

最適な学習回数超過時におけるFLVQのパターン認識精度低下を抑制する 新しいクリस्प関数

New Crisp Functions for FLVQ to Improve a Reduction of Recognition Ability after the Optimal Training Count

吉田 嵩†
Takashi Yoshida

相川 直幸†
Naoyuki Aikawa

1. はじめに

近年、コンピュータの発達により、行動認識 [1] や文字認識 [2] といったパターン認識が盛んに研究・実用化されている。パターン認識とは、画像、音声などの雑多な情報を含むデータの中から、意味を持つ対象を選別して取り出す処理である。それらの多くは、人間の脳であれば至極当然に行えるが、コンピュータで実現するには認識精度・処理速度共に困難を伴う事が多い。近年、パターン認識は、どのクラスに分類するかという識別問題に帰着できるとした立場からの研究が成果を挙げている。それらの研究においては、機械学習により大量のデータから識別パラメータを構成する手法が主流となっている [3], [4]。

現在までに、様々な機械学習によるパターン認識手法が研究されてきた [3]-[7]。それらの多くは高い認識精度を持つが、未知カテゴリーの識別が困難である。それを解決するために、桜庭らによってFLVQ(Fuzzy Learning Vector Quantization)が提案された [8]。FLVQは、Kohonenによって提案されたLVQ1(Learning Vector Quantization)[9]をファジィ理論を用いて表現したアルゴリズムである。LVQのProcessing Element(PE)は、一般的なニューラルネットワークに用いられるような積和型のPEとは異なり、距離型のPEである。この距離型PEモデルをファジィ理論で表す事により、新しいニューラルネットワークモデルを構成した。その特徴として、入力と参照ベクトルが正規三角ファジィ数として与えられ、入力-参照間の距離の代わりに入力-参照間の類似度が用いられる事が挙げられる。入力ベクトルと最も類似度の高いPEを算出し、そのPEが属するカテゴリーに分類を行う。また、上記のPEモデルにより、測定誤差等によるあいまいさを直接扱うことが可能である。さらに、参照ベクトルにあいまいさを持たせる事は各参照ベクトルに領域を持たせることと等しく、それにより従来手法では困難であった未知カテゴリーの識別が可能となった。また、馬らによって、LVQ2[9]に基づいたFLVQの改良版である、FLVQ2が提案された [10]。FLVQ2では、最も類似度の高いPEと2番目に高いPEの2つを用いて更新を行う。FLVQ2は、FLVQよりも優れた認識精度をもち、また手書き文字の認識にも応用できることが示された [11]。

ところが、FLVQ、FLVQ2ともに、最も高いパターン認識精度が得られる学習回数(以下、最適な学習回数)を超えて学習を行った場合、パターン認識精度が

低下してしまうという問題点がある。この問題を回避するためには、一度学習を行い、最適な学習回数の情報を得た後、再度学習をやり直す必要がある。しかし、実際にFLVQ、FLVQ2を用いて解析を行う場合、1度の学習で高い認識精度を得ることが望ましい。

そこで本論文では、FLVQにおける最適な学習回数超過時のパターン認識精度低下を抑制するためのクリस्प関数を提案する。まず、最適な学習回数超過時に認識精度が低下する原因が、従来のクリस्प関数を用いた場合における逆方向への類似度の更新である事を示す。次に、類似度を正しく更新するために、クリस्प関数が満たすべき条件を導出し、その条件に基づいた新しいクリस्प関数を提案する。最後に、シミュレーションを通して、提案法が従来法と同等のパターン認識精度を持ちながら、最適な学習回数超過時におけるパターン認識精度低下を大幅に抑制できる事を示す。

