

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。

コード内のコピーは  
CTRL + ALT + 左クリック




# 農学生命情報科学 特論I 第2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





# 講義予定

- 第1回(2014年6月11日)
  - 西: NSG概論。現状や展望など。講義のみ
- 第2回(2014年6月18日)
  - 門田: データベース、データ取得、ファイル形式および変換、前処理
  - 教科書の1.3節周辺
- 第3回(2014年6月25日)
  - 門田: アセンブル、マッピング、カウント情報取得
  - 教科書の2.3節周辺
- 第4回(2014年7月2日)
  - 門田: クラスタリング、データ正規化、実験デザイン、分布(モデル)、発現変動解析
  - 教科書の3.3節周辺

## 授業の目標・概要

次世代シーケンサ(NGS)の普及により、以前は主にゲノム解析系で必要とされていた配列解析のためのスキルがトランスクリプトーム解析においても要求される時代になっています。本科目では、様々な局面で応用可能な配列解析系のスキルアップを目指し、RNAシーケンス(RNA-Seq)に基づく(非モデル生物の)トランスクリプトーム解析を題材とした実習を含む講義を行います。

# Contents (第2回)

- イントロダクション(Introduction)
  - NGSデータ概観(PacBioとIllumina)
  - NGSデータベース(DB)、データ形式(FASTQ形式)
  - SRADBパッケージを用いたデータ取得、エラーへの対処
- 前処理(Pre-processing)
  - qracパッケージを用いたQuality Control (QC)
- アダプター配列除去
  - 基本戦略(girafeパッケージ)
  - 昔は正常に動作していたのに…という例(QuasRパッケージ)
  - アダプター除去を含む様々なフィルタリングの組合せ(ShortReadパッケージ)
  - 課題


# 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
    - DNA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

光刺激

ヒト




- ・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

教科書p9の図1-8に示してあるように、実際には「遺伝子 = 転写物」ではない点に注意!

# トランスクリプトーム取得 (NGS)

## ■ 次世代シーケンサー (Illumina社の場合)


光刺激前 (T1) の目のトランスクリプトーム



数百塩基程度  
に断片化



アダプター配列  
を両末端に付加



配列決定

・ペアードエンド法  
断片配列の両末端が数百塩基以内の対の2種類の配列が得られる




約50-250塩基

・シングルエンド法



シングルエンド法  
の場合



# 様々なNGSプラットフォーム

- [イントロ](#) | 一般 | [配列取得](#) | [プロモーター配列](#) | [BSgenome](#)(last modified 2014/04/25)
- [イントロ](#) | 一般 | [配列取得](#) | [プロモーター配列](#) | [GenomicFeatures\(Lawrence 2013\)](#)(last modified 2014/04/23)
- [イントロ](#) | 一般 | [配列取得](#) | [トランスクリプトーム配列](#) | [公共DBから](#)(last modified 2014/04/02)
- [イントロ](#) | 一般 | [配列取得](#) | [トランスクリプトーム配列](#) | [biomaRt\(Durinck 2009\)](#)(last modified 2013/09/25)
- [イントロ](#) | NGS | [様々なプラットフォーム](#)(last modified 2014/06/08) **NEW**
- [イントロ](#) | NGS | [qPCRやmicroarrayなどとの比較](#)(last modified 2014/06/05) **NEW**
- [イントロ](#) | NGS | [Viewer](#)(last modified 2014/01/20)

## イントロ | NGS | [様々なプラットフォーム](#) **NEW**

NGS機器(プラットフォーム)もいくつかあります:

- 会社名: 製品名
- [Illumina: MiSeq, NextSeq 500, HiSeq 2500, HiSeq X Ten, ...](#)
- [Roche: GS FLX+ System, GS Junior+ System](#)
- [Life Technologies: SOLiD](#)
- [Life Technologies: Ion PGM System](#)
- [Pacific Biosciences: PacBio RS II System](#)
- [Dover社など「POLONATOR G.007」](#)
- ...

**Pacific Biosciences (PacBio)について:**

PacBio RS II Systemは最長で20,000bp以上(平均は4,500 bp)読めるようですが配列のqualityが若干(85%程度)劣るようです。しかしエラーの入る場所がランダムなようで多数決ルール(majority rule)でエラー補正がかなりうまくいらしいです。このロングリードでトランスクリプトーム配列決定(新規アインフォームの発見)をヒト([Sharon et al., 2013](#))やニワトリ([Thomas et al., 2014](#))で行った論文などが出始めています。

Smart-seq2の実験手順([Picelli et al., Nat Protoc., 2014](#))なども出ているようですね。葉緑体ゲノムでのアセンブリ性能評価([Ferrarini et al., BMC Genomics, 2013](#))もなされています。

# 実際のデータ

- [過去のお知らせ](#) (last modified 2014/04/21)
- [Rのインストールと起動](#) (last modified 2014/05/14) **NEW**
- [サンプルデータ](#) (last modified 2014/04/01)
- [書籍 | トランスクリプトームについて](#) (last modified 2014/05/12) **NEW**
- [書籍 | トランスクリプトーム解析 | 2.3.1 RNA-seqデータ\(FASTQファイル\)](#) (last modified 2014/05/12)

## サンプルデータ **NEW**

1. Illumina/36bp/single-end/human ([SRA000299](#)) data ([Marioni et al., Genome Res., 2008](#))  
「Kidney 7 samples vs Liver 7 samples」のRNA-seqの遺伝子発現行列データ([Supplemental Table S1](#))
25. Illumina HiSeq 2000/200bp/50bp/single-end/human ([SRA062939](#)) data ([Chan et al., Hum. Mol. Genet., 2013](#))
26. Illumina Genome Analyzer II/54bp/single-end/human ([SRP017142](#); [GSE42212](#)) data ([Neyret-Kahn et al., Genome Res., 2013](#))  
ヒト fibroblastsの2群間比較用データ: 3 proliferative samples vs. 3 Ras samples
27. Illumina HiSeq 2000 ([GPL14844](#))/50bp/single-end/Rat ([SRP037986](#); [GSE53960](#)) data ([Yu et al., Nat Commun., 2014](#))  
ラットの10組織×雌雄(2種類)×4種類の週齢(2, 6, 21, 104 weeks)×4 biological replicatesの計320サンプルからなるデータ。
28. Illumina GAIIX/76bp/paired-end/Drosophila or Illumina HiSeq 2000/100bp/paired-end/Drosophila ([SRP009459](#); [GSE33905](#)) data ([Graveley et al., Nature, 2011](#); [Brown et al., Nature, 2014](#))  
ショウジョウバエの様々な組織のデータ(modENCODE)。29 dissected tissue samplesのstrand-specific, paired-endの biological replicates (duplicates)があります。
29. Illumina HiSeq 2000/36bp/single-end/Arabidopsis ([SRP011435](#); [GSE36469](#)) data ([Huang et al., Development, 2012](#))  
シロイヌナズナの2群間比較用データ: 4 DEX-treated vs. 4 mock-treated
30. PacBio/xxx bp/Human ([xxx](#)) data ([Sharon et al., Nat Biotechnol., 2013](#))  
ヒトの長鎖RNA-seqデータです。配列長はリードによって異なります。
31. PacBio/xxx bp/Chicken ([SRP038897](#) by SRA; [SRP038897](#) by SRA) data ([Sharon et al., PLoS One, 2014](#))  
ニワトリの長鎖RNA-seqデータです。配列長はリードによって異なります。

PacBioのロングリードデータも出始めています

30. PacBio/xxx bp/Human (xxx) data (Sharon et al., Nat Biotechnol., 2013)  
 ヒトの長鎖RNA-seqデータ。配列長はリードによって異なります。
31. PacBio/xxx bp/Chicken (SRP038897 by DRA; SRP038897 by SRA) data  
 (Sharon et al., PLoS One, 2014)

32. ニ  
k-m  
(sar  
50増  
を10  
Cが

**DRASearch**  Send Feedback [Search Home](#) [DRA Home](#)

**SRP038897**

Study Detail		Navigation	
<b>Title</b>	Long-read sequencing of chicken transcripts and identification of new transcript isoforms.	Submission	SRA142153
<b>Study Type</b>	Transcriptome Analysis		SRA142158
	The chicken has long served as an	Experiment	SRX475467
		Sample	SRS561227

**DRASearch**  Send Feedback [Search Home](#) [DRA Home](#)

**SRX475467** [FASTQ](#) [SRA](#)

**Abstract**

Experiment Detail		Navigation	
<b>Title</b>	Chicken embryonic heart transcriptome sequencing	Submission	SRA142153
<b>Description</b>	Collecting embryonic chicken heart RNA Chicken eggs were stored at 4°C after laying and then incubated in Genesis Hova-Bators until tissue was harvested. Hearts were dissected from embryos at HH stages 18-20, 25, and 32 and immediately flash frozen in N2. The hearts were homogenized and suspended in TriZol (Life Technologies) by repipetting, and then total RNA was extracted into the aqueous phase, precipitated with isopropanol, washed with 75% ethanol and then resuspended into nuclease free water. RNA purification and cDNA synthesis mRNA were purified using the Strategene Absolutely mRNA purification kit: Briefly, the RNA were hybridized to oligo-dT magnetic beads,	Study	SRP038897
<b>Center Name</b>		Sample	SRS561227
		Run	SRR1177086

SRX475467 FASTQ SRA

サンプルデータ

## Experiment Detail

## Navigation

**Title** Chicken embryonic heart transcriptome sequencing

Collecting embryonic chicken heart RNA Chicken eggs were stored at 4°C after laying and then incubated in Genesis Hova-Bators until tissue was harvested. Hearts were dissected from embryos at HH stages 18-20, 25, and 32 and immediately flash frozen in N2. The hearts were homogenized and suspended in TriZol (Life Technologies) by resuspension, and then total RNA was

Submission [SRA142153](#) FASTQ

Study [SRP038897](#)

Sample [SRS561227](#)

Run [SRR1177086](#) FASTQ

SRR1177086 FASTQ SRA

## Run Detail

## Navigation

**Alias** Chicken embryonic heart transcriptome sequencing

**Instrument model**

**Date of run**

**Run center**

**Number of spots** 1,849,778

**Number of bases** 1,989,004,881

Submission [SRA142153](#) FASTQ

Study [SRP038897](#)

Experiment [SRX475467](#) FASTQ

Sample [SRS561227](#) FASTQ

READS (joined)

quality  show 10 rows << 1 / 184978 Page >>

Copyright©DNA Data Bank of Japan. All Rights Reserved

比較的新しい論文のリードごとの塩基配列情報は見られるものの、FASTQファイルがまだ生成されてなくてダウンロードができないこともある。

29. Illumina HiSeq 2000/36bp/single-end/Arabidopsis (SRP011435; GSE36469) data (Huang et al., Development)

シロイヌナズナの2群間比較用データ: 4 DEX-treated vs. 4 mock-treated

30. PacBio/xxx bp/Human (xxx) data (Sharon et al., Nat Biotechnol., 2013)

ヒトの長鎖RNA-seqデータです。配列長はリードによって異なります。

31. PacBio/xxx bp/Chicken (SRP038897 by DRA; SRP038897 by SRA) data (Sharon et al., PLoS One, 2014)

ニワトリの長鎖RNA-seqデータです。配列長はリードによって異なります。

・ サンプルデータ

DDBJ SRA (DRA)がだめな場合は、NCBI SRAにトライ

NCBI Resources How To

SRA SRA SRP038897 Save search Advanced

Display Settings: Full Send to:

**SRX475467: Chicken embryonic heart transcriptome sequencing**  
1 PACBIO\_SMRT (PacBio RS) run: 1.8M spots, 2G bases, 486.4Mb downloads

**Accession:** SRX475467

**Experiment design:** Collecting embryonic chicken heart RNA Chicken eggs were stored at 4°C after laying and then incubated in Genesis Hova-Bators until tissue was harvested. Hearts were dissected from embryos at HH stages 18-20, 25, and 32 and immediately flash frozen in N2. The hearts were homogenized and suspended in TriZol (Life Technologies) by repipetting, and then total RNA was extracted into the aqueous phase, precipitated with isopropanol, washed with 75% ethanol and then resuspended into nuclease free water. RNA purification and cDNA synthesis mRNA were purified using the Stratagene Absolutely mRNA purification kit: Briefly, the RNA were hybridized to oligo-dT magnetic beads, separated from solution on a magnetic stand, washed, and then resuspended into the kit's elution buffer. First strand cDNA synthesis was performed using the SMART cDNA kit (Clontech): The first cDNA strand was synthesized from purified poly-A RNA using the SMARTScribe MMLV Reverse Transcriptase (Clontech), the CDS III oligo-dT primer and the SMART IV primer for template switching in order to add a consistent 5' site for LD-PCR amplification using the CDS III primer and the 5' PCR Primer. CDSIII primer: 5'-ATTCTAGAGGCCGAGGCCGCGACATG-d(T)30N-1N-3' (N = A, G, C, or T; N-1 = A, G, or C) SMART IV oligonucleotide: 5'-AAGCAGTGGTATCAACGCAGAGTGGCCATTACGGCCGGG-3' 5' PCR Primer: 5'-AAGCAGTGGTATCAACGCAGAGT-3' Library preparation and sequencing The cDNA was run on an agarose gel and four separate size ranges were fractionated: 0-1 kb, 1-2 kb, 2-3 kb, and over 3kb. Each size fraction was extracted from the gel and SMRTbell libraries were created using the DNA Template Library Preparation kit (Pacific Biosciences): The cDNA was cleaned using Ampure beads and the ends were repaired. Blunt hairpin adapters were then ligated to the insert cDNA, exonucleases were added to remove failed ligation products, and SMRTbell templates with cDNA inserts were purified. The sequencing primer and then the polymerase were then sequentially annealed to the SMRTbell templates using the DNA Polymerase Binding kit (Pacific Biosciences). The MagBead loading kit was used to load annealed templates onto a Pacific Biosciences RS II sequencer, and sequencing was performed for each template library using the DNA Sequencing kit (Pacific Biosciences). Sequences containing both 5' and 3' adapters were identified, and the adapters and poly-A/T sequences were trimmed. The resulting sub-reads were then mapped using GMAP (21) (2012-07-20 release, default settings) to the galGal4 genome assembly (11).

**Submitted by:** Gladstone Institute

**Study summary:** SRP038897 • Long-read sequencing of chicken transcripts and identification of new transcript isoforms. • PRJNA239269 •  
[All experiments](#) • [Run Selector \(more...\)](#)

**Sample:** SAMN02650959 • Model organism or animal sample for Gallus gallus ([more...](#))

**Library:** PacBio embryonic chicken heart cDNA ([more...](#))

**Platform:** PacBio SMRT™ ([more...](#))

**Spot descriptor:**

1 forward

Total: 1 M spots, 2G bases, 486.4Mb

#	# of Spots	# of Bases	Size
1. <a href="#">SRR1177086</a>	1,849,778	2G	<a href="#">486.4Mb</a>

Study summary: [SRP038897](#) • Long-read sequencing of chicken transcripts and identification of new transcript isoforms. • [PRJNA239269](#)  
 All experiments • [Run Selector \(more...\)](#)  
 Sample: [SAMN02650959](#) • Model organism or animal sample for Gallus gallus ([more...](#))  
 Library: PacBio embryonic chicken heart cDNA ([more...](#))  
 Platform: PacBio SMRT™ ([more...](#))  
 Spot descriptor:  
 1 forward

Total: 1 M spots, 2G bases, 486.4Mb

#	# of Spots	# of Bases	Size
1. <a href="#">SRR1177086</a>	1,849,778	2G	<a href="#">486.4Mb</a>

• [サンプルデータ](#)

NCBI Site map All databases Search

Sequence Read Archive

Main Browse Search Download Submit Documentation Software Trace Archive Trace Assembly Trace Home Trace BLAST

Studies Samples Analyses Run Browser Run Selector Provisional SRA

Chicken embryonic heart transcriptome sequencing (SRR1177086) [Change accession...](#)

Metadata Reads Download

Run	Spots	Bases	Size	GC content	Published	Access Type
SRR1177086	1.8 M	2.0 Gbp	510.0 M	48.1%	2014-02-26	public

Quality graph ([bigger](#))

This run has 1 read per spot:

$\bar{L}=1075, \sigma=685.6, 100\%$

[Legend](#)

Experiment	Library												
<a href="#">SRX475467</a>	<table border="1"> <thead> <tr> <th>Name</th> <th>Platform</th> <th>Strategy</th> <th>Source</th> <th>Selection</th> <th>Layout</th> </tr> </thead> <tbody> <tr> <td>PacBio embryonic chicken heart cDNA</td> <td>PacBio SMRT™</td> <td>OTHER</td> <td>TRANSCRIPTOMIC</td> <td>cDNA</td> <td>SINGLE</td> </tr> </tbody> </table>	Name	Platform	Strategy	Source	Selection	Layout	PacBio embryonic chicken heart cDNA	PacBio SMRT™	OTHER	TRANSCRIPTOMIC	cDNA	SINGLE
Name	Platform	Strategy	Source	Selection	Layout								
PacBio embryonic chicken heart cDNA	PacBio SMRT™	OTHER	TRANSCRIPTOMIC	cDNA	SINGLE								

[Show design](#)

Biosample	Sample Description	Organism	Links
<a href="#">SAMN02650959</a> (SRS561227)		<a href="#">Gallus gallus</a>	<ul style="list-style-type: none"> <li><a href="#">Model organism or animal sample for Gallus gallus</a></li> <li><a href="#">PRJNA239269 [Gallus gallus]</a></li> </ul>

Bioproject	SRA Study	Title
<a href="#">PRJNA239269</a>	<a href="#">SRP038897</a>	Long-read sequencing of chicken transcripts and identification of new transcript isoforms.

