tbasic でのユニコード (Unicode) の取扱い

Ver. 1.61 用 tbasic.org [*1]

[2025 年 01 月版]

Tiny Basic for Windows(tbasic) は Ver.1.2 よりユニコード（Unicode）対応になりました。また，Ver.1.6 より，ユニコード対応が強化されました。さらに，Ver.1.61 より，ユニコードの初期設定等が少し変更になりました。ここでは tbasic でのユニコード機能を活用したいと考える方へ，その考え方，使い方について説明します。ユニコードについては，別により詳しい説明文書「ユニコードへ」がホームページにありますので，必要な場合，そちらを参照してください。

[*1] https://www.tbasic.org

目次

第 I 部
基礎知識編

1　ユニコードベースとは

コンピューターでの処理は，外部からデータを入力し，それをコンピューター内部で処理し，その結果を出力するものです。tbasic がユニコードベースになったとは，tbasic 内部での文字処理がすべてユニコード形式で行われることを意味します[*2]。普通に計算処理を行う場合には，内部での文字処理がどのような形式で行われているか，意識する必要はありません。しかし，文書を扱う場合にはユニコードについて，ある程度意識して処理をする必要があります。

また，外部のデータとしては，ユニコード形式の他，種々のタイプのデータが実際に使われていますから，それらのことも考慮する必要があります。

tbasic では，外部データは内部にデータ取り込む時点で，ユニコード形式に変換して処理します。そして，それを必要に応じて，種々の形式に変換して出力します。このため，tbasic では，外部との出入力について種々の形式をサポートしています。

2　テキストファイルとエンコーディング

コンピューターで扱うファイルの分類として，テキストファイルとバイナリファイルがあります。テキストファイルは書式なし文書を保存するファイル，バイナリファイルはそれ以外のファイルと言われています。アルファベットだけを保存するのであれば，テキストファイルは単に改行付きアスキー文字の行の集まりで，単純な構造を持っています。

しかし，漢字等を保存する場合は，対応した形式に従う必要があり，単純ではありません。更に，漢字等を保存する形式は種々あり，それぞれに異なっています。ですから，そのようなテキストファイルを正しく読むためには，それに対応した形式の理解が必要です。この形式をエンコーディング（符号化方式，Encoding）と言います。

また，エンコーディングを規定するためには，対応する文字の集合の規定と，その各々の文字の番号付けが必要になります，これを符号化文字集合と言います。つまり，漢字の文書を扱う場合，

> 漢字の文書を扱う場合，
> 　・符号化文字集合と
> 　・それに対応するエンコーディング
> が必要

となります。

[*2] Windows では内部的に `UTF-16LE` で処理を行っていますが，tbasic を扱う際，このことは特に意識する必要はありません。

3　漢字のエンコーディング

3.1　基本漢字

日本のコンピューターでの漢字の利用は，漢字の符号化文字集合の規定から始まります。

1978 年，日本漢字の符号化文字集合，JIS 基本漢字（JIS X 208）が規定されました。基本漢字は漢字を 94(区) × 94(点) の表（面）に対応付け，全体で 6879 文字が登録されています[*3]。これは，日常での使用にはほぼ十分なものです。1973 年に規定された ISO/IEC 2022 の技術を基本漢字に適用すると，日本語のエンコーディングを構成することができます。

1970 年代の漢字利用は，統一的な規格ではなく，個々のコンピューターでのエンコーディングの個別実装に限られていました。1980 年代に入ると，パーソナルコンピューターや Unix の普及により，統一的な規格が求められようになりました。

それ中で規定された，基本漢字のエンコーディング規格としては次の 3 つがあります。

- Shift-JIS
- EUC
- JIS

Shift-JIS はパソコン用の符号化方式で，1982 年に MSDOS 等に実装され，そして後に，Windows や Macintosh の内部エンコーディングとして，長く使われました。コンピューター内部でのエンコーディングとしては，現在はユニコードエンコーディングが使われていますが，外部ファイル用のエンコーディングとして Shift-JIS は現在でも広く使われています。

EUC は Unix 上で主に使われた符号化方式で 1985 年に規定されました。

JIS は電子メール等で利用されている 7 ビット符号化方式です。電子メールの仕様として使われる場合，ISO-2022-JP とも言われています。

メール本体は ASCII（7 ビット）で構成されるという規則の中で，特殊な変換をしないで日本語を表す方法として考案されました。

正式には 1993 年 RFC1648 で規定されましたが，1986 年頃から使われています。そして，電子メールの送受信のエンコーディング方式としては，現在でも広く使われています。

このように JIS 基本漢字のエンコーディングは，1980 年代に標準化が進み，

> 1980 年代後半のコンピューターでは，基本漢字が標準的に使える

ようになりました。

[*3] ここで現れる 94 と言う数は，元々は，アスキーコード表での印刷可能文字「!」から「~」までの個数に由来します。

3.2 補助漢字・拡張漢字

1990 年になると，補助漢字（JIS X 0212）が規定されました。これは，基本漢字（JIS X 208）に無い漢字等を補ったもので，アルファベット 245 文字，漢字 5801 文字が含まれます。基本漢字とは別な 94(区) × 94(点) の表で構成されています。

EUC は，補助漢字が使えるように拡張が行われ，EUC-JP として規定されましたが，広く使われるようにはなりませんでした。また，Shift-JIS は，補助漢字を使うための拡張はなされませんでした。

