

情報科学概論

本講義の位置づけ

- 情報系以外の出身者を対象
- 情報科学の基礎を初等的に解説

担当: 楫, 中島, 関, 杉本(講義順)

日時: 5/23, 5/30, 6/6, 6/13, 各 4, 5限

- 基本的に, 各講義は独立した内容

評価, 成績

- 出席とレポートによる(本講義中で説明)

本日の講義

情報処理の理論と仕組み

■ オペレーティングシステム概論(4限)

- ◆ 計算機のオペレーティングシステム(OS)について知る
- ◆ 歴史的経緯をなぞりつつ, 現代のOSが備える機能を概観

■ 情報理論入門(5限)

- ◆ 「情報」を数学的・工学的に取り扱うための基礎技術
- ◆ 情報の計量, 圧縮, 誤り訂正について学ぶ

本資料: <http://narayama.naist.jp/~kaji/lecture/>

オペレーティングシステム概論

オペレーティングシステム:

- Windows, MacOS, Linux etc....
- 工業製品であると同時に, 情報科学の成果の集大成
- science と engineering を結ぶ「橋」(のひとつ)

本日の講義内容:

- ◆ オペレーティングシステム(OS)とは何か
- ◆ OSの役割とは
- ◆ OSが備えている機能について

OSとは何か: OSのない(?) 計算機

昔のパソコン(マイコン):

- ◆ プログラムを実行するには, カセットテープからロード
- ◆ 同時に一つのプログラムしかロードできない
- ◆ メインメモリのどの部分を使用するか, 強く意識
- ◆ 入出力装置へのアクセスも直接的




ハードウェアとプログラムが
直接的に結びついている

シャープ MZ-80C, 1980年
Z-80 (2MHz), 4KB ROM + 48KB RAM
写真出典 <http://www.itoi.co.jp/attic/time3.html>

OSがないと何が困るか

ハードウェアとプログラムが直接的に結びついていると...

- ◆ それぞれの能力を最大限引き出せる
- ◆ 一部の構成が変わると、全体の構成にも影響



OSのある世界

現在のパソコン: OS搭載

- ◆ プログラムの格納場所やロード方法は意識不要
 - ◆ ハードウェアを直接駆動する必要もない
 - ◆ 機器が多少変化しても, プログラムは共通利用可能
 - ◆ 複数のプログラムを安全に同時実行可能
-
- ハードウェア構成の本質的な部分は, 昔と同じ
 - 昔は人間(プログラム)が直接やっていたことを,
オペレーティングシステム(OS)がサポートしてくれる
 - OSは, 裏方仕事を引き受ける特別なプログラム

OSの役割

- OS: 裏方仕事をひきうける特別なプログラム
 - ◆ システムを使いやすくする
 - ◆ 計算機資源を効率よく利用する
 - ◆ 複数のサービスを同時かつ安全に提供する

etc...

- 現在のOS: 非常に複雑で、多様な役割を負う


- 昔はもっとシンプル:

歴史を追うことで、実像が見えてくる... かも

初期のコンピュータシステム

■ 草創期のコンピュータ:

- ◆ パンチカードからプログラムやデータを入力
- ◆ パンチカードには機械語でプログラムを記述
- ◆ 出力は紙テープやラインプリンタ
- ◆ 別プログラムに切り替えるには, システムリセット



パンチカード

- ◆ プログラムの作成が面倒
- ◆ カードの取り扱いが大変
- ◆ プログラムの切り替えも面倒

高級言語, コンパイラ

オペレーティングシステム

第1世代のOS

- 第1世代のOS(1950年代)
 - ◆ 主として、**プロセッサの利用効率の向上**が目的
 - ◆ プログラムの切り替え中は、プロセッサが遊んでいる
 - 切り替えを自動的に行い、遊び時間をなくそう
 - ⇒ **バッチジョブ**の概念が登場
- バッチジョブ＝「コンパイル、プログラム起動、データ投入などの一連の操作を一まとめにしたもの」

第1世代OSの機能


■ 第1世代OSが提供する機能

◆ バッチジョブの受付

ユーザから投入されたジョブを受け付ける

◆ バッチジョブの切り替え

ジョブ実行環境を初期化し, 新しいジョブを開始する



第2世代のOS

- 第1世代OS: 各ジョブが**順番にプロセッサを占有**する
 - ◆ 柔軟性の欠如...「急ぎの仕事」に対応できない
 - ◆ 応答性の悪さ... プログラムミスの発見が遅れる

- 第2世代のOS(1960年代前半)

- ◆ **ユーザの利便性を改善**することが強く意識される
- ◆ 「**複数のプログラムが同時並行的に実行**」...

