

Bioinformatika III

Trimačių struktūrų analizė ir spėjimas

Paskaita 3 – struktūrinių failų formatai (CIF)

Saulius Gražulis
2021 m.

CIF ir mmCIF formatas

ASCII (CIF 3: UTF-8) koduotės failai

Laisvo formato sintaksė

Duomenys žymimi raktiniais žodžiais, bet
įrašai nėra suskirstyti eilutėmis

Reliacinis duomenų modelis

Duomenų raktiniai žodžiai ir jų semantika
aprašyti CIF žodynose (CIF dictionaries)

<http://www.iucr.org/iucr-top/cif/standard/cifstd1.html>

<http://www.iucr.org/iucr-top/cif/spec/version1.1/cifsyntax.html>

CIF failo pavyzdys

```
data_1KNV
#
_entry.id      1KNV
#
_audit_conform.dict_name      mmcif_pdbx.dic
_audit_conform.dict_version    1.044
...
_cell.entry_id            1KNV
_cell.length_a             121.230
_cell.length_b             122.280
_cell.length_c             56.870
_cell.angle_alpha          90.00
_cell.angle_beta           90.00
_cell.angle_gamma          90.00
...
loop_
_atom_site.group_PDB
_atom_site.id
_atom_site.type_symbol
...
ATOM   1     N   N   . ASN A 1 4   ? 3.407  40.303 50.109  1.00 66.19 ? ? ? ? ? 4   ASN A N   1
ATOM   2     C   CA  .
ASN A 1 4   ? 4.752
                           40.029 49.523  1.00 67.25 ? ? ? ? ? 4   ASN A CA   1
```

Kalbos

Matematikoje, *kalba L* vadinama pora ($A, W \subset A^*$), kur:

A yra *baigtinis alfabetes* (t.y. baigtinis simbolių rinkinys),

A^* yra (begalinė) visų galimų *baigtinių simbolių eilučių* iš A aibė,

W yra A^* poaibis.

Gramatikos

Gramatikos pavyzdys:

$$\begin{aligned} R &\rightarrow S \mid S + R \mid S - R \\ S &\rightarrow D \mid D \times S \mid D / S \\ D &\rightarrow V \mid (R) \\ V &\rightarrow a \mid b \mid c \end{aligned}$$

Teisingas sakiny:

$$(a + b) / (a - b \times b / c)$$

Neteisingas sakiny:

$$((a)(+-b)/(((a-b)bbcded \times b / c))$$

Bekaus-Nauro forma (angl. Backus-Naur Form (BNF))

```
<reiškinys> ::= <sandauga>
              | <sandauga> + <reiškinys>
              | <sandauga> - <reiškinys>

<sandauga>  ::= <daugiklis>
              | <daugiklis> * <sandauga>
              | <daugiklis> / <sandauga>

<daugiklis> ::= <vardas> | ( <reiškinys> )

<vardas> ::= a | b | c
```

CIF failo sintaksė, STAR formatas

Gramatika Bekuso-Nauro (Backus-Naur) forma:

```
...
<data_block>   ::= <data_heading> <data>+ { <wspace>+ | <EOF> }
<data_heading> ::= <DATA_> <non_blank_char>+
<data>          ::= { <wspace>+ <data_name> <wspace>* <blank>
                      <data_value_1> }
                  | { <wspace>+ <data_name> <wspace>* <terminate>
                      <data_value_2> }
                  | <data_loop>

<data_loop>     ::= <wspace>+ <L00P_> <data_loop_field> <data_loop_values>

<data_loop_field> ::= { <wspace>+ <data_name> }+
<data_name>       ::= '-' <non_blank_char>+
<data_loop_values> ::= { { <wspace>* <blank> <data_value_1> }
                         | { <wspace>* <terminate> <data_value_2> } }+
...

```

CIF 1: <http://ww1.iucr.org/iucr-top/cif/spec/version1.1/cifsyntax.html#gram>

CIF 2: Bernstein 2016 <https://doi.org/10.1107/s1600576715021871>

CIF 2 gramatika: <https://journals.iucr.org/j/issues/2016/01/00/aj5269/aj5269sup1.txt>

GitHub: <https://github.com/COMCIFS>

CIF failo sintaksės ypatumai

```
# Komentarai prasideda "groteliu" (#) simboliu
# Leistini tik ASCII simboliai, todel tenka rasyti "sveplai"

data_DataName
_tag1 value
_tag2 1.23(3)
_tag3 'eilutes su tarpais turi buti viengubose kabutese'
_tag4 "arba dvigubose kabutese"
_tag5 'zodis d'Alamber (su kabute-apostrofu) gali buti kabuciu vidury (!)'
_tag5a
'reiksme gali buti bet kur, net ir kitoje eiluteje'

loop_
_tag6 # duomenu zymiu isdestymas eilutes bet koks
_tag7 _tag8
123 456 789
111 222
333

DaTa_NextDataName # pagal gramatika, data_ neskiria didziuju ir mazuju
_tag1 123 # duom. zymes unikalios data_ bloke, bet skirtinguose
          # blokuose gali kartotis

# pabaigoje jokios zymes
```

