

コンピュータ・サイエンス1

第10回

コンピュータでの文字の扱い(2)

人間科学科コミュニケーション専攻

白銀 純子

第10回の内容

- コンピュータでの文字の扱い(2)

設問1

- 下記の2進数が計算結果だった場合、7桁の2進数とすると、負の数になる2進数はどれか、すべて答えなさい。

1. 0111100
2. 10001111
3. 011111000
4. 101010101010
5. 0101010100
6. 00001111
7. 11110000

数を7桁にあわせると...



1. 0111100
2. 0001111
3. 1111000
4. 0101010
5. 1010100
6. 0001111
7. 1110000

解答: 3, 5, 7

設問2

- 「やってみよう!」の浮動小数の表現の問題の2. と3. の結果を報告すること
 - 問題2: 0.0000000001234を浮動小数点方式で表現
 - 仮数部は小数点第2位まで

0 . 0 0 0 0 0 0 0 0 1 2 3 4
1 2 3 4 5 6 7 8 9 10

- 0.0000000001234を小数点第2位までの小数にするために
- 「.(小数点)は10回移動する
- 小数点は右に移動している(= 指数部はマイナスの数)

解答: 12.34×10^{-10}

設問2

- 「やってみよう!」の浮動小数の表現の問題の2. と3. の結果を報告すること
 - 問題2: 4560000000000000を浮動小数点方式で表現
 - 仮数部は小数点第2位まで

4 5 6 0 0 0 0 0 0 0 0 0 0 0 0 0
↑ ↑ ↑ ↑ ↑ ↑ ↑ ↑ ↑ ↑ ↑ ↑ ↑ ↑
14 13 12 11 10 9 8 7 6 5 4 3 2 1

- 4560000000000000を小数点第2位までの小数にするために
➡ 「.(小数点)は14回移動する
➤ 小数点は左に移動している(= 指数部はプラスの数)

解答: 4.56×10^{14}

Question!

浮動小数点方式[1](p. 10)

■ 小数: $D \times 10^n$ と表現できる

- Ex. 1: $0.5 = 5 \times 10^{-1}$
- Ex. 2: $-0.0625 = -6.25 \times 10^{-2}$
- Ex. 3: $0.00000000084 = 8.4 \times 10^{-9}$

どの数でも「 $\times 10^n$ 」の「10」の部分は同じ(実際のコンピュータでは「 $\times 2^n$ 」)



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

- 仮数部
 - ✓ 符号は「0」が「+」、「1」が「-」
 - ✓ 固定小数点方式
- 指数部
 - ✓ 符号は「0」が「+」、「1」が「-」(ただし、2の補数表現とは別の特殊な形で表現される)

大きな数の表現 (p. 10)

■ 浮動小数点方式を利用して表現

Ex.

➤ $20000000000000 = 2 \times 10^{12}$

➤ $-425000000000000000000 = -4.25 \times 10^{17}$

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)

浮動小数の計算方法

1. 仮数部の有効桁数が小数点第X位の数にしたときにどうなるかを考える
 - 「X」は問題で与えられる
2. 1. の数になるために、小数点「.」が何桁分移動するかを数える
3. 2. の移動が右向きに移動であれば、2. の数に「-」(マイナス)をつける
 - 左向きに移動であれば、2. の数には何もしない
4. 数を「(1. の小数) $\times 10$ (3. の数)」の形で表す

Ex. 1: 0.0000000001234を、仮数部の有効桁数が小数点第2位の浮動小数として表すこと

1. 仮数部の数: 12.34
2. 12.34になるために、小数点は10回移動する
3. 2. の移動は右向きである→ 2. の回数を「-10」にする
4. 0.0000000001234を浮動小数で表すと: 12.34×10^{-10}

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... $1 \div 6$:

コンピュータは「0.16666...666」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

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...有効桁数が小数点第3位とすると、 $1 \div 6 \times 100000$ の計算は...

- 「 $1 \div 6$ 」の時点で0.166に桁落ちし、それに100000をかけて、16600
- 1×100000 を6で割ると(計算の順序を変えると)、16666.666
- 本来の $1 \div 6$ に100000をかけると、16666.66666666....

- 
- 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「 $1 \div 6 \times 100000$ 」の計算は、「 1×100000 」をしてから6で割る

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)

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・1にはならない)ビット

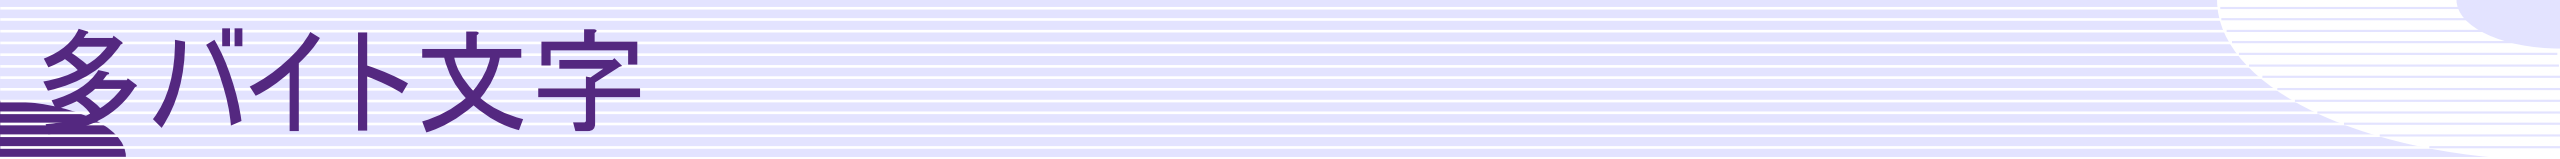
ビット数[2](p. 14)

- 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



多バイト文字

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

日本語の符号化方式

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ので残りは128文字)

■ 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(ㇰ, ㇱなどの旧字を含む), 濁音・半濁音(ヴを含む), 小文字(「ァ」「ィ」「カ」「ケ」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)

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続いて現れることが多い



- 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

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

FUC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、0XXXXXXXX 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(1XXXXXXXX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

例えばある文章が...

00110110100101101010010101101010

1から始まっているから日本語文字

0から始まっているからASCII文字

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

やってみよう!

- プリントの文字コード(この授業での演習用文字コード)によると、下記1.～3.は、どの文字コードでどんな言葉を表しているか?

1. 62B7 2654 4C25 1D7F 720B
2. 6AD0 FBB8 1D7F DCB5 B2BD 09AE
3. A88D 1D7F 4C25 EC4C B2BD EC4C 01C1

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

- 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: どの文字を扱うかと文字の符号化の方法を決めた規格

- UCS(Universal multi-octet coded Character Set)でどの文字を扱うかを規定
- UTF(UCS Transformation Format)で文字の符号化の方法を規定

UTF-8(p. 18)

- Unicodeでの代表的な符号化方式(符号化方式はいくつか存在)
- 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文字を同じバイト数で表現
- 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、UTF-8への移行が急速に進んでいる

- ただし、以前からの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
- 完全移行できたら、文字化けが起こらなくなる

Question!