

大漢和辞典の検字番号に基づく構造化4バイトコードの提案

斎 藤 秀 紀[†]

JIS X 0208 には、符号間への文字の挿入機能の欠如や中国・韓国語への拡張機能の問題がある。本研究では、諸橋敏次編「大漢和辞典」の検字番号に基づく構造化4バイトコードの符号化法と活用法を述べた。最初に、4バイトコードの構造を(1)大漢和辞典の検字番号を16進化94進数変換した整数部3バイトと小数部1バイト符号(2)既存の2バイトコードを統合した符号(3)2の8ビット目が'01'である符号を2個結合した3種にまとめ、これらが画数・読み・部首情報の漢和辞書による基準化、多国語の表現、一字体一符号化を実現できることを示した。次に、符号間への文字の追加機能をつかった一字体一符号化法が、文字集合と漢字符号の固定や文字集合間の互換性を維持した文字集合の分割に利用できることを述べた。最後に、4バイトコードの機能をワークステーション(EWS-4800)とパーソナルコンピュータ(PC-9800)間のデータ伝送を通して検証した。その結果、4バイトコードは、JIS X 0208-1978 の見直しで生じたデータ間の互換性を崩す問題を解決でき、異機種間の共通符号にも使用できる見通しをえた。

A Proposal for a Structural 4-byte Code Based on the Daikanwa-Dictionary Index Number

HIDENORI SAITO[†]

In place of JIS X 0208, I propose a structural 4-byte code containing three types of codes: (1) codes consisting of a 3-byte integer part and a 1-byte decimal part, derived by converting the Daikanwa Dictionary index number into 94-ary code and then into hexadecimal code; (2) codes integrating existing 2-byte code, and (3) codes combining two codes whose 8th bit of 2 is '01'. The 4-byte code makes it possible to standardize the number of strokes, readings, and radicals based on the Daikanwa Dictionary, to include characters used in various countries, and to realize one-character-one-code correspondence. This allows insertion of additional characters between codes, stabilizes relationships between character groups and kanji codes, and separates character groups while maintaining mutual exchangeability of characters. To test the code, data were transmitted between a workstation and a personal computer, successfully maintaining mutual exchangeability of the data.

1. はじめに

コンピュータによる漢字処理は、古典文献・漢籍や図書情報の処理、特許情報処理、日本語教育と教材開発、外国人のための辞書の作成、多国間で情報交換を行う電子メールなど多様化している。また、中国や韓国など漢字使用国との間で交換する技術文献や商用書簡を一元的に表現し管理できる漢字符号の開発が必要になっている。

しかし、現在使用されている情報交換用漢字符号JIS X 0208 は、中国(GB 2312)、韓国(KSC 5601)を含む多国語への拡張機能や大規模な漢和辞書を電子化できる符号化領域の確保、表外字に対する符号化

法、符号間への文字挿入機能、コードブックを基準にした文字や属性情報の規定、長期のデータ保存を目的にした文字管理機能などが欠けている。そのほか、JIS X 0208 には、二つの水準と文字配列基準の設定、第一水準の文字の割り当てに「政令で規定する」とした文字集合の配当に係わる問題がある^{1)~3)}。

文字集合の拡張は、漢字処理の多様化を目的に日本工業規格(JIS)で補助漢字 JIS X 0212-1990(漢字5,801字、非漢字266字)を定めた⁴⁾。また、多国語化の提案は、和田⁵⁾、UNIX System V⁶⁾、国際標準化機構(ISO: International Organization For Standardization)^{7),8)}が行っている。しかし、いずれの提案も連続した2バイトコードに文字集合を対応させているため JIS X 0208 と同様の問題をもっている。

本稿では、現行の情報交換用漢字符号と文字集合の拡張および属性情報(画数・部首・読みなど)を漢和辞書で規定することを目的に、整数部3バイトと小数

[†] 国立国語研究所情報資料研究部電子計算機システム開発研究室

Section for the Development of Software for Language Data, Department of Data Orientation,
The National Language Research Institute




図 1 大漢和辞典の見出しと検字番号(文献 10)から引用)
Fig. 1 An example of a character entry and index number in the *Daikanwa Dictionary*.

