

**Методические рекомендации для решения конкурсных материалов для проведения практического этапа Московского конкурса межпредметных навыков и знаний «Интеллектуальный мегаполис. Потенциал» в номинации «ИТ-класс» по направлению «Большие данные»**

**1. Назначение конкурсных материалов**

Материалы практического этапа Московского конкурса межпредметных навыков и знаний «Интеллектуальный мегаполис. Потенциал» (далее – Конкурс) предназначены для оценки уровня практической подготовки участников Конкурса.

**2. Условия проведения**

Практический этап Конкурса проводится в дистанционной форме. При выполнении работы обеспечивается строгое соблюдение порядка организации и проведения Конкурса.

**3. Продолжительность выполнения**

На выполнение заданий практического этапа Конкурса отводится 90 минут.

**4. Содержание и структура**

Индивидуальный вариант участника включает 13 заданий, базирующихся на содержании элективного курса «Большие данные» - [https://profil.mos.ru/images/news/14\\_10\\_2020\\_K/rp\\_spec\\_big\\_data.pdf](https://profil.mos.ru/images/news/14_10_2020_K/rp_spec_big_data.pdf).

Использование сред программирования, редакторов, электронных таблиц и иных программных средств запрещено.

**5. Система оценивания**

Задание считается выполненным, если ответ участника совпал с эталоном. Каждое задание базового уровня сложности оценивается в 3 балла, повышенного уровня сложности – в 6 баллов. Максимальный балл за выполнение всех заданий – 60 баллов. Для получения максимального балла за практический этап Конкурса необходимо дать верные ответы на все задания.

**6. Приложения**

1. План конкурсных материалов для проведения практического этапа Конкурса.
2. Демонстрационный вариант конкурсных заданий практического этапа Конкурса.

## План конкурсных материалов для проведения практического этапа Конкурса

| № задания    | Уровень сложности | Темы элективных курсов                         | Контролируемые требования к проверяемым умениям                                                            | Балл      |
|--------------|-------------------|------------------------------------------------|------------------------------------------------------------------------------------------------------------|-----------|
| 1            | Базовый           | Введение в Python. Базовые операции.           | 2.4.3 Функции                                                                                              | 3         |
| 2            | Базовый           | Введение в Python. Базовые операции.           | 2.4.4 Структуры данных в Python: списки, множества и словари - примеры создания и основные операции с ними | 3         |
| 3            | Базовый           | Введение в нейронные сети                      | 2.10.1 Типология нейронных сетей                                                                           | 3         |
| 4            | Базовый           | Введение в Python. Базовые операции.           | 2.4.1 Базовые типы данных в Python: численные, строковые, логические переменные                            | 3         |
| 5            | Базовый           | Введение в Python. Базовые операции.           | 2.4.1 Базовые типы данных в Python: численные, строковые, логические переменные                            | 3         |
| 6            | Базовый           | Введение в Python. Базовые операции.           | 2.4.4 Структуры данных в Python: списки, множества и словари - примеры создания и основные операции с ними | 3         |
| 7            | Повышенный        | Введение в Python. Базовые операции.           | 2.4.6 Пример реализации функции одной переменной                                                           | 6         |
| 8            | Повышенный        | Методы кластеризации и детектирования аномалий | 2.7.1 Алгоритм k средних                                                                                   | 6         |
| 9            | Повышенный        | Введение в Python. Базовые операции.           | 2.4.3 Функции                                                                                              | 6         |
| 10           | Повышенный        | Введение в Python. Базовые операции.           | 2.4.4 Структуры данных в Python: списки, множества и словари - примеры создания и основные операции с ними | 6         |
| 11           | Повышенный        | Введение в машинное обучение                   | 2.1.5 Способы задания входных данных для алгоритма машинного обучения                                      | 6         |
| 12           | Повышенный        | Библиотека pandas. Примеры                     | 2.6.5 Создание таблиц                                                                                      | 6         |
| 13           | Повышенный        | Библиотека pandas. Примеры                     | 2.6.6 Агрегация и слияние имеющихся данных                                                                 | 6         |
| <b>ИТОГО</b> |                   |                                                |                                                                                                            | <b>60</b> |

## Разбор конкурсных заданий демонстрационного варианта практического этапа Конкурса

### Пример состава задания практического этапа Конкурса.

1. Какой параметр необходимо передать функции `range()` для того, чтобы возвращаемый объект `range` содержал следующую последовательность данных 0, 1, 2, 3

Ответ: 4

**Рекомендации:** `range()` позволяет вам генерировать ряд чисел в рамках заданного диапазона. В зависимости от того, как много аргументов вы передаете функции, вы можете решить, где этот ряд чисел начнется и закончится, а также насколько велика разница будет между двумя числами.

