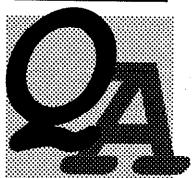


素朴な疑問

漢字コードの種類と相互関係 はどうなっているの？†

宮 澤 彰†

1. 内部コードと交換用符号

漢字コードの話というと、JIS コードとか、シフト JIS コードといった名称が一般的にはなじみ深いものでしょう。しかし、JIS コードは交換用符号、シフト JIS コードは内部コードで、同列に並べて論じるのは誤解のもとになるということを最初に指摘しておきたいと思います。

ここでいう交換用符号とは JIS (日本工業規格) や ISO (国際標準化機構) で決められている符号化文字集合のことです。普通 7 ビット 94 文字とか、2×7 ビットの 94×94 文字などの枠に文字を割り当てた表になっています。交換用符号は国際的な登録制度があり、登録されると識別のための終端文字が与えられます。

一方、内部コードはハードウェア、ソフトウェアシステムの中で使われる値と文字との対応です。1つまたは複数の交換用符号を JIS X 0202 「情報交換用符号の拡張法」という規格 (ISO では 2022) に従って 7 ビットまたは 8 ビットの環境に「呼び出す」ことにより内部コードとなります。この X 0202 はかなり複雑な規格で、同じ交換用符号でも様々な呼出し方が可能であり、呼出し方が異なれば内部コードとしては違ったものとなります。さらに、JIS X 0202 によらない方法で交換用符号を使用しているシステムも多く、これら多くの異なる内部コードを生み出す原因となっています。

最初に交換用符号について見てみましょう。

2. JIS X 0208 情報交換用漢字符号

「JIS コード」といえばこれを指すといつても過言ではないでしょう。94 区×94 点の枠に記号類、英数字、仮名、ギリシャ文字、ロシア文字と 6 千 3 百余字の漢字を割り当てています。以前は C 6226 という番号でした。

有名なコードですが、現在の 1990 年版以前に、1983 年版、1978 年版があり、やや異なっていることは広くは知られていません。90 年版と 83 年版の異なりは人名用漢字の追加にともなう 2 字の追加のみですが、78 年版から 83 年版への変更は記号類 71 文字、漢字 4 文字の追加のほか、字体の入れ替えをともなう大きなものでした。なお、83 年版と 90 年版は同じ終端文字で識別されますが、78 年版の終端文字とは異なっています。また、一般に旧 JIS、新 JIS という言い方をするときは 78 年版と 83 年版以降の終端文字や字体について言っています。

字体の入れ替えは 81 年の常用漢字表の公布に対応するもので、たとえば「桧」と「檜」などのコード値が入れ替えられました。あるいは「鳴」のように字体が換えられたものもあります。この変更は少なくとも字体に注意深い人々にはかなりの混乱を引き起こしました。JIS としては最新版のみが有効なわけですが、市場に出回っているハードウェア、ソフトウェアは必ずしも最新版に従ってはいません。たとえば新しいプリンタで印刷したら字体が変わっていたとか、画面と印字が違うとか、別のパソコンに持つていったら字体が変わってしまったなどの現象が起きています。現在もこの混乱はおさまっていません。このため、自分の使用しているシステムがどの版の JIS であるかは注意しておく必要があります。

† What are the *Kanji Character Sets and their Relations?*
by Akira MIYAZAWA (R & D Department National Center for Science Information Systems).

† 学術情報センター研究開発部

3. JIS X 0212 補助漢字集合

X 0208 の補助として用いるために 1990 年に制定されたもので、記号類 21 字、ウムラウトなどの拡張アルファベット 251 字、および X 0208 に含まれない漢字 5801 字を含んでいます。漢字はメーカや大規模ユーザの外字表を集め共通性のあるものが選定されたほか、X 0208 の 78 年版の文字で 83 年版での改訂にともなって字体を換えられたもののうち 28 字が選定されています。

この交換用符号は一般的なコンピュータシステムにはほとんど普及していません。

4. 諸外国の「漢字コード」

漢字を含む交換用符号は中国、韓国、台湾、米国、およびベトナムで規格化されています。中国では GB 2312 という番号で JIS X 0208 と似た構成の中に記号類、英数字、日本語仮名、ギリシャ文字、ロシア文字に漢字を 6 千 7 百余字を含んでいます。このほかに、GB 2312 に対応する繁体字、拡張の文字集合などが別の番号で規格となっていますが、実用システムで普及しているのは GB 2312 のみと言つていいでしょう。

