

GLVQ클러스터링을 위한 필기체 숫자의 효율적인 특징 추출 방법

전 종 원* 민 준 영**

요 약

패턴인식은 전처리, 특징추출, 식별의 과정을 거쳐 인식을 하게된다. 식별과정에서 여러개의 패턴이 출력되어 있을 경우에 유사한 패턴끼리 클러스터링을 하여 한 카테고리 내에서 패턴을 분할하게 된다. 클러스터링 방법에는 통계적인 방법으로 k-means방법, ISODATA알고리즘등이 있으며[1], 최근에는 신경망에 의한 클러스터링 방법으로 T. Kohonen의 LVQ(Learning Vector Quantization)가 주로 이용되었다[6]. Nikhil R. Pal, et al은 LVQ알고리즘을 보다 개선한 방법으로 GLVQ(Generalized LVQ, 1993)를 제안하였다[4]. 본 논문은 GLVQ 알고리즘으로 패턴을 클러스터링 할 경우에 효율적인 특징추출 방법을 제안한다. 본 논문에서는 20명의 필기체 숫자 0에서 9까지의 200개 패턴을 여러가지 방법으로 특징추출하여 GLVQ알고리즘으로 10개(0-9의 패턴)의 클러스터로 구분하고, 해당 클러스터에서 오분류되는 패턴의 비율로서 그 효율성을 비교하였다. 그 결과 투영조합 방법을 이용하였을 경우 98.5%의 분류율을 나타내었다.

The Efficient Feature Extraction of Handwritten Numerals in GLVQ Clustering Network

Jeon Jong Won* Min Joon Young**

ABSTRACT

The structure of a typical pattern recognition consists a pre-processing, a feature extraction(algorithm) and classification or recognition. In classification, when widely varying patterns exist in same category, we need the clustering which organize the similar patterns. Clustering algorithm is two approaches. First, statistical approaches which are k-means, ISODATA algorithm. Second, neural network approach which is T. Kohonen's LVQ(Learning Vector Quantization). Nikhil R. Pal et al proposed the GLVQ(Generalized LVQ, 1993). This paper suggest the efficient feature extraction methods of handwritten numerals in GLVQ clustering network. We use the handwritten numeral data from 20's authors(ie, 200 patterns) and compare the proportion of misclassified patterns for each feature extraction methods. As results, when we use the projection combination method, the classification ratio is 98.5%.

1. 서 론

필기체 문자 패턴은 그 형태가 필기자에 따라 다양하기 때문에 특징추출과 인식에 많은 어려움이 따른다. 패턴인식시스템은 데이터 입력부와 전처리단계, 특징추출단계, 그리고 정해진 클래

스에 데이터를 할당하는 분류단계로 나누어진다.

일반적으로 사용하는 특징 추출 방법에는 Fourier transform, multivariate Analysis, K-L변환(Karhunen-Loeve transform)등이 있으나 그 이론을 세우기가 어려운 실정에 있다. 특징추출 단계를 거쳐 식별하는 방법에는 이론적 방법과 구조해석적인 방법이 있으나 최근에는 신경망에 의한 방법들이 연구되어지고 있다[7].

신경망은 교사학습(supervised learning)과 무

* 정 회 원 : 상지대학교 병설전문대학 전자계산학과 교수
** 정 회 원 : 상지대학교 병설전문대학 전자계산학과 교수
논문접수 : 1995년 3월30일, 심사완료 : 1995년 9월 29일

교사학습(unsupervised learning)으로 크게 구분할 수 있는데 교사학습일 경우에는 본 논문에서는 무교사학습을 통한 패턴의 분류를 이용하였다. 무교사 학습에서의 패턴 분류방법에는 T. Kohonen의 LVQ(Learning Vector Quantization)알고리즘, Carpenter와 Grossberg의 ART1(Adaptive Resonance Theory 1), ART2가 있으며, 최근에 발표된 것으로 Nikhil R. Pal et. al.의 GLVQ(Generalized LVQ)가 있다.


