

卒業論文

文字認識における辞書のマルチ
テンプレート化に関する研究

東北大学工学部 電気・情報系

阿曾研究室

孫方

平成6年3月25日

目次

第1章 序論	3
1.1 本研究の背景と目的	3
1.2 本論文の構成	5
第2章 文字認識	6
2.1 文字入力	8
2.2 前処理	8
2.3 特徴量抽出	8
2.4 認識	11
2.4.1 辞書の作成	11
2.4.2 評価値	13
2.5 候補出力	13
第3章 文字特徴量の分布	14
3.1 はじめに	14
3.2 分布状況	14
3.2.1 主成分分析法	14
3.2.2 分布状況の調査結果	15
3.3 特徴領域の重なり	21
3.3.1 領域半径	21
3.3.2 重なり具合の調査結果	21
3.4 まとめ	22

第4章 マルチテンプレート化の手法	23
4.1 はじめに	23
4.2 マルチテンプレート辞書作成のアルゴリズム	23
4.3 カテゴリを分割する条件	26
4.4 認識実験	28
4.5 まとめ	28
第5章 結論	30
謝辞	31
参考文献	32

第 1 章

序論

1.1 本研究の背景と目的

情報処理技術の急速な発展にともない、計算機の扱う情報の量はますます増大し、多用化、複雑化している。しかし、計算機の発展の速度に比べ、人間と計算機間の情報交換手段、いわゆるマン・マシンインターフェースはそれほど改善されていない。もし、我々が普段情報交換のために用いている、紙に書かれた、あるいは印刷された文字を自動的に計算機に入力できれば、それは人間にとって訓練の必要がなく、わかりやすく、容易な手段と言える。さらに、近年では OA 化により、ワープロやファックス、コピー機などの事務機器が産業から家庭に広がっており、大量の文書が出回っている。このような大量の文書の保存、変更、管理を計算機によって行なうという社会的要求が強まってきた。そういう意味において、急速に発展している情報化社会のなかで、文字認識技術の重要さは音声、画像技術と並んで、ますます重みが増してくると考えられる。

文字認識についての研究は約三十年前から行なわれ、種々の成果が得られている。現在、特定の分野においては OCR(Optical Character Reader) が実用化されている。しかし、現状では認識率 100%の文書認識システムは完成されておらず、どうしても誤認識を生じてしまう。誤認識がある場合には、修正に手間がかかり過ぎるために多くの労力が必要とされる。このため、大量の文書認識の自動化が困難となっており、文書認識の完全な自動化に大変期待が寄せられている。

文字認識において、単一フォントの活字を扱う場合と比較して、マルチフォントの活字や手書き文字を扱った場合の認識率はかなり低い。対策として、パターンの変形に強い特徴量の開発 [3]、入力パターン [4] や辞書パターン [5] を変形する手法、字種ごとに複数の辞書を用意する方法 (マルチテンプレート法) [6][7][8] 等が検討されている。

このうち、マルチテンプレート法はアルゴリズムが簡単であり、既存の認識システムに組み込むことが容易であるという利点がある。しかし、マルチテンプレート化を行うことにより辞書のカテゴリ数が大きくなり、誤認識となる字種が出現する可能性が大きくなるなどの悪影響も考えられる (カテゴリとは、同等とみなされるものの集合である)。

マルチテンプレート法についてこれまで様々な研究が行われてきた。斐ら [6] は、テンプレート数を固定し、クラスタリングアルゴリズムを変えてテンプレートを作成し、認識実験を行い、4つのクラスタリング手法のうち、simple algorithm が一番よいという結論を得ている。八代 [7] は、手書き文字を対象にクラスタリングアルゴリズムと一字種あたりのテンプレート数を様々に変えて実験を行っている。クラスタリング法は3種類の中で LBG 法が一番よい、テンプレート数は一字種あたり 32 個のとき一番いい認識率が得られた、などの結果が得られている。加藤ら [8] は、明朝体、ゴシック体、その他の辞書を持ち入れ替えて用いる手法が提案されている。エラー率関数を用い、最初に一部を認識し、人が介在することで辞書の配置を替える (ディスク上の辞書のうち、必要なものをメモリに持ってきて使う)。しかし、これらの研究では、同一カテゴリ内の最適なテンプレート数の判断法についての検討はなされていない。また、カテゴリ間の分布についてはほとんど考慮されていない。

本研究では、認識率を下げずにマルチテンプレート法における認識用辞書の総カテゴリ数を抑えることを目的とする。まず、統計的な手法を用いて、空間上での特徴量の分布状況を調べる。そして、総カテゴリ数を抑えたマルチテンプレートの辞書を人が介在せずに作成する手法について述べ、実験によりその有効性を確認する。

