有顔法は、学習顔画像に対して主成分分析(PCA)を行い、固有ベクトルに対応する固有顔を用いて、固有ベクトルとの内積をとることで、対象顔画像のPCA展開係数を算出する。これらの係数は、分類のための特徴量として使用される。数字に対応する固有画像を、ここでは数字を扱うので「固有数」と呼ぶことにする。

同様に、低解像度のナンバープレート画像に対してPCAを行い、PCA展開係数を特徴量として分類することができる。しかし、本研究では、低解像度のナンバープレート画像に対してスパースPCAを実行し、スパースPCA展開係数を特徴量として用いる手法を提案する。Sparse PCAベースの固有値を使用する動機は、PCAベースの固有値によって抽出される大域的な特徴ではなく、画像の局所的な特徴を反映する特徴を得ることである。

実験結果では、PCAに基づく固有数とSparse PCAに基づく固有数を用いて認識結果を比較する。

Received June 3, 2024; Revised August 20, 2024; Accepted December 9, 2024

† Ryukoku University, Graduate School of Science and Technology
(1-5, Yokotami, Oe-cho, Seta, Otsu-shi, Shiga 520-2194, Japan)

†† Hyogo Prefectural Police, Forensic laboratory
(5-4-1, Shimoyamate, Chuo-ku, Kobe-shi, Hyogo 650-8510, Japan) 1

【機械翻訳コンテンツの著作権について】

当サイトに掲載されている原著論文の著作権は映像情報メディア学会に帰属します。原著論文および翻訳論文の無断使用は禁止します。
引用の際には、必ず原著論文の書誌情報をご記載ください。詳細は映像情報メディア学会著作権規定をご覧ください。

Discriminating Car License Plate Numbers on Low Resolution Using Sparse PCA

Ryotaro Ooe , Kazuhiro Fujita (member)[†], Koji Shinomiya^{††}

Abstract License plates captured in surveillance videos often have insufficient resolution, making it difficult to recognize the numbers. In this paper, we propose a novel method for license plate number recognition using sparse PCA coefficients and Naive Bayes classifier. The proposed method is applied to low-resolution license plate images, and its performance is compared with two conventional methods: moment features with Bayes classifier and PCA coefficients with naive Bayes classifier. The evaluation results, including the first-candidate recognition rate, the recognition rate up to the second candidate, and the classification cross-entropy, show that the proposed method achieves the best performance.

Key words: License plate number recognition, Low-resolution images, Sparse PCA, Naive Bayes classifier

1. Introduction

In criminal investigations, license plates captured by surveillance video cameras are often small and have low-resolution number characters, making it difficult for humans to identify them. Specifically, the number of pixels per number character can be as low as 4 pixels vertically and 2 pixels horizontally, making it challenging to recognize. Traditional recognition methods¹⁾ assume sufficient resolution and good imaging conditions. However, these methods are not effective for low-resolution number plate images because the inherent geometric features of the characters are weakened. Yoshikawa et al.²⁾ proposed a fuzzy inference-based method for low-resolution license plate number recognition. However, this method does not distinguish between "0", "1", and "8" due to their low-resolution ambiguity, categorizing them as a single group. This approach does not meet the requirements of criminal investigations. Shinomiya et al.³⁾ proposed a method using moment features for low-resolution license plate number recognition. This method extracts five features representing the geometrical properties of low-resolution license plate numbers: skewness and flatness in both horizontal and vertical directions, and the ratio of standard deviations in horizontal and vertical directions. These features are used for Bayesian classification. However, this method has

limitations, as shown in their experimental result where "3" was incorrectly classified as "9", "7", and "5" before being correctly identified as "3" in the fourth candidate. Tsuji et al.⁴⁾ conducted a study on identifying hiragana characters instead of numbers on low-resolution license plates to improve identification accuracy.

In this study, we propose a method using eigen images, which has been successfully applied to face recognition⁵⁾. The Eigen Face method performs Principal Component Analysis (PCA) on training face images and uses the Eigen Faces, which correspond to the eigenvectors, in order to calculate the PCA expansion coefficients of the target face image by taking the inner product with eigen vectors. These coefficients are then used as features for classification. We refer to the eigen images corresponding to numbers as "Eigen Numbers" since we are dealing with numbers.

Similarly, we can perform PCA on low-resolution license plate images and use the PCA expansion coefficients as features for classification. However, in this study, we propose a method that performs Sparse PCA on low-resolution license plate images and uses Sparse PCA expansion coefficients as features. The motivation behind using Sparse PCA-based Eigen Numbers is to obtain features that reflect the local characteristics of the images instead of the global characteristics which is extracted by PCA-based Eigen Numbers.

In the experimental results, we compare the recognition results using PCA-based Eigen Numbers and Sparse PCA-based Eigen Numbers.

Received June 3, 2024; Revised August 20, 2024; Accepted December 9, 2024

[†] Ryukoku University, Graduate School of Science and Technology
(1-5, Yokotami, Oe-cho, Seta, Otsu-shi, Shiga 520-2194, Japan)

^{††} Hyogo Prefectural Police, Forensic laboratory
(5-4-1, Shimoyamate, Chuo-ku, Kobe-shi, Hyogo 650-8510, Japan)

2. 学習画像データセット

本研究では、篠宮ら³⁾が提案した低解像度画像生成法で生成した低解像度画像(256×128画素)を学習データとして用いる。

具体的には、低解像度画像 $\{\hat{x}_{m,n}\}$ は、元画像 $\{x_{m,n}\}$ ³⁾ からピクセル化された画像 $\{x_{\sim m,n}\}$ の平滑化版であると仮定する。ナンバープレート番号の元画像は、以下の式でピクセル化されます：

$$\tilde{x}_{m,n} = \frac{1}{W^2} \sum_{k=0}^{W-1} \sum_{l=0}^{W-1} x_{\left[\frac{m-m_0}{W}\right]W+k, \left[\frac{n-n_0}{W}\right]W+l} \quad (1)$$

ここで、 W は画素化係数を制御するパラメータであり、 m_0, n_0 は画素化のためのオフセットパラメータである。ダウンサンプリング後、以下の式で画像を平滑化する：

$$\hat{x}_{m,n} = \sum_{k,l} b_{k,l} \tilde{x}_{m-k,n-l} \quad (2)$$

$$b_{k,l} = \int_{k-\frac{1}{2}}^{k+\frac{1}{2}} \int_{l-\frac{1}{2}}^{l+\frac{1}{2}} b(u,v) du dv \quad (3)$$

$$b(u,v) = \begin{cases} \frac{1}{\pi r^2}, & u^2 + v^2 \leq r \\ 0, & \text{elsewhere} \end{cases} \quad (4)$$