기존의 특징추출방법에 대한 연구는 문자패턴의 획의 정보로부터 특징을 추출하는 방법을 사용해왔다.[9, 10, 11, 12] 본 논문에서는 GLVQ 클러스터링 네트워크를 이용한 패턴 분류를 하기 위하여 획 성분 뿐만아니라 여백정보에 대한 특징추출을 포함한 여러가지 특징추출 방법을 적용하여 그 분류비율을 비교함으로써 가장 분류율이 높은 특징추출방법을 유도한다. 특징추출과정에 있어서 입력 데이터에 대한 전처리로 패턴의 최소영역을 추출하여 일정한 크기로 정규화하였으며 분류 알고리즘의 특성을 알아보는 데 중점을 두기 위해 기타 잡음제거나 세선화등과 같은 전처리 과정은 생략하였다. 본 논문의 구성은 다음과 같다. 2장에서는 GLVQ알고리즘에 적용한 특징추출 방법을 기술하였고, 3장에서는 무교사 학습에서 패턴 분류를 하는 Pal의 GLVQ알고리즘을 소개하였다. 4장에서는 필기체 숫자에서 특징을 추출하여 GLVQ알고리즘에 적용한 결과를 비교하였고, 5장에서 결론을 맺는다.

2. 전처리 및 특징추출

2.1 정규화(normalization)

본 논문에서의 실험 데이터는 필기체 숫자 패턴이다. 따라서 동일한 패턴이라 할지라도 데이터의 형태가 다양하고 그 변화를 거의 예측할 수 없다. 이러한 점에서 입력된 이진 영상패턴에 대해 규격화하는 과정이 필요하며 이는 특징추출에 있어서도 효과적인 처리효과를 가져온다. 여기에서는 두 가지 단계를 거쳐 입력 패턴을 정규화하였다. 먼저, 정보점이 존재하는 최소한의 영역으로 처리영역을 설정하였다. 따라서 처리 데이

타량의 감소와 시간을 감소할 수 있다. 이와같이 처리영역이 설정된 영상패턴에 대해서 규격보다 큰 글자는 축소시키고 또한 규격보다도 작게 입력된 패턴에 대해서는 확대하므로써 10×10으로 스케일링(scaling)하였다.



(그림 1) 전처리
(Fig.1) Preprocessing

2.2 특징추출

여기에서는 GLVQ알고리즘의 클러스터링에 관한 분석과 패턴인식의 응용 가능성을 확인하기 위해 몇가지 다른 종류의 특징들을 추출하여 실험 하였다. 실험 대상으로 적용 범위가 많은 필기체 숫자를 택하였으며, 20명의 다른 필기자로 부터 각각 0에서 9까지 10개의 숫자 패턴을 입력하게 하였다.

2.2.1 이진 데이터(Binary data)

이진 영상패턴의 정보점 1과 비정보점 0를 그대로 알고리즘의 Attribute로 사용하였다. 따라서 Attribute의 총 수는 100개이다.

2.2.2 분할패턴 비율(Block pattern ratio)

입력 패턴을 3×3 과 4×4크기로 분할하여 각각 9개,16개의 블록패턴으로 분할하였다. 3×3 분할패턴의 블록은 25%씩 중첩시켜 각 블록의 크기는 4×4가 되며 4×4 분할패턴의 블록은 50%씩 중첩시켜 각 블록의 크기는 4×4로 하였다.

이와같은 방법으로 생성된 각 블록내의 정보점, 즉 획성분을 패턴 전체의 정보점 수로 나누어 그 비율을 Attribute로 사용하였다.

$$\text{Attribute} = \frac{\text{블러내 정보점 수} \times 10}{\text{전체 패턴의 정보점 수}}$$

, (정보점=1, 비정보점=0) (식 1)

1.9	1.7	1.4
1.4	0.0	1.4
1.7	1.7	1.9

(a) 3 × 3


2.4	2.2	1.8
1.9	0.2	1.8
2.2	2.3	2.4

(b) 4 × 4

(그림 2) 3×3 분할패턴의 Attribute (숫자 '0')
(Fig. 2) Attribute of pattern divided by 3×3
(Numeral '0')

2.2.3 블러링(Blurring)

이진 영상패턴에서는 정보점이 존재하는 영역과 존재하지 않는 영역에 각각 1과 0을 할당한다. 이것을 정보점이 존재하는 영역과 존재하지 않은 영역 그리고 경계부분에 각각 다른 가중치를 주어서 정보점이 밀집되어 있는 부분으로 갈수록 그 값이 점점 크고 반대로 여백공간으로 갈수록 그 값이 점점 작아지도록 블러링처리하였다. 즉, 정보점이 존재하는 위치를 중심으로 3×3 영역내에 화소값을 1씩 증가시켜 결국 정보점이 존재하는 중심부의 값이 가장 크고 중심부에서 멀어질수록 그 값이 감소되게 하였다. 이것은 필기자에 따라 다양한 필기형태가 나타남으로 크기와 위치 변화를 더욱 감쇄시키고 잡음에 대한 영향을 감소시킨다. 처리결과 (그림 3)과 같이 데이터가 둥고선 형태로 나타나게 된다.



