

生物配列の解析

清水謙多郎

shimizuk@fc.jwu.ac.jp

BioPython

- **BioPython**
 - バイオインフォマティクスで広く使われている Pythonライブラリ
 - 生物のデータの解析や操作を簡単に行えるツールを提供
 - 開発はオープンソースで行われ、GitHubを通じて、ボランティアベースで継続的に維持されている
- 主な機能
 - 配列解析: DNA、RNA、タンパク質の配列操作
 - データ形式: FASTA、GenBank、PDBファイルなど、主要なデータ形式（ファイル形式）に対応
 - データベースアクセス: 生物データベースからのデータの取得

ゲノムデータベースにアクセスする

- アメリカ国立生物工学情報センター
(National Center of Biotechnology Information, NCBI)
 - バイオテクノロジーや分子生物学に関連するデータベースやソフトウェアを開発し、サービスを提供している
- <https://www.ncbi.nlm.nih.gov/>

An official website of the United States government [Here's how you know](#)

National Library of Medicine
National Center for Biotechnology Information [Log in](#)

All Databases [Search](#)

Welcome to NCBI

The National Center for Biotechnology Information advances science and health by providing access to biomedical and genomic information.

[About the NCBI](#) | [Mission](#) | [Organization](#) | [NCBI News & Blog](#)

Submit
Deposit data or manuscripts into NCBI databases

Download
Transfer NCBI data to your computer

Learn
Find help documents, attend a class or watch a tutorial

Popular Resources

PubMed
Bookshelf
PubMed Central
BLAST
Nucleotide
Genome
SNP
Gene
Protein
PubChem

NCBI News & Blog

Comparing Yeast Species Used in Beer Brewing and Bread Making 29 Sep 2023

NCBI Home

Resource List (A-Z)

All Resources

Chemicals & Bioassays

Data & Software

DNA & RNA

Domains & Structures

Genes & Expression

Genetics & Medicine

Genomes & Maps

Homology

Literature

Proteins

Sequence Analysis

Taxonomy

Develop
Use NCBI APIs and code

Analyze
Identify an NCBI tool for your

Research
Explore NCBI research and

NCBIのウェブページ

An official website of the United States government [Here's how you know](#)



[shimizu5455@gmail...](#)

All Databases ▾

Search

NCBI Home

Resource List (A-Z)

All Resources

Chemicals & Bioassays

Data & Software

DNA & RNA

Domains & Structures

Genes & Expression

Genetics & Medicine

Genomes & Maps

Homology

Literature

Proteins

Sequence Analysis

Taxonomy

Training & Tutorials

Variation

Welcome to NCBI

The National Center for Biotechnology Information advances science and health by providing access to biomedical and genomic information.

[About the NCBI](#) | [Mission](#) | [Organization](#) | [NCBI News & Blog](#)

Submit

Deposit data or manuscripts into NCBI databases



Download

Transfer NCBI data to your computer



Learn

Find help documents, attend a class or watch a tutorial



Develop

Use NCBI APIs and code libraries to build applications



Analyze

Identify an NCBI tool for your data analysis task



Research

Explore NCBI research and collaborative projects



Popular Resources

PubMed

Bookshelf

PubMed Central

BLAST

Nucleotide

Genome

SNP

Gene

Protein

PubChem

NCBI News & Blog

New and Improved SciENcv Biographical Sketch Experience Coming Soon!

20 Jul 2023

Required for NSF grant application

submissions beginning October 2023 via

RefSeq Release 219

18 Jul 2023

RefSeq release 219 is now available online and from the FTP site. You can access RefSeq data through NCBI

dbGaP: Making it Easier to Find Study Data with Third-Party Annotations

「Genome」をクリックする

大腸菌ゲノムの取得（1）



Search NCBI ...

NCBIのGenomeのページ

<https://www.ncbi.nlm.nih.gov/genome/>

Log in

NCBI Datasets Taxonomy Genome Gene Command-line tools Documentation

Genome

Search by taxonomic name or ID, Assembly name, BioProject, BioSample, WGS or Nucleotide accession

Search term

Enter a search term

Search

Try examples: [Homo sapiens](#) [GCF_000001405.40](#) [PRJNA489243](#) [SAMN15960293](#) [WFKY01](#) [GRCh38.p14](#) [NC_000913.3](#)

Genomic data available from NCBI Datasets

Click below to learn more about the genomic data available from NCBI Datasets.



Eukaryota



Archaea



Bacteria



Viruses

All Genomes

2.54M

Total

38.64K

Reference

2.08M

Annotated



大腸菌ゲノムの取得（2）

NIH National Library of Medicine
National Center for Biotechnology Information

Search NCBI ... Log in

NCBIのGenomeのページ
<https://www.ncbi.nlm.nih.gov/genome/>

NCBI Datasets Taxonomy Genome Gene Command-line tools Documentation

Genome

Search by taxonomic name or ID, Assembly name, BioProject, BioSample, WGS or Nucleotide accession

Search term Esch | X Search

「Escherichia coli K-12」のゲノムを取得したい
途中まで入力すると、オートコンプリートで候補が出てくる

- Escherichia coli
- Escherichia
- Escherichia coli K-12
- Escherichia fergusonii
- Escherichia coli BL21
- Escherichia coli str. K-12 substr. MG1655
- Eschrichtius robustus (grey whale)
- Escherichia coli O157
- Escherichia albertii
- Escherichia marmotae
- Escherichia coli Nissle 1917

Bacteria 2.0 M Total 86.6 M Reference 2.0 M Annotated

Viruses



大腸菌ゲノムの取得 (3)

NIH National Library of Medicine
National Center for Biotechnology Information

Search NCBI ... Log in

NCBI Datasets Taxonomy Genome Gene Command-line tools Documentation

「NCBI Datasets」を選択

Genome

Download a genome data package including genome, transcript and protein sequence, annotation and a data report

Selected taxa
Escherichia coli K-12 Enter one or more taxonomic names

「Escherichia coli」にヒットしたゲノム配列が表示される
ここから選択するのはたいへん

Filters

Download	Select columns	123 Genomes	Rows per page	20	1-20 of 123	<	>
<input type="checkbox"/>	Assembly	GenBank	RefSeq	Scientific name	Modifier	Annotation	Action
<input type="checkbox"/>	ASM584v2	GCA_000005845.2	GCF_000005845.2	Escherichia coli str. K-12 substr...	K-12 substr. MG165...	<input type="button" value="NCBI RefSeq"/> <input type="button" value="Submitter"/>	
<input type="checkbox"/>	ASM2564343v1	GCA_025643435.1	GCF_025643435.1	Escherichia coli str. K-12 substr...	K-12 substr. MG165...	<input type="button" value="NCBI RefSeq"/>	
<input type="checkbox"/>	ASM2564345v1	GCA_025643455.1	GCF_025643455.1	Escherichia coli str. K-12 substr...	K-12 substr. MG165...	<input type="button" value="NCBI RefSeq"/>	
<input type="checkbox"/>	ASM154463v1	GCA_001544635.1	GCF_001544635.1	Escherichia coli str. K-12 substr...	K-12 substr. MG165...	<input type="button" value="NCBI RefSeq"/> <input type="button" value="Submitter"/>	
<input type="checkbox"/>	ASM156633v1	GCA_001566335.1	GCF_001566335.1	Escherichia coli str. K-12 substr...	JW5437-1 substr. ...	<input type="button" value="NCBI RefSeq"/> <input type="button" value="Submitter"/>	
<input type="checkbox"/>	ASM284368v1	GCA_002843685.1	GCF_002843685.1	Escherichia coli str. K-12 substr...	K-12 substr. MG165...	<input type="button" value="NCBI RefSeq"/> <input type="button" value="Submitter"/>	
<input type="checkbox"/>	ASM130806v1	GCA_001308065.1	GCF_001308065.1	Escherichia coli str. K-12 substr...	K-12 substr. MG165...	<input type="button" value="NCBI RefSeq"/> <input type="button" value="Submitter"/>	
<input type="checkbox"/>	ASM120710v1	GCA_002607105.1	GCF_002607105.1	Escherichia coli str. K-12 substr...	K-12 substr. MG165...	<input type="button" value="NCBI RefSeq"/>	

Feedback

大腸菌ゲノムの取得（4）



Search NCBI ...



