

ありうべき日本語処理とは

by 中 博俊



わんくま
同盟

わんくま同盟 福岡勉強会 #4

我々が普段利用している日本語。
無意識のうちに日本語処理を行っていませんか？

日本人が、日本語を使う上で、
自然体に利用できる情報処理
が求められています。



残念ながら私は日本語学者ではなくDeveloperです。

記述の中には日本語の歴史などで誤りがあるかもしれません
せんが、その節はご容赦ください。



キーワードについて

- ・言語処理についての
キーワードはいろいろ
あります。
- ・1つ1つおさらいしま
しょう。



キーワードについて

- 文字セット(Character Sets)
 - 字体を定義した文字の集合
 - ASCII, JIS, Unicode
 - JIS(n面m区o点) 区点コードなどとも
 - Unicodeなど(U+0000などと表現)
- エンコード(Encode)
 - ある文字セットなどに番号を振り、実際に取り扱う形式のこと
 - ShiftJIS, EUC, UTF-8, UTF-16
 - ShiftJISにもJISにない漢字が含まれている。文字セットでもある。



キーワードについて

- 字体(Character)

- 概念的なもの。



- 字形(Glyph)

- 文字通り字の形
- 前述の違いを区別する

- 書体(Style)

- 薔薇(メイリオ) 薔薇(MSP明朝)

キーワードについて

- 包摂

- **偉** と **偉**

は違う字だけれど、見る人は
その字の違いに有意差を見出さない関係。

- JISでも包摂関係の設定はそこそこある。

18-10

鷗

322a 89a8 196 鳥4

b2aa 9D0E 196 鳥[11]

[S9738] [M47268]c

オウ, かもめ 地 詳説

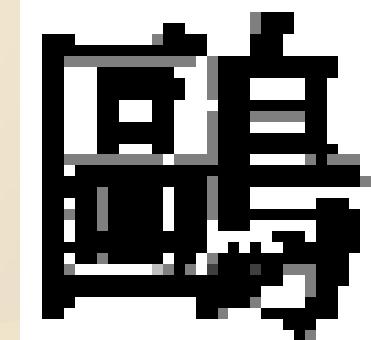
73

鷗



両者は包摂関係にある。

両者の字体は同一。
コード化した場合も同一(JISコード)



わんくま
同盟

わんくま同盟 福岡勉強会 #4

文字に関するJIS標準

- ASCII(1963)
- JISX0201(1969)
 - ラテン文字と半角カタカナ
- JISX0208(1978(旧JIS), 1983(新JIS))
 - 第1水準, 第2水準
- JISX0212(1990)
 - 補助漢字
- JISX0213(2000)
 - 第3水準, 第4水準

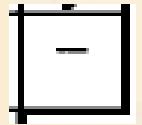


ASCIIとJISの非互換

- ASCIIは文字集合です。
- JISも文字集合です。
- 両者は同一、または包含関係のように思われますが、文字集合としての互換性はありません。



YEN SIGN



OVER LINE

0	@	P	｀	p
!	1	A	Q	a
"	2	B	R	b
#	3	C	S	c
\$	4	D	T	d
%	5	E	U	e
&	6	F	V	f
'	7	G	W	g
(8	H	X	h
)	9	I	Y	i
*	:	J	Z	j
+	;	K	[k
,	<	L	¥	l
-	=	M]	m
.	>	N	^	n
/	?	O	_	o



わんくま
同盟

わんくま同盟 福岡勉強会 #4

文字に関するJIS標準

- ASCII(1963)
- JISX0201(1969)
- 初版制定年度から考えても、日本語がカタカナだけとはいえないだけで大きな前進
- 通貨記号がないと実質的に利用できないため、¥と＼の違いはどうでもよかったですと思われる。



今回のVista問題は一体何の問題？

- **字形が変わる**
- **字が増える**
- **結合文字の正式対応**



字形が変わる

いままでも
散々変わつて
います。



わんくま
同盟

わんくま同盟 福岡勉強会 #4

字形が変わる(JISX0208の変遷)