1.2 本論文の構成

第 1 章 序論であり、本研究の背景と目的について述べる。

第 2 章 文字認識アルゴリズムについて説明する。

第 3 章 文字特徴量の分布を調べる。具体的には、主成分分析法を用いて、カテゴリ間分布とカテゴリ内分布を調べ、領域半径の概念を用いて特徴領域の重なり具合を調べる。

第 4 章 第 3 章の結果を踏まえ、辞書のマルチテンプレート化の手法について検討する。また、本手法を用いて認識用辞書を作成し、認識実験より有効性を確認する。

第 5 章 結論であり、まとめと今後の課題について述べる。

第 2 章

文字認識

文字認識とは、入力されたイメージが何という文字であるかを判断する処理である。文字認識の手法は、大きく次の二つに分けられる。

1. パターンマッチング法
2. 構造解析法

パターンマッチング法では、予め読もうとする文字の一つ一つにテンプレート (template: 原形) を用意しておく。それに対し、入力してきた未知の文字パターンを重ね合せていき、最も近いテンプレートの文字がその入力文字であると決定する。すなわち、パターンマッチング法は、パターン同士の重なり具合で評価し、認識を行なう。このため、文字の多少の変形やノイズに強く、計算機上で容易に高速に実現できるが、類似文字の識別は難しい。普通は、計算量削減のため、文字画像そのものではなく、文字画像から得られる特徴量 (特徴ベクトル) を用いて認識を行う。

構造解析法は文字がどのように構成されているかを解析して総合的な判断を下す。具体的に言うと、構造解析法は線分の接続関係や位置関係などの文字構造に着目し、構造の類似性で認識を行なう。この手法は類似文字の多い漢字や、手書きなどによる変形が大きい文字の認識に有効であるが、特徴量の定義や抽出が難しく、また計算機上での処理に時間がかかる等、問題も多い。

本研究では、パターンマッチング法を用いた。図 2.1 に文字認識のアルゴリズムを示す。

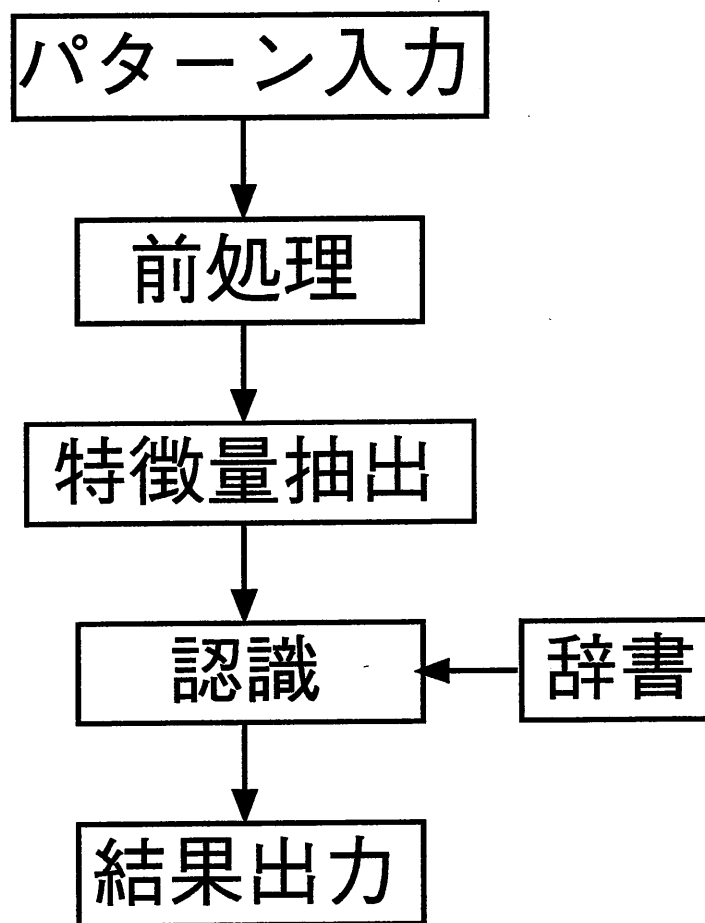


図 2.1: 文字認識のアルゴリズム

2.1 文字入力

文字入力とは、新聞・本・雑誌などの文書を二値画像として取り込む処理である。画像データはイメージスキャナによって入力される。入力された画像データは切り出しの処理により各文字ごとに切り出される。

