コンピュータ・サイエンス1

第9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9回の内容

- 浮動小数
- コンピュータでの文字の扱い(1)

設問1

- 下記の6桁の2進数のうち、2の補数を考えるとすると、マイナスの数はどれか、すべて答えなさい。

1. 000000
2. 101010
3. 010101
4. 111000
5. 000111
6. 110011
7. 001100
8. 111111

解答: 2, 4, 6, 8

設問2

- 「やってみよう!」の2の補数の足し算の1. の結果を報告すること
  - 1. の問題: (+10)+(+8)を5桁の2の補数として計算し、10進数として表現

$(+10)_{10} = (01010)_2$
$(+8)_{10} = (01000)_2$

```
  01010
+) 01000
  10010
```

負の数と判断

2の補数(マイナスの数)として10進数に直す
1. $(10010 - 1)_2 = (10001)_2$ (2の補数から1を引く)
2. $(10001)_2 \rightarrow (01110)_2$ (1と0を反転する)
3. $(01110)_2 = (14)_{10}$ (2進数を10進数に直す)
4. $(14)_{10} \rightarrow (-14)_{10}$ (マイナス記号をつける)

解答: -14

前回の質問の解答

コンピュータでの計算(1)

- コンピュータの内部では、常に2進数!

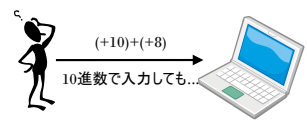

1. 入力された数はすべて2進数で表現!
   - ✓ $(+10)_{10} = (01010)_2$
   - ✓ $(+8)_{10} = (01000)_2$
2. 計算は必ず2進数で!
   - ✓ $(+10)_{10}+(+8)_{10}$ ✗ (この計算はしない)
   - ✓ $(01010)_2+(01000)_2$ ○
3. 計算結果の表示だけ10進数!

コンピュータでの計算を考えるときは、必ず2進数で!
- 1, 2, 3の手順で計算すること!
- 10進数を頭の中に置いておくと、混乱のもと

コンピュータでの計算(2)

- コンピュータはどこまでも大きな数を表現できるわけではない
  - ハードウェアの性能等の理由で
    - ➡ 表現できる数(2進数)の桁数に制限ができた
- コンピュータに搭載する電子回路はなるべく節約したい
  - 様々な種類(足し算用・かけ算用・引き算用・割り算用…)の回路を搭載するとコンピュータの値段が高くなる
    - ➡ マイナスの数を扱って、計算のための回路は足し算だけにする
    - ➡ さらに節約のために、マイナスの数とプラスの数は一緒くたに扱いたい
    - ➡ 2進数で最も大きな桁が0のときは正の数、1のときは負の数として扱う

コンピュータでの2進数では、桁数と正負の判定方法は、絶対のルール!
- ➢ オーバーフローはこのルールがあることによって起こる弊害

オーバーフローのおさらい

- オーバーフローには2種類!
  - 2進数で、計算結果が指定された桁数よりも多くなってしまい、大きい桁が削られてしまうこと
  - 2進数で、正の数同士(負の数同士)の計算結果が、負の数(正の数)になってしまうこと

要は、人間が手でやった計算結果と、コンピュータがやった計算結果が違う現象!

コンピュータの考え方

Ex. 1: 5桁の2進数で…
$(01011)_2 \times (00100)_2 = (0101100)_2$

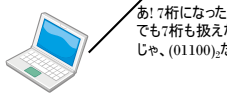

Ex. 2: 4桁の2進数で…
$(0110)_2 + (0111)_2 = (1101)_2$

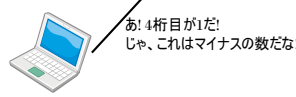

計算結果の桁数が短くなるオーバーフローと、正負の判定は別
- ➢ 先頭が1で始まる数は、オーバーフロー関係なくマイナスの数

人間がコンピュータの動作を考えるには…

- 計算結果を見たときに…
  1. 決められた桁数を超えていないか? →超えていたら、桁数あわせ
  2. 一番大きな桁が0か1か? →0なら正の数、1なら負の数
     - 1. の結果に関係なく判断する

