Нейронные сети и их практическое применение.

Лекция 10. Вычислительные платформы для реализации НС.

Дмитрий Буряк
к.ф.-м.н
dyb04@yandex.ru

Параметры вычислителей для НС

- Обучение и применение НС требует большой объем вычислений.
- Многие достижения в применении НС связаны с появлением новых вычислителей.
- Основные параметры для сравнения:
  - производительность
  - энергопотребление
- Факторы
  - разрядность: аналоговая, 1бит, …, 64бит.
  - форм-фактор – важна производительность одного чипа
  - обучение – вычисление (inference)

Ускорители для НС

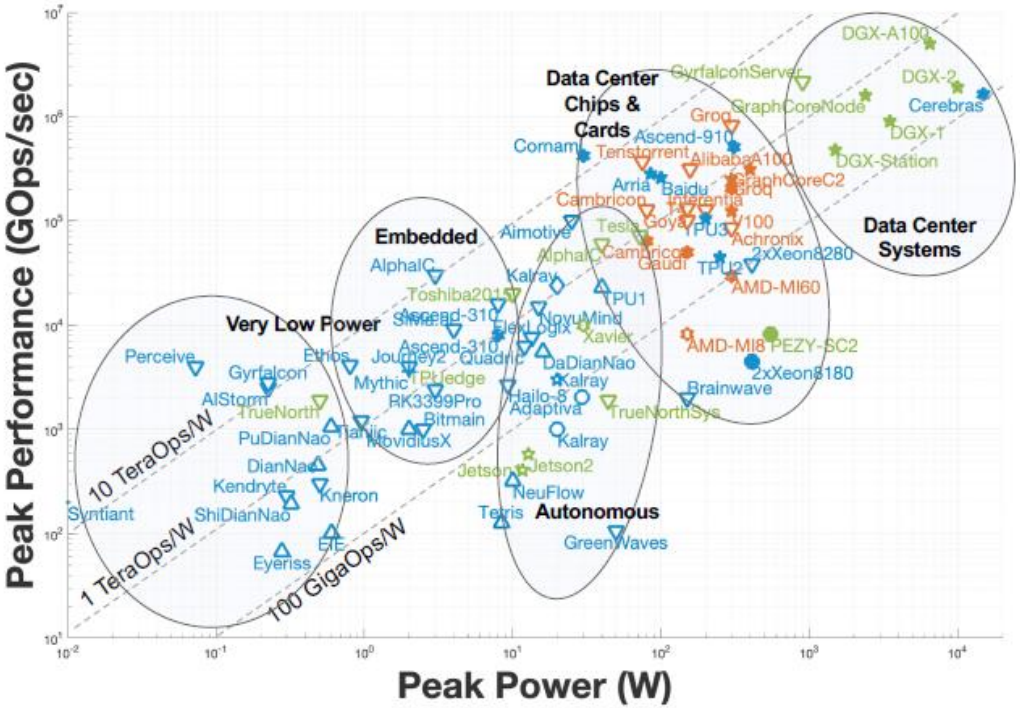

Зависимость пиковой производительности от потребляемой мощности НС ускорителей (A.Reuther, et al., Survey of Machine Learning Accelerators, 2020)

- 5 категория по типу применения
- низкое энергопотребление (обработка речи, маленькие сенсоры)
- встроенные (камеры, роботы)
- автономные (автопилоты в автомобилях)
- Чипы и карты для центров обработки данных
- Системы в центрах обработки данных

Тенденции

- ❑ Высокая плотность решений для всех областей применения
- ❑ Разнообразие архитектур и технологий
- ❑ Многие вычислители имеют эффективность > 1TeraOps/W
- ❑ Для реализации обучения требуется как минимум 100Вт
- ❑ Разнообразие решений по разрядности выполняемых вычислений
  - ▪ сложность сравнения вычислителей между собой
  - ▪ какая достаточная точность для выполнения вычислений в НС?

Чипы с низким энергопотреблением

- Предназначены только для применения НС.
- Syntiant
  - Processor-in-memory
  - веса (int4), активации (int8)
  - < 200мВт
  - Amazon Alexa – распознавание ключевой фразы.

