

はじめに

清水謙多郎


shimizuk@fc.jwu.ac.jp

授業の目的

ゲノムやタンパク質などの生物情報のさまざまなデータベース、データ解析手法を紹介し、それらの実習を通して、生命科学、健康・医療、農学の分野で情報科学がどのように利用されているかを体験する。

1. ゲノム、遺伝子、タンパク質

分子生物学の基礎、データサイエンスの 利用





3. 遺伝子のバリエーション


お酒が飲める／飲めないに関わる遺伝子、
血液型の遺伝子、短距離走／長距離走のど
ちらが得意かに関わる遺伝子など

血液型の決まり方

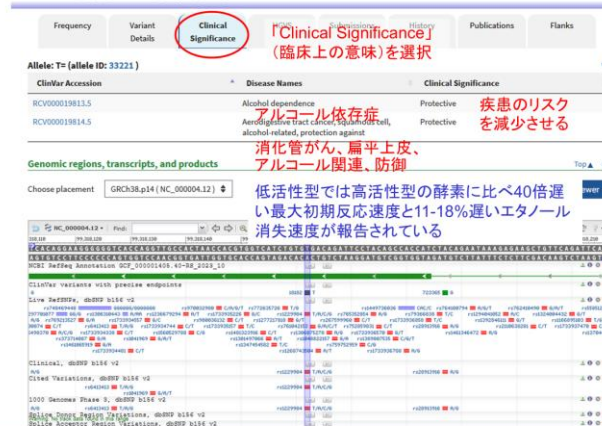
血液型に関するABO遺伝子の主

SNP id	遺伝子の配列	変異
変異なし(A型の遺伝子を基準にした場合)		
rs8176746	796番目のC→A	2
rs8176747	800番目のG→C	2
rs8176719	261番目のGの欠失	3 ク

A型遺伝子が作る酵素  を付加(転移) B型遺伝子が作る酵素  を付加

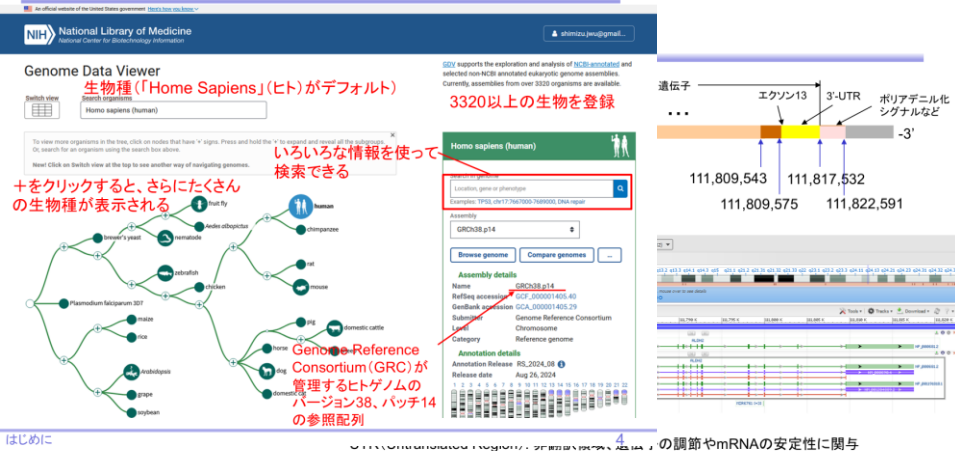


SNPを調べてみよう



2. ゲノムブラウザによるゲノムの閲覧、ヒトと他の生物のゲノム、遺伝子の比較

ALDH2遺伝子の検索



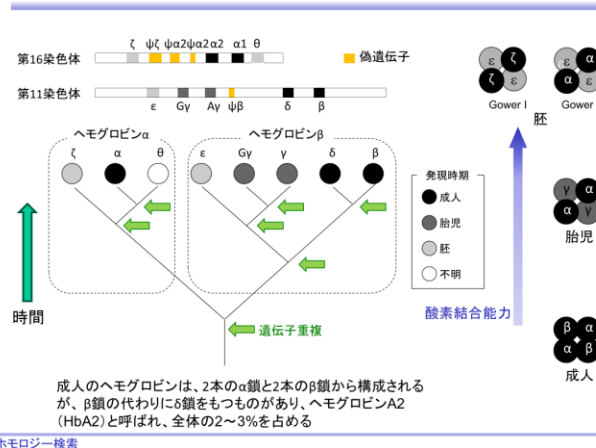
4. ホモロジー検索

アミラーゼや嗅覚遺伝子の進化、マンモスがもつ遺伝子が現存するどの生物の遺伝子に近いのか

ホモロジー検索の利用




ヒトのヘモグロビンの遺伝子と分子進化



参考書

とくに指定しませんが、バイオインフォマティクスの分野、データ解析についてしっかり学びたいという人には以下の書籍を紹介します。



門田幸二, 清水謙多郎, 岸野洋久, 寺田透（編）,
Web連携テキスト バイオインフォマティクス
基礎と応用, 培風館, 2022.