[Show abstract](#)

リードごとの塩基配列情報を見る場合はここ

Study summary: SRP038897 • Long-read sequencing of chicken transcriptome and identification of new transcript isoforms. • PRJNA239269  
 All experiments • Run Selector (more...)  
 Sample: SAMN02650959 • Model organism or animal sample for Gallus gallus (more...)  
 Library: PacBio embryonic chicken heart cDNA (more...)  
 Platform: PacBio SMRT™ (more...)  
 Spot descriptor:  
 1 forward

Total: 1 run, 1.8M spots, 2G bases, 486.4Mb

#	Run	# of Spots	# of Bases	Size
1.	<a href="#">SRR1177086</a>	1,849,778	2G	486.4Mb

• サンプルデータ

NCBI Site map All databases Search

## Sequence Read Archive

Main Browse Search Download Submit Documentation Software Trace Archive Trace Assembly Trace Home Trace BLAST

Studies Samples Analyses **Run Browser** Run Selector Provisional SRA

### Chicken embryonic heart transcriptome sequencing (SRR1177086) [Change accession...](#)

Metadata Reads Download

Filter:  Find Filtered Download [What does it do?](#)  
[What can the filter be applied to?](#)

< 1 1 184978 >

View:  biological reads  technical reads  quality scores [advanced options](#)

**Read**

1. [SRR1177086.1 SRS561227](#)  
 name: 1, member: default

2. [SRR1177086.2 SRS561227](#)  
 name: 2, member: default

3. [SRR1177086.3 SRS561227](#)  
 name: 3, member: default

4. [SRR1177086.4 SRS561227](#)  
 name: 4, member: default

5. [SRR1177086.5 SRS561227](#)  
 name: 5, member: default

6. [SRR1177086.6 SRS561227](#)  
 name: 6, member: default

7. [SRR1177086.7 SRS561227](#)  
 name: 7, member: default

8. [SRR1177086.8 SRS561227](#)  
 name: 8, member: default

9. [SRR1177086.9 SRS561227](#)  
 name: 9, member: default

10. [SRR1177086.10 SRS561227](#)  
 name: 10, member: default

```
>gnl|SRA|SRR1177086.1 1
ATAGTTACCCCCACTCTTCAGCTACTCTGATTTTTACAATTAACCTCACAGCTATATAAT
ACATGCTGCTATACACCAATTTCAATAGCGGAAATTTTTAACTGGGTAGCTATTTTCATG
AGAATCTTCAGTTTCCGTATTTCTATCAACACTTAATTAACAGGTTAAGGAAGCAATATAT
TTTATTGTTGTTTCAGCACTGACTACTGTTTCTCTCTCTCCTTTGTTTTTTGTTTTTAT
GTATTACCCCTGCTTTCCTGCTAACCTCTGTGTAATTAAGTTAACTTGATATATTTTTT
ACTGAAATGACGAACATAGGTTTTAAGGAGAATTTTCTTCAATGAGCAATACCCATGAC
ATAGTAAACGACGACTCTTAGCCGTGTACACGCTGTTTAAATGATTTACTGTCAAGT
TTGTCCCAAAATGGGAATTTGTTTAAAGAACAAATGGACTAAATGATCTGCAGAAGACCTCAT
TCCAGACTTTAAATGGAATAACTTCCCTTATCGCATTTAGTTTGTGAACTTTGAAATCA
GTTTCAGGACGCACCTTATGCCCTAATTCATAGAACTTTTTTTCCAAATAATTGTGGAAAT
GATCATTTTAAATTACTGTCCGATTTT
```

最初のリードの塩基配列が表示されます。

Study summary: [SRP038897](#) • Long-read sequencing of chicken transcript and identification of new transcript isoforms. • [PRJNA239269](#)  
 All experiments • [Run Selector](#) (more...)  
 Sample: [SAMN02650959](#) • Model organism or animal sample for Gallus gallus (more...)  
 Library: PacBio embryonic chicken heart cDNA (more...)  
 Platform: PacBio SMRT™ (more...)  
 Spot descriptor:  
 1 forward

Total: 1 run, 1.8M spots, 2G bases, [486.4Mb](#) ?

#	Run	# of Spots	# of Bases	Size
1.	<a href="#">SRR1177086</a>	1,849,778	2G	<a href="#">486.4Mb</a>

• [サンプルデータ](#)

NCBI Site map All databases Search

## Sequence Read Archive

Main Browse Search Download Submit Documentation Software Trace Archive Trace Assembly Trace Home Trace BLAST

Studies Samples Analyses **Run Browser** Run Selector Provisional SRA

### Chicken embryonic heart transcriptome sequencing (SRR1177086) [Change accession...](#)

Metadata Reads Download

Filter:  Find Filtered Download [What does it do?](#)

[What can the filter be applied to?](#)

< 1 1 184978 >

View:  biological reads  technical reads  quality scores [advanced options](#)

**Read**

1. [SRR1177086.1 SRS561227](#)  
name: 1, member: default

2. [SRR1177086.2 SRS561227](#)  
name: 2, member: default

3. [SRR1177086.3 SRS561227](#)  
name: 3, member: default

4. [SRR1177086.4 SRS561227](#)  
name: 4, member: default

5. [SRR1177086.5 SRS561227](#)  
name: 5, member: default

6. [SRR1177086.6 SRS561227](#)  
name: 6, member: default

7. [SRR1177086.7 SRS561227](#)  
name: 7, member: default

8. [SRR1177086.8 SRS561227](#)  
name: 8, member: default

9. [SRR1177086.9 SRS561227](#)  
name: 9, member: default

10. [SRR1177086.10 SRS561227](#)  
name: 10, member: default

>gnl|SRA|SRR1177086.2 2  
 ATGGGGACAAC T GCTTCTGGGTGTTCCACTGAAGGGACCC TGAGCCAGCAATCTCCTGCA  
 CAATGGC CACTGACCAAGCTGAGAAGGCTGCCGATGACCCCAACCATCTGGGCAAAGGTGCT  
 ACGCCAGAACTCTGAGTCCCAATTGGGCTGGAAATCACTGGAGAGGCTTTTGCCAGCTATGCC  
 CTCAGTGACGAAAAACCTAACTTCCCTCCAACCTTTGATGTTCACGCCAAGGCTCAGTTCAGC  
 TTCGTGGT CACGGCTCCAAGGCC TGAATGCCCATTTGGCGGAAGCTTGAAGAACATCGATG  
 ACATTAGAGGTGCTTGGCAAAC TACCCAGCGAGCATGCATGCTTACATCCTCAGGGTGG  
 CCCAGGTGAACTTCAAGCTGCTTCTCCCACTGTATCCTGTGCATCTGTGGCCTGCCCGC  
 TATCCCAGTGATTT CACCCGAGAAGTT CATGCTGCGTGGGAGCAAGTTCTGTCCAGACA  
 ATTTCCCTGTCTCGACTGAGAAATACGATAAAGGCTTTCCACACACTGGGTTAGGCGA  
 CATGCATCCATGGCAACATAAAAAAAAACACTAGCAAAGTTCTGGGGCTAATTCTTCTTA  
 TGCACGTCCCAACCATCCCTGCGCAGGGGCC TACGCCACGCTCGTCAGACACCAATAAT  
 AATTAAC TG

2番目のリードを表示。リードによって長さが異なる

Study summary: [SRP038897](#) • Long-read sequencing of chicken transcripts and identification of new transcript isoforms. • [PRJNA239269](#)  
[All experiments](#) • [Run Selector \(more...\)](#)  
 Sample: [SAMN02650959](#) • Model organism or animal sample for Gallus gallus ([more...](#))  
 Library: PacBio embryonic chicken heart cDNA ([more...](#))  
 Platform: PacBio SMRT™ ([more...](#))  
 Spot descriptor:  
 1 forward

Total: 1 run, 1.8M spots, 2G bases, [486.4Mb](#)

#	Run	# of Spots	# of Bases	Size
1.	<a href="#">SRR1177086</a>	1,849,778	2G	<a href="#">486.4Mb</a>

• [サンプルデータ](#)

NCBI Site map All databases Search

Sequence Read Archive

Main Browse Search Download Submit Documentation Software Trace Archive Trace Assembly Trace Home Trace BLAST

Studies Samples Analyses **Run Browser** Run Selector Provisional SRA

Chicken embryonic heart transcriptome sequencing (SRR1177086) [Change accession...](#)

Metadata Reads Download

Filter:  Find Filtered Download [What does it do?](#)

[What can the filter be applied to?](#)

チェックを入れるとクオリティスコアも表示される

< 1 1 184978 > View:  biological reads  technical reads  quality scores [advanced options](#)

1. [SRR1177086.1 SRS561227](#)  
name: 1, member: default

2. [SRR1177086.2 SRS561227](#)  
name: 2, member: default

3. [SRR1177086.3 SRS561227](#)  
name: 3, member: default

4. [SRR1177086.4 SRS561227](#)  
name: 4, member: default

5. [SRR1177086.5 SRS561227](#)  
name: 5, member: default

6. [SRR1177086.6 SRS561227](#)  
name: 6, member: default

7. [SRR1177086.7 SRS561227](#)  
name: 7, member: default

8. [SRR1177086.8 SRS561227](#)  
name: 8, member: default

9. [SRR1177086.9 SRS561227](#)  
name: 9, member: default

10. [SRR1177086.10 SRS561227](#)  
name: 10, member: default

**Read**

>gnl|SRA|SRR1177086.2 2  
 ATGGGGACAAC T G C T T T G G G T G T T C C A C T G A A G G G A C C C T G A G C C A G C A A T C T C C T G C A  
 C A A T G G C A C T G A C C A A G C T G A G A A G G C T G C C G A T G A C C C C A C C A T C T G G G C A A A G G T G C T  
 A C G C C A G A A T C T G A G T C C C A T T G G G C T G G A A T C A C T G G A G A G G C T T T T G C C A G C T A T G C C  
 C T C A G T G A C G A A A A C C T A A C T T C C T C C A A C T T T G A T G T C A C G C C A A G G C T C A G T T C A G C  
 T T C G T G G T C A C G G C T C C A A G G C C T G A A T G C C C A T T G G C G G A A G C T T G A A G A A C A T C G A T G  
 A C A T T A G A G T G C T T G G C A A C T A C C C A G C G A G C A T G C A T G C T T A C A T C C T C A G G G T G G  
 C C C A G G T G A A C T T C A A G C T G C T T C C C A C T G T A T C C T G T G C A T C T G T G C C T G C C C G C  
 T A T C C C A G T G A T T T C A C C C G A G A A G T T C A T G C T G C G T G G G A G C A A G T T C C T G T C C A G A C A  
 A T T T C C T C T G T T C T C G A C T G A G A A A T A C G A T A A A G G C T T T C C A C A C A C T G G G T T A G G C G A  
 C A T G C A T C C A T G G C A A C A T A A A A A A A A C A C T A G C A A A G T T C T G G G G C T A A T T C T T C C T A  
 T G C A C G T C C C C A A C C A T C C C T G C G C A G G G G C C T C A G C C A C G C T C G T C A G A C A C C A A T A A T  
 A A T T A A C T G

**One channel quality score**

61  
 61  
 61  
 61

# 実際のデータ

PacBioデータの長さがよく分かります

## ■ Illumina社のGenome Analyzer

- SRA061145: Marioni et al., *Genome Res.*, **18**: 1509–1517, 2008

**Read**  
 >gnl|SRA|SRR002320.1 080226\_CMLIVERKIDNEY\_0007:1:1:112:735  
 GTGGTGGGGTTGGTATTTGGTTTCTCGTTTAAATTA

サンプルデータ1,  
36 bp

## ■ Applied Biosystems社のSOLiD4 System

- SRA000306: Cloonan et al., *Nat. Methods*, **5**: 613–619, 2008

**Read**  
 >gnl|SRA|SRR015249.1  
 S0014\_20071116\_1\_EB\_EBtranscriptome\_44\_35\_267\_F3 (Biological)  
 T20220213203000111000122223221121222

サンプルデータ5,  
25–35 bp

## ■ Illumina社のHiSeq 2000

- SRA062939: Chan et al., *Hum. Mol. Genet.*, **22**: 2662–2675, 2013

**Read**  
 >gnl|SRA|SRR649760.1 TAHITI:357:C1BLHACXX:6:1101:1211:2087  
 NATCGGAAGAGCACACGTCTGAACTCCAGTCACATGTCAGAAATCTCGTATGCCGTCTTCT  
 GCTTGAAAAAAGAAAGCTGTGAGTGGAGTGATGAG

サンプルデー  
タ25, 100 bp

# Contents (第2回)

- イン트로ダクション(Introduction)
  - NGSデータ概観(PacBioとIllumina)
  - NGSデータベース(DB)、データ形式(FASTQ形式)
  - SRADBパッケージを用いたデータ取得、エラーへの対処
- 前処理(Pre-processing)
  - qracパッケージを用いたQuality Control (QC)
- アダプター配列除去
  - 基本戦略(girafeパッケージ)
  - 昔は正常に動作していたのに…という例(QuasRパッケージ)
  - アダプター除去を含む様々なフィルタリングの組合せ(ShortReadパッケージ)
  - 課題

# NGS用データベース

- イントロ | 一般 | 配列取得 | トランスクリプトーム配列 | [biomaRt\(Durinck 2009\)](#) (last modified 2013/09/25)
- イントロ | NGS | [様々なプラットフォーム](#) (last modified 2014/06/08) **NEW**
- イントロ | NGS | [qPCRやmicroarrayなどとの比較](#) (last modified 2014/06/05) **NEW**
- イントロ | NGS | [Viewer](#) (last modified 2014/01/29)
- イントロ | NGS | 配列取得 | FASTQ or SRALite | [公共DBから](#) (last modified 2014/03/27)
- イントロ | NGS | 配列取得 | FASTQ or SRALite | [SRADB\(Zhu 2013\)](#) (last modified 2014/06/08) **NEW**
- [イントロ | NGS | アノテーション情報取得 | について](#) (last modified 2014/03/26)
- イントロ | NGS | アノテーション情報取得 | [GFF/GTF形式ファイル](#) (last modified 2014/04/11)

SRA, DRA, ENAが公式?!  
なNGS data repository

## イントロ | NGS | 配列取得 | FASTQ or SRALite | 公共DBから **NEW**

次世代シーケンサ(NGS)から得られる塩基配列データを公共データベースから取得する際には以下を利用すると便利です。

データの形式は基本的に [Sanger type](#) の FASTQ 形式です。

FASTA形式はリードあたり二行(idの行と配列の行)で表現します。

FASTQ形式はリードあたり4行(@から始まるidの行と配列の行、および+から始まるidの行とbase callの際のqualityの行)で表現します。

FASTQ形式は、Sangerのものがデファクトスタンダード(業界標準)です。かつてIlluminaのプラットフォームから得られるのはFASTQ-like formatという表現がなされていたようです([Cock et al., Nucleic Acids Res., 2010](#))。しかし少なくとも2013年頃には、IlluminaデータもBaseSpaceやCASAVA1.8のconfigureBclToFastq.plなどを用いることで業界標準のFASTQ形式(つまりSanger typeのデータ)に切り替えられるようであり、NCBI SRAなどの公共DBから取得するデータは全てはSanger typeのデータになっていたと思います([Kibukawa E., テクニカルサポートウェビナー, 2013](#))。

- [NCBI Sequence Read Archive \(SRA\): NCBI Resource Coordinators., Nucleic Acids Res., 2014](#)
- [DDBJ Sequence Read Archive \(DRA\): Kodama et al., Nucleic Acids Res., 2012](#)
- [European Nucleotide Archive \(ENA\): Leinonen et al., Nucleic Acids Res., 2011](#)
- [DBCLS SRA: Nakazato et al., PLoS One, 2013](#)

2次DBのDBCLS SRAも面白いサイトです

# DBCLS SRA

DBCLS SRA



DISCOVER


Interesting & Available SRA Data

全体をざっくりと知りたい  
場合によく利用しています

## Trends in SRA data


→ for more detail

### Species




<i>Homo sapiens</i>	209829
<i>Mus musculus</i>	39882
<i>Plasmodium falciparum</i>	17068
human metagenome	15984
human gut metagenome	15872
[TaxonID]	15005
<i>Streptococcus pneumoniae</i>	13467
<i>Staphylococcus aureus</i>	13205
<i>Saccharomyces cerevisiae</i>	11093
<i>Danio rerio</i>	9688
<i>Drosophila melanogaster</i>	9450
<i>Mycobacterium tuberculosis</i>	7996
<i>Anopheles gambiae</i>	7916
<i>Caenorhabditis elegans</i>	7272
soil metagenome	7054
<b>Total</b>	<b>639429</b> (experiments)

### Study Type




Whole Genome Sequencing	22176
Other	6119
Transcriptome Analysis	4562
Metagenomics	2864
Epigenetics	1525
Population Genomics	438
RNASeq	118
Exome Sequencing	93
Cancer Genomics	52
Pooled Clone Sequencing	32
Resequencing	28
Synthetic Genomics	8
Gene Regulation Study	5
<b>Total</b>	<b>37820</b> (studies)

### Platform



Illumina HiSeq 2000	368400
Illumina Genome Analyzer II	64215
454 GS FLX Titanium	53079
Illumina Genome Analyzer Ix	34562
Illumina MiSeq	28104
454 GS FLX	20227
Illumina Genome Analyzer	15418
unspecified	13081
454 GS Junior	7714
AB SOLiD 4 System	5679
...	
<b>Total</b>	<b>639429</b> (experiments)

### Disease



Genetic Predisposition to Disease	8
Breast Neoplasms	6
Disease Progression	6
Malaria	5
Lung Neoplasms	5
Obesity	4
Leukemia, Myeloid, Acute	4
Brain Neoplasms	3
Aneuploidy	3
Prostatic Neoplasms	3

# NGSデータ取得は全体像の理解が大事

- Chan et al., *Hum. Mol. Genet.*, **22**: 2662–2675, 2013
  - 論文中に、NGSデータはGene Expression Omnibus (GEO)中にGSE42960で登録したという記載あり

イントロ | NGS | 配列取得 | FASTQ or SRALite | 公共DBから **NEW**

NCBI SRA内で  
GSE42960で検索

次世代シーケンサ(NGS)から得られる塩基配列データを公共データベースから取得する際には以下を利用すると便利です。

データの形式は基本的にSanger typeのFASTQ形式です。

FASTA形式はリードあたり二行(idの行と配列の行)で表現します。

FASTQ形式はリードあたり4行(@から始まる行)で表現します。

FASTQ形式は、SangerのものがデファクトスタンダードなのはFASTQ-like formatという表現がなされた2013年頃には、IlluminaデータもBaseSpaceや


FASTQ形式(つまりSanger typeのデータ)こそは全てはSanger typeのデータになっていたと

[NCBI Sequence Read Archive \(SRA\):](#)

[DDBJ Sequence Read Archive \(DRA\):](#)

• [European Nucleotide Archive \(ENA\):](#)

• [DBCLS SRA: Nakazato et al., PLoS Or](#)



NCBI Resources How To Sign in to NCBI

SRA SRA GSE42960 Search Advanced Help

## SRA

The Sequence Read Archive (SRA) stores raw sequencing data from the next generation of sequencing platforms including Roche 454 GS System®, Illumina Genome Analyzer®, Applied Biosystems SOLiD® System, Helicos Heliscope®, Complete Genomics®, and Pacific Biosciences SMRT®.