Ex. 1: 5桁の2進数の計算結果が$(011001)_2$の場合
1. 計算結果が6桁なので桁数あわせ
   →$(11001)_2$
2. 一番大きな桁が1
   →この数は負の数$(11001)_2 = (-7)_{10}$

Ex. 3: 5桁の2進数の計算結果が$(01001)_2$の場合
1. 計算結果が5桁なので桁数あわせなし
   →$(01001)_2$のまま
2. 一番大きな桁が0
   →この数は正の数$(01001)_2 = (9)_{10}$

Ex. 2: 5桁の2進数の計算結果が$(0100010)_2$の場合
1. 計算結果が7桁なので桁数あわせ
   →$(00010)_2$
2. 一番大きな桁が0
   →この数は正の数$(00010)_2 = (2)_{10}$

Ex. 4: 5桁の2進数の計算結果が$(10010)_2$の場合
1. 計算結果が5桁なので桁数あわせなし
   →$(10010)_2$のまま
2. 一番大きな桁が1
   →この数は負の数$(10010)_2 = (-12)_{10}$

なので…

- 5桁の2進数$(11110)_2$
  - 一番大きな桁が1 →この数は負の数と判断 →2の補数として10進数に
    1. $(11110 - 1)_2 = (11101)_2$ (2の補数から1を引く)
    2. $(11101)_2 \rightarrow (00010)_2$ (1と0を反転する)
    3. $(00010)_2 = (2)_{10}$ (2進数を10進数に直す)
    4. $(2)_{10} \rightarrow (-2)_{10}$ (マイナス記号をつける)
- 5桁の2進数$(10011)_2$(前回授業のp. 30のスライドの計算結果)
  - 一番大きな桁が1 →この数は負の数と判断→2の補数として10進数に
    1. $(10011 - 1)_2 = (10010)_2$ (2の補数から1を引く)
    2. $(01101)_2 \rightarrow (01101)_2$ (1と0を反転する)
    3. $(01101)_2 = (13)_{10}$ (2進数を10進数に直す)
    4. $(13)_{10} \rightarrow (-13)_{10}$ (マイナス記号をつける)

Question!

前回の復習

2の補数表現[2](p. 9)

- 2の補数 = 負の数を2進数で表現したもの(コンピュータの世界では)
- 計算方法(例: -20を10桁の2進数に直す)
  1. 2の補数に直したい10進数のマイナスを取り除く
     - $(-20)_{10} \rightarrow (20)_{10}$
  2. 1. の結果を2進数に直す
     (この時点で桁数あわせ!! 後で桁数あわせをすると、合わせ方を間違えやすい)
     - $(20)_{10} = (0000010100)_2$
  3. 2. の結果の0と1を逆にする(0の桁を1、1の桁を0にする)

0 0 0 0 0 1 0 1 0 0

↓

1 1 1 1 1 0 1 0 1 1

2の補数表現[2](p. 9)

- 2の補数 = 負の数を2進数で表現したもの(コンピュータの世界では)
- 計算方法(例: -20を10桁の2進数に直す)
  4. 3. の結果に1を足し算する

```
 1111101011
+)         1
------------
 1111101100
```

-20を2進数に直した結果
(2の補数 = 2進数での負の数の表現)

2進数での負の数の表現では、
「-」の記号はつけない

2の補数を10進数に変換[2]

- 計算方法(例: 1111101100を10進数に直す)
  1. 2の補数から1を引き算する

```
 1111101100
-)         1
------------
 1111101011
```

  2. 1. の結果の0と1を逆にする(0の桁を1、1の桁を0にする)

1111101011

↓

0000010100

※2の補数→10進数の方法は、10進数→2の補数の逆

2の補数を10進数に変換[2]

