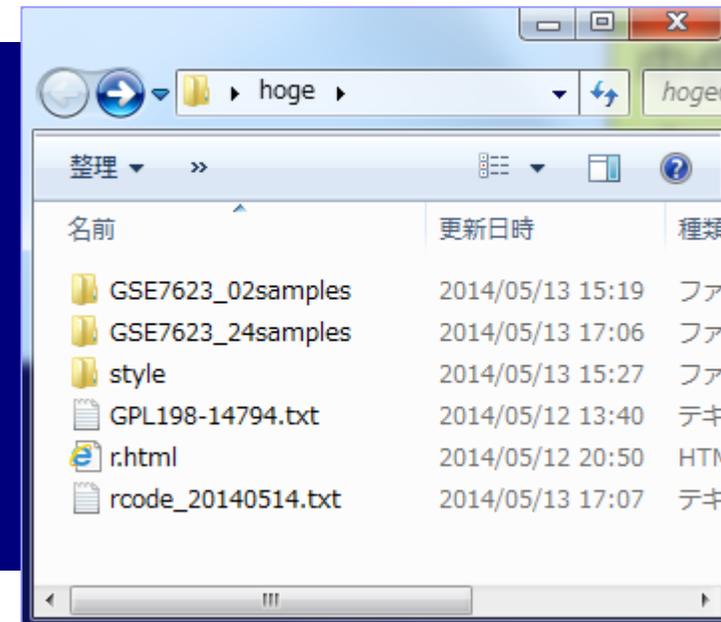


機能ゲノム学 第1回

東京大学大学院農学生命科学研究科
アグリバイオインフォマティクス教育研究ユニット
門田幸二

kadota@iu.a.u-tokyo.ac.jp

講義室後ろにあるUSBメモリ
中のhogeフォルダをデスクトッ
プにコピーしておいてください。



前回(4/30)のhogeフォルダが
デスクトップに残っているかも
しれないのでご注意ください。

NGS速習コース開催(9/1~12@東大農)

実施日	実施時間	大項目	項目番号および項目	習得技術	レベル	形式	担当講師(敬称略)
9月1日	10:40-12:00	1. コンピュータリテラシーとサーバー設計	1-1. OS、ハード構成	コンピューターの基本の理解	初級	講義	中村保一(DBBJ)
	13:15-14:45		1-2. ネットワーク基礎	インターネット、セキュリティの基本の理解	初級	講義	中村保一(DBBJ)
	15:00-16:30		1-3. UNIX I	UNIXの基礎の理解 Linux導入	初級	実習	仲里猛留(DBCLS)
	16:45-18:15						仲里猛留(DBCLS)
9月2日	10:30-12:00						仲里猛留(DBCLS)
13:15-14:45	仲里猛留(DBCLS)						
15:00-16:30	仲里猛留(DBCLS)						
16:45-18:15	仲里猛留(DBCLS)						
9月3日	10:30-12:00		1-4. スクリプト言語	Perl シェルスクリプト	中級	実習	山口昌雄(アメリエフ)
13:15-14:45	山口昌雄(アメリエフ)						
15:00-16:30	山口昌雄(アメリエフ)						
16:45-18:15	山口昌雄(アメリエフ)						
9月4日	10:30-12:00	山口昌雄(アメリエフ)					
13:15-14:45	山口昌雄(アメリエフ)						
15:00-16:30	山口昌雄(アメリエフ)						
16:45-18:15	山口昌雄(アメリエフ)						
9月5日	10:30-12:00	2. 配列インフォマティクス	2-1. 配列解析基礎	配列、ゲノムデータ記述のフォーマット、アラインメント(DP)、データベース検索(BLAST, BLAT)等の基礎的な配列比較解析の原理と実習	初級	実習	坊屋秀雅(DBCLS)
	13:15-14:45		2-2. バイオ系データベース概論	基本的な各種バイオ系データベースの理解、統合DBの利用法	初級	実習	坊屋秀雅(DBCLS)
	15:00-16:30						小野浩雅(DBCLS)
	16:45-18:15						小野浩雅(DBCLS)
9月8日	10:30-12:00	3. データ解析基礎	3-1. R基礎I	R言語の基礎(インストールから利用まで)	初級	実習	門田幸二(東京大学)
	13:15-14:45		3-2. R基礎2	ファイルの読み込み、行列演算の基本	初級	実習	門田幸二(東京大学)
	15:00-16:30		3-3. R各種パッケージ	Rの各種パッケージのインストール法と代表的なパッケージの利用法	中級	実習	門田幸二(東京大学)
	16:45-18:15		3-4. R bioconductor I	Bioconductorの利用法	中級	実習	門田幸二(東京大学)
9月9日	10:30-12:00						門田幸二(東京大学)
13:15-14:45	門田幸二(東京大学)						
15:00-16:30	門田幸二(東京大学)						
16:45-18:15	3-5. R bioconductor II		FASTAandFASTQ形式ファイルの読み込み ファイル形式の変換(FASTQ→FASTA)、クオリティチェック、リード配列長分布、フィルタリングやリミミング、GC含量計算など	中級	実習	門田幸二(東京大学)	
9月10日	10:30-12:00	4. 次世代シーケンサ	4-1. 次世代シーケンサ基礎I	原理の理解	初級	講義	倉田哲也(NAIST)
	13:15-14:45		4-2. 次世代シーケンサ基礎II	応用分野とそのための計測技術の理解 (RNA-seq, ChIP-seq, がんゲノム、個人ゲノム、環境ゲノム、Hi-C)	初級	講義	倉田哲也(NAIST)
	15:00-16:30		4-3. 次世代シーケンサ実習I	ファイル形式、可視化、quality check、マッピング、アセンブル	初級	実習	山口昌雄(アメリエフ)
	16:45-18:15						山口昌雄(アメリエフ)
9月11日	10:30-12:00		4-4. 次世代シーケンサ実習II	代表的なパイプラインについての実習: RNA-seq	初級	実習	山口昌雄(アメリエフ)
	13:15-14:45						山口昌雄(アメリエフ)
	15:00-16:30						山口昌雄(アメリエフ)
	16:45-18:15						山口昌雄(アメリエフ)
9月12日	10:30-12:00	6. 分子生命科学	6-1. 分子生命科学概論	複製、転写、翻訳、代謝、シグナル伝達などの基礎知識	初級	講義	河岡慎平(ATR)
	13:15-14:45						河岡慎平(ATR)
	15:00-16:30						河岡慎平(ATR)
	16:45-18:15	5. ゲノム関連の倫理・法律	5-1. ゲノム情報倫理概論	ゲノム情報を扱う上で、プライバシー保護などの必要な倫理的問題、法的問題の国内外の状況を理解し、ゲノム情報を適切に利用できるようにする。匿名化、暗号化、情報セキュリティ概要			箕輪真理(NBDC) 川崎実苗(NBDC)

申し込み受付は6/2の11:00-
(おそらくそれで枠がいっぱいになるので)2週間全て
参加可能な本当にやる気のあるヒトのみ募集。
全国から募集(アグリバイオの講義とは無関係)

講義予定

- 第1回(2014年5月14日)
 - 原理、各種データベース、生データ取得、遺伝子発現行列作成(データ正規化)
 - 教科書の1.2節、2.2節周辺
- 第2回(2014年5月21日)
 - クラスタリング(データ変換や距離の定義など)、実験デザイン、分布
 - 教科書の3.2節周辺
- 第3回(2014年5月28日)
 - 発現変動解析(多重比較問題)、各種プロット(M-A plotや平均-分散プロット)
 - 教科書の3.2節と4.2節周辺
- 第4回(2014年6月4日)
 - 機能解析(Gene Ontology解析やパスウェイ解析)、分類など

授業の目標・概要

細胞中で発現している全転写物(トランスクリプトーム)の解析技術は、マイクロアレイから次世代シーケンサ(RNA-seq)に移行しつつあります。RNA-seqデータ解析の多くは、マイクロアレイの知識を前提としています。また、ニュートリゲノミクス(食品系)分野では、マイクロアレイは現在でも主流派です。マイクロアレイデータを主な例として、各種トランスクリプトーム解析手法について解説します。



Contents (第1回)

- イン트로ダクション
 - マイクロアレイの原理や特徴(長所・短所)
 - データ解析例とバイオインフォマティクス要素技術
 - 発現データベース(DB)
 - Affymetrix GeneChipの用語: CELファイル、プローブセット、summarization...
- 発現DBからのプローブレベルデータ取得
 - GEOウェブサイト経由
 - R経由(教科書の § 2.2.1)
- 前処理法の適用(プローブレベルデータ → 発現行列データ)
 - MAS法、RMA法、RMX法(RobLoxBioC)、IRON法(教科書の § 2.2.2~2.2.4)
 - データの正規化(グローバル正規化、quantile正規化)

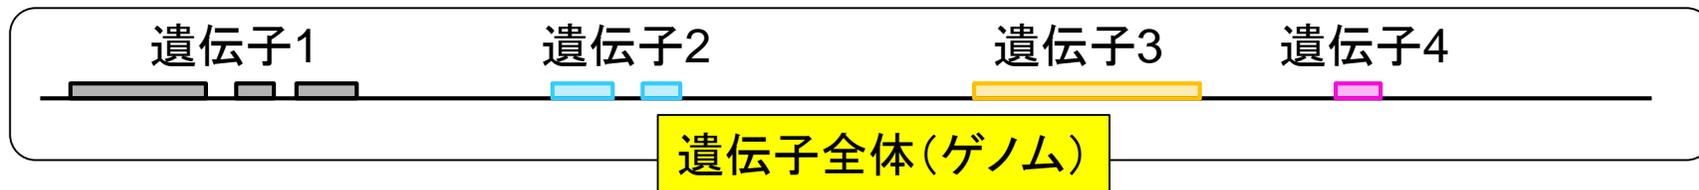
トランスクリプトームとは

- ある特定の状態の組織や細胞中に存在する全RNA(転写物、transcripts)の総体
- 様々なトランスクリプトーム解析技術
 - マイクロアレイ
 - cDNAマイクロアレイ、Affymetrix GeneChip、タイリングアレイなど
 - 配列決定に基づく方法
 - EST、SAGE、CAGE、次世代シーケンサ(RNA-seq)など
 - (電気泳動に基づく方法)
 - Differential Display、AFLP、HiCEPなど

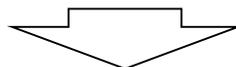
調べたい組織でどの遺伝子がどの程度発現しているのかを一度に観察

トランスクリプトームとは

- ある状態のあるサンプル(例:目)のあるゲノムの領域



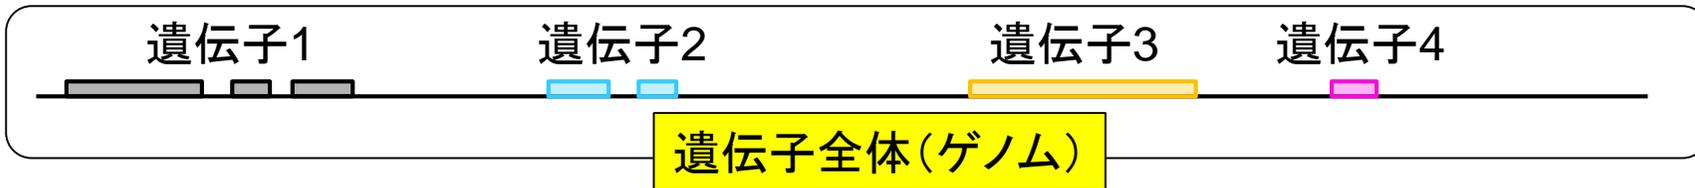
- ・どの染色体上のどの領域にどの遺伝子があるかは調べる個体(例:ヒト)が同じなら不変(目だろうが心臓だろうが...)



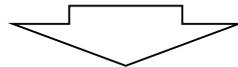
- ・遺伝子1は沢山転写されている(発現している)
- ・遺伝子4はごくわずかしか転写されていない
- ・...

トランスクリプトームとは

- ある状態のあるサンプル(例:目)のあるゲノムの領域



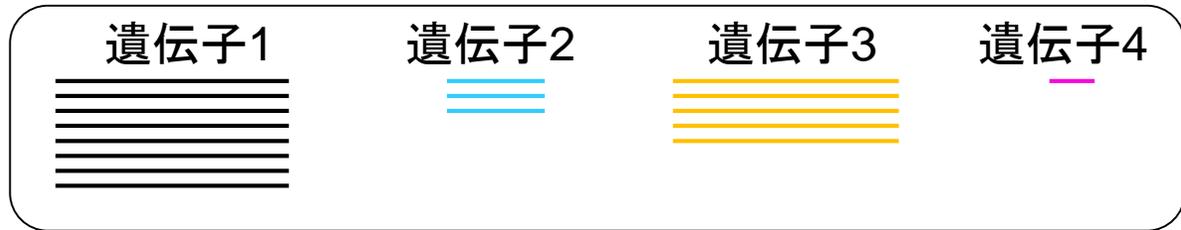
- ・どの染色体上のどの領域にどの遺伝子があるかは調べる個体(例:ヒト)が同じなら不変(目だろうが心臓だろうが...)



- ・遺伝子2は光刺激に反応して発現亢進
- ・遺伝子4も光刺激に反応して発現亢進

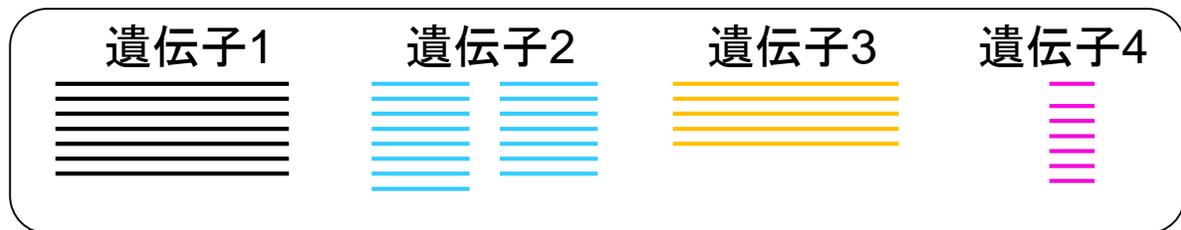
トランスクリプトーム情報を得る手段

■ 光刺激前 (T1) の目のトランスクリプトーム



これがいわゆる
「遺伝子発現行列」

■ 光刺激後 (T2) の目のトランスクリプトーム

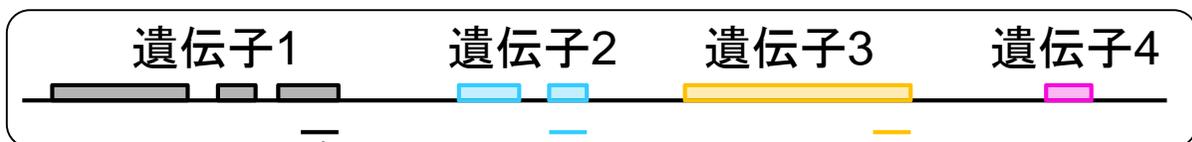


	T1	T2
遺伝子1	8	7
遺伝子2	3	15
遺伝子3	5	5
遺伝子4	1	7
...

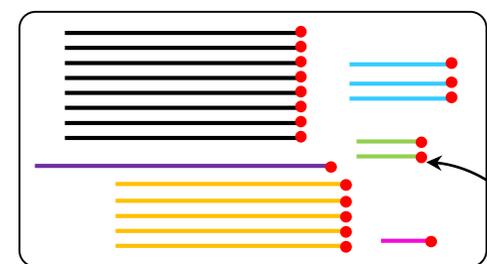
・マイクロアレイ
・RNA-seq

トランスクリプトーム取得(マイクロアレイ)

- よく研究されている生き物は多数の遺伝子(の配列情報)がわかっている



光刺激前(T1)の目のトランスクリプトーム



蛍光標識

ハイブリダイゼーション(二本鎖形成)

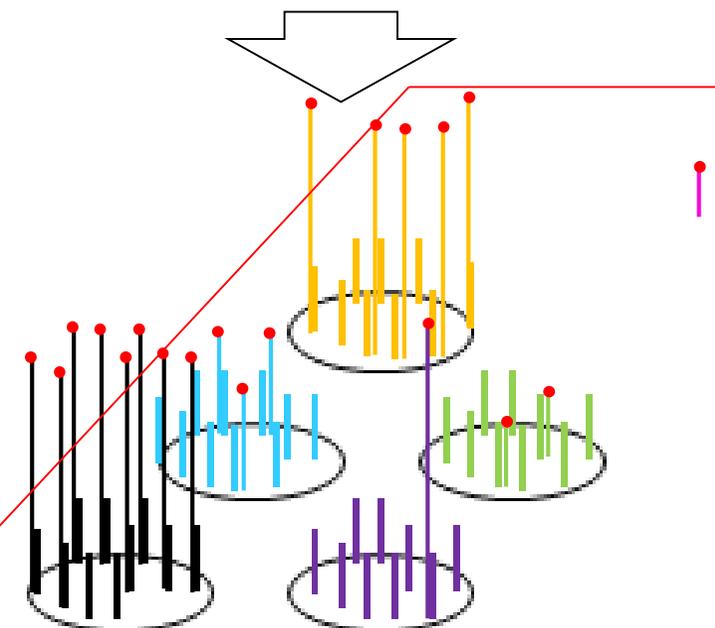
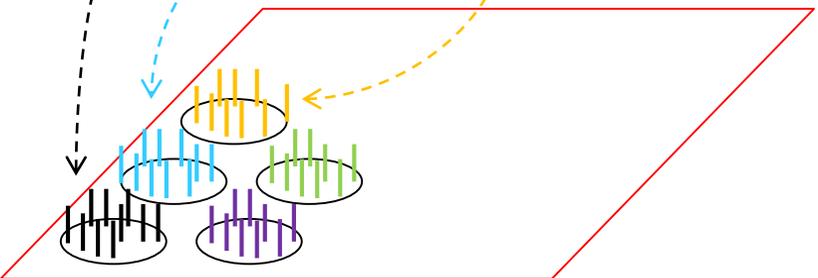


Image courtesy of Affymetrix

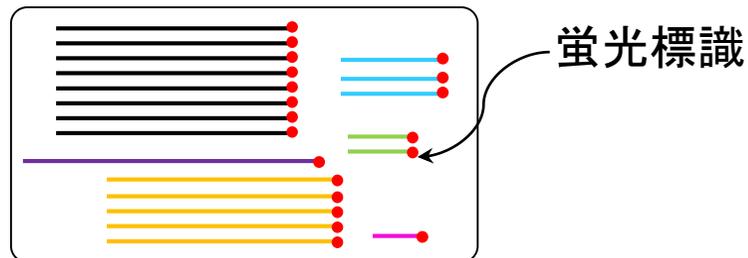


わかっている遺伝子(の配列の相補鎖)を搭載した”チップ”

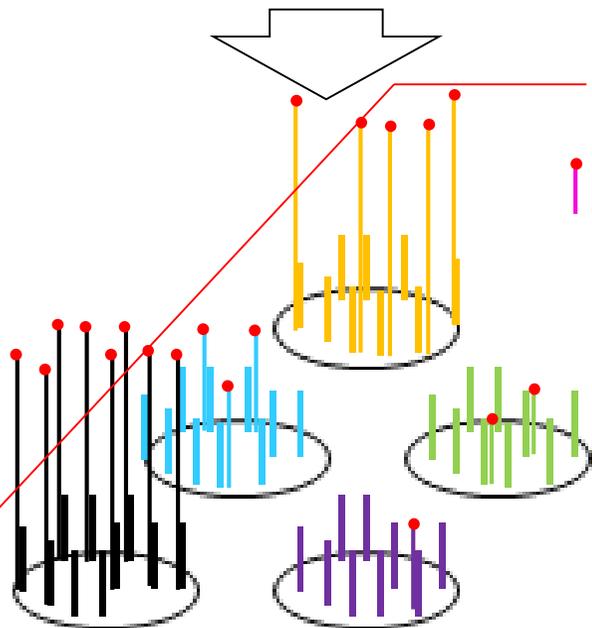
- ・メーカーによって搭載されている遺伝子の種類が異なる
- 搭載されていない遺伝子(未知遺伝子含む、例: **遺伝子4**)の発現情報は測定不可...

マイクロアレイデータ → 遺伝子発現行列

■ 光刺激前 (T1) の目のトランスクリプトーム

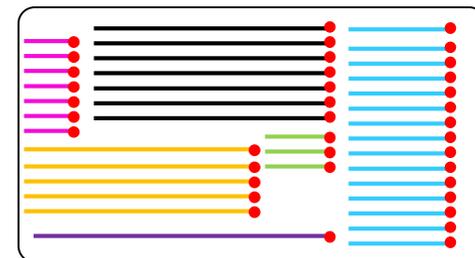


ハイブリダイゼーション
(二本鎖形成)



専用の検出器で各
遺伝子に対応する
領域の蛍光信号
強度を測定

光刺激後 (T2) の目の
トランスクリプトーム



ハイブリダイゼーション
と
シグナル検出

	T1	T2
遺伝子1	8	7
遺伝子2	3	15
遺伝子3	5	5
遺伝子4	?	?
遺伝子5
...

正規化

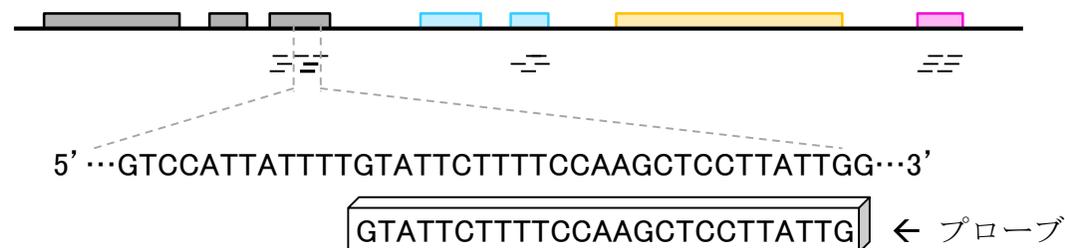
ステレオタイプなイメージ

■ マイクロアレイの長所

- 取り扱いやすいデータ量 (~100Mb程度)
- 長年の実績: 解析手法がほぼ確立。(Windows Rのみで解析可能)
- 検査用チップが利用可能 (MammaPrintなど)

■ マイクロアレイの短所

- 解析可能範囲が搭載転写物に限定
- プローブが3'末端に偏っている (3'発現解析用アレイ)
- ダイナミックレンジが狭い



マイクロアレイの実用例

- MammaPrint: 乳癌予後予測検査サービス(2008年)
 - 乳癌手術を受けた患者の転移・再発の可能性に関する情報提供
 - 70遺伝子の活性を測定
 - 不必要な補助化学療法などを避けることが可能(ローリスク群)
- 安全に登山をするための新たなバイオマーカー、heme oxygenase-1 (HO-1)の発見
 - **背景**: エベレスト頂上は酸素濃度が薄く、通常は10秒程度で意識を失うらしい。三浦雄一郎氏(登山家)がなぜ酸素ボンベなしでエベレスト頂上で数十秒もコメントできるのか?
 - **実験**: 低酸素室滞在前後の白血球の遺伝子発現変化をマイクロアレイで調査した結果、エベレスト登頂経験者はHO-1が低酸素刺激で特異的に変化(発現上昇)
 - **結論**: HO-1は、生体が低酸素に曝されたときに血管を拡張したり、低酸素による酸化ストレス傷害に対して抗酸化作用を示したりする。エベレスト登頂経験者はHO-1濃度を高めて高度への順化を行うために、低酸素時にも血管が拡張しやすく末梢循環が保たれているのだろう。

ただし、HO-1が搭載されていないマイクロアレイでは測定不可能!



