УНИВЕРСИТЕТ ЛОБАЧЕВСКОГО

Кафедра высокопроизводительных вычислений и системного программирования

Оптимизация библиотеки CatBoost для использования векторных расширений RISC-V

Иосиф Мееров

+ Е. Козинов, Е. Васильев, А. Горшков, В. Кустикова, А. Маклаев, В. Волокитин

ННГУ им. Н. И. Лобачевского, Институт ИТММ

Нижний Новгород, Митап Альянса RISC-V 6 ноября 2024г.

Содержание

- Наша лаборатория
- Мотивация
- Что такое CatBoost?
- Алгоритм
- Оптимизация
- Результаты
- Вместо заключения

Наша HPC-лаборатория

- ***Предметная область:*** **разработка научного ПО в междисциплинарных проектах, анализ и оптимизация производительности**
  - Вычислительна физика (лазерная физика, квантовая динамика…)
  - Вычислительная биология
  - Финансовая математика
  - Компьютерная графика, компьютерное зрение, ML & DL
  - Алгоритмы на графах и разреженная алгебра
- ***В основном ориентировано на x86-64 (C, C++, SYCL, Kokkos, Parallel Studio…)***

Почему мы заинтересовались устройствами RISC-V?

Мотивация

Почему мы заинтересовались устройствами RISC-V?

- Свободная, открытая, перспективная архитектура
- Первые устройства RISC-V *достаточно* легко использовать
- Системное ПО приемлемого качества и постоянно развивается
- Программные библиотеки *часто* могут быть построены и использованы без модификаций (*достижение высокой производительности может быть непростым делом*)

RISC-V это глоток свежего воздуха!

- **Ложка дегтя:**
  - Не хватает инструментов для анализа производительности
  - Не хватает документации и методических статей
  - Не хватает устройств HPC-класса

Проблемы нас не останавливают, а мотивируют

Цель

Ключевой вопрос: как оценивать производительность больших программных комплексов и какие техники могут улучшить производительность на устройствах RISC-V?

- Рассматриваем **CatBoost**, один из широко распространенных пакетов ML, основанный на *деревьях решений*
- Рассматриваем алгоритмы CatBoost как **«черный ящик»**, не погружаясь глубоко в логику алгоритмов (*типично для performance engineering)*
- Фокусируемся на **аспектах производительности** и ищем пути **ускорить код**, *обнаружив* и *векторизовав* основные **вычислительно-трудоемкие циклы** при работе на выбранных наборах данных

Цель

Ключевой вопрос: как оценивать производительность больших программных комплексов и какие техники могут улучшить производительность на устройствах RISC-V?

- Рассматриваем алгоритмы CatBoost как **«черный ящик»**, не погружаясь глубоко в логику алгоритмов (*типично для performance engineering)*
- Фокусируемся на **аспектах производительности** и ищем способы **ускорить код**, *обнаружив* и *векторизовав* основные **вычислительно-трудоемкие циклы** при работе на выбранных наборах данных

Чем обусловлен такой план?

Что такое CatBoost?

- **CatBoost** реализует алгоритм, основанный на ***градиентном бустинге деревьев решений***, пакет разработан **Yandex**
- Используется в *поисковых и рекомендательных системах,* персональных помощниках, ПО для автомобилей и др., в частности, в Yandex, CERN…
- Библиотека с *открытым исходным кодом* (Apache 2.0)
- Решает задачи классификации, регрессии и др.
- Python, R, Java и C++ APIs
- Оптимизирован для вычислений на CPU и GPU
- Включает средства для тренировки и вывода моделей, анализа качества и визуализации

Градиентный бустинг деревьев решений

- **CatBoost реализует градиентный бустинг деревьев решений**

- **Идея бустинга** – построить сильные предсказательные модели, используя ансамбли слабых моделей
- Алгоритм использует «забывчивые деревья решений» (*oblivious decision trees)* с малой глубиной в качестве слабых моделей
- **Забывчивое дерево** – упрощенная модель дерева решений, где все узлы на одном уровне проверяют одно и то же условие
- В ходе тренировки, деревья добавляются к ансамблю, и каждое дерево пытается исправить ошибки предыдущего