2.2 前処理


文字を認識する場合の前処理とは、切り出されたイメージデータから特徴量を抽出するために必要なイメージ処理である。ここでは、前処理は、入力文字の線の輪郭を滑らかにするためのスムージング・ノイズ除去、文字の大きさの正規化、細線化と線素化の4つの処理によって構成されている。図2.2に前処理の流れを示す。

2.3 特徴量抽出


パターンマッチング法では、処理の高速化、パターン分離の効率化などのために、文字パターンを特徴量という数値ベクトルに変換する。この過程を特徴量抽出という。本研究では、方向線素特徴量 [1] を用いた。

- 方向線素特徴量：


方向線素特徴量の抽出法は図2.3のように、まず、 64×64 ドットの線素化画像の縦横を8ドット間隔に分割する。次に、 16×16 ドットの領域を49個定義する(左上を0とし、8ドットずつずらし、左から右、上から下へ順に並ぶ)。各領域ごとに縦、横、斜め 45° 、斜め 135° の4種類の線素の数を、重みつきでカウントし、4次元のベクトルとする。1領域内の重みは図2.3のようになっている。よって1文字あたり $196(= 49 \times 7)$ 次元のベクトルとなる。




(a) イメージ




(b) ノイズ除去・スムージング



(c) 正規化

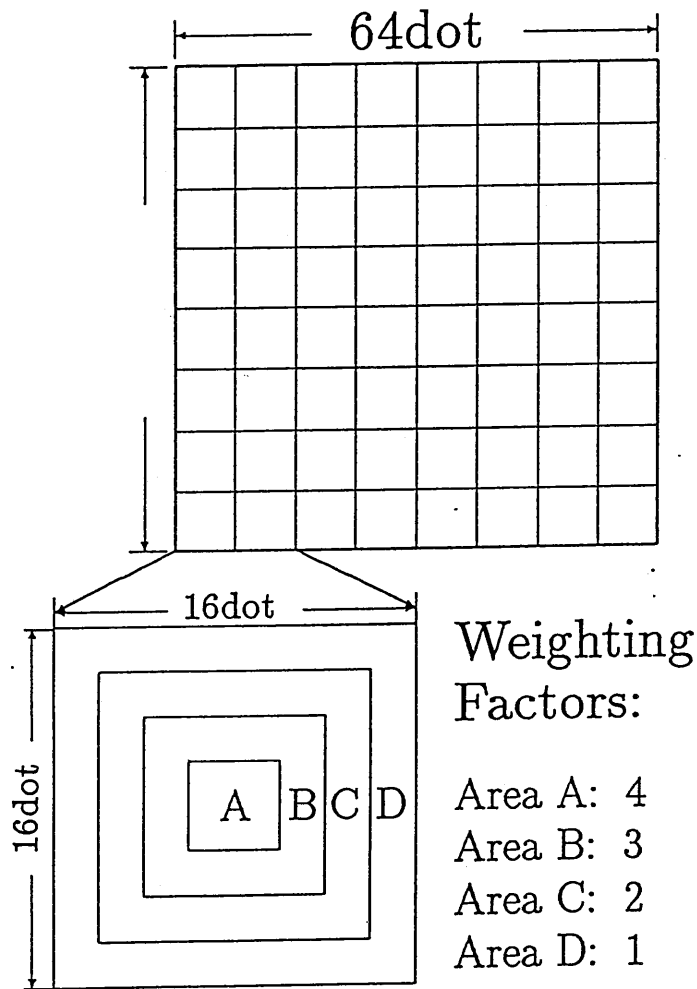


(d) 細線化



(e) 方向線素化

図 2.2: 前処理



方向線素: | — / \

方向線素特徴量: $V_m = (V_{m_1}, V_{m_2}, V_{m_3}, V_{m_4})$

where $m = 1 \sim 49$

小領域の数: $49(7 \times 7)$

方向線素特徴量の次元数: $196(4 \times 49)$

図 2.3: 方向線素特徴量

2.4 認識

ここでは最も一般的な全数整合法を説明する。全数整合法は、各文字の辞書ベクトルと特徴抽出で得られた未知入力文字の特徴量で評価値(距離)を求め、小さいものから順に認識結果とする方法である。アルゴリズムの簡潔性やある程度の高い認識率を得られることから、一般的に用いられている。認識で用いられる辞書・評価値について以下で説明する。

2.4.1 辞書

辞書ベクトルを作成するとき、各字種ごとに、あらかじめ多数の学習パターンを用意しておき、そのパターンから求めた特徴ベクトルの平均を辞書ベクトルとする。シングルテンプレート法、マルチテンプレート法の辞書の構成はそれぞれ次のようになる。