NCBI Datasets Taxonomy Genome Gene Command-line tools Documentation

NCBI Datasets

A one-stop shop for finding, browsing, and downloading genomic data

Enter a species

Examples: *Helianthus annuus* *red-winged blackbird* *Amphiprion ocellaris*



How to use NCBI Datasets

The best way to start is to use the search bar above. But here's an example of the types of resources and data we offer.

What can you learn about *Ursus arctos* (brown bear) in NCBI Datasets?



Looking for basic information?

Browse the taxonomy tree
View the *Ursus arctos* taxonomy page



Interested in genomic data?

Feedback

大腸菌ゲノムの取得（5）



Search NCBI ...



NCBI Datasets Taxonomy Genome Gene Command-line tools Documentation

NCBI Datasets

A one-stop shop for finding, browsing, and downloading genomic data

E

Escherichia coli (E. coli)

Escherichia coli K-12

Equus caballus (horse)

Escherichia

Enterovirus

Enterobacteriaceae

Enterobacter

Enterococcus

Enterococcus faecium

Erignathus barbatus (bearded seal)

Eukaryota (eucaryotes)

オートコンプリートを使って
「Escherichia coli K-12」を選択



is of resources and data we offer.

What's new in NCBI Datasets?



Looking for basic information?

Browse the taxonomy tree

View the *Tursiops truncatus* taxonomy page



Interested in genomic data?

Feedback

大腸菌ゲノムの取得（6）



Search NCBI ...

Log in

NCBI Datasets Taxonomy Genome Gene Command-line tools Documentation

Escherichia coli K-12 ☆

Escherichia coli k-12 is a strain of E. coli (Escherichia coli).

NCBI Taxonomy ID 83333

Taxonomic rank strain

Current scientific name Escherichia coli K-12

[View taxonomic details](#)



Browse taxonomy

Genome

[Browse all 123 genomes](#)

Reference genome

[ASM584v2](#)

Univ. Wisconsin (2013). Strain: K-12 substr. MG1655.

RefSeq GCF_00000584.2

[Download](#)

まず、ゲノムデータの概要を
閲覧してみよう

Lineage

[Bacteria \(eubacteria\)](#)

Superkingdom

[Pseudomonadota](#)

Phylum

[Gammaproteobacteria](#)

Class

[Enterobacterales](#)

Order

[Enterobacteriaceae](#)

Family

[Escherichia](#)

Genus

[Escherichia coli](#)

Species

[View full lineage](#)

[Browse taxonomy](#)



大腸菌ゲノムの取得（7）



Search NCBI ...



NCBI Datasets Taxonomy Genome Gene Command-line tools Documentation

Genome assembly ASM584v2 reference

Download

datasets

curl

Actions

NCBI RefSeq assembly GCF_000005845.2

⋮

Submitted GenBank assembly GCA_000005845.2

⋮

Taxon *Escherichia coli* str. K-12 substr. MG1655

Strain K-12 substr. MG1655

Submitter Univ. Wisconsin

Date Sep 26, 2013

[View the legacy Assembly page](#)



[View annotated genes](#)

Assembly statistics

RefSeq

GenBank

Genome size

4.6 Mb

4.6 Mb

Additional genomes

[Browse all *Escherichia coli* genomes \(239001\)](#)

BioProject

[PRJNA225](#)

Model organism for genetics, physiology, biochemistry

Pathogen Detection Resource

[Isolate Browser](#)

[SNP Tree Viewer](#)

[Genotypes identified by AMRFinderPlus](#)

Publications

Showing 5 of 108

[Mol Syst Biol 2006](#)

[Highly accurate genome sequences of *Escherichia coli* K-12 strains MG1655 and W3110](#)

K Hayashi, et al.

[Nucleic Acids Res 2006](#)

Feedback

大腸菌ゲノムの取得 (8)

Assembly statistics

	RefSeq	GenBank
Genome size	4.6 Mb	4.6 Mb
Total ungapped length	4.6 Mb	4.6 Mb
Number of chromosomes	1	1
Number of scaffolds	1	1
Scaffold N50	4.6 Mb	4.6 Mb
Scaffold L50	1	1
Number of contigs	1	1
Contig N50	4.6 Mb	4.6 Mb
Contig L50	1	1
GC percent	50.5	50.5
Assembly level	Complete Genome	Complete Genome

Sample details

BioSample ID	SAMN02604091
Description	Sample from Escherichia coli str. K-12 substr. MG1655
Owner name	NCBI
Strain	K-12
Substrain	MG1655
Sample name	U00096
SRA	SRS6067201

[View more ▾](#)

Mol Syst Biol 2006

Highly accurate genome sequences of Escherichia coli K-12 strains MG1655 and W3110

K Hayashi, et al.

Nucleic Acids Res 2006

Escherichia coli K-12: a cooperatively developed annotation snapshot--2005

M Riley, et al.

Science 1997

The complete genome sequence of Escherichia coli K-12

P Blattner, et al.

BMC Bioinformatics 2023

RegCloser: a robust regression approach to closing genome gaps

S Cao, et al.

GigaByte 2023

Optimizing experimental design for genome sequencing and assembly with Oxford Nanopore Technologies

JM Sutton, et al.

[View all 108 in PubMed](#)


Feedback

ゲノム配列をどう決めるか？


過去の資料から

DNAシークンサ
配列断片が生成される

数百bp(ショートリード)
~数万bp(ロングリード)




現在のシークンサでは、1回の実験で 10^{12} 塩基を越える解析が可能なものが存在



ゲノムアセンブリーの質に関する指標

ゲノム1Mb
(1000kb)



アセンブリ結果のコンティグ長を大きい順に加算し、
全体の50%（半分）を超える大きさになったコンティグ長をN50として表し、本数をL50として表す。

大腸菌ゲノムの取得 (9)



Search NCBI ...



NCBI Datasets Taxonomy Genome Gene Command-line tools Documentation

Genome assembly ASM584v2

[reference](#)

「Download」ボタンを
押す

[Download](#)



NCBI RefSeq assembly GCF_000005845.2

Submitted GenBank assembly GCA_000005845.2

Taxon *Escherichia coli* str. K-12 substr. MG1655

Strain K-12 substr. MG1655

Submitter Univ. Wisconsin

Date Sep 26, 2013

Actions

[View the legacy Assembly page](#)



[View annotated genes](#)

Assembly statistics

RefSeq

GenBank

Genome size

4.6 Mb

4.6 Mb

Additional genomes

[Browse all *Escherichia coli* genomes \(239001\)](#)

BioProject

[PRJNA225](#)

Model organism for genetics, physiology, biochemistry

Pathogen Detection Resource

[Isolate Browser](#)

[SNP Tree Viewer](#)

[Genotypes identified by AMRFinderPlus](#)

Publications

Showing 5 of 108

[Mol Syst Biol 2006](#)

[Highly accurate genome sequences of *Escherichia coli* K-12 strains MG1655 and W3110](#)

K Hayashi, et al.

[Nucleic Acids Res 2006](#)

Feedback

大腸菌ゲノムの取得（10）

NIH National Library of Medicine
National Center for Biotechnology Information

Search NCBI...

NCBI Datasets Taxonomy Genome

Genome assembly

Download datasets URL

NCBI RefSeq assembly GCF_

Submitted GenBank assembly GCA_

Taxon Escherichia coli

Strain K-12

Submitter Univ.

Date Sep 2006

View annotated genes

Assembly statistics

RefSeq GenBank

Genome size 4.6 Mb 4.6 Mb

Total unmasked length 4.6 Mb 4.6 Mb

Download Package

1 genome selected for download

Select file source

All (radio button selected)

RefSeq only

GenBank only

Select file types

Genome sequences (FASTA)

Annotation features (GTF)

Annotation features (GFF)

Sequence and annotation (GBFF)

Transcripts (FASTA)

Genomic coding sequences (FASTA)

Protein (FASTA) (checkbox circled in red)

Sequence report (JSONL)

Assembly data report (JSONL)

Your selected data will be downloaded as a ZIP archive

Estimated file size is 5 MB

Name your file ncbi_dataset.zip

Cancel Download

Log in

International genomes

All Escherichia coli genomes (287362)

project

25

Organism for genetics, physiology, and biochemistry

Oxygen Detection

source

Browser

View

es identified by AMRFinderPlus

carries

「Genome Sequences (FASTA)」(デフォルトでチェック済み)と「Protein (FASTA)」をチェックして、「Download」ボタンを押す

大腸菌ゲノムの取得（11）

- 参照配列GCF_000005845.2を選択
- 圧縮ファイルの中の`ncbi_dataset/data/`の下に配列が存在
 - GCF_000005845.2_ASM584v2_genomic.fna
 - protein.faa