ここで、 r は平滑化パラメータである。

本研究では、画素化係数 $W=32$ 、平滑化パラメータ $r=16$ の低解像度画像を学習用画像として生成した。図1に本研究で用いた低解像度画像の学習例を示す。各数値について、異なるシフトを持つ1,024枚の画像を学習データとして使用し、合計10,240枚の画像を得た。

3. センターアライメントによる前処理

Sparse PCAを行う場合、画像のずれが問題になることがある。そこで、本研究では、前処理として以下のセンターアライメントを行う。具体的には、ターゲット番号画像の重心を画像の中心にずらす。

まず、目標数画像 $\{\hat{x}_{m,n} ; m = 0, 1, 2, \dots, M-1, n =$

$0, 1, 2, \dots, N-1\}$ using the following equations:

$$\mu_1 = \left\lceil \frac{1}{MN} \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} m \hat{x}_{m,n} + 0.5 \right\rceil \quad (5)$$

$$\mu_2 = \left\lceil \frac{1}{MN} \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} n \hat{x}_{m,n} + 0.5 \right\rceil \quad (6)$$

ここで、 $\{\hat{x}_{m,n}\}$ はターゲット

画像 $\{\hat{x}_{m,n}\}$ から正規化された画像で、その和が1になるように、次式で定義される。

$$\hat{x}_{m,n} = \frac{\hat{x}_{m,n}}{\sum_{m=0}^{M-1} \sum_{n=0}^{N-1} \hat{x}_{m,n}} \quad (7)$$

重心を画像の中心にずらした画像 $\{x_{m,n}\}$ (M_2, N_2)は次式で定義される：

$$x'_{m,n} = \hat{x}_{m-\mu_1+\frac{M}{2}, n-\mu_2+\frac{N}{2}} \quad (8)$$

4. スパースPCA拡張係数を用いた認識

顔認識では、顔画像から特徴量を抽出するために主成分分析(PCA)が用いられてきた。ベイズ分類のための特徴を抽出するために、固有顔としても知られるPCAの固有ベクトルが使用される。

PCAベースの固有顔が顔の大域的な特徴を表すのに対して、スパースPCAベースの固有顔は局所的な特徴を捉える。スパースPCA展開係数を用いることで、目のような局所的な特徴のみを反映した特徴ベクトルを得ることができる。これは、目を表す固有顔の展開係数は、その固有顔とターゲット画像の内積をとることで得られるため、目以外の特徴を除外しているためである。これに基づき、低解像度ナンバープレートの数字にスパースPCAを適用することで、画像の局所的な特徴を表す固有画像が得られると期待される。さらに、これらの固有画像と対象画像の内積である展開係数を用いることで、対応する局所部分の特徴を捉える特徴ベクトルを得ることができる。

PCAは、低解像度のナンバープレート画像から特徴を抽出するためにも使用できる。しかし、このアプローチは、画像数の大域的な特徴のみを捉える。本論文では、Sparse PCA展開係数を特徴量としたナンバープレート番号認識手法を提案する。我々の経験から、低解像度のナンバープレート番号認識には局所的な特徴が重要であると考えている。実験セクションでは、PCA拡張係数とSparse PCA拡張係数を用いた認識結果を比較し、その結果について述べる。

与えられた画像 x_n の集合に Sparse PCA を適用することにより、固有ベクトル u_k (以下、固有数) と展開係数 $\{c_{n,k}\}$ が得られる。

2. Training Image Dataset

In this study, the low-resolution number images (256×128 pixels) which are generated by the low-resolution image generation method proposed by Shiomiya et al.³⁾ are used as training image data.

Specifically, the low-resolution image $\{\hat{x}_{m,n}\}$ is assumed to be a smoothed version of the image $\{\tilde{x}_{m,n}\}$ which is pixelized from original image $\{x_{m,n}\}$ ³⁾. The original image of the license plate number is pixelized using the following equation:

$$\tilde{x}_{m,n} = \frac{1}{W^2} \sum_{k=0}^{W-1} \sum_{l=0}^{W-1} x_{\lfloor \frac{m-m_0}{W} \rfloor W+k, \lfloor \frac{n-n_0}{W} \rfloor W+l} \quad (1)$$

where W is a parameter that controls the pixelizing factor, and m_0, n_0 are offset parameters for pixelization. After downsampling, the image is smoothed using the following equation:

$$\hat{x}_{m,n} = \sum_{k,l} b_{k,l} \tilde{x}_{m-k,n-l} \quad (2)$$

$$b_{k,l} = \int_{k-\frac{1}{2}}^{k+\frac{1}{2}} \int_{l-\frac{1}{2}}^{l+\frac{1}{2}} b(u,v) du dv \quad (3)$$

$$b(u,v) = \begin{cases} \frac{1}{\pi r^2}, & u^2 + v^2 \leq r \\ 0, & \text{elsewhere} \end{cases} \quad (4)$$

where r is a smoothing parameter.

In this study, we generated training low-resolution images with a pixelizing factor of $W = 32$ and a smoothing parameter of $r = 16$. Fig. 1 shows some of the training low-resolution images which are used in this study. For each number, 1,024 images with different shifts were used as training data, resulting in a total of 10,240 images.

3. Preprocessing by Center Alignment

Image misalignment can be a problem when performing Sparse PCA. Therefore, in this study, we perform the following center alignment as a preprocessing step. Specifically, we shift the center of gravity of the target number image to the center of the image.

First, we calculate the center of gravity μ_1, μ_2 of the target number image $\{\hat{x}_{m,n}; m = 0, 1, 2, \dots, M-1, n = 0, 1, 2, \dots, N-1\}$ using the following equations:

$$\mu_1 = \left\lfloor \frac{1}{MN} \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} m \hat{x}_{m,n} + 0.5 \right\rfloor \quad (5)$$

$$\mu_2 = \left\lfloor \frac{1}{MN} \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} n \hat{x}_{m,n} + 0.5 \right\rfloor \quad (6)$$

where $\{\hat{x}_{m,n}\}$ is the image which is normalized from

the target number image $\{\hat{x}_{m,n}\}$ so that its sum is 1, defined by the following equation:

$$\hat{x}_{m,n} = \frac{\hat{x}_{m,n}}{\sum_{m=0}^{M-1} \sum_{n=0}^{N-1} \hat{x}_{m,n}} \quad (7)$$

The image $\{x'_{m,n}\}$ with the center of gravity shifted to the center of the image $(\frac{M}{2}, \frac{N}{2})$ is defined by the following equation:

$$x'_{m,n} = \hat{x}_{m-\mu_1+\frac{M}{2}, n-\mu_2+\frac{N}{2}} \quad (8)$$

4. Recognition Using Sparse PCA Expansion Coefficients

In face recognition, Principal Component Analysis (PCA) has been used to extract features from face images. The eigenvectors of the PCA, also known as Eigen Faces, are used in order to extract features for Bayesian classification.