更に，2000 年には，拡張漢字（JIS X0213）が規定されました。これは，基本漢字を拡張したもので，２面９４区９４点（11223 文字）で構成されています。第１面は基本漢字の表（面）を基として，基本漢字表で未使用の部分に文字を加えています。第２面は第１面と同じく 94 区 94 点で構成されていますが，実際に規定されているのは 26 点区です。拡張漢字は，基本漢字，補助漢字を含み，エンコーディングが構成しやすい構造をしていました。

これにより，拡張漢字については，Shift-JIS，EUC に対して，それぞれ拡張が行われ，それぞれ，Shift-JIS2004，EUC-JIS-2004 として規定されました。しかし，これらについても広く使われるようにはなりませんでした。

実は現在，よく使われているエンコーディングは，Shift-JIS，EUC，JIS で，いずれも基本漢字が基本です。コンピューター上で標準的に，補助漢字，拡張漢字が使用できるようになるには，規定から少し時間が必要でした。

4　ユニコード（Unicode）

4.1　始まり

符号化文字集合の拡張に伴って，その利用のためのエンコーディングが規定されても，そのエンコーディングが実際のコンピューターで広く使われるようになるとは限りません。

実際のコンピューターでの使用は，コンピューター内部でのエンコーディングでの使用を伴う必要があります。しかし，コンピューター内部でのエンコーディングの更新・変更は，OS 内部でのテキストの取り扱い処理の更新・変更にが必要になるからです。

JIS X 208，JIS X 0212，JIS X 0213 はいずれも 94×94 の表として定義されています。そして，これらの規定は，ISO/IEC 2022 の技術の利用を想定しています。これは複数の表を切り替えてそれぞれの表の文字を使用する方法です。多くの表を用意すれば，それを切り替えることで，多くの文字を使用することができます。しかし，それには煩雑な切り替え処理が必要です。更に，これらのエンコーディングは，１文字が１バイト或いは２バイト，また，場合によっては３バイト必要となるなど煩雑な処理が必要でした。

このような状況は日本に限らず，世界的な問題でした。一方で，世界のグローバル化に伴い，多国語を同時に利用したいとの要望はますます高まっていきます。しかし，この方法では，使用文字を増やすたびに，OS 内部のエンコーディングを修正していく必要があり，そのたびに煩雑さが増し，速度の低下が起こり，困難が伴います。

このことへの対応として，小規模の符号化文字集合を複数個使って，多くの文字を表すのではなく，「世界中の文字を含む大きな符号化文字集合を一つ定めて，それを使ってコンピューターで多国語の文字を扱えるようにする」方法が検討されるようになりました。

1980 年代後半，このような目的への試みへのプロジェクトが始まり，このコードは，Universal，uniform，unique な code の意味から Unicode（ユニコード）と言われるようになりました。

1988 年には「Unicode Standard への提案（Unicode 88）」が公開されました。

そこでは，

> Unicode は ASCII コードの拡張であり，次の性質を持つ。
> ・Unicode は固定 16 ビットコードである。
> ・世界中の文字と固定幅で１対１に対応する。

と主張しています。

4.2　Unicode Ver.1(1991)

1991 年には，多くの組織，企業が参加して Unicode 制定のための非営利国際的組織 Unicode Consortium が発足し，1991 年 10 月にはその仕様書”The Unicode Standard Version 1.0” が発表されました。これは，1988 年の提案に沿って，それを具体化したものでした。

そこでは，

- Unicode 番号は，先頭に U+ を付けた 16 ビットの固定長 16 進数 U+0000 から U+FFFF で表される。
- Unicode は，現在，過去の世界中の文書を表す十分な文字を含んでいる。
- Unicode では，どのような言語であってもエスケープまたは制御記号による切り替えなしで利用できる
- 固定幅のコードは，種々のテキスト処理がより簡単に可能である。

と述べられています。

Ver. 1.0 では，全体で 34,338 の文字等[*4]が登録され，日本語では，JIS X 208（基本漢字），JIS X 0212（補助漢字）が含まれました。

また，内部コードとして 16 ビットを利用する際，Endian [*5]を区別するものとして BOM(Byte Order Mark) が定義されました。

4.3 Unicode Ver.2(1996)

1996 年には Ver. 2.0 が発表されました。Ver. 1 の発表後，各国より多くの文字の登録の要請があり，Ver. 2 では多くの文字が追加され，合計 47,400 文字が登録されています。

Unicode は 16 ビットで表すとされていますが，この範囲では最大 $2^{16} = 65536$ までしか表すことができません。Ver.1 当時の想定ではこれでも十分とされていましたが[*6]，Ver. 2 でこれを超える文字を登録するためのサロゲートペア（Surrogate pair）と言われる拡大法を定めました。

これは，1024×1024 の表を新たに登録可能にするもので，2 個の 16 ビット (=32 ビット）を使って表現されます。この構成法により，Unicode 番号は 0 から 10FFFF となりました。これは 16 ビットを超えるものです。ですから，標準的な方法でこの文字を表すと，4 バイト必要になります。この文字を使用することは，Unicode の最初の目標「固定幅で文字を表す」を修正するものでした。この領域は将来的に極めてまれな文字を割り当てる可能性を残すものとして，文字は割り当てられませんでした。