部 1 バイトを基本に仮想小数点をもつ 4 バイトコードを提案する。4 バイトコードの利用は、諸橋轍次編「大漢和辞典」(以下大漢和)の検字番号(大漢和収載の文字につけた番号: 図 1)に基づく情報処理用の漢字符号の設定、属性情報の規定、中国・韓国語を含む多国語の取り込み、大規模の漢和辞書の電子媒体化と文字発生装置への応用を想定した。4 バイトコードの構造は、漢字符号と利用面の接続点を明確にするため次の 3 種にまとめた。

- (1) 大漢和と接続するための構造。
- (2) 既存の 2 バイトコードを包含するための構造。
- (3) コンピュータの内部符号を表現するための構造。

また、4 バイトコードの小数部をつかった一字体一符号化の方法は、JIS X 0208 の二つの水準と、二つの文字配列、JIS X 0208-1978 と 1983 年版の間で生じた互換性の問題を解決できることを示し、文字集合に対して共通指標となる文字概念(字体)を見出しとして行った字形のグループ化、交換性をもった文字集合の全体と部分の設定、部分集合の索引化と属性情報による文字配列に利用できることを述べた。さらに、小数部を使用した文字の追加機能は、符号間に文字を挿入した場合も基本配列を維持できることからデータ保存用符号に利用できることを示した。

そのほか、10 進数で表現された大漢和の検字番号を 94 進数と 16 進数に変換する処理(以下 16 進化 94 進数変換)は、4 バイトコードを JIS X 0201 に従う 16 進数 21 から 7E へ基準化する方法と、図 3 の構造を数量的にモデル化する方法に使用した^{9), 10)}。

実験は、2 バイトと 4 バイトコードを混在させた日本語用例(KWIC)をテストデータとし、16 進化 94

進数変換アルゴリズムの確認、各バイトの 2 の 8 ピット目をつかった 2 バイト・4 バイトコードの識別、通信回線を使用する問題点の洗いだしを行った。また、シフト JIS コード、拡張 UNIX コード、JIPS コード(日本電気(株)が規定した漢字符号)などの端末の漢字符号と 4 バイトコード間の符号変換処理を削減するためには、G1, G2 領域の符号を JIS X 0208 に変換し図 3-II 構造にまとめる処理が有効であることを確認した。

2. 現在使用されている情報交換用漢字符号

「システムソフトウェアの標準化に関する調査研究」によると、現段階における漢字コードの拡張法は、今後の拡張字数が 8,836 字以内では第二セットをつくるか空き領域を使用する。8,836 字を超える場合は、第二・第四セットを設定、符号の長さは 3 バイトないし 4 バイトとする案が検討されている。同様に中国では「GB 2312-1980(基本集)」に対して第二補助集および第四補助集の制定を審議中であり、第二補助集 7,237 字、第四補助集 7,039 字の 14,276 字を印刷字母を含め中国の標準として使用する。選択は「漢語大辞典」の 58,000 字から行う。配列は、中国文字改革委員会制定(1983)の漢字部首をとる。台湾の CCCII は、7 ビット 3 列をつかい 28,737 字を、米国は、REACC-83(7 ビット 3 バイト)で漢字を 13,650 字、かな文字 174 字、ハングル文字 2,026 字を符号化している¹¹⁾。

北京図書館では、GB 2312-1980 と独立に北京中文符号を採用し、簡体字・繁体字 32,000 字を符号化している。多国語の表現は、和田が制御符号を含む JIS X 0208 と GB 2312 を 2 バイトコード化する方法を提案している。また、UNIX System V リリース 3.1 では、同様の目的で拡張 UNIX コードを提案している。日本語処理は、JIS X 0208 の文字集合をセット 1 に、表外字はセット 3 にあて 17,672 字を符号化する。ISO では、各国語の漢字符号を併用するため既存の情報処理用の文字集合を包含する 4 バイトコードを計画中である。また、第 2 版ではユニコード(Unicode)との共用を考慮し、「00」から「FF」までの 2 バイトを使用する案が進められている。

東京外国语大学は、漢和辞書の検字番号を 16 進 4 バイト化し、そのなかで中国漢字を表現している¹²⁾。また、国立国語研究所では、大漢和の検字番号 5 衍を部首と部首からの相対位置にわけ、数値化した漢字 2 文