2013/10/17 [プレスリリース] 世界初、マイクロアレイ関連技術の国際標準化を達成

世界初、マイクロアレイ関連技術の国際標準化を達成 ～ ISO最終国際規格案、各国投票で承認 ～

このたび、特定非営利活動法人バイオチップコンソーシアム(以下JMAC)は、当コンソーシアムが中心となって、提案・手続きを進めてまいりましたマイクロアレイに関わる世界初の規格案が、国際標準として承認されましたことをお知らせいたします。

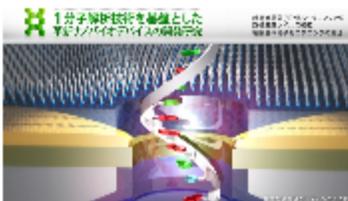
記

マイクロアレイとは、遺伝子検査に主に用いられるバイオチップ^{*1}の一種で、基板上に一群のDNAプローブ(特定の遺伝子を検出するためのDNA断片)を高密度で付着させて配置し、直接あるいは間接的に、大量の生物由来物質を高スループットで分析するものです。例えばヒトの全遺伝子のような、多種類の合成DNAを基板上に配置して、遺伝子の活動を示す発現量を測定するマイクロアレイが研究分野で使われています。2000年にヒトゲノムの配列が解明されてから、ヒトの遺伝子配列が理論的には全て得られるため、これまではバイオの研究現場で、全遺伝子の活動を調べる用途などに使われて来ました。

近年マイクロアレイは、食品分野をはじめ、環境や医療などの分野における遺伝子検査に利用される動きが活発になり、これまでの研究用途から産業用途へと、市場がシフトしてきました。これはマイクロアレイに関する技術が成熟度を増し、分析精度や再現性が大幅に向上したことが原因と考えられます。しかし、産業利用のためには、開発各社で解決できない問題もありました。その1つが、測定精度の管理です。研究に用いるのであれば、1つの解析対象に対し、複数のチップを用いて結果を取得した後で統計解析を行うことも可能です。しかし産業利用のためには、主にコストの面から、1度の解析により期待される精度で結果を得る必要があります。このような背景から、まずマイクロアレイの測定精度に関わる用語の定義を統一し、それに加えて精度保証のための手段を提供するような標準が必要となっていました。

最先端研究開発支援プログラム

(FIRSTプログラム)



サイト内検索

検索
検索...

ログインフォーム

ユーザ名

パスワード

自動ログイン

主に産業界の活動

- ※ [パスワードを忘れましたか?](#)
- ※ [ユーザ名を忘れましたか?](#)

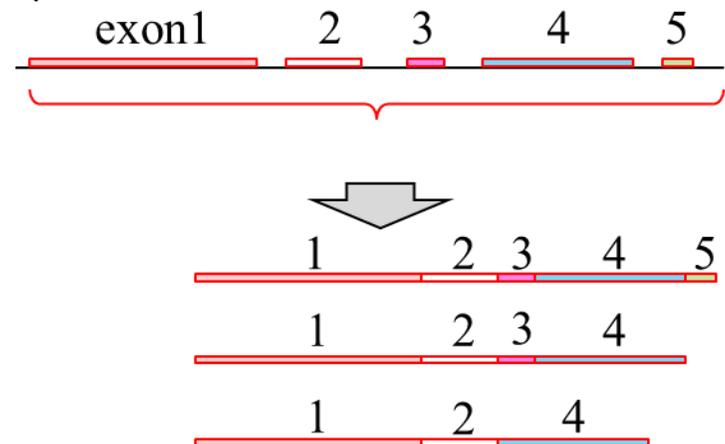
ステレオタイプなイメージ

■ RNA-seqの短所

- 取り扱いづらいデータ量(数百Gb?!)
- Windows userは自力解析が困難(ほとんどがLinux用)
- ダイナミックレンジが広いがために?!**変**な結果に遭遇。
- ゼロカウントデータの取り扱い

■ RNA-seqの長所

- (多少のoff-targetは含むが)全発現転写物の解析が可能
- 解像度: 遺伝子レベル → 転写物レベル
- ダイナミックレンジが広い



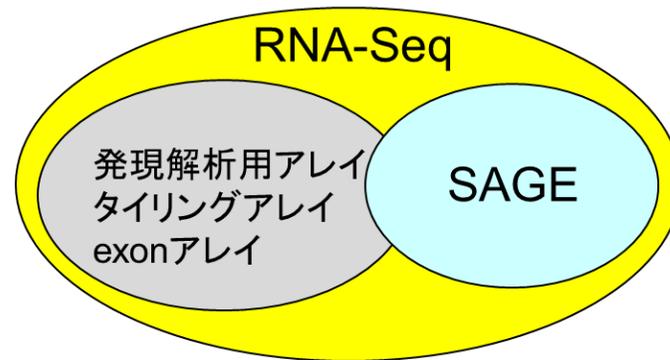
マイクロアレイ

- 機能(遺伝子セット)解析が主目的の場合にはまだ主役
 - Gene Ontology解析やパスウェイ解析
 - 実績のある市販アレイに搭載されている遺伝子のみでも「この栄養素はこのパスウェイに効いている」的な新規知見が得られればよい、という思想
 - 「個別の遺伝子の変動解析」というよりは「遺伝子セットの変動解析」
 - 同一アレイを用いている限り全体的な情報量が豊富
 - 公共データベース(GEO, ArrayExpressなど)
 - 3'発現解析用アレイが未だに使われる所以
 - 異なるアレイであっても同一生物種であればマージ可能
 - virtualArray (Heider and Alt, *BMC Bioinformatics*, 14:75, 2013)など

意義

■ 全体的にはマイクロアレイ → RNA-seq

- 転写物全体の配列情報を取得可能 (RefSeqのようなmulti-fasta形式のファイルをゲットできるイメージ)
- 選択的スプライシングの全体像の理解
- 発現変動exonや転写物の同定



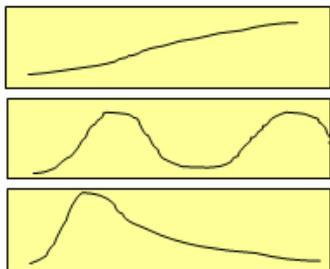
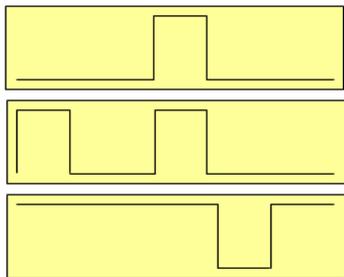
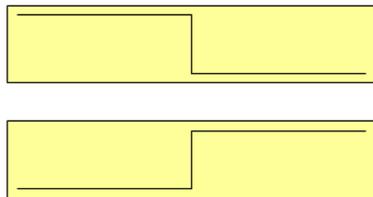
- ・データ解析の基本的な考え方はマイクロアレイと同じ
- ・食品系の研究 (Nutrigenomics) はアレイが未だ主流



発行日：2013年9月30日

データ解析もいろいろ

発現変動遺伝子同定



遺伝子発現行列

二群間比較用

	A群		B群	
	A1	A2	B1	B2
gene 1	$x_{1,1}^A$	$x_{1,2}^A$	$x_{1,1}^B$	$x_{1,2}^B$
gene 2	$x_{2,1}^A$	$x_{2,2}^A$	$x_{2,1}^B$	$x_{2,2}^B$
...
gene i	$x_{i,1}^A$	$x_{i,2}^A$	$x_{i,1}^B$	$x_{i,2}^B$
...
gene n	$x_{n,1}^A$	$x_{n,2}^A$	$x_{n,1}^B$	$x_{n,2}^B$

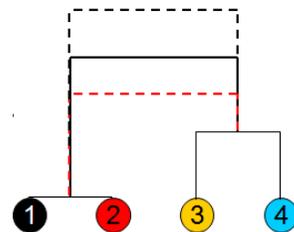
様々な組織(条件)

	S1	S2	S3	S4	...
gene 1	$x_{1,1}$	$x_{1,2}$	$x_{1,3}$	$x_{1,4}$...
gene 2	$x_{2,1}$	$x_{2,2}$	$x_{2,3}$	$x_{2,4}$...
...
gene i	$x_{i,1}$	$x_{i,2}$	$x_{i,3}$	$x_{i,4}$...
...
gene n	$x_{n,1}$	$x_{n,2}$	$x_{n,3}$	$x_{n,4}$...

時系列データ

	T1	T2	T3	T4	...
gene 1	$x_{1,1}$	$x_{1,2}$	$x_{1,3}$	$x_{1,4}$...
gene 2	$x_{2,1}$	$x_{2,2}$	$x_{2,3}$	$x_{2,4}$...
...
gene i	$x_{i,1}$	$x_{i,2}$	$x_{i,3}$	$x_{i,4}$...
...
gene n	$x_{n,1}$	$x_{n,2}$	$x_{n,3}$	$x_{n,4}$...

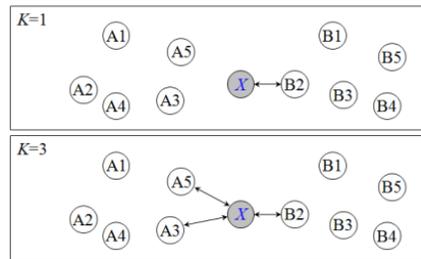
クラスタリング



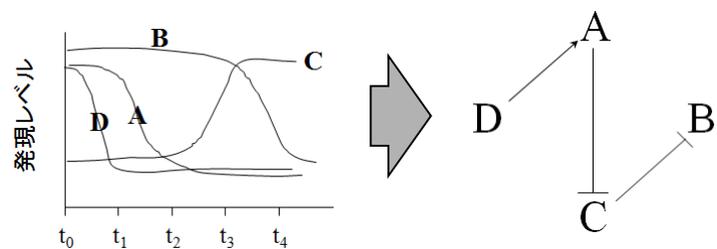
機能解析

- Gene Ontology (GO)
- パスウェイ解析

分類(診断)

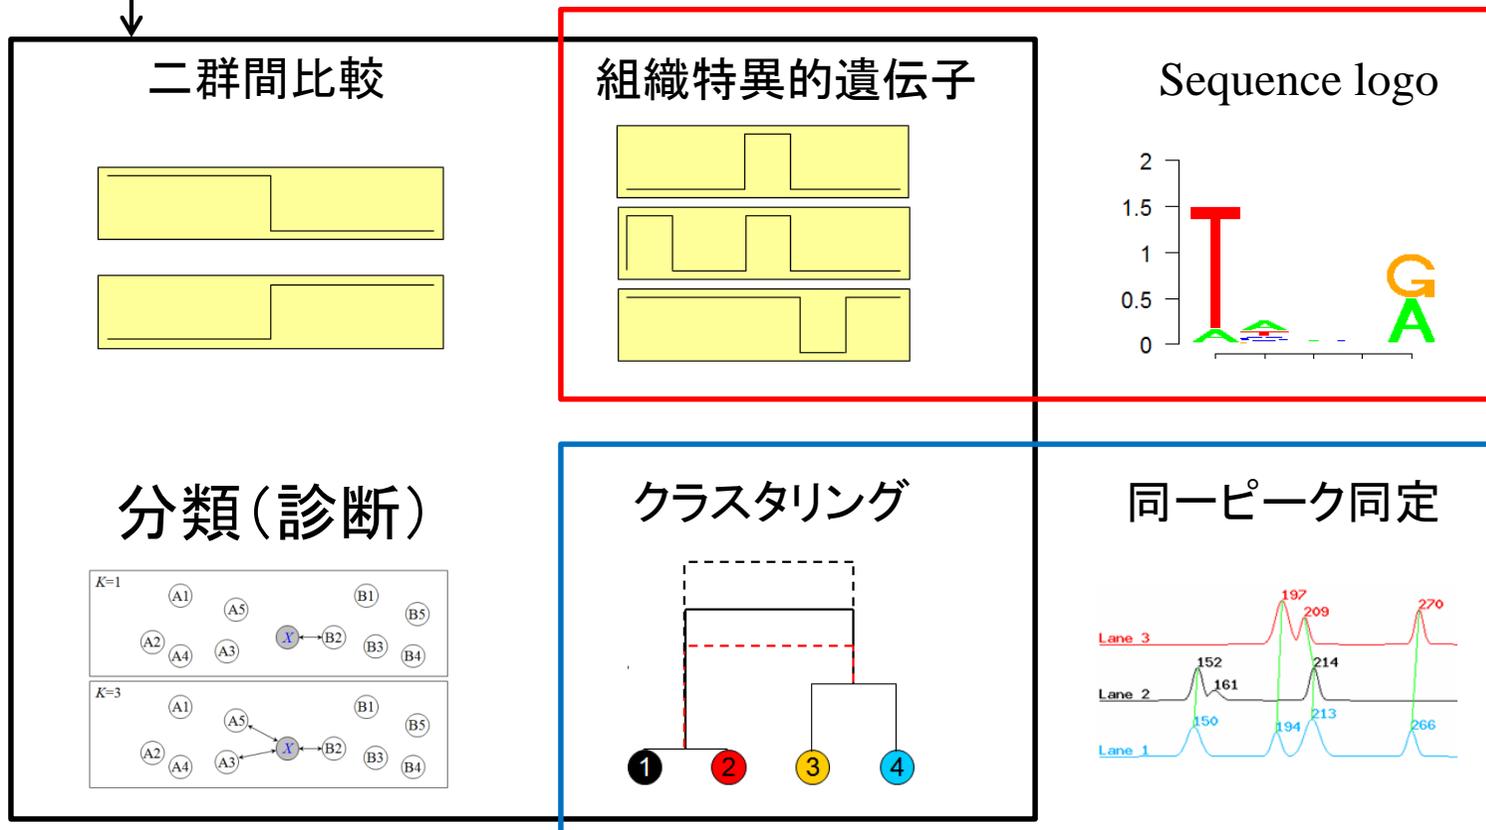


遺伝子ネットワーク推定



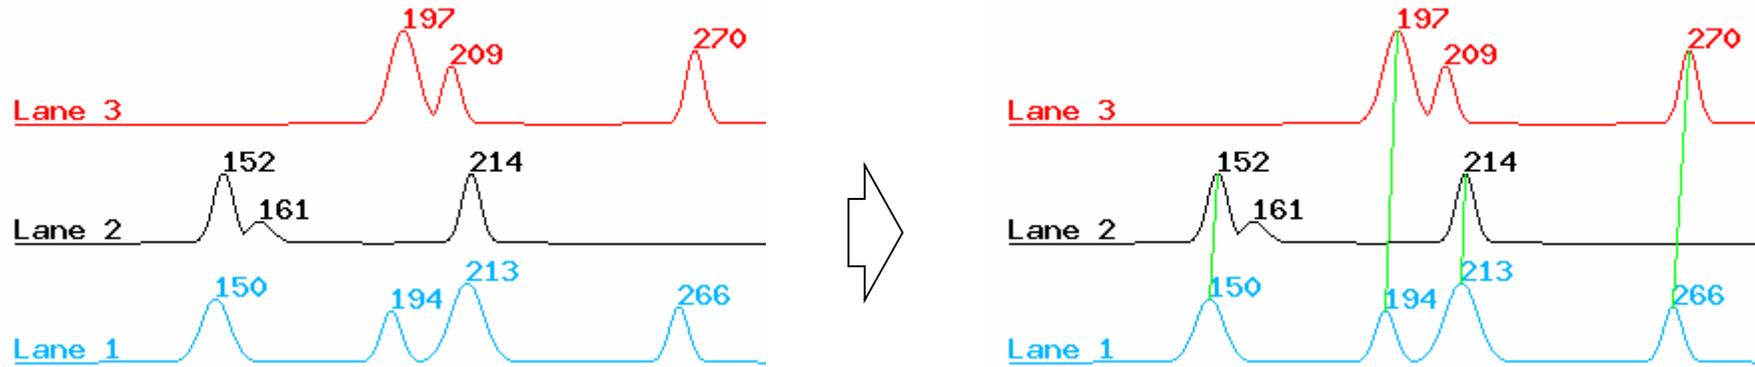
バイオインフォマティクス要素技術

■ 相関係数や**エントロピー**などの応用例を紹介



基本スキルのみでいろいろなことができます

クラスタリングの考えを同一ピーク認識に応用



②ピーク間
距離を計算

②'クラスター間距離が
最短のものをマージ

Lane	M. W.
1	150
1	194
1	213
1	266
2	152
2	161
2	214
3	197
3	209
3	270

①分子量
でソート

Lane	M. W.	
1	150	↔ 2
2	152	↔ 9
2	161	↔ 33
1	194	↔ 3
3	197	↔ 12
3	209	↔ 4
1	213	↔ 1
2	214	↔ 52
1	266	↔ 4
3	270	

c.	TDF
1	0
2	0
3	0
4	0
5	0
6	0
7	0
8	0
9	0
10	0

Contents (第1回)

- イン트로ダクション
 - マイクロアレイの原理や特徴(長所・短所)
 - データ解析例とバイオインフォマティクス要素技術
 - 発現データベース(DB)
 - Affymetrix GeneChipの用語: CELファイル、プローブセット、summarization...
- 発現DBからのプローブレベルデータ取得
 - GEOウェブサイト経由
 - R経由(教科書の § 2.2.1)
- 前処理法の適用(プローブレベルデータ → 発現行列データ)
 - MAS法、RMA法、RMX法(RobLoxBioC)、IRON法(教科書の § 2.2.2~2.2.4)
 - データの正規化(グローバル正規化、quantile正規化)

発現データベース(DB)



東京大学大学院農学生命科学研究科

アグリバイオインフォマティクス教育研究ユニット

Agricultural Bioinformatics Research Unit

+ サイトマップ + English



受講生の方へ



研究者の方へ

- + ホーム
- + 本ユニットについて
- + メンバー
- + 教育プログラム
- + 研究フォーラム
- + イベント
- + お問い合わせ
- + リンク
- + モバイルサイト



ホーム > 教育プログラム > 各講義のページ > 9.機能ゲノム学



9.機能ゲノム学

授業の目標・概要

細胞中で発現している全転写物(トランスクリプトーム)の解析技術は、マイクロアレイから次世代シーケンサ(RNA-seq)に移行しつつあります。RNA-seqデータ解析の多くは、マイクロアレイの知識を前提としています。また、ニュートリゲノミクス(食品系)分野では、マイクロアレイは現在でも主流派で、△解析手法について解説し

担当教員

門田幸二 (東大・農・アグ)

お知らせ

講義では、Rの様々なパッケージを参考にして必要なパ

参考図書

受講者は以下の教科書を用
門田幸二 著(金明哲 編)、
2014年4月、ISBN:978-4-

参考図書

受講者は以下の教科書を用意してください。

門田幸二 著(金明哲 編)、「シリーズ Useful R ⑦ トランスクリプトーム解析」、共立出版、2014年4月。ISBN:978-4-320-12370-0

講義日程 (平成26年度)

1. 平成26年05月14日
(Rで)マイクロアレイデータ解析
2. 平成26年05月21日
3. 平成26年05月28日
4. 平成26年06月04日

(Rで)マイクロアレイデータ解析です



(Rで)マイクロアレイデータ解析

(last modified 2014/05/09, since 2005)

What's new?

- ・ 門田幸二 著 [シリーズ Useful R 第7巻トランスクリプトーム解析](#) 刊行(共立出版)。マイクロアレイ解析に関する最近の知見や、ROKU法 (Kadota et al., 2006)、WAD法 (Kadota et al., 2008)などについての解説も含んでいます。書籍中のマイクロアレイ解析部分のRコードについては、このページの「[書籍 | トランスクリプトーム解析 | ...](#)」に掲載してあります。(2014/04/27) **NEW**
- ・ お知らせは主に [\(Rで\)塩基配列解析](#) で行っておりますのでそちらをご覧ください。(2014/03/05)

- ・ [はじめに](#) (last modified 2014/01/21)
- ・ [過去のお知らせ](#) (last modified 2014/03/03)
- ・ [Rのインストールと起動](#) (last modified 2014/04/17) **NEW**
- ・ [Rの昔のバージョンのインストール](#) (last modified 2012/04/07)
- ・ [使用例\(初心者向け\)](#) (last modified 2011/09/15)
- ・ [サンプルデータ](#) (last modified 2013/11/25)
- ・ [書籍 | について](#) (last modified 2014/04/17) **NEW**

- ・ 書籍 | トランスクリプトーム解析 | [1.1 はじめに](#) (last modified 2014/05/09) **NEW**
- ・ 書籍 | トランスクリプトーム解析 | [1.2.1 原理\(Affymetrix 3'発現アレイ\)](#) (last modified 2014/05/09) **NEW**
- ・ 書籍 | トランスクリプトーム解析 | [1.2.2 最近の知見](#) (last modified 2014/05/09) **NEW**
- ・ 書籍 | トランスクリプトーム解析 | [2.2.1 生データ\(プローブレベルデータ\)取得](#) (last modified 2014/04/18) **NEW**
- ・ 書籍 | トランスクリプトーム解析 | [2.2.2 データの正規化\(基礎\)](#) (last modified 2014/04/17) **NEW**
- ・ 書籍 | トランスクリプトーム解析 | [2.2.3 データの正規化\(計算例\)](#) (last modified 2014/04/18) **NEW**
- ・ 書籍 | トランスクリプトーム解析 | [2.2.4 データの正規化\(その他\)](#) (last modified 2014/04/18) **NEW**
- ・ 書籍 | トランスクリプトーム解析 | [2.2.5 アノテーション情報](#) (last modified 2014/04/18) **NEW**
- ・ 書籍 | トランスクリプトーム解析 | [3.2.1 クラスタリング\(データ変換や距離の定義など\)](#) (last modified 2014/04/18) **NEW**
- ・ 書籍 | トランスクリプトーム解析 | [3.2.2 実験デザイン、データ分布、統計解析との関係](#) (last modified 2014/04/18) **NEW**
- ・ 書籍 | トランスクリプトーム解析 | [3.2.3 多重比較問題](#) (last modified 2014/04/19) **NEW**
- ・ 書籍 | トランスクリプトーム解析 | [3.2.4 各種プロット \(M-A plotや平均-分散プロットなど\)](#) (last modified 2014/04/19) **NEW**
- ・ 書籍 | トランスクリプトーム解析 | [4.2.1 2群間比較](#) (last modified 2014/04/19) **NEW**
- ・ 書籍 | トランスクリプトーム解析 | [4.2.2 他の実験デザイン\(paired, multi-factor, 3群間\)](#) (last modified 2014/04/19) **NEW**
- ・ 書籍 | トランスクリプトーム解析 | [4.2.3 多重比較\(特異的発現パターン\)](#) (last modified 2014/04/20) **NEW**

- ・ [イントロ | 発現データ取得 | 公共DBから](#) (last modified 2014/05/10) **NEW**
- ・ [イントロ | 発現データ取得 | inSilicoDb\(Taniguchi 2011\)](#) (last modified 2013/08/20)
- ・ [イントロ | 発現データ取得 | ArrayExpress\(Kauffmann 2009\)](#) (last modified 2013/08/29) 推奨
- ・ [イントロ | 発現データ取得 | GEOquery\(Davis 2007\)](#) (last modified 2013/08/20)



公共DBを眺めることを通じて、3'発現アレイといわれる所以を知ろう

発現DB

イントロ | 発現データ取得 | 公共DBから **NEW**

遺伝子発現(主にマイクロアレイ)データベースをリストアップします。

一次データベース

- [GEO: Barrett et al., Nucleic Acids Res., 2013](#)
 - [GSE7623](#)(ラット 24サンプル, 62MB): [Nakai et al., BBB, 2008](#)
 - [GSE30533](#)(ラット 10サンプル, 25MB): [Kamei et al., PLoS One, 2013](#)
 - [GSE2361](#)(ヒト 36サンプル, 130MB): [Ge et al., Genomics, 2005](#)
 - [GSE10246](#)(マウス 182サンプル, 1.1GB): [Lattin et al., Immunome Res., 2008](#)
 - [GSE1133](#)(ヒトとマウス 438サンプル, 1.7GB): [Su et al., Proc Natl Acad Sci U S A, 2004](#)
 - [GSE15998](#)(マウス 106サンプル, 4.0GB): [原著論文はなし?!エクソアレイ](#)
- [ArrayExpress: Rustici et al., Nucleic Acids Res., 2013](#)
 - [GSE7623](#)(ラット 24サンプル, 62MB): [Nakai et al., BBB, 2008](#)
 - [GSE30533](#)(ラット 10サンプル, 25MB): [Kamei et al., PLoS One, 2013](#)
 - [GSE2361](#)(ヒト 36サンプル, 130MB): [Ge et al., Genomics, 2005](#)
 - [GSE10246](#)(マウス 182サンプル, 1.1GB): [Lattin et al., Immunome Res., 2008](#)
 - [GSE1133](#)(リンク先なし): [Su et al., Proc Natl Acad Sci U S A, 2004](#)
 - [GSE15998](#)(マウス 106サンプル, 4.0GB): [原著論文はなし?!エクソアレイ](#)

二次データベース

- [inSilico Db: Coletta et al., Genome Biol., 2012](#)
- [BioGPS: Wu et al., Nucleic Acids Res., 2013](#)
- [Expression Atlas: Petryszak et al., Nucleic Acids Res., 2014](#)
- [CellFinder: Stachelscheid et al., Nucleic Acids Res., 2014](#)

[トップページへ](#)

多くのジャーナルが生データの公共DB(GEOまたはArrayExpress)への登録を義務付けている。

遺伝子発現(主にマイクロアレイ)データベースをリストアップします。

一次データベース

[GEO: Barrett et al., Nucleic Acids Res., 2013](#)

どれだけのデータが登録されているかを眺めるのはここ

二次データベース

NCBI Resources How To Sign in to NCBI

GEO Home Documentation Query & Browse Email GEO

Gene Expression Omnibus

GEO is a public functional genomics data repository supporting MIAME-compliant data submissions. Array- and sequence-based data are accepted. Tools are provided to help users query and download experiments and curated gene expression profiles.