(그림 3) 블러링 매트리뷰트(숫자 '2')
(Fig. 3) Blurring attributes(numeral '2')

2.2.4 블러링 분할패턴 비율(Blurring block pattern ratio)


블러링 패턴을 2.2.2에서와 같이 다시 블러패턴으로 분할하여 그 비율을 Attribute로 사용하였다. 2.2.2와의 차이점은 처리 데이터가 다소 연속적인 특성을 갖는다는 점이다.

2.2.5 방향 투영(Projection)

지금까지는 획 성분의 점의 분포나 또는 획의 변화 성분을 특징으로 하였다. 이것을 반대 관점에서 서서 획과 획 사이의 여백부분을 특징으로 처리하기 위해서 획 성분에 접근하기까지 각 방향에서 투영하여 여백부분에 (표 1)과 같이 고유 코드값을 할당하였다. 즉, 좌,우,상,하 방향에서의 여백부분과 좌우,상하등 두 방향에서 모두 여백으로 나타나는 부분 그리고 숫자 '0'의 중심부 분등에서 나타나는 폐쇄점등으로 분류하여 각각 처리코드를 부여하였다. 이와같이 처리할 경우

(표 1) 방향투영 처리 코드
(Table 1) projection coding

투영각	코드	투영각	코드
좌측	C2	상.하측	C24
우측	C4	좌.상측	C10
상측	C8	좌.하측	C18
하측	C16	우.상측	C12
좌.우측	C6	우.하측	C20
정보점	C1	폐쇄점	C0



(그림 4) 투영 매트리뷰트의 예(숫자 '4')
(Fig. 4) Example of Projection attribute(numeral '4')

Attribute수는 10개가 되며 처리결과는 (그림 4)와 같다.

2.2.6 방향 투영 조합(Projection combination)

투영처리 결과값, 비율, 중심값 그리고 이들 특성들의 조합으로 10개의 Attribute을 구성하였다. 이들 Attribute는 <표 2>와 같다.

<표 2> 조합 코드
(Table 2) Combination code

Attr.No	Feature
#1	c0—ratio
#2	c5+c6+c1 or c9+c14+c1
#3	c3—center - c4—center
#4	c4+c1
#5	c1+c5+c9+c14
#6	c4—center - c3—center
#7	c0—center
#8	c5+c9+c4+c8-c6-c14-c3-c1-c0
#9	c0—No
#10	c0+c1

3. GLVQ(Generalized LVQ)

LVQ알고리즘에서는 초기 연결강도(weight vector) v_{ir} 에 의해서 클러스터링 결과가 많은 영향을 받기 때문에 Nikhel R. Pal et. al.은 학습을 winner 뿐만 아니라 non-winner도 같이 학습을 시키는 Generalized Learning Vector Quantization(GLVQ) 클러스터링 알고리즘을 제안하였다. GLVQ는 손실함수(loss function) L_s (식 2)를 최소화 시키는 학습방법을 적용하였다.[4]

$$L_s = \sum_{r=1}^c g_{ir} \|x - v_r\|^2 \tag{식 2}$$

$$g_{ir} = \begin{cases} 1 & \text{if } r=i \\ \frac{1}{\sum_{r=1}^c \|x - v_r\|^2} & \text{if } r \neq i \end{cases}$$


여기서 winner일 경우에는 L_s 를 v_i (winner class center)로 미분하고, non-winner일 경우에는 v_j (non-winner class center)로 미분하여 (식 3)과 (식 4)로써 학습을 한다.

$$v_{ir} = v_{ir-1} + \alpha_i(x_k - v_{ir-1}) \frac{D^2 - D + \|x_k - v_{ir-1}\|^2}{D_2} \tag{식 3}$$

$$v_{ir} = v_{ir-1} + \alpha_i(x_k - v_{ir-1}) \frac{\|x_k - v_{ir-1}\|^2}{D_2} \text{ if } r \neq i \tag{식 4}$$

$$D = \sum_{r=1}^c \|x - v_r\|^2$$

GLVQ의 네트워크의 구성은 (그림 5)와 같다.