されているように見せる仕組みの実現





ユーザは、「自分が計算機を占有している」ように使える

タイムシェアリングシステム

タイムシェアリングシステム (TSS, 時分割処理)

- プロセッサが、複数のプログラムを少しずつ実行する
- 短い時間(タイムスライス)で、プログラムを切替える




- トータルの実行時間は変わらない
(切替オーバーヘッドのため、効率は若干低下)
- ユーザの利便性は向上
⇒ 生産性の著しい向上



仮想計算機実現手段としてのTSS

- 時分割処理は, ユーザが計算機を独占しているように「錯覚」させるための仕組み
- 各ユーザに「**独立した仮想計算機**」を提供している
 - ◆ 他ユーザのプログラムの影響を受けないように...
 - ◆ ユーザのミスがシステム全体に影響しないように...



プロセスの概念の登場

- 独立した仮想計算機:
 - ◆ 個別のプログラム
 - ◆ 個別の計算環境(レジスタやメモリの内容)を保有している
- プロセッサは, 時分割で,
 - 各仮想計算機の動作をシミュレートすると考えることもできる

計算環境まで含めた仮想計算機をプロセスと呼ぶ

第3世代のOS

- 第2世代OS:
 - ◆ TSSにより,「仮想計算機」をユーザに提供
- 第3世代のOS(1960年代後半～70年代前半)
 - ◆ 抽象性と汎用性の導入
 - ◆ 仮想計算機:
 - 論理的な存在で, 比較的自由に設計可能
 - ハードウェアが違ってても, 同じ仮想計算機を!
 - ハードウェア上の制約からの脱却
 - ⇒ 仮想記憶などの技術が確立

マイルストーン: IBM OS/360

■ IBM System/360:

- ◆ 1964年発売の汎用計算機ファミリー
- ◆ 目的や用途に応じて、自由度の高い組合わせが可能



IBM System/360
IBMのWebページより

■ IBM OS/360:

- ◆ IBM System/360で採用されたOS
- ◆ ハードウェアの差異を吸収し、高い汎用性を実現
- ◆ 仮想記憶等、最新の技術を導入

第4世代のOS

- 第4世代のOS(1970年代後半～現在)
 - ◆ 基本的には, 第3世代までの延長
 - ◆ プロセス間通信やネットワーク対応等,
「協調作業」をサポートする仕組みが特徴的

現在のOS(1)

現在のOS: 多くの役割を背負っている

1. 計算資源の有効利用
 - プロセッサを遊ばせない
2. ハードウェアの差異の吸収
 - プログラムの再利用が可能となる
3. 論理的で使いやすい計算環境の提供
 - プログラミングが楽になる
 - ユーザの負担を小さくする

現在のOS(2)

4. プロセスの独立性・安全性保障
 - 他のユーザに邪魔されない計算環境を実現
 - あるユーザのミスが, 他のユーザやシステム全体に影響しないような仕組みを実現
5. 協調作業をサポートする仕組みの提供
 - 同一計算機内でのプロセス間通信
 - ネットワーク機能等, 外部世界との架け橋

代表的なOS: UNIX(1)

- 元来はミニコン, ワークステーション用OS
- 1970年代初頭に誕生, **他のOSに大きな影響を及ぼす**
 - ◆ モジュール化, モジュールの単機能化
 - ◆ パイプ, ソケット等の概念
 - ◆ 豊富なネットワーク機能
 - ◆ TCP/IPの実装(BSD UNIX) ⇒ インターネットの礎を築く
- 高い移植性, 優れたパフォーマンス
- **セキュリティ, 安定性, 堅牢性に優れた, 完成度の高いOS**

代表的なOS: UNIX(2)

