A. Что посмотреть?

1.1 Резюме

Этот ноутбук **читает данные из файлов в той же папке**, решает 3 подзадачи и сохраняет ответы в CSV:

- **A1** `favorite_genre` → `answer_a1.csv`
- **A2** `actor_match` → `answer_a2.csv`
- **A4** `next_in_session` → `answer_a3.csv`

1.2 Файлы, которые должен видеть ноутбук

Вход (в одной папке с ноутбуком): - `queries_A.csv` — запросы (по 5 кандидатов `c1..c5`) - `items_A.csv` — метаданные фильмов (`genre`, `duration`) - `events_A.csv` — события пользователей (`open/finish/like`) - `item_meta_A.json` — метаданные фильмов (списки актёров `actors`) - `sessions_A.json` — сессии (внутри `sessions[*].path`)

Выход (создаётся рядом с ноутбуком):

Файл	Относительный путь	Назначение
`answer_a1.csv`	`./answer_a1.csv`	ответы для `favorite_genre`
`answer_a2.csv`	`./answer_a2.csv`	ответы для `actor_match`
`answer_a4.csv`	`./answer_a3.csv`	ответы для `next_in_session`

1.3 Универсальный паттерн решения

Одинаковый каркас используется во всех трёх подзадачах:

1) `melt` переводит кандидатов `c1..c5` из wide в long (по строке на кандидата).

2) `merge(..., how='left')` присоединяет признаки/скор, **не теряя кандидатов**.

3) Если есть списки (актёры, пары переходов), используем `explode`. Важно: **пустые списки дают** `NaN` строку (это удобно, чтобы оставить кандидата и получить вклад 0).

4) Выбор победителя делается сортировкой `sort_values` + `drop_duplicates('query_id')` (первый в отсортированном порядке).

5) Сохранение — `to_csv(index=False)`.

Ссылки на документацию pandas (официально):

- `pandas.melt`: https://pandas.pydata.org/docs/reference/api/pandas.melt.html
- `DataFrame.explode`: https://pandas.pydata.org/docs/reference/api/pandas.DataFrame.explode.html
- `pandas.merge`: https://pandas.pydata.org/docs/reference/api/pandas.merge.html

- `DataFrame.sort_values`:
  https://pandas.pydata.org/docs/reference/api/pandas.DataFrame.sort_values.html
- `DataFrame.drop_duplicates`:
  https://pandas.pydata.org/docs/reference/api/pandas.DataFrame.drop_duplicates.html
- `DataFrame.to_csv`:
  https://pandas.pydata.org/docs/reference/api/pandas.DataFrame.to_csv.html

[1]:
```
import pandas as pd
import matplotlib.pyplot as plt
```

1.3.1 Быстрая проверка загрузки данных

Ниже читаем все файлы один раз, смотрим размеры таблиц и распределение `query_type`.

[2]:
```
Q = pd.read_csv('queries_A.csv')
I = pd.read_csv('items_A.csv')
E = pd.read_csv('events_A.csv')
M = pd.read_json('item_meta_A.json')[['item_id','actors']]
S = pd.read_json('sessions_A.json')

print('Q', Q.shape, 'I', I.shape, 'E', E.shape, 'M', M.shape, 'S', S.shape)
Q.query_type.value_counts()
```

```
Q (800, 8) I (260, 3) E (5334, 3) M (260, 2) S (180, 2)
```

[2]:
```
query_type
favorite_genre     400
actor_match        200
next_in_session    200
Name: count, dtype: int64
```

[3]:
```
vc = Q.query_type.value_counts().sort_index()
ax = vc.plot(kind='bar', title='Количество запросов по типам')
ax.set_xlabel('query_type')
ax.set_ylabel('count')
plt.tight_layout()
plt.show()
```

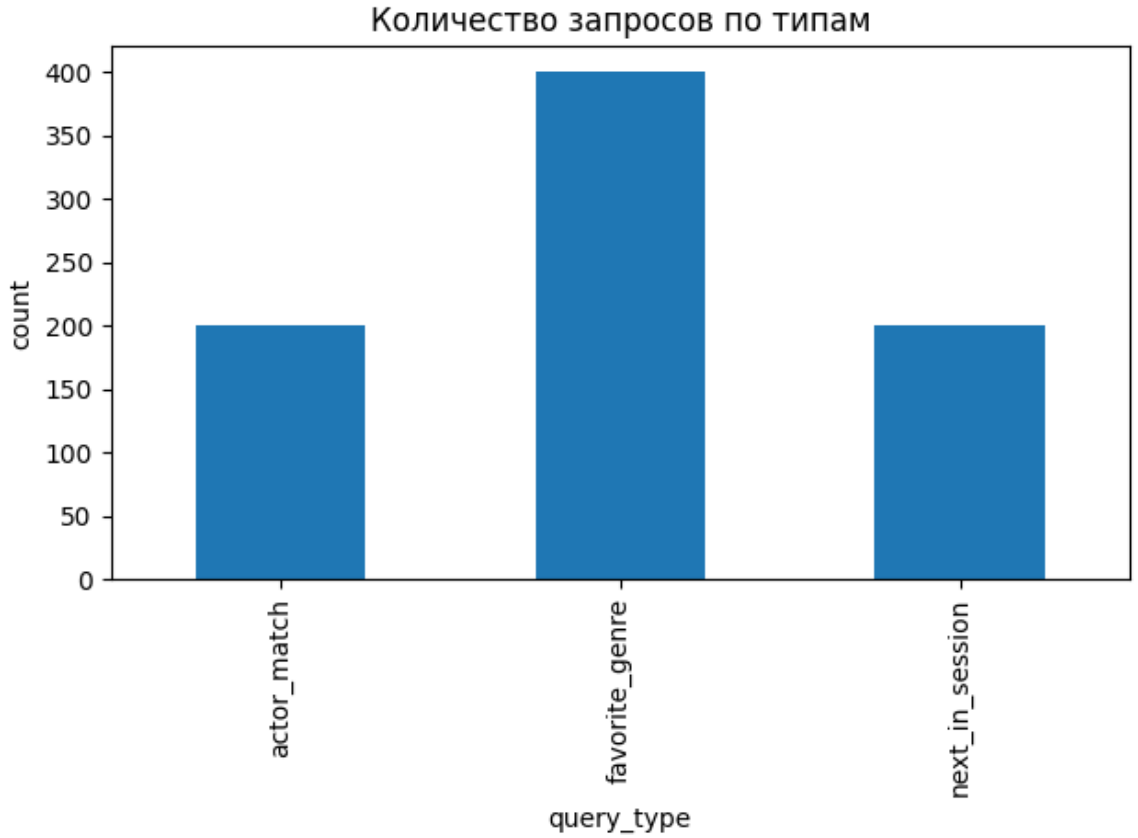

1.3.2 A1. favorite_genre

[4]:
```
q = Q[Q.query_type ==
'favorite_genre'][['query_id','user_id','c1','c2','c3','c4','c5']]

e = E[['user_id','item_id','event_type']].copy()
e['w'] = e.event_type.map({'open': 1, 'finish': 2, 'like': 3})
e = e.merge(I[['item_id','genre']], on='item_id', how='left')
g = e.groupby(['user_id','genre'], as_index=False)['w'].sum()

c = q.melt(['query_id','user_id'], ['c1','c2','c3','c4','c5'],
value_name='item_id')[['query_id','user_id','item_id']]
c = c.merge(I[['item_id','genre','duration']], on='item_id', how='left')
c = c.merge(g, on=['user_id','genre'], how='left')
c['w'] = c.w.fillna(0)

c = c.sort_values(['query_id','w','duration','item_id'], ascending=[1,0,1,1])
a1 = c.drop_duplicates('query_id')[['query_id','item_id']]

a1.to_csv('answer_a1.csv', index=False)
a1.head()
```

[4]:

	query_id	item_id
400	1	1199

```
1201          2     1065
1602          3     1211
403           4     1086
4             5     1163
```

1.3.3 A2. actor_match

[5]:
```
q = Q[Q.query_type ==
'actor_match'][['query_id','user_id','c1','c2','c3','c4','c5']]
e = E[E.event_type.isin(['finish','like'])][['user_id','item_id']]

m = M[['item_id','actors']].copy()
m['actors'] = m.actors.apply(lambda x: x if isinstance(x, list) else [])

ua = e.merge(m, on='item_id', how='left')
ua = ua.explode('actors').dropna(subset=['actors'])
ua = ua.drop_duplicates(['user_id','actors'])
ua['hit'] = 1
ua = ua[['user_id','actors','hit']]

c = q.melt(['query_id','user_id'], ['c1','c2','c3','c4','c5'],
value_name='item_id')[['query_id','user_id','item_id']]
c = c.merge(m, on='item_id', how='left')
c = c.explode('actors')
c = c.drop_duplicates(['query_id','item_id','actors'])

c = c.merge(ua, on=['user_id','actors'], how='left')
c['hit'] = c.hit.fillna(0)

s = c.groupby(['query_id','item_id'], as_index=False)['hit'].sum()
s = s.sort_values(['query_id','hit','item_id'], ascending=[1,0,1])
a2 = s.drop_duplicates('query_id')[['query_id','item_id']]

a2.to_csv('answer_a2.csv', index=False)
a2.head()
```

[5]:
```
    query_id  item_id
4        401     1252
9        402     1255
14       403     1227
19       404     1216
24       405     1232
```

1.3.4 A3. next_in_session

[6]:
```
q = Q[Q.query_type ==
'next_in_session'][['query_id','user_id','c1','c2','c3','c4','c5']]

fin = E[E.event_type == 'finish'][['user_id','item_id']].drop_duplicates()
fin = fin.rename(columns={'item_id': 'from_item'})
```

```
t = S.explode('sessions').dropna(subset=['sessions'])
t['path'] = t.sessions.apply(lambda x: x.get('path', []))
t = t[['user_id','path']]
t['pair'] = t.path.apply(lambda p: list(zip(p[:-1], p[1:])))
t = t.explode('pair').dropna(subset=['pair'])
t['from_item'] = t.pair.str[0]
t['item_id'] = t.pair.str[1]
t['hit'] = 1
tr = t.groupby(['user_id','from_item','item_id'], as_index=False)['hit'].
 ↪sum()

c = q.melt(['query_id','user_id'], ['c1','c2','c3','c4','c5'],
value_name='item_id')[['query_id','user_id','item_id']]
c = c.merge(fin, on='user_id', how='left')
c = c.merge(tr, on=['user_id','from_item','item_id'], how='left')
c['hit'] = c.hit.fillna(0)

s = c.groupby(['query_id','item_id'], as_index=False)['hit'].sum()
s = s.sort_values(['query_id','hit','item_id'], ascending=[1,0,1])
a3 = s.drop_duplicates('query_id')[['query_id','item_id']]

a3.to_csv('answer_a3.csv', index=False)
a3.head()
```