2.FLVQ及びFLVQ2

ここでは、従来のFLVQ及びFLVQ2を簡単に示し、それらの問題点を明らかにする。

2.1. 認識

FLVQは4層ニューラルネットワークとなっており、 N 次元の入力層、類似度を計算する層、カテゴリーを決定する層、1次元の出力層から成り立っている。また、類似度を計算する層は、 M 個のPEから成り立っている。 i 番目のPEを $PE_i(i=1,2,3,\dots,M)$ とみると、 PE_i は N 次元参照ベクトル \mathbf{m}_i を持ち、1つのカテゴリー C_i に属する。まず、ネットワークに N 次元入力ベクトルを入力すると、各PEと入力ベクトルの類似度 $\mu_i(i=1,2,3,\dots,M)$ が計算される。その中から、最大の類似度 μ_c を持つ PE_c が決定され、その時の入力ベクトルをカテゴリー C_c と認識する($c \in i$)。

2.2. 学習アルゴリズム

今、 t 回目の更新時における N 次元入力(教師)ベクトルを $\mathbf{x}(t) = \{x_1(t), x_2(t), \dots, x_N(t)\}$ 、 $\mathbf{x}(t)$ のカテゴリーを C_x とする。また、 $\mathbf{m}_i(t) = \{m_{i1}(t), m_{i2}(t), \dots, m_{iN}(t)\}(i=1,2,\dots,M)$ とする。ここで、 $x_j(t)$ 、 $m_{ij}(t)(j=1,2,\dots,N)$ は、正規三角ファジィ数である。

FLVQの学習では、 PE_c の参照ベクトル $\mathbf{m}_c(t)$ が更新される。 $x_j(t)$ と $m_{cj}(t)$ の類似度を $\mu_{cj}(t)$ とおく

†東京理科大学基礎工学部電子応用工学科

と、 $m_c(t)$ は

$$m_{cj}(t+1) = \beta(t) * m_{cj}(t) + \alpha(t)[(1 - \mu_{cj}(t)) * (x_j(t) - m_{cj}(t))] \text{ for } Cc = Cx \quad (1a)$$

$$m_{cj}(t+1) = \gamma(t) * m_{cj}(t) - \alpha(t)[(1 - \mu_{cj}(t)) * (x_j(t) - m_{cj}(t))] \text{ for } Cc \neq Cx \quad (1b)$$

と更新される。ただし、全てのPEに対して類似度が0ならば、

$$m_{ij}(t+1) = \delta(t) * m_{ij}(t) \text{ for } \mu_i = 0 (i = 1, 2, \dots, M) \quad (1c)$$

によって全参照ベクトルを更新する(以下、発火なし)。なお、FLVQの演算は拡張原理[12]及び演算子‘*’[8]によって行われる事に注意されたい。式(1a)-(1c)における $\alpha(t)$, $\beta(t)$, $\gamma(t)$, $\delta(t)$ はクリस्प関数と呼ばれるノンファジイ関数である。文献[10]では、

$$\alpha(t) = 0.999 * \alpha(t-1) \quad \alpha(0) = 0.03 \quad (2a)$$

$$\beta(t) = 0.99 \quad (2b)$$

$$\gamma(t) = 1 - \alpha(t) \quad (2c)$$

$$\delta(t) = 1.02 \quad (2d)$$

としている。

一方、FLVQ2では、 $m_c(t)$ だけでなく、2番目に大きい類似度 $\mu_s(t)$ を持つPE_sにも注目し、

$$m_{cj}(t+1) = \gamma(t) * m_{cj} - \alpha(t)[(1 - \mu_{cj}) * (x_j(t) - m_{cj}(t))] \\ m_{sj}(t+1) = \beta(t) * m_{sj} + \alpha(t)[(1 - \mu_{sj}) * (x_j(t) - m_{sj}(t))] \text{ for } Cc = Cx \text{ and } Cs \neq Cx \quad (3)$$

