



CBI学会2019年大会、2019年10月21日(月)、13:00-17:00

〈チュートリアル〉
計算毒性学と
化学データサイエンスの基本

株式会社 インシリコデータ
湯田 浩太郎

本日のプログラム:

1. 13:00-13:05: (5分) 挨拶:株式会社 インシリコデータ 湯田浩太郎

2. 13:05-13:20(15分) ◆導入 計算毒性学と「化学データサイエンス」

計算毒性学でのコンピューター導入原理、二大毒性評価関連技術(化学多変量解析/パターン認識アプローチ、人工知能アプローチ)、データサイエンスから「化学データサイエンス」へ

3. 13:20-13:50(30分) ◇第一部 計算機化学(Computer Chemistry)関連

化合物保存形式、化合物命名法、化合物検索(完全一致、部分構造、2・3次元構造検索、他)手法、一元一項対応串刺し検索、化合物の扱い(縮合多環、互変異性、立体/幾何異性)、化合物表記(ケトエノール、ニトロニトロソ、他)

4. 13:50-15:20(90分) ◇第二部 化学多変量解析/パターン認識(ケモトリックス(Chemometrics))関連

化学パラメーター、2/3次元パラメーター、種々データ解析手法、過剰適合、偶然相関、線形/非線形性、特徴抽出、最少サンプル数、最少パラメーター数、クラスポピュレーション、次元変換/圧縮/縮小、分類率/予測率、要因解析、オートスケーリング、アウトライヤー/インライヤー、解析信頼性指標(サンプル数/パラメーター数)、KY(K-step Yard sampling)法、パーセプトロン、バックプロパゲーション、遺伝的アルゴリズム、ファジー理論、内挿/外挿問題、他

<15:20-15:40 休憩 20分>

5. 15:40-16:20(40分) ◇第三部 人工知能(Artificial Intelligence)関連

人工知能の歴史、ルールベース型人工知能、ニューラルネットワーク型人工知能、深層学習、サンプル数問題、要因説明問題、ルールのコンピューターへの組み込み、ネットワーク構造、LISP、FORTRAN、PYTHON、

6. 16:50-17:00(30分) ◇第四部 計算機科学(Computer Science)関連

データベース理論、プログラミング言語、クラスター、クラウド、スーパーコンピューター、ネットワーク、WEB、他

7. 16:50-17:00(10分) ◇討論および名刺交換会

◇第一部

計算機化学(Computer Chemistry)関連

- 化合物保存形式
- 化合物命名法
- 一元一項対応(Canonicalization)
- 化合物検索手法;
(完全一致、部分構造、2・3次元構造検索、他)
- データベース連携(ビッグデータ化);串刺し検索
- 化合物の扱い;縮合多環、互変異性、立体/幾何異性、塩、他
- 化合物表記;ケトエノール、ニトロ/ニトロソ、他

□化学分野の基本情報

◇化学データ(アナログ)のデジタル化

アナログ(英: analog、英語発音: ['ænə,lɔ:g] アナローグ):

連続した量(例えば時間)を他の連続した量(例えば角度)で表示すること。デジタルが連続量をとびとびな値(離散的な数値)として表現(標本化・量子化)することと対比される。時計や温度計などがその例である。

<https://ja.wikipedia.org/wiki/アナログ>

□化合物の世界はアナログである

デジタル(英語: digital, 英語発音: ['dɪdʒətɪl]。デジタル)

離散量(とびとびの値しかない量)のこと。連続量を表すアナログと反対の概念である。工業的には、状態を示す量を量子化・離散化して処理(取得、蓄積、加工、伝送など)を行う方式のことである。

<https://ja.wikipedia.org/wiki/デジタル>

■コンピューターの世界はデジタルである

□化学分野の基本情報


◇化学データ(アナログ)のデジタル化

- 
- * 化合物構造式(アナログデータ、イメージデータ、トポロジカルデータ)
⇒ デジタル情報を基本とするコンピューターでは扱えない
 - * 二次元及び三次元構造式
⇒ コンピューターは一次元で0/1のデータしか扱えない(2/3次元は想定外)
 - * コンピューターサイエンスによる検索及びデータ解析
⇒ デジタル情報を用いて展開されている
 - * 化学分野へのコンピューター適用の技術やサイエンスが存在
⇒ コンピューター化学(Computer Chemistry)が展開されてきた