CIF failo semantika, CIF žodynai

Ką reiškia '_atom_site_label'? Koks žymuo (tag) naudojamas koordinatėms?

```
data_atom_site_fract_
  _loop_name           '_atom_site_fract_x'
                      '_atom_site_fract_y'
                      '_atom_site_fract_z'
  _category            atom_site
  _type                numb
...
  _list_reference      '_atom_site_label'
  _definition          ; Atom-site coordinates as fractions of the _cell_length_ values.
;
data_atom_site_label
  _name                '_atom_site_label'
  _category            atom_site
  _type                char
...
  _definition          ; The _atom_site_label is a unique identifier for a particular site
                      in the crystal.
...
```

CIF “žodynų žodynai”, DDL

Ką reiškia '_name'? Koks žymuo nurodo duomenų tipą?

```
data_name
    _definition
;
    The data name(s) of the defined item(s). If data items are
    closely related or represent an irreducible set, their names
    may be declared as a looped sequence in the same definition.
;
    _name
    _category
    _type
    _list
loop_ _example
    '_name'
    'name'
    'char'
    'both'
    '_atom_site_label'
    '_atom_attach_all'  '_atom_attach_ring'
```

mmCIF, DDL2 žodynas

Standartinis CIF žodynas neturėjo mechanizmų makromolekulių struktūroms užrašyti

PDB sukūrė naują mmCIF (macromolecular CIF) žodyną, pritaikytą biologinėms makromolekulėms

(mm)CIF formato **privalumai**

ASCII tekstas, įskaitomas tiek žmogui, tiek mašinai

Griežtai apibrėžta sintaksė

Semantinė informacija kaupiama to paties formato žodynose

Tinka visiems struktūrinės informacijos tipams

Numatyta standartinė galimybė įvesti naujus duomenų laukus

(mm)CIF formato trūkumai

Sudėtinga gramatika

Daugelį dažnai pasitaikančių klaidų sunku griežtai lokalizuoti ar net aptikti, ypač lentelėse ('loop_ loops)

Skaitymas reikalauja sudėtingo specializuoto sintaksinio analizatoriaus

Kai kurie semantiniai aspektai iki šiol nepakankamai griežtai aprašyti

Silpnas daugianacionalinių simbolių palaikymas, nepalaikomas UTF-8

Pradinis CIF formatas netinka makromolekulėms, reikalingas dar sudėtingesnis mmCIF formato variantas (žodynas)

Dėl didelio variantų skaičiaus skaitančios programos yra sudėtingos, ir ne visi *teisingi* CIF failai bus skaitomi visų programų

PDB XML schema

mmCIF žodynus galima paversti 1:1 į XML schema

```
<?xml version="1.0" encoding="UTF-8" ?>
<PDBx: datablock datablockName="1KNV"
    xmlns:PDBx="http://deposit.pdb.org/pdbML/pdbx.xsd"
    xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
    xsi:schemaLocation="http://deposit.pdb.org/pdbML/pdbx.xsd pdbx.xsd">
...
<PDBx:atom_siteCategory>
<PDBx:atom_site id="1">
    <PDBx:group_PDB>ATOM</PDBx:group_PDB>
    <PDBx:type_symbol>N</PDBx:type_symbol>
    <PDBx:label_atom_id>N</PDBx:label_atom_id>
    <PDBx:label_alt_id xsi:nil="true" />
    <PDBx:label_comp_id>ASN</PDBx:label_comp_id>
    <PDBx:label_asym_id>A</PDBx:label_asym_id>
    <PDBx:label_entity_id>1</PDBx:label_entity_id>
    <PDBx:label_seq_id>4</PDBx:label_seq_id>
    <PDBx:Cartn_x>3.407</PDBx:Cartn_x>
    <PDBx:Cartn_y>40.303</PDBx:Cartn_y>
    <PDBx:Cartn_z>50.109</PDBx:Cartn_z>
...
...
```

Ontologijos ir semantiniai tinklai

Ontologija (Graikiškai ων „būtis“, λόγος „žodis“ ar „kalba“) — filosofijos skyrius, /.../ Pagrindinis ontologijos klausimas — „Kas egzistuoja?“

Ontologija — kompiuterijoje šiuo termino daugiskaitine forma „ontologijos“ ... vadinamas tam tikros srities savokų visumos specifikavimas išreikštu pavidalu.

<https://en.wikipedia.org/wiki/Ontology>

[https://en.wikipedia.org/wiki/Ontology_\(information_science\)](https://en.wikipedia.org/wiki/Ontology_(information_science))

<http://lt.wikipedia.org/wiki/Ontologija>

[http://lt.wikipedia.org/wiki/Ontologija_\(informatika\)](http://lt.wikipedia.org/wiki/Ontologija_(informatika))

Kaip turėtų atrodyti „idealus“ formatas?

