コンピュータ・サイエンス1

第8回
コンピュータでの文字の扱い(1)

人間科学科コミュニケーション専攻
白銀 純子

第8回の内容

- コンピュータでの文字の扱い方(1)

前々回の質問の回答

16進数

- 練習問題: $(55)_8$を16進数になおすこと

$(55)_8 = (45)_{10}$

16)45
16) 2・・・余り: 13
0・・・余り: 2

$(13)_{10} = (D)_{16}$

$(55)_8 = (2D)_{16}$

16進数、つまり$(2D)_{16}$は数!

- 1つ1つの桁の文字がなんであるかによって、数の大きさを表現
- 各桁の文字の並びの順序が違ってしまうと、違う数
  - ✓ $(45)_{10}$と$(54)_{10}$は違う数!

$(2D)_{16}$と$(D2)_{16}$は違う数!

- 余りを並べる順序を間違わないように注意

前回の復習

小数を表現する方法(p. 10)

- 固定小数点方式
- 浮動小数点方式

固定小数点方式[1](p. 10)

- 小数部分の桁数をあらかじめ決めておく方法

Ex. 2進数で表現した数の右から2ビットを小数部分とする場合

10進数の小数	2進数の小数	
0.00	00	00
0.25	00	01
0.50	00	10
0.75	00	11
1.00	10	00
1.25	10	01
1.50	10	10
…	…	
3.75	11	11

➡ 小数部分は$1/2^2$刻み(0.25刻み)で表現

固定小数点方式[2](p. 10)

- 小数部分の桁数がnの場合: 2進数では、小数部分が$1/2^n$刻みで表現

nを大きくすると、それだけ小数部分を細かく表現可能

※ただし、実際コンピュータは小数も2進数で考えているが、人間が考えるときの便宜上、10進数で考えることが多い

固定小数点方式[3](p. 10)

- 小数を表す桁数が決まっていると…

Ex. 右から2桁を小数部分とすると…

$$(2 \div 1000)_{10} = (0.002)_{10} \rightarrow (0.00)_{10}$$

小数を正確に表現できない

何桁分の小数部分を持っているかは数値によって異なる
＝固定小数点方式で小数を表せる場合は少ない

浮動小数点方式

浮動小数点方式[1](p. 10)

- 小数: D × 10^nと表現できる
- Ex.
  - $0.5 = 5 \times 10^{-1}$
  - $-0.0625 = -6.25 \times 10^{-2}$
  - $0.0000000084 = 8.4 \times 10^{-9}$

どの数でも「$\times 10^n$」の「10」の部分は同じ

小数を「$D \times 10^n$」の形と考え、「D」と「n」だけ記憶しておく

浮動小数点方式[2](p. 10)

- 浮動小数点方式:
  小数を「$D \times 10^n$」と考え、「D」と「n」を記憶することで小数を表す方式

Ex.

D = 6.25, n = -3の場合: 0.00625
D = 6.25, n = -2の場合: 0.0625
D = 6.25, n = -1の場合: 0.625
D = 6.25, n = 0の場合: 6.25

nの数値が何かで、小数点が仮数の中を動くように見えるから「浮動小数点」と名づけられた

- D: 仮数部
- n: 指数部

と呼ぶ

浮動小数点方式[4](p. 10)

- コンピュータでは、指数部は2の累乗
  →小数を「$D \times 2^n$」として考え、「D」と「n」を記憶

Ex.

- $0.5 = 1.0 \times (1/2) = 1.0 \times 2^{-1}$
- $-0.0625 = -1.0 \times (1/16) = 1.0 \times 2^{-4}$

大きな数の表現(p. 10)

- 浮動小数点方式を利用して表現

Ex.