[6]:

	query_id	item_id
2	601	1028
5	602	1071
11	603	1049
17	604	1101
20	605	1004

B. Сейсмоактивный остров

[ ]:
```
import numpy as np
import pandas as pd

data = np.load('data_B.npy')
N = data.shape[0]
m = np.nanmean(data, axis=1)

# Попарная корреляция
sim = np.zeros((N, N))
for i in range(N):
    for j in range(i, N):
        mask = ~np.isnan(m[i]) & ~np.isnan(m[j])
        a, b = m[i, mask] - m[i, mask].mean(), m[j, mask] - m[j, mask].mean()
        d = np.sqrt((a**2).sum() * (b**2).sum())
        if d > 0:
            sim[i, j] = sim[j, i] = (a * b).sum() / d

# Каждому сэмплу - кластер с максимальной средней корреляцией
# Инициализация: жадно
labels = np.full(N, -1)
reps = []
for i in range(N):
    best_sim, best_c = -1, -1
    for c, r in enumerate(reps):
        if sim[i, r] > best_sim:
            best_sim = sim[i, r]
            best_c = c
    if best_sim > 0.35:
        labels[i] = best_c
    else:
        labels[i] = len(reps)
        reps.append(i)

# Уточнение: переназначаем по средней корреляции с кластером
for _ in range(10):
    clusters = [np.where(labels == c)[0] for c in range(max(labels) + 1)]
    changed = False
    for i in range(N):
        best_score, best_c = -2, labels[i]
        for c, members in enumerate(clusters):
            others = members[members != i]
            score = sim[i, others].mean() if len(others) > 0 else sim[i,
members[0]]
            if score > best_score:
                best_score = score
                best_c = c
        if best_c != labels[i]:
            labels[i] = best_c
```

```
            changed = True
    if not changed:
        break
    # Обновляем кластеры
    clusters = [np.where(labels == c)[0] for c in range(max(labels) + 1)]

y = pd.read_csv('y.csv')['cluster'].values
from sklearn.metrics import adjusted_rand_score
print(f"Clusters: {len(set(labels))}, ARI = {adjusted_rand_score(y, labels):.
 ↪6f}")

pd.DataFrame({'ID': range(N), 'target': labels}).to_csv('submission_B.csv',
index=False)
```

C. Ошибка новичка

[1]:
```
import json
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from catboost import CatBoostClassifier
import warnings
from IPython.display import display
warnings.filterwarnings('ignore')
pd.set_option('display.max_columns', None)
pd.set_option('display.max_rows', None)

# Фиксируем сид для воспроизводимости всех шагов
SEED = 42
np.random.seed(SEED)

# Загрузка доступных файлов
train = pd.read_csv('train.csv')
test = pd.read_csv('test.csv')
solution = pd.read_csv('ytest.csv')
with open('map.json', 'r') as f:
    map_data = json.load(f)

display(train.head())
display(test.head())
```

```
   longitude   latitude  target  habitat_quality_score  biodiversity_index  \
0 -68.624132 -32.868160       0              38.746018            0.869221
1 -51.964445   1.978971       0              17.456343            3.414865
2 -50.585866  -5.300425       0              43.883046            1.930266
3 -64.666741 -32.100087       0              29.736058            1.724559
4 -72.512342  -5.718456       1              66.547123            9.257867

   canopy_density  soil_moisture_level  forest_age_years  \
0        0.584679             6.031727         97.911830
1        0.327984             4.694215        169.739698
2        0.750885             7.864357        214.602112
3        0.322355             4.448480        275.153342
4        0.428812             3.822563        179.540444

   tree_density_per_hectare  annual_rainfall_mm  habitat_fragmentation_index
\
0                396.493164         1293.066100                     0.507221
1                350.579890         2353.814818                     0.247614
2                237.872776         1147.090078                     0.574802
3                458.725205         1252.207036                     0.648601
4                346.391230          604.782917                     0.732562

   predator_pressure_score  vegetation_complexity         forest_type  \
0                 1.040142                    3.0  tropical_rainforest
```

```
1                 7.522185                   9.0           dry_forest
2                 3.255146                   4.0           dry_forest
3                 6.404152                   9.0  tropical_rainforest
4                 4.880406                   2.0           dry_forest

  climate_zone soil_type disturbance_level conservation_status  \
0      montane      peat               low         unprotected
1    temperate      loam           minimal         unprotected
2  subtropical      loam          moderate         unprotected
3    temperate      loam               low         buffer_zone
4     tropical      clay               low         unprotected

  dominant_tree_species water_source_type  temperature_variability  \
0                  palm            stream                 4.037666
1                  pine              none                 5.882945
2                  palm          seasonal                 3.366330
3              mahogany            stream                 8.984897
4                bamboo          seasonal                 3.966467

   elevation_range  human_activity_index  canopy_height_avg  \
0       730.654928              0.075256           6.710190
1       316.780429              3.614124          30.770752
2       474.802210              2.251489           5.000000
3       187.292371              3.063365          16.284970
4       191.639490              3.888626          36.796504

   seasonal_variation_score
0                  6.874974
1                  6.384739
2                  5.690438
3                  6.328448
4                  5.780874

   longitude   latitude  habitat_quality_score  biodiversity_index  \
0 -72.102869  19.626859              45.511580            3.743753
1 -50.441167  -8.396785              34.751298            4.712511
2 -58.372430   0.312577              73.162533            2.579567
3 -76.362920 -14.279388              86.832262            4.097908
4 -67.162159   6.450007              63.631579            4.895632

   canopy_density  soil_moisture_level  forest_age_years  \
0        0.648016             3.260149        172.921350
1        0.226638             5.191137        357.568190
2        0.747227             7.533181        300.220431
3        0.602197             6.429846        325.612904
4        1.000000             4.502920        308.714905

   tree_density_per_hectare  annual_rainfall_mm  habitat_fragmentation_index
\
0                226.157888         1177.791799                     0.558007
1                429.731562         1922.536202                     0.332591
```

```
2                144.840477         1844.822680                    0.654825
3                323.532762         1571.667498                    0.383862
4                693.209698         1688.758358                    0.344897

   predator_pressure_score  vegetation_complexity          forest_type  \
0                 7.795448                    3.0     secondary_forest
1                 5.712367                    7.0           dry_forest
2                 2.073700                    1.0         cloud_forest
3                 0.798348                    5.0           dry_forest
4                 1.378641                    1.0  tropical_rainforest

  climate_zone soil_type disturbance_level conservation_status  \
0      montane  laterite              high         unprotected
1    temperate     sandy          moderate           protected
2  subtropical      loam              high           protected
3     tropical  alluvial           minimal         buffer_zone
4  subtropical     sandy           minimal           protected

  dominant_tree_species water_source_type  temperature_variability  \
0                 kapok            stream                 5.205539
1                  palm          seasonal                 8.634001
2                  pine              none                 5.382953
3                  pine            stream                 8.282785
4                  pine            stream                10.690082

   elevation_range  human_activity_index  canopy_height_avg  \
0       318.967595              3.626041          23.686628
1       184.900374              1.830241          28.697284
2       536.571256              0.074063          26.366329
3       649.036995              0.000000          34.803212
4       388.522453              4.500977          45.697464

   seasonal_variation_score  ID
0                  6.492307   0
1                  4.313709   1
2                  3.480140   2
3                  3.417066   3
4                  6.823274   4
```

1.4 Функция для визуализации

Создадим вспомогательную функцию для визуализации точек на карте с контуром береговой линии (`map.json`).

[2]:
```python
def plot_map(points, coastline, color_by=None, figsize=(5, 5)):
    """
    Визуализирует точки на карте с контуром береговой линии.

    Параметры:
    ----------
    points : pd.DataFrame
```

```
        DataFrame с точками, должен содержать колонки 'longitude' и
'latitude'
    coastline : list
        Список координат береговой линии [[lon1, lat1], [lon2, lat2], ...]
    color_by : str, optional
        Название колонки для раскраски точек. Если None, все точки одного
цвета
    figsize : tuple, optional
        Размер фигуры (ширина, высота)

    Пример использования:
    --------------------
    # Простая визуализация без раскраски
    plot_map(train, coastline)

    # С раскраской по таргету
    plot_map(train, coastline, color_by='target')

    # Изменение размера
    plot_map(train, coastline, color_by='target', figsize=(16, 10))
    """
    fig, ax = plt.subplots(figsize=figsize)

    # Рисуем береговую линию
    if coastline:
        coastline_array = np.array(coastline)

        # Рисуем все точки побережья как плотный scatter с квадратными
маркерами
        ax.scatter(coastline_array[:, 0], coastline_array[:, 1],
                   s=1.5, marker='s', color='#CCCCCC', alpha=0.7,
label='Coastline')

    # Рисуем точки
    if color_by is None:
        # Без раскраски - все точки одного цвета
        ax.scatter(points['longitude'], points['latitude'],
                   s=50, alpha=0.6, edgecolors='black', linewidths=0.5,
                   label='Points')
    else:
        # С раскраской по указанной колонке
        if points[color_by].dtype in ['object', 'category']:
            # Категориальная переменная
            unique_vals = points[color_by].unique()
            colors = plt.cm.tab10(np.linspace(0, 1, len(unique_vals)))

            for i, val in enumerate(unique_vals):
                mask = points[color_by] == val
                ax.scatter(points[mask]['longitude'],
points[mask]['latitude'],
```

```
                            s=50, alpha=0.6, edgecolors='black', linewidths=0.
↪5,
                            label=f'{color_by}={val}', color=colors[i])
        else:
            # Числовая переменная
            scatter = ax.scatter(points['longitude'], points['latitude'],
                                 c=points[color_by], cmap='RdYlGn',
                                 s=50, alpha=0.6, edgecolors='black',
linewidths=0.5)
            plt.colorbar(scatter, ax=ax, label=color_by)

    ax.set_xlabel('Longitude')
    ax.set_ylabel('Latitude')
    ax.set_title(f'Карта точек (n={len(points)})')
    ax.legend()
    ax.grid(True, alpha=0.3)
    plt.tight_layout()
    plt.show()

print("Функция plot_map() готова к использованию")
```

```
Функция plot_map() готова к использованию
```

1.5 Демонстрация функции визуализации

Попробуем функцию на загруженных данных.

