

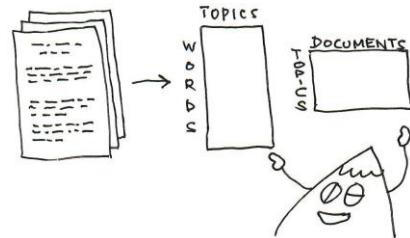


# Тематический анализ больших данных

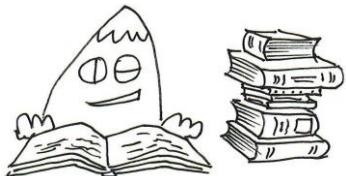
*BigARTM — библиотека с открытым кодом для тематического моделирования больших текстовых коллекций и массивов транзакционных данных.*

## Что такое тематическое моделирование?

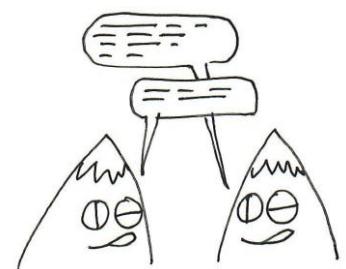
Это технология статистического анализа текстов для автоматического выявления тематики в больших коллекциях документов. Тематическая модель определяет, к каким темам относится каждый документ, и какими словами описывается каждая тема. Для этого не требуется никакой ручной разметки текстов, обучение модели происходит без учителя. Похоже на кластеризацию, но тематическая кластеризация является «мягкой» и допускает, чтобы документ относился к нескольким кластерам-темам. Тематическое моделирование не претендует на понимание смысла текста, однако оно способно отвечать на вопросы «о чём этот текст» или «какие общие темы имеет эта пара текстов».



## Для чего используется тематическое моделирование?



- для разведочного поиска в электронных библиотеках, это поиск по смыслу, а не по ключевым словам
- для обнаружения и отслеживания событий в новостных потоках
- для выявления тематических сообществ в социальных сетях
- для построения профилей интересов пользователей в рекомендательных системах
- для категоризации интентов собеседника и управления диалогом в системах разговорного интеллекта
- для поиска мотивов в нуклеотидных и аминокислотных последовательностях
- для аннотирования изображений
- для поиска изображений по тексту и текстов по изображениям
- для поиска аномального поведения объектов в видеопотоке
- для выявления паттернов поведения клиентов по транзакционным данным.

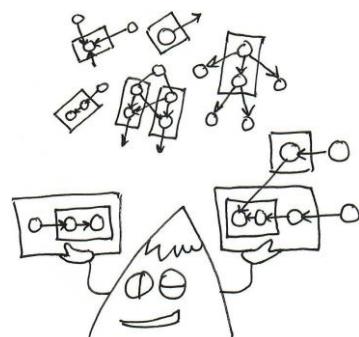


## Слышал про модель LDA. Что-то ещё бывает?

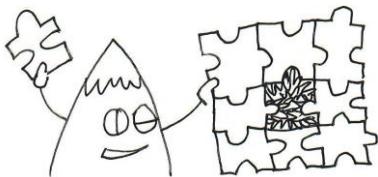
*LDA, латентное размещение Дирихле — самая известная и часто используемая тематическая модель. Проблема в том, что задача тематического моделирования имеет очень много (бесконечно много) решений, и LDA выдаёт одно из них, не предоставляя способа выбрать лучшее решение под конкретную задачу.*  
Модель LDA была изобретена в 2003 году. Её предшествовала более простая модель, называемая *вероятностным латентным семантическим анализом*, PLSA (1999).

Позже появились сотни специализированных моделей, но разработка каждой такой модели требовала заново производить математические выкладки и программную реализацию.

*Теория аддитивной регуляризации* (ARTM) позволяет собирать модели из готовых модулей в стиле конструктора LEGO. Она появилась в 2014 году, и тогда же стартовал проект BigARTM.



## Что такое регуляризация и почему она «аддитивная»?



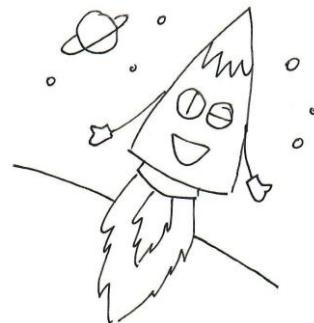
Регуляризация служит для задания желаемых свойств решения с помощью критериев-регуляризаторов. Они способны улучшать качество классификации текстов, учитывать дополнительные нетекстовые данные, повышать точность и полноту поиска, различность тем, разреженность решения, и т.д. Аддитивная регуляризация (ARTM) позволяет задавать несколько критериев одновременно. Например, чтобы тематизировать новостной поток, необходимо учитывать время документов, использовать верхние уровни готового рубрикатора, разделять темы на подтемы и создавать новые темы «на лету». ARTM позволяет складывать регуляризаторы от разных моделей, создавая комбинации моделей с заданными свойствами под конкретные приложения. Это приводит к модульной технологии тематического моделирования с высокой степенью повторного использования кода, которая и реализована в проекте BigARTM.