Using SRA	Tools	Other Resources
<a href="#">Handbook</a>	<a href="#">BLAST</a>	<a href="#">SRA Home</a>
<a href="#">Download</a>	<a href="#">SRA Run browser</a>	<a href="#">Trace Archive</a>
<a href="#">E-Utilities</a>	<a href="#">Submit to SRA</a>	<a href="#">Trace Assembly</a>
<a href="#">Factsheet</a>	<a href="#">SRA software</a>	<a href="#">GenBank Home</a>

# NGSデータ取得は全体像の理解が大事

**Results: 4**

**Search in related databases**

Database	Access		all
	public	controlled	
BioSamples			
BioProject			
dbGaP			
GEO	5		5
Datasets			

**Find related data**

Database:

**Search details**

GSE42960 [All Fields]

**Display Settings:**  Summary **Send to:**

- [GSM1054024: FRDA015-Nico; Homo sapiens; RNA-Seq](#)  
1 ILLUMINA (Illumina HiSeq 2000) run: 36.5M spots, 3.6G bases, 2.2Gb downloads  
Accession: SRX210739
- [GSM1054023: FRDA015-UT; Homo sapiens; RNA-Seq](#)  
1 ILLUMINA (Illumina HiSeq 2000) run: 26.5M spots, 2.6G bases, 1.6Gb downloads  
Accession: SRX210738
- [GSM1054022: FRDA05-Nico; Homo sapiens; RNA-Seq](#)  
1 ILLUMINA (Illumina HiSeq 2000) run: 16.8M spots, 3.4G bases, 1.9Gb downloads  
Accession: SRX210737
- [GSM1054021: FRDA05-UT; Homo sapiens; RNA-Seq](#)  
1 ILLUMINA (Illumina HiSeq 2000) run: 22.4M spots, 4.5G bases, 2.5Gb downloads  
Accession: SRX210736

原著論文を読むことで Illumina HiSeq 2000を使っていること、2群間比較用データであることは既知。ニコチンアミド処理群 (Nico) 対 未処理群 (Untreated; UT)。

生データをダウンロードすると、9GB程度になる。

# NGSデータ取得は全体像の理解が大事

Results: 4

[GSM1054024: FRDA015-Nico; Homo sapiens; RNA-Seq](#)

1. 1 ILLUMINA (Illumina HiSeq 2000) run: 36.5M spots, 3.6G bases, 2.2Gb downloads  
Accession: SRX210739

[GSM1054023: FRDA015-Nico; Homo sapiens; RNA-Seq](#)

2. 1 ILLUMINA (Illumina HiSeq 2000) run: 36.5M spots, 3.6G bases, 2.2Gb downloads  
Accession: SRX210738

[GSM1054022: FRDA05-Nico; Homo sapiens; RNA-Seq](#)

3. 1 ILLUMINA (Illumina HiSeq 2000) run: 36.5M spots, 3.6G bases, 2.2Gb downloads  
Accession: SRX210737

[GSM1054021: FRDA05-Nico; Homo sapiens; RNA-Seq](#)

4. 1 ILLUMINA (Illumina HiSeq 2000) run: 36.5M spots, 3.6G bases, 2.2Gb downloads  
Accession: SRX210736

Display Settings:  Summary

Search in related databases

Database	Access
NCBI	all
public	controlled

GSM1054024, SRX210739, SRR649760, ...IDだらけです

NCBI Resources  How To

SRA SRA  Advanced

Display Settings:  Full Send to:

[SRX210739](#): [GSM1054024](#): [FRDA015-Nico](#); Homo sapiens; RNA-Seq  
1 ILLUMINA (Illumina HiSeq 2000) run: 36.5M spots, 3.6G bases, 2.2Gb downloads

Accession: SRX210739  
Experiment design: n/a  
Submitted by: GEO  
Study summary: [SRP017580](#) • GSE42960: The effect of nicotinamide on dysregulated genes associated with frataxin deficiency in FRDA. • [SRP017580](#) • [All experiments](#) • [Run Selector \(more...\)](#)  
Sample: [SAMN01831458](#) • [GSM1054024](#): [FRDA015-Nico \(more...\)](#)  
Library: [\(more...\)](#)  
Platform: [Illumina \(more...\)](#)  
Spot descriptor:

Experiment attributes:  
GEO Accession: [GSM1054024](#)

Total: 1 run, 36.5M spots, 3.6G bases, [2.2Gb](#) ? A

#	Run	# of Spots	# of Bases	Size
1.	<a href="#">SRR649760</a>	36,487,727	3.6G	<a href="#">2.2Gb</a>

ID: 28686

# NGSデータ取得は全体像の理解が大事

NCBI Site map All databases Search

Sequence Read Archive

Main Browse Search Download Submit Documentation Software Trace Archive Trace Assembly Trace Home Trace BLAST

Studies Samples Analyses **Run Browser** Run Selector Provisional SRA

**GSM1054024: FRDA015-Nico; Homo sapiens; RNA-Seq (SRR649760)** [Change accession...](#)

Metadata Reads Download

Run	Spots	Bases	Size	GC content	Published	Access Type
SRR649760	36.5 M	3.6 Gbp	2.4 G	49.6%	2013-04-03	public

Quality graph [\(bigger\)](#)

This run has 1 read per spot:

L=100, 100%

Legend

Experiment	Library												
<a href="#">SRX210739</a>	<table border="1"> <thead> <tr> <th>Name</th> <th>Platform</th> <th>Strategy</th> <th>Source</th> <th>Selection</th> <th>Layout</th> </tr> </thead> <tbody> <tr> <td></td> <td>Illumina</td> <td>RNA-Seq</td> <td>TRANSCRIPTOMIC</td> <td>cDNA</td> <td>PAIRED</td> </tr> </tbody> </table>	Name	Platform	Strategy	Source	Selection	Layout		Illumina	RNA-Seq	TRANSCRIPTOMIC	cDNA	PAIRED
Name	Platform	Strategy	Source	Selection	Layout								
	Illumina	RNA-Seq	TRANSCRIPTOMIC	cDNA	PAIRED								

Biosample	Sample Description	Organism	Links
<a href="#">SAMN01831458</a> (SRS380023)	source: primary cultured lymphocytes	<a href="#">Homo sapiens</a>	<ul style="list-style-type: none"> <li><a href="#">GSM1054024: FRDA015-Nico</a></li> <li><a href="#">GEO Sample</a></li> </ul>

Bioproject	SRA Study	Title
<a href="#">SRP017580</a>	<a href="#">SRP017580</a>	GSE42960: The effect of nicotinamide on dysregulated genes associated with frataxin deficiency in FRDA.

[Show abstract](#)

ある論文のデータ全体を指し示すIDの大元がGSE42960で、それに付随する実験IDのSRX210739、ランIDのSRR649760などの全体をまとめたデータをメタデータという。

Illuminaの場合はフローセルと呼ばれるスライドグラス程度の大きさのものをを用いて、一度に8サンプル分のsequencingが可能。この実験をラン(RUN)という。

# NGSデータ取得は全体像の理解が大事

NCBI Site map All databases Search

Sequence Read Archive

Main Browse Search Download Submit Documentation Software Trace Archive Trace Assembly Trace Home Trace BLAST

Studies Samples Analyses **Run Browser** Run Selector Provisional SRA

**GSM1054024: FRDA015-Nico; Homo sapiens; RNA-Seq (SRR649760)** [Change accession...](#)

Metadata **Reads** Download

Filter:  Find Filtered Download [What does it do?](#)

[What can the filter be applied to?](#)

< 1 1 3648773 >

View:  biological reads  technical reads  quality scores [advanced options](#)

**Read**

1. [SRR649760.1](#) [SRS380023](#)  
name: TAHITI:357:C1BLHACXX:6:1101:1211:2087  
member: default  
x: 1211, y: 2087  
< >

2. [SRR649760.2](#) [SRS380023](#)  
name: TAHITI:357:C1BLHACXX:6:1101:1181:2160  
member: default  
x: 1181, y: 2160  
< >

3. [SRR649760.3](#) [SRS380023](#)  
name: TAHITI:357:C1BLHACXX:6:1101:1321:2056  
member: default  
x: 1321, y: 2056  
< >

4. [SRR649760.4](#) [SRS380023](#)  
name: TAHITI:357:C1BLHACXX:6:1101:1272:2155  
member: default  
x: 1272, y: 2155  
< >

5. [SRR649760.5](#) [SRS380023](#)

```
>gnl|SRA|SRR649760.1 TAHITI:357:C1BLHACXX:6:1101:1211:2087
NATCGGAAGAGCACACGTCTGAACTCCAGTCACATGTCAGAAATCTCGTATGCCGTCTTCT
GCTTGA
```

リードごとの塩基配列情報を見る場合はここ

# NGSデータ取得は全体像の理解が大事

NCBI Site map All databases Search

Sequence Read Archive

Main Browse Search Download Submit Documentation Software Trace Archive Trace Assembly

Studies Samples Analyses **Run Browser** Run Selector Provisional SRA

**GSM1054024: FRDA015-Nico; Homo sapiens; RNA-Seq (SRR649760)**

Metadata Reads **Download**

Object	.sra
Run SRR649760	2.4 Gb <a href="#">HTTP</a> <a href="#">FTP</a>
Experiment SRX210739	2.4 Gb <a href="#">HTTP</a> <a href="#">FTP</a>
Study SRP017580	8.8 Gb <a href="#">HTTP</a> <a href="#">FTP</a>

(use [Aspera plugin](#) for fast download)

ダウンロードはここだが...

FASTQ形式ではなくSRA形式ファイルなので非推奨。

[1階層上のディレクトリへ](#)

12/17/2012 12:00午前	ディレクトリ	<a href="#">SRR633901</a>
12/17/2012 12:00午前	ディレクトリ	<a href="#">SRR633902</a>
01/16/2013 12:00午前	ディレクトリ	<a href="#">SRR649759</a>
01/16/2013 12:00午前	ディレクトリ	<a href="#">SRR649760</a>

[1階層上のディレクトリへ](#)

12/17/2012 12:00午前	2,676,898,597	<a href="#">SRR633901.sra</a>
--------------------	---------------	-------------------------------

# 様々なファイル形式…

- 情報量 : SRA-full > SRA-lite > FASTQ > FASTA
  - SRA-full: 塩基配列、クオリティ情報、Intensity情報など画像以外の全て
  - SRA-lite: SRA-fullからIntensity情報を除いて軽量化したもの
  - FASTQ: 塩基配列とクオリティ情報のみからなるもの
  - FASTA: 塩基配列のみからなるもの
  - ファイルサイズ (SRA-full : SRA-lite : FASTQ : FASTA)
    - 6 : 3 : 2 : 1
    - 例: SRA-fullはFASTQの約3倍

FASTQ形式ファイルの利用が基本

# FASTA形式とFASTQ形式

## ■ FASTA形式

- 1行目：“>”ではじまる一行のdescription行
- 2行目：配列情報

```
>SEQ_ID  
GATTTGGGGTTCAAAGCAGTATCGATCAAATAGTAAATCCATTTGTTCAACTCACAGTTT
```

## □ FASTQ形式

- 1行目：“@”ではじまる1行のdescription行
- 2行目：配列情報
- 3行目：“+”からはじまる1行(のdescription行)
- 4行目：クオリティ情報

```
@SEQ_ID  
GATTTGGGGTTCAAAGCAGTATCGATCAAATAGTAAATCCATTTGTTCAACTCACAGTTT  
+  
!' '* ((( (**+)) %%%++) (%%%) .1***-+*'') **55CCF>>>>>CCCCCCC65
```

[http://en.wikipedia.org/wiki/FASTQ\\_format](http://en.wikipedia.org/wiki/FASTQ_format)



# 公共DBからデータを取得する場合

- ENA Sequence Read Archive (ERA; 欧)
  - FASTQ形式でダウンロード可能
- NCBI Sequence Read Archive (SRA; 米)
  - SRA形式でダウンロード可能
- DDBJ Sequence Read Archive (DRA; 日)
  - FASTQ形式とSRA-Lite形式でダウンロード可能

ENAを概観しながら…

- ・サンプル数と得られるファイル数の違いなどを認識
- ・論文中の情報を頼りにSRAまたはSRP IDを入手する手続き
- ・メタデータ(全体像)情報を把握

## イントロ | NGS | 配列取得 | FASTQ or SRALite | 公共DBから **NEW**

次世代シーケンサ(NGS)から得られる塩基配列データを公共データベースから取得する際には以下を利用すると便利です。

データの形式は基本的に [Sanger type](#) の FASTQ 形式です。

FASTA形式はリードあたり二行(idの行と配列の行)で表現します。

FASTQ形式はリードあたり4行(@から始まるidの行と配列の行、および+から始まるidの行とbase callの際のqualityの行)で表現します。

FASTQ形式は、Sangerのものがデファクトスタンダード(業界標準)です。かつてIlluminaのプラットフォームから得られるのはFASTQ-like formatという表現がなされていたようです([Cock et al., Nucleic Acids Res., 2010](#))。しかし少なくとも2013年頃には、IlluminaデータもBaseSpaceやCASAVA1.8のconfigureBclToFastq.plなどを用いることで業界標準のFASTQ形式(つまりSanger typeのデータ)に切り替えられるようですし、NCBI SRAなどの公共DBから取得するデータは全てはSanger typeのデータになっていたと思います([Kibukawa E., テクニカルサポートウェビナー, 2013](#))。

◦ [NCBI Sequence Read Archive \(SRA\): NCBI Resource Coordinators., Nucleic Acids Res., 2014](#)

[DDBJ Sequence Read Archive \(DRA\): Kodama et al., Nucleic Acids Res., 2012](#)

[European Nucleotide Archive \(ENA\): Leinonen et al., Nucleic Acids Res., 2011](#)

[DBCLS SRA: Nakazato et al., PLoS One, 2013](#)



# NGSデータ取得は全体像の理解が大事

■ Chan et al., *Hum. Mol. Genet.*, **22**: 2662–2675, 2013

- 論文中に、NGSデータはGene Expression Omnibus (GEO)中にGSE42960で登録したという記載あり

ENAでGSE42960で検索

The screenshot shows the ENA website interface. At the top, there is a navigation bar with 'EMBL-EBI' logo and links for 'Services', 'Research', 'Training', and 'About us'. A search bar contains the text 'GSE42960' and a magnifying glass icon. A red arrow points to this search bar. Below the navigation bar is the ENA logo and the text 'European Nucleotide Archive'. A secondary navigation bar includes 'ENA Home', 'Search & Browse', 'Submit & Update', 'About ENA', 'Contact', and 'FAQ'. The main content area features a sidebar with 'NEWS AND ANNOUNCEMENTS' and a main section titled 'European Nucleotide Archive' with a description of the archive and two search boxes: 'Text search' and 'Sequence Search'. Both search boxes have 'Advanced Search' links next to them.

# NGSデータ取得は全体像の理解が大事

## ■ Chan et al., *Hum. Mol. Genet.*, **22**: 2662–2675, 2013

- 論文中に、NGSデータはGene Expression Omnibus (GEO)中にGSE42960で登録したという記載あり

**EBI Search**

GSE42960

Examples: VAV\_HUMAN, tpi1, Sulston ...

Help & Documentation | About EBI Search |  |

Search results for **GSE42960**

Showing 3 results out of 3 in All results

**Filter your results**

Source

- All results (3)
- Nucleotide sequences (2)
- Gene expression (1)

**Gene expression (1 results found)**

[E-GEO-42960 - The effect of nicotinamide on dysregulated genes associated with frataxin deficiency in FRDA.](#)

Source: ArrayExpress  
ID: E-GEO-42960

To investigate the efficacy of nicotinamide treatment using our ex-vivo primary lymphocyte model, we performed high-throughput RNA sequencing on libraries generated from untreated and nicotinamide treated samples. PBMC isolated from FRDA affected individuals were cultured to prepare the primary lymphocyte cell lines. The primary cultured cells were ...

**Nucleotide sequences (2 results found)**

[SRP017580](#)

**GSE42960:** The effect of nicotinamide on dysregulated genes associated with frataxin deficiency in FRDA.

Source: Study (Read/Analysis)  
ID: SRP017580

[SRA062939](#)

SRA062939  
Submitted by Gene Expression Omnibus on 17-DEC-2012

Source: Submission (Read/Analysis)  
ID: SRA062939

実質的にどちらでもよい

# NGSデータ取得は全体像の理解が大事

- Chan et al., *Hum. Mol. Genet.*, 22: 2662–2675, 2013

計6個のFASTQ形式  
ファイルになるようだ

ENAは全体像をつかみやすい

Download: [TEXT](#)

Navigation Read Files Attributes

Download files

View: [TEXT](#)

Select columns

Showing results 1 - 4 of 4 results

Study accession	Secondary study accession	Sample accession	Secondary sample accession	Experiment accession	Run accession	Scientific name	Instrument model	Library layout	Fastq files (ftp)	Fastq files (galaxy)	Submitted files (ftp)	Submitted files (galaxy)	CoL tax ID	CoL scientific name
<a href="#">SRP017580</a>	<a href="#">SRP017580</a>	<a href="#">SAMN01831455</a>	<a href="#">SRS380020</a>	<a href="#">SRX210736</a>	<a href="#">SRR633901</a>	<a href="#">Homo sapiens</a>	Illumina HiSeq 2000	PAIRED	<a href="#">File 1</a> <a href="#">File 2</a>	<a href="#">File 1</a> <a href="#">File 2</a>			<a href="#">6850099</a>	<a href="#">Homo sapiens Linnaeus, 1758</a>
<a href="#">SRP017580</a>	<a href="#">SRP017580</a>	<a href="#">SAMN01831456</a>	<a href="#">SRS380021</a>	<a href="#">SRX210737</a>	<a href="#">SRR633902</a>	<a href="#">Homo sapiens</a>	Illumina HiSeq 2000	PAIRED	<a href="#">File 1</a> <a href="#">File 2</a>	<a href="#">File 1</a> <a href="#">File 2</a>			<a href="#">6850099</a>	<a href="#">Homo sapiens Linnaeus, 1758</a>
<a href="#">SRP017580</a>	<a href="#">SRP017580</a>	<a href="#">SAMN01831457</a>	<a href="#">SRS380022</a>	<a href="#">SRX210738</a>	<a href="#">SRR649759</a>	<a href="#">Homo sapiens</a>	Illumina HiSeq 2000	PAIRED	<a href="#">File 1</a>	<a href="#">File 1</a>			<a href="#">6850099</a>	<a href="#">Homo sapiens Linnaeus, 1758</a>
<a href="#">SRP017580</a>	<a href="#">SRP017580</a>	<a href="#">SAMN01831458</a>	<a href="#">SRS380023</a>	<a href="#">SRX210739</a>	<a href="#">SRR649760</a>	<a href="#">Homo sapiens</a>	Illumina HiSeq 2000	PAIRED	<a href="#">File 1</a>	<a href="#">File 1</a>			<a href="#">6850099</a>	<a href="#">Homo sapiens Linnaeus, 1758</a>

For Aspera download, please [download and install Aspera Connect](#)

# NGSデータ取得は全体像の理解が大事

- Chan et al., *Hum. Mol. Genet.*, 22: 2662–2675, 2013

Navigation Read Files Attributes

This table contains the files for submission SRA062939

▶ [Download files](#)

View: [TEXT](#)

[Select columns](#)

Showing results 1 - 4 of 4 results

SRA, DRA, ENAどれもよいが、論文から得られるGSE IDを頼りに、「SRA IDまたはSRP ID」情報入手(SRA062939またはSRP017580)するとともに、メタデータ情報を把握すべし

Study accession	Secondary study accession	Sample accession	Secondary sample accession	Experiment accession	Run accession	Scientific name	Instrument model	Library layout	Fastq files (ftp)	Fastq files (galaxy)	Submitted files (ftp)	Submitted files (galaxy)	CoL tax ID	CoL scientific name
<a href="#">SRP017580</a>	<a href="#">SRP017580</a>	<a href="#">SAMN01831455</a>	<a href="#">SRS380020</a>	<a href="#">SRX210736</a>	<a href="#">SRR633901</a>	<a href="#">Homo sapiens</a>	Illumina HiSeq 2000	PAIRED	<a href="#">File 1</a> <a href="#">File 2</a>	<a href="#">File 1</a> <a href="#">File 2</a>			<a href="#">6850099</a>	<a href="#">Homo sapiens Linnaeus, 1758</a>
<a href="#">SRP017580</a>	<a href="#">SRP017580</a>	<a href="#">SAMN01831456</a>	<a href="#">SRS380021</a>	<a href="#">SRX210737</a>	<a href="#">SRR633902</a>	<a href="#">Homo sapiens</a>	Illumina HiSeq 2000	PAIRED	<a href="#">File 1</a> <a href="#">File 2</a>	<a href="#">File 1</a> <a href="#">File 2</a>			<a href="#">6850099</a>	<a href="#">Homo sapiens Linnaeus, 1758</a>
<a href="#">SRP017580</a>	<a href="#">SRP017580</a>	<a href="#">SAMN01831457</a>	<a href="#">SRS380022</a>	<a href="#">SRX210738</a>	<a href="#">SRR649759</a>	<a href="#">Homo sapiens</a>	Illumina HiSeq 2000	PAIRED	<a href="#">File 1</a>	<a href="#">File 1</a>			<a href="#">6850099</a>	<a href="#">Homo sapiens Linnaeus, 1758</a>
<a href="#">SRP017580</a>	<a href="#">SRP017580</a>	<a href="#">SAMN01831458</a>	<a href="#">SRS380023</a>	<a href="#">SRX210739</a>	<a href="#">SRR649760</a>	<a href="#">Homo sapiens</a>	Illumina HiSeq 2000	PAIRED	<a href="#">File 1</a>	<a href="#">File 1</a>			<a href="#">6850099</a>	<a href="#">Homo sapiens Linnaeus, 1758</a>

[ftp://ftp.sra.ebi.ac.uk/vol1/fastq/SRR633/SRR633901/SRR633901\\_1.fastq.gz](ftp://ftp.sra.ebi.ac.uk/vol1/fastq/SRR633/SRR633901/SRR633901_1.fastq.gz)

ダウンロードして得られるのは、Run IDから始まるSRR...という名前のファイル

# Contents (第2回)

- イン트로ダクション(Introduction)
  - NGSデータ概観(PacBioとIllumina)
  - NGSデータベース(DB)、データ形式(FASTQ形式)
  - SRADBパッケージを用いたデータ取得、エラーへの対処
- 前処理(Pre-processing)
  - qracパッケージを用いたQuality Control (QC)
- アダプター配列除去
  - 基本戦略(girafeパッケージ)
  - 昔は正常に動作していたのに…という例(QuasRパッケージ)
  - アダプター除去を含む様々なフィルタリングの組合せ(ShortReadパッケージ)
  - 課題

# RでNGSデータ取得

SRADBパッケージを利用して、R経由でNCBI SRAからFASTQファイル群をダウンロード可能。数時間かかるのでやらないで!