(그림 5) GLVQ 네트워크
(Fig. 5) GLVQ Network

GLVQ의 특징으로는 연결강도의 초기값에 영향을 받지 않고 클러스터링을 할 수 있으며, 학습이 완료된 후의 각 class center의 오차도 매우 근소하다.

각 단계별 GLVQ 클러스터링 알고리즘은 다음과 같다.

GLVQ 클러스터링 알고리즘[4]

[단계 1] 패턴벡터 $X = \{x_1, x_2, \dots, x_n\} \subset R^p$

$c, T, \epsilon > 0$ 결정.

c : 클러스터의 수.

T : 최대 반복횟수.

ϵ : $\|v_t - v_{t-1}\|$ 의 허용오차.

[단계 2] 초기weight 결정. $V_0 = (v_{1,0}, \dots, v_{c,0}) \in R^p$

초기 학습률 결정. $\alpha_0 \in (1, 0)$

[단계 3] For $t=1, 2, \dots, T$. 반복횟수에 따라 학습률 계산. $\alpha_t = \alpha_0(1 - t/T)$

For $k=1, 2, \dots, n$;

a. 승자노드의 발견.

$$\|X_k - V_{ir-1}\| = \min_{1 \leq j \leq c} \{ \|x_k - v_{j,t-1}\| \}$$

b. 승지노드 및 승자가 아닌 노드의 weight수정

$$v_{it} = v_{i,t-1} + \alpha_i(x_k - v_{i,t-1}) \frac{D^2 - D + \|x_k - v_{i,t-1}\|^2}{D^2}$$

승자노드인 경우

$$v_{it} = v_{i,t-1} + \alpha_i(x_k - v_{i,t-1}) \frac{\|x_k - v_{i,t-1}\|^2}{D^2} \quad (r \neq i)$$

승자노드가 아닌 경우

Next k.

[단계 4] 에러계산. $E_t = \sum_{k=1}^n \sum_{i=1}^c |v_{ik,t} - v_{ik,t-1}|$.

[단계 5] if $E_t \leq \epsilon$ then STOP; Else Next t.

$$U_{LVQ,i} = \begin{cases} 1: \|x_k - v_j\| \leq \|x_k - v_j\|, 1 \leq j \leq c, j \neq i \\ 0: otherwise. \end{cases} \quad 1 \leq i \leq c \quad \text{and} \quad 1 \leq k \leq n.$$

$U_{LVQ} = [u_{LVQ,i}] : c \times n$ 행렬로써 x_k 패턴이 클러스터 c 에 포함되어 있는 상태를 나타내는 행렬.

실제로 Nikhil R. Pal은 Anderson의 IRIS데이터를 가지고 반복횟수와 학습률을 변화시켜 가면서 LVQ와 GLVQ로 클러스터링 한 결과를 비교하였는데 GLVQ는 150개의 IRIS데이터중 에러의 갯수가 17개로 일정한 반면에 LVQ인 경우에는 학습률에 따라 100개에서 17개의 에러를 나타내고 있다.

4. 실험결과

필기체 숫자를 실험 대상으로 하였던 데이터 패턴은 필기자에 따라 패턴의 변화가 심한 특성을 갖는다. 따라서 클러스터링 효과가 뛰어난 GLVQ알고리즘을 적용한 바 필기체 패턴 인식의 가능성을 확인할 수 있었다. 알고리즘의 실험결과로 알 수 있듯이 Attribute수와 클러스터링 성공률은 비례하지 않으며 오히려 Attribute수의 증가가 분류율을 저하시키는 효과를 가져왔다.

