Онлайновые, параллельные и распределённые реализации алгоритмов тематического моделирования

Мурат Апишев
great-mel@yandex.ru

МФТИ (ГУ)

20 октября, 2016

Содержание лекции

Тематическое моделирование

Тематическое моделирование — приложение машинного обучения к статистическому анализу текстов.

Тема — терминология предметной области, набор терминов (униграм или $n-$грам) часто встречающихся вместе в документах.

Тематическая модель исследует скрытую тематическую структуру коллекции текстов:

- *тема* t — это вероятностное распределение $p(w|t)$ над терминами w
- *документ* d — это вероятностное распределение $p(t|d)$ над темами t

Приложения

Приложения:

- информационный поиск по длинным текстовым запросам;
- анализ данных социальных медиа (соцсети, блоги);
- мягкая кластеризация, визуализация данных;
- классификация текстов;
- суммаризация текстов.

Проблемы при работе с большими данными:

- слишком медленная обработка данных в однопоточном режиме;
- невозможность потоковой обработки;
- необходимость хранения в памяти больших массивов информации.

Необходимо использовать параллельные, распределённые и онлайновые варианты алгоритмов.

Задача тематического моделирования

Дано: W — словарь терминов (униграм или n–биграм),
D — коллекция текстовых документов $d \subset W$,
n_{dw} — счётчик частоты появления слова w в документе d.

Найти: модель $p(w|d) = \sum_{t \in T} \phi_{wt}\theta_{td}$ с параметрами $\underset{W \times T}{\Phi}$ и $\underset{T \times D}{\Theta}$:
$\phi_{wt} = p(w|t)$ — вероятности терминов w в каждой теме t,
$\theta_{td} = p(t|d)$ — вероятности тем t в каждом документе d.

Критерий максимизация логарифма правдоподобия:

$$\sum_{d \in D} \sum_{w \in d} n_{dw} \ln \sum_{t \in T} \phi_{wt}\theta_{td} \to \max_{\phi,\theta};$$

$$\phi_{wt} \geqslant 0; \quad \textstyle\sum_w \phi_{wt} = 1; \qquad \theta_{td} \geqslant 0; \quad \textstyle\sum_t \theta_{td} = 1.$$

PLSA и EM-алгоритм

Максимизация логарифма правдоподобия:

$$\sum_{d\in D}\sum_{w\in W} n_{dw} \ln \sum_{t} \phi_{wt}\theta_{td} \;\to\; \max_{\Phi,\Theta}$$

EM-алгоритм: метод простых итерация для решения системы уравнений

$$\text{E-шаг:}\quad p_{tdw} = \underset{t\in T}{\operatorname{norm}}\left(\phi_{wt}\theta_{td}\right)$$

$$\text{M-шаг:}\quad \begin{cases} \phi_{wt} = \underset{w\in W}{\operatorname{norm}}\left(n_{wt}\right), \quad n_{wt} = \sum\limits_{d\in D} n_{dw}p_{tdw} \\ \theta_{td} = \underset{t\in T}{\operatorname{norm}}\left(n_{td}\right), \quad n_{td} = \sum\limits_{w\in d} n_{dw}p_{tdw} \end{cases}$$

где $\underset{i\in I}{\operatorname{norm}}\, x_i = \dfrac{\max\{x_i,0\}}{\sum\limits_{j\in I}\max\{x_j,0\}}$

Методика изложения

- Существуют различные постановки задач тематического моделирования (PLSA, LDA, ARTM).
- В рамках каждой постановки существуют различные методы обучения (EM-алгоритм, сэмплирование и т.д.).
- Дальше в лекции будут рассматриваться реализации различных моделей и подходов.

Для единообразия будет использоваться нотация PLSA (и его обобщения — ARTM), технически верно описывающая реализованный алгоритм [1].

[1] даже если авторы алгоритма работали с байесовской моделью LDA

Самое главное

Базовая операция — обработка одного документа: `ProcessDocument`.

- Принимает на вход текущие счётчики n_{wt} (может и n_{td}, если они хранятся, иначе можно использовать случайные θ_d) и документ d.
- Возвращает инкременты $\tilde{n}_{wt}$ (может и итоговые векторы θ_d, если они вычисляются и нужны)

Внутри могут быть разные реализации: сэмплирование Гиббса, итерации EM-алгоритма.

Любой процесс распараллеливания концептуально состоит из двух этапов:

1. Параллельный многократный запуск операций `ProcessDocument`.
2. Агрегирование всех инкрементов $\tilde{n}_{wt}$ и их прибавление, возможно, с некоторым весом, к исходным n_{wt}.

Процесс повторяется итеративно до сходимости.

Метрика качества

Вопрос: сходится до сходимости чего?

Методов оценивания качества тематического моделирования много, они разнообразны и специфичны для разных задач.

Одна из универсальных величин, характеризующих степень сходимости модели с заданным словарём W — *перплексия*:

$$\mathscr{P}(D) = \exp\left(-\frac{1}{n}\sum_{d\in D}\sum_{w\in d} n_{dw} \ln \sum_{t\in T} \phi_{wt}\theta_{td}\right), \quad n = \sum_d n_d.$$

Она построена на основе логарифма правдоподобия и характеризует степень качества описания коллекции моделью. Чем ниже — тем лучше.

AD-LDA

- Алгоритм Approximate Distributed LDA (AD-LDA) был предложен в «D. Newman, A. Asuncion, P. Smyth, and M. Welling — Distributed algorithms for topic models».
- Основан на коллапсированной схеме Гиббса.
- Распараллеливается по ядрам, т.е. даже в рамках машины используется не многопоточная, а многопроцессорная архитектура.

Описание:

- Коллекция D распределяется по P. Документы распределяются случайным образом, без предварительной кластеризации.
- Информация о словах каждого документа и счётчики n_{td} также распределены (обозначим последние n_{tdp}).
- Каждый процессор имеет свою локальную *полную* копию n_{wtp} глобальных счётчиков n_{wt}.

Алгоритм

1. На потоки (*сэмплеры*) загружается по частям коллекция и копируются счётчики n_{wt}.
2. Каждый сэмплер производит обработку своих данных, вызывая `ProcessDocument` для каждого документа. Аккумулируются инкременты $\tilde{n}_{wtp}$.
3. Обновляются локальные счётчики n_{tdp}.
4. Общий шаг синхронизации для обновления глобальных n_{wt}.
5. Новая n_{wt} копируется на процессоры и начинается следующая итерация обработки.

Эксперименты

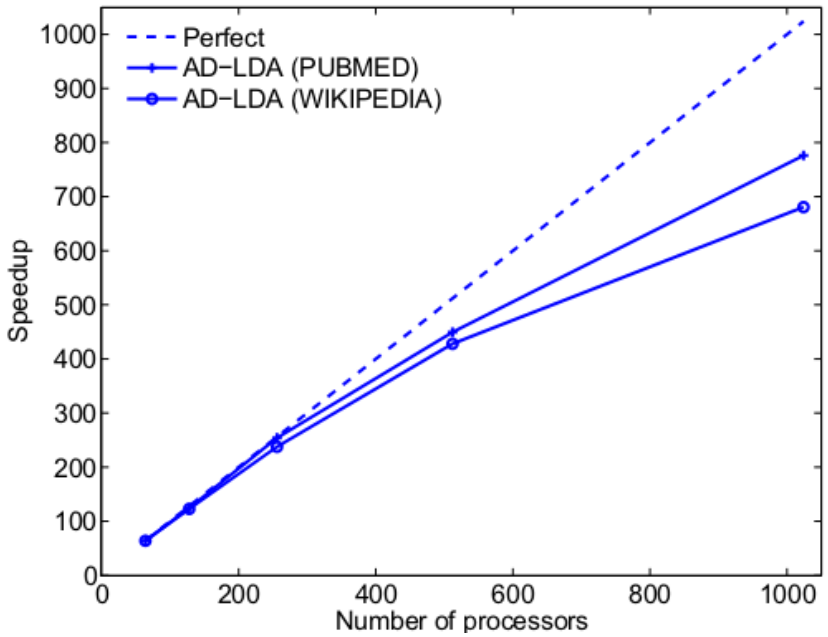

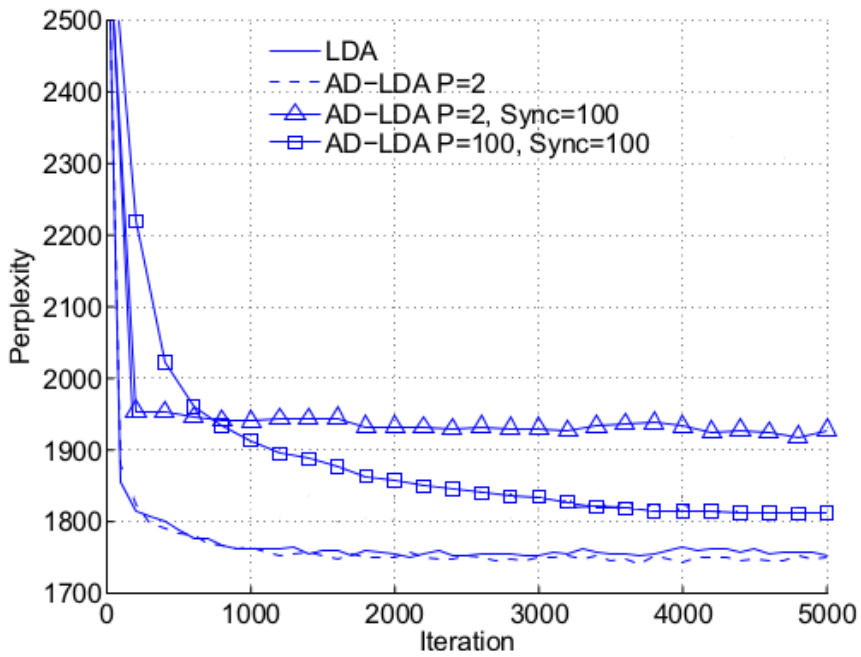

Выводы

AD-LDA имеет ряд серьёзных недостатков:

- Необходимость частых синхронизаций.
- Из-за синхронизации скорость определяется самым медленным процессором.
- Во время итераций сеть простаивает, а во время синхронизаций — перегружена.
- Большое потребление памяти — копия глобальных счётчиков n_{wt} хранится на каждом ядре.

