

情報理学入門

九州大学 大学院システム情報科学研究院
竹田正幸

情報理学とは？

- Information Science
- 一般には「情報科学」と訳す。
- 「情報工学」(Information Engineering)に対比させて「情報理学」と訳すのが自然では?
 - 工学部: Faculty of Engineering
 - 理学部: Faculty of Science
- で、「情報理学」とはどういう学問か？

情報理学は どんな学問か？

情報理学はどういう学問か？

- 物質と情報=世界を構成する二つの要素
- 物理学 =物質の理(ことわり)についての学
- 情報理学=情報の理(ことわり)についての学

日本初・九大発の造語
(有川節夫九大前総長)



歴史の深い学問は魅力的！

- 数学や物理学は、紀元前から存在！
 - 先人たちの研究の蓄積が体系化され教科書に。
 - 研究者は、その体系を消化吸収した上で、新しい研究を展開。
 - 最先端の研究に追いつくのが大変。

もし、私がより遠くを眺めることができたとしたら、それは巨人の肩に乗ったからです

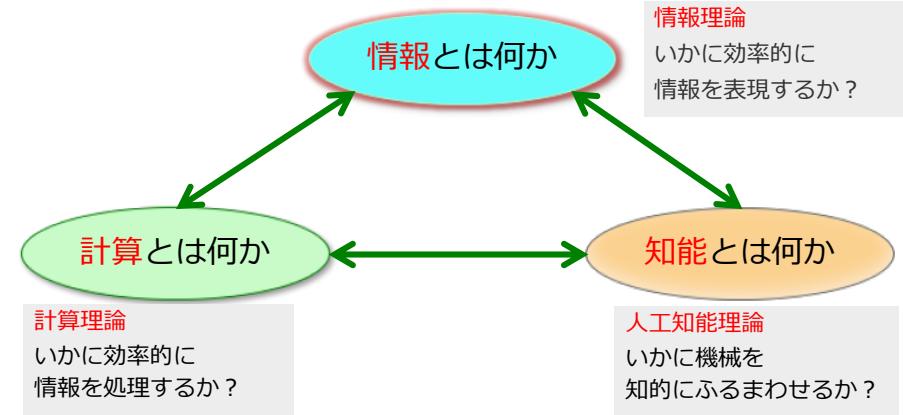


Isaac Newton
(Wikipediaより)

- 情報を扱う学問は、20世紀に始まったばかり。
 - やるべきことがいっぱい残っており 大学院生でも世界最先端で活躍できる。
 - 「教科書を読むひと」から「教科書に載るひとへ」！

情報理論

情報理学で研究すること



これらについて、理論と実用の両面から研究

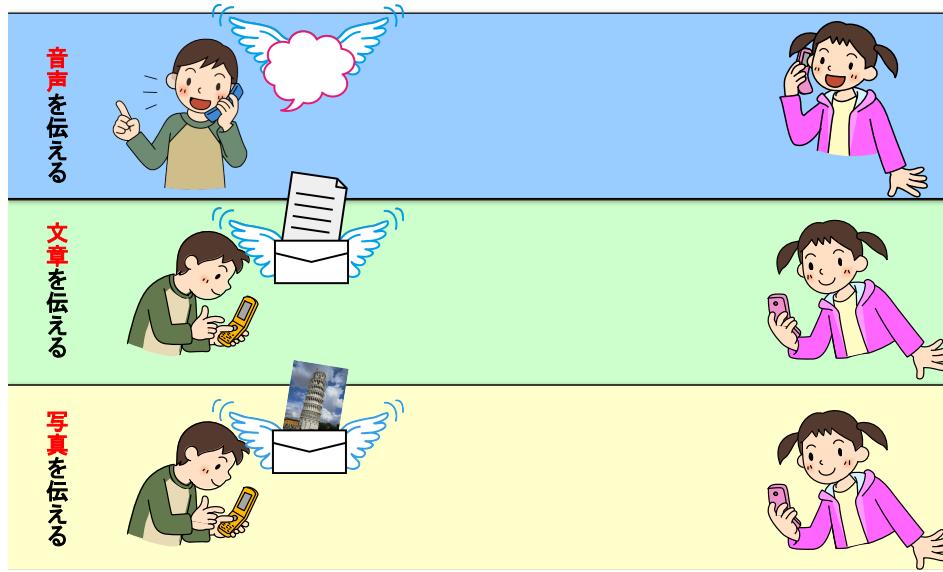
情報理論

- 創始者：
 - Claude E. Shannon (1916-2001)
 - 情報通信の基礎理論。
 - デジタル／アナログ変換の基礎理論。
 - デジタル回路設計の創始者(修士論文21才)。
- 高度情報化社会を支える基盤技術。
 - 情報、通信、暗号、データ圧縮、符号化。

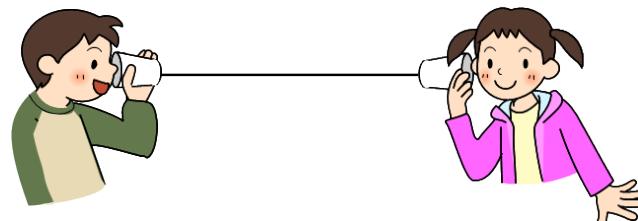


Claude E. Shannon
(Wikipediaより)