基本的な教科書がありますので、あらためて紹介しますが、この講義の内容をカバーするものではありません。

生物と情報

生物という複雑な対象を理解するには、
実験データを蓄積し、

それを解析することにより、
そこに埋もれている情報を探し出して、
新しい知識を得る

生命現象をシミュレートして、
生物の理解、応用に役立てる

理論

ゲノムなどの網羅
的な解析による大
量のデータ

データベース


仮説の構築

ソフトウェア

実験に代わる解析、
予測、設計へ

データサイエンス

- 1980年代後半、ヒトゲノムプロジェクトの発足 → 大量のゲノムデータの処理




データベース、ソフトウェア
の研究は1970年代から

ヒトゲノム解読以降、
「ポストゲノム」の時代

- 多数の生物、個体（個人）のゲノム、さらにタンパク質、代謝物質、表現型などを含めた超大量かつ多様なデータ（ビッグデータ）の解析の必要性

生命科学のデータベースの登録数の増加



データベースの話は、あとで改めてします

生命科学のビッグデータ 1

• ゲノムデータ

- ヒトゲノム1個のシーケンスデータは約3.2Gb（ギガベース）
- 30×深度での全ゲノムシーケンスのrawデータで 80～200GB（ギガバイト）程度／個人
- 大規模なゲノムプロジェクトでは数十PBの規模に達する（→ バイオバンクデータ）

• トランスクリプトームデータ

- RNAシーケンス（RNA-seq）のデータは、1回のサンプルで10～30Gb
- 数百～数千サンプルを扱うプロジェクトでは、データ量は TB～数十TB
- シングルセルRNA-seq（scRNA-seq）では、細胞数やリード数でさらに指数的に増加、サンプルあたりの原データ+中間ファイルで、1～5TBを超えることもある

• プロテオームデータ

- 質量分析を用いたタンパク質の同定・定量解析では、1回の実験で10GB～100GBのデータが生成される
- 大規模プロジェクト（例えば人口集団・疾患集団）では 数TB～10PBのデータが蓄積されることがある

• メタボロームデータ

- メタボローム解析では、1回のサンプルで数MBから数GBのデータが生成される
- 大規模な研究では数百～数千サンプルを解析 → 数十TBのデータ量

生命科学のビッグデータ 2

・ パーソナルヘルスデータ

- ウェアラブルデバイスや健康管理アプリから得られるデータは1人あたり数MBから数GB/日程度のデータ量
- 数百万人規模のコホート研究や国民健康モニタリングプロジェクトでは 数PB 規模のデータが生成・保管されている

・ バイオイメージングデータ

- 1回のMRIスキャンで数百MB～数GBのデータが生成される
- 顕微鏡画像やタイムラプス／3D撮像などでは、1実験で 数十～数百GB
- 多数の症例や多数の時間点を含む研究で 数十～数百TB に拡大
- イメージングデータは、分子イメージング、植物のイメージング、微生物の観察、生態系モニタリングなど多岐にわたる