を用いて更新される。ただし、 $m_s(t)$ は、PE_sの参照ベクトルを表す。また、発火なしの際は式(1c)を用いて全参照ベクトルを更新する。

2.3. 従来の学習アルゴリズムの問題点

FLVQ, FLVQ2の学習において、図1のように、最適な学習回数を超えた場合にパターン認識精度が低下する事がある。従って、実際にFLVQ, FLVQ2を識別器として用いる際には、最適な学習回数で学習をとめる必要がある。しかし、最適な学習回数は一度学習してみなければわからないため、2度学習を行うことになってしまう。そこで次節において、最適な学習回数超過時におけるパターン認識精度低下の原因がクリस्प関数である事を明らかにし、認識精度低下を抑制するためのクリस्प関数を提案する。

3. 提案法

ここでは、最適な学習回数超過時のパターン認識精度低下の原因を考えるために、FLVQの参照ベクトルにおける三角ファジイ数の中心値、あいまいさの更新

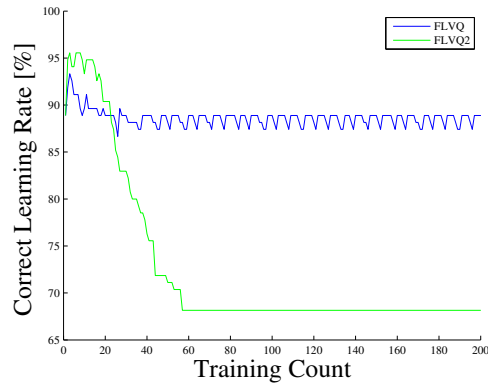


図1: 学習後半におけるパターン認識精度低下




図2: 三角ファジイ数

量について考察する。さらに、考察に基づき、認識精度低下を防ぐ新たなクリस्प関数を提案する。

3.1. 中心値の更新量及びあいまいさの更新量

今、図2に示すように、ある三角ファジイ数Fを、

$$F = (f, p, q) \quad (4)$$

と表す。fは三角ファジイ数の中心値、pは左端値、qは右端値である。また、fから見て左側のあいまいさ w_l 、右側あいまいさ w_r は、

$$w_l = f - p \quad (5a)$$

$$w_r = q - f \quad (5b)$$

と表される。式(4)を用いると、 $x_j(t)$ は、

$$x_j(t) = (f_x(t), p_x(t), q_x(t)) \quad (6a)$$

$$w_{lx}(t) = f_x(t) - p_x(t) \quad (6b)$$

$$w_{rx}(t) = q_x(t) - f_x(t) \quad (6c)$$

となり、 $m_{cj}(t)$ は、

$$m_{cj}(t) = (f_m(t), p_m(t), q_m(t)) \quad (7a)$$

$$w_{lm}(t) = f_m(t) - p_m(t) \quad (7b)$$

$$w_{rm}(t) = q_m(t) - f_m(t) \quad (7c)$$

となる。

認識能力低下の原因を調べるためには、どのように参照ベクトルが更新されているのかをノンファジィな値で観察する事が肝要である。ここで、式(6a)-(7c)は入力・参照ベクトルのノンファジィな表現である。また、参照ベクトルの更新量は、中心値の更新量、左側あいまいさの更新量、右側あいまいさの更新量に分ける事で、ノンファジィな観察が可能となる。従って以下では、式(6a)-(7c)を用いて中心値、左右のあいまいさそれぞれの更新量を算出する事で、認識能力低下の原因を明らかにする。

まず、中心値の更新量 $\Delta f_m(t)$ は、

$$\begin{aligned}\Delta f_m(t) &= f_m(t+1) - f_m(t) \\ &= \begin{cases} \alpha(t)\{f_x(t) - f_m(t)\} & \text{for } Cc = Cx \\ -\alpha(t)\{f_x(t) - f_m(t)\} & \text{for } Cc \neq Cx \end{cases}\end{aligned}\quad (8)$$

となる。従来の $\alpha(t)$ は式(2a)より、単調減少する関数である。従って、 $\Delta f_m(t)$ は必ず収束するため、認識精度低下の原因では無い。