- シングルテンプレート法：

図2.4-aに示すように、各字種ごとに一つの辞書を用意する。辞書のサイズは字種数分でよいが、マルチフォントの活字や手書き文字を認識する場合、認識率が低い。

- マルチテンプレート法：

図2.4-bに示すように、一つの文字に対して、複数の辞書を用意する。マルチフォントの活字や手書き文字の認識にかなり有効であるが、辞書のカテゴリ数が大きくなる。

a シングルテンプレート法



b マルチテンプレート法




図 2.4: マルチテンプレート法

2.4.2 評価値

認識を行う際、近さの尺度 (評価値) としてはユークリッド距離 (実際はその 2 乗) を用いる。字種 k の辞書ベクトルを

$$\mathbf{m}^k = (m_1^k, m_2^k, \dots, m_N^k) \quad (2.1)$$

とし、入力パターンから求めた特徴ベクトルを

$$\mathbf{v} = (v_1, v_2, \dots, v_N) \quad (2.2)$$

とすると、字種 k の評価値 E_k は、

$$E_k = \sum_{i=1}^N (v_i - m_i^k)^2 \quad (2.3)$$

となる。 E_k の小さいものから候補字種とする (N は特徴ベクトルの次元数で、ここでは $N = 196$)。

2.5 候補出力

評価値計算をした後評価値の小さい順に、第 1 位候補、第 2 位候補、 \dots 、第 n 候補を出力する。

第 3 章

文字特徴量の分布

3.1 はじめに

マルチテンプレート化の手法を検討するために、文字パターン (マルチフォント活字) の空間上での分布などの統計的性質を調べ、文字パターンの分布状況を明らかにする。具体的には、まず、主成分分析法を用いて、カテゴリ (字種) 間の分布とカテゴリ内の分布を調べた。次に、領域半径 [2] の概念を用いて、カテゴリ間の重なり具合を調査した。

調査対象としたのは、数字・アルファベット・平仮名と片仮名計 198 字種である (人間でも区別できない大文字の「あ」と小文字の「あ」などは同一字種とみなした)。これらは特にフォントによる変形が大きく、また文書中での使用頻度も高く、マルチテンプレート化の効果が大きいと期待される字種である。サンプルパターンとして明朝体・ゴシック体などの印刷文字を 1 字種あたり 105 ~ 315 個用いた。特徴量としては方向線素特徴量を用いた。

3.2 分布状況

3.2.1 主成分分析法

カテゴリ間の分布を調べる際、主成分分析法を用いた。ここでは、主成分分析法について、簡単に説明する。

主成分分析法は多くの変量の値を、できるだけ情報の損失なしに、少数個の主成分で代表させる方法である。多次元空間上で最も分散の大きい方向を第一主成分、第一主成分と直交する方向のうち最も分散の大きい方向を第二主成分とする。以下、同様に、第三、第四…、と定義される。パターン分散共分散行列を V とするとき、 V の固有ベクトルのうち固有値が最大のものが第一主成分となる。次式を満たす λ が固有値、 \mathbf{a} が固有ベクトルとなる。

$$V\mathbf{a} = \lambda\mathbf{a}$$

第 n 固有値を λ_n としたとき、第 n 主成分の寄与率は、次のように定義される。

$$\text{第 } n \text{ 主成分の寄与率} = \frac{\lambda_n}{\sum_{i=1}^N \lambda_i}$$

ここで、 N は次元数であり、方向線素特徴量では $N = 196$ である。第 n 主成分の寄与率は第 n 主成分軸上での分散を表す。

3.2.2 分布状況の調査結果

カテゴリ間分布を調べるために、まず調査対象とした各字種の重心ベクトルの集合を主成分分析した。横軸を第一主成分、縦軸を第二主成分としてプロットした結果を図 3.1 に、この場合の累積寄与率を図 3.2 に示す。さらに、対象字種のうち、「0」「A」「あ」「い」「ア」「イ」の 6 字種について、図 3.1 と同じ軸上に、カテゴリに含まれるすべてのパターンをプロットした結果を図 3.3 に示す。図 3.1、図 3.3 で完全に分布状況が把握できるとは言い難いが、カテゴリ内の分布の広がりに対して、カテゴリ間の分布はかなり密であることが予想される。

次に、カテゴリ内の分布がどの程度偏っているかを調べるために、各カテゴリごとに第一主成分の寄与率を求めた。結果を図 3.4 に示す。また、寄与率に関する度数分布を図 3.5 に示す。図 3.5 より、第一主成分の寄与率は 20 ~ 30% のものが一番多く、高いものは 70% にも達する。196 次元のうち第一主成分だけで 20 ~ 30% の寄与率となることから、かなり偏った分布をしていることが分かる。