[3]:
```
# Получаем coastline из map.json
coastline = map_data.get('coastline', [])

# Пример 1: Train без раскраски
plot_map(train, coastline)

# Пример 2: Train с раскраской по таргету
plot_map(train, coastline, color_by='target')
```

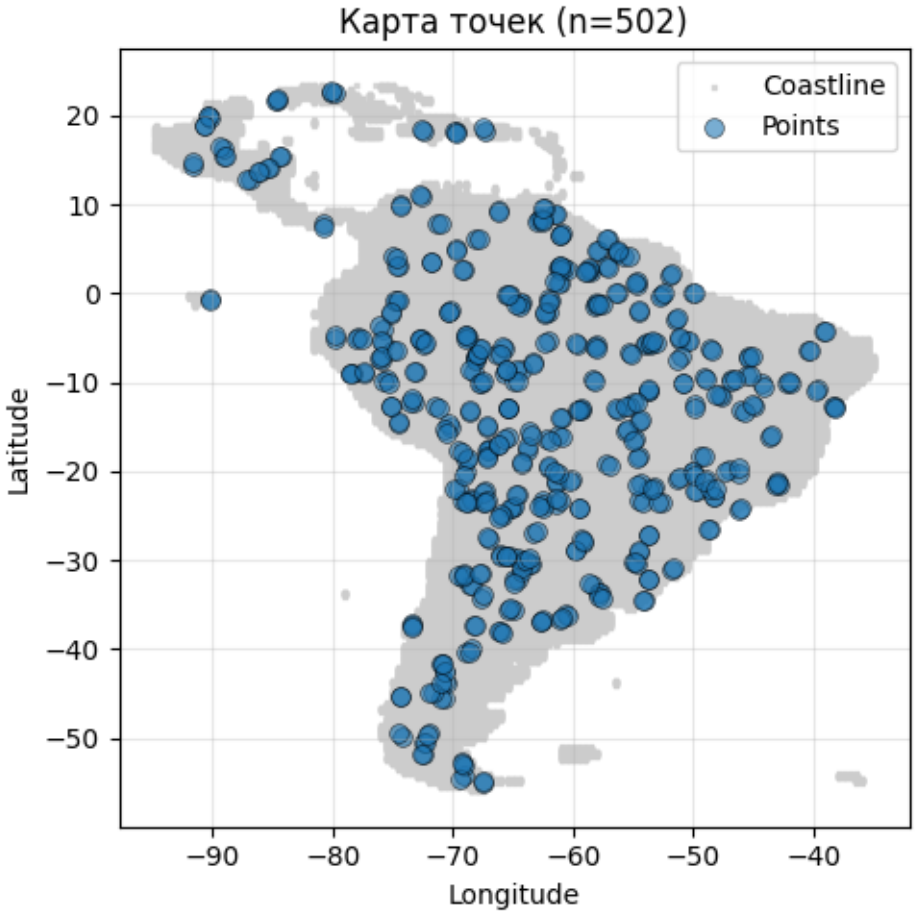
Карта точек (n=502)
Coastline
Points
Latitude
Longitude
20
10
0
−10
−20
−30
−40
−50
−90
−80
−70
−60
−50
−40

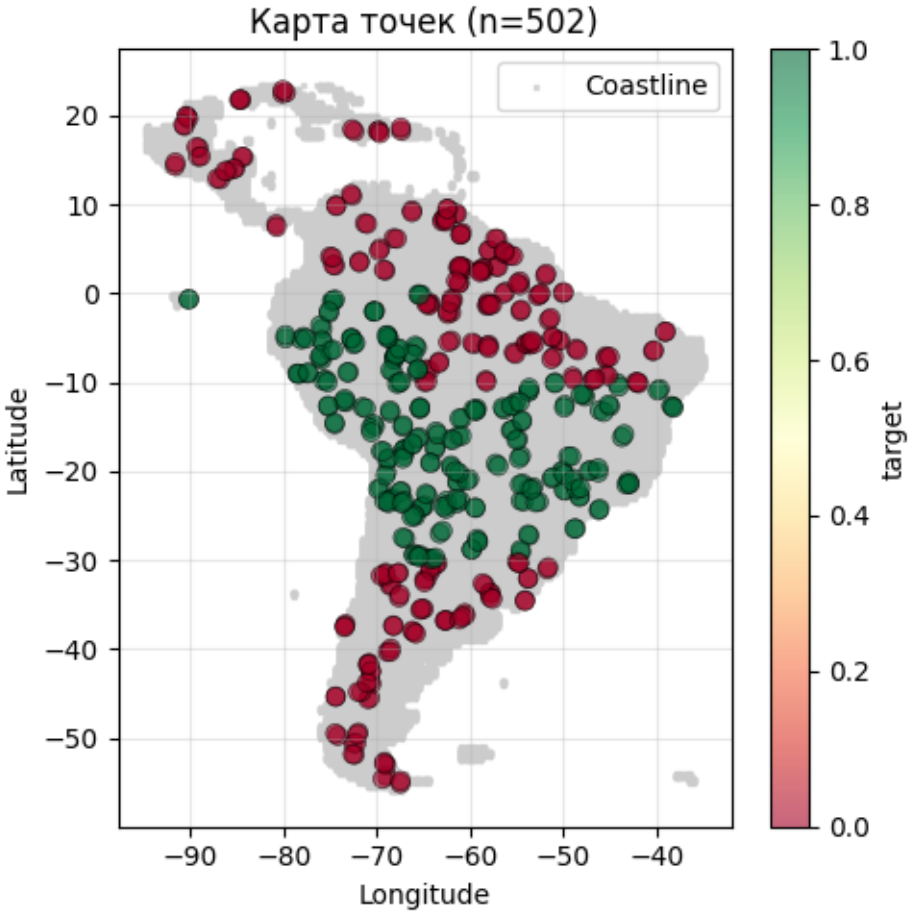

1.6 Шаг 1: Первый базовый подход

По условию задачи у нас есть `train.csv` (прямые наблюдения) и `test.csv`, где часть точек добавлена по спутниковым данным.

Сначала строим честный baseline на всех признаках и смотрим `F1 score` на разметке из `ytest.csv`. Это нужно как контрольная точка, чтобы понять, насколько модель склонна переобучаться в исходной постановке.

[4]:
```python
# Функция для оценки качества
def evaluate(y_pred, solution):
    """Оценка F1-score: overall, public, private"""
    from sklearn.metrics import f1_score

    merged = solution.copy()
    merged['pred'] = np.asarray(y_pred).reshape(-1)

    # Считаем метрику на уже округленных предсказаниях (0/1)
    merged['pred_label'] = np.clip(np.rint(merged['pred']), 0, 1).astype(int)

    public_mask = merged['Usage'] == 'public'
    private_mask = merged['Usage'] == 'private'
```

```
    overall_f1 = f1_score(merged['target'], merged['pred_label'])
    public_f1 = f1_score(merged.loc[public_mask, 'target'], merged.
 ↪loc[public_mask, 'pred_label'])
    private_f1 = f1_score(merged.loc[private_mask, 'target'], merged.
 ↪loc[private_mask, 'pred_label'])

    print(f"F1 overall: {overall_f1:.6f}")
    print(f"F1 public:  {public_f1:.6f}")
    print(f"F1 private: {private_f1:.6f}")

    return public_f1, private_f1, overall_f1

# Выделяем признаки (все кроме служебных)
feature_cols_numeric = [col for col in train.columns
                        if col not in ['ID', 'target', 'cluster', 'is_train']
                        and train[col].dtype in ['int64', 'float64']]

categorical_cols = train.select_dtypes(include=['object']).columns.tolist()
categorical_cols = [col for col in categorical_cols if col not in ['ID']]

all_features = feature_cols_numeric + categorical_cols

X_train = train[all_features]
y_train = train['target']
X_test = test[all_features]

from sklearn.model_selection import train_test_split
X_train_tr, X_train_val, y_train_tr, y_train_val = train_test_split(
    X_train, y_train, test_size=0.2, random_state=SEED, stratify=y_train
)

model = CatBoostClassifier(
    iterations=500,
    learning_rate=0.1,
    depth=12,
    random_seed=SEED,
    verbose=0,
 )

model.fit(X_train_tr, y_train_tr, cat_features=categorical_cols)
y_pred_test_baseline = np.asarray(model.predict(X_test)).reshape(-1).
 ↪astype(int)

baseline_public, baseline_private, baseline_overall =
evaluate(y_pred_test_baseline, solution)
```

```
F1 overall: 0.646440
F1 public:  0.645707
F1 private: 0.647208
```

[5]:
```
from sklearn.metrics import f1_score
f1_score(solution.target.values, (solution.target.values * 0 + 0.5 >= 0.5).
 ↪astype(int))
```

[5]:
```
0.5270917803169922
```

1.7 Шаг 2: Анализ важности признаков

Связываем результат baseline с условием задачи. Если в топе важности оказываются координаты (`longitude`, `latitude`), модель может использовать географическую «подсказку» вместо устойчивых экологических закономерностей. Это и есть первая типичная ошибка новичка: неявная утечка/спуриация через признаки, которые слишком прямо кодируют разделение.

[6]:
```
# Feature importance
importance_df = pd.DataFrame({
    'feature': all_features,
    'importance': model.get_feature_importance()
}).sort_values('importance', ascending=False)

print("\nTop 10 признаков:")
print(importance_df.head(10).to_string(index=False))

print("Это может означать, что модель переобучается на координаты.")
print("\nВНИМАНИЕ: longitude и latitude в топе важности!")
```

```
Top 10 признаков:
                 feature  importance
                latitude   25.842854
   habitat_quality_score   18.788004
      biodiversity_index   12.708726
               longitude    9.644228
             forest_type    6.298411
       disturbance_level    5.888199
            climate_zone    2.864203
     conservation_status    1.980591
seasonal_variation_score    1.594778
    human_activity_index    1.516413
Это может означать, что модель переобучается на координаты.

ВНИМАНИЕ: longitude и latitude в топе важности!
```

1.8 Шаг 3: Визуализация координат

Посмотрим, как распределены классы в пространстве координат.

[7]:
```
# Используем нашу функцию для визуализации
print("Train данные с раскраской по таргету:")
plot_map(train, coastline, color_by='target', figsize=(10, 8))
```

```
# Анализ распределения классов
print("\n" + "="*70)
print("АНАЛИЗ КООРДИНАТ")
print("="*70)

# Статистика по долготе
print("\nРаспределение классов по долготе:")
for target_val in [0, 1]:
    subset = train[train['target'] == target_val]
    print(f"\nКласс {target_val}:")
    print(f"  Longitude: min={subset['longitude'].min():.2f},
max={subset['longitude'].max():.2f}, mean={subset['longitude'].mean():.2f}")
    print(f"  Latitude:  min={subset['latitude'].min():.2f},
max={subset['latitude'].max():.2f}, mean={subset['latitude'].mean():.2f}")

print("\n" + "="*70)
print("ВЫВОД: Классы четко разделены по координатам!")
print("   Модель запомнила географическую границу между классами.")
print("   В реальном тесте эта закономерность не работает.")
print("   РЕШЕНИЕ: Нужно убрать longitude и latitude из признаков.")
print("="*70)
```

Train данные с раскраской по таргету:

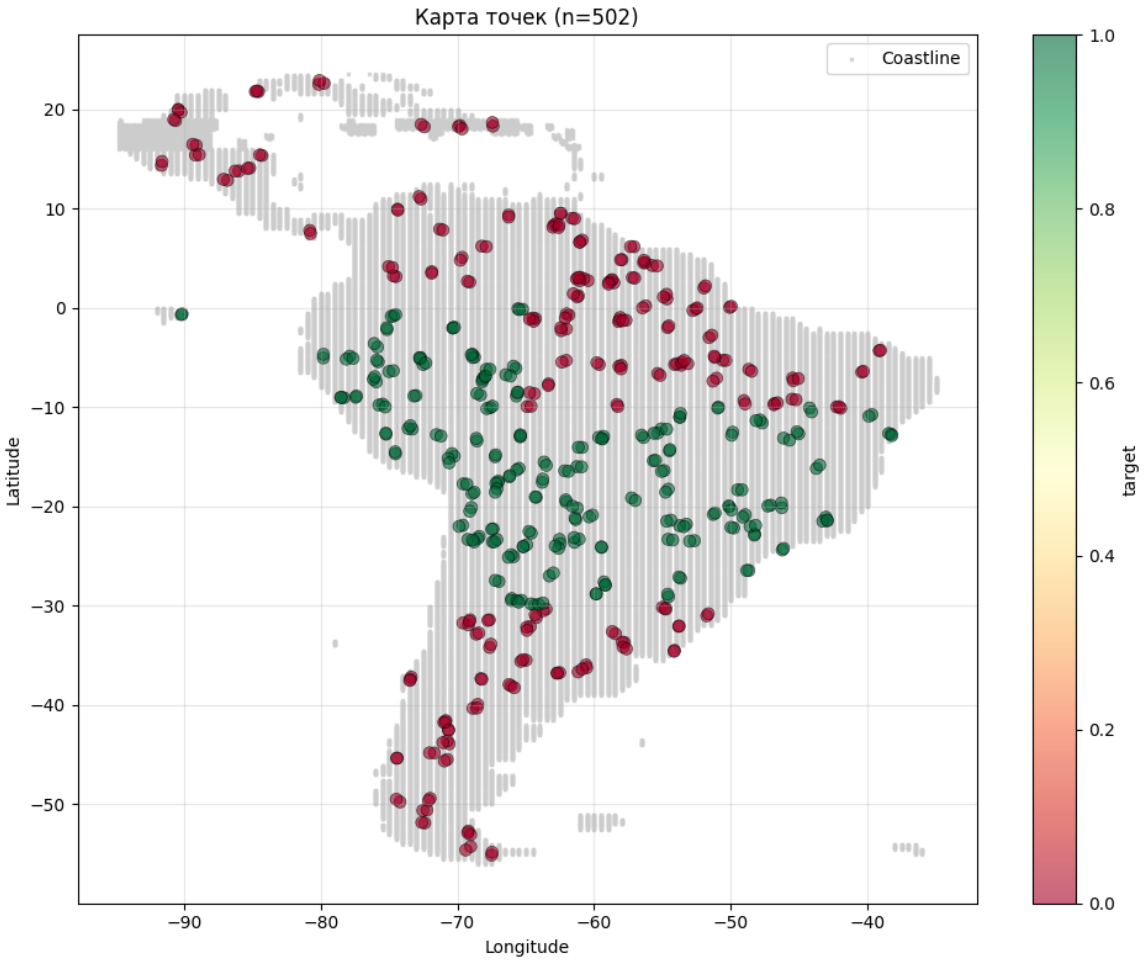

```
======================================================================
АНАЛИЗ КООРДИНАТ
======================================================================

Распределение классов по долготе:

Класс 0:
  Longitude: min=-91.65, max=-39.05, mean=-64.11
  Latitude:  min=-55.12, max=22.89, mean=-10.67

Класс 1:
  Longitude: min=-90.20, max=-38.22, mean=-62.39
  Latitude:  min=-29.95, max=-0.10, mean=-15.78

======================================================================
ВЫВОД: Классы четко разделены по координатам!
   Модель запомнила географическую границу между классами.
   В реальном тесте эта закономерность не работает.
   РЕШЕНИЕ: Нужно убрать longitude и latitude из признаков.
======================================================================
```

1.9 Шаг 4: Убираем координаты и переобучаем модель

Исправляем первую ошибку: убираем `longitude` и `latitude`, чтобы модель опиралась на содержательные признаки среды. Снова считаем `F1 score` и сравниваем с baseline. Если качество растет, значит координаты действительно мешали обобщению.

[8]:
```python
# Убираем координаты
features_no_coords = [f for f in all_features if f not in ['longitude',
'latitude']]
categorical_cols_filtered = [c for c in categorical_cols if c in
features_no_coords]

X_train_no_coords = train[features_no_coords]
X_test_no_coords = test[features_no_coords]

X_train_tr_no_coords, X_train_val_no_coords, y_train_tr_no_coords,
y_train_val_no_coords = train_test_split(
    X_train_no_coords, y_train, test_size=0.2, random_state=SEED,
stratify=y_train
)

model.fit(X_train_tr_no_coords, y_train_tr_no_coords,
cat_features=categorical_cols_filtered)
y_pred_test_no_coords = np.asarray(model.predict(X_test_no_coords)).
 ↪reshape(-1).astype(int)
```

```
nocoords_public, nocoords_private, nocoords_overall =
evaluate(y_pred_test_no_coords, solution)
```

```
F1 overall: 0.783972
F1 public:  0.798155
F1 private: 0.769591
```

1.10 Шаг 5: Детектор train vs test (поиск сдвига распределения)

Проверяем вторую ошибку новичка из условия: игнорирование того, что `train` и часть `test` собраны разными способами. Если модель легко отличает `train` от `test`, это признак domain shift (распределения различаются). Тогда у части test-точек стандартная модель может быть слишком уверенной и ошибаться системно.

[9]:
```
from catboost import cv, Pool

# Создаем датасет для классификации train vs test
X_combined = pd.concat([X_train_no_coords, X_test_no_coords], axis=0)
y_combined = np.concatenate([np.ones(len(X_train_no_coords)), np.
 ↪zeros(len(X_test_no_coords))])

model_ood = CatBoostClassifier(
    iterations=50,
    learning_rate=0.1,
    depth=6,
    random_seed=SEED,
    verbose=0
)

cv_data = Pool(data=X_combined, label=y_combined,
cat_features=categorical_cols_filtered)
_ = cv(
    pool=cv_data,
    params={
        'iterations': 50,
        'learning_rate': 0.1,
        'depth': 6,
        'loss_function': 'Logloss',
        'eval_metric': 'AUC',
        'random_seed': SEED,
        'verbose': False
    },
    fold_count=5,
    shuffle=True,
    stratified=True,
    partition_random_seed=SEED
)

model_ood.fit(X_combined, y_combined, cat_features=categorical_cols_filtered)
test_similarity_scores = model_ood.predict(X_test_no_coords,
prediction_type='Probability')[:, 1]
```

```
plt.figure(figsize=(10, 5))
plt.hist(test_similarity_scores, bins=100, alpha=0.7, edgecolor='black')
plt.xlabel('Вероятность принадлежности к train')
plt.ylabel('Количество объектов')
plt.title('Train/Test Classifier: Распределение вероятностей на test')
plt.grid(True, alpha=0.3)
plt.tight_layout()
plt.show()
```

```
Training on fold [0/5]

bestTest = 0.6328465347
bestIteration = 9

Training on fold [1/5]

bestTest = 0.6250990099
bestIteration = 4

Training on fold [2/5]

bestTest = 0.6888
bestIteration = 6

Training on fold [3/5]

bestTest = 0.6909022556
bestIteration = 11

Training on fold [4/5]

bestTest = 0.6967669173
bestIteration = 16
```

1.11 Шаг 6: OOD-корректировка предсказаний

Используем train/test-детектор как индикатор OOD-точек (похожести тестовой точки на train). Для точек с очень низкой похожестью понижаем вероятность класса 1 и снова считаем только `F1 score`.

Так мы адресуем вторую ошибку: учитываем сдвиг распределения и делаем предсказания устойчивее на «спутниковой» части теста.

[10]:
```
print("\nКорректируем предсказания для OOD объектов...")
print("="*70)

# Порог OOD: точки с низкой похожестью на train считаем сдвинутыми по распределению
ood_threshold = 0.07

y_pred_corrected = y_pred_test_no_coords.copy()
ood_mask = test_similarity_scores < ood_threshold
y_pred_corrected[ood_mask] = 0

# Выводим F1-score для каждого подхода: overall/public/private
_, _, _ = evaluate(y_pred_test_baseline, solution)
_, _, _ = evaluate(y_pred_test_no_coords, solution)
_, _, corrected_overall = evaluate(y_pred_corrected, solution)
```

```
Корректируем предсказания для OOD объектов...
======================================================================
F1 overall: 0.646440
F1 public:  0.645707
F1 private: 0.647208
F1 overall: 0.783972
F1 public:  0.798155
F1 private: 0.769591
F1 overall: 0.918549
F1 public:  0.918340
F1 private: 0.918768
```

[11]:
```
# Сохраняем submission с лучшими доступными предсказаниями
final_pred = y_pred_corrected

submission = pd.DataFrame({
    'ID': test['ID'].values,
    'target': (final_pred > 0.5) * 1
})
submission.to_csv('author_submission.csv', index=False)
```

D. Наследие Человечества

[1]:
```
# Шаг 0. Импорты
import csv
import json
from pathlib import Path

import numpy as np
from sklearn.feature_extraction.text import TfidfVectorizer
from sklearn.linear_model import LogisticRegression
from sklearn.metrics.pairwise import cosine_similarity
from sklearn.preprocessing import StandardScaler

# Фиксируем генератор случайных чисел для воспроизводимости
rng = np.random.default_rng(42)
```

1.12 Разбор решения по шагам

Решения идут по порядку и усложняются шаг за шагом: 1. Решение 0: IOU/Jaccard по словам. 2. Решение 1: unigram TF-IDF. 3. Решение 2: word+char TF-IDF. 4. Решение 3: решение 2 + greedy one-to-one. 5. Решение 4: решение 3 + logreg-reranker. 6. Решение 5: решение 4 + greedy one-to-one.

1.12.1 Шаг 1. Загрузка train/test/ytest

Читаем `train.json` и `test.json`, восстанавливаем train-пары, а `true_test` и разбиение `Public/Private` строим по `ytest.csv` через соответствия `left_id` ↔ `right_id` и колонку `Usage`.