Keyword or GEO Accession

Getting Started	Tools	Browse Content
Overview	Search for Studies at GEO DataSets	Repository Browser
FAQ	Search for Gene Expression at GEO Profiles	DataSets: 3413
About GEO DataSets	Search GEO Documentation	Series: 47340
About GEO Profiles	Analyze a Study with GEO2R	Platforms: 12912
About GEO2R Analysis	GEO BLAST	Samples: 1131572
How to Construct a Query	Programmatic Access	
How to Download Data	FTP Site	

イントロ | 発現データ取得 | 公共DBから NEW

遺伝子発現(主にマイクロアレイ)データベースをリストアップします。

一次データベース

- [GEO: Barcode](#)
- [GSE](#)

二次データベース

- [inSilico Db](#)
- [BioGPS: W](#)
- [Expression](#)
- [CellFinder](#)

どれだけのデータが登録されているかを眺めるのはここ

The screenshot shows the ArrayExpress website interface. At the top, there is a search bar with the text "Examples: E-MEXP-31, cancer, p53, Geuvadis" and a "Search" button. Below the search bar, there is a navigation menu with "Home", "Experiments", "Arrays", "Submit", "Help", "About ArrayExpress", "Feedback", and "Login". The main heading is "ArrayExpress - functional genomics data". Below this, there is a paragraph describing the database: "ArrayExpress is a database of functional genomics experiments that can be queried and the data downloaded. It includes gene expression data from microarray and high throughput sequencing studies. Data is collected to MIAME and MINSEQE standards. Experiments are submitted directly to ArrayExpress or are imported from the NCBI GEO database." To the right of this paragraph, there is a "Data Content" section with a bar chart icon and the text "Updated today at 06:00". Below this, there is a red-bordered box containing the following statistics: "49013 experiments", "1406218 assays", and "23.47 TB of archived data". At the bottom of the page, there is a "Latest News" section with a date "7 February 2014" and a title "High throughput sequencing (HTS) data sets in ArrayExpress".



49013 experiments
1406218 assays
23.47 TB of archived data

2つのDB間で用語の統一はなされていない...

発現DB

Gene Expression Omnibus

GEO is a public functional genomics data repository supporting MIAME-compliant data submissions. Array- and sequence-based data are accepted. Tools are provided to help users query and download experiments and curated gene expression profiles.

Keyword or GEO Accession

Getting Started	Tools	Browse Content								
Overview FAQ About GEO DataSets About GEO Profiles About GEO2R Analysis How to Construct a Query How to Download Data	Search for Studies at GEO DataSets GEO Profiles Analyze a Study with GEO2R GEO BLAST Programmatic Access FTP Site	Repository Browser <table border="1"> <tbody> <tr> <td>DataSets:</td> <td>3413</td> </tr> <tr> <td>Series: </td> <td>47340</td> </tr> <tr> <td>Platforms:</td> <td>12912</td> </tr> <tr> <td>Samples:</td> <td>1131572</td> </tr> </tbody> </table>	DataSets:	3413	Series:	47340	Platforms:	12912	Samples:	1131572
DataSets:	3413									
Series:	47340									
Platforms:	12912									
Samples:	1131572									

DataSets, Series, Platforms, Samplesの説明はここ

NCBI

NCBI > GEO > Info > GEO Overview

GEO Overview

- General overview
- Data organization
- Query and analysis

General overview

GEO is an international repository of high-throughput sequencing, and other data.

The three main goals of GEO are:

1. Provide a robust data (see Data organization)
2. Offer simple submission and retrieval of data
3. Provide user-friendly tools for data analysis

Please see the GEO DataSets and Gene Profiles pages for more information.

Data organization

GEO records are organized into three main categories:

- Platform
- Sample
- Series

Platform records are supplied by submitters

A Platform record is composed of a summary description of the array or sequencer and, for array-based Platforms, a data table defining the array template. Each Platform record is assigned a unique and stable GEO accession number (GPLxxx). A Platform may reference many Samples that have been submitted by multiple submitters.

Example Platform record >

Sample records are supplied by submitters

A Sample record describes the conditions under which an individual Sample was handled, the manipulations it underwent, and the abundance measurement of each element derived from it. Each Sample record is assigned a unique and stable GEO accession number (GSMxxx). A Sample entity must reference only one Platform and may be included in multiple Series.

Example Sample record >

Series records are supplied by submitters

A Series record links together a group of related Samples and provides a focal point and description of the whole study. Series records may also contain tables describing extracted data, summary conclusions, or analyses. Each Series record is assigned a unique and stable GEO accession number (GSExxx).

Example Series record >

Selected primary records undergo an upper-level of rendering into DataSet and gene Profile records:

DataSet records are assembled by GEO curators

As explained above, A GEO Series record is an original submitter-supplied record that summarizes an experiment. These data are reassembled by GEO staff into GEO Dataset records (GDSxxx).

A DataSet represents a curated collection of biologically and statistically comparable GEO Samples and forms the basis of GEO's

A Text description of the array or sequencer

B Text tab-delimited table of the array template

C Text description of the biological sample and protocols to which it was subjected

D Text tab-delimited table of processed hybridization result (may optionally include raw data columns)

E Original raw data file, or processed sequence data file

F Text description of the overall experiment

G Tar archive of original raw data files, or processed sequence data files

Browse Content

Repository Browser

DataSets: 3413

Series: 47340

Platforms: 12912

Samples: 1131572

Platformsは、大まかにはアレイの種類数。(今はシーケンサーも登録されている。例:GPL11154)

Platformの例

■ Affymetrix GeneChip

- Affymetrix Human Genome U133 Plus 2.0 Array: **GPL570**
 - 2003年11月リリース、54,675 probesets、94,000枚以上の利用実績
- Affymetrix Human Genome U133A Array: **GPL96**
 - 2002年3月リリース、22,283 probesets、34,000枚以上
- Affymetrix Mouse Genome 430 2.0 Array: **GPL1261**
 - 2004年5月リリース、45,101 probesets、38,000枚以上
- Affymetrix Rat Genome 230 2.0 Array: **GPL1355**
 - 2004年6月リリース、31,099 probesets、10,000枚以上

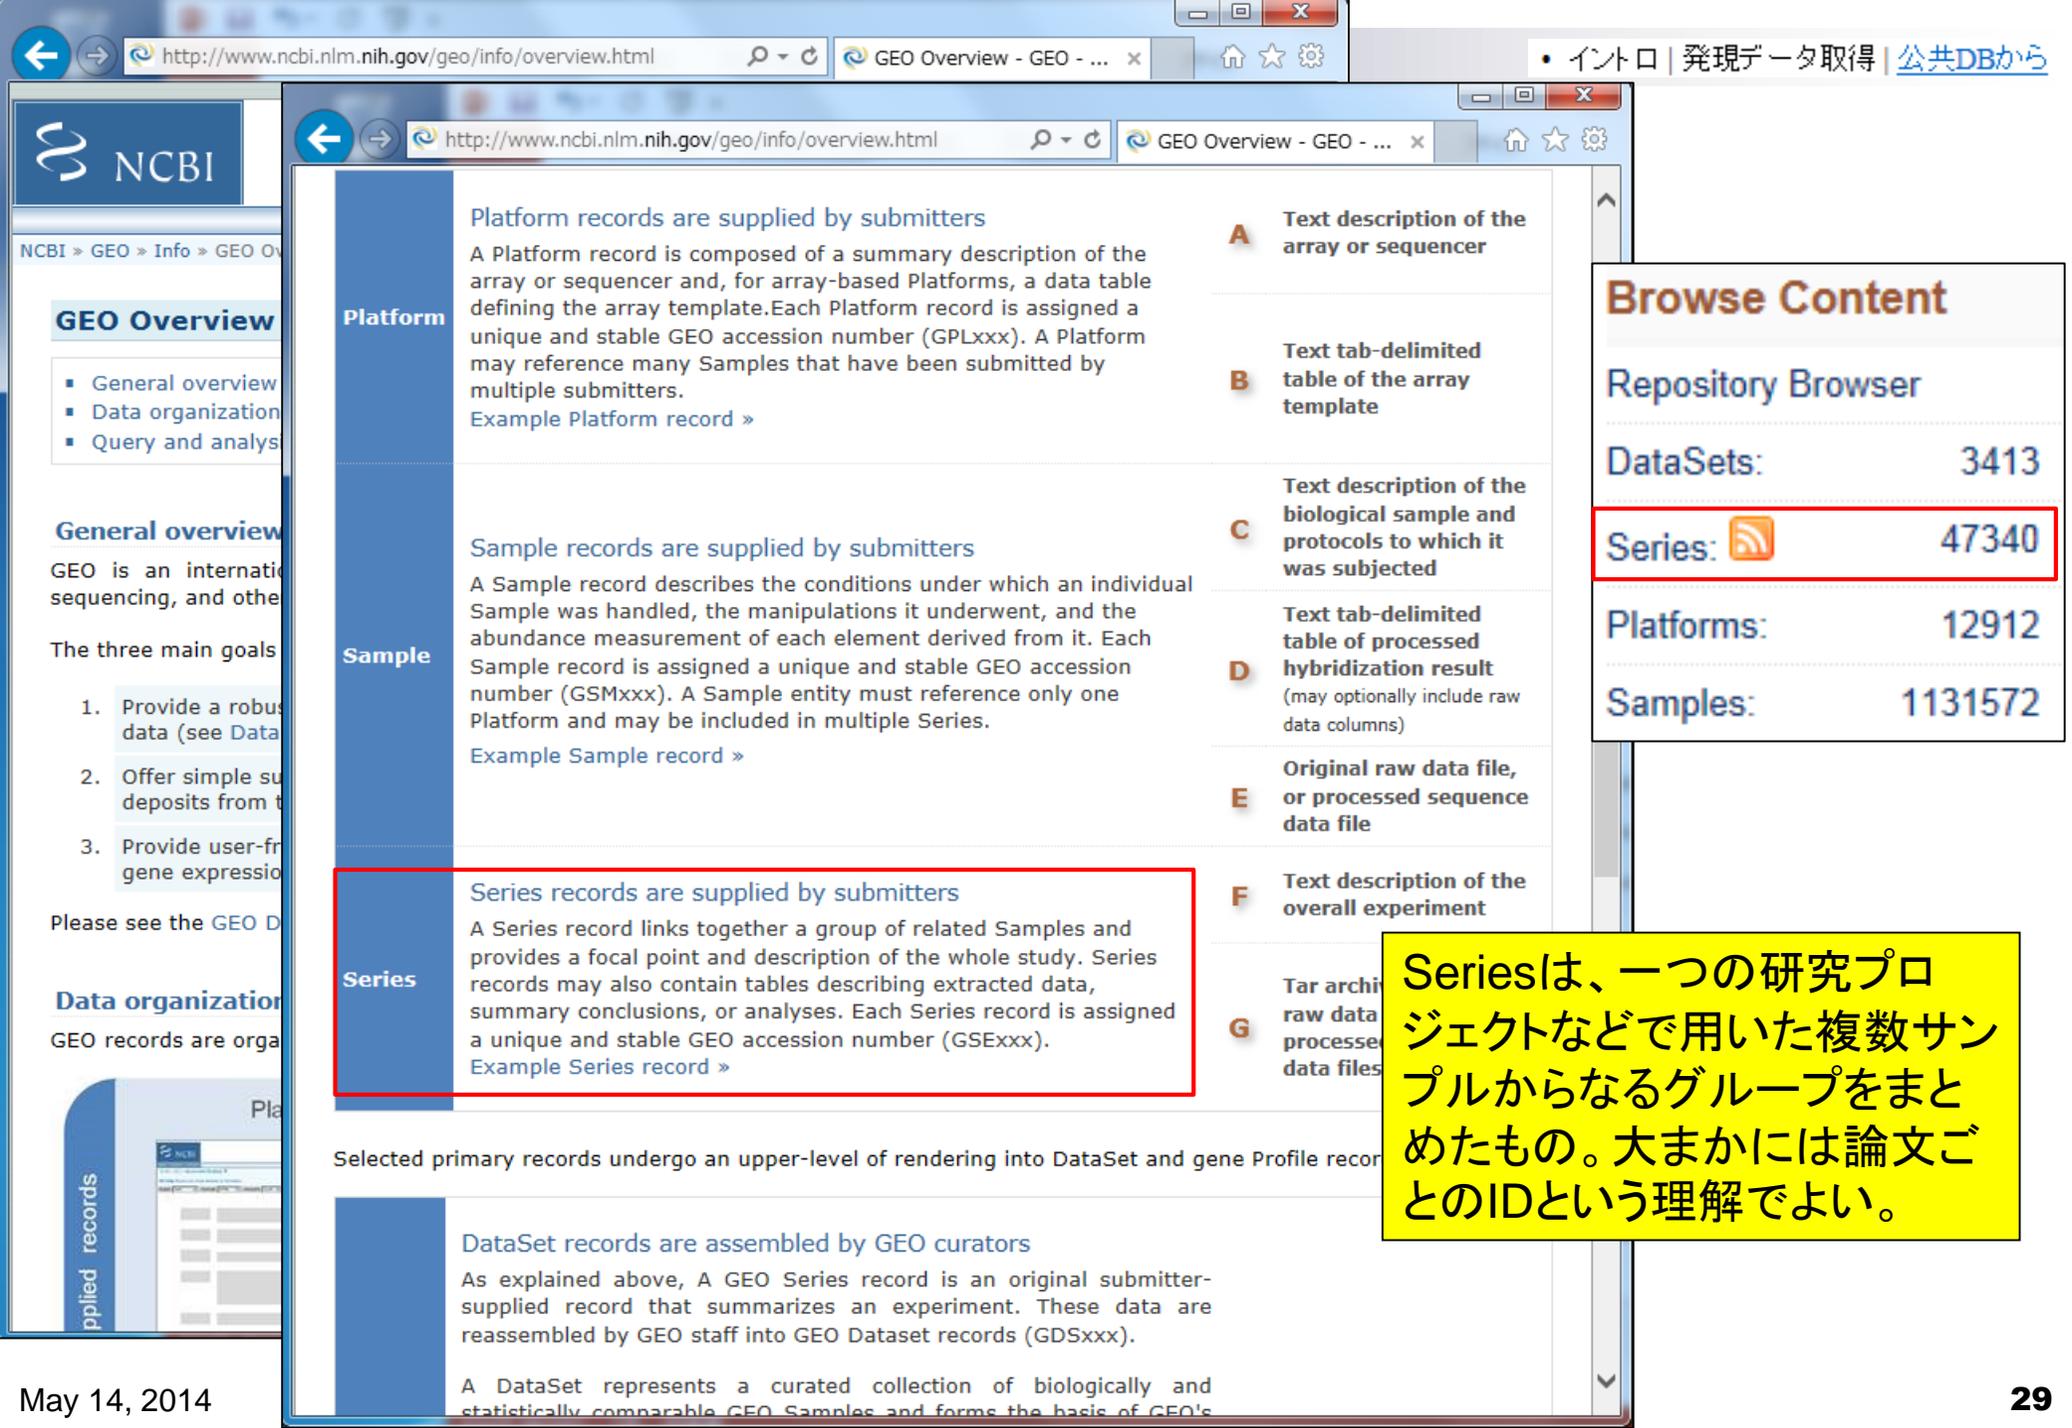
同じメーカー、同じ生物種でも様々なバージョンのアレイが存在する

■ Illumina BeadChip

- Illumina HumanHT-12 V4.0 expression beadchip: **GPL10558**
 - 2010年6月リリース、47,323 probes、18,000枚以上
- Illumina HumanHT-12 V3.0 expression beadchip: **GPL6947**
 - 2008年6月リリース、49,576 probes、18,000枚以上

■ Agilent Microarray

- Agilent-014850 Whole Human Genome Microarray 4x44K G4112F: **GPL6480**
 - 2008年2月リリース、41,108 probes、11,000枚以上



Platform

Platform records are supplied by submitters
A Platform record is composed of a summary description of the array or sequencer and, for array-based Platforms, a data table defining the array template. Each Platform record is assigned a unique and stable GEO accession number (GPLxxx). A Platform may reference many Samples that have been submitted by multiple submitters.
Example Platform record »

Sample

Sample records are supplied by submitters
A Sample record describes the conditions under which an individual Sample was handled, the manipulations it underwent, and the abundance measurement of each element derived from it. Each Sample record is assigned a unique and stable GEO accession number (GSMxxx). A Sample entity must reference only one Platform and may be included in multiple Series.
Example Sample record »

Series

Series records are supplied by submitters
A Series record links together a group of related Samples and provides a focal point and description of the whole study. Series records may also contain tables describing extracted data, summary conclusions, or analyses. Each Series record is assigned a unique and stable GEO accession number (GSExxx).
Example Series record »

- A Text description of the array or sequencer
- B Text tab-delimited table of the array template
- C Text description of the biological sample and protocols to which it was subjected
- D Text tab-delimited table of processed hybridization result (may optionally include raw data columns)
- E Original raw data file, or processed sequence data file
- F Text description of the overall experiment
- G Tar archive of raw data, processed data files

Browse Content

Repository Browser

DataSets: 3413

Series:  47340

Platforms: 12912

Samples: 1131572

Seriesは、一つの研究プロジェクトなどで用いた複数サンプルからなるグループをまとめたもの。大まかには論文ごとのIDという理解でよい。

Selected primary records undergo an upper-level of rendering into DataSet and gene Profile records

DataSet records are assembled by GEO curators

As explained above, A GEO Series record is an original submitter-supplied record that summarizes an experiment. These data are reassembled by GEO staff into GEO Dataset records (GDSxxx).

A DataSet represents a curated collection of biologically and statistically comparable GEO Samples and forms the basis of GEO's

Seriesの例

■ Affymetrix GeneChip

- Ge et al., *Genomics*, 86: 127–141, 2005
 - GSE2361、ヒト36サンプル、GPL96を利用
- Nakai et al., *Biosci Biotechnol Biochem.*, 72: 139–148, 2008
 - GSE7623、ラット24サンプル、GPL1355を利用
- Kamei et al., *PLoS One*, 8: e65732, 2013
 - GSE30533、ラット10サンプル、GPL1355を利用

■ Illumina BeadChip

- Sharma et al., *Cancer Cell*, 23: 35–47, 2013
 - GSE28680、ヒト24サンプル、GPL10558を利用

■ NGSデータも…

- Neyret-Kahn et al., *Genome Res.*, 23: 1563–1579, 2013
 - GSE42213、ヒト26サンプル、GPL10999とGPL11154を利用
 - GSE42211、ヒト20サンプル、GPL10999とGPL11154を利用 (ChIP-seq)
 - GSE42212、ヒト6サンプル、GPL10999を利用 (RNA-seq)
- Huang et al., *Development*, 139: 2161–2169, 2012
 - GSE36469、シロイヌナズナ8サンプル、GPL13222を利用

・NGSデータも登録されている
 ・1論文1 GSE IDとは限らない
 ・1 GSE ID 1 GPL IDとは限らない



NCBI

NCBI > GEO > Info > GEO Overview

GEO Overview

- General overview
- Data organization
- Query and analysis

General overview

GEO is an international repository of high-throughput sequencing, and other data.

The three main goals of GEO are:

1. Provide a robust data (see Data organization)
2. Offer simple submission and retrieval of data
3. Provide user-friendly tools for data analysis

Please see the GEO DataSets and Series records.

Data organization

GEO records are organized into three main categories: Platform, Sample, and Series.

Platform

Platform records are supplied by submitters

A Platform record is composed of a summary description of the array or sequencer and, for array-based Platforms, a data table defining the array template. Each Platform record is assigned a unique and stable GEO accession number (GPLxxx). A Platform may reference many Samples that have been submitted by multiple submitters.

Example Platform record »

Sample

Sample records are supplied by submitters

A Sample record describes the conditions under which an individual Sample was handled, the manipulations it underwent, and the abundance measurement of each element derived from it. Each Sample record is assigned a unique and stable GEO accession number (GSMxxx). A Sample entity must reference only one Platform and may be included in multiple Series.

Example Sample record »

Series

Series records are supplied by submitters

A Series record links together a group of related Samples and provides a focal point and description of the whole study. Series records may also contain tables describing extracted data, summary conclusions, or analyses. Each Series record is assigned a unique and stable GEO accession number (GSExxx).

Example Series record »

- A** Text description of the array or sequencer
- B** Text tab-delimited table of the array template
- C** Text description of the biological sample and protocols to which it was subjected
- D** Text tab-delimited table of processed hybridization result (may optionally include raw data columns)
- E** Original raw data file, or processed sequence data file
- F** Text description of the overall experiment
- G** Tar archive of original raw data files, or processed sequence data files

Selected primary records undergo an upper-level of rendering into DataSet and gene Profile records:

DataSet records are assembled by GEO curators

As explained above, A GEO Series record is an original submitter-supplied record that summarizes an experiment. These data are reassembled by GEO staff into GEO Dataset records (GDSxxx).

A DataSet represents a curated collection of biologically and statistically comparable GEO Samples and forms the basis of GEO's

Browse Content

Repository Browser

DataSets:	3413
Series:	47340
Platforms:	12912
Samples:	1131572

Samplesは、登録されているサンプル数

Platformの例

■ Affymetrix GeneChip

□ Affymetrix Human Genome U133 Plus 2.0 Array: **GPL570**

■ 2003年11月リリース、54,675 probesets、**94,000枚以上の利用実績**

どうやって調べたのか?

□ Affymetrix Human Genome U133A Array: **GPL96**

■ 2002年3月リリース、22,282 probesets、24,000枚以上

□ Affymetrix Mouse Gene

■ 2004年5月リリース

□ Affymetrix Rat Gene

■ 2004年6月リリース

■ Illumina BeadChip

□ Illumina HumanHT-1

■ 2010年6月リリース

□ Illumina HumanHT-1

■ 2008年6月リリース

■ Agilent Microarray

□ Agilent-014850 Whole

■ 2008年2月リリース

Gene Expression Omnibus

GEO is a public functional genomics data repository supporting MIAME-compliant data submissions. Array- and sequence-based data are accepted. Tools are provided to help users query and download experiments and curated gene expression profiles.

