

論文

国際標準化文字集合に対応した 大規模漢字フォントの制作

上地 宏一

2023年9月に公開された国際標準化文字コード Unicode に収録される 10 万弱の漢字および IVD に登録されている 3 万弱の異体字を全て収録する大規模漢字フォントを制作した。加えてその 13 万字種を検索できるツールの制作を行った。本稿ではその詳細を述べる。

キーワード : Unicode、漢字、異体字、フォント、漢字部品

1. はじめに

現在、コンピュータで文字を扱うための基盤となる文字コードは Unicode 標準（および国際標準規格である ISO/IEC 10646。以降まとめて Unicode と記す）にはほぼ統一されたと言っても過言ではないが、Unicode はこの 30 年間に繰り返し更新され、字種が追加されてきた。本稿では、Unicode 15.1 版（2023年9月公開）に対応した大規模漢字フォントの制作とその公開について述べる。

2. 背景

2-1 Unicode の漢字集合の現状

Unicode に収録されているCJKV 統合漢字・互換漢字および IVD をまとめたものが表1である。Unicode の改版に伴い、漢字ブロックが追加され、収録される漢字集合が増えている。2024年1月現在最新となる 15.1 版では 98,682 漢字が収録され (Unicode 2023a)、また IVD において 29,437 グリフが登録されている (Unicode 2022)。例えば日本で用いられる漢字は常用漢字の 2,136 字や人名用漢字の 863 字などがあり、一般的な漢和辞典の親字数は 1 万字強である¹⁾ のに対し、Unicode には大型漢字字典に収録される史料的な漢字や異体字が多く含まれ、また中国大陸、台湾、韓国、ベトナムなどからも継続的に字種追加の申請がなされた結果、ある種の博物館的文字コードになっている。Unicode の収録文字に対する漢字の比率は高く、15.1 版の全 149,813 文字に対して、純粋な漢字だけでもその 65% を占めることになる。

表1 Unicode の漢字ブロック一覧 (Unicode 2023b をもとに筆者作成)²⁾

ブロック名	コードポイント範囲	文字数	Unicode の版番号と年
URO	U+4E00 ~ U+9FFF	20,992	1.1 版 1993 年
拡張 A 集合	U+3400 ~ U+4DBF	6,592	3.0 版 1998 年
拡張 B 集合	U+20000 ~ U+2A6DF	42,720	3.1 版 2000 年
拡張 C 集合	U+2A700 ~ U+2B739	4,154	5.2 版 2008 年
拡張 D 集合	U+2B740 ~ U+2B81D	222	6.0 版 2009 年
拡張 E 集合	U+2B820 ~ U+2CEA1	5,762	8.0 版 2012 年
拡張 F 集合	U+2CEB0 ~ U+2EBE0	7,473	10.0 版 2015 年
拡張 G 集合	U+30000 ~ U+3134A	4,939	13.0 版 2019 年
拡張 H 集合	U+31350 ~ U+323AF	4,192	15.0 版 2021 年
拡張 I 集合	U+2EBF0 ~ U+2EE5D	622	15.1 版 2023 年
互換漢字	U+F900 ~ U+FAD9	472	—
互換漢字補助	U+2F800 ~ U+2FA1D	542	—
IVD	—	29,437	2022-09-13 版

2-2 大規模漢字フォント

Unicode の拡張によってさまざまな漢字の情報交換が保証されるようになっても、実際に画面に表示したり、紙に印字したりするためにはフォントが必要になる。漢字のような数の大きな文字集合ではフォントの制作にコストがかかるため、欧文と比べてそのバリエーションは少なくなる。さらにすべての漢字集合を収録する必要はないため、例えば日本の漢字フォントには中国の簡体字が含まれなかつたり、あるいは史料的な漢字が含まれなかつたりするなど、文字コードに収録されていても実質的に「使えない」漢字というものが存在し、あるいは「使えない」漢字の方が多いのが現状である。

その中で「大規模漢字フォント」と呼ばれるものが存在し、Unicode の 10 万の漢字を部分的に網羅することで、珍しい漢字をコンピュータで処理したいという一部のニーズを満たすことが可能となっている。そのいくつかを例挙したのが表2である。これらのほとんどは OS に標準で添付されていないため、使いたい人は自分でフォントをダウンロードしてインストールする作業が必要となる。