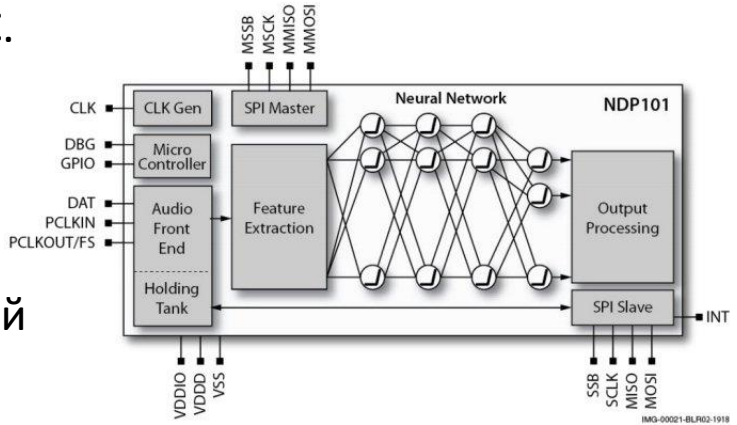

- Mythic Intelligent Processing Unit
  - аналоговая схема для реализации матричного умножения (~Syntiant)
  - цифровой управляющий процессор RISK-V
  - встроенные системы и центры обработки данных.
- AIStorm
  - вычисления выполняются «на» сенсоре в аналоговом виде (~Syntiant)
  - обработка сигналов биометрических сенсоров.

Processor-in-memory

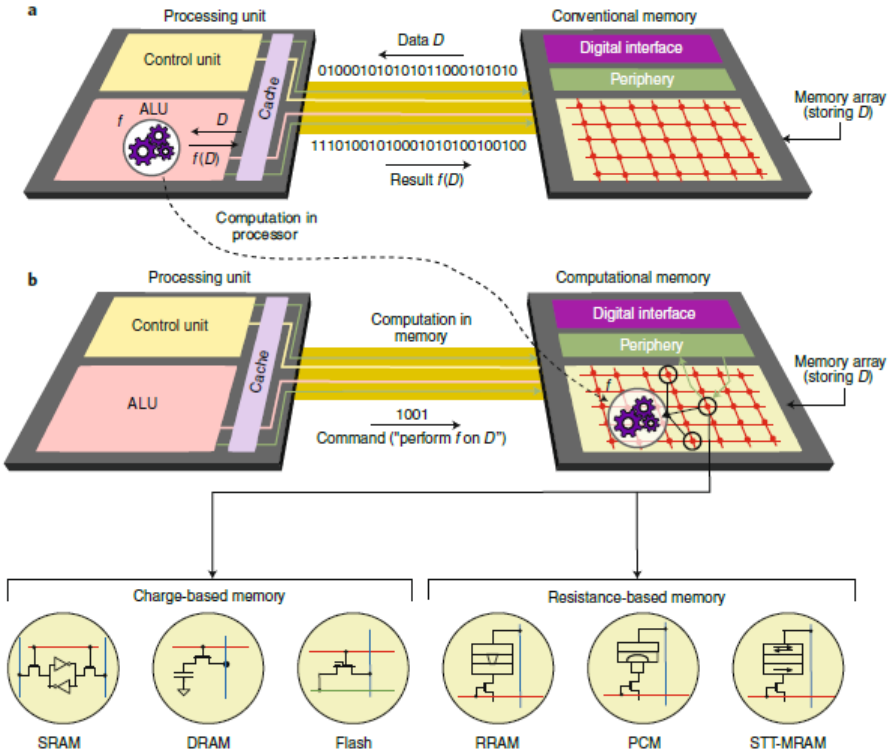

- Затраты времени и энергии на передачу данных из памяти в процессор.
- Реализация вычислений в памяти.
- Веса кодируются в запоминающих устройствах: SRAM, Flash, RRAM и т.д.
- Умножение матриц реализовано через прохождение аналогового сигнала (тока) через запоминающие устройства.