大腸菌ゲノムの取得（12）

GCF_000005845.2_ASM584v2_genomic.fna

解凍した結果

>NC_000913.3 Escherichia coli str. K-12 substr. MG1655, complete genome
AGCTTTCAATTGACTGCAACGGCAATATGTCTCTGTGTGGATTAAAAAAGAGTGTCTGATAGCAGCTTCTGAAC TG
GTTACCTGCCGTGAGTAAATTAAAATTATTGACTTAGGTCACTAAATACTTAACCAATATAGGCATAGGCCACAGAC
AGATAAAAATTACAGAGTACACAACATCCATGAAACGCATTAGCACCACCATTACCAACACCATTACCAACAGGT
AACGGTGCAGGGCTGACCGTACAGGAAACACAGAAAAAGCCGCACCTGACAGTGCAGGCTTTTTTCGACCAAAGG
TAACGAGGTAAACAACCATGCGAGTGTGAAGTTCGGCGGTACATCAGTGGAAATGCAGAACGTTCTGCGTGTGCCG
ATATTCTGAAAGCAATGCCAGGCAGGGCAGGTGGCCACCGTCCTCTGCCCGCAGGAAATCACCAACACCTGGTG
GCGATGATTGAAAAAACATTAGCGGCCAGGATGCTTACCCAATATCAGCGATGCCAACGTATTTGCCAACCTT
GACGGGACTCGCCGCCAGCGGGTTCCCGCTGGCGAATTGAAAATTCGTCATCAGGAATTGCCCAAATAA
AACATGTCCTGCATGGCATTAGTTGTTGGGCAGTGCCCGGATAGCATCAACGCTGCCGTGATTGCCGTGGCAGAAA
ATGTCATGCCATTATGCCGGCGTATTAGAAGCGCGGTACAACGTTACTGTTATCGATCCGGTCGAAAAACTGCT
GGCAGTGGGCATTACCTCGAATCTACCGTCGATATTGCTGAGTCCACCCGCCGTATTGCCGCAAGCCGATCCGGCTG
ATCACATGGTGTGATGGCAGGTTACCGCCGTAATGAAAAGGCAGACTGGTGGTGTGACGGGCTATACCTG
TACTCTGCTGCCGTGCTGGCTGCCTGTTACCGCCGATTGTTGCGAGATTGGACGGACGTTGACGGGCTATACCTG
CGACCCCGCTCAGGTGCCGATGCGAGGTTGTGAAGTCGATGTCCTACCAAGGAAGCGATGGAGCTTCTACTTCGGCG
CTAAAGTTCTCACCCCCGACCATTACCCCATGCCAGTCCAGATCCCTGCCTGATTAAAATACCGAAATCCT
CAAGCACCAGGTACGCTATTGGTGCCAGCGTGTGAAGACGAATTACCGGTCAAGGGATTCCAATCTGAATAACAT
GGCAATGTTCAGCGTTCTGGTCCGGGATGAAAGGGATGGTCGGCATGGCGCGCGTCTTGAGCGATGTCACGCG
CCCGTATTCCGTGGTGTGATTACGCAATCATCTCCGAATACAGCATCAGTTCTGCGTCCACAAAGCAGTGTG
CGAGCTGAACGGCAATGCAGGAAGAGTTCTACCTGGAACTGAAAGAAGGCTACTGGAGCCGCTGGCAGTGACGGAAACG
GCTGGCATTATCTCGTGGTAGGTATGCGCACCTGCGTGGGATCTCGCGAAATTCTTGCCGACTGGCCC
GCGCCAATATCAACATTGTCGCCATTGCTCAGGGATCTTCTGAACGCTCAATCTCTGCGTGGTAAATAACGATGATGCG
ACCACTGGCGTGCCTACTCATCAGATGCTTCAATACCGATCAGGTTATCGAAGTGTGATTGGCGTCGGTGG
CGTGGCGGTGCGCTGCTGGAGCAACTGAAGCGTCAGCAAAGCTGGCTGAAGAATAAACATATCGACTTACGTTCTGCG
GTGTTGCCAACTCGAAGGCTGCTCACCAATGTACATGGCCTTAATCTGGAAAATGGCAGGAAGAATGGCGCAAGCC
AAAGAGCGTTAATCTGGCGCTTAATCGCCTCGTGAAGAATATCATCTGCTGAACCCGGTATTGTTGACTGCAC
TTCCAGGCCAGGCACTGGCGGATCAATATGCCACTTCTGCGGAAGGTTCCACGTTGTCACGCCAACAAAAGGCCA
ACACCTCGTCGATGGATTACTACCATCAGTGCCTATGCCGGAAAATGCCGGCGTAAATTCCCTATGACACCAAC
GTTGGGCTGGATTACCGTTATTGAGAACCTGCAAAATCTGCTCAATGCAGGTGATGAATTGATGAAGTCTCCGGCAT
TCTTCTGGTTCGCTTCTTATATCTCGCAAGTTAGACGAAGGCATGAGTTCTCCGAGGCAGCCTGGCGCGGG
AAATGGTTATACCGAACCGGACCCGCGAGATGATCTTCTGGTATGGATGTCGCGTAAACTATTGATTCTCGCTCGT
GAAACGGGACGTGAACCTGGAGCTGGCGGATATTGAAATTGAAACCTGCTGCTGCCGAGAGTTAACGCCGAGGGTGTG
TGCGCTTTATGGCGAATCTGTACAACACTCGACGATCTTGCCTGCCGCGCTGGCGAAGGCCGTGATGAAGGAAAAG
TTTGCCTATGTTGGCAATATTGATGAAGATGGCGTCTGCCGCTGAAGATTGCCGAAGTGGATGGTAAATGATCCGCTG
TTCAAAGTGAAGGAAACGCCCTGCCCTATAGCCACTATTATCAGCCGCTGCCGTGGTACTGCCGCGATA
TGGTGCAGGGCAATGACGTTACAGCTGCCGGTCTTGCTGATCTGCTACGTACCTCTCATGGAAGTTAGGAGTCTGAC

FASTA形式

大腸菌ゲノムの取得（13）

GCF_000005845.2_ASM584v2_protein.faa

>NP_414542.1 thr operon leader peptide [Escherichia coli str. K-12 substr. MG1655]

MKRISTTITTTITTTGNGAG

>NP_414543.1 fused aspartate kinase/homoserine dehydrogenase 1 [Escherichia coli str. K-12 substr. MG1655]
MRVLKFGGTSVANAERFLRVADILESNARQGVATVLSAPAKITNHVAMIEKTISGQDALPNISDAERIFAELLTGLAA
AQPGFPLAQLKTFVDQEFAQIKHVLHGSQLGQCPDSINAALICRGEKMSIAIMAGVLEARGNVTIDPVEKLLAVGHY
LESTVDIAESTRRIASRIPADHMVLMAGFTAGNEKGELVVLGRNGSDYSAAVLAACLRADCCEIWTDVDGVYCDPRQV
PDARLLKSMSYQEAMELSYFGAKVLHPRTITPIAQFQIPCLIKNTGNPQAPGTLIGASRDEELPVKGISNLNNMAMFSV
SGPGMKGVMVGMAARVFAAMSRARISVVLITQSSEYSISFCVPQSDCVRAERAMQEEFYLELKEGLLEPLAVTERLAIIS
VVGDGMRTLRGISAKFFAALARANINIVIAIQGSSERSISVVVNNDATTGVRVTHQMLFNTDQVIEVFVIGVGGVGGAL
LEQLKRQQSWLKNKHIDLRCVGVANSKALLTNVHGLNLENWQEELAQAKEPFNLGRLIRLVKEYHLLNPVIVDCTSSQAV
ADQYADFLREGFHVVTPNKKANTSSMDYYHQLRYAAEKSRRKFLYDTNVGAGLPVIENLQNLLNAGDELMKFSGILSGSL
SYIFGKLDEGMSFSEATTLAREMGYTEPDPRDDLSGMDVARKLLILARETGRELADIEIEPVLPAAEFNAEGDVAAFMA
NLSQLDDLFAARVAKARDEGKVLRVGNIDEDGVCRVKIAEVGNDPLFKVKNGENALAFYSHYYQPLPLVLRGYGAGND
VTAAGVFADLLRTLSWKLGV

>NP_414544.1 homoserine kinase [Escherichia coli str. K-12 substr. MG1655]