・ バイオバンクデータ

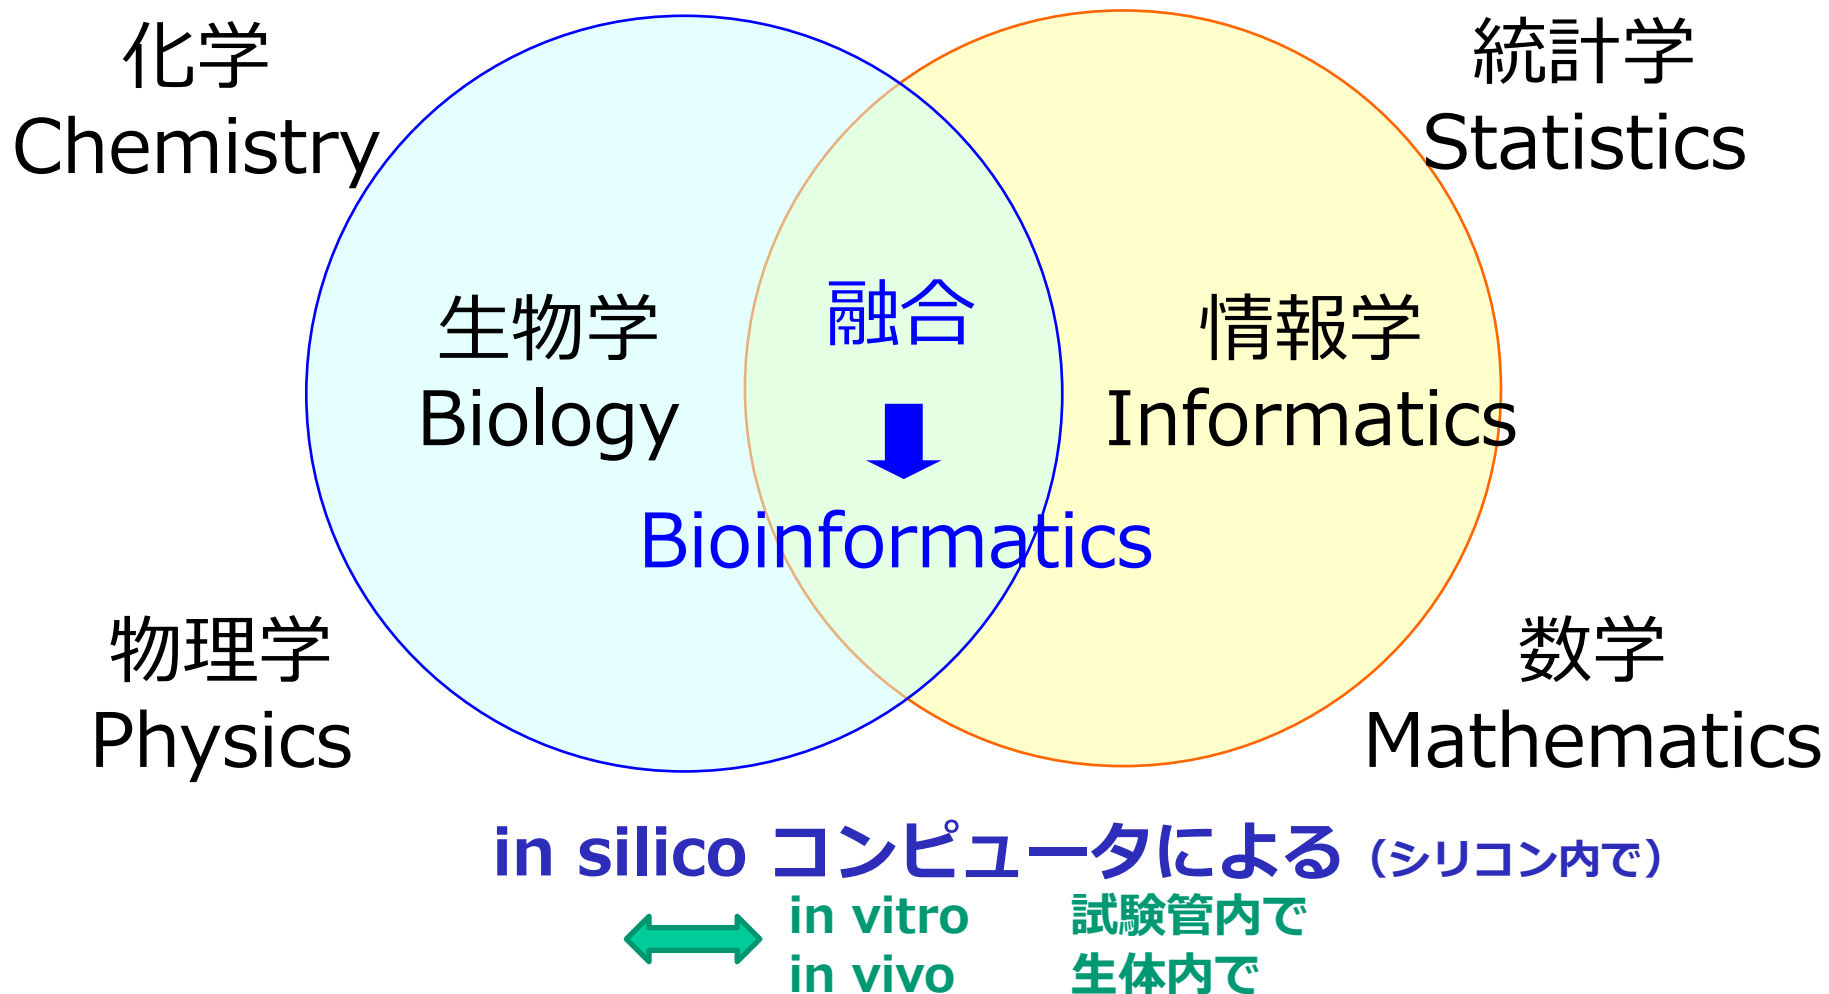
- UK Biobank → 約50万人分の健康情報やゲノムデータ、総データ量は約28PB
- 米国 All of Us → 100万人規模を目標とする国民コホート研究、健康情報・電子カルテ・ゲノムデータを収集、既に数十万人分が登録済み
- 中国 GSA (Genome Sequence Archive) → 20PB超
- 東北メガバンク → 地域住民の健康情報やゲノムデータ、総データ量は十数PB