Чипы для встроенных решений

- Встроенные приложения с высокой производительностью при небольшом энергопотреблении и малом форм-факторе: обработка видео, небольшие БЛА и роботы.
- ARM, процессоры Etos
  - Применение MAC Compute Engines (MCEs)
  - Производительность MCE: 1TOP/s на 1GHz.
- Gyrfalcon, Lightspeeur
  - processor-in-memory
  - обработка видео
  - применение в серверах обработки данных (128 чипов).

Автономные системы

- Системы помощи водителю, автопилот, роботы.
- Huawei HiSilicon Ascend 310
  - CPU + ускоритель для вычислений AI
  - Высокая производительность, как с int8, так и с fp16.
- Tesla Full Self-Driving (FSD) Computer chip
  - 3 quard Cortex-A72 + Mali G71 + 2 Neural Processing Unit
  - применение в беспилотных системах (уровни автономности 4 и 5).

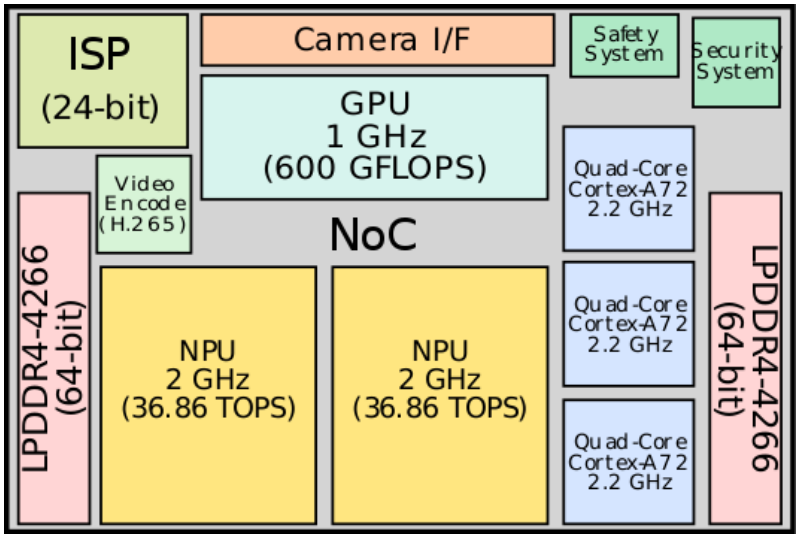

Автономные системы. Nvidia Jetson

- Встраиваемые системы
  - небольшой размер;
  - низкий уровень энергопотребления;
  - высокопроизводительные вычисления.
- Модули NVIDIA Jetson Tx2
  - GPU: 256 ядер CUDA (Pascal);
  - CPU: ARM 6 ядер;
  - Память: 8Гб.
- Модули NVIDIA Xavier
  - GPU: 256 ядер CUDA (Volta) + 64 tensor cores
  - CPU: ARM 8 ядер;
  - Память: 32Гб;
  - 32 TOPs, 10Вт.

