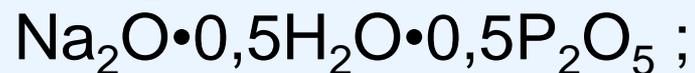


Одномерные формы  
отображения  
химического вещества  
в базах данных

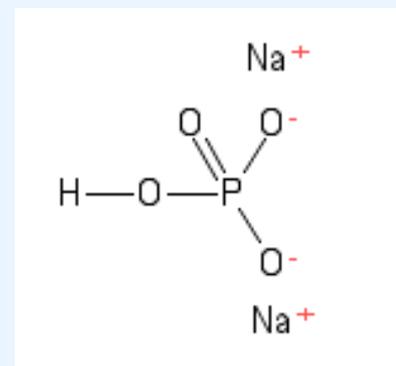


*Это:*

гидроортофосфат натрия,  
натрий-гидрофосфат,  
кислый фосфат натрия двузамещенный,  
динатрийгидротетраоксофосфат(V),  
disodium orthophosphate,  
hidrogenoortofosfato de disodio,



и т. д.

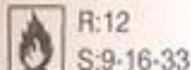


# Вещество в справочнике, каталоге

## Блок идентификаторов

IUPAC name	Ethane	[hide]
<a href="#">Wikipedia</a>		
<b>Identifiers</b>		
CAS number	74-84-0	✓
PubChem	6324	
EC number	200-814-8	
UN number	1035	
RTECS number	KH3800000	
SMILES	CC	[hide]
InChI	1/C2H6/c1-2/h1-2H3	[hide]
ChemSpider ID	6084	

14420 Ethane, 99+%  
C<sub>2</sub>H<sub>6</sub> FW 30.07 [74-84-0] mp -172° bp -88° fp -135° RTECS KH3800000  
EINECS 200-814-8 TSCA Merck 12,3767 BRN 1730716 UN 1035  
EXTREMELY FLAMMABLE / KEEP COLD



CH<sub>3</sub>-CH<sub>3</sub> 110g 172.00

Каталог реактивов  
Lancaster

# CAS Registry Number

CASRN, CAS RN, CAS Number, CAS#

— номер, под которым химическое вещество (или смесь веществ) зарегистрировано в *Chemical Abstracts Service*.

Присваивается в хронологическом порядке, химический смысл не закладывается.

Формат: **7558-79-4**.

# CAS Registry Number: особенности регистрации

Свой *CASRN* присваивается каждому химическому **объекту**, например:

Цис-1,2-дихлорэтен,  
транс-1,2-дихлорэтен,

1,2-дихлорэтен (без указания изомерии)

$C_2HDCl_2$  (без указания изомерии)

цис- $C_2D_2Cl_2$

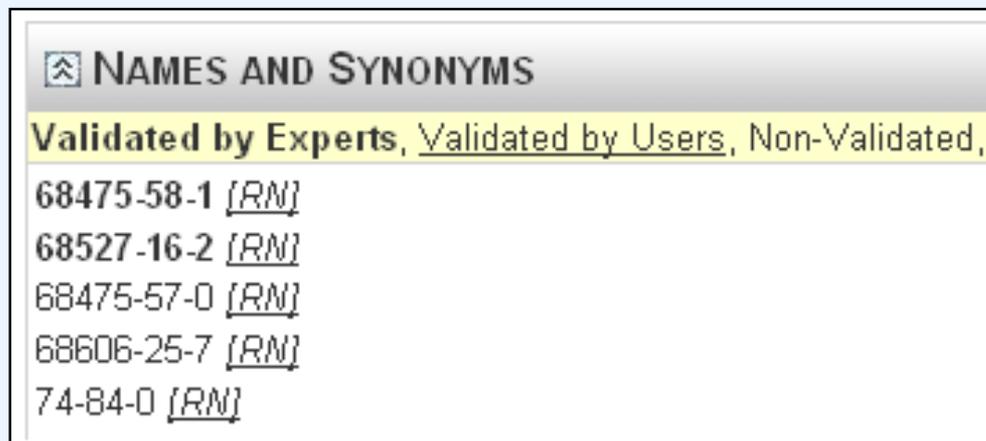
и т. д.