次に、左右のあいまいさの更新量 $\Delta w_{lm}(t)$, $\Delta w_{rm}(t)$ は、

$$\begin{aligned}\Delta w_{lm}(t) &= w_{lm}(t+1) - w_{lm}(t) \\ &= \Delta f_m(t) - \Delta p_m(t)\end{aligned}\quad (9a)$$

$$\begin{aligned}\Delta w_{rm}(t) &= w_{rm}(t+1) - w_{rm}(t) \\ &= \Delta q_m(t) - \Delta f_m(t)\end{aligned}\quad (9b)$$

となる。ただし、

$$\Delta p_m(t) = p_m(t+1) - p_m(t) \quad (10a)$$

$$\Delta q_m(t) = q_m(t+1) - q_m(t) \quad (10b)$$

である。 $\Delta p_m(t)$, $\Delta q_m(t)$ は正認識時、誤認識時で値が変わるため、場合分けして考える。

3.2. 正認識時

まず、正認識時における参照ベクトルの左右エッジの更新量を求める。式(1a)を式(6a)-(7c)によって展開すると、

$$\begin{aligned}\Delta p_m(t) &= \Delta f_m(t) - (\beta(t) - 1)w_{lm}(t) \\ &\quad - \alpha(t)(1 - \mu_{cj}(t))(w_{lx}(t) + w_{rm}(t))\end{aligned}\quad (11)$$

$$\begin{aligned}\Delta q_m(t) &= \Delta f_m(t) + (\beta(t) - 1)w_{rm}(t) \\ &\quad + \alpha(t)(1 - \mu_{cj}(t))(w_{rx}(t) + w_{lm}(t))\end{aligned}\quad (12)$$

となる。従って、3.1で述べたように $\Delta w_{lm}(t)$, $\Delta w_{rm}(t)$ は、

$$\begin{aligned}\Delta w_{lm}(t) &= (\beta(t) - 1)w_{lm}(t) \\ &\quad + \alpha(t)(1 - \mu_{cj}(t))(w_{lx}(t) + w_{rm}(t))\end{aligned}\quad (13a)$$

$$\begin{aligned}\Delta w_{rm}(t) &= (\beta(t) - 1)w_{rm}(t) \\ &\quad + \alpha(t)(1 - \mu_{cj}(t))(w_{rx}(t) + w_{lm}(t))\end{aligned}\quad (13b)$$

となる。正認識時では、よりあいまいさを拡大させる事により、 $\mathbf{x}(t)$ との類似度がより高まるように更新を行いたい。従って、

$$\Delta w_{lm}(t) \geq 0 \quad (14a)$$

$$\Delta w_{rm}(t) \geq 0 \quad (14b)$$

を満たさなければならない。式(2a), (2b)に表した従来の $\alpha(t)$, $\beta(t)$ を用いて、 $\Delta w_{lm}(t)$, $\Delta w_{rm}(t)$ を表すと、

$$\begin{aligned}\Delta w_{lm}(t) &= -0.01w_{lm}(t) + 0.03 \times (0.999)^t \\ &\quad \times (1 - \mu_{cj}(t))(w_{lx}(t) + w_{rm}(t))\end{aligned}\quad (15a)$$

$$\begin{aligned}\Delta w_{rm}(t) &= -0.01w_{rm}(t) + 0.03 \times (0.999)^t \\ &\quad \times (1 - \mu_{cj}(t))(w_{rx}(t) + w_{lm}(t))\end{aligned}\quad (15b)$$

となる。ここで、正しいカテゴリーの類似度が1に近づくように学習を行うため、 $1 - \mu_{cj}(t)$ は学習が進むにつれ0に近づく。また、 $\alpha(t)$ も0に向かって単調減少する関数である。従って、学習の経過と共に、式(15a), (15b)の右辺第2項は0に近づいていくため、式(14a), (14b)を満たさなくなり正認識時に類似度が低下する。その結果として、認識精度の低下は発生する。そこで、常に式(14a), (14b)を満たすための $\beta(t)$ が必要である。なお、式(8)より、 $\alpha(t)$ は中心値の収束にも関わるパラメータである。式(2a)によって中心値が収束する事を考え、本論文では $\alpha(t)$ は従来の式(2a)を用いる。式(14a), 式(14b)を $\beta(t)$ について解くと、

$$\beta(t) \geq 1 - \frac{\alpha(t)(1 - \mu_{cj}(t))(w_{lx}(t) + w_{rm}(t))}{w_{lm}(t)} \quad (16a)$$

$$\beta(t) \geq 1 - \frac{\alpha(t)(1 - \mu_{cj}(t))(w_{rx}(t) + w_{lm}(t))}{w_{rm}(t)} \quad (16b)$$