While PCA-based eigenfaces represent global features of a face, Sparse PCA-based eigenfaces capture local features. By using Sparse PCA expansion coefficients, we can obtain a feature vector that reflects only local features, such as those of the eyes. This is because the expansion coefficient for an eigenface representing the eyes is obtained by taking the inner product of that eigenface and the target image, thus excluding features other than the eyes. Based on this, we expect that by applying Sparse PCA to low-resolution number plate digits, we can obtain eigenimages that represent local features of the image. Moreover, by using the expansion coefficients, which are the inner products of these eigenimages and the target image, we can obtain feature vectors that capture the features of the corresponding local parts.

PCA can also be employed to extract features from low-resolution license plate number images. However, this approach captures only the global features of the number image. In this paper, we propose a method for license plate number recognition using Sparse PCA expansion coefficients as features. We believe that local features are important for low-resolution license plate number recognition, based on our experience. In the experimental section, we compare the recognition results using PCA expansion coefficients and Sparse PCA expansion coefficients, and discuss the results.

By applying Sparse PCA to a set of given images $\mathbf{x}_n$, the eigenvectors $\mathbf{u}_k$ (hereinafter referred to as Eigen Numbers) and expansion coefficients $\{c_{n,k}\}$ is obtained




Fig. 1 Training Image Dataset

を最小化するために、以下の目的関数を最小化する：

$$\frac{1}{2} \left\{ \sum_n \|\mathbf{x}_n - \sum_k c_{n,k} \mathbf{u}_k\|^2 + \alpha \sum_{n,k} |c_{n,k}| \right\} \quad \text{subject to } \|\mathbf{u}_k\|^2 = 1 \quad (9)$$

ここで、 α はスパース性を制御するパラメータである。図2にPCAとSparse PCAで得られた固有数画像を示す。図2に示すように、スパースPCAで得られた固有画像は、画像の局所的な性質を表している。

4.1 認識のための特徴量

低解像度のナンバープレート画像 $\mathbf{x}$ に対して、固有数 $\{\mathbf{u}_k\}$ との内積を評価することにより、展開係数 $\{C_k\}$ を以下のように求めることができる。

$$C_k = \mathbf{x}^T \mathbf{u}_k \quad (10)$$

これらの展開係数 $\{C_k\}$ を認識するための特徴量として用いる。

4.2 ナイーブベイズ分類

特徴ベクトル $\mathbf{y}$ は、固有数 $\{\mathbf{u}_k\}$ を用いて対象画像 $\mathbf{x}$ を展開して得られる展開係数 $\{C_k\}$ を用いて、以下のように定義される。

$$\mathbf{y} \equiv (C_0, C_1, \dots, C_{K-1})^T \quad (11)$$

低解像度ナンバープレートは、シミュレーションによって事前に生成された学習画像から抽出された特徴から学習する、以下に示すナイーブベイズ分類器を用いて分類される。クラス $\{\omega_l; l = 0, 1, 2, \dots, 9\}$ はナンバープレート番号 $\{0, 1, 2, \dots, 9\}$ 。ベイズの定理を用いると、特徴ベクトル $\mathbf{y}$ が与えられたときのクラス ω_l の事後確率 $P(\omega_l | \mathbf{y})$ は以下ようになる。

$$P(\omega_l | \mathbf{y}) = \frac{P(\omega_l) p(\mathbf{y} | \omega_l)}{p(\mathbf{y})} \quad (12)$$

特徴量 $\{C_k\}$ の独立性、すなわち素朴な仮定を仮定すると、以下ようになる。

$$P(\omega_l | \mathbf{y}) = \frac{P(\omega_l) \prod_{k=0}^{K-1} p(C_k | \omega_l)}{p(\mathbf{y})} \quad (13)$$

さらに、 $P(\omega_l)$ がすべてのクラスで同じであると仮定すると、以下のように分類結果 $\hat{\omega}_l$ が得られる。

$$\hat{\omega}_l = \arg \max_{\omega_l} \prod_{k=0}^{K-1} p(C_k | \omega_l) \quad (14)$$

5. 認識実験によるデータ収集

5.1 学習画像に対する認識実験

10,240枚の低解像度ナンバープレート画像を5,120枚のトレーニング画像と5,120枚の検証画像に分割した。次に、PCAとSparse PCAを用いて学習画像の固有数を求め、展開係数に基づいてナイーブベイズ分類器を学習させ、検証画像に対して認識実験を行った。認識精度を評価した。図3は、PCAとSparse PCAの両方について、次元数1~20での精度評価結果である。この図から、PCAとSparse PCAの精度はともに8次元で飽和していることがわかる。さらに、精度はこの点より少し上下に変動している。そこで、PCAとSparse PCAの次元をともに8とした。

図2は、5,120枚の学習画像に対して、PCAとスパースPCAを用いて8次元で得られた固有値を示している。図からわかるように、PCAを用いて得られた固有数値は画像全体の特徴を表し、Sparse PCA($\alpha=1$)を用いて得られた固有数値は画像の局所的な特徴を表している。

表1は、5,120枚の検証画像に対して、スパースPCA展開係数を特徴量として用いた場合の分類結果の混同行列である。0 "は "8 "と誤分類され、"2 "は "1 "または "7 "と誤分類され、




Fig. 1 Training Image Dataset

in order to minimize the following objective function:

$$\frac{1}{2} \left\{ \sum_n \|\mathbf{x}_n - \sum_k c_{n,k} \mathbf{u}_k\|^2 + \alpha \sum_{n,k} |c_{n,k}| \right\} \quad \text{subject to } \|\mathbf{u}_k\|^2 = 1 \quad (9)$$

where α is a parameter that controls the sparsity. Fig. 2 shows the Eigen Number images obtained by PCA and Sparse PCA. As shown in Fig. 2, the eigen images obtained by Sparse PCA represent the local properties of the images.

4.1 Features for Recognition

For a low-resolution license plate number image $\mathbf{x}$, the expansion coefficients $\{C_k\}$ can be obtained by evaluating the inner product with the Eigen Numbers $\{\mathbf{u}_k\}$ as follows

$$C_k = \mathbf{x}^T \mathbf{u}_k \quad (10)$$

These expansion coefficients $\{C_k\}$ are used as features for recognition.

