

**Программа  
автоматизированного выделения  
значений и единиц измерения физических величин  
из полнотекстовых материалов**

**Выполнила:**  
Хвостова Мария Олеговна  
НИЯУ МИФИ

**Научный руководитель:**  
Антонов Евгений Вячеславович  
ЛИТ ОИЯИ

16.04.2024

❖ **Цель**

разработать инструмент для  
*выделения из текста,*  
*унификации записи*  
физических величин

❖ **Применение**

*анализ содержания*  
научно-технических текстов,  
*конвертация* физических величин *в СИ*

## Физическая величина

числовое  
значение

+

единица  
измерения

5.8 MW/m<sup>2</sup>

## Буквенная запись в СИ

приставка

*m; μ ...*


единица измерения

*m kg s A K mol cd* базовая

*C = A\*s; ...* производная  
именованная

*m/s = m/s; ...* производная  
неименованная

## Принцип работы



## Составляющие инструмента

- ❖ Справочник
- ❖ Алгоритм
- ❖ Программный интерфейс
- ❖ Средства контейнеризации

# Программа автоматизированного выделения значений и единиц измерения физических величин из полнотекстовых материалов

Составляющие инструмента

## Справочник

*приставки - 24*

*базовые единицы СИ - 7*

*производные именованные  
единицы СИ - 14*

*добавленные единицы - 29*

```
'G':  
  {'Name': 'giga',  
   'Value': 1000000000  
  }
```

```
'H': {  
  'Name': 'henry',  
  'Quantity': 'inductance',  
  'SI': [1, 'kg*m^2*s^-2*A^-2'],  
  'Powers': True
```


```
'J/kg': {  
  'Name': 'joule per kilogram',  
  'Quantity': 'specific energy',  
  'SI': [1, 'm^2*s^-2']
```

```
'°F': {  
  'Name': 'degree Fahrenheit',  
  'Quantity': 'temperature',  
  'SI': ['(x-32)*5/9+273.15', 'K'],  
  'Powers': False  
},
```


```
'appm': {  
  'Name': 'atomic parts per million',  
  'Quantity': 'ratio',  
  'SI': [1, 'appm'],  
  'Powers': False  
}
```

Составляющие инструмента

## Алгоритм



## Составляющие инструмента Алгоритм выделения



Составляющие инструмента

## Алгоритм декомпозиции

### числовая группа

*шаблон*  
*re*

интервал  
нормальная запись  
экспоненциальная запись

$33.0 \pm 0.8$ ;  $5 * 10^{-3}$ ;  $5e^{-3}$

[2.5, 2.7]

### символьная группа

*шаблон*  
*re*



простая/составная  
приставки  
степени

$g/cm^3$  —  $\{...\}$

g ["', 'g', ", "']  
cm3 ['c', 'm', '3', "']

```
{'Symbol': 'g/cm3',  
'Type': 'compound', 'Description':  
['NOT IN DATABASE'],  
'BaseUnits': [  
  {'Symbol': 'g', 'Type':  
'base', 'Root': 'g', 'Power': '1',  
'Description': [{'Name': 'gram',  
'Quantity': 'mass', 'SI': [0.001, 'kg'],  
'Powers': True}], 'Prefix': {'Symbol':  
'', 'Description': []}},  
  {'Symbol': 'cm3', 'Type':  
'base', 'Root': 'm', 'Power': '3',  
'Description': [{'Name': 'metre',  
'Quantity': 'length', 'SI': [1, 'm'],  
'Powers': True}], 'Prefix': {'Symbol':  
'c', 'Description': [{'Name': 'centi',  
'Value': 0.01}]}}]}
```

Составляющие инструмента

## Алгоритм конвертации

числовое значение

{...}

коэффициент (K)

“

$$\begin{aligned} \text{ч.зн. (конвертированное)} &= \\ &= \text{ч.зн. (обработанное)} * K \end{aligned}$$

$$2500.0-2700.0 = 2.5*1000-2.7*1000$$

единица измерения

{...}

полная символьная запись  
в базовых единицах (ПСЗ)

”

$$\begin{aligned} \text{ед.изм. (конвертированная)} &= \\ &= \text{ПСЗ (приведённая)} \end{aligned}$$

$$\text{kg/m}^3 = (\text{kg})^1/(\text{m})^3$$

# Программа автоматизированного выделения значений и единиц измерения физических величин из полнотекстовых материалов

## Составляющие инструмента Программный интерфейс

### Text Analysis 0.0.1 OAS 3.1

/openapi.json

Text Analysis API provides measurement units extraction service.

#### SI

**POST** /SI/units Get Measurement Units

**POST** /SI/values Get Converted Measurement Units With Values

#### Parameters

No parameters

Request body required

Example Value | Schema

```
{
  "text": [
    "string"
  ],
  "exclude_units": [
    "string"
  ]
}
```

Code

Details

200

Response body

```
{
  "Symbol": "°C",
  "Value": [
    550,
    700
  ],
  "SI_converted": "823.15-973.15, K"
},
{
  "Symbol": "cm",
  "Value": [
    20
  ],
  "SI_converted": "0.2, m"
},
{
  "Symbol": "MPa",
  "Value": [
    8
  ],
  "SI_converted": "8000000.0, kg/(m*s^2)"
},
{
  "Symbol": "cm/s",
  "Value": [
```

Response headers

```
content-length: 591
content-type: application/json
date: Sat,13 Apr 2024 13:32:07 GMT
server: uvicorn
```