図 3.1: 重心ベクトルの主成分分析の結果 (全字種)




図 3.2: 累積寄与率




図 3.3: 6 字種のパターンの分布




図 3.4: 各字種の第一主成分の寄与率




図 3.5: 寄与率に関する度数分布

3.3 特徴領域の重なり

3.3.1 領域半径

各字種のカテゴリ間の特徴領域の重なり具合を調べるために、領域半径 [2] の概念を用いた。ある距離尺度 E のもとで字種 k の領域半径を

$$r_k = \max_{P \in \mathcal{K}(k)} E(\mathbf{m}^k, F(P)) \quad (3.1)$$

と定める。ここで \mathbf{m}^k は字種 k の特徴量の重心である。また、 $\mathcal{K}(k)$ は字種 k のイメージの集合であり、 F はイメージから特徴量への写像を表す。すなわち、 $F(P)$ は字種 k の (実際にはサンプルから求めた) 特徴量の集合である。特徴領域 (その字種の特徴量が分布する領域) を

$$C(k) = \{\mathbf{u} | E(\mathbf{m}^k, \mathbf{u}) \leq r_k\} \quad (3.2)$$

と定義すれば、式 (3.3) の条件が満たされたとき字種 j と字種 k の特徴領域は距離尺度 E のもとで重なりがないと考えられる。

$$C(j) \cap C(k) = \emptyset \quad (3.3)$$

3.3.2 重なり具合の調査結果

上で述べた考え方をもとに、つぎの 3 種類の距離尺度を用いて重なり具合を調べた。

- (a) ユークリッド距離
- (b) マハラノビス距離 (分散共分散行列は全字種の平均)
- (c) マハラノビス距離 (分散共分散行列は対象とする 2 字種の平均)

ユークリッド距離を距離尺度とした場合、特徴領域は超球となり、マハラノビス距離を距離尺度とした場合は分散の大きい方向に広がった超楕円に近い形となる。全字種対のうち重なっていない対の割合 (分離率) を表 3.1 に示す。

表 3.1 より、方向線素特徴量を用いた場合の文字特徴量の分布はつぎのようであると考えられる。すなわち、(a) と (c) との比較から、特定の方向の分散のみが大きく、実際に領域

距離尺度	ユークリッド距離	マハラノビス距離	
		全字種の平均	2 字種の平均
重なっている	19474	19503	284
重なっていない	29	0	19219
重なっていない率	0.15%	0%	98.54%

カテゴリ対の総数：19503

表 3.1: 重なり具合の調査結果

が重なっている字種対は少ないことが予想される。また、(b) と (c) との比較から、字種ごとに主成分の方向が大きく異なることが予想される。

3.4 まとめ

本章では、文字特徴量の分布状況を調べる手法を述べ、数字・アルファベット・平仮名・片仮名を用いて分布状況を調査した。主成分分析を用いた調査から、字種内の分布の広がりに対して字種間の分布はかなり密であること、字種内の分布はかなり偏っていることが分かった。領域半径の概念を用いた重なり具合の調査から、字種内の分布は特定の方向の分散のみが大きく、実際に領域が重なっている字種対は少ないこと、字種ごとに主成分の方向が大きく異なることが分かった。次章では、本章における調査結果を踏まえて、マルチテンプレート化の手法について検討する。

第 4 章

マルチテンプレート化の手法

4.1 はじめに

前章で、文字特徴量の分布状況の概略が把握できた。本章では、この結果を踏まえてマルチテンプレート化の手法を検討する。

4.2 マルチテンプレート辞書作成のアルゴリズム

マルチテンプレート辞書作成のアルゴリズムを図 4.1 に示す。

まず、学習パターンから特徴ベクトルを求め、その各字種をそれぞれひとつのカテゴリとみなす。各カテゴリごとに、次節で述べる手法で分割する必要があるかどうかを調べる。そして、分割する必要があるすべてのカテゴリのうち、第一主成分の固有値が最も大きいものを探し、そのカテゴリが属する字種のベクトルを分割する。この操作を分割する必要があるカテゴリがなくなるまで繰り返す。そして、最終的に得られた各カテゴリごとに重心を求め、辞書とする。

分割の手法としては K-means 法を用いた。初期クラスタ中心は、分割すべきであると判断されたカテゴリの重心から第一主成分の方向に $\pm\alpha$ だけ移動した点 (α は微小長さ) および、そのカテゴリが属する字種の他のカテゴリの重心 (存在すれば) とし、その字種の全てのベクトルをクラスタリングする。具体例を図 4.2 に示す。