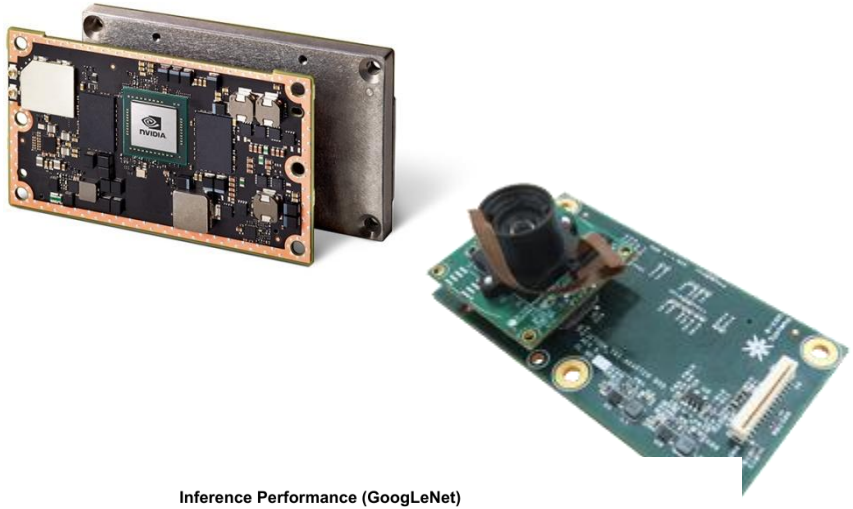

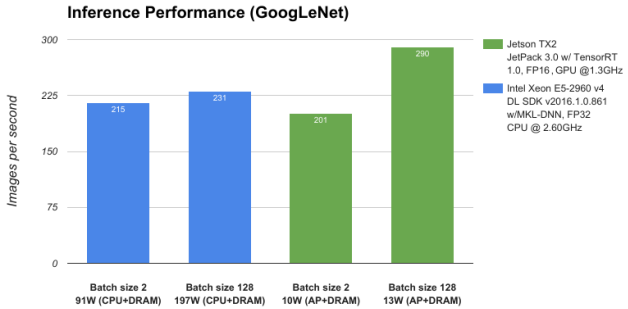

Чипы для центров обработки данных

- Применение различных технологий: на основе CPU, программируемые FPGA, с применением GPU.
- Intel Xeon.
- Preferred Networks, PFN-MN-3
  - 4 чипа + 32Гб RAM
  - Каждый чип имеет 4 матрицы из 2048 вычислительных элементов и 512 блоков матричных вычислений.
  - Поддержка вычислений fp16;
  - Применяются в одном из японских суперкомпьютеров (exascale).
- Intel Arria
  - Intel Xeon + Altera Arria FPGA
  - Загрузка FPGA конфигурации, НС вычисляется на FPGA

Чипы для центров обработки данных. GPU карты

- NVIDIA (Ampere, Turing,HGX)
  - Тензорные ядра
    . Предназначены для умножения матриц за такт;
    . Volta, 4x4, fp16 (64GEMM) → Ampere (256GEMM)
    . Обработка разреженных матриц: Sparse Tensor Cores;
  - Turing – эффективное вычисление HC;
  - HGX – до 16 A100 на одной карте
- AMD (Instinct)
  - MI100;
  - MI250 (128Гб, 2 GPU чипа, 560Вт, 95.7 TFLOPS матричная производительность).

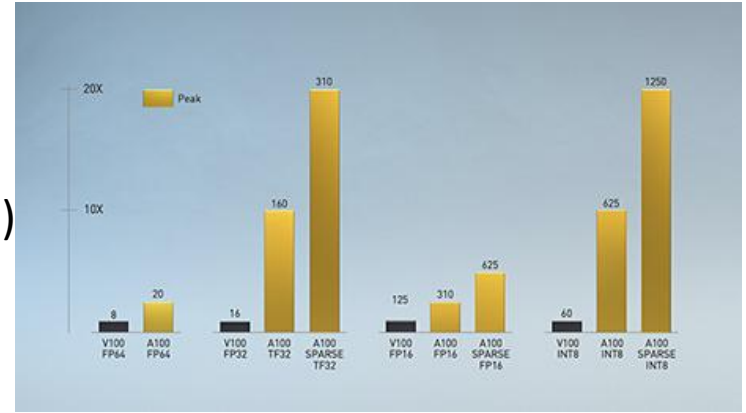

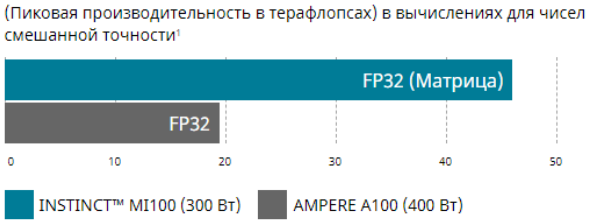

Сравнение MI100 и A100 на задачах машинного обучения (https://www.amd.com/ru/products/server-accelerators/instinct-mi100)

Специальные чипы для центров обработки данных.