また，8 ビットエンコーディングとして，UTF-8 が規定されました[*7] 。また，UTF-16 についても言及されています。

纏めると，

- 登録文字数 47,400
- UTF-16 でサロゲートペアの導入
- Unicode 番号は 0 から 10FFFF
- UTF-32 の予感

となります。

[*4] 割り当てられたコードで，必ずしも文字以外のものも含みます。

[*5] バイトを並べる順序のこと。メモリは普通バイト単位で，番号付けされます。例えば，1 番地のバイト数を A，2 番地のバイト数を B とします。これらの 2 バイト (1,2 番地) で数を表す場合，$A \times 256 + B$ とする方法と $A + B \times 256$ とする方法があります。前者を Big-Endian，後者を Little-Endian と言います。

[*6] Ver. 2 の段階でも未割り当てが 18000 もあり，将来予想される必要数を超えると述べられています。

[*7] UTF は Unicode Transformation Format に由来します。]

4.4 Unicode Ver.3(2000)

2000 年には Ver. 3.0 が発表されました。Ver. 3 では 57,709 文字が登録されています。

UTF について，明示的に定義がなされ，16 ビット Encoding，UTF-16BE，UTF-16LE の定義が述べられています。

日本語関係では，半角，全角（Halfwidth，Fullwidth）の性質が定義され，半角カタカナや全角アルファベットが登録されています[*8]。

・半角文字：　ｱｲｳｴｵ
・全角文字：　アイウエオ

纏めると，

- 登録文字数 57,709
- `UTF-8`，`UTF-16` の明確な定義
- 半角，全角の定義

となります。

4.5 Unicode Ver.4(2003) とその後

2003 年には Ver. 4.0 が発表されました。

Ver. 4.0 では，59,213 文字が登録されています。特に，日本語関係では，JIS X 213（拡張漢字）が登録されています。

また，16 ビットを超える領域の Unicode 番号が実際に割り当てられています。例えば，`U+10000` から `U+1005D` に古代ギリシアで使われた音節文字 `Linear B Syllabary` が登録されました。

下の図は，tbasic でこの部分 10 文字[*9]を表示したものです。

このように，Ver. 4.0 では，16 ビットを超えた番号が実際に登録されました。これにより，「16 ビット固定幅で全ての文字を表すという」Unicode の当初の目標は果たされないことになりました。しかしその代わり，

[*8] Shift-JIS では，半角は 1 バイト，全角は 2 バイトとその文字を保存する際のメモリの量も意味しました。しかし，Unicode では Halfwidth，Fullwidth は文字の幅を示す性質で，その文字を保存するためのメモリを意味するものではありません。

[*9] これらの特殊文字を表示するためには，それに対応したフォントが必要です。以下では，Noto Sans Linear B を使用しています。

32 ビットエンコーディング UTF-32 が規定されました。UTF-32 では，すべての文字が Unicode 番号と直接対応付けられ，これを用いれば，固定幅での表現が得られることになります。

Ver.1.0 から Ver.4.0 を通じて次が規定されました。

- 登録文字数 59,213
- 8,16,32 ビット用 Encodeing UTF-8,UTF-16,UTF-32
- Endian 判定記号 Byte Order Mark BOM
- Unicode 番号を 0 から 10FFFF とする。
- 日本語関係では拡張漢字[*10]を含む

これらの，規定により，Ver. 4.0 で現在のユニコードの基本的枠組みが完成したと言えます。

その後更新が続けられ，最新版は Ver. 16(2024 September 10) です[*11]。154,998 文字が登録されています。Ver.1.0.0 は，全体で 700 ページ弱，Ver.16.0.0 はコア部分だけでも 1000 ページを超えます。この他コードチャートは数千ページに及び，全体で膨大な文書になっています。

ユニコードが制定されると，コンピューター内部のコードとしてユニコードが使われるようになりました。現在では，Windows，Mac，Linux，Android 等が採用しています。

Windows で Unicode が採用される前は，内部コードは Shift-JIS を使っていました。この状況では，例えば，日本語の文章に「très bien」と言う言葉を含めることはできません。日本語に限ってみても，人名や地名などで使われる特殊な漢字，例えば鴎，鷗や吉や吉についてみると，Shift-JIS では鷗や吉を扱うことはできませんが，Unicode では扱うことができます[*12]。

4.6 Unicode の成果

ユニコードは世界中の文字を一つの文字集合で表し，それらを簡単に効率的に利用する方法の模索でした。Unicode Ver.1 が発表されて，約 30 年が経ち，その成果を纏めると次のようになります。

- ユニコードは世界中のコンピューターで使われている。⇒ Unicode は世界標準
- ユーザーは，一つのエンコーディングで世界中の文字を混在してコンピューターで使用できる。
- 状況に応じて，UTF-8，UTF-16，UTF-32 を使うことができる。これらはすべてユニコードとして等価である。

例えば，Unicode を使うと，

パソコン，personal computer，persönlicher Rechner，个人电脑，개인용 컴퓨터

のように，外国語が混在する文章を扱うことができます。

[*10] 基本漢字，補助漢字を含みます。
[*11] 2025 年 1 月現在
[*12] 画面等に正しく表示するには対応するフォントが適切にインストールされている必要があります。

5　tbasic で扱える外部ファイル

現在，コンピューターの世界では，広くユニコードが使われつつありますが，Windows では，外部ファイルの日本語形式として，現在も Shift-JIS が広く使われています。

