Направления

- Высокопроизводительные вычисления (high-perfomance computation)
- Облачные технологии и технологии распределенной обработки (map-reduce)
- Обработка больших данных (data mining, big data, ..)
- Интернет вещей (IoT)

Высокопроизводительные вычисления

- выбор вычислительной модели;
- использование эффективного вычислительного алгоритма;
- использование оптимальных структур данных и средств кодирования;
- использование оптимизированных библиотек;
- оптимизация при компиляции программы;
- оптимизация готовой программы на основе её выполнения;
- параллельное программирование;

Внедрение параллельного программирования

- Применение компиляторов, автоматически распараллеливающих фрагменты кода
- Применение специализированных библиотек, реализующих параллельные алгоритмы вычислений
- Применение специализированных пакетов расчета
- Применение технологий параллельного программирования.

Автоматически распараллеливающие компиляторы

- Некоторые компиляторы позволяют выполнять автоматическое распараллеливание фрагментов кода программы. Б
- Большинство распараллеливающих компиляторов работают со специализированными языками, которые упрощают задачу выделения независимых участков кода.
- Компиляторы универсальных языков высокого уровня (C/C++) позволяют распараллеливать только участки с явной независимой обработкой (например, циклическая обработка).

```
for (int i = 0; i < N; i++)
 a[i] = b[i] + c[i];
```

```
for (int i = 0; i < N; i++)
 x[a[i]] = x[b[i]] + x[c[i]];
```

