


# ИТМО

## GaMAC: открытая библиотека для автоматического решения задачи кластеризации на GPU

Усов Иван, Кулин Никита, Муратов Симар  
[parallaxel@yandex.ru](mailto:parallaxel@yandex.ru), [kylin98@list.ru](mailto:kylin98@list.ru), [SYMuratov@itmo.ru](mailto:SYMuratov@itmo.ru)

08.10.2024

# Задача кластеризации



- Unsupervised разбиение набора данных на непересекающиеся подмножества
- Множество эвристических алгоритмов кластеризации
- Огромное пространство гиперпараметров
- Нет универсальной функции оценки качества разбиений

# Существующие реализации

## Для задачи кластеризации:

- Scikit-learn (<https://scikit-learn.org/stable/modules/clustering.html>)
- PyClustering (<https://pyclustering.github.io/docs/0.8.2/html/index.html>)
- Spark MLlib (<https://spark.apache.org/docs/latest/ml-clustering.html>)
- CuML (<https://docs.rapids.ai/api/cuml/stable/api/#clustering>)

## Для задач обучения с учителем:

- Auto-Sklearn (<https://automl.github.io/auto-sklearn/master/>)
- AutoWeka (<https://www.automl.org/automl-for-x/tabular-data/autoweka/>)
- LightAutoML (<https://github.com/sb-ai-lab/LightAutoML>)
- FEDOT (<https://github.com/aimclub/FEDOT>)

## Фичи Sparkling:

- Поддержка мультимодальных распределенных данных
- Автоматическая система настройки алгоритмов кластеризации

## Ограничения Sparkling:

- Страдает производительность на небольших наборах данных
- Сложная процедура развертывания и поддержки окружения
- Небольшой выбор алгоритмов кластеризации и мер качества


## Новые фишки в GaMAC:

- Буст производительности за счет реализаций на GPU
- Простое использование на обычной рабочей станции
- Разнообразные алгоритмы кластеризации и меры качества
- Пересмотр подхода к обработке мультимодальных данных
- Система мета-обучения для рекомендации мер качества
- Нормальный CI/CD


# Аналоги на GPU

	Кластеризация	Мультимодальность	Мета обучение	AutoML  
<b>GaMAC</b>	+	+	+	+
LAMA GPU	-	-	-	+
cuML	+	-	+	-
	Multi-node	SaaS	CI/CD to cloud	MLOps features
<b>GaMAC</b>	+	+	+	+
LAMA GPU	-	-	-	+
cuML	+	+	+	+

# Перевод на GPU



GaMAC GPU Dev



GaMAC sandbox

**Задача:** переводим картинки и текст в эмбединги для склейки с табличными данными



## Гипотезы:

- 1) Каждую модальность кодировать отдельными моделями
- 2) Contrastive image-text модели
- 3) Fusion модели (Image-text to text)

## Датасеты:

1. MSCOCO
2. EMNIST
3. CIFAR

## Эксперимент:

1. Получить эмбединги картинки и текста
2. Сделать кластеризацию на эмбедингах
3. Посчитать метрики по кластеризации

## Кандидаты:

1. E5 + ResNet50
2. E5 + Swin Transformer
3. CLIP-ViT-B
4. CLIP-ViT-L/14
5. Llama-3.2-11B-Vision (In Progress)

# Сведение мультимодальных данных к табличным ИТМО

dataset	method	silhouette	calinski harabasz	davies bouldin	normalized mutual info
EMNIST	clip_b	0.164941	960.231015	2.000735	0.838490
	baseline	0.083806	650.689334	2.633190	0.490402
	swin_e5	0.109977	650.949920	2.339482	0.580193
	clip_l	<b>0.289205</b>	<b>1934.123559</b>	<b>1.520208</b>	<b>0.983215</b>
CIFAR	clip_l	<b>0.317251</b>	<b>191.928211</b>	<b>1.474333</b>	<b>0.993279</b>
	clip_b	0.255371	163.843154	1.747091	0.984153
	baseline	0.031173	48.950943	3.452677	0.533847
	swin_e5	0.054847	41.406548	3.329345	0.804645
MSCOCO	clip_l	0.050994	106.564796	3.801835	-
	clip_b	0.063904	131.452354	3.271781	-
	baseline	<b>0.442548</b>	<b>431.290599</b>	3.677789	-
	swin_e5	0.348317	76.934665	<b>3.258689</b>	-



CLIP модели лучше работают по сравнению с отдельным кодированием

# Рекомендация меры качества

## Параметры обучения:

- 1000 двумерных представлений наборов данных
- 200-мерное мета-признаковое описание наборов данных
- $\approx 20$  внутренних мер качества
- $\approx 100$  ассессоров для визуальной оценки разбиений
- Построение полного порядка на 15 разбиениях
- Сравнение ранжирования ассессора с ранжированием по мере

# GaMAC

<https://github.com/parallaxel/GaMAC>



# Sparkling

<https://gitlab.com/rainifmo/sparkling>



**Спасибо  
за внимание!**

**ITMO** *re than a*  
**UNIVERSITY**