歴史的経緯

- 初期バージョンの開発は、AT&T (ベル研究所) が主体
 - ◆ 独占禁止法の関係で、当初は比較的自由に配布可能
⇒ 急速な普及, 発展を遂げる
- BSD UNIX...カリフォルニア大バークレー校
 - ◆ AT&T版をベースに、大規模な機能改善を加えたもの
 - ◆ 豊富なネットワーク機能の実現
- AT&Tが分割され、UNIX の商用利用が可能に
 - ⇒ 厳しいライセンス管理, 不毛な法廷闘争
 - ⇒ 開発は停滞, オープンソース UNIX へ

代表的なOS: UNIX(3)

オープンソースUNIX:

- UNIXと同様の機能, 操作性を提供するOS
- ソースコードが公開されており, 誰でも無料で利用可能
 - ◆ GNU/Linux...GNU のソフトウェア群と Linux カーネル



- ◆ FreeBSD, OpenBSD, NetBSD etc.
- ◆ Solaris (Sun Microsystems)

商標権の関係から, UNIXとは名乗っていない

代表的なOS: Mac OS

- アップルコンピュータ・マッキントッシュ搭載のOS
 - ◆ グラフィカルディスプレイ, マウスの利用を前提
 - ◆ 統一的操作性を持つグラフィカル・ユーザインタフェース
 - ◆ とくにユーザインタフェース面において, 大きな影響

Macintosh 128K (1984)

<http://www.tamabi.ac.jp/mc/collect/collect.htm>



- 歴史的経緯
 - ◆ 元来は, ハードウェアに依存したOS (System 1~6)
 - ◆ System 7 (96年): ハードウェアとの分離, ネット対応
 - ◆ System 8, 9: システムの安定化
 - ◆ MacOS X: BSD UNIX ベース (NeXT社の技術を継承)

代表的なOS: Windows(1)

■ Microsoft Windowsシリーズ

- ◆ パーソナルコンピュータ, 小型サーバ向けOS
- ◆ PC用OSとして圧倒的なシェアを誇る
- ◆ 他のOSの長所を吸収, 巨大で複雑なOSに
- ◆ 安定性, セキュリティの問題が指摘されることも

■ 歴史的経緯

- ◆ 出発点は MS-DOS:「ディスク」オペレーションシステム
 - 基本的なファイル管理機能のみ
 - 後に, UNIXライクな機能を拡張
- ◆ 初期Windowsは, MS-DOSのユーザインタフェースを提供

代表的なOS: Windows(2)

歴史的経緯(続)

- Windows 3.1(1992, 日本版は1993)
 - ◆ タスク管理, メモリ管理の充実, 基本的なネット機能の装備
 - ◆ 日本語対応 ⇒ 日本のパソコン市場に大きな変化
- Windows 95 (1995)
 - ◆ ユーザインタフェースの改善
 - ◆ ネットワーク対応
- Windows 98, Windows ME...MS-DOSの技術制約が足枷に
- Windows NT, Windows 2000...MS-DOSに依存しないOS
- Windows XP...NT系列と95系列の融合
- Windows Vista...ユーザインタフェースの刷新

前半部分のまとめ

- OSとは何か
 - ◆ 歴史
 - ◆ 役割
 - ◆ 機能
 - ◆ 代表的なOS
- パソコンで動いているOSは, 生きた教材
 - ⇒ あちこち探してみると, 新しい発見があるはず

出欠確認 兼 ミニレポート


配布した用紙に以下を記入し，5限終了時に提出すること

- 所属，学生番号，氏名
- 5限開始時に着席している座席番号
(背中部分に表示があるはず)
- 以下の課題への回答(数行程度でよい)



- 課題：
 - ◆ 携帯電話等，モバイル機器にもOSが搭載されている。
これらのOSが，パソコン用OSと異なる点はどこか？

講義後半：情報理論入門



Claude E. Shannon (1916－2001)

情報理論の創始者

情報理論を支える3本の柱：

- 情報の定量化

- ◆ 情報の量を, どのように量るか

- 情報源符号化

- ◆ 情報源で発生する情報を, いかに効率よく表現するか

- 通信路符号化

- ◆ 偶発的に発生する誤りから, いかに情報を保護するか

情報の定量化

基本的な考え方:

- あるニュースを知る...対象に関する不確かさが減少する
- ニュースの持つ情報量 = 不確かさの減少量

⇒「不確かさ」を定量化することが先決...エントロピーの導入

エントロピー

- ◆ もともとは, 物理の専門用語
- ◆ 系の乱雑さを示す指標

情報源

■ 情報源:

- ◆ 情報を発生する存在
- ◆ 発生する情報は, 有限種類ある記号のどれか
- ◆ 一単位時刻あたり一つの記号を発生する
- ◆ 発生する記号の統計的性質(確率)はわかっている
- ◆ 実際にどの記号が発生するかは, わからない

$a_1 \quad a_2 \quad a_3 \quad a_4 \quad \dots$

情報源

- ▶ 時刻 i に記号 a_i を発生する
- ▶ $a_i \in M$ (M は有限集合)

情報源と記憶

- サイコロを投げる, コインを投げる etc.
 - ◆ 記号の生起確率分布が, 以前に発生した記号とは独立
⇒ 記憶の無い情報源
- 自然言語の文字, 天気データ etc.
 - ◆ 記号の生起確率分布が, 以前に発生した記号に依存
⇒ 記憶のある情報源
- 現実世界の多くの情報源は, 記憶のある情報源
 - ◆ 記憶の無い情報源の組合せとして表現できる場合も多い
 - ◆ この講義では, 記憶の無い情報源だけを考える

エントロピー

記憶の無い情報源 S が, 以下の確率で各記号を発生するとき...

記号	a_1	a_2	...	a_n
確率	p_1	p_2	...	p_n

S のエントロピーは $H(S) = \sum_{i=1}^n -p_i \log_2 p_i$ (ビット)

■ コイン投げの場合

記号	表	裏
確率	2^{-1}	2^{-1}

$$2^{-1} = 1/2$$

$$H(S) = -2^{-1} \log_2 2^{-1} - 2^{-1} \log_2 2^{-1} = 2^{-1} + 2^{-1} = 1 \text{ ビット}$$

エントロピーの例

■ コインを2枚投げる場合

記号	表表	表裏	裏表	裏裏
確率	4^{-1}	4^{-1}	4^{-1}	4^{-1}

$$H(S) = 4(-4^{-1} \log_2 4^{-1}) = \log_2 4 = 2 \text{ ビット}$$

■ サイコロ投げの場合

記号	1	2	3	4	5	6
確率	6^{-1}	6^{-1}	6^{-1}	6^{-1}	6^{-1}	6^{-1}

$$H(S) = 6(-6^{-1} \log_2 6^{-1}) = \log_2 6 = 2.585 \text{ ビット}$$

直感的には、「エントロピーが大きい＝予想が難しい」

「エントロピーが大きい＝発生情報に関する不確かさが大きい」

エントロピーの例(2)

■ 奈良の天気

記号	晴	曇	雨
確率	0.4	0.5	0.1

$$\begin{aligned} H(S) &= -0.4\log_2 0.4 - 0.5\log_2 0.5 - 0.1\log_2 0.1 \\ &= -0.4(-1.322) - 0.5(-1.0) - 0.1(-3.322) = 1.361 \text{ ビット} \end{aligned}$$

■ サハラ砂漠の天気

記号	晴	曇	雨
確率	1.0	0	0

$$H(S) = -1.0\log_2 1.0 = 0 \text{ ビット}$$

あいまいさなく、発生情報を予想可能

通報とエントロピー

■ サッカー日本チームの成績

記号	勝	引分	負
確率	3^{-1}	3^{-1}	3^{-1}

$$H(S) = 3(-3^{-1} \log_2 3^{-1}) = \log_2 3 = 1.585 \text{ ビット}$$

■ あるニュースを聞いた...「昨日の試合では、負けなかった」

⇒ 勝ったか、引き分けたか

記号	勝	引分	負
確率	2^{-1}	2^{-1}	0

$$H(S) = 2(-2^{-1} \log_2 2^{-1}) = \log_2 2 = 1 \text{ ビット}$$

■ ニュースを聞いたことで、エントロピーが0.585ビット減少した

情報量

- ニュースを聞く前の試合結果...1.585ビット
- ニュースを聞いた後の試合結果...1.0ビット

ニュースを聞いたことで、試合結果に関する不確かさが減少した
⇒ **ニュースが情報をもたらした**

ニュースがもたらした情報の量 = 不確かさの減少量と定義する
「昨日の試合では、負けなかった」...0.585ビットの情報量を持つ

通報と情報量

■ サッカーブラジルチームの成績

記号	勝	引分	負
確率	0.6	0.3	0.1

$$H(S) = -0.6\log_2 0.6 - 0.3\log_2 0.3 - 0.1\log_2 0.1 \\ - 0.6(-0.737) - 0.3(-1.737) - 0.1(-3.322) = 1.295 \text{ ビット}$$