Y!LDA

- Y!LDA был предложен в «A. Smola and S. Narayanamurthy — An architecture for parallel topic models,».
- Он так же основан на коллапсированной схеме Гиббса.
- Производит двухуровневую обработку:
  1. многопоточную в рамках одного нода;
  2. многопроцессорную в рамках кластера, в соответствии с т.н. *архитектурой классной доски*.

Схема многопоточного параллелизма

- На каждом ноде создаётся несколько потоков-сэмплеров.
- И один поток, задача которого — сливать полученные от сэмплеров обновления $\tilde{n}_{wt}$ в глобальную n_{wt}.
- Глобальное (в рамках нода) состояние n_{wtp} является общим для всех ядер нода.

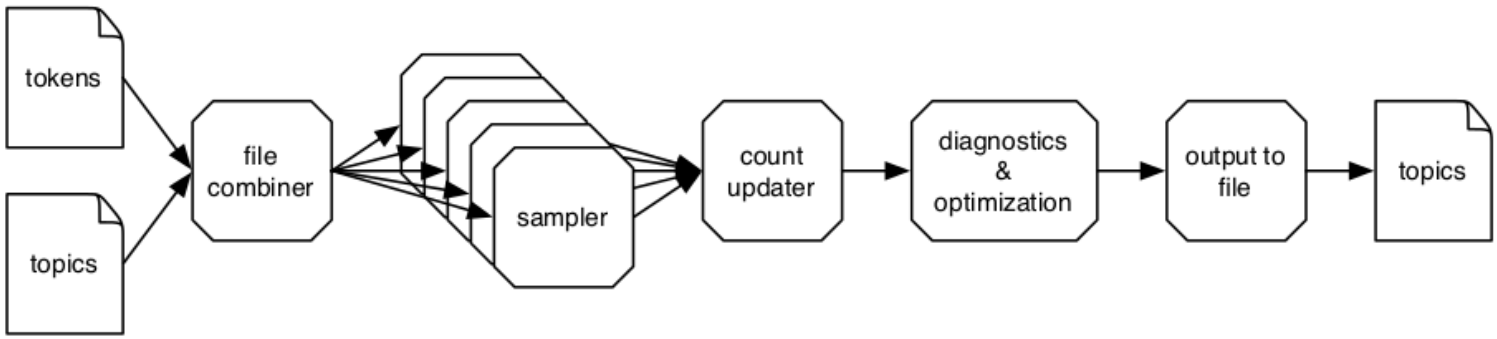

Описание вычислений на кластере

Проблема: синхронизация глобальной (в рамках кластера) матрицы n_{wt} между всеми нодами-обработчиками.

Архитектура классной доски:

- глобальная матрица счётчиков n_{wt} хранится в единственном экземпляре;
- она является общей для всех нодов;
- её обновление производится сэмплерами асинхронно по одному слову w за один раз.

Схема обновлений n_{wt}

---

1 Инициализировать $n_{wt} = n_{wtp} = n_{wtp}^{old}$, для всех нодов p;
2 **repeat**
3 | Заблокировать глобально n_{wt} для некоторого слова;
4 | Заблокировать локально n_{wtp} для данного слова;
5 | Обновить глобальное состояние: $n_{wt} := n_{wt} + (n_{wtp} - n_{wtp}^{old})$;
6 | Обновить локальное состояние: $n_{wtp}^{old} = n_{wtp} = n_{wt}$;
7 | Разблокировать n_{wtp};
8 | Разблокировать n_{wt};
9 **until** производится сэмплирование;

- n_{wt} — глобальное состояние.
- n_{wtp} — текущее локальное состояние.
- n_{wtp}^{old} — копия локального состояния на момент последней синхронизации с n_{wt}.

Технические детали реализации

- Все данные внутри программы реализуются и передаются с помощью технологии Google protocol buffers. Она позволяет описывать структуры данных на псевдо-языке, компилировать его в код на C++/Python/Java, сериализовывать/десериализовывать эти структуры.
- Для хранения глобального n_{wt} используется `memcached` — сервис, реализующий в оперативной памяти хранилище на основе хеш-таблицы.
- Алгоритм реализован на кластере рабочих станций с сервером и на Hadoop-кластере с машинами аналогичной мощности.

Достоинства Y!LDA

Таким образом, Y!LDA решает описанные выше проблемы AD-LDA:

- Отсутствие выделенного шага синхронизации позволяет более быстрым сэмплерам не ждать медленных.
- Сеть равномерно загружена всё время работы.
- Количество памяти, используемой для хранения копий глобальных счётчиков n_{wt} определяется не числом ядер в кластере, а числом нодов.

Но одна проблема есть:
выделенный поток (потоки) слияния могут стать узким местом алгоритма, и в рамках нода, и в рамках кластера.

Mr. LDA

- Реализация Mr. LDA описана в «K. Zhai, J. Boyd-Graber, N. Asadi, M. Alkhouja — Mr. LDA: A Flexible Large Scale Topic Modeling Package using Variational Inference in MapReduce».
- Алгоритм основан на вариационном выводе (вариационный EM-алгоритм).
- Обработка производится в рамках парадигмы MapReduce и реализована на Hadoop.

Описание схемы MapReduce

Описание этого алгоритма сделано в качестве примера обучения тематической модели с использованием MapReduce, оно не соответствует в деталях содержимому оригинальной статьи.

- На каждый документ коллекции создаётся mapper. Он производит вызов `ProcessDocument`.
- На каждую тему создается reducer. Он занимается слиянием полученных инкрементов n_{wt}.
- Третий компонент — driver — присутствует в системе в единственном экземпляре, управляет всем процессом обучения и вычисляет перплексию.
- Глобальные параметры n_{wt} хранятся в специальной, доступной только для чтения и общей для всех mapper-ов памяти, называемой *распределённым кэшем*.

ZenLDA

- Реализация ZenLDA описана в «B. Zhao, H. Zhou, G. Li, Y. Huang — ZenLDA: An Efficient and Scalable Topic Model Training System on Distributed Data-Parallel Platform».
- Алгоритм основан на коллапсированной схеме Гиббса.
- Работа выполнена на фреймворке Spark.
- Основная идея — в хранении данных модели в виде графа.

ZenLDA: граф модели

- Три типа вершин: слова, документы и вершины n_t нормировочных констант.
- Каждая вершина-слово соединена ребром со всеми вершинами документами, в которых она встречается хоть раз.
- Каждому слову приписана строка матрицы n_{wt}, каждому документу — его n_{td}.
- Текущее присваивание тем слов документа Z_{dw} приписано ребру $w - d$.

ZenLDA: схема обработки

- Граф некоторым образом разбивается на части.
- Части передаются нодам-обработчикам.
- Обработчики выполняют итерации сэмплирования.
- Результаты отправляются на мастер.
- Мастер производит обновление счётчиков n_{wt} и n_t.

ZenLDA: схема обработки

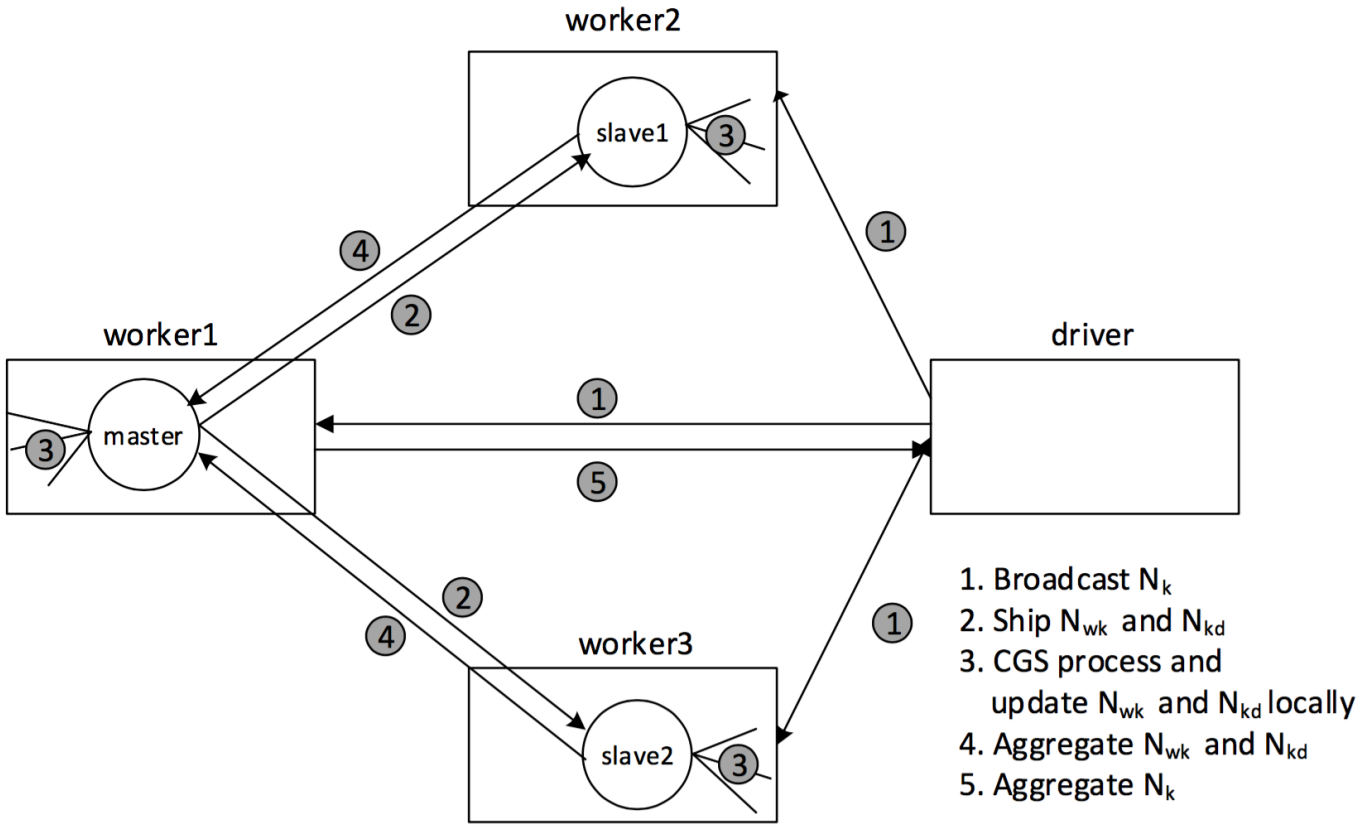

ZenLDA: эксперименты

Данные:

Название	Словарь	Документы	Длина
BingWebC1Mon	302.098	16.422.424	3.150.765.984
VW.BingWebC320G	4.780.428	406.038.204	54.059.670.863

Количество тем в экспериментах: 1k, 10k, 100k.

