

Лекция 5. Multithreading in C++

CS Club, Novosibirsk, 2019

Типы многозадачности

- Cooperative (совместная). Следующая задача выполняется только после того, как предыдущая явно отдала поток управления (lightweight threads, fibers).
- Preemptive (вытесняющая). Операционная система сама определяет когда забрать поток управления у задачи и отдать его другой задаче.

МНОГОПОТОЧНОСТЬ В C++

Threads management

- `std::thread` object
- threads utility (`id`, `yield`, `sleep`, ...)
- `thread_local` (TLS)

Locking

- Mutual exclusion
- Lock management
- Condition variables

Tasks

- `async`
- `future` & `promise`

Parallel/vectorized algorithms (C++17)

Memory model

- models
- atomic template
- `atomic_flag`

C++20

- Executors
- Latches and barriers
- Coroutines*
- Transactional memory
- Task blocks
- `jthread`

Косвенно

- OpenMP*
- Exceptions
- Message/event loop
- Priorities

МНОГОПОТОЧНОСТЬ В C++

Threads management

- `std::thread` object
- threads utility (`id`, `yield`, `sleep`, ...)
- `thread_local` (TLS)

Locking

- Mutual exclusion
- Lock management
- Condition variables

Tasks

- `async`
- `future` & `promise`

Parallel/vectorized algorithms (C++17)

Memory model

- models
- atomic template
- `atomic_flag`

C++20


- `Executors`
- `Latches and barriers`
- `Coroutines*`
- `Transactional memory`
- `Task blocks`
- `jthread`

Косвенно

- `OpenMP*`
- `Exceptions`
- `Message/event loop`
- `Priorities`

Многопоточность – это легко и эффективно. В теории

Multithreaded programming



Часть 1. Параллельные алгоритмы

Параллельные алгоритмы (C++17)

```
1. void parallel_run()
2. {
3.     vector<double> data = { /* ... */ };
4.     // before:
5.     sort(begin(data), end(data));
6.     // now we could run in parallel:
7.     sort(execution::par, begin(data), end(data));
8. }
```

- Большая часть алгоритмов STL поддерживает теперь параллельный запуск с несколькими policy (стратегиями)

```
1. execution::seq        // sequenced
2. execution::par        // parallel
3. execution::par_unseq  // parallel + vectorized (SIMD)
4. execution::unseq      // vectorized, since C++20
5.
6. // 69 new functions + a few new
7. sort, for_each, transform, transform_reduce, ...
```

Низкая загрузка CPU

```
1. std::transform(std::execution::par,  
2.   vec.begin(), vec.end(), out.begin(),  
3.   [](double v) { return v * 2.0; });
```

Operations	Vector Size	i7 4720 (4 Cores)	i7 8700 (6 Cores)
execution::seq	10k	0.002763	0.001924
execution::par	10k	0.009869	0.008983
openmp parallel for	10k	0.003158	0.002246
execution::seq	100k	0.051318	0.028872
execution::par	100k	0.043028	0.025664
openmp parallel for	100k	0.022501	0.009624
execution::seq	1000k	1.69508	0.52419
execution::par	1000k	1.65561	0.359619
openmp parallel for	1000k	1.50678	0.344863

<https://www.bfilipek.com/2018/11/parallel-alg-perf.html>

Высокая загрузка CPU

```
1. std::transform(std::execution::par,  
2.   vec.begin(), vec.end(), vecNormals.begin(), // input vectors  
3.   vecFresnelTerms.begin(), // output term  
4.   [](const glm::vec4& v, const glm::vec4& n)  
5.   {  
6.       return fresnel(v, n, 1.0f);  
7.   });
```

Operation	Vector Size	i7 4720 (4 Cores)	i7 8700 (6 Cores)
execution::seq	10k	0.246722	0.169383
execution::par	10k	0.090794	0.067048
openmp parallel for	10k	0.049739	0.029835
execution::seq	100k	2.49722	1.69768
execution::par	100k	0.530157	0.283268
openmp parallel for	100k	0.495024	0.291609
execution::seq	1000k	25.0828	16.9457
execution::par	1000k	5.15235	2.33768
openmp parallel for	1000k	5.11801	2.95908


Соображения и рекомендации

- Параллельные алгоритмы делают больше работы чем последовательные
- Важно не только кол-во элементов, но и загрузка CPU каждой операцией (больше элементов и загрузки!)
- Лучше если меньше чтения памяти, больше CPU usage
- Правильно всегда проводить benchmark, чтобы оценить ускорение и целесообразность
- Начинайте с OpenMP, если он уместен


Часть 2. Поток

Проблемные ситуации

- Race condition/data race (состояние гонки).



- Deadlock (взаимная блокировка).



- Livelock – блокировки как таковой нет, но крутимся в бессмысленном цикле.
- etc.