- $2000000000000 = 2 \times 10^{12}$
- $-42500000000000000 = -4.25 \times 10^{17}$

指数部が「+」の数になる

コンピュータは「2」と「+12」,「-4.25」と「+17」を記憶しておく
(実際には、「$\times 10^n$」ではなく「$\times 2^n$」で表現)

大きな数の表現[例](p. 10)

- Windowsの電卓のあるモード(オーバーフローをなかなかしないモード)で…

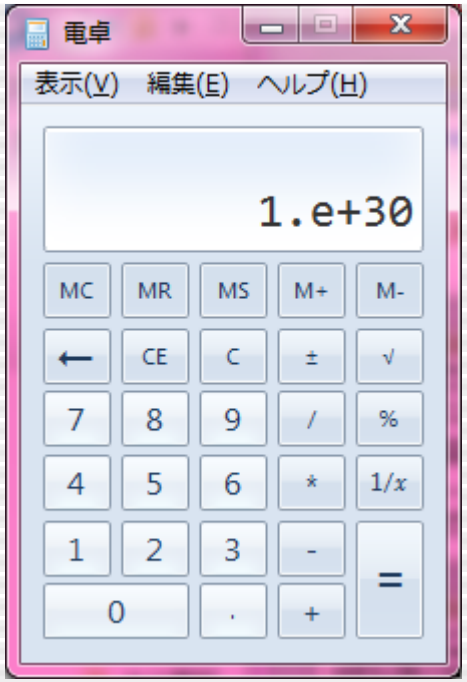

Ex. 10000000000000000 × 10000000000000000
= 1.e+30

1.0×10^{30} という意味
(浮動小数点方式での表現)

※オーバーフローしにくいモードは、大きな数を浮動小数点方式で表現する
= それだけたくさんの桁がある数を表現できるので、オーバーフローしにくい

桁落ち(1)

- 小数部分が無限のものを扱えるわけではない
  - 例えば割り算で割り切れない数や円周率

小数部分を適当なところで切り捨てる
(四捨五入ではない)

例えば…$1 \div 3$: コンピュータは「$0.3333\ldots333$」と考える

本来はこの後も無限に続く

コンピュータが扱える小数の桁数:
「有効桁数」と呼ぶ

桁落ち(2)

- 小数部分が無限のものは適当なところまでで切り捨てられる

本来の数よりも、小数の桁数が小さくなってしまう現象

桁落ちが起こると…

- 数が本来の数よりも小さくなってしまう
  - 微妙な数値が必要な場合には要注意
- 桁落ちをした数に大きな数をかけると、本来の数に大きな数をかけたときとの差が大きくなる

例えば…1÷3の結果が桁落ちし、0.333になるとすると

- 0.333に100000をかけると33300
- 1×100000を3で割ると(計算の順序を変えると)33333.333
- 本来の1/3に100000をかけると、33333.333…

- コンピュータで計算をするときは、計算の順番に注意
  (割り算はなるべく後にすること)
- 例えば「1÷3×100000」の計算は、「1×100000」をしてから3で割る

桁落ち(補足)[1]

- 小数の桁が切り落とされたために、本来の数よりも小さくなってしまう現象
  - Ex. 1÷7の計算
    - 小数点第3位まで表現できるコンピュータ: 0.142
    - 本来の(人間が手で計算した)計算結果: 0.142857142857...

コンピュータの結果では
この部分がなくなる

- 小数が出てくる計算では、割り算の順序が重要

Ex. 1: ある試験の得点(96, 68, 76, 92, 70, 88)の平均点を、小数点第1位まで表現できるコンピュータで計算

桁落ちが発生する時点

順序1(先に割り算): 96÷6 + 68÷6 + 76÷6 + 92÷6 + 70÷6 + 88÷6
= 16 + 11.3 + 12.6 + 15.3 + 11.6 + 14.6 = 81.4

順序2(後で割り算)(96 + 68 + 76 + 92 + 70 + 88)÷6
= 490÷6 = 81.6

割り算の順序によって計算結果が違う
(割り算を後にすると本来の計算結果により近い)

桁落ち[2]

Ex. 2: あるショッピングセンターでの売り上げ予測

- ある月に13209人来て、289157341円売り上げがあった。このとき、1000000人来場したときの売り上げ予測は? (小数点第1位まで表現できるコンピュータで計算)

普通に考えると...売り上げ÷実際の来場人数×1000000人

桁落ちが発生する時点

$289157341 \div 13209 \times 1000000$

$= 21890.9 \times 1000000 = 21890900000$

桁落ち後

割り算を後にすると...

