

НИЖЕГОРОДСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ ИМ. Н.И. ЛОБАЧЕВСКОГО
ИНСТИТУТ ИНФОРМАЦИОННЫХ ТЕХНОЛОГИЙ, МАТЕМАТИКИ И МЕХАНИКИ

КОМПИЛЯТОРЫ ДЛЯ ГЛУБОКИХ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ

Общая схема построения тензорных компиляторов

При поддержке компании YADRO

Сысоев А.В.,
Кустикова В.Д.

Содержание

- ❑ Обзор общих подходов к оптимизации
- ❑ Понятие тензорного компилятора
- ❑ Общая архитектура тензорных компиляторов
- ❑ Представление нейросетевой модели в виде графа вычислений
- ❑ Типовые подходы к оптимизации графа вычислений
- ❑ Типовые подходы к оптимизации кода операторов
- ❑ Заключение
- ❑ Литература

ОБЗОР ОБЩИХ ПОДХОДОВ К ОПТИМИЗАЦИИ

Цель оптимизации программ

- **Цель оптимизации программ** – получение из работающего* варианта программы другого работающего* варианта, удовлетворяющего некоторым критериям

* принципиальный момент

Рассматриваемые критерии

Основными *критериями* при оптимизации программ являются:

❑ Скорость работы

Миф: компьютеры работают все быстрее. Ничего делать не нужно 😊

// Большие задачи; Real-time; Финансы и др. области

❑ Объем используемой памяти

Миф: много дешевой памяти и будет еще больше. Ничего делать не нужно 😊

// Большие задачи; ограничения на ускорителях

❑ Объем места, занимаемого на диске

Выглядит сомнительным, но вспоминаем про инженерные расчеты и ограничения на кластерах

Рассматриваемые критерии. Взаимодействие

Скорость (performance)

vs.

Память

vs.

Место на диске

Часто критерии **противоречивы**:

- ❑ Используем дополнительную память – ускоряем работу
- ❑ Используем место на диске для однократного расчета и последующего хранения и использования – ускоряем работу
(**пример**: кратчайшие пути, см. [Renato Werneck](#), 2010)

Обычно **один из критериев является основным!**

- ❑ В современных условиях это чаще **скорость работы**, но есть и другие случаи

Требования к оптимизации*

❑ Оптимизация ради оптимизации не только бесполезна, но и вредна!

❑ Требования:

- Переносимость
- Небольшая трудоемкость
- Значимый выигрыш
- Понятность программы
- Возможность развития

* По материалам К. Касперски. *Техника оптимизации программ. Эффективное использование памяти.* БХВ-Петербург, 2003.

Требования к оптимизации. Переносимость

- ❑ Избегаем ассемблерных вставок
- ❑ Избегаем недокументированных возможностей аппаратуры и средств разработки

Основная причина – совместимость (средства разработки и аппаратура развиваются)

Требования к оптимизации. Небольшая трудоемкость

- ❑ Оптимизация не должна существенно увеличивать трудоемкость разработки и тестирования!

Основная причина – необходимо уложиться в сроки и бюджет и выпустить продукт

Требования к оптимизации. Значимый выигрыш

- ❑ Оптимизация должна приносить значимый* выигрыш

Основная причина – соразмерность затрат и результата (избегаем оптимизации ради оптимизации)

* Есть области, в которых 2% это значимый выигрыш:

Пример: моделирование финансовых рынков

Требования к оптимизации. Понятность программы

- ❑ Текст программы должен оставаться понятным «нормальному» программисту

Основная причина – сопровождение

Требования к оптимизации. Возможность развития

- ❑ Необходимо соблюдать проектные решения (в целом)

Основная причина – модификации неизбежны


Правила оптимизации*

- ❑ Прежде чем оптимизировать программу, **убеждаемся в ее работоспособности**
- ❑ Основной прирост производительности приходит от алгоритмической оптимизации и выбора структур данных, а не от «трюков». **Ищем эффективные алгоритмы и подходящие СД**
- ❑ Оптимизация кода $\neq$ ассемблерная реализация. **Улучшаем код для увеличения быстродействия в рамках ЯПВУ. Используем возможности компилятора**
- ❑ **Используем оптимизированные библиотеки**

* По материалам К. Касперски. *Техника оптимизации программ. Эффективное использование памяти.* БХВ-Петербург, 2003.

