

# 使用 MolAICal 计算药物化学过滤器 MCFs 及 MCE-18 描述符

作者: Qifeng Bai

邮箱: molaical@yeah.net

个人主页: <https://molaical.github.io/baiqf.html>

## 1. 引言

药物化学过滤器 (MCFs) 的作用是剔除含有所谓“结构警示”的化合物<sup>1</sup>。含有此类结构单元的分子要么具有不稳定或反应性基团, 要么会发生生物转化, 进而产生有毒代谢物或中间体。PAINS (泛测定干扰化合物) 过滤器由一系列子结构过滤器组成, 旨在减少筛选库中的假阳性结果、测定伪影以及非特异性生物活性分子。其设计依据是: 结构中的某些片段可能会引发不良性质——如反应性、螯合作用、胶体聚集形成以及染料相关效应等, 这些都会干扰测定结果。由于 MCFs 和 PAINS 均涉及反应性, 因此在 MolAICal 中, MCFs 的功能涵盖了 MCFs 和 PAINS 所涉及的结构。

“MCE-18”全称为“药物化学演进, 2018”, 是一种原创分子描述符<sup>2</sup>, 用于有效评估具有药理学相关性分子的新颖性和先导化合物潜力。MCE-18 计算公式:

$$\text{MCE-18} = \left( \text{AR} + \text{NAR} + \text{CHIRAL} + \text{SPIRO} + \frac{\overbrace{\text{sp}^3 + \text{Cyc} - \text{Acyc}}^{\text{NCSPTR}}}{1 + \text{sp}^3} \right) \times Q^1$$

## 参数说明

1. AR: 芳香环或杂芳香环的存在情况 (0 = 不存在, 1 = 存在)。
2. NAR: 脂环或杂脂环的存在情况 (0 = 不存在, 1 = 存在)。
3. CHIRAL: 手性中心的存在情况 (0 = 不存在, 1 = 存在)。
4. SPIRO: 螺原子的存在情况 (0 = 不存在, 1 = 存在)。
5.  $\text{sp}^3$ :  $\text{sp}^3$  杂化碳原子的比例 (范围为 0 至 1)。
6. Cyc:  $\text{sp}^3$  杂化的环碳原子比例 (范围为 0 至 1)。
7. Acyc:  $\text{sp}^3$  杂化的非环碳原子比例 (范围为 0 至 1)。
8. NCSPTR: 复合项, 计算公式为 ( $\text{sp}^3 + \text{Cyc} - \text{Acyc}$ )。
9.  $Q^1$ : 归一化二次指数, 用于表征结构骨架的支化程度。

如需了解更详细的 MolAICal 相关信息, 请访问: <https://molaical.github.io>。

## 2. 材料

### 2.1. 软件要求

1. MolAICal: <https://molaical.github.io> 或 <https://molaical.gitlab.io>

注意：确保 MolAICal 安装正确！

### 2.2. 示例文件

1. 所有必要的教程文件可从以下网址下载：

[https://gitee.com/molaical/tutorials/tree/master/024-mcf\\_mce18](https://gitee.com/molaical/tutorials/tree/master/024-mcf_mce18)

## 第一部分：使用 MolAICal 计算化学过滤器（MCFs）

1. 为单个 SMILES 字符串计算 MCFs

```
#> molaical.exe -tool mcf -s "CC(=O)OC1=CC=CC=C1C(=O)O"
```

2. 为单个 SMILES 字符串计算 MCFs（不输出属性）

```
#> molaical.exe -tool mcf -s "CC(=O)OC1=CC=CC=C1C(=O)O" -p false
```

3. 计算 MCFs 并指定输出文件及格式（如“text”“json”或“csv”）

```
#> molaical.exe -tool mcf -s "CC(=O)OC1=CC=CC=C1C(=O)O" -o result.csv -f csv
```

4. 计算 MCFs 并指定输出文件（不输出属性）

```
#> molaical.exe -tool mcf -s "CC(=O)OC1=CC=CC=C1C(=O)O" -o result.csv -f csv -p false
```

默认情况下，还会输出一些属性用于分子的进一步评估：

- ✧ **SMILES:** 输入分子的 SMILES 序列。
- ✧ **Valid:** 判断分子是否有效，值为 True（有效）或 False（无效）。
- ✧ **Passes filters:** 判断分子是否通过 MCFs 评估，值为 True（通过）或 False（未通过）。若值为 True，表明该分子通过了 MCFs 和 PAINS 过滤器。
- ✧ **LogP:** 辛醇 - 水分配系数，指物质在辛醇相中的浓度与在水相中的浓度之比。
- ✧ **SA Score:** 即合成可及性分数，用于粗略评估特定分子的合成难度（评分 10 表示难，1 表示易）。该分数由分子片段的综合贡献得出<sup>3</sup>。