Производилось сравнение с прочими распределёнными фреймворками (например, LightLDA).

ZenLDA показал в 2-6 раз более высокую производительность.

ZenLDA: эксперименты

Зависимость скорости обработки одной итерации от числа тем при фиксированном датасете (**разреженность!**):

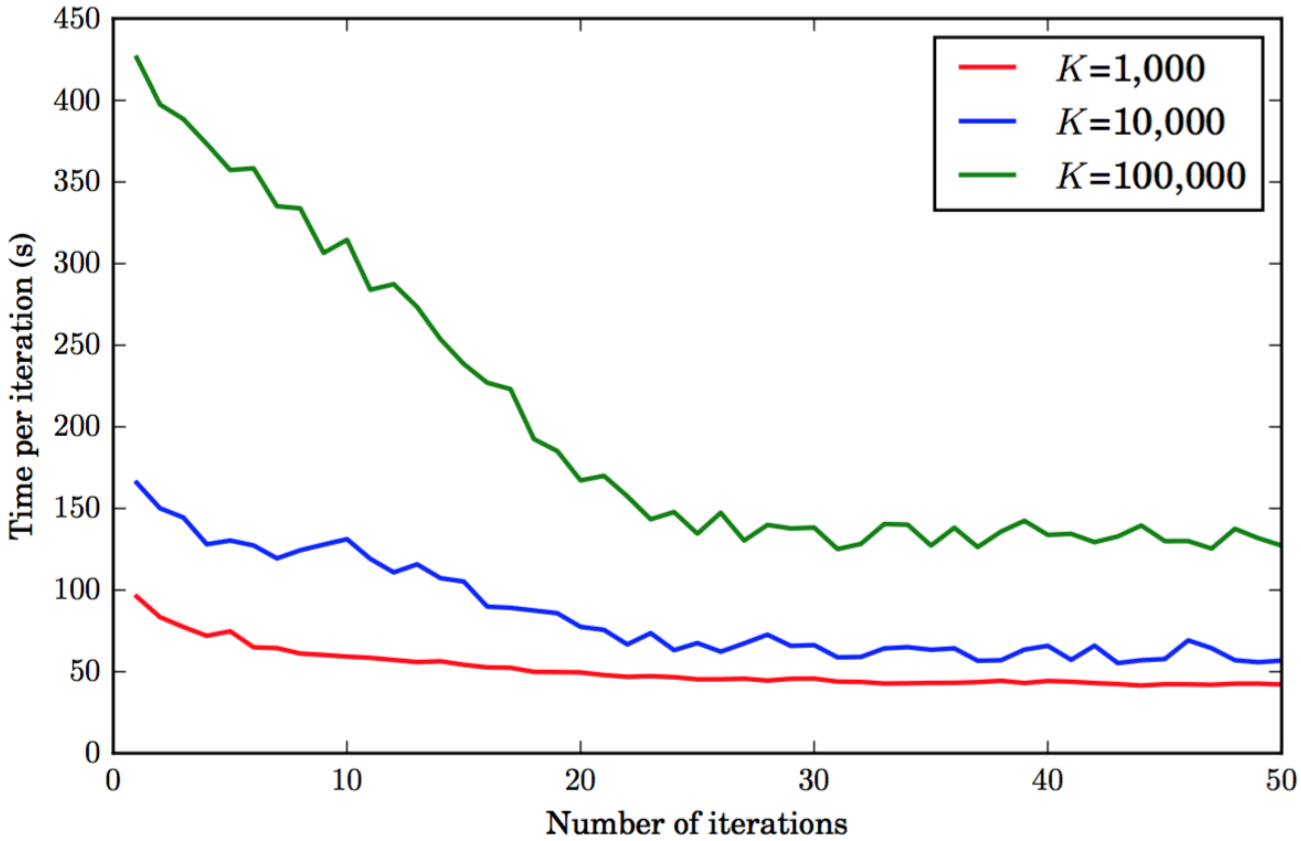

Оффлайновые и онлайновые EM-алгоритмы

Все дальнейшие реализации основаны на EM-алгоритме.

Оффлайновый EM-алгоритм:

1. Многократное итерирование по коллекции.
2. Однократная обработка документа.
3. Φ (n_{wt}) обновляется в конце каждого прохода по коллекции.
4. Применяется при обработке небольших коллекций.

Онлайновый EM-алгоритм:

1. Однократный проход по коллекции.
2. Многократная обработка одного документа.
3. Φ (n_{wt}) обновляется через определённое число обработанных документов.
4. Применяется при обработке больших коллекций в потоковом режиме.

FOEM-LDA

- Реализация FOEM-LDA описана в «J. Zeng, Z. Liu, X. Cao — Fast Online EM for Big Topic Modeling».
- В основе онлайновый однопоточный EM-алгоритм.
- Медленная реализация, но есть интересные особенности.
- Обработали Pubmed с 1000 тем за 29 часов с использованием **2 ГБ RAM**.

FOEM-LDA

- **Проблема:** модель (Φ-подобная матрица) может стать слишком большой и не помещаться в память.
- **Решение:** хранить матрицу на диске, загрузить строки для самых частых слов, прочие подгружать при необходимости и потом удалять.

FOEM-LDA

- **Проблема:** обработка слишком большого количества тем и слов.
- **Решение:** обрабатывать только важные слова и темы.

  Важность темы определяется как степень недообученности:

$$n_{dw}|p_{tdw} - p_{tdw}^{old}|$$

  Эта величина суммируется по всем документам *(пересчитывается в конце внутреннего цикла по темам)*.

  Важность слова определяется той же величиной, дополнительно просуммированной по темам *(пересчитывается в конце внешнего цикла по словам)*.

Online LDA: VW.LDA

Алгоритм Online LDA был предложен в «M. D. Hoffman, D. M. Blei, F. Bach — Online Learning for Latent Dirichlet Allocation», в его основе лежит вариационный EM-алгоритм.

Vowpal Wabbit LDA:

- Онлайновый.
- Не параллельный.
- Реализован на C++ без STL и сторонних библиотек.
- Относительно эффективный инструмент для моделирования больших коллекций в потоковом режиме.
- Может использоваться на кластере.

Online LDA: Gensim

- Онлайновый.
- Параллельный (однопоточная реализация LdaModel, многопоточная — LdaMulticore). Архитектурно похож на Y!LDA. Многопоточный параллелизм реализован не очень эффективно, плохая масштабируемость.
- Распределённый (неэффективная реализация).
- Реализован на Python.
- Удобный инструмент для моделирования небольших коллекций.

ARTM: ещё раз о задаче тематического моделирования

Дано: W — словарь терминов (униграм или n–биграм),
D — коллекция текстовых документов $d \subset W$,
n_{dw} — счётчик частоты появления слова w в документе d.

Найти: модель $p(w|d) = \sum_{t \in T} \phi_{wt}\theta_{td}$ с параметрами $\underset{W \times T}{\Phi}$ и $\underset{T \times D}{\Theta}$:
$\phi_{wt} = p(w|t)$ — вероятности терминов w в каждой теме t,
$\theta_{td} = p(t|d)$ — вероятности тем t в каждом документе d.

Критерий максимизация логарифма правдоподобия:

$$\sum_{d \in D} \sum_{w \in d} n_{dw} \ln \sum_{t \in T} \phi_{wt}\theta_{td} \;\to\; \max_{\phi,\theta};$$

$$\phi_{wt} \geqslant 0; \quad \textstyle\sum_w \phi_{wt} = 1; \qquad \theta_{td} \geqslant 0; \quad \textstyle\sum_t \theta_{td} = 1.$$

Проблема: задача стохастического матричного разложения некорректно поставленная: $\Phi\Theta = (\Phi S)(S^{-1}\Theta) = \Phi'\Theta'$.

ARTM и регуляризованный EM-алгоритм

Максимизация логарифма правдоподобия с дополнительными аддитивными регуляризаторами R:

$$\sum_{d\in D}\sum_{w\in W} n_{dw} \ln \sum_t \phi_{wt}\theta_{td} + R(\Phi,\Theta) \to \max_{\Phi,\Theta}$$

EM-алгоритм: метод простых итераций для системы уравнений

$$\text{E-шаг:} \quad p_{tdw} = \underset{t\in T}{\text{norm}}\left(\phi_{wt}\theta_{td}\right)$$

$$\text{M-шаг:} \quad \begin{cases} \phi_{wt} = \underset{w\in W}{\text{norm}}\left(n_{wt} + \phi_{wt}\dfrac{\partial R}{\partial \phi_{wt}} \right), \quad n_{wt} = \sum\limits_{d\in D} n_{dw} p_{tdw} \\ \theta_{td} = \underset{t\in T}{\text{norm}}\left(n_{td} + \theta_{td}\dfrac{\partial R}{\partial \theta_{td}} \right), \quad n_{td} = \sum\limits_{w\in d} n_{dw} p_{tdw} \end{cases}$$

Примеры регуляризаторов

Многие байесовские модели могут быть интерпретированы в терминах ARTM.

Примеры регуляризаторов:

1. Сглаживание Φ / Θ (приводит к известной модели LDA)
2. Разреживание Φ / Θ
3. Декорреляция тем в Φ
4. Частичное обучение
5. Максимизация когерентности тем
6. Отбор тем
7. ...

Мультимодальная тематическая модель

Мультимодальная тематическая модель распределения тем на терминах $p(w|t)$, авторах $p(a|t)$, метках времени $p(y|t)$, изображениях $p(o|t)$, связанных документвх $p(d'|t)$, рекламных баннерах $p(b|t)$, пользователях $p(u|t)$, и объединяет все эти модальности в одно тематическую модель.

