



НОЦ "ПАРАЛЛЕЛЬНЫЕ ВЫЧИСЛЕНИЯ"  
APPLIED PARALLEL COMPUTING E&R CENTER

# Межпроцессное взаимодействие с CUDA IPC



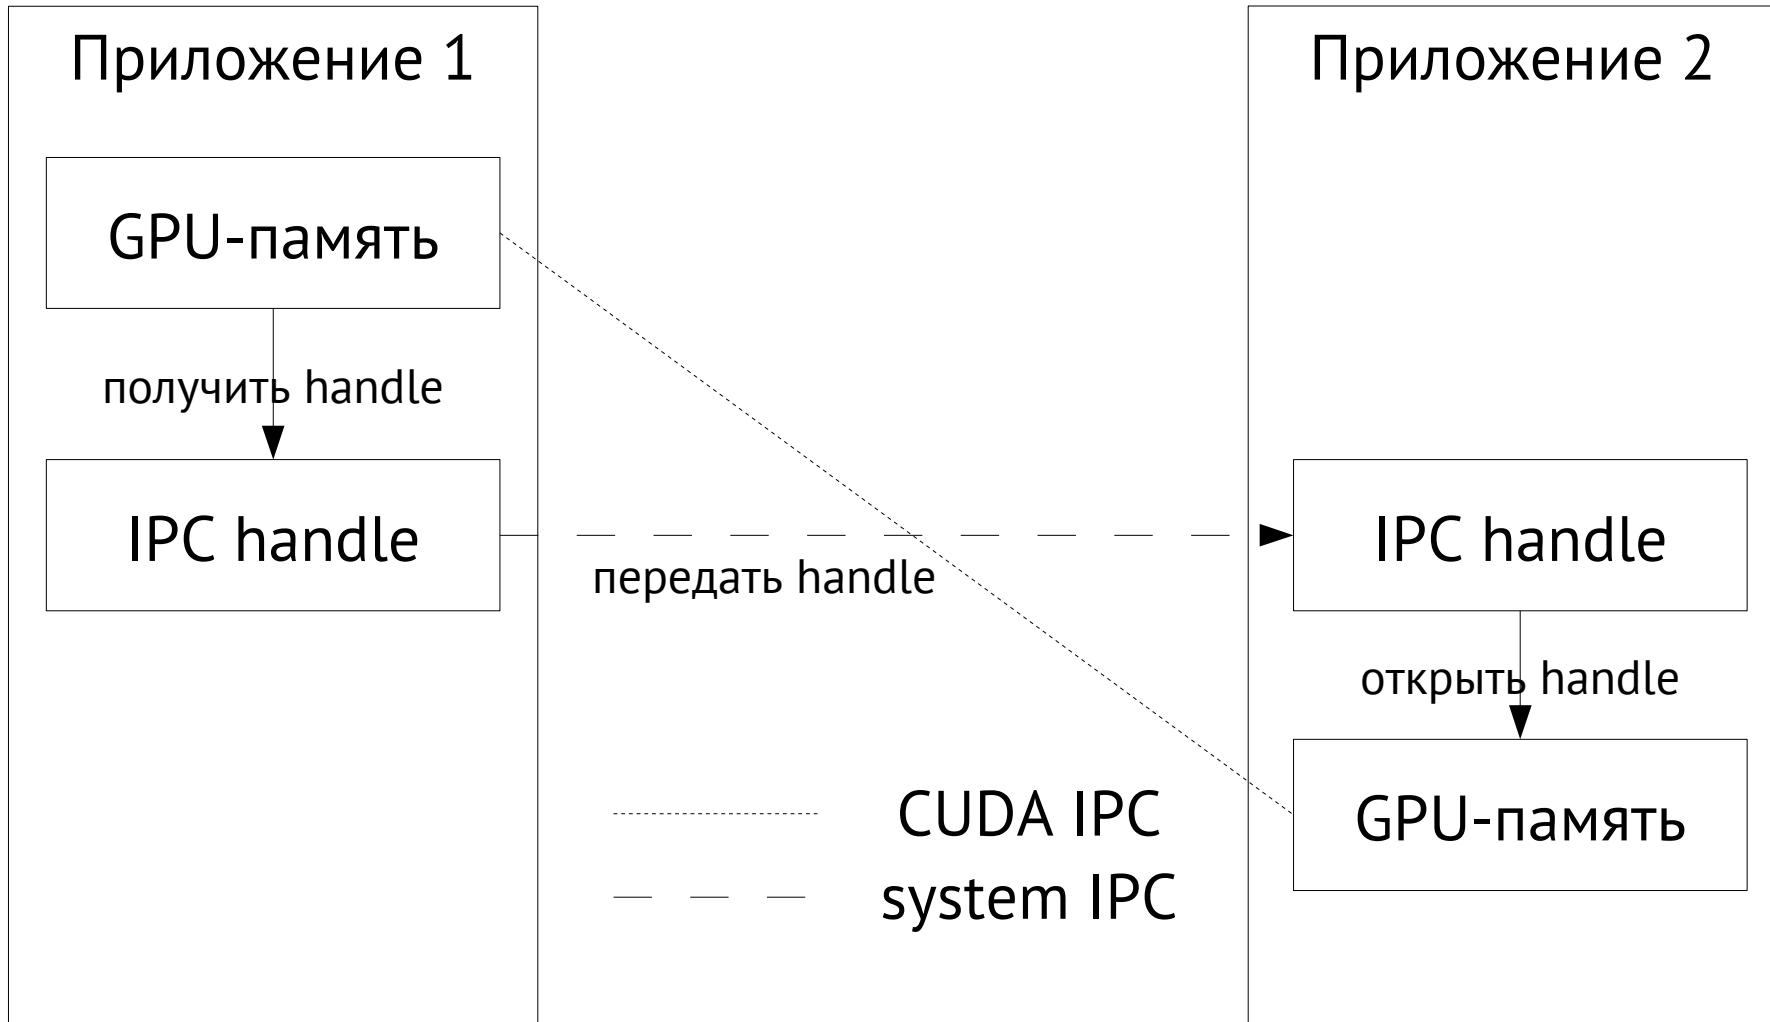
# CUDA IPC

НОЦ "ПАРАЛЛЕЛЬНЫЕ ВЫЧИСЛЕНИЯ"  
APPLIED PARALLEL COMPUTING E&R CENTER

- Совместное использование CUDA-объектов в раздельных приложениях:
  - device memory (напр., double \*)
  - CUDA events (cudaEvent\_t)
- Работает в рамках одной машины
- Требует «традиционного» IPC для обмена handle'ами



# CUDA IPC – схема использования





# CUDA IPC – типы и функции (device memory)

- `cudaIpcMemHandle_t`
- `cudaIpcGetMemHandle(cudaIpcMemHandle_t *handle, void *devPtr)`
- `cudaIpcOpenMemHandle(void **devPtr, cudaIpcMemHandle_t handle, unsigned int flags)`
- `cudaIpcCloseMemHandle(void *devPtr)`



# CUDA IPC – функции (device memory)

## Приложение 1

```
double *a;  
cudaIpcMemHandle_t handle;  
cudaMalloc(&a, 1024);  
cudaIpcGetMemHandle(&handle, a);  
...  
<send handle>  
  
<wait> ◀  
cudaFree(a);
```

## Приложение 2

```
double *a;  
cudaIpcMemHandle_t handle;  
  
→ <receive handle>  
cudaIpcOpenMemHandle(&a, handle);  
...  
kernel<<<...>>>(a);  
...  