- イントロ | NGS | [qPCRやmicroarrayなどとの比較](#) (last modified 2014/06/05) **NEW**
- イントロ | NGS | [Viewer](#) (last modified 2014/01/29)
- イントロ | NGS | 配列取得 | FASTQ or SRALite | [公共DBから](#) (last modified 2014/03/27)
- イントロ | NGS | 配列取得 | FASTQ or SRALite | [SRADB\(Zhu 2013\)](#) (last modified 2014/06/08) **NEW**
- イントロ | NGS | [アノテーション情報取得](#) | について (last modified 2014/03/26)
- イントロ | NGS | [アノテーション情報取得](#) | GTF/GFF形式でダウンロード (last modified 2014/04/11)
- イントロ | NGS | [配列取得](#) | FASTQ or SRALite | SRADB(Zhu\_2013) **NEW**

SRADBパッケージを用いてRNA-seq配列を取得するやり方を示します。SRALite形式などでも取得可能なようですが、ここではFASTQ形式のRNA-seqデータ("SRP017580": [Chan et al., Hum. Mol. Genet., 2013](#))のgzip圧縮済みのFASTQファイルをダウンロードする場合:

## 1. RNA-seqデータ取得する場合:

論文中の記述  
下記情報を眺  
この2のサン  
1.5pM (SRX0

```
param <- "SRP017580"
#必要なパッケージをロード
library(SRADB)
```

Illumina HiSeq 2000のpaired-endデータです。計xファイル、合計x Gb程度の容量のファイルがダウンロードされます。東大の有線LANでx時間程度かかります。

```
param <- "SRP017580" #取得したいSRA IDを指定

#必要なパッケージをロード
library(SRADB) #パッケージの読み込み

#前処理
#sqlfile <- "SRAMetadb.sqlite" #最新でなくてもよく、手元に予めダウンロードしてある"SRAMetadb"
sqlfile <- getSRADBFile() #最新のSRAMetadb SQLiteファイルをダウンロードして解凍
sra_con <- dbConnect(SQLite(), sqlfile) #おまじない

#前処理(実験デザインの全体像を表示)
hoge <- sraConvert(param, sra_con=sra_con) #paramで指定したSRA IDに付随するstudy (SRP...), sa
hoge #hogeの中身を表示
apply(hoge, 2, unique) #hoge行列の列ごとにユニークな文字列を表示させている。

#前処理(FASTQファイルサイズを表示)
k <- getFASTQInfo(hoge$run) #「hoge$run」で指定したSRRから始まるIDのFASTQファイルサ
k #kの中身を表示
hoge2 <- cbind(k$library.name, #ライブラリ名と、
               k$run.read.count, #総リード数と、
               k$file.name, #ファイル名と、
               k$file.size) #ファイルサイズ、の順番で列方向で結合した結果をhoge2に格
```

6. ヒトのRNA-seqデータ("SRP017580": [Chan et al., Hum. Mol. Genet., 2013](#))のgzip圧縮済みのFASTQファイルをダウンロードする場合:

取得 | FASTQ or SRALite | [SRADB\(Zhu 2013\)](#)

Illumina HiSeq 2000のpaired-endデータです。計xファイル、合計x Gb程度の容量のファイルがダウンロードされます。高速の有線LANでx時間程度かかります。


```
param <- "SRP017580" #取得したいSRA IDを指定

#必要なパッケージをロード
library(SRADb) #パッケージの読み込み

#前処理
#sqlfile <- "SRAMetadb.sqlite" #最新でなくてもよく、手元に予め
sqlfile <- getSRAdbFile() #最新のSRAMetadb SQLiteファイル
sra_con <- dbConnect(SQLite(), sqlfile)#おまじない

#前処理(実験デザインの全体像を表示)
hoge <- sraConvert(param, sra_con=sra_con)#paramで指定したSRA IDに付随
hoge #hogeの中身を表示
apply(hoge, 2, unique) #hoge行列の列ごとにユニークな文字列を表示させている。

#前処理(FASTQファイルサイズを表示)
k <- getFASTQinfo(hoge$run) #「hoge$run」で指定したSRRから始まるIDのFASTQファイルサ
k #kの中身を表示
hoge2 <- cbind(k$library.name, #ライブラリ名と、
              k$run.read.count, #総リード数と、
              k$file.name, #ファイル名と、
              k$file.size) #ファイルサイズ、の順番で列方向で結合した結果をhoge2に格
```





SRAまたはSRP IDを与える  
ことでコピーでFASTQファイル  
をダウンロード可能です


```
R Console
> getwd()
[1] "C:/Users/kadota/Desktop/hoge/SRP017580"
> list.files()
character(0)
> |
```

Illumina HiSeq 2000のpaired-endデータです。計xファイル、合計x Gb程度の容量のファイルがダウンロードされます。東大有線LANでx時間程度かかります。

```
param <- "SRP017580"
#必要なパッケージをロー
library(SRADb)
#前処理
#sqlfile <- "SRAmetadb
sqlfile <- getSRADBFile
sra_con <- dbConnect(
#前処理(実験デザインの全
hoge <- sraConvert(pa
hoge
apply(hoge, 2, unique
#前処理(FASTQファイルサ
k <- getFASTQinfo(hog
k
hoge2 <- cbind(k$libr
k$run.read.count, #総リード数
k$file.name, #ファイル名
k$file.size) #ファイルサイズ
```



```
R Console
> #前処理
> #sqlfile <- "SRAmetadb.sqlite"
> sqlfile <- getSRADBFile()
URL 'http://gbnci.abcc.ncifcrf.gov/backup/SRAmetadb.sqlite.gz'
Content type 'text/plain; charset=ISO-8859-1' length 1000000
開かれた URL
```



ここまでのコマンドで、NCBI SRA中の全てのメタデータ情報を含んだSRAmetadb.sqliteのgzip圧縮ファイルがダウンロードされる。東大有線LANで20分程度。

Illumina HiSeq 2000のpaired-endデータです。計xファイル、合計x Gb程度の容量のファイルがダウンロードされます。有線LANでx時間程度かかります。


```
param <- "SRP017580" #取得したいSRA IDを指定

#必要なパッケージをロード
library(SRADb) #パッケージの読み込み

#前処理
#sqlfile <- "SRAmetadb.sqlite" #最新でなくてもよく、手元に予め
sqlfile <- getSRADBFile() #最新のSRADB SQLiteファイル
sra_con <- dbConnect(SQLite(), sqlfile) #おまじない

#前処理(実験デザインの全体像を表示)
hoge <- sraConvert(param, sra_con=sra_con) #paramで指定したSRA IDに付随
hoge #hogeの中身を表示
apply(hoge, 2, unique) #hoge行列の列ごとにユニークな文字列を表示させる

#前処理(FASTQファイルサイズを表示)
k <- getFASTQinfo(hoge$run) #「hoge$run」の中身を表示
k #kの中身を表示
hoge2 <- cbind(k$library.name, #ライブラリ名
               k$run.read.count, #総リード数
               k$file.name, #ファイル名
               k$file.size) #ファイルサイズ
```



```
R Console
> #sqlfile <- "SRAmetadb.sqlite" #最新でな$
> sqlfile <- getSRADBFile() #最新のSRA$
URL 'http://gbnci.abcc.ncifcrf.gov/backup/SRAmetad$
Content type 'text/plain; charset=ISO-8859-1' lengt$
開かれた URL
downloaded 434.8 Mb

Unzipping...

Metadata associate with downloaded file:

c("schema version", "creation timestamp")c("1.0", "$
> sra_con <- dbConnect(SQLite(), sqlfile) #おまじない
> |
```

ダウンロード後は自動で解凍。  
解凍後のファイルは6GB程度

Illumina HiSeq 2000のpaired-endデータです。計xファイル、合計x Gb程度の容量のファイルがダウンロードされます。有線LANでx時間程度かかります。

```

param <- "SRP017580" #取得したいSRA IDを指定


#必要なパッケージをロード
library(SRADb) #パッケージの読み込み

#前処理
#sqlfile <- "SRAmetadb.sqlite" #最新でなくてもよく、手元に予め
sqlfile <- getSRAdbFile() #最新のSRAmetadb SQLiteファイル
sra_con <- dbConnect(SQLite(), sqlfile) #おまじない

#前処理(実験デザインの全体像を表示)
hoge <- sraConvert(param, sra_con=sra_con) #paramで指定したSRA IDに付随
hoge #hogeの中身を表示
apply(hoge, 2, unique) #hoge行列の列ごとにユニークな文字列を

#前処理(FASTQファイルサイズを表示)
k <- getFASTQinfo(hoge$run)
k #「hoge$run」で指定したSRRから始まる
hoge2 <- cbind(k$library.name, #kの中身を表示
               k$run.read.count, #ライブラリ名と、
               k$file.name, #総リード数と、
               k$file.size) #ファイル名と、
                          #ファイルサイズ、の順番で列方向で結合した結果をhoge2に格

```



**SRAmetadb.sqliteファイルのダウンロードは結構大変だが、一度ダウンロードしておけば格納されているSRAメタデータ情報は利用可能**

```

R Console
> getwd()
[1] "C:/Users/kadota/Desktop/hoge/SRP017580"
> list.files()
[1] "SRAmetadb.sqlite"
> sqlfile <- "SRAmetadb.sqlite"
> sra_con <- dbConnect(SQLite(), sqlfile) #おまじない
> |

```

## 6. ヒトのRNA-seqデータ("SRP017580": [Chan et al., Hum. Mol. Genet., 2013](#))のgzip圧縮済みのFASTQファイルをダウンロードする場合:

• [イントロ](#) | [NGS](#) | [配列取得](#) | [FASTQ or SRALite](#) | [SRADB\(Zhu 2013\)](#)

Illumina HiSeq 2000のpaired-endデータです。計xファイル、合計x Gb程度の容量のファイルがダウンロードされます。東大の有線LANでx時間程度かかります。

```
#前処理
#sqlfile <- "SRAMetadb.sqlite" #最新でなくてもよく、手元に予めダウンロードしてある"SRAM
sqlfile <- getSRADBFile() #最新のSRADB (生体試料) (生体試料) (生体試料)
sra_con <- dbConnect(SQLite(), sqlfile) #おまじか

#前処理(実験デザインの全体像を表示)
hoge <- sraConvert(param, sra_con=sra_con) #paramで指$
hoge #hogeの中身を$
apply(hoge, 2, unique) #hoge行列の列$

#前処理(FASTQファイルサイズを表示)
k <- getFASTQinfo(hoge$run) #「hoge$
k #kの中身
hoge2 <- cbind(k$library.name, #ライプ$
               k$run.read.count, #総リー$
               k$file.name, #ファイ$
               k$file.size) #ファイ$
hoge2 #hoge2の

#本番(FASTQファイルのダウンロード)
getFASTQfile(hoge$run, srcType='ftp') #「hoge$
```

```
R Console
> hoge <- sraConvert(param, sra_con=sra_con) #paramで指$
> hoge #hogeの中身を$
      study submission      sample experiment      run
1 SRP017580  SRA062939 SRS380021  SRX210737  SRR633902
2 SRP017580  SRA062939 SRS380023  SRX210739  SRR649760
3 SRP017580  SRA062939 SRS380022  SRX210738  SRR649759
4 SRP017580  SRA062939 SRS380020  SRX210736  SRR633901
> apply(hoge, 2, unique) #hoge行列の列$
$study
[1] "SRP017580"

$submission
[1] "SRA062939"

$sample
[1] "SRS380021" "SRS380023" "SRS380022" "SRS380020"

$experiment
[1] "SRX210737" "SRX210739" "SRX210738" "SRX210736"

$run
[1] "SRR633902" "SRR649760" "SRR649759" "SRR633901"

> |
```

ENAで見られるメタデータ情報がR Console画面上でも見られます

Illumina HiSeq 2000のpaired-endデータです。計xファイル、合計x Gb程度の容量のファイルがダウンロードされます。東大の有線LANでx時間程度かかります。

```
#前処理
#sqlfile <- "SRAMetadb.sqlite"
sqlfile <- getSRAdbFile()
sra_con <- dbConnect(SQLite(), sqlfile)

#前処理(実験デザインの全体像を表示)
hoge <- sraConvert(param, sra_con=sra_con)#paramで指$
hoge
apply(hoge, 2, unique)

#前処理(FASTQファイルサイズを表示)
k <- getFASTQinfo(hoge$run)
k
hoge2 <- cbind(k$library.name,
               k$run.read.count,
               k$file.name,
               k$file.size)

hoge2

#本番(FASTQファイルのダウンロード)
getFASTQfile(hoge$run, srcType='')
```

#最新でなくてもよく、手元に予めダウンロードしてある"SRADB"を使う場合  
#最新のSRADBを使う場合は、事前にSRADBをダウンロードしておく必要がある  
#おまじか

```
R Console
> hoge <- sraConvert(param, sra_con=sra_con) #paramで指$
> hoge #hogeの中身を$
      study submission      sample experiment      run
1 SRP017580  SRA062939  SRS380021  SRX210737  SRR633902
2 SRP017580  SRA062939  SRS380023  SRX210739  SRR649760
3 SRP017580  SRA062939  SRS380022  SRX210738  SRR649759
4 SRP017580  SRA062939  SRS380020  SRX210736  SRR633901
> apply(hoge, 2, unique) #hoge行列の列$
$study
```

Study accession	Secondary study accession	Sample accession	Secondary sample accession	Experiment accession	Run accession	Scientific name	Instrument model	Library layout	Fastq files (ftp)
<a href="#">SRP017580</a>	<a href="#">SRP017580</a>	<a href="#">SAMN01831455</a>	<a href="#">SRS380020</a>	<a href="#">SRX210736</a>	<a href="#">SRR633901</a>	<a href="#">Homo sapiens</a>	Illumina HiSeq 2000	PAIRED	<a href="#">File 1</a> <a href="#">File 2</a>
<a href="#">SRP017580</a>	<a href="#">SRP017580</a>	<a href="#">SAMN01831456</a>	<a href="#">SRS380021</a>	<a href="#">SRX210737</a>	<a href="#">SRR633902</a>	<a href="#">Homo sapiens</a>	Illumina HiSeq 2000	PAIRED	<a href="#">File 1</a> <a href="#">File 2</a>
<a href="#">SRP017580</a>	<a href="#">SRP017580</a>	<a href="#">SAMN01831457</a>	<a href="#">SRS380022</a>	<a href="#">SRX210738</a>	<a href="#">SRR649759</a>	<a href="#">Homo sapiens</a>	Illumina HiSeq 2000	PAIRED	<a href="#">File 1</a>
<a href="#">SRP017580</a>	<a href="#">SRP017580</a>	<a href="#">SAMN01831458</a>	<a href="#">SRS380023</a>	<a href="#">SRX210739</a>	<a href="#">SRR649760</a>	<a href="#">Homo sapiens</a>	Illumina HiSeq 2000	PAIRED	<a href="#">File 1</a>

ENAで見られるメタデータ情報がR Console画面上でも見られます

①ライブラリ名、②総リード数、  
③ファイル名、④ファイルサイズ

```
#前処理(実験デザインの全体像を表示)
hoge <- sraConvert(param, sra_con=sra_con)#paramで指定したSRA IDIに付随する
hoge #hogeの中身を表示
apply(hoge, 2, unique) #hoge行列の列ごとにユニークな文字列を抽出

#前処理(FASTQファイルサイズを表示)
k <- getFASTQinfo(hoge$run)
k #kの中身を表示
hoge2 <- cbind(k$library.name, #「hoge$run」で指定したSRRから始まる
               k$run.read.count, #kの中身を表示
               k$file.name, #ライブラリ名と総リード数
               k$file.size) #ファイル名とファイルサイズ
hoge2 #hoge2の中身を表示

#本番(FASTQファイルのダウンロード)
getFASTQfile(hoge$run, srcType='ftp') #「hoge$run」で指定したSRRから始まる
```

```
R Console
6 ftp://ftp.sra.ebi.ac.uk/vol1/fastq/SRR633/SRR633901$
> hoge2 <- cbind(k$library.name, #ライブラリ名$ ①
+               k$run.read.count, #総リード数$ ②
+               k$file.name, #ファイル名$ ③
+               k$file.size) #ファイルサイズ$ ④
> hoge2 #hoge2の中身$
      [,1] [,2] [,3] [,4]
[1,] "null" "16817117" "SRR633902_1.fastq.gz" "1Gb"
[2,] "null" "16817117" "SRR633902_2.fastq.gz" "1Gb"
[3,] "null" "36487727" "SRR649760.fastq.gz" "2Gb"
[4,] "null" "26457253" "SRR649759.fastq.gz" "2Gb"
[5,] "null" "22419833" "SRR633901_1.fastq.gz" "1Gb"
[6,] "null" "22419833" "SRR633901_2.fastq.gz" "1Gb"
> | ① ② ③ ④
```

```

#前処理(実験デザインの全体像を表示)
hoge <- sraConvert(param, sra_con=sra_con)#paramで指定したSRA IDIに付随する
hoge                                     #hogeの中身を表示
apply(hoge, 2, unique)                   #hoge行列の列ごとにユニークな文字列を

#前処理(FASTQファイルサイズを表示)
k <- getFASTQinfo(hoge$run)
k
hoge2 <- cbind(k$library.name,
               k$run.read.count,
               k$file.name,
               k$file.size)
hoge2

#本番(FASTQファイルのダウンロード)
getFASTQfile(hoge$run, srcType='ftp') # hoge$