- Разработаны специально для обучения и применения НС
  - Последовательность вычислений в НС детерминирована;
  - Проектирование HW с учетом вычислений и обращений к памяти в НС
  - Применение в облачных платформах
- Amazon Web Services: Inferentia chip
- Baidu: Kunlun
- Google: TPU (tensor processing units)
  - Появление 2015г.
  - Архитектура конвейерного массива – уменьшить обращение к памяти при умножении матриц;
  - Меньше энергопотребление и размер чипа.

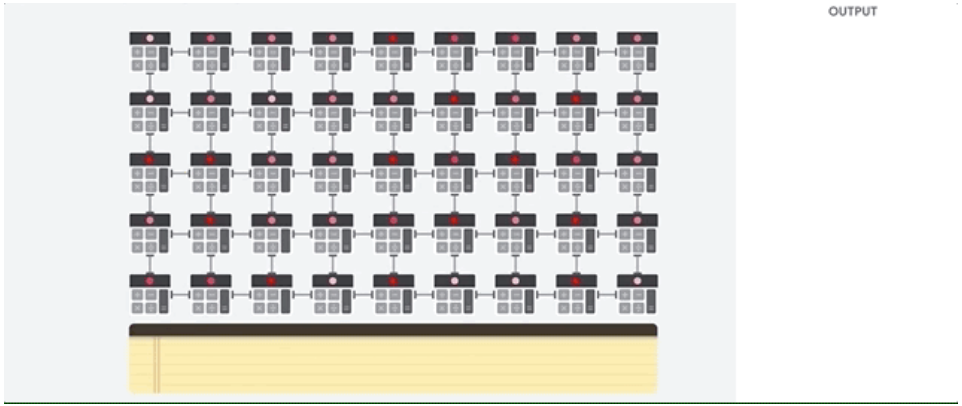

https://habr.com/ru/post/422317/

HPC системы для центров обработки данных

- Объединение нескольких GPU на базе серверного решения.
- Набор узлов: CPU, несколько GPU, высокоскоростной интерфейс (например, NVLink).
- Соединение между узлами: Infiniband/Ethernet
- ПО для реализации распределенных вычислений

- Области применения
  - искусственный интеллект
  - облачные центры обработки данных
  - корпоративные вычисления
  - высокопроизводительные вычисления

Зачем HPC для НС

- Уменьшение времени на обучение НС.
- Возможность построения больших моделей
  - увеличенный размер пакета;
  - увеличенная размерность входных данных;
  - больше параметров в модели.

- Победитель ILSVRC -2017 – SENet
  - Реализация распределенного обучения на 64 GPU: размер пакета 2048 изображений.
- Обучение сети для обработки гравитационных волн
  - HAL кластер (64 GPU NVIDIA V100): сокращение времени обучения с 1 месяца до 12.4ч.

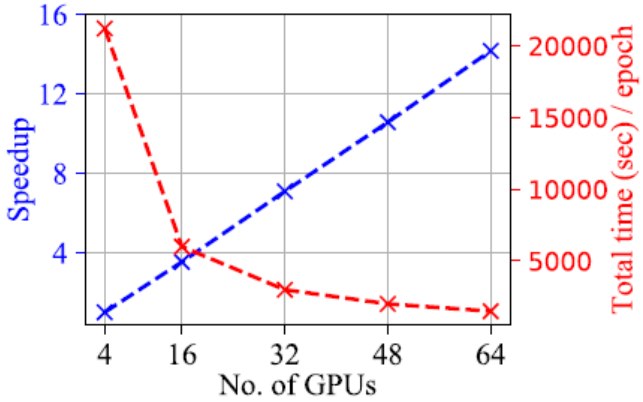

Время обучения сети для анализа гравитационных волн (E.A. Huerta, et al., Convergence of artificial intelligence and high Performance computing on NSF-supported cyberinfrastructure, 2020)

Семейство DGX

- DGX-1, DGX-2, DGX A100.
- Параметры DGX A100
  - 5 Pflops на задачах AI;
  - 8xNVIDIA A100 Tensor Cores GPU;
  - Размер общей памяти GPU: 320Gb;
  - CPU: Dual AMD Rome 7742 (128 cores), 2.25GHz;
  - Обмен GPU-GPU: 600GB/s (12 NVLinks/GPU);
  - Между узлами: HDR Infiniband, 200GB/s;
  - Общий объем памяти: 1TB.