Нас не испугать dead lock'ами!



Создание потока

- Поток создается с помощью объекта `std::thread` (заголовочный файл `<thread>`).

```
1. void big_calc(string how)
2. {
3.     cout << "i\'m working " << how << "\n";
4. }
5.
6. int main()
7. {
8.     thread th1{big_calc, "hard"};
9.     thread th2{big_calc, "24/7"};
10.
11.     // doing smth
12.
13.     th1.join();
14.     th2.join();
15.     return 0;
16. }
```

Объект потока `std::thread`

```
1. // can be moved, not copied
2. class thread
3. {
4.     //...
5.     template< class Function, class... Args >
6.     explicit thread(Function&& func, Args&&... args);
7.
8.     // std::terminate if joinable
9.     ~thread();
10.
11.     bool                joinable                () const noexcept;
12.     std::thread::id     get_id                   () const;
13.     native_handle_type native_handle           ();
14.     static unsigned     hardware_concurrency();
15.
16.     void join    (); // waits for thread func finish
17.     void detach(); // detaches thread object from system thread
18.     // ...
19. };
```

Вспомогательные функции

- Находятся в namespace `std::this_thread`
 - `yield` - отдает поток управления
 - `get_id` - возвращает `std::thread::id`
 - `sleep_for/sleep_until` - приостанавливает ПТОК

```
1. void thread_func()  
2. {  
3.     lock_guard<mutex> lock(m);  
4.  
5.     if (task_queue.empty())  
6.         std::this_thread::yield(); // Hmm... Really?  
7.     else  
8.         //...  
9. }
```


Mutual exclusion

- `mutex`: обеспечивает базовые функции `lock()` и `unlock()` и не блокируемый метод `try_lock()`
- `recursive_mutex`: можно повторно захватить
- `timed_mutex`: в отличие от обычного мьютекса, имеет еще два метода: `try_lock_for()` и `try_lock_until()`
- `recursive_timed_mutex`: это комбинация `timed_mutex` и `recursive_mutex`
- `shared_timed_mutex` : предоставляет общий доступ нескольким потокам (читатели) или эксклюзивный одному потоку (писатель).

Lock management

- `lock_guard` – самый что ни на есть простой RAII держатель `mutex`'а
- `unique_lock`
 - `try_lock[_for/_until]`
 - конструирование без или с тэгом: `defer_lock`, `try_to_lock`, `adopt_lock`
 - `owns_lock` проверка
- `shared_lock` – то же, что и `unique_lock`, но для `shared_timed_mutex`

Пример захвата mutex

- Чтобы избежать deadlock'а на нескольких mutex'ах используйте функцию `std::lock`

```
1. void move_money(account& a1, account& a2, int amount)
2. {
3.     unique_lock l1(a1.mut, defer_lock);
4.     unique_lock l2(a2.mut, defer_lock);
5.
6.     // avoids deadlocks
7.     std::lock(a1.mut, a2.mut);
8.
9.     if (a1.balance >= amount)
10.    {
11.        a1.balance -= amount;
12.        a2.balance += amount;
13.    }
14.    // ...
15. }
```

Exception catching

- Exception никаким образом не транслируется далее через границу потока.
- Что делать?

```
1. void thread_func()  
2. {  
3.     try  
4.     {  
5.         // function body  
6.     }  
7.     catch (...)  
8.     {  
9.         // what to do with the exception?  
10.    }  
11. }
```

Exception rethrow (1)

- Попробуем его сперва поймать и сохранить!

```
1. void thread_func()  
2. {  
3.     try  
4.     {  
5.         // function body  
6.     }  
7.     catch (...)  
8.     {  
9.         std::exception_ptr p = current_exception();  
10.        exceptions_queue.push_back(p);  
11.    }  
12. }
```

Exception rethrow (2)

```
1. void invoker()  
2. {  
3.     thread th(thread_func);  
4.     //...  
5.     th.join();  
6.  
7.     while(!exceptions_queue.empty())  
8.     {  
9.         try  
10.        {  
11.            auto p = exceptions_queue.top();  
12.            exceptions_queue.pop();  
13.            rethrow_exception(p);  
14.        }  
15.        catch(std::exception const& e)  
16.        {  
17.            cout << "FAILURE: " << e.what() << end;  
18.        }  
19.    }  
20. }
```

Condition variables

- Блокируют поток(и) пока не будет получено уведомление от другого потока.
- До начала ожидания по condition variable (`wait`) блокируется `mutex`, а в самом `wait` – разблокируется.
- `wait` выходит, когда другой поток уведомляет condition variable (либо мифический *spurious wakeup*), либо `timeout`.
- Когда `wait` выходит, одновременно обратно блокируется `mutex`.

Что есть для condition variable в C++11?