Есть три способа вызова `range()`:

- `range(стоп)` берет один аргумент;
- `range(старт, стоп)` берет два аргумента;
- `range(старт, стоп, шаг)` берет три аргумента.

Вызывая `range()` с одним аргументом, вы получите ряд целых чисел, начинающихся с 0 и включающих каждое число до, но не включая число, которое вы обозначили как конечное (стоп). Т.е. если вы вызвали функцию `range(4)` (с аргументом 4), то получите следующий ряд чисел: 0, 1, 2, 3. Число 4 не включено в ряд.

2. Заданы два списка:

```
List1 = [1, 2, 3, 4, 5]
```

```
List2 = List1
```

Что выведет в качестве результата своего выполнения функция `print(List1 is List2)`?

Ответ: **TRUE**

**Рекомендации:** ключевое слово `is` в Python используется для проверки того, совпадают ли ссылки памяти двух объектов. Оператор `is` принимает два операнда и возвращает `True`, если оба объекта имеют одинаковую ссылку на память, и `False`, если нет. В данном примере оба объекта ссылаются на один участок памяти. Если бы объект `List2` создавался следующим образом – `List2=[1,2,3,4,5]`, то оператор `is` выдал бы ответ `FALSE`, т.к. объекты ссылаются на разные участки памяти.

3. Задана нейронная сеть следующим программным кодом:

```
import tensorflow as tf  
from tensorflow import keras  
  
model = tf.keras.Sequential([keras.layers.Dense(units=1, input_shape=[1],  
use_bias=True)])
```

Сколько слоев имеет созданная нейронная сеть? Ответ запишите в виде числа.

Ответ: **1**

**Рекомендации:** TensorFlow — открытая программная библиотека для машинного обучения, разработанная компанией Google для решения задач построения и обучения нейронной сети. Класс `Sequential` библиотеки TensorFlow создает последовательную модель нейронной сети, принимая в качестве параметров слои, создаваемой нейронной сети. Слои можно добавлять, как во время инициализации объекта класса, так и в дальнейшем, используя метод `add()`. При создании экземпляра `model` класса `Sequential` мы определили один слой, который был создан методом `keras.layers.Dense(units=1, input_shape=[1], use_bias=True)`.

4. С какого символа начинаются однострочные комментарии в коде на языке Python?

Ответ: #

**Рекомендации:** такой тип комментариев нужен для написания простых, быстрых комментариев во время отладки. Такие комментарии начинаются с символа решетки # и автоматически заканчиваются символом окончания строки (EOL).

5. На каком из участков программного кода представлена глобальная переменная?

Ответ напишите числом.

*#Участок 1*

*a = 1*

*#Участок 2*

*def sample():*

*a = 1*

Ответ: 1

**Рекомендации:** область видимости переменных в языке программирования Python представляет собой некое пространство имен, в рамках которого функционируют созданные объекты. Эта особенность позволяет ограничивать доступ к определенным значениям во избежание конфликтов между одинаковыми идентификаторами. Переменные бывают двух видов: локальные и глобальные, что в большинстве случаев определяется местом их первичной идентификации в программе. Для создания переменных, обладающих локальной областью видимости, необходимо всего лишь поместить их в отдельный блок кода (например, функцию), изолированный от остальной программы.

Чтобы иметь возможность использовать некоторое значение в любой части программы, следует объявить глобальную переменную.

Для этого понадобится создать переменную отдельно от области кода, ограниченной определенным блоком кода, например, функцией.