MVKVYAPASSANMSVGFDVLAvgavTPVDGALLGDVVTVEAAETFSLNNLGRFADKLPSEPRENIVYQCWERFCQELGKQI
PVAMTLEKNMPIGSGLGSSACSVAAALMAMNEHCGKPLNDTRLLALMGELEGRISGSIHYDNVAPCFLGGMQLMIEENDI
ISQQVPGFDEWLWVLAyPGIKVSTAEARAILPAQYRRQDCIAHGRHLAGFIHACYSRQPPELAALKMDVIAEPYRERLLP
GFRQARQAAEIGAVASGIGSGPTLFALCDKPETAQRVADWLGNLYLQNQEGFVHICRLDTAGARVLEN

>NP_414545.1 threonine synthase [Escherichia coli str. K-12 substr. MG1655]

MKLYNLKDNEQVSFAQAVTQGLGKNQGLFFPHDLPEFSLTEIDEMLKLDFTVRSAKILSAFIGDEIPQEILEERVRAAF
AFPAPVANVESDVGCLELFHGPTLAFKDFGGRFMAQMLTHIAGDKPVILTATSGDTGAAVAFYGLPNVKVILYPRG
KISPLQEKLFCTLGGNIETVAIDGDFDACQALVKQAFDDEELKVALGLNSANSINISRLIAQICYYFEAVAQLPQETRNQ
LVSVPSGNFGDLTAGLLAKSLGLPVKRFIAATNVNDTVPRFLHDGQWSPKATQATLSNAMDVSQPNNWPRVEELFRRKI
WQLKELYAAVDDETTQQTMRELKELEYTSEPHAAVAYRALRDQLNPGEYGLFLGTAHPAKFKESVEAILGETLDLPKEL
AERADLPLLSHNLPADFAALRKLMNNHQ

>NP_414546.1 DUF2502 domain-containing protein YaaX [Escherichia coli str. K-12 substr. MG1655]

MKKMQSIVLALSLSVLVAPMAAQAAEITLVPSVKLQIGDRDNRGYYWDGGHWRDHGWWKQHYEWGRNRWHLHGPPPPRHH
KKAPHDHHGGHGPBKHH

>NP_414547.1 peroxide stress resistance protein YaaA [Escherichia coli str. K-12 substr. MG1655]

MLILISPAKTLQYQSPLTTRYTLPPELDDNSQQLIHEARKLTPQISTLMRISDKLAGINAARFHWDWPQDFTPANARQAI
LAFKGDVYTGLQAETFSEDDFDFAQQHRLMLSGLYGVLRPLDLMQPYRLEMGIRLENARGKDLYQFWGDIITNKLNEALA
AQGDNVVINLASDEYFKSVKPKKLNAEIIKPVFLDEKNGKFKIISFYAKKARGLMSRFIIENRLTKPEQLTGFNSEGYFF
DEDSSNGELVFKRYEQR

>NP_414548.1 putative transporter YaaJ [Escherichia coli str. K-12 substr. MG1655]

MPDFFSFINSVLWGSVMIYLLFGAGCWFTFRTGFVQFRYIRQFGKSLKNSIHPQPGGLTSFQSLCTS LAARVGSGNLAGV

大腸菌K12株の
ゲノムから翻訳
されるタンパク質
のアミノ酸配列

FASTA形式

大腸菌ゲノムの取得（14）



Search NCBI ...

Log in

NCBI Datasets Taxonomy Genome Gene Command-line tools Documentation

次に、Escherichia coli O157:H7 str. Sakaiを選択

NCBI Datasets

A one-stop shop for finding, browsing, and downloading genomic data

- Escherichia coli
- Escherichia coli O157** (highlighted with a red circle)
- Escherichia coli DH5[alpha]
- Escherichia coli BL21(DE3)
- Escherichia coli ATCC 25922
- Escherichia coli B
- Escherichia coli BW25113
- Escherichia coli Nissle 1917
- Escherichia coli K1
- Escherichia coli O157:H7 str. Sakai** (highlighted with a red circle)
- Escherichia coli ATCC 8739
- Escherichia coli str. K-12 substr. DH10B

こちらは選ばない！

Looking for basic information?
Browse the taxonomy tree
View the Ursus arctos taxonomy page



大腸菌ゲノムの取得（15）



Search NCBI ...

Log in

NCBI Datasets **Taxonomy** Genome Gene Command-line tools Documentation

Bacteria / Pseudomonadota / Gammaproteobacteria / Enterobacterales / Enterobacteriaceae / Escherichia / Escherichia coli

Escherichia coli O157:H7 str. Sakai ☆

Escherichia coli o157:h7 str. sakai is a strain of E. coli (Escherichia coli).

[Browse taxonomy](#)

Current scientific name Escherichia coli O157:H7 str. Sakai

Taxonomic rank strain

NCBI Taxonomy ID 386585

For more details see [NCBI Taxonomy](#)

[View the legacy Genome page](#)

Genome

[Browse all 1 genomes](#)

Reference genome

ASM886v2

GIRC (2018). Strain: Sakai substr. RIMD 0509952.

RefSeq GCF_000008865.2

ダウンロード

[Download](#)

次のページで、「Genome Sequences (FASTA)」(デフォルトでチェック済み)と「Protein (FASTA)」をチェックして、「Download」ボタンを押す

Feedback

GC含量


- 塩基配列中のGとCの割合

$$GC\text{含量} = \frac{\text{配列に含まれる} G \text{と} C \text{の数}}{\text{配列の長さ}} = \frac{G + C}{A + G + C + T}$$

- 生物種によりゲノムのGC含量は異なる
 - 放線菌は高GC (>60%)、マイコプラズマは低GC (<30%) など
- 染色体やその部位によって異なる
 - 真核生物では、GC含量が一定の領域（アイソコア）が存在することがある
 - 遺伝子が密に存在する部分ではGC含量が高くなる（例外も多い）
- 外来性領域で、GC含量に差があることがある
 - これらの領域の同定に利用される
- 核酸の立体構造の安定性に関係
 - GC含量が高いほど融解温度は高い傾向



DNAとRNA

塩基



DNA → A, C, G, T
RNA → A, C, G, U

塩基の対を形成
(水素結合による)



複製と転写は、糖の5'末端から3'末端
に向けて行われる

GCスキー (GC Skew)

- 塩基配列中のGとCの偏り

$$GC\text{スキー} = \frac{\text{配列に含まれる} G \text{と} C \text{の数の差}}{\text{配列に含まれる} G \text{と} C \text{の数の和}} = \frac{G - C}{G + C}$$

- ゲノム全体ではGとCの量はほぼ等しいが、区間を限定してカウントすると、そこに偏りが生じる
 - 一定幅のウィンドウをスライディングさせてカウント
- 環状の微生物ゲノムにおける複製のリーディング鎖とラギング鎖の違い → 複製開始・終了点の決定に利用される
 - リーディング鎖とラギング鎖の突然変異率の違い、コドン使用頻度の違いによる

リーディング鎖 (leading strand) : 新しい鎖が、DNAがほどけていく方向と同じ方向に合成される側の鎖

DNAポリメラーゼが連続的にヌクレオチドをつなげていける

したがって、リーディング鎖は途切れなく長く合成される


ラギング鎖 (lagging strand) : DNAポリメラーゼの進む向きがほどける方向と逆向きになる

このため、酵素は少しずつ戻りながら、短いDNAの断片を繰り返し合成

これらの断片は 岡崎フラグメント (Okazaki fragments) と呼ばれ、後でDNAリガーゼという酵素によって1本につなげられる

スライディングウィンドウ

配列




- 配列を一定の長さ（ウィンドウサイズ）で、一定の間隔（ステップサイズ）で切り出す
- 配列の各部分の局所的な特徴を表すのに効果的
- 生物の配列解析でよく用いられる

GC含量とGCスキーの解析例

2本鎖DNAが環状になっているのを表しておらず、2本鎖をつなげて環状に示したもの

Length: 4,686,137 bp




[CGView Server](#)の出力例
window size = 100bp

Escherichia coli str. K-12 substr. DH10B

真性細菌のリーディング鎖はラギング鎖に比べてGに富む

→ GC skewのシフトポイントはリーディング鎖とラギング鎖の境目(複製開始点と終結点)

Length: 580,076 bp



Mycoplasma genitalium G37

課題 4

大腸菌K-12とMycoplasma genitaliumのゲノムの
サイズとGC含量を比較せよ。ゲノムをダウンロードし、
Pythonのプログラムで解析せよ。結果をmanabaに提
出すること。

課題 4



Search NCBI ...