4.2 Naive Bayes Classification

The feature vector $\mathbf{y}$ is defined as follows using the expansion coefficients $\{C_k\}$ obtained by expanding the target image $\mathbf{x}$ using the Eigen Numbers $\{\mathbf{u}_k\}$.

$$\mathbf{y} \equiv (C_0, C_1, \dots, C_{K-1})^T \quad (11)$$

Low-resolution license plate numbers are classified using the Naive Bayes classifier shown below, which learns from features extracted from training images generated by simulation beforehand. The classes $\{\omega_l; l = 0, 1, 2, \dots, 9\}$ correspond to the license plate numbers $\{0, 1, 2, \dots, 9\}$. Using Bayes' theorem, the posterior probability $P(\omega_l|\mathbf{y})$ of class ω_l given feature vector $\mathbf{y}$ is as follows:

$$P(\omega_l|\mathbf{y}) = \frac{P(\omega_l)p(\mathbf{y}|\omega_l)}{p(\mathbf{y})} \quad (12)$$

Assuming the independence of the features $\{C_k\}$ i.e., the naive assumption, we have the following:

$$P(\omega_l|\mathbf{y}) = \frac{P(\omega_l) \prod_{k=0}^{K-1} p(C_k|\omega_l)}{p(\mathbf{y})} \quad (13)$$

Furthermore, assuming that $P(\omega_l)$ is the same for all classes, we obtain the classification result $\hat{\omega}_l$ as follows:

$$\hat{\omega}_l = \arg \max_{\omega_l} \prod_{k=0}^{K-1} p(C_k|\omega_l) \quad (14)$$

5. Recognition Experiment

5.1 Recognition Experiment on Training Images

We divided 10,240 sample low-resolution license plate number images into 5,120 training images and 5,120 validation images. We then obtained the Eigen Numbers for the training images using PCA and Sparse PCA, trained a Naive Bayes classifier based on the expansion coefficients, and carried out a recognition experiment on the validation images. We evaluated the accuracy of the recognition. Fig. 3 shows the results of the accuracy evaluation for dimensionalities of 1 to 20 for both PCA and Sparse PCA. From this figure, it can be seen that the accuracy of both PCA and Sparse PCA saturate at a dimensionality of 8. Furthermore, the accuracy fluctuates slightly above and below this point. Therefore, we set the dimensionality of both PCA and Sparse PCA to 8.

Fig. 2 shows the Eigen Numbers obtained using PCA and Sparse PCA with a dimensionality of 8 for 5,120 training images. As can be seen from the figure, the Eigen Numbers obtained by using PCA represent the overall characteristics of the entire image, while the Eigen Numbers obtained by using Sparse PCA ($\alpha = 1$) represent the local characteristics of the image.

Table 1 shows the confusion matrix of the classification results by using the Sparse PCA expansion coefficients as features for 5,120 validation images. Some "0"s were misclassified as "8"s, some "2"s were mis-




Fig. 2 Eigen Number




Fig. 3 次元による精度レートの変化

”3 ”は ”1 ”または ”7 ”と誤分類され、”5 ”は ”9 ”と誤分類され、”6 ”は ”4 ”と誤分類され、”7 ”は ”1 ”と誤分類され、”8 ”は ”4 ”と誤分類され、”9 ”は ”5 ”と誤分類された。全体の精度は0.932であった。

5.2 分類結果の評価について

精度に加え、以下の式で定義されるカテゴリカルクロスエントロピーも、実際のナンバープレート数字画像の分類結果を評価するために採用される。

$$E = -\frac{1}{9} \sum_i \sum_{j=0}^9 t_{i,j} \log P(\omega_j | \mathbf{y}_i) \quad (15)$$

ここで、 $\mathbf{y}_i$ はターゲット画像 x_i から得られる特徴ベクトル (PCA / Sparse PCA 展開係数)、 $t_{i,j}$ は i 番目のターゲット画像に対応する正しいクラスのワンホットエンコーディングで、次式で定義される。



Fig. 4 Actual Low-Resolution Numberplate Image "9173"



Fig. 5 Actual Low-Resolution Numberplate Image "4685"

$$t_{i,j} = \begin{cases} 1, & \omega_j \text{ is the correct class} \\ 0, & \text{それ以外の} \end{cases} \quad (16)$$

5.3 実際の低解像度ナンバープレート画像認識の実験#1

表2、3、4、5は、提案手法を用いた2枚の低解像度ナンバープレート画像³⁾(図4、図5)の分類結果である。

PCA展開係数を用いた場合、”9 ”は $P(\omega_9) = 0.017$ という低い確率で2番目の候補に、”3 ”は $P(\omega_3) = 0.150$ という3番目の候補に分類された。しかし、それ以外の数字はすべてトップ1候補として正しく分類された。

SparsePCA展開係数を採用した場合、”9 ”は再び $P(\omega_9) = 0.008$ という低い確率で2番目の候補に分類された。それ以外の数字もトップ1候補として正しく分類された。篠宮の方法³⁾も $P(\omega_9) = 0.380$ で「9」を第2候補、




Fig. 2 Eigen Number




Fig. 3 Variation of Accuracy Rate with Dimensionality

classified as "1"s or "7"s, some "3"s were misclassified as "1"s or "7"s, some "5"s were misclassified as "9"s, some "6"s were misclassified as "4"s, some "7"s were misclassified as "1"s, some "8"s were misclassified as "4"s, and some "9"s were misclassified as "5"s. The overall accuracy was 0.932.

5.2 Evaluation of Classification Results

In addition to the accuracy rate, the categorical cross-entropy defined by the following equation is also employed to evaluate the classification results for real numberplate digit images.

$$E = -\frac{1}{9} \sum_i \sum_{j=0}^9 t_{i,j} \log P(\omega_j | \mathbf{y}_i) \quad (15)$$

where $\mathbf{y}_i$ is the feature vector (PCA / Sparse PCA expansion coefficient) obtained from the target image $\mathbf{x}_i$, $t_{i,j}$ is the one-hot encoding of the correct class corresponding to the i -th target image, and is defined by the following equation.



Fig. 4 Actual Low-Resolution Numberplate Image "9173"



Fig. 5 Actual Low-Resolution Numberplate Image "4685"

$$t_{i,j} = \begin{cases} 1, & \omega_j \text{ is the correct class} \\ 0, & \text{otherwise} \end{cases} \quad (16)$$

5.3 Experiment#1 of Actual Low-Resolution Number Plate Image Recognition

Table 2, 3, 4, 5 shows the classification results for two actual low-resolution number plate images³⁾ (Fig. 4 and Fig. 5) using our proposed methods.

In the case of using PCA expansion coefficients, "9" was classified as the second candidate with a low probability of $P(\omega_9) = 0.017$, and "3" was classified as the third candidate with $P(\omega_3) = 0.150$. However, all other digits were correctly classified as the top-1 candidates.