Классификация вычислительных систем

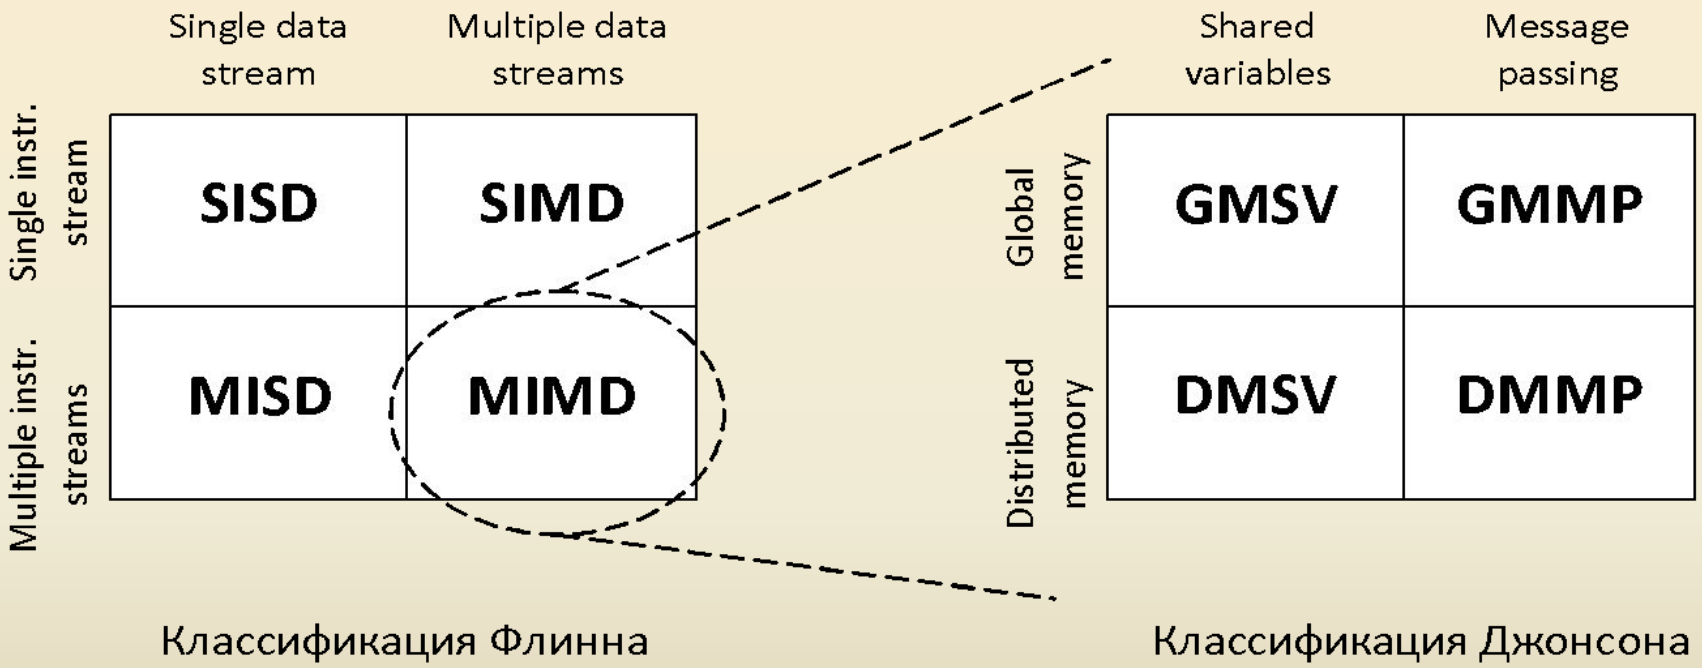

Классификация Флинна

Классификация Джонсона

Распределенные системы

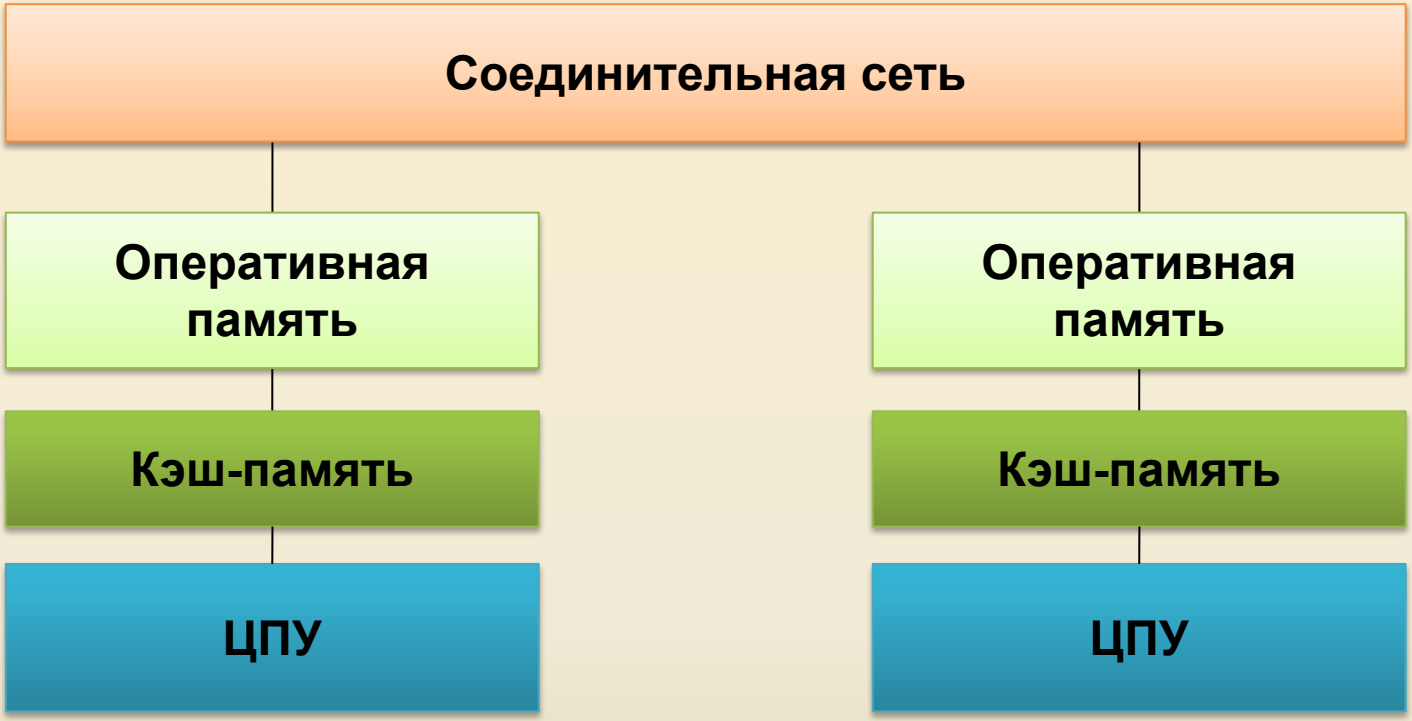

Для взаимодействия, как правило, используются интерфейсы передачи сообщений (MPI, WCF, ..)