が得られる。

ここで、式(16a), (16b)の右辺は各PE毎、各次元毎に異なった値を持ち得る。そこで提案法では、各PE毎に異なった値の $\beta(t)$ を持つものとする。以下では、 PE_i の $\beta(t)$ を $\beta_i(t)$ と表記する。ただし、 PE_i 内では全ての次元において同一の $\beta_i(t)$ が用いられるものとする。従って、 PE_i の全次元において式(16a), (16b)が成り立つように $\beta_i(t)$ は選ばれなければならない。その

ため,

$$B_{ijl}(t) = 1 - \frac{\alpha(t)(1 - \mu_{cj}(t))(w_{lx}(t) + w_{rm}(t))}{w_{lm}(t)} \quad (17a)$$

$$B_{ijr}(t) = 1 - \frac{\alpha(t)(1 - \mu_{cj}(t))(w_{rx}(t) + w_{lm}(t))}{w_{rm}(t)} \quad (17b)$$

$$B_{ij}(t) = \max\{B_{ijl}(t), B_{ijr}(t)\} \quad (17c)$$

$$B_i(t) = \max_j\{B_{ij}(t)\} \quad (17d)$$

とおくと, $\beta_i(t)$ が満たすべき条件は,

$$\beta_i(t) \geq B_i(t) \quad (18)$$

となる.

提案法では, 式(18)が常に満たされるように $\beta_i(t)$ を更新する. その際, 参照ベクトルの更新同様に, PE_c に属する $\beta_c(t)$ のみを更新するものとする. ここで, 最適な学習回数における FLVQ の高い認識精度を考慮すると, 式(18)を満たしている限り, $\beta_c(t)$ は定数で良い. 以上を踏まえて, 提案法では $\beta_c(t)$ を

$$\beta_c(t) = \begin{cases} 1 & \text{for } B_c(t) > 1 \\ B_c(t) & \text{for } \beta_c(t) < B_c(t) \\ \beta_c(t-1) & \text{for otherwise} \end{cases} \quad \text{and for } Cc = Cx \quad (19)$$

によって更新する.

3.3. 誤認識時

正認識時同様に, 誤認識時における参照ベクトルの左右エッジの更新量を求める. 求めた更新量から $\Delta w_{lm}(t)$, $\Delta w_{rm}(t)$ を求めると,

$$\Delta w_{lm}(t) = (\gamma(t) - 1)w_{lm}(t) + \alpha(t)(1 - \mu_{cj}(t))(w_{rx}(t) + w_{lm}(t)) \quad (20a)$$

$$\Delta w_{rm}(t) = (\gamma(t) - 1)w_{rm}(t) + \alpha(t)(1 - \mu_{cj}(t))(w_{lx}(t) + w_{rm}(t)) \quad (20b)$$

となる. 誤認識時では, よりあいまいさを収縮させる事により, $\mathbf{x}(t)$ との類似度を低くしたい. 従って,

$$\Delta w_{lm}(t) \leq 0 \quad (21a)$$

$$\Delta w_{rm}(t) \leq 0 \quad (21b)$$

を満たさなければならない. しかし, 式(2c)に表した従来の $\gamma(t)$ を用いて $\Delta w_{lm}(t)$, $\Delta w_{rm}(t)$ を表すと,

$$\Delta w_{lm}(t) = \alpha(t)[(1 - \mu_{cj}(t))w_{rx}(t) - \mu_{cj}(t)w_{lm}(t)] \quad (22a)$$

$$\Delta w_{lm}(t) = \alpha(t)[(1 - \mu_{cj}(t))w_{lx}(t) - \mu_{cj}(t)w_{rm}(t)] \quad (22b)$$