また，tbasic も Ver.1.2 より前のバージョンでは Shift-JIS しか扱えませんでした。しかし実は，Windows の PC での内部的処理には比較的古くからユニコード（`UTF-16`）が使われていました。今後も tbasic は，従来との互換性の維持のため，Shift-JIS を使うことができます。しかし，Shift-JIS で使えない日本語の文字もありますし，可能なら，これからは，ユニコードを使うのが良いでしょう。

tbasic で扱える外部ファイルは上に挙げた通りですが，それらに対応する具体的エンコーディング（Encoding）は次の通りです。

表 1

tbasic でのエンコーディング名	名前	説明
SJIS	Shift_JIS	日本語 (Shift_JIS)
EUC	EUC-JP	日本語 EUC
JIS	ISO-2022-jp	日本語 JIS
UTF-8	UTF-8	Unicode(BOM 無し，UTF-8)
UTF-8BOM	UTF-8	Unicode(BOM 付，UTF-8)
UTF-16LE	UTF-16LE	Unicode(BOM 無し，UTF-16 Little Endian)
UTF-16BE	UTF-16BE	Unicode(BOM 無し，UTF-16 Big Endian)
UTF-16BE	UTF-16	Unicode(BOM 無し，UTF-16 Big Endian)
UTF-16LEBOM	UTF-16	Unicode(BOM 付，UTF-16 Little Endian)
UTF-16BEBOM	UTF-16	Unicode(BOM 付，UTF-16 Big Endian)
UTF-32LE	UTF-32LE	Unicode(BOM 無し，UTF-32 Little Endian)
UTF-32BE	UTF-32BE	Unicode(BOM 無し，UTF-32 Big Endian)
UTF-32BE	UTF-32	Unicode(BOM 無し，UTF-32 Big Endian)
UTF-32LEBOM	UTF-32	Unicode(BOM 付，UTF-32 Little Endian)
UTF-32BEBOM	UTF-32	Unicode(BOM 付，UTF-32 Big Endian)

この表を見る通り，エンコーディング名はファイルの実際の形式について曖昧な部分もあります。このことから，tbasic では，独自なエンコーディング名を使うことにしています。tbasic でエンコーディング名を使う場合，上の表の左端にある「tbasic でのエンコーディング名」を使ってください。

第 II 部
操作編

6　プログラム編集

プログラムは編集画面で，記述・編集します。ここでは，プログラム編集でのエンコーディングの扱いについて説明します。

6.1　初期エンコーディング

初期エンコーディング（Default Encoding）はいくつかの場合で，自動的に利用されるエンコーディングです。tbasic では，Ver.1.61 から，初期エンコーディングが 2 種，

初期読み込みエンコーディング
と
初期書き込みエンコーディング

になりました。初期エンコーディングは，[オプション][環境設定] で行います。環境設定については，詳しい説明が「Basic 入門」「tbasic 導入編」にあります。

■ 初期読み込みエンコーディング

初期読み込みエンコーディングは，テキストファイルを読み込むときに，利用するエンコーディングです。この設定には，具体的なエンコーディングの他に，AUTO：自動という設定があります。自動の場合は，読み込むファイルのエンコーディングを自動判定して，それに従って，ファイルを読み込むものです。殆どの場合，この設定で十分なので，自動判定が推奨です。

初期読み込みエンコーディングの変更は, 環境設定で行うか, プログラムの中で, コマンド SetReadEncoding で行えます。

■初期書き込みエンコーディング

初期書き込みエンコーディングは，テキストファイルを書き込むときに利用するエンコーディングです。推奨は UTF-8 です。UTF-8 以外を使いたい場合は，Shift-JIS でも良いかもしれませんが，très bien といった外国語や，日本語に限ってみても人名や地名など，例えば，吉や鷗など，Shift-JIS では扱えない文字もあるので注意が必要です。。

初期書き込みエンコーディングは，次項で説明する新規プログラムの作成でのエンコーディングとしても使われます。初期書き込みエンコーディングの変更は，環境設定で行うか，プログラムの中で，コマンド SetWriteEncoding で行えます。

6.2　新規プログラムを作成する

エディター画面から，プログラムの「新規作成」をすると，初期書き込みエンコーディングのテキストファイルとして作成されます。以下の画面にある例では，初期書き込みエンコーディングが UTF-8 と設定されていますから，外部ファイルとして UTF-8 と保存するように作成されます。