Алгоритм CatBoost

Пример:
задача классификации

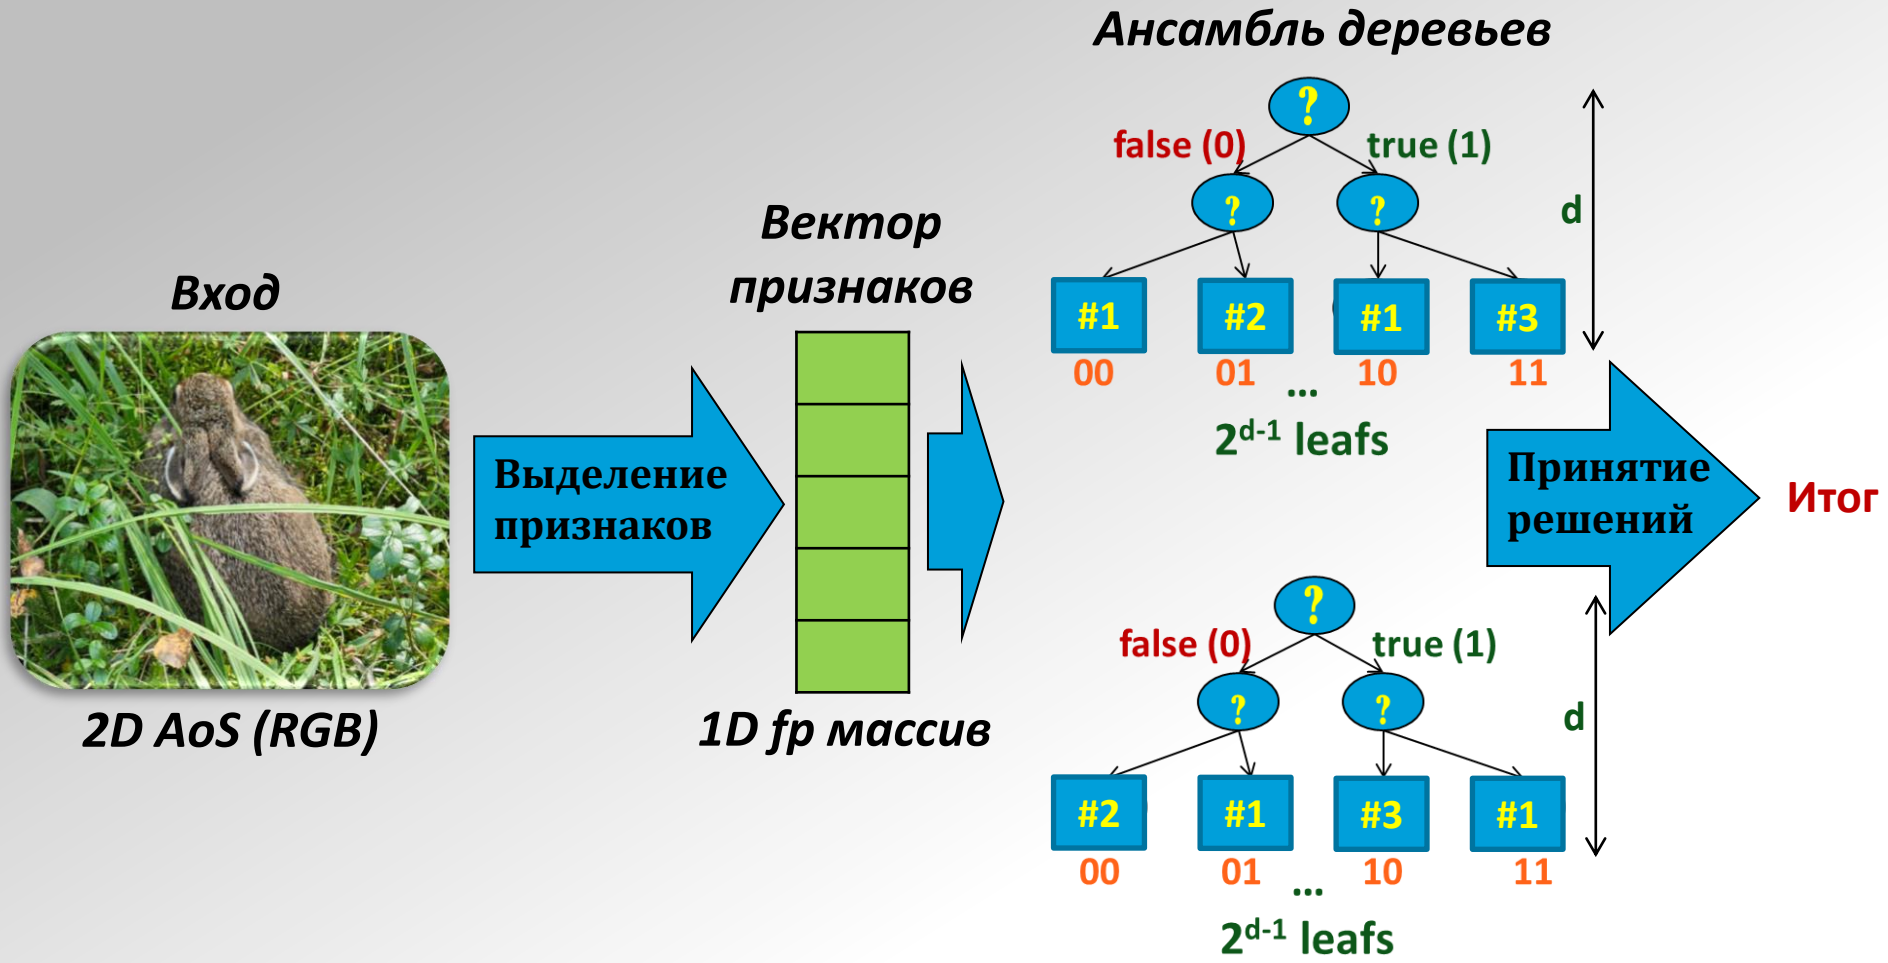

Алгоритм CatBoost

Пример:
задача классификации

Забывчивое дерево это упрощенное дерево (на одном уровне все узлы содержат одно и то же условие)

Оптимизация (реализовано Yandex)
- не нужно хранить деревья напрямую
- не нужны традиционные проверки
! Достаточно отсортировать все натренированные пороги, сделать бинаризацию и использовать битовые операции, чтобы найти результирующий лист дерева

Наша цель: улучшить производительность на RISC-V CPUs, не меняя алгоритм и структуры данных

