Разработка параллельных программ для систем с распределенной памятью

Создание распределенных приложений

Основы технологии MPI

Особенности систем с распределенной памятью

СИСТЕМЫ С РАСПРЕДЕЛЕННОЙ ПАМЯТЬЮ

Распределенные системы (1)

- Мультикомпьютеры
  - Кластерные системы (Clusters)
  - Массивно-параллельные процессоры (MPP)

Распределенные системы (2)

- Своя оперативная память
- Своя операционная система
- Различные вычислительные мощности
- **Неограниченное масштабирование**

Распределенные системы (3)

- Возможно использовать только процессы
- **Высокая стоимость коммуникаций**

Способы создания распределенных программ

СОЗДАНИЕ РАСПРЕДЕЛЕННЫХ ПРИЛОЖЕНИЙ

Распределенное приложение

- Распределенное приложение (программа) - множество одновременно выполняемых взаимодействующих процессов, которые могут выполняться на одном или нескольких узлах вычислительной сети

Стоимость коммуникаций

- Выбор оптимальной топологии
- Минимизация количества связей
- Минимизация количества пересылок
- Минимизация размера сообщений
- Унификация и типизация сообщений
- И т.д.

Выбор технологии

- Специальные языки
  - Erlang, Go и т.п.
- Общая шина сообщений
  - RabbitMq и т.п.
- Высокоуровневые библиотеки
  - WCF (SOAP), WebAPI (REST), MPI и т.п.
- Низкоуровневые функции и объекты
  - Socket, Pipe и т.п.

Специализированные языки

- Инкапсулируют сложность коммуникаций
- Основное внимание на прикладной задаче
- Простая запись математических алгоритмов
- **Встроенные средства распараллеливания**

Общая шина сообщений

- Инкапсулирует сложность коммуникаций
- Основное внимание на прикладной задаче
- Простая и очевидная схема взаимодействия
- **Гибки[illegible]ы [illegible]ти сообщ[illegible]**

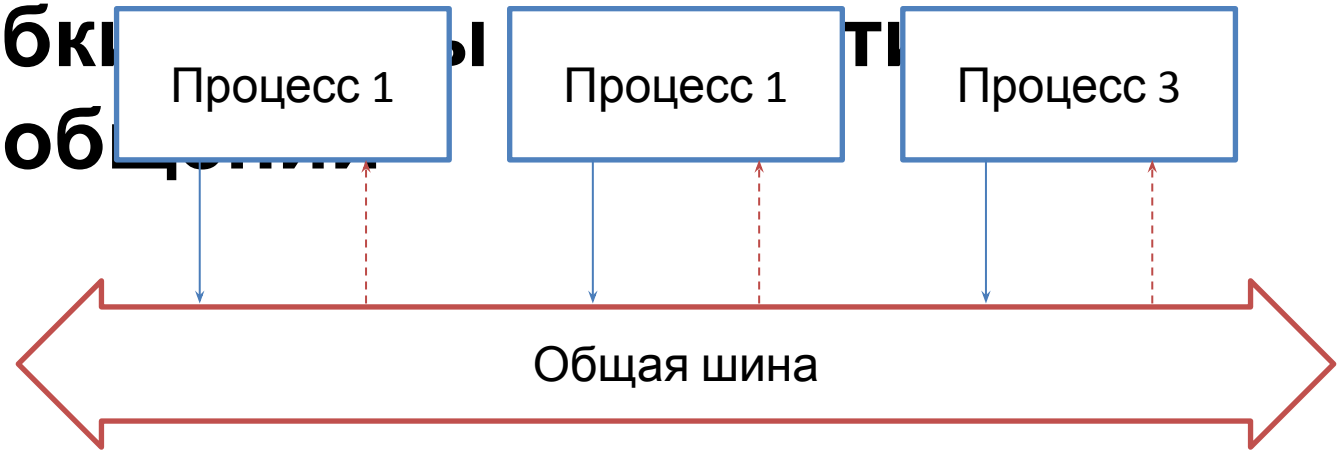

Высокоуровневые библиотеки

- Инкапсулируют сложность коммуникаций
- Основное внимание на прикладной задаче
- Асинхронность чаще реализуется вручную
- Произвольная схема взаимодействия

Низкоуровневые функции

- Сложность осуществления коммуникаций
- Гибкость осуществления коммуникаций
- Вероятная зависимость от платформы
- Произвольная схема взаимодействия

Combo?

- При разработке крупных систем зачастую используются разные подходы

Распараллеливание вычислительных алгоритмов с помощью MPI

ОСНОВЫ ТЕХНОЛОГИИ MPI

Почему рассматриваем MPI?