Многопроцессорные системы

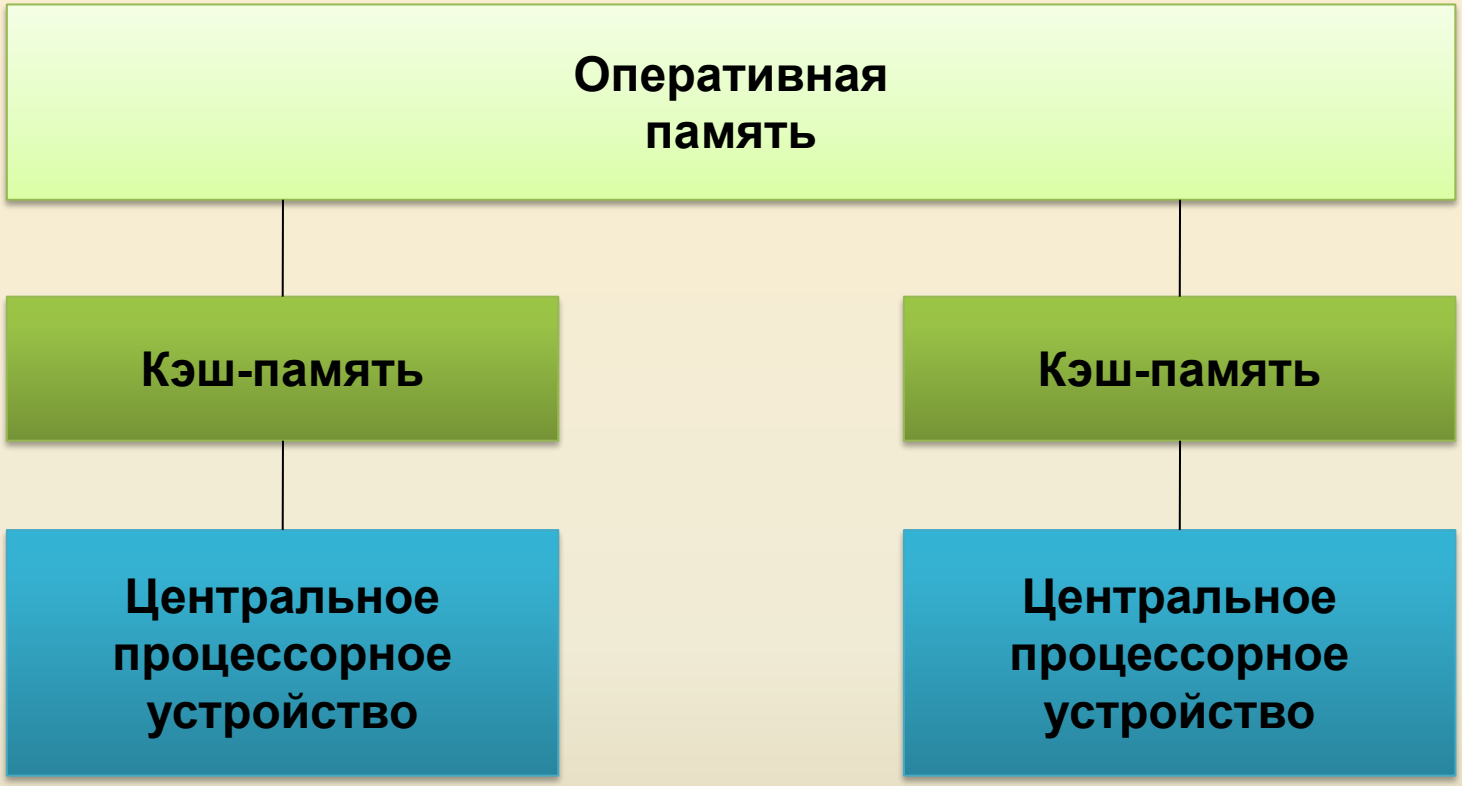

Системы с общей памятью (shared memory systems), многоядерные системы

Технологии параллельного программирования

Распределенные системы	Многопроцессорные системы	Гибридные системы
• Стандарт MPI • Erlang • Go	• Стандарт OpenMP • Task Parallel Library (C#) • Intel Cilk Plus • Intel TBB	• Nvidia CUDA • OpenACC • OpenCL • MS AMP C++ • MC#

Технологии ПП для многоядерных систем

- Низкоуровневые средства (потоки)
  - Библиотеки для C/C++: pthreads, Windows Threads, boost::thread, std::thread (C++ 11);
  - Библиотеки для C#, Java, Python, ..
- Высокоуровневые средства (задачи)
  - Стандарт OpenMP (C++, Fortran)
  - Расширение Intel Cilk Plus (C++)
  - Библиотека Threading Building Blocks (C++)
  - Библиотека Parallel Primitives Library (C++)
  - Библиотека Task Parallel Library (C#)
  - ..

Потоки vs. задачи

- Работа с потоками предполагает:
  - декомпозиция задачи на части;
  - создание и управление потоками;
  - синхронизация потоков;
  - балансировка нагрузки потоков
  - агрегирование результатов;

- Работа с задачами упрощает разработку за счет **планировщика**, который самостоятельно подбирает оптимальное число потоков, выполняет декомпозицию и агрегирование данных, динамически балансирует нагрузку

Стандарт OpenMP

- Стандарт для многопроцессорного программирования на языках C/C++/Fortran
- Развивается с 1997 г. Последнее обновление: версия 4.5 (2015 г.)
- Поддерживается большинством компиляторов (Visual Studio, Intel C++, gcc, ..)
- Средства распараллеливания – директивы

```
// Параллельный цикл с OpenMP
    #pragma omp parallel for
    for (int i = 0; i < n; i++)
        y[i] = a * x[i] + y[i];
```

Intel Cilk Plus

- Расширение для языка C++ от Intel
- Средства распараллеливания: 3 ключевых слова, расширенная векторная нотация, гиперобъекты,..

```
// Параллельный цикл
cilk_for (int i = 0; i < n; i++)
        y[i] = a * x[i] + y[i];
```

```
// Расширенная индексная нотация:
 y[0:n] = a * x[0:n] + y[0:n];
```

Библиотека Intel TBB

- Кроссплатформенная библиотека шаблонов C++, разработанная компанией Intel для параллельного программирования.
- Включает типовые шаблоны распараллеливания, структуры данных для многопоточных сценариев, средства синхронизации

```
 tbb::parallel_for(
    tbb::blocked_range<int>(0, n),
    [&](tbb::blocked_range<int> r) {
      for (int i=r.begin(); i != r.end(); ++i)
         y[i] = a * x[i] + y[i];
    }
);
```

Технологии программирования распределенных систем

- Интерфейсы передачи сообщений (MPI, WCF, ..)
- Библиотеки-оболочки над интерфейсом MPI (OO-MPI, boost mpi, MPI.NET, Global Arrays, ..)
- Языки с встроенной поддержкой обмена сообщениями (Go, Erlang, Chapel, X10, ..)

- Технологии MapReduce (apache hadoop, microsoft hdinsight, ..)