桁落ちが発生する時点

$289157341 \times 1000000 \div 13209$

$= 289157341000000 \div 13209 = 21890933530.1$

桁落ち後

割り算の順序によって、計算結果が大きく違う

文字の表現

文字の符号化(p. 13)

- 文字: コンピュータは整数に置き換えて扱う(番号をつけて扱う)
  - 文字を2進数で表現する(「符号化」と呼ぶ)
- 2進数で表現される文字集合
  - 半角英数文字
    - 図形文字
    - 制御文字
  - 多バイト文字
    - 図形文字

※文字集合: 文字の集まり

図形文字と制御文字(p. 13)

- 図形文字: 通常、画面に表示される文字
  - 人間が明示的に書いたり読んだりする文字
  - アルファベット, 数字, ひらがな, 漢字, 記号, etc.
- 制御文字: 通常、画面に表示されない文字
  - コンピュータに何らかの制御をするための文字
  - 改行, TAB, ESC, etc.

ASCII文字

ASCII文字(p. 13)

- ASCII: American Standard Code for Information Interchange
- 半角文字を表す文字集合
  - アルファベット大文字(26文字)
  - アルファベット小文字(26文字)
  - 数字(10文字)
  - 記号(スペース, 「,」, 「.」, etc.)

1文字を表すために、最低限7ビット必要
(6ビット: 64種類の情報, 7ビット: 128種類の情報)

※1文字を表す2進数の桁数(ビット数)は、どの文字でも同じ(つまり7ビット)

図形文字(p. 13)

- ASCII: 情報量が7ビットで収まるように、扱う文字を取り決めた文字集合
  - アルファベット(大文字・小文字): 52文字
  - 数字: 10文字
  - 記号(スペースを含む): 33文字

図形文字: 合計95文字

番号例(p. 14)

番号	文字	番号	文字	番号	文字
47	0	65	A	97	a
48	1	67	B	98	b
49	2	68	C	99	c
50	3	69	D	100	d
51	4	70	E	101	e
52	5	71	F	102	f
53	6	72	G	103	g
54	7	73	H	104	h
55	8	74	I	105	I
56	9	75	J	106	j

「数」としての0～9ではなく、「文字」としての0～9

番号の決まり(p. 14)

- 7ビットで1文字を表現 = 128文字表現可能
  - 図形文字: 95文字
    - 32番～126番までが図形文字
  - 残り33文字: 制御文字を表現
    - 0番～31番と127番が制御文字
      ※32番のスペースを、制御文字と考えることもある
- アルファベットの大文字と小文字の番号に規則
  - 小文字の番号は、大文字の番号に$32(=(2^5)_{10}=(100000)_2)$を足したもの
    - Ex. A: $(65)_{10} = (01000001)_2$, a: $(97)_{10} = (01100001)_2$
  - 大文字⇔小文字の変換はやりやすい

制御文字例(p. 14)

- BS(8番): Back Space
- HT(9番): TAB
- LF(10番): UNIX系OSでの改行
- CR(13番): Mac OSでの改行
  - Windowsでの改行は、13番と10番を組み合わせて「CRLF」の2つの制御文字で表現される
    - つまり、Windowsでは1つの改行が2文字分(2ビット)

- DEL(127番): Delete

※OS: Operating System(オペレーティングシステム)

ビット数[1](p. 14)