表2 有名な大規模漢字フォント

名称	説明
Simsun-ExtB・MingLiU-ExtB	Windows Vista から標準搭載された拡張 B 集合対応フォント
今昔文字鏡・GT 明朝・T フォント	それぞれ数万字を収録。Unicode に準拠していないため情報交換には不適
IPAmj 明朝 ³⁾	日本の行政処理で収集・整理された文字を収録した 6 万字のフォント。Unicode のコードポイントに対応していない漢字は未収録
BabelStoneHan ⁴⁾	最新の拡張 I 集合までを網羅（全てではなく一部）する 6 万字を収録。Unicode 収録漢字のカバー率は 57%

花園明朝 ⁵⁾	筆者により公開。拡張F集合まで収録、2017年以降更新停止
謎乃明朝 ⁶⁾	グリフウィキの成果を利用し、花園明朝の後継ともいえる。拡張I集合を含むUnicodeの全漢字を収録するが、非漢字は未収録

2-3 花園明朝フォントとグリフウィキ

「花園明朝」フォントは筆者によって公開されている大規模漢字フォントである。Unicodeの漢字を中心に収録したフォントであり、2007年6月に公開を開始して以来、収録文字数を増やしながら版を重ね、2017年の最新公開版では拡張F集合までの10万字（非漢字含む）を収録した。世界でも数少ないUnicodeの大規模漢字集合を収録したフリーフォントとなっている。この花園明朝フォントの制作には「グリフウィキ」と名付けられた漢字字形共有Webデータベースのグリフデータが活用されている。グリフウィキも筆者が運営しているWebサイトであり、2007年10月の公開以降、多くのボランティアによって100万を超えるグリフが登録されている。Unicodeの漢字集合の追加はISO/IEC 10646のJTC1/SC2/WG2委員会の中のIRGで審議されるが、その議論の過程で扱われる文書・資料はWebで公開される⁷⁾。この資料を基に追加の候補となる漢字をボランティアが同時進行的にグリフウィキに登録することにより、文字コードの新版の公開の時点で（あるいは公開後、そう遅くない時期に）、グリフウィキにその追加字種データが整備されていることが実現している。

筆者は定期的にUnicodeの漢字ブロックの拡張に対応して花園明朝フォントの版の改訂を行ってきたが、2017年9月の改訂以降、いくつかの問題により更新が止まってしまった。一番の原因是、2009年からグリフウィキに登録されている非漢字を積極的に収録することにした方針変更である。もともとグリフウィキ（および内部で使われている漢字字形生成エンジンであるKAGEシステム）は漢字字形を扱うものであったが、必然的に非漢字も登録されてきた。公開当初の花園明朝フォントは「漢字」のフリーフォントを謳っていたが、文字種数の多さをアピールする狙いもあり非漢字の収録を行うことになった。しかし、非漢字集合は多種多様のブロックで構成されていることや、各ブロックがどれだけの字種をカバーすれば、そのブロックを収録しているとアピールできるのかの知識が乏しく（例えば「ひらがな」ブロックを収録したとしても「「ぬ」だけは入っていません」では使い物にならない）、これらの管理を行うことが難しくなった結果、更新が滞ってしまった。

3. 字雲（Jigmo）フォントの制作

3-1 概要

そこで筆者は、非漢字の収録をあきらめて漢字に特化した新たな大規模漢字フォント「字雲（Jigmo）フォント」を制作することにした。ただし収録対象を厳密に漢字だけに限定すると使いにくく、最低限の英数字やかな文字は必要であるため、収録する文字種を東アジア文化圏の文字に限定するとともに、フォントだけでなくフォントを生成するツールを併せて公開することで、利用者が自分のニーズに合わせて文字種の増減を行い、自分でフォントを生成できるようにすることとした。