- 78 1978年2月1日刊行第1次規格に用いられた字形(第2次規格で改変)。
- 78誤 第1次規格の正誤票で誤とされた字形で、誤字形であったもの。当該区点位置は、51-48(嗤), 54-82(幣), 73-28(葵), 80-19(唯)について、附属書7“区点位置詳説”に示す。
- 78/1 第1次規格第1刷に用いられ、1978年11月発行の正誤票で置換えられた字形ではなく、当該区点位置に包摂される。
- 78/4 第1次規格第4刷より前の規格票に用いられ、第4刷附属の正誤票で置換えではなく、当該区点位置に包摂される。
- 78/4X 第1次規格第4刷より前の規格票の字形索引に用いられ、第4刷附属の正誤字形ではなく、当該区点位置に包摂される。
- 78/4正 第1次規格第4刷附属の正誤票で置換えが指示され、当該区点位置に包摂される。
- 78/4- 第1次規格第4刷以降の第1次規格で用いられる字形。
- 78/5 第1次規格第5刷だけに見える字形。
- 83 1983年の第2次規格に用いられた字形(第3次規格で改変)。
- 78-83 第1次規格・第2次規格を通じて用いられた字形。なお、この規格の例示字体の字形は、第3次規格(1990年)によるもの。



わんくま
同盟

わんくま同盟 福岡勉強会 #4

字形が変わる

今回の変更は2000年の国語審議会の審議がベースになっています。

この2000年の国語審議会の答申のポイントは3つ

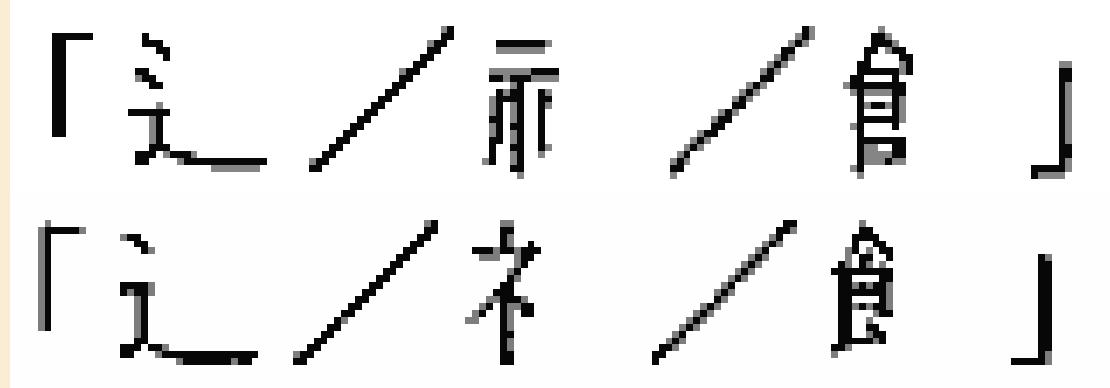
- 表外漢字字体表
 - 今回の範囲
- 国際社会に対応する日本語の在り方
 - Hirotoshi, Nakaと書くかNAKA Hirotoshiと書くか等
- 現在社会における敬意表現
 - 敬語についてなど。この後文化審議会 国語分科会(国語審議会の現在の継承機関) 敬語小委員会で、5種類に分けるなどが最近の話題。