- コンピュータでは8ビットを1つの単位として扱うことが多い
  → ASCII文字も8ビットで表現すると扱いやすい
  - 8ビットのうち、7ビット分(2進数で7桁目まで)で文字を表現する
  - 残りビット(2進数で8桁目)に常に0を入れておく
    - ASCII文字としては無駄なビット
    - 日本語を表現するときに利用

例えば…
A: 65番(10進数)
= 1000001番(2進数)
= 01000001番(2進数, コンピュータ内での表現)
ASCII的には無駄な(何も利用していない)ビット

ビット数[2](p. 14)

- 8ビットで1文字を表現 = 1バイトで1文字を表現

「1バイト文字」と呼ばれる

Ex.「Hello, my name is John.」

- アルファベット: 17文字
- 記号: 2文字
- スペース: 4文字

} 23文字 = 23バイト

ちなみに…

- アスキーアートも文字コードのASCIIから(ASCII art)
  - アスキーアート: 文字だけで作った絵
    - 感情を表す「(^^);」のような単純なものから、人や動物に見えるものまで様々

- アスキーアートの例
  - http://ja.wikipedia.org/wiki/%E3%82%A2%E3%82%B9%E3%82%AD%E3%83%BC%E3%82%A2%E3%83%BC%E3%83%88
  - http://bhdaa.sakura.ne.jp/zukan/

多バイト文字

背景[1](p. 15)

- コンピュータは主にアメリカで作られ発展
  - 使う人も、専門家だけだった
  - 当初は扱う文字はアルファベット・数字・いくつかの記号でよかった
- コンピュータが全世界に普及
  - 使う人も、専門家だけではなくなった
  - 英語圏以外の言語圏に対応する必要が出てきた
    - 様々な言語圏の文字に対応

背景[2](p. 15)

- 様々な言語圏の文字: 英語圏の文字と同様に2進数で表現する必要性
  - 英語圏の文字: 128文字で表現可能
    - 1バイト分(256文字分)のうち、128文字分は英語圏の文字
  - 英語圏以外の文字: 128文字以上必要な場合も
    - 日本語
    - 中国語
    - 韓国語
    - etc.

→ 128文字では収まらない

1文字を複数のバイト(多バイト)で表現

文字化け(p. 15)

- 多バイト文字の出現により、文字化けが発生
- 文字化けの原因
  - フォントの問題
  - 文字集合の符号化方式の問題

「文字コード」と呼ぶ

詳細な理由は何であれ…
要は文字を表す2進数(0と1の並び)を、コンピュータが理解していないために発生
- その2進数をどのような形でディスプレイに表示して良いかをコンピュータが理解していないため

フォントの問題[3](p. 15)

- 機種依存文字: コンピュータによって表現のしかたが違う文字
  - それぞれの文字を表現するビット列が、コンピュータによって異なる
    - 1文字1文字を表現するビット列は、JIS(日本の国家規格)などで決まっている
      → コンピュータの環境に依存しない
    - 規格で決められた文字に含まれていない文字もある

      機種依存文字
    - Ex. 丸付き数字(①, ②, …)、ローマ数字(Ⅰ, Ⅱ, …), etc.
- 外字: 登録されていない文字を、利用者が作ったもの
  - 人名漢字などを作ることが多い
  - 作ったコンピュータでしか使えない

符号化方式の問題[1](p. 15)

- 符号化: 1つの文字を2進数(ビット列)として表現すること
- ある1つの文字を表現するビット列が複数通り存在する場合
  - 半角英数の文字はASCIIの1通りだけ
    - 他にも存在するが、ASCIIが世界標準
    - 大部分のコンピュータはASCIIを利用
  - 日本語は複数通り存在

符号化方式の問題[2](p. 15)

- ある文書で使われている符号化方式をコンピュータが判別できないときに文字化け
  - 判別できなければ、コンピュータが普段使っている符号化方式で表示しようとすることが多い

Ex. Windowsで文書を開いた場合

- 文書はJISで書いてあり、WindowsはJISであると判別できなかった
- WindowsはShift JISとして開こうとする
- 文書は文字化けして表示される

※ソフトウェアによっても、符号化方式を判別できるものとできないものがある
(Ex. Windowsのメモ帳は、JISなどは判別できない)

日本語の符号化方式

日本語の文字(p. 15)

- 日本語固有の文字
  - ひらがな
  - カタカナ
  - 漢字
  - かぎカッコ
  - 句読点
  - etc.