■ ニュース「昨日の試合では、負けなかった」

記号	勝	引分	負
確率	2/3	1/3	0

$$H(S) = -\frac{2}{3}\log_2 \frac{2}{3} - \frac{1}{3}\log_2 \frac{1}{3} = 0.918 \text{ ビット}$$

情報量は $1.295 - 0.918 = 0.377$ ビット...同じ通報でも、情報量は違う

通報の順序と情報量(1)

- トランプのカードを, 52枚の中から1枚選ぶ

$$H(S) = 52 \left(-\frac{1}{52} \log_2 \frac{1}{52} \right) = 5.70 \text{ ビット}$$

- ヒント1: 選んだ札は赤い札である

$$H(S) = 26 \left(-\frac{1}{26} \log_2 \frac{1}{26} \right) = 4.70 \text{ ビット}$$

◆ ヒント1の持つ情報量 = $5.70 - 4.70 = 1.00$ ビット

- ヒント2: 選んだ札は絵札である

$$H(S) = 6 \left(-\frac{1}{6} \log_2 \frac{1}{6} \right) = 2.58 \text{ ビット}$$

◆ ヒント2の持つ情報量 = $4.70 - 2.58 = 2.12$ ビット

通報の順序と情報量(2)

■ ヒント3: 選んだ札は8以上である

◆ ヒント2の後にヒント3をもらった場合

- エントロピーは変化無し...ヒント3の情報量は 0 ビット

◆ ヒント2の前にヒント3をもらった場合

$$H(S) = 52 \left(-\frac{1}{52} \log_2 \frac{1}{52} \right) = 5.70 \text{ ビット}$$

↓ ヒント1...1.00ビット

$$H(S) = 26 \left(-\frac{1}{26} \log_2 \frac{1}{26} \right) = 4.70 \text{ ビット}$$

↓ ヒント3...1.12ビット

$$H(S) = 12 \left(-\frac{1}{12} \log_2 \frac{1}{12} \right) = 3.58 \text{ ビット}$$

↓ ヒント2...1.00ビット

$$H(S) = 6 \left(-\frac{1}{6} \log_2 \frac{1}{6} \right) = 2.58 \text{ ビット}$$

天気予報

■ 100日間の天気予報Aとその結果の記録:

- ◆ 予報が晴で, 天気も晴...45日
- ◆ 予報が晴で, 天気は雨...15日
- ◆ 予報が雨で, 天気は晴...12日
- ◆ 予報が雨で, 天気も雨...28日

		予 報 A	
		晴	雨
実 況	晴	45	12
	雨	15	28

■ 同じ期間の天気予報B:

- ◆ 予報が晴で, 天気も晴...0日
- ◆ 予報が晴で, 天気は雨...43日
- ◆ 予報が雨で, 天気は晴...57日
- ◆ 予報が雨で, 天気も雨...0日

		予 報 B	
		晴	雨
実 況	晴	0	57
	雨	43	0

天気予報の当たる確率

天気予報は、必ずしも正確でない

■ 予報Aの当たる確率

$$(45 + 28) / 100 = 73\%$$

		予 報 A	
		晴	雨
実 況	晴	45	12
	雨	15	28

■ 予報Bの当たる確率

$$(0 + 0) / 100 = 0\%$$

...絶対はずれる天気予報

		予 報 B	
		晴	雨
実 況	晴	0	57
	雨	43	0

予報Aのほうが役に立つ(情報量が大きい)か？

■ 晴れる日, 雨の日は, トータル57日と43日

$$H(S) = -0.57 \log_2 0.57 - 0.43 \log_2 0.43 = 0.986 \text{ ビット}$$

⇒ 予報が, このエントロピーをどれだけ減らせるか？

予報Aの情報量

■ 予報Aが晴のとき...