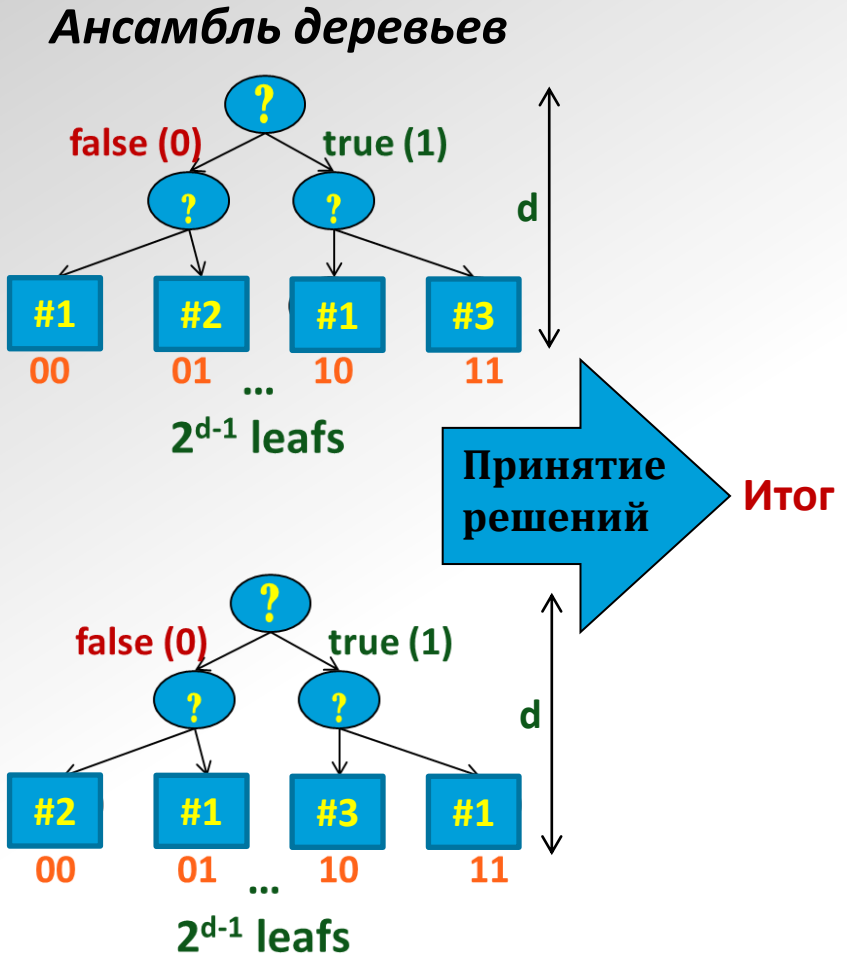

Наборы данных

Набор данных	Строки/Столбцы	Число классов	Функция потерь	Темп обучения	Глубина дерева
MQ2008	9630 x 46	-	YetiRank	0.02	6
Santander customer transaction	400k x 202	2	LogLoss	0.01	1
Covertype	464.8k x 54	7	MultiClass	0.50	8
YearPredictionMSD	515k x 90	-	MAE	0.30	6
image-embeddings	5649 x 512	20	MultiClass	0.05	4

- Используем несколько распространенных наборов данных
- Нет гарантии, что набор *репрезентативен*, но, по крайней мере, мы покрываем несколько разных сценариев

Наборы данных (краткое описание)

- *“Covertype”*
  - 52 целочисленных и бинарных признака, представляющих дикие местности и типы почв
  - требуется прогнозировать тип лесного покрова (7 классов)
  - набор данных был разделен на обучающую и тестовую выборку в соотношении 70:30
- *“Santander customer transaction”*
  - 200 ненормализованных признаков, бинарная классификация
  - тренировочная и тестовая выборки имеют по 200 000 элементов каждая
- *“YearPredictionMSD”*
  - 90 ненормализованных признаков, извлеченных из песен
  - требуется прогнозировать год выхода песни
  - 463 715 сэмплов в тренировочной выборке и 51 630 в тестовой

Наборы данных (краткое описание)

- “MQ2008”
  - 46 признаков для решения задачи ранжирования
  - содержит 9 630 тренировочных сэмплов и 2 874 тестовых сэмплов
- “image-embeddings”
  - подмножество набора данных PASCAL VOC 2007 (20 классов)
  - не содержит изображений с объектами нескольких классов
  - содержит 9 630 тренировочных сэмплов и 2 874 тестовых сэмплов
  - эмбеддинги генерируются для изображений с использованием натренированной модели *resnet34* из библиотеки TorchVision
  - для получения эмбеддингов, из модели убран последний классификационный слой

Возможности для оптимизации

- ***x86 CPUs***: множество средств для анализа и оптимизации оптимизации (VTune, Advisor, компиляторы C, C++, Fortran…)
- ***RISC-V CPUs***:
  - Компиляторы на ранней стадии разработки (*весьма неплохого качества, тем не менее*)
  - Набор средств для оптимизации существенно ограничен
  - Их функциональность скудная (могут лишь искать хотспоты)
- Как оптимизировать большие коды? *(стандартно для perf. eng.)*
  - Найти хотспоты (вычислительно-трудоемкие участки кода)
  - Попробовать векторизовать вычислительные циклы
  - Проверить и улучшить эффективность распараллеливания
- ***Что мы сделали***: вручную векторизовали код на **RVV 0.7.1**

Как найти хотспоты на устройствах RISC-V?

- Выяснилось, что использовать ***perf*** из Linux для анализа CatBoost **проблематично**, т.к. код содержит *интерфейс* на Python и *динамические библиотеки* на C++
- **Технология профилирования:**
  - Найти точку входа – наиболее нагруженную функцию **(perf)**
  - Изучить тело функции, вставить замеры времени и аккумулировать времена в глобальную переменную **(свой таймер)**
  - Проанализировать результаты, продвинуться вглубь, построить граф вызова функций

Как найти хотспоты на устройствах RISC-V?

- **Технология профилирования:**
  - Найти точку входа – наиболее нагруженную функцию **(perf)**
  - Изучить тело функции, вставить замеры времени и аккумулировать времена в глобальную переменную **(свой таймер)**
  - Проанализировать результаты, продвинуться вглубь, построить граф вызова функций
- **Валидация:**
  - Использовать тот же подход на x86 CPUs и сравнить с результатами профилировки имеющимися на x86 средствами
  - Сравнить запуски с профилировкой и без нее на RISC-V CPUs
  - Провести ***итоговые эксперименты*** **без профилировки** на **полных наборах данных**