Жизненный цикл оптимизации

Предполагаем, что программа *написана* и *работает*, но работает *недостаточно быстро*




Много тонкостей

*Тензорные компиляторы
пытаются помочь
программистам, решая часть
задач оптимизации
автоматически /
автоматизировано*

ПОНЯТИЕ ТЕНЗОРНОГО КОМПИЛЯТОРА

Решение задач средствами глубокого обучения



Мотивация...

- Глубокое обучение широко применяется при решении практических задач
- Вывод предполагает многократное выполнение операций над 2-, 3- и 4-мерными матрицами – **тензорами**
- Типовые преобразования:
 - Полносвязный слой
 - Сверточный слой

Мотивация

Внедрение глубоких моделей
предполагает высокую скорость вывода



Необходимо ускорять операции
над тензорами



Необходимо разрабатывать
специализированные инструменты



Тензорные компиляторы

Понятие тензорного компилятора

- **Тензорный компилятор** – отдельный инструмент или компонент какого-либо фреймворка, который обеспечивает оптимизацию и преобразование глубокой нейросетевой модели в исполняемый формат под конкретное устройство

ОБЩАЯ АРХИТЕКТУРА ТЕНЗОРНЫХ КОМПИЛЯТОРОВ


Общая архитектура тензорных компиляторов...

- ❑ Архитектура тензорных компиляторов отражает современный подход к проектированию традиционных компиляторов для языков программирования высокого уровня
- ❑ **Основные компоненты:**
 - Фронтенд (frontend) – интерфейсная часть
 - Бэкенд (backend) – серверная часть
- ❑ **Вход тензорного компилятора** – модель глубокого обучения в формате какого-либо фреймворка
- ❑ **Выход тензорного компилятора** – исполняемый код под выбранную целевую платформу вычислительной системы (аналогично традиционным компиляторам)

Общая архитектура тензорных компиляторов...

- ❑ **Задача тензорного компилятора** – преобразование модели глубокого обучения (входа) в исполняемый код под конкретную платформу (выход)
- ❑ Разнообразие вариантов представления моделей и множество целевых платформ ведет к тому, что работа тензорного компилятора разбивается на **стадии**
- ❑ **Результат всех стадий, кроме последней**, – модель глубокого обучения, преобразованная в какой-либо вариант **промежуточного представления** (*intermediate representation, IR*)

Общая архитектура тензорных компиляторов...