[2]:
```
# Шаг 1. Загрузка train/test/ytest (ещё компактнее)
base_dir = Path("/Users/aguschin/Git/uni/vsosh/zakl/nlp")
train_json_path, test_json_path, ytest_csv_path = (
    base_dir / "train.json",
    base_dir / "test.json",
    base_dir / "ytest.csv",
)

def split_poem(text):
    lines = [line.strip() for line in text.split("\n") if line.strip()]
    cut = min(8, len(lines) - 1)
    if cut < 1:
        return None, None
    left, right = "\n".join(lines[:cut]).strip(), "\n".join(lines[cut:]).
 ↪strip()
    return (left, right) if left and right else (None, None)

# train: из полных текстов -> пары половинок -> shuffle правых
train_pairs = [split_poem(text) for text in json.loads(train_json_path.
 ↪read_text(encoding="utf-8"))]
train_pairs = [(left, right) for left, right in train_pairs if left and
right]
```

```
left_parts = [left for left, _ in train_pairs]
right_parts = [right for _, right in train_pairs]
train_idx = np.arange(len(left_parts), dtype=int)
perm_train = np.random.default_rng(123).permutation(len(left_parts))
left_train = left_parts
right_train_shuffled = [right_parts[i] for i in perm_train]
true_train = np.empty(len(left_parts), dtype=int)
true_train[perm_train] = np.arange(len(left_parts))
n_train = len(left_train)

# test: готовые left/right
test_data = json.loads(test_json_path.read_text(encoding="utf-8"))
left_items, right_items = test_data["left"], test_data["right"]
left_test = [item["left_text"] for item in left_items]
left_ids = [item["left_id"] for item in left_items]
right_test_shuffled = [item["right_text"] for item in right_items]
right_ids = [item["right_id"] for item in right_items]
n_test = len(left_test)

# ytest: left_id -> right_id и Usage
with open(ytest_csv_path, "r", encoding="utf-8") as f:
    ytest_rows = [row for row in csv.DictReader(f)]

left_to_right = {}
left_to_usage = {}
for row in ytest_rows:
    left_id = (row.get("left_id") or "").strip()
    right_id = (row.get("right_id") or "").strip()
    usage = (row.get("Usage") or "Private").strip().title()
    if not left_id or not right_id:
        continue
    if usage not in {"Public", "Private"}:
        usage = "Private"
    left_to_right[left_id] = right_id
    left_to_usage[left_id] = usage

right_id_to_pos = {rid: j for j, rid in enumerate(right_ids)}
true_test = np.array([right_id_to_pos[left_to_right[lid]] for lid in
left_ids], dtype=int)
usage_test = np.array([left_to_usage.get(lid, "Private") for lid in
left_ids], dtype=object)
public_mask = usage_test == "Public"
private_mask = usage_test == "Private"

# проверки и служебные переменные
assert all(lid in left_to_right for lid in left_ids), "Не все left_id из test
есть в ytest.csv"
assert all(left_to_right[lid] in right_id_to_pos for lid in left_ids),
"Некоторые right_id из ytest.csv отсутствуют в test.json"
vowels = set("аеёиоуыэюя")
```

```
test_idx = np.arange(n_test, dtype=int) + 10_000_000
overlap = len(set(train_idx.tolist()) & set(test_idx.tolist()))
assert overlap == 0, "train/test overlap detected"

print(f"Источник train: {train_json_path}")
print(f"Источник test : {test_json_path}")
print(f"Источник gt   : {ytest_csv_path}")
print(f"Всего пар: Train: {n_train} | Test: {n_test}")
print(f"Usage split: Public={int(public_mask.sum())} |
Private={int(private_mask.sum())}")
print(f"Честность split: overlap(train,test)={overlap}\n")
```

```
Источник train: /Users/aguschin/Git/uni/vsosh/zakl/nlp/train.json
Источник test : /Users/aguschin/Git/uni/vsosh/zakl/nlp/test.json
Источник gt   : /Users/aguschin/Git/uni/vsosh/zakl/nlp/ytest.csv
Всего пар: Train: 2000 | Test: 640
Usage split: Public=320 | Private=320
Честность split: overlap(train,test)=0
```

1.12.2 Решение 0 — IOU/Jaccard по словам

Базовый скор: для каждой пары половинок считаем пересечение слов и делим на объединение. Оценка/выбор пары: `top1` через `argmax` (greedy matching не используется).

[3]:
```
# Шаг 2. Решение 0: IOU/Jaccard через split()

# Решение 0: базовый скор по пересечению слов

def _masked_acc(pred_idx: np.ndarray, true_idx: np.ndarray, mask: np.
 ↪ndarray):
    return float((pred_idx[mask] == true_idx[mask]).mean()) if mask.any()
else float("nan")

# Функция: считает единый score через argmax (Overall/Public/Private)
def evaluate_similarity_argmax(sim: np.ndarray, true_idx: np.ndarray):
    pred = sim.argmax(axis=1)
    score = float((pred == true_idx).mean())
    score_public = _masked_acc(pred, true_idx, public_mask)
    score_private = _masked_acc(pred, true_idx, private_mask)
    return {
        "score": score,
        "score_public": score_public,
        "score_private": score_private,
    }

# Функция: превращает каждый текст в множество токенов
def _token_sets(texts):
    return [set(text.split()) for text in texts]

# Функция: строит матрицу Jaccard/IOU для всех пар left-right
```

```
def _jaccard_matrix(left_sets, right_sets):
    n_left = len(left_sets)
    n_right = len(right_sets)
    sim = np.zeros((n_left, n_right), dtype=np.float32)
    for i, lset in enumerate(left_sets):
        for j, rset in enumerate(right_sets):
            union = lset | rset
            if union:
                sim[i, j] = len(lset & rset) / len(union)
    return sim

word_train_l = _token_sets(left_train)
word_train_r = _token_sets(right_train_shuffled)
word_test_l = _token_sets(left_test)
word_test_r = _token_sets(right_test_shuffled)

sim0_test = _jaccard_matrix(word_test_l, word_test_r)
metrics0 = evaluate_similarity_argmax(sim0_test, true_test)
print(
    f"0_iou_argmax: "
    f"score={metrics0['score']:.4f} (pub={metrics0['score_public']:.4f},
priv={metrics0['score_private']:.4f})"
)
```

```
0_iou_argmax: score=0.1734 (pub=0.1594, priv=0.1875)
```

1.12.3 Решение 1 — unigram TF-IDF

Улучшаем решение 0: заменяем простое пересечение слов на TF-IDF-представление слов и косинусную близость.

[4]:
```
# Шаг 2. Решение 1: unigram TF-IDF

# Решение 1: улучшаем решение 0 с помощью TF-IDF признаков
vec1 = TfidfVectorizer(ngram_range=(1, 1), min_df=5, max_df=0.95,
sublinear_tf=False)
vec1.fit(left_train + right_train_shuffled)
sim1_test = cosine_similarity(vec1.transform(left_test), vec1.
 ↪transform(right_test_shuffled))
metrics1 = evaluate_similarity_argmax(sim1_test, true_test)
print(
    f"1_unigram_tfidf: "
    f"score={metrics1['score']:.4f} (pub={metrics1['score_public']:.4f},
priv={metrics1['score_private']:.4f})"
)
```

```
1_unigram_tfidf: score=0.2734 (pub=0.2562, priv=0.2906)
```

1.12.4 Решение 2 — word+char TF-IDF

Улучшаем решение 1: смешиваем similarity из word TF-IDF и char TF-IDF, затем считаем argmax-метрики.

[5]:
```
# Шаг 3. Решение 2: word+char TF-IDF

# Функция: строит blended similarity из word и char TF-IDF
def _build_tfidf_blend(left_train, right_train, left_eval, right_eval, cfg,
alpha):
    vec_word = TfidfVectorizer(analyzer="word", **cfg["word"] )
    vec_char = TfidfVectorizer(analyzer="char_wb", **cfg["char"] )
    vec_word.fit(left_train + right_train)
    vec_char.fit(left_train + right_train)
    sim_word = cosine_similarity(vec_word.transform(left_eval), vec_word.
 ↪transform(right_eval))
    sim_char = cosine_similarity(vec_char.transform(left_eval), vec_char.
 ↪transform(right_eval))
    return alpha * sim_word + (1.0 - alpha) * sim_char

cfg2b = {
    "word": dict(ngram_range=(1, 2), min_df=2, max_df=0.95,
sublinear_tf=True),
    "char": dict(ngram_range=(2, 5), min_df=1, max_df=0.99,
sublinear_tf=True),
}
alpha2b = 0.25

# Решение 2: улучшаем решение 1 смешением word/char признаков
sim2b_train = _build_tfidf_blend(left_train, right_train_shuffled,
left_train, right_train_shuffled, cfg2b, alpha2b)
sim2b_test = _build_tfidf_blend(left_train, right_train_shuffled, left_test,
right_test_shuffled, cfg2b, alpha2b)
metrics2 = evaluate_similarity_argmax(sim2b_test, true_test)
print(
    f"2_word_char_tfidf: "
    f"score={metrics2['score']:.4f} (pub={metrics2['score_public']:.4f},
priv={metrics2['score_private']:.4f})"
)
```

```
2_word_char_tfidf: score=0.4938 (pub=0.4969, priv=0.4906)
```

1.12.5 Решение 3 — TF-IDF + greedy one-to-one

Берём матрицу скоров решения 2 и добавляем жадное взаимно-однозначное сопоставление для роста one2one.

[6]:
```
# Функция: строит жадное взаимно-однозначное соответствие
def greedy_one2one_matching(sim: np.ndarray):
    n = sim.shape[0]
    flat_order = np.argsort(sim, axis=None)[::-1]
    pred = np.full(n, -1, dtype=int)
    used_left = np.zeros(n, dtype=bool)
    used_right = np.zeros(n, dtype=bool)
    matched = 0
    for idx in flat_order:
```

```
        i, j = divmod(idx, n)
        if (not used_left[i]) and (not used_right[j]):
            pred[i] = j
            used_left[i] = True
            used_right[j] = True
            matched += 1
            if matched == n:
                break
    return pred

# Функция: считает единый score через greedy
def evaluate_similarity_greedy(sim: np.ndarray, true_idx: np.ndarray):
    pred = greedy_one2one_matching(sim)
    score = float((pred == true_idx).mean())
    score_public = _masked_acc(pred, true_idx, public_mask)
    score_private = _masked_acc(pred, true_idx, private_mask)
    return {
        "score": score,
        "score_public": score_public,
        "score_private": score_private,
    }

# Решение 3: добавляем greedy к решению 2
metrics3 = evaluate_similarity_greedy(sim2b_test, true_test)
print(
    f"3_tfidf_greedy: "
    f"score={metrics3['score']:.4f} (pub={metrics3['score_public']:.4f},
priv={metrics3['score_private']:.4f})"
)
```

```
3_tfidf_greedy: score=0.5062 (pub=0.5094, priv=0.5031)
```

1.12.6 Решение 4 — logreg reranker

Улучшаем решение 3: добавляем pairwise-фичи и логистическую регрессию, которая переоценивает кандидатов перед `argmax`.