Keyword or GEO Accession

Getting Started	Tools	Browse Content
Overview	Search for Studies at GEO DataSets	Repository Browser
FAQ	Search for Gene Expression at GEO Profiles	DataSets: 3413
About GEO DataSets	Search GEO Documentation	Series: 47340
About GEO Profiles	Analyze a Study with GEO2R	Platforms: 12912
About GEO2R Analysis	GEO BLAST	Samples: 1131572
How to Construct a Query	Programmatic Access	
How to Download Data	FTP Site	

Samplesのところを2回クリック(クリックごとに昇順と降順が繰り返される)

Accession	Title	Technology	Organism(s)	Data rows	Samples	Series	Contact	Release date
GPL17146	LC_MRA-1001_miRHuman_11.0_080411 Sanger_miRBase 10.1 (miRNA ID version)	in situ oligonucleotide	<i>Homo sapiens</i>	837	1	1	Wenxin Li	May 09, 2014
GPL18665	NimbleGen Triticum aestivum CGH 270K array [120227_Taest_SRS_CGH]	spotted oligonucleotide	<i>Triticum aestivum</i>	291,410	22	1	Tatiana Belova	May 09, 2014
GPL18671	NanoString nCounter GX Human Immunology v1	other	<i>Homo sapiens</i>	540			Gregory Gonye	May 09, 2014
GPL18672	Illumina HiSeq 2000 (M. musculus)	high-throughput sequencing	<i>M. musculus</i>				GEO	May 09, 2014
GPL18673	Illumina HiSeq 2000 (Phaseolus vulgaris)	high-throughput sequencing	<i>Phaseolus vulgaris</i>		4	2	GEO	May 09, 2014
GPL18674	Illumina HiSeq 2000 (Phaseolus coccineus)	high-throughput sequencing	<i>Phaseolus coccineus</i>		4	2	GEO	May 09, 2014
GPL11220	Zymomonas mobilis ZM4 6.7K (expr_HX4)	in situ oligonucleotide	<i>Zymomonas mobilis</i>	6,708	16	1	Shihui YANG	May 08, 2014
GPL18661	Ion Torrent Proton (Jatropha curcas)	high-throughput sequencing	<i>Jatropha curcas</i>				GEO	May 08, 2014
GPL18662	Illumina HiSeq 2000 (Locusta migratoria)	high-throughput sequencing	<i>Locusta migratoria</i>				GEO	May 08, 2014
GPL18663	Illumina HiSeq 2000 (Candida parapsilosis)	high-throughput sequencing	<i>Candida parapsilosis</i>				GEO	May 08, 2014
GPL18666	Agilent-049384 Aplysia Tellabs Array (Number version)	other	<i>Aplysia californica</i>				Robert J Calin-ageman	May 08, 2014
GPL18669	Illumina HiSeq 2000 (Papio cynocephalus)	high-throughput sequencing	<i>Papio cynocephalus</i>				GEO	May 08, 2014
GPL18653	Gallus gallus 14K A-MEXP-831	other	<i>Gallus gallus</i>				Anthony Jackson	May 07, 2014
GPL18654	Rat microRNA array	other	<i>Rattus norvegicus</i>				HAOQUN HUANG	May 07, 2014
GPL18660	Affymetrix AGRONOMICS Tiling Array	other	<i>Arabidopsis thaliana</i>				GEO admin	May 07, 2014
GPL12528	Agilent-049384 Aplysia Tellabs Array (Number version)	other	<i>Aplysia californica</i>				Biao Wei Mu	May 06, 2014

①Illumina社のNGS機器であるHiSeq 2000に対して一つのGPL IDが付与されているわけではなく、「NGS機器と適用した生物種」で一つのGPL IDが付与されているようだ。例えば、HiSeq 2000を用いてマウス(M. musculus)サンプルに適用したものはGPL18672が付与されている。②データはまだ存在しない。③理由はおそらくごく最近そのような方針にしたためであろう



Gene Expression Omnibus

GEO Publications | FAQ | MIAME | Email GEO

Login

NCBI » GEO » Repository browser » Platforms

Series | Samples | **Platforms** | DataSets

Summary | Advanced search | Find platform

Search

12,912 platforms

Export

Page 1 of 646 Page size 20

Accession	Title	Technology	Organism(s)	Data rows	Samples	Series	Contact	Release date
GPL570	[HG-U133_Plus_2] Affymetrix Human Genome U133 Plus 2.0 Array	in situ oligonucleotide	<i>Homo sapiens</i>	54,675	94089	3451	Affymetrix, Inc.	Nov 07, 2003
GPL1261	[Mouse430_2] Affymetrix Mouse Genome 430 2.0 Array	in situ oligonucleotide	<i>Mus musculus</i>	45,101	38555	2955	Affymetrix, Inc.	May 25, 2004
GPL96	[HG-U133A] Affymetrix Human Genome U133A Array	in situ oligonucleotide	<i>Homo sapiens</i>	22,283	34783	987	Affymetrix, Inc.	Mar 11, 2002
GPL10558	Illumina HumanHT-12 V4.0 expression beadchip	oligonucleotide beads	<i>Homo sapiens</i>	47,323	18387	609	Illumina Inc.	Jun 17, 2010
GPL6947	Illumina HumanHT-12 V3.0 expression beadchip	oligonucleotide beads	<i>Homo sapiens</i>	49,576	18312	388	Illumina Inc.	Jun 10, 2008
GPL6244	[HuGene-1_0-st] Affymetrix Human Gene 1.0 ST Array [transcript (gene) version]	in situ oligonucleotide	<i>Homo sapiens</i>	33,297	17742	878	Affymetrix, Inc.	Dec 05, 2007
GPL8490	Illumina HumanMethylation27 BeadChip (HumanMethylation27_270596_v.1.2)	oligonucleotide beads	<i>Homo sapiens</i>	27,578	14800	263	Illumina Inc.	Apr 27, 2009
GPL6246	[MoGene-1_0-st] Affymetrix Mouse Gene 1.0 ST Array [transcript (gene) version]	in situ oligonucleotide	<i>Mus musculus</i>	35,557	13817	1134	Affymetrix, Inc.	Dec 05, 2007
GPL13534	Illumina HumanMethylation450 BeadChip (HumanMethylation450_15017482)	oligonucleotide beads	<i>Homo sapiens</i>	485,577	12217	199	Illumina Inc.	May 13, 2011
GPL6801	[GenomeWideSNP_6] Affymetrix Genome-Wide Human SNP 6.0 Array	in situ oligonucleotide	<i>Homo sapiens</i>	1,880,794	12077	207	Affymetrix, Inc.	Apr 30, 2008
GPL6480	Agilent-014850 Whole Human Genome M G4112F (Probe Name version)				11621	509	Agilent Technologies	Feb 11, 2008
GPL571	[HG-U133A_2] Affymetrix Human Genome				11036	445	Affymetrix, Inc.	Nov 07, 2003
GPL198	[ATH1-121501] Affymetrix Arabidopsis A				10682	820	Affymetrix, Inc.	Jul 18, 2002
GPL1355	[Rat230_2] Affymetrix Rat Genome 230				10482	493	Affymetrix, Inc.	Jul 20, 2004
GPL4133	Agilent-014850 Whole Human Genome M G4112F (Feature Number version)				10183	528	Agilent Technologies	Aug 17, 2006
GPL3718	[Mapping250K_Nsp] Affymetrix Mapping Array				9823	156	Affymetrix, Inc.	May 13, 2006

(NGS機器も含まれるため、もはや正確な言い回しではないが...) 赤枠部分がアレイごとに用いられたサンプル数。トップ3はいずれもAffymetrix 3'発現アレイと呼ばれるもの。

様々なDNAマイクロアレイ(DNAチップ)

1. スポット型 (Stanford大学)

- 搭載DNA: cDNA (またはoligonucleotide)
- 解析法: 2色法 (比較したい2サンプルを同時に分析)

Stanford型

2. プリント型 (Agilent社)

- 搭載DNA: oligonucleotide (60mer)
- 解析法: 2色法または1色法

3. 合成オリゴ型 (Affymetrix社)

- 搭載DNA: oligonucleotide (25mer)
- 解析法: 1色法 (調べたい1サンプルを分析)

Affymetrix型



得られる遺伝子発現データのイメージ

■ 二色法の場合

	目的試料	対照試料		目的/対照	log(比)
遺伝子1	100	100	➡	1	0
遺伝子2	4000	1000		4	2
遺伝子3	7000	7000		1	0
遺伝子4	2000	8000		0.25	-2
...

■ 一色法の場合

	目的試料
遺伝子1	100
遺伝子2	4000
遺伝子3	7000
遺伝子4	2000
...	...

目的試料中の遺伝子2の発現レベルは対照試料に比べて4倍高い

目的試料中で遺伝子3は沢山発現している

Affymetrix型マイクロアレイ (GeneChip®)

- **目的試料**の発現情報を直接「シグナル強度」として得る

Affymetrix GeneChipデータ解析

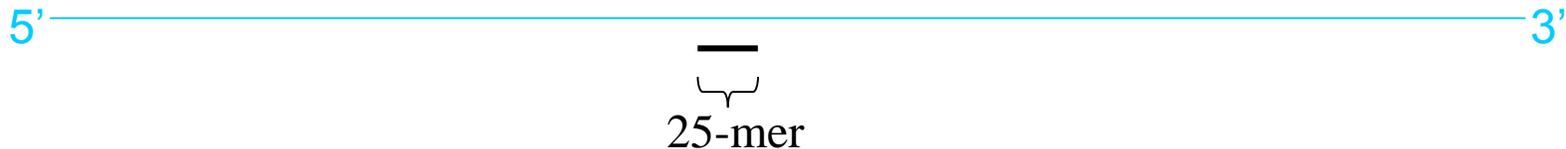
■ 25-mer程度では

□ 本当に目的遺伝子の発現を調べられているのか？！

ヒト→ 3Gbp(=3 × 10⁹ bp) < 4²⁵ (=1 × 10¹⁵ bp)

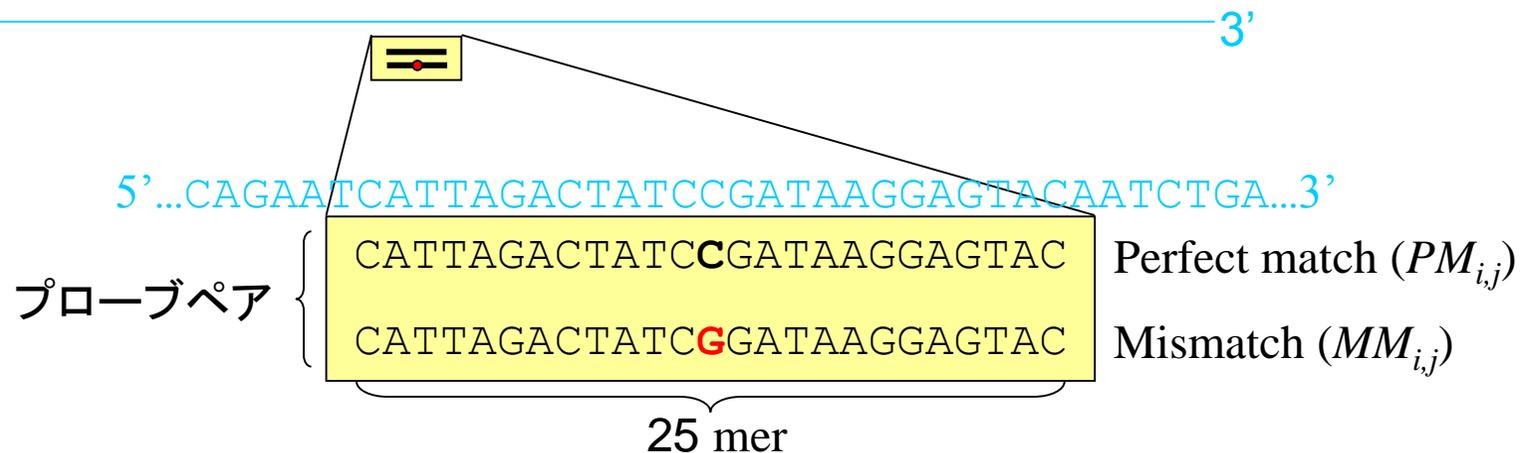
理論上は25merで充分…

□ 発現量を正確に定量できるのか？



Affymetrix GeneChipデータ解析

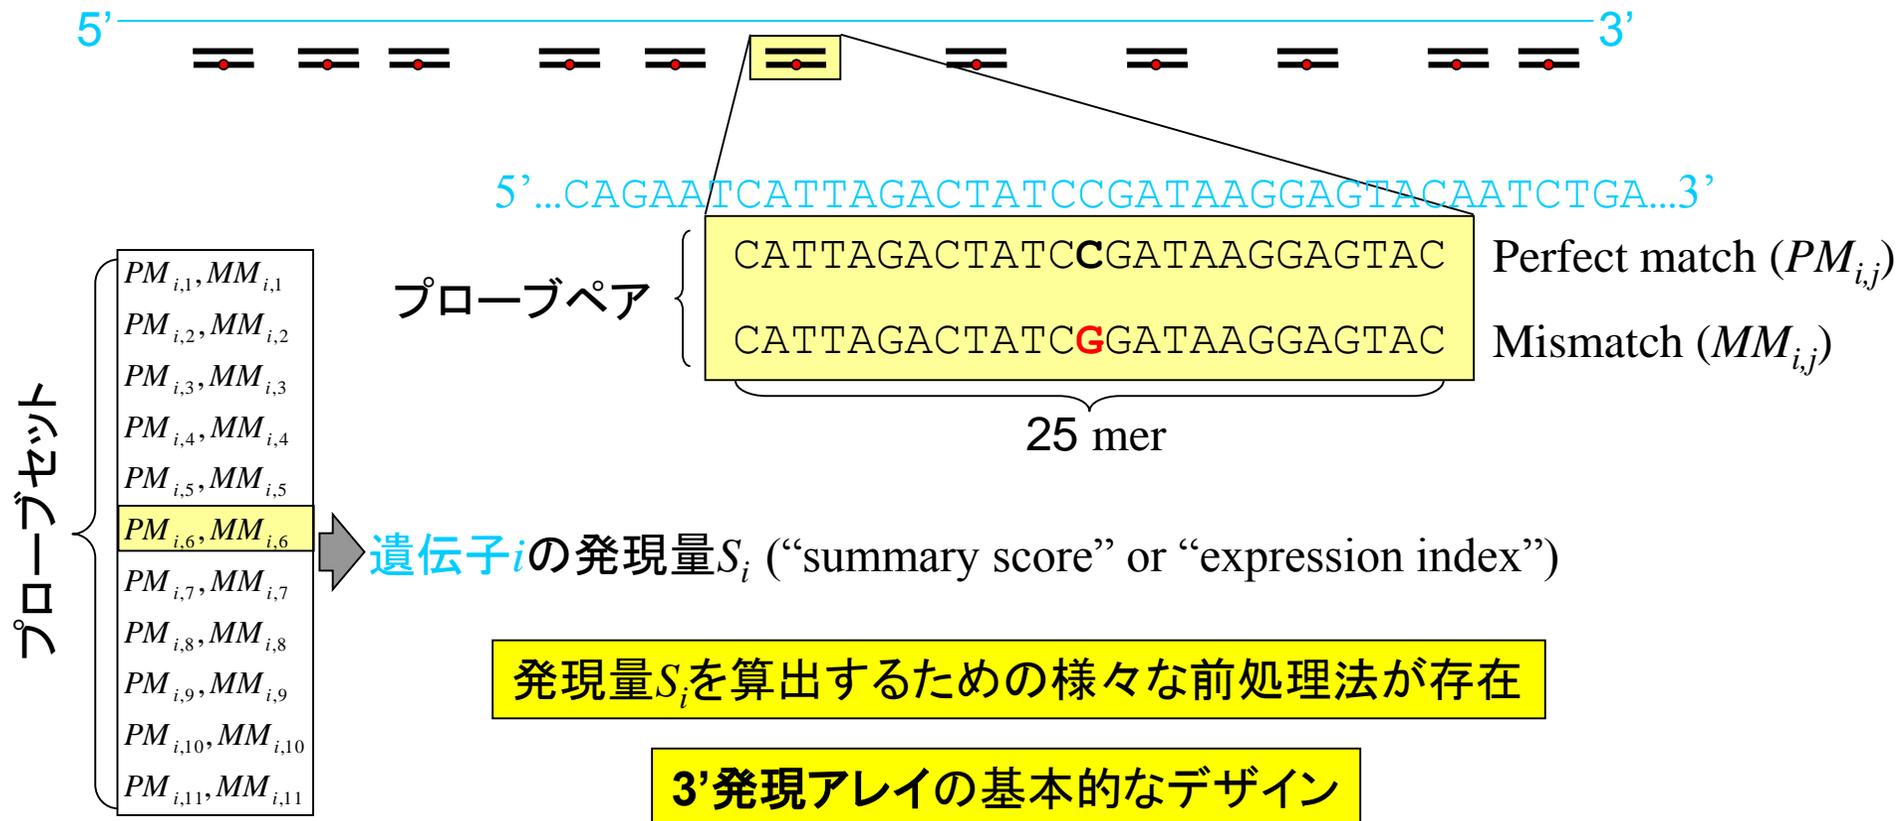
- 遺伝子 i の発現量 S_i を正確に知るために
 - PM/MMプローブ戦略(ユニークな配列選択と最適 T_m)



特異的なハイブリダイゼーションと非特異的なハイブリダイゼーションを区別すべく、目的遺伝子配列に対してPMと一塩基MMがペアになっているのが特徴的

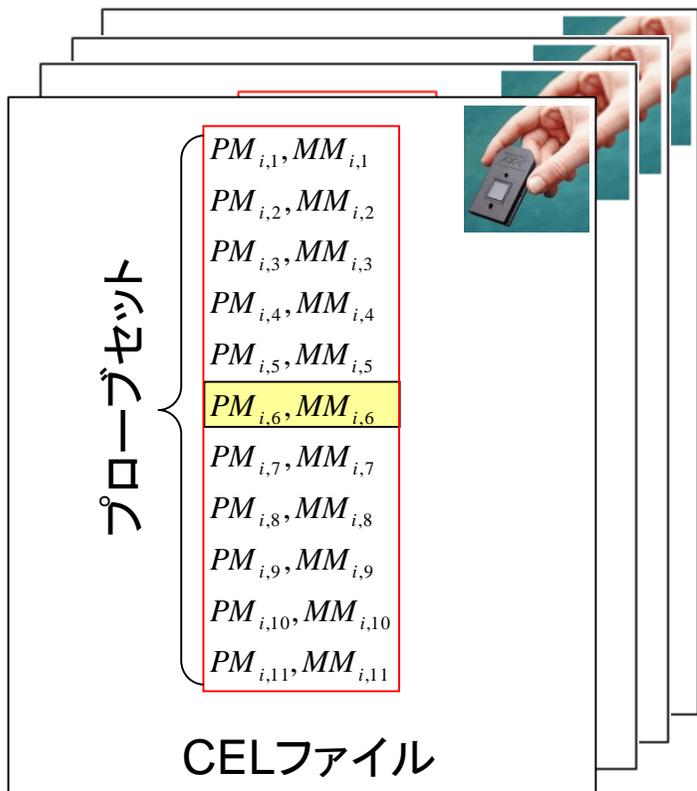
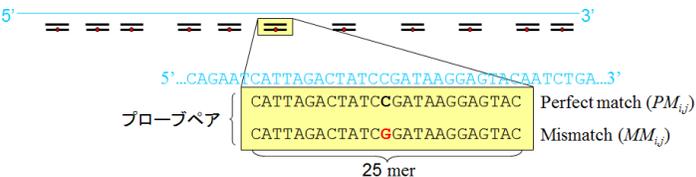
Affymetrix GeneChipデータ解析

- 遺伝子*i*の発現量 S_i を n_i ($n_i=11\sim 20$)種類のプローブペアのシグナル強度をもとに計算



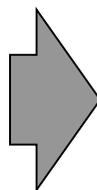
全体的なイメージ

— CELファイル —
チップ上に搭載されている全遺伝子のプローブのシグナル強度情報を含むファイル



CELファイル

前処理法



遺伝子発現行列

	S1	S2	S3	S4	...
gene 1	$x_{1,1}$	$x_{1,2}$	$x_{1,3}$	$x_{1,4}$...
gene 2	$x_{2,1}$	$x_{2,2}$	$x_{2,3}$	$x_{2,4}$...
...
gene i	$x_{i,1}$	$x_{i,2}$	$x_{i,3}$	$x_{i,4}$...
...
gene n	$x_{n,1}$	$x_{n,2}$

適用した前処理法の数だけ遺伝子発現行列が存在

	A	B	C	D
1		sample1	sample2	sample3
2	gene1	10.87	12.13	8.87
3	gene2	7.03	7.17	12.13
4	gene3	8.50	8.50	10.87
5	gene4	12.13	10.87	7.17
6	gene5	5.77	6.30	5.77
7	gene6	8.87	8.87	8.50
8	gene7	6.77	7.03	6.30
9	gene8	6.30	6.77	6.77
10	gene9	7.17	5.77	7.03
11	gene10	4.80	4.80	4.80

3'発現アレイの意味を確認

NCBI GEO Repository browser » Platforms

Search 12,912 platforms Export Page 1 of 646 Page size 20

Accession	Title	Technology	Organism(s)	Data rows	Samples	Series	Contact	Release date
GPL570	[HG-U133_Plus_2] Affymetrix Human Genome U133 Plus 2.0 Array	in situ oligonucleotide	<i>Homo sapiens</i>	54,675	94089	3451	Affymetrix, Inc.	Nov 07, 2003
GPL1261	[Mouse430_2] Affymetrix Mouse Genome 430 2.0 Array	in situ oligonucleotide	<i>Mus musculus</i>	45,101	38555	2955	Affymetrix, Inc.	May 25, 2004
GPL96	[HG-U133A] Affymetrix Human Genome U133A Array	in situ oligonucleotide	<i>Homo sapiens</i>	22,283	34783	987	Affymetrix, Inc.	Mar 11, 2002
GPL10558	Illumina HumanHT-12 V4.0 expression beadchip	oligonucleotide beads	<i>Homo sapiens</i>	47,323	18387	609	Illumina Inc.	Jun 17, 2010
GPL6947	Illumina HumanHT-12 V3.0 expression beadchip	oligonucleotide beads	<i>Homo sapiens</i>	49,576	18312	388	Illumina Inc.	Jun 10, 2008
GPL6244	[HuGene-1_0-st] Affymetrix Human Gene 1.0 ST Array [transcript (gene) version]	in situ oligonucleotide	<i>Homo sapiens</i>	33,297	17742	878	Affymetrix, Inc.	Dec 05, 2007
GPL8490	Illumina HumanMethylation27 BeadChip (HumanMethylation27_270596_v.1.2)	oligonucleotide beads	<i>Homo sapiens</i>	27,578	14800	263	Illumina Inc.	Apr 27, 2009
GPL6246	[MoGene-1_0-st] Affymetrix Mouse Gene 1.0 ST Array [transcript (gene) version]	in situ oligonucleotide	<i>Mus musculus</i>	35,557	13817	1134	Affymetrix, Inc.	Dec 05, 2007
GPL13534	Illumina HumanMethylation450 BeadChip (HumanMethylation450_15017482)	oligonucleotide beads	<i>Homo sapiens</i>					
GPL6801	[GenomeWideSNP_6] Affymetrix Genome-Wide Human SNP 6.0 Array	in situ oligonucleotide	<i>Homo sapiens</i>					
GPL6480	Agilent-014850 Whole Human Genome Microarray 4x44K G4112F (Probe Name version)	in situ oligonucleotide	<i>Homo sapiens</i>					
GPL571	[HG-U133A_2] Affymetrix Human Genome U133A 2.0 Array	in situ oligonucleotide	<i>Homo sapiens</i>					
GPL198	[ATH1-121501] Affymetrix Arabidopsis ATH1 Genome Array	in situ oligonucleotide	<i>Arabidopsis thaliana</i>	22,810	10682	820	Affymetrix, Inc.	Jul 18, 2002
GPL1355	[Rat230_2] Affymetrix Rat Genome 230 2.0 Array	in situ oligonucleotide	<i>Rattus norvegicus</i>	31,099	10482	493	Affymetrix, Inc.	Jul 20, 2004
GPL4133	Agilent-014850 Whole Human Genome Microarray 4x44K G4112F (Feature Number version)	in situ oligonucleotide	<i>Homo sapiens</i>	45,220	10183	528	Agilent Technologies	Aug 17, 2006
GPL3718	[Mapping250K_Nsp] Affymetrix Mapping 250K Nsp SNP Array	in situ oligonucleotide	<i>Homo sapiens</i>	262,338	9823	156	Affymetrix, Inc.	May 13, 2006

Arabidopsis ATH1 Genome Arrayに搭載されているプローブセット“247100_at”の転写物配列(NM_126050)上のプローブ位置を確認

NCBI
HOME SEARCH SITE MAP
NCBI > GEO > Accession Display

Scope: Self Format: HTML

Platform GPL198

Status Public on Jul 18, 2002
Title [ATH1-121501] Affymetrix
Technology type in situ oligonucleotide
Distribution commercial
Organism [Arabidopsis thaliana](#)
Manufacturer Affymetrix
Manufacture protocol see manufacturer's website

The current release has been updated with new annotation data from the Arabidopsis Genome Initiative (AGI) represented on the Arabidopsis genome (TAIR, Gene Ontology (GO) symbol, as well as the TIGR database. The current release has been updated with new annotation data from the Arabidopsis Genome Initiative (AGI) represented on the Arabidopsis genome (TAIR, Gene Ontology (GO) symbol, as well as the TIGR database. The current release has been updated with new annotation data from the Arabidopsis Genome Initiative (AGI) represented on the Arabidopsis genome (TAIR, Gene Ontology (GO) symbol, as well as the TIGR database.