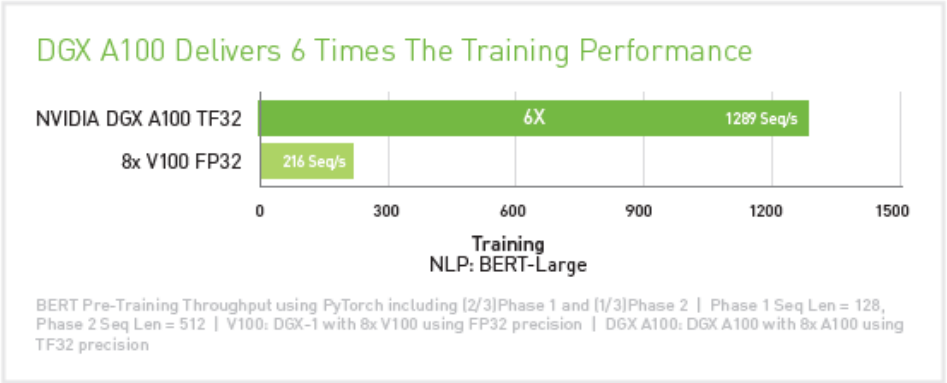

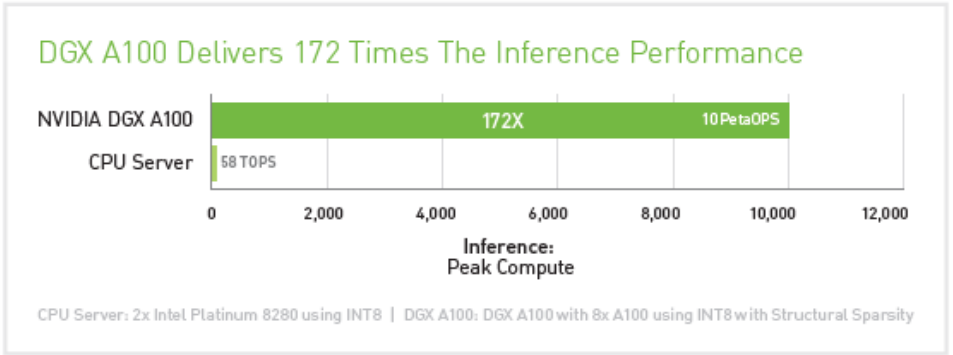

NVIDIA DGX Pod

- Масштабируемая архитектура ЦОД для задач ИИ
  - Стойки серверов DGX;
  - Сетевое оборудование;
  - Устройства хранения данных;
  - Электропитание, охлаждение;
  - Полный программный стек для ИИ.
- SATURNV – пример реализации на основе DGX Pod (116 в Top500, 11.2021)
- NVIDIA DGX SuperPod – второе поколение.

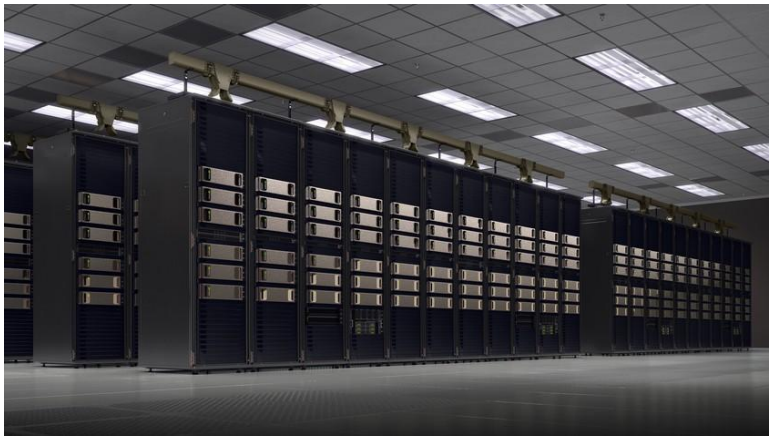

Вычислительный центр NVIDIA SATURNV

Платформа IBM Power

- Базовая платформа для HPC серверов
  - Анализ больших данных, высокопроизводительные вычисления, ИИ;
  - Масштабируемость: сервер → суперкомпьютер

- IBM Power9
  - коммутаторные межсоединения;
  - аппаратная поддержка ускорителей;
  - расширенная система команд (ИИ, когнитивные вычисления);
  - высокопроизводительные вычисления.