Кандидаты для векторизации

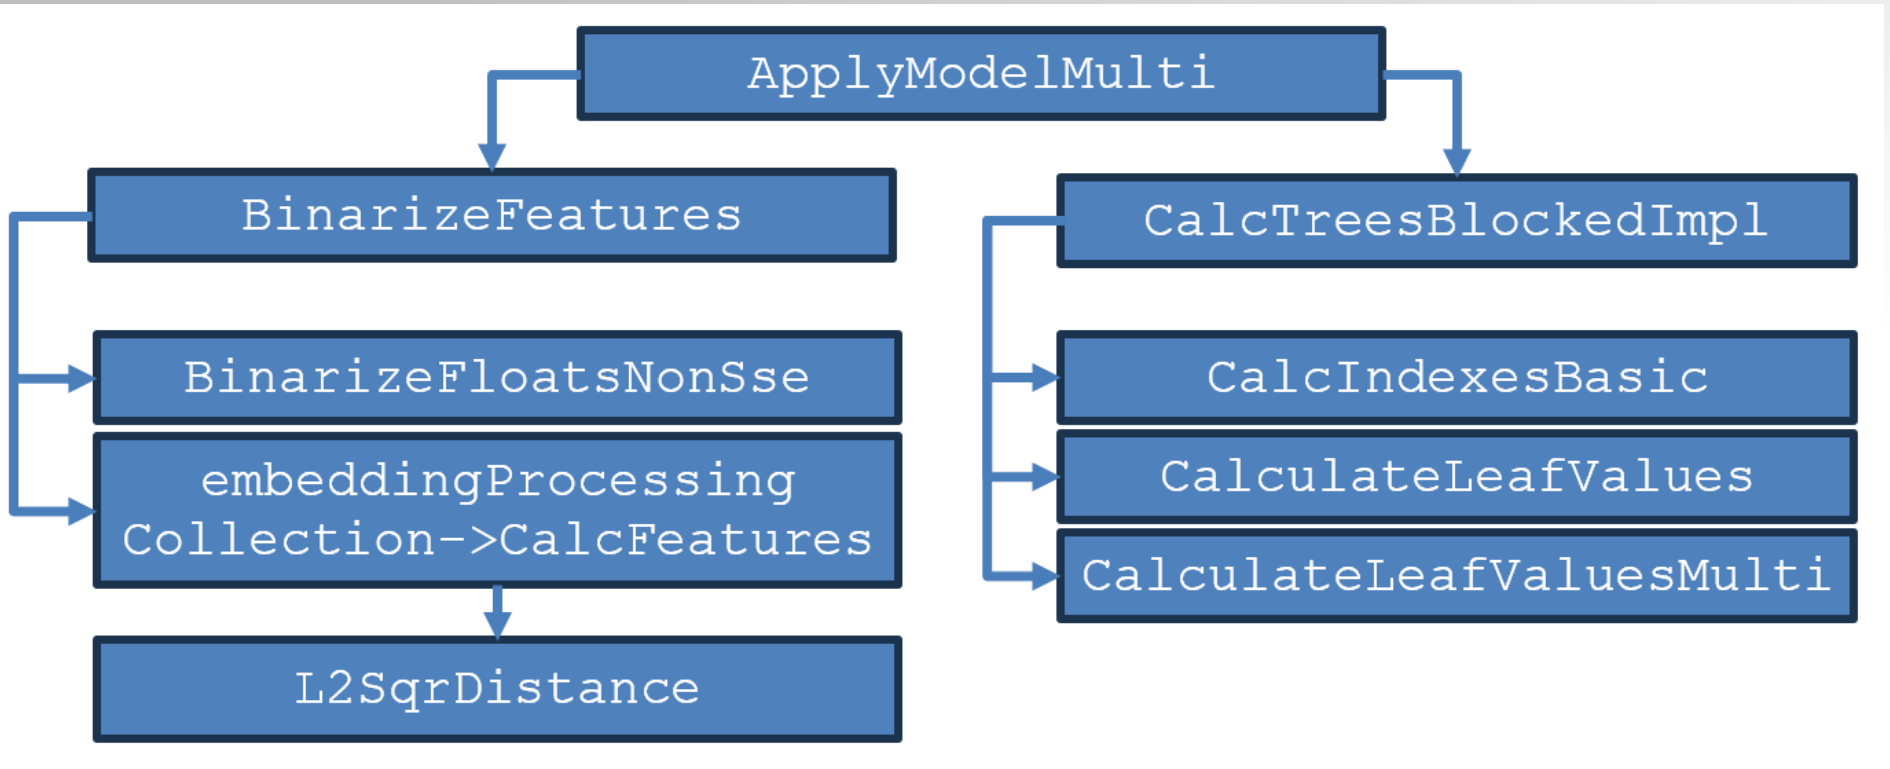

Функция BinarizeFloatsNonSse()