となる. 上記の通り, $\mu_{cj}(t)$ は1へと近づくため, 式(22a), (22b)は式(21a), (21b)を常に満たすように思える. しかし, $w_{rx}(t)$, $w_{lm}(t)$, $w_{lx}(t)$, $w_{rm}(t)$, $\mu_{cj}(t)$ のバランスによっては, 式(21a), (21b)を満たさない場合がある. 従って, 常に式(21a), (21b)を満たすための $\gamma(t)$ を考える必要がある.

式(21a), 式(21b)を $\gamma(t)$ について解くと,

$$\gamma(t) \leq 1 - \frac{\alpha(t)(1 - \mu_{cj}(t))(w_{rx}(t) + w_{lm}(t))}{w_{lm}(t)} \quad (23a)$$

$$\gamma(t) \leq 1 - \frac{\alpha(t)(1 - \mu_{cj}(t))(w_{lx}(t) + w_{rm}(t))}{w_{rm}(t)} \quad (23b)$$

が得られる.

ここで, 式(16a), (16b)同様に, 式(23a), (23b)の右辺は各 PE 毎, 各次元毎に異なった値を持ち得る. そこで, 以下では $\beta_i(t)$ 同様に, PE_i の $\gamma(t)$ を $\gamma_i(t)$ と表記する. ただし, PE_i 内では全次元において同一の $\gamma_i(t)$ を用いる. 従って, PE_i の全次元において式(16a), (16b)が成り立つように $\beta_i(t)$ は選ばなければならない. そのため,

$$G_{ijl}(t) = 1 - \frac{\alpha(t)(1 - \mu_{cj}(t))(w_{rx}(t) + w_{lm}(t))}{w_{lm}(t)} \quad (24a)$$

$$G_{ijr}(t) = 1 - \frac{\alpha(t)(1 - \mu_{cj}(t))(w_{lx}(t) + w_{rm}(t))}{w_{rm}(t)} \quad (24b)$$

$$G_{ij}(t) = \min\{G_{ijl}(t), G_{ijr}(t)\} \quad (24c)$$

$$G_i(t) = \min_j\{G_{ij}(t)\} \quad (24d)$$

とおくと, $\gamma_i(t)$ が満たすべき条件は,

$$\gamma_i(t) \leq G_i(t) \quad (25)$$

となる.

提案法では, 式(25)が常に満たされるように $\gamma_i(t)$ を更新する. その際, $\beta_c(t)$ 同様に, PE_c に属する $\gamma_c(t)$ のみを更新するものとする. また, 最適な学習回数における FLVQ の高い認識精度を考慮し, 式(25)を満たしている限り, $\gamma_c(t)$ は従来の式(2c)で良い. 以上を踏まえて, 提案法では $\gamma_c(t)$ を

$$\gamma_c(t) = \begin{cases} 0 & \text{for and } G_c(t) < 0 \\ G_c(t) & \text{for } \gamma_c(t) > G_c(t) \\ 1 - \alpha(t) & \text{for otherwise} \end{cases} \quad \text{and for } Cc \neq Cx \quad (26)$$

によって更新する.