〈표 3〉에서와 같이 2진 데이터를 Attribute로 사용한 경우 극히 저조한 분류율을 보였으며 패턴의 왜곡에 둔감한 블러링에서는 이보다 높은 분류율을 그리고 패턴의 분할 처리의 경우 보다 높은 분류율을 보였다. 마지막으로 패턴의 왜곡에 보다 덜 민감한 여백의 투영 조합 값을 At-

tribute로 사용한 경우 가장 높은 분류율이 나타났는데 필기체 패턴의 경우 획의 변화에 비하여 그 여백 성분의 변화도는 훨씬 둔감하기 때문에 여백정보 또한 중요한 특징 파라미터로 이용할 수 있음을 확인할 수 있었다.

$$\text{분류율} = \frac{\text{총패턴 수} - \text{오분류 패턴 수}}{\text{총 패턴 수}} \times 100(\%) \quad (\text{식 } 5)$$

〈표 3〉 분류율 비교
(Table 3) comparison of classification

특징추출방법	attribute 수	분류율(%)	혼합분류 패턴군
2진 데이터	100	61.5	(5, 6), (7, 9)
분할패턴 비율	9	89.5	
블러링	100	82.5	(5, 6)
블러링 분할패턴 비율	9	92.5	
방향 투영	100	87.5	(4, 9)
방향 투영 조합	10	98.5	

Projection조합에 의한 특징추출방법을 이용하였을 경우 GLVQ학습결과는 〈표 4〉와 같다.

〈표 4〉 학습 결과
(Table 4) Learned results

```
input file : INPUT6.dat
Output file : jm10.out
Tolerant Error : 0.000100
Initial Alpha 0.400000
Number of Cluster : 10
Maximum iteration : 10000
Number of Patterns : 200
Number of Attributes : 10

Final Centers of Each Cluster
Cluster : 0
4.33957 4.33959 4.33961 7.33938 13.33795
4.77856 4.50778 8.49426 4.33964 4.77906
Cluster : 1
3.76295 3.76297 3.76300 7.04647 7.47839
3.76291 3.90622 7.32738 6.43600 11.76019
Cluster : 2
11.95099 4.95431 4.95433 7.95418 8.68603
4.95426 7.35980 4.95472 8.95399 4.95435
Cluster : 3
4.20947 4.20949 4.84485 8.62775 7.36933
4.42145 4.20963 13.20760 4.20953 4.42043
Cluster : 4
3.52430 3.52433 3.90889 6.52405 7.66182
4.48577 12.37901 3.66914 6.56380 3.52437
```

Cluster : 5

2.39680 2.39685 6.39644 5.99062 6.30898
10.39600 4.94704 6.15059 2.39712 2.39691

Cluster : 6

3.99715 3.99717 3.99719 8.19877 7.74815
3.99710 7.90116 4.14972 11.99432 3.99720

Cluster : 7

3.19977 3.19980 11.19852 7.24325 6.66258
6.19644 4.84693 6.19974 3.19996 3.19985

Cluster : 8

1.80513 1.80520 5.80472 10.66179 3.66801
6.00119 3.80353 7.38003 1.80555 1.99906

Cluster : 9

4.24998 11.24772 4.25001 7.24978 6.50065
4.24992 7.24981 10.24969 4.25004 4.25003

Final Patterns of each Cluster

Cluster : 0

4 14 24 34 44 54 64 74 84 94
104 114 144 154 164 174 184 194

Cluster : 1

9 19 29 39 49 59 69 79 89 99 109 119
129 134 139 149 159 169 179 189 199

Cluster : 2

0 10 20 30 40 50 60 70 80 90 100
110 120 130 140 150 160 170 180 190

Cluster : 3

7 17 27 37 47 57 67 77 87 107 117
127 137 147 157 167 177 187 197

Cluster : 4

6 16 26 36 46 56 66 76 86 96 106 116
124 126 136 146 156 166 176 186 196

Cluster : 5

5 15 25 35 45 55 65 75 85 95 105
115 125 135 145 155 165 175 185 195

Cluster : 6

8 18 28 38 48 58 68 78 88 98 108
118 128 138 148 158 168 178 188 198

Cluster : 7

2 12 22 32 42 52 62 72 82 92 102
112 122 132 142 152 162 172 182 192

Cluster : 8

3 13 23 33 43 53 63 73 83 93 97
103 113 123 133 143 153 163 173 183 193

Cluster : 9

1 11 21 31 41 51 61 71 81 91
101 111 121 131 141 151 161 171 181 191

5. 결 론

패턴인식에 있어서 전처리, 특징추출, 분류 알고리즘 모두 중요하지만 이들 상호간의 적합한 연관관계 또한 중요하다. 분류 알고리즘에 적합한 특징을 추출할 것과 반대로 추출된 특징에 적합한 분류 알고리즘의 선택이 전체적인 시스템에

보다 중요하다는 것을 확인하였다.