3-2 フォント生成ツール

字雲フォントはフォント生成ツールとフォントファイルから成り立っている。ツールは以下の手順

でフォントを生成する。

1. unicode.org から文字コードのメタデータを取得
2. 利用者が定義したキーワードリストに基づいて、フォントに収録する文字種を決定
3. 文字種に基づいてコードポイントリストを生成
4. リストに基づいて各コードポイントのSVGデータをグリフウィキから取得
5. FontForge でフォントファイルの生成
6. グリフ一覧 (HTML) の生成

2. のキーワードリストは標準では図1のようなテキストファイルになっていて、IDEOGRAPHIC (漢字ブロックに記述される)によって漢字を収録し、CJK(中国・日本・韓国に関する文字につく)、HIRAGANA (日本語のひらがな)、HANGUL (韓国語のハングル) や BOPOMOFO (中国語の注音記号) など、東アジア文化圏の文字種を取り込むように記述している。これは Unicode が公開しているメタデータ⁸⁾を使って Unicode 収録文字の文字名に部分一致したものをフォントへの収録対象とする仕組みとなっている。たとえばここに「TIBETAN LETTER (チベット文字の文字ブロック名)」を追記すれば、U+0F00～U+0FFF に収録されるチベット文字が追加される。また、ASCII の文字 (英数字・基本的な記号) については強制的に収録することとしている。

CJK
IDEOGRAPHIC
KANGXI
ROUNDED SYMBOL
IDEOGRAPH
ERA NAME
VERTICAL KANA
HIRAGANA
KATAKANA
HENTAIGANA
<square> 30
HANGZHOU
BOPOMOFO
MAHJONG
XIANGQI
HANGUL
Hangul
KOREAN CHARACTER

図1 収録対象キーワードリスト (keywords.txt)

このツールはあくまでもフォント生成に必要なデータとスクリプト（フォント生成の指示プログラム）を生成するだけであり、実際にフォントを生成するためには外部アプリケーションである「FontForge⁹⁾」を利用する。ツールはPython言語およびPerl言語からなる複数のスクリプトとそれらを統括するシェルスクリプトの集合体である。

3-3 フォントファイル

現在のフォントファイル形式（TrueTypeおよびOpenType形式）は内部テーブルの制約により、1つのフォントファイルに含めることのできるグリフ数が65,536個に限定されているため、Unicodeの全10万漢字を1つのフォントファイルに収めることができない。現在、Unicodeの漢字は第0面、第2面、第3面に収録されている（一部「かな」や記号・絵文字の一部は第1面）が、すでに第2面は6万字が埋まっていて、今後の字種追加も見越した結果、以下のようにそれぞれの面ごとにフォントファイルを分けた3ファイル構成としたことにした。

- Jigmo.ttf 第0, 1面の文字を収録（非漢字：ASCII、かな、記号、漢字：URO、拡張A、互換漢字）
- Jigmo2.ttf 第2面の文字を収録（非漢字：ASCII、漢字：拡張B, C, D, E, F, I）、互換漢字補助
- Jigmo3.ttf 第3面の文字を収録（非漢字：ASCII、漢字：拡張G, H）
(※それぞれ、その面の漢字を親字とするIVDグリフを含む)

この結果、利用時に文字によって3つのフォントを切り替える必要が出てくるため不便であるが、現状では解決不能なため、将来の文字処理システムの改善（たとえばいくつかのフォントをまとめた論理・抽象フォント）をOSに期待するしかない。

3-4 GitHubでの公開

フォント生成ツールはGitHubのプロジェクトとして公開し¹⁰⁾（図2）、また生成したフォントファイル（Jigmoフォント）も同プロジェクトのWebページに公開している¹¹⁾（図3）。フォントファイルのライセンスはCC0¹²⁾（日本の著作権法では無効となるが、便宜的なパブリックドメイン相当）として自由に使うことができる。フォント生成ツールのライセンスはMITライセンス¹³⁾である。

kamichikoichi / jigmo

Code Issues Pull requests Actions Projects Security Insights

main 1 branch 0 tags Go to file Code

kamichikoichi Ext.tj追加を分かりやすく

f72490b on Sep 17, 2023 31 commits

File	Description	Time Ago
docs	Ext.tj追加を分かりやすく	4 months ago
documents	ツールファイルの配置	5 months ago
LICENSE	Create LICENSE	5 months ago
README.md	macOSの不具合解消	5 months ago
ascii.txt	ツールファイルの配置	5 months ago
basefont.ttf	ツールファイルの配置	5 months ago
divide_ttx.pl	ツールファイルの配置	5 months ago
getglyphs.py	ツールファイルの配置	5 months ago
glyphlist.pl	ツールファイルの配置	5 months ago
asub_dummy.txt	ツールファイルの配置	5 months ago