- Классы

```
1. class condition_variable;  
2. class condition_variable_any;
```

- ФУНКЦИИ

```
1. void notify_one();  
2. void notify_all();  
3.  
4. void wait( std::unique_lock<std::mutex>& l );  
5. void wait( std::unique_lock<std::mutex>& l, Predicate pred );  
6.  
7. cv_status wait_for (unique_lock<mutex>& l, const chrono::duration& t);  
8. cv_status wait_until(unique_lock<mutex>& l, const chrono::time_point& t);  
9 // the same + Predicate
```


Пример condition variable

```
1. mutex          mt;
2. condition_variable cv;
3. vector<char>    buf;
4.
5. void sending_thread()
6. {
7.     while (<some condition>)
8.     {
9.         unique_lock<mutex> l(mt);
10.        while (buf.empty())
11.            cv.wait(l);
12.
13.        send(buf.data(), buf.size());
14.    }
15. }
16. void on_frame(vector<char> const& data)
17. {
18.     {
19.         unique_lock<mutex> l(mt);
20.         buf.insert(buf.end(), data.begin(), data.end());
21.     }
22.     cv.notify_one();
23. }
```

Пример condition variable

```
1. mutex          mt;
2. condition_variable cv;
3. vector<char>    buf;
4.
5. void sending_thread()
6. {
7.     while (<some condition>)
8.     {
9.         unique_lock<mutex> l(mt);
10.        cv.wait(l, [](){ return !buf.empty(); });
11.
12.        send(buf.data(), buf.size());
13.    }
14. }
15. void on_frame(vector<char> const& data)
16. {
17.     {
18.         unique_lock<mutex> l(mt);
19.         buf.insert(buf.end(), data.begin(), data.end());
20.     }
21.     cv.notify_one();
22. }
```

Часть 3. Задачи

Отложенные вычисления

- Представим себе, что вычисления занимают длительное время.
- Закономерно, хочется передать такие вычисления другому потоку.
- Но результат желательно видеть в потоке, инициировавшем вычисления. *Pull model*
- Как это сделать, но при этом не создавать самим поток, защищать данные mutex'ом и т.д.

Future and Promise

- future позволяет дождаться вычисления результата

```
1. void calc(promise<long> p)
2. {
3.     long sum = 0;
4.     long sign = 1;
5.     for (long i = 0; i < 100000000; ++i)
6.         { sum += i * sign; sign *= -1; }
7.
8.     p.set_value(sum);
9. }
10.
11. int main()
12. {
13.     promise<long> p;
14.     future<long> f = p.get_future();
15.     thread t{calc, move(p)};
16.     ...
17.     std::cout << f.get() << '\n';
18.     t.join();
19. }
```

Packaged task and Future

- Как бы нам не вносить модификацию в саму функцию?

Packaged task and Future

- Как бы нам не вносить модификацию в саму функцию?

```
1. long calc()
2. {
3.     long sum = 0;
4.     long sign = 1;
5.     for (long i = 0; i < 100000000; ++i)
6.         { sum += i * sign; sign *= -1; }
7.
8.     return sum;
9. }
10.
11. int main()
12. {
13.     packaged_task<long> task{calc};
14.     future<long> f = task.get_future();
15.
16.     thread t{move(task)};
17.     ...
18.     cout << f.get() << endl;
19.     t.join();
20. }
```

async and future

- Можно ли проще, если не хочется управлять потоком самостоятельно?

```
1. int main()  
2. {  
3.     future<long> f = std::async(std::launch::async, calc);  
4.     ...  
5.     cout << f.get() << '\n';  
6. }
```

- Возможные стратегии запуска:
 - `std::launch::async` – в другом потоке
 - `std::launch::deferred` – в этом же потоке

future class

```
1.  template <class R>
2.  class future {
3.  public:
4.      /*constructors and assignment operators skipped*/
5.
6.      shared_future<R> share();
7.
8.      /*see description*/ get();
9.
10.     // functions to check state
11.     bool valid() const noexcept;
12.     void wait () const;
13.
14.     // template declaration are skipped
15.     future_status wait_for (const chrono::duration& rel_time) const;
16.     future_status wait_until(const chrono::time_point& abs_time) const;
17. };
```

Часть 4. Очереди сообщений

Очередь событий/сообщений

- Хочу инициировать вычисления в параллельном потоке
- И получать нотификации с результатами вычислений в исходном (инициирующем) потоке. *Push model*
- Как?