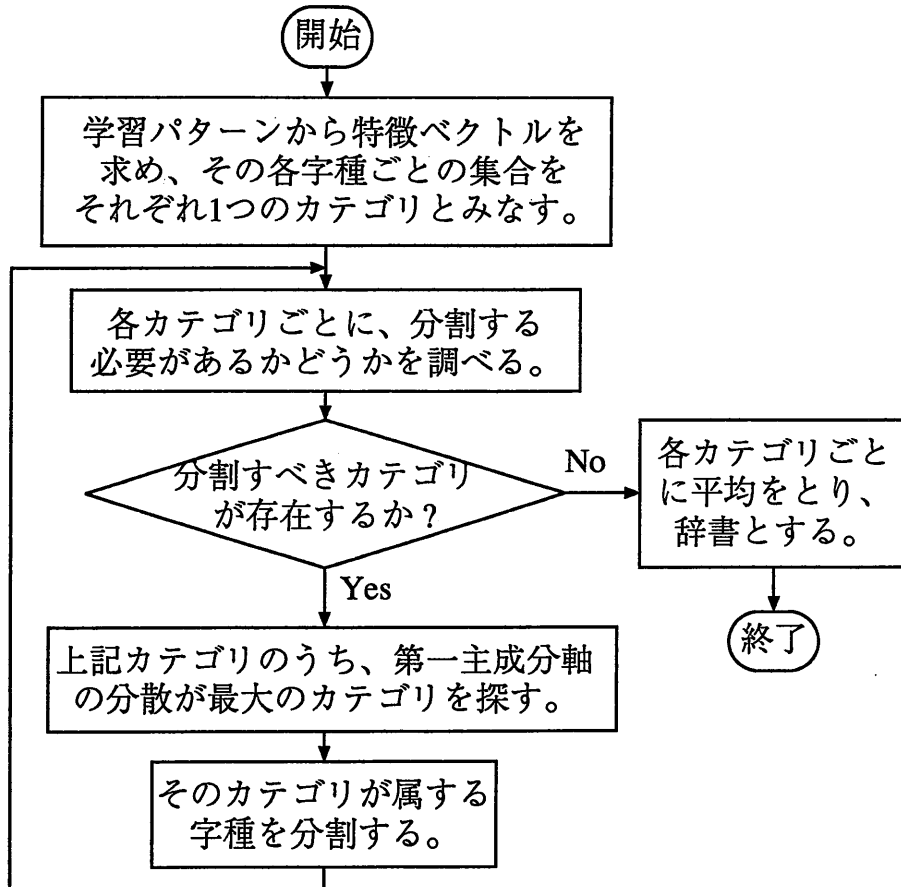


図 4.1: マルチテンプレート辞書作成のアルゴリズム




図 4.2: 初期クラスタ中心の取り方

4.3 カテゴリを分割する条件

カテゴリ k の第1主成分の固有値を λ^k 、固有ベクトル (単位ベクトル) を \mathbf{a}^k とする。第1主成分の寄与率が十分高いものとし、特徴量の分布を正規分布と仮定すれば、適当な定数 α を用いて、次の2点でカテゴリ k の特徴領域の両端を表せると考えられる。

$$\mathbf{m}^k + \alpha\sqrt{\lambda^k}\mathbf{a}^k \quad (4.1)$$

$$\mathbf{m}^k - \alpha\sqrt{\lambda^k}\mathbf{a}^k \quad (4.2)$$

ただし $\alpha = 3.3$ とした。これは、正規分布である場合に、カテゴリに属するパターンの99.9%が含まれる値である。これを用いて、

$$\min_{j \neq k} E(\mathbf{m}^k \pm \alpha\sqrt{\lambda^k}\mathbf{a}^k, \mathbf{m}^j) < \alpha\sqrt{\lambda^k} \quad (4.3)$$

$$\text{カテゴリ } k \text{ の属する字種のカテゴリ数} < M \quad (4.4)$$

のとき、カテゴリ k は分割する必要があるとみなす (図 4.3 参照)。ただし、 M は定数であり、一つの字種が必要以上に細かく分割されるのを防ぐために設定した。

図 4.3 を用いて、本判断法を具体的に説明する。

図 (a) のなかの2個の楕円はそれぞれ文字 j と文字 k の特徴領域を表している。図で、

$$d_1 = E(\mathbf{m}^k + \alpha\sqrt{\lambda^k}\mathbf{a}^k, \mathbf{m}^j) \quad (4.5)$$

$$d_2 = \alpha\sqrt{\lambda^k} \quad (4.6)$$

である。

文字 k に属する点 \mathbf{x} に着目する。分割しないと、図からわかるように、点 \mathbf{x} から文字 j の重心との距離は文字 k の重心までの距離より短いので、文字 k に属する点 \mathbf{x} は文字 j に誤認識される。この場合、 $d_1 < d_2$ であるので、つまり、式 (4.3) が満たされるから、文字 k は分割される。図 (b) のように分割されると、同じ点 \mathbf{x} から、文字 k の重心までの距離の方が短くなり、正しく文字 k に認識されるようになる。