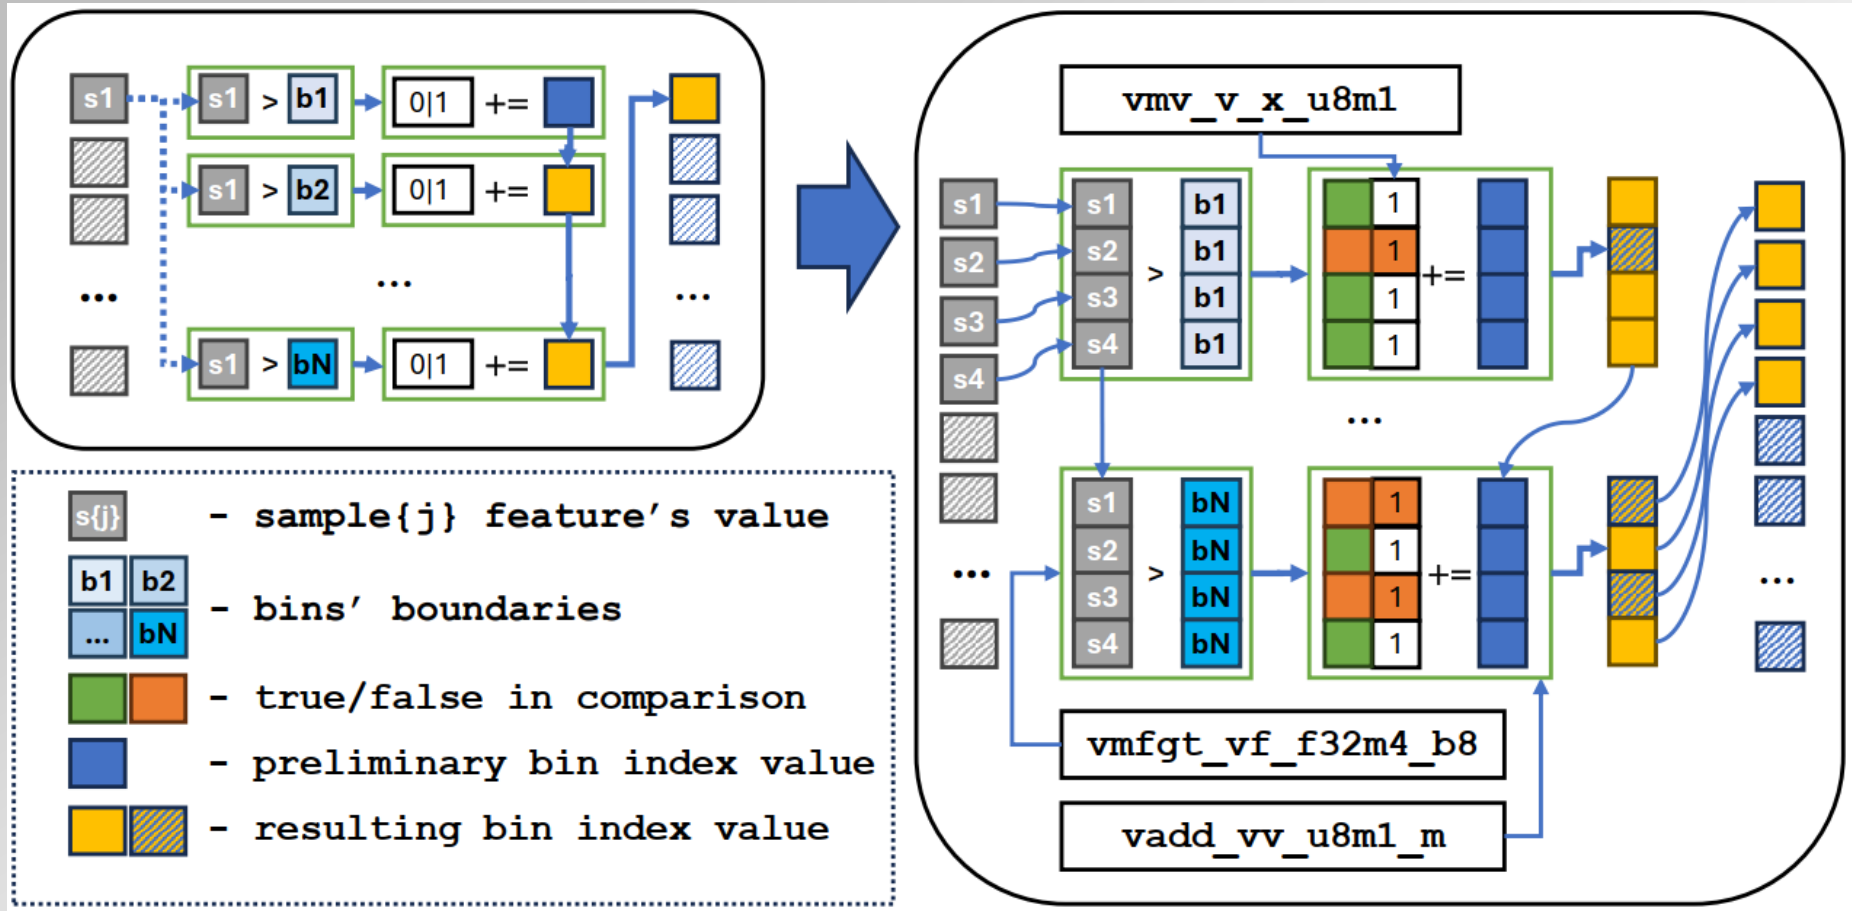

Функция CalcIndexesBasic()