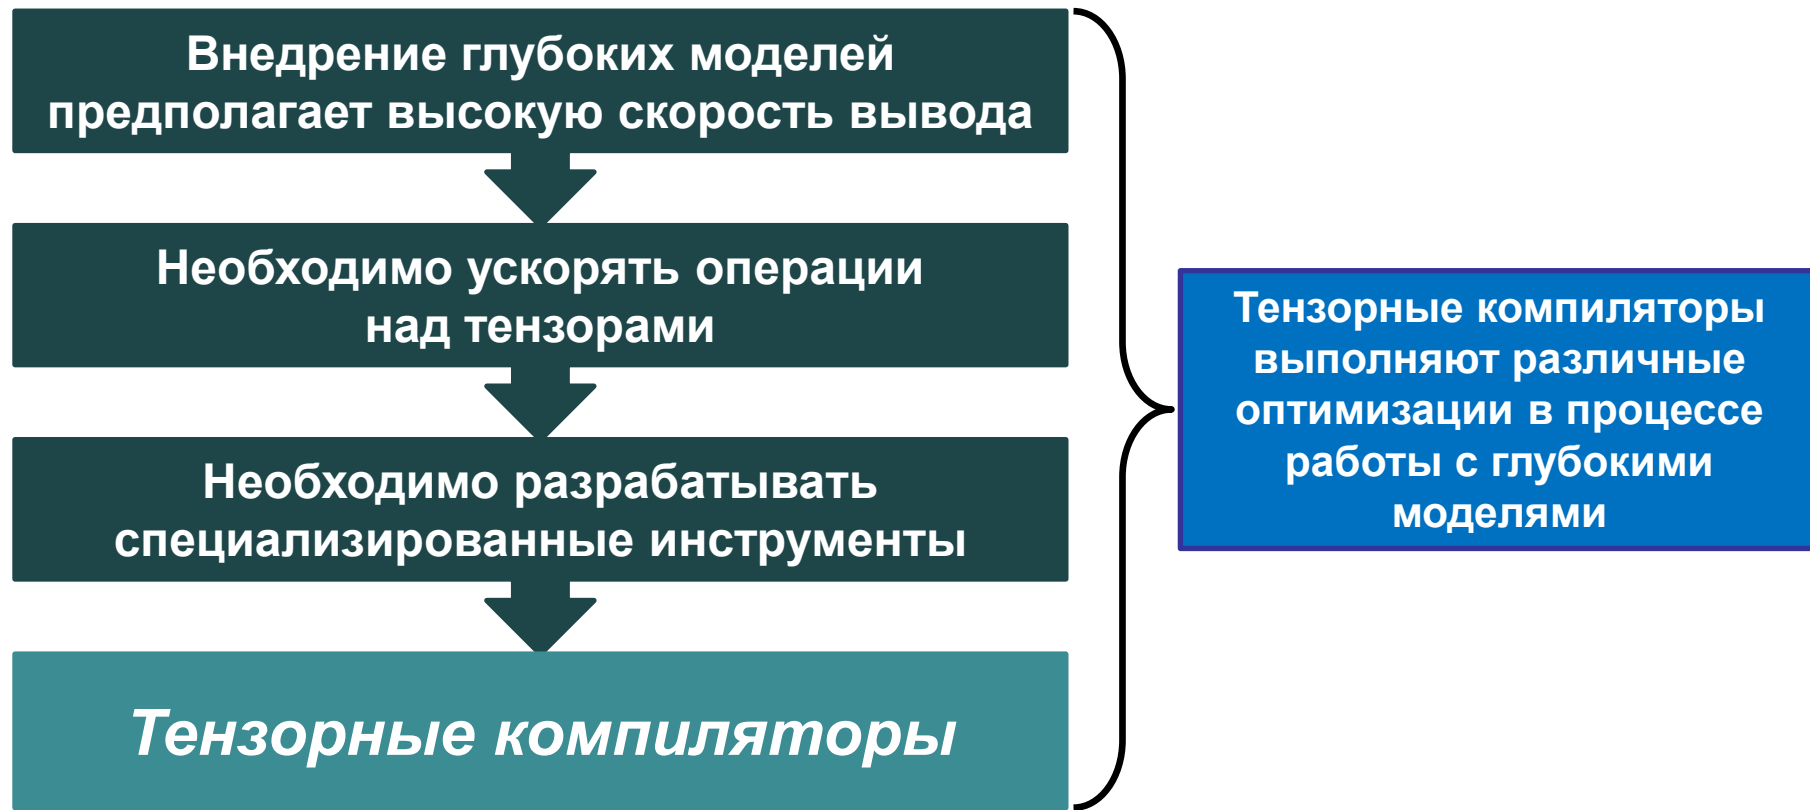


Общая архитектура тензорных компиляторов

□ Схема работы тензорного компилятора:

- **Фронтенд** принимает нейросетевую модель в формате какого-либо фреймворка глубокого обучения, преобразует в граф вычислений и обеспечивает оптимизацию на уровне графа вычислений
- **Бэкенд** преобразует высокоуровневое представление в виде графа вычислений в низкоуровневое и выполняет аппаратно-зависимые оптимизации
- Низкоуровневое представление используется для генерации кода (например, для генерации LLVM IR)

Еще раз о мотивации



ПРЕДСТАВЛЕНИЕ НЕЙРОСЕТЕВОЙ МОДЕЛИ В ВИДЕ ГРАФА ВЫЧИСЛЕНИЙ

Граф вычислений...

- Граф вычислений может определяться двумя способами

Вариант 1

- **Граф вычислений** состоит из следующих компонент:

- Узлы – операторы (преобразования)
- Ребра – тензоры (обрабатываемые данные)

- Тензоры могут представлять:

- Входные данные
- Тензоры весов

- Операторы имеют набор атрибутов

- **Примечание 1:** граф вычислений не содержит информацию о том, как реализованы операторы

- **Примечание 2:** граф вычислений не содержит циклов

Граф вычислений

- Граф вычислений может определяться двумя способами

Вариант 2

- **Граф вычислений** состоит из следующих компонент:

- Узлы – данные или операторы (преобразования)
- Ребра – зависимость от потока данных

- Данные – тензоры:

- Входные данные
- Тензоры весов


- Операторы имеют набор атрибутов

- **Примечание 1:** граф вычислений не содержит информацию о том, как реализованы операторы

- **Примечание 2:** граф вычислений не содержит циклов


Граф вычислений – пример...