- 計算方法(例: 1111101100を10進数に直す)
  1. 2. の結果を10進数に直す
     - $(0000010100)_2 = (20)_{10}$
  2. 3. の結果に-(マイナス)をつける
     - $(20)_{10} \rightarrow (-20)_{10}$

1111101100を
10進数に直した数

※2の補数→10進数の方法は、10進数→2の補数の逆

小数の表現方法(続き)

10進数の小数を2進数に直す[1]

- 例: 101.1101 (整数部分101は10進数で5)

1. 2進数の整数部分は、通常の方法で10進数に直す
2. 10進数の小数部分各桁の上に「1/2」を書く
3. 2. で書いた「1/2」の「2」の右肩に左から1, 2, 3, ...と書いていく
   - $1/2^0$, $1/2^1$, $1/2^2$, ...ができていく

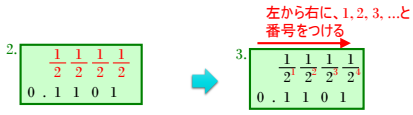

10進数の小数を2進数に直す[2]

4. 各桁の上の「$1/2^n$」と、それぞれの桁の数をかけあわせる
5. 4. の結果を足し合わせ、1. の整数部分とあわせる

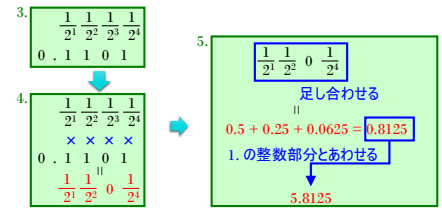

やってみよう!

- 2進数1.101を10進数に変換
  (2010年度ITパスポート春季試験問題)
- 2進数に変換した時、有限小数で表現できる10進数は、
  以下のうちどれか
  - 0.1
  - 0.2
  - 0.4
  - 0.5

  (2012年度ITパスポート秋季試験問題)

小数の表現方式

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
- 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[2](p. 10)

- 小数を表す桁数が決まっていると…

Ex. 小数点以下が2桁分と決まっていると…

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

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. 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

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

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)

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. 1000000000000000 × 1000000000000000
= 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÷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

桁落ちの例

- 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. 電卓での計算: 9999999999999999 × 9999999999999999
→ 9.9999999999999998e+31 = 9.9999999999999998 × 10^{31}
= 99999999999999980000....00000

でも実際に計算すると…

9999999999999999
×) 9999999999999999
...91
+) ...91
...01

桁落ち

つまり本当の計算では…
9999999999999999 × 9999999999999999
= x.xxxx...01

やってみよう!

- スマートフォンの電卓で、大きな数のかけ算をしてみよう!
  - 結果が浮動小数点表示になるか?
  - 桁落ちしているか?

を確認しよう!

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÷6×100000の計算は…

- 「1÷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(計算の順序を変えると)、16666.666
- 本来の1÷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÷6×100000」の計算は、「1×100000」をしてから6で割る

やってみよう!

1. 0.0000055を浮動小数点方式で表現
2. 0.000000001234を浮動小数点方式で表現
3. 456000000000000を浮動小数点方式で表現
   ※3つとも仮数部は小数点第2位の小数とすること
4. (10÷7)×10000を計算
   - 小数点第2位までが有効桁数
   - 桁落ちを考えて計算すること
5. 10÷7×10000を計算
   - 小数点第2位までが有効桁数
   - 桁落ちの影響がなるべく少ないように計算すること

Question!

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
  - 図形文字: 95文字
    - 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
  - 制御文字: 33文字
    - BackSpace, Delete, Tab, 改行(CRとLF), etc.

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

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)
=0**1000001**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

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/

Question!

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(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)

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

コンピュータサイエンス 1 の授業

半角の文字　日本語の文字

6 月 1 日

- 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

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

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

XXXXXXXX

= 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

例えばある文章が...

1から始まっているから日本語文字

0011011010010110101001010110 1010

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

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