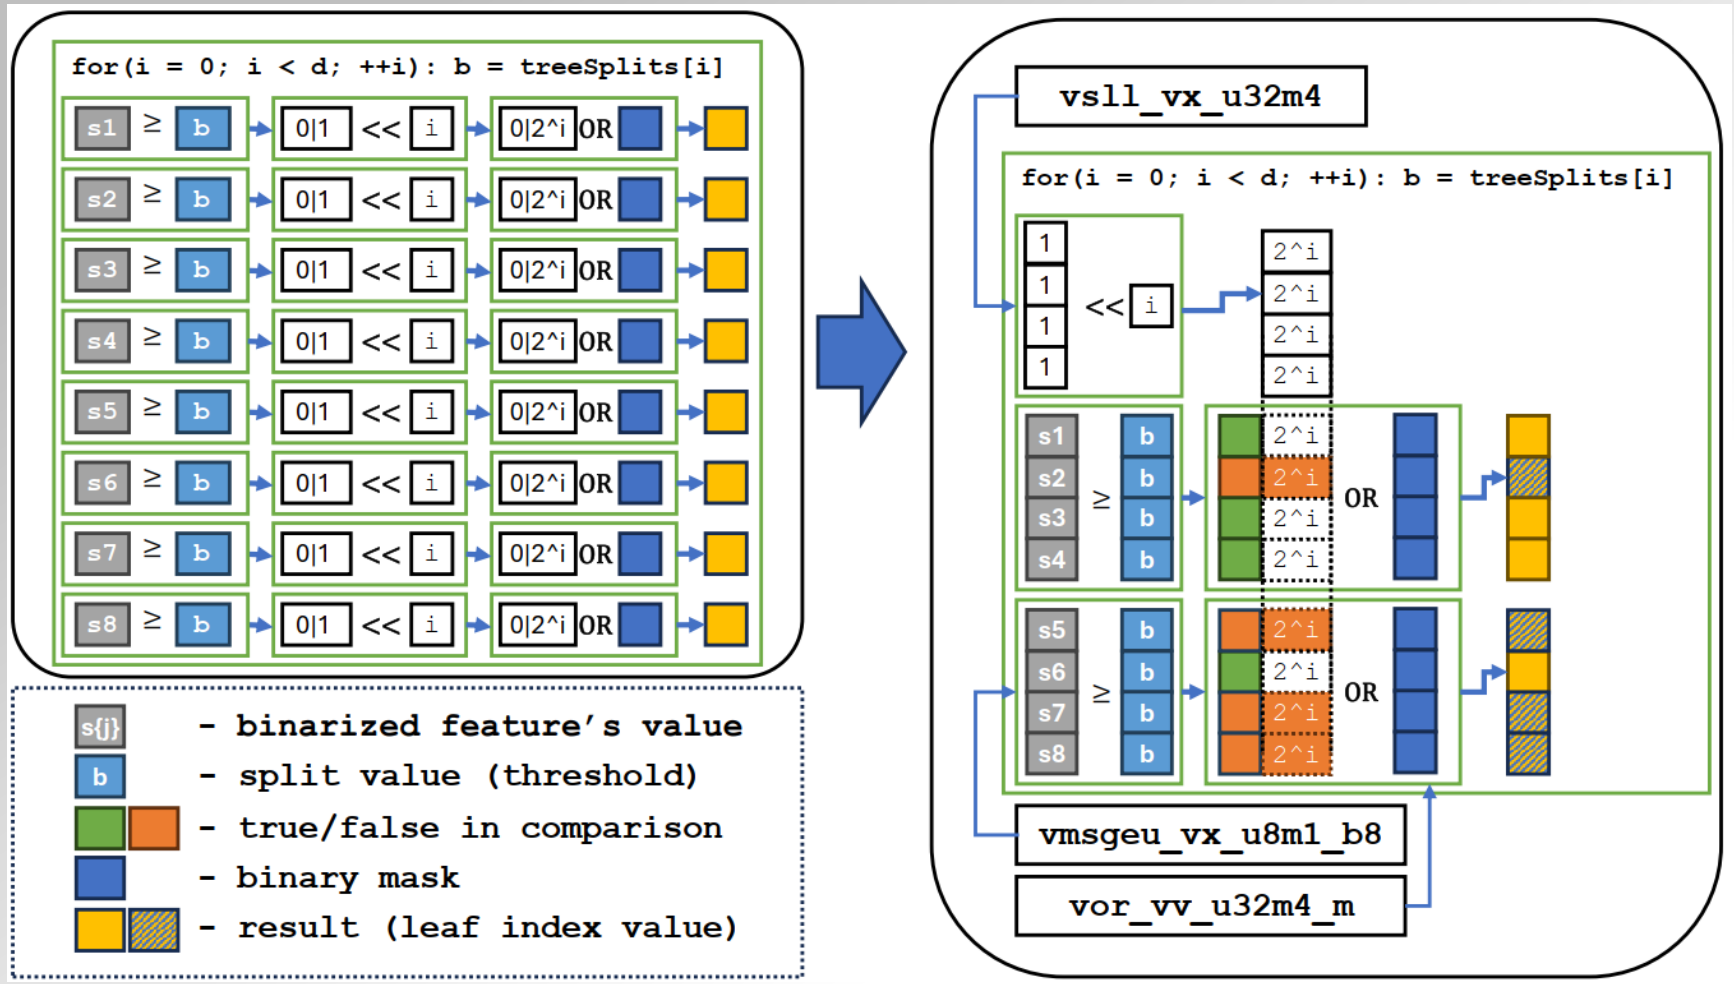

Функция L2SqrDistance()