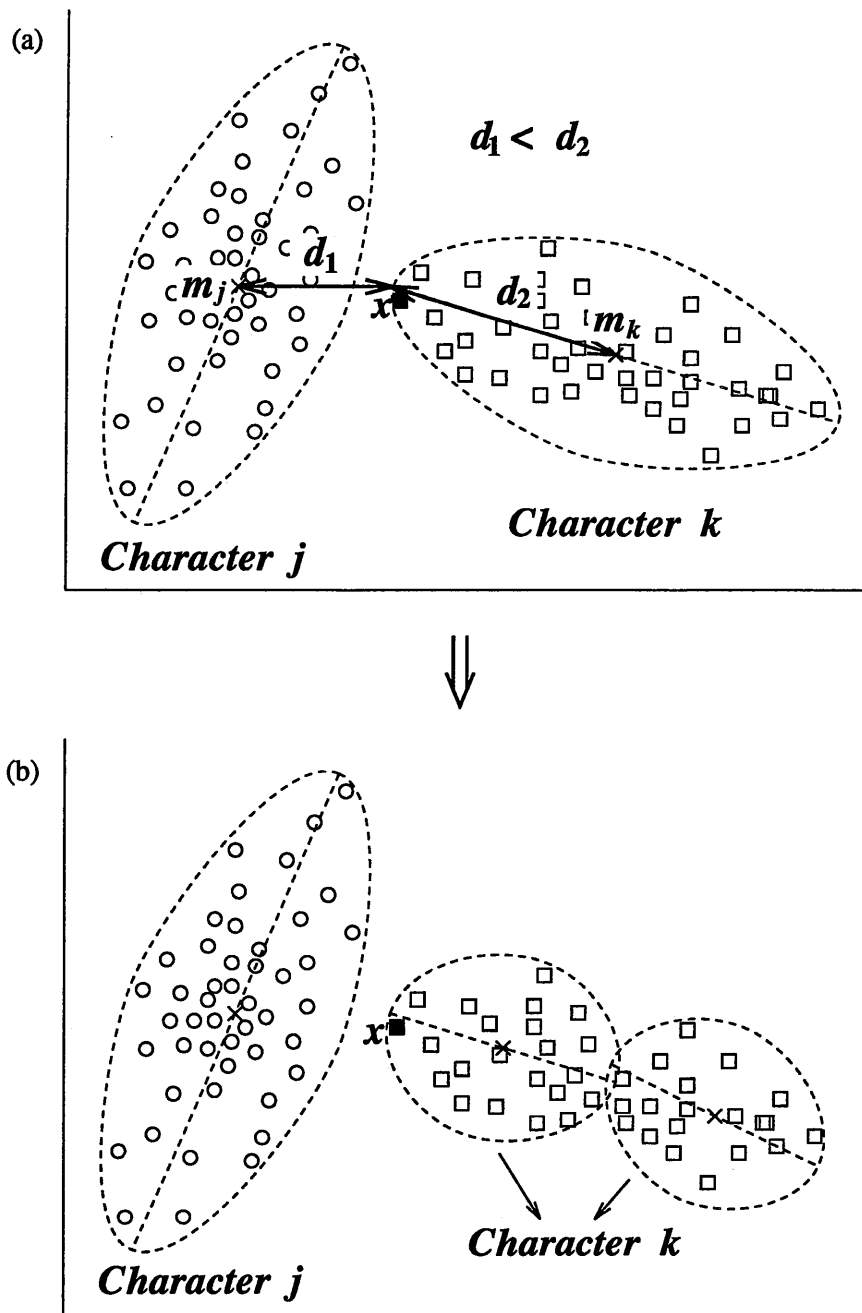


図 4.3: 分割する条件

4.4 認識実験

本手法の有効性を確かめるために認識実験を行った。

第3章で用いたデータを学習データとし、4.2で述べた手法で認識辞書を作成した。そして、学習データとは別のフォントの明朝体とゴシック体を各2セットずつオープン実験用のデータとし、学習データとして用いたものをそのままクローズ実験用のデータとした。評価値としてはユークリッド距離を用い、(4.4)式の M は様々に変えた。