- ✧ **NP Score:** 即类天然产物分数，是一种贝叶斯指标，用于评估分子与天然产物所涵盖的结构空间的相似程度<sup>4</sup>。
- ✧ **QED:** 即药物相似性定量估计，是一个 [0,1] 区间内的值，用于评估分子成为可行药物候选物的可能性。与 SA 分数类似，QED 中的描述符阈值在过去十年中有所变化，当前阈值可能未涵盖最新药物<sup>5</sup>。
- ✧ **Molecular weight (MW):** 化合物中原子量的总和。

从上述网址下载“024-mcf\_mce18/molecules.smi”；“molecules.smi”可包含多个 SMILES 字符串，因此 MolAICal 可一次性为一个或多个分子计算 MCFs。请尝试以下示例：

1. 从文件中计算 MCFs（文件可包含多行 SMILES，每行代表一个分子的 SMILES）

```
#> molaical.exe -tool mcf -i molecules.smi -o result.csv -f csv
```

2. 从文件中计算 MCFs（不输出属性，文件可包含多行 SMILES，每行代表一个分子的 SMILES）

```
#> molaical.exe -tool mcf -i molecules.smi -o result.csv -f csv -p false
```

注意：用户可选择上述任一方式计算 MCFs。如需更详细的帮助，请参考 MolAICal 手册。

## 第二部分：使用 MolAICal 计算 MCE-18

1. 为单个 SMILES 计算 MCE-18

```
#> molaical.exe -tool mce18 -s "CC(=O)OC1=CC=CC=C1C(=O)O"
```

2. 仅输出 SMILES 和 MCE-18 值

```
#> molaical.exe -tool mce18 -s "CC(=O)OC1=CC=CC=C1C(=O)O" -sm true
```

3. 输入 SMILES 并输出 CSV 格式文件

```
#> molaical.exe -tool mce18 -s "CC(=O)OC1=CC=CC=C1C(=O)O" -o output.csv
```

4. 输入 SMILES 并输出 CSV 格式文件（不输出详细内容）

```
#> molaical.exe -tool mce18 -s "CC(=O)OC1=CC=CC=C1C(=O)O" -o output.csv -q true
```

5. 输入 SMILES 并输出 CSV 格式文件（仅包含 SMILES 和 MCE-18 值）

```
#> molaical.exe -tool mce18 -s "CC(=O)OC1=CC=CC=C1C(=O)O" -o output.csv -sm true
```

6. 输入包含 SMILES 字符串的文件（每行一个）并输出 CSV 格式文件

```
#> molaical.exe -tool mce18 -i molecules.smi -o results.csv
```

7. 输入包含 SMILES 字符串的文件（每行一个）并输出 CSV 格式文件（仅包含 SMILES 和 MCE-18 值）

```
#> molaical.exe -tool mce18 -i molecules.smi -o results.csv -sm true
```

### 对 MCE-18 的值进行分析：

从实际应用场景来看，**45-78** 是一个相对理想的范围

对供应商化合物库（如 ChemDiv、Enamine）的分析显示：

**MCE-18 <45:** 分子结构简单、新颖性低，多为“旧骨架”，吸引力有限；

**MCE-18: 45-78:** 新颖性足够，符合当前药物化学趋势（45-63），与制药公司近期专利化合物的结构相似性高（63-78）；

**MCE-18 > 78:** 需要手动评估靶点适应性和药物相似性，因为过度复杂可能导致开发困难。

**注意：**用户可选择上述任一方式计算 MCE-18。如需更详细的帮助，请参考 MolAICal 手册。

---

如果只研究 MCFs 和 MCE-18 的计算方法，阅读至此已足够。

后续教程内容属于可选部分，在将分子从其它格式转换为 **canonical SMILES** 格式，或执行批量 **canonical SMILES** 转换时，可以参考以下教程。

---

### 第三部分：多种化学文件格式转换为 **canonical SMILES** 的方法

为了计算 MCE-18、SA 和 MCFs，常常需要将 mol2、sdf、mol 等化学文件格式转换为 canonical SMILES 表示法。在此背景下，MolAICal 提供了一种基于 RDKit 的方法，可将 mol2、sdf、mol、pdb、inchi 和 SMILES 等格式的分子结构转换为其 canonical SMILES 表示形式。