```

①ライブラリ名、②総リード数、  
③ファイル名、④ファイルサイズ

```

R Console
> hoge$run
[1] "SRR633902" "SRR649760" "SRR649759" "SRR633901"
> dim(k)
[1] 6 19 ←
> colnames(k)
[1] "study" "sample"
[3] "experiment" "run"
[5] "analysis" "organism"
[7] "instrument.platform" "instrument.model"
[9] "library.name" "library.layout"
[11] "library.strategy" "library.source"
[13] "library.selection" "run.read.count"
[15] "run.base.count" "file.name"
[17] "file.size" "md5"
[19] "ftp"
> k$sample
[1] "SAMN01831456" "SAMN01831456" "SAMN01831458"
[4] "SAMN01831457" "SAMN01831455" "SAMN01831455"
> k[,2]
[1] "SAMN01831456" "SAMN01831456" "SAMN01831458"
[4] "SAMN01831457" "SAMN01831455" "SAMN01831455"
> |

```

kオブジェクトは6行×19列からなる

Illumina HiSeq 2000のpaired-endデータです。計xファイル、合計x Gb程度の容量のファイルが生成されます。有線LANでx時間程度かかります。

```
#前処理
#sqlfile <- "SRAMetadb.sqlite" #最新でなくてもよく、手元に予めた
sqlfile <- getSRAdbFile() #最新のSRAMetadb SQLiteファイル
sra_con <- dbConnect(SQLite(), sqlfile)#おまじない

#前処理(実験デザインの全体像を表示)
hoge <- sraConvert(param, sra_con=sra_con)#pa
hoge #hogeの
apply(hoge, 2, unique) #hoge行


#前処理(FASTQファイルサイズを表示)
k <- getFASTQinfo(hoge$run) #「hoge
k #kの中身
hoge2 <- cbind(k$library.name, #ライブラリ
               k$run.read.count, #総リード数
               k$file.name, #ファイル名
               k$file.size) #ファイルサイズ

hoge2 #hoge2

#本番(FASTQファイルのダウンロード)
getFASTQfile(hoge$run, srcType='ftp') #「hoge
```

```
R Console
5 22419833
6 22419833
file.size
1 1Gb b4ae
2 1Gb 28b3
3 2Gb b904
4 2Gb 453e
5 1Gb 83f
6 1Gb 87be34aa35953444b80e002f4e08fd3b

1 ftp://ftp.sra.ebi.ac.uk/vol1/fastq/SRR633/SRR633902$
2 ftp://ftp.sra.ebi.ac.uk/vol1/fastq/SRR633/SRR633902$
3 ftp://ftp.sra.ebi.ac.uk/vol1/fastq/SRR649/SRR6497$
4 ftp://ftp.sra.ebi.ac.uk/vol1/fastq/SRR649/SRR6497$
5 ftp://ftp.sra.ebi.ac.uk/vol1/fastq/SRR633/SRR633901$
6 ftp://ftp.sra.ebi.ac.uk/vol1/fastq/SRR633/SRR633901$
> list.files()
[1] "SRAMetadb.sqlite" "SRR633901_1.fastq.gz"
[3] "SRR633901_2.fastq.gz" "SRR633902_1.fastq.gz"
[5] "SRR633902_2.fastq.gz" "SRR649759.fastq.gz"
[7] "SRR649760.fastq.gz"
> |
```



計6個のgzip圧縮FASTQ  
ファイルが得られます





# FASTQファイル実例

名前	更新日時	サイズ	種類
SRAMetadb.sqlite	2014/06/09 20:12	6,175,629 KB	SQLITE
SRR633901_1.fastq.gz	2014/06/09 23:23	1,726,817 KB	GZ ファイ
SRR633901_2.fastq.gz	2014/06/09 23:46	1,676,647 KB	GZ ファイ
<b>SRR633902_1.fastq.gz</b>	2014/06/10 16:44	<b>1,296,428 KB</b>	GZ ファイ
SRR633902_2.fastq.gz	2014/06/10 16:56	1,258,485 KB	GZ ファイ
SRR649759.fastq.gz	2014/06/09 23:07	2,185,607 KB	GZ ファイ
SRR649760.fastq.gz	2014/06/09 22:25	2,995,384 KB	GZ ファイ

- gzip圧縮ファイル解凍後のSRR633902\_1.fastqをテキストエディタで表示

MD5チェックサムが王道ですが、私はペアエンドリードの場合は、もう片方のファイルサイズと比較して判断します。基本思考停止して再ダウンロード

```
R Console
> cbind(k$file.name, k$md5)
      [,1]                [,2]
[1,] "SRR633902_1.fastq.gz" "b4ae071d828a9cfc1ce8ce9171a63c15"
[2,] "SRR633902_2.fastq.gz" "28b3e87b697fa07b76cd1bae663c6acd"
[3,] "SRR649760.fastq.gz"    "b9048e444b9795f4c28ac8d6fedc21a1"
[4,] "SRR649759.fastq.gz"    "453ebd92e18db08a314e115ea421572a"
[5,] "SRR633901_1.fastq.gz"  "83f05650bedb2a0996dded414d9eb018"
[6,] "SRR633901_2.fastq.gz"  "87be34aa35953444b80e002f4e08fd3b"
> hoge$run[1]
[1] "SRR633902"
> getFASTQfile(hoge$run[1], srcType='ftp')
```

# Contents (第2回)

- イントロダクション(Introduction)
  - NGSデータ概観(PacBioとIllumina)
  - NGSデータベース(DB)、データ形式(FASTQ形式)
  - SRADBパッケージを用いたデータ取得、エラーへの対処
- 前処理(Pre-processing)
  - qracパッケージを用いたQuality Control (QC)
- アダプター配列除去
  - 基本戦略(girafeパッケージ)
  - 昔は正常に動作していたのに…という例(QuasRパッケージ)
  - アダプター除去を含む様々なフィルタリングの組合せ(ShortReadパッケージ)
  - 課題

# Quality Control

- イントロ | ファイル形式の変換 | [qseq --> FASTA](#) (last modified 2013/06/17)
- イントロ | ファイル形式の変換 | [qseq --> Illumina FASTQ](#) (last modified 2013/06/17)
- イントロ | ファイル形式の変換 | [qseq --> Sanger FASTQ](#) (last modified 2013/08/19)
- **前処理 | クオリティチェック | について (last modified 2014/06/10) NEW**
- 前処理 | クオリティチェック | [qseq](#) (last modified 2014/06/10) NEW
- 前処理 | クオリティチェック | [PHREDスコアに変換](#) (last modified 2013/06/18)
- 前処理 | クオリティチェック | [配列長分布を調べる](#) (last modified 2013/06/18)
- 前処理 | フィルタリング | [PHREDスコアが低い塩基をNに置換](#) (last modified 2014/03/03)
- 前処理 | フィルタリング | [PHREDスコアが低い配列\(リード\)を除去](#) (last modified 2014/03/03)
- 前処理 | フィルタリング | [ACGTのみからなる配列を抽出](#) (last modified 2013/06/18)

## 前処理 | クオリティチェック | について NEW

Quality Control (QC)を実行する様々な方法をリストアップします。Kraken などアダプター配列除去などが行えるものも含まれます。

### Rパッケージ:

- [qseq](#): 原著論文なし
- [PIQA](#): [Martinez-Alcantara et al., Bioinformatics, 2009](#)
- [ShortRead](#): [Morgan et al., Bioinformatics, 2009](#)
- [giraffe](#): [Toedling et al., Bioinformatics, 2010](#)

### R以外:

- [FastQC](#): 原著論文なし
- [FASTX-ToolKit](#): 原著論文なし
- [SolexaQA](#): [Cox et al., BMC Bioinformatics, 2010](#)
- [Quake](#): [Kelley et al., Genome Biol., 2010](#)
- [NGSQC](#): [Dai et al., BMC Genomics, 2010](#)
- [PRINSEQ](#): [Schmieder and Edwards, Bioinformatics, 2011](#)
- [ECHO](#): [Kao et al., Genome Res., 2011](#)
- [Btrim](#): [Kong Y., Genomics, 2011](#)
- [Hammer](#): [Medvedev et al., Bioinformatics, 2011](#)
- [ConDeTri](#): [Smeds et al., PLoS One, 2011](#)
- [BIGpre](#): [Zhang et al., Genomics Proteomics Bioinformatics, 2011](#)
- [NGS QC Toolkit](#): [Patel et al., PLoS One, 2012](#)
- [SEQuel](#): [Ronen et al., Bioinformatics, 2012](#)
- [Slim-Filter](#): [Golovko et al., BMC Bioinformatics, 2012](#)
- [HTQC](#): [Yang et al., BMC Bioinformatics, 2013](#)
- [QC-Chain](#): [Zhou et al., PLoS One, 2013](#)
- [Kraken](#): [Davis et al., Methods, 2013](#)

### Review:

- [Paszekiewicz et al., Front Genet., 2014](#)

FASTQ形式ファイルを入力として全体像を眺める作業。FastQCが有名だが、Rパッケージもいくつかある。

# qrqcパッケージで全体像を眺める

qrqcはシンプルだが、若干動作が不安定な印象。使われた実績はあり

- イントロ | ファイル形式の変換 | [qseq --> FASTA](#) (last modified 2013/06/17)
- イントロ | ファイル形式の変換 | [qseq --> Illumina FASTQ](#) (last modified 2013/06/17)
- イントロ | ファイル形式の変換 | [qseq --> Sanger FASTQ](#) (last modified 2013/08/19)
- 前処理 | クオリティチェック | [qrqc](#) (last modified 2014/06/10) **NEW**
- 前処理 | クオリティチェック | [PHREDスコアに変換](#) (last modified 2013/06/18)

## 前処理 | クオリティチェック | qrcq **NEW**

FastQCのR版のようなものです。Sanger FASTQ形式ファイルを読み込んで、positionごとの「クオリティスコア (quality score)」、「どんな塩基が使われているのか (base frequency and base proportion)」、「リード長の分布」、「GC含量」、「htmlレポート」などを出力してくれます。

### 2. サンプルデータ25のFASTQ形式ファイル(SRR633902\_1\_sub.fastq)の場合:

1. サンプル  
SRR037439  
BMC Bioin  
にあるrepo

SRR633902から得られるFASTQファイルの最初の2,000行分を抽出したヒトデータです ([Chan et al., Hum. Mol. Genet., 2013](#))。下記を実行すると「SRR633902\_1\_sub」という名前のフォルダが作成されます。中にあるreport.htmlをダブルクリックするとhtmlレポートを見ることができます。「Error: insufficient values in manual scale. 2 needed but only 1 provided.」というエラーが出ることは確認済みですが、htmlファイルは作成されます。

```
in_f <- "SRR633902_1_sub.fastq" #入力ファイル名を指定してin_fに格納
#必要なパッケージをロード
library(qrcq) #パッケージの読み込み
#入力ファイルの読み込み
fastq <- readSeqFile(in_f) #in_fで指定したファイルの読み込み
#本番
makeReport(fastq) #htmlレポートの作成
```

- [qrqc: 原著論文はまだ?!](#)
- [qrqc利用論文: Loman et al., Nat Biotechnol., 2012](#)


## 2. サンプルデータ25のFASTQ形式ファイル(SRR633902\_1\_sub.fastq)の場合:

• 前処理 | クオリティチェック | [qrac](#)

SRR633902から得られるFASTQファイルの最初の2,000行分を抽出したヒトデータです ([Chan et al., Hum. Mol. Genet., 2013](#))。下記を実行すると「SRR633902\_1\_sub」という名前のフォルダが作成されます。中にあるreport.htmlをダブルクリックするとhtmlレポートを見ることができます。「Error: Insufficient values in manual scale. 2 needed but only 1 provided.」というエラーが出ることは確認済みですが、htmlファイルは作成されます。

```
in_f <- "SRR633902_1_sub.fastq"      #入力ファイル名を指定してin_fに格納
#必要なパッケージをロード
library(qrac)                        #パッケージの読み込み
#入力ファイルの読み込み
fastq <- readSeqFile(in_f)          #in_fで指定したファイルの読み込み
#本番
makeReport(fastq)                   #htmlレポートの作成
```

hogeフォルダ中にあり。通常利用時は、(Windowsのヒトは)右クリックでファイルの保存。



```
R Console
> getwd()
[1] "C:/Users/kadota/Desktop/hoge"
> list.files()
[1] "SRR633902_1_sub.fastq"
> |
```

## 2. サンプルデータ25のFASTQ形式ファイル(SRR633902\_1\_sub.fastq)の場合:

• 前処理 | クオリティチェック | [qrc](#)

SRR633902から得られるFASTQファイルの最初の2,000行分を抽出したヒトデータです ([Chan et al., Hum. Mol. Genet., 2013](#))。下記を実行すると「SRR633902\_1\_sub」という名前のフォルダが作成されます。中にあるreport.htmlをダブルクリックするとhtmlレポートを見ることができます。「Error : Insufficient values in manual scale. 2 needed but only 1 provided.」というエラーが出ることは確認済みですが、htmlファイルは作成されます。

```
in_f <- "SRR633902_1_sub.fastq"
```

```
#必要なパッケージをロード  
library(qrc)
```

```
#入力ファイルの読み込み  
fastq <- readSeqFile(in_f)
```

```
#本番  
makeReport(fastq)
```


切り取り(T)


コピー(C)

R Console

```
> #入力ファイルの読み込み  
> fastq <- readSeqFile(in_f) #in_fで指定したファイル  
>  
> #本番  
> makeReport(fastq) #htmlレポートの作成  
Error : .onAttach failed in attachNamespace() for 'mgcv', detail$  
call: formatDL(nm, txt, indent = max(nchar(nm, "w")) + 3)  
error: incorrect values of 'indent' and 'width'  
Error : mgcv package required for this functionality. Please install  
Error : Insufficient values in manual scale. 2 needed but only 1 provided.  
Report written to directory './SRR633902_1_sub-report'.  
> list.files()  
[1] "SRR633902_1_sub-report"  
[2] "SRR633902_1_sub.fastq"  
> |
```

R console画面上でペーストすると、エラーは出るがSRR633902\_1\_sub-reportというフォルダは作成される






C:\Users\kadota\Desktop\hoge\SRR633902\_1\_sub-report\report.html

### General Information

File: SRR633902\_1\_sub.fastq  
 Type: FASTQ  
 Sequence Length Range: 100 to 100  
 Total Sequences: 1000  
 Unique Sequences: 906

### Quality by Position



縦軸: Phred quality score、横軸: 塩基のポジション。50 bpあたりから100 bpにかけてクオリティ値が下がりますが、これが一般的な傾向です



# Quality Control

## ■ 作業内容

- フィルタリング (filtering)
  - クオリティ値の低い塩基やリードの除去
  - rRNAやtRNAの除去
- トリミング (trimming)
  - 最初の35塩基のみ利用など
- 重複除去 (de-duplication)
- コンタミ (contamination)
- バーコード配列 (barcoding)
- アダプター配列除去 (adapter removal)
- ...

実験デザインや使用する機器にもよるが様々な前処理が行われます

Quality Control (QC)を実行する様々な方法をリストアップします。Krakenなどアダプター配列除去などが行えるものも含まれます。

### Rパッケージ:

- [qrc](#): 原著論文なし
- [PIQA](#): [Martinez-Alcantara et al., Bioinformatics, 2009](#)
- [ShortRead](#): [Morgan et al., Bioinformatics, 2009](#)
- [girafe](#): [Toedling et al., Bioinformatics, 2010](#)

### R以外:

- [FastQC](#): 原著論文なし
- [FASTX-ToolKit](#): 原著論文なし
- [SolexaQA](#): [Cox et al., BMC Bioinformatics, 2010](#)
- [Quake](#): [Kelley et al., Genome Biol., 2010](#)
- [NGSQC](#): [Dai et al., BMC Genomics, 2010](#)
- [Cutadapt](#): [Martin, M., EMBnet.journal, 2011](#)
- [PRINSEQ](#): [Schmieder and Edwards, Bioinformatics, 2011](#)
- [ECHO](#): [Kao et al., Genome Res., 2011](#)
- [Btrim](#): [Kong Y., Genomics, 2011](#)
- [Hammer](#): [Medvedev et al., Bioinformatics, 2011](#)
- [ConDeTri](#): [Smeds et al., PLoS One, 2011](#)
- [BIGpre](#): [Zhang et al., Genomics Proteomics Bioinformatics, 2011](#)
- [NGS QC Toolkit](#): [Patel et al., PLoS One, 2012](#)
- [RobiNA](#): [Lohse et al., Nucleic Acids Res., 2012](#)
- [SEQuel](#): [Ronen et al., Bioinformatics, 2012](#)
- [AdapterRemoval](#): [Lindgreen S., BMC Res Notes, 2012](#)
- [Slim-Filter](#): [Golovko et al., BMC Bioinformatics, 2012](#)
- [HTQC](#): [Yang et al., BMC Bioinformatics, 2013](#)
- [QC-Chain](#): [Zhou et al., PLoS One, 2013](#)
- [Kraken](#): [Davis et al., Methods, 2013](#)

### Review:

- [Paszkiwicz et al., Front Genet., 2014](#)

# Kraken

## LinuxとMac用のみ

	Barcoding Simple	Barcoding mismatch	5' Adapter Stripping	3' Adapter Stripping	Quality Stripping	Complexity Filtering	Complexity Stripping	N-stripping	Size Selection	De-duplication	Compression	Detailed QC	Multi-processor	Mapper Integration	rRNA/rRNA filtering	Graphical Interface	Color space	URL and Reference (If available)
Btrim																		graphics.med.yale.edu/trim/ (Kong, 2011)
Cutadapt																		code.google.com/p/cutadapt/ (Martin, 2011)
AdapterRemoval																		code.google.com/p/adapterremoval/ (Lindgreen, 2012)
FASTX toolkit																		hannoniab.cshl.edu/fastx_toolkit/
UEA toolkit																		sma-tools.cmp.uea.ac.uk (Moxon et al., 2008)
Novoalign																		www.novocraft.com/main/index.php
RobiNA																		mapman.gabipd.org/web/guest/robin (Lohse et al., 2012)
Kraken Tools																		www.ebi.ac.uk/enright/kraken

Table 1

### R以外:

- [FastQC](#): 原著論文なし
- [FASTX-ToolKit](#): 原著論文なし
- [SolexaQA](#): Cox et al., *BMC Bioinformatics*, 2010
- [Quake](#): Kelley et al., *Genome Biol.*, 2010
- [NGSQC](#): Dai et al., *BMC Genomics*, 2010
- [Cutadapt](#): Martin, M., *EMBNET journal*, 2011
- [PRINSEQ](#): Schmieder and Edwards, *Bioinformatics*, 2011
- [ECHO](#): Kao et al., *Genome Res.*, 2011
- [Btrim](#): Kong Y., *Genomics*, 2011
- [Hammer](#): Medvedev et al., *Bioinformatics*, 2011
- [ConDeTri](#): Smeds et al., *PLoS One*, 2011
- [BIGpre](#): Zhang et al., *Genomics Proteomics Bioinformatics*, 2011
- [NGS QC Toolkit](#): Patel et al., *PLoS One*, 2012
- [RobiNA](#): Lohse et al., *Nucleic Acids Res.*, 2012
- [SEQuel](#): Ronen et al., *Bioinformatics*, 2012
- [AdapterRemoval](#): Lindgreen S., *BMC Res Notes*, 2012
- [Slim-Filter](#): Golovko et al., *BMC Bioinformatics*, 2012
- [HTQC](#): Yang et al., *BMC Bioinformatics*, 2013
- [QC-Chain](#): Zhou et al., *PLoS One*, 2013
- [Kraken](#): Davis et al., *Methods*, 2013

### Review:

- [Paszkiwicz et al.](#), *Front Genet.*, 2014

Table 1を見るといろいろできるように見えるが...