字で表外字を表している。数値化は、出現頻度の高い漢字を 1 から 450 の数字にあて、部首「一：001：計」から「龠：271：合」と、相対位置「001：計」から「450：力」を表現している¹³⁾。

これらの文字集合は、JIS X 0201 やこれに準ずる符号を基本に、切り替え符号で拡張や多国語化をはかっている。しかし、いずれも文字・属性情報・漢字符号を総合的に管理する方法やこれらの情報を漢和辞書などで独立に規定する考え方が欠けている。

3. 情報交換用漢字符号の問題点

3.1 JIS X 0208 の問題点

JIS X 0208 は、日本における情報交換用漢字符号として利用されているが実用面でいくつかの問題がある。以下は事例である。

(1) 文字集合は、使用頻度の高い一群を第一水準に、そのほかを第二水準に配当した。また、第一水準を読み順、第二水準を部首順とする二つの配列基準をとり、第一水準への文字配当に「政令で規定するもの」とする規則をもうけた。

JIS X 0208 の文字集合を二つの水準にわけ読みと部首に配列したことは、文字の使用効率と検字の容易性を向上させることにあった。しかし、第一水準の文字配当に「使用頻度の高い漢字」と「政令で規定する」とする規則の併用は、常用漢字表の改訂で水準間の文字の入れ替えを避けられないものにした。

見直し作業による JIS X 0208-1983 年版は、294 字の字形変更と 84 区点以降へ 2 文字の追加があった。野村の調査では(1)常用漢字に関するもの 14 字、(2)人名用漢字に関するもの 16 字、(3)通用字体の準用に関するもの 151 字、(4)異体字の位置に関するもの 44 字、(5)部分字形の統一に関するもの 47 字、(6)独自の理由に関するもの 22 字である(第一水準 206 字、第二水準 88 字)¹⁴⁾。294 字の字形の変更は、JIS X 0208-1978 と 1983 年版で出力字形と文字配列が異なる問題が生じた。

(2) 文字の追加機能と属性情報の規定に関する問題

JIS X 0208 および JIS X 0212 に対する文字の追加方法には、利用者にゆるされている登録領域をつかう方法(JIS X 0208, JIS X 0212 の空き領域 2,600 字程度)と、JIS X 0202(35,344 字)を使用する方法がある。しかし、JIS X 0208 では、略字や俗字などの字形を整理し(李の調査によると JIS X 0208 の異体字の種類は 555 種 1,159 字である¹⁵⁾)、JIS X 0202 と

併せた空き領域を使用した場合も大漢和収載の 50,311 字や漢籍・古典文献を符号化する機能はない。

また、符号間への文字挿入機能の欠如は、利用者とシステムによる文字の二重登録や重複する文字の移動を余儀なくさせた。1983 年の 4 文字の登録を含め 84 区点への 6 文字の移動は、互換性を崩す要因となつた。配列順序は、堯：5272、楓：15310、遙：39035、瑠：21149、凜：1717、熙：19192 である(数字は大漢和の検字番号)。JIS X 0208-1990 年版における情報交換用の文字集合は、第一・第二水準・84 区点の 6 文字・利用者登録・補助漢字の 5 ブロックにわけられた。

一方、漢字処理における文字配列は、部首・画数・読みを使用することが多い。しかし、JIS X 0208 は、属性情報の規定がなく、部首も「丨, 丶, 冂, 𠂔」が欠落している。読み順を使用した場合は、利用者と作成者の間で読みの選択があることがある。漢字符号では、配列が読みと部首順になり、検字、データ配列、印刷物に対する人手作業が困難になる。これらは、JIS 0208 の規格の改訂や文字の追加に対して配列順序の維持を考慮しなかったことによる。