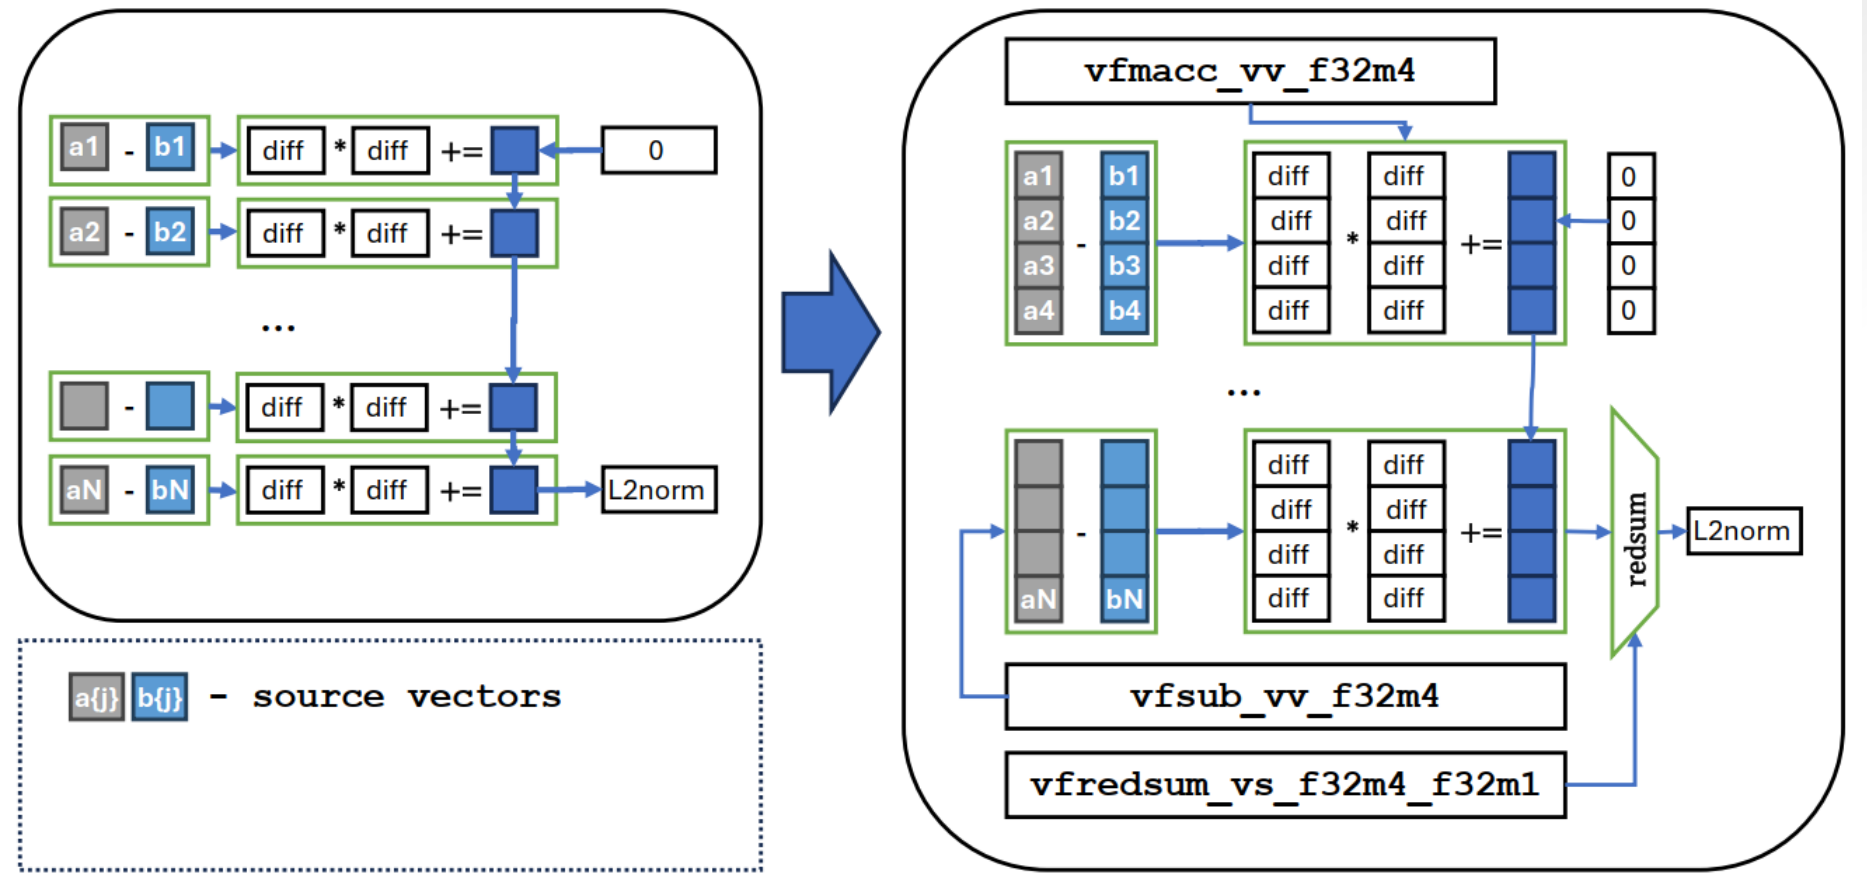

Векторизация для RISC-V CPUs: Идея

- Векторное расширение RVV 0.7.1 позволяет *выбрать число векторных регистров, используемых в одной операции*
- Например, мы можем использовать **блок из 4х 128-битных регистров** и соответствующие векторные операции, как будто архитектура содержит **512-битные регистры**
- Для этого нужно указать суффикс **m4** в наименованиях интринсиков
- Таким образом можно **значительно** повысить производительность, но определить наилучший вариант (m1, m2, m4, m8) пока можно только экспериментально
- Мы использовали наилучший вариант

Оборудование

- **X86** (*тренировка моделей, подготовка наборов данных, вычисление точности, сравнение производительности*):
  - Intel Xeon Silver 4310T (2 CPUs с 10 ядрами, 20 ядер всего), 64 GB RAM
- **RISC-V**: **Mini-cluster Lichee Cluster 4A**
  - 7 план с RISC-V TH1520 CPUs на базе ядер C910
  - Каждый процессор содержит 4 ядра с поддержкой RVV 0.7.1
  - Каждая плата имеет 16GB RAM

Предварительные результаты (1)

Profiling results of CatBoost prediction on the `YearPredictionMSD` dataset on RISC-V CPU. The code was run in a serial mode. Time is given in seconds.

Function/metric	Call count	Baseline		Optimized		Speedup
		time	% total time	time	% total time	
CalcTreesBlockedImpl	8	1.35	89.41%	0.39	79.82%	**3.43**
CalcIndexesBasic	79992	1.02	67.60%	0.07	15.11%	**13.68**
CalculateLeafValues	79992	0.21	13.70%	0.20	40.56%	**1.03**
BinarizeFloatsNonSse	720	0.09	5.63%	0.03	6.05%	**2.85**
Other (profiler, auxiliary func ...)		0.07	4.95%	0.07	14.14%	-
Total time		**1.51**		**0.49**		**3.06**

Предварительные результаты (2)

Profiling results of CatBoost prediction on the `Covertype` dataset on RISC-V CPU. The code was run in a serial mode. Time is given in seconds.

Function/metric	Call count	Baseline		Optimized		Speedup
		time	% total time	time	% total time	
CalcTreesBlockedImpl	8	1.45	95.70%	0.81	93.17%	**1.79**
CalcIndexesBasic	39520	0.70	46.40%	0.06	6.33%	**12.76**
CalculateLeafValues Multi	39520	0.67	44.44%	0.69	78.64%	**0.98**
BinarizeFloatsNonSse	432	0.02	1.24%	0.01	1.49%	**1.45**
Other (profiler, auxiliary func ...)		0.05	3.05%	0.05	5.34%	-
Total time		**1.52**		**0.87**		**1.74**

Предварительные результаты (3)

Profiling results of CatBoost prediction on the `image-embedding` dataset on RISC-V CPU. The code was run in a serial mode. Time is given in seconds.

Function/metric	Call count	Baseline		Optimized		Speedup
		time	% total time	time	% total time	
CalcTreesBlockedImpl	8	1.60	8.15%	1.17	18.54%	**1.36**
CalcIndexesBasic	38064	0.35	1.76%	0.04	0.56%	**9.72**
CalculateLeafValues Multi	38064	1.18	6.05%	1.07	16.95%	**1,11**
BinarizeFeatures	1	17.93	91.60%	5.10	80.70%	**3.51**
BinarizeFloats NonSse	312	0.03	0.13%	0.00	0.07%	**5.44**
embeddingProcessing Collection		17.91	91.48%	5.10	80.63%	**3.51**
Other (profiler, auxiliary func ...)		0.05	0.25%	0.05	0.76%	-
Total time		**19.58**		**6.33**		**3.10**

Результаты на полных наборах данных

Final comparison results. The code was run in a multithreaded mode. Time is given in seconds. An accuracy is same in all runs, therefore it is shown only once for each dataset.

DataSet	Accuracy	Time (x86)	Time (RISC-V) Baseline	Time (RISC-V) Optimized	Speedup
Santander customer transaction	0.911	0.17	16.07	7.65	**2.10**
Covertype	0.960	0.42	59.41	30.60	**1.94**
YearPredictionMSD	9.168	0.06	16.30	2.79	**5.84**
MQ2008	0.850	0.02	0.55	0.50	**1.10**
image-embeddings	0.802	0.18	16.66	6.00	**2.78**

Производительность: выводы

- Время на сервере x86 приведено только для информации, детальное сравнение с x86 пока не имеет большого смысла
- Получено значительное (до 6x) ускорение
- **Два возможных ограничения:**
  - Ускорение достигается при обработке «пачки» входных данных (на одном сэмпле ускорение не ожидается)
  - Хотспоты и распределение нагрузки зависят от ***набора данных*** и ***решаемой задачи***. Мы исследовали различные модели, но в некоторых других сценариях может потребоваться ***дополнительная оптимизация*** для эффективного использования ресурсов RISC-V CPU

Вместо заключения. Научный прорыв

- Ричард Фейнман – нобелевский лауреат по физике

1959 год

«**There's Plenty of Room at the Bottom**»

Новый тренд –

миниатюризация элементной базы

1968: **20 µm** → **2025**: **2 nm**

Источник: The Nobel Foundation

Вместо заключения. Закон Мура

- Гордон Мур – один из создателей Интел

1965 год (коррекция в 1975 году):
«**Число транзисторов удваивается за 2 года**»

Новый тренд –
рост производительности за счет миниатюризации, повышения тактовой частоты, улучшения архитектуры

Источник: Intel Free Press.