# Review論文だと...

	HTQC	FastQC	SolexaQA	NGS QC Toolkit	Kraten	QC-Chain
Language	C++	Java	Perl	Perl	C	C++
Q score boxplot	Shaded	Shaded	Shaded	Shaded		
Tile based Q scores	Shaded		Shaded			
Duplication removal					Shaded	Shaded
Filtering	Shaded			Shaded		
Trimming	Shaded		Shaded	Shaded		
Adaptor detection		Shaded		Shaded	Shaded	
Contamination detection						Shaded

Comparison of feature of software packages for quality control of Illumina read data. Shaded areas indicate that the feature is present.

Table 1


評価項目によって印象は変わりますね...

R以外:

- [FastQC](#): 原著論文なし
- [FASTX-ToolKit](#): 原著論文なし
- [SolexaQA](#): Cox et al., *BMC Bioinformatics*, 2010
- [Quake](#): Kelley et al., *Genome Biol.*, 2010
- [NGSQC](#): Dai et al., *BMC Genomics*, 2010
- [Cutadapt](#): Martin, M., *EMBnet journal*, 2011
- [PRINSEQ](#): Schmieder and Edwards, *Bioinformatics*, 2011
- [ECHO](#): Kao et al., *Genome Res.*, 2011
- [Btrim](#): Kong Y., *Genomics*, 2011
- [Hammer](#): Medvedev et al., *Bioinformatics*, 2011
- [ConDeTri](#): Smeds et al., *PLoS One*, 2011
- [BIGpre](#): Zhang et al., *Genomics Proteomics Bioinformatics*, 2011
- [NGS QC Toolkit](#): Patel et al., *PLoS One*, 2012
- [RobiNA](#): Lohse et al., *Nucleic Acids Res.*, 2012
- [SEQuel](#): Ronen et al., *Bioinformatics*, 2012
- [AdapterRemoval](#): Lindgreen S., *BMC Res Notes*, 2012
- [Slim-Filter](#): Golovko et al., *BMC Bioinformatics*, 2012
- [HTQC](#): Yang et al., *BMC Bioinformatics*, 2013
- [QC-Chain](#): Zhou et al., *PLoS One*, 2013
- [Kraken](#): Davis et al., *Methods*, 2013

Review:

- [Paszkievicz et al., Front Genet., 2014](#)



# Quality Control

## ■ 作業内容

- フィルタリング (filtering)
  - クオリティ値の低い塩基やリードの除去
  - rRNAやtRNAの除去
- トリミング (trimming)
  - 最初の35塩基のみ利用など
- 重複除去 (de-duplication)
- コンタミ (contamination)
- バーコード配列 (barcoding)
- アダプター配列除去 (adapter removal)
- ...




Fig. 2

特にアダプター配列除去(adapter removal)は small RNA sequencing (sRNA-seq)の場合に、マップ率に多大な影響を及ぼします

# アダプター配列除去

girafeパッケージのデフォルト設定はイマイチですが、感覚をつかむ上では便利なのでそれを利用して説明します

- 前処理 | トリミング | ポリア配列除去 | [ShortRead\(Morgan 2009\)](#) (last modified 2014/06/11) NEW
- 前処理 | トリミング | アダプター配列除去(基礎) | [girafe\(Toedling 2010\)](#) (last modified 2014/06/11)
- 前処理 | トリミング | アダプター配列除去(基礎) | [ShortRead\(Morgan 2009\)](#) (last modified 2014/06/11)
- 前処理 | トリミング | アダプター配列除去(応用) | [QuasR\(Lerch 20XX\)](#) (last modified 2014/06/11)
- 前処理 | トリミング | アダプター配列除去(応用) | [ShortRead\(Morgan 2009\)](#) (last modified 2014/06/13) 推奨

## 前処理 | トリミング | アダプター配列除去(基礎) | [girafe\(Toedling 2010\)](#) NEW

[girafe](#)パッケージを用いたアダプター配列除去を行うやり方を示します。アダプター配列除去を行うやり方を示します。注意点1としては、実際に塩基配列長が短くなってもdescription行の記述(特に配列長情報の記述)は変わりませんので、「なんかおかしい」と気にしなくて大丈夫です。

注意点2としては、例えば、アダプター配列の5側が「CATCG...」となっているにも関わらずなぜ二番目の配列の3側「...CATAG」の最後の5塩基がトリムされているのだろうか?と疑問に思われる方がいらっしゃるかもしれませんが、これは、R Console上で「?trimAdapter」と打ち込んでデフォルトのオプションを眺めることで理由がわかります。つまり、アラインメントスコア計算時に、この関数はデフォルトで一致に1点、不一致に-1点を与えて一塩基づつオーバーラップの度合いを上げていく、という操作をしているからです。したがって、もし完全一致のみに限定したい場合は、trimAdapter関数のところで、不一致に対して大幅に減点するようなパラメータを与えればいいんです。例えば「mismatch.score = -1000」とか。。。

「ファイル」-「ディレクトリの変更」で解析したいファイルを置いてあるディレクトリに移動し以下をコピー。

### 1. サンプルデータ7のFASTQ形式ファイル(SRR037439.fastq)の場合:

[SRR037439](#)から得られるFASTQファイルの最初の2,000行分を抽出したMAQC2 brainデータです ([Bullard et al., BMC Bioinformatics, 2010](#))。

デフォルトのパラメータ(一致に1点、不一致に-1点)でトリムし、FASTQ形式で保存するやり方です。writeFastq関数のデフォルトオプションはcompress=Tで、gzip圧縮ファイルを出力します。ここではcompress=Fとして非圧縮ファイルを出力しています。

```
in_f <- "SRR037439.fastq" #入力ファイル名を指定してin_fに格納
out_f <- "hoge1.fastq" #出力ファイル名を指定してout_fに格納
param_adapter <- "CATCGATCCTGCAGGCTAGAGACAGATCGGAAGAGCTCGTATGCCGTCTTCTGCTTG" #アダプター配列

#必要なパッケージをロード
library(girafe) #パッケージの読み込み

#入力ファイルの読み込み
fastq <- readFastq(in_f) #in_fで指定したファイルの読み込み
sread(fastq) #配列情報を表示
```

# アダプター配列除去のイメージ

- アダプター配列: **CATCGATCCTGCAGGCTAGAGACAGAT...**
- FASTQ形式ファイル: SRR037439.fastq

```

@SRR037439.1 HWI-E4_6_30ACL:2:1:0:176 length=35
NNNNNNNNNNNNNNNNNNCTACCCCCCAGCCGCCGCA
+SRR037439.1 HWI-E4_6_30ACL:2:1:0:176 length=35
!!!!!!!!!!!!!!!!!!!!!!"#####"#####
@SRR037439.2 HWI-E4_6_30ACL:2:1:0:252 length=35
NNNNNNNNNNNNNNNNNNAGACAGTTGATTTAGCATAG
+SRR037439.2 HWI-E4_6_30ACL:2:1:0:252 length=35
!!!!!!!!!!!!!!!!!!!!!!"+#####"#####&
@SRR037439.3 HWI-E4_6_30ACL:2:1:0:1152 length=35
NNNNNNNNNNNNNNNNNNGGGTGGGGCGTTTGTCTTG
+SRR037439.3 HWI-E4_6_30ACL:2:1:0:1152 length=35
!!!!!!!!!!!!!!!!!!!!!!/5$$&"#####"#####%
@SRR037439.4 HWI-E4_6_30ACL:2:1:0:1349 length=35
NNNNNNNNNNNNNNNNNNCCCCGCCCCGCCCTCCCTC
+SRR037439.4 HWI-E4_6_30ACL:2:1:0:1349 length=35

```

3'側の2塩基が除去される

3'側の5塩基が除去される

3'側の0塩基が除去される

3'側の4塩基が除去される

アラインメント時に指定するパラメータ(一致に何点、不一致に...)次第で結果が変わる

```

@SRR037439.5 HWI-E4_6_30ACL:2:1:0:1669 length=35
NNNNNNNNNNNNNNNNNNGGTCGCCCCGACGCCACA
+SRR037439.5 HWI-E4_6_30ACL:2:1:0:1669 length=35
!!!!!!!!!!!!!!!!!!!!!!",#####"#####&"#####&"#####

```

3'側の2塩基が除去される

# アダプター配列除去のイメージ

- アダプター配列: **CATCGATCCTGCAGGCTAGAGACAGAT...**
- FASTQ形式ファイル: SRR037439.fastq



```

@SRR037439.1 HWI-E4_6_30ACL:2:1:0:176 length=35
NNNNNNNNNNNNNNNNNNCTACCCCCCAGCCGCCGCA
+SRR037439.1 HWI-E4_6_30ACL:2:1:0:176 length=35
!!!!!!!!!!!!!!!!!!!!!!"#####"#####

@SRR037439.2 HWI-E4_6_30ACL:2:1:0:252 length=35
NNNNNNNNNNNNNNNNNNAGACAGTTGATTTAGCATAG
+SRR037439.2 HWI-E4_6_30ACL:2:1:0:252 length=35
!!!!!!!!!!!!!!!!!!!!!!"+#####"#####"&

@SRR037439.3 HWI-E4_6_30ACL:2:1:0:1152 length=35
NNNNNNNNNNNNNNNNNNGGGTGGGGCGTTTGTCTTG
+SRR037439.3 HWI-E4_6_30ACL:2:1:0:1152 length=35
!!!!!!!!!!!!!!!!!!!!!!/5$$&"#####"#####

@SRR037439.4 HWI-E4_6_30ACL:2:1:0:1349 length=35
NNNNNNNNNNNNNNNNNNCCCCGCCCCGCCCTCCCTC
+SRR037439.4 HWI-E4_6_30ACL:2:1:0:1349 length=35
!!!!!!!!!!!!!!!!!!!!!!"#####"#####

@SRR037439.5 HWI-E4_6_30ACL:2:1:0:1669 length=35
NNNNNNNNNNNNNNNNNNGATCGCCCCCGACGCCGCA
+SRR037439.5 HWI-E4_6_30ACL:2:1:0:1669 length=35
!!!!!!!!!!!!!!!!!!!!!!",#####"#####"&"#####"&
    
```

3'側の2塩基が除去される

3'側の5塩基が除去される

3'側の0塩基が除去される

3'側の4塩基が除去される

この結果は一致に+1点、不一致に-1点を与えた場合です。具体的にどういう計算をしているのだろう?

3'側の2塩基が除去される

# アダプター配列除去のイメージ

- 一塩基づつずらしたアラインメントのoverlapの範囲で一致(+1), 不一致(-1)の総和を計算し、最も得点の高かったものを採用している

score (case)	score	Sequence
score (case1)	-1	NNNNNNNNNNNNNNNAGACAGTTGATTTAGCATAG CATCGATCCTGCAGGCTAGAGACAGAT...
score (case2)	-2	NNNNNNNNNNNNNNNAGACAGTTGATTTAGCATAG CATCGATCCTGCAGGCTAGAGACAGAT...
score (case3)	-1	NNNNNNNNNNNNNNNAGACAGTTGATTTAGCATAG CATCGATCCTGCAGGCTAGAGACAGAT...
score (case4)	-4	NNNNNNNNNNNNNNNAGACAGTTGATTTAGCATAG CATCGATCCTGCAGGCTAGAGACAGAT...
score (case5)	+3	NNNNNNNNNNNNNNNAGACAGTTGATTTAGCATAG CATCGATCCTGCAGGCTAGAGACAGAT...
score (case6)	-6	NNNNNNNNNNNNNNNAGACAGTTGATTTAGCATAG CATCGATCCTGCAGGCTAGAGACAGAT...
score (case7)	-5	NNNNNNNNNNNNNNNAGACAGTTGATTTAGCATAG CATCGATCCTGCAGGCTAGAGACAGAT...
score (case8)	-4	NNNNNNNNNNNNNNNAGACAGTTGATTTAGCATAG CATCGATCCTGCAGGCTAGAGACAGAT...
score (case9)	-5	NNNNNNNNNNNNNNNAGACAGTTGATTTAGCATAG CATCGATCCTGCAGGCTAGAGACAGAT...
...		

Case5(3'側の5塩基を除去)のスコアが最大



# 1. サンプルデータ7のFASTQ形式ファイル(SRR037439.fastq)の場合:

SRR037439から得られるFASTQファイルの最初の2,000行分を抽出したMAQC2 brainデータです (Bullard et al., BMC Bioinformatics, 2010)。デフォルトのパラメータ(一致に1点、不一致に-1点)でトリムし、FASTQ形式で保存するやり方です。writeFastq関数のデフォルト オプションはcompress=Tで、gzip圧縮ファイルを出力します。ここではcompress=Fとして非圧縮ファイルを出力しています。

```
in_f <- "SRR037439.fastq" #入力ファイル名を指定してin_fに格納
out_f <- "hoge1.fastq" #出力ファイル名を指定してout_fに格納
param_adapter <- "CATCGATCCTGCAGGCTAGAGACAGATCGGAAGAGCTCGTATGCCGTCTTCTGCTTG" #アダプター配列を指定

#必要なパッケージをロード
library(girafe) #パッケージ

#入力ファイルの読み込み
fastq <- readFastq(in_f) #in_fで指定
sread(fastq) #配列情報を抽出
table(width(fastq)) #配列長ごとの頻度

#本番
fastq <- trimAdapter(fastq, param_adapter) #trimAd
sread(fastq) #配列情報を抽出
table(width(fastq)) #配列長ごとの頻度

#ファイルに保存
writeFastq(fastq, out_f, compress=F) #fastqの中
```

```
R Console
> #入力ファイルの読み込み
> fastq <- readFastq(in_f) #in_fで$
> sread(fastq) #配列情報$
A DNASringSet instance of length 500
width seq
[1] 35 NNNNNNNNNNNNNNNNNCTACCCCCCAGCCGCCGCA
[2] 35 NNNNNNNNNNNNNNNNNAGACAGTTGATTTAGCATAG
[3] 35 NNNNNNNNNNNNNNNNNGGGTGGGGCGTTTGTCTTG
[4] 35 NNNNNNNNNNNNNNNNNCCCCGCCCGCCCTCCCTC
[5] 35 NNNNNNNNNNNNNNNNNGGTCGCCCCCGACGCCACA
... ..
[496] 35 CTGGACGGCCCCCCCCCACACACCACCCCCCCC
[497] 35 TGTCACTTGTGCTTTGCTCTTGTCCCACGGGGCTT
[498] 35 CCGCCCTTTTCCAGAAATTTCCGCACAAAAAAA
[499] 35 CGTTCTTGTGCCCCCGGGGCGGGGGGAAAAACC
[500] 35 GGAGCCTCCCCCCCCCCCCAAGGGGGGGGGGGGC
> table(width(fastq)) #配列長$
35
500
> |
```

FASTQファイル読み込み後のリード塩基配列情報はsread関数で抽出可能。table関数を用いて配列長分布を調べている。この場合35bpのものが500個あったということ



# 1. サンプルデータ7のFASTQ形式ファイル(SRR037439.fastq)の場合:

SRR037439から得られるFASTQファイルの最初の2,000行分を抽出したMAQC2 brainデータです (Bullard et al., BMC Bioinformatics, 2010)。デフォルトのパラメータ(一致に1点、不一致に-1点)でトリムし、FASTQ形式で保存するやり方です。writeFastq関数のデフォルト オプションは compress=Tで、gzip圧縮ファイルを出力します。ここでは compress=Fとして非圧縮ファイルを出力しています。

```
in_f <- "SRR037439.fastq" #入力ファイル名を指定してin_fに格納
out_f <- "hoge1.fastq" #出力ファイル名を指定してout_fに格納
param_adapter <- "CATCGATCCTGCAGGCTAGAGACAGATCGGAAGAGCTCGTATGCCGTCTTCTGCTTG" #アダプター配列を指定
```

```
#必要なパッケージをロード
library(girafe) #パッケージ
```

```
#入力ファイルの読み込み
fastq <- readFastq(in_f) #in_fで指定
sread(fastq) #配列情報を抽出
table(width(fastq)) #配列長ごとの頻度
```

```
#本番
fastq <- trimAdapter(fastq, param_adapter) #trimAd$
sread(fastq) #配列情報を抽出
table(width(fastq)) #配列長ごとの頻度
```

```
#ファイルに保存
writeFastq(fastq, out_f, compress=F) #fastqの中
```

```
R Console
> #本番
> fastq <- trimAdapter(fastq, param1) #trimAd$
> sread(fastq) #配列情報$
A DNASringSet instance of length 500
width seq
[1] 33 NNNNNNNNNNNNNNNNCTACCCCCCAGCCGCCG
[2] 30 NNNNNNNNNNNNNNNNAGACAGTTGATTTAG
[3] 35 NNNNNNNNNNNNNNNNNGGGTGGGGCGTTTGTCTTG
[4] 31 NNNNNNNNNNNNNNNNCCCCGCCCGCCCTC
[5] 33 NNNNNNNNNNNNNNNNNGGTCGCCCCCGACGCCCA
...
[496] 35 CTGGACGGCCCCCCCCACACACCACCCCCC
[497] 35 TGTCACTTGTGCTTTGCTCTTGTCCCACGGGGCTT
[498] 35 CCGCCCTTTTCCAGAAATTTCCGCACAAAAAA
[499] 35 CGTTCTTGTGCCCCCGGGGCGGGGGGAAAAACC
[500] 35 GGAGCCTCCCCCCCCCAAGGGGGGGGGGGGC
> table(width(fastq)) #配列長$
19 20 23 25 27 29 30 31 32 33 35
3 1 4 1 4 2 4 8 1 8 464
> |
```

アダプター配列除去後のリード塩基配列情報はsread関数で抽出可能。table関数を用いて配列長分布を調べている。この場合19 bpのものが3個など…。

# 1. サンプルデータ7のFASTQ形式ファイル(SRR037439.fastq)の場合:

SRR037439から得られるFASTQファイルの最初の2,000行分を抽出したMAQC2 brainデータです (Bullard et al., BMC Bioinformatics, 2010)。デフォルトのパラメータ(一致に1点、不一致に-1点)でトリムし、FASTQ形式で保存するやり方です。writeFastq関数のデフォルト オプションは compress=Tで、gzip圧縮ファイルを出力します。ここでは compress=Fとして非圧縮ファイルを出力しています。

```
in_f <- "SRR037439.fastq" #入力ファイル名を指定してin_fに格納
out_f <- "hoge1.fastq" #出力ファイル名を指定してout_fに格納
param_adapter <- "CATCGATCCTGCAGGCTAGAGACAGATCGGAAGAGCTCGTATGCCGTCTTCTGCTTG" #アダプター配列を指定
```

```
#必要なパッケージをロード
library(girafe) #パッケージ
```

```
#入力ファイルの読み込み
fastq <- readFastq(in_f) #in_fで指定
sread(fastq) #配列情報を
table(width(fastq)) #配列長ごと
```

```
#本番
fastq <- trimAdapter(fastq, param_adapter) #trimAd$
sread(fastq) #配列情報を
table(width(fastq)) #配列長ごと
```

```
#ファイルに保存
writeFastq(fastq, out_f, compress=F) #fastqの中
```

```
R Console
> #本番
> fastq <- trimAdapter(fastq, param1) #trimAd$
> sread(fastq) #配列情報$
A DNASTringSet instance of length 500
width seq
[1] 33 NNNNNNNNNNNNNNNNCTACCCCCCAGCCGCCG
[2] 30 NNNNNNNNNNNNNNNNAGACAGTTGATTTAG
[3] 35 NNNNNNNNNNNNNNNNNGGGTGGGGCGTTTGTCTTG
[4] 31 NNNNNNNNNNNNNNNNCCCCGCCCGCCCTC
[5] 33 NNNNNNNNNNNNNNNNNGGTCGCCCCCGACGCCCA
... ..
[496] 35 CTGGACGGCCCCCCCCACACACCACCCCCC
[497] 35 TGTCACTTGTGCTTTGCTCTTGTCCCACGGGGCTT
[498] 35 CCGCCCTTTTCCAGAAATTTCCGCACAAAAAA
[499] 35 CGTTCTTGTGCCCCGGGGCGGGGGGAAAAACC
[500] 35 GGAGCCTCCCCCCCCCAAGGGGGGGGGGGGC
> table(width(fastq)) #配列長$
19 20 23 25 27 29 30 31 32 33 35
3 1 4 1 4 2 4 8 1 8 464
```

table関数を用いて配列長分布を調べている。トリム前は500リードの配列長はすべて35bpだったが、トリム後に19bp長になっているものが3つ存在する。それを調べる