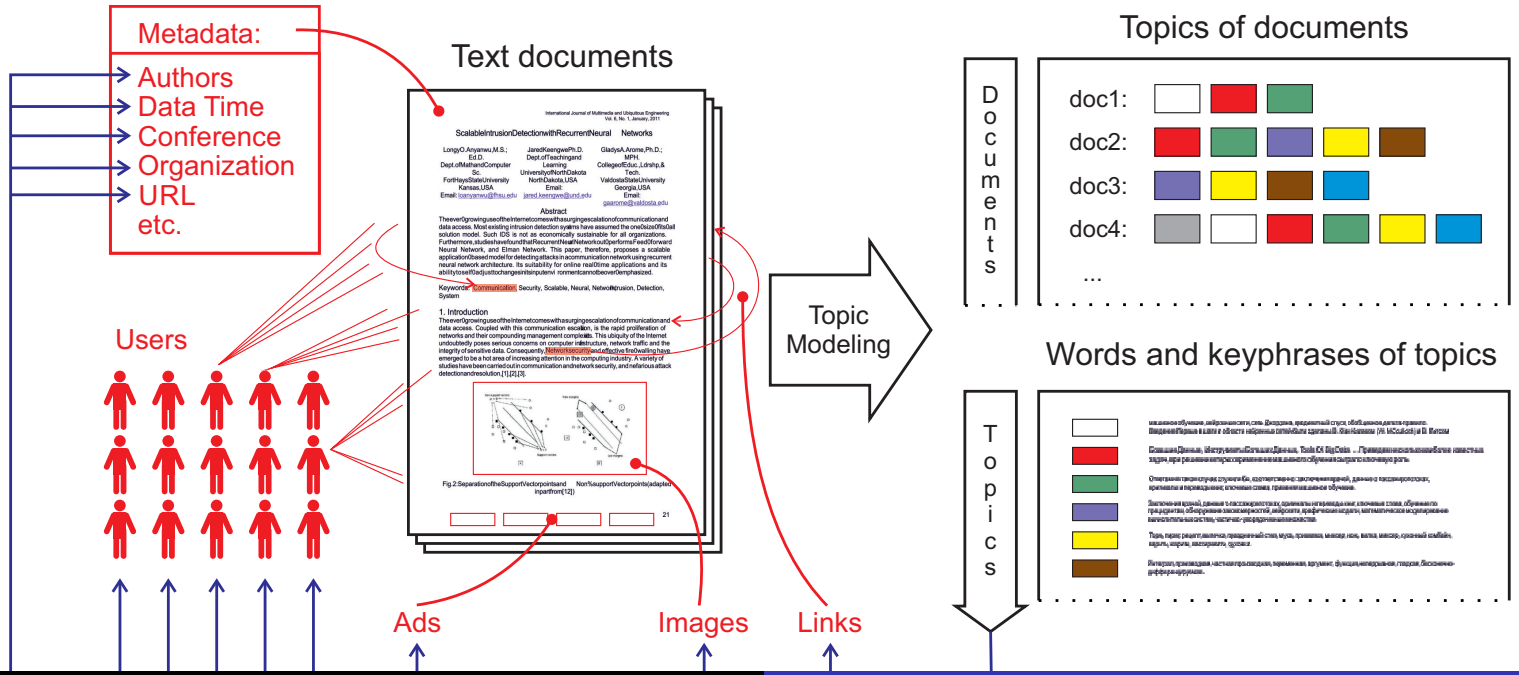

M-ARTM и мультимодальный регуляризованный EM-алгоритм

W^m — словарь терминов m-й модальности, $m \in M$,
$W = W^1 \sqcup W^m$ как объединение словарей всех модальностей.

Максимизация логарифма мультимодального правдоподобия с аддитивными регуляризаторами R:

$$\sum_{m\in M} \lambda_m \sum_{d\in D} \sum_{w\in W^m} n_{dw} \ln \sum_t \phi_{wt}\theta_{td} + R(\Phi,\Theta) \;\to\; \max_{\Phi,\Theta}$$

EM-алгоритм: метод простых итерация для системы уравнений

$$\text{E-шаг:} \quad p_{tdw} = \underset{t\in T}{\text{norm}}\left(\phi_{wt}\theta_{td}\right)$$

$$\text{M-шаг:} \quad \begin{cases} \phi_{wt} = \underset{w\in W^m}{\text{norm}}\left(n_{wt} + \phi_{wt}\frac{\partial R}{\partial \phi_{wt}} \right), \quad n_{wt} = \sum\limits_{d\in D} \lambda_{m(w)} n_{dw} p_{tdw} \\ \theta_{td} = \underset{t\in T}{\text{norm}}\left(n_{td} + \theta_{td}\frac{\partial R}{\partial \theta_{td}} \right), \quad n_{td} = \sum\limits_{w\in d} \lambda_{m(w)} n_{dw} p_{tdw} \end{cases}$$

Проект BigARTM

Особенности BigARTM:

- Быстрая[2] параллельная и онлайновая обработка данных;
- Поддержка мультимодальных регуляризованных тематических моделей;
- Встроенная расширяемая библиотека регуляризаторов и метрик качества;

Сообщество BigARTM:

- Открытый репозиторий `https://github.com/bigartm`
- Описание и документация `http://bigartm.org`

Лицензия BigARTM и программные особенности:

- Бесплатное коммерческое использование (BSD 3-Clause license)
- Кроссплатформенная — Windows, Linux, Mac OS X (32 bit, 64 bit)
- Программные API: command line, C++, Python

[2]Vorontsov K., Frei O., Apishev M., Romov P., Dudarenko M. BigARTM: Open Source Library for Regularized Multimodal Topic Modeling of Large Collections Analysis of Images, Social Networks and Texts. 2015

Операция ProcessDocument

Input: документ $d \in D$, матрица $\Phi = (\phi_{wt})$;
Output: матрица $(\tilde{n}_{wt})$, вектор θ_{td};

1 инициализировать $\theta_{td} := \frac{1}{|T|}$ для всех $t \in T$;
2 **repeat**
3 $\quad p_{tdw} := \underset{t \in T}{\text{norm}}\left(\phi_{wt}\theta_{td}\right)$ для всех $w \in d$ и $t \in T$;
4 $\quad \theta_{td} := \underset{t \in T}{\text{norm}}\left(\sum_{w \in d} n_{dw} p_{tdw} + \theta_{td}\frac{\partial R}{\partial \theta_{td}}\right)$ для всех $t \in T$;
5 **until** до сходимости θ_d;
6 $\tilde{n}_{wt} := n_{dw} p_{tdw}$ для всех $w \in d$ и $t \in T$;

Оффлайновый алгоритм: описание

Коллекция документов D разбивается на пакеты, называемые *батчами*.

Оффлайновый алгоритм производит сканирование коллекции, вызывая ProcessDocument для каждого документа $d \in D$ в коллекции.

Затем он агрегирует результирующие матрицы $(\tilde{n}_{wt})$ в финальную матрицу (n_{wt}) размера $|W| \times |T|$.

После каждого прохода по коллекции алгоритм пересчитывает матрицу Φ по формуле

$$\phi_{wt} = \underset{w \in W}{\text{norm}}\left(n_{wt} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}} \right), \quad n_{wt} = \sum_{d \in D} n_{dw} p_{tdw}$$

Оффлайновый алгоритм: листинг

Input: коллекция D;
Output: матрица $\Phi = (\phi_{wt})$;

1 инициализировать (ϕ_{wt});
2 создать батчи $D := D_1 \sqcup D_2 \sqcup \cdots \sqcup D_B$;
3 **repeat**
4 $\quad (n_{wt}) := \sum_{b=1,\ldots,B} \sum_{d \in D_b} \text{ProcessDocument}(d, \Phi)$;
5 $\quad (\phi_{wt}) := \underset{w \in W}{\text{norm}}\left(n_{wt} + \phi_{wt} \frac{\partial R}{\partial \phi_{wt}}\right)$;
6 **until** до сходимости (ϕ_{wt});

Оффлайновый алгоритм: обсуждение

Внешний цикл распараллеливается по потокам.

Внутри каждого пакета внутренний цикл по документам $d \in D_b$ производится в однопоточном режиме.

Значения θ_{td} появляются только в фунеции `ProcessDocument`

$\Rightarrow$

Эффективное использование памяти: реализация никогда не хранит в памяти целиком всю матрицу Θ.

Вместо этого значения θ_{td} пересчитываются при каждом проходе по коллекции.

Операция `ProcessDocument` может быть полезна как отдельная функция для поиска распределений θ_{td} новых документов, не участвовавших в обучении.