When SparsePCA expansion coefficients were employed, "9" was again classified as the second candidate with a low probability of $P(\omega_9) = 0.008$. All other digits were also correctly classified as the top-1 candidates. It is worth noting that Shinomiya's method³⁾ also clas-

表1 スパースPCA拡張係数を用いた分類結果のコンフュージョンマトリックス

Actual Class	Predicted Class										Accuracy
	0	1	2	3	4	5	6	7	8	9	
0	379	0	0	0	0	0	0	0	133	0	0.752
1	0	512	0	0	0	0	0	0	0	0	1.000
2	0	21	467	0	0	0	0	24	0	0	0.912
3	0	32	0	451	0	0	0	29	0	0	0.881
4	0	0	0	0	512	0	0	0	0	0	1.000
5	0	0	0	0	0	471	0	0	0	41	0.920
6	0	0	0	0	20	0	492	0	0	0	0.961
7	0	22	0	0	0	0	490	0	0	0	0.957
8	0	0	0	0	23	0	0	0	489	0	0.955
9	0	0	0	0	0	5	0	0	0	507	0.990
											0.932

Table 2 PCAによる "9173" の判別結果

	"9"	"1"	"7"	"3"
$P(\omega_0)$	0.000	0.000	0.000	0.000
$P(\omega_1)$	0.000	<u>1.000</u>	0.000	0.000
$P(\omega_2)$	0.000	0.000	0.000	0.000
$P(\omega_3)$	0.000	0.000	0.000	<u>0.150</u>
$P(\omega_4)$	0.000	0.000	0.000	0.000
$P(\omega_5)$	0.983	0.000	0.000	0.609
$P(\omega_6)$	0.000	0.000	0.000	0.000
$P(\omega_7)$	0.000	0.000	<u>1.000</u>	0.238
$P(\omega_8)$	0.000	0.000	0.000	0.000
$P(\omega_9)$	<u>0.017</u>	0.000	0.000	0.003

Table 5 SparsePCA($\alpha=1.0$)による "4685" の判別結果

	"4"	"6"	"8"	"5"
$P(\omega_0)$	0.000	0.001	0.025	0.000
$P(\omega_1)$	0.000	0.000	0.000	0.000
$P(\omega_2)$	0.000	0.000	0.000	0.000
$P(\omega_3)$	0.000	0.000	0.000	0.000
$P(\omega_4)$	<u>0.979</u>	0.000	0.001	0.000
$P(\omega_5)$	0.000	0.000	0.000	<u>1.000</u>
$P(\omega_6)$	0.018	<u>1.000</u>	0.000	0.000
$P(\omega_7)$	0.000	0.000	0.000	0.000
$P(\omega_8)$	0.003	0.000	<u>0.975</u>	0.000
$P(\omega_9)$	0.000	0.000	0.000	0.000

Table 3 SparsePCA($\alpha=1.0$)による "9173" の判別結果

	"9"	"1"	"7"	"3"
$P(\omega_0)$	0.000	0.000	0.000	0.000
$P(\omega_1)$	0.000	<u>1.000</u>	0.000	0.000
$P(\omega_2)$	0.000	0.000	0.000	0.000
$P(\omega_3)$	0.000	0.000	0.000	<u>0.986</u>
$P(\omega_4)$	0.000	0.000	0.000	0.000
$P(\omega_5)$	0.992	0.000	0.000	0.002
$P(\omega_6)$	0.000	0.000	0.000	0.000
$P(\omega_7)$	0.000	0.000	<u>1.000</u>	0.012
$P(\omega_8)$	0.000	0.000	0.000	0.000
$P(\omega_9)$	<u>0.008</u>	0.000	0.000	0.000

Table 6 "9173", "4685" の結果のカテゴリ別クロスエントロピー

	Top-1 Accuracy	Top-2 Accuracy	Categorical Cross Entropy
moment[3]	0.750	0.875	1.086
PCA	0.750	0.875	0.764
SparsePCA	0.875	1.000	0.624

表4 PCAによる「4685」の判別結果

	"4"	"6"	"8"	"5"
$P(\omega_0)$	0.000	0.000	0.019	0.000
$P(\omega_1)$	0.000	0.000	0.000	0.000
$P(\omega_2)$	0.000	0.000	0.000	0.000
$P(\omega_3)$	0.000	0.000	0.000	0.000
$P(\omega_4)$	<u>0.965</u>	0.000	0.000	0.000
$P(\omega_5)$	0.000	0.013	0.000	<u>0.999</u>
$P(\omega_6)$	0.035	<u>0.987</u>	0.000	0.000
$P(\omega_7)$	0.000	0.000	0.000	0.000
$P(\omega_8)$	0.000	0.000	<u>0.981</u>	0.000
$P(\omega_9)$	0.000	0.000	0.000	0.001

$P(\omega_3) = 0.005$ で「3」を第3候補に分類したことは注目に値する。しかし、それ以外の数字はすべてトップ1候補として正しく分類された。

数字がトップ1候補に分類された場合でも、 $P(\omega_1)$ の値は大きく変化する可能性があることに注意することが重要である。値が低い場合、top-1候補とtop-2候補の差は小さいことが多い。

したがって、前述のカテゴリカルクロスエントロピー(式(15))に基づく評価結果を表6に示す。表6から、モーメント特徴に基づく方法³⁾は、カテゴリカルクロスエントロピーの点で最悪の結果をもたらすことが観察できる。さらに、Sparse PCA拡張係数はPCA拡張係数よりもわずかに良い結果を示した。

5.4 実際の低解像度ナンバープレート画像認識の実験#2

図6に、篠宮³⁾の研究では使用されなかった新しい低解像度ナンバープレート数字画像を示す。表7は、図6に示した5枚のナンバープレートで18桁の分類を評価し、認識精度とカテゴリクロスエントロピーを求めたものである。その結果、SparsePCA拡張係数、PCA拡張係数、モーメント特徴量は、top-1、top-2ともに高い精度を示し、順不同であることがわかった。SparsePCAはほぼ0.8のトップ2精度を達成し、これは良い結果とみなされた。表8は、SparsePCAによる具体的な認識結果である。

Table 1 Confusion Matrix of Classification Results using Sparse PCA Expansion Coefficients

Actual Class	Predicted Class										Accuracy
	0	1	2	3	4	5	6	7	8	9	
0	379	0	0	0	0	0	0	0	133	0	0.752
1	0	512	0	0	0	0	0	0	0	0	1.000
2	0	21	467	0	0	0	0	24	0	0	0.912
3	0	32	0	451	0	0	0	29	0	0	0.881
4	0	0	0	0	512	0	0	0	0	0	1.000
5	0	0	0	0	0	471	0	0	0	41	0.920
6	0	0	0	0	20	0	492	0	0	0	0.961
7	0	22	0	0	0	0	0	490	0	0	0.957
8	0	0	0	0	23	0	0	0	489	0	0.955
9	0	0	0	0	0	5	0	0	0	507	0.990
											0.932