図2 GitHub でのフォント生成ツールの公開

Jigmo (字雲) フォント

(click to download Jigmo fonts)

現在公開されているJigmo (字雲) フォント : 2023年8月16日版

ダウンロード

- Jigmo fonts
 - Jigmo-20230816.zip
 - サイズ: 32,799,320 バイト (31.2MB)
 - SHA256: 4D2641686E0978819A3FC0F5250B31A209F829DE42BB12448745FC8D89DD2FC2

Jigmo (字雲) フォントについて

このフォントは自由かつ無償の漢字フリーフォントです。非漢字は一部のみ含まれます。明朝体フォント1ウェイトが収録されます。フォントの生成にはKAGEシステム、Clipper, FontForgeおよびTeXを利用しています。

収録されているグリフはすべてグリフウィキに登録されているデータを利用しています。このデータは、グリフウィキに登録ユーザーとして、あるいは匿名ユーザーとして

図3 GitHub でのフォントファイルの公開

4. 入力補助ツールの制作¹⁴⁾

4-1 多漢字の検索手段

字雲フォントの公開によって Unicode のすべての収録漢字に対応したグリフ表示が可能となる一方で、その文字をどのように入力するのかという問題は解決していない。通常、我々がパソコンに漢字仮名交じり文を入力するときにはローマ字入力を用いる。これは漢字の「読み」を入力し、その読みに相当する漢字仮名交じり表記の候補を選択・確定するものである。しかしながら Unicode の 10 万字種の文字を読みで入力することは効率的ではない、例えば「コウショウ」という読み仮名に対応する漢字熟語は 48 種類あるという（日本漢字能力検定協会 2021）。また古典文献に見られる漢字によっては、地名として記述されているだけで、読み（や字義）が不明なケースもある。従来、こういった大規模漢字集合から任意の文字を探し出す方法としては、以下の 3 系統に分かれるが、現実的な解として②の漢字部品検索が最適である。

①部首・画数から調べる

- ・部首画数検字：部首と、部首を除いた画数（部首内画数）から文字を探す伝統的な検字方法である。214 種類の部首は明代の漢字字典である『字彙』（明・梅膺祚編、1615 年）、『正字通』（明・張自烈編、1627 年）から清代の康熙字典（清・張玉書ほか編、1716 年）に継承され、現代の漢和辞典・漢字字典でもこのいわゆる「康熙部首」ないしその派生部首が使われる。しかし同じ部首・同じ画数でも大量の漢字があり探すのは困難であるほか、Unicode 漢字特有の Unification（字形統合）により、同じコードポイントの文字であっても国・地域によって画数が変わることがあり、画数による検字を困難としている）
- ・規格票および UniHan データベースから調べる：規格票では漢字ブロックごとに康熙部首・画数順に並んでいるため、上記部首画数検字が可能であるが、漢字ブロックは URO、拡張 A～I の 10 パートに分かれているため、最悪の場合 10 回検字作業を繰り返すことになる。Unicode では 10 パートの漢字全てをまとめた上で部首画数順に並べた UniHan データ¹⁵⁾およびその検索 Web サービス¹⁶⁾を提供しているため、多少は労力を減らすことが可能となっている。

②漢字部品から調べる

- ・CHISE IDS Find¹⁷⁾：守岡知彦氏提供の Web サービスで漢字部品を入力し、その部品を含む漢字の一覧を検索可能。インターネットに接続している必要があること、部品を入力できる漢字スキルが必要である。
- ・文字情報基盤検索システム¹⁸⁾：一般社団法人文字情報技術促進協議会提供の Web サービスで漢字部品から文字を検索できるほか、既存の文字を分解して検索部品に用いるなどの工夫がみられる。インターネットに接続している必要があることと、経済産業省実施の文字情報基盤整備事業によって収集された日本の行政で使われた文字が検索対象のため、Unicode の 10 万字すべてを検索できないことが残念である。