Оффлайновый алгоритм: диаграмма Гантта

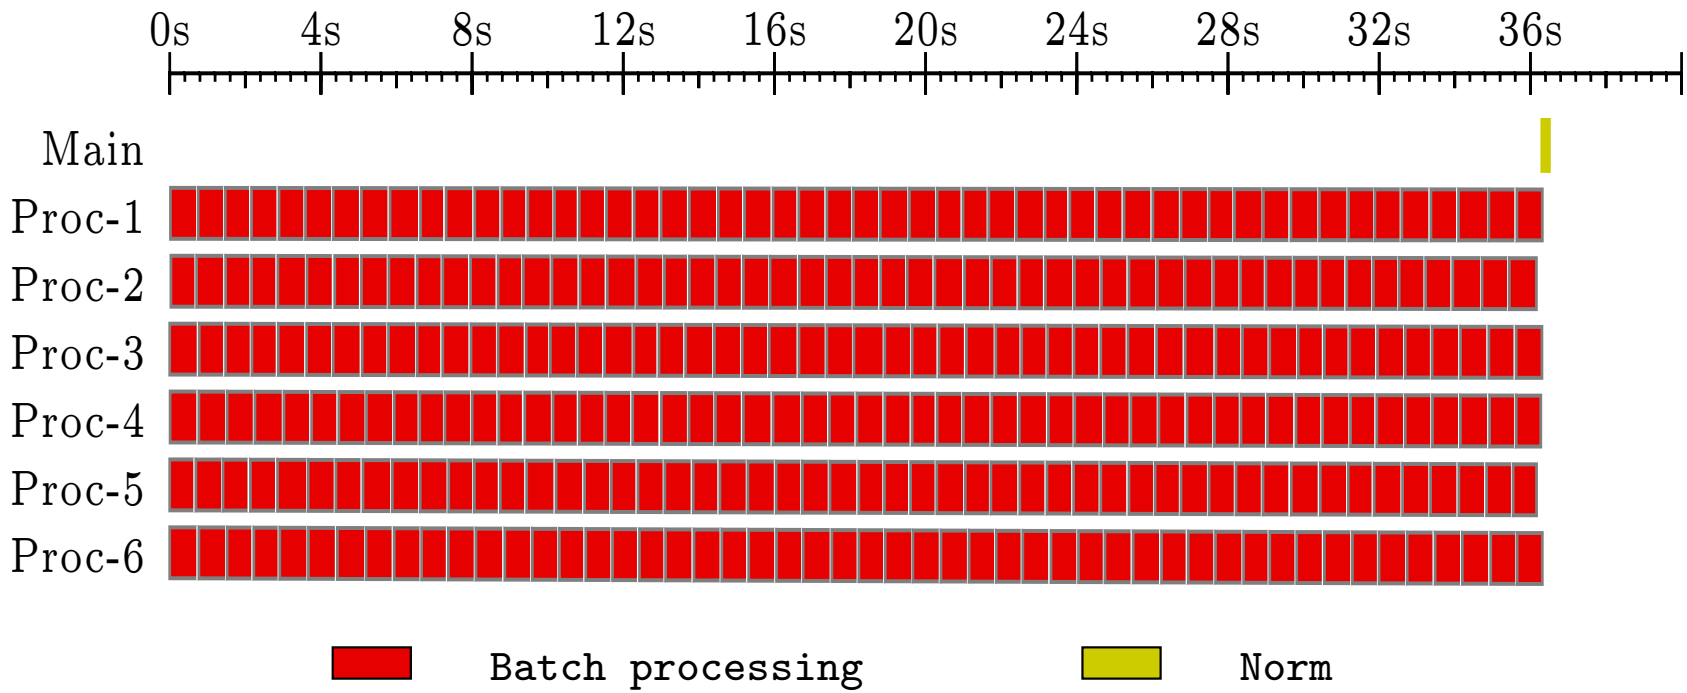

- Этот и последующие диаграммы Гантта создавались с помощью коллекции NYTimes: `https://archive.ics.uci.edu/ml/datasets/Bag+of+Words`
- Размер коллекции $\approx$ 300k документов, но алгоритмы запускались на подможествах размером от 70% до 100 % для достижения единого времени работы ($\approx$ 36 сек.)

Онлайновый алгоритм: описание

Алгоритм является обобщением алгоритма Online variational Bayes для модели LDA (на нём основаны Gensim и VW.LDA).

Онлайновый ARTM улучшает скорость сходимости оффлайнового алгоритма путём пересчёта матрицы Φ после каждых η батчей.

Введём элементарную операцию для упрощения нотации:

$$\text{ProcessBatches}(\{D_b\}, \Phi) = \sum_{D_b} \sum_{d \in D_b} \text{ProcessDocument}(d, \Phi)$$

Онлайновый алгоритм: листинг

Input: коллекция D, параметры η, τ_0, κ;
Output: матрица $\Phi = (\phi_{wt})$;

создать батчи $D := D_1 \sqcup D_2 \sqcup \cdots \sqcup D_B$;
инициализация (ϕ^0_{wt});
for all обновить $i = 1, \ldots, \lfloor B/\eta \rfloor$
    $(\tilde{n}^i_{wt}) := \text{ProcessBatches}(\{D_{\eta(i-1)+1}, \ldots, D_{\eta i}\}, \Phi^{i-1})$;
    $\rho_i := (\tau_0 + i)^{-\kappa}$;
    $(n^i_{wt}) := (1 - \rho_i) \cdot (n^{i-1}_{wt}) + \rho_i \cdot (\tilde{n}^i_{wt})$;
    $(\phi^i_{wt}) := \underset{w \in W}{\text{norm}}(n^i_{wt} + \phi^{i-1}_{wt} \frac{\partial R}{\partial \phi_{wt}})$;

Онлайновый алгоритм: обсуждение

Разбиение коллекции на батчи имеет важное значение — оно сказывается на итоговой модели.

Весовая формуладля новых счётчиков $\rho_i := (\tau_0 + i)^{-\kappa}$ была взята из Online LDA, это одна из возможных эвристик, не самая универсальная.

Типичные значения τ_0 лежат между 64 и 1024, κ — между 0.5 и 0.7.

Проблема: все рабочие потоки проставивают во время операций агрегации и нормализации, поскольку новая версия матрицы Φ, которая нужна для вывода, ещё не готова.

Онлайновый алгоритм: диаграмма Гантта

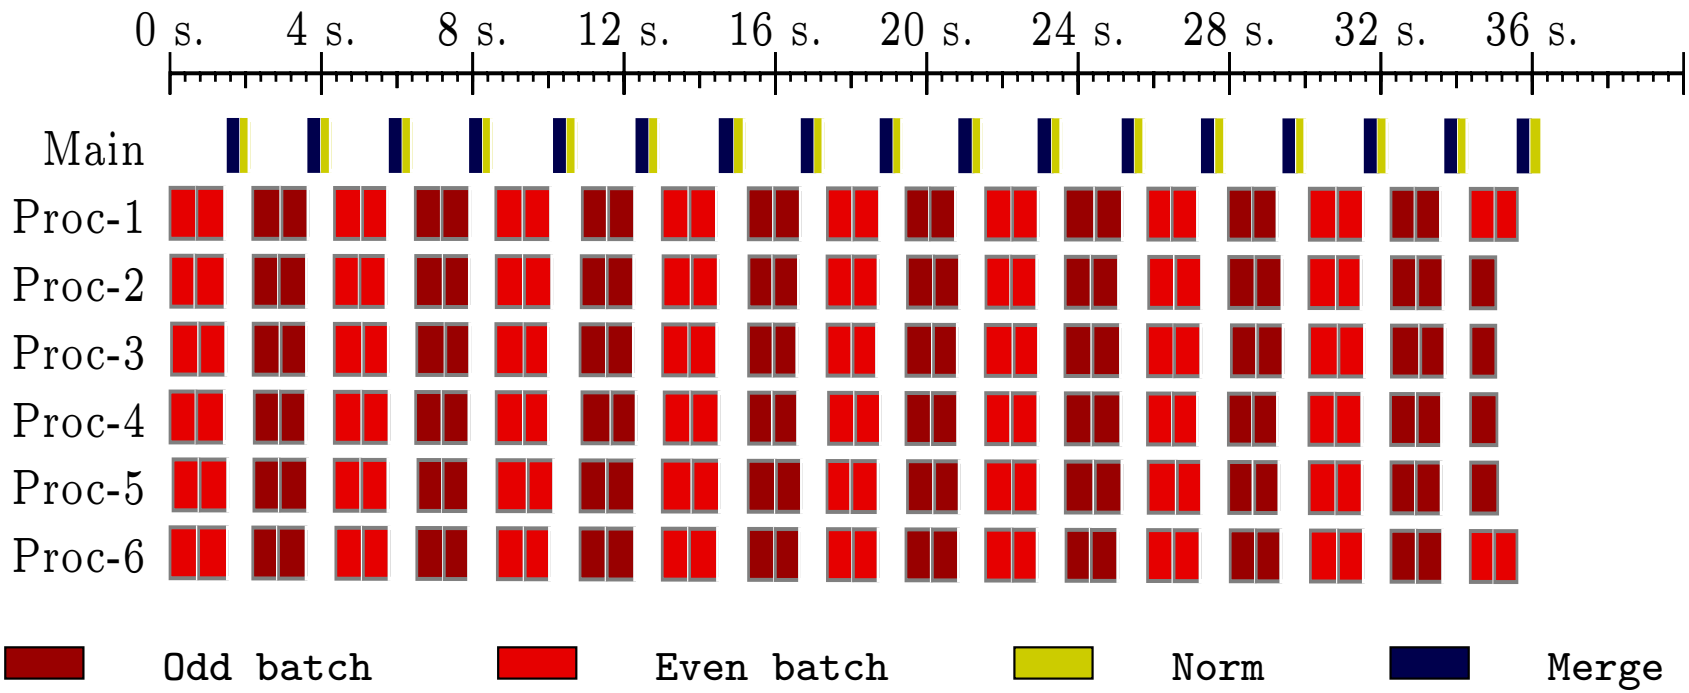

Асинхронный онлайновый алгоритм (Async): описание

- Есть поток `DataLoader`, который загружает батчи с диска в *очередь обработки* `Processor queue`.
- Каждый поток обработчик `Processor` извлекает из очереди по одному батчу и производит на нём итерации EM-алгоритма.
- После того, как `Processor` окончил обработку батча, он помещает инкременты $\tilde{n}_{wt}$ в *очередь слияния* `Merger queue` (если в ней есть место) и начинает обработку следующего батча.
- Когда число обновлений в очереди `Merger queue` становится равным параметру η, выделенный поток `Merger` производит обновление матрицы Φ.