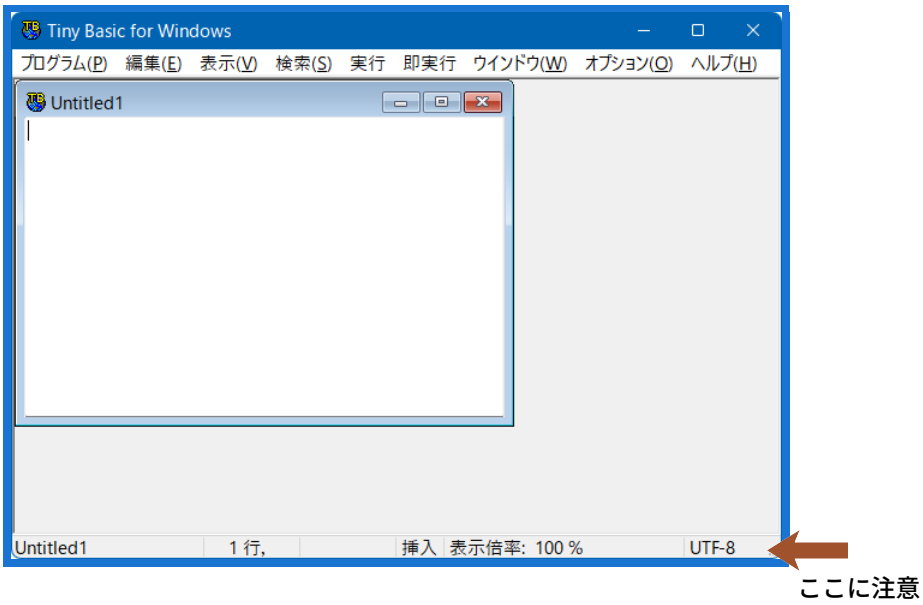

6.3　プログラムを開く

エディター画面から，プログラムの「開く」をクリックし，ダイアログボックスを開き，開くプログラムを選択すると，同時にエンコーディングを選択できます。起動時，「開く」ではエンコーディングは「Auto」設定になります。殆んどの場合，「Auto」で正しく開くことができますが，文字化けが起きる場合は，プルダウンメニューから，エンコーディングを具体的に指定して，開いてください。

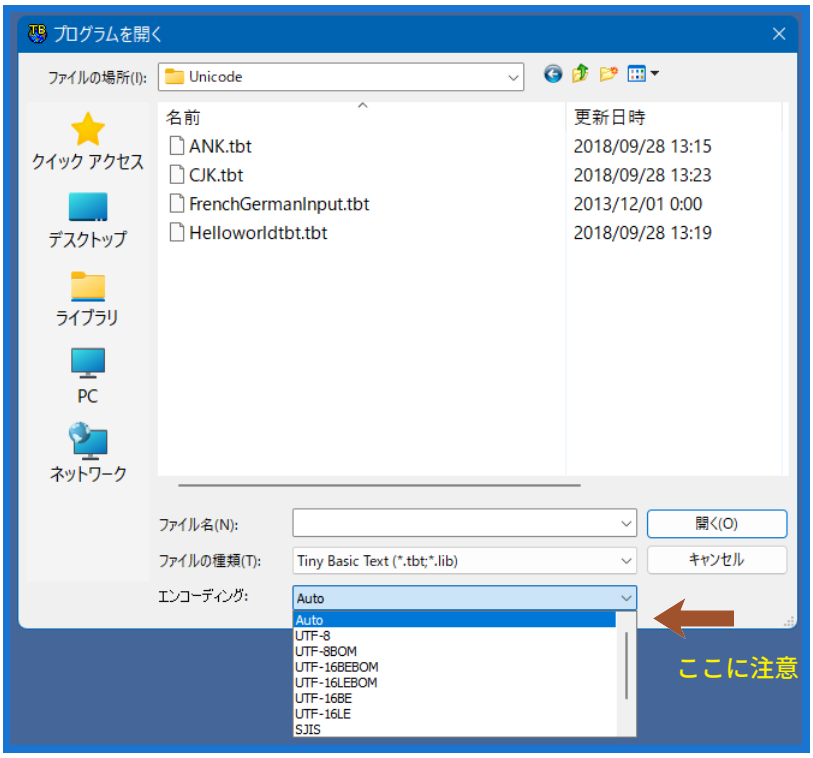

ファイルをエディター画面にドラッグアンドドロップして開く場合や，ダブルクリックして開く場合もエンコーディングは自動判定で読み込みます。

6.4　プログラムを保存する

エディター画面から，「名前を付けて保存」をクリックし，ダイアログボックスを開き，保存するプログラムを選択と同時にエンコーディングを選択できます。

保存しようとるファイルのエンコーディングがデフォルトになりますが，プルダウンメニューから，エンコーディングを具体的に指定することもできます。

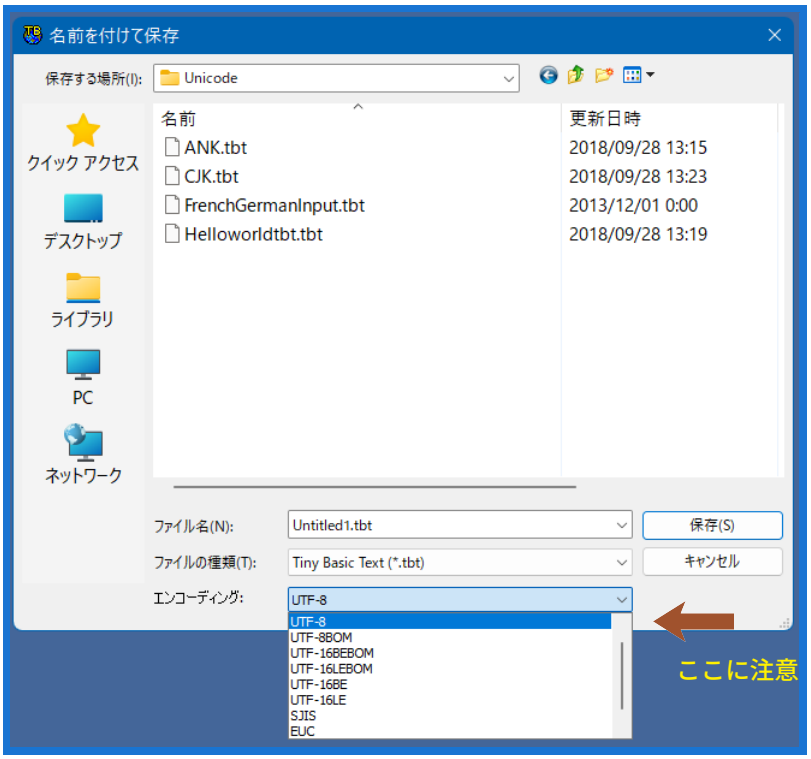

プログラムの「上書き保存」をした場合は，保存しようとするファイルのエンコーディングで保存されます。

7 実行環境

7.1 符号化指定コマンド

初期エンコーディングは，環境設定で指定しますが，プログラムの中で初期エンコーディングを再設定することができます。

```
SetReadEncoding(Enc1)
SetWriteEncoding(Enc2)
```