6. Какой индекс в примере ниже необходимо использовать для доступа к последнему элементу списка?

```
a = [1,2,3]
print(a[***])
```

Ответ: -1

**Рекомендации:** Индексация списков в Python начинается с 0. Второй элемент имеет индекс 1. Если в списке n элементов, последний из них будет иметь индекс (n-1). Попытавшись обратиться к элементу по несуществующему индексу, мы получим ошибку — IndexError. Для обращения к последнему элементу списка можно использовать индекс -1 или вычислить длину списка с помощью метода len() и отнять от полученной длины 1. Т.к. в ответе просят указать индекс, то верным будет в качестве ответа показать -1.

7. Задана функция:

```
def function(list):
    data1 = list[0]
    data2 = list[0]
    for number in list:
        if number > data1:
            data1 = number
        elif number < data2:
            data2 = number
    return data1, data2
```

Какие два числа будут напечатаны на экране в результате выполнения следующей строчки программного кода?

```
print(function([0, -1, 10, 55, -5, 22, 117, 280, -75]))
```

Ответ: 280, -75

**Рекомендации:** В задаче определена функция с именем `function`, это реализуется через зарезервированное слово `def`. Функция в качестве параметра принимает список `list`. Далее в теле функции определены две переменные `data1` и `data2`, которым присвоено значение начального элемента списка `list`, переданного в качестве параметра в функцию. Далее в функции реализован цикл `for`, который перебирает все элементы списка `list`, переданного в функцию в качестве параметра. При этом при каждой итерации цикла идет проверка является ли текущее значение переменной `data1` меньшим, чем текущий перебираемый элемент в списке, если является, то переменной `data1` присваивается текущее перебираемое значение списка, т.е. `data1 = number`.

Если условие проверки не выполнено, то реализована следующая проверка, которая рассматривает является ли текущее значение списка меньшим, чем значение переменной `data2`, если является, то значение `data2` заменяется на текущее значение списка, т.е. `data2 = number`. После окончания цикла реализован возврат переменных `data1` и `data2` из функции с помощью зарезервированного слова `return`. По сути своей, функция реализует поиск и возврат наибольшего и наименьшего значений в переданном в нее списке.

В следующей строчке кода внутри функции `print` вызвана реализованная функция `function` и в качестве аргумента в нее передан список, состоящий из последовательности чисел 0, -1, 10, 55, -5, 22, 117, 280, -75. Функция нашла в нем максимальное (280) и минимальной (-75) значения, которые и должны быть напечатаны на экране.

8. Дан следующий программный код:

```
from sklearn.cluster import KMeans
import pandas as pd
import matplotlib.pyplot as plt
from matplotlib import style
%matplotlib inline

data = pd.DataFrame([[1, 2], [5, 8], [1.5, 1.8], [8, 8], [1, 0.6],
                    [9, 11]], columns=['x', 'y'])


kmeans = KMeans(n_clusters=2).fit(data.values)
centroids = kmeans.cluster_centers_
labels = kmeans.labels_

data['labels'] = labels

group1 = data[data['labels']==1].plot(kind='scatter', x='x', y='y', color='DarkGreen',
label="Группа 1" )
group2 = data[data['labels']==0].plot(kind='scatter', x='x', y='y', color='Brown',
ax=group1, label="Группа 2" )

plt.scatter(centroids[:, 0],centroids[:, 1], marker = "x")
plt.show()
```

Результатом выполнения программного кода стал следующий график:



Какой результат (число) выведется на экран в результате выполнения следующей строчки программного кода?

```
print(kmeans.predict([[3,3]])[0])
```

Ответ: **0**

**Рекомендации:** Задача направлена на понимание работы библиотеки sklearn. Библиотека scikit-learn – самый распространенный выбор для решения задач классического машинного обучения. Она предоставляет широкий выбор алгоритмов обучения с учителем и без учителя.

Обучение без учителя (самообучение, спонтанное обучение, англ. Unsupervised learning) — один из способов машинного обучения, при котором испытываемая система спонтанно обучается выполнять поставленную задачу без вмешательства со стороны экспериментатора.

Как правило, оно пригодно только для задач, в которых известны описания множества объектов (т.е. существуют обучающие выборки), и требуется обнаружить внутренние взаимосвязи или закономерности, существующие между объектами.

Примерами обучения без учителя являются кластеризация – задача группировки множества объектов на подмножества (кластеры) таким образом, чтобы объекты из одного кластера были более похожи друг на друга, чем на объекты из других кластеров по какому-либо критерию.