- ◆ 本当に晴れ: $45 / 60 = 0.75$

- ◆ 雨が降る: $15 / 60 = 0.25$

- ◆ 「晴」という予報を知った後のエントロピー

$$H(S) = -0.75 \log_2 0.75 - 0.25 \log_2 0.25 = 0.811 \text{ ビット}$$

- ◆ 「晴」という予報の持つ情報量は $0.986 - 0.811 = 0.175$ ビット

■ 「雨」という予報の持つ情報量は $0.986 - 0.811 = 0.105$ ビット

■ 予報Aの平均情報量は, $0.6 \cdot 0.175 + 0.4 \cdot 0.105 = 0.147$ ビット

		予 報 A	
		晴	雨
実 況	晴	45	12
	雨	15	28

予報Bの情報量

■ 予報Aが晴のとき...

- ◆ 本当に晴れ: $0 / 43 = 0$

- ◆ 雨が降る: $43 / 43 = 1.00$

- ◆ 「晴」という予報を知った後のエントロピー

$$H(S) = -1.0 \log_2 1.0 = 0 \text{ ビット}$$

- ◆ 「晴」という予報の持つ情報量は $0.986 - 0 = 0.986$ ビット

■ 「雨」という予報の持つ情報量は $0.986 - 0 = 0.986$ ビット

■ 予報Bの平均情報量は 0.986 ビット

⇒ 当たる確率は低くても、情報量は予報Aより大きい

⇒ 我々が直感的に理解している情報量と、よくマッチしている

		予 報 B	
		晴	雨
実 況	晴	0	57
	雨	43	0

情報源符号化定理

シャノンの情報源符号化定理

- エントロピー h の情報源から発生する記号は、一記号あたり h ビットで表現(符号化)することが可能である
- コイン投げ: エントロピーは1ビット
 - ◆ 「表」を0に, 「裏」を1 に符号化すれば良い
- コイン2枚投げ: エントロピーは2ビット
 - ◆ 「表表」「表裏」「裏表」「裏裏」をそれぞれ, 00, 01, 10, 11に
- サイコロ: エントロピーは2.585ビット
 - ◆ 1, 2, 3, 4, 5, 6 を, 001, 010, 011, 100, 101, 110 に...
 - ⇒ 平均3ビット? ...**もっと効率よく符号化できるはず**

情報源符号化

情報源符号化:

- ◆ 情報源から発生する記号を, 効率よく表現するための手法
- ◆ 情報圧縮, と呼ばれることも

情報源記号	符号語
晴	00
曇	010
雨	011
雪	1101

- ◆ コンパクトに表現するだけでなく, 取り扱いやすさも必要
⇒ 瞬時復号可能性

瞬時復号可能性

瞬時復号可能性:

符号語を区切らず書いても、後戻り無しで復号できるという性質

情報源記号	C_1	C_2
晴	0	0
曇	10	01
雨	110	011
雪	111	111

C_1 は瞬時復号可能

C_2 は瞬時復号可能でない

晴, 雪, 雪, 晴を符号化して送る

■ C_1 : 01111110 $\Rightarrow$ 0 | 111 | 111 | 0...すぐに符号語に区切れる

■ C_2 : 01111110...7文字目まで受け取った段階では

◆ 0 | 111 | 111 | か 01 | 111 | 11 か 011 | 111 | 1 か不明

晴 雪 雪 曇 雪 (雪?) 雨 雪 (雪?)

瞬時符号となる条件

符号 C が瞬時符号となる $\Leftrightarrow$

C のどの符号語も, C の他の符号語の接頭語になっていない

情報源記号	C_1	C_2
晴	0	0
曇	10	01
雨	110	011
雪	111	111

0 は 01, 011 の接頭語

01 は 011 の接頭語


$C = \{w_1, w_2, \dots, w_M\}$, $|w_i| = l_i$ とする. もし C が瞬時復号可能なら
$$2^{-l_1} + 2^{-l_2} + \dots + 2^{-l_M} \leq 1 \quad (\text{クラフトの不等式})$$

瞬時符号の作り方

■ 符号木の葉を符号語に対応させる

■ 符号木:

- ◆ 二分木(子が最大2つの木構造)
- ◆ 辺には 0 か 1 がラベル付け
- ◆ 異なる子は異なるラベルで連結



平均符号長

- 確率 p_i で発生する記号に, 符号語 w_i を対応付ける
- 符号語 w_i の長さを l_i とすると...
- 平均符号語長は... $\sum p_i l_i$