SetReadEncoding，SetWriteEncoding はそれぞれ，初期読み込みエンコーディング，初期書き込みエンコーディングを Enc1 と Enc2 に再設定します。この再設定は，実行しているプログラムでのみ有効です。ここで SetReadEncoding(Enc1) は，AUTO も可能で，AUTO 初期値推奨ですので，SetReadEncoding は特殊な場合以外は設定不要でしょう。

エンコーディング名は tbasic での名前を文字列で指定します。

例 7.1.

```
SetWriteEncoding("SJIS")
```

初期書き込みエンコーディングを SJIS に指定します。

7.2 Encoding の確認

外部ファイルのエンコーディング名を確認したいことがあるかも知れません。このために，GetFileEncodingName 関数があります。

```
GetFileEncodingName(File1)
```

は，File1 の Encoding 名を返します。判定できない場合は，Unknown を返します。

例 7.2.

```
GetFileEncodingName("file1.txt")
```

は，file1.txt のエンコーディング名を返します。

7.3 外部ファイルへのデータ出力

外部ファイルへのデータ出力は,

```
WriteAllLines(File1,A())
WriteAllText(File1,A())
AppendAllText(File1,Text)
Open file1 for output as #1
```

等で行いますが，この形での使い方では，file1 の初期エンコーディングを利用して，文字配列 A() または，Text のデータを File1 に書き込みます。

初期エンコーディングは SetWriteEncoding を使っていつでも再設定できますから，どのようなエンコーディングでも利用できます。

また,

```
WriteAllLines(File1,A(),Enc1)
WriteAllText(File1,A(),Enc1)
AppendAllText(File1,Text,Enc1)
```

のように，直接エンコーディングを指定することもできます。

例 7.3.

WriteAllLines(file1.txt, A$(),"UTF-8BOM")

配列 A$() を file1.txt にエンコーディング UTF-8BOM で書き込みます。

7.4 外部ファイルからのデータ入力

外部ファイルからの入力は，

```
ReadAllLines(file1)
ReadAllText(file1)
Open file1 for input as #1
```

等で行いますが，この形での使い方では，file1 のエンコーディング初期読み込みエンコーディングの設定に従って，入力を行います。

初期読み込みエンコーディングは AUTO 設定が推奨です。殆どの場合，この方法で期待通りの動作をしますが，時には，この読込では，文字化けが起こって上手く行かないこともあります[*13]。

この場合は，いくつかのエンコーディングを指定して，試して正しいものを探す他ありません。

```
ReadAllLines(file1, Enc1)
ReadAllText(file1, Enc1)
```

の形式では，エンコーディングを Enc1 に指定して読み込みます[*14]。

例 7.4.

```
A$() = ReadAllLines(file1.txt, "EUC")
```

file1.txt を 文字配列 A$() にエンコーディング EUC で読み込む。

[*13] エンコーディングは，場合によっては間違った判定をすることがあります。例えば，Shift-JIS と EUC では，同じファイルで両方ともものエンコーディングが正しいと見做せることがあります。この場合は，一方のエンコーディングでは正しく読めますが，他方のエンコーディングで読むと，不適な文になることがあります。

[*14] Open file1 for ... 形式の文ではこのような使い方はサポートしていません。

8 文字列

8.1 tbasic での文字列

tbasic が内部的に扱う，文字・文字列はすべてユニコード文字・文字列です。ユニコードは，16 進数で，0 から 10FFFF の数で番号付けられています。ユニコードのコード番号を表すときは U+ を付けて表します。0 から FFFF は，元々 16 ビットでユニコードが始まったことから，U+0000 から U+FFFF と 16 進 4 桁で表すのが慣例となっています。この部分を基本領域と言います。それ以上 U+10000 から U+10FFFF を拡張領域と言い，16 進 6 桁で表します。

ユニコードは U+0000,・・・,U+10FFFF のように番号付けされた多国語文字の集まり。
U+0000 ～ U+FFFF を基本領域,
U+10000 ～ U+10FFFF を拡張領域と言う。
tbasic では，これらのユニコード文字の並びが文字列です。

ユニコード文字は U+0000 から，U+10FFFF まで番号付けられていますが，その各々が 1 文字です。1 文字ということで言えばそれらの各々文字について区別はありません。これはある意味で当然な感じですが，多少注意が必要です。

現在でも，色々な場面で，半角文字，全角文字といった区別があり，使い方が違うことがあります。

全角・半角の違いは，元々は文字の幅を意味するものでしたが，コンピューターでは，ASCII で表される英数記号を半角，それ以外のいわゆる漢字を全角文字と言うこともあります。

エンコーディングの立場では，1 バイトで表される文字を半角，2 バイトで表される文字を全角とする場合もあります。Shift-JIS エンコーディングでは，JIS X 0201 部分を 1 バイト，JIS X 0208 部分を 2 バイトで表していました。これを内部コードとしたシステムでの文字列は，漢字は 2 バイト，英数記号は 1 バイトとして扱っていました[*15]。