□化学分野の基本情報

◇化学データ(アナログ)のデジタル化


- * 化合物構造式(アナログデータ、イメージデータ、トポロジカルデータ)
⇒ デジタル情報を基本とするコンピューターでは扱えない



二次元化合物構造表示



三次元化合物の
ボール&スティック表示



Graph Convolutional
Networks



001001101101100001010000110101011110010110100101110100
10011111100110100

□化学分野の基本情報



◇化学データ(アナログ)のデジタル化

- 
- * 化合物構造式(アナログデータ、イメージデータ、トポロジカルデータ)
⇒ デジタル情報を基本とするコンピューターでは扱えない
 - * 二次元及び三次元構造式
⇒ コンピューターは一次元で0/1のデータしか扱えない(2/3次元は想定外)
 - * コンピューターサイエンスによる検索及びデータ解析
⇒ デジタル情報を用いて展開されている
 - * 化学分野へのコンピューター適用の技術やサイエンスが存在
⇒ コンピューター化学(Computer Chemistry)が展開されてきた

□ 化合物命名法およびID番号

■ Reproducibility of chemical compounds:

Linear notation and Chemical ID number of compounds



■ Compound Name; Morphine

IUPAC: (5 α ,6 α)-7,8-didehydro-4,5-epoxy-17-methylmorphinan-3,6-diol

SMILES: OC(C=CC1CC2N3C)=C(OC4C(O)C=5)C1C4(CC3)C2C5

InChIKey: InChI=1S/C17H19NO3/c1-18-7-6-17-10-3-5-13(20)16(17)21-15-12(19)4-2-9(14(15)17)8-11(10)18/h2-5,10-11,13,16,19-20H,6-8H2,1H3/t10-,11+,13-,16-,17-/m0/s1

■ Compound Properties

Chemical formula: C₁₇H₁₉NO₃

■ Chemical ID Number

CAS number: 57-27-2

ATC code: N02AA01 (WHO)

PubChem:CID: 5288826

DrugBank: APRD00215

ChemSpider: 4450907

KEGG: D08233

□化学分野の基本情報

■化合物表記法の種類と違い(分子式、化合物名、WLN、Smiles) 線形による化合物表記

①CAS(Chemical Abstracts Service)番号 最新の登録化合物数: 1億4千4百万化合物

- 番号は基本的に登録順で、左の数値、中央の数値を用いた通し番号がつけられる
- 構造や物性などとは関連付けることなく割り当てられ、番号に化学的な意味は持たせていない

異性体は異なる物質なので、CAS登録番号の割り当ても異なる。例えばD-グルコースは50-99-7、L-グルコースは921-60-8である。まれに、分子の種類全体に対して1つのCAS登録番号が割り当てられることもある(全てのアルコール脱水素酵素は9031-72-5である)。

チェックディジットの計算式は次のとおりである。

CAS登録番号が $N_8N_7N_6N_5N_4N_3-N_2N_1-R$ (R, N_i は各桁の0~9の数字、桁が存在しない場合は0とみなす) の場合、

$$R = (8 \times N_8 + 7 \times N_7 + 6 \times N_6 + 5 \times N_5 + 4 \times N_4 + 3 \times N_3 + 2 \times N_2 + N_1) \bmod 10$$

