

ライフサイエンスデータベース統合推進事業「統合化推進プログラム」平成26年度キックオフミーティング、東京JST, 2014年6月2日

蛋白質構造データバンクの高度化と 統合的運用

代表研究者:中村 春木

分担研究者:藤原 敏道

(大阪大学蛋白質研究所・教授)



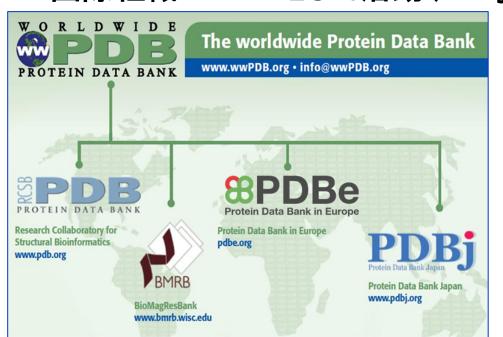


http://pdbj.org/
http://wwpdb.org/



蛋白質の形のデータバンク:PDB

- ・生体高分子の構造(形)に関する全ての情報を集めた国際的データベース:データバンク方式(1971年から開始)
- •情報は、研究者・教育者・学生・企業を問わず無償で利用される
- ・運営は各国(米国、欧州、日本)の政府機関による研究費用でまかな われている
- → 国際組織wwPDBとして活動(PDBjは2003年からの創立メンバー)



X線結晶回折実験, 核磁気共鳴(NMR)法, 超低温電子顕微鏡(EM), による実験結果のアーカイブ

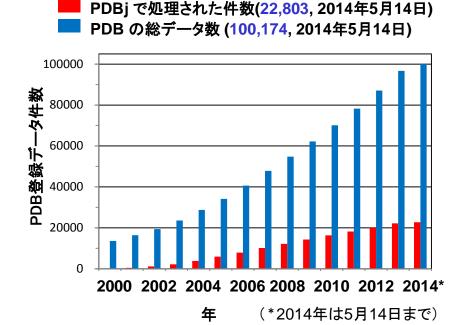




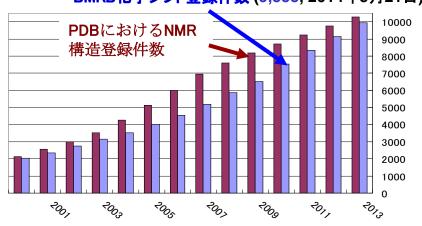
PDBjの活動

- Data-inの活動: wwPDBの一員として品質管 理をしつつ登録作業を実施 新たな標準フォーマット等 の開発(PDB/RDF, BMRB/RDF)
- Data-out の活動: 共通データのダウンロード サイト(毎週アプデート)の 運営

種々のサービスや二次 データベースの開発・提供



BMRB(化学シフト), PDB(原子座標)の登録総数の推移 BMRB化学シフト登録件数 (9,555, 2014年5月21日)





PDBj, PDBj-BMRBのData-out活動 http://pdbj.org/





PDB/RDF

世界標準のRDF format の開発

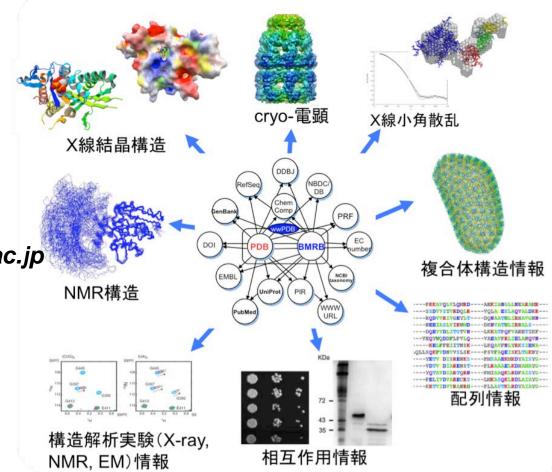
http://rdf.wwpdb.org/

ROTEIN DATA BANK	Welcome to the Worldwide Protein Data Bar
PDB/RDF	About PDB/RDI PDB/RDF , chem_comp/RDI
PDB ID: property: keywords:	(e.g., '7RSA') PDB D (e.g., 'PDBo:entity.pdbx_description') (e.g., 'alcohol')
submit reset Download XSLT stylesheet for conv	rerting PDBML to RDF: PDBML2rdf.xsl.gz (gzipped 22KB)