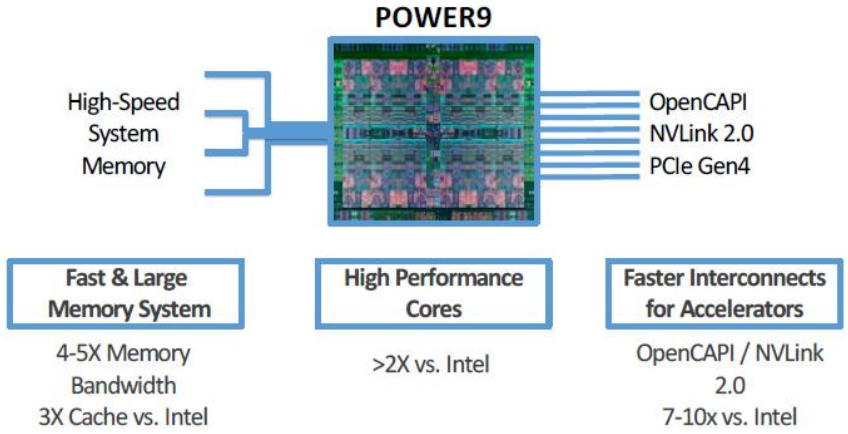

- IBM Power10
  - Вычислительная эффективность до 20 раз выше чем Power9;
  - Энергоэффективность до 3 раз выше, чем Power9;

HPC на базе IBM Power9

- IBM AC922 Power System
  - Технология объединения памяти CPU и GPU;
  - Поддержка больших моделей, больших наборов данных;
  - Ускорение 95% от линейного на задачах глубокого обучения.

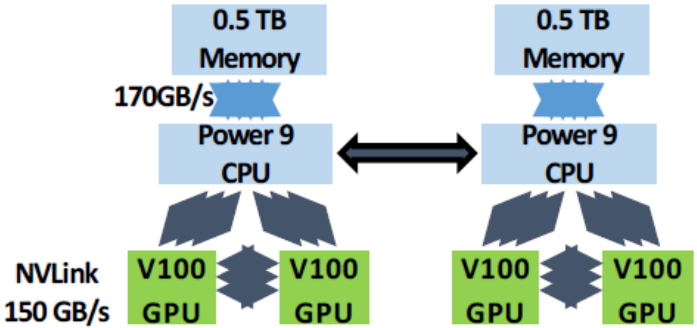

- Сравнение с Xeon 2640
  - Ускорение передачи данных CPU-GPU ~5 раз;
  - Увеличение скорости вычислений в 3.8 раз.

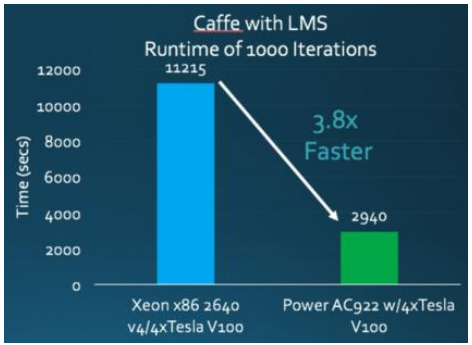

IBM PowerAI

- PowerAI – набор дистрибутивов популярных библиотек для глубокого обучения, оптимизированных для серверных решений IBM;
  - TensorFlow, Caffe, Torch, …;
- Distributed Deep Learning (DDL) – коммуникационная библиотека (на базе MPI) для эффективной реализации распределенных вычислений;
  - Близкое к линейному масштабирование (до 256 GPU);
- Large Model Support (LMS) – совместное использование основной памяти и памяти GPU при обучении больших моделей.