필기체 문자의 효율적 식별을 위해 여러가지 특징들을 추출한 후, GLVQ알고리즘을 이용하여 분류율을 비교한 결과 방향 투영값들의 조합에 의한 특징을 이용한 경우 가장 높은 분류율을 보였다.

따라서 필기체와 같은 패턴의 변형이 심한 경우 획의 성분보다 획들에 의해서 분할된 여백을 특징으로 사용할 경우 보다 높은 분류율을 얻을 수 있음을 확인 할 수 있었다.

앞으로 이와같이 방법에 의해 얻어진 특징과 분류알고리즘을 좀 더 개발한다면 필기체 한글인식에서도 효과적인 결과가 기대되며 앞으로의 연구과제이다. 또한 이 분류알고리즘은 문자패턴뿐만 아니라 다른 다변량 데이터에 대해서도 적용가능하리라고 생각된다.

참 고 문 헌

[1] Helge Ritter, Thomas Martinets, Klaus Schulten, 'Neural Computation and Self-Organizing Maps', Addison-Wesley Publishing Co. Inc., 1992.
[2] John Hertz, Anders Krogh, Richard G. Palmer, 'Introduction to the Theory of Neural Computation', Addison-Wesley Publishing Co. Inc., 1991.
[3] M.A.Ismail and M.S.Kamel, "Multidimensional Data Clustering Utilizing Hybrid Search Strategies", Pattern Recognition, Vol. 22, No. 1, 1989, pp.75-89.
[4] Nikhil R. Pal, James C. Bezdek, Etric C. K.Tsao, "Generalized Clustering Networks and Kohonen's Self-Orgrnizing Scheme", IEEE Trans. on Neural Networks, Vol. 4, No. 4, 1993, pp.549-557.
[5] Robert Schalkkoff, 'Pattern Recognition -statistical structureal and approaches', John and Wiley & Sons, Inc., 1992.
[6] T. Kohonen, "The Self-Organizing Map", Proc. IEEE, Vol. 78, No. 9, 1990, pp. 1464-1480.

- [7] Yoh-Han Pao, 'Adaptive Pattern Recognition and Neural Network', Addison-Wesley Publishing Co. Inc., 1989.
- [8] 김대수, '신경망 이론과 응용 (I),(II)', 하이테크정보,1994.
- [9] C. Y. Suen, C.Nadal, R. Legault, T. A. Mai, and L. Lam, "Computer Recognition of Unconstrained Handwritten Numeral", Proc. of the IEEE, Vol.80, No. 7, July 1992, pp.1162-1180.
- [10] C. Nadal and C. Y. Suen, "Reconition of Totally Unconstrained Handwritten Digit by Decomposition and Vectorisation", Technical Report, Concordia University, Montreal,Canada, 1988.
- [11] L. Lam and C. Y. Suen, "Structural Classification and Relaxation Matching of Totally Unconstrained Handwritten Zip-Code Numbers", Pattern Recognition, Vol.21, No. 1, 1988,pp 19-31.
- [12] T. May and C. Y. Suen, "A Generalized Knowledge-based System for the Recognition Unconstrained Handwritten Numerals", IEEE Trans. on Systems, Man and Cybernetics, Vol. 20, No. 4, 1990, pp835-848.



전 종 원

1987년 경희대학교 전자공학과 졸업
 1989년 경희대학교 대학원 전자공학과 공학석사
 1995년 경희대학교 대학원 전자공학과 박사과정 수료
 1992년~현재 상지대학교 병설

전문대학 전자계산과 조교수
 관심분야 : 영상신호처리, 신경회로망



민 준 영

1982년 아주대학교 산업공학과 졸업.(학사)
 1989년 성균관대학교 경영대학원 정보처리학전공(석사)
 1995년 성균관대학교 대학원 전산통계전공(박사)
 1993년~현재 상지대학교병설전

문대학 전자계산과 전임강사.
 관심분야 : 신경회로망, 패턴인식.