NCBI Datasets Taxonomy Genome Gene Command-line tools Documentation

NCBI Datasets

A one-stop shop for finding, browsing, and downloading genomic data

Mycoplasmoides ge

Mycoplasmoides genitalium

途中まで入力する
と、オートコンプ
リートの機能が働く



How to use NCBI Datasets

The best way to start is to use the search bar above. But here's an example of the types of resources and data we offer.

What can you learn about *Canis lupus familiaris* (dog) in NCBI Datasets?



Looking for basic information?

Browse the taxonomy tree
View the *Canis lupus familiaris* taxonomy page



Interested in genomic data?

Browse all 21 genomes

Feedback

課題 4



Search NCBI ...



NCBI Datasets **Taxonomy** Genome Gene Command-line tools Documentation

Bacteria / Mycoplasmatota / Mycoplasmoidales / Metamycoplasmataceae / Mycoplasmoides

Mycoplasmoides genitalium ☆

Mycoplasmoides genitalium is a species of bacteria in the family *Metamycoplasmataceae*.

[Browse taxonomy](#)

Current scientific name *Mycoplasmoides genitalium*

Taxonomic rank species

NCBI Taxonomy ID 2097

For more details see [NCBI Taxonomy](#)

View the legacy [Genome page](#)

External links

[Encyclopedia of Life](#)

Genome

[Browse all 6 genomes](#)

Reference genome

[ASM2732v1](#)

TIGR (2006). Strain: G-37.

RefSeq GCF_000027325.1

[Download](#)

課題 4

Search NCBI ...

NCBI Datasets Taxonomy Genome Gene Command-line tools Documentation

Genome assembly

Download datasets curl

NCBI RefSeq assembly	GCF_000027325.1
Submitted GenBank assembly	GCA_000027325.1
Taxon	Mycoplasma genitalium
Strain	G-37
Relation to type material	assembly
Submitter	TIGR
Date	Jan 9, 2012

[View the legacy Assembly page](#)

 View annotated genes

Assembly statistics

RefSeq	
Genome size	580.1 kb
Total ungapped length	580.1 kb
	580.1 kb

Download Package

1 Genome available for download
Select the files you want

Select file source

All (2)
 RefSeq only (1)
 GenBank only (1)

Select file types

Genome sequences (FASTA)
 Annotation features (GTF)
 Annotation features (GFF)
 Sequence and annotation (GBFF)
 Transcripts (FASTA)
 Genomic coding sequences (FASTA)
 Protein (FASTA)
 Sequence report (JSONL)
 Assembly data report (JSONL)

Your selected data will be downloaded as a ZIP archive
Estimated file size is 162 kB

Name your file —
GCF_000027325.1.zip

Safari users: please disable automatic zip file extraction. [More info...](#)

Cancel **Download**


tional genomes
all Mycoplasmoides genitalium s (6)
roject
ave agent of a wide range of tal and respiratory tract infections
lications
of 90
Acad Sci U S A 2006
al genes of a minimal bacterium et al.
1995
imal gene complement of asma genitalium r, et al.
in Bio 2021
Dom: evolutionary modeling of families by assessing translocations in domains et al.
Biol 2021
informed prediction of bacterial lic pathways and reconstruction of e metabolic models J Zimmermann, et al.

配列を比較する方法

遺伝子やタンパク質の配列を並べて比較する
アラインメントという方法が使われる

ACGAAGCTCTA

ACCAGAGTCA



長さをそろえて、
文字と文字の「最適な」
対応関係を調べる

ACGA-AGCTCTA
||| ||| ||| | |
ACCAGAG-TC-A

必要に応じてギャップ文字「-」
を入れる

- 対応する文字がないということ
- 進化の過程で文字が挿入されたり失われたりすることがあるため

配列の類似度の表し方

- 配列一致度

- 対応する配列要素（文字）が一致している割合

$$\text{配列一致度} = \frac{\text{配列要素の一致数}}{\text{アラインメントの長さ}}$$

- 配列要素間の類似度のスコアの和を定義し、その和で配列の類似度を表す

配列の類似度（アラインメントスコア）

= 配列要素間の類似度のスコアの和

配列の類似度のスコア（1）

- 一致、不一致のスコア
 - 塩基配列の比較でよく用いられる
 - ギャップにはペナルティ（負のスコア）を与える
 - 例えば、一致 +1、不一致 -1、ギャップ -2

これは一例、いろいろなスコアが考えられる

一致 +1、不一致 -1、ギャップ -2

ACTTGATCTTA
ACTGTATTA



A C T T G A T C T T A
A C - T G - T A T T A


+1+1-2+1+1-2+1-1+1+1+1

→ +3

配列一致度 $8/11 = 72.7\%$

配列要素間の類似度のスコア（2）

- 要素間の類似度スコア
 - アミノ酸配列の比較でよく用いられる
 - 進化の過程でアミノ酸がどれくらい置換されやすいかを示す
 - 20×20のマトリックスで表される
 - 要素 (i, j) は、アミノ酸*i*からアミノ酸*j*への置換のされやすさを示すスコア
 - ギャップには置換スコアに応じたペナルティ（負のスコア）を与える




BLOSUM62については後で説明します。

置換マトリックスの推定法

- **PAM**

- Dayhoff (1978)
 - 類縁タンパク質において、進化の過程でアミノ酸が置換される割合を調べて計算



- **BLOSUM**

- Henikoffら (1992)
 - 類縁タンパク質の複数の配列のアラインメントを作成し、実際に観測されるアミノ酸の置換をもとに計算



PAMマトリックス

	A	R	N	D	C	Q	E	G	H	I	L	K	M	F	P	S	T	W	Y	V
A	3																			
R	-3	6																		
N	-1	-1	4																	
D	0	-3	2	5																
C	-3	-4	-5	-7	9															
Q	-1	1	0	1	-7	6														
E	0	-3	1	3	-7	2	5													
G	1	-4	0	0	-4	-3	-1	5												
H	-3	1	2	0	-4	3	-1	-4	7											
I	-1	-2	-2	-3	-3	-3	-4	-4	-4	6										
L	-3	-4	-4	-5	-7	-2	-4	-5	-3	1	5									
K	-2	2	1	-1	-7	0	-1	-3	-2	-3	-4	5								
M	-2	-1	-3	-4	-6	-1	-3	-4	-4	1	3	0	8							
F	-4	-5	-4	-7	-6	-6	-7	-5	-3	0	0	-7	-1	8						
P	1	-1	-2	-3	-4	0	-2	-2	-1	-3	-3	-2	-3	-5	6					
S	1	-1	1	0	0	-2	1	-2	-2	-4	-1	-2	-3	1	3					
T	1	-2	0	-1	-3	-2	-2	-1	-3	0	-3	-1	-1	-4	-1	2	4			
W	-7	1	-4	-8	-8	-6	-8	-8	-3	-6	-3	-5	-6	-1	-7	-2	-6	12		
Y	-4	-5	-2	-5	-1	-5	-5	-6	-1	-2	-2	-5	-4	4	-6	-3	-3	-2	8	
V	0	-3	-3	-3	-3	-3	-2	-3	3	1	-4	1	-3	-2	-2	0	-8	-3	5	

PAM120

	A	R	N	D	C	Q	E	G	H	I	L	K	M	F	P	S	T	W	Y	V
A	2																			
R	-2	6																		
N	0	0	2																	
D	0	-1	2	4																
C	-2	-4	-4	-5	4															
Q	0	1	1	2	-5	4														
E	0	-1	1	3	-5	2	4													
G	1	-3	0	1	-3	-1	0	5												
H	-1	2	2	1	-3	3	1	-2	6											
I	-1	-2	-2	-2	-2	-2	-2	-3	-2	5										
L	-2	-3	-3	-4	-6	-2	-3	-4	-2	2	6									
K	-1	3	1	0	-5	1	0	-2	0	-2	-3	5								
M	-1	0	-2	-3	-5	-1	-2	-3	-2	2	4	0	6							
F	-4	-4	-4	-6	-4	-5	-5	-5	-2	1	2	-5	0	9						
P	1	0	-1	-1	-3	0	-1	-1	0	-2	-3	-1	-2	-5	6					
S	1	0	1	0	0	-1	0	1	-1	-1	-3	0	-2	-3	1	3				
T	1	-1	0	0	-2	-1	0	0	-1	0	-2	0	-1	-2	0	1	3			
W	-6	2	-4	-7	-8	-5	-7	-7	-3	-5	-2	-3	-4	0	-6	-2	-5	17		
Y	-3	-4	-2	-4	0	-4	-4	-5	0	-1	-1	-4	-2	7	-5	-3	-3	0	10	
V	0	-2	-2	-2	-2	-2	-2	-1	-2	4	2	-2	2	-1	-1	-1	0	-6	4	