また、比較のため、字種ごとにカテゴリ数固定で作成した辞書を用いた認識実験も行った。分割の手法としては LBG 法を用いた。

総カテゴリ数に対する認識率(1位認識率)は図4.4のようになった。図より、オープン実験、クローズ実験とも、カテゴリ数が同程度の場合、本手法の方が良い結果が得られることが分かる。また、同程度の認識率を得るために必要な総カテゴリ数は本手法の方が少ない。グラフから分かるように、例えば、クローズ実験において認識率98%を得るのに必要な総カテゴリ数は、本手法ではカテゴリ数を固定する手法の半分程度となっている。認識率を下げずに辞書のサイズを抑えるという本研究の本来の目的が達成され、有効性が確認できた。

4.5 まとめ

本章では、まずマルチテンプレートの辞書を作成する手法を提案した。そして、実際にその手法で作成した辞書を用いて認識実験を行い、有効性を確認した。




図 4.4: 実験結果

第 5 章

結論

マルチテンプレート辞書の総カテゴリ数を抑えることを目的とし、空間上での特徴量の分布状況を調べた。そして、総カテゴリ数を抑えたマルチテンプレートの辞書を作成する手法について述べた。さらに、実験により本手法の有効性を示した。

過去の研究では、各字種の適当なカテゴリ数の判断法についての検討はあまりなされていなかった。また、字種間の分布について考慮したアルゴリズムはほとんどなかった。本研究は統計的性質を考慮し、字種ごとのカテゴリ数の新しい判断法を提案するものである。

しかし、本手法ではカテゴリを分割する際に特徴量の第一主成分しか考慮しておらず、また、第一主成分軸上の分布を正規分布と仮定している。実際には、第一主成分の寄与率が低い場合、第二主成分以降も考慮する必要がある。また、主成分軸上の分布についても詳しい解析が必要と思われる。これらは今後の課題である。

また、評価実験では数字・アルファベット・平仮名・片仮名の印刷文字のみを対象としたが、これに漢字を加えること、印刷文字のみではなく手書き文字も対象とすることも今後の課題である。

謝辞

本研究を進めるにあたり、全般的な御指導を賜りました東北大学工学部阿曾弘具教授に心より感謝致します。

また、情報処理教育センターの大町真一郎助手には本研究全般に渡り親身な御指導、御助言をいただきました。ここに深く感謝します。

さらに、御討論、御協力をいただいた阿曾研究室の後藤英昭氏、粟津辰功氏、森 大毅氏、秋山秀三氏、金津知俊氏、八戸高専の細越淳一氏に心から感謝します。

最後に多面に渡り御意見、御協力をいただき、また日頃の生活においてお世話になった阿曾研究室の皆様感謝致します。

参考文献

- [1] 孫寧, 田原透, 阿曾弘具, 木村正行: “方向線素特徴量を用いた高精度文字認識”, 電子情報通信学会論文誌 (D-II), **J74-D-II**, No.3, pp.330-339 (平成3年2月)
- [2] 阿曾弘具, 越後和徳, 木村正行: “文字特徴量空間の性質と特徴抽出法の性能評価法”, 電子情報通信学会論文誌 (D-II), **J76-D-II**, No.11, pp.2285-2294 (平成5年11月)
- [3] 目黒眞一, 梅田三千雄: “マルチフォント印刷漢字の認識”, 電子情報通信学会論文誌 (D), **J65-D**, No.8, pp.1026-1033 (昭和57年8月)
- [4] 郭軍, 孫寧, 根本義章, 佐藤利三郎: “整形変換を用いた手書き文字データベース ETL9B の高精度認識”, 電子情報通信学会論文誌 (D-II), **J76-D-II**, No.5, pp.1015-1022 (平成5年5月)
- [5] 泉井良夫, 原島博, 宮川洋: “階層的な辞書の変形を用いた手書き文字認識”, 電子情報通信学会論文誌 (D), **J68-D**, No.3, pp.361-368 (昭和60年3月)
- [6] 裴東善, 森下哲次, 燕山幸和, 伊崎保直, 山本栄一郎: “手書漢字認識におけるテンプレート複数化の検討”, 電子情報通信学会技術研究報告 PRL81-42
- [7] 八代博昭: “手書き漢字認識の高精度化に関する基礎研究”, 東北大学大学院工学研究科情報工学専攻 昭和63年 修士学位論文 (平成63年2月)
- [8] 加藤真, 高橋弘晏: “階層的辞書配置によるマルチフォント漢字認識”, 電子情報通信学会論文誌 (D-II), **J74-D-II**, No.1, pp.8-18 (平成3年1月)