Data table header descriptions

ID Affymetrix Probe
ORF Entrez Gene Link
SPOT_ID identifies controls
Species Scientific Name The genus and species
Annotation Date The date that the probe was first used on the Affymetrix platform
Sequence Type
Sequence Source The database from which the probe was taken.
Target Description GenBank description of the target. Blank for some probes.
Representative Public ID The accession number of the representative sequence and its source database used.
Gene Title Title of Gene representative
Gene Symbol A gene symbol, with the TIGR database.
ENTREZ_GENE_ID Entrez Gene Data Bank ID
RefSeq Transcript ID References to multiple transcripts for each probe.
AGI TAIR locus tag
Gene Ontology Biological Process Gene Ontology Category ID. Each annotation of a probe is associated with a description of the biological process. The evidence code is provided.
Gene Ontology Cellular Component Gene Ontology Category ID. Each annotation of a probe is associated with a description of the cellular component. The evidence code is provided.
Gene Ontology Molecular Function Gene Ontology Category ID. Each annotation of a probe is associated with a description of the molecular function. The evidence code is provided.

Data table

ID	ORF	SPOT_ID	Species Scientific Name	Annotation Date	Sequence Type	Sequence Source
244901_at	orf25		Arabidopsis thaliana	Jun 9, 2011	Exemplar sequence	Affymetrix Proprietary
244902_at	nad4L		Arabidopsis thaliana	Jun 9, 2011	Exemplar sequence	Affymetrix Proprietary
244903_at	orf149		Arabidopsis thaliana	Jun 9, 2011	Exemplar sequence	Affymetrix Proprietary
244904_at	orf275		Arabidopsis thaliana	Jun 9, 2011	Exemplar sequence	Affymetrix Proprietary
244905_at	orf122c		Arabidopsis thaliana	Jun 9, 2011	Exemplar sequence	Affymetrix Proprietary
244906_at	orf240a		Arabidopsis thaliana	Jun 9, 2011	Exemplar sequence	Affymetrix Proprietary
244907_at	orf120		Arabidopsis thaliana	Jun 9, 2011	Exemplar sequence	Affymetrix Proprietary
244908_at	orf107d		Arabidopsis thaliana	Jun 9, 2011	Exemplar sequence	Affymetrix Proprietary
244909_at	orf100a		Arabidopsis thaliana	Jun 9, 2011	Exemplar sequence	Affymetrix Proprietary
244910_s_at	orf119		Arabidopsis thaliana	Jun 9, 2011	Exemplar sequence	Affymetrix Proprietary
244911_at	orf170		Arabidopsis thaliana	Jun 9, 2011	Exemplar sequence	Affymetrix Proprietary
244912_at	ccb382		Arabidopsis thaliana	Jun 9, 2011	Exemplar sequence	Affymetrix Proprietary
244913_at	orf121b		Arabidopsis thaliana	Jun 9, 2011	Exemplar sequence	Affymetrix Proprietary
244914_at	orf107e		Arabidopsis thaliana	Jun 9, 2011	Exemplar sequence	Affymetrix Proprietary
244915_s_at	orf158		Arabidopsis thaliana	Jun 9, 2011	Exemplar sequence	Affymetrix Proprietary
244916_at						
244917_at						
244918_at						

Total number of rows: 22810
Table truncated, full table size 6018 Kbytes.

[Download full table...](#)

[Annotation SOFT table...](#)

Download family	Format
SOFT formatted family file(s)	SOFT
MINiML formatted family file(s)	MINiML

Supplementary data files not provided

ダウンロード後のファイル (GPL198-14794.txt) はhogeフォルダにあります



3'発現アレイの意味を確認

Excel 2010のスクリーンショット。ファイル名は「GPL198-14794.txt - Excel」。検索と置換ダイアログボックスが開いており、検索する文字列(N)に「247100_at」が入力されている。背景には、Arabidopsis ATH1 Genome Arrayの転写物配列に関するデータが表形式で表示されている。表の247100_at行が赤い枠で囲まれている。

Row	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
2204	247086_at	At5g66320		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix	GAT A-bind	At5g66320		836764	NM_126030	AT5G66320	0006350
2205	247087_at	At5g66330		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix	putative pr	At5g66330		836765	NM_126031	AT5G66330	0007165
2206	247088_at	At5g66340		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix							66340
2207	247089_at	At5g66360		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix							66360
2208	247090_at	At5g66370		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix							66370
2209	247091_at	At5g66390		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix							66390
2210	247092_at	At5g66380		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix							66380
2211	247093_at	At5g66350		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix							66350
2212	247094_at	At5g66280		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix							66280
2213	247095_at	At5g66400		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix							66400
2214	247096_at	At5g66430		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix							66430
2215	247097_at	At5g66460		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix							66460
2216	247098_at	At5g66470		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix							66470
2217	247099_at	At5g66500		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix							66500
2218	247100_at	At5g66520		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix	sele nium-k	At5g66520		836784	NM_126050	AT5G66520	
2219	247101_at	At5g66530		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix	apospory-s	At5g66530		836785	NM_126051	AT5G66530	0005975
2220	247102_at	At5g66550		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix	putative pr	At5g66550		836787	NM_126053	AT5G66550	
2221	247103_at	At5g66610		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix	putative pr	At5g66610	DAR7 (DA1 DAR7	836793	NM_126059	AT5G66610	
2222	247104_at	At5g66620		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix	putative pr	At5g66620	DAR6 (DA1 DAR6	836794	NM_126060	AT5G66620	0006508
2223	247105_at	At5g66630		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix	putative pr	At5g66630	DAR6 (DA1 DAR6	836795	NM_126061	AT5G66630	0006915
2224	247106_at	At5g66240		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix	WD re						
2225	247107_at	At5g66040		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix	senesc						
2226	247108_at	At5g66160		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix	ReMer						
2227	247109_at	At5g65870		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix	putativ						
2228	247110_at	At5g65830		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix	putativ						
2229	247111_at	At5g65880		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix	unknown p	At5g65880		836777	NM_126055	AT5G65880	
2230	247112_at	At5g65950		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix	unknown p	At5g65950		836725	NM_125992	AT5G65950	
2231	247113_at	At5g65960		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix	unknown p	At5g65960		836726	NM_125993	AT5G65960	0007264
2232	247114_at	At5g65910		Arabidopsis	9-Jun-11	Exemplar	s1	Affymetrix	unknown p	At5g65910		836720	NM_125988	AT5G65910	

検索と置換ダイアログボックスの検索する文字列(N)は「247100_at」。

247100_at行は赤い枠で囲まれている。

Arabisopsis ATH1 Genome Arrayに搭載されているプローブセット“247100_at”の転写物配列(NM_126050)上のプローブ位置を確認

準備完了

(Rで)マイクロアレイデータ解析

(last modified 2014/05/12, since 2005)

What's new?

- ・ 門田幸二 著 [シリーズ Useful R 第7巻トランスクリプトーム解析](#) 刊行(共立出版)。マイクロアレイ解析に関する最近の知見や、ROKUF法 (Kadota et al., 2006)、WAD法 (Kadota et al., 2008)などについての解説も含んでいます。書籍中のマイクロアレイ解析部分のRコードについては、このページの「[書籍 | トランスクリプトーム解析 | ...](#)」に掲載してあります。(2014/04/27) **NEW**
- ・ お知らせは主に [\(Rで\)塩基配列解析](#) で行っておりますのでそちらをご覧ください。(2014/03/05)

- ・ [はじめに](#) (last modified 2014/01/21)
- ・ [過去のお知らせ](#) (last modified 2014/03/03)
- ・ [Rのインストールと起動](#) (last modified 2014/04/17) **NEW**
- ・ [Rの昔のバージョンのインストール](#) (last modified 2012/04/07)
- ・ [使用例\(初心者向け\)](#) (last modified 2011/09/15)
- ・ [サンプルデータ](#) (last modified 2013/11/25)
- ・ [書籍 | について](#) (last modified 2014/04/17) **NEW**
- ・ [書籍 | トランスクリプトーム解析 | 1.1 はじめに](#) (last modified 2014/05/05)
- ・ [書籍 | トランスクリプトーム解析 | 1.2.1 原理\(Affymetrix 3'発現アレイ\)](#) (last modified 2014/05/05)
- ・ [書籍 | トランスクリプトーム解析 | 1.2.2 最近の知見](#) (last modified 2014/05/05)
- ・ [書籍 | トランスクリプトーム解析 | 2.2.1 生データ\(プローブレベルデータ\)](#) (last modified 2014/05/05)
- ・ [書籍 | トランスクリプトーム解析 | 2.2.2 データの正規化\(基礎\)](#) (last modified 2014/05/05)
- ・ [書籍 | トランスクリプトーム解析 | 2.2.3 データの正規化\(計算例\)](#) (last modified 2014/05/05)
- ・ [書籍 | トランスクリプトーム解析 | 2.2.4 データの正規化\(その他\)](#) (last modified 2014/05/05)
- ・ [書籍 | トランスクリプトーム解析 | 2.2.5 アンテーション情報](#) (last modified 2014/05/05)
- ・ [書籍 | トランスクリプトーム解析 | 3.2.1 クラスタリング\(データ変換や距離\)](#) (last modified 2014/05/05)
- ・ [書籍 | トランスクリプトーム解析 | 3.2.2 実験デザイン, データ分布, 統計](#) (last modified 2014/05/05)
- ・ [書籍 | トランスクリプトーム解析 | 3.2.3 多重比較問題](#) (last modified 2014/05/05)
- ・ [書籍 | トランスクリプトーム解析 | 3.2.4 各種プロット \(M-A plotや平均-分散\)](#) (last modified 2014/05/05)
- ・ [書籍 | トランスクリプトーム解析 | 4.2.1 2群間比較](#) (last modified 2014/05/05)
- ・ [書籍 | トランスクリプトーム解析 | 4.2.2 他の実験デザイン \(paired, multi\)](#) (last modified 2014/05/05)
- ・ [書籍 | トランスクリプトーム解析 | 4.2.3 多群間比較\(特異的発現パターン\)](#) (last modified 2014/05/05)
- ・ [イントロ | 発現データ取得 | 公共DBから](#) (last modified 2014/05/11) **NEW**
- ・ [イントロ | 発現データ取得 | inSilicoDb\(Taminau 2011\)](#) (last modified 2014/05/11)
- ・ [イントロ | 発現データ取得 | ArrayExpress\(Kauffmann 2009\)](#) (last modified 2014/05/11)

Arabidopsis ATH1 Genome Arrayに搭載されているプローブセット“247100_at”の転写物配列 (NM_126050) 上のプローブ位置を確認

書籍 | トランスクリプトーム解析 | 1.2.1 原理(Affymetrix 3'発現アレイ) **NEW**

シリーズ [Useful R 第7巻トランスクリプトーム解析](#) のp3-5です。

p3:

- ・ GEO: [Barrett et al., Nucleic Acids Res., 2013](#)
- ・ ヒト用: [GPL570](#)(Affymetrix Human Genome U133 Plus 2.0 Array)
- ・ マウス用: [GPL1261](#)(Affymetrix Mouse Genome 430 2.0 Array)
- ・ ラット用: [GPL1355](#)(Affymetrix Rat Genome 230 2.0 Array)

p5:

- ・ アンテーションファイル(GPL570-13270.txt)は、[GPL570](#)の「Download full table...」ボタンを押すことでダウンロード可能。
- ・ [GGRNA: Naito and Bono, Nucleic Acids Res., 2012](#)
- ・ [Probe Search](#)
- ・ [GGRNAを用いたHomo sapiens\(human\)中の1552263_atの検索結果](#)

[トップページへ](#)

統合遺伝子検索
GGRNA ver.2

Help | [Advanced search](#) | [English](#) | [旧バージョン](#)

検索

Saccharomyces cerevisiae S288c

Arabidopsis ATH1 Genome Arrayに搭載されているプローブセット“247100_at”の転写物配列(NM_126050)上のプローブ位置を確認

遺伝子をGoogleのように検索できるサイトです。NCBI RefSeq の transcript を全文検索します。
 検索例:

- 「homeobox」「claudin」..... フリーワード検索
- 「RNA interference」..... ダブルクオートで囲ってフレーズ検索
- 「Argonaute "PAZ domain"」..... Argonaute かつ "PAZ domain" のAND検索
- 「NM_001518」「10579」..... RefSeq IDやGene IDなど各種IDから検索
- 「symbol:VIM」..... 遺伝子名(symbolまたはsynonym)から検索
- 「ref:Naito」..... 文献情報のなかからフリーワード検索
- 「1552311_a_at」..... マイクロアレイのプローブIDから塩基配列を検索
- 「aa:KDEL」..... アミノ酸配列を検索
- 「caagaagagattg」..... 塩基配列を検索
- 「comp:caagaagagattg」..... 相補鎖を検索
- 「iub:aggtcannrtgacct」..... N, R, Y 等のあいまいな塩基を含む塩基配列を検索

詳細な使い方

新着情報:

- 2014-03-17 データベースをRefSeq rel. 64 (Mar, 2014)に更新。
- 2013-07-24 ソースを公開 - [GitHub](#)
- 2013-07-08 GGRNA ver.2公開。全生物種のRefSeqを検索できます。
- 2012-05-29 下記論文の日本語による解説を「DBCLSからの成果発信」に掲載。
- 2012-05-29 GGRNAの論文がNucleic Acids Researchに掲載されました。
- 過去の新着情報

GGRNA ver.2 by @meso_cacase at DBCLS
 This page is licensed under a [Creative Commons Attribution 2.1 Japan License](#)

統合遺伝子検索
GGRNA ver.2

Help | [Advanced search](#) | [English](#)

247100_at

Arabidopsis thaliana (thale cress)

検索

遺伝子をGoogleのように検索できるサイトです。NCBI RefSeq の transcript を全文検索します。
 検索例:

- 「homeobox」「claudin」..... フリーワード検索
- 「RNA interference」..... ダブルクオートで囲ってフレーズ検索
- 「Argonaute "PAZ domain"」..... Argonaute かつ "PAZ domain" のAND検索
- 「NM_001518」「10579」..... RefSeq IDやGene IDなど各種IDから検索
- 「symbol:VIM」..... 遺伝子名(symbolまたはsynonym)から検索
- 「ref:Naito」..... 文献情報のなかからフリーワード検索
- 「1552311_a_at」..... マイクロアレイのプローブIDから塩基配列を検索
- 「aa:KDEL」..... アミノ酸配列を検索
- 「caagaagagattg」..... 塩基配列を検索
- 「comp:caagaagagattg」..... 相補鎖を検索
- 「iub:aggtcannrtgacct」..... N, R, Y 等のあいまいな塩基を含む塩基配列を検索

詳細な使い方

新着情報:

- 2014-03-17 データベースをRefSeq rel. 64 (Mar, 2014)に更新。
- 2013-07-24 ソースを公開 - [GitHub](#)
- 2013-07-08 GGRNA ver.2公開。全生物種のRefSeqを検索できます。
- 2012-05-29 下記論文の日本語による解説を「DBCLSからの成果発信」に掲載。
- 2012-05-29 GGRNAの論文がNucleic Acids Researchに掲載されました。
- 過去の新着情報



マイクロアレイ(デバイスの進歩)

■ **3'発現アレイ** → exon array → **transcriptome array**

- Affymetrix Human Transcriptome Array (HTA 2.0)
- Furney et al., *Cancer Discov.*, **3**: 1122-1129, 2013.
- GPL17585(exon level)
- GPL17586(gene level)

転写物数は有限であるため、
RNA-seqによる網羅的な同定後
はトランスクリプトームアレイに移
行するほうがお手軽かもしれない



247100_at 検索
Arabidopsis thaliana (thale cress)

2014-05-12 15:35:19, GGRNA : RefSeq release 64 (Mar, 2014)

Summary:

- [seq:TTGCTCAAAGCCTGTCGAATTCACA \(1\)](#)
- [seq:TTAGCGGGAGACCGATCACACCCAG \(1\)](#)
- [seq:GGGACCACACACGAGTTTTAGCGG \(1\)](#)
- [seq:GGGAAATGCAGTTGTGGGGACTACT \(1\)](#)
- [seq:GATGCTGCTTGATCTAGTTGATGAT \(1\)](#)
- [seq:GAGAGGCTATTGTGCATCAGCATAG \(1\)](#)
- [seq:GACTAAACCAGGAACCATTATTCGT \(1\)](#)
- [seq:GACCGATCACACCCAGAGATAGAGA \(1\)](#)
- [seq:GAAATTGGCTATTACATACGGGTTA \(1\)](#)
- [seq:AGATAGGACAAGGTTCCATCATTTC \(1\)](#)
- [seq:AAGTAACGAAGCTCATCTCTAAGAT \(1\)](#)
- **INTERSECTION (1)**

Results:

トップ50件を表示。検索語に色がつきます。重なる色は濃く表示されます。

[Arabidopsis thaliana pentatricopeptide repeat-containing protein cds. \(1863 bp\)](#)
 gcg**ttgctcaaagcctgtcgaattcaca**aaaacatcgaattggagagaaattggagatc
 tcatggcgggaagatattgataaggcaaatattcatgctatggataaaaagtgggacaag
 aaagaacaaggagtagcaaaagtccaggatgtatcaaatagcttgga**gggaccac**
ccgatcacaccagagatagagaaaatcaatcaaatggagaatcatgagaaggaagaa
 agagttagaagagatgctgctgatctagttgatgatgatgaaagagag**gctattgtg**
gctattacatacgggtaatcaagactaa**accaggaaccattattcgt**tataatgaaga
 aca**aagtaacgaagctcatct**aagatatacaagagggatattgtaatgagagatag
 gat**gggaaatgcagttgtggggactact**gg...
 [position] 1264 1480 1498 1507 1602 1634 1662 1692 1754 1803 1818
 Synonym: K1F13.18; K1F13_18
 NM_126050.1 - Arabidopsis thaliana (thale cress) - [NCBI](#) - [TAIR](#)

Data Export:

下記より最大10000件まで取得できます。

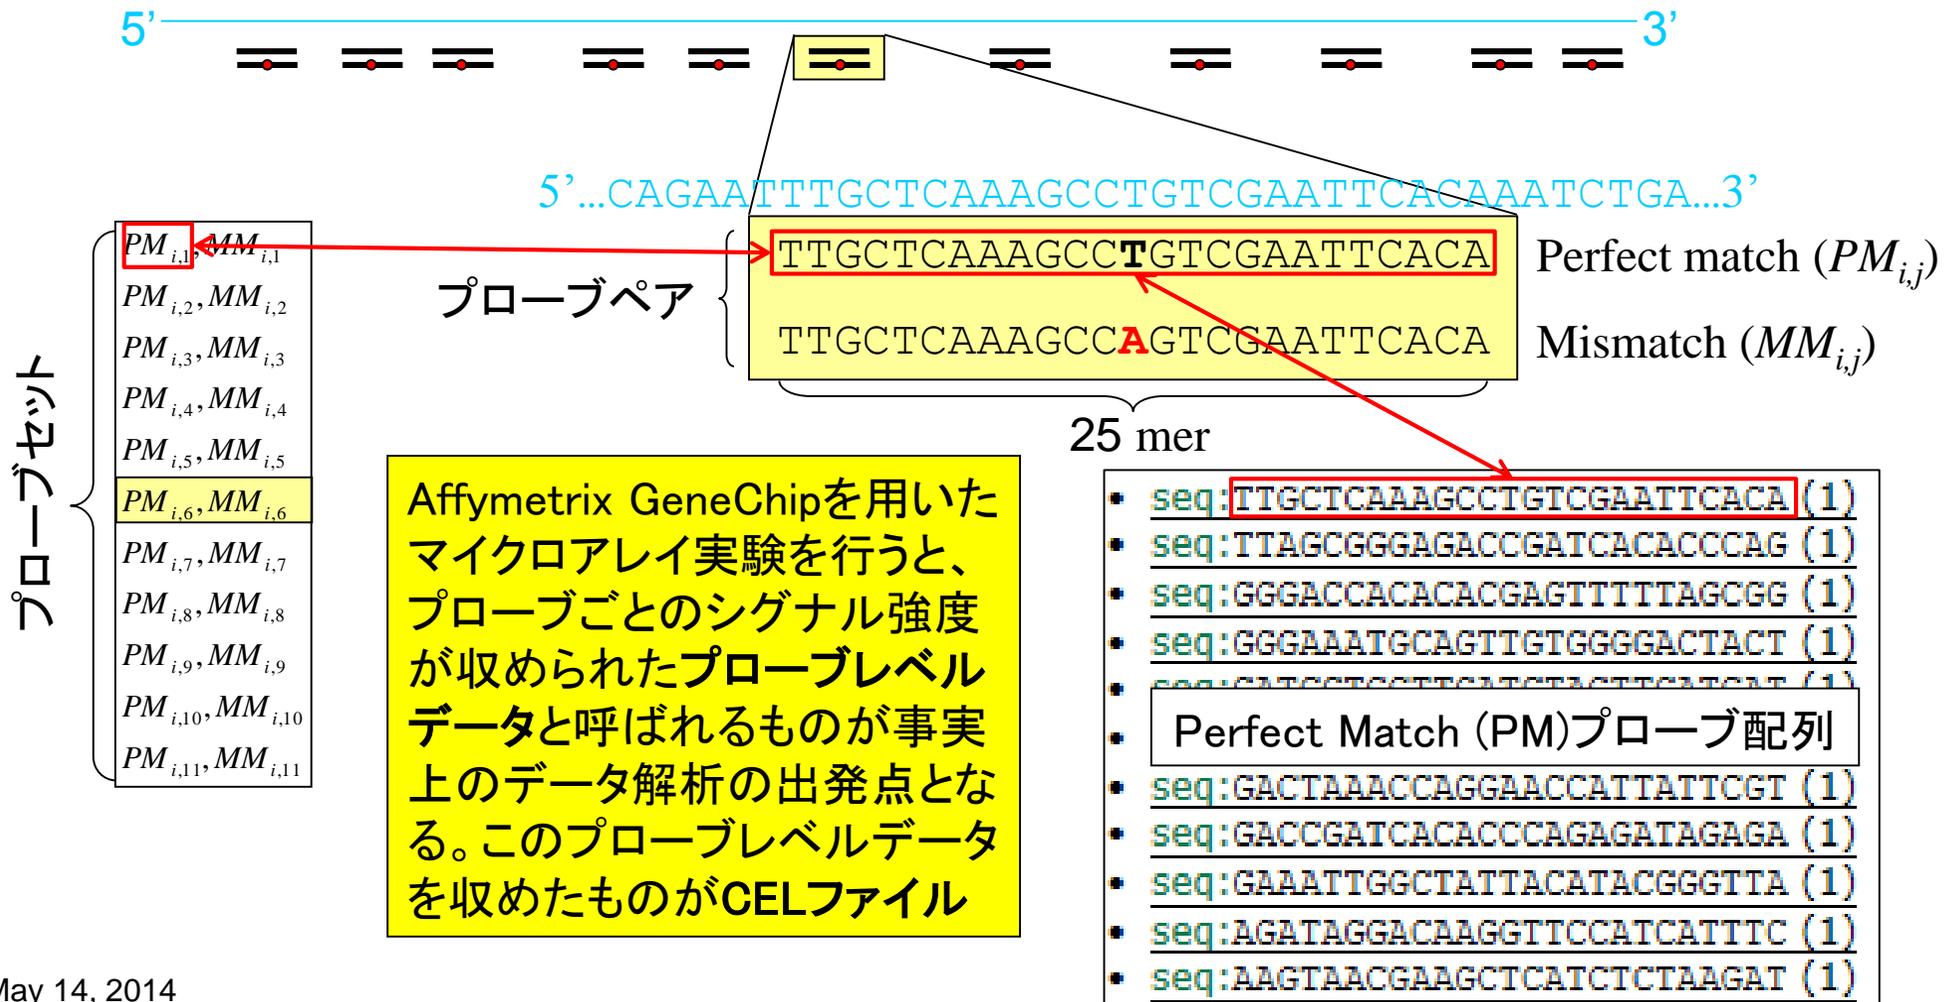
- タブ区切りテキスト → [表示](#) | [ダウンロード](#)
エクセル等の表計算ソフトに直接コピーできます。
- JSON形式 → [リンク](#) | [ダウンロード](#)