MPI-программа

```
int rank;
float msg = 0.0;
MPI_Status status;
MPI_Init();
MPI_Comm_rank(MPI_COMM_WORLD, &rank);
if (rank == 0)
{
   msg = 3.14;
   printf("Sending message..\n", size);
   MPI_Send(&msg, 1, MPI_FLOAT, 1, 0, MPI_COMM_WORLD);
}
else if (rank == 1)
{
   MPI_Recv(&msg, 1, MPI_FLOAT, 0, 0,
                        MPI_COMM_WORLD, &status);
   printf("Received message: %f\n", msg);
}
MPI_Finalize();
```

MPI.NET

```
static void Main(string[] args)
  {
     using (new MPI.Environment(ref args))
     {
        Intracommunicator comm = Communicator.world;
        string name = MPI.Environment.ProcessorName;
        string[] names = comm.Gather(name, 0);
        if (comm.Rank == 0)
        {
           Array.Sort(names);
           foreach(string host in names)
              Console.WriteLine(host);
        }
     }
  }
```

Программирование GPU

- Современные графические процессоры (GPU) представляют собой гибко программируемые массивно-параллельные вычислительные устройства с высоким быстродействием и большим объемом собственной памяти
- Основные преимущества применения графических процессоров для параллельных вычислений связаны: с энергетической эффективностью, максимальным соотношением производительности к цене, высоким быстродействием
- Графический процессор является сопроцессором центрального процессора, обладает возможностью параллельного выполнения огромного количества отдельных нитей

Организация GPU-устройств (G80)

- 8 поточных процессоров (SP)
- Каждый SP-процессор исполняет 32 потока
- 2 специальных процессора SFU для сложных функций

