

ODA+ML подходы для непрерывного анализа производительности суперкомпьютеров: обзор и наши подходы

Личманов Д.И., Воеводин Вад.В.,
Матвеев В.А., Антонов А.С.

Научно-исследовательский вычислительный центр МГУ имени М.В. Ломоносова

Исследование выполнено за счет гранта Российского научного фонда №25-21-00137

Operational data analytics (ODA)

- Эффективная работа СКЦ невозможна без постоянного контроля его состояния
- **Цель ODA в сфере HPC:** обеспечить постоянный сбор, хранение и анализ информации о различных аспектах поведения суперкомпьютеров для оперативного принятия решений
- Сбор и хранение – ОК. Но анализ недостаточно развит
 - 2020^(*): «Анализ ODA данных по-прежнему в основном выполняется вручную»

* Ott M., Shin W., et al. (2020). Global experiences with HPC operational data measurement, collection and analysis.

ODA: исходная классификация задач и подходов

Ввиду масштабности HPC-систем, выделяют следующие направления ODA, объединённые по целевым компонентам кластеров:

- Уровень инженерной инфраструктуры
- Уровень вычислительной аппаратуры
- Уровень системного программного обеспечения
- Уровень приложений




Схема классификации направлений по ODA

Обзор работ в ODA, использующих ML

	Инженерная инфраструктура	Вычислительная аппаратура	Системное ПО	Приложения
Supervised	Достаточно	Достаточно	Мало	Много
Unsupervised	Нет	Достаточно	Мало	Достаточно
Reinforcement	Мало	Нет	Достаточно	Нет

Число работ

- Нет
- Мало
- Достаточно
- Много

- Все направления используют Supervised, поскольку это традиционно наиболее точные методы
- Отсутствие работ по обучению с подкреплением для вычислительной аппаратуры обусловлен тем, что в основном рассматривается пара состояний “нормальное” и “аномальное”, поэтому система наград неприменима
- Отказ от unsupervised для инженерной инфраструктуры связан как с наличием большого числа размеченных исторических данных, так и со стоимостью ошибки


Актуальные задачи в рамках ODA

В рамках ODA для НРС в текущих работах можно выделить следующие направления, в которых использование ML наиболее распространено:

- Оптимизации планировщика заданий
- Управление системой охлаждения на инженерном уровне
- Определение системных и программных аномалий на вычислительных узлах
- Предсказание энергопотребления приложения
- Предсказание времени выполнения заданий и времени ожидания заданий в очереди

Применение обучения с подкреплением для оптимизации планировщика заданий

- На основе небольшого множества характеристик выполняющихся задач строится планировщик заданий, нацеленный на автоматическую адаптацию без ручной подстройки
- В качестве модели выбрана Actor-Critic модель обучения RL-агента
- За целевую метрику, являющуюся также наградой при обучении RL-агента, брался средний показатель замедления времени выполнения задачи из-за простаивания в очереди
- Учитывался механизм Backfilling
- На реальных и синтетических пулах входных задач показывает в среднем на 20% меньшее значение замедления, чем эвристические и классические ML-методы




			Системное ПО	
Reinforcement				

Zhang, D., Dai, D., He, Y., Bao, F. S., & Xie, B., 2020. RLScheduler: an automated HPC batch job scheduler using reinforcement



Оптимизация охлаждающего контура




	Инженерный уровень			
Reinforcement				

- Для каждого охлаждающего элемента настраивается его скорость (fan speed) и степень открытости водного клапана
- Используется представление датчиков и охлаждающих элементов в виде графовой структуры, обрабатываемой графовой нейронной сетью
- Формула для награды учитывает инженерные ограничения на температуру входящего в контур воздуха и на рабочую температуру сервера
- На реальной системе удалось снизить энергопотребление системы охлаждения на $\approx 15\%$

Zhan, X., Zhu, X., Cheng, P., Hu, X., He, Z., Geng, H., ... & Zhao, F., 2025. Data center cooling system optimization using offline reinforcement learning

Использование вариационных автокодировщиков для определения аномалий на узлах




- Изначально автокодировщик обучается на здоровых узлах, не имеющих аномалий
- Обнаружение аномалий проводится через сравнение reconstruction error с пороговым значением
- Для тестирования использовали синтетические аномалии: memleak, membw, crioscuru, cachesoru. Из бенчмарков - популярные VT, CG, FT и т.д.
- Используются статистические методы, позволяющие выбирать для обучения и инференса ограниченное число характеристик
- На основе малого числа данных (≈ 60 запусков на здоровых узлах) получилось добиться F1-score=0.96, реальные запуски на ≈ 1500 узлах показали F1-score=0.9