Нейронная сеть




Граф вычислений – пример

*Нейронная
сеть*



*Граф
вычислений
нейросети*



ТИПОВЫЕ ПОДХОДЫ К ОПТИМИЗАЦИИ ГРАФА ВЫЧИСЛЕНИЙ

Общая архитектура тензорных компиляторов

ГЛУБОКАЯ
МОДЕЛЬ



TensorFlow

PyTorch



Caffe2

mxnet



ONNX

...

ФРОНТЕНД

ПРЕОБРАЗОВАНИЕ
МОДЕЛИ

ГРАФ ВЫЧИСЛЕНИЙ
(ВЫСОКОУРОВНЕВЫЙ IR)

ОПТИМИЗАЦИЯ
ГРАФА ВЫЧИСЛЕНИЙ

ОПТИМИЗИРОВАННЫЙ
ГРАФ ВЫЧИСЛЕНИЙ (IR)

ПЕРЕХОД
К УРОВНЮ КОДА

БЭКЕНД

ПРОГРАММНЫЙ КОД
(НИЗКОУРОВНЕВЫЙ IR)

АППАРАТНО-
ЗАВИСИМАЯ
ОПТИМИЗАЦИЯ КОДА

ГЕНЕРАТОР КОДА
ПОД ЦЕЛЕВУЮ ПЛАТФОРМУ

ЦЕЛЕВАЯ
ПЛАТФОРМА

CPU
(x86, ARM, RISC-V)

GPU
(NVIDIA, AMD)

ASIC
(TPU, INFERENTIA)

DSP
...

Оптимизация графа вычислений...

Уровни

- Тензорные компиляторы могут выполнять оптимизацию графа вычислений на трех уровнях:
 - Узел
 - Блок
 - Поток данных

Оптимизация графа вычислений...

Уровень узла

- Тензорные компиляторы могут выполнять оптимизацию графа вычислений на трех уровнях:

– Узел

– Блок

– Поток данных

- Оптимизация на уровне узла включает:

- Устранение узлов

- Пусть A – нулевой тензор,
- Тогда узел суммирования A и B можно удалить, поскольку результат известен заранее – это тензор B

- Замену на узлы с более низкой вычислительной стоимостью

- Пусть A – тензор размерности 0, B – тензор-константа,
- Тогда узел суммирования A и B можно заменить на узел-константу с тензором B

Оптимизация графа вычислений...

Уровень блока...

- ❑ Тензорные компиляторы могут выполнять оптимизацию графа вычислений на трех уровнях:

– Узел

– **Блок**

– Поток данных

- ❑ Оптимизация на уровне блока включает:

- Алгебраические упрощения (algebraic simplification)
- Слияние операторов (operator fusion)

Оптимизация графа вычислений...

Уровень блока...

- Тензорные компиляторы могут выполнять оптимизацию графа вычислений на трех уровнях:

– Узел

– **Блок**

– Поток данных

- Оптимизация на уровне блока включает:

- Алгебраические упрощения (algebraic simplification)

- Эквивалентные преобразования

- Пусть требуется вычислить $C = A^T B^T$, что требует два транспонирования и одно умножение матриц

- Вместо этого можно вычислить $C = (BA)^T$, что требует одно транспонирование и одно умножение матриц

- Слияние операторов (operator fusion)

Оптимизация графа вычислений...

Уровень блока...

- Тензорные компиляторы могут выполнять оптимизацию графа вычислений на трех уровнях:

– Узел

– **Блок**

– Поток данных

- Оптимизация на уровне блока включает:

- Алгебраические упрощения (algebraic simplification)

- Свертка констант (constant-folding) – предварительное вычисление частей графа, которые могут быть определены статически

<pre>int x = 14 int y = 7-x/2 return y*(28/x+2)</pre>	<pre>int x = 14 int y = 7-14/2 return y*(28/14+2)</pre>	<pre>int x = 14 int y = 0 return 0</pre>
---	---	--

- Слияние операторов (operator fusion)

Оптимизация графа вычислений...

Уровень блока

- Тензорные компиляторы могут выполнять оптимизацию графа вычислений на трех уровнях:

– Узел

– **Блок**

– Поток данных

- Оптимизация на уровне блока включает:

– Алгебраические упрощения (algebraic simplification)

– Слияние операторов (operator fusion) – слияние нескольких преобразований в одно без сохранения в памяти промежуточных результатов



Оптимизация графа вычислений...

Уровень потока данных...