Алгоритм Async: схема

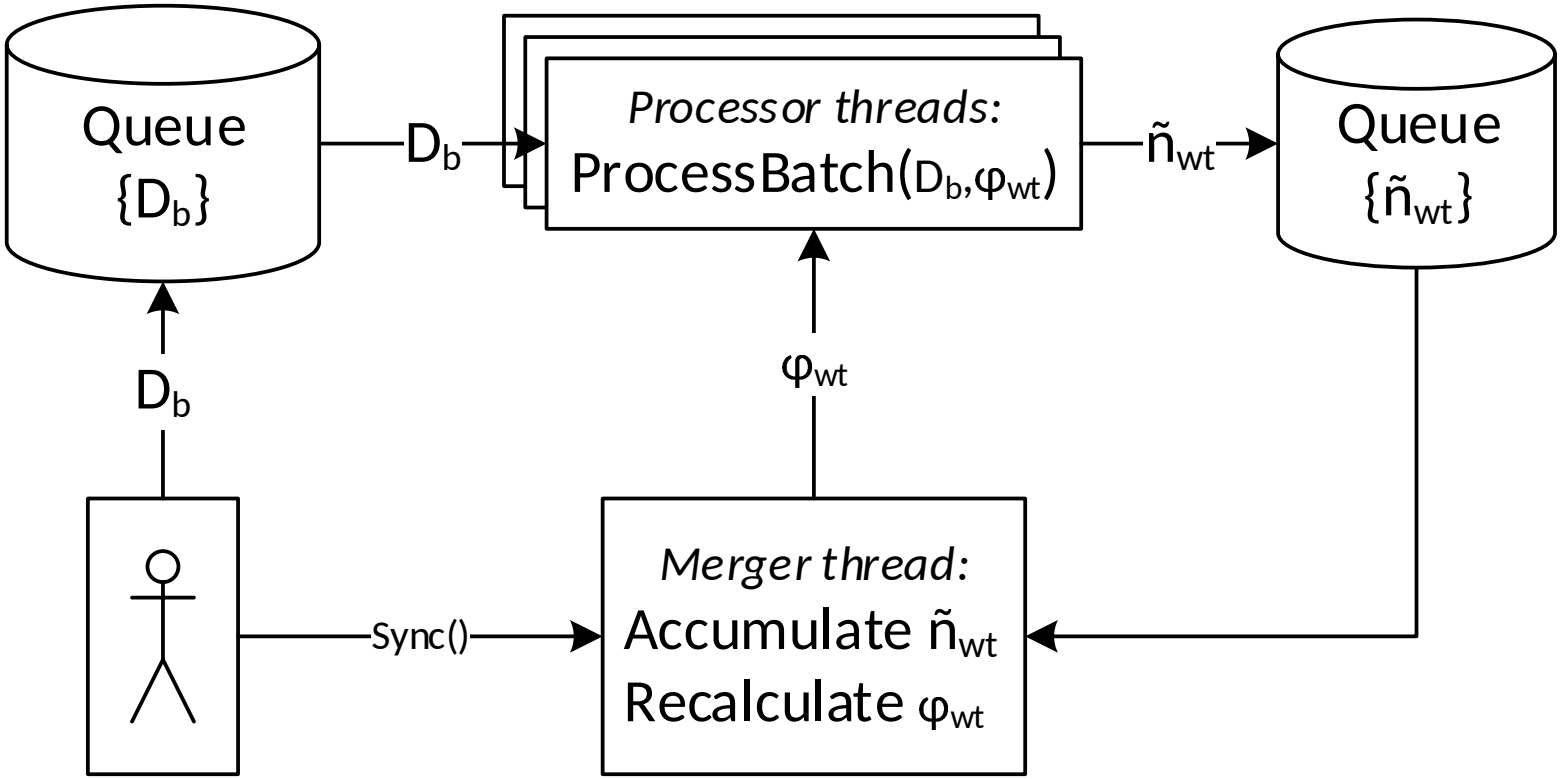

Алгоритм Async: достоинства

В нормальной ситуации Async совмещает все полезные качества предыдущих алгоритмов (т.е. хорошую сходимость и высокую степень загруженности потоков).

- 3.7M статей англ. Википедии, $|W|$=100k

Фреймворк	procs	обучение	вывод	перплексия
BigARTM	1	35 min	72 sec	4000
LdaModel	1	369 min	395 sec	4161
VW.LDA	1	73 min	120 sec	4108
BigARTM	4	9 min	20 sec	4061
LdaMulticore	4	60 min	222 sec	4111
BigARTM	8	**4.5 min**	**14 sec**	4304
LdaMulticore	8	57 min	224 sec	4455

- *procs* = число параллельных потоков
- *вывод* = время подсчёта распределений θ_d для теста в 100k док-в

Алгоритм Async: диаграмма Гантта в нормальной ситуации

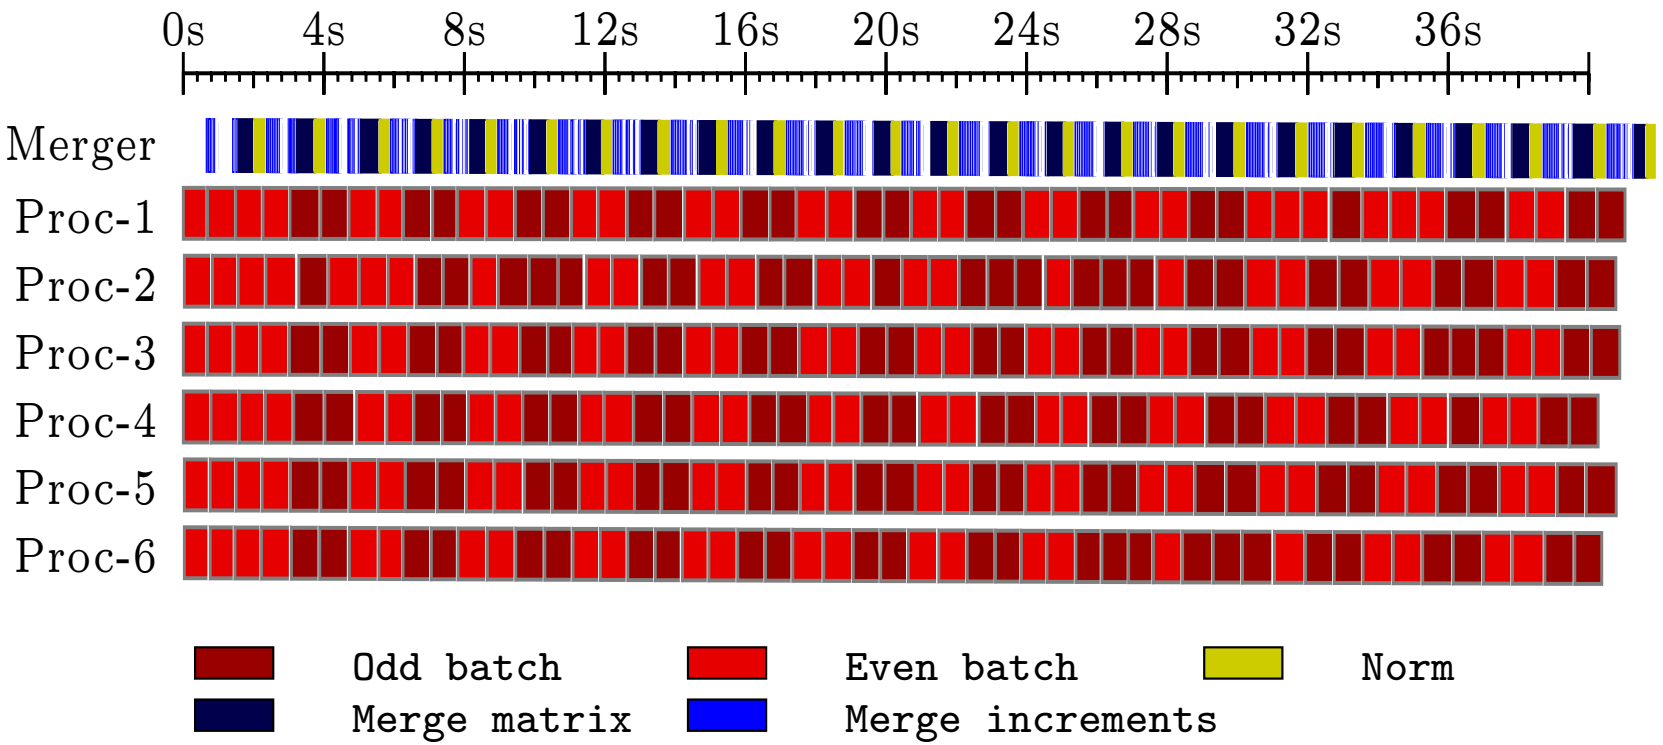

Алгоритм Async: недостатки

- Алгоритм Async не определяет порядок слияния $\tilde{n}_{wt} \Rightarrow$ результирующая матрица Φ различна от запуска к запуску.
- Помещение инкрементов $\tilde{n}_{wt}$ в очередь может серьёзно увеличить потребление памяти $\Rightarrow$ что приводит к перегрузке потока слияния *Merger*.

  Особенно поток слияния могут перегрузить маленькие батчи или малое число внутренних итераций в `ProcessDocument`.

- Это означает, что пользователь должен настраивать технические параметры, что недопустимо.