表外漢字字体表についてのポイント

印刷標準字体

字体の中で標準とする字形は常用漢字を除き康熙字典に原点を見出すこと。

3部首許容



しんにゅう、しめすへん、しょくへんは昔より下の形を印刷で使ってきたから、特別に許す。



わんくま
同盟

わんくま同盟 福岡勉強会 #4

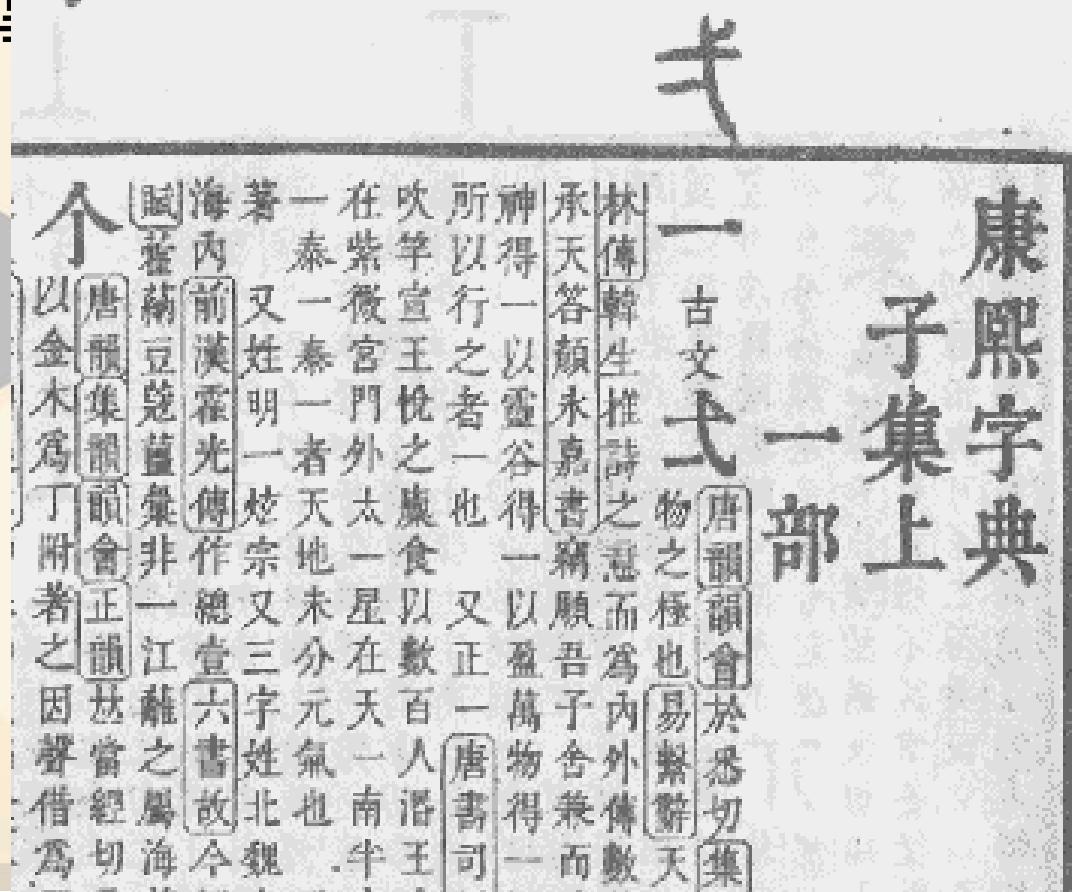
そもそも康熙(熙)字典ってなによ？

- 1716年に中国で作られた、最も完成された初めての漢字の事典



そもそも康熙(熙)字典ってなによ？

- 1716年に中国
　　めの漢字の



常用(当用)漢字vs表外漢字

- 現在の常用漢字は1946(昭和二十一年)/1/16に吉田茂首相の名前で出されたものが最初。
- 1949(昭和二十四年)/4/28に字体の変更などが大掛かりに行われた。
- 澱谷區 → 渋谷区と変更されたのは戦後の漢字行政の決定による。
- 區は区とされたにもかかわらず、森鷗外の鷗の字は鷗に戻る。



常用漢字

- ・ 常用漢字 자체는 今後定期的に改定しようと
している。
- ・ 新常用漢字表を平成十九年度の文化審議会
で策定するような方向
- ・ 常用漢字表に表外漢字から採用されると、代
表字形も変わるかもしれない。



異体字をどうするの？

- ・ 濡(U+6F80, JIS213:1-63-8)
- ・ 滢(U+6F81, JIS213:1-63-7)
- ・ 渥(U+6E0B, JIS213:1-29-34)
- ・ 区(U+533A, JIS213:1-22-72)
- ・ 區(U+5340, JIS213:1-50-31)



異体字をどうするの？

- .NET System.String
 - PS C:\Users\localnaka> "渢" -eq "澁"
 - False
 - PS C:\Users\localnaka> "渢" -eq "澁"
 - False
- .NET System.Data.SqlTypes.SqlString
 - \$a = New-Object Data.SqlTypes.SqlString "渢"
 - \$b = New-Object Data.SqlTypes.SqlString "澁"
 - \$a -eq \$b
- SQL Server 2005
 - declare @a table(col nvarchar(100))
 - insert into @a values('渢')
 - insert into @a values('澁')
 - insert into @a values('澁')
 - select * from @a where [col] collate Japanese_90_CI_AI = '渢'