3.2 DIS 10646 の問題点

DIS 10646 (Draft International Standard : ISO で決定される規格案) の第 2 版は、ユニコードとの結合をはかり符号化領域を 2 進数の '00' から 'FF' とする 2 バイトコードを提案している。しかし、DIS 10646 は、現在各国で使用している情報交換用文字集合を統合したため、既存の漢字符号の問題もそのまま持ち込むことが予想される。特に、連続した 16 ビットコードに文字集合を割り当てたことは、字形の変更や追加文字への対応がよわく、規格の改訂にともなうデータ保守と新旧データ間の互換性を維持するうえで問題が残る。また、DIS 10646 は、16 ビットコードを使用しているため JIS X 0201 規格に従う漢字符号からの移行費用が膨大になる可能性がつよい。

そのほか、DIS 10646 の問題には、表外字管理と漢字の属性情報の規定、コードブックによる情報管理法に関するものがある。以下は、予想される問題である。

- (1) 2 進数符号を基本とするため JIS X 0201 に従う複数バイトを使用した情報交換用漢字符号との間に符号交換が必要になる。
- (2) 符号間に追加機能がないため文字の追加が文字配列の基本性を崩すおそれがある。

- (3) 国家規格や ISO 規格の変更に対する互換性の維持の方法が明確になっていない。
- (4) データ保存・運用管理に必要な漢字の属性情報が規定されていない。
- (5) 表外字の登録領域が少ない。
- (6) 各国で使用している標準字形との相違が多国語の混在処理に心理的な負担をかける可能性がある。
- (7) DIS 10646 が示す 2 バイトコードによる多国語表現は、4 バイトコードに配当される文字集合との関係が明確になっていない。
- (8) JIS X 0202 で規定された制御文字が DIS 10646 の符号化領域と重複する。
- (9) 辞書の電子媒体による出版は、辞書をもとにした情報交換用漢字符号への発展が予想される。

4. 4 バイトコードの作成方法

4.1 漢字符号の構造化の考え方と大漢和の結合方法

JIS X 0208 と DIS 10646 に共通する問題は、符号間への文字の挿入機能や文字集合に対する属性情報の規定、コードブックの使用に対する考え方がないことである。この問題を解決するためには、漢字符号・文字・属性情報をコードブック上に固定しデータの作成者と利用者の双方に明示することが必要になる。コードブックは、属性情報・漢字符号・文字集合の規定とともにデータを長期間保存・管理する方法に使用できる。また、JIS X 0208 の文字集合を二つの水準にわけたことは、文字選定の段階で利用目的に応じた階層化の考え方があったことが伺える。この条件は、4 バイトコードの特性を構造として示し、利用者にインターフェースの形で明示する手段として重要な機能となる。

このような、要求事項は、漢和辞書のなかに見ることができる。辞書の索引配列は、部首・読み・画数を使用し、本体は部首順に配列している。JIS X 0208 が読みと部首による配列を採用したことは、漢和辞書の本体が部首配列を、索引が複数配列を使用したのと同じといえる。見出し、属性情報、検字番号、索引、本体の文字配列を総合的に規定するためには、情報交換用漢字符号と文字集合の配列を漢和辞書と一致させることが必要になる。以上のことと実現するためには、JIS X 0208 で確定した機能と新しく導入すべき機能を構造として明示し、4 バイトコードに反映させることが重要である。

4 バイトコードが JIS X 0208 から引き継ぐ機能は、二つの文字配列と二つの水準の設定、第一水準の文字配当にある制限文字集合による情報交換の考え方である。JIS X 0208 で採用した同一規格内での「読み」と「部首」による文字配列法は、同一字形で異なる読みをもつ中国語や韓国語の混在処理、特殊な読みに対する複数の索引設定に拡張できる。また、第一水準の制限文字集合の考え方は、専門領域別に文字集合を規定する場合や、利用者による任意の文字集合の抽出、文字集合を制限した常用漢字などと共通する。

新しく導入すべき機能は、コードブックによる字形や属性情報の規定、検字番号の情報交換用漢字符号への利用、符号間への文字の挿入機能と一文字一符号化の採用、文字集合の分割利用と分割した文字集合に対する利用者配列の導入、多国語の混在および 2 バイト系情報交換用漢字符号からの移行性が課題になる。以下は、4 バイトコードの設計条件である。