プローブ配列をテキストファイルで取り扱うこともできます。ここで示されているのはPerfect Match (PM)プローブ配列のみ

```
# [ GGRNA.v2 | 2014-05-12 16:10:02 ]
#
# seq:TTGCTCAAAGCCTGTCGAATTCACA 1
# seq:TTAGCGGGAGACCGATCACACCCAG 1
# seq:GGGACCACACACGAGTTTTAGCGG 1
# seq:GGGAAATGCAGTTGTGGGGACTACT 1
# seq:GATGCTGCTTGATCTAGTTGATGAT 1
# seq:GAGAGGCTATTGTGCATCAGCATAG 1
# seq:GACTAAACCAGGAACCATTATTCGT 1
# seq:GACCGATCACACCCAGAGATAGAGA 1
# seq:GAAATTGGCTATTACATACGGGTTA 1
# seq:AGATAGGACAAGGTTCCATCATTTC 1
# seq:AAGTAACGAAGCTCATCTCTAAGAT 1
# [ INTERSECTION ] 1
#
# accession version gi length symbol synonym geneid division sou
NM_126050 NM_126050.1 18425083 1863 K1F13.18; K1F13_18
```

Affymetrix GeneChipデータ解析

- 遺伝子*i*の発現量 S_i を n_i ($n_i=11\sim 20$)種類のプローブペアのシグナル強度をもとに計算



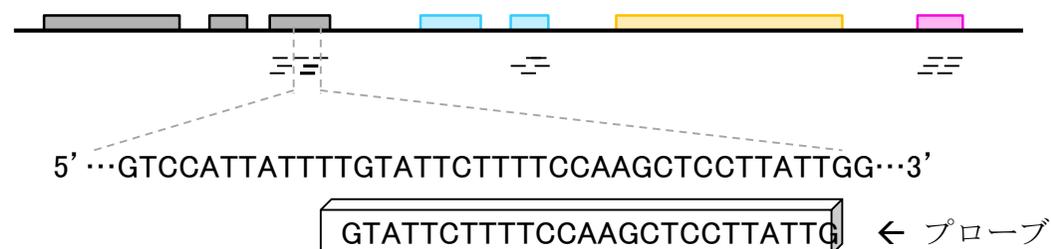
ステレオタイプなイメージ

■ マイクロアレイの長所

- 取り扱いやすいデータ量 (~100Mb程度)
- 長年の実績: 解析手法がほぼ確立。(Windows Rのみで解析可能)
- 検査用チップが利用可能(MammaPrintなど)

■ マイクロアレイの短所

- 解析可能範囲が搭載転写物に限定
- プローブが3'末端に偏っている(3'発現解析用アレイ)
- ダイナミックレンジが狭い



ダイナミックレンジ周辺の雑感

- 既知濃度のspike-inデータとシグナル強度との直線性
- Hekstra et al., *Nucleic Acids Res.*, **31**: 1962-1968, 2003
 - マイクロアレイはシグナル強度が高発現側で飽和し、低発現側では実際の濃度よりも高めに見積もられる (Fig. 4B)

プローブレベルのハイブリダイゼーションはLangmuir-adsorption modelに従う

ダイナミックレンジ周辺の雑感

- Langmuir-adsorption modelによる直線性向上の取り組み
 - 非特異的結合 (non-specific binding; NSB) の理解
 - 総説(Harrison et al., *Nucleic Acids Res.*, **41**: 2779-2796, 2013)
 - Gが4つ以上連続するプローブは外れ値になりやすい(Upton et al., 2008)
 - 4G signatureを持つプローブ同士がGカルテットを形成(Langdon et al., 2009)
 - ...
 - 方法
 - Hook法 (Binder et al., *Algorithms Mol. Biol.*, **3**: 11, 2008)
 - Inverse Langmuir法(Mulders et al., *BMC Bioinformatics*, **10**: 64, 2009)
 - MSNS model (Furusawa et al., *Bioinformatics*, **25**: 36-41, 2009)

ダイナミックレンジ向上を目指した方法は存在する

ダイナミックレンジ周辺の雑感

- 既知濃度のspike-inデータとシグナル強度との直線性
- “昔の方法”で数値化したアレイデータとの比較が多い
 - Nookaew et al., *Nucleic Acids Res.*, **40**: 10084-10097, 2012
 - PLIER(2004年ごろ)とcubic spline法(Workman et al., 2002)
 - Xu et al., *BMC Bioinformatics*, **14 Suppl 9**: S1, 2013
 - RMA (Irizarry et al., *Biostatistics*, **4**: 249-264, 2003)
 - Raghavachari et al., *BMC Med. Genomics*, **5**: 28, 2012
 - RMA (Irizarry et al., *Biostatistics*, **4**: 249-264, 2003)
 - Mortazavi et al., *Nat. Methods*, **5**: 621-628, 2008
 - MAS5 (Hubbell et al., *Bioinformatics*, **18**: 1585-1592, 2002)

比較的最近の方法との評価をすべきではある

Contents (第1回)

- イン트로ダクション
 - マイクロアレイの原理や特徴(長所・短所)
 - データ解析例とバイオインフォマティクス要素技術
 - 発現データベース(DB)
 - Affymetrix GeneChipの用語: CELファイル、プローブセット、summarization...
- 発現DBからのプローブレベルデータ取得
 - GEOウェブサイト経由
 - R経由(教科書の § 2.2.1)
- 前処理法の適用(プローブレベルデータ → 発現行列データ)
 - MAS法、RMA法、RMX法(RobLoxBioC)、IRON法(教科書の § 2.2.2~2.2.4)
 - データの正規化(グローバル正規化、quantile正規化)

発現DBからの生データ取得

■ Affymetrix GeneChip

- Ge et al., *Genomics*, 86: 127–141, 2005
 - GSE2361、ヒト36サンプル、GPL96を利用
- Nakai et al., *Biosci Biotechnol Biochem.*, 72: 139–148, 2008
 - GSE7623、ラット24サンプル、GPL1355を利用
- Kamei et al., *PLoS One*, 8: e65732, 2013
 - GSE30533、ラット10サンプル、GPL1355を利用

GSE7623のプローブレベルデータ取得
(つまりCELファイル取得)を行います。

■ Illumina BeadChip

- Sharma et al., *Cancer Cell*, 23: 35–47, 2013
 - GSE28680、ヒト24サンプル、GPL10558を利用

■ NGSデータも…

- Neyret-Kahn et al., *Genome Res.*, 23: 1563–1579, 2013
 - GSE42213、ヒト26サンプル、GPL10999とGPL11154を利用
 - GSE42211、ヒト20サンプル、GPL10999とGPL11154を利用 (ChIP-seq)
 - GSE42212、ヒト6サンプル、GPL10999を利用 (RNA-seq)
- Huang et al., *Development*, 139: 2161–2169, 2012
 - GSE36469、シロイヌナズナ8サンプル、GPL13222を利用

- 書籍 | トランスクリプトーム解析 | 4.2.4 各種プロット (M-A plot や 平均-分散プロット など) (last modified 2014/04/19) **NEW**
- 書籍 | トランスクリプトーム解析 | 4.2.2 他の実験デザイン (paired, multi-factor, 3群間) (last modified 2014/04/19)
- 書籍 | トランスクリプトーム解析 | 4.2.3 多群間比較 (特異的発現パターン) (last modified 2014/04/19)
- イントロ | 発現データ取得 | **公共DBから** (last modified 2014/05/11) **NEW**
- イントロ | 発現データ取得 | [inSilicoDb \(Taminau 2011\)](#) (last modified 2013/08/20)
- イントロ | 発現データ取得 | [ArrayExpress \(Kauffmann 2009\)](#) (last modified 2013/08/29) 推奨
- イントロ | 発現データ取得 | [GEO \(Barrett et al., 2007\)](#) (last modified 2013/08/29)

イントロ | 発現データ取得 | 公共DBから **NEW**

遺伝子発現 (主にマイクロアレイ) データベースをリストアップします。

一次データベース

- GEO:** [Barrett et al., Nucleic Acids Res., 2013](#)
 - [GSE7623](#) (ラット 24 サンプル, 62MB): [Nakai et al., BBB, 2008](#)
 - [GSE30533](#) (ラット 10 サンプル, 25MB): [Kamei et al., PLoS One, 2013](#)

Gene Expression Omnibus

GEO is a public functional genomics data repository supporting MIAME-compliant data submissions. Array- and sequence-based data are accepted. Tools are provided to help users query and download experiments and curated gene expression profiles.

[Array](#)

 Gene Expression Omnibus

GSE7623

Getting Started	Tools	Browse Content
Overview	Search for Studies at GEO DataSets	Repository Browser
FAQ	Search for Gene Expression at GEO Profiles	DataSets: 3413
About GEO DataSets	Search GEO Documentation	Series:  47349
About GEO Profiles	Analyze a Study with GEO2R	Platforms: 12911
About GEO2R Analysis	GEO BLAST	Samples: 1132039
How to Construct a Query	Programmatic Access	
How to Download Data	FTP Site	

NCBI GEO Gene Expression Omnibus

HOME | SEARCH | SITE MAP | GEO Publications | FAQ | MIAME | Email GEO

NCBI > GEO > Accession Display 2

GEO help: Mouse over screen elements for information.

Scope: Self | Format: HTML | Amount: Quick | GEO accession: GSE7623

Series GSE7623 [Query DataSets](#)

Status: Public on Jan 09, 2008
 Title: 24 h-fasting effects on the brown and white adipose tissue an
 Organism: [Rattus norvegicus](#)
 Experiment type: Expression profiling by array
 Summary: The functional balance between brown adipose tissue (BAT) and white adipose tissue (WAT) is important for metabolic homeostasis. To compare the effects of fasting on the gene expression profile of WAT and liver, using DNA microarray analysis. Tissues were obtained from rats that had been fed or fasted for 24 h. Taking the false discovery rate (FDR) into account, we extracted the top 1,000 genes that were differentially expressed between fed and fasted rats. In all three tissues, ontology analysis revealed marked changes in the expression of 'metabolism' category genes and a hypergeometric test detected protein biosynthesis-related genes. We identified simultaneous down-regulation of pathways in the BAT, WAT, and liver. In the BAT, WAT, and liver, there was marked up-regulation of 'metabolism' category genes, suggesting a shift in energy allocation in saving energy as a result of fasting.

Overall design: Rats (7-week-old) were given a commercial diet between 10:00 and 16:00 for 7 days. At 10:00 on day 8, they were divided into two groups comprising animals of similar body weights. One group continued as described above (fed group, n=4 for array analysis), where they received water ad libitum. At 16:00 on day 8, the liver, interscapular and perinephrial WAT were excised, and analyzed for fasting effects.

Contributor(s): Nakai Y, Hashida H, Kadota K, Minami M, Shimizu K, Matsumoto I, Abe K
 Citation(s): Nakai Y, Hashida H, Kadota K, Minami M et al. Up-regulation of genes related to the ubiquitin-proteasome system in the brown adipose tissue of 24-h-fasted rats. *Biosci Biotechnol Biochem* 2008 Jan;72(1):139-48. PMID: 18175912

Contributor(s): Nakai Y, Hashida H, Kadota K, Minami M, Shimizu K, Matsumoto I, Kato H, Abe K
 Citation(s): Nakai Y, Hashida H, Kadota K, Minami M et al. Up-regulation of genes related to the ubiquitin-proteasome system in the brown adipose tissue of 24-h-fasted rats. *Biosci Biotechnol Biochem* 2008 Jan;72(1):139-48. PMID: 18175912
 Submission date: Apr 2008
 Last update date: Sep 2008
 Contact name: Yuji Nakai
 Organization name: The University of Tokyo
 Street address: 1-1-1, Yayoi
 City: Bunkyo-ku
 State/province: Tokyo
 ZIP/Postal code: 113-8657
 Country: Japan

Platforms (1): **GPL1355 [Rat230_2] Affymetrix Rat Genome 230 2.0 Array**

Samples (24):
 # More...
 GSM184414 Brown adipose tissue, fed #1
 GSM184415 Brown adipose tissue, fed #2
 GSM184416 Brown adipose tissue, fed #4

Relations
 BioProject: PRJNA100245

Analyze with GEO2R

Download family
 SOFT formatted family file(s)
 MINiML formatted family file(s)
 Series Matrix File(s)

Supplementary file	Size	Download	File type/resource
GSE7623_RAW.tar	61.7 Mb	(http)(custom)	TAR (of CEL, CHP, EXP)

Raw data provided as supplementary file
 Processed data provided as supplementary file

Format
 SOFT 2
 MINiML 2
 TXT 2

ラットゲノムからプローブを設計した、ラット用のチップを用いて発現データを得ている

全部で24サンプルのデータからなることが分かる(24枚のアレイを使っている)

生データのダウンロードはここ。hogeフォルダ中にあり

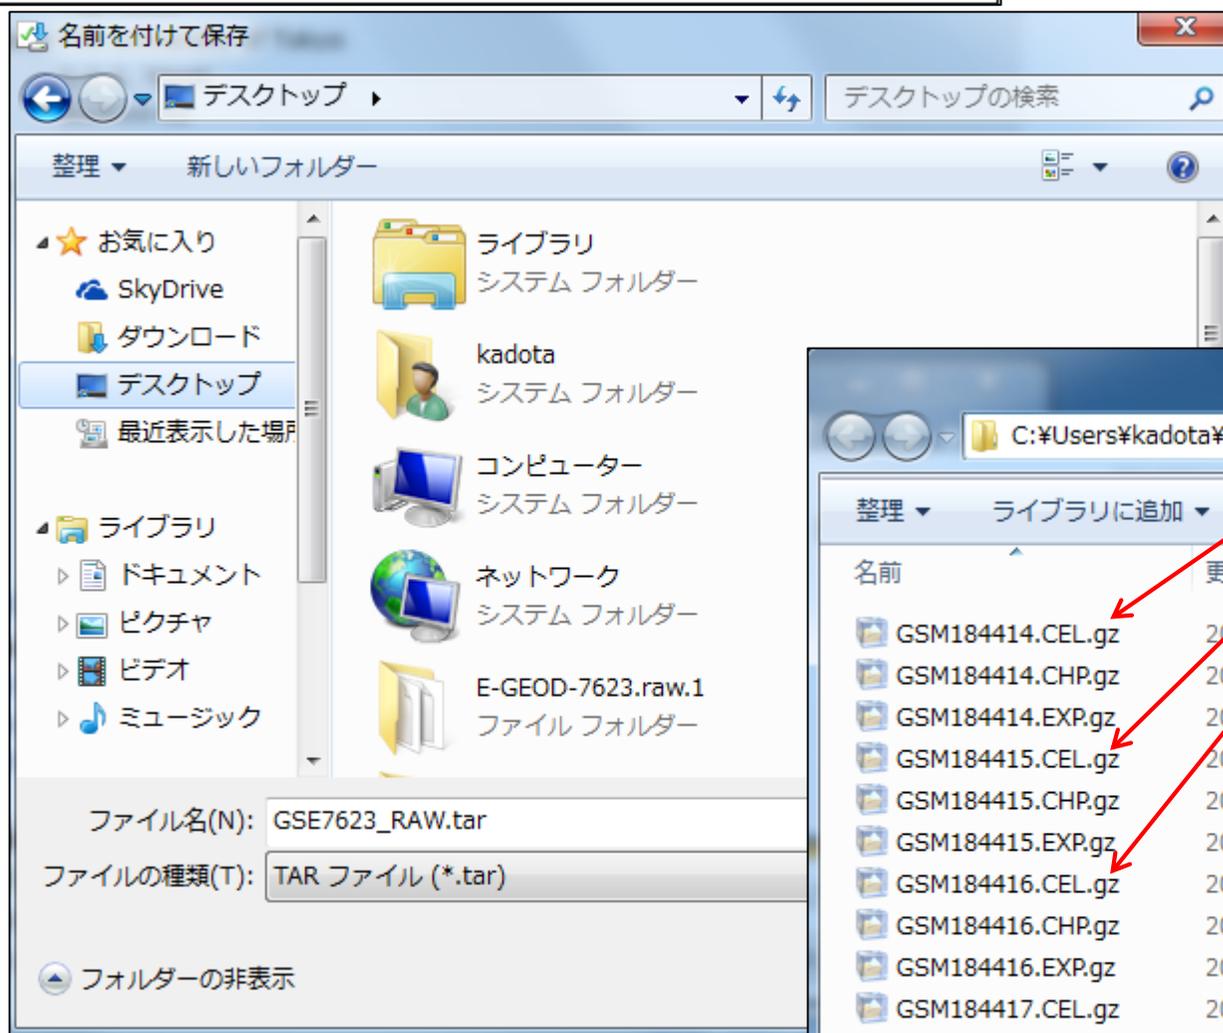
May 14, 2014

58

ファイルを開く(O)

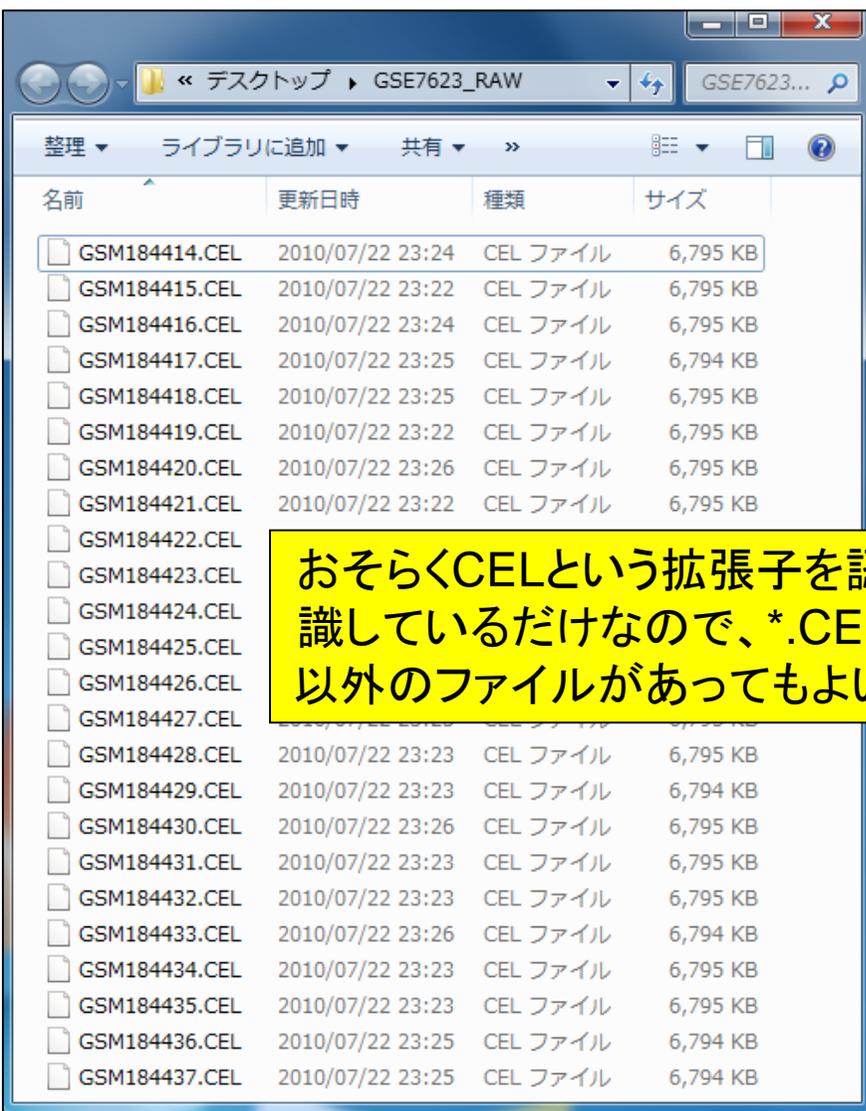
保存(S)

キャンセル(C)



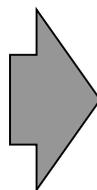
デスクトップ上でtarファイルを解凍しても、さらにgzip圧縮されたCELファイルの解凍を行う必要がある

前処理法適用前の状態



— CELファイル —
チップ上に搭載されている全遺伝子のプローブのシグナル強度情報を含むファイル

前処理法



遺伝子発現行列

	S1	S2	S3	S4	...
gene 1	$x_{1,1}$	$x_{1,2}$	$x_{1,3}$	$x_{1,4}$...
gene 2	$x_{2,1}$	$x_{2,2}$	$x_{2,3}$	$x_{2,4}$...
...
gene i	$x_{i,1}$	$x_{i,2}$	$x_{i,3}$	$x_{i,4}$...
...
gene n	$x_{n,1}$	$x_{n,2}$

	A	B	C	D
1		sample1	sample2	sample3
2	gene1	10.87	12.13	8.87
3	gene2	7.03	7.17	12.13
4	gene3	8.50	8.50	10.87
5	gene4	12.13	10.87	7.17
6	gene5	5.77	6.30	5.77
7	gene6	8.87	8.87	8.50
8	gene7	6.77	7.03	6.30
9	gene8	6.30	6.77	6.77
10	gene9	7.17	5.77	7.03
11	gene10	4.80	4.80	4.80

R経由で生データ取得(教科書の § 2.2.1)