たとえば、水のCAS登録番号は 7732-18-5 なので、以下の通り5になる。

$$(6 \times 7 + 5 \times 7 + 4 \times 3 + 3 \times 2 + 2 \times 1 + 1 \times 8) = 105$$

$$105 \bmod 10 = 5 \quad (105 = 10 \times 10 + 5)$$

<https://ja.wikipedia.org/wiki/CAS登録番号>

□ 多種多様の化合物ファイル形式

■ Reproducibility of chemical compounds: Notation by connection table


List of file formats handled
by the
“OpenBabel system”



```
mol -- MDL MOL format
pdb -- Protein Data Bank format
smi -- SMILES format
xyz -- XYZ cartesian coordinates format
CONFIG -- DL-POLY CONFIG
CONTCAR -- VASP format
HISTORY -- DL-POLY HISTORY
POSCAR -- VASP format
VASP -- VASP format
abinit -- ABINIT Output Format
acesin -- ACES input format
acesout -- ACES output format
acr -- ACR format
adf -- ADF cartesian input format
adfout -- ADF output format
alc -- Alchemy format
arc -- Accelrys/MSI Biosym/Insight II CAR format
ascii -- ASCII format
axsf -- XCrySDen Structure Format
bfg -- MSI BGF format
box -- Dock 3.5 Box format
bs -- Ball and Stick format
c09out -- Crystal 09 output format
c3d1 -- Chem3D Cartesian 1 format
c3d2 -- Chem3D Cartesian 2 format
cac -- CAChe MolStruct format
cacrt -- Cacao Cartesian format
cache -- CAChe MolStruct format
cacint -- Cacao Internal format
can -- Canonical SMILES format
```

□化合物特定上での問題点

- ◆コンピューター上では全く同じ化合物と認識されるか？
化合物構造式入力に異なる化合物エディターを用いると
同じSmilesでストアしても、全く異なるSmilesとなる
- ◆化合物データベース上で問題が生じる
 - ①化合物の重複登録が発生する
 - ②化合物検索でヒットしなくなる




SMILES 1: OC1=C(N(C)C)C=CC=C1 ;by ChemDraw
2: c1(O)c(N(C)C)cccc1 ;by Ecosar
3: C1=CC(=C(C=C1)N(C)C)O ;by QSAR Toolbox
4: CN(C)c1ccccc1O ;by OpenBabel
5: C1=CC(O)=C(N(C)C)C=C1 ;Manual Input by Yuta
6: C1(O)=C(N(C)C)C=CC=C1 ;Manual Input by Yuta

□二次元化合物構造式の変化性問題

◆全く同じ化合物が作画状態の違いで異なる図となる

1. 化合物の**方向性**の違い(上下/左右/表裏)
2. **表記**の違い(芳香族結合、ブリッジ構造、他)







◆コンピューター上では全く同じ化合物と認識されるか？



□化合物構造表記の多様性に関する問題

◇ Problem in compound structure:

- tautomer
- nitro
- aromatic
- salt



- 作画者の考えや習慣、用途等により変化する
- 表記を間違えたわけではなく、すべて正しい

□化合物のシステム開発や利用上での 化合物操作上での問題点

◆以下の内容に関して、システム利用目的に応じて対応必要

1. 化合物表記手法の変化性
 - ・多種多様の表記法が存在
 - ・同じ表記法であっても内容が異なる
2. 化合物入力時の変化性
 - ・二次元構造式の変化性
 - ・三次元構造式の変化性(ローカル／グローバル)
3. 化合物構造式の多様性
 - ・同じ化合物に正しい表記が複数存在

□化合物のシステム開発や利用上での 化合物操作上での問題点

◆システム開発や利用上での留意点

1. データベースの連携


- ・組み合わせ解析が困難で、不安定
- ・単体のデータベースであっても、化合物登録上問題が発生
- ・複数データベースの串刺し検索等が不可能
- ・データを集積してのビッグデータ化が出来ない

2. データサイエンスでの解析


- ・入力構造依存のパラメーター値が変化する
- ・予測モデルの信頼性が低下する
- ・予測結果が入力構造依存となる

□二次元化合物構造式の作画(異なるソフト)

ACD/ChemSketch




ChemBioDraw




□ 二次元化合物構造式の作画 (同一のソフト)