ケータイやPCでできること



音声を伝える：糸電話

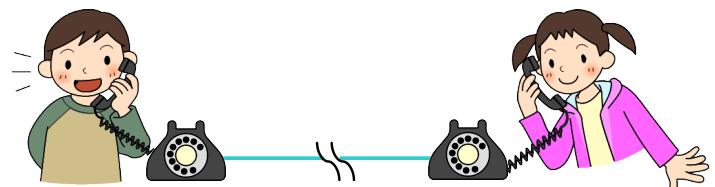


音(=空気の振動)を、糸の振動として伝える

ケータイやPCでできること



音声を伝える：アナログ式電話



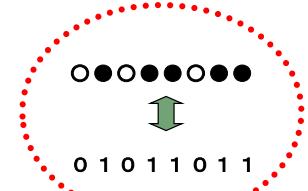
音(=空気の振動)を、アナログ電気信号として伝える

音声を伝える：デジタル式電話



情報のデジタル表現

- 情報通信機器では、
文字、絵や写真、音や声など様々な情報が、
○と●の並びとして表される。
- 通常は0と1の並びと言われるが
2種類の記号なら何でもよい。



実際はどう表しているかというと
 ◇ 電気の強い・弱い
 ◇ 光の強い・弱い
 ◇ くぼみのある・なし
 ◇ 磁石の力の向き
 ...

情報のデジタル表現

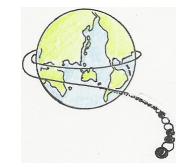


データ量の単位

- データ量=球の数
- 1ビット=球1個
- 1バイト=8ビット
- 1キロバイト=1024バイト \leftrightarrow 約98m
- 1メガバイト=1024キロバイト \leftrightarrow 約100km

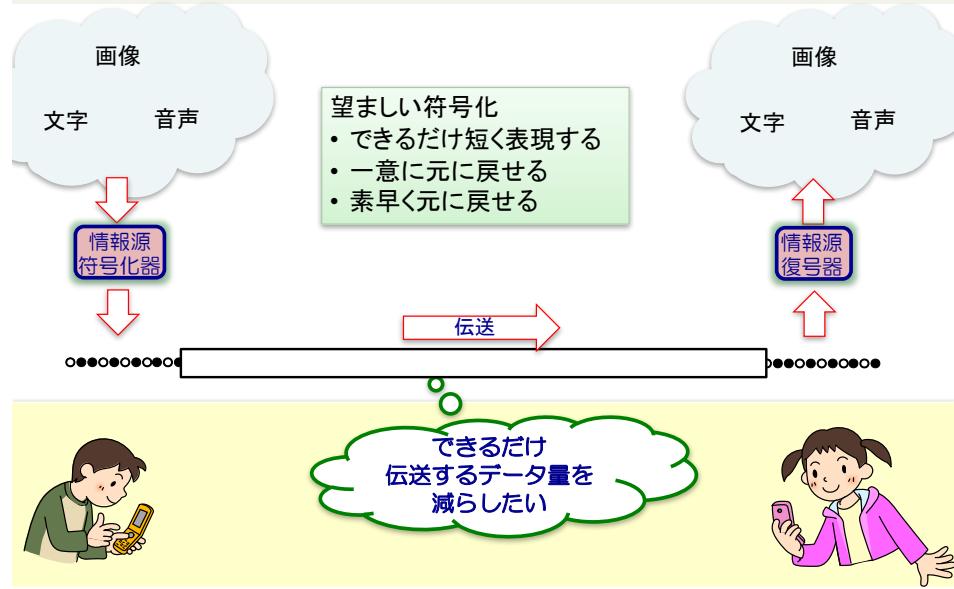


CD1枚(650メガバイト)

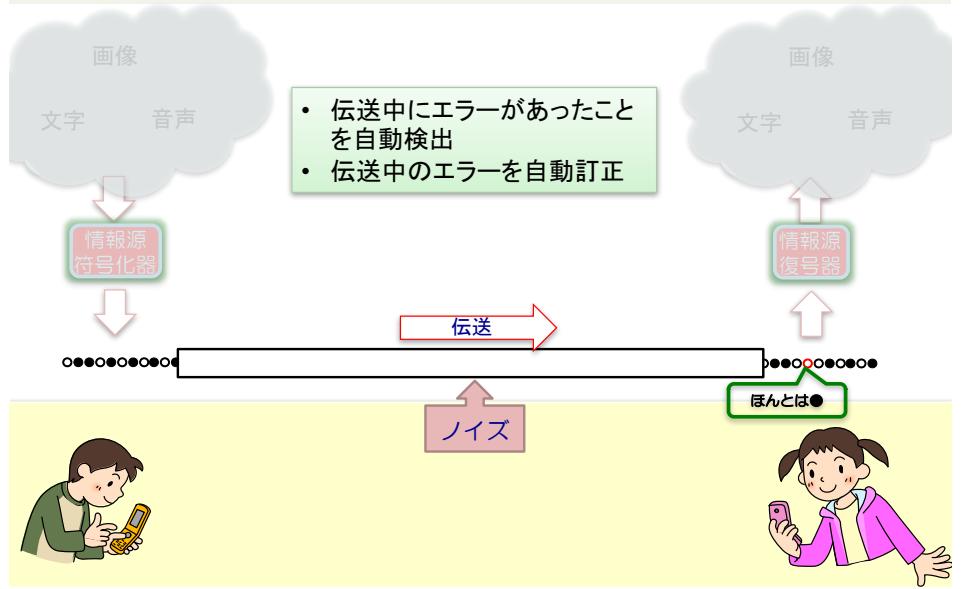


地球1周半(65000km)