このようなシステムでは，文字列の長さと，それを表す内部メモリーの大きさが異なり，文字列の処理に煩雑さが伴いました。

一方ユニコードでは，半角文字と全角文字は文字としての数え方に区別はありません[*16]。

これにより，それらの煩雑さが無く，簡単に扱うことができます。

つまり，

ユニコードでは文字を数える場合，半角・全角の区別はない。
これにより，文字列処理を，より簡単に行うことができる。

となります。

[*15] tbasic も Ver.1.1 まではこの方式でした。
[*16] ユニコードでの半角全角は文字のフォントの幅についての性質です。

8.2　tbasic での文字列への入力

tbasic のエディターはユニコード対応エディターですから，ユニコードをそのまま入力可能です。普通は，キーボードで IME を利用して入力しますが。IME パッドからも入力できます。

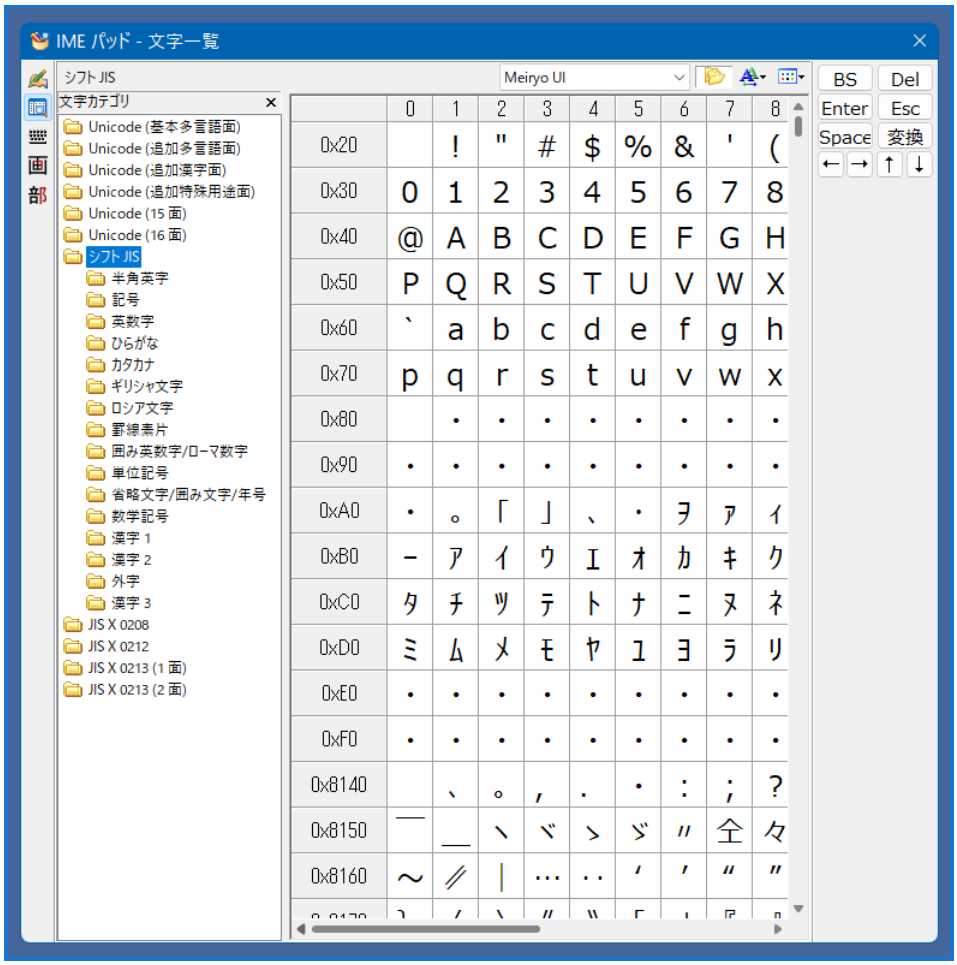

ユニコード番号が分かっている場合は，プログラムの中で，ユニコード番号から対応する文字を得ることができます。

tbasic ではコード番号から文字を得る関数として AcsW，AscU, ChrW，ChrU があります。

関数	引数の範囲	説明	逆関数
Chr$	$0 \leqq x < 128$	この範囲で ASC 文字（ユニコード文字）を与えます。	Asc
ChrW	$0 \leqq x < 65535$	この範囲でユニコード文字（基本領域）を与えます。	AscW
ChrU	$0 \leqq x < 1114111$	この範囲でユニコードを与えます。	AscU

AscW，ChrW は対応する Visual Basic の関数と同じもので，16 ビット文字の範囲で処理をします。

例えば ChrW で扱える番号は U0000+〜UFFFF までです。また AscW もそれに対応した文字しか番号を返しません。AscW などが返す数値は 10 進法で返しますが，Hex$を使えば，ユニコード番号で良く使われる 16 進表示で表すこともできます。同様に，&h を使うと，16 進表示で ChrW の入力も可能です。

AscU と ChrU は AscW，ChrW と似たものですが，tbasic 独自の拡張関数です。AscU と ChrU は 16 ビットを超える番号にも対応します。16 ビットの範囲では，AscU と ChrU はそれぞれ，AscW，ChrW と同じ動作をします。AscU(A$) は文字列 A$の先頭文字のユニコード番号を返します。ChrU(N) はユニコード番号 N の文字を返します。

これらを使うと一覧等が簡単に作成可能です。

例 8.1.

```
For i=&h03B1 to &h03B1+24
   A$=A$+ChrU(i)
Next i
```

これを実行すると，

A$="α β γ δ ε ζ η θ ι κ λ μ ν ξ ο π ρ ς σ τ υ φ χ ψ ω"

となります。

例 8.2.