Table 2 Discriminating Result for "9173" by PCA

	"9"	"1"	"7"	"3"
$P(\omega_0)$	0.000	0.000	0.000	0.000
$P(\omega_1)$	0.000	<u>1.000</u>	0.000	0.000
$P(\omega_2)$	0.000	0.000	0.000	0.000
$P(\omega_3)$	0.000	0.000	0.000	<u>0.150</u>
$P(\omega_4)$	0.000	0.000	0.000	0.000
$P(\omega_5)$	0.983	0.000	0.000	0.609
$P(\omega_6)$	0.000	0.000	0.000	0.000
$P(\omega_7)$	0.000	0.000	<u>1.000</u>	0.238
$P(\omega_8)$	0.000	0.000	0.000	0.000
$P(\omega_9)$	<u>0.017</u>	0.000	0.000	0.003

Table 3 Discriminating Result for "9173 by SparsePCA($\alpha = 1.0$)

	"9"	"1"	"7"	"3"
$P(\omega_0)$	0.000	0.000	0.000	0.000
$P(\omega_1)$	0.000	<u>1.000</u>	0.000	0.000
$P(\omega_2)$	0.000	0.000	0.000	0.000
$P(\omega_3)$	0.000	0.000	0.000	<u>0.986</u>
$P(\omega_4)$	0.000	0.000	0.000	0.000
$P(\omega_5)$	0.992	0.000	0.000	0.002
$P(\omega_6)$	0.000	0.000	0.000	0.000
$P(\omega_7)$	0.000	0.000	<u>1.000</u>	0.012
$P(\omega_8)$	0.000	0.000	0.000	0.000
$P(\omega_9)$	<u>0.008</u>	0.000	0.000	0.000

Table 4 Discriminating Result for "4685" by PCA

	"4"	"6"	"8"	"5"
$P(\omega_0)$	0.000	0.000	0.019	0.000
$P(\omega_1)$	0.000	0.000	0.000	0.000
$P(\omega_2)$	0.000	0.000	0.000	0.000
$P(\omega_3)$	0.000	0.000	0.000	0.000
$P(\omega_4)$	<u>0.965</u>	0.000	0.000	0.000
$P(\omega_5)$	0.000	0.013	0.000	<u>0.999</u>
$P(\omega_6)$	0.035	<u>0.987</u>	0.000	0.000
$P(\omega_7)$	0.000	0.000	0.000	0.000
$P(\omega_8)$	0.000	0.000	<u>0.981</u>	0.000
$P(\omega_9)$	0.000	0.000	0.000	0.001

sified "9" as the second candidate with $P(\omega_9) = 0.380$ and "3" as the third candidate with $P(\omega_3) = 0.005$. However, all other digits were correctly classified as the top-1 candidates.

It is important to note that even when digits are classified as the top-1 candidate, the value of $P(\omega_1)$ can vary significantly. In cases where the value is low, the difference between the top-1 and top-2 candidates is often small. Therefore, the evaluation results based on the

Table 5 Discriminating Result for "4685" by SparsePCA($\alpha = 1.0$)

	"4"	"6"	"8"	"5"
$P(\omega_0)$	0.000	0.001	0.025	0.000
$P(\omega_1)$	0.000	0.000	0.000	0.000
$P(\omega_2)$	0.000	0.000	0.000	0.000
$P(\omega_3)$	0.000	0.000	0.000	0.000
$P(\omega_4)$	<u>0.979</u>	0.000	0.001	0.000
$P(\omega_5)$	0.000	0.000	0.000	<u>1.000</u>
$P(\omega_6)$	0.018	<u>1.000</u>	0.000	0.000
$P(\omega_7)$	0.000	0.000	0.000	0.000
$P(\omega_8)$	0.003	0.000	<u>0.975</u>	0.000
$P(\omega_9)$	0.000	0.000	0.000	0.000

Table 6 Categorical Cross-Entropy of Results for "9173, "4685"

	Top-1 Accuracy	Top-2 Accuracy	Categorical Cross Entropy
moment[3]	0.750	0.875	1.086
PCA	0.750	0.875	0.764
SparsePCA	0.875	1.000	0.624

aforementioned categorical cross-entropy (Eq. (15)) are shown in Table 6. From Table 6, it can be observed that the moment features based method³⁾ yielded the worst results in terms of categorical cross-entropy. Furthermore, the Sparse PCA expansion coefficients performed slightly better than the PCA expansion coefficients.

5.4 Experiment#2 of Actual Low-Resolution Number Plate Image Recognition

Fig. 6 shows new low-resolution numberplate digit images which were not used in the study by Shinomiya³⁾. Table 7 shows the recognition accuracy and categorical cross-entropy obtained by evaluating the classification 18 digits on 5 numberplates shown in Fig. 6. The results show that SparsePCA expansion coefficients, PCA expansion coefficients, and the moment features performed well in that order, both in terms of top-1 and top-2 accuracy. SparsePCA achieved a top-2 accuracy of almost 0.8, which was considered as a good result. Table 8 shows the specific recognition results by SparsePCA.




Fig. 6 実際のナンバープレート画像

Table 7 実際のナンバープレート画像に対する実験結果#2

	Top-1 accuracy	Top-2 accuracy	Categorical Cross Entropy
moment	0.444	0.556	2.905
PCA	0.611	0.722	2.070
SparsePCA	0.722	0.778	1.878

6. 実験#3 スパースPCAの次元について

実験#1と#2では、次元数8のスパースPCAを用いた認識実験を行った。次元数の変化に対するスパースPCAの頑健性を評価するため、実験#1と#2の合計26枚の画像について、スパースPCAとPCAの両方の次元数を変化させ、認識精度の変化を調べた。図7はTop-1認識精度を、図8はTop-2認識精度をSparse PCAとPCAの次元数の関数として示したものである。

Table 8 実際のナンバープレート画像に対する実験結果#2 (Sparse PCA)

Plate	Number	1st Candidate	2nd Candidate
384	3	3 (0.997)	9 (0.002)
	8	8 (0.966)	0 (0.034)
	4	1 (0.975)	7 (0.025)
741	7	1 (0.998)	7 (0.002)
	4	4 (1.000)	-
	1	1 (1.000)	-
2631	2	2 (0.855)	3 (0.145)
	6	6 (1.000)	-
	3	3 (0.812)	7 (0.170)
	1	1 (1.000)	-
4175	4	8 (0.991)	0 (0.009)
	1	1 (1.000)	-
	7	7 (1.000)	-
	5	5 (1.000)	-
7302	7	3 (0.990)	2 (0.008)
	3	3 (0.999)	7 (0.001)
	0	7 (0.559)	3 (0.441)
	2	2 (0.999)	3 (0.001)