(в том числе, какая-нибудь особенно важная смесь, содержащая это вещество)

# CAS Registry Number проблемы использования

а) Доступ к полному списку *CASRN* – платный.

б) Плодятся неточности в бесплатном WWW.



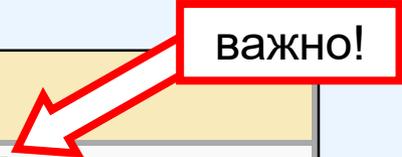
в) *CASRN* ↔ химический объект *и*  
*CASRN* ↔ химическое вещество.

# CAS Registry Number

## где найти правильный код?

- а) В редактируемых научных базах данных.
- б) (В каталогах реактивов) (?).
- в) Официальный краткий список:  
Common Chemistry (<http://www.commonchemistry.org/>)
- г) В Wikipedia (в статье о конкретном веществе).

Identifiers	
CAS number	74-84-0 ✓



Дополнительный материал:  
CAS Registry Number и справочник Common Chemistry  
[http://www.abc.chemistry.bsu.by/bulchinf/2009\\_1\\_6-8.pdf](http://www.abc.chemistry.bsu.by/bulchinf/2009_1_6-8.pdf)

Двумерная графическая формула  
(2D-структура)

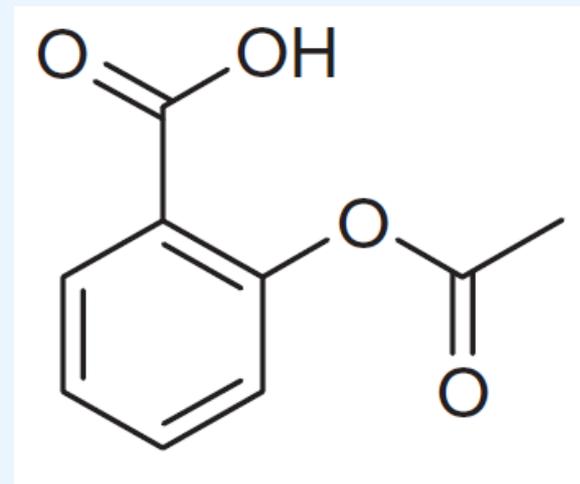
**Топология** структуры:

вид атомов и порядок их соединения друг с другом.

**Топография** структуры:

расположение атомов в пространстве.

Двумерная графическая формула отображает топологию структуры.



ацетилсалициловая кислота (аспирин)

# Линейная нотация (линейная запись) –

одномерная форма отображения химического объекта в виде строки буквенно-цифровых символов

Один из способов отображения топологии структуры в форме линейной нотации:

**SMILES**

# SMILES

[СМАЙЛЗ]

на поисковом бланке

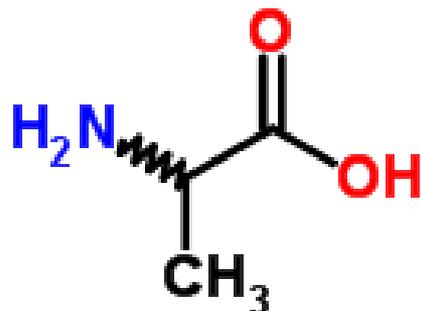
Systematic Name, Synonym, Trade Name,  
Registry Number **SMILES** or InChI

Search

в результатах поиска

Пример:

O=C(O)C(N)C



3D

ChemSpider ID:	582
Empirical Formula:	C <sub>3</sub> H <sub>7</sub> NO <sub>2</sub>
Molecular Weight:	89.0932
Nominal Mass:	89 Da
Average Mass:	89.0932 Da
Monoisotopic Mass:	89.047678 Da

load save zoom

Systematic Name: 2-aminopropanoic acid

SMILES: O=C(O)C(N)C

# Синтаксис SMILES. Атомы.

В общем случае,  
атомы отображаются символами химических элементов и  
записываются в квадратных скобках,  
*например:* [As].