BMRB/RDF

http://bmrbpub.protein.osaka-u.ac.jp





```
<rdf:Description rdf:about="http://rdf.wwpdb.org/pdb/1BY4">
    <rdf:type rdf:resource="http://purl.uniprot.org/core/Structure_Resource"/>
    <database rdf:resource="http://purl.uniprot.org/database/PDB"/>
    <method rdf:resource="http://purl.uniprot.org/core/X-Ray_Crystallography"/>
    <resolution rdf:datatype="http://www.w3.org/2001/XMLSchema#float">2.10</resolution>
    </rdf:Description>
```

第二期プロジェクトの紹介

1)蛋白質構造アーカイブの構築・公開

- 1-1)wwPDBメンバーの一員として、データ登録・編集・品質管理 (remediationを含む)の実施
- 1-2)リガンド・蛋白質複合体結晶解析による医薬スクリーニング データの精密化・登録支援

2)異なる階層のデータと蛋白質構造情報との統合化

- 2-1)遺伝情報を活用した遠縁蛋白質検出と蛋白質機能推定 サービスの拡張
- 2-2)蛋白質複合体に対する多面的解析ツールおよびサービスの 開発と公開
- 2-3)統合化されたNMR実験データベースを有効利用するための ツール群開発と高度化

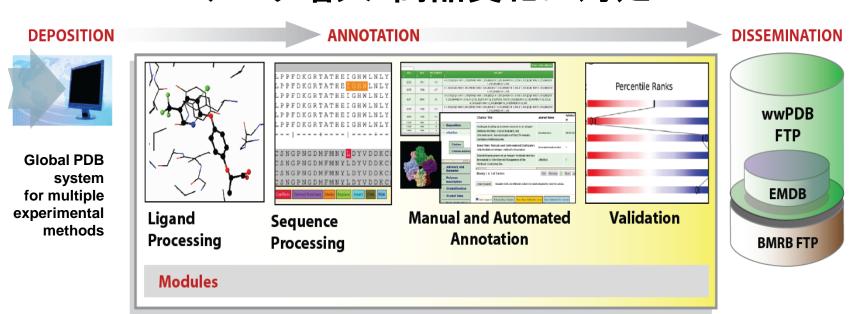
3)人材養成の実施



第二期プロジェクトの紹介

- 1)蛋白質構造アーカイブの構築・公開
- 1-1)wwPDBメンバーの一員として、データ登録・編集・品質管理 (remediationを含む)の実施
- ✓ 新たな自動登録・アノテーションシステムの導入と推進

新しいデータ処理システム データ増大・高品質化に対処





✓ Validation report (PDF版とXML版)の公開・配布



wwPDB X-ray Structure Validation Summary Report (i)

Feb 28, 2014 - 04:13 AM GMT

PDB ID : 3WDZ

Title : Crystal Structure of Keap1 in Complex with phosphorylated p62

Authors : Fukutomi, T.; Takagi, K.; Mizushima, T.; Tanaka, K.; Komatsu, M.; Ya-

mamoto, M.

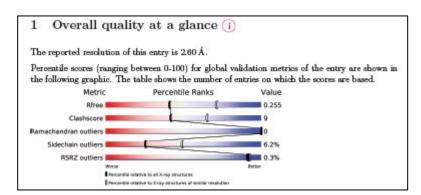
Deposited on : 2013-06-26 Resolution : 2.60 Å(reported)

This is a wwPDB validation summary report for a publicly released PDB entry.