- (1) 4 バイトコードは、単独の使用と既存の 2 バイトコードと併用できること。
- (2) 2 バイト・4 バイトコード間の識別に各バイトの 2 の 8 ビット目のビットを使用できること。
- (3) 4 バイトコードは、JIS X 0201 に従うこと。
- (4) 大漢和と結合するための符号と内部符号は、検字番号を基本とすること。
- (5) 4 バイトコードは、符号間に追加機能をもつこと。
- (6) 中国・韓国語を統一表現できること。

そのほか、漢和辞書のコードブック化には、長期のデータ保存に対する支援手段としての利用がある。データとなる符号化された文字は、入力と再現時点で一致している。この前提のもとでデータは、電子媒体に記録される。しかし、規格改訂による字形の変更是、情報交換用に規定された字形と資料の関係を崩し、データを再現するための基準が変化する。過去のデータ作成環境を再現するためには、資料上の字形と漢字符号に対応する字形を固定し、コードブックによる情報管理と電子媒体化が必要になる。電子媒体化されたコードブックは、コンピュータの文字発生装置との併用によってデータを作成した環境を再現できる。

なお、コードブックに利用できる最大の漢和辞書に、諸橋轍次編「大漢和辞典」がある。大漢和のコードブック化には、和製漢字の補填や大漢和にない漢字を定義する必要があるが、情報処理用に使用できる文字集合の大枠を確定させ、属性情報の規定や JIS に

おける字形の逐次追加、自由領域への利用者登録を最少限におさえることができる。大漢和には、補遺版および各親字間に追加する文字の位置を示す追加用記号「」「」欠番がある。これらは、編集上生じたと思われるが、総字数の 50,311 字の内容は本体 48,902 字、補遺版 1,062 字、追加 504 字、欠番の総数は 157 字である。JIS C 6226 との比較では、大漢和・新字源・大字典のどれにも収録されていない漢字が 94 字ある。

4.2 4 バイトコードの一字体一符号化の方法*

文字集合の一字体一符号化の方法は、変動が少ないと考えられる字体を 4 バイトコードの見出しにあて、字形を小数部に配当する。整数部に見出しをあてることは、漢字符号と文字集合の大枠を規定できる。また、小数部は、配当した種々の字形を符号化の基準として使用でき、字形変更や追加処理を局所化できる。字形の変更の局所化は、漢字符号と字体の関係を一对一に固定でき、分割した文字集合の部分と全体、部分間で漢字符号の交換性を維持できる。部分となる文字集合は、本体と独立に配列した場合も符号と文字の関係は不变である。これによって、漢字符号は文字表現としての機能を明確にし、文字配列は JIS X 0208 の暗黙の方法から属性情報で明確に規定できる。

一字体一符号化した文字集合に対する文字の追加は、小数部の空き番号への登録を基本とし、字形の変更は符号の切り替えに対応する。改訂前の字形を使用する場合は、変更の必要はない。この方法は、小数部に文字を登録するさい重複がおきにくく長期のデータ保存用符号として重要な機能となる。

図 2 は、漢字「剣」の常用漢字表でかかげる通用字体(常用漢字表および人名用漢字別表でかかげる字体)を指標とし、小数部「1, 3, 5, 7, 9, 11」に異なる字形を総画順に配当した例である。整数部の 6 枠の数字は、大漢和の検字番号 ‘2076’ を基本字形とし 16 進化 94 進数変換した値である。見出し漢字につけた括弧内の

剣(23-85,2076)213728.21 鋸(78-63,0000)213728.23

剣(49-91,0000)213728.25 剣(49-88,2228)213728.27

剣(49-90,2243)213728.29 鋸(49-89,2245)213728.2B

図 2 4 バイトコードへの文字配当例

Fig. 2 Examples of characters and their 4-byte codes.