- Позволяет раскрыть некоторые особенности реализации более высокоуровневых решений, а также дает хорошее представление о сложностях и особенностях разработки распределенных приложений

MPI

- *«The MPI standard includes point-to-point message-passing, collective communications, group and communicator concepts, process topologies, environmental management, process creation and management, one-sided communications, extended collective operations, external interfaces, I/O, some miscellaneous topics, and a profiling interface»*

  - Стандарт - http://www.mpi-forum.org
  - MPICH - http://www.mpich.org
  - Microsoft MPI

Концепция MPI

- Определяет API и протокол обмена сообщениями между процессами распределенного приложения
  - Базовые понятия касаются преимущественно вопросов коммуникации: функции обмена сообщениями, типы данных и формат сообщений, коммуникаторы, топологии и способ идентификации процесса (ранг)

Коммуникатор

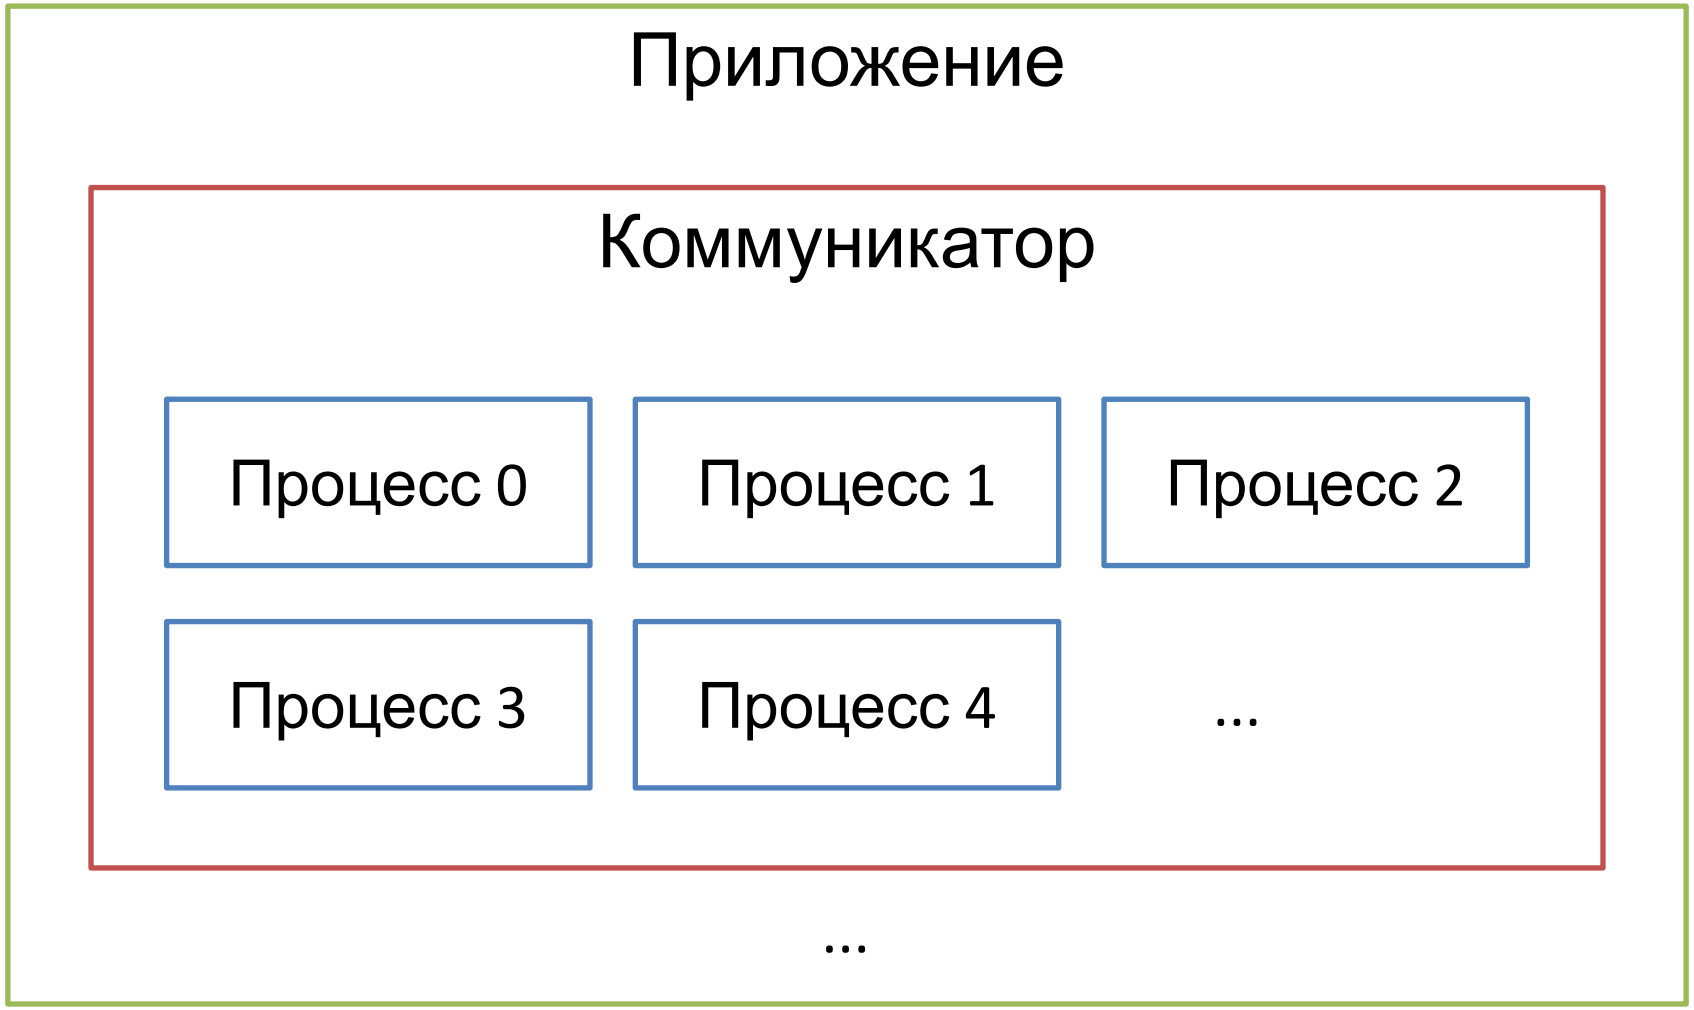

Виртуальные топологии

- Есть возможность задавать виртуальную топологию связей между процессами, которая будет отражать логическую взаимосвязь процессов приложения
- Виртуальная топология может быть использована при распределении процессов по узлам с целью уменьшения коммуникационной трудоемкости

Структура кода MPI-процесса

```
#include <mpi.h>

void main(int argc, char *argv[])
{
    <Программный код без использования функций MPI>
    MPI_Init(&argc, &argv);
    <Программный код с использованием функций MPI>
    MPI_Finalize();
    <Программный код без использования функций MPI>
}
```

Ранг и количество процессов

```
#include <mpi.h>

void main(int argc, char *argv[])
{
    <Программный код без использования функций MPI>
    MPI_Init(&argc, &argv);
    int rank, size;
    MPI_Comm_rank(MPI_COMM_WORLD, &rank);
    MPI_Comm_size(MPI_COMM_WORLD, &size);