We welcome your comments at validation@mail.wwpdb.org

A user guide is available at $\label{eq:http://wwpdb.org/ValidationPDFNotes.html} \end{substitute} A user guide is available at <math display="block">\end{substitute} http://wwpdb.org/ValidationPDFNotes.html$

Validation reportの表紙



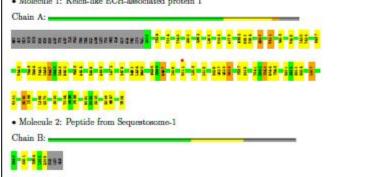
These plots are drawn for all protein, RNA and DNA chains in the entry. The first graphic for a chain summarises the proportions of errors displayed in the second graphic. The second graphic shows the sequence view annotated by issues in geometry and electron density. Residues are colorcoded according to the number of geometric quality criteria for which they contain at least one outlier: green = 0, yellow = 1, orange = 2 and red = 3 or more. A red dot above a residue indicates a poor fit to the electron density (RSRZ > 2). Stretches of 2 or more consecutive residues without

any outlier are shown as a green connector. Residues present in the sample, but not in the model,

Molecule 1: Kelch-like ECH-associated protein 1

are shown in grey.

3 Residue-property plots (1)



Validation report



✓ 新しいPDBフォーマット(PDBx/mmCIF)への移行:

ユーザに対するサービスサイト、コンバータプログラム、 セミナーやワークショップの開催

```
MOTA
                GLN A 39
                              24.690 -27.754 24.275 1.00 60.76
                                                                         N
ATOM
            CA GLN A
                              23.581 -26.768 24.416 1.00 60.98
                                                                          C
MOTA
                GLN A 39
                              23.990 -25.379 23.905 1.00 59.98
MOTA
                GLN A
                              25.070 -25.209 23.330 1.00 60.25
ATOM
            CB
               GLN A 39
                              23.136 -26.685 25.878 1.00 60.69
MOTA
                VAL A
                              23.115 -24.395 24.122 1.00 59.58
            CA
               VAL A
                              23.342 -23.010 23.690 1.00 57.26
                                                                                            PDB
ATOM
ATOM
                VAL A
                              24.000 -22.152 24.778 1.00 56.00
```

```
100p
atom site.group PDB
                                                                                             PDBx
atom site.id
_atom_site.auth_atom_id
atom site.type symbol
_atom_site.auth_comp_id
atom site.auth asym id
atom site.auth seq id
_atom_site.Cartn_x
atom site.Cartn y
_atom_site.Cartn_z
atom site.pdbx PDB model num
atom site.occupancy
_atom_site.pdbx_auth_alt_id
atom site.B iso or equiv
ATOM
          1 N
                  N GLN A
                             39
                                  24.690 -27.754
                                                    24.275 1 1.00
                                                                      60.76
MOTA
            CA
                  C GLN A
                                  23.581 -26.768
                                                    24.416 1 1.00
                                                                       60.98
MOTA
             C
                  C GLN A
                                  23.990
                                         -25.379
                                                    23.905 1 1.00
                                                                       59.98
                                                                      60.25
                                         -25.209
ATOM
                    GLN A
                                  25.070
                                                    23.330 1 1.00
                                  23.136 -26.685
                                                                       60.69
MOTA
             CB
                                                    25.878 1 1.00
                  C GLN
                                  23.115
                                         -24.395
                                                    24.122 1 1.00
                                                                       59.58
ATOM
            N
                  N VAL A
                  C VAL
                                  23.342 -23.010
                                                    23.690 1 1.00
                                                                       57.26
ATOM
ATOM
                  C VAL A
                                  24.000
                                         -22,152
                                                    24.778 1 1.00
                                                                       56.00
```



1-2)リガンド・蛋白質複合体結晶解析による医薬スクリーニング データの精密化・登録支援

蛋白質・リガンド複合体や抗原・抗体複合体構造)における構造精密化と登録作業のパイプライン構築 → 将来ビッグデータに

問題点:製薬企業において行われている医薬スクリーニングのための蛋白質・リガンド複合体構造データが公開されないまま企業内に死蔵されている。

1)知財権の問題(特に多数のpositiveでない化合物との複合体)

2)技術面の問題

- ・製薬企業ではリガンド周辺のみを決定し蛋白質受容体全体の構造は精密化を行わない。
- ・positiveな化合物との複合体については構造全体の精密化が行われ、PDBへ登録したり特許申請が行われたりするが、negativeなもの放置されることが多い。