PAM250

BLOSUMマトリックス

	A	R	N	D	C	Q	E	G	H	I	L	K	M	F	P	S	T	W	Y	V
A	5																			
R	-2	7																		
N	-1	-1	7																	
D	-2	-2	2	8																
C	-1	-4	-2	-4	13															
Q	-1	1	0	0	-3	7														
E	-1	0	0	2	-3	2	6													
G	0	-3	0	-1	-3	-2	-3	8												
H	-2	0	1	-1	-3	1	0	-2	10											
I	-1	-4	-3	-4	-2	-3	-4	-4	-4	5										
L	-2	-3	-4	-4	-2	-2	-3	-4	-3	2	5									
K	-1	3	0	-1	-3	2	1	-2	0	-3	-3	6								
M	-1	-2	-2	-4	-2	0	-2	-3	-1	2	3	-2	7							
F	-3	-3	-4	-5	-2	-4	-3	-4	-1	0	1	-4	0	8						
P	-1	-3	-2	-1	-4	-1	-1	-2	-2	-3	-4	-1	-3	-4	10					
S	1	-1	1	0	-1	0	-1	0	-1	-3	-3	0	-2	-3	-1	5				
T	0	-1	0	-1	-1	-1	-1	-2	-2	-1	-1	-1	-2	-1	2	5				
W	-3	-3	-4	-5	-5	-1	-3	-3	-3	-2	-3	-1	1	-4	-4	-3	15			
Y	-2	-1	-2	-3	-3	-1	-2	-3	2	-1	-1	-2	0	4	-3	-2	-2	2	8	
V	0	-3	-3	-4	-1	-3	-3	-4	-4	4	1	-3	1	-1	-3	-2	0	-3	-1	5

BLOSUM50

	A	R	N	D	C	Q	E	G	H	I	L	K	M	F	P	S	T	W	Y	V
A	4																			
R	-1	5																		
N	-2	0	6																	
D	-2	-2	1	6																
C	0	-3	-3	-3	9															
Q	-1	1	0	0	-3	5														
E	-1	0	0	2	-4	2	5													
G	0	-2	0	-1	-3	-2	-2	-2	6											
H	-2	0	1	-1	-3	0	0	-2	8											
I	-1	-3	-3	-3	-1	-3	-3	-4	-3	4										
L	-1	-2	-3	-4	-1	-2	-3	-4	-3	2	4									
K	-1	2	0	-1	-3	1	1	-2	-1	-3	-2	5								
M	-1	-1	-2	-3	-1	0	-2	-3	-2	1	2	-1	5							
F	-2	-3	-3	-3	-2	-3	-3	-3	-1	0	0	-3	0	6						
P	-1	-2	-2	-1	-3	-1	-1	-2	-2	-3	-3	-1	-2	-4	7					
S	1	-1	1	0	-1	0	0	0	-1	-2	-2	0	-1	-2	-1	4				
T	0	-1	0	-1	-1	-1	-1	-2	-2	-1	-1	-1	-1	-2	-1	1	5			
W	-3	-3	-4	-4	-2	-2	-3	-2	-2	-3	-2	-3	-1	1	-4	-3	-2	11		
Y	-2	-2	-2	-3	-2	-1	-2	-3	2	-1	-1	-2	-1	3	-3	-2	-2	2	7	
V	0	-3	-3	-3	-1	-2	-2	-3	-3	3	1	-2	1	-1	-2	-2	0	-3	-1	4

BLOSUM62

PAM120の物理化学特性による整理

	C	S	T	P	A	G	N	D	E	Q	H	R	K	M	I	L	V	F	Y	W	
C	9	0	-3	-4	-3	-4	-5	-7	-7	-7	-4	-4	-7	-6	-3	-7	-3	-6	-1	-8	C
S	0	3	2	1	1	1	1	0	-1	-2	-2	-1	-1	-2	-2	-4	-2	-3	-3	-2	S
T	-3	2	4	-1	1	-1	0	-1	-2	-2	-3	-2	-1	-1	0	-3	0	-4	-3	-6	T
P	-4	1	-1	6	1	-2	-2	-3	-2	0	-1	-1	-2	-3	-3	-3	-2	-5	-6	-7	P
A	-3	1	1	1	4	1	-1	0	0	-1	-3	-3	-2	-2	-1	-3	0	-4	-4	-7	A
G	-4	1	-1	-2	1	5	0	0	-1	-3	-4	-4	-3	-4	-4	-5	-2	-5	-6	-8	G
N	-5	1	0	-2	-1	0	4	2	1	0	2	-1	1	-3	-2	-4	-3	-4	-2	-4	N
D	-7	0	-1	-3	0	0	2	5	3	1	0	-3	-1	-4	-3	-5	-3	-7	-5	-8	D
E	-7	-1	-2	-2	0	-1	1	3	5	2	-1	-3	-1	-3	-3	-4	-3	-7	-5	-8	E
Q	-7	-2	-2	0	-1	-3	0	1	2	6	3	1	0	-1	-3	-2	-3	-6	-5	-6	Q
H	-4	-2	-3	-1	-3	-4	2	0	-1	3	7	1	-2	-4	-4	-3	-3	-3	-1	-3	H
R	-4	-1	-2	-1	-3	-4	-1	-3	-3	1	1	6	2	-1	-2	-4	-3	-5	-5	-5	R
K	-7	-1	-1	-2	-2	-3	1	-1	-1	0	-2	2	5	0	-3	-4	-4	-7	-5	-5	K
M	-6	-2	-1	-3	-2	-4	-3	-4	-3	-1	-4	-1	0	8	1	3	1	-1	-4	-6	M
I	-3	-2	0	-3	-1	-4	-2	-3	-3	-3	-4	-2	-3	1	6	1	3	0	-2	-6	I
L	-7	-4	-3	-3	-3	-5	-4	-5	-4	-2	-3	-4	-4	3	1	5	1	0	-2	-3	L
V	-3	-2	0	-2	0	-2	-3	-3	-3	-3	-3	-3	-4	1	3	1	5	-3	-3	-8	V
F	-6	-3	-4	-5	-4	-5	-4	-7	-7	-6	-3	-5	-7	-1	0	0	-3	8	4	-1	F
Y	-1	-3	-3	-6	-4	-6	-2	-5	-5	-5	-1	-5	-5	-4	-2	-2	-3	4	8	-2	Y
W	-8	-2	-6	-7	-7	-8	-4	-8	-8	-6	-3	1	-5	-6	-6	-3	-8	-1	-2	12	W
	C	S	T	P	A	G	N	D	E	Q	H	R	K	M	I	L	V	F	Y	W	