4. シミュレーション

有名なパターン認識問題である, あやめ, 乳癌, ワインの分類問題 [13] を用いて提案法のパターン認識精度を評価する. 各問題に対して, 表1に示す条件でシミュレーションを行う. 教師, テストデータセットによる偏りを排除するために, 本論文では 10-Fold 交差検定

表1: 各パターン認識問題の仕様

| 問題 | 入力次元 N | カテゴリー数 | PE 数 M |
|-----|----------|--------|------------|
| あやめ | 4 | 3 | 3 |
| 乳癌 | 9 | 2 | 2 |
| ワイン | 13 | 3 | 3 |

[14] を用いて、下記の様にシミュレーションを行った。

1. 各問題について、データセットを10分割し、10個のサブセットを作成
2. 9個のサブセットを教師データセット、残りをテストデータセットとして使用
3. 最適な学習回数で学習を一旦ストップし、教師及びテストデータセットに対する正認識率を計算
4. 学習を再開し、計500回学習させ、教師及びテストデータセットに対する正認識率を計算
5. テストデータセットに用いられていないサブセットをテストデータセット、残りを教師データセットとし、3.へ
6. 全てのサブセットがテストに用いられたらシミュレーション終了

また、提案法のクリスプ関数の初期値は式(27)、従来法は式(2a)-(2d)とした。

$$\begin{aligned}
 \alpha(t) &= 0.99\alpha(t-1), \quad \alpha(0) = 0.03 \\
 \beta_i(0) &= 0.99 \\
 \gamma_i(0) &= 1 - \alpha(0) \\
 \delta(t) &= 1.02 \\
 &\quad (i = 1, 2, \dots, M)
 \end{aligned} \tag{27}$$

各問題について、教師、テストデータセットに対し、最適な学習回数、500回学習を行ったときの正認識率から、認識精度の低下率を求めた。得られた10パターンの結果から算出した平均値を表2に示す。なお、500回学習を行うのは、提案法、従来法共に認識能力の低下が収束していると判断するのに十分な回数と考えられるからである。表2より、提案法の低下率の低さがわかる。また、低下率が低いだけでなく、パターン認識精度自体も従来法と同等以上であることが見て取れる。

次に、提案法の認識精度低下抑制能力における初期値依存性を調べるために、 $\alpha(0)$, $\beta_i(0)$ を $\{0.03, 0.50, 0.99\}$ から1つずつ選び、9通りの初期値セットを作成し、3つの問題に対し再度シミュレーションを行った。その後、各初期セットに対し、表2同様に、平均の正認識率、低下率を求めた。得られた結果から、対象とする問題を問わず、最適な学習回数における各手法の最大

認識率、平均認識率を求めた。同様に、各手法の最大低下率、最小低下率、平均低下率も求めた。得られた結果を表3に示す。表3より、提案法はクリスプ関数の初期値に依らず高い認識精度を持ち、かつ認識精度低下を大幅に抑制できる事がわかった。

5. まとめ

本論文では、FLVQにおける最適な学習回数超過時における、パターン認識精度低下を抑制するための新しいクリスプ関数を提案した。従来のFLVQ及びFLVQ2では、最適な学習回数を超過した場合に、認識精度が低下する。そこで、まず、その原因として、従来のクリスプ関数を用いた場合にあいまいさが逆方向へ更新され、結果類似度も誤った方向へ更新される事を示した。次に、類似度を正しく更新するために、クリスプ関数が満たすべき条件を導出し、その条件に基づいた新しいクリスプ関数を提案した。最後に、シミュレーションを通して、提案法がクリスプ関数の初期値に依らず高い認識精度を持ち、かつ認識精度低下を大幅に抑制できる事を示した。