③手書きで調べる

- ・グリフウィキ手書き検索¹⁹⁾：kurgm 氏提供の Web サービスで、グリフウィキに登録されている 32 万弱のグリフを手書きで検索できる。書き方に依存すること、Unicode に関係ないグリフも検索

されること、インターネットに接続している必要があり、かつサービスがスリープ状態に入ると復帰に30秒以上待たされることなどがデメリットである。

4-2 IDS データの活用

Unicode の収録漢字は、IRG における追加収録審議の際に IDS (漢字構造記述) データを提出することになっていて、10万字すべての漢字について IDS データが確保されていることから、この IDS を活用した漢字部品検索ができるかと考え、入力補助 (漢字検索) ツールを作成することにした。実際には拡張 I 集合の IDS データが探し出せなかつたため、cwhk 氏がグリフウィキに登録した IDS データを含め、以下の IDS データを組み合わせて利用することとした。

- CHISE プロジェクト公開の IDS データ²⁰⁾ : 先述の CHISE IDS Find の元にもなっている、URO および拡張 A～H 集合 (拡張 I 集合が不足する) の IDS データ。大元は台湾中央研究院の CDP データベースをその一部としている。一部 Unicode 以外の漢字部品を用いているため、その部分は活用できない。
- 漢字データベースプロジェクト公開の CJKVI データベース²¹⁾ : CHISE プロジェクトの IDS データをベースにしつつ、極力 Unicode の漢字のみで構成しているほか、CJKV の各代表字形に IDS 上の差異がある場合は併記している (例: U+6F22 「漢」: 𠀤 汗 𩫣 口夫 [GTKV] 𠀤 漢 [J] の 2 併記)。URO および拡張 A～F 集合 (拡張 G, H, I 集合が不足する) を網羅する。
- BabelStone 公開の IDS データ²²⁾ : 先述の「BabelStoneHan」フォントの公開者でもあるイギリスの中国学者である Andrew West 氏公開の IDS データである。漢字データベースプロジェクト公開の CJKVI データベースをベースにしつつ、IDS で表現できない 3 種の抽象表現記号 (図 4) を取り組んだ意欲的なデータである。URO および拡張 A～H 集合 (拡張 I 集合が不足する) を網羅する。
- cwhk 氏がグリフウィキに登録した IDS データ²³⁾ : 現状で唯一入手可能であった拡張 I 集合の IDS データである。

鏡部品記号 𠀤𠀤 = 臼

回転記号 𠁧 = ↘

引き算記号 ⊖ 東ノ = 東

図 4 3 種の特殊記号

入力補助ツールは单一の HTML ファイルで構成されるスタンドアロン型の Web アプリケーションとし、ネットワークを必要とせずに内部に各種データを保持し、また JavaScript 言語によってロジック部分を記述することとする。これにより、HTML ファイル 1 つを取得すればツールが利用できる手軽さを実現できる。

4-3 漢字部品の定義

漢字部品を使った漢字検索には、その部品について 2 種類の考え方がある。

- ①任意の漢字部品を指定：あらゆる漢字部品を入力して検索するタイプで、先述の「CHISE IDS Find」や「文字情報基盤検索システム」が採用している。問題点は、漢字（部品）に対する知識の有無が検索に影響することである。
- ②部品セットの定義：漢字部品を 100～200 種類用意し、その中から指定するタイプである。①と比較すると漢字に対する知識の必要性は低いが、部品数を絞ると検索結果の候補が多すぎることになり、逆に部品を多くすると部品の選択が難しくなる。

今回は②の方法を取ることとした。その理由はツールを 1 つの HTML ファイルで構築する目的があり、よりシンプルなロジックとするためである。部品の選別は以下の手順で行うこととした。