具現化することの効果:

- 1)リガンドと蛋白質とのドッキング過程に対して、positiveとnegativeの双方の構造がpublicデータとして集積し、ドッキング技術が進む。(将来はビッグデータ化の可能性もある)
- 2)パイプラインのシステムを公開することにより、企業内でパイプラインを利用することによって、リガンド結合部位を含む全体の構造が迅速に精密化され、スクリーニングが効率的に行われる。



1-2)リガンド・蛋白質複合体結晶解析による医薬スクリーニング データの精密化・登録支援

蛋白質・リガンド複合体や抗原・抗体複合体構造)における構造精密化と登録作業のパイプライン構築 → 将来ビッグデータに (H26年度:パイプライン構築と試行, H27年度:公開・実施)

製薬企業等における化 合物・蛋白質受容体の 複合体結晶構造

:構造因子、アポ体(疑似アポ体)の原子構造

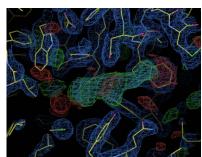
構造精密化



PDBが許容 する精度に PDBへの登 録用ファイル



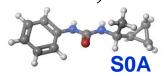
入力情報

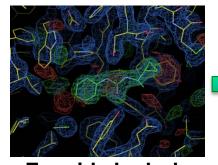


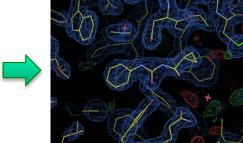
Epoxide hydrolase (含阻害剤電子密度+ アポ体構造モデル)

化合物情報

ChemComp, LigandBOX, PubChem







Epoxide hydrolaseの阻害剤(S0A: 1-[(1R)-1-cyclopropylethyl]-3-phenylurea)構造を電子密度にフィットして構造精密化

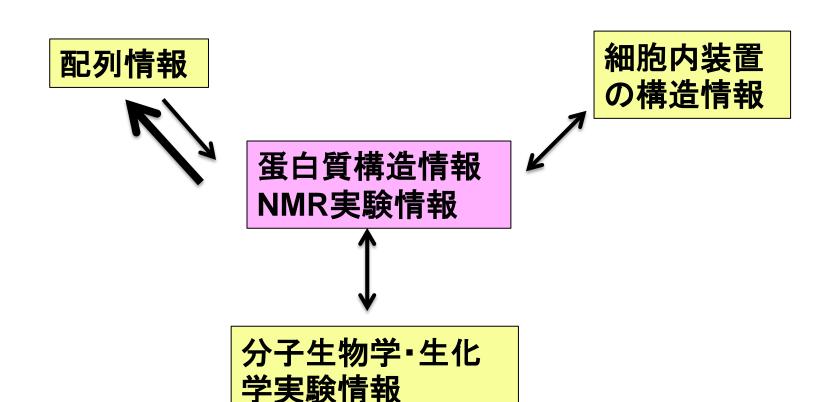


2)異なる階層のデータと蛋白質構造情報との統合化

第1期:世界標準のRDFフォーマット(PDB/RDF, BMRB/RDF)

など技術的基盤を開発・確立

第2期:コンテンツ・レベルでの階層間の統合化





2)異なる階層のデータと蛋白質構造情報との統合化

第1期:世界標準のRDFフォーマット(PDB/RDF, BMRB/RDF)

など技術的基盤を開発・確立

第2期:コンテンツ・レベルでの階層間の統合化

配列情報

配列→機能の高度化 MAFFTash, DASH, SFAS 細胞内装置 の構造情報

統合化の障害

- ①PDB構造の Redundancy
- ②PDB中のアミノ酸番号
- ③構造解析のための 多数の変異
- ④非天然のリガンド

蛋白質構造情報 NMR実験情報

分子生物学·生化 学実験情報



2)異なる階層のデータと蛋白質構造情報との統合化

配列情報



蛋白質構造情報 NMR実験情報

分子生物学·生化学 実験情報 細胞内装置 の構造情報

構造生命科学の課題の一つ

- **1** Large structures in PDB
- ②EMDB, SSBD(統合生命動態データベース)との統合化
- ③EM画像同士、EM画像と原 子構造の形の類似性検索
- **4eF-site (静電的分子表面)** for large structures
- ⑤ProMode (基準振動ダイナ ミクス) for large structures