    <Программный код с использованием функций MPI>
    MPI_Finalize();
    <Программный код без использования функций MPI>
}
```

Передача и прием сообщений

```
int MPI_Send(
        void* buffer,
        int count,
        MPI_Datatype type,
        int dest,
        int tag,
        MPI_Comm comm
);

int MPI_Recv(
        void* buffer,
        int count,
        MPI_Datatype type,
        int source,
        int tag,
        MPI_Comm comm,
        MPI_Status* status
);
```

Корневой процесс

```
#include <mpi.h>

void main(int argc, char *argv[])
{
	int rank, size;
	MPI_Init(&argc, &argv);
	MPI_Comm_rank(MPI_COMM_WORLD, &rank);
	MPI_Comm_size(MPI_COMM_WORLD, &size);
	if (rank == 0)
	{
		// Корневой процесс
	}
	else
	{
		// Дочерние процессы
	}
	MPI_Finalize();
}
```

Редукция

- Передача данных от всех процессов одному процессу (обычно корневому процессу)

```
int MPI_Reduce(
        void* sendBuffer,
        void* receiveBuffer,
        MPI_Datatype type,
        MPI_Op operation,
        int root,
        MPI_Comm comm
);
```

Барьерная синхронизация

- Точка синхронизации, которую должны достигнуть все процессы, прежде чем продолжат свое выполнение

```
int MPI_Barrier(MPI_Comm comm);
```

Время выполнения

```
double startTime = MPI_Wtime();;
<Блок кода>
double stopTime = MPI_Wtime();;
double elapsed = stopTime - startTime;
```

Пример вычислений

```
void CalculatePi(int rank, int size, int n)
{
	double pi;

	MPI_Bcast(&n, 1, MPI_INT, 0, MPI_COMM_WORLD);

	double sum = 0.0;
	double coeff = 1.0 / (double)n;

	for (int i = rank + 1; i <= n; i += size)
	{
		double x = coeff * ((double)i + 0.5);
		sum += 4.0 / (1.0 + x * x);
	}

	sum *= coeff;

	MPI_Reduce(&sum, &pi, 1, MPI_DOUBLE, MPI_SUM, 0, MPI_COMM_WORLD);

	if (rank == 0)
	{
		printf("PI = %.8f\n", pi);
	}
}
```

ВОПРОСЫ?