日本語の文字(p. 15)

- ASCII
  - 1文字を8ビットで表現→全部で256文字分表現可能
  - 現状で128文字存在(128文字分利用されている)
- 日本語
  - ひらがな: あ～ん(ゐ, ゑなどの旧字を含む), 濁音・半濁音,
    小文字(「ぁ」,「ぃ」など)
  - カタカナ: ア～ン(ヰ, ヱなどの旧字を含む), 濁音・半濁音(ヴを含む),
    小文字(「ァ」,「ィ」,「ヵ」,「ヶ」など)

169文字

ひらがな・カタカナだけでもASCIIでは表現できない

日本語文字集合の規格(p. 16)

- 現状での日本語文字集合の規格: JIS X 0208:1997
  - ひらがな・カタカナ・漢字・非漢字文字で6879個

JIS第1水準(使用頻度の高い漢字): 2965個
JIS第2水準(使用頻度の低い漢字): 3390個

- $2^{13} = 8192$なので、13ビットで表現可能
- コンピュータ処理では、バイト単位(8ビット単位)が好都合

16ビット(2バイト)で日本語1文字を表現

ASCII文字との区別(p. 16)

- 日本語の文書
  - 日本語の2バイト文字
  - ASCIIの1バイト文字

混在

日本語の2バイト文字(JIS X 0208)とASCIIの1バイト文字は区別する必要
(1つの文書の中で、どれが2バイト文字でどれが1バイト文字か)

- モード切り替えによる区別方法
- ASCII文字の番号を避ける区別方法

モード切り替え(p. 16)

- 文字集合切り替えのための特別な記号を用意
  - ここから先はASCII文字
  - ここから先は日本語文字
  - ここから先は中国語漢字
  - etc.

エスケープシーケンス

通常の文書では頻繁に文字集合が切り替わることがなく、同じ文字集合に属する文字が現れることが多いという性質を利用

- 国際標準規格: ISO-2022
- 日本語に適用したもの: ISO-2022-JP

ISO-2022-JPの例(p. 16)

ESC $B	F|	K¥	$N	ESC (B	JP	ESC $B	$@	!#	ESC (B	¥n
	日	本	は		JP		だ	。		

- 「ESC $B」や「ESC (B」、「¥n」などがエスケープシーケンス
- 「F|」や「K¥」、「$N」などは、2バイト文字をASCII文字で表現した場合の文字
  (2バイト文字は、1バイト文字2文字の組み合わせで表現できる)
- エスケープシーケンス「ESC $B」や「ESC(B」は、3バイトずつ
- 「¥n」は改行を表し、半角文字の扱いなので、改行の前に2バイト文字がある場合は、
  改行と2バイト文字との間にもエスケープシーケンス
- 文章の開始(終了)が1バイト文字の場合は、文章の先頭(終了)にエスケープシーケンスはなし
- 文章の開始が2バイト文字の場合は、文章の先頭にエスケープシーケンスあり

モード切り替えの考え方[1](p. 16)