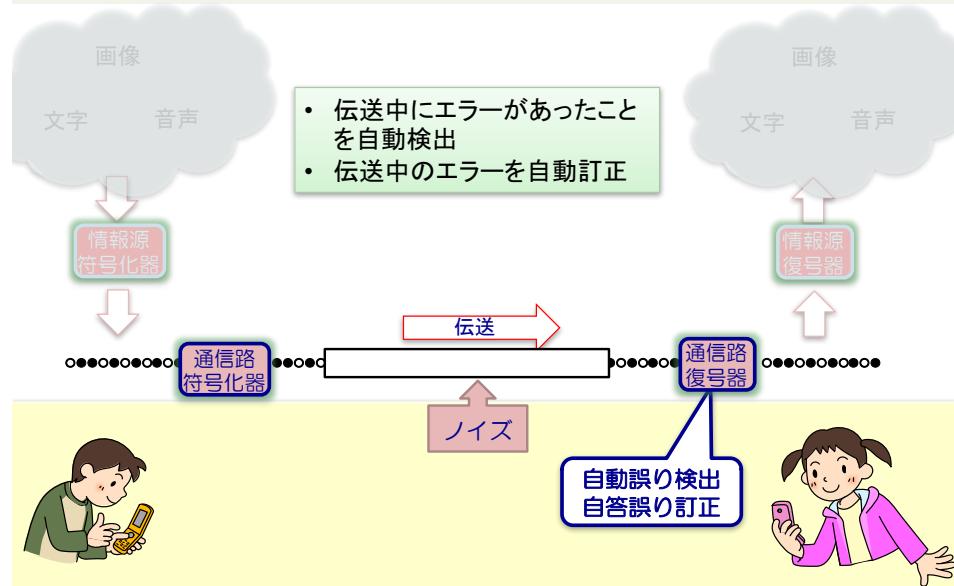
(I) 情報源符号化



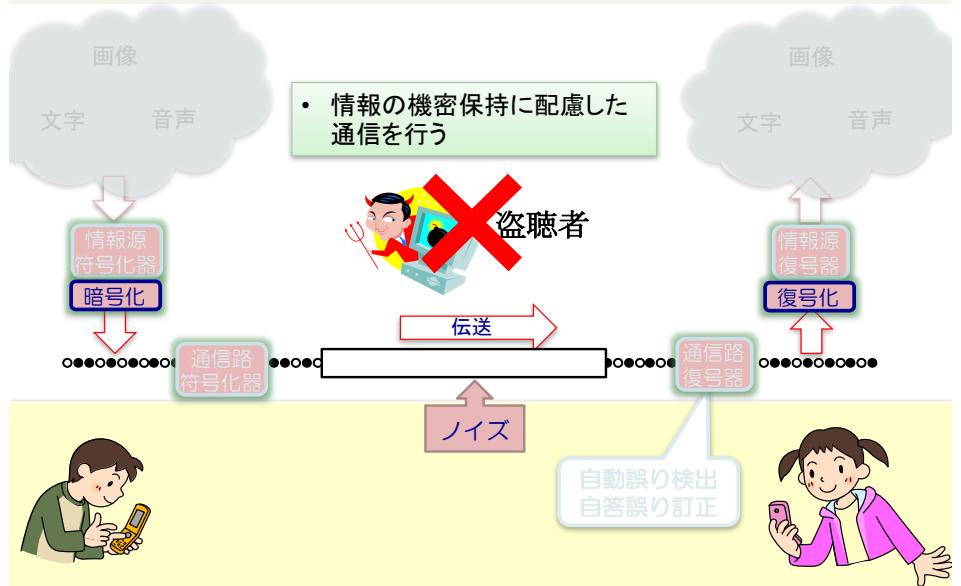
(II) 通信路符号化



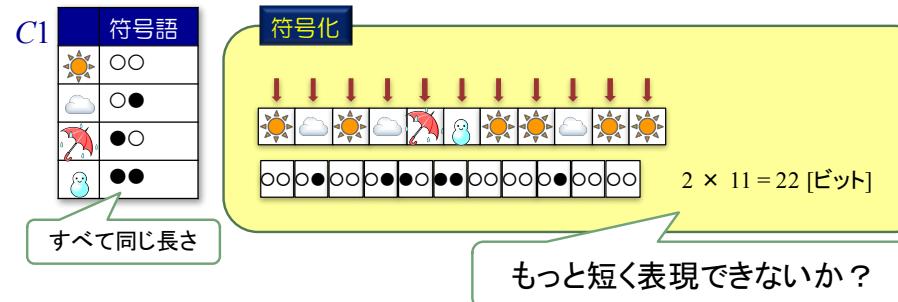
(II) 通信路符号化



(III) 暗号化

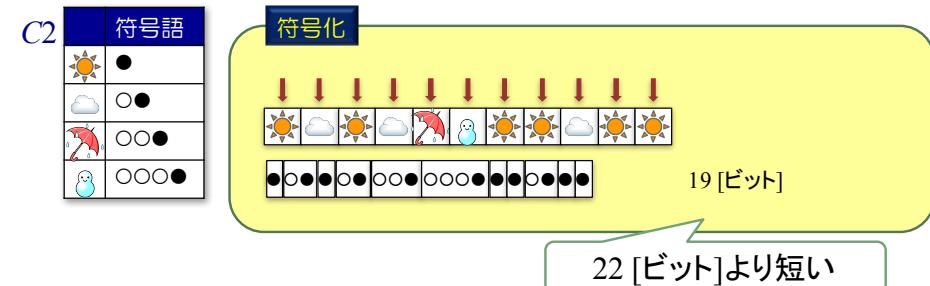


例：符号C1

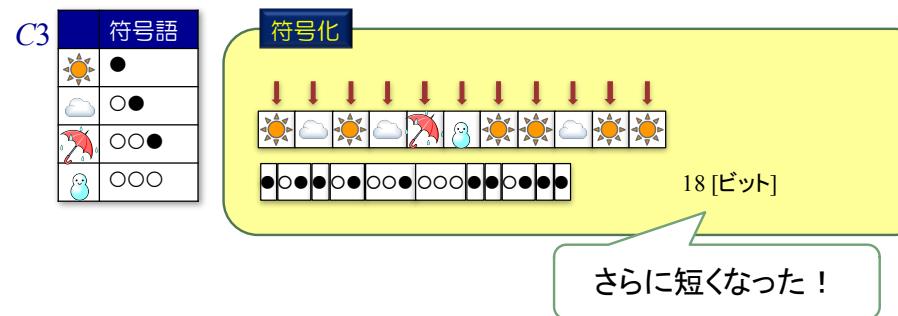


例：符号C2

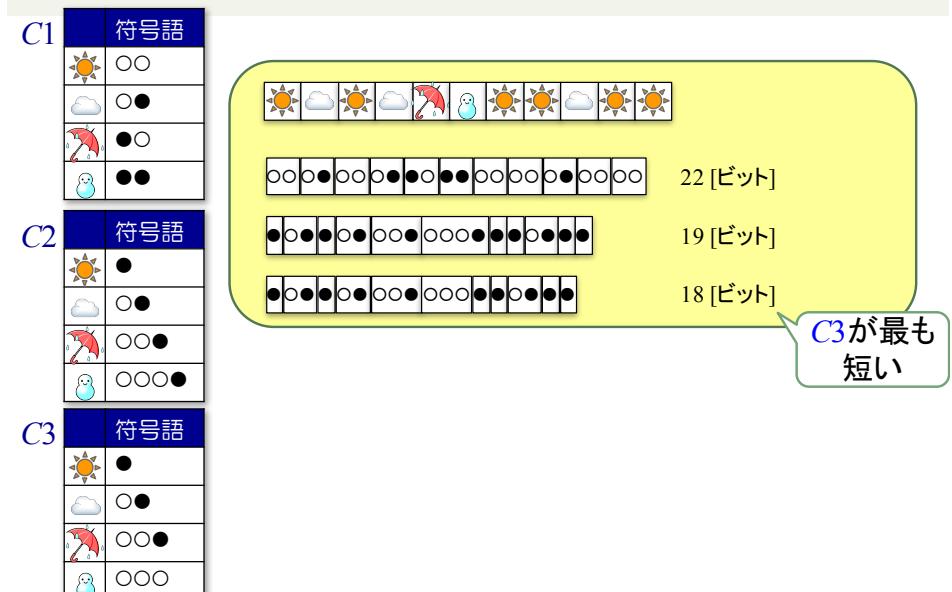
例：符号C2



C3



符号化の長さの比較



別の記号列では...

C1	符号語
	○○
	○●
	●○
	●●



C1が最も
短い

A horizontal row of 12 numbered circles, each containing a single black dot. The circles are arranged in a sequence: circle 1 (black dot), circle 2 (black dot), circle 3 (no dot), circle 4 (no dot), circle 5 (black dot), circle 6 (black dot), circle 7 (black dot), circle 8 (no dot), circle 9 (no dot), circle 10 (black dot), circle 11 (black dot), and circle 12 (black dot). The circles are contained within a yellow rectangular frame.

22 [ビット]

A horizontal row of 20 black dots on a yellow background.

26 Fl. 1

<i>C2</i>	符号語
	●
	○●
	○○●
	○○○●

記号の**生起確率**を考慮する必要がある

情報源符号化の目的

記号の確率分布に応じて
できるだけ平均符号語長の短い符号を設計すること。

ただし、次の2つの条件を満たすことが前提。

- 一意に元に戻せること (一意複号可能性) .
 - 素早く元に戻せること (瞬時複号可能性) .