[7]:
```
# Коротко: считаем статистики половинок и собираем pairwise-feature cube
def _half_stats(texts):
    stats = []
    for text in texts:
        lines = [line.strip() for line in text.split("\n") if line.strip()]
or [text.strip()]
        words = ["".join(ch for ch in w if ch.isalpha()) for w in text.
 ↪replace("\n", " ").split()]
        words = [w for w in words if w]
        letters = [ch for ch in text if ch.isalpha()]
        v_all = [sum(1 for ch in line.lower() if ch in vowels) for line in
lines]
        v_edge = [sum(1 for ch in line.lower() if ch in vowels) for line in
lines[-4:]]
```

```
        cap_ratio = (sum(1 for w in words if w[0].isupper()) / len(words)) if
words else 0.0
        latin_ratio = (sum(1 for ch in letters if 'a' <= ch.lower() <= 'z') /
len(letters)) if letters else 0.0
        stats.append([len(lines), np.mean([len(line) for line in lines]), np.
 ↪mean(v_all), np.mean(v_edge), cap_ratio, latin_ratio])
    return np.asarray(stats, dtype=np.float32)

# Коротко: переводим разницу скалярного признака в similarity
def _pair_sim(left_vals, right_vals):
    diff = np.abs(left_vals[:, None] - right_vals[None, :])
    norm = np.maximum(left_vals[:, None], right_vals[None, :])
    return 1.0 - diff / (norm + 1e-12)

# Коротко: формируем обучающие пары (true + hard negatives + random
negatives)
def _sample_pairs(cube, true_idx, hard_source_sim, hard_k=8, rand_k=8,
random_state=42):
    rng_local = np.random.default_rng(random_state)
    n = cube.shape[0]
    rows, labels = [], []
    for i in range(n):
        j_true = true_idx[i]
        rows.append(cube[i, j_true]); labels.append(1)
        hard_neg = [j for j in np.argsort(-hard_source_sim[i]) if j !=
j_true][:hard_k]
        forbidden = set(hard_neg + [j_true])
        pool = np.array([j for j in range(n) if j not in forbidden],
dtype=int)
        rand_neg = rng_local.choice(pool, size=min(rand_k, len(pool)),
replace=False).tolist() if len(pool) else []
        for j in hard_neg + rand_neg:
            rows.append(cube[i, j]); labels.append(0)
    return np.asarray(rows, dtype=np.float32), np.asarray(labels, dtype=np.
 ↪int32)

left_train_feat = _half_stats(left_train)
right_train_feat = _half_stats(right_train_shuffled)
left_test_feat = _half_stats(left_test)
right_test_feat = _half_stats(right_test_shuffled)

train_maps = [sim2b_train] + [_pair_sim(left_train_feat[:, k],
right_train_feat[:, k]) for k in range(left_train_feat.shape[1])] +
[_jaccard_matrix(word_train_l, word_train_r).astype(np.float32)]
test_maps = [sim2b_test] + [_pair_sim(left_test_feat[:, k], right_test_feat[:
 ↪, k]) for k in range(left_test_feat.shape[1])] +
[_jaccard_matrix(word_test_l, word_test_r).astype(np.float32)]
cube_train = np.stack(train_maps, axis=2).astype(np.float32)
cube_test = np.stack(test_maps, axis=2).astype(np.float32)
```

```
x_train, y_train = _sample_pairs(cube_train, true_train, sim2b_train,
hard_k=8, rand_k=8, random_state=42)
scaler = StandardScaler()
model = LogisticRegression(C=0.03, max_iter=2000, class_weight="balanced",
solver="lbfgs", random_state=42)
model.fit(scaler.fit_transform(x_train), y_train)
flat_scores = model.predict_proba(scaler.transform(cube_test.reshape(-1,
cube_test.shape[-1])))[:, 1]
test_scores_4 = flat_scores.reshape(cube_test.shape[0], cube_test.shape[1])

alpha4 = 0.82
sim4_test = alpha4 * test_scores_4 + (1.0 - alpha4) * sim2b_test
metrics4 = evaluate_similarity_argmax(sim4_test, true_test)
print(
    f"4_logreg_rerank: "
    f"score={metrics4['score']:.4f} (pub={metrics4['score_public']:.4f},
priv={metrics4['score_private']:.4f})"
)
```

```
4_logreg_rerank: score=0.5203 (pub=0.5031, priv=0.5375)
```

1.12.7 Решение 5 — logreg reranker + greedy

Финальное улучшение: к score-матрице решения 4 снова применяем greedy one-to-one для максимального one2one.

[8]:
```
# Решение 5: добавляем greedy к скалам решения 4
metrics5 = evaluate_similarity_greedy(sim4_test, true_test)
print(
    f"5_logreg_rerank_greedy: "
    f"score={metrics5['score']:.4f} (pub={metrics5['score_public']:.4f},
priv={metrics5['score_private']:.4f})"
)
```

```
5_logreg_rerank_greedy: score=0.5656 (pub=0.5687, priv=0.5625)
```

[10]:
```
# Сохраняем сабмит для автора из лучшего решения
sim_test = sim4_test
pred_idx = sim_test.argmax(axis=1)

author_submission_path = base_dir / "author_submission.csv"
with open(author_submission_path, "w", newline="", encoding="utf-8") as f:
    writer = csv.writer(f)
    writer.writerow(["left_id", "right_id"])
    for i, lid in enumerate(left_ids):
        writer.writerow([lid, right_ids[int(pred_idx[i])]])

print(f"Saved {author_submission_path}")
```

```
Saved /Users/aguschin/Git/uni/vsosh/zakl/nlp/author_submission.csv
```

1.12.8 Шаг 5. Результаты матчинга

Показываем только примеры матчинга для лучшего текущего решения: лучшие и худшие пары.

[12]:
```
# Шаг 5. Результаты матчинга по квантилям для лучшего решения

def _preview_text(text, max_chars=220, max_lines=8):
    lines = [line.strip() for line in text.split("\n") if line.strip()][:
 ↪max_lines]
    preview = "\n".join(lines)
    return preview[:max_chars] + ("..." if len(preview) > max_chars else "")

sim_test = sim4_test
pred_idx = sim_test.argmax(axis=1)

quantiles_to_show = [0.99, 0.75, 0.5, 0.25, 0.0]  # можно менять вручную
if not quantiles_to_show or any(q < 0 or q > 1 for q in quantiles_to_show):
    raise ValueError("Квантили должны быть в [0, 1], список не должен быть
пустым")

match_scores = sim_test[np.arange(len(left_test)), pred_idx]
used = set()

def pick_idx_for_quantile(q):
    target = float(np.quantile(match_scores, q))
    order = np.argsort(np.abs(match_scores - target))
    idx = next((int(i) for i in order if int(i) not in used), int(order[0]))
    used.add(idx)
    return idx, target

print(f"Матчинг для лучшего решения")
print(f"Квантили: {quantiles_to_show}")
print()

for q in quantiles_to_show:
    i, target = pick_idx_for_quantile(q)
    j = int(pred_idx[i])
    print(f"=== q={q:.2f} | target={target:.4f} | sim={match_scores[i]:.4f}
===")
    print(f"left={i} -> pred_right={j} | true={true_test[i]} | correct={j ==
true_test[i]}")
    print("LEFT :", _preview_text(left_test[i]))
    print("RIGHT:", _preview_text(right_test_shuffled[j]))
    print()
```

```
Матчинг для лучшего решения
Квантили: [0.99, 0.75, 0.5, 0.25, 0.0]

=== q=0.99 | target=0.9055 | sim=0.9076 ===
left=383 -> pred_right=628 | true=628 | correct=True
LEFT : Человек живет на белом свете.
```

```
Где - не знаю. Суть совсем не в том.
Я - лежу в пристрелянном кювете,
Он - с мороза входит в теплый дом.
Человек живет на белом свете,
Он - в квартиру поднялся уже.
Я - лежу в пристрелянном ...
RIGHT: Человек живет на белом свете
Он - в квартире зажигает свет
Я - лежу в пристрелянном кювете,
Я - вмерзаю в ледяной кювет.
Снег не тает. Губы, щеки, веки
Он засыпал. И велит дрожать...
С думой о далеком человеке
Легче до а...

=== q=0.75 | target=0.7871 | sim=0.7870 ===
left=208 -> pred_right=508 | true=508 | correct=True
LEFT : Бронепоезда взвывают вдруг,
Стылый ветер грудью разрывая.
Бронепоезда идут на юг
Вдоль твоих перронов,
Лозовая!
Звезды первую звезду зовут.
Дым заката холоден и розов.
Над бронеплощадками плывут
RIGHT: Бескозырки черные матросов.
Говорит, гремит, вздыхает бронь
Отдаленно
и громоподобно.
И горит на станции огонь,
Керосиновый огонь бездомный.
Лист осенний, запоздавший лист,
Братьев в путь-дорогу созывает.

=== q=0.50 | target=0.7115 | sim=0.7113 ===
left=342 -> pred_right=350 | true=350 | correct=True
LEFT : Славянка тихая, сколь ток приятен твой,
Когда, в осенний день, в твои глядятся воды
Холмы, одетые последнею красой
Полуотцветшия природы.
Спешу к твоим брегам... свод неба тих и чист;
При свете солнечном прохлада повевае...
RIGHT: Иду под рощею излучистой тропой;
Что шаг, то новая в глазах моих картина;
То вдруг сквозь чащу древ мелькает предо мной,
Как в дыме, светлая долина;
То вдруг исчезло все... окрест сгустился лес;
Все дико вкруг меня, и су...

=== q=0.25 | target=0.6497 | sim=0.6498 ===
left=532 -> pred_right=415 | true=415 | correct=True
```

```
LEFT : Посвящается Феллини
Мертвец играл на дудочке,
По городу гулял,
И незнакомой дурочке
Он руку предлагал.
А дурочка, как Золушка,
Ему в глаза глядит,-
Он говорит о золоте,
RIGHT: О славе говорит.
Мертвец, певец и умница,
Его слова просты -
Пусты ночные улицы,
И площади пусты.
«Мне больно, мне невесело,
Мне холодно зимой,
Возьми меня невестою,

=== q=0.00 | target=0.1137 | sim=0.1137 ===
left=533 -> pred_right=373 | true=329 | correct=False
LEFT : Нет.
Это неправда.
Нет!
И ты?
Любимая,
за что,
за что же?!
Хорошо -
RIGHT: Что нашу грусть -
В листы,
И груз - в цветы
Всего за только всхруст
Руки
В руке:
Игру.
Индус, а может Златоуст
```

E. Подозрительные пирожные

Решение состоит из следующих этапов: 1. Загружаем предобученную CNN и получаем эмбеддинги для картинок. 2. Вычисляем для каждой картинки outlier-метрики `robust_mahalanobis`, `global_knn`, `class_knn`. 3. Аггрегируем метрики с весами (`2.0`, `1.5`, `0.5`). 4. Сортируем картинки по значению матрики, выбираем top-`K` и сохраняем в `submission_author.csv`.