ACD/ChemSketch



ACD/ChemSketch



□化合物原子の番号付け

■完全一致検索

1. 変換コードを用いたアプローチ

①MORGAN名: 立体情報を持たない化合物

MORGAN名とは化合物に一元一項対応で付けられた化合物名

MORGAN名 = ユニークナンバリング + 原子／結合情報

ユニークナンバリング:


化合物を構成する原子につけられる番号を、1化合物1通りに決定すること

□化合物原子の番号付け

■MORGAN名の実施形態

化合物に付けられた原子番号が異なると右図のように、まったく同じ化合物であってもコンピュータ内部では異なる化合物として認識する。

この故、化合物の原子に付けられる番号はユニーク（一元一項対応）でなければならない



□一元一項対応の重要性

化合物情報をコンピューターで扱う上での
重要な基本事項

◆一元一項対応 (Canonicalization: 規範化) とは
一つの化合物は同じ記述方式であれば1:1に定義される

◆一元多項対応とは
一つの化合物が複数の記述(1:多)で定義される

□化学分野の基本情報

■一元一項対応関連の考え

一元一項対応 ⇒ 化合物(1) ⇒ 化合物名(1)

多元一項対応 ⇒ 化合物(N) ⇒ 化合物名(1)

一元多項対応 ⇒ 化合物(1) ⇒ 化合物名(N)

多元多項対応 ⇒ 化合物(N) ⇒ 化合物名(N)

但し、化合物名＝化合物表記
()内は数を示す

□一元一項対応の重要性

◆一元多項対応の時に発生する問題点

1. 化合物データベース関連上での問題

- ① 多重登録が頻発する
- ② 化合物検索の精度が保たれない
- ③ 複数の化合物データベース間の連携が困難

2. 化合物データ解析関連上での問題

- ① 重複データの存在可能性
- ② パラメーターの不安定性
- ③ 予測モデルの汎用性減少

□化学分野の基本情報

■なぜ一元一項対応が重要となるのか

◇化合物に関する
検索や化合物データ解析を
想定すると

一元一項対応が必須

実在の化合物

化合物表記

| | | | | |
|--------|---|---------|---|---------|
| 一元一項対応 | ⇒ | 化合物(1) | ⇒ | 化合物名(1) |
| | | 化合物検索 ○ | | データ解析 ○ |


| | | | | |
|--------|---|---------|---|---------|
| 多元一項対応 | ⇒ | 化合物(N) | ⇒ | 化合物名(1) |
| | | 化合物検索 × | | データ解析 × |

| | | | | |
|--------|---|---------|---|---------|
| 一元多項対応 | ⇒ | 化合物(1) | ⇒ | 化合物名(N) |
| | | 化合物検索 × | | データ解析 × |

| | | | | |
|--------|---|---------|---|---------|
| 多元多項対応 | ⇒ | 化合物(N) | ⇒ | 化合物名(N) |
| | | 化合物検索 × | | データ解析 × |

□一元一項対応の概念図

一元一項対応の 表記法






□一元一項対応の重要性 (Smilesを例に)

化合物

表記法およびローカル表記

重複登録
検索ヒットせず



SMILES



- 1: OC1=C(N(C)C)C=CC=C1 ;by ChemDraw
- 2: c1(O)c(N(C)C)cccc1 ;by Ecosar
- 3: C1=CC(=C(C=C1)N(C)C)O ;by QSAR Toolbox
- 4: CN(C)c1ccccc1O ;by OpenBabel
- 5: C1=CC(O)=C(N(C)C)C=C1 ;Manual Input by Yuta
- 6: C1(O)=C(N(C)C)C=CC=C1 ;Manual Input by Yuta

データベース連携や統合によるビッグデータ化

データベース統合による
化合物ビッグデータ化



極めて大きな
化合物数



◇ビッグデータの5Vとは

データベース構築では達成の最適化目標として、右に示される5種類のVの実現が理想とされる

データの価値
(Value)


データ量 (Volume)

データの収集の速さ (Velocity)

データの種類 (Variety)

データの正確さ (Veracity)

□ビッグデータ構築上での留意点



□化学関連システム間連携上での留意点