Без квадратных скобок  
можно отображать атомы "органических" элементов  
в "низших нормальных" валентных состояниях:

B(III)	C(IV)	N(III, V*)	O(II)	F(I)
	P(III, V),	S(II, IV, VI)	Cl(I)	
			Br(I)	
			I(I)	

\* На самом деле – N(IV)

Водород при **этих** атомах, насыщающий свободные  
валентности, можно не указывать.

# Гидриды

<i>Объект</i>	<i>Строка SMILES</i>
метан $\text{CH}_4$	C
аммиак $\text{NH}_3$	N
вода $\text{H}_2\text{O}$	O
сероводород $\text{H}_2\text{S}$	S
хлороводород HCl	Cl
арсин $\text{AsH}_3$	[AsH3]

Водород -  
в неявной  
форме

Водород -  
в явной  
форме

# Ковалентная химическая связь

Соседние атомы записывают рядом.

Ковалентная связь отображается так:

одинарная      никак (иногда -)

двойная      =

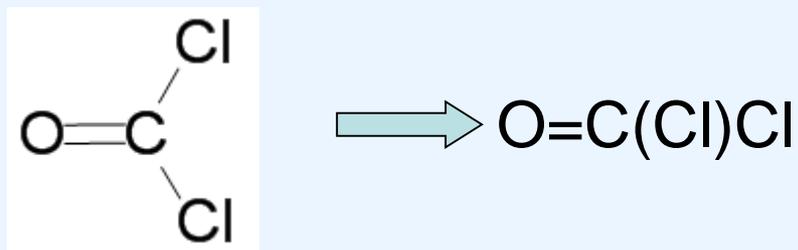
тройная      #

*Например:*

<i>Объект</i>	<i>Строка SMILES</i>
этан $\text{CH}_3\text{CH}_3$	CC
пропан $\text{CH}_3\text{CH}_2\text{CH}_3$	CCC
углекислый газ	O=C=O
синильная кислота	C#N

# Боковые цепи (заместители)

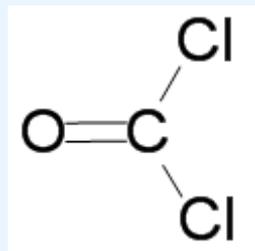
Боковую цепь указывают в круглых скобках после символа того атома, к которому она присоединена.



$\begin{array}{c} \text{CH}_3 \\   \\ \text{CH}_2 \\   \\ \text{H}_3\text{C}-\text{CH}_2-\text{N}-\text{CH}_2-\text{CH}_3 \end{array}$	$\begin{array}{c} \text{CH}_3 \quad \text{O} \\   \quad    \\ \text{H}_3\text{C}-\text{CH}-\text{C}-\text{OH} \end{array}$	$\begin{array}{c} \text{CH}_3 \\   \\ \text{CH}_2 \quad \text{CH}_3 \\   \quad   \\ \text{CH}_2 \quad \text{CH}_2-\text{CH}_3 \\   \quad   \\ \text{H}_2\text{C}=\text{CH}-\text{CH}-\text{CH}-\text{CH}_2-\text{CH}_2-\text{CH}_3 \end{array}$
<chem>CCN(CC)CC</chem>	<chem>CC(C)C(=O)O</chem>	<chem>C=CC(CCC)C(C(C)C)CCC</chem>

# Стандартная (каноническая) запись

Возможны многочисленные варианты записи:



$O=C(Cl)Cl$  ,  $ClC(Cl)=O$   
 $ClC(=O)Cl$  ,  $C(Cl)(Cl)=O$   
и т. д.

Все они считаются правильными и каждый может использоваться как поисковый термин.

Один из вариантов является стандартным (каноническим). Стандартный генерируют по правилам, которые мы изучать не будем.

В базах данных информация хранится на основе канонических форм.

Компьютер сам преобразовывает запись пользователя в каноническую форму.

# Ионы и ионные соединения

Заряд иона указывают внутри квадратных скобок.