- 同じ文字集合に属する文字が現れることが多い

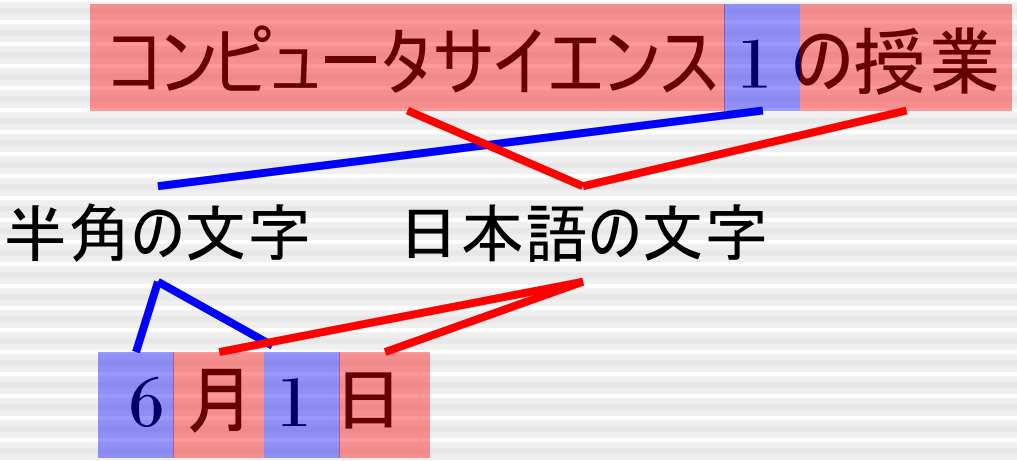

- 上側の文章: 日本語文字がいくつか続いた後、半角文字が少しあり、また日本語文字が続く
- 下側の文章: 日本語文字と半角の文字が交互にある

モード切り替えの考え方[2](p. 16)

- 普通の日本語の文章は、日本語の文字がずっと続き、たまに半角文字が出てくるということが多い

ある言語の文章では、その言語の文字がずっと続き、別の言語の文字はところどころに出てくる

頻繁に文字集合が切り替わるわけではない(ある言語と別の言語の文字が1文字ずつ交互に出てきたり、ということは少ない)
→文字集合がどこで切り替わっているか、わかるようにしておけば良い

モード切り替えの考え方[6](p. 16)

- 日本語文字: 1文字2バイト
- ASCII文字: 1文字1バイト
  - 改行はASCII文字扱い
    - Mac OSやUNIX系OSだとASCII文字1文字分 = 1バイト
    - WindowsだとASCII文字2文字分 = 2バイト
- エスケープシーケンス: 1つ3バイト

東女はTWCUです。

- 日本語文字: 6文字 = 12バイト
- ASCII文字: 4文字 = 4バイト
- エスケープシーケンス: 3個 = 9バイト

} 25バイト

※この文章は改行なしとする

モード切り替えの問題(p. 17)

- 文書を先頭から順番に見ていく場合には問題ない
- 文書を途中から見ていくときに問題が生じる
  - 見始めた途中の文字が、ASCII文字か日本語文字か、エスケープシーケンスかが判別できない

Ex. 見始めた途中の文字が「70」番だった場合

- ASCII文字の「F」?
- 日本語文字の一部?
- 韓国語の一部?

検索や置換などの文書処理に時間がかかる

ASCII文字の番号を避ける(p. 17)

- ASCIIで使われていない番号を2バイト文字の番号にあてる方法
  - EUC(日本語のものを**EUC-JP**)
    - 第1バイト(前半の8ビット)と第2バイト(後半の8ビット)両方でASCII領域が避けられている
  - SJIS(Shift JIS)
    - 第2バイト(後半の8ビット)ではASCII領域も使われている
  - 文章のバイト数は、単純に、日本語文字で2バイト、ASCII文字で1バイトで数えれば良い

EUCとSJIS[1](p. 17)

- ASCII文字: 8個の0と1で、1文字分を表現
  - 実際には、7個の0と1で1文字分を表現
  - 8ビット目は必ず0

＝ ASCII文字は、0XXXXXXX という形

Ex.「a」を0と1で表現すると: 01100001

8ビット目が1になる番号(1XXXXXXXという形の番号)はASCII文字ではない

EUCとSJIS[2](p. 17)