1 Large structures in PDB



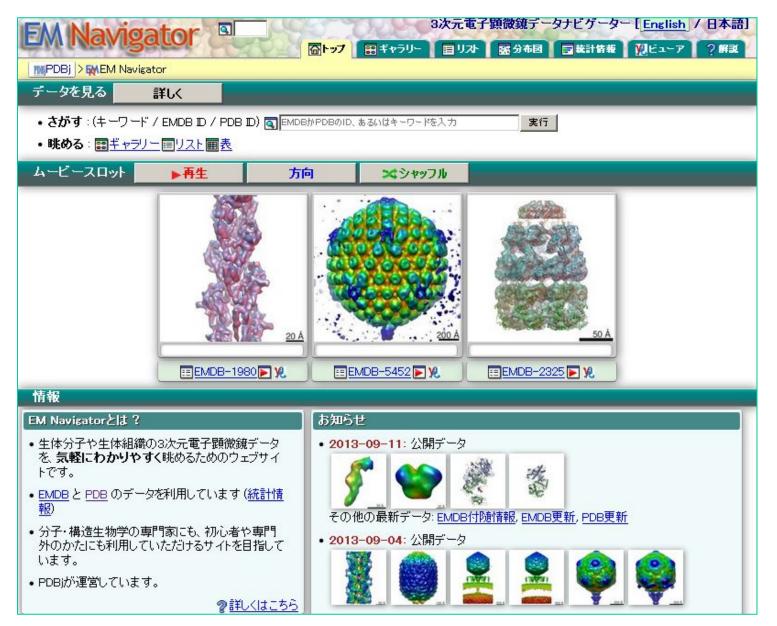


HIV-1 Capsid 3J3Q

- •1356 chains
- •>2M atoms
- •25 PDB format entries



②EMDB, SSBD(統合生命動態データベース)との統合化





③EM画像同士、EM画像と原子構造の形の類似性検索

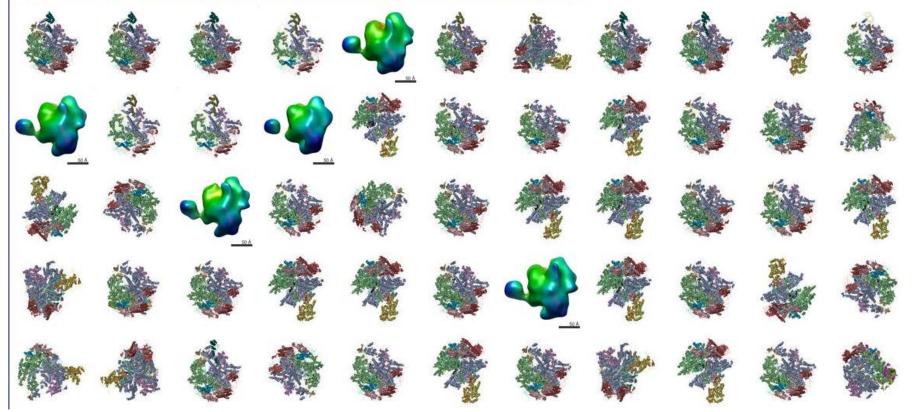
Subject structure

EMDB-ID: 2189 human RNA polymerase II in complex with Alu RNA Yorodumi

Query: human RNA polymerase II with RNA (EMDB: 2189) Similar str. from 185,558 images

Search Result [Display as list]

3000 similar structures found from all 185558 (filter level: 0.5)