Tekstinis, ASCII -> UTF8

Įrašas <=> eilutė

Laukai atskirti tarpais

Raktiniai žodžiai nurodo įrašą

Fiksuoti įrašų laukai ir tipai?

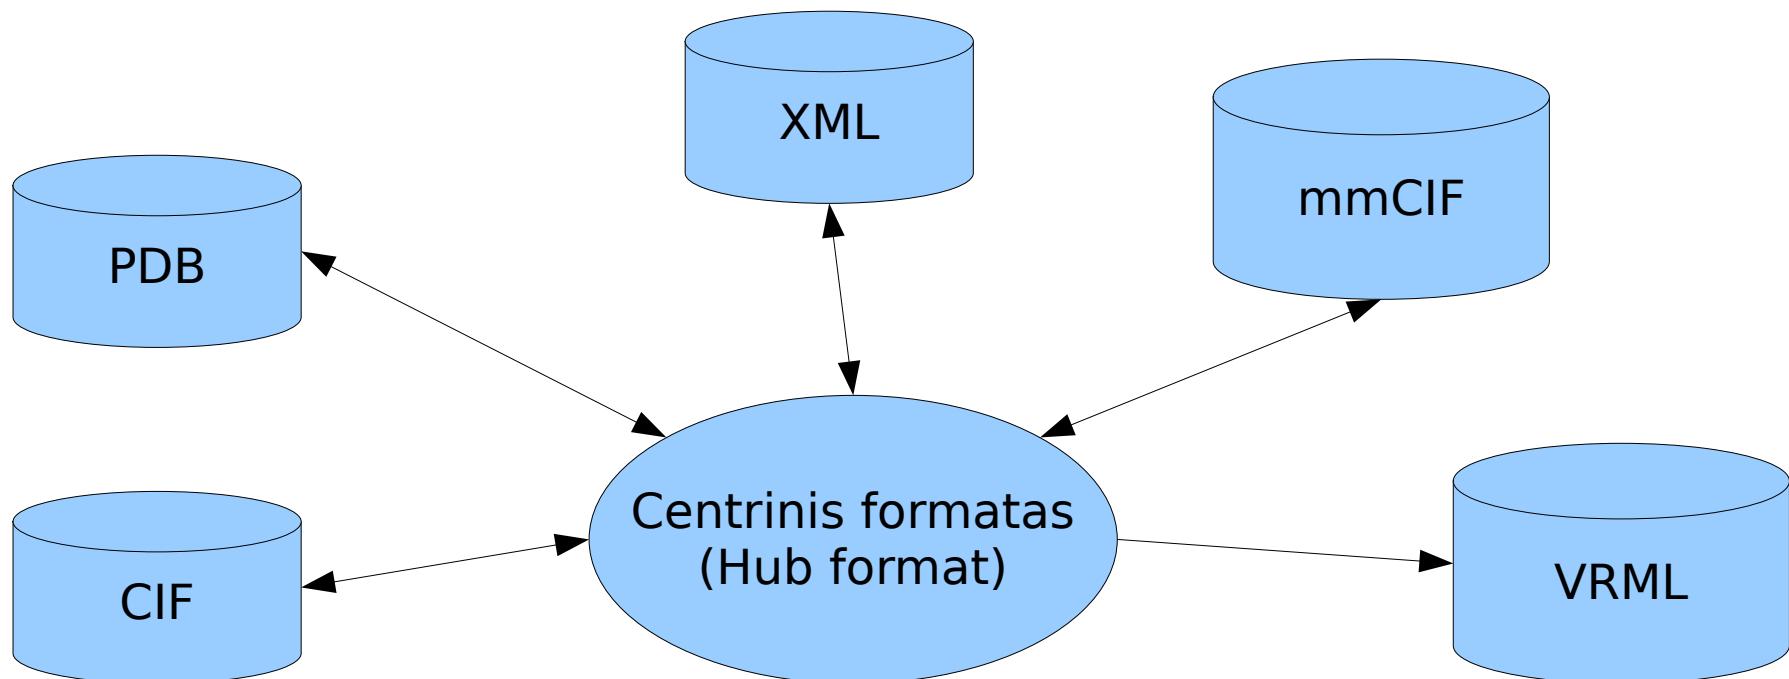
Jokių dydžio apribojimų!

„Idealaus“ formato pavyzdys...

```
FORMAT My ideal macromolecular data format ver. 0.0
#
# Komentarai gali būti skirti žmogui
#
TITLE Restrikcijos endonukleazės struktūra
AUTHORS Saulius Gražulis; Elena Manakova (Манакова, Елена)
CELL 100.0 100.0 100.0 100.0 90 90 90
SPACEGROUP P212121
#
ATOM N ASN A 4 3.407(1) 40.303(2) 50.109(11) 1.00 66.19 N
ATOM CA ASN A 4 4.752 40.029 49.523 1.00 67.25 C
...
```

Galimi „nuosavo“ formato panaudojimai

„Centriniai“ formatai (Hub formats)



Sėkmingo Hub-formato pavyzdys: netpbm <http://netpbm.sourceforge.net/>