平均符号語長

記号	確率
	0.70
	0.15
	0.10
	0.05

情報源S

平均符号語長を短くするには、現れやすい記号→短い符号語と割り当てればよい。

C1	符号語	符号語長
	○○	2 × 0.70 = 1.40
	○●	2 × 0.15 = 0.30
	●○	2 × 0.10 = 0.20
	●●	2 × 0.05 = 0.10

2.00 [ビット]

C2	符号語	符号語長
	●	1 × 0.70 = 0.70
	○●	2 × 0.15 = 0.30
	○○●	3 × 0.10 = 0.30
	○○○●	4 × 0.05 = 0.20

1.50 [ビット]

C3	符号語	符号語長
	●	1 × 0.70 = 0.70
	○●	2 × 0.15 = 0.30
	○○●	3 × 0.10 = 0.30
	○○○	3 × 0.05 = 0.15

1.45 [ビット]

平均符号語長の限界？

- 情報源 S に対して、符号 C を変えるとその平均符号語長も変わる。
 - 平均符号語長は、どこまで小さくできるのだろうか？

エントロピー

【定義】

記号	確率
a_1	p_1
a_2	p_2
...	...
a_M	p_M

情報源 $S =$ に対し, S のエントロピー $H(S)$ を

次で定める。

$$H(S) = p_1(-\log_2 p_1) + \dots + p_M(-\log_2 p_M)$$

平均符号語長とエントロピー

【定理】 S を任意の情報源とする。 S に対する任意の一意復号可能符号 C の平均符号語長 $L(C)$ は次の不等式を満たす。

$$H(S) \leq L(C)$$

記号	確率
a_1	p_1
a_2	p_2
...	...
a_M	p_M

つまり、エントロピーは平均符号語長の下限である！

記号	符号語
a_1	$C(a_1)$
a_2	$C(a_2)$
...	...
a_M	$C(a_M)$

エントロピー（続き）

例

情報源 S

	確率
	0.70
	0.15
	0.10
	0.05

$$\begin{aligned} 0.70 & (-\log_2 0.70) = 0.3602 \\ 0.15 & (-\log_2 0.15) = 0.4105 \\ 0.10 & (-\log_2 0.10) = 0.3322 \\ 0.05 & (-\log_2 0.05) = 0.2161 \\ H(S) & = 1.3190 \end{aligned}$$

平均符号語長とエントロピー（続き）

例

	確率
	0.70
	0.15
	0.10
	0.05

	符号語
	○○
	○●
	●○
	●●

$$H(S)=1.3190 \quad L(C1)=2.0000 \quad L(C2)=1.5000 \quad L(C3)=1.4500$$

VI

VI VI VI

$$H(S)=1.3190$$

$$H(S)=1.3190$$

$$H(S)=1.3190$$

最大値問題を解く

計算理論

計算理論

■ 創始者:

- Alan M. Turing (1912-1954)
- 現在のコンピュータの原型となるTuring機械を提唱.
- アルゴリズムの概念を明確化.



Alan M. Turing
(Wikipediaより)

■ アルゴリズム

- コンピュータによる処理(計算)手順.
- 料理のレシピみたいなもの.

■ アルゴリズムの研究

- 効率的な処理手順を考えること.



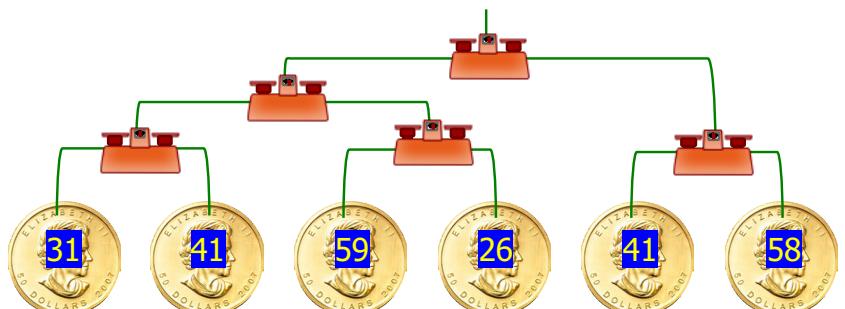
鶏のから揚げの作り方

1. 鶏モモ肉を切る
2. しょうゆ, みりん, 塩こしょうで下味をつける
3. から揚げ粉をまんべんなく付ける
4. 180°Cの油で揚げる

最大値問題

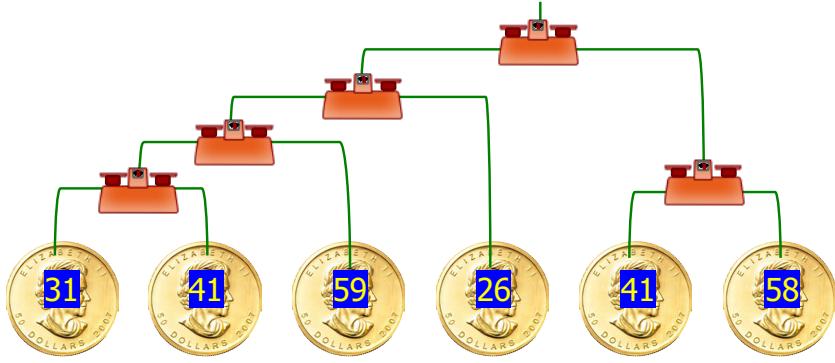
■ 重さがバラバラの金貨が6枚ある。天秤を使って一番重い金貨をみつけるアルゴリズムを作れ。