段階 1 IDS データを元に、全ての漢字部品とその出現回数をカウントする

段階 2 設定した閾値で頻度の高い部品に絞り、それ以外の部品を IDS データを使って分解する

段階 3 再度、漢字部品とその出現回数をカウントし、閾値で頻度の低い部品を捨てる

閾値を 106 個とした場合の、段階 1 の時点でのカウント結果の上位 20 位を表 3 の左から 1 番目に、閾値前後 10 位を 2 番目に示す。網掛けは閾値以下で除かれる部品である。また、段階 3 の上位 20 位を表 3 の左から 3 番目に、閾値前後 10 位を 4 番目に示す。当初「鬼」「支」「衣」といった部品は閾値より上位にあったが、分解後再整列の結果、閾値以下となっている。また再整列の結果、「一」が 5 万回を超える（10 万字種の半分に含まれる部品であることを意味する）など、情報量としてやや問題があると言えなくもない。なお、この出現回数は同じ部品が 2 回以上出現する場合も 1 回とカウントする（「林」も「森」も出現する「木」部品は 1 回）。また抽出された 106 個の品を図 5 に示す。

また、検索に於いて「孫引き」を有効とするかどうかも検討の対象となった。例えば「口」という部品を含む漢字（例：「名」）を、「口」に含まれる「一」でも検索できるべきかどうかである。孫引きを有効とすると、特に画数の少ない漢字部品の情報量が低下するため、今回は無効とした。一方で、孫引きができないため、利用者はより高度な（複雑な）部品を指定しないと検索漏れが発生するという問題も生じる。今回は部品の個数を 106 個に抑え、画面上で一覧できることによりこの問題を回避できると考えた。

表3 部品の出現回数リスト

部品	出現回数	部品	出現回数	部品	出現回数	部品	出現回数
口	5,029	己	398	一	51,353	酉	896
艹	4,175	ム	398	ノ	42,911	ネ	895
木	3,782	子	392	丨	35,075	水	894
氵	3,557	鬼	384	口	22,102	毛	799
金	2,752	支	379	丶	17,308	羊	789
才	2,542	衣	377	し	15,091	乃	783
土	2,515	刀	371	十	13,886	見	711
一	2,191	水	370	日	11,531	歹	683
火	2,161	羊	369	土	10,383	衣	683
日	2,144	風	367	人	9,710	革	674
糸	2,054	升	365	八	9,440	衣	657
月	2,036	ト	365	口	8,923	舟	601
イ	2,012	瓦	364	二	8,883	口	590
山	1,966	匁	357	丶	8,801	走	589
女	1,922	骨	356	木	8,588	九	575
言	1,918	匚	355	丁	7,713	巳	566
竹	1,879	工	354	艸	7,153	鬼	465
虫	1,840	黒	353	大	6,592	彫	460
鳥	1,813	儿	352	士	5,984	入	458
魚	1,595	干	342	月	5,083	支	450

一ノ丨口丶し十日土人八口二ノ木口艸大一月へ
 氵田又ム一ヘイノ目王才女艸火山糸金心貝尸虫
 フ久言口禾竹冂广戈メ厂辻文巾立く隹米四鳥ト
 ムニ刀爪白リ魚車几石止示皿足力己門弓馬耳子
 雨貢牛穴彳冂广方欠食羽殳酉ネ水毛羊乃見歹衣
 革

図5 106個の部品リスト（出現回数の多い順）

4-4 部品の同定

例えば「こざと (防・阪の左側部品)」と「おおざと (郎・郵の右側部品)」といった見た目上全く同じ部品を区別することは検索において非効率であると考えられる。また「己・巳・巳」といった区別の煩雑な部品も1つにまとめて指定できた方が検索しやすい。さらにUnicodeの10万字を検索対象とする際に、中国大陸の簡体字部品を非簡化部品と区別して検索できる必要もないと考えた。そこで、いくつかの部品同士を同定して検索するためのテーブルを用意することとした。具体的な同定部品テーブルの一部を図6に示す。全体で69レコードある。テーブルの中で全く同じ部品が2つ並んでいるように見える箇所(「舟」「阝」「食」)があるが、これは漢字としての部品と、「康熙部首ブロック(U+2F00～U+2FDF)」による部品とを同定しているためである。

臣	臣	臣		
舟	舟			
丶	丶	丶		
西	西	西		
見	见			
言	言	讠		
貝	贝			
足	足			
車	车			
辵	辵			
金	金	钅		
門	门			
阝	阝	阝		
青	青			
頁	页			
食	食	食	飠	匂
馬	马			
魚	鱼			
鳥	鸟			
黃	黄			
黒	黑			