# 特定の条件を満たすリードを調べる

```

R Console
> table(width(fastq)) #配列長ごとの出現頻$
 19  20  23  25  27  29  30  31  32  33  35
  3   1   4   1   4   2   4   8   1   8 464
> obj <- as.logical(width(fastq) == 19)
> sum(obj)
[1] 3
> sread(fastq[obj])
A DNASTringSet instance of length 3
width seq
[1] 19 CNNNNNNNNNNNNNTGTGT
[2] 19 CTNNNNNNNNNNNTGGGGGG
[3] 19 CAAGGACCCTGGGTCCCA
> id(fastq[obj])
A BStringSet instance of length 3
width seq
[1] 47 SRR037439.23 HWI-E4_6_30ACL:2:1:0:181 length=35
[2] 49 SRR037439.130 HWI-E4_6_30ACL:2:1:2:1099 length=35
[3] 49 SRR037439.199 HWI-E4_6_30ACL:2:1:4:1799 length=35
> |
    
```

配列長が19 bpのもの位置情報を取得し、その数を確認

objがTRUEとなる要素のみに対して、塩基配列とdescription情報を表示

最も多くアダプター配列を含むリード IDを特定できた

アダプター配列除去アルゴリズムの詳細を知ること  
girafeのデフォルトパラメータがイマイチであることを知る



# 「?関数名」で詳細な使用法を学ぶ

```
R Console
> ?trimAdapter
starting httpd help server ... done
>
```

## Remove 3' adapter contamination

### Description

一致に+1、不一致に-1を与えているところ

Function to remove 3' adapter contamination from reads

### Usage

```
trimAdapter(fq, adapter, match.score = 1, mismatch.score = -1,
            score.threshold = 2)
```

### Arguments

一致に+1、不一致に-1を与えて、2塩基以上のオーバーラップがないとトリムしない設定にしているのがデフォルト

<code>fq</code>	Object of class <code>ShortReadQ</code> ; the reads with possible adapter contamination.
<code>adapter</code>	object of class <code>DNASTring</code> or class <code>character</code> ; the sequence of the 3' adapter which could give rise to the 3' contamination. If of class <code>character</code> , it is converted to a <code>DNASTring</code> inside the function.
<code>match.score</code>	numeric; alignment score for matching bases
<code>mismatch.score</code>	numeric; alignment score for mismatches
<code>score.threshold</code>	numeric; minimum total alignment score required for an overlap match between the 3' end of the read and the 5' end of the adapter sequence.

# Contents (第2回)

- イントロダクション(Introduction)
  - NGSデータ概観(PacBioとIllumina)
  - NGSデータベース(DB)、データ形式(FASTQ形式)
  - SRADBパッケージを用いたデータ取得、エラーへの対処
- 前処理(Pre-processing)
  - qracパッケージを用いたQuality Control (QC)
- アダプター配列除去
  - 基本戦略(girafeパッケージ)
  - 昔は正常に動作していたのに…という例(QuasRパッケージ)
  - アダプター除去を含む様々なフィルタリングの組合せ(ShortReadパッケージ)
  - 課題

- 前処理 | トリミング | アダプター配列除去(基礎) | [girafe\(Toedling 2010\)](#) (last modified 2014/06/11) **NEW**
- 前処理 | トリミング | アダプター配列除去(基礎) | [ShortRead\(Morgan 2009\)](#) (last modified 2014/06/11) **NEW**
- 前処理 | トリミング | アダプター配列除去(応用) | [QuasR\(Lerch 20XX\)](#) (last modified 2014/06/11) **NEW**
- 前処理 | トリミング | アダプター配列除去(応用) | [ShortRead\(Morgan 2009\)](#) (last modified 2014/06/13) 推奨
- 前処理 | トリミング | [指定した末端塩基数だけ除去](#) (last modified 2013/06/15)
- [アセンブル | について](#) (last modified 2011/07/26)
- [アセンブル | ゲノム | 田](#) (last modified 2014/06/10) **NEW**

2013年11月ごろはうまくいっていましたが、2014年6月に試すとエラーが出ていました、という例

## 前処理 | トリミング | アダプター配列除去(応用) | QuasR(Lerch\_20XX) **NEW**

QuasRパッケージを用いたアダプター配列除去とそれに付随する様々な組み合わせのやり方を示します。2013年11月ごろ(R ver. 3.0.2 and Bioconductor 2.13)ではうまくいっていましたが、2014年6月11日(R ver. 3.1.0 and Bioconductor 2.14)で試すと、エラーが発生してR Guiが終了してしまうことを確認済みです。圧縮ファイルのままアダプター配列除去できるので非常にありがたかったのですが...。誰か対処法が分かったかたはお知らせいただければ幸いです。「ファイル」-「ディレクトリの変更」で解析したいファイルを置いてあるディレクトリに移動し以下をコピー。

### 1. gzip圧縮状態のFASTQ形式ファイル(SRR609266.fastq.gz)の場合:

small RNA-seqデータ(ファイルサイズは400Mb弱、11928428リード)です。原著論文(Nie et al., BMC Genomics, 2013)中の記述から [GSE41841](#)を頼りに、[SRP016842](#)にたどりつき、[イントロ | NGS | 配列取得 | FASTQ or SRALite | SRadb\(Zhu 2013\)](#)の7を実行して得られたものが入力ファイルです。原著論文の中では、アダプター配列やクオリティの低いリードを除去したのち、ゲノムにマッピングしたと書いてあります。アダプター配列情報はどこにも書かれていませんでしたが、Table S2中のアダプター配列除去後の最も短いリードが18 nt (例: "GCAGTCGTGGCCGAGCGG")であり、「この18 nt」と「この配列を含む生リード配列の差分」がアダプター配列ということになります。詳細な情報は書かれていませんでしたが、おそらくアダプター配列は "TGGAATTCTCGGGTGCCAAGGAACTCCAGTC..." という感じだろうと推測できます。ここでは、1塩基ミスマッチまで許容して(推定)アダプター配列除去を行ったのち、"ACGT"のみからなる配列(許容するN数が0)で、配列長が18nt以上のものをフィルタリングして出力しています。

```

in_f <- "SRR609266.fastq.gz" #入力ファイル名を指定してin_fに格納(RNA-seqファイル)
out_f <- "SRR609266_p.fastq.gz" #出力ファイル名を指定してout_fに格納
param_adapter <- "TGGAATTCTCGGGTGCCAAGGAACTCCAGTC" #アダプター配列を指定
param_mismatch <- 1 #許容するミスマッチ数を指定
param_nBases <- 0 #許容するNの数を指定
param_minLength <- 18 #アダプター配列除去後の許容する最低配列長を指定

#必要なパッケージをロード
library(QuasR) #パッケージの読み込み

#本番(前処理)
res <- preprocessReads(filename=in_f, #前処理を実行
  outputFilename=out_f, #前処理を実行
  Rpattern=param_adapter, #前処理を実行
  max.Rmismatch=rep(param_mismatch, nchar(param_adapter)), #前処理を実行
  nBases=param_nBases, #前処理を実行
  minLength=param_minLength) #前処理を実行
res #確認してるだけです

```

## エラーの具体例 (2014年6月13日)

以下のオブジェクトはマスクされています (from 'packa

```
anyDuplicated, append, as.data.frame, as.vector, cbind,
colnames, do.
intersect, is
paste, pmax,
Reduce, rep.i
union, unique
```

要求されたパッケージ  
要求されたパッケージ  
要求されたパッケージ

R for Windows GUI front-end は動作を停止しました

問題が発生したため、プログラムが正しく動作しなくなりました。プログラムは閉じられ、解決策がある場合はWindows から通知されます。

プログラムの終了(C)

• 前処理 | トリミング | アダプター配列除去(応用) | [QuasR\(Lerch 20XX\)](#)

エラーの原因はメモリ不足だそうです by 孫堅強氏(2014年6月19日)

R Console

```
tapply, union, unique, unlist
```

要求されたパッケージ IRanges をロード中です  
要求されたパッケージ XVector をロード中です  
要求されたパッケージ Rbowtie をロード中です

2013年11月1日のセミナーで見せた結果

```
>
> #本番(前処理)
> res <- preprocessReads(filename=in_f, #前処理を実行
+                          outputFilename=out_f, #前処理を実行
+                          Rpattern=param_adapter, #前処理を実行
+                          max.Rmismatch=rep(param_mismatch, nchar(param_a$
+                          nBases=param_nBases, #前処理を実行
+                          minLength=param_minLength) #前処理を実行
+                          filtering SRR609266.fastq.gz
> res #確認してるだけです

                SRR609266.fastq.gz
totalSequences      11928428
matchTo5pAdapter         0
matchTo3pAdapter      11928428
tooShort             157229
tooManyN              21422
lowComplexity         0
totalPassed          11749931
> |
```

# アダプター配列除去 (推奨のやり方)

- 前処理 | トリミング | アダプター配列除去(基礎) | [girafe\(Toedling 2010\)](#) (last modified 2014/06/11) NEW
- 前処理 | トリミング | アダプター配列除去(基礎) | [ShortRead\(Morgan 2009\)](#) (last modified 2014/06/11)
- 前処理 | トリミング | アダプター配列除去(応用) | [QuasR\(Lerch 20XX\)](#) (last modified 2014/06/11) NEW
- 前処理 | トリミング | アダプター配列除去(応用) | [ShortRead\(Morgan 2009\)](#) (last modified 2014/06/13)
- 前処理 | トリミング | 指定した末端塩基数だけ除去 (last modified 2013/06/15)

hogeフォルダ中のファイルを解凍すれば実行できますが見るだけにして

## 前処理 | トリミング | アダプター配列除去(応用) | [ShortRead\(Morgan 2009\)](#) NEW

ShortReadパッケージを用いたアダプター配列除去とそれに付随する様々な組み合わせのやり方を示します。

### 1. FASTA形式ファイルの場合:

```
in_f <- "smp
out_f <- "hog
param_adapter
param_mismatch
param_nBases
param_range <
```

#必要なパッケージをロード  
library(ShortRead)

#入力ファイルの読み込み  
fasta <- readDNAStrSet(fasta)

#本番1(アダプター配列除去)

### 3. FASTQ形式ファイル(SRR609266.fastq)の場合:

small RNA-seqデータ(ファイルサイズは1.8GB、圧縮後で400Mb弱、11928428リード)です。原著論文(Nie et al., BMC Genomics, 2013)中の記述から GSE41841を頼りに、SRP016842にたどりつき、イントロ | NGS | 配列取得 | FASTQ or SRALite | SRADB(Zhu 2013)の7を実行して得られたものが入力ファイルです。

原著論文では、アダプター配列やクオリティの低いリードを除去したのち、ゲノムにマッピングしたと書いてあります。アダプター配列情報はどこにも書かれていませんでしたが、Table S2中のアダプター配列除去後の最も短いリードが18 nt (例:"GCAGTCGTGGCCGAGCGG")であり、「この18 nt」と「この配列を含む生リード配列の差分」がアダプター配列ということになります。詳細な情報は書かれていませんでしたが、おそらくアダプター配列は"TGGAATTCTCGGGTGCCAAGGAACTCCAGTC..."という感じだろうと推測できます。

アダプター配列既知("TGGAATTCTCGGGTGCCAAGGAACTCCAGTC")で、許容するミスマッチ数が2、ACGTのみからなる配列(param\_nBases <- 0)、配列長の範囲指定(20:30)の組み合わせです。

```
in_f <- "SRR609266.fastq"
out_f <- "hoge3.fasta"
param_adapter <- "TGGAATTCTCGGGTGCCAAGGAACTCCAGTC"
param_mismatch <- 2
param_nBases <- 0
param_range <- 20:30
```

#入力ファイル名を指定してin\_fに格納(RNA-seqファイル)  
#出力ファイル名を指定してout\_fに格納  
#アダプター配列を指定  
#許容するミスマッチ数を指定  
#許容するACGT以外の文字数(実質的にはNの許容数に相当)  
#配列長の範囲を指定

#必要なパッケージをロード  
library(ShortRead)

#パッケージの読み込み

#入力ファイルの読み込み

```
fasta <- readDNAStrSet(in_f, format="fastq")#in_fで指定したファイルの読み込み
fasta
```

#確認してるだけです

#本番1(アダプター配列除去)

### 3. FASTQ形式ファイル(SRR609266.fastq)の場合:

small RNA-seqデータ(ファイルサイズは1.8GB、圧縮後で400Mb弱、11928428リード)です。• 前処理 | トリミング | アダプター配列除去(応用) | [ShortRead\(Morgan 2009\)](#) | [Genomics, 2013](#)中の記述から [GSE41841](#)を頼りに、[SRP016842](#)にたどりつき、[イントロ](#) | [NGS](#) | [配列取得](#) | [FASTQ or SRALite](#) | [SRADB\(Zhu 2013\)](#)の7を実行して得られたものが入力ファイルです。

原著論文では、アダプター配列やクオリティの低いリードを除去したのち、ゲノムにマッピングしたと書いてあります。アダプター配列情報はどこにも書かれていませんでしたが、Table S2中のアダプター配列除去後の最も短いリードが18 nt(例:"GCAGTCGTGGCCGAGCGG")であり、「この18 nt」と「この配列を含む生リード配列の差分」がアダプター配列ということになります。詳細な情報は書かれていませんでしたが、おそらくアダプター配列は"TGGAATTCTCGGGTGCCAAGGAACTCCAGTC..."という感じだろうと推測できます。

アダプター配列既知("TGGAATTCTCGGGTGCCAAGGAACTCCAGTC")で、許容するミスマッチ数が2、ACGTのみからなる配列(param\_nBases <- 0)、配列長の範囲指定(20:30)の組み合わせです。

```
in_f <- "SRR609266.fastq" #入力ファイル名を指定してin_fに格納(RNA-seqファイル)
out_f <- "hoge3.fasta" #出力ファイル名を指定してout_fに格納
param_adapter <- "TGGAATTCTCGGGTGCCAAGGAACTCCAGTC" #アダプター配列を指定
param_mismatch <- 2 #許容するミスマッチ数を指定
param_nBases <- 0 #許容するACGT以外の文字数(実質的にはMの許容数に相当)
param_range <- 20:30 #

#必要なパッケージをロード
library(ShortRead)

#入力ファイルの読み込み
fasta <- readDNASTringSet(in_f, format="fastq")
fasta

#本番1(アダプター配列除去)
fasta <- trimLRPatterns(Rpattern=param_adapter,
  subject=fasta,
  max.Rmismatch=rep(param_mismatch, length(param_adapter)))
fasta

#本番2(ACGTのみの配列を抽出)
hoge <- rowSums(alphabetFrequency(DNASTringSet(fasta)))
```

```
R Console
> #入力ファイルの読み込み
> fasta <- readDNASTringSet(in_f, format="fastq") #in_f$
> fasta #確認してるだ$
A DNASTringSet instance of length 11928428
width seq names
[1] 49 TCTNCGGT...CGGGTGC SRR609266.1 FCC0N...
[2] 49 TATGTCTA...CCAAGGA SRR609266.2 FCC0N...
[3] 49 TCTTCGGT...CGGGTGC SRR609266.3 FCC0N...
[4] 49 TCTTCGGT...CGGGTGC SRR609266.4 FCC0N...
[5] 49 TCTTCGGT...CGGGTGC SRR609266.5 FCC0N...
... ..
[11928424] 49 NATTATGA...CAATTCT SRR609266.1192842...
[11928425] 49 NCTTCGGT...GGGTGCC SRR609266.1192842...
[11928426] 49 NCAGTTAG...CCAAGGA SRR609266.1192842...
[11928427] 49 NCTTCGGT...CGGGTGC SRR609266.1192842...
[11928428] 49 NCTTCGGT...CGGGTGC SRR609266.1192842...
> |
```

全部で11,928,428リード。  
配列長は49 bp

#本番1(アダプター配列除去)

```
fasta <- trimLRPatterns(Rpattern=param_adapter,#アダプター配列除去を行った結果をfastaに格納
subject=fasta,#アダプター配列除去を行った結果をfastaに格納
max.Rmismatch=rep(param_mismatch, nchar(param_adapter)))#アダプ
fasta
#確認してるだけです
```

総リード数は不変だが、アダプター配列除去によって配列長にバリエーションができたことがわかる。

#本番2(ACGTのみの配列を抽出)

```
hoge <- rowSums(alphabetFr
```

```
R Console
> fasta
A DNASTringSet instance of length 11928428
width seq names
[1] 33 TCTNCGGTAGTAT...GTATCCCCGCCT SRR609266.1 FCC0N...
[2] 27 TATGTCFAAGGAGAATTCAAAAAGAG SRR609266.2 FCC0N...
[3] 33 TCTTCGGTAGTAT...GTATCCCCGCCT SRR609266.3 FCC0N...
[4] 33 TCTTCGGTAGTAT...GTATCCCCGCCT SRR609266.4 FCC0N...
[5] 33 TCTTCGGTAGTAT...GTATCCCCGCCT SRR609266.5 FCC0N...
... ..
[11928424] 40 NATTATGATGACA...CACTGATTGCAT SRR609266.1192842...
[11928425] 32 NCTTCGGTAGTAT...AGTATCCCCGCC SRR609266.1192842...
[11928426] 27 NCAGTTAGTGGAGGAGTATTCTGGCGT SRR609266.1192842...
[11928427] 33 NCTTCGGTAGTAT...GTATCCCCGCCT SRR609266.1192842...
[11928428] 33 NCTTCGGTAGTAT...GTATCCCCGCCT SRR609266.1192842...
> table(width(fasta))

 18  19  20  21  22  23  24  25
55342 104978 517762 266238 298548 166321 138027 173525
 26  27  28  29  30  31  32  33
196544 339400 337122 131834 58820 69083 1543235 6517163
 34  35  36  37  38  39  40  41
 783 73928 99457 63429 71625 66676 62746
 43  44  45  46  47
175 37820 46158 145176 63998
```

最短の18 bpのものが55,342リード、最長の47 bpのものが63,998リード。

#本番2(ACGTのみの配列を抽出)

```
hoge <- rowSums(alphabetFrequency(DNAStringSet(fasta))[,1:4])#ACGTの総数をカウントした結果:  
obj <- (width(fasta) - hoge) <= param_nBases#条件を満たすかどうかを判定した結果をobjに格納  
fasta <- fasta[obj]  
fasta
```