* 本節の論旨は、本論文の採録時までに別稿「1 字体に 1 符号を対応させる漢字符号化の方法」として『計量国語学』に受理されている(1994年 6 月刊行予定)。

数字は、JIS の区点番号、大漢和の検字番号、4 バイトコードである。検字番号の ‘0000’ は、大漢和にならぬ字形である。小数部に中国・韓国語を登録する場合は、各国で許容できる見出しを選ぶ必要がある。なお、大漢和をコードブックに使用する場合は、辞書も一字体一検字番号化する必要がある。

4.3 検字番号を 4 バイトコードへ変換する方法

4 バイトコードは、利用面のインターフェースと漢字符号の特性を規定するため、図 3 で示した 3 種の構造にまとめた。I は、大漢和と結合のための符号を構造として表現したものであり、II は既存の 2 バイトコードとの併用をはかるための構造である。III は、I と II の構造を重ね合わせ内部符号表現したものである。

I は、検字番号を 16 進化 94 進数変換し、整数部を 3 バイトに変換した構造である。4 バイトコードの整数部で表現できる字数は 830,584 字である。10 進表現した 5 枠の検字番号を 16 進化 94 進数に変換する手続きは、検字番号の初期値を ‘1’ から ‘0’ に調整する(例えば検字番号 ‘830584’ は ‘830583’ となる)。次に、検字番号の下位 2 枠を JIS X 0208 の符号化範囲である 7E と 21 の差 94 を「法」とする計算を行い剩余を 16 進数に変換する。結果には、JIS X 0208 で規定した符号の最小値に調整するため重み 16 進数 ‘21’ を加える(式(1))。この計算を各 2 枠単位(‘05’, ‘83’)と繰り返し 3 バイトコードをつくる。

小数部は、追加個数の取りうる範囲を最大 94 に制限したため、1 から 94 の値を 16 進に変換し重み 21 を加えた値となる(式(2))。図 3 で示した記号「A」は、4 バイトコードの小数部である。

$$\text{整数部} = \text{HEX}(\text{検字番号 MOD } 94) + \text{重み } 21 \quad (1)$$




図 3 3 種の 4 バイトコード
Fig. 3 The three types of 4-byte code.



図 4 2バイトコードと4バイトコード領域
Fig. 4 The 2- and 4-byte code regions.

$$\text{小数部} = \text{HEX}(\text{小数部番号}) + \text{重み } 21 \quad (2)$$

HEX: 16進数変換用関数, MOD: 剰余関数

Ⅱは、既存の2バイトコードを4バイトコードに組み込む構造で基本面2バイトコード、切り替え用コード1バイト、小数部1バイトで構成する。Ⅲの整数部は、8,836字を94枚集めた3次元表現となる。G1, G2領域の文字集合を構造Ⅱへ統合する操作は、各領域の2の8ビット目を‘00’に調整しJIS X 0208, GB 2312, KSC 5601を、先頭1バイトで識別する。

Ⅲは、2の8ビットが‘01’であるG3領域の2バイトコードを2個結合し、ⅠとⅡをコンピュータの内部符号にまとめる構造である。G3領域を4バイトコードの要素とする方法は、4バイトコード構造の基本をつくり、2バイト・4バイトコードの識別を各バイトの2の8ビット目で処理する方法を確立できる(各バイトの2の8ビット目は、G0, G1, G2領域が‘00’, ‘10’, ‘11’, 4バイトコードは‘0101’である)。この方法は、既存の2バイトコードとの併用と、4バイトコードへの移行を緩やかなものにする(図4)。

ここで、2バイトコードから4バイトコードを引用する場合は、出現頻度の低い文字が対象になる可能性が高くデータ量の増加は少ないと考えてよい(国立国語研究所における雑誌・新聞の漢字調査では「現代雑誌九十種の用語用字一漢字表」昭和31年1年分: 3,328字「現代新聞の漢字」昭和41年1年分: 3,213字である^{16), 17)}。ただし、既存の2バイトコードと4バイトコードは、文字集合を独立に符号化しているため、4バイトコードを表外字として位置づけ運用上で重複をさけることが必要である。

5. 実験システムの概要

実験では、2バイト・4バイトコードで表現した日本語用例(KWIC)を回線を通すことによって(1)大漢和の検字番号を16進化94進数変換するアルゴリズムの検証、(2)各バイトの2の8ビット目をつかった2バイ




図 5 実験プログラムの概要
Fig. 5 Outline of the test program.