図6 同定部品テーブル (一部)

4-5 ツールの実装

以上をまとめて入力補助ツールを制作した。完成したアプリケーションを起動した画面が図7である。




図7 初期状態（総画数1画の検索結果に相当）

左上に並んでいるものが 106 種類の部品ボタンであり、画数順に並んでいる。その下にある範囲スライダは画数を絞り込むつまみである。スライダの右には土の範囲指定ができるようになっていて、スライダの画数に厳密に一致する検索、±1 画の幅を以て検索する検索、±2 画、±3 画を指定できる。このことにより、国・地域によって画数の異なる漢字検索に対応させている。

部品ボタンをクリックすると、その部品を含む漢字に絞り込まれる。グレーアウトしているボタンは、現状で絞り込まれた対象に含まれない部品を指す。図7は、総画数1画に一致する漢字を検索した初期状態で、下の四角に22個の検索結果が並んでいる。

図8は総画数12画に一致する「土」「皿」を含む漢字の検索結果である。14個の漢字が表示されている。ピンク色のボタンが絞り込みに指定した部品を指す。白い部品ボタンをクリックするとさらにその部品で絞り込むことになる。




図8 検索結果その1




図9 検索結果その2 (関連字および IVD の表示)

図9は総画数16画で「しんにょう」と「糸」を含む漢字の検索結果である。検索結果の漢字をクリックすると、画面右部分にその漢字が拡大表示され、コードポイントが表示されるほか、グリフwi

キに登録されている異体字関係にある別のコードポイントの漢字が列挙される。また IVD に登録されている、選択した漢字をベースとする異体字グリフも併せて表示される。図 10 はその拡大図であるが、検索結果中の「縫」をクリックしていて、上の 6 字がその異体字関係にある別漢字であることと、下の 5 字（そのうち 2 字は下に隠れている）が「縫」の異体字（IVD）グリフ（1 文字目は 1 点しんによう十久の末筆がトメ、2 文字目は 2 点しんによう十久の末筆が払い、3 文字目は 1 点しんによう十久の末筆が払い…）であることを示している。これらの文字を他のアプリケーションにコピーアンドペーストすることで漢字を入力する補助となる。このツールによって Unicode の 10 万の漢字と 3 万の異体字を余すところなくパソコンに入力することができる。



図 10 図 9 の一部拡大

5. おわりに

5-1 現状における課題

本稿では大規模漢字集合に対応したフリーフォントの制作と、入力補助ツールの制作を行った。現状で判明している問題点は主に 2 つである。

- ① OS・アプリケーションにおける文字コードの対応のタイムラグ：セキュリティ対策から、OS やアプリケーションにおいて、文字コードで未定義のコードポイントに対しては、特にフォントの指定がない限りフォールバックとしてのフォント表示を行わないとのことである（emk 2023）。つまりせっかく文字コードの改訂で新しい字種が収録され、その改訂に対応したフォントを導入しても、OS やアプリケーション側の対応が遅れると、実際には表示されないケースが発生する。オープンソースであれば自分で修正する・改善要求を出すなどの対応も可能であるが、基本的に待つしかない類の問題である。
- ② 入力補助ツールの検索スピードの問題：当ツールで最も候補数の多い「総画数 13 画±3 画」で検索を行うと 54,503 個の候補が表示され、それにかかる時間は 7 秒程度（CPU : i7-1065G7、RAM : 16GB、OS : Windows 11、ブラウザ : Firefox）であり、快適に操作できるとはいがたい。こちらも設計思想として 1 ファイル単体で動くこととしているため、これ以上の改善は難しいと思われる。

5-2 将来の展望

今回は画面表示の関係で部品数を 106 個としたが、部品数と検索のしやすさの関係について、漢字スキルの大小がどのように影響するかなど、より詳細な検証を行いたい。これについては稿を改めることとする。