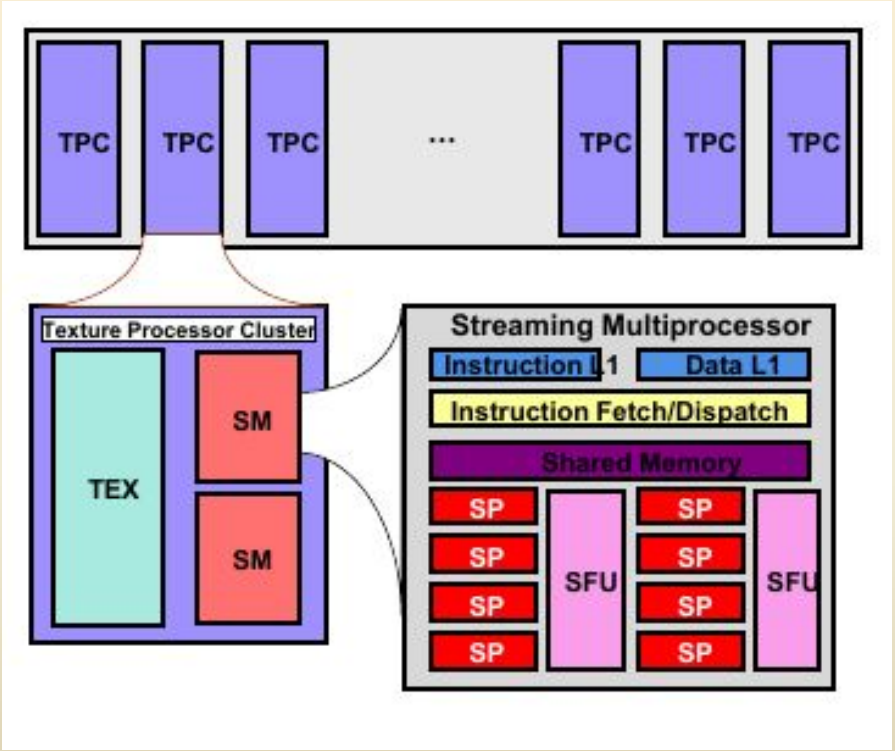

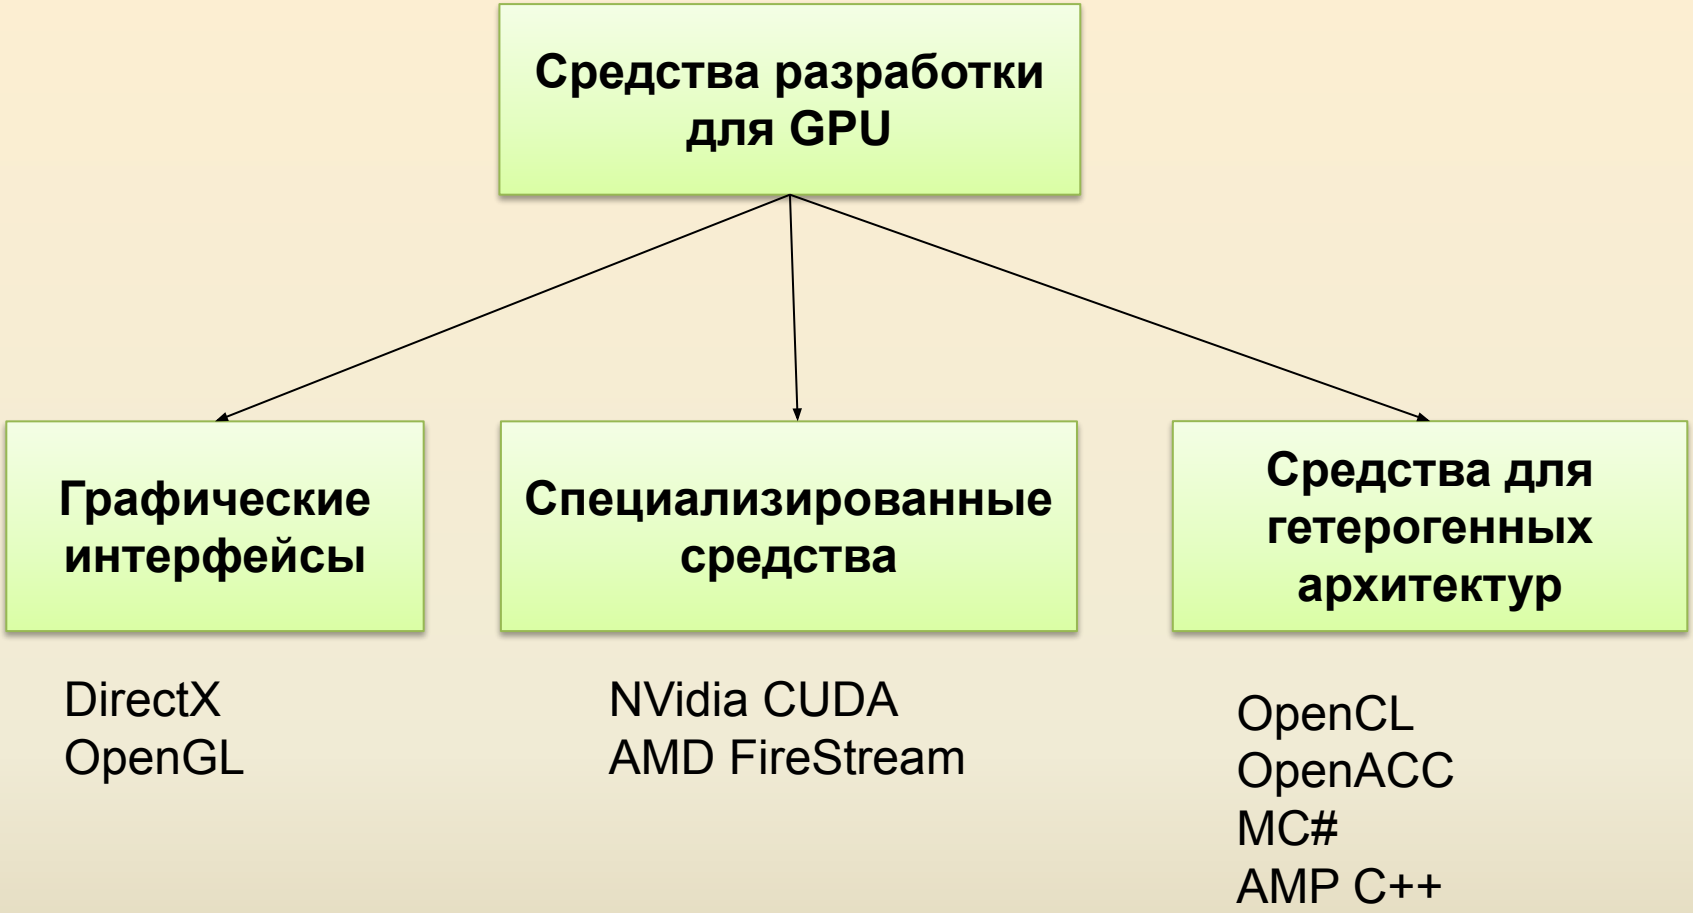
Средства разработки для GPU
Графические интерфейсы
Специализированные средства
Средства для гетерогенных архитектур
DirectX
OpenGL
NVidia CUDA
AMD FireStream
OpenCL
OpenACC
MC#
AMP C++

Графические интерфейсы

- Данные средства были разработаны для решения задач визуализации, поэтому при их использовании для задач общего назначения появляется «привязка к графике».
- Используя графические интерфейсы (OpenGL и Direct3D), осуществляется подготовка текстур, содержащих необходимые входные данные, и через операцию *рендеринга* на графическом процессоре запускается программа для их обработки
- Недостатки данного подхода связаны с тем, что использование возможностей GPU происходит через интерфейсы, ориентированные на работу с графикой. Так в графических API полностью отсутствует возможность взаимодействия между параллельно обрабатываемыми пикселами.

Специализированные интерфейсы

- Специализированные средства от производителей позволяют разрабатывать программу на диалекте языка C и отказаться от специфической терминологии компьютерной графики.
- Библиотеки не универсальны: они разработаны для поддержки оборудования одного производителя, и перенос программы с одной архитектуры на другую может повлечь значительные изменения кода (также это касается некоторых техник оптимизации, специфичных для одной из платформ).

Средства гетерогенного программирования

- Данные средства реализуют модель гетерогенных вычислений, которая предполагает возможность использования в одной программе ресурсов центральных процессоров (или ядер одного процессора) и графических процессоров разных производителей
- К этой группе относятся: платформонезависимые стандарты OpenCL, OpenACC, библиотеки и расширения для высокоуровневых языков (AMP C++, MC#, Thrust Parallel Library, OpenTK).

Интерфейс CUDA

- Технология CUDA (Compute Unified Device Architecture) представляет собой архитектуру параллельных вычислений на графических процессорах компании NVIDIA.
- Данная технология включает в себя расширения стандартного языка C (с элементами C++) для разработки параллельных приложений на графическом процессоре, набор оптимизированных библиотек (быстрое преобразование Фурье, базовые операции линейной алгебры и др.), специальный драйвер CUDA для вычислений с быстрой передачей данных между центральным и графическим процессором, а также драйвер CUDA, взаимодействующий с графическими интерфейсами OpenGL и Direct3D.