Алгоритм К–средних делит набор данных на непересекающиеся кластеры, каждый из которых описывается средним центром массы в кластере. Средние значения обычно называют «центроидами» кластера. Действие алгоритма таково, что он стремится минимизировать суммарное квадратичное отклонение точек кластеров от центров этих кластеров. Это так же называется инерцией.

В этой задаче рассмотрен пример кластеризации методом К–средних с помощью `scikit-learn` и `pandas`. В начале подключены необходимые модули.

```
from sklearn.cluster import KMeans
import pandas as pd
import matplotlib.pyplot as plt
from matplotlib import style
%matplotlib inline
```

Далее созданы исходные данные вручную — это двухмерный массив значений `x` и `y`. В этом наборе данных данные имеют только две оси (но метод К–средних может использоваться с любым количеством осей).

```
data = pd.DataFrame([[1, 2], [5, 8], [1.5, 1.8], [8, 8], [1, 0.6],
                    [9, 11]], columns=['x', 'y'])
```

Далее мы сначала создаем модель, а затем вызываем метод запуска обучения `fit()`, используя свой источник данных. Теперь модель заполнена центроидами и метками. К ним можно получить доступ через свойства `cluster_centers_` и `labels_` соответственно.

```
kmeans = KMeans(n_clusters=2).fit(data.values)
centroids = kmeans.cluster_centers_
labels = kmeans.labels_
```

```
data['labels'] = labels
```

Далее реализован код, который визуализирует кластеры, и крестами помечает их центры. Чтобы различать принадлежность точек к каждому кластеру, построим группы данных на отдельных осях (имеется в виду – виртуальных), а также зададим им ключевые слова, цвета и метки.

```
group1 = data[data['labels']==1].plot(kind='scatter', x='x', y='y', color='DarkGreen',
label="Группа 1")
group2 = data[data['labels']==0].plot(kind='scatter', x='x', y='y', color='Brown',
ax=group1, label="Группа 2")

plt.scatter(centroids[:, 0],centroids[:, 1], marker = "x")
plt.show()
```

При вызове функции `print` в качестве параметра в нее передается результат вызова метода `predict` с для точки с координатами `[3, 3]`. Метод `predict` возвращает список с номерами кластеров, которым принадлежат переданные точки. Мы передали одну точку, поэтому в качестве индекса для списка указали `[0]`. По итогу, точка с координатами `[3, 3]` относится к первому кластеру, нумерация кластеров идет с 0, поэтому функция предсказания (`predict`) вернула 0.

9. Задана функция:

```
def sum_range(first, second):
    if first > second:
        second, first = first, second
```

```
i = first
f = 0
while i <= second:
    f = f + i
    i = i + 1
return f
```

Какое число будет выведено на экран в результате выполнения следующей строчки кода?

```
print(sum_range(3, 2))
```

Ответ: 5

**Рекомендации:** в примере реализована функция `sum_range(first, second)`, которая суммирует все целые числа от значения «first» до значения «second» включительно. Если пользователь задаст первое число большее чем второе, в функции реализована проверка, после которой числа меняются местами. Далее в функции определена переменная-счетчик «i» и переменная суммы «f». Далее реализован цикл с предусловием `while`, условием продолжения которого является факт того, что переменная-счетчик меньше второго параметра, переданного в функцию. При соблюдении этого условия выполняется цикл .в теле которого реализовано суммирование чисел и увеличение значения счетчика на единицу. После окончания цикла, функция возвращает значение переменной «f», т.е. сумму чисел от наименьшего переданного в функцию значения, до наибольшего.

При вызове функции `print`, в качестве параметра в нее передается результат вызова метода `sum_range(3, 2)`. Т.е. функция `sum_range` провела суммирование чисел от 2 до 3 (2+3) и результат был выведен на экран.