異体字をどうするの？

- .NET System.String
 - PS C:\Users\localnaka> "渢" -eq "澁"
 - False
 - PS C:\Users\localnaka> "渢" -eq "澁"
 - False
- .NET System.Data.SqlClient.SqlString
 - \$a = New System.Data.SqlClient.SqlString("渢")
 - \$b = New System.Data.SqlClient.SqlString("澁")
 - \$a -eq \$b
- SQL Server 2005
 - declare @a table(col nvarchar(100))
 - insert into @a values('渢')
 - insert into @a values('澁')
 - insert into @a values('澁')
 - select * from @a where [col] collate Japanese_90_CI_AI = '渢'

全部だましめ



わんくま
同盟

わんくま同盟 福岡勉強会 #4

今回のVista問題は一体何の問題？

- 字形が変わる
- 字が増える
- 結合文字の正式対応



わんくま
同盟

わんくま同盟 福岡勉強会 #4

今回のVista問題は一体何の問題？

Unicode対応 していないの？



わんくま同盟 福岡勉強会 #4

今回のVista問題は一体何の問題？

- 字形が変わる
- 字が増える
- 結合文字の正式対応



Unicode結合文字をどうするの

- サロゲートペアのことではありません。

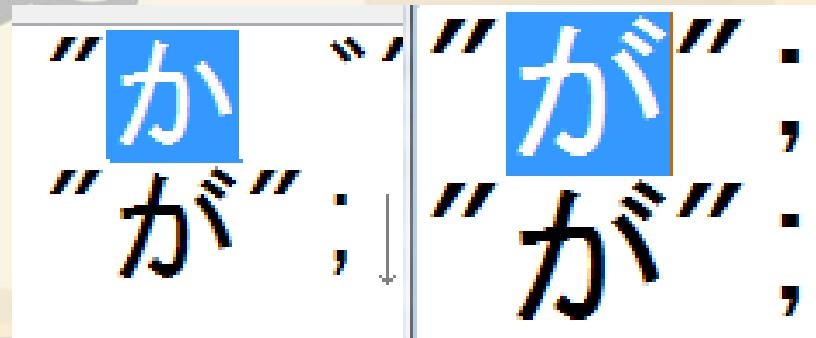
304B か HIRAGANA LETTER KA

304C が HIRAGANA LETTER GA

≡ 304B か 3099 ♂

304D き HIRAGANA LETTER KI

- “が”という文字はU+304Cで定義しているが、U+304B, U+3099も同様とみなすという意味。
- Windows Vistaから正式に対応



Unicode結合文字をどうするの

- .NET System.String1(ただのEqual)
 - string a = "が";
 - string b = "が";
 - MessageBox.Show((a + "==" + b + "=" + (a == b).ToString()).ToString());
- .NET System.String1(カルチャ依存)
 - MessageBox.Show((a + "==" + b + "=" + (string.Equals(a, b, StringComparison.CurrentCulture)).ToString()).ToString());
- .NET System.Data.SqlTypes.SqlString
 - System.Data.SqlTypes.SqlString a = new System.Data.SqlTypes.SqlString("が");
 - System.Data.SqlTypes.SqlString b = new System.Data.SqlTypes.SqlString("が");
 - MessageBox.Show((a + "==" + b + "=" + (a == b).ToString()).ToString());
- SQL Server 2005
 - declare @a table(col nvarchar(100))
 - insert into @a values(nchar(12363) + nchar(12441))
 - insert into @a values('が')
 - select * from @a where [col] = 'が'



Unicode結合文字をどうするの

- .NET System.String1(ただのEqual)

 - string a = "が";
- string b = "が";
- MessageBox.Show((a + "==" + b + "=" + (a == b).ToString()).ToString());

- .NET System.String1(カルチャ依存)