<i>Объект</i>	<i>Строка SMILES</i>
$\text{Fe}^{2+}$	[Fe+2]
$\text{H}_3\text{O}^+$	[OH3+]
$\text{NH}_4^+$	[NH4+]

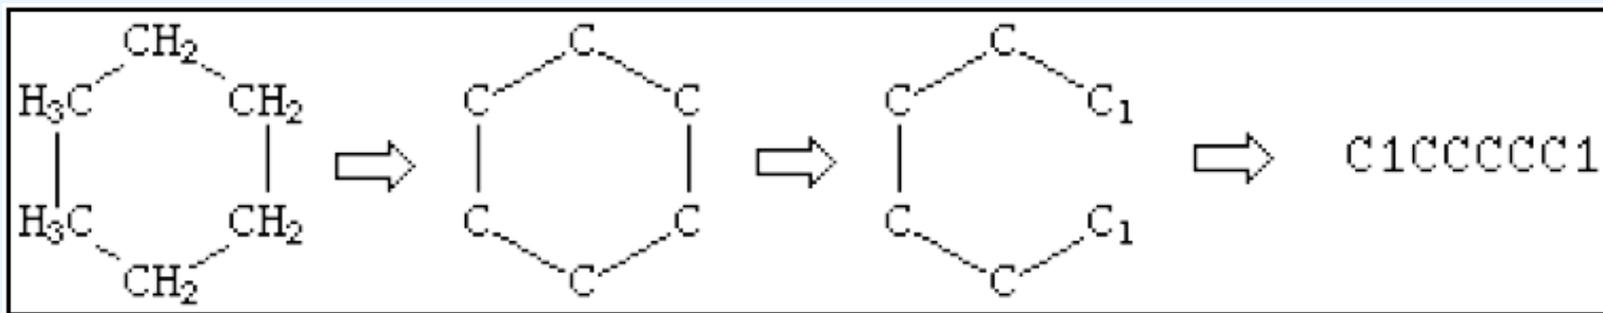
Обратим  
внимание  
на порядок  
записи цифр  
и знака "плюс"

Точкой отделяют автономные частицы.  
Например, катион и анион.

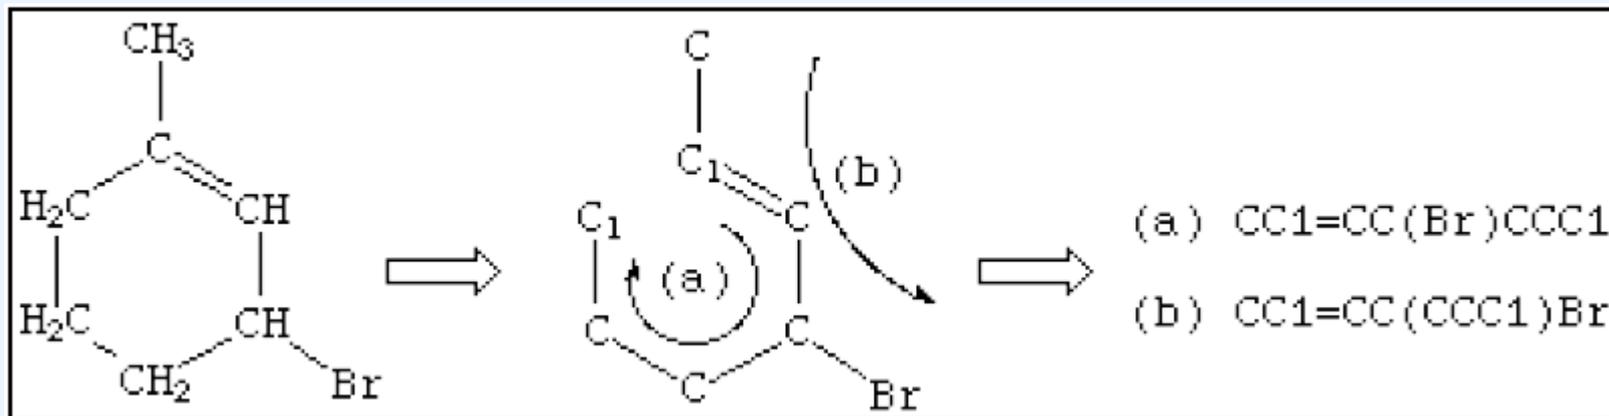
<i>Объект</i>	<i>Строка SMILES</i>
$\text{NaOH}$	[Na+].[OH-]