Алгоритм Async: диаграмма Гантта в плохой ситуации

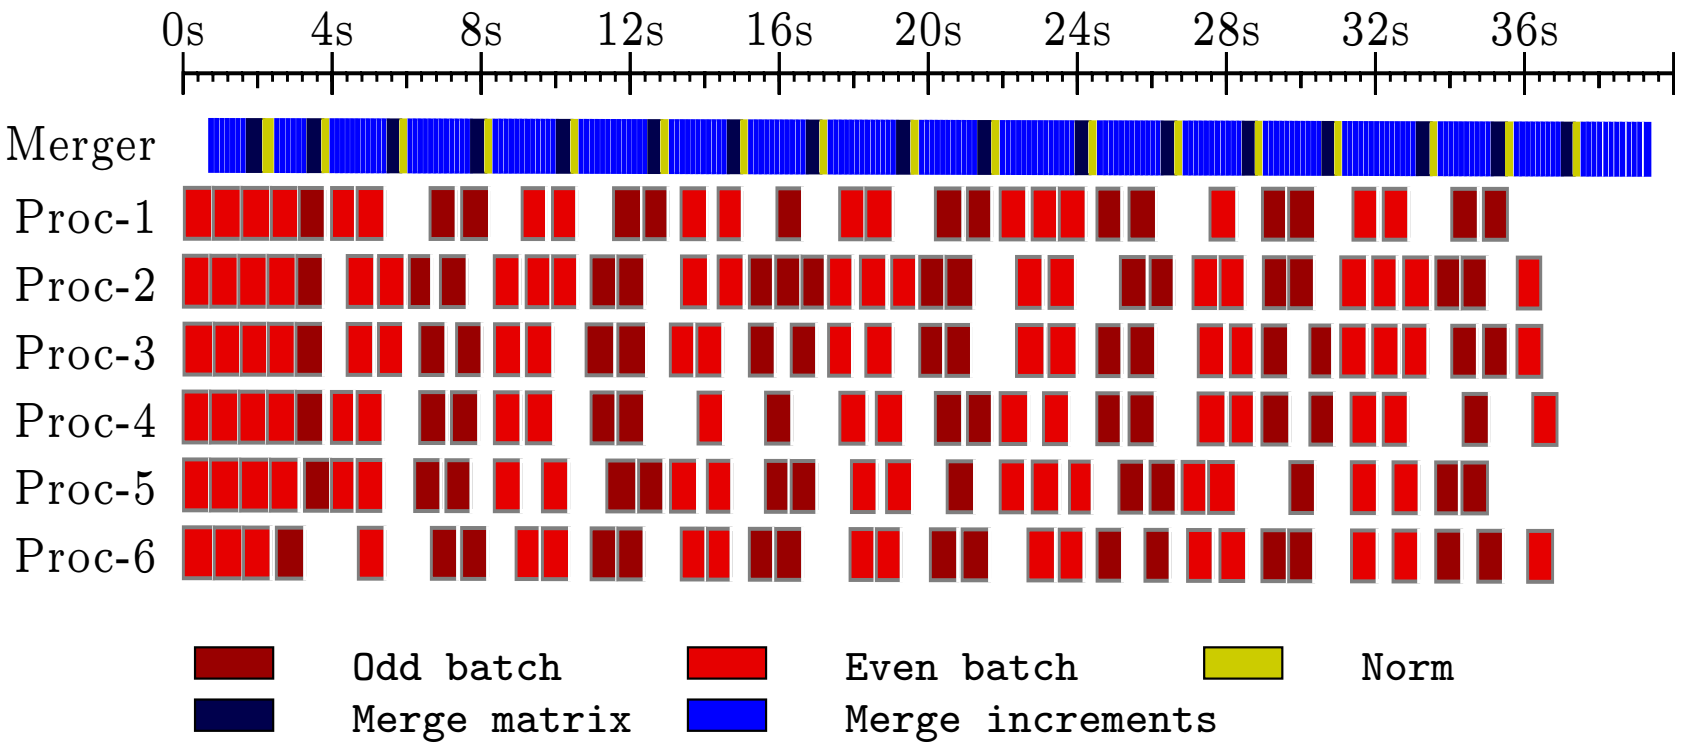

Детерминированный асинхронный онлайновый алгоритм (DetAsync): описание

Чтобы избежать недетерминированного поведения, потребуем обновлений не после *первых* η батчей, а после *заданных* η батчей.

Введём две новые операции: `AsyncProcessBatches` и `Await`.

AsyncProcessBatches эквивалентна ProcessBatches, кроме того, что она берёт задачу на выполнение и сразу возвращает управление в вызвавший поток.

Она выдаёт объект типа future (прмером является `std::future` из стандарта C++11), который может быть затем подан в операцию `Await` для получения результатов, т.е. инкрементов $\tilde{n}_{wt}$.

Между вызовами `AsyncProcessBatches` и `Await` алгоритм может выполнять полезную работу по обновлению Φ, пока в фоновом режиме потоки `Processor` вычисляют матрицу $\tilde{n}_{wt}$.

DetAsync: схема

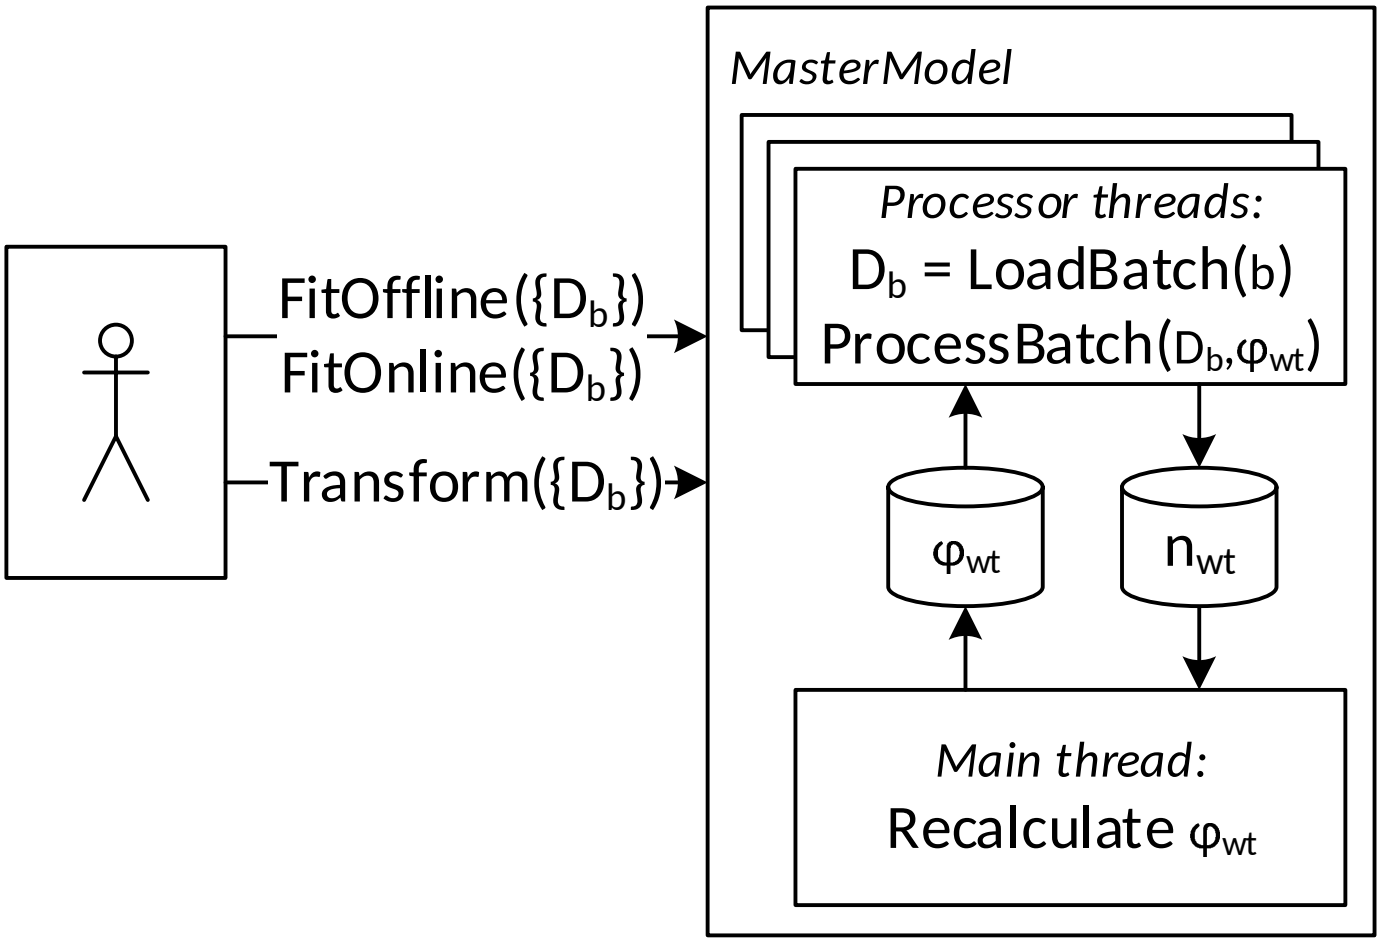

DetAsync: листинг

Input: коллекция D, параметры η, τ_0, κ;
Output: матрица $\Phi = (\phi_{wt})$;

создать батчи $D := D_1 \sqcup D_2 \sqcup \cdots \sqcup D_B$;
инициализировать (ϕ^0_{wt});
$F^1 := \text{AsyncProcessBatches}(\{D_1, \ldots, D_\eta\}, \Phi^0)$;
for all обновления $i = 1, \ldots, \lfloor B/\eta \rfloor$
    if $i \neq \lfloor B/\eta \rfloor$ **then**
        $F^{i+1} := \text{AsyncProcessBatches}(\{D_{\eta i+1}, \ldots, D_{\eta i+\eta}\}, \Phi^{i-1})$;
    $(\hat{n}^i_{wt}) := \text{Await}(F^i)$;
    $\rho_i := (\tau_0 + i)^{-\kappa}$;
    $(n^i_{wt}) := (1 - \rho_i) \cdot (n^{i-1}_{wt}) + \rho_i \cdot (\hat{n}^i_{wt})$;
    $(\phi^i_{wt}) := \underset{w \in W}{\text{norm}}(n^i_{wt} + \phi^{i-1}_{wt} \frac{\partial R}{\partial \phi_{wt}})$;