### Значит, BigARTM – это большой ARTM?

Не совсем. Приставка «big» в названии означает, что реализация модульной технологии ARTM позволяет эффективно обрабатывать большие данные. Что для этого сделано в BigARTM:

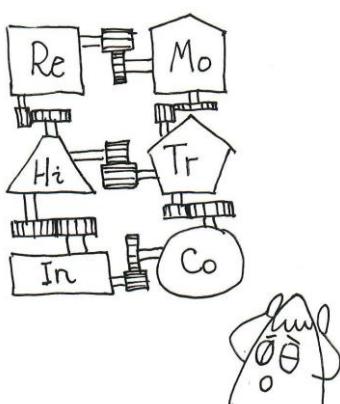
- распараллеливание на ядрах центрального процессора,
- пакетная обработка данных, не требующая единовременной загрузки больших данных в оперативную память,
- эффективный алгоритм с линейной вычислительной сложностью по объёму коллекции и по числу тем,
- хранение самых часто обновляемых данных – распределений слов в темах – целиком в оперативной памяти,
- реализация ядра библиотеки на языке C++ с соблюдением современных стандартов промышленного программирования.

Эксперименты показывают, что BigARTM в разы опережает по скорости вычислений алгоритмы, реализованные в популярных свободно доступных библиотеках Gensim и Vowpal Wabbit.



### Что ещё есть в BigARTM?

BigARTM реализует несколько механизмов, которые снимают многие ограничения простых моделей типа PLSA или LDA и расширяют спектр приложений тематического моделирования.

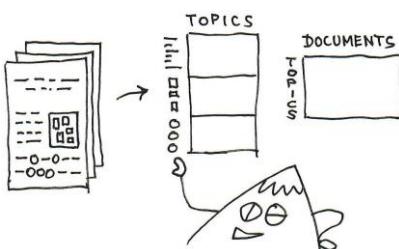
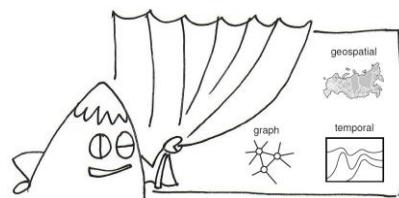


- *Regularization*. Регуляризаторы, которые можно комбинировать в любых сочетаниях.
- *Modalities*. Модальности, которыми можно описывать нетекстовые объекты внутри документов.
- *Hierarchy*. Тематические иерархии, в которых темы разделяются на подтемы.
- *Co-occurrence*. Использование данных о совместной встречаемости слов.
- *Intratext*. Внутритекстовые регуляризаторы, обрабатывающие текст как последовательность тематических векторов слов.
- *Transaction*. Тематизация транзакционных данных.

## Какие регуляризаторы уже встроены в BigARTM?

- Сглаживание заставляет распределение слов в теме (или распределение тем в документе) быть похожим на заданное распределение. Это аналог модели LDA.
- Разреживание обнуляет малые вероятности в распределении слов в теме (или в распределении тем в документе).
- Декоррелирование делает темы более различными.
- Отбор тем позволяет модели избавляться от мелких, неинформативных, дублирующих и зависимых тем.
- Когерентность группирует часто совместно встречающиеся слова в одних и тех же темах, улучшая интерпретируемость тем.

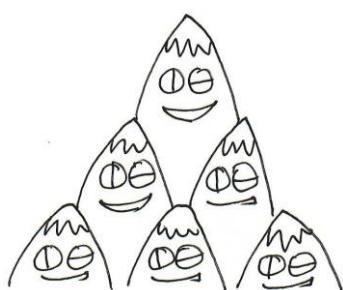
Полный список регуляризаторов можно найти в документации.



*Мультимодальные тематические модели* обрабатывают документы, содержащие не только слова, но и токены других модальностей. Это могут быть метаданные документа – авторы, время, источник, классы или рубрики, и т.д. Это могут быть также токены, находящиеся внутри текста – ссылки, теги, словосочетания, именованные сущности, объекты на изображениях, записи о действиях пользователей, и т.д. Модальности помогают строить темы с учётом дополнительной информации. С другой стороны, темы помогают выявлять семантику нетекстовых модальностей, предсказывать или рекомендовать значения пропущенных токенов.

## Можно ли языки считать модальностями?

Да, *мультиязычные тематические модели* реализуются как частный случай мультимодальных. Параллельные или сравнимые тексты на нескольких языках образуют один документ, и слова разных языков считаются в нём модальностями. Мультиязычные модели позволяют создавать системы кроссызычного и мультиязычного тематического поиска, в которых запрос даётся на одном языке, а ответ может быть получен на других языках. Например, по тексту патента на русском языке можно искать близкие патенты на английском. Если в своей коллекции нет параллельных текстов, а мультиязычный поиск нужен, то её можно дополнить параллельными текстами из Википедии.