Fig. 7 スパースPCA次元のトップ1精度

図7と図8から、スパースPCAのトップ1認識精度はある程度変動しているが、トップ2認識精度は比較的小さな変動を示しており、スパースPCAが次元の変化に対してある程度頑健であることが示唆される。一方、PCAでは、Top-1認識精度、Top-2認識精度とともに、次元数が13を超えると急激に低下することから、PCAはSparse PCAに比べて次元数の変化に対するロバスト性が低いことがわかる。

7. 認識結果と潜在的な戦略の比較

実験#1と#2では、スパースPCAを用いた手法の有効性を実証するために、Top-1とTop-2の精度とCategorical Cross Entropyを用いた認識結果を比較した。本節では、困難なケースを処理する際の様々な手法の性能を調べるために、表9、10、11に詳細な比較結果を示す。

**Fig. 6** Actual Numberplate Images**Table 7** Experimental Results #2 for Actual Numberplate images


	Top-1 accuracy	Top-2 accuracy	Categorical Cross Entropy
moment	0.444	0.556	2.905
PCA	0.611	0.722	2.070
SparsePCA	0.722	0.778	1.878

6. Experiment #3 for dimension of Sparse PCA

In Experiments #1 and #2, we have carried out recognition experiments using Sparse PCA with a dimensionality of 8. To evaluate the robustness of Sparse PCA to changes in dimensionality, we varied the dimensionality of both Sparse PCA and PCA for a total of 26 images from Experiments #1 and #2, and investigated the changes in recognition accuracy. Fig. 7 shows the Top-1 recognition accuracy, and Fig. 8 shows the Top-2 recognition accuracy, as a function of the dimension-

Table 8 Experimental Result #2 for Actual Numberplate Images (Sparse PCA)

Plate	Number	1st Candidate	2nd Candidate
384	3	3 (0.997)	9 (0.002)
	8	8 (0.966)	0 (0.034)
	4	1 (0.975)	7 (0.025)
741	7	1 (0.998)	7 (0.002)
	4	4 (1.000)	-
	1	1 (1.000)	-
2631	2	2 (0.855)	3 (0.145)
	6	6 (1.000)	-
	3	3 (0.812)	7 (0.170)
	1	1 (1.000)	-
4175	4	8 (0.991)	0 (0.009)
	1	1 (1.000)	-
	7	7 (1.000)	-
	5	5 (1.000)	-
7302	7	3 (0.990)	2 (0.008)
	3	3 (0.999)	7 (0.001)
	0	7 (0.559)	3 (0.441)
	2	2 (0.999)	3 (0.001)

**Fig. 7** Top-1 accuracy for Sparse PCA dimension

ality of Sparse PCA and PCA. Fig. 7 and Fig. 8 indicate that while the Top-1 recognition accuracy of Sparse PCA fluctuates to some extent, the Top-2 recognition accuracy exhibits relatively small fluctuations, suggesting that Sparse PCA has a certain level of robustness to changes in dimensionality. On the other hand, for PCA, both Top-1 recognition accuracy and Top-2 recognition accuracy decrease rapidly when the dimensionality exceeds 13, indicating that PCA is less robust to changes in dimensionality compared to Sparse PCA.

7. Comparison of recognition results and potential strategy

In Experiments #1 and #2, we compared the recognition results using the Top-1 and Top-2 accuracy as well as Categorical Cross Entropy to demonstrate the effectiveness of the method using Sparse PCA. In this section, to investigate the performance of different methods in handling challenging cases, we present de-




図8 Sparse PCA次元のトップ2精度

Table 9 4175 "の"5"の認識結果の比較

	$P(\omega_5)$	$P(\omega_7)$	$P(\omega_9)$
moment	0.000	0.997	0.003
PCA	1.000	0.000	0.000
Sparse PCA	1.000	0.000	0.000

Table 10 9173 "の"3"の認識結果の比較

	$P(\omega_3)$	$P(\omega_5)$	$P(\omega_7)$	$P(\omega_9)$
moment	0.005	0.108	0.338	0.548
PCA	0.150	0.609	0.238	0.003
Sparse PCA	0.986	0.002	0.012	0.000

Table 11 7302 "の"7"の認識結果の比較

	$P(\omega_3)$	$P(\omega_5)$	$P(\omega_7)$
moment	0.000	0.000	1.000
PCA	0.000	0.333	0.667
Sparse PCA	0.008	0.990	0.002

表9は、モーメントベースの手法が高い過信を示すケースを示している。表10は、モーメントベース、PCAベース、スパースPCAベースの手法で顕著に異なる結果が得られるケースを示している。表11は、Sparse PCA-methodが過信問題を示すケースを示している。しかし、モーメントベース法とPCAベース法は正しく分類できるため、複数の手法を統合することで過信問題を回避できると考えられる。具体的には、複数の手法の出力に対してソフト投票を行うか、MLP (Multi-Layer Perceptron) を用いて統合することができる。さらに、全く異なるアプローチとして、DNN(Deep Neural Network)を用いた手法の統合も考えられる。

8. むすび

本研究では、スパースプリンシパルに基づく低解像度ナンバープレート数字認識のための新しい手法を提案する。

成分分析 (Sparse PCA) 係数とナイーブベイズ分類。提案手法を実際の低解像度ナンバープレート画像を用いて評価し、ベイズ分類によるモーメント特徴量とナイーブベイズ分類によるPCA係数の2つの従来手法と比較した。評価指標は、トップ1精度、トップ2精度、カテゴリークロスエントロピーである。その結果、SparsePCA係数とNaive Bayes分類を用いた提案手法は、従来手法を凌駕することが実証された。しかし、提案手法は依然として高い信頼度で誤分類を示しており、これは過信問題として知られている。したがって、今後の研究では、複数の分類法を統合するなど、過信問題を回避するための手法の開発に焦点を当てるべきである。

References

- 1) C-N.E.Anagnostopoulos, I.E.Anagnostopoulos, I.D.Psoulas, V.Loumos: "License Plate Recognition From Still Images and Video Sequences: A Survey", IEEE Trans. on Intelligent Transportation Systems, Vol.9, No.3, September 2008
- 2) Ayumi Yoshikawa, Naoko Yoshikawa, Kazuhiro Fujita: "Equipment of discriminating symbol, Method of discriminating the symbol, and its computer program", Patent 4243941 in Japan (2009/01/26)
- 3) Koji Shinomiya, Naoki Takamura, Kazuhiro Fujita, Nobuyuki Nakamori: "Discriminating Car License Plate Numbers on Low Resolution Using Moment Characteristics", ITE Trans. on Media Technology and Applications, Vol.1, No.4, pp.271-277 (2013)
- 4) Hiroo Tsuji, Yohei Fukumizu, Takakuni Douseki, Hironori Yamauchi: "Hiragana Recognition of Degraded License Plate Image by Multistrcuture Convolutional Neural Network", Journal of Signal Processing, Vol.22, No.3, pp.121-134 (2018 May)
- 5) Andreas C.Müller, Sarah Guido: "Introduction to Machine Learning with Python", O'REILLY (2016)



Ryotaro Ooe received his B.E. and M.E. degrees from Ryukoku University, Japan in 2021, 2023, respectively. He works at currently at Kyocera Communication System Inc., Japan from April 2023. His research interests are image processing and pattern recognition.