[1]:
```
import json
import numpy as np
import pandas as pd
import torch
import torch.nn as nn
from torch.utils.data import DataLoader, TensorDataset

ARTIFACTS_DIR = "."
TEST_PACKAGE = f"{ARTIFACTS_DIR}/public_test_package.npz"
TEST_META = f"{ARTIFACTS_DIR}/public_test_meta.json"
WEIGHTS_PATH = f"{ARTIFACTS_DIR}/model_weights.pt"
SUBMISSION_PATH = "submission.csv"

DEVICE = torch.device("cuda" if torch.cuda.is_available() else "cpu")
print("Device:", DEVICE)
```

```
Device: cpu
```

Код сети и получения эмбеддингов картинок:

[2]:
```
class SmallCNN(nn.Module):
    def __init__(self, n_classes=10):
        super().__init__()
        self.features = nn.Sequential(
            nn.Conv2d(1, 16, kernel_size=3, padding=1),
            nn.ReLU(inplace=True),
            nn.MaxPool2d(2),
            nn.Conv2d(16, 32, kernel_size=3, padding=1),
            nn.ReLU(inplace=True),
            nn.MaxPool2d(2),
            nn.Conv2d(32, 64, kernel_size=3, padding=1),
            nn.ReLU(inplace=True),
        )
        self.fc1 = nn.Linear(64 * 8 * 8, 64)
        self.act = nn.ReLU(inplace=True)
        self.fc2 = nn.Linear(64, n_classes)

    def forward(self, x):
        z = self.features(x)
        z = z.flatten(1)
        h = self.act(self.fc1(z))
        logits = self.fc2(h)
        return logits, h
```

```
def infer_embeddings_and_preds(model, x_np, batch_size=256):
    ds = TensorDataset(torch.from_numpy(x_np).float())
    loader = DataLoader(ds, batch_size=batch_size, shuffle=False)
    all_emb, all_pred = [], []
    model.eval()
    with torch.no_grad():
        for (xb,) in loader:
            xb = xb.to(DEVICE)
            logits, emb = model(xb)
            all_emb.append(emb.cpu().numpy())
            all_pred.append(logits.argmax(dim=1).cpu().numpy())
    emb = np.concatenate(all_emb, axis=0).astype(np.float32)
    pred = np.concatenate(all_pred, axis=0).astype(np.int64)
    return emb, pred

state = torch.load(WEIGHTS_PATH, map_location=DEVICE)
n_classes = int(state["fc2.weight"].shape[0]) if "fc2.weight" in state else
10
model = SmallCNN(n_classes=n_classes)
model.load_state_dict(state)
model = model.to(DEVICE).eval()
print("Model loaded")
```

```
Model loaded
```

[3]:
```
test = np.load(TEST_PACKAGE)
x_test = test["images"].astype(np.float32)

K = 1000

emb_test, pred_test = infer_embeddings_and_preds(model, x_test)

n_test = len(x_test)
print(f"n_test={n_test}, K={K}, emb_dim={emb_test.shape[1]}")
```

```
n_test=10000, K=1000, emb_dim=64
```

1.12.9 Идея решения

Будем искать выбросы в пространстве эмбеддингов нейросети.
Предполагаем, что после прохождения через обученную модель объекты одного и того же класса образуют в пространстве признаков компактные кластеры. Тогда выбросы можно искать как точки, которые расположены “нетипично” относительно остальных точек.

Для этого используются несколько типов метрик:

1. **Global kNN score.**
   Для каждого объекта считается среднее расстояние до его ближайших соседей среди всех объектов датасета.
   Если объект находится изолированно, его score будет большим.

2. **Class kNN score.**
   Аналогично предыдущему пункту, но соседи ищутся только среди объектов того же

предсказанного класса.
Это позволяет находить точки, которые выглядят необычно именно внутри своего класса, даже если глобально они не слишком далеки от других.

3. **Robust Mahalanobis score внутри класса.**
Для каждого предсказанного класса оценивается среднее μ и матрица ковариаций Σ эмбеддингов, после чего для каждого объекта считается расстояние Махаланобиса до центра своего класса. Расстояние Махаланобиса считается так:

$$(x_i - \mu)^T \Sigma^{-1} (x_i - \mu)$$

Идея использования ковариации в том, что Махаланобис смотрит на точку относительно формы распределения класса. Иногда точку-выброс можно поймать тем, что она отклоняется не по длине, а по “неправильному направлению” в пространстве. Чтобы выбросы не искажали изначальные оценки μ и Σ по выборке, используем робастную схему: на каждой итерации временно отбрасываем самые далёкие точки, и оцениваем параметры только по оставшемуся “ядру” класса.

Таким образом, решение опирается на следующую гипотезу:
выбросы — это объекты, которые в пространстве признаков либо далеки от типичного распределения своего класса, либо плохо вписываются в локальную структуру соседей.

Примечание: без использования расстояния Махаланобиса можно получить до 80% баллов за задачу.

Ниже реализованы функции метрик:

[4]:
```
import numpy as np

def score_robust_mahalanobis(emb, pred, lam=0.15, trim_frac=0.10, iters=2):
    """
    Считает робастный Mahalanobis score внутри каждого предсказанного класса.

    Идея:
    - для каждого класса оцениваем "нормальное" распределение эмбеддингов;
    - затем для каждого объекта считаем расстояние Махаланобиса до центра
класса;
    - чтобы выбросы не портили оценку среднего и ковариации,
      несколько раз отбрасываем самые далёкие точки и пересчитываем
статистики.

    Параметры:
    - emb: матрица эмбеддингов shape [N, d]
    - pred: предсказанные классы shape [N]
    - lam: коэффициент регуляризации ковариации
    - trim_frac: доля самых далёких точек, временно исключаемых при trimming
    - iters: число итераций робастного пересчёта
    """
    d = emb.shape[1]  # размерность пространства признаков
    out = np.zeros(len(emb), dtype=np.float64)  # итоговый score для всех
объектов
    eye = np.eye(d, dtype=np.float64)  # единичная матрица для регуляризации
```

```
    # Обрабатываем каждый класс отдельно
    for c in np.unique(pred):
        m = pred == c           # маска объектов класса c
        h = emb[m].astype(np.float64)  # эмбеддинги только этого класса
        n = len(h)

        # Если объектов слишком мало, робастную оценку делать ненадёжно.
        # Тогда просто считаем обычное расстояние Махаланобиса.
        if n < 8:
            mu = h.mean(axis=0, keepdims=True)    # центр класса
            cen = h - mu                          # центрированные эмбеддинги

            # Ковариация + диагональная регуляризация для устойчивости
            cov = (cen.T @ cen) / max(1, n - 1) + lam * eye

            # Псевдообратная матрица вместо обычной обратной -
            # устойчивее, если ковариация плохо обусловлена
            inv = np.linalg.pinv(cov)

            # Квадрат расстояния Махаланобиса для каждой точки:
            # (x - mu)^T inv (x - mu)
            out[m] = np.einsum("bi,ij,bj->b", cen, inv, cen)
            continue

        # Изначально считаем, что сохраняем все точки класса
        keep = np.ones(n, dtype=bool)

        # Начальная грубая оценка среднего и обратной ковариации
        mu = h.mean(axis=0, keepdims=True)
        inv = np.linalg.pinv(np.cov(h.T) + lam * eye)

        # Несколько итераций робастного trimming
        for _ in range(max(1, iters)):
            # Берём только текущие "надёжные" точки
            hh = h[keep]

            # Пересчитываем центр по оставшимся точкам
            mu = hh.mean(axis=0, keepdims=True)

            # Центрируем оставшиеся точки
            cen_hh = hh - mu

            # Пересчитываем ковариацию по очищенному подмножеству
            cov = (cen_hh.T @ cen_hh) / max(1, len(hh) - 1) + lam * eye
            inv = np.linalg.pinv(cov)

            # Считаем расстояния Махаланобиса уже для всех точек класса
            cen_all = h - mu
            dist_all = np.einsum("bi,ij,bj->b", cen_all, inv, cen_all)
```

```
            # Порог: оставляем (1 - trim_frac) долю ближайших точек
            thr = float(np.quantile(dist_all, 1.0 - trim_frac))
            keep = dist_all <= thr

            # Защита от ситуации, когда осталось слишком мало точек:
            # тогда ослабляем trimming
            if keep.sum() < max(5, int(0.5 * n)):
                keep = dist_all <= float(np.quantile(dist_all, 0.7))

        # После финальной оценки считаем итоговый Mahalanobis score
        # для всех точек этого класса
        cen = h - mu
        out[m] = np.einsum("bi,ij,bj->b", cen, inv, cen)

    return out


def score_global_knn(emb, k=10):
    """
    Считает глобальный kNN score:
    среднее расстояние до k ближайших соседей по всему датасету.

    Если точка находится изолированно от остальных,
    её score будет большим.
    """
    n = emb.shape[0]

    # Если точек слишком мало, meaningful score нет
    if n <= 2:
        return np.zeros(n, dtype=np.float64)

    # Нельзя брать соседей больше, чем число остальных точек
    kk = min(k, n - 1)

    x = emb.astype(np.float64)

    # Квадраты норм для всех точек
    x2 = np.sum(x * x, axis=1, keepdims=True)

    # Матрица квадратов попарных евклидовых расстояний:
    # ||xi - xj||^2 = ||xi||^2 + ||xj||^2 - 2 <xi, xj>
    d2 = x2 + x2.T - 2.0 * (x @ x.T)

    # Убираем расстояние точки до самой себя
    np.fill_diagonal(d2, np.inf)

    # Берём kk наименьших расстояний в каждой строке
    knn = np.partition(d2, kk - 1, axis=1)[:, :kk]
```

```
    # Возвращаем среднее обычное расстояние до ближайших соседей
    return np.mean(np.sqrt(np.maximum(knn, 0.0)), axis=1)


def score_class_knn(emb, pred, k=8):
    """
    Считает class-wise kNN score:
    среднее расстояние до k ближайших соседей внутри предсказанного класса.

    Это помогает находить объекты, которые нетипичны
    именно для своего класса.
    """
    out = np.zeros(len(emb), dtype=np.float64)

    # Считаем score отдельно внутри каждого класса
    for c in np.unique(pred):
        m = pred == c
        h = emb[m].astype(np.float64)
        n = len(h)

        # Если в классе слишком мало точек, score считаем нулевым
        if n <= 2:
            out[m] = 0.0
            continue

        kk = min(k, n - 1)

        # Квадраты норм точек внутри класса
        h2 = np.sum(h * h, axis=1, keepdims=True)

        # Матрица квадратов попарных расстояний внутри класса
        d2 = h2 + h2.T - 2.0 * (h @ h.T)

        # Исключаем расстояние до самой себя
        np.fill_diagonal(d2, np.inf)

        # Находим kk ближайших соседей
        knn = np.partition(d2, kk - 1, axis=1)[:, :kk]

        # Среднее расстояние до ближайших соседей внутри класса
        out[m] = np.mean(np.sqrt(np.maximum(knn, 0.0)), axis=1)

    return out

def rank_score(x):
    """
    Преобразует массив значений в ранги.

    Наименьший элемент получает ранг 0,
    следующий - 1, и так далее.
```

```
    Это удобно, если потом нужно объединять
    несколько score разного масштаба.
    """
    # Индексы элементов в порядке возрастания значений x
    order = np.argsort(x)

    # Массив для рангов
    r = np.empty_like(order, dtype=np.float64)

    # Записываем для каждого элемента его позицию в отсортированном порядке
    r[order] = np.arange(len(x), dtype=np.float64)
    return r
```