コマンド	実行結果
Print AscW("A")	65
Print Hex$(AscW("叱"))	53F1
Print ChrW(&h53F1)	叱
Print Hex$(AscW("眞"))	771E
Print ChrW(&h771E)	眞
Print Hex$(AscW("真"))	771F
Print ChrW(&h771F)	真
Print Hex$(AscW("潴"))	7026
Print ChrW(&h7026)	潴
Print Hex$(AscU("叱"))	20B9F
Print ChrU(20B9F)	叱

8.3 文字列操作

文字列を操作するための関数やコマンドについて説明します。文字列の標準的な操作としては，文字列の長さや，部分文字列の取得，検索等があります。これらはそれぞれ，関数 Len，Left$，Mid$，Right$，InStr で可能です。

関数名	使い方	意味
Len	Len(A$)	A$ の長さを返す
Left$	Left$(A$,n)	A$ の左から n 文字を返す
Mid$	Mid$(A$,i,n)	A$ の i 番目の文字から n 文字を返す
Right$	Right$(A$,n)	A$ の右から n 文字返す
InStr	InStr(n,A$, B$)	A$ の n 番目の文字から，B$を探し，検索開始位置からの文字数を返す

使い方は，標準的ですが，半角・全角の区別なく，1 文字と数えることに注意してください。

例 8.3.

コマンド	実行結果
Len("半角 ABC と全角ＡＢＣ")	13
Left$("123 １２３半角全角",5)	123 １２
Mid$("日本語の文字",2,3)	本語の
Right$("半角全角 ABC ＡＢＣ",4)	C ＡＢＣ
InStr(1,"全角１２３半角 123","12")	8

ユニコードでは，文字の種類に関わらず，１つの文字は１つと数えると説明しましたが，これには少し補足が必要です。

ユニコードには，結合文字と言う概念があります。これは，「が」と言う文字は「か」と「゛」を結合した文字であるという考えです。「か」は U+304B，「゛」は U+3099 として登録されていますが，一方で，「が」を表す文字は U+304C として登録されています。

「が」と「が（＝「か」と「゛」）」は結果として同じ文字を表しますが[*17]，前者は 1 文字，後者は 2 文字です。

例 8.4.
```
A$=ChrU(&h304C)
B$=ChrU(&h304B)+ChrU(&h3099)
Print A$,B$
Print Len(A$),Len(B$)
```

これの実行結果は，

```
が                    が
 1                     2
```

となります。

[*17] 印刷すると全く同じに見えます。

この状況に対応する関数として Normalize があります。

Normalize(x) は文字列 x を分解して等価な合成文字で置換した文字列を返す。

例 8.5. 上の例での合成文字について,

Normalize(ChrU(&h304B)+ChrU(&h3099)) は，ChrU(&h304C) である「が」

を返します。

サロゲートペアについての扱い

ユニコードは世界中の文字を一つの体系として表示するプロジェクトですが，最初はすべての文字を 2 バイト（16 ビット）で表すことを想定して規定されました。しかし，その後拡張され現在では 21 ビットを使って表現されています。UTF-16 エンコーディングは 16 ビットを基本とする内部処理の方法ですが，21 ビットで番号付けされた文字をすべて 16 ビットでは表現できません。そこで，UTF-16 では，いくつかの文字は 2 コード（32 ビット）で表現しています。このような扱いの文字は サロゲートペア と言われています。つまり，サロゲートペアで表される文字 1 文字は，UTF-16 の内部表現では 2 コード文字の扱いになります。

例えば,「叱」（口へんに七）という文字は U+20B9F で指定される文字で，U+FFFF を超えるコード番号を持ちます[a]。UTF-16 エンコーディングでは U+FFFF を超えるものは 1 コードで表すことはできません。今の場合，**叱**=ChrW(&hD842) + ChrW(&hDF9F) と表され，UTF-16 としては 2 コード（32 ビット）になります。

現在の .NET 系の言語での取扱いは Len や Mid 関数は内部表現で量るのが基本になっていますから，Len("**叱**") =2 と返すことになります。これはある意味大変煩雑なことになります。

そこで，tbasic では，ユニコードとしての 1 文字は 1 文字と扱うことにしました。つまりサロゲートペアは 1 文字として扱う処理を特別に内部的に行います。従って，tbasic では，

Len("**叱**") =1

と返します。このような処理は，文字列処理を行う，Len，Left$，Mid$，Right$，InStr などでも対応しています。ですから，ユーザーは，サロゲートペアの存在を気にせずにプログラムを書くことができます。まとめると

Tiny Basic for Windows での文字列処理ではサロゲートペアについて考えなくて良い。

となります。

[a] 「叱」(U+53F1)（口へんに匕）とは別字です。

「tbasic でのユニコード (Unicode) の取扱い」更新記録

- （2025 年 01 月版）Ver.1.61 用に主に操作編を修正・書き直し。
- （2023 年 03 月版）Ver.1.6 用に全面的に修正・書き直し。ユニコードについての基礎知識を追加。
- （2013 年 10 月版）初版公開