記号	確率	C_1	C_2
晴	0.4	0	111
曇	0.3	10	110
雨	0.2	110	10
雪	0.1	111	0

- C_1 の平均符号長は $0.4 \cdot 1 + 0.3 \cdot 2 + 0.2 \cdot 3 + 0.1 \cdot 3 = 1.9$
 - C_2 の平均符号長は $0.4 \cdot 3 + 0.3 \cdot 3 + 0.2 \cdot 2 + 0.1 \cdot 1 = 2.6$
- ⇒ 平均符号長が短いほうが, 効率よい(コンパクトな表現)

情報源符号化の目的

求められる情報源符号化法:


- ◆ 瞬時復号可能であること
- ◆ 平均符号長ができるだけ短いこと

⇒ **ハフマン符号化法**

- ◆ 符号木を, ボトムアップ的に構成していく
- ◆ 情報源記号と一対一に対応する葉節点を準備
- ◆ 葉節点には, 対応する情報源記号の生起確率を付与
- ◆ 生起確率の小さな木(節点)を併合し, より大きな木を構成
- ◆ 併合された木の確率は, その部分木の確率の和
- ◆ 全体が一つの符号木になるまで, 操作を繰り返す

ハフマン符号化法

記号	A	B	C	D
確率	0.60	0.25	0.10	0.05



ハフマン符号の平均符号長

記号	確率	C_1	C_2
A	0.60	00	0
B	0.25	01	10
C	0.10	10	110
D	0.05	11	111

- C_1 の平均符号長...2
- C_2 の平均符号長... $0.60 \cdot 1 + 0.25 \cdot 2 + 0.10 \cdot 3 + 0.05 \cdot 3 = 1.60$
- ハフマン符号 C_2 のほうが, 効率がよい
- この情報源のエントロピー $H(S) = 1.49$ ビット
- ハフマン符号にも, まだ改良の余地がある $\Rightarrow$ ブロック化

ブロックハフマン符号

- 情報源記号を、いくつかまとめて(ブロック化して)符号化する

記号 確率 符号語

A	0.6	0
B	0.3	10
C	0.1	11

平均符号長 1.4 ビット

記号 確率 符号語

AA	0.36	0
AB	0.18	100
AC	0.06	1100
BA	0.18	101
BB	0.09	1110
BC	0.03	11110
CA	0.06	1101
CB	0.03	111110
CC	0.01	111111

平均符号長 2.67 ビット

⇒ 一記号あたり 1.335 ビット

ユニバーサル符号化, 非可逆符号化

- ハフマン符号化...情報源記号の確率分布が, 事前に必要
- 確率分布が(正確には)わからないケースも多い

⇒ **ユニバーサル符号化法**

- ◆ どのような情報源に対しても, そこそこ良い性能を発揮
 - ◆ LZ77法 (lha, gzip, zoo, zip etc.)
 - ◆ LZ78法 (compress, stufit etc.)
 - ◆ LZW法 (GIF, TIFF 等の画像フォーマット)
-
- 音声や画像等の情報...
 - ◆ 細部まで正確に再現できなくても, 実害なし
 - ◆ 再現性を一部犠牲にして, 高い圧縮率を⇒**非可逆符号化**

通信路符号化

偶発的に発生する誤りから、情報を保護したい

- ◆ 通信路において発生するノイズから情報を守る
- ◆ CD-ROM が傷ついても、中のデータは読めるようにする
- あくまでも偶発的な情報の損失だけを対象とする
 - ◆ 暗号, セキュリティ...意図的な妨害行為
- 基本的な考え方:
 - ◆ 誤りを検出し, 訂正するための「余分な情報」を追加する

パリティ検査符号

パリティ記号の付加:

0と1で表現されたひとまとまりのデータの中に,

▶ 1が**偶数個**あれば**0**を

▶ 1が**奇数個**あれば**1**を

データの最後にくっつける操作

01001  01001**0**

01011  01011**1**

■ パリティ記号の付加されたデータは,
偶数個の1を含む(偶パリティ符号)

■ 1の個数が奇数個


⇒ 誤りの影響を受けている

誤りを含む  101001

サーバ用メモリ等で利用されている

誤りの検出から訂正へ

- 偶パリティ符号そのものには, 誤り訂正能力がない
- 偶パリティ符号を組み合わせれば, 誤り訂正可能に
- 例: 4ビットの情報を保護したい
 - ◆ 4ビットを長方形状に並べる
 - ◆ 水平方向, 垂直方向にパリティ記号(5ビット)を付加