- サンプルデータ (last modified 2013/11/25)
- 書籍 | について (last modified 2014/04/17) **NEW**
- 書籍 | トランスクリプトーム解析 | 1.1はじめに (last modified 2014/05/09) **NEW**
- 書籍 | トランスクリプトーム解析 | 1.2.1 原理(Affymetrix 3'発現アレイ) (last modified 2014/05/12) **NEW**
- 書籍 | トランスクリプトーム解析 | 1.2.2 最近の知見 (last modified 2014/05/09) **NEW**
- 書籍 | トランスクリプトーム解析 | 2.2.1 生データ(プロブレベルデータ)取得 (last modified 2014/04/18) **NEW**
- 書籍 | トランスクリプトーム解析 | 2.2.2 データの正規化(基礎) (last modified 2014/04/17) **NEW**
- 書籍 | トランスクリプトーム解析 | 2.2.3 データの正規化(計算例) (last modified 2014/04/18) **NEW**
- 書籍 | トランスクリプトーム解析 | 2.2.4 データの正規化(その他) (last modified 2014/04/18) **NEW**
- 書籍 | トランスクリプトーム解析 | 2.2.5 アノテーション情報 (last modified 2014/04/18) **NEW**
- 書籍 | トランスクリプトーム解析 | 3.2.1 クラスタリング(データ変換や距離の定義など) (last modified 2014/04/18) **NEW**
- 書籍 | トランスクリプトーム解析 | 3.2.2 実験デザイン、データ分布、統計解析との関係 (last modified 2014/04/18) **NEW**
- 書籍 | トランスクリプトーム解析 | 3.2.3 多重比較問題 (last modified 2014/04/19) **NEW**
- 書籍 | トランスクリプトーム解析 | 3.2.4 各種プロット(M-A plotや
- 書籍 | トランスクリプトーム解析 | 4.2.1 2群間比較 (last modified
- 書籍 | トランスクリプトーム解析 | 4.2.2 他の実験デザイン(paired
- 書籍 | トランスクリプトーム解析 | 4.2.3 多群間比較(特異的発現
- インポート | 発現データ取得 | 公共DBから (last modified 2014/05/
- インポート | 発現データ取得 | inSilicoDb(Taminau 2011) (last mo
- インポート | 発現データ取得 | ArrayExpress(Kauffmann 2009) (las
- インポート | 発現データ取得 | GEOquery(Davis 2007) (last modifi
- インポート | アノテーション情報取得 | 公共DB(GEO)から (last mo
- インポート | アノテーション情報取得 | GEOquery(Davis 2007) (las
- インポート | アノテーション情報取得 | Rのパッケージ*.dbから (last

経験上、R経由で
ArrayExpressから
のダウンロード
のほうが簡単

書籍 | について **NEW**

2014年4月に(Rで)塩基配列解析および(Rで)マイクロアレイデータ解析を体系的にまとめた以下の書籍が出版されました。ここでは(Rで)マイクロアレイデータ解析に関連したマイクロアレイ部分の書籍中のRコードを章・節・項ごとに示します。

なるべく書籍中の記述形式に準拠しますが、例えばp72中の最初のsetwd("C:/Users/kadota/Desktop")というコマンドを忠実に実行してもエラーが出るだけです。これはkadotaというヒトのPC上でのみ成立するコマンドだからです。ここで利用しているsetwd関数は作業ディレクトリの変更に相当し、「ファイル」-「ディレクトリの変更」でデスクトップに移動することと同義です。したがって、このページ全体で統一的に使っているように、ディレクトリの変更作業自体はR Gui画面左上の「ファイル」メニューを利用することとし、setwd関数部分の記述は省略します。

- 門田幸二著(金明哲 編), シリーズ Useful R 第7巻トランスクリプトーム解析, 共立出版, 2014年4月. ISBN: 978-4-320-12370-0

イントロ | 発現データ取得 | 公共DBから NEW

遺伝子発現(主にマイクロアレイ)データベースをリストアップします。

一次データベース

- GEO: [Barrett et al.](#)
 - [GSE7623](#)
 - [GSE3053](#)
 - [GSE2361](#)
 - [GSE1024](#)
 - [GSE1133](#)
 - [GSE1599](#)
- ArrayExpress: [R](#)
 - [GSE7623](#)
 - [GSE3053](#)
 - [GSE2361](#)
 - [GSE1024](#)
 - [GSE1133](#)
 - [GSE1599](#)

二次データベース

- [inSilico Db: Col](#)
- [BioGPS: Wu et al.](#)
- [Expression Atlas](#)
- [CellFinder: Stac](#)

EMBL-EBI

Cookies on EMBL-EBI website

This website uses cookies to store a small amount of information to improve your navigation on the site. Cookies used for the operation of the site and to enhance the user experience.

To find out more about the cookies we use, see our [Cookie Policy](#).

[Dismiss this notice](#)

Browse Content

Repository Browser

DataSets:	3413
Series:	47340
Platforms:	12912
Samples:	1131572

EMBL-EBI

ArrayExpress

Home Experiments Arrays Submit Help About ArrayExpress

Search

Examples: E-MEXP-31, cancer, p53, Geuvadis

Advanced

Feedback Login

ArrayExpress - functional genomics data

ArrayExpress is a database of functional genomics experiments that can be queried and the data downloaded. It includes gene expression data from microarray and high throughput sequencing studies. Data is collected to [MIAME](#) and [MINSEQE](#) standards. Experiments are submitted directly to ArrayExpress or are imported from the NCBI GEO database.

Data Content

Updated today at 06:00

- 49013 experiments
- 1406218 assays
- 23.47 TB of archived data

2つのDB間で用語の統一はなされていないものの、ArrayExpressはGSE7623などのGEO IDでの検索も可能

Latest News

7 February 2014 - **High throughput sequencing (HTS) data sets in ArrayExpress**

Did you know that ArrayExpress contains nearly 6000 HTS experiments? They range from common study types such as [RNA-seq](#) and [ChIP-seq](#) to [methylation profiling seq](#), [FAIRE-seq](#) (formaldehyde-assisted isolation of regulatory elements), [GRO-seq](#) (global run-on seq) and many more. For each experiment, study and sample information is stored at ArrayExpress, while raw sequence data files (e.g. fastq files) are stored at the [Sequence Read Archive](#) of the European Nucleotide Archive. If you're planning to [submit](#) a sequencing experiment to ArrayExpress, why not check out this [help page](#) for more information?

R経由で生データ取得(教科書の § 2.2.1)

- [サンプルデータ](#) (last modified 2013/11/25)
- [書籍 | について](#) (last modified 2014/04/17) **NEW**
- 書籍 | [トランスクリプトーム解析 | 1.1 はじめに](#) (last modified 2014/05/09) **NEW**
- 書籍 | [トランスクリプトーム解析 | 1.2.1 原理\(Affymetrix 3'発現アレイ\)](#) (last modified 2014/05/12) **NEW**
- 書籍 | [トランスクリプトーム解析 | 1.2.2 最近の知見](#) (last modified 2014/05/09) **NEW**
- 書籍 | [トランスクリプトーム解析 | 2.2.1 生データ\(プローブレベルデータ\)取得](#) (last modified 2014/04/18) **NEW**
- 書籍 | [トランスクリプトーム解析 | 2.2.2 データの正規化\(基礎\)](#) (last modified 2014/04/17) **NEW**
- 書籍 | [トランスクリプトーム解析 | 2.2.3 データの正規化\(計算例\)](#) (last modified 2014/04/18) **NEW**
- 書籍 | [トランスクリプトーム解析 | 2.2.4 データの正規化\(その他\)](#) (last modified 2014/04/18) **NEW**
- 書籍 | [トランスクリプトーム解析 | 2.2.5 アノテーション情報](#) (last modified 2014/04/18) **NEW**
- 書籍 | [トランスクリプトーム解析 | 3.2.1 クラスタリング\(データ変換や距離の定義など\)](#) (last modified 2014/04/18) **NEW**
- 書籍 | [トランスクリプトーム解析 | 3.2.2 実験デザイン, データ分布, 統計解析との関係](#) (last modified 2014/04/18) **NEW**
- 書籍 | [トランスクリプトーム解析 | 3.2.3 多重比較問題](#) (last modified 2014/04/19) **NEW**
- 書籍 | [トランスクリプトーム解析 | 3.2.4 各種プロット\(M-A plotや平均-分散プロットなど\)](#) (last modified 2014/04/19) **NEW**
- 書籍 | [トランスクリプトーム解析 | 4.2.1 2群間比較](#) (last modified 2014/04/19) **NEW**
- 書籍 | [トランスクリプトーム解析 | 4.2.2 他の実験デザイン\(paired, multi-factor, 3群間\)](#) (last modified 2014/04/19) **NEW**
- 書籍 | [トランスクリプトーム解析 | 4.2.3 多群間比較\(特異的発現パターン\)](#) (last modified 2014/04/20) **NEW**
- インポート | [発現データ取得 | 公共DBから](#) (last modified 2014/05/11) **NEW**
- インポート | [発現データ取得 | inSilicoDb\(Taminau 2011\)](#) (last modified 2013/08/20)
- インポート | [発現データ取得 | ArrayExpress\(Kauffmann 2009\)](#) (last modified 2013/08/29) 推奨
- インポート | [発現データ取得 | GEOquery\(Davis 2007\)](#) (last modified 2013/08/20)
- インポート | [アノテーション情報取得 | 公共DB\(GEO\)から](#) (last modified 2013/08/18)
- インポート | [アノテーション情報取得 | GEOquery\(Davis 2007\)](#) (last modified 2013/09/18) 推奨
- インポート | [アノテーション情報取得 | Rのパッケージ*dbから](#) (last modified 2013/08/18)

教科書中のR
コードはこちら

GSE7623のプローブレベル
データ取得(つまりCELファイル
取得)をR経由で行います。

イントロ | 発現データ取得 | ArrayExpress(Kauffmann_2009)

3. AffymetrixデータGSE7623 (Nakai et al., BBB, 2008)のCELファイルを取得したい場合:

```

param <- "GSE7623" #入手したいIDを指定
#必要なパッケージをロード
library(ArrayExpress) #パッケージの読み込み
#前処理(データ取得)
hoge <- getAE(param, type="raw", extract=F) #paramで指定

```

RGU (64-bit)

ファイル 編集 閲覧 その他 パッケージ ウィンドウ

R Console

R は多くの貢献者による共同プロジェクトです。
詳しくは 'contributors()' と入力してください。
また、R や R のパッケージを出版物で引用する際の形式については
'citation()' と入力してください。

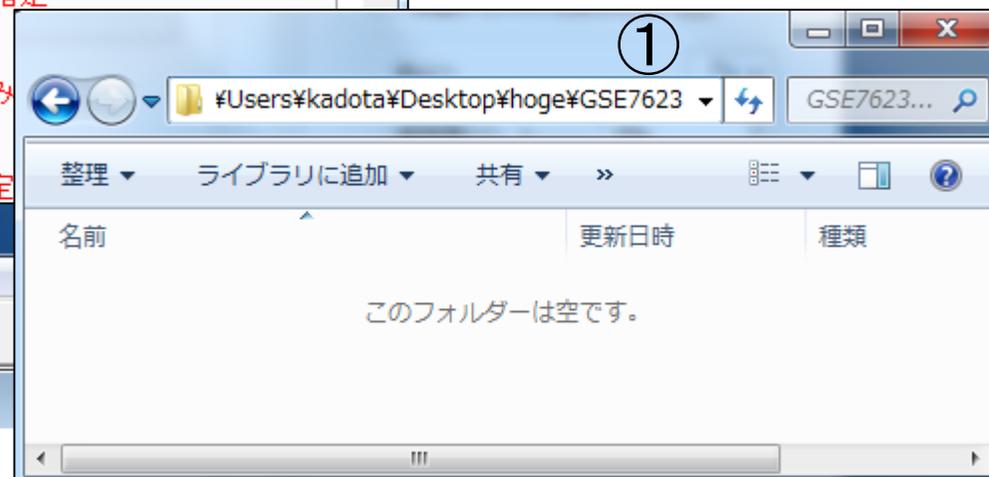
'demo()' と入力すればデモをみることができます。
'help()' とすればオンラインヘルプが出ます。
'help.start()' で HTML ブラウザによるヘルプがみられます。
'q()' と入力すれば R を終了します。

```

> getwd()
[1] "C:/Users/kadota/Desktop/hoge/GSE7623"
> |

```

②



①デスクトップにhogeフォルダ、およびその中にGSE7623フォルダを作成する。②Rを起動し、作業ディレクトリをそこに変更しておく

```

URL 'http://www.ebi.ac.uk/arrayexpress/files/E-GEOD-7623/E-GEOD-7623-raw.1.zip'
Content type 'text/plain' length 4484 bytes
開かれた URL
downloaded 4484 bytes

```

コピー実行後

```

Copying raw data files

URL 'http://www.ebi.ac.uk/arrayexpress/files/E-GEOD-7623/E-GEOD-7623-raw.1.zip'
Content type 'text/plain' length 4484 bytes
開かれた URL
downloaded 4484 bytes

```

Users\kadota\Desktop\hoge\GSE7623

名前	更新日時	種類
A-AFFY-43.adf.txt		ドキュメント
E-GEOD-7623.idf.txt		ドキュメント
E-GEOD-7623.raw.1.zip	2014/05/13 12:25	ZIP ファイル
E-GEOD-7623.sdrf.txt	2014/05/13 12:22	テキスト ドキュメント

4つのファイルが作成されるので、zipファイルを解凍

37% / E-GEOD-7623.raw.1.zip

C:\Users\kadota\Desktop\hoge\GSE7623\E-GEOD-7623.raw.1.zip

GSM184431.CEL

キャンセル

名前	更新日時	種類	サイズ
GSM184414.CEL	2010/07/22 23:24	CEL ファイル	6,795 KB
GSM184415.CEL	2010/07/22 23:22	CEL ファイル	6,795 KB
GSM184416.CEL	2010/07/22 23:24	CEL ファイル	6,795 KB
GSM184417.CEL	2010/07/22 23:25	CEL ファイル	6,794 KB
GSM184418.CEL	2010/07/22 23:25	CEL ファイル	6,795 KB
GSM184419.CEL	2010/07/22 23:22	CEL ファイル	6,795 KB
GSM184420.CEL	2010/07/22 23:26	CEL ファイル	6,795 KB
GSM184421.CEL	2010/07/22 23:22	CEL ファイル	6,795 KB
GSM184422.CEL	2010/07/22 23:23	CEL ファイル	6,795 KB
GSM184423.CEL	2010/07/22 23:23	CEL ファイル	6,795 KB
GSM184424.CEL	2010/07/22 23:23	CEL ファイル	6,795 KB
GSM184425.CEL	2010/07/22 23:23	CEL ファイル	6,794 KB
GSM184426.CEL	2010/07/22 23:27	CEL ファイル	6,795 KB
GSM184427.CEL	2010/07/22 23:23	CEL ファイル	6,795 KB
GSM184428.CEL	2010/07/22 23:23	CEL ファイル	6,795 KB
GSM184429.CEL	2010/07/22 23:23	CEL ファイル	6,794 KB
GSM184430.CEL	2010/07/22 23:26	CEL ファイル	6,795 KB
GSM184431.CEL	2010/07/22 23:23	CEL ファイル	6,795 KB
GSM184432.CEL	2010/07/22 23:23	CEL ファイル	6,795 KB
GSM184433.CEL	2010/07/22 23:26	CEL ファイル	6,794 KB
GSM184434.CEL	2010/07/22 23:23	CEL ファイル	6,795 KB
GSM184435.CEL	2010/07/22 23:23	CEL ファイル	6,795 KB
GSM184436.CEL	2010/07/22 23:25	CEL ファイル	6,794 KB
GSM184437.CEL	2010/07/22 23:25	CEL ファイル	6,794 KB

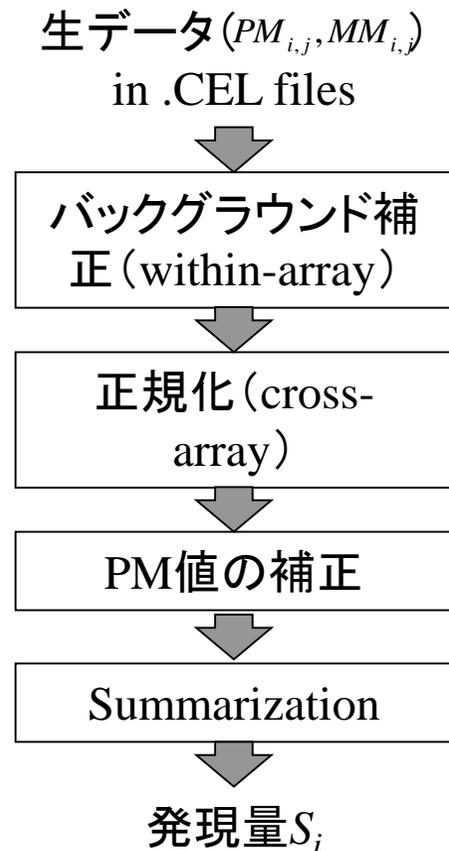
CELファイルのみからなるので便利

Contents (第1回)

- イン트로ダクション
 - マイクロアレイの原理や特徴(長所・短所)
 - データ解析例とバイオインフォマティクス要素技術
 - 発現データベース(DB)
 - Affymetrix GeneChipの用語: CELファイル、プローブセット、summarization...
- 発現DBからのプローブレベルデータ取得
 - GEOウェブサイト経由
 - R経由(教科書の § 2.2.1)
- 前処理法の適用(プローブレベルデータ → 発現行列データ)
 - MAS法、RMA法、RMX法(RobLoxBioC)、IRON法(教科書の § 2.2.2~2.2.4)
 - データの正規化(グローバル正規化、quantile正規化)

様々な前処理法

- MBEI (Li and Wong, *PNAS*, **98**: 31-36, 2001)
- VSN (Huber et al., *Bioinformatics*, **18** Suppl 1: S96-104, 2002)
- MAS5 (Hubbell et al., *Bioinformatics*, **18**: 1585-92, 2002)
- RMA (Irizarry et al., *Biostatistics*, **4**: 249-64, 2003)
- GCRMA (Wu et al., *Tech. Rep.*, *John Hopkins Univ.*, 2003)
- PDNN (Zhang et al., *Nat. Biotechnol.*, **21**: 818-21, 2003)
- PLIER (Affymetrix, 2004)
- SuperNorm (Konishi, T., *BMC Bioinformatics*, **5**: 5, 2004)
- multi-mgMOS (Liu et al., *Bioinformatics*, **21**: 3637-3644, 2005)
- GLA (Zhou and Rocke, *Bioinformatics*, **21**: 3983-3989, 2005)
- FARMS (Hochreiter et al., *Bioinformatics*, **22**: 943-949, 2006)
- DFW (Chen et al., *Bioinformatics*, **23**: 321-327, 2007)
- Hook (Binder et al., *AMB*, **3**: 11, 2008)
- GRSN (Pelz et al., *BMC Bioinformatics*, **9**: 520, 2008)
- RMX (Kohl et al., *BMC Bioinformatics*, **11**: 583, 2010)
- KDL and KDQ (Hsieh et al., *BMC Bioinformatics*, **12**: 222, 2011)
- IRON (Welsh et al., *BMC Bioinformatics*, **14**: 153, 2013)



様々な前処理法

生データ ($PM_{i,j}, MM_{i,j}$)
in .CEL files

バックグラウンド補正 (within-array)

正規化 (cross-array)

PM値の補正

Summarization

発現量 S_i

■ MAS5 (Hubbell et al., *Bioinformatics*, 18: 1585-92, 2002)

- 特徴: アレイごとに独立して前処理を実行 (per-array basis)
- 正規化: グローバル正規化

■ RMA (Irizarry et al., *Biostatistics*, 4: 249-64, 2003)

- 特徴: 読み込んだ複数サンプル (複数アレイ) の情報を用いて前処理を実行 (multi-array basis)
- 正規化: quantile正規化 (プローブレベルデータに対して実行)

Table 1: Frequency of preprocessing algorithms used during 2003 – 2008

	2003	2004	2005	2006	2007	2008
MAS (2002)	8	34	53	42	47	16
RMA (2003)		8	15	29	20	9
MBEI (2001)	0	3	7	16	8	3
GCRMA (2004)			0	5	8	4
VSN (2002)	0	0	0	4	0	2

よく使われているのはMAS5とRMAです

Our investigation was performed for 394 different papers with analyses performed using the Affymetrix HG-U133A array (Gene Expression Omnibus (GEO) ID: GPL96) [32]. These results were

要素技術 (グローバル正規化)

- 「各サンプルから測定されたmRNAの全体量は一定」と仮定
 - マイクロアレイ上の遺伝子数が少ない場合は非現実的だが、数千～数万種類の遺伝子が搭載されているので妥当(だろう)



	sample1	sample2		sample1	sample2	
gene1	10.5	12.4	正規化 ➔	gene1	14.2	15.3
gene2	6.4	7.1		gene2	8.7	8.8
gene3	8.0	8.5		gene3	10.9	10.5
gene4	10.8	11.4		gene4	14.7	14.1
gene5	5.6	6.7		gene5	7.6	8.3
gene6	8.4	8.9		gene6	11.4	11.0
gene7	6.2	7.0		gene7	8.4	8.6
gene8	6.1	6.8		gene8	8.3	8.4
gene9	6.6	6.5		gene9	9.0	8.0
gene10	5.1	5.8		gene10	6.9	7.2
平均値	7.4	8.1	平均値	10.0	10.0	

チップごとに独立して正規化 (per-array basis)

要素技術 (Quantile正規化)

- 「シグナル強度の順位が同じなら値も同じ」と仮定

正規化前

s1	s2
10.5	12.4
6.4	7.1
8.0	8.5
10.8	11.4
5.6	6.7
8.4	8.9
6.2	7.0
6.1	6.8
6.6	6.5
5.1	5.8

列ごとに
ソート
→

s1	s2
5.1	5.8
5.6	6.5
6.1	6.7
6.2	6.8
6.4	7.0
6.6	7.1
8.0	8.5
8.4	8.9
10.5	11.4
10.8	12.4

行ごとの平
均を算出
→

Ave.
5.5
6.1
6.4
6.5
6.7
6.9
8.3
8.7
11.0
11.6

対応する行の要素
の元の位置に平均
値を代入
→

正規化後

s1	s2
11.0	11.6
6.7	6.9
8.3	8.3
11.6	11.0
6.1	6.4
8.7	8.7
6.5	6.7
6.4	6.5
6.9	6.1
5.5	5.5

data19.txt

データセット中のサンプル数が変わると結果が変わる (multi-array basis)

要素技術 (Quantile正規化)

- 「シグナル強度の順位が同じなら値も同じ」と仮定

正規化前				正規化前				正規化後		
s1	s2	s3		s1	s2	s3	Ave.	s1	s2	s3
10.5	12.4	9.3	列ごとに ソート →	5.1	5.8	3.5	4.8	10.9	12.1	8.9
6.4	7.1	13.2		5.6	6.5	5.2	5.8	7.0	7.2	12.1
8.0	8.5	10.7		6.1	6.7	6.1	6.3	8.5	8.5	10.9
10.8	11.4	7.8		6.2	6.8	7.3	6.8	12.1	10.9	7.2
5.6	6.7	5.2		6.4	7.0	7.7	7.0	5.8	6.3	5.8
8.4	8.9	9.0		6.6	7.1	7.8	7.2	8.9	8.9	8.5
6.2	7.0	6.1		8.0	8.5	9.0	8.5	6.8	7.0	6.3
6.1	6.8	7.3		8.4	8.9	9.3	8.9	6.3	6.8	6.8
6.6	6.5	7.7		10.5	11.4	10.7	10.9	7.2	5.8	7.0
5.1	5.8	3.5		10.8	12.4	13.2	12.1	4.8	4.8	4.8

data19_plus1.txt

データセット中のサンプル数が変わると結果が変わる (multi-array basis)

The impact of quantile and rank normalization procedures on the power of gene differential expression analysis.

Qiu X, Wu H, Hu R.

Department of Biostatistics and Computational Biology, University of Rochester, 601 Elmwood Rochester, New York 14642, USA. huruizg@hotmail.com.