[5]:
```
# Строим outlier-score на тестовых эмбеддингах по ансамблю рангов
# из трёх метрик: robust Mahalanobis + global kNN + class kNN.

# Робастное расстояние Махаланобиса внутри предсказанного класса:
# показывает, насколько объект нетипичен относительно распределения своего
класса.
s_robust = score_robust_mahalanobis(emb_test, pred_test, lam=0.15,
trim_frac=0.10, iters=2)

# Глобальный kNN-score:
# среднее расстояние до ближайших соседей во всём наборе.
# Большие значения соответствуют более изолированным точкам.
s_gknn = score_global_knn(emb_test, k=10)

# Class-wise kNN-score:
# среднее расстояние до ближайших соседей только внутри своего предсказанного
класса.
# Помогает находить точки, которые странно выглядят именно внутри класса.
s_cknn = score_class_knn(emb_test, pred_test, k=8)

# Объединяем три score в один итоговый показатель подозрительности.
# Перед объединением переводим каждый score в ранги,
# чтобы разные шкалы значений не мешали друг другу.
# Здесь robust Mahalanobis имеет наибольший вес,
# global kNN - средний, class kNN - меньший дополнительный вклад.
final_score = (
    2.0 * rank_score(s_robust)
    + 1.5 * rank_score(s_gknn)
    + 0.5 * rank_score(s_cknn)
)

# Выбираем K объектов с наибольшим итоговым score
# как наиболее вероятные выбросы.
topk = np.argsort(-final_score)[:K]

# Формируем бинарный вектор ответов:
# 1 - объект считаем выбросом, 0 - обычным объектом.
```

```
is_outlier = np.zeros(n_test, dtype=np.int64)
is_outlier[topk] = 1

# Собираем файл для отправки:
# для каждого id указываем предсказание is_outlier.
submission = pd.DataFrame({
    "id": np.arange(n_test, dtype=np.int64),
    "is_outlier": is_outlier,
})

# Сохраняем submission в CSV без индекса DataFrame.
submission.to_csv(SUBMISSION_PATH, index=False)

# Выводим служебную информацию:
# куда сохранён файл и сколько объектов помечено как выбросы.
print("Saved:", SUBMISSION_PATH)
print("Predicted outliers:", int(is_outlier.sum()))

# Показываем первые строки submission-таблицы.
submission.head()
```

```
Saved: submission.csv
Predicted outliers: 1000
```

[5]:

	id	is_outlier
0	0	0
1	1	0
2	2	0
3	3	0
4	4	0

Проверим решение: ячейка ниже вычисляет скор на public и private частях датасета.

[6]:

```
#!/usr/bin/env python3
"""
Validate submission.csv against y_test.csv and compute hits@k metrics.

Expected columns:
  y_test.csv: id, is_outlier_true, Usage
  submission.csv: id, is_outlier
"""

from __future__ import annotations

import argparse
import json
from pathlib import Path
from typing import Dict, List

import pandas as pd

BASELINE_SOLUTION_SCORE_PUBLIC=113
```

```
BASELINE_SOLUTION_SCORE_PRIVATE=95
AUTHOR_SOLUTION_SCORE_PUBLIC=338
AUTHOR_SOLUTION_SCORE_PRIVATE=308


def _strip_jupyter_kernel_args(unknown: List[str]) -> List[str]:
    cleaned: List[str] = []
    i = 0
    while i < len(unknown):
        tok = unknown[i]
        if tok == "-f" and i + 1 < len(unknown) and unknown[i + 1].
 ↪endswith(".json"):
            i += 2
            continue
        cleaned.append(tok)
        i += 1
    return cleaned


def _validate_binary_column(col: pd.Series, name: str) -> pd.Series:
    numeric = pd.to_numeric(col, errors="coerce")
    bad = numeric.isna() | (~numeric.isin([0, 1]))
    if bad.any():
        first_bad_idx = int(col.index[bad][0])
        raise ValueError(
            f"Колонка '{name}' должна содержать только 0/1. "
            f"Первая некорректная строка: {first_bad_idx}"
        )
    return numeric.astype(int)


def _clip_score_0_100(value: float) -> float:
    return max(0.0, min(100.0, float(value)))


def _compute_hits_metrics(
    df: pd.DataFrame, include_score_0_100: bool = True
) -> Dict[str, float | int | bool]:
    k_true = int(df["is_outlier_true"].sum())
    k_pred = int(df["is_outlier"].sum())
    hits_at_k = int(((df["is_outlier_true"] == 1) & (df["is_outlier"] == 1)).
 ↪sum())
    if AUTHOR_SOLUTION_SCORE <= BASELINE_SOLUTION_SCORE:
        normalized_score_0_100 = 0.0
    else:
        normalized_score_0_100 = 100.0 * (
            (hits_at_k - BASELINE_SOLUTION_SCORE)
            / (AUTHOR_SOLUTION_SCORE - BASELINE_SOLUTION_SCORE)
        )
        normalized_score_0_100 = _clip_score_0_100(normalized_score_0_100)
```

```
    metrics: Dict[str, float | int | bool] = {
        "n_samples": int(len(df)),
        "k_true": k_true,
        "k_pred": k_pred,
        "k_match": bool(k_true == k_pred),
        "hits_at_k": hits_at_k,
    }
    if include_score_0_100:
        metrics["score_0_100"] = normalized_score_0_100
    return metrics


def validate_and_score_submission(ytest_path: Path, submission_path: Path) ->
Dict[str, object]:
    try:
        ytest = pd.read_csv(ytest_path)
    except Exception as exc:  # pragma: no cover
        raise ValueError(f"Ошибка чтения ytest.csv: {exc}") from exc

    try:
        submission = pd.read_csv(submission_path)
    except Exception as exc:  # pragma: no cover
        raise ValueError(f"Ошибка чтения submission.csv: {exc}") from exc

    if ytest.empty:
        raise ValueError("ytest.csv пустой")
    if submission.empty:
        raise ValueError("submission.csv пустой")

    required_ytest_cols = {"id", "is_outlier_true", "Usage"}
    required_submission_cols = {"id", "is_outlier"}

    missing_ytest_cols = required_ytest_cols - set(ytest.columns)
    if missing_ytest_cols:
        raise ValueError(f"В ytest.csv отсутствуют колонки:
{sorted(missing_ytest_cols)}")

    missing_submission_cols = required_submission_cols - set(submission.
 ↪columns)
    if missing_submission_cols:
        raise ValueError(
            f"В submission.csv отсутствуют колонки:
{sorted(missing_submission_cols)}"
        )

    ytest = ytest[["id", "is_outlier_true", "Usage"]].copy()
    submission = submission[["id", "is_outlier"]].copy()

    ytest["id"] = ytest["id"].astype(str).str.strip()
```

```
    ytest["Usage"] = ytest["Usage"].astype(str).str.strip().str.title()

    submission["id"] = submission["id"].astype(str).str.strip()

    if (ytest["id"] == "").any():
        raise ValueError("В ytest.csv есть пустые id")
    if (submission["id"] == "").any():
        raise ValueError("В submission.csv есть пустые id")

    invalid_usage = sorted(set(ytest["Usage"]) - {"Public", "Private"})
    if invalid_usage:
        raise ValueError(f"В ytest.csv недопустимые значения Usage:
{invalid_usage}")

    if ytest["id"].duplicated().any():
        duplicates = (
            ytest.loc[ytest["id"].duplicated(keep=False), "id"]
            .unique()
            .tolist()
        )
        suffix = " ..." if len(duplicates) > 10 else ""
        raise ValueError(
            f"В ytest.csv есть дубликаты id: {duplicates[:10]}{suffix} "
            f"(всего {len(duplicates)})"
        )

    if submission["id"].duplicated().any():
        duplicates = (
            submission.loc[submission["id"].duplicated(keep=False), "id"]
            .unique()
            .tolist()
        )
        suffix = " ..." if len(duplicates) > 10 else ""
        raise ValueError(
            f"В submission.csv есть дубликаты id: {duplicates[:10]}{suffix} "
            f"(всего {len(duplicates)})"
        )

    y_ids = set(ytest["id"])
    s_ids = set(submission["id"])

    missing_ids = y_ids - s_ids
    if missing_ids:
        miss = sorted(list(missing_ids))
        suffix = " ..." if len(miss) > 10 else ""
        raise ValueError(
            f"В submission.csv отсутствуют id: {miss[:10]}{suffix} "
            f"(всего {len(miss)})"
        )
```

```
    extra_ids = s_ids - y_ids
    if extra_ids:
        extra = sorted(list(extra_ids))
        suffix = " ..." if len(extra) > 10 else ""
        raise ValueError(
            f"В submission.csv есть лишние id: {extra[:10]}{suffix} "
            f"(всего {len(extra)})"
        )

    ytest["is_outlier_true"] =
_validate_binary_column(ytest["is_outlier_true"], "is_outlier_true")
    submission["is_outlier"] =
_validate_binary_column(submission["is_outlier"], "is_outlier")

    merged = ytest.merge(submission, on="id", how="left",
validate="one_to_one")

    if merged["is_outlier"].isna().any():
        raise ValueError("После merge есть NaN в предсказаниях")

    k_true_total = int(merged["is_outlier_true"].sum())
    k_pred_total = int(merged["is_outlier"].sum())
    if k_pred_total != k_true_total:
        raise ValueError(
            "В submission.csv должно быть ровно K единиц в колонке
is_outlier, "
            f"где K={k_true_total}. Сейчас: {k_pred_total}"
        )

    overall_metrics = _compute_hits_metrics(merged, include_score_0_100=True)
    public_metrics = _compute_hits_metrics(
        merged.loc[merged["Usage"] == "Public"], include_score_0_100=False
    )
    private_metrics = _compute_hits_metrics(
        merged.loc[merged["Usage"] == "Private"], include_score_0_100=False
    )
    overall_metrics["score_0_100"] =
_clip_score_0_100(overall_metrics["score_0_100"])

    return {
        **overall_metrics,
        "n_total": int(len(merged)),
        "n_public": int((merged["Usage"] == "Public").sum()),
        "n_private": int((merged["Usage"] == "Private").sum()),
        "public": public_metrics,
        "private": private_metrics,
    }


def main(argv: List[str] | None = None) -> None:
```

```
    parser = argparse.ArgumentParser(description="Проверка сабмита и подсчет
hits@k")
    parser.add_argument("--ytest", type=str, default="y_test.csv", help="Путь
к y_test.csv")
    parser.add_argument(
        "--submission",
        type=str,
        default="submission.csv",
        help="Путь к submission.csv",
    )
    parser.add_argument(
        "--save-json",
        type=str,
        default=None,
        help="Опциональный путь для сохранения метрик в JSON",
    )
    args, unknown = parser.parse_known_args(argv)
    unknown = _strip_jupyter_kernel_args(unknown)
    if unknown:
        parser.error(f"unrecognized arguments: {' '.join(unknown)}")

    ytest_path = Path(args.ytest)
    submission_path = Path(args.submission)

    if not ytest_path.exists():
        raise FileNotFoundError(f"файл ytest не найден: {ytest_path}")
    if not submission_path.exists():
        raise FileNotFoundError(f"файл submission не найден:
{submission_path}")

    metrics = validate_and_score_submission(ytest_path, submission_path)
    print(json.dumps(metrics, indent=2))

    if args.save_json is not None:
        out_path = Path(args.save_json)
        with out_path.open("w", encoding="utf-8") as file:
            json.dump(metrics, file, indent=2)
        print(f"Метрики сохранены в JSON: {out_path}")


if __name__ == "__main__":
    main()
```