■ 勝ち抜き戦をやればOK。



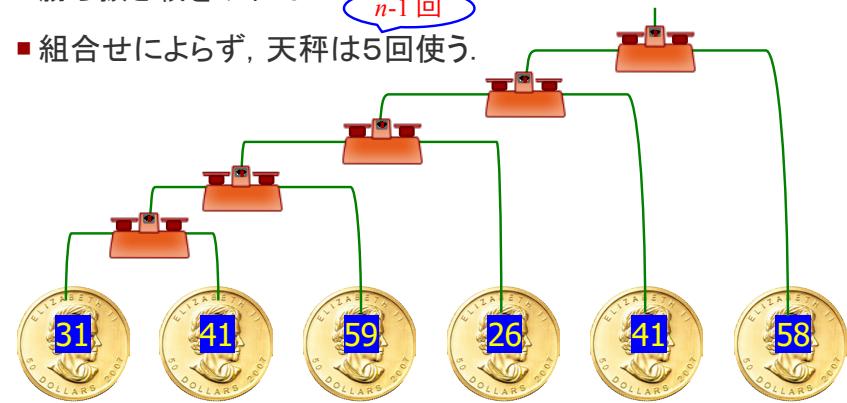
最大値問題

- 重さがバラバラの金貨が6枚ある。天秤を使って一番重い金貨をみつけるアルゴリズムを作れ。
- 勝ち抜き戦をやればOK。



最大値問題

- 重さがバラバラの金貨が6枚ある。天秤を使って一番重い金貨をみつけるアルゴリズムを作れ。
- 勝ち抜き戦をやればOK。
- 組合せによらず、天秤は5回使う。



最大値問題

定義(最大値問題)。

入力：実数の列 $\langle a_1, a_2, \dots, a_n \rangle$.

出力：最大値を与える添字 i .

定理。最大値問題はちょうど $n-1$ 回の大小比較により解くことができる。

並べ替え問題を解く

並べ替え問題

n 枚の金貨を、軽い方から順に並べ替えよ。

before



after



並べ替え問題

n 枚の金貨を、軽い方から順に並べ替えよ。

before



after



並べ替え問題

定義(並べ替え問題).

入力: 実数の列 $\langle a_1, a_2, \dots, a_n \rangle$.

出力: 入力を並べ替えて得られる単調増加列 $\langle b_1, b_2, \dots, b_n \rangle$.

並べ替えアルゴリズム

■ 最大値を求める問題を繰り返し解けばよい。



26 31 41 41 58 59

並べ替え問題を解く

定義(並べ替え問題).

入力: 実数の列 $\langle a_1, a_2, \dots, a_n \rangle$.

出力: 入力を並べ替えて得られる単調増加列 $\langle b_1, b_2, \dots, b_n \rangle$.

単純な方法

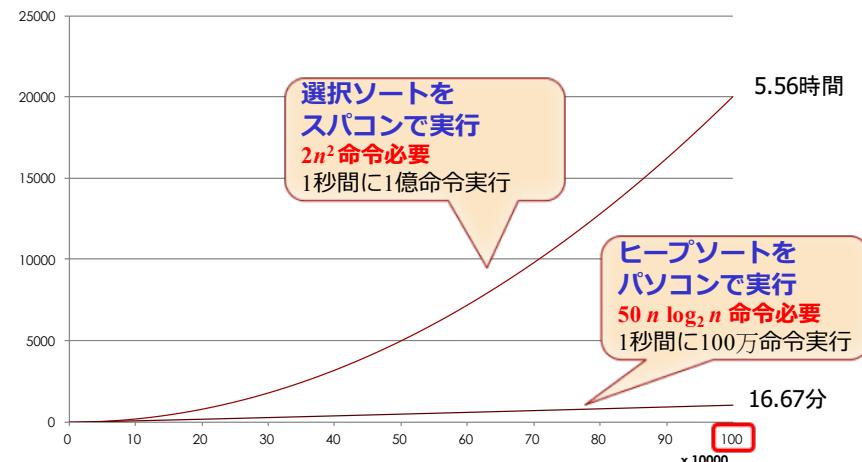
定理. 選択ソートの実行時間は $c_1 n^2$ 以下である ($c_1 > 0$ は定数).

うまい方法

定理. ヒープソートの実行時間は $c_2 n \log_2 n$ 以下である ($c_2 > 0$ は定数).

定数 c_1, c_2 は使用するコンピュータの性能に依存

アルゴリズムを工夫する意義



効率化の限界

定義(並べ替え問題).

入力: 実数の列 $\langle a_1, a_2, \dots, a_n \rangle$.

出力: 入力を並べ替えて得られる単調増加列 $\langle b_1, b_2, \dots, b_n \rangle$.

うまい方法

定理. ヒープソートの実行時間は $c_2 n \log_2 n$ 以下である ($c_2 > 0$ は定数).

Q. もっと効率の良い
アルゴリズムは
作れないのか?

A. 作れない!

定理. (値の比較に基づいた) 任意の並べ替えアルゴリズムの実行時間は $c_3 n \log_2 n$ 以上である ($c_3 > 0$ は定数).