韓国では KSC 5601 という規格で、やはり JIS と同様の構成の中に記号類と、英数字、日本語仮名、ロシア文字、ハングル 2 千 3 百余字と、漢字 4 千 8 百余字が含まれています。韓国でもまた、記号類、拡張アルファベット、ハングル、漢字を含んだ拡張セットが制定されていますが、普及はしていません。

台湾では CNS 11643 という番号の規格があります。これは、94×94 文字の面を 2 面使い、記号類、英数字、ギリシャ文字に 1 万 3 千余字の漢字を含んだものでした。その後、漢字が拡張されて数面に及んでいます。実用システムでは CNS の他、BIG 5 など何種かのコードが用いられているようです。

米国では ANSI Z 39.64 という番号で書誌用の東アジア文字が規格化されており、図書館目録データベースの世界で使用されています。台湾で考えられた CCCII という交換用符号をもとにしたもので、3×7 ビットの構成の中に、日本語仮名、ハングル千 9 百余字および漢字 1 万 3 千数百字を含んでおり、漢字の異体字関係をコードの構造で

表現しているところに特徴があります。

ベトナムでは 20 世紀初頭まで字喃（チュノム）と呼ばれる漢字を借応用した文字が使われていました。近年これをコンピュータ処理するための交換用符号が規格化されています。

5. ISO 10646 UCS と JIS X 0221

ISO/IEC 10646 Universal Multiple-Octet Coded Character Set (UCS) は 2 バイトまたは 4 バイトの枠に世界中の文字を集めた交換用符号です。ただし、現在のところ 2 バイトの枠内 Basic Multilingual Plane: BMP しか規定されていません。

UCS は前期の ISO 2022 (JIS X 0202) の 94 文字枠にはしばられず、このまま内部コードとして使用されることを想定しており、16 ビットまたは 32 ビットの全コード値を使用します。16 ビットでは 65536 文字の枠があることになります。現在の BMP の中にはラテンアルファベット、拡張ラテン（ウムラウトなど）、ギリシャ、キリル、アルメニア、ヘブライ、アラビア、漢字等々の世界中の文字および大量の記号類、合計 3 万余字が含まれています。

UCS の決定に至る審議経過はすっきりしたものではありませんでした。当初 ISO とは別個に活動を続けていた米国の UNICODE コンソーシアムの案が最終段階になって採用されるということになったためです。いきさつはともあれ、国際標準と業界のコードという 2 本立ては避けられました。

漢字部分に関しては CJK-JRG (China, Japan, Korea Joint Research Group) というところで各国の交換用符号の文字を統合化して作成した 20902 文字の表が採用されました。前章に述べた日本、中国、韓国、台湾の交換用符号を集め、同字、字体のわずかな違いであるものを横並びにしました。

Row/Cell Hex code	C	J	K	
	G - Hanzi - T	Kanji	Hanja	
098/208 62D0	拐	拐	拐	
	0 - 3955 0 - 2553	1 - 4D66 1 - 4570	0 - 327D 0 - 1893	0 - 4E58 0 - 4656

図-1 UCS 漢字部分の一部

て康熙字典順に並べたもので、図-1 のようになっています。G, T, J, K の各列は中国の GB, 台湾の CNS, 日本の JIS, 韓国 KS に対応しており、字の下に書いてある数字が交換用符号の種類と 16 進コードおよび句点番号です。したがって各国の交換用符号との間の変換テーブルになっているわけです。日本の列では交換用符号の種類 0 および 1 で JIS X 0208, X 0212 の全漢字が含まれています。

JIS X 0221 国際符号化文字集合 (UCS) はこの国際規格を翻訳して JIS としたもので 1995 年制定、4 月に出版予定です。内容は国際規格とまったく同じですが、付属書で日本用のサブセットが定義されています。UCS に対応したオペレーティングシステムが最近ようやく市場に出始めたところです。

6. 内部コード

日本のコンピュータシステムはそのほとんどが JIS X 0208 を使用しているが、最初に述べたように内部コードとしてはいくつかの使用法があります。

内部コードのコード値を表現するために以下の記法を導入しましょう。

21	16 進数 8 ビット値
21 22	8 ビット値の列
{21,22}	21 と 22 の集合
{21-23}	= {21,22,23}
21{A1,A2}	= {21 A1,21 A2}
{21,22}{A1,A2}	
	= {21 A1,21 A2,22 A1,22 A2}