		Вычислительная аппаратура	Системное ПО	
Unsupervised				

Aksar, B., Sencan, E., Schwaller, B., Aaziz, O., Leung, V. J., Brandt, J., and Coskun, A. K., 2023. Prodigy: Towards unsupervised anomaly detection in production hpc systems

Предсказание энергопотребления приложения



- Цель фреймворка – предсказывать мощность CPU и InstRetired, чтобы в рантайме выбирать частоту CPU (DVFS), минимизируя энергию
- Для сбора характеристик используют системы мониторинга DCDB и GEOPM
- Для полученных признаков по скользящему окну подсчитывается набор статистик
- Для обучения используют мультиклассовый классификатор случайный лес
- На известных приложениях получилось добиться хорошей точности по мощности, точность относительно базового подхода выросла на 0.25
- Нет апробации на реальных данных

Ozer, G., Garg, S., Davoudi, N., Poerwawinata, G., Maiterth, M., Netti, A., & Tafani, D., 2019. Towards a predictive energy model for HPC runtime systems using supervised learning.

Статус по направлению Applications

- Несмотря на большое количество работ по направлению приложений, подавляющее большинство работ по этой теме в качестве основной задачи ставят эффективность работы НРС-системы в целом
- Почти отсутствуют работы, посвящённые эффективности приложения как такового




Наш подход к ODA+ML

- Мы хотим автоматически выявлять актуальные конкретные проблемы с производительностью в пользовательских заданиях
 - Актуальные проблемы: ошибки при предсказании переходов, использование сложной арифметики, насыщение канала к DRAM памяти
 - “Конкретные” проблемы означает, что мы понимаем, какие дальнейшие шаги по их устранению можно предпринять
 - Предполагается использование методов ML
- Конечная цель: создание универсальной рекомендательной системы для пользователей суперкомпьютера


Входные данные для предлагаемого подхода

- Основной источник данных: система мониторинга на вычислительных узлах
- Каждое задание представляется многомерным временным рядом
- Основная сложность – требуются данные от процессорных датчиков (PMU), но одновременно можно собирать только 4 аппаратных датчика(на СК Ломоносов-2)
- Использование мультиплексирования приводит к накладным расходам и снижает точность



Число промахов в LLC кэш-память в секунду

MPI IB receive data in B



Объём данных (в байтах), полученных по сети

Основная идея предлагаемого подхода

- Разработка точных формул для обнаружения определённой проблемы производительности на основании метрик, полученных от средства мониторинга
 - Для некоторых случаев есть готовые формулы (Intel Vtune, pmu-tools, ...)
- Апробация на бенчмарках с целью проверки корректности формул и замера точности
- Генерация обучающего множества
 - Моделирование различной интенсивности целевой проблемы
 - Создание разнообразного фона для неэффективного приложения
- Обучение классификатора, работающего на меньшем наборе аппаратных событий, но предоставляющего приемлемую точность

Примеры формул

False sharing rate

$$= \frac{L2_RQSTS:DEMAND_RFO_MISS}{OFFCORE_RESPONSE_0:DMND_DATA_RD + MEM_LOAD_UOPS_RETIRED:L1_MISS} \times \frac{OFFCORE_REQUESTS_OUTSTANDING:DEMAND_RFO_CYCLES}{CYCLE_ACTIVITY:STALLS_MEM_ANY} \times \frac{OFFCORE_RESPONSE_0_REMOTE_DRAM}{(OFFCORE_RESPONSE_0_LOCAL_DRAM + OFFCORE_RESPONSE_0_REMOTE_DRAM + OFFCORE_RESPONSE_0_DMND_DATA_RD_ANY)}$$

Branch misprediction rate

$$= \frac{BR_MISP_RETIRED.ALL_BRANCHES_PS}{BR_MISP_RETIRED.ALL_BRANCHES_PS + MACHINE_CLEARS.COUNT} \times \frac{UOPS_ISSUED.ANY - UOPS_RETIRED.RETIRE_SLOTS + 4 * INT_MISC.RECOVERY_CYCLES}{2 * CPU_CLK_UNHALTED.THREAD_ANY}$$



Что хотим разработать в итоге