□

□

□

□

□

アルゴリズムを工夫する意義

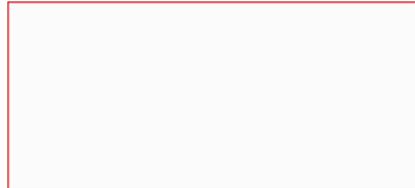
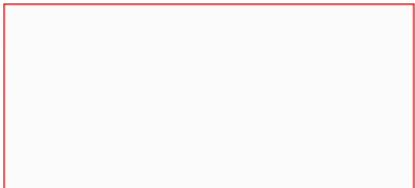
■ Youtube
「フカシギの数え方」
おねえさんといっしょ！みんなで数えてみよう！
(2012/09/10公開)

■ 「Graphillion: 数え上げおねえさんを救え」

人工知能理論

こんなことがほんとにできるの？

- はなして翻訳（NTTドコモ）



人工知能理論

■ 創始者：

Marvin Minsky (1927-)
John McCarthy (1927-2011)
Terry Allen Winograd (1946-)

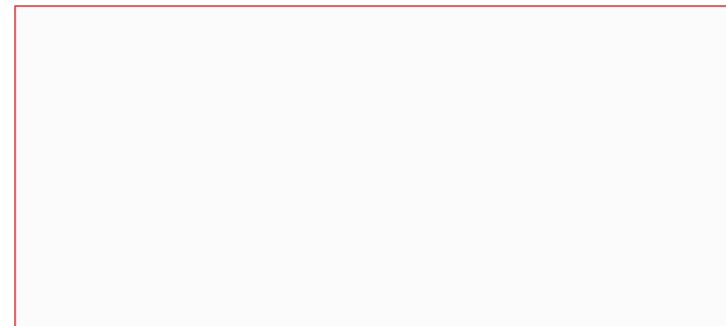
■ 人間の行なう知的な活動の原理を究明.

- 画像認識／文字認識／音声認識
- 自然言語理解
- 探索
- 推論
- 学習／発見

■ コンピュータを知的に振る舞わせるために必要な技術を開発.

こんなことがほんとにできるの？

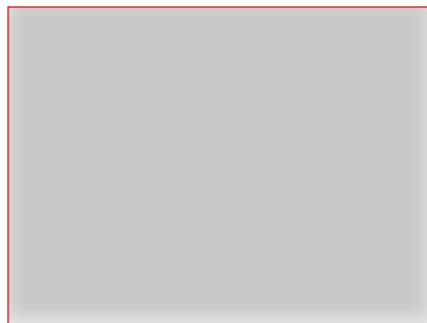
- うつして翻訳（NTTドコモ）



考えるコンピュータ？

- コンピュータの擬人化は誤解を招く
 - 人間的にふるまって見えても、人間の作成したプログラムどおりに動作する機械にすぎない。
- 計算する機械、すなわち、計算機(computer)。
- コンピュータ上のすべての情報は、記号列(バイト列)として表現されている。
- 計算とは、単なる記号列の書き換えにすぎない。
 - Turing機械

SONYスマイルシャッター



スマイルシャッターモードで撮る人物の顔を認識させる。



笑顔を作るとシャッターが切れる。

顔とは？笑顔とは？

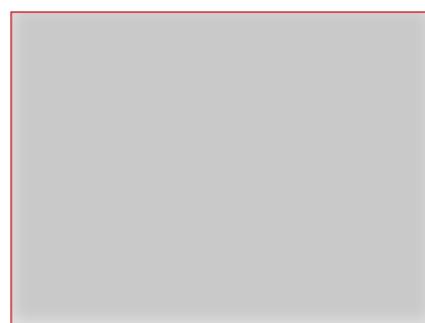
笑顔=口を開けて歯が見え、目が細まった顔

口とは？口が開くとは？歯とは？目とは？目が細まるとは？

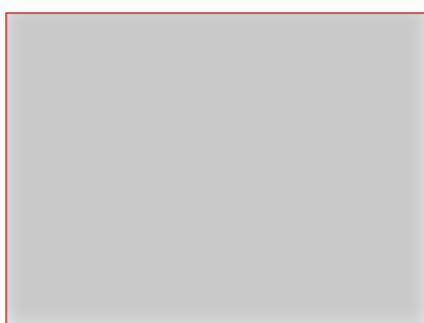
人工知能研究

- 人間の「知的活動」を解析して数学的に定式化し、それを計算機に実行させる。
- 計算機プログラムであるから、しょせん、定型的処理。
- チェスの世界チャンピオンに勝った**と言っても、膨大な量の「しらみつぶし」を瞬時に行っているだけ。
- 数学的に明確に定式化できる問題に限定される。
 - 顔とは？（デジカメの顔検出・顔認識）
 - 笑顔とは？（デジカメのスマイルシャッター）

SONYスマイルシャッター



笑顔認識のターゲットを特定すると....

