

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)

Copyright (C) Junko Shiozane, Tokyo Woman's Christian University 2016. All rights reserved.

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

Copyright (C) Junko Shiozane, Tokyo Woman's Christian University 2016. All rights reserved.

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: 0.000000001234を浮動小数点方式で表現

■ 仮数部は小数点第2位まで

0.000000001234

1 2 3 4 5 6 7 8 9 10

➢ 0.000000001234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}

Copyright (C) Junko Shiozane, Tokyo Woman's Christian University 2016. All rights reserved.

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: 456000000000000を浮動小数点方式で表現

■ 仮数部は小数点第2位まで

456000000000000

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

➢ 456000000000000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}

Copyright (C) Junko Shiozane, Tokyo Woman's Christian University 2016. All rights reserved.

Question!

Copyright (C) Junko Shiozane, Tokyo Woman's Christian University 2016. All rights reserved.

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: $0.0000000084 = 8.4 \times 10^{-9}$

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

Copyright (C) Linko Shirogane, Tokyo Woman's Christian University 2016. All rights reserved.

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

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)

Copyright (C) Linko Shirogane, Tokyo Woman's Christian University 2016. All rights reserved.

大きな数の表現(p. 10)

■ 浮動小数点方式を利用して表現

Ex.

- $2000000000000 = 2 \times 10^{12}$
- $-425000000000000000 = -4.25 \times 10^{17}$

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)

Copyright (C) Linko Shirogane, Tokyo Woman's Christian University 2016. All rights reserved.

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: 0.000000001234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. 0.000000001234を浮動小数で表すと: 12.34×10^{-10}

Copyright (C) Linko Shirogane, Tokyo Woman's Christian University 2016. All rights reserved.

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 ÷ 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

Copyright (C) Linko Shirogane, Tokyo Woman's Christian University 2016. All rights reserved.

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いう現象

桁落ち

Copyright (C) Linko Shirogane, Tokyo Woman's Christian University 2016. All rights reserved.

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7で割ると(計算の順序を変えと)、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

Copyright (C) Junko Shiozane, Tokyo Woman's Christian University 2016. All rights reserved.

13

文字の表現

Copyright (C) Junko Shiozane, Tokyo Woman's Christian University 2016. All rights reserved.

14

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

Copyright (C) Junko Shiozane, Tokyo Woman's Christian University 2016. All rights reserved.

15

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.

Copyright (C) Junko Shiozane, Tokyo Woman's Christian University 2016. All rights reserved.

16

ASCII文字

Copyright (C) Junko Shiozane, Tokyo Woman's Christian University 2016. All rights reserved.

17

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)

Copyright (C) Junko Shiozane, Tokyo Woman's Christian University 2016. All rights reserved.

18

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

Copyright (C) Junko Shiozawa, Tokyo Woman's Christian University 2016. All rights reserved.

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

Copyright (C) Junko Shiozawa, Tokyo Woman's Christian University 2016. All rights reserved.

多バイト文字

Copyright (C) Junko Shiozawa, Tokyo Woman's Christian University 2016. All rights reserved.

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

Copyright (C) Junko Shiozawa, Tokyo Woman's Christian University 2016. All rights reserved.

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

Copyright (C) Junko Shiozawa, Tokyo Woman's Christian University 2016. All rights reserved.

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

Copyright (C) Junko Shiozawa, Tokyo Woman's Christian University 2016. All rights reserved.

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**

Copyright (C) Junko Shiozono, Tokyo Woman's Christian University 2016. All rights reserved.

日本語の符号化方式

Copyright (C) Junko Shiozono, Tokyo Woman's Christian University 2016. All rights reserved.

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(あ, ゐなどの旧字を含む), 濁音・半濁音, 小文字(「ぁ」「ぃ」など)
 - カタカナ: ア〜ン(ア, エなどの旧字を含む), 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

Copyright (C) Junko Shiozono, Tokyo Woman's Christian University 2016. All rights reserved.

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

Copyright (C) Junko Shiozono, Tokyo Woman's Christian University 2016. All rights reserved.

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

Copyright (C) Junko Shiozono, Tokyo Woman's Christian University 2016. All rights reserved.

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

Copyright (C) Junko Shiozono, Tokyo Woman's Christian University 2016. All rights reserved.

ISO-2022-JPの例(p. 16)


ESC \$B	Fj	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
- 「Fj」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)

Copyright (C) Junko Shiozawa, Tokyo Woman's Christian University 2016. All rights reserved.

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

Copyright (C) Junko Shiozawa, Tokyo Woman's Christian University 2016. All rights reserved.

モード切り替えの問題(p. 17)

- 文書在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

Copyright (C) Junko Shiozawa, Tokyo Woman's Christian University 2016. All rights reserved.

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

Copyright (C) Junko Shiozawa, Tokyo Woman's Christian University 2016. All rights reserved.

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

0000000から1111111まで、フルに使ってASCII文字を1文字ずつ表現

XXXXXXX

= 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

Copyright (C) Junko Shiozawa, Tokyo Woman's Christian University 2016. All rights reserved.

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

Copyright (C) Junko Shiozawa, Tokyo Woman's Christian University 2016. All rights reserved.

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

Copyright (C) Junko Shiozono, Tokyo Woman's Christian University 2016. All rights reserved.

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

Copyright (C) Junko Shiozono, Tokyo Woman's Christian University 2016. All rights reserved.

Unicode

Copyright (C) Junko Shiozono, Tokyo Woman's Christian University 2016. All rights reserved.

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

Copyright (C) Junko Shiozono, Tokyo Woman's Christian University 2016. All rights reserved.

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

Copyright (C) Junko Shiozono, Tokyo Woman's Christian University 2016. All rights reserved.

Question!

Copyright (C) Junko Shiozono, Tokyo Woman's Christian University 2016. All rights reserved.