〈注〉

- 1) たとえば『角川 新字源 改訂新版』（角川書店、2017 年）では親字数を（筆者注：約）13,500 としている。
- 2) IVD は漢字ブロックではないが同じ表にまとめている。各ブロックは収録後の版において数文字の追加がなされている場合がある。互換漢字ブロックはコードポイントの抜けが 2 つあるほか、一部のコードポイントは互換漢字ではなく統合漢字の扱いとなっている。互換漢字および互換漢字補助はいくつかのサブブロックの集合体となっているため版の記述は省いた。
- 3) IPAmj 明朝 <https://moji.or.jp/mojikiban/font/>
- 4) BabelStoneHan <https://www.babelstone.co.uk/Fonts/Han.html>
- 5) 花園明朝フォント <https://glyphwiki.org/hanazono/>
- 6) 謎乃明朝 <https://github.com/ge9/NazonoMincho>
- 7) ISO/IEC JTC1/SC2/WG2/IRG <https://appsrv.cse.cuhk.edu.hk/~irg/>
- 8) Unicode Character Database 内 : UnicodeData.txt
<https://www.unicode.org/Public/15.1.0/ucd/UnicodeData.txt>
- 9) FontForge <https://fontforge.org/en-US/>
- 10) GitHub 内 : kamichikoichi/jigmo <https://github.com/kamichikoichi/jigmo>
- 11) 字雲フォント <https://kamichikoichi.github.io/jigmo/>
- 12) Creative Commons CC0 <https://creativecommons.org/publicdomain/zero/1.0/>
- 13) MIT ライセンス原文 <https://opensource.org/license/mit/>
- 14) 第 4 章は漢字文献情報処理研究会・第 20 回大会（2018 年 1 月於花園大学）にて筆者が口頭発表した「大規模漢字集合の文字検索を自作する」の内容および発表で得られたご意見をもとに改めて制作しなおしたものである。
- 15) UniHan データ : Radical-Stroke Index
<https://www.unicode.org/Public/UCD/latest/charts/RSIndex.pdf>
- 16) Unihan Radical-Stroke Index <https://unicode.org/charts/unihanrsindex.html>
- 17) CHISE IDS Find <https://www.chise.org/ids-find>
- 18) 文字情報基盤検索システム <https://moji.or.jp/mojikibansearch/basic>

- 19) グリフウィキ手書き検索 <https://kurgm.github.io/gwtegaki/>
- 20) <http://git.chise.org/gitweb/?p=chise/ids.git;a=tree>
- 21) <https://raw.githubusercontent.com/cjkvi/cjkvi-ids/master/ids.txt>
- 22) <https://babelstone.co.uk/CJK/IDS.TXT>
- 23) <https://glyphwiki.org/wiki/Group:sandbox@496>

〈参考文献〉

- emk, 2023, 「利用者:emk 拡張 I の漢字を web ブラウザで表示する」(<https://glyphwiki.org/wiki/User:emk@5>, 2024 年 1 月 4 日閲覧) .
- 日本漢字能力検定協会, 2021, 「一番多い同音異義語は?」
(<https://www.kanken.or.jp/kanken/trivia/category06/16060106.html>, Internet Archivers より 2021 年 7 月 22 日時点の記録を 2024 年 1 月 4 日閲覧)
- Unicode Inc., 2022, “Ideographic Variation Database,” (<https://unicode.org/ivd/>, 2024 年 1 月 4 日閲覧).
- Unicode Inc., 2023a, “The Unicode Standard 15.1.0,” (<https://www.unicode.org/versions/Unicode15.1.0/>, 2024 年 1 月 4 日閲覧).
- Unicode Inc., 2023b, “The Unicode® Standard Version 15.1 - Core Specification, Appendix E: Han Unification History,” (<https://www.unicode.org/versions/Unicode15.1.0/appE.pdf>, 2024 年 1 月 4 日閲覧) .

Production of Large Kanji Fonts for International Standardized Character Sets

KAMICHI, Koichi

In this paper, I detail the development of a Kanji font containing all of the approximately 100,000 Kanji characters in the Unicode international standard character code released on September 2023, as well as 30,000 variants registered in the ideographic variation database. In addition, I created a tool to search 130,000 characters.

Key words : Unicode, Kanji, Variants, Fonts, Kanji Parts