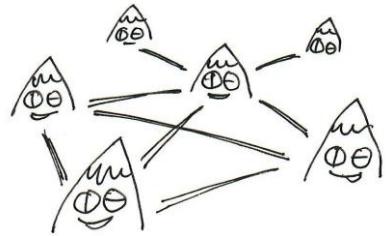


## Иерархии тоже реализуются через модальности?

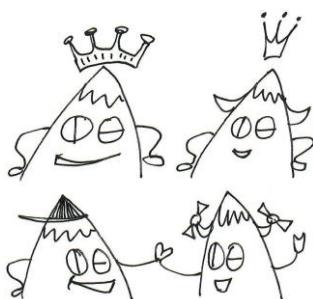
Это возможно, но более эффективным оказался другой подход. Вообще, *иерархические тематические модели* используются для автоматической рубрикации текстов. В BigARTM тематическая иерархия строится сверху вниз по уровням. Каждая дочерняя тема связывается с одной или несколькими родительскими. Каждая родительская тема может разделиться на несколько подтем, либо перейти на следующий уровень целиком. При построении каждого следующего уровня темы родительского уровня обрабатываются наряду с самой коллекцией как большие «псевдо-документы». Оказалось, что это работает лучше, чем использование родительских тем в качестве модальности.

## Зачем нужны модели совстречаемости слов?

Тематические модели совстречаемости строятся не по частотам слов в документах, а по частотам совместной встречаемости слов. Построить такую модель довольно просто: достаточно сформировать коллекцию псевдо-документов, в которой каждый документ соответствует слову и содержит все слова, встречающиеся с ним в одном контексте, например, в одном предложении. Этую модель называют также *тематической моделью сети слов* (WNTM). В чём принципиальное отличие, и чем это лучше? В основе данного подхода лежит *дистрибутивная гипотеза*: «смысл слова в языке определяется совокупностью всех слов, встречающихся в его локальных контекстах». Любая тематическая модель строит для каждого слова его векторное представление в виде распределения вероятностей тем. Но в моделях совстречаемости эти векторы точнее отражают смыслы слов и лучше решают задачи семантической близости слов и документов.



Кажется, это похоже на word2vec.  
Но ведь тематические модели – это другое?



В обоих подходах слова и документы получают *векторные представления* (embedding) фиксированной размерности, которые помогают решать различные задачи текстовой аналитики. В этом они похожи. Отличие в том, что тематический вектор является вероятностным распределением. Каждая координата в нём равна вероятности соответствующей темы, при этом каждая тема описывается характерными ключевыми словами или фразами. Поэтому тематические векторные представления оказываются *интерпретируемыми*, и это одно из ключевых преимуществ тематических моделей. Векторные представления семейства x2vec (word2vec, doc2vec, node2vec и другие) таким свойством не обладают. Ещё одно отличие в том, что тематическая модель находит общую тематическую структуру коллекции, а не только векторные представления слов и документов.

## Зачем нужны внутритекстовые регуляризаторы?

Внутритекстовые регуляризаторы позволяют учитывать порядок слов, синтаксические связи, деление текста по предложениям и абзацам и другую внутритекстовую информацию. Важным их применением является тематическая *сегментация текстов*. Благодаря механизму регуляризации, не только темы определяют сегментацию, но и сегментация может влиять на темы.

Внутритекстовая регуляризация позволяет отойти от гипотезы «мешка слов» – самого критикуемого допущения в тематическом моделировании. Есть и другие способы частичного учёта порядка слов, например, в моделях совстречаемости или при использовании модальности словосочетаний. Однако механизм внутритекстовых регуляризаторов – наиболее общий и гибкий. Он позволяет определять собственные новые регуляризаторы для выявления и анализа внутренней тематической структуры текста.



## Что такое транзакционные данные?



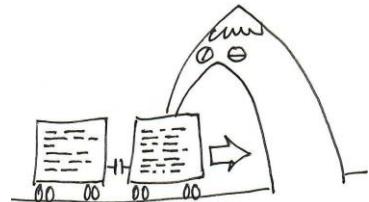
*Транзакциями* называются взаимодействия между объектами. В коллекции текстов транзакция – это вхождение слова в документ. Совстречаемость двух слов – это тоже транзакция. В более сложных приложениях во взаимодействиях может участвовать более двух объектов. Например, транзакция {u,b,p} в рекламной сети – «пользователь u кликнул баннер b, расположенный на странице p»; финансовая транзакция {b,s,g} – «покупатель b купил товар g у продавца s». Предложение в тексте – это пример транзакции, состоящей из произвольного числа слов. *Транзакционные* или *гиперграфовые* тематические модели основаны на предположении, что транзакция происходит, когда образующие её объекты имеют общие темы. Модель строит тематические векторные представления объектов любых модальностей, участвующих в транзакциях. Это наиболее общий вид тематических моделей, которые можно строить с использованием BigARTM.