- ❑ Тензорные компиляторы могут выполнять оптимизацию графа вычислений на трех уровнях:

– Узел

– Блок

– Поток данных

- ❑ Оптимизация на уровне потока данных включает:

- Удаление общих подвыражений
- Удаление «мертвого» кода
- Статическое планирование памяти
- Преобразование размещения структур данных

Оптимизация графа вычислений...

Уровень потока данных...

- Тензорные компиляторы могут выполнять оптимизацию графа вычислений на трех уровнях:

– Узел

– Блок

– Поток данных

- Оптимизация на уровне потока данных включает:

– Удаление общих подвыражений

- Пусть требуется вычислить $C = AB$, а затем далее $D = AB + E$, что требует два умножения матриц и одно сложение
- Вместо этого можно во втором выражении заменить AB на уже вычисленное C , т.е. вычислять $D = C + E$, что требует одно умножение матриц и одно сложение

Оптимизация графа вычислений...

Уровень потока данных...

- Тензорные компиляторы могут выполнять оптимизацию графа вычислений на трех уровнях:

– Узел

– Блок

– Поток данных

- Оптимизация на уровне потока данных включает:

- Удаление «мертвого» кода

- Код называется «мертвым», если его результаты и/или побочные эффекты не используются
- Обычно «мертвый» код возникает после выполнения других оптимизаций над графом
- Удаление «мертвого» кода не влияет на конечный результат, но ускоряет вычисления

Оптимизация графа вычислений...

Уровень потока данных...

- Тензорные компиляторы могут выполнять оптимизацию графа вычислений на трех уровнях:


– Узел

– Блок

– Поток данных

- Оптимизация на уровне потока данных включает:

– Статическое планирование памяти – предварительное выделение памяти



Оптимизация графа вычислений...

Уровень потока данных...

- Тензорные компиляторы могут выполнять оптимизацию графа вычислений на трех уровнях:


– Узел

– Блок

– Поток данных

- Оптимизация на уровне потока данных включает:

– Статическое планирование памяти – предварительное выделение памяти



Оптимизация графа вычислений

Уровень потока данных

- Тензорные компиляторы могут выполнять оптимизацию графа вычислений на трех уровнях:

– Узел

– Блок

– Поток данных

- Оптимизация на уровне потока данных включает:

- Преобразование размещения структур данных (layout transformations)
 - Граф вычислений преобразуется так, чтобы использовать более эффективное внутреннее расположение данных для выполнения на целевой платформе
 - Для каждого оператора определяется предпочтительное размещение данных
 - Например, преобразование данных в строчный, столбцовый или блочный формат

ТИПОВЫЕ ПОДХОДЫ К ОПТИМИЗАЦИИ КОДА ОПЕРАТОРОВ

Общая архитектура тензорных компиляторов

ГЛУБОКАЯ
МОДЕЛЬ



TensorFlow

PyTorch



Caffe2

mxnet



ONNX

...

ФРОНТЕНД

ПРЕОБРАЗОВАНИЕ
МОДЕЛИ

ГРАФ ВЫЧИСЛЕНИЙ
(ВЫСОКОУРОВНЕВЫЙ IR)

ОПТИМИЗАЦИЯ
ГРАФА ВЫЧИСЛЕНИЙ

ОПТИМИЗИРОВАННЫЙ
ГРАФ ВЫЧИСЛЕНИЙ (IR)

ПЕРЕХОД
К УРОВНЮ КОДА

БЭКЕНД

ПРОГРАММНЫЙ КОД
(НИЗКОУРОВНЕВЫЙ IR)

АППАРАТНО-
ЗАВИСИМАЯ
ОПТИМИЗАЦИЯ КОДА

ГЕНЕРАТОР КОДА
ПОД ЦЕЛЕВУЮ ПЛАТФОРМУ

ЦЕЛЕВАЯ
ПЛАТФОРМА

CPU

(x86, ARM, RISC-V)

GPU

(NVIDIA, AMD)

ASIC

(TPU, INFERENTIA)

DSP

...

Оптимизация кода операторов...

- ❑ **Задача бэкенда тензорного компилятора** – сгенерировать исполняемый код под целевую платформу
- ❑ Эффективное выполнение кода требует использования различных аппаратно-зависимых оптимизаций:
 - Реализация операторов через использование готовых оптимизированных ядер
 - Учет особенностей подсистемы памяти на целевой платформе
 - Оптимизация циклов
 - Распараллеливание

Оптимизация кода операторов...