Программирование GPU с помощью CUDA

Общая схема исполнения программ

1. Подготовка данных на CPU
2. Копирование данных в память GPU
3. Выполнение вычислительных функций (ядер) на GPU
4. Копирование результатов работы в память CPU.

```
// Определение функции-ядра
__global__ void matAdd ( float * A, float * B, float * C, int N)  {
    int i = blockIdx.x * blockDim.x + threadIdx.x;
    int j = blockIdx.y * blockDim.y + threadIdx.y;
    if ( i < N && j < N )
      C [i * N + j] = A [i * N + j] + B [i * N + j];
}
```

“Hello-world” на CUDA

```
// Выделяем память на GPU для копий переменных a, b, c
cudaMalloc((void **)&d_a, size);
cudaMalloc((void **)&d_b, size);
cudaMalloc((void **)&d_c, size);
// Копируем данные на устройство
cudaMemcpy(d_a, &a, size, cudaMemcpyHostToDevice);
cudaMemcpy(d_b, &b, size, cudaMemcpyHostToDevice);
// Запускаем функцию ядра на графическом процессоре
add<<<N,1>>>(d_a, d_b, d_c);
// Сохраняем результаты на хосте
cudaMemcpy(&c, d_c, size, cudaMemcpyDeviceToHost);
// Очищаем память
 cudaFree(d_a); cudaFree(d_b); cudaFree(d_c);
```

Стандарт OpenCL

- OpenCL (Open Computing Language) является открытым межплатформенным стандартом для параллельных вычислений на современных процессорах разных типов.
- Основное внимание в стандарте сосредоточено на поддержке многоядерных центральных процессоров и графических ускорителей.
- Стандарт предоставляет программистам переносимый и эффективный доступ ко всей мощи гетерогенных вычислительных платформ.

Стандарт OpenACC

- Стандарт для упрощения программирования GPU разных производителей

  “OpenACC: More Science Less Programming“

- Поддерживается компиляторами: PGI Accelerator Compiler, Cray Compilation Environment, PathScale Enzo Compiler. Ограниченная поддержка в GCC 6.0
- Основные директивы: #pragma acc parallel, #pragma acc kernels, #pragma acc data, #pragma acc loop, #pragma acc cache, #pragma acc update, #pragma acc declare, #pragma acc wait

Пример OpenACC-функции

```
// Умножение вектора на число
void VectorMultiplication(int n, float a, float *x, float * y) {
      #pragma acc kernels
      for (int i = 0; i < n; ++i)
        y[i] = a * x[i];
}
// Вычисление числа Пи
double CalcPi(long N) {
   double pi = 0.0f; long i;
   #pragma acc parallel loop reduction(+:pi)
   for (i=0; i<N; i++) {
      double t= (double)((i+0.5)/N);
      pi +=4.0/(1.0+t*t);
   }
   return pi;
}
```

Вычисления на GPU на других языках

- Для языка C#: Cloo, OpenCL.NET, CUDA.NET
- Для языка F#: AleaGPU, Brahma
- Для языка Python: Anaconda Accelerate, PyCuda,
- ..

https://developer.nvidia.com/language-solutions

Облачные вычисления

- Комплексное решение, предоставляющее компьютерные ресурсы в виде сервиса.
- Ресурсы могут предоставляться через Интернет или локальную сеть и доступны на различных платформах и устройствах.
- В качестве основных ресурсов выступают: вычислительные мощности (аппаратные ресурсы), программное обеспечение, данные.
- Компьютеры в облаке настроены на совместную работу, а различные приложения используют совокупную вычислительную мощность так, как будто выполняются на одиночной системе.

Уровни облачных вычислений

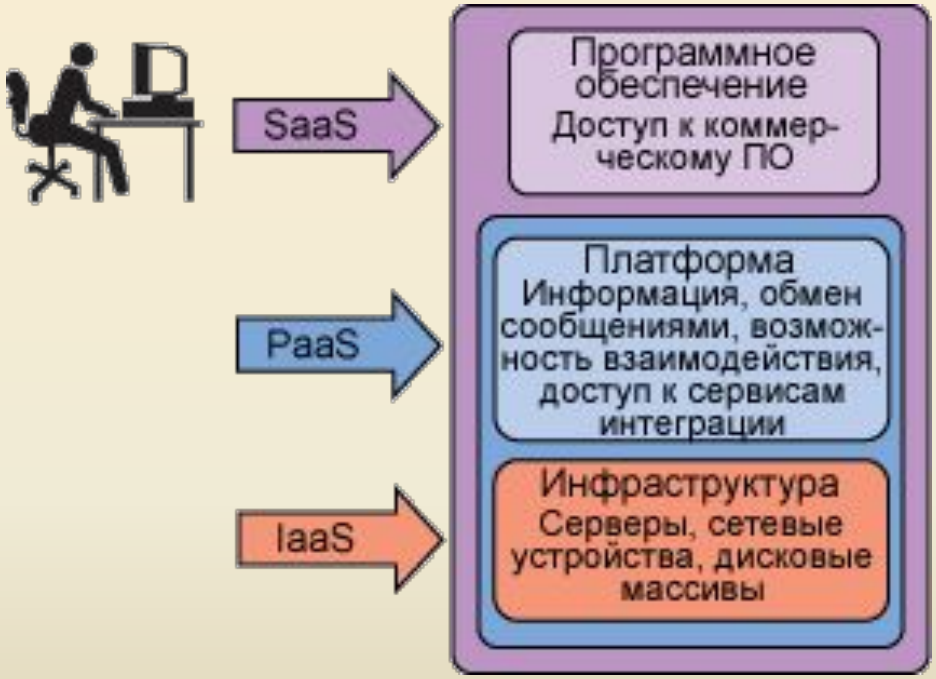

В облачной инфраструктуре выделяют несколько уровней, каждый из которых обеспечивает тот или иной вид сервиса для потребителей: уровень инфраструктуры, уровень платформы и уровень приложений.