#objがTRUEとなる要素のみ抽出した結果をfastaに格納  
#確認してるだけです

Nを含むリードがちゃんと消えていることがわかる

#本番3(指定した長さの範囲の配列を抽出)

```
obj <- (width(fasta) >= mi  
fasta <- fasta[obj]  
fasta
```

#ファイルに保存

```
writeXStringSet(fasta, fil
```

```
R Console  
> fasta  
A DNAStringSet instance of length 11907289  
      width seq                                     names  
[1]    27 TATGTCTAAGGAGAATTCAAAAAAGAG SRR609266.2 FCC0N...  
[2]    33 TCTTCGGTAGTAT...GTATCCCCGCCT SRR609266.3 FCC0N...  
[3]    33 TCTTCGGTAGTAT...GTATCCCCGCCT SRR609266.4 FCC0N...  
[4]    33 TCTTCGGTAGTAT...GTATCCCCGCCT SRR609266.5 FCC0N...  
[5]    22 CCTTCCAAACGTAAACTCATT SRR609266.6 FCC0N...  
... ..  
[11907285] 32 GCCGTGATCGTCT...AGGACCCTACGT SRR609266.1192837...  
[11907286] 44 TTCTTACAATTC...GTGCCCAGGAAC SRR609266.1192837...  
[11907287] 33 AAGGGAGATATGG...GCGAAGAGCACC SRR609266.1192837...  
[11907288] 33 TGCCGTGATCGTC...AGGACCCTACGT SRR609266.1192837...  
[11907289] 33 TCTTCGGTAGTAT...GTATCCCCGCCT SRR609266.1192837...  
> table(width(fasta))  
  
      18      19      20      21      22      23      24      25  
55264 104821 517002 265848 298040 166022 137801 173238  
      26      27      28      29      30      31      32      33  
196247 338821 336547 131613 58713 68977 1540653 6505885  
      34      35      36      37      38      39      40      41  
      42      43      44      45      46      47  
      669 73800 99268 63313 71490 66552 62624  
104 37715 45908 144393 63763
```

最短の18 bpのものが55,264リード、  
最長の47 bpのものが63,763リード。

```
#本番3(指定した長さの範囲の配列を抽出)
obj <- (width(fasta) >= min(param_range)) & (width(fasta) <= max(param_range)) #条件を満た
fasta <- fasta[obj] #objがTRUEとなる要素のみ抽出した結果をfastaに格納
fasta #確認してるだけです
```

```
#ファイルに保存
writeXStringSet(fasta, fil
```

配列長の範囲を20-30 bp  
に限定すると2,619,892リード  
に減ることがわかる

```
R Console
> fasta
A DNAStringSet instance of length 2619892
      width seq
[1] 27 TATGTCTAAGGAGAATTCAAAAAAGAG
[2] 22 CCTTGCAAACGTAACTCATT
[3] 28 TAACGGCAATAAACTCATCATCCAATGC
[4] 25 TAGAGATGCCACTGACTAGAACTG
[5] 20 GAAATATTAGGAGGGTTAGG
...
[2619888] 24 TATATGGTACTGACAATGATTGAT
[2619889] 28 TATGTTGAGTCCTTGTGGAATAATACT
[2619890] 28 AAGCTGACATCTGTAGCACTGCCCGGGA
[2619891] 26 TAACTCATTTTCGAACACCCAACTC
[2619892] 28 TATTGAACCTAAACAACCTATGCACCTGA
> table(width(fasta))

 20  21  22  23  24  25  26  27  28
517002 265848 298040 166022 137801 173238 196247 338821 336547
 29  30
131613 58713
> param_range
[1] 20 21 22 23 24 25 26 27 28 29 30
> min(param_range)
[1] 20
> |
```

最短の20 bpのものが517,002リード、  
最長の30 bpのものが58,713リード。

#本番3(指定した長さの範囲の配列を抽出)

```
obj <- (width(fasta) >= min(param_range)) & (width(fasta) <= max(param_range)) #条件を満た
```

```
fasta <- fasta[obj]
```

```
fasta
```

#objがTRUEとなる要素のみ抽出した結果  
#確認してるだけです

#ファイルに保存

```
writeXStringSet(fasta, file=out_f, format="fasta", width=50) #fastaの中身
```

出力はFASTA形式にしている。アダプター配列や各種前処理後は、クオリティスコア情報はいらないだろう、という思想。主なメリットはファイルサイズ

The image shows two windows from a Windows operating system. The left window is titled 'hoge3.fastaのプロパティ' (Properties of hoge3.fasta) and displays the following information:

- ファイルの種類: FASTA ファイル (.fasta)
- プログラム: EmEditor
- 場所: C:\Users\kadota\Desktop\hoge
- サイズ: 196 MB (206,120,754 バイト)
- ディスク上のサイズ: 196 MB (206,123,008 バイト)
- 作成日時: 2014年6月18日、13:00:48
- 更新日時: 2014年6月18日、13:00:56
- アクセス日時: 2014年6月18日、13:00:48

The right window is a text editor titled 'C:\Users\kadota\Desktop\hoge\hoge3.fasta - E...' and displays the following FASTA file content:

```
>SRR609266.2 FCCON94ACXX:4:1101:2035:2249/1+
TATGTCTAAGGAGAATTCAAAAAGAG+
>SRR609266.6 FCCON94ACXX:4:1101:6148:2248/1+
CCTTGCAAACCTGTAACCTCATT+
>SRR609266.8 FCCON94ACXX:4:1101:10466:2246/1+
TAACGGCAATAAACTCATCATCCAATGC+
>SRR609266.19 FCCON94ACXX:4:1101:1906:2266/1+
TAGAGATGCCTACTGACTAGAACTG+
>SRR609266.22 FCCON94ACXX:4:1101:2178:2497/1+
GAAATATTAGGAGGGTTAGG+
>SRR609266.24 FCCON94ACXX:4:1101:2317:2263/1+
GCAGTCTGTAATATTTTCATCTGATCGGT+
>SRR609266.28 FCCON94ACXX:4:1101:2690:2268/1+
GCCATTTGGATCGCGGAGATC+
>SRR609266.30 FCCON94ACXX:4:1101:2672:2285/1+
ACCGGAATGCTGAGACCTCG+
>SRR609266.31 FCCON94ACXX:4:1101:2621:2342/1+
TGGCAATGAATGCATCATACGGAGTC+
```

At the bottom of the text editor window, it shows '196 MB (206,120,754 Text 22行, 31桁 日本語 (シフト JIS))'.

# アダプター配列除去 (推奨のやり方)

前処理 | トリミング | アダプター配列除去(応用) | ShortRead(Morgan\_2009) **NEW**

ShortReadパッケージを用いたアダプター配列除去とそれに付随する様々な組み合わせのやり方を示します。

「ファイル」→「データ」

## 4. FASTQ形式ファイル(SRR609266.fastq.gz)の場合:

small RNA-seqデータ(400Mb弱、11928428リード)です。圧縮ファイルもreadDNAStringSet関数で通常手順で読み込みます。原著論文(Nie et al., BMC Genomics, 2013)中の記述から GSE41841 を検索 | NGS | 配列取得 | FASTQ or SRALite | SRadb(Zhu 2013)の7を実行して得た配列をFASTQ形式でダウンロードしました。原著論文では、アダプター配列やクオリティの低いリードを除去したのち、アダプター配列情報はどこにも書かれていませんでしたが、Table S2中のアダプター配列(例:"GCAGTCGTGGCCGAGCGG")であり、「この18 nt」と「この配列を含む」ということとなります。詳細な情報は書かれていませんでしたが、おそらくアダプター配列は"TGGAATTCTCGGGTGCCAAGGAAGTCCAGTC"という感じだろうと推測できます。アダプター配列既知("TGGAATTCTCGGGTGCCAAGGAAGTCCAGTC")で、許容するミスマッチ数が2、ACGTのみからなる配列(param\_nBases <- 0)、配列長の範囲指定(20:30)の組み合わせです。

readDNAStringSet関数はgzip圧縮ファイルも読み込み可能。gzip圧縮ファイルとして保存することも可能

## 1. FASTA形式ファイル

```
in_f <- "smp"
out_f <- "hoge"
param_adapter <- "TGGAATTCTCGGGTGCCAAGGAAGTCCAGTC"
param_mismatch <- 2
param_nBases <- 0
param_range <- 20:30
```

#必要なパッケージをロード

#入力ファイルの読み込み

#本番1(アダプター配列の除去)

```
in_f <- "SRR609266.fastq.gz" #入力ファイル名を指定してin_fに格納(RNA-seqファイル)
out_f <- "hoge4.fasta.gz" #出力ファイル名を指定してout_fに格納
param_adapter <- "TGGAATTCTCGGGTGCCAAGGAAGTCCAGTC" #アダプター配列を指定
param_mismatch <- 2 #許容するミスマッチ数を指定
param_nBases <- 0 #ACGT以外の配列を抽出
param_range <- 20:30 #本番2(ACGTのみの配列を抽出)
hoge <- rowSums(alphabetFrequency(DNAStringSet(fasta))[,1:4]) #ACGTの総数をカウントした結果
obj <- (width(fasta) - hoge) <= param_nBases #条件を満たすかどうかを判定した結果をobjに格納
fasta <- fasta[obj] #objがTRUEとなる要素のみ抽出した結果をfastaに格納
fasta #確認してるだけです

#本番3(指定した長さの範囲の配列を抽出)
obj <- (width(fasta) >= min(param_range)) & (width(fasta) <= max(param_range)) #条件を満たすかどうかを判定した結果をobjに格納
fasta <- fasta[obj] #objがTRUEとなる要素のみ抽出した結果をfastaに格納
fasta #確認してるだけです

#ファイルに保存
writeXStringSet(fasta, file=out_f, format="fasta", width=50, compress=T) #fastaの中身を指定して出力ファイルに格納
```

# Tips

## 4. FASTQ形式ファイル(SRR609266.fastq.gz)

small RNA-seqデータ(400Mb弱、11928428)あります。原著論文(Nie et al., BMC Genomics, 2010) | NGS | 配列取得 | FASTQ or SRALite | ShortRead

原著論文中では、アダプター配列やクオリティアダプター配列情報がどこにも書かれていません(例: "GCAGTCGTGGCCGAGCGG")であるということになります。詳細な情報は書かれていません。アダプター配列既知("TGGAATTCTCGGGTGCCAAGGAACTCGGGT")からなる配列(param\_nBases <- 0)、配列長の

```
in_f <- "SRR609266.fastq.gz"
out_f <- "hoge4.fasta.gz"
param_adapter <- "TGGAATTCTCGGGTGCCAAGGAACTCGGGT"
param_mismatch <- 2
param_nBases <- 0
param_range <- 20:30
```

#必要なパッケージをロード  
library(ShortRead)

#入力ファイルの読み込み  
fasta <- readDNASTringSet(in\_f, format="fastq")

### rcoade\_adapter.txt

```
in_f <- "SRR609266.fastq.gz" #入力ファイル名を指定してin_fに格納(RNA-seq)
out_f <- "hoge4.fasta.gz" #出力ファイル名を指定してout_fに格納+
param_adapter <- "TGGAATTCTCGGGTGCCAAGGAACTCCAGTC" #アダプター配列を指定+
param_mismatch <- 2 #許容するミスマッチ数を指定+
#param_nBases <- 0 #許容するACGT以外の文字数(実質的にはNの数を指定)
param_range <- 20:30 #配列長の範囲を指定+
+
#必要なパッケージをロード+
library(ShortRead) #パッケージをロード+
+
#入力ファイルの読み込み+
fasta <- readDNASTringSet(in_f, format="fastq") #確認し
fasta #確認し
+
#本番1(アダプター配列除去)+
fasta <- trimLRPatterns(Rpattern=param_adapter, #アダプター配列除去を行った結果
subject=fasta, #アダプター配列除去を行った結果をfastaに格納
max.Rmismatch=rep(param_mismatch, nchar(param_adapter))) #アダプター配列除去の最大許容ミスマッチ数を指定
fasta #確認してるだけです+
+
#本番2(ACGTのみの配列を抽出)+
#hoge <- rowSums(alphabetFrequency(DNASTringSet(fasta))[,1:4]) #ACGTの総数をカウント
#obj <- (width(fasta) - hoge) <= param_nBases #条件を満たすかどうかを判定した結果
#fasta <- fasta[obj] #objがTRUEとなる要素のみ抽出した結果をfastaに格納
#fasta #確認してるだけです+
+
#本番3(指定した長さの範囲の配列を抽出)+
obj <- (width(fasta) >= min(param_range)) & (width(fasta) <= max(param_range))
fasta <- fasta[obj] #objがTRUEとなる要素のみ抽出した結果をfastaに格納
fasta #確認してるだけです+
#table(width(fasta)) #配列長ごとの出現頻度を表示+
+
#ファイルに保存+
writeXStringSet(fasta, file=out_f, format="fasta", width=50, compress=T) #fasta
```

Nを一つでも含むリードの除去を行うステップを省く場合。(＃を左端に入れば、そのコマンドは実行されない)

# 課題1と2

Table S1

Length	Total
18nt	55702
19nt	106074
20nt	521188
21nt	267851
22nt	300121
23nt	167156
24nt	138656
25nt	174267
26nt	197271
27nt	339876
28nt	337492
29nt	132016
30nt	58901
31nt	69938
32nt	1551638
33nt	6529060
34nt	141067
35nt	72969
36nt	73926
37nt	99344
38nt	63419
39nt	71469
40nt	66514
41nt	61526
42nt	37604
43nt	27361
44nt	29035
all	11691441

■ 原著論文中的のアダプター配列除去後の配列長分布は右表のとおりであった。

rcode\_adapter.txt(の一部)

```

in_f <- "SRR609266.fastq.gz" #入力ファイル名を指定してin_fに格納(RNA
out_f <- "hoge4.fasta.gz" #出力ファイル名を指定してout_fに格納+
param_adapter <- "TGGAATTCTCGGGTGCCAAGGAAGTCCAGTC" #アダプター配列を指定+
param_mismatch <- 2 #許容するミスマッチ数を指定+
#param_nBases <- 0 #許容するACGT以外の文字数(実質的にはNO
param_range <- 20:30 #配列長の範囲を指定+
+
#必要なパッケージをロード+
library(ShortRead) #パッケージの読み込み+
+
#入力ファイルの読み込み+
fasta <- readDNASTringSet(in_f, from
fasta
+
#本番1(アダプター配列除去)

```

1. 右表と同じように18-44塩基の範囲内にあるsmall RNAリードのみを抽出するためにはどこをどう変更すればよいか示せ。
2. 指定した範囲に含まれる総リード数を示せ。

# 課題3

Table S1

Length	Total
18nt	55702
19nt	106074
20nt	521188
21nt	267851
22nt	300121
23nt	167156
24nt	138656
25nt	174267
26nt	197271
27nt	339876
28nt	337492
29nt	132016
30nt	58901
31nt	69938
32nt	1551638
33nt	6529060
34nt	141067
35nt	72969
36nt	73926
37nt	99344
38nt	63419
39nt	71469
40nt	66514
41nt	61526
42nt	37604
43nt	27361
44nt	29035
all	11691441

右表に示されているように、原著論文中のアダプター配列除去を含むフィルタリング後の総リード数は11,691,441個であった。以下に様々な条件で得られた総リード数を示す。

条件1-1(許容するミスマッチ数=1; Nを含んでもよい): 11,619,415個

```
param_mismatch <- 1      #許容するミスマッチ数を指定+
#param_nBases <- 0      #許容するACGT以外の文字数(実質的にはNの許容数に相当)を指定
param_range <- 18:44     #配列長の範囲を指定+
```

条件1-2(許容するミスマッチ数=1; Nを全く含まない): 11,599,894個

```
param_mismatch <- 1      #許容するミスマッチ数を指定+
param_nBases <- 0        #許容するACGT以外の文字数(実質的にはNの許容数に相当)を指定+
param_range <- 18:44     #配列長の範囲を指定+
```

条件2-1(許容するミスマッチ数=0; Nを含んでもよい): 11,357,039個

```
param_mismatch <- 0      #許容するミスマッチ数を指定+
#param_nBases <- 0      #許容するACGT以外の文字数(実質的にはNの許容数に相当)を指定
param_range <- 18:44     #配列長の範囲を指定+
```

条件2-2(許容するミスマッチ数=0; Nを全く含まない): 11,338,479個

```
param_mismatch <- 0      #許容するミスマッチ数を指定+
param_nBases <- 0        #許容するACGT以外の文字数(実質的にはNの許容数に相当)を指定+
param_range <- 18:44     #配列長の範囲を指定+
```

自分でもいくつか試し、結果を簡単に考察せよ。原著論文も明確に条件を記述しているわけではないので細かな違いは気にしなくてよい。

# 課題遂行時に何人か遭遇したエラーの解説

## 4. FASTQ形式ファイル(SRR609266.fastq.gz)の場合:

small RNA-seqデータ(400Mb弱、11928428リード)です。圧縮ファイルもreadDNAStringSet関数で通常手順で読み込みます。原著論文(Nie et al., BMC Genomics, 2013)中の記述から GSE41841を頼りに、SRP016842にたどりつき、[イントロ | NGS | 配列取得 | FASTQ or SRALite | SRadb\(Zhu 2013\)](#)の7を実行して得られたものが入力ファイルです。

原著論文中では、アダプター配列やクオリティの低いリードを除去したのち、ゲノムにマッピングしたとアダプター配列情報はどこにも書かれていませんでしたが、Table S2中のアダプター配列除去後の最長nt(例:"GCAGTCGTGGCCGAGCGG")であり、「この18 nt」と「この配列を含む生リード配列の差分」ということになります。詳細な情報は書かれていませんでしたが、おそらくアダプター配列は"TGGAATTCTCGGGTGCCAAGGAAGTCCAGTC..."という感じだろうと推測できます。

アダプター配列既知("TGGAATTCTCGGGTGCCAAGGAAGTCCAGTC")で、許容するミスマッチ数が2、ACGTのみからなる配列(param\_nBases <- 0)、配列長の範囲指定(20:30)の組み合わせです。

Macだとメモリ云々の問題に関わらず、gzファイルのままでは読み込めないようです by 受講生

```
in_f <- "SRR609266.fastq.gz" #入力ファイル名を指定してin_fに格納(RNA-seqファイル)
out_f <- "hoge4.fasta.gz" #出力ファイル名を指定してout_fに格納
param_adapter <- "TGGAATTCTCGGGTGCCAAGGAAGTCCAGTC" #アダプター配列を指定
param_mismatch <- 2 #許容するミスマッチ数を指定
param_nBases <- 0 #許容するACGT以外の文字数(実質的にはNの許容数に相当)を
param_range <- 20:30 #配列長の範囲を指定
```

```
#必要なパッケージをロード
library(ShortRead)
```

```
#入力ファイルの読み込み
fasta <- readDNAStringSet(in_f, format="FASTQ")
```

何人かの方が、作業ディレクトリの変更も正しく行い、SRR609266.fastq.gzファイルもhogeフォルダ中に存在するにも関わらず、入力ファイル読み込み時にエラーに遭遇しました。この理由は2つ考えられます。1つめは、USBメモリにコピーする際に正しくコピーできていなかった可能性、そして2つめはUSBメモリ中のSRR609266.fastq.gzファイル段階では正しいものであったが、各自のPCにコピーする際に正しくコピーできなかった可能性です。講義中に述べたMD5チェックサム(MD5 check sum)でファイルの同一性を確認するのは重要…ですね。