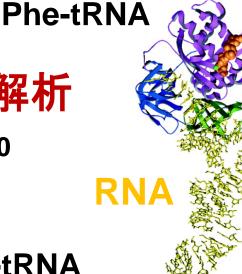


EF-Tu-GTP with

EF-G-GDP

Molecular mimicryの解析

分子擬態: R. Green, Curr Biol., 2000





Query: EF-Tu-GTP with Phe-tRNA

Subject structure

PDB-ID: 1ob2, Assembly: deposited form

E. coli elongation factor EF-Tu complexed with the antibiotic kirromycin, a GTP analog, and Phe-tRNA

¥ Yorodumi

Search Result [Display as list]

s found f all 18555 milar struc ilter level:







































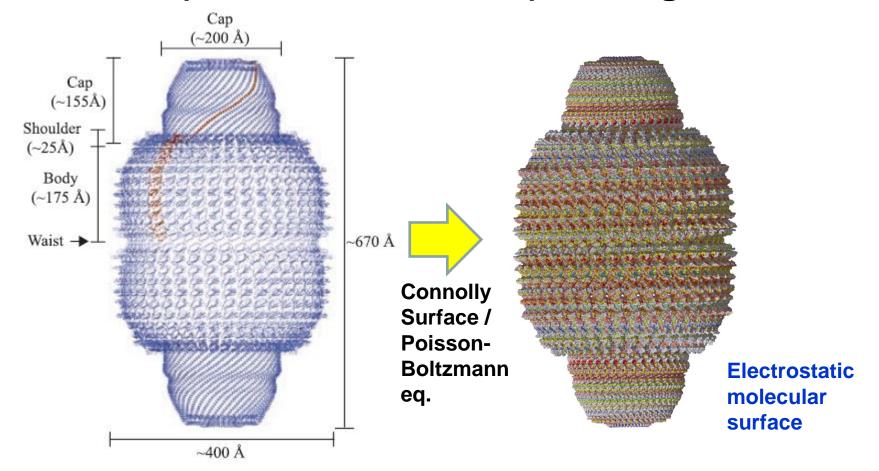








④eF-site (静電的分子表面) for large structures ⑤ProMode (基準振動ダイナミクス) for large structures



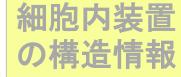
Vault (2zuo, 2zv4, 2zv5): more than 10,000,000 Da (78 chains)

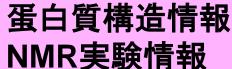
Tanaka et al. (2009) Science, 323. 384-388



2) 異なる階層のデータと蛋白質構造情報との統合化

配列情報







分子生物学·生化 学実験情報

解析対象分子の配列相同性情報や、一塩基多型 (SNP: OMIM)、 Yeast-2-hybridやpull-down assayなどの相互作用情報 (UniProt, IntAct)、疾患関連情報(CTD)、文献情報(PubMed) などを統合的に検索・表示できるWebツールの開発



3)人材養成

- 3-1)構造解析研究者·DB利用者·アノテータへの教育·情報提供
- ✓ 構造解析研究者への情報提供・交流(日本結晶学会、アジア結晶学会、NMR討論会等)
- ✓ 蛋白質構造を利用する研究者への情報提供・交流(日本バイオインフォマティクス学会、CBI学会、日本分子生物学会、日本生物物理学会、蛋白質科学会、アジアオセアニア蛋白質連合等)
- ✓ wwPDBメンバーとのタイトな連携・交流によるアノテータおよび 技術者・研究者のon-the-job-training



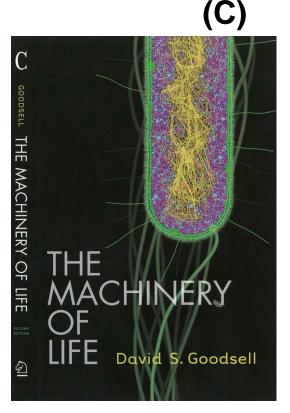


3-2)一般社会へのアウトリーチ活動

- ✓ 一般社会人・小学生以上の学生に対するサイエンスアゴラ (東京お台場)(A)などの展示や一般向け講習会 教材の出版
 - (B) 見てわかる構造生命科学(化学同人: 2014年4月刊)
 - (C) The Machinery of Life (by David S. Goodsell) (第二版の日本語訳: 2014年出版予定)

(A)2013年11月サイエンスアゴラ (東京・日本未来科学館)





(B)