EUC (Extended Unix Code) は日本語環境では JIS X 0201 「情報交換用符号」のローマ文字用図形文字集合 94 文字および片仮名用図形文字集合 94 文字、JIS X 0208、拡張用の 94×94 文字集合が使用できます。{21-7E} にローマ文字用集合、{A1-FE} {A1-FE} に X 0208、8 E{A1-FE} に片仮名用集合、8 F{A1-FE}{A1-FE} に拡張用文字集合を呼び出すものです。この内部コードは制御文字 SS 2 (8E), SS 3 (8F) の後ろで最上位ビット 1 を使用していることを除けば X 0202 の拡張方法に従っています。なお、EUC ではプログラム内部での処理用に 2 バイト等長の処理コードも規定されています。

シフト JIS は日本のパーソナルコンピュータのほとんど、およびワークステーションの一部で使われており最も普及している内部コードです。X 0201 および X 0208 が使用でき、{21-7E} にローマ文字用集合、{A1-DF} に片仮名用集合、{81-9F, E0-EF}{40-7E, 80-FC} に X 0208 という割当てです。これは、X 0201 の未使用部分を 2 バイト文字の第 1 バイトとして使用し、47×188 (=94×94) の 2 バイトコード値の集合を作り、X 0208 を大小順を保存しながらその中にいれたものです。シフト JIS の欠点としては、制御文字部分を図形文字として使用している点と、各種のシステム間で外字領域の互換性のないことがあげられます。

メインフレーム用の OS では各社異なる内部コードを使用しています。例として富士通の JEF コードを取り上げると、{40-FF} に EBCDIC または EBCDIK、{41-7F}{A1-FE} に富士通拡張文字、{80-A0}{A1-FE} にユーザ定義外字、{A1-FE}{A1-FE} に X 0208 を割り当てています。1 バイト 2 バイトの切り替えは制御文字を用いてロックングシフトで行っています。ロックングシフトと呼ぶのは、1 バイトの中で 2 バイト開始の制御文字が現れると以降の文字を 2 バイトとして扱い、1 バイト開始の制御文字が現れるまで続くという方式です。これに対し、シフト JIS や EUC では 1 バイト 2 バイトの切り替えのための制御文字を必要としません。

IBM のメインフレーム用 OS は {41-FE}{41-FE} に独自の文字集合を割り当てており、JIS X 0208 との対応はコード変換で行っています。他社のメインフレーム用 OS はロックングシフト方式、使用する交換用符号など JEF と類似していますが、割当てスペース、制御文字のコード値は各々異なっています。

以上のようなところが主な内部コードですが、通信などにからんで JIS と呼ばれる内部コードがあります。JIS の X 0201 と X 0208 とを使用し、エスケープシーケンス 1B 24 42 で X 0208 へ、1B 28 4A で X 0201 へロックングシフトする方式です。42 と 4A は各々 X 0208 と X 0201 (ローマ文字) を識別する終端文字です。呼び出し場所は {21-7E}{21-7E} および {21-7E} で、X 0201 のローマ文字、片仮名の切り替えは SI

(0F), SO (0E) で行います。システムによっては、これを JIS 7 と称し、片仮名を{A1-FE}に呼び出して SI, SO を使用しない方式を JIS 8 と称しています。

実は上記のエスケープシーケンスは現在の JIS X 0202 では旧式となっていますが、83年版の X 0208 にはこのように規定してあったものです。新しい JIS に従えば 1B 24 28 42 0F となるのですが、これ以外の指示呼び出し方法も可能です。また、78年版の X 0208 に対しては終端文字が 40 となります。これらの理由でいくつかの変種がありますが、このいわゆる JIS コードは端末との通信、メールのやりとりなどに広く使われている内部コードです。

参考文献

交換用符号については各規格を参照のこと。また、内部コードについては各 OS のマニュアルを参照のこと。

(平成 7 年 4 月 3 日受付)



宮澤 彰 (正会員)

1949 年生。1975 年東京大学大学院理学系研究科修士課程（科学史および科学基礎論）修了。理学修士。同年国文学研究資料館助手。1983 年東京大学文献情報センター助教授。1986 年学術情報センター助教授。現在同センター教授。データベース作成の基礎論という観点から、文字コード論、計算言語学、情報図書館学などに興味を持つ。東洋音楽学会会員。