Закон Мура: справедлив ли он сейчас?

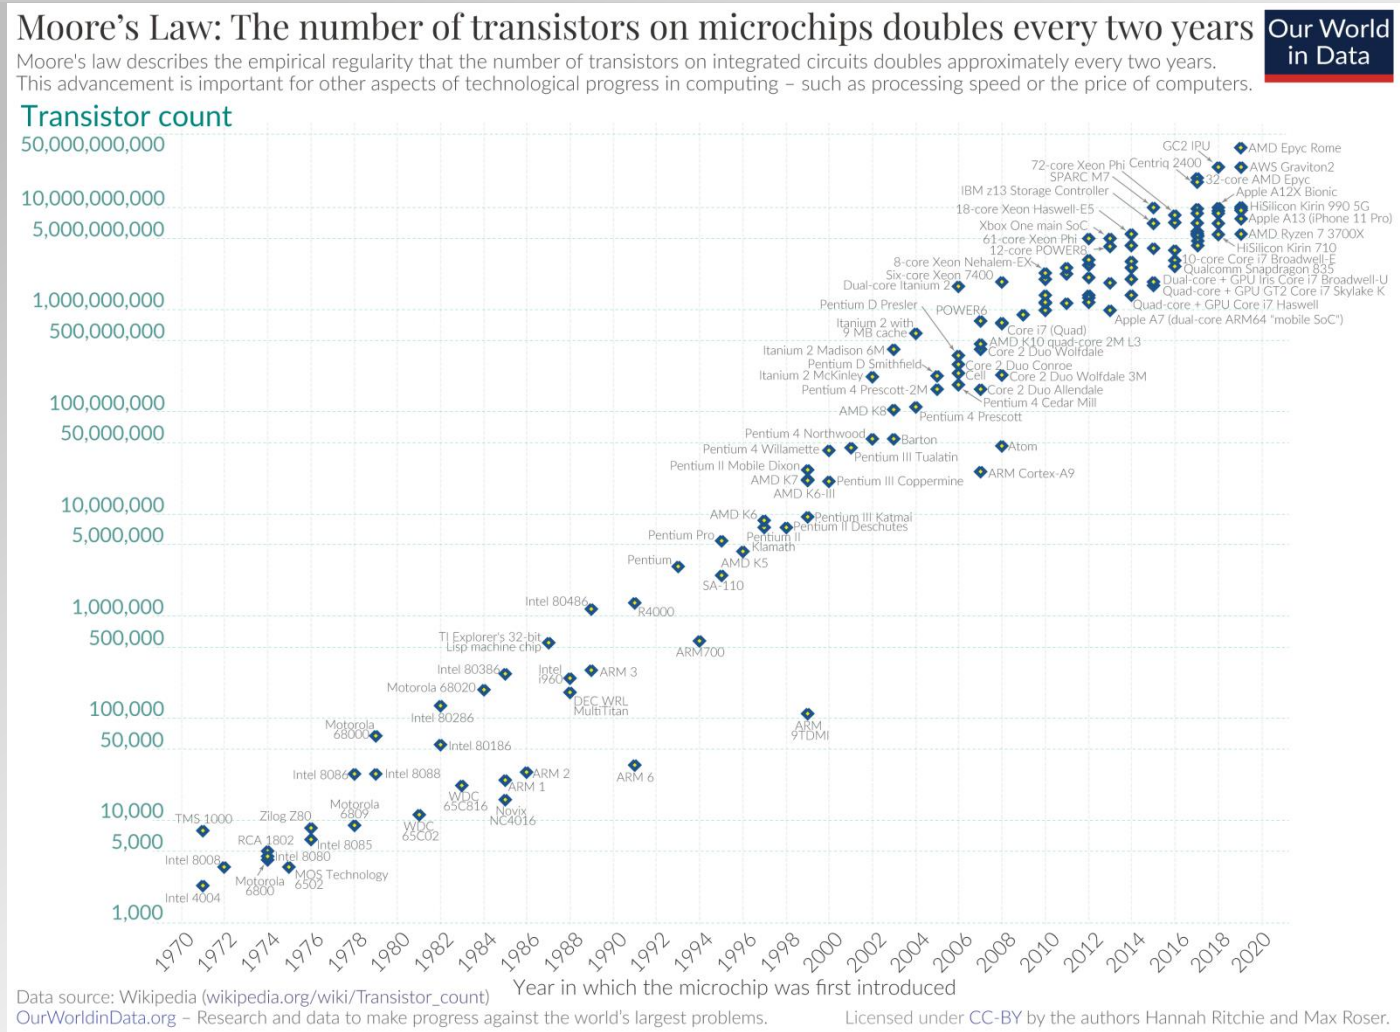

Data source: Wikipedia (wikipedia.org/wiki/Transistor_count)
OurWorldinData.org – Research and data to make progress against the world's largest problems.

Вместо заключения. Вспомним про ПО!

- Чарльз Лейзерсон – один из ведущих специалистов в области информатики

2020 год:

«**There's plenty of room at the Top: What will drive computer performance after Moore's law?**» // Science, Vol 368, Issue 6495

Новый тренд –

физические возможности миниатюризации и повышения производительности **пока исчерпаны**; **но есть масса возможностей по повышению эффективности использования техники!**

Источник: Cleiserson.

Индустрии нужны специалисты

- «There’s plenty of room at the Top» (C. Leiserson)

Есть масса возможностей по повышению эффективности использования техники!

Приходите в нашу предметную область:

- **Это интересно – как читать детектив ☺**
- **Это востребовано – многие коды плохо оптимизированы**
- **Вы сразу видите результат!**

Взгляд в будущее

There’s plenty of room at the Middle

Перспективное направление –
сопряженная разработка
программного и аппаратного обеспечения
(software/hardware co-design)

Началось активное развитие данного направления.
Можно внести свой вклад

Контакты

- Иосиф Мееров, зав. каф. Высокопроизводительных вычислений и системного программирования, институт ИТММ ННГУ, **meerov@vmk.unn.ru**

- Код:
  https://github.com/itlab-vision/catboost/tree/catboost_1_2_2_rvv
- Статья:
  https://arxiv.org/abs/2405.11062 (представлено на PPAM'24, будет опубликовано в Springer LNCS)