0111 $\longrightarrow$ 011110101

(9, 4) 符号


- ▶ 長さ9ビット
- ▶ 内4ビットが本来の情報
- ▶ 符号化率 4/9

誤り訂正の原理

- 前出の (9,4) 符号 $\Rightarrow$ どの行, 列とも, 1は偶数個
- 1ビットの誤りが発生すると...
 - ◆ 誤りを含む行, 列だけ, 1が奇数個になる
 - ◆ 受信者は, 誤りの発生位置を特定することが可能
 - 誤りは, 異常のある行・列の交点に存在するはず



正常(誤り無し)




異常(誤りあり)

一般的な線形符号へ

前出の (9,4) 符号 $\Rightarrow$ 行単位, 列単位でパリティ記号を計算

- ◆ 二次元的な行, 列にこだわる必要はない
- ◆ 斜めにたどる, 途中で曲げる, スポットの拾う etc...
- ◆ データビットの任意の組合せからパリティ記号を計算可能
- ◆ 組み合わせ方により, 符号の性能が変化する



線形符号:


データビットの部分集合から
パリティ記号を定義する符号

いかにして良い組み合わせ方を探すか

$\Rightarrow$ 符号設計者の腕の見せ所

ハミング符号


- 代表的なブロック符号
- 符号語中に発生する1ビットの誤りを訂正可能
- 非常に効率が良い(完全符号)



0111 $\longrightarrow$ 0111100

■ (7,4)符号

■ 効率 4/7



0111 $\longrightarrow$ 011110101


■ (9,4)符号

■ 効率 4/9

(どちらも, より大規模の符号も構成可能)

線形符号の特徴

- 符号化, 誤りの検出, 訂正とも, 行列演算により実行可能
- 行列演算 $\Rightarrow$ 単純な組合せ回路だけで実現可能
 $\Rightarrow$ 高速に動作させるのに有利
- 規模の大きな線形符号
 - ◆ 巨大な行列に対する演算が必要となる
 - ◆ 組合せ回路の面積増大 $\Rightarrow$ 遅延, 消費電力, 設計困難
 - ◆ スケーラビリティが悪い



もっと扱いやすい線形符号は？

巡回符号

- 符号化, 復号を, シフトレジスタで実現できる線形符号
- 一般の線形符号に比べ, 実装面で有利
 - ◆ シフトレジスタ利用による配線の簡単化
 - ◆ 符号化処理と復号処理で, 回路の一部共有化が可能

代表的な巡回符号:

- ◆ BCH符号
- ◆ Reed-Solomon符号:
 - 多元符号(バイト単位での取り扱い等も容易)
 - CD, DVD等でも採用

畳込み符号

- 符号化装置を, 有限状態機械として実現する方式
- **最尤復号**が, 比較的効率よく行える(ビタビアルゴリズム)
 - ◆ 統計的に, 最も信頼度の高い復号法
- **軟判定復号**の実現も容易
 - ◆ 復号精度を上げる技術
 - ◆ 受信値の信頼度を, 0と1の二値でなく, より多段階で表現
- 多くの通信方式にて, 畳込み符号が実際に用いられている

次世代誤り訂正符号

ターボ符号, LDPC符号

- 非常に規模の大きな符号
- 繰り返し計算を行うことにより, 誤りの推測・訂正を行う
- サイバネティクス, 機械学習的アプローチ, と理解することも

後半部分まとめ

- 情報の定量化
 - ◆ 情報の量を, どのように量るか
- 情報源符号化
 - ◆ 情報源で発生する情報を, いかに効率よく表現するか
- 通信路符号化
 - ◆ 偶発的に発生する誤りから, いかに情報を保護するか

現代の情報システムを支える基盤となる理論体系


出欠確認 兼 ミニレポート

配布用紙に以下を記入し，退室時，ドア付近の箱に提出

- 所属，学生番号，氏名
- 5限開始時に着席していた座席番号
(背中部分に表示があるはず)
- 以下の課題への回答(数行程度でよい)



- 課題：
 - ◆ 携帯電話等，モバイル機器にもOSが搭載されている。
これらのOSが，パソコン用OSと異なる点はどこか？



バイオの学生

物質創成の学生