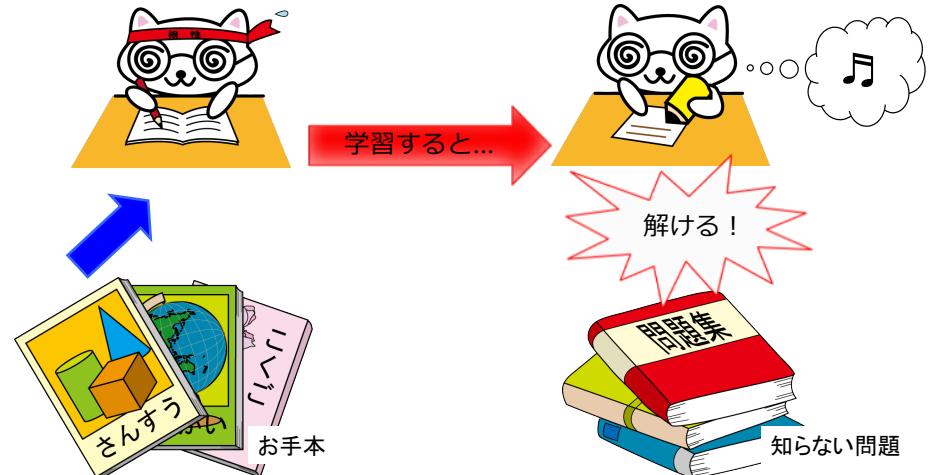


人工知能研究

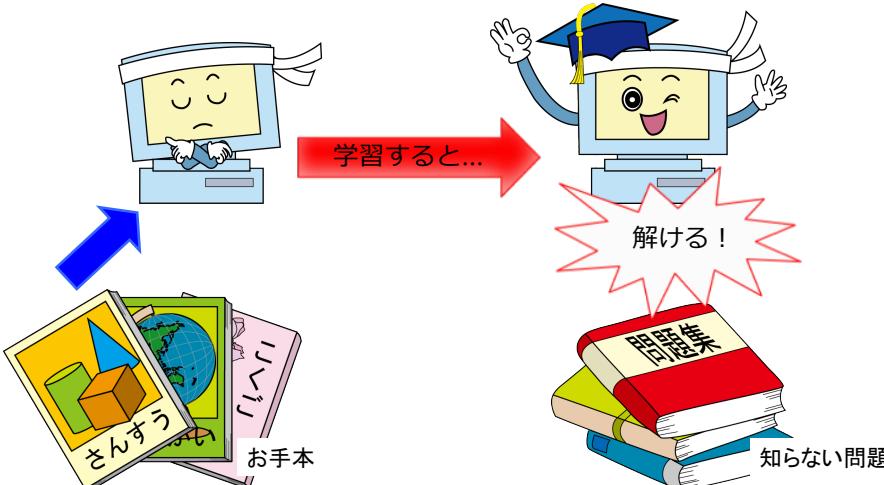
- 人間の「知的活動」を解析して数学的に定式化し、それを計算機に実行させる。
- 計算機プログラムであるから、しょせん、定型的処理。
- チェスの世界チャンピオンに勝った**と言っても、膨大な量の「しらみつぶし」を瞬時に行っているだけ。
- 数学的に明確に定式化できる問題に限定される。
 - 顔とは？（デジカメの顔検出・顔認識）
 - 笑顔とは？（デジカメのスマイルシャッター）
 - 現実世界の近似にすぎないが、近似がうまくいけば、役に立つ。

学習とは？

- 学んで知識を理解したり記憶したりすること (Wikipedia)

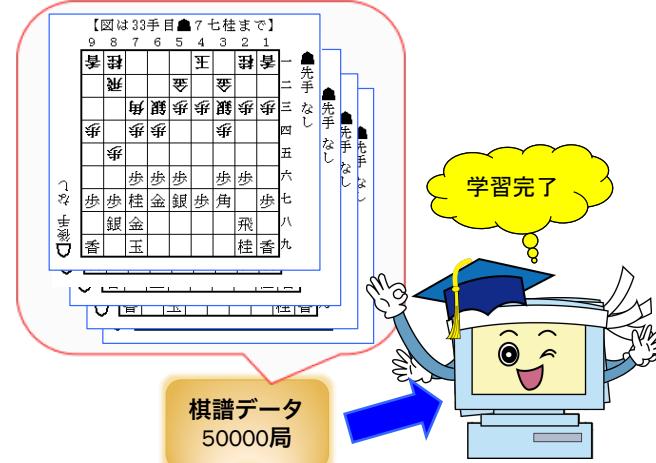


機械学習とは？



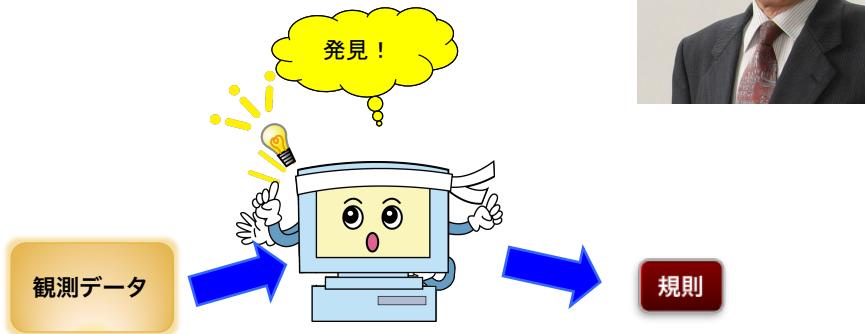
機械学習：具体例

- 専門家の行動に関する実データを与える



機械発見とは？

- 発見科学
 - 九大発・世界初の研究分野 by 有川教授(前総長)
 - 発見を科学する。
- 人間の行う発見をコンピュータで支援する。



計算機は役に立つ道具であればよい

- スターウォーズのロボット
 - C-3POとR2-D2
 - 実際に戦いの役に立ったのはどっち？

計算機は役に立つ道具であればよい

- スターウォーズのロボット
 - C-3POとR2-D2
 - 実際に戦いの役に立ったのはどっち？
- 桃太郎の家来
 - 犬（仁）, 猿（智）, 雉（勇）
 - 猿の智による貢献は？

計算機は役に立つ道具であればよい

- スターウォーズのロボット
 - C-3POとR2-D2
 - 実際に戦いの役に立ったのはどっち？
- 桃太郎の家来
 - 犬（仁）, 猿（智）, 雉（勇）
 - 猿の智による貢献は？
- 中途半端に賢い猿より、忠実な犬を！