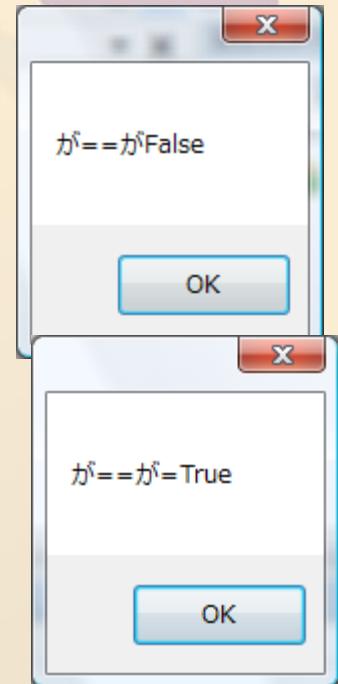
 - MessageBox.Show((a + "==" + b + "=" + (string.Equals(a, b, StringComparison.CurrentCulture)).ToString()).ToString());

- .NET System.Data.SqlTypes.SqlString

 - System.Data.SqlTypes.SqlString a = new System.Data.SqlTypes.SqlString("が");
- System.Data.SqlTypes.SqlString b = new System.Data.SqlTypes.SqlString("が");
- MessageBox.Show((a + "==" + b + "=" + (a == b).ToString()).ToString());

- SQL Server 2005

 - declare @a table(col nvarchar(100))
- insert into @a values(nchar(12363) + nchar(12441))
- insert into @a values('が')
- select * from @a where [col] = 'が'





そんなことより



わんくま
同盟

わんくま同盟 福岡勉強会 #4

繰り返し文字をどうするの

3031	↖	VERTICAL KANA REPEAT MARK	(5)	(4)	(3)	(2)	(1)
3032	↗	VERTICAL KAN SOUND MARK • the preceding preferred to the following	一	ばら	しげ	しみ	いよ
3033	/	VERTICAL KAN SOUND MARK	つ	く	く	く	く
3034	/＼	VERTICAL KAN SOUND MARK • the preceding conjunction with the following	代る	思ひ	こころ	しば	それ
3035	\	VERTICAL KAN SOUND MARK	くり返し	知らず	く	く	ます
			ひらり	エッサッサ	く	く	く
			く	く	く	く	く
			く	く	く	く	く



繰り返し文字をどうするの

2005

3005

々々々々

IDEOGRAP

2006

々々々々

IDEOGRAP A D

(5)

(4)

(3)

(2)

(1)

双葉山々々々々

一歩々々々々々

正々々々々々々

我々々々々々々

世々々々々々々

堂々々々々々々

近々々々々々々

個々々々々々々

年々々々々々々

近々々々々々々

日々々々々々々



わんくま
同盟

わんくま同盟 福岡勉強会 #4

かなをどうするの

- 正假名 vs 現代仮名

- 言う=言ふ

- 文語体 vs 口語体

- てふてふ=ちようちよう

- 送りがなのゆれ

- 味わう=味う



わんくま
同盟

わんくま同盟 福岡勉強会 #4

かなをどうするの

- 半角 vs 全角
 - $1=1$
- 英文スペルの同一字形
 - D(U+13A0 チェロキー)
 - A(U+0410 キリル)



完全なユニバーサルフォントないし…

	1D10	1D11	1D12	1D13	1D14	1D15	1D16	1D17	1D18	1D19	1D1A	1D1B	1D1C	1D1D
0		⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	m		~	♪	:
1		⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚
2		,	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚
3		₩	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚
4	⋮	{	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚
5		{		⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚
6	:	—		⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚
7	:	—		⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚

Unicode (追加多言語面) - 音楽記号

メイリオ

文字カテゴリ

- Unicode (基本多言語面)
- Unicode (追加多言語面)
- 線文字 B 音節
- 線文字 B 表意文字
- エーゲ数字
- 古代イタリア
- ゴート文字
- ウガリト
- デザレット
- シェイヴィアン
- オスマニア
- キプロス
- ビザンチン音楽記号
- 音楽記号
- 太玄經記号
- 数学英数字記号
- Unicode (追加漢字面)
- Unicode (15面)
- Unicode (16面)
- シフト JIS
- JIS X 0208