#### 1. Mol2 转 canonical SMILES

```
#> molaical.exe -tool tosmi -i lig.mol2 -t mol2
```

#### 2. Mol2 转 canonical SMILES（不显示转换失败信息）

```
#> molaical.exe -tool tosmi -i lig.mol2 -t mol2 -q true
```

注：-q：取值为 true 和 false，“true”表示抑制转换失败信息。

#### 3. SMILES 转 canonical SMILES

```
#> molaical.exe -tool tosmi -i "CCO" -t smiles
```

#### 4. InChI 转 canonical SMILES

```
#> molaical.exe -tool tosmi -i "InChI=1S/C2H6O/c1-2-3/h3H,2H2,1H3" -t inchi
```

#### 5. PDB 转 canonical SMILES

```
#> molaical.exe -tool tosmi -i lig.pdb -t pdb
```

#### 6. mol 转 canonical SMILES

```
#> molaical.exe -tool tosmi -i lig.mol -t mol
```

#### 7. SDF 转 canonical SMILES

```
#> molaical.exe -tool tosmi -i lig.sdf -t sdf
```

注：“-q、-u 或 -r”也可用于将 .mol2、.sdf、.mol、.pdb、InChI、SMILES 等分子格式转换为 canonical SMILES。

### 第四部分：批量将多种分子文件格式转换为 SMILES 的脚本使用

有时，需要计算 .mol2、.sdf、.mol、.pdb 和 InChI 等格式的分子文件的 MCFs 和 MCE-18 描述符。这些文件需批量转换为 SMILES 字符串，才能使用上述方法进行计算。

这里提供两个 Linux bash 脚本用于批量格式转换：

1) 打开 “024-mcf\_mce18\batch”，查看 run\_combine.sh:

```
-----
#!/bin/bash
cp /dev/null all.smi
for i in `ls -l | grep ".sdf" | awk '{print $9}'`
do
    # Above “.sdf” is a keyword. The below command is to remove the suffix.
    molaical.exe -tool tosmi -t sdf -q true -i $i > tmp.smi
    # Output last line.
    tail -n 1 tmp.smi >> all.smi
done
rm tmp.smi
-----
```

用户可对 “all.smi” 重命名，该文件包含从 SDF 格式示例文件中提取的所有 SMILES 字符串。

2) 打开 “024-mcf\_mce18\batch”，查看 run\_individual.sh:

```
-----
#!/bin/bash
for i in `ls -l | grep ".sdf" | awk '{print $9}'`
do
    # Above “.sdf” is a keyword. The below command is to remove the suffix.
    tmp=$(echo $i | awk -F'.' '{print $1}')
    # echo $tmp
    molaical.exe -tool tosmi -t sdf -q true -i $i > tmp.smi
    # Output last line.
    tail -n 1 tmp.smi > $tmp'.smi'
done
rm tmp.smi
-----
```

该脚本会将 SDF 文件逐个转换为包含 SMILES 字符串的文件。SDF 文件与其对应的包含 SMILES 字符串的转换文件具有相同的前缀名。

### 3) 运行 run\_combine.sh 和 run\_individual.sh

运行脚本前，需正确指定 “molaical.exe” 的路径。在 Linux 控制台中：

对于第一个脚本：

```
#> chmod +x run_combine.sh
#> ./run_combine.sh
```

对于第二个脚本：

```
#> chmod +x run_individual.sh
#> ./run_individual.sh
```

注：上述示例基于 SDF 格式的分子，但该方法同样适用于 mol2、sdf、mol、pdb、inchi、SMILES 等其他格式的分子。请在对应的脚本中将文件扩展名（如“.sdf”）修改为“.mol2”等目标格式的扩展名。

## 参考文献

1. Polykovskiy, D.; Zhebrak, A.; Sanchez-Lengeling, B.; Golovanov, S.; Tatanov, O.; Belyaev, S.; Kurbanov, R.; Artamonov, A.; Aladinskiy, V.; Veselov, M.; Kadurin, A.; Johansson, S.; Chen, H.; Nikolenko, S.; Aspuru-Guzik, A.; Zhavoronkov, A., Molecular Sets (MOSES): A Benchmarking Platform for Molecular Generation Models. *Frontiers in Pharmacology* 2020, Volume 11 - 2020.
2. Ivanenkov, Y. A.; Zagribelnyy, B. A.; Aladinskiy, V. A., Are We Opening the Door to a New Era of Medicinal Chemistry or Being Collapsed to a Chemical Singularity? *Journal of Medicinal Chemistry* 2019, 62 (22), 10026-10043.
3. Ertl, P.; Schuffenhauer, A., Estimation of synthetic accessibility score of drug-like molecules based on molecular complexity and fragment contributions. *J Cheminform* 2009, 1 (1), 8.
4. Ertl, P.; Roggo, S.; Schuffenhauer, A., Natural product-likeness score and its application for prioritization of compound libraries. *Journal of Chemical Information and Modeling* 2008, 48 (1), 68-74.
5. Shultz, M. D., Two Decades under the Influence of the Rule of Five and the Changing Properties of Approved Oral Drugs. *J Med Chem* 2019, 62 (4), 1701-1714.