Abstract

BACKGROUND: Quantile and rank normalizations are two widely used pre-processing methods designed to remove technological noise presented in genomic data. Subsequent analysis such as gene differential expression analysis is usually based on normalized expression data. In this study, we find that these normalization procedures can have a profound impact on gene differential expression analysis, especially in terms of testing power.

RESULTS: We conduct theoretical derivations to show that the testing power of gene differential expression analysis based on quantile or rank normalized gene expressions can be improved with fixed sample size no matter how strong the gene differentiation effects are. Extensive simulation analyses and find the results corroborate theoretical predictions.

CONCLUSIONS: Our finding may explain why genes with well documented structures are not always detected in microarray analysis. It provides new insights in microarray design and will help practitioners in selecting proper normalization procedures.

Evaluation of normalization methods in mammalian microRNA-Seq data.

Garmire LX, Subramaniam S.

Department of Bioengineering, Jacobs School of Engineering, University of California at San Diego, La Jolla, California 92093-0412, USA. lgarmire@gmail.com

Abstract

Simple total tag count normalization is inadequate for microRNA sequencing data generated from the next generation sequencing technology. However, so far systematic evaluation of normalization methods on microRNA sequencing data is lacking. We comprehensively evaluate seven commonly used normalization methods including global normalization, Lowess normalization, Trimmed Mean Method (TMM), quantile normalization, scaling normalization, variance stabilization, and invariant method. We assess these methods on two individual experimental data sets with the empirical statistical metrics of mean square error (MSE) and Kolmogorov-Smirnov (K-S) statistic. Additionally, we evaluate the methods with results from quantitative PCR validation. Our results consistently show that Lowess normalization and quantile normalization perform the best, whereas TMM, a method applied to the RNA-Sequencing normalization, performs the worst. The poor performance of TMM normalization is further evidenced by abnormal results from the test of differential expression (DE) of microRNA-Seq data. Comparing with the models used for DE, the choice of normalization method is the primary factor that affects the results of DE. In summary, Lowess normalization and quantile normalization are recommended for normalizing microRNA-Seq data, whereas the TMM method should be used with caution.

Brief Bioinform. 2012 Sep 17. [Epub ahead of print]

A comprehensive evaluation of normalization methods for Illumina high-throughput RNA sequencing data analysis.

Dillies MA, Rau A, Aubert J, Hennequet-Antier C, Jeanmougin M, Servant N, Keime C, Marot G, Castel D, Estelle J, Guernec G, Jaqla B, Jouneau L, Laloë D, Le Gall C, Schaeffer B, Le Crom S, Guedi M, Jaffrézic F; on behalf of The French StatOmique Consortium.

Abstract

During the last 3 years, a number of approaches for the normalization of RNA sequencing data have emerged in the literature, differing both in the type of bias adjustment and in the statistical strategy adopted. However, as data continue to accumulate, there has been no clear consensus on the appropriate normalization method to be used or the impact of a chosen method on the downstream analysis. In this work, we focus on a comprehensive comparison of seven recently proposed normalization methods for the differential analysis of RNA-seq data, with an emphasis on the use of varied real and simulated datasets involving different species and experimental designs to represent data characteristics commonly observed in practice. Based on this comparison study, we propose practical recommendations on the appropriate normalization method to be used and its impact on the differential analysis of RNA-seq data.

マイクロアレイ

RNA-seq

正規化はRNA-seqでも議論されている

前処理法の違いを実感してみよう

■ MAS5 (Hubbell et al., *Bioinformatics*, 18: 1585–92, 2002)

- 特徴: アレイごとに独立して前処理を実行 (per-array basis)
- 正規化: グローバル正規化

■ RMA (Irizarry et al., *Biostatistics*, 4: 249–64, 2003)

- 特徴: 読み込んだ複数サンプル (複数アレイ) の情報を用いて前処理を実行 (multi-array basis)
- 正規化: quantile正規化 (プローブレベルデータに対して実行)

■ RMX (Kohl et al., *BMC Bioinformatics*, 11: 583, 2010)

- 教科書中のRobLoxBioCと同じ方法

- [正規化 | Affymetrix GeneChip | について](#) (last modified 2013/09/02)
- 正規化 | Affymetrix GeneChip | [frma \(McCall 2010\)](#) (last modified 2013/08/21)
- 正規化 | Affymetrix GeneChip | [rmx \(Kohl 2010\)](#) (last modified 2013/11/19) 推奨
- 正規化 | Affymetrix GeneChip | [GRSN \(Pelz 2008\)](#) (last modified 2013/05/27)
- 正規化 | Affymetrix GeneChip | [Hook \(Binder 2008\)](#) (last modified 2013/05/30)
- 正規化 | Affymetrix GeneChip | [DFW \(Chen 2007\)](#) (last modified 2013/08/20)
- 正規化 | Affymetrix GeneChip | [FARMS \(Hochreiter 2006\)](#) (last modified 2013/08/20)
- 正規化 | Affymetrix GeneChip | [multi-mgMOS \(Liu 2005\)](#) (last modified 2013/08/21)
- 正規化 | Affymetrix GeneChip | [GCRMA \(Wu 2004\)](#) (last modified 2013/08/21)
- 正規化 | Affymetrix GeneChip | [PLIER \(Affymetrix 2004\)](#) (last modified 2013/08/21)
- 正規化 | Affymetrix GeneChip | [VSN \(Huber 2002\)](#) (last modified 2013/08/21)
- 正規化 | Affymetrix GeneChip | [RMA \(Irizarry 2003\)](#) (last modified 2013/08/21)
- 正規化 | Affymetrix GeneChip | [MAS5.0 \(Hubbell 2002\)](#) (last modified 2013/11/25)
- 正規化 | Affymetrix GeneChip | [MBEI \(Li 2001\)](#) (last modified 2013/08/21)

3つの前処理
法をやります

正規化 | Affymetrix GeneChip | RMA (Irizarry_2003)

Affymetrix chip (GeneChip™)を用いて得られた*.CELファイルを元に、RMA(Irizarry et al., Biostatistics, 2003)アルゴリズムを用いてSummary scoreを算出。

「ファイル」-「ディレクトリの変更」

1. (CELファイルがあるディレクトリ)

```

out_f <- "hoge1.txt"
#必要なパッケージをロード
library(affy)
#データファイルの読み込み
hoge <- ReadAffy()
#本番
eset <- rma(hoge)
#ファイルに保存
write.exprs(eset, file=out_f)

```

3つのコードの主な違いは、前処理法の違いを表す関数名とパッケージ名部分

正規化 | Affymetrix GeneChip | MAS5.0 (Hubbell_2002)

Affymetrix chip (GeneChip™)を用いて得られた*.CELファイルを元に、MAS5.0 (Hubbell et al., Bioinformatics, 2002)アルゴリズムを用いてSummary scoreを算出するやり方を示します。低発現領域でのばらつきが大きいことが指摘をすれば決して悪い方法ではない

のばらつきが大きいことが指摘をすれば決して悪い方法ではない
レイごとに独立して正規化を行う利点があります。

「ファイル」-「ディレクトリの変更」

1. (CELファイルがあるディレクトリ)

```

out_f <- "hoge1.txt"
#必要なパッケージをロード
library(affy)
#データファイルの読み込み
hoge <- ReadAffy()
#本番
eset <- mas5(hoge)
#対数変換
summary(exprs(eset))
exprs(eset)[exprs(eset) < 1] <- 1
summary(exprs(eset))
exprs(eset) <- log(exprs(eset), 2)
#ファイルに保存
write.exprs(eset, file=out_f)

```

正規化 | Affymetrix GeneChip | rmx (Kohl 2010)

RobLoxBioCというRパッケージ中に実装されているrobsummarization法です。論文中にMAS5の拡張版と書いてありますが、論文に書かれているように、サンプルごとに独立して正規化を前のデータになっているので、robloxbioc関数を用いた代替したものを出力しています。

「ファイル」-「ディレクトリの変更」で適切なディレクトリへ移動

1. (CELファイルがあるディレクトリ上で)手元にあるCELファイルを読み込み

```

out_f <- "hoge1.txt"
#必要なパッケージをロード
library(RobLoxBioC)
#データファイルの読み込み(*.CELファイル)
hoge <- ReadAffy()
#本番
eset <- robloxbioc(hoge)
#対数変換
summary(exprs(eset))
exprs(eset)[exprs(eset) < 1] <- 1
summary(exprs(eset))
exprs(eset) <- log(exprs(eset), 2)
#ファイルに保存
write.exprs(eset, file=out_f)

```

hoge - GSE7623_24samples
フォルダ中には、実行後のファイルがある。実際にやるのはGSE7623_02samplesのみ

hoge - GSE7623_24samples
フォルダにディレクトリ変更して前処理法を実行。テンプレートスクリプトは出力ファイル名が同じことに注意

#出力ファイル名を指定してout_fに格納

#パッケージの読み込み

#*.CELファイルの読み込み

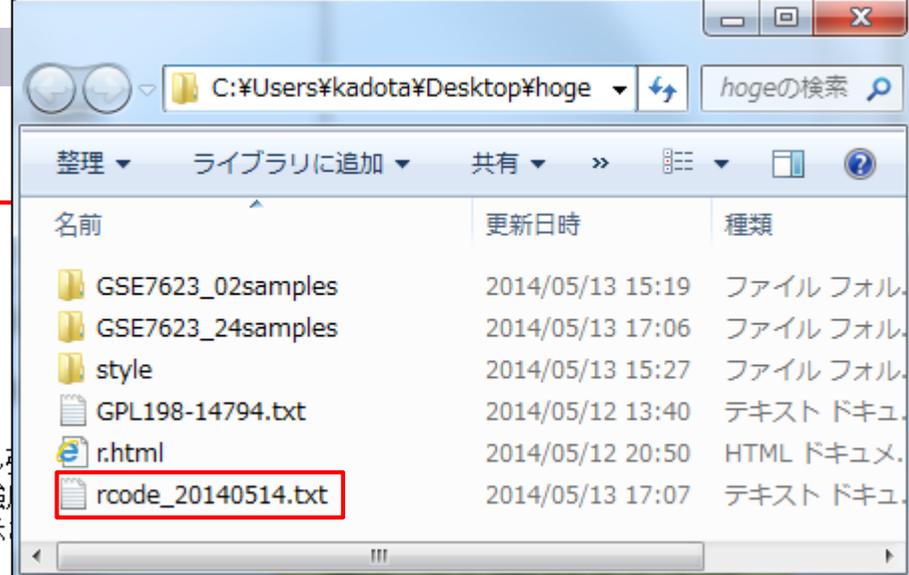
#rmxを実行し、結果をesetに保存

#得られたesetの遺伝子発現行列のシグナル強度
#対数変換 (log2) できるようにシグナル強度が
#上記処理後のシグナル強度分布を再び表示させ
#底を2として対数変換

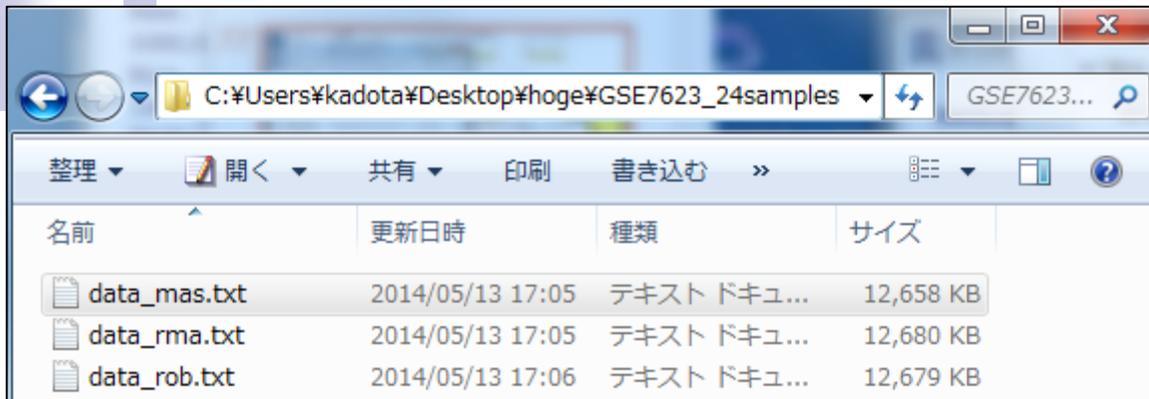
#結果を指定したファイル名で保存

門田のやり方

```
#####↓
### MAS5 ###↓
#####↓
out_f <- "data_mas.txt"← #出力ファイル名を指定してout_fに格納↓
library(affy) #パッケージの読み込み↓
hoge <- ReadAffy() #*.CELファイルの読み込み↓
eset <- mas5(hoge) #MASを実行し、結果をesetに保存↓
summary(exprs(eset)) #得られたesetの遺伝子発現行列のシグナル強度分布を表示↓
exprs(eset)[exprs(eset) < 1] <- 1 #対数変換 (log2) できるようにシグナル強度が1未満のものに1を代入↓
summary(exprs(eset)) #上記処理後のシグナル強度分布を再び表示↓
exprs(eset) <- log(exprs(eset), 2) #底を2として対数変換↓
write.exprs(eset, file=out_f) #結果を指定したファイル名で保存↓
↓
#####↓
### RMA ###↓
#####↓
out_f <- "data_rma.txt"← #出力ファイル名を指定してout_fに格納↓
library(affy) #パッケージの読み込み↓
hoge <- ReadAffy() #*.CELファイルの読み込み↓
eset <- rma(hoge) #RMAを実行し、結果をesetに保存↓
write.exprs(eset, file=out_f) #結果を指定したファイル名で保存↓
↓
#####↓
### RMX (RobLoxBioC) ###↓
#####↓
out_f <- "data_rob.txt"← #出力ファイル名を指定してout_fに格納↓
library(RobLoxBioC) #パッケージの読み込み↓
hoge <- ReadAffy() #*.CELファイルの読み込み↓
eset <- robloxbioc(hoge) #rmxを実行し、結果をesetに保存↓
summary(exprs(eset)) #得られたesetの遺伝子発現行列のシグナル強度分布を表示↓
exprs(eset)[exprs(eset) < 1] <- 1 #対数変換 (log2) できるようにシグナル強度が1未満のものに1を代入↓
summary(exprs(eset)) #上記処理後のシグナル強度分布を再び表示させて確認↓
exprs(eset) <- log(exprs(eset), 2) #底を2として対数変換↓
write.exprs(eset, file=out_f) #結果を指定したファイル名で保存↓
←
```



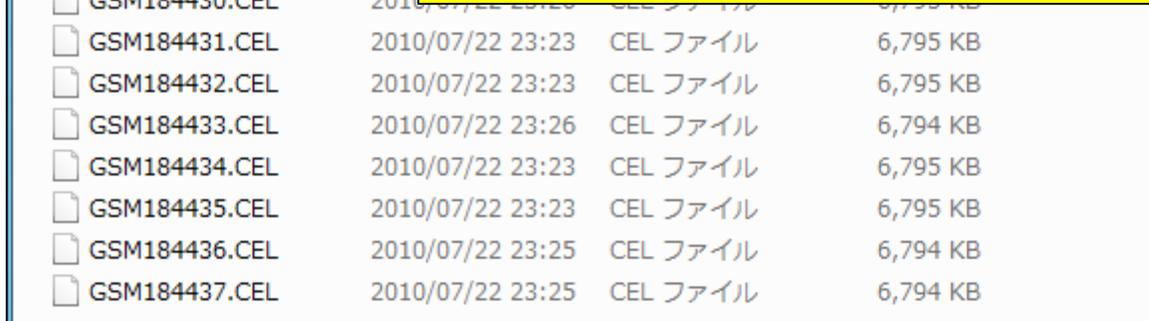
メモ帳やワードパッドなどのテキストエディタを開いて、出力ファイル名などを適宜変更した一連のコードをファイルとして保存しています。プログラムの実行時間は7~8分程度。



data_mas.txt 24サンプル(24列)

	A	B	C	D	E	F	G
1		GSM184414.CEL	GSM184415.CEL	GSM184416.CEL	GSM184417.CEL	GSM184418.CEL	...
2	1367452_at	12.78	12.45	12.81	12.30	12.59	
3	1367453_at	11.80	12.15	11.94	11.97	11.85	
4	1367454_at	11.39	11.16	11.15	11.21	11.54	
5	1367455_at	12.36	12.53	12.43	12.60	12.44	
6	1367456_at	13.45	13.54	13.55	13.63	13.37	
7	1367457_at	10.40	10.70	10.48	10.46	10.14	
8	1367458_at	9.93	10.24	9.97	9.96	8.70	
9	1367459_at	13.83	13.71	13.95	13.70	13.77	
10	1367460_at	13.36	13.55	13.48	13.43	13.54	
11	1367461_at	10.84	11.32	10.98	11.05	10.40	
12	1367462_at	13.47	13.39	13.44	13.43	13.37	
13	1367463_at	14.05	14.06	14.10	13.86	13.79	
14	1367464_at	10.84	11.16	11.09	11.34	11.46	
15	...						

31099 probesetIDs
(31099行)



MAS正規化法同士の結果を比較

GSE7623_24samples

24サンプル(24列)

	A	B	C	D	E	F	G
1		GSM184414.CEL	GSM184415.CEL	GSM184416.CEL	GSM184417.CEL		
2	1367452_at	12.78	12.45	12.81	12.30		
3	1367453_at	11.80	12.15	11.94	11.97		
4	1367454_at	11.39	11.16	11.15	11.21		
5	1367455_at	12.36	12.53	12.43	12.60		
6	1367456_at	13.45	13.54	13.55	13.63		
7	1367457_at	10.40	10.70	10.48	10.46		
8	1367458_at	9.93	10.24	9.97	9.96		
9	1367459_at	13.83	13.71	13.95	13.70		
10	1367460_at	13.36	13.55	13.48	13.43		
11	1367461_at	10.84	11.32	10.98	11.05		
12	1367462_at	13.47	13.39	13.44	13.43		
13	1367463_at	14.05	14.06	14.10	13.86		
14	1367464_at	10.84	11.16	11.09	11.34		
15	...						

GSE7623_02samples 2サンプル(2列)

	A	B	C
1		GSM184414.CEL	GSM184415.CEL
2	1367452_at	12.78	12.45
3	1367453_at	11.80	12.15
4	1367454_at	11.39	11.16
5	1367455_at	12.36	12.53
6	1367456_at	13.45	13.54
7	1367457_at	10.40	10.70
8	1367458_at	9.93	10.24
9	1367459_at	13.83	13.71
10	1367460_at	13.36	13.55
11	1367461_at	10.84	11.32
12	1367462_at	13.47	13.39
13	1367463_at	14.05	14.06
14	1367464_at	10.84	11.16
15	...		

MASはアレイごとに独立して前処理を実行するので(サンプル数の増減にかかわらず)同一サンプル間で得られる数値情報は不変。

RMA正規化法同士の結果を比較

GSE7623_24samples

24サンプル(24列)

	A	B	C	D	E	F	G
1		GSM184414.CEL	GSM184415.CEL	GSM184416.CEL	GSM184417.CEL		
2	1367452_at	10.52	10.23	10.35	10.11		
3	1367453_at	9.66	10.05	9.90	9.82		
4	1367454_at	9.65	9.40	9.44	9.45		
5	1367455_at	10.76	11.10	10.82	11.03		
6	1367456_at	11.71	11.60	11.59	11.49		
7	1367457_at	8.96	8.77	8.74	8.74		
8	1367458_at	8.28	8.55	8.66	8.43		
9	1367459_at	11.81	11.66	11.70	11.52		
10	1367460_at	11.63	11.62	11.48	11.51		
11	1367461_at	9.38	9.47	9.41	9.33		
12	1367462_at	11.94	11.75	11.89	11.66		
13	1367463_at	12.38	12.08	12.34	12.02		
14	1367464_at	9.48	9.61	9.63	9.58		
15	...						

GSE7623_02samples 2サンプル(2列)

	A	B	C
1		GSM184414.CEL	GSM184415.CEL
2	1367452_at	10.53	10.22
3	1367453_at	9.91	10.17
4	1367454_at	9.68	9.54
5	1367455_at	10.69	10.85
6	1367456_at	11.60	11.51
7	1367457_at	8.89	8.93
8	1367458_at	8.17	8.47
9	1367459_at	11.98	11.73
10	1367460_at	11.60	11.76
11	1367461_at	9.02	9.11
12	1367462_at	11.88	11.68
13	1367463_at	12.41	12.20
14	1367464_at	9.43	9.62
15	...		

課題1: RMAは同一サンプル間で得られる数値が異なっていることがわかる。この理由を簡潔に説明せよ。

課題2: RMX(RobLoxBioC)についても同様の比較を行い、正規化の特徴について簡潔に述べよ(per-array basis or multi-array basis)。ヒントは教科書p39の表2-1。

教科書 § 2-2-2～ § 2-2-4について

■ § 2-2-2 データの正規化(基礎)

- 行列データへのアクセスの基本をおさらい。列名変更。
- summary関数やapply関数。箱ひげ図をpng形式で保存。

■ § 2-2-3 データの正規化(計算例)

- MAS5前処理法を例として、警告メッセージへの対応やサブセットでの実行、プローブごとのシグナル強度の抽出、プローブ配列情報取得(GGRNAと同じような機能)。
- 折れ線グラフの作成手順などを折りませながら、数式の解読が苦手なヒト向けに、重みつき平均の一種であるTukey's biweight estimator計算手順の解説を通じて、重みをつけるという概念の具現化や用いるパラメータの意味合いや感覚を述べている。また、一連の作業を繰り返して、より頑健な値を得るというひらめきやその具体的事例としてRobLoxBioCの計算例を示している。本書の醍醐味的部分!

■ § 2-2-4 データの正規化(その他)

- RMAの改良版開発に至る背景(quantile正規化時にサンプル数の増減で結果が変わること)、およびプローブ効果、バッチ効果、トレーニングセット、リファレンス分布の例や基本的な考え方を述べている。また、refRMA, frozen RMA, IRON, frmaTools周辺の比較的最近提唱された方法の特徴についても述べている。

原著論文の引用はお忘れなく

イントロ | 発現データ取得 | ArrayExpress(Kauffmann 2009)

マイクロアレイで取得するGEO IDなどの利用「ファイル」
1. Affymetrix法(Irizar)

6. AffymetrixデータGSE781 ([Lenburg et al., BMC Cancer, 2003](#))のCELファイルを取得
合:
GSE781は2種類のアレイ(GPL96 and GPL97)を使っています。ファイルサイズが大い(程度?)ので注意してください。

```
param <- "GSE781" #入手したいIDを指定
#必要なパッケージをロード
library(ArrayExpress) #パッケージの読み込み
#前処理(データ取得)
hoge <- getAE(param, type="raw", extract=F
```

- [ArrayExpress: Kauffmann et al., Bioinformatics, 2009](#)
- [affy: Gautier et al., Bioinformatics, 2004](#)

Rパッケージやプログラムの多くは原著論文が存在する。各項目の最後のほうにRパッケージとその原著論文のPubMedへのリンクを張ってあります。

Bioinformatics. 2009 Aug 15;25(16):2092-4. doi: 10.1093/bioinformatics/btp354. Epub 2009 Jun 8.

Importing ArrayExpress datasets into R/Bioconductor.

[Kauffmann A¹](#), [Rayner TE](#), [Parkinson H](#), [Kapushesky M](#), [Lukk M](#), [Brazma A](#), [Huber W](#).

Author information

Abstract

SUMMARY: ArrayExpress is one of the largest public repositories of microarray datasets. R/Bioconductor provides a comprehensive suite of microarray analysis and integrative bioinformatics software. However, easy ways for importing datasets from ArrayExpress into R/Bioconductor have been lacking. Here, we present such a tool that is suitable for both interactive and automated use.

AVAILABILITY: The ArrayExpress package is available from the Bioconductor project at <http://www.bioconductor.org>. A users guide and examples are provided with the package.

PMID: 19505942 [PubMed - indexed for MEDLINE] PMCID: PMC2723004 [Free PMC Article](#)