Уровень инфраструктуры

- Уровень инфраструктуры или уровень IaaS (*Infrastructure as a Service — инфраструктура как сервис*) предоставляет аппаратные средства и системное программное обеспечение в качестве ресурса Ресурсы: серверы, системы хранения данных, клиентские системы, сетевое оборудование. Системное программное обеспечение включает операционные системы, средства виртуализации, автоматизации.
- Использование технологий уровня IaaS избавляет клиента (предприятие) от необходимости поддержки сложных инфраструктур центров обработки данных, клиентских и сетевых инфраструктур. Как правило, пользователь сервисов инфраструктуры оплачивает реально используемые ресурсы: серверное время, дисковое пространство, сетевую пропускную способность и т. д.
- Примерами облачных сервисов, предоставляющих инфраструктурные услуги: Elastic Compute Cloud (EC2), Simple Storage Service (S3), GoGrid, Enomaly, Eucalyptus. Сервис EC2 позволяет арендовать образы виртуальных машин. Сервис S3 предназначен для хранения данных.

Уровень платформы

- Уровень платформы или уровень PaaS (*Platform as a Service — платформа как сервис*) — это предоставление интегрированной платформы для разработки, тестирования, развертывания и поддержки приложений.
- Для разворачивания приложений разработчику не нужно приобретать оборудование и программное обеспечение, нет необходимости организовывать их поддержку.
- Существующие технологии уровня PaaS, как правило, позволяют использовать определенные языки разработки. Примерами облачных технологий, интегрирующих среду для разработки, являются: платформа Google AppEngine (разработка на языках Java, Python, Go), Engine Yard (Ruby), PHP Fog, Stackato (Perl), Cloudbees (Java), Windows Azure (.NET, Java, PHP, Ruby), OpenShift (Java, Ruby, PHP, Python).

Уровень программного обеспечения

- Уровень приложений или уровень SaaS (*Software as a Service — программное обеспечение как сервис*) — модель развертывания приложения, которая подразумевает предоставление приложения конечному пользователю как услуги по требованию.
- Приложение приспособлено для удаленного использования, одним приложением могут пользоваться несколько клиентов.
- Наибольшим спросом среди SaaS-приложений пользуются: почта, коммуникации, антивирусные программы, программы управления проектами, дистанционное обучение, CRM, хранение и резервирование данных. Распространенными SaaS-сервисами являются: Gmail, Office 365, Google Apps, Salesforce.com.

Типы развертывания

- *Частное облако (private cloud)* — используется для предоставления сервисов внутри одной компании, которая является одновременно и заказчиком и поставщиком услуг.
- *Публичное облако* — используется облачными провайдерами для предоставления сервисов внешним заказчикам.
- *Смешанное (гибридное) облако* — это комбинация открытого и закрытого облака.

Достоинства и недостатки облачных решений

- Среди основных преимуществ технологий облачных вычислений можно выделить: доступность и открытость, экономичность, простота использования, гибкость и мастшабируемость.
- Среди недостатков облачных технологий можно выделить: необходимость постоянного соединения с сетью, возможность проблем с безопасностью данных, ограниченная функциональность облачных приложений, зависимость от компании, предоставляющей сервисы облачной инфраструктуры.

Анализ данных

- **Data mining** - процесс извлечения закономерностей (шаблонов) в больших массивах информации.
- “DM - процесс обнаружения в сырых данных ранее неизвестных, нетривиальных, практически полезных, доступных интерпретации знаний, необходимых для принятия решений в различных сферах человеческой деятельности”
- Варианты перевода: анализ данных (АД), обнаружение знание (knowledge discovery), интеллектуальный анализ данных, раскопка данных, добыча данных, ..
- Связанные и смежные области: машинное обучение (machine learning), big data, data science, ..

Программные продукты анализа данных

Категория	Свободное	Платное
Статистические пакеты		StatSoft, STATISTIKA, S-Plus
Специализированные инструменты	GATree	CART, Viscovery SOMine, WhizWhy
Универсальные пакеты	KNIME*, Orange, KEEL, Weka, RapidMiner*	IBM, Oracle, Micrisoft SQL, Deductor, PolyAnalyst
Языки разработки	R, Python+	Xelopes