## Как готовить данные для BigARTM?

BigARTM не предназначен для решения задач текстовой аналитики «под ключ». Пользователь сам определяет, какая необходима предобработка входных данных и постобработка выходных.

Перед обращением к BigARTM часто используются следующие методы предварительной обработки текстов:

- удаление слишком редких слов, разметки и прочей «грязи»,
- исправление опечаток,
- лемматизация или стемминг,
- удаление слишком частых слов (стоп-слов),
- автоматическое выделение терминов или коллокаций,
- выделение именованных сущностей,
- синтаксический парсинг (для некоторых Intraparaphrase-механизмов),
- вычисление частот совместной встречаемости слов.



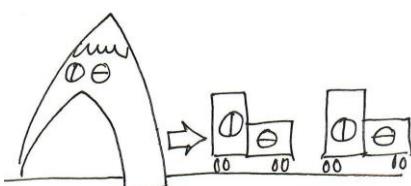
## Какие данные получаются на выходе, и как их использовать?

Основные результаты тематического моделирования находятся в двух матрицах:

- *матрица Фи «слова-темы»* содержит распределение вероятностей слов для каждой темы; они нужны, чтобы интерпретировать темы и показывать их пользователям;
- *матрица Тета «темы-документы»* содержит распределение вероятностей тем для каждого документа; они используются в качестве векторных представлений документов для поиска, классификации, визуализации документов.

Кроме того, есть побочные результаты моделирования:

- *распределения вероятностей тем для каждого слова в каждом документе*; они служат для анализа тематической структуры документа и поиска информации внутри документов;
- *метрики качества модели*, вычисляемые на каждой итерации; они используются для мониторинга итерационного процесса и выбора стратегии регуляризации.



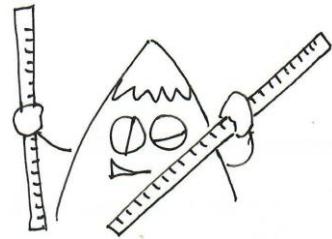
## Какие метрики качества вычисляются в BigARTM?

BigARTM располагает встроенными метриками качества (scores), и позволяет добавлять свои.

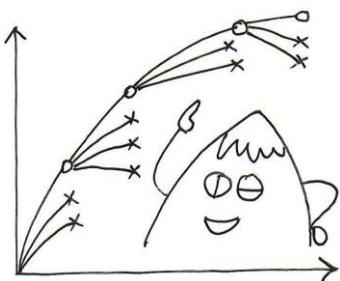
Некоторые метрики, доступные «из коробки»:

- **Перплексия.** Общепринятая мера качества моделей языка.
- **Разреженность.** Доля вероятностей, близких к нулю, в матрице Фи или Тета, соответственно.
- **Чистота и контрастность** оценивают различность тем.
- **Когерентность** наиболее вероятных слов темы. Является общепринятой мерой интерпретируемости темы.
- **Доля фоновых слов.** Если она велика, это может свидетельствовать о вырожденности модели.

Метрики качества пересчитываются на каждой итерации по каждому обработанному пакету данных.



## Что такое стратегия регуляризации и как её выбирать?



Регуляризаторы во многом подобны лекарствам: в малых дозах они бесполезны, в больших становятся ядом, а некоторые их сочетания приводят к плохо предсказуемым последствиям. Комбинирование регуляризаторов требует проведения экспериментов по подбору коэффициентов, управляющих силой их воздействия на модель.

*Стратегия регуляризации* определяется набором регуляризаторов, последовательностью их включения и правилами изменения коэффициентов в ходе итераций. Пока стратегию приходится подбирать вручную, ориентируясь на предшествующий опыт и рекомендации из примеров и статей. Чаще всего регуляризаторы включают по очереди, перебирая для каждого коэффициент регуляризации. Команда BigARTM уже работает над автоматической стратегией регуляризации, которая будет подбирать коэффициенты сама, по целевым значениям метрик качества.

## Чтобы разобраться в деталях, что почитать?

Документация по BigARTM есть на сайте [bigartm.org](http://bigartm.org).

Теория описана здесь (на русском языке):

[www.MachineLearning.ru/wiki/images/d/d5/Voron17survey-artm.pdf](http://www.MachineLearning.ru/wiki/images/d/d5/Voron17survey-artm.pdf)

и в статье (на английском):

[fruct.org/publications/fruct21/files/Koc.pdf](http://fruct.org/publications/fruct21/files/Koc.pdf).