# Циклы

Два атома цикла нумеруют одним и тем же числом и связь между этими атомами условно разрывают:



Допускаются варианты выбора основной цепи:

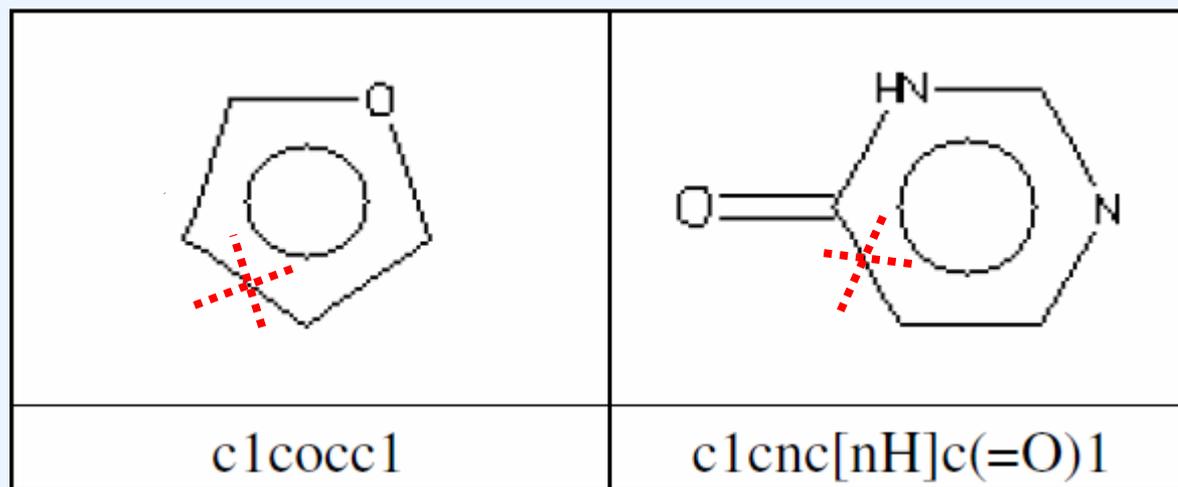


# Ароматические соединения

Химические символы атомов, образующих ароматические связи, записывают **строчными** буквами.

Пример 1.      циклогексан      C1CCCCC1  
                  бензол        c1ccccc1  
                  фенол        Oc1ccccc1

Пример 2.



# SMILES и Google

Код SMILES – буквенно-цифровой;  
в принципе может быть компонентом запроса  
для универсальной поисковой системы.



31 млн.

[DrugBank: Showing Mitomycin \(DB00305\)](#)  
23 Jun 2009 ... Canonical SMILES,  
COC12C3NC3CN1C1=C(C2COC(N)=O)C(=O)C(N)=C(C)C1=O. Drug Category. Alkylating  
Agents; Antibiotics, Antineoplastic ...  
[www.drugbank.ca/drugs/DB00305](http://www.drugbank.ca/drugs/DB00305) - [Cached](#) - [Similar](#)

[TR000 C1C\(C\)C1](#) [TR001 C12\(C\)C3\(C\)C\(=O\)C4\(C\)C1\(C\)C5\(C\)C\(C\)C\(C\)C1](#) ...  
... c1cc(O)c2C(=O)C3=C(O)C4(O)C(=O)C(C(N)=O)=C(O)C(N(C)C)C4CC3C(C)(O)c2c1 TR345  
[O-][N+](=O)c1cc(ccc1O)[As](=O)(O)O TR346 C(C)C TR347 C1(C)=CCC(CC1)C(=C)C ...  
[www.predictive-toxicology.org/data/ntp/corrected\\_smiles.txt](http://www.predictive-toxicology.org/data/ntp/corrected_smiles.txt) - [Cached](#)

Поиск работает, но есть проблемы:

- а) запрос как фрагмент кода; как сумма терминов.
- б) регистр букв тоже может иметь значение.