単位について

接頭語	名前	読み	国際単位系(SI)	情報系	命数	語の意味
Y	Yotta	ヨタ	10^{24}	$2^{80}=1,208,925,819,614,629,174,706,176$	杼	8
Z	Zetta	ゼタ	10^{21}	$2^{70}=1,180,591,620,717,411,303,424$	10垓	7
E	Exa	エクサ	10^{18}	$2^{60}=1,152,921,504,606,846,976$	100京	6
P	Peta	ペタ	10^{15}	$2^{50}=1,125,899,906,842,624$	1000兆	5
T	Tera	テラ	10^{12}	$2^{40}=1,099,511,627,776$	兆	怪物
G	Giga	ギガ	10^9	$2^{30}=1,073,741,824$	10億	巨人
M	Mega	メガ	10^6	$2^{20}=1,048,576$	100万	大量
k	Kilo	キロ	10^3	$2^{10}=1,024$	千	1000
h	hecto	ヘクト	10^2		百	100
da	deca	デカ	10^1		十	10
d	deci	デシ	10^{-1}			10
c	centi	センチ	10^{-2}			100
m	miri	ミリ	10^{-3}	SIと区別するため、IEC(国際電気標準会議)では、2のべき乗に対して、binaryを付ける単位を提唱している。例えば、 2^{10} はkilobinary(略称Kibi, Kiと表記)、同様に、 2^{20} はMibi, Mi、 2^{30} はGibi, Giとなる。		1000
μ	micro	マイクロ	10^{-6}			微小
n	nano	ナノ	10^{-9}			小人
p	pico	ピコ	10^{-12}			先端
f	femto	ファムト	10^{-15}			15
a	atto	アト	10^{-18}			18
z	zepto	セプト	10^{-21}			7
y	yocto	ヨクト	10^{-24}			8

バイオインフォマティクスとは

生命科学の問題を情報学（インフォマティクス）の考え方や手法によって解決しようという学問



コンピュータ科学と分子生物学の発展

コンピュータ科学

生成系AI
ビッグデータ 機械学習
次世代スーパーコンピュータ
クラウドコンピューティング
Google検索 Wikipedia

DVD
World Wide Web
CD-ROM 携帯電話
スーパーコンピュータ
商用パーソナルコンピュータ
関係データベース ARPANET
UNIX

人工知能、数値計算
シャノン「通信の数学的理論」

プログラム内蔵型コンピュータ

チューリングマシン

分子生物学

AlphaFold
ゲノム編集 合成生物学
メタゲノム
次世代シーケンサー
ES細胞、iPS細胞
ヒトゲノムの解読
クローン羊ドリー
DNAマイクロアレイ

PCR法
塩基配列データベース

遺伝子工学の特許
組換えDNA
コドン
形質導入
DNA構造の発見

遺伝子の本体がDNAであることを証明
ー遺伝子ー酵素説
ウィーバーによる分子生物学の提唱
合成抗生物質
ペニシリン

2025

2000

1975

1950

1925

情報学の概念の生物学への浸透






- 核酸はタンパク質を正しい時と場所で作るための情報を暗号化してもっている
- DNA配列にコードされた情報がどのようにタンパク質に翻訳されるか
- 細胞の死は、内部プログラムによる
- フィードバック制御によって、受容体からのシグナル伝達を負に調節する
- 転写回路によって細胞は論理演算を遂行できる
- それぞれの細胞は特定の組み合わせの細胞外シグナル分子に応答するようにプログラムされている
- 初期の発生段階では、シグナル伝達経路間のクロストークがきわめて強くなる
- . . .

細胞の分子生物学 第6版より

プログラミング言語

バイオインフォマティクスでよく使われるプログラミング言語

バイオ分野のデータ解析に
便利な拡張（ライブラリ）

R	統計解析のための言語および開発実行環境、豊富なパッケージが利用可能	多数のバイオインフォマティクスパッケージ
Python	文法がシンプル、書きやすさを重視、豊富なライブラリ、AI、自然言語処理、ソフトウェアツールなど	
Perl	テキスト処理機能が充実、正規表現が組み込まれる、書きやすさ、豊富なライブラリ	
Ruby	オブジェクト指向言語として開発される、書きやすさを重視、豊富なライブラリ、Webシステム開発など	
Java	オブジェクト指向、機能が豊富、高性能、豊富なライブラリ、システム開発に利用される	
C++	C言語の拡張、オブジェクト指向、機能が非常に豊富、高性能、システム開発に広く利用される	

PubMedの論文検索ヒット数

PubMed: 生命科学や生物医学に関する文献検索エンジン

件数