Использование оптимизированных ядер

- ❑ **Задача бэкенда тензорного компилятора** – сгенерировать исполняемый код под целевую платформу
- ❑ Эффективное выполнение кода требует использования различных аппаратно-зависимых оптимизаций:
 - Реализация операторов через использование готовых оптимизированных ядер
 - Возможность использовать оптимизированные под конкретную целевую платформу библиотеки
 - предоставляют как реализации операторов в целом (например, матричного умножения)
 - так и оптимизированные ядра (например, для эффективного использования векторных инструкций)
 - Возможность «подставлять» собственные реализации операторов, например, написанные в интринсиках

Оптимизация кода операторов...

Учет особенностей подсистемы памяти

- ❑ **Задача бэкенда тензорного компилятора** – сгенерировать исполняемый код под целевую платформу
- ❑ Эффективное выполнение кода требует использования различных аппаратно-зависимых оптимизаций:
 - Учет особенностей подсистемы памяти на целевой платформе
 - Память на различных целевых платформах организована по разным принципам
 - Иерархия кэш-памяти, векторные регистры на CPU
 - Несколько видов памяти на GPU
 - Генерация эффективного кода требует учета организации памяти для улучшения локальности обрабатываемых данных

Оптимизация кода операторов...

Оптимизация циклов

- ❑ Задача бэкенда тензорного компилятора – сгенерировать исполняемый код под целевую платформу
- ❑ Эффективное выполнение кода требует использования различных аппаратно-зависимых оптимизаций:
 - Оптимизация циклов
 - Разделение цикла
 - Слияние циклов
 - Векторизация цикла
 - Разворачивание цикла
 - Переупорядочивание циклов

Оптимизация кода операторов

Распараллеливание

- ❑ Задача бэкенда тензорного компилятора – сгенерировать исполняемый код под целевую платформу
- ❑ Эффективное выполнение кода требует использования различных аппаратно-зависимых оптимизаций:
 - Распараллеливание
 - Современные целевые платформы являются не только SIMD-устройствами, но и многопоточными/многоядерными
 - Технологии разработки программ поддерживают многопоточное/параллельное программирование
 - В отдельных случаях (например, распараллеливание простых циклов) могут помочь бэкенды универсальных компиляторов (например, LLVM)

Заключение

- ❑ Тензорные компиляторы обеспечивает оптимизацию и преобразование глубокой нейросетевой модели в исполняемый формат под конкретное вычислительное устройство
- ❑ Тензорные компиляторы выполняют оптимизацию вывода нейросетевой модели на двух уровнях:
 - Граф вычислений (во фронтенде компилятора)
 - Код операторов (в бэкенде компилятора)

Литература

1. Goodfellow I., Bengio Y., Courville A. Deep Learning. – MIT Press. – 2016. – [<http://www.deeplearningbook.org>].
2. Николенко С., Кадури́н А., Архангельская Е. Глубокое обучение. Погружение в мир нейронных сетей. – Изд-во «Питер». – 2018. – 476 с.
3. Учебно-образовательный курс «Современные методы и технологии глубокого обучения в компьютерном зрении (версия 2)» [http://hpc-education.unn.ru/ru/обучение/курсы/магистратура/deep_learning_in_computer_vision_2].
4. Li, Mingzhen & Liu, Yi & Liu, Xiaoyan & Sun, Qingxiao & You, Xin & Yang, Hailong & Luan, Zhongzhi & Gan, Lin & Yang, Guangwen & Qian, Depei. (2021). The Deep Learning Compiler: A Comprehensive Survey. IEEE Transactions on Parallel and Distributed Systems. 32. 708-727. 10.1109/TPDS.2020.3030548.

Авторский коллектив

- ❑ Мееров Иосиф Борисович, к.т.н., доцент, зав. каф. ВВиСП
Института ИТММ ННГУ им. Н.И. Лобачевского
- ❑ Кустикова Валентина Дмитриевна, к.т.н., доцент каф. ВВиСП
Института ИТММ ННГУ им. Н.И. Лобачевского
- ❑ Родимков Юрий Александрович, младший научный сотрудник каф. ВВиСП
Института ИТММ ННГУ им. Н.И. Лобачевского
- ❑ Сысоев Александр Владимирович, к.т.н., доцент каф. ВВиСП
Института ИТММ ННГУ им. Н.И. Лобачевского