Очередь событий/сообщений

```
1. boost::asio::io_service io;
2.
3. void some_long_calc_thread_1(function<void(long)> const& cb)
4. {
5.     long res = 0;
6.     long sign = 1;
7.     for (long i = 0; i < 100000000; ++i)
8.         { res += sign * i; sign *= -1; }
9.
10.    io.post(bind(cb, res));
11. }
12.
13. void print_res_thread_0(long res)
14. { cout << res; }
15.
16. int main()
17. {
18.     thread th (some_long_calc_thread_1, print_res_thread_0);
19.     // do smth
20.     io.run();
21.     th.join();
22.     return 0;
23. }
```

Часть 5. Memory model

Давайте сделаем синглтон

- Защитим синглтон mutex'ом
- double-checked locking (anti-pattern)

```
1. singleton* instance() {  
2.     if (ptr_ == nullptr) {  
3.         lock_guard lock(mtx);  
4.         if (ptr_ == nullptr) {  
5.             ptr_ = new singleton();  
6.         }  
7.     }  
8.     return ptr_;  
9. }
```

Давайте сделаем синглтон

- Защитим синглтон mutex'ом
- double-checked locking (anti-pattern)

```
1. singleton* instance() {  
2.     if (ptr_ == nullptr) {  
3.         lock_guard lock(mtx);  
4.         if (ptr_ == nullptr) {  
5.             ptr_ = new singleton();  
6.         }  
7.     }  
8.     return ptr_;  
9. }
```

- Операция создания объекта и присваивания указателя не обязана быть атомарной

Давайте сделаем синглтон

- Компилятор может сделать создание примерно так, как написано ниже
- Теперь в этом коде кроется ошибка
- Исправляется это объявлением `std::atomic<singleton*> ptr_`

```
1. singleton* instance() {
2.     if (ptr_ == nullptr) {
3.         lock_guard lock(mtx);
4.         if (ptr_ == nullptr) {
5.
6.             ptr_ = aligned_alloc
7.                 (alignof(singleton), sizeof(singleton));
8.
9.             /* creating thread may switch here... */
10.            ptr_ = new (ptr_) singleton;
11.        }
12.    }
13.    return ptr_;
14. }
```


Подготовим данные в другом потоке (lock free)

Thread 1

```
1. uint64_t key{ 0 };
2. volatile bool key_ready{ false };
3.
4. void calculate_key()
5. {
6.     secret_key = make_key();
7.     key_ready = true;
8. }
```

Thread 2

```
1. void use_key()
2. {
3.     if (key_ready)
4.         cout << secret_key;
5. }
```

Компилятор может переставить обращения

Thread 1

```
1. uint64_t key{ 0 };
2. volatile bool key_ready{ false };
3.
4. void calculate_key()
5. {
6.     key_ready = true;
7.     secret_key = make_key();
8. }
```

Thread 2

```
1. void use_key()
2. {
3.     if (key_ready)
4.         cout << secret_key;
5. }
```

- **volatile** никак не спасает от перестановки в C++, он вообще не для многопоточности

Вставим барьеры

Thread 1

```
1. uint64_t key{ 0 };
2. bool key_ready{ false };
3.
4. void calculate_key()
5. {
6.     secret_key = make_key();
7.     STORE ↘ ----- ↗ STORE
8.     key_ready = true;
9. }
```

Thread 2

```
1. void use_key()
2. {
3.     if (key_ready)
4.         LOAD ↘ ----- ↗ LOAD
5.         cout << secret_key;
6. }
```

В C++11 определены модели памяти

```
1. enum memory_order {
2.     memory_order_relaxed,
3.     memory_order_consume,
4.     memory_order_acquire, // LOAD---STORE ; LOAD---LOAD
5.     memory_order_release, // STORE---STORE; LOAD---STORE
6.     memory_order_acq_rel, // no STORE---LOAD; x86/64
7.     memory_order_seq_cst  // ALL
8. };
```

```
1. void do_smth_useful()
2. {
3.     //...
4.     if (can_start) {
5.         ACQUIRE
6.         //...
7.         // any store/load stay between ACQUIRE&RELEASE
8.         //...
9.         RELEASE
10.    }
11. }
```

Подготовим данные в другом потоке (теперь правильно)

Thread 1

```
1.  uint64_t key{ 0 };
2.  atomic<bool> key_ready{ false };
3.
4.  void calculate_key()
5.  {
6.      secret_key = make_key();
7.      key_ready.store(true, memory_order_release);
8.  }
```

Thread 2

```
1.  void use_key()
2.  {
3.      if (key_ready.load(memory_order_acquire))
4.          cout << secret_key;
5.  }
```

Давайте сделаем правильный синглтон

```
1. struct singleton
2. {
3.     //...
4.
5.     static singleton* instance() {
6.         if (ptr_.load() == nullptr) { // memory_order_seq_cst
7.             lock_guard lock(mtx_);
8.             if (ptr_ == nullptr) { // memory_order_seq_cst
9.                 // memory_order_seq_cst
10.                ptr_.store(new singleton());
11.            }
12.        }
13.        return ptr_;
14.    }
15.
16. private:
17.     static std::mutex mtx_;
18.     static std::atomic<singleton*> ptr_;
19. };
```

Здесь должно было наступить
просветление!



Вопросы?