トと4バイトコードの識別、(3)各端末の漢字符号(シフトJISコード、拡張UNIXコード、JIPSコード)に対し中間符号JIS X 0208をつかった符号変換処理の削減、(4)既存の2バイトコードを構造Ⅱに集約する効果を確認した。

実験の方法は、2バイトと4バイトコードで表現した日本語用例1.2万件をワークステーション(EWS-4800)におき、漢字1文字をキーに用例を検索する(図5)。4バイトコードは、変換処理を少なくするために各端末の内部符号をJIS X 0208に変換したのち4バイトコード化した。該当する用例は、2バイトと4バイトコード混在のまま端末に返送し画面表示する。実験用のデータは、漢字パターンの作成をさけるため、JIS X 0208で規定した漢字を4バイトコードにて、英数字・かな文字をJIS X 0208で表現した。各用例の長さは、前部分を60バイト、後部分を116




図 6 符号の表示画面
Fig. 6 Display showing the codes.

バイトとし、満たない場合は16進数'00'で埋めた。用例の見出しあは、漢字2文字をキーにあて4バイトコードで表現した。実験装置は、EWS-4800をサーバと端末に使用し、パーソナルコンピュータ(PC-9800)を端末と日本語処理端末(N-6500)のシミュレート機能に併用させた。

図6は、用例とキー‘車’の漢字符号であるシフトJISコード(8ED4), 大漢和の検字番号(38172), 4バイトコード(253F2821), JIS X 0208(3C56), 用例を検索するのに要した時間、2バイトと4バイトコード間の変換時間、検索したデータ件数を表示したものである。4バイトコードの空白は、かな文字部分である。4バイトコードの16進数値は、‘253F28’が3バイト整数部, ‘21’が小数部である。用例1.2万件から137件を検索するのに要した時間は、PC-9800で820ミリ秒、16用例をサーバから端末に転送する時間3秒、2バイトと4バイトコード間の符号変換時間は18秒であった。EWS-4800のコード変換時間は、PC-9800と同一条件で10ミリ秒である。

6. おわりに

本稿では、漢字符号の以下の点を検討した。

(1) JIS X 0208および漢字使用国における漢字符号の利用状態を紹介し、JIS X 0208における配列規準の二重性、利用者登録の定義域のつかい方、通用字体と異体字に対する符号化の方法などが規格改訂で水準間の入れ替えをおこし、互換性を崩す原因となったことを指摘した。また、属性情報や字形を規定する基準書がないことが実務面で問題になることを述べた。

DIS 10646においても JIS X 0208と同様の問題があり、実用化には既存の2バイト系情報交換用漢字符号からの移行が問題になることを述べた。

(2) 4バイトコードを提案するにあたって、JIS X 0208で確定した機能と付け加えるべき機能を構造化する方法が、漢字符号の特性と利用面とのインターフェースを明確にできることを示し、大漢和の検字番号を16進化94進数に変換する方法が4バイトコードの構造化と大漢和のコードブックとしての利用、図3の構造を数量的に処理できることを述べた。また、

4バイトコードの小数部をつかった一文字一符号化の方法は、文字集合全体の配列規定と目的に応じた文字集合の抽出、全体と部分間で独立した配列をとる場合の符号の一貫性を維持できることを説明した。

そのほか、4バイトコードの小数部は、異なる字形

リストや符号化領域が21から7Eの範囲にある中国、韓国およびJIS X 0208に準拠した漢字符号を統合できることから、各國語の混在が予想される多国言語辞書や日本語教育のための教材の作成、異体字の研究をともなう総索引の作成、古典文献の研究に有効な手段となることを述べた。

(3) (1)と(2)を検証するために実験を行った。実験では、大漢和の検字番号を16進化94進数変換する手続きと構造化の方法、2バイトと4バイトコードの混在と識別処理、符号化領域のG0からG3領域をJIS X 0208に統合させ、既存の2バイトコードを領域単位で切り替える方法、2の8ビット目が‘01’である領域を4バイトコード化する方法を機能面から確認した。

これによって、JIS X 0208および4バイトコードの混在が現行の2バイトコードを小規模用漢字符号に、4バイトコードを大規模用の文字集合として使用できる見通しをえた。さらに、4バイトコードは、メタコード化することによって、JIS X 0208やISOの規格改訂による変更情報の管理、大規模の漢和辞書の電子媒体化に必要な符号化の方法、電子媒体化した辞書によるコンピュータ文字発生装置の作成、JIS X 0208やシフトJISコードの各漢字符号を包含したネットワーク用符号へと発展が期待できることを指摘した。なお、今後本研究は、実用面での問題を把握するため以下の実験を予定している。