	0	1	2	3	4	5	6
U+1D100	<input type="checkbox"/>						
U+1D110	<input type="checkbox"/>						
U+1D120	<input type="checkbox"/>						
U+1D130	<input type="checkbox"/>						
U+1D140	<input type="checkbox"/>						
U+1D150	<input type="checkbox"/>						
U+1D160	<input type="checkbox"/>						
U+1D170	<input type="checkbox"/>						
U+1D180	<input type="checkbox"/>						
U+1D190	<input type="checkbox"/>						



登録されていない漢字は？

- 今昔文字鏡
 - 過去に一度でも出現した文字を分けて登録する方針
 - 一字形主義

文字収録範囲

今昔文字鏡16万字

大漢和辞典(大修館書店) 5万字

Unicode 2.7万字

JISX0221(ISO/IEC10646)

JIS 第1・第2水準 + JIS 第3・第4水準

JISX0213

6,355字 + 3,695字

日本・中国・台湾・韓国・ベトナムの漢字

甲骨文字、西夏文字、水族文字…



わんくま
同盟

わんくま同盟 福岡勉強会 #4

あたらしい漢字政策が取られたら？

- 日本、韓国、北朝鮮、中国(香港)、台灣、ベトナムあたりが現在の漢字ユーザ
- 国の施策で漢字の省略を奨励したらどうするの？
- 字体は同じだけど、字形が大きく変わる
- その字形は別の国で使っている。
- →変更できない。
- 国別主義で解決できるのか？
 - ・ 同一字形の別コードはフィッシングを生む



日本語は生きている。今後も入れ替え、変更は発生する。

固定化して考へてはならない。



Microsoft®

**ready
for a new day**



参考文献など

Michel Caplan(International Fundamentals team)

<http://blogs.msdn.com/michkap>

JIS X 0213:2004 対応と新日本語フォント「メイリオ」について

http://www.microsoft.com/japan/windows/products/windowsvista/jp_font/default.mspx

国語審議会

http://www.mext.go.jp/b_menu/shingi/12/kokugo/index.htm

青空文庫(当用漢字表など)

http://aozora.gr.jp/kanji_table/

言葉言葉言葉

<http://members.jcom.home.ne.jp/w3c/>

Unicode 表

<http://www.unicode.org/charts/>

国語表記の基準

<http://www.bunka.go.jp/kokugo/frame.asp?tm=20070409103237>



文字コード表に親しもう

IME2007の文字コード表は秀逸

The screenshot shows two windows side-by-side. On the left is the 'IME パッド - 文字一覧' window, which displays a grid of Japanese characters for the 'JIS X 0213 (2面)' font. The right window is the '文字コード表' (Character Map) application, showing a large grid of various characters from different code pages. The font dropdown in the Character Map window is set to 'Arial'. A status bar at the bottom of the Character Map window shows 'U+0021: Exclamation Mark'.

IME パッド - 文字一覧

JIS X 0213 (2面)

文字カテゴリ

- Unicode (基本多言語面)
- Unicode (追加多言語面)
- Unicode (追加漢字面)
- Unicode (15面)
- Unicode (16面)
- Shift JIS
- JIS X 0208
- JIS X 0212
- JIS X 0213 (1面)
- JIS X 0213 (2面)

	0	1	2	3	4	5	6	7	8	9	
2-1-00	𠂇	𠂉	𠂊	𠂋	𠂌	𠂍	𠂎	𠂏	𠂐	𠂑	
2-1-10	𠂔	𠂖	𠂗	𠂘	𠂙	𠂚	𠂛	𠂜	𠂝	𠂞	
2-1-20	𠂟	𠂢	𠂤	𠂥	𠂦	𠂦	𠂨	𠂩	𠂪	𠂪	
2-1-30	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	
2-1-40	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	
2-1-50	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	
2-1-60	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	
2-1-70	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	𠂪	

文字コード表

フォント(F): Arial

コピーリスト文字(A):

選択(S) コピー(C)

U+0021: Exclamation Mark

Windowsの文字コード表
追加面に対応してないけど、文
字名が出るので、ちょっと便利



わんくま同盟 福岡勉強会 #4