10. Задана строчка программного кода:

```
filtered = [i for i in range(6) if i%2==0]
```

Какое число будет напечатано ПОСЛЕДНИМ в последовательности при вызове функции print, как представлено ниже?

```
print(filtered[2])
```

Ответ: 4

### Рекомендации:

Язык программирования Python многогранен и в нем можно в одной строчке реализовать то, что в других языках занимает целые функции. В данной задаче приведен такой пример. Мы в одной строчке определили переменную `filtered`, а далее, после знака равенства написали интересную конструкцию. Внутри этой конструкции определена функция `range` с аргументом 6, которая возвращает следующую последовательность 0, 1, 2, 3, 4, 5. Далее эта последовательность перебирается в цикле `for` и при каждой итерации идет проверка условия того, что делится ли число на 2 без остатка, т.е. является ли оно четным и сохраняются только эти значения. В итоге мы получаем список: 0, 2, 4. При печати в итоговом списке мы обращаемся только ко второму элементу и выводим его на печать, т.е. это число 4.

11. Во время реализации модели машинного обучения у нас есть набор данных. Необходимо разделить выборку на обучающую и тестовую. Тестовая выборка должна быть размером 30% от исходной. Какое значение необходимо вставить вместо символов `***`, для разделения тестовой и обучающей выборок в указанной пропорции?

```
from sklearn.model_selection import train_test_split  
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=***, random_state=0)
```

Ответ: 0.3

**Рекомендации:** вопрос направлен на понимание сути машинного обучения и использование библиотеки Scikit-learn. В примере использован модуль `train_test_split` библиотеки Scikit-learn, который очень полезен для разделения датасетов. Конечно, можно выполнить такие разбиения каким-либо другим способом (возможно, используя только Numpy). Библиотека Scikit-learn включает полезные функции, позволяющие сделать это немного проще.

Для того, чтобы размер обучающей тестовой выборки был равен 30%, необходимо, указать в качестве параметра размерности тестовой выборки 0.3.

12. Какое значение будет находится в ячейке первой строчки столбца **num\_nulls** в дата фрейме `df` после программного кода, представленного ниже?

```
import pandas as pd
import numpy as np

df = pd.DataFrame({'first': [0,0,0], 'second':[0,0,np.nan], 'third':
                    [np.nan,1,1]})
df = df[['first', 'second', 'third']]
df['num_nulls'] = df[['second', 'third']].isnull().sum(axis=1)
df.head()
```

Ответ: 1

**Рекомендации:** В начале программного кода импортированы библиотеки NumPy и Pandas. Далее определен датафрейм, следующей структуры:

|   | first | second | third |
|---|-------|--------|-------|
| 0 | 0     | 0.0    | NaN   |
| 1 | 0     | 0.0    | 1.0   |
| 2 | 0     | NaN    | 1.0   |

Строчка `df['num_nulls'] = df[['second', 'third']].isnull().sum(axis=1)` добавляет в датафрейм столбец с именем `num_nulls`, который содержит подсчет NaN элементов по строчкам. Итоговый датафрейм будет выглядеть следующим образом:

|   | first | second | third | num_nulls |
|---|-------|--------|-------|-----------|
| 0 | 0     | 0.0    | NaN   | 1         |
| 1 | 0     | 0.0    | 1.0   | 0         |
| 2 | 0     | NaN    | 1.0   | 1         |

Мы видим, что первая строчка в столбце `num_nulls` содержит значение 1.

13. Какое значение будут содержать все строчки столбца 'b' в датафрейме после выполнения следующего программного кода?

```
import pandas as pd
```

```
df1 = pd.DataFrame({'a':[0,0,0], 'b': [1,1,1]})
```

```
df2 = df1
```

```
df2['b'] = df2['b'] * 2
```

```
df1.head()
```

Ответ: 2

**Рекомендации:** В начале программного кода импортированы библиотеки Pandas. Далее определен датафрейм, следующей структуры:

|   | a | b |
|---|---|---|
| 0 | 0 | 1 |
| 1 | 0 | 1 |
| 2 | 0 | 1 |

Далее создан еще один датафрейм df2, который по сути своей не является новым объектом, а содержит только ссылку на участок памяти датафрейма df1. Поэтому при изменении значений датафрейма df2, будут изменены значения и датафрейма df1. Строчка `df2['b'] = df2['b'] * 2` умножает каждый элемент столбца a на 2. В итоге мы имеем следующий датафрейм:

|   | a | b |
|---|---|---|
| 0 | 0 | 2 |
| 1 | 0 | 2 |
| 2 | 0 | 2 |

Потому все строчки датафрейма df1 в столбце b содержат значения 2.