システイン

親水性・小型

負電荷側鎖

正電荷側鎖

疎水性

芳香族側鎖

BLOSUM62の物理化学特性による整理

	C	S	T	P	A	G	N	D	E	Q	H	R	K	M	I	L	V	F	Y	W	
C	9	-1	-1	-3	0	-3	-3	-3	-4	-3	-3	-3	-3	-1	-1	-1	-1	-2	-2	-2	C
S	-1	4	-1	-1	1	0	1	0	0	0	-1	-1	0	-1	-2	-2	-2	-2	-2	-3	S
T	-1	-1	5	-1	0	-2	0	-1	-1	-1	-2	-1	-1	-1	-1	-1	0	-2	-2	-3	T
P	-3	-1	-1	7	-1	-2	-2	-1	-1	-1	-2	-2	-1	-2	-3	-3	-2	-4	-3	-4	P
A	0	1	0	-1	4	0	-2	-2	-1	-1	-2	-1	-1	-1	-1	0	-2	-2	-3	A	
G	-3	0	-2	-2	0	6	0	-1	-2	-2	-2	-2	-2	-3	-4	-4	-3	-3	-3	-2	G
N	-3	1	0	-2	-2	0	6	1	0	0	1	0	0	-2	-3	-3	-3	-3	-2	-4	N
D	-3	0	-1	-1	-2	-1	1	6	2	0	-1	-2	-1	-3	-3	-4	-3	-3	-3	-4	D
E	-4	0	-1	-1	-1	-2	0	2	5	2	0	0	1	-2	-3	-3	-2	-3	-2	-3	E
Q	-3	0	-1	-1	-1	-2	0	0	2	5	0	1	1	0	-3	-2	-2	-3	-1	-2	Q
H	-3	-1	-2	-2	-2	-2	1	-1	0	0	8	0	-1	-2	-3	-3	-3	-1	2	-2	H
R	-3	-1	-1	-2	-1	-2	0	-2	0	1	0	5	2	-1	-3	-2	-3	-3	-2	-3	R
K	-3	0	-1	-1	-1	-2	0	-1	1	1	-1	2	5	-1	-3	-2	-2	-3	-2	-3	K
M	-1	-1	-1	-2	-1	-3	-2	-3	-2	0	-2	-1	-1	5	1	2	1	0	-1	-1	M
I	-1	-2	-1	-3	-1	-4	-3	-3	-3	-3	-3	-3	-3	1	4	2	3	0	-1	-3	I
L	-1	-2	-1	-3	-1	-4	-3	-4	-3	-2	-3	-2	-2	2	2	4	1	0	-1	-2	L
V	-1	-2	0	-2	0	-3	-3	-3	-2	-2	-3	-3	-2	1	3	1	4	-1	-1	-3	V
F	-2	-2	-2	-4	-2	-3	-3	-3	-3	-3	-1	-3	-3	0	0	0	-1	6	3	1	F
Y	-2	-2	-2	-3	-2	-3	-2	-3	-2	-1	2	-2	-2	-1	-1	-1	-1	3	7	2	Y
W	-2	-3	-3	-4	-3	-2	-4	-4	-3	-2	-2	-3	-3	-1	-3	-2	-3	1	2	11	W
	C	S	T	P	A	G	N	D	E	Q	H	R	K	M	I	L	V	F	Y	W	

システイン

親水性・小型

負電荷側鎖

正電荷側鎖

疎水性

芳香族側鎖

PAMの考え方

- シトクロムやグロビンなど、近縁のタンパク質を集め、生物の進化の過程で、各位置のアミノ酸の置換の頻度を調べた
- 100個のアミノ酸のうち1個のアミノ酸が変異する進化上の時間を1PAM (Point Accepted Mutation, 点突然変異) という
 - タンパク質によって1PAMの実時間は異なる
- PAM n とは、 n PAMの時間でどれだけアミノ酸が置換されるかを示す
 - マルコフ過程を仮定し、1PAMの置換が n PAMの時間続くと仮定
 - n の値が大きいほど、スコア値が発散

BLOSUMの考え方

- 近縁のタンパク質の配列のアラインメントを作成し、とくにギャップなしでアラインされた領域（ブロック）を取り出して、アミノ酸の置換の頻度を調べた
- BLOSUM は、 BLOcks amino acid Substitution Matrixの略
- BLOSUM m とは、 $m\%$ 以上一致した配列をひとまとめにして置換の頻度を計算したもの
 - m の値が小さいほど、（配列が似ていなくても）まとめて扱われる配列の割合が増え、スコア値が発散する

BLOSUM62 miscalculations improve search performance

To the editor:

The BLOSUM¹ family of substitution matrices, and particularly BLOSUM62, is the *de facto* standard in protein database searches and sequence alignments. In the course of analyzing the evolution of the Blocks database², we noticed errors in the software source code used to create the initial BLOSUM family of matrices (available online at <ftp://ftp.ncbi.nih.gov/repository/blocks/unix/blosum/blosum.tar.Z>). The result of these errors is that the BLOSUM matrices—BLOSUM62, BLOSUM50, etc.—are quite different from the matrices that should have been calculated using the algorithm described by Henikoff and Henikoff¹. Obviously, minor errors in research, and particularly in software source code, are quite common. This case is noteworthy for three reasons: first, the BLOSUM matrices are ubiquitous in computational biology; second, these errors have gone unnoticed for 15 years; and third, the ‘incorrect’ matrices perform better than the ‘intended’ matrices.

The error that had the most impact was an incorrect normalization during a weighting procedure; this procedure, the error and its impact are discussed in greater detail in **Supplementary Note** online. Recalculated matrices are also available in the **Supplementary Note**, and differences from the original matrices are highlighted. These two matrices differ in 15% of their positions. Both the corrected and the original source code are also available through a link in the **Supplementary Note**. It is worth noting that the relevant comparison for BLOSUM62 is not with the revised BLOSUM62 (which we call RBLOSUM62) because matrices can only be ‘fairly’ compared if they have the same relative entropy³. We found that this relative entropy (when calculated from raw matrix values), which is a measure of the information content in a substitution matrix, was inflated in the BLOSUM matrices due to the errors. Thus, BLOSUM62 is best ‘fairly’ compared with RBLOSUM64 based on raw matrix value entropies. (Comparisons based on rounded



worse than BLOSUM62 across a wide

range of errors per query cutoffs using both Smith-Waterman and BLAST search tools. (An errors-per-query cutoff is approximately equivalent to the E-value cutoff that one would use in a BLAST search, but is calculated by averaging the results of numerous searches.) Although the performance difference is statistically significant, it is, however, relatively small in magnitude. More detailed analyses about the statistically significant performance differences caused by the errors, as well as the potential origins of these performance differences, are provided in the **Supplementary Note**.

We find it interesting that the BLOSUM62 matrix is used every day (and more interesting still that its derivation is a common topic in computational biology classes), and yet we can find no previously published mention of any of the errors discussed here. We did find that some of the errors were fixed in later tangential work by the original authors¹¹, but the ‘correct’ matrices have never been published or adopted. We also note that the existence of statistically significant improvements due to (essentially random) software errors supports the notion that there is significant room for improvement in our understanding of protein evolution. Of course, software errors are quite common and nothing

ギャップペナルティ

- ギャップを挿入することで柔軟なアラインメントが可能
 \Leftrightarrow 多用しすぎると、アラインメントの意味が失われる
- ギャップには負のスコア（ペナルティ）を与える
- リニアギャップペナルティ
 - $v(k) = -kd$
- アフィンギャップペナルティ
 - $v(k) = -d - (k-1)e$



- 1回の変異事象で複数の挿入・欠失が起きる可能性が高い
 - 異なる位置の挿入・欠失は異なる変異事象によるもの
- } リニアギャップは区別しない

アラインメントスコアの計算

アラインメントスコア

配列一致度

置換スコア BLOSUM62

ギャップペナルティ $d = 8$

K S A L T I Q L I - -		
K S T L A N I F E Q V		
+5+4-1+4-1-3-3+0-3-8-8	→	-14
		27.3%

K S A L - T I - - Q L I		
K S T L A N I F E Q V -		
+5+4-1+4-8+0+4-8-8+5+1-8	→	-4
		41.7%

K S A L T - I Q L I -		
K S T L A N I F E Q V		
+5+4-1+4-1-8+4-3-3-3-8	→	-10
		36.4%

K S A L - T I - Q L I		
K S T L A N I F E Q V		
+5+4-1+4-8+0+4-8+2-2+3	→	+2
		36.4%

■
■
■

最適なアラインメント

- 一般に、最適なアラインメント（アラインメントスコアが最大のアラインメント）を求めるにはどうすればよいか？

長さ m と長さ n の2つの配列
のアラインメントの数

$$f(m, n) = \sum_{k=0}^{\min\{m,n\}} 2^k {}_m C_k {}_n C_k$$
$$= \sum_{k=0}^{\min\{m,n\}} \frac{(m+n-k)!}{k! (m-k)! (n-k)!}$$




$$\begin{aligned} f(1,2) &= f(2,1) = 5 \\ f(4,2) &= f(2,4) = 41 \\ f(8,4) &= f(4,8) = 3649 \\ f(16,8) &= f(8,16) = 39490049 \\ f(100,100) &\approx 2 \times 10^{74} \end{aligned}$$

ダイナミックプログラミング
(動的計画法)

最適アラインメントを求める手順

- 最適なアラインメントスコアを段階的に計算
 - あるところまでの最適解が求まっているとき、それを用いて、次のステップの最適解を求める
1. ステップワイスにスコア行列の要素を計算する
 2. 最適解を求めた順序を記憶しておき、後で、最適なアラインメントを求める