cudaIpcCloseMemHandle(handle);  
...  
<signal>
```



## CUDA IPC – типы и функции (events)

- `cudaIpcEventHandle_t`
- `cudaIpcGetEventHandle(cudaIpcEventHandle_t *handle, cudaEvent_t event)`
- `cudaIpcOpenEventHandle(cudaEvent_t *event, cudaIpcEventHandle_t handle)`



# CUDA IPC – функции (events)

## Приложение 1

```
cudaEvent_t event;
cudaIpcEventHandle_t handle;

cudaEventCreate(&event,
cudaEventDisableTiming |
cudaEventInterprocess);

cudaIpcGetEventHandle(&handle, event);
<send handle> → <receive handle>
...
cudaEventRecord(event);
...

<wait> ← <signal>
cudaEventDestroy(event);
```

## Приложение 2

```
cudaEvent_t event;
cudaIpcEventHandle_t handle;

...
cudaIpcOpenEventHandle(&event,
handle);
...
cudaEventSynchronize(event);
...
<signal>
```



# CUDA IPC – приложения

- MPI
  - MVAPICH – intra-node GPU buffer exchange
- Многокомпонентные архитектуры
  - daemon (C/FORTRAN) + UI (Python, Java)



## CUDA IPC: пример из CUDA SDK

- simpleIPC.cu
- использует shared memory:
  - mmap(NULL, ..., MAP\_SHARED | MAP\_ANONYMOUS)
- порождает дочерние процессы:
  - fork(...)
- эмулирует барьерную синхронизацию поверх разделяемой памяти