- ASCIIで使われていない番号を2バイト文字の番号にあてる方法
  - EUC(日本語のものを**EUC-JP**)
    - 第1バイト(前半の8ビット)と第2バイト(後半の8ビット)両方でASCII領域が避けられている
  - SJIS(Shift JIS)
    - 第2バイト(後半の8ビット)ではASCII領域も使われている
  - 文章のバイト数は、単純に、日本語文字で2バイト、ASCII文字で1バイトで数えれば良い

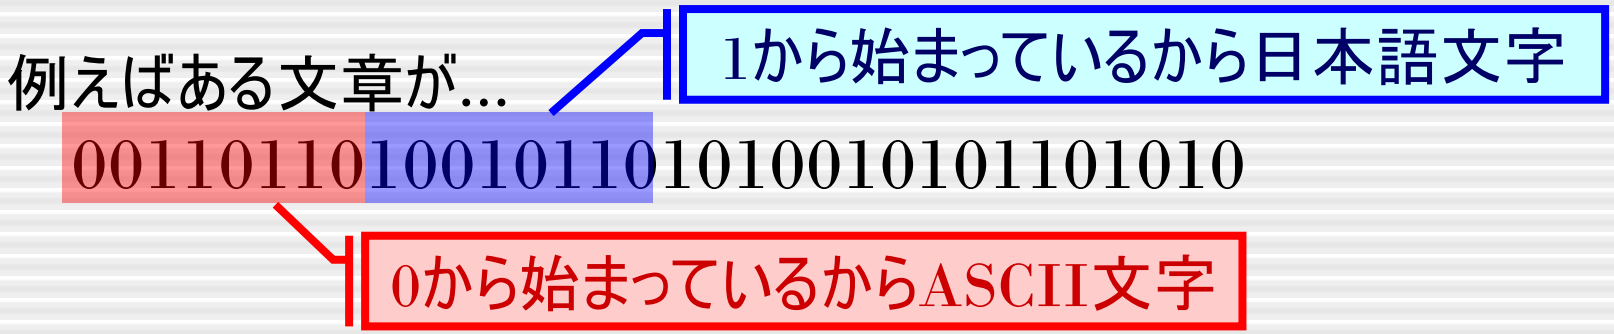

Webやメールでの文字化け(p. 18)

- Webページや電子メール
  - 文字コードの指示が文書中に書かれている場合

    「charset=iso-2022-jp」や「charset=Shift_JIS」など

    ➡ ソフトウェアは指示通りに文字コードを解釈し、表示
  - 文字コードの指示が文書中に書かれていない場合

    ➡ ソフトウェアは文書のデータの特徴から文字コードを判別

    ⬇

    文字化けが発生する場合
    - 文書中の文字コードの指示が間違っている場合
    - 文字コードの指示がなく、文字コードを判別できなかった場合

Unicode

言語圏ごとの文字コード(p. 18)

- これまでの多バイト文字の扱い:
  異なる言語圏ごとに文字集合を作成
  - 様々な文字集合ができてしまって不便
    - コンピュータネットワークの国際化が進んだ
    - コンピュータの資源が豊富になった

↓

国際文字集合規格として各文字集合を統一化

統一文字コード(p. 18)

- Unicode
  - ASCII
  - ラテン文字
  - 日本語
  - 韓国語
  - 中国語
  - ベトナム語
  - ギリシャ文字
  - 記号
  - etc.

Unicodeバージョン5.2.0で
107361文字

UTF-8(p. 18)

- Unicodeでの代表的な符号化方式
- 1文字を1～6バイトの可変長(文字によってバイト数が異なる)で符号化する方式
  - ASCIIやISO-2022-JP、Shift JIS、EUC-JPは1文字を全て同じバイト数で表現している
- OS(WindowsやMacなどのオペレーティングシステム)でファイル名などの内部処理に利用
  - 半角英数を符号化した結果が、ASCII文字と全く同じになるため、従来のシステムと相性が良い

現在、Unicodeへの移行が急速に進んでいる
- ただし、以前から使われてきたファイルを移行するのは大変なので、完全移行には時間がかかる