参考文献

- [1] 吉川正祥, 篠崎隆宏, 岩野公司, 古井貞熙, “軽量な画像特徴量を用いたマルチモーダル音声認識,” 電子情報通信学会論文誌 (D), Vol.J95-D, No.3, Mar.2012.
- [2] 太田貴大, 和田俊和, “局所特徴を用いた認識に基づく文字切り出し,” 電子情報通信学会論文誌 (D), Vol.95-D, No.4, Apr.2012.
- [3] C.M. ビショップ (元田浩 他監訳), “パターン認識と機械学習 上 - ベイズ理論による統計的予測,” 丸善出版, 2007.
- [4] C.M. ビショップ (元田浩 他監訳), “パターン認識と機械学習 下 - ベイズ理論による統計的予測,” 丸善出版, 2008.
- [5] H.A. Rowley, S.Baluja, T.Kanade, “Neural Network-Based Face Detection,” CVPR, Jun.1996.
- [6] F.-C. Lin, L.-W. Ko, S.-A. Chen, C.-F. Chen, C.-T. Lin, “EEG-based Cognitive State Monitoring and Prediction by Using the Self-Constructing Neural Fuzzy System,” ISCAS, May.2010.
- [7] 前川卓也, 渡部晋治, “ユーザーの身体的特徴情報を用いた行動認識モデルの学習手法,” 情報処理学会論文誌, Vol.53, No.7, Jul.2012.
- [8] 櫻庭祐一, 中本高道, 森泉豊榮, “ファジー理論を用いた学習ベクトル量子化法,” 電子情報通信学会論文誌 (D-2), Vol.73-D-2, No11, Nov.1990.
- [9] T. コホネン (大北正昭 他監訳), “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.

- [10] 馬化波, 桑田一仁, 亀井且有, 井上和夫, “改良形ファジー学習ベクトル量子化法 (FLVQ2) の提案,” 電子情報通信学会論文誌 (D-2), Vol.77-D-2, No4, Nov.1994.
- [11] 亀井且有, 福岡孝仁, “ファジィ学習ベクトル量子化法による手書き文字認識,” 日本ファジィ学会誌, Vol.10, No.5, Oct.1998.
- [12] 菅野道夫, “ファジィ制御,” 日刊工業新聞社, 1990.
- [13] A. Frank, A. Asuncion, “UCI Machine Learning Repository,” <http://archive.ics.uci.edu/ml>, 2010.
- [14] R. Kohavi, “A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection,” IJCAI'95 Proceedings of the 14th international joint conference on Artificial intelligence, Vol.2, 1995.

表 2: 教師, テストデータセットに対する正認識率

| | | FLVQ | | FLVQ2 | | 提案法 | |
|-----|-------|--------|--------|--------|--------|-------|-------|
| | | 教師 | テスト | 教師 | テスト | 教師 | テスト |
| あやめ | 最適回数 | 93.56 | 92.67 | 96.15 | 96.00 | 95.93 | 95.33 |
| | 500 回 | 90.52 | 89.33 | 67.70 | 68.00 | 95.93 | 95.33 |
| | 低下率 | -3.04 | -3.33 | -28.44 | -28.00 | 0.00 | 0.00 |
| 乳癌 | 最適回数 | 83.90 | 83.73 | 96.50 | 96.27 | 96.10 | 95.97 |
| | 500 回 | 60.85 | 60.30 | 34.33 | 34.33 | 96.10 | 95.97 |
| | 低下率 | -23.05 | -23.43 | -62.17 | -61.94 | 0.00 | 0.00 |
| ワイン | 最適回数 | 90.63 | 88.75 | 94.17 | 90.00 | 90.56 | 88.75 |
| | 500 回 | 77.50 | 70.63 | 56.46 | 55.63 | 90.56 | 89.38 |
| | 低下率 | -13.13 | -18.13 | -37.71 | -34.38 | 0.00 | 0.63 |

表 3: 正認識率, 低下率のクリスプ関数初期値依存性

| | | FLVQ | | FLVQ2 | | 提案法 | |
|----------|-----|--------|--------|--------|--------|-------|-------|
| | | 教師 | テスト | 教師 | テスト | 教師 | テスト |
| 正認識率 [%] | 最大値 | 95.48 | 94.67 | 96.50 | 96.27 | 96.15 | 96.67 |
| | 平均値 | 42.72 | 39.81 | 75.49 | 74.19 | 93.29 | 92.58 |
| 低下率 [%] | 最大値 | -41.82 | -42.84 | -62.17 | -61.94 | -0.30 | -1.25 |
| | 最小値 | -1.63 | -0.30 | 0.00 | 0.00 | 0.00 | 0.63 |
| | 平均値 | -16.10 | -15.63 | -27.18 | -26.49 | -0.04 | -0.03 |