Kazuhiro Fujita received his B.E., M.E., and Ph.D. degrees in electrical engineering from Kyoto Institute of Technology, Japan, in 1986, 1988, 1993, respectively. He joined Kyoto Institute of Technology as a research assistant in 1988. He was an associate professor at Kyoto Institute of Technology from 2003 to 2004. He moved to Ryukoku University in 2004 as an associate professor. He is currently a professor in Ryukoku University. His research interest is statistical image processing. He is a member of the IEEE, IEICE, ITE, and Japanese Association of Forensic Science and Technology.



Koji Shinomiya received his B.E. degree from Himeji Institute of Technology, Japan in 1993. He joined the Forensic Science Lab, Hyogo Prefectural Police H.Q. in 1993. He is currently engaged in identification and research of image and speech information processing. He is a member of Acoustical Society of Japan, and Japanese Association of Forensic Science and Technology.




Fig. 8 Top-2 accuracy for Sparse PCA dimension

Table 9 Comparison of recognition results for "5" in "4175"

	$P(\omega_5)$	$P(\omega_7)$	$P(\omega_9)$
moment	<u>0.000</u>	0.997	0.003
PCA	<u>1.000</u>	0.000	0.000
Sparse PCA	<u>1.000</u>	0.000	0.000

Table 10 Comparison of recognition results for "3" in "9173"

	$P(\omega_3)$	$P(\omega_5)$	$P(\omega_7)$	$P(\omega_9)$
moment	0.005	0.108	0.338	0.548
PCA	<u>0.150</u>	0.609	0.238	0.003
Sparse PCA	<u>0.986</u>	0.002	0.012	0.000

Table 11 Comparison of recognition results for "7" in "7302"

	$P(\omega_2)$	$P(\omega_3)$	$P(\omega_7)$
moment	0.000	0.000	<u>1.000</u>
PCA	0.000	0.333	<u>0.667</u>
SparsePCA	0.008	0.990	<u>0.002</u>

tailed comparison results in Tables 9, 10, and 11. Table 9 demonstrates a case where the moment-based method exhibits high overconfidence. Table 10 presents a case where the moment-based, PCA-based, and Sparse PCA-based methods yield notably different results. Table 11 demonstrates a case where Sparse PCA-method exhibits the overconfident problem. However, since the moment-based method and the PCA-based method can correctly classify, it is considered that the overconfident problem can be avoided by integrating multiple methods. Specifically, soft voting can be performed on the outputs of multiple methods, or they can be integrated using an MLP (Multi-Layer Perceptron). Additionally, as a completely different approach, integrating a method using a DNN (Deep Neural Network) can also be considered.

8. Conclusion

We propose a novel method for low-resolution number plate digit recognition based on Sparse Principal

Component Analysis (Sparse PCA) coefficients and Naive Bayes classification. The proposed method was evaluated using actual low-resolution numberplate images and compared with two conventional methods: moment features with Bayes classification and PCA coefficients with naive Bayes classification. The evaluation metrics included top-1 accuracy, top-2 accuracy, and categorical cross-entropy. The results demonstrated that the proposed method using SparsePCA coefficients and Naive Bayes classification outperformed the conventional methods. However, the proposed method still exhibited some misclassifications with high confidence, which is known as the overconfident problem. Therefore, future research should focus on developing methods to avoid the overconfident problem, such as integrating multiple classification methods.

References


- 1) C-N.E.Anagnostopoulos, I.E.Anagnostopoulos, I.D.Psoroulas, V.Loumos: " License Plate Recognition From Still Images and Video Sequences: A Survey ", IEEE Trans. on Intelligent Transportation Systems, Vol.9, No.3, September 2008
- 2) Ayumi Yoshikawa, Naoko Yoshikawa, Kazuhiro Fujita: " Equipment of discriminating symbol, Method of discriminating the symbol, and its computer program ", Patent 4243941 in Japan (2009/01/26)
- 3) Koji Shinomiya, Naoki Takamura, Kazuhiro Fujita, Nobuyuki Nakamori: " Discriminating Car License Plate Numbers on Low Resolution Using Moment Characteristics ", ITE Trans. on Media Technology and Applications, Vol.1, No.4, pp.271-277 (2013)
- 4) Hiroo Tsuji, Yohei Fukumizu, Takakuni Douseki, Hironori Yamauchi: " Hiragana Recognition of Degraded License Plate Image by Multistrcuture Convolutional Neural Network ", Journal of Signal Processing, Vol.22, No.3, pp.121-134 (2018 May)
- 5) Andreas C.Müller, Sarah Guido: " Introduction to Machine Learning with Python ", O'REILLY (2016)



Ryotaro Ooe received his B.E. and M.E. degrees from Ryukoku University, Japan in 2021, 2023, respectively. He works at currently at Kyocera Communication System Inc., Japan from April 2023. His research interests are image processing and pattern recognition.



Kazuhiro Fujita received his B.E., M.E., and Ph.D. degrees in electrical engineering from Kyoto Institute of Technology, Japan, in 1986, 1988, 1993, respectively. He joined Kyoto Institute of Technology as a research assistant in 1988. He was an associate professor at Kyoto Institute of Technology from 2003 to 2004. He moved to Ryukoku University in 2004 as an associate professor. He is currently a professor in Ryukoku University. His research interest is statistical image processing. He is a member of the IEEE, IEICE, ITE, and Japanese Association of Forensic Science and Technology.



Koji Shinomiya received his B.E. degree from Himeji Institute of Technology, Japan in 1993. He joined the Forensic Science Lab, Hyoto Prefectural Police H.Q. in 1993. He is currently engaged in identification and research of image and speech information processing. He is a member Acoustical Society of Japan, and Japanese Association of Forensic Science and Technology.