DetAsync: диаграмма Гантта

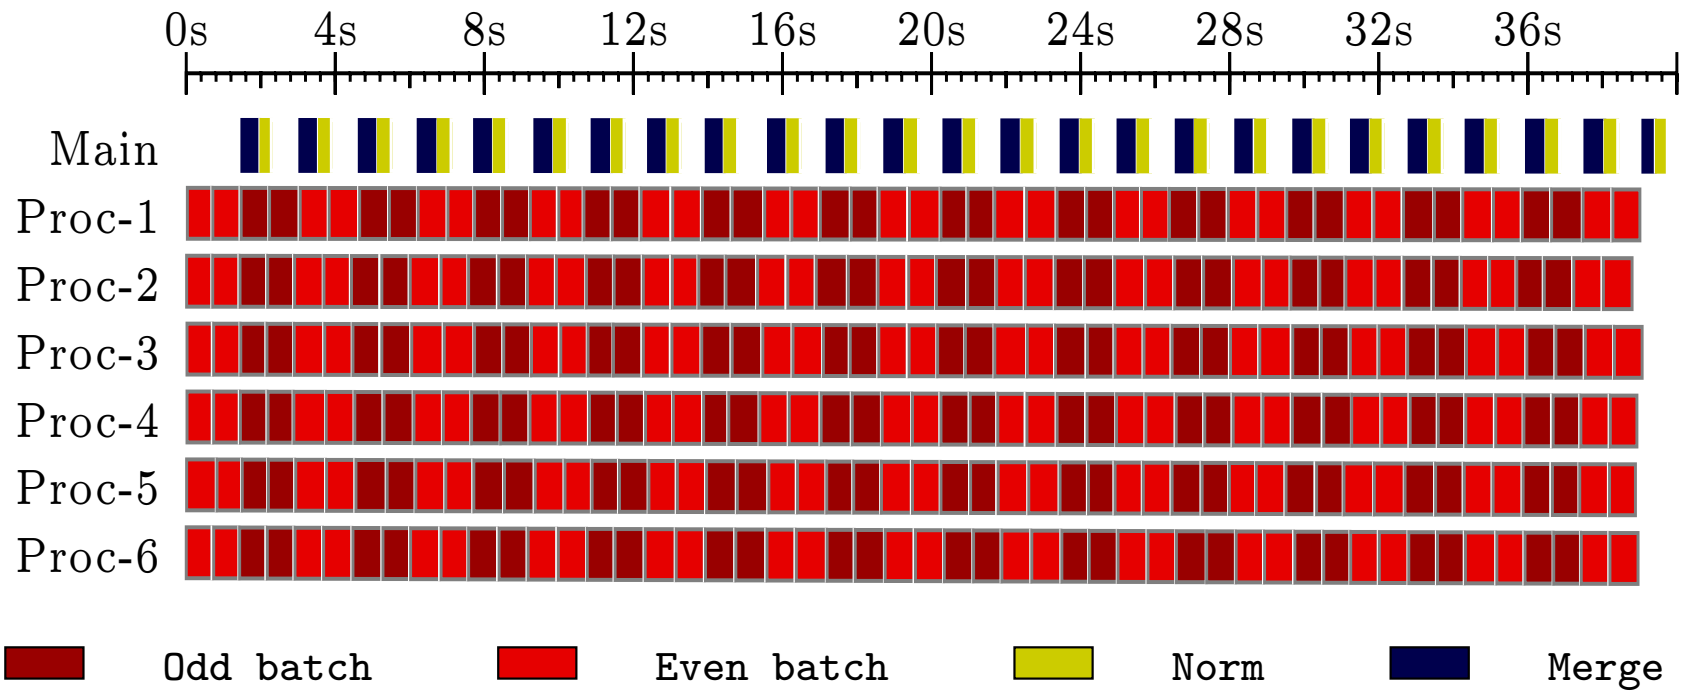

DetAsync: детали реализации

- В старой архитектуре матрицы $\tilde{n}_{wt}$, построенные по разным батчам, хранились в очереди и агрегировались потоком слияния `Merger`.
- В новой архитектуре поток `Merger` был удалён, потоки-обработчики пишут обновления напрямую в n_{wt} (локальный аналог «архитектуры классной доски»).
- *Spin lock-и* предотвращают одновременное обновление одной строки несколькими потоками.
- Тройка операций «lock-update-release» производится в цикле по всем словам документа $w \in d$ в конце операции `ProcessDocument`.
- Выделенный поток загрузки данных `DataLoader` был так же ликвидирован, потоки-обработчики сами загружают себе батчи на обработку с диска.

Все структуры данных, передаваемые внутри библиотеки, сгенерированы технологией Google protocol buffers.

Эксперименты

- Коллекции: *Википедия* ($|D| = 3.7$M статей, $|W| = 100$K слов), *Pubmed* ($|D| = 8.2$M аннотаций, $|W| = 141$K слов).
- Машина: Intel Xeon CPU E5-2650 v2 system с 2 процессорами, 16 физическими ядрами в совокупности (32 с гипер-тредингом).
- Метрика: значение перплексии $\mathscr{P}$ достигнутое за выделенное время.
- Время: каждому алгоритму было выделено на работу 30 минут.

Пиковое потребление оперативной памяти (Gb):

	$\|T\|$	Оффлайн	Онлайн	DetAsync	Async (v0.6)
Pubmed	1000	5.17	4.68	8.18	13.4
Pubmed	100	1.86	1.62	2.17	3.71
Вики	1000	1.74	2.44	3.93	7.9
Вики	100	0.54	0.53	0.83	1.28

Достигнутое значение перплексии

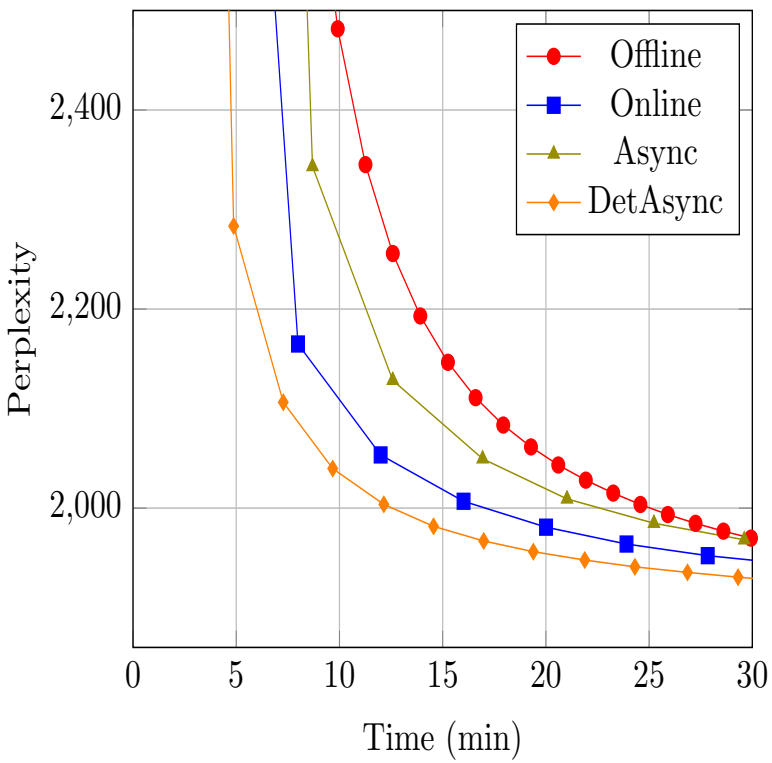

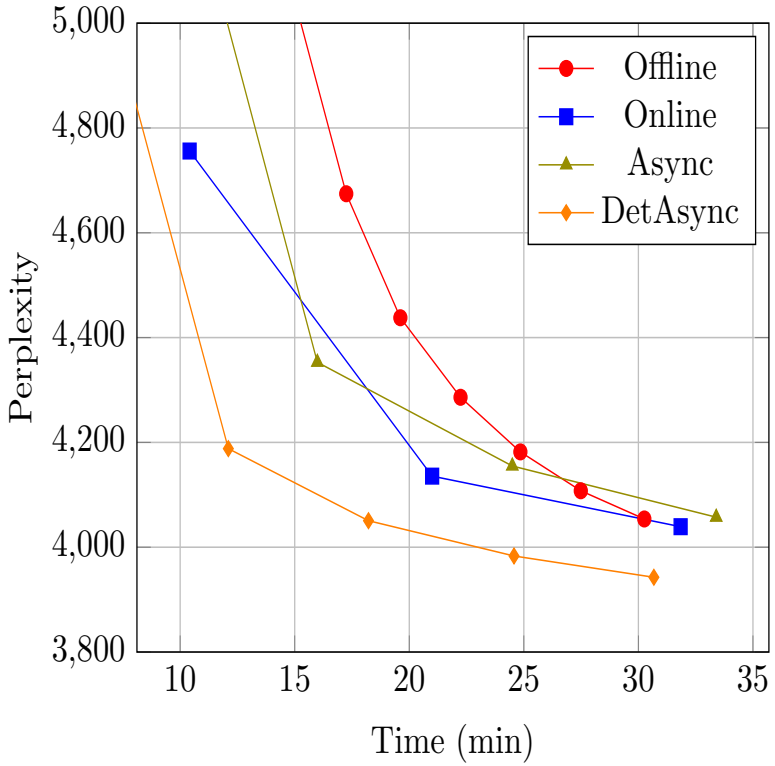

Википедия (слева), Pubmed (справа).

Алгоритм DetAsync достиг наилучшего значения перплексии за выделенное время.

Выводы

- Как и в любой задаче машинного обучения, при распараллеливании методов обучения тематической модели важны объёмы потребляемой памяти, степень загруженности вычислительных ресурсов, скорость сходимости. Выигрыш в одном ведёт к потерям в другом, но найти компромисс можно и нужно.
- Алгоритмы AD-LDA, Y!LDA и Mr.LDA представляют, прежде всего, теоретический интерес, как различные подходы к параллельному и распределённому обучению моделей.
- Библиотеки BigARTM, Vowpal Wabbit LDA и Gensim — реально используемые инструменты для тематического моделирования на одной машине (в случае VW.LDA — ещё и на кластере).
- При использовании на одном ноде наиболее эффективным является алгоритм DetAsync, реализованный в BigARTM. Кроме этого, библиотека полезна поддержкой мультимодальных моделей ARTM, готовым набором регуляризаторов и метрик качества.

Список литературы I


D. Newman, A. Asuncion, P. Smyth, and M. Welling. (2009). Distributed algorithms for topic models, // NIPS.


Alexander Smola and Shravan Narayanamurthy. (2010). An architecture for parallel topic models, // VLDB.


Ke Zhai, Jordan Boyd-Graber, Nima Asadi, Mohamad Alkhouja. (2012). Mr. LDA: A Flexible Large Scale Topic Modeling Package using Variational Inference in MapReduce, // ACM.


T. Hofmann.. Probabilistic latent semantic indexing, // Proceedings of the 22nd annual international ACM SIGIR conference on Research and development in information retrieval. — New York, NY, USA: ACM, 1999. — Pp. 50–57.


D. M. Blei, A. Ng, and M. Jordan. (2003). Latent Dirichlet allocation, // Journal of Machine Learning Research, vol. 3, pp. 993–1022.

Список литературы II


Воронцов К. В.. Аддитивная регуляризация тематических моделей коллекций текстовых документов, // Доклады РАН. 2014. — Т. 455., No3. 268–271.


Vorontsov K. V., Potapenko A. A. (2014). Additive Regularization of Topic Models, // Machine Learning Journal. Special Issue «Data Analysis and Intelligent Optimization with Applications».


Matthew D. Hoffman, David M. Blei, Francis Bach. (2010). Online Learning for Latent Dirichlet Allocation, // NIPS.


K. Vorontsov, O. Frei, M. Apishev., P. Romov, M. Suvorova, A. Yanina. (2015). BigARTM: Non-Bayesian Additive Regularization for Multimodal Topic Modeling of Large Collections // Topic Models: Post-Processing and Applications, CIKM 2015 Workshop, October 19, 2015, Melbourne, Australia. ACM, New York, NY, USA. pp. 29–37.

Список литературы III


Frei Olexander, Apishev Murat (2016). Parallel Non-blocking Deterministic Algorithm for Online Topic Modeling, // AIST (to appear).


Jia Zeng, Zhi-Qiang Liu, Xiao-Qin Cao. (2015). Fast Online EM for Big Topic Modeling, // IEEE.


Bo Zhao, Hucheng Zhou, Guoqiang Li, Yihua Huang. (2015). ZenLDA: An Efficient and Scalable Topic Model Training System on Distributed Data-Parallel Platform, // ACM.