- (1) 漢和辞書の電子媒体化に対する情報交換用漢字符号の在り方の検討。
- (2) 4バイトコードへDIS 10646を取り込む実験。
- (3) SQLを使用した4バイトコードの評価。
- (4) 英数字やアルファベットを4バイトコードの小数部で符号化する方法の検討。

謝辞 本論文をまとめるにあたり、東京電機大学・守屋慎次教授には論文の問題点を指摘していただいた。また、実験システムの開発には、日本電気株式会社・C&C第二官庁システム事業部第4営業部・杉宏一部長、中村千恵子さん、C&C事業部第3システム部・加藤隆士主任に大変お世わになりました。ここに記して謝意を表します。

参考文献

- 1) 中華人民共和国標準信息編碼字符集 GB 2312-1980: 技術標準出版社、中国北京(1981)。
- 2) Lee, B. W., Kan, I. b. and Lam, K. T.: Information Exchange of Bibliographic Informa-

- tion—From an Asian Perspective, *First International Conference on Scholarly Information Network East Asian Applications & International Cooperation* (1987).
- 3) 情報交換用漢字符号系 JIS X 0208-1990: 日本工業標準調査会審議, 日本規格協会 (1990).
 - 4) 情報交換用漢字符号系—補助漢字 JIS X 0212-1990: 日本工業標準調査会審議, 日本規格協会 (1990).
 - 5) Wada, E.: Three Byte Code Considered Harmful and Standardization of the Two Octet Character Sets, *First International Conference on Scholarly Information Network Ease Asian Applications & International Cooperation* (1987).
 - 6) 日本語処理機能を備えた Unix の標準化: 日経エレクトロニクス, No. 387, pp. 243-251 (1986).
 - 7) Universal Multiple-Octet Coded Character Set (UCS) Part 1: Architecture and Basic Multilingual Plane Unified Ideographic CJK Character (Version 1.0), ISO/IEC Draft International Standard 10646-1 (December 1991).
 - 8) 長谷川裕美: ユニコードと DIS 10646 統合のユニバーサル文字セット UCS の全貌, SuperASC-II, Vol. 3, No. 5, pp. 162-170 (1992).
 - 9) 斎藤秀紀: 漢字コードのメタコード化の方法, 第 46 回情報処理学会全国大会論文集(1), pp. 23-24 (1993).
 - 10) 諸橋轍次編: 大漢和辞典, 第 3 刷, 大修館書店 (1971).
 - 11) システムソフトウェアの標準化に関する調査研究(拡張漢字コード) 報告書: 日本規格協会 (1987).
 - 12) コンピュータマニュアルシリーズ別冊 2 文字フォントリスト 2 V. 02. 00: 東京外国语大学, アジア・アフリカ言語文化研究所・電子計算機室 (1988).
 - 13) 松本 昭: 国研用漢字レタタイプと同機利用の言語情報処理, 電子計算機による国語研究, 国語研究所報告 31, pp. 57-89 (1968).
 - 14) 野村雅昭: JIS C 6226 情報交換用漢字符号の改正, 標準化ジャーナル, Vol. 14, No. 3, pp. 4-9 (1984).
 - 15) 李 春澤: 韓国標準規格と日本工業規格の漢字について, 学術情報センター紀要, Vol. 3, pp. 21-24 (1993).
 - 16) 現代雑誌九十種の用語用字(第二分冊漢字表), 国立国語研究所報告 22 (1963).
 - 17) 現代新聞の漢字, 国立国語研究所報告 56 (1976).
- (平成 5 年 8 月 25 日受付)
(平成 6 年 2 月 17 日採録)



斎藤 秀紀 (正会員)

1940 年生。昭和 41 年東京電機大学工学部(二部)電気通信工学科卒業。昭和 40 年国立国語研究所文部教官。現在、同研究所情報資料研究部電子計算機システム開発研究室に勤務。用語・用字調査および電子計算機による言語処理、漢字符号、データベースに関する研究に従事。IEEE、計量国語学会各会員。