## Использование инструмента

### ❖ Cmd

```
curl -X 'POST' \  
'http://127.0.0.1:8008/SI/values' \  
-H 'accept: application/json' \  
-H 'Content-Type: application/json' \  
-d '{  
  "text": [  
    "  
  ],  
  "exclude_units": [  
  ]  
'
```

### ❖ Программный интерфейс

```
POST http://localhost:8008/SI/values  
HTTP/1.1
```

```
{  
  "text": [  
    "  
  ],  
  "exclude_units": [  
    "  
  ]  
}
```

## Пример работы инструмента: ввод

“Such LMs can provide sufficient tritium breeding ratio and have high thermal conductivity ( $\sim 101 \text{ W/m}\cdot\text{K}$ ) and low viscosity  $\sim 10^{-7} \text{ m}^2/\text{s}$  that make them very favorable for heat removal. All LM blanket concepts have, however, feasibility issues associated with magnetohydrodynamic (MHD) interactions between the flowing high electrical conductivity LM  $106 \text{ S/m}$  and a strong plasma-confining magnetic field. Only a weak flow is needed for a slow ( $0.1\text{-}1 \text{ mm/s}$ ) circulation of the breeder toward the external ancillary system for tritium extraction and LM purification. In this concept, a high-temperature PbLi alloy flows slowly (velocity  $10 \text{ cm/s}$ ) in large poloidal rectangular ducts (duct size  $\sim 20 \text{ cm}$ ) to remove the volumetric heat and produce tritium, while the pressurized He (typically to  $8 \text{ MPa}$ ) is used to remove the surface heat flux and to cool the ferritic first wall and other blanket structures to  $< 550^\circ\text{C}$ . Thermal insulation is needed to thermally insulate the high-temperature self-cooled PbLi (which operates at  $\sim 550\text{-}700^\circ\text{C}$  depending on the variant of the design)”

## Пример работы инструмента: вывод

```
[ { "Symbol": "mm/s", "Value": [ "0.1", "1.0" ], "SI_converted": "0.0001-0.001, m/s" },  
  { "Symbol": "°C", "Value": [ "550.0", "700.0" ], "SI_converted": "823.15-973.15, K" },  
  { "Symbol": "W/m*K", "Value": [ "101" ], "SI_converted": "101.0, kg*m/(s^3*K)" },  
  { "Symbol": "°C", "Value": [ "550" ], "SI_converted": "823.15, K" },  
  { "Symbol": "cm/s", "Value": [ "10" ], "SI_converted": "0.1, m/s" },  
  { "Symbol": "cm", "Value": [ "20" ], "SI_converted": "0.2, m" },  
  { "Symbol": "S/m", "Value": [ "106" ], "SI_converted": "106.0, A^2*m^-1" },  
  { "Symbol": "MPa", "Value": [ "8" ], "SI_converted": "8000000.0, kg/(m*s^2)" },  
  { "Symbol": "m2/s", "Value": [ "1e-07" ], "SI_converted": "1e-07, m^2/s" } ]
```

# Программа автоматизированного выделения значений и единиц измерения физических величин из полнотекстовых материалов

## Сравнение результатов работы инструмента и Quantulum3

[ { "Symbol": "*mm/s*", "Value": [ "0.1", "1.0" ], "SI\_converted": "0.0001-0.001, m/s" },  
{ "Symbol": "*°C*", "Value": [ "550.0", "700.0" ], "SI\_converted": "823.15-973.15, K" },  
{ "Symbol": "*W/m\*K*", "Value": [ "101" ], "SI\_converted": "101.0, kg\*m^2/(s^3\*K)" },  
{ "Symbol": "*°C*", "Value": [ "550" ], "SI\_converted": "823.15, K" },  
{ "Symbol": "*cm/s*", "Value": [ "10" ], "SI\_converted": "0.1, m/s" },  
{ "Symbol": "*cm*", "Value": [ "20" ], "SI\_converted": "0.2, m" },  
{ "Symbol": "*S/m*", "Value": [ "106" ], "SI\_converted": "106.0, A^2\*m^-1" },  
{ "Symbol": "*MPa*", "Value": [ "8" ], "SI\_converted": "8000000.0, kg/(m\*s^2)" },  
{ "Symbol": "*m2/s*", "Value": [ "1e-07" ], "SI\_converted": "1e-07, m^2/s" } ]

[Quantity(0.55, "Unit(name='millimetre per second)'),  
Quantity(625, "Unit(name='degree Celsius)'),  
Quantity(101, "Unit(name='watt per metre)'),  
Quantity(550, "Unit(name='degree Celsius)'),  
Quantity(10, "Unit(name='centimetre per second)'),  
Quantity(20, "Unit(name='centimetre)'),  
Quantity(106, "Unit(name='siemens per metre)'),  
Quantity(8, "Unit(name='megapascal')"]

## Проблемы в работе инструмента

- ❖ **Множественность Unicode-кодировок** символов одного вида

'MICRO  
SIGN'  
(U+00B5)




'GREEK  
SMALL  
LETTER MU'  
(U+03BC)



- ❖ **Буквенное написание** физических величин

*seven kilometers per second*

- ❖ **Вариативность** записи физических величин



## Перспективы применения инструмента

- ❖ **Усовершенствованный поиск текстов с предварительно заданным набором единиц измерения и/или диапазонов их значений**



- ❖ **Индексация текстов для выделения технических параметров оборудования/ условий проведения экспериментов ...**



**Спасибо за внимание!**

## Приложение 1