最短経路の場合の数

- 「スタート」から右下の「ゴール」に至る最短経路は何通りあるか？
 - 各頂点に至る最短経路の数を段階的に求める

その他のダイナミックプログラミングの応用

- 最短経路
- ゲーム理論
- 資源割り当て問題
- 音声認識
- 自然言語処理
- 物体検出

など



グローバルアラインメントとローカルアラインメント

- **グローバルアラインメント**: 配列全体にわたり類似性を考慮してアラインメント
 - 全体的に類似した配列の異なる部位を調べる
 - 同じタンパク質の生物種間の違いを調べる
 - 進化の解析を行う
 - **最適なペアワイスアラインメント**のアルゴリズムとして **Needleman-Wunsch**のアルゴリズムがある
- **ローカルアラインメント**: 局所的な類似部分をアラインメント
 - 機能に関わる配列パターンを考慮したアラインメント
 - 長さが大きく異なる配列、配列類似性が低い配列の比較に用いられる
 - **最適なペアワイスアラインメント**のアルゴリズムとして **Smith-Waterman**のアルゴリズムがある

ダイナミックプログラミング（動的計画法）による

ダイナミックプログラミングとは

- 最適性の原理
 - 与えられた問題の最適解を規模を小さくした部分問題に適用したとき、それがその部分問題の最適解となっていること
- 部分問題の解からもとの問題の解を構成することができる
- ダイナミックプログラミングの基本手順
 1. 与えられた問題の規模の小さな部分問題を解き、それらの結果を記録する
 2. 記録されている結果に基づいて、そこから導かれるより大きな部分問題をステップワイズに解く
 3. これらを与えられた問題が解けるまで繰り返す

Needleman-Wunschの基本手順


- $F(i,j)$: 部分配列 $x_1 x_2 \dots x_i$ と $y_1 y_2 \dots y_j$ の最適アライメントのスコア値
- 基本手順 (マトリックス F の形成)

$$F(i, j) = \max \begin{cases} F(i - 1, j - 1) + s(x_i, y_j) & 1 \\ F(i - 1, j) - d & 2 \\ F(i, j - 1) - d & 3 \end{cases}$$

- 初期条件: $F(0,0) = 0$
- 境界条件: $F(i,0) = -id$ $F(0,j) = -jd$
- $F(m,n)$ が最適アラインメントのスコア値
- 最大値 (max) をとるとき選択した経路を覚えておく
- 最適アラインメントは、 $F(m,n)$ から $F(0,0)$ までトレースバックにより経路をたどって求める

リニアギャップペナルティ $-d$ を仮定

ダイナミックプログラミングの計算



最大スコアを与えるパスを記録

→ 後のトレースバックに利用

1. x_i と y_j を置換

… x_i

… y_j

2. x_i がギャップに対応

… x_i


… _

3. y_j がギャップに対応

… _

… y_j

Needleman-Wunschの適用例（1）




一致+1、不一致-1

ギャップペナルティ $d = 2$

Needleman-Wunschの適用例（2）

$$\begin{array}{l} \rightarrow 0 + (+1) = 1 \\ \rightarrow -2 + (-2) = -4 \\ \downarrow -2 + (-2) = -4 \end{array}$$

最大値1を採用
赤の→を残す




一致+1、不一致-1

ギャップペナルティ $d = 2$

Needleman-Wunschの適用例（3）

$$\begin{array}{l} \rightarrow -2 + (+1) = -1 \\ \rightarrow -4 + (-2) = -6 \\ \downarrow 1 + (-2) = -1 \end{array} \left. \begin{array}{l} \text{最大値}-1を採用(赤と緑と2つあることに注意)} \\ \rightarrow \text{を2つとも残す} \end{array} \right\}$$




一致+1、不一致-1

ギャップペナルティ $d = 2$


Needleman-Wunschの適用例（4）

$$\begin{array}{l} \rightarrow -2 + (-1) = -3 \\ \rightarrow 1 + (-2) = -1 \\ \downarrow -4 + (-2) = -6 \end{array}$$

最大値-1を採用
青の→を残す




Needleman-Wunschの適用例（5）



一致+1、不一致-1

ギャップペナルティ $d = 2$


Needleman-Wunschの適用例（6）



一致+1、不一致-1

ギャップペナルティ $d = 2$



Needleman-Wunschの適用例（7）



一致+1、不一致-1


ギャップペナルティ $d = 2$

Needleman-Wunschの適用例（8）



矢印を逆にたどって、最適アライメントを求める

Needleman-Wunschの適用例（9）




$$\begin{array}{lll} \textcolor{red}{x} = -\mathbf{ACC} & \textcolor{green}{x} = \mathbf{A-CC} & \textcolor{blue}{x} = \mathbf{AC-C} \\ \textcolor{red}{y} = \mathbf{AAAC} & \textcolor{green}{y} = \mathbf{AAAC} & \textcolor{blue}{y} = \mathbf{AAAC} \end{array}$$

一致+1、不一致-1

ギャップペナルティ $d = 2$

Needleman-Wunschの適用例 (10)



Smith-Watermanのアルゴリズム

- 2つの配列の局所的に最も一致している部分のアラインメント（ローカルアラインメント）を求める
- ダイナミックプログラミングによる
- Needleman-Wunschのアルゴリズムとの違い
 - 不一致には必ず負のスコア
 - スコア行列の値が負になつたら、そこでアラインメントを中止

2つの配列のローカルアラインメントを求める

$$x = x_1 x_2 \cdots x_n$$

$$y = y_1 y_2 \cdots y_m$$


Smith-Watermanの基本手順

- $F(i,j)$: 部分配列 $x_1 x_2 \dots x_i$ と $y_1 y_2 \dots y_j$ の最適アラインメントのスコア値
- 基本手順 (マトリックス F の形成)

$$F(i, j) = \max \begin{cases} 0 \\ F(i - 1, j - 1) + s(x_i, y_j) \\ F(i - 1, j) - d \\ F(i, j - 1) - d \end{cases}$$

- 初期条件: $F(0,0) = 0$
- 境界条件: $F(i,0) = 0$ $F(0,j) = 0$
- マトリックス F 上で、スコア最大の要素を見つけ、そこからアラインメントを見つける
- 最大値 (max) をとるとき選択した経路を覚えておく
- 局所アラインメントは、最大の要素からたどれるところまでトレースバックにより経路をたどって求める

Smith-Watermanの適用例



ドットマトリックス

- **ドットマトリックス:** 比較する配列を行方向、列方法に並べ、対応する要素が一致したとき1、一致しないとき0を値としてもつマトリックス

1の要素に○を記す

		塩基配列 <i>a</i>									
		A	C	G	T	A	G	C	T	C	A
塩基配列 <i>b</i>	A	○									○
	C		○				○		○	○	
	T			○				○			
	G			○		○					
	A	○				○					○
	G			○			○				
	G			○			○				
	C		○					○	○	○	
	C		○					○	○	○	
	G			○		○					

基本的なドットマトリックス

1要素のマッチングを見るだけ
ではノイズが大きい




		塩基配列 <i>a</i>									
		A	C	G	T	A	G	C	T	C	A
塩基配列 <i>b</i>	A	○									
	C		○						○		
	T			○				○			○
	G				○						
	A	○				○				○	
	G				○					○	
	G				○				○	○	
	C		○					○		○	
	C		○					○	○	○	
	G			○		○					

フィルタリングを実施

フィルタリングにより一致部分
がより明確になる

ドットマトリックスによるアラインメント



a ACGTAGCTCCA
||| ||| |||
b ACTGAGGCCGA

a ACGTAGCTCCA
|||
b ACTGAGGCCGA

a ACGTAGCTCCA
|||
b ACTGAGGCCGA

a ACGTAG-CTCCA
||| ||| |||
b ACTGAGGC-CGA


ドットマトリックスの特徴

- アルゴリズムが単純
- 視覚的にわかりやすい
- 一致部分をマトリックスの対角成分として表示
- 同一配列のマトリックス表示によるリピート部分の検出
- 塩基配列でよく用いられる
- 1要素の一致だけでは、ノイズが大きすぎる



- フィルタリングの利用
 - スラインディングウィンドウ
(window size, stringency)
 w s

ドットマトリックスの各1の要素を基点とし、
対角線上の w 先を見て、そのうち少なくとも
 s 以上1が存在する場合、基点の1を残す



リーディングフレームの解析

- 1本のRNAは、3通りのリーディングフレーム（読み枠）の可能性があり、DNAは、順鎖、逆相補鎖あわせて6通りのリーディングフレームの可能性がある
- 3塩基の区切り方により、翻訳されるアミノ酸配列が決まる
- すべての可能性を調べるにはコンピュータ処理が適する6通りのリーディングフレーム（読み枠）