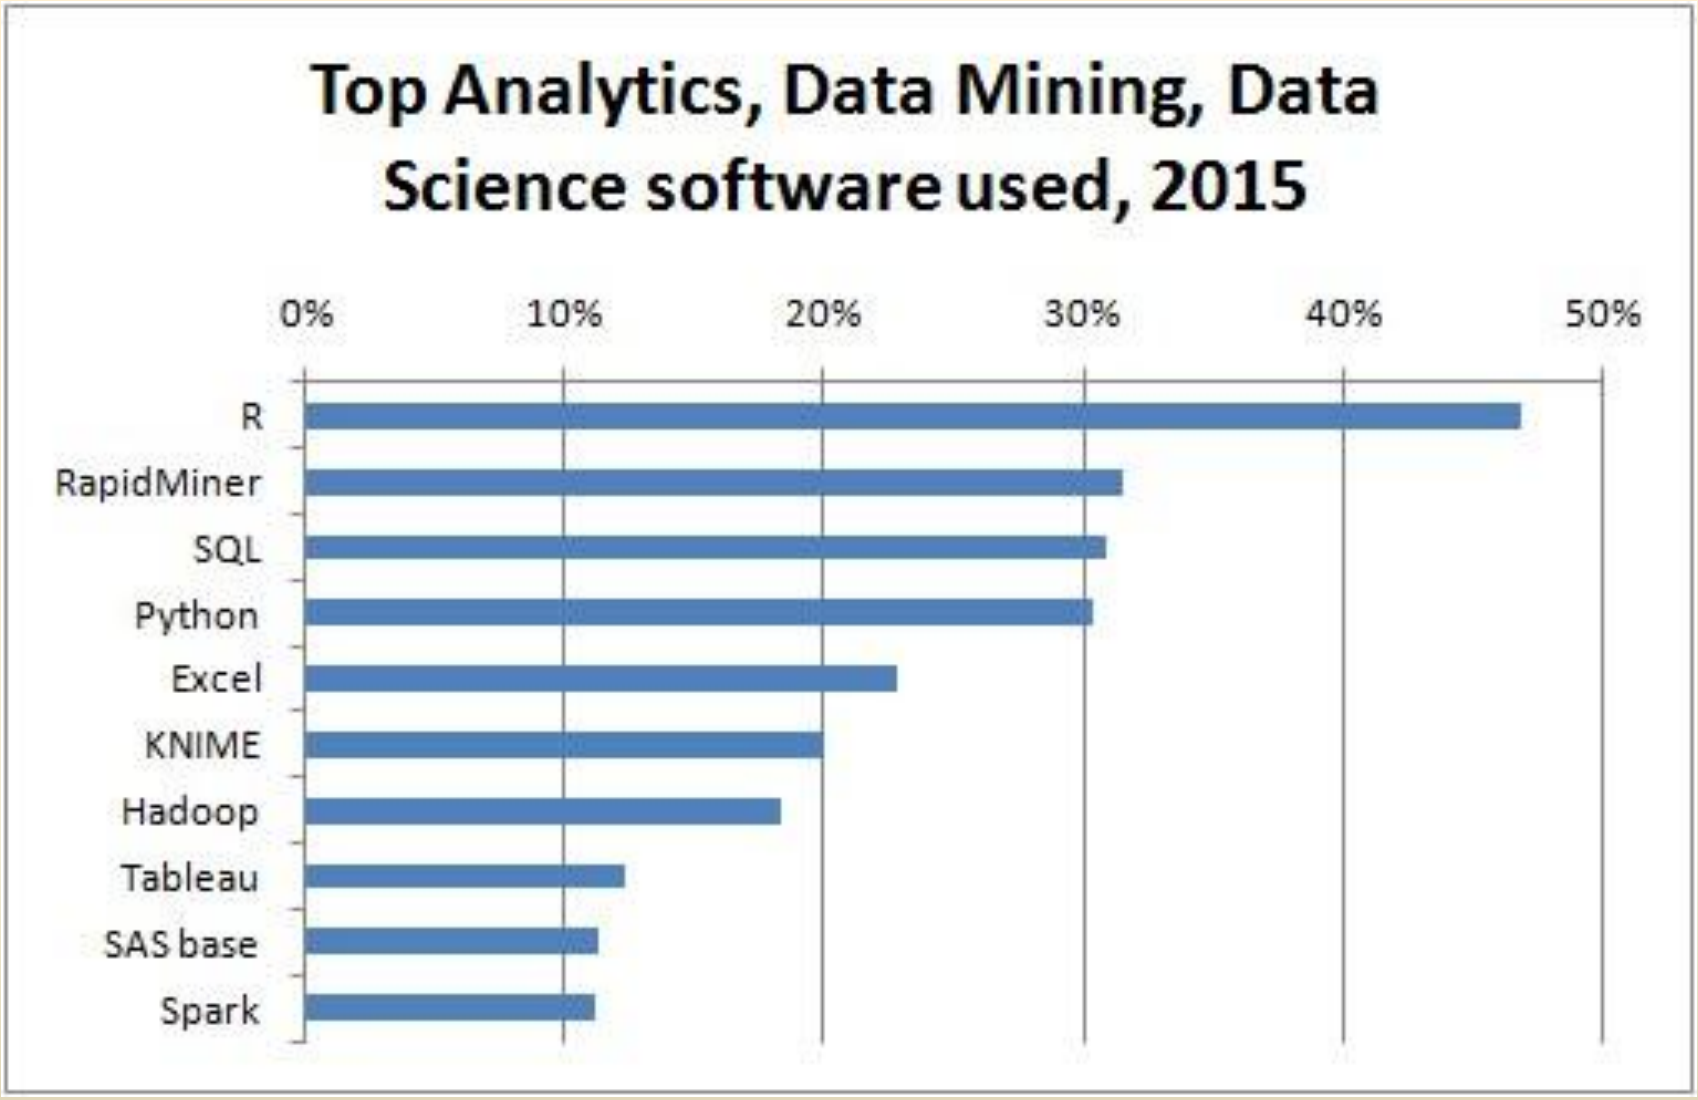

http://www.kdnuggets.com/polls/2015/analytics-data-mining-data-science-software-used.html

Магические квадранты для продвинутой аналитики, февраль 2015