Zaawansowane programowanie w C++ (ZPR)

Wykład 11 – C++ i współbieżność

Robert Nowak

24L

Równoległość - obliczenia podczas obsługi urządzeń

- bardzo wolna reakcja człowieka
- wolne urządzenia wejścia - wyjścia (np. drukarki)
- bardzo szybkie procesory

Aplikacja wielowątkowa:

- pozwala reagować na zlecenia użytkownika podczas obliczeń
- lepiej wykorzystuje dostępną moc obliczeniową
- może obsługiwać wiele zleceń równolegle
- **poprawnie zaprojektowana** jest szybsza na platformach wieloprocesorowych (wielordzeniowych)

Wątek („lekki proces") – niezależne ciągi instrukcji w ramach procesu

- wątki współdzielą kod, dane oraz zasoby.
- mechanizm przełączania nie wprowadza dużych narzutów

C++ pozwala implementować aplikacje wielowątkowe

Współdzielone	Niezależne
▶ obiekty dynamiczne ▶ obiekty automatyczne, jeżeli dostęp przez wskaźnik ▶ obiekty globalne ▶ zasoby systemu operacyjnego (pliki, okna itp) ▶ kod wykonywany	▶ rejestry ▶ ciąg wykonywanych instrukcji ▶ stos ▶ zmienne automatyczne

Program ma zawsze jeden wątek (funkcja main()) - wątek główny lub inicjujący. Może tworzyć dodatkowe wątki.

Wątki w C++

Zabronione funkcje biblioteki standardowej (przechowują stan pomiędzy wołaniami):

funkcja	biblioteka	zamiennik
rand	cstdlib	random, Boost.Random
strtok	cstring	regex, Boost.Tokenizer, Boost.Regex
asctime ctime gmtime localtime	ctime	chrono, Boost.Chrono, Boost.Date_Time

- należy używać bibliotek przeznaczonych do pracy wielowątkowej
- standard C++03 nie dostarczał mechanizmów tworzenia i synchronizacji wątków, standard C++11 ma te mechanizmy,
- można było używać wątków mechanizmami dostarczanymi przez system operacyjny

Biblioteka Boost.DateTime

nazwa	opis	wielkość
`date`	data (gregoriańska) od 1 stycznia 1400 do 31 grudnia 9999	4B
`date_duration`	długość w czasie (w dniach)	4B
`date_period`	przedział czasu	8B
`ptime`	punkt w czasie (`date`+`time_duration`). Dokładność: *ms* (lub *ns*).	8 lub 12B
`time_duration`	długość w czasie	4 lub 8B
`time_period`	przedział czasu	16 lub 24B

```
gregorian::date d(2011,gregorian::Apr,20); //data 20 kwietnia 2011
posix_time::ptime t1(d,posix_time::time_duration(18,0,0) );//18:00
posix_time::ptime t2(d, posix_time::hours(12)+posix_time::seconds(4));
posix_time::time_duration td = t2 - t1; //odejmowanie, 4 sekundy
posix_time::ptime t3 = t2 + td*10; //mnożenie przez liczbę
```

Biblioteka std::chrono (Boost.Chrono)

Biblioteka wykorzystywana w boost::thread (od wersji 1.49)

nazwa	opis
`time_point`	reprezentuje punkt w czasie
`duration`	długość w czasie, przechowuje liczbę cykli oraz długość cyklu
`clock`	dostarcza funkcji `now`, bieżący punkt w czasie

```
#include <chrono>
duration<long, milli > d1; //licznik milisekund używając typu long
duration<int, ratio<60> > d2; //licznik minut używając typu int

this_thread::sleep_for( milliseconds(1000)); //argument typu duration

system_clock::time_point time_limit = system_clock::now() + seconds(1);
this_thread::sleep_until(time_limit); //wykorzystuje time_point
```

std::thread - wątki w C++

```
#include <thread>
//Funkcja główna wątku użytkownika
void my_thread() { /* ...  */ }
//Można też użyć funktora
class MyThread {
  public:
  //tutaj implementacja funkcji wątku użytkownika
  void operator()() { /* ...  */ }
};
int main() {
  std::thread thrd(&my_thread); //Utworzenie i uruchomienie wątku
  try {
    thrd.join(); //Bieżący watek czeka na zakończenie wątku thrd
  } catch(...) { } //wyjątek zgłaszany, gdy wątek już nie istnieje
  return 0;
}

//liczba procesorów (rdzeni) dostępnych na platformie
unsigned int n = std::thread::hardware_concurrency();
```

Skalowalność - zapewnienie wydajnej pracy współbieżnej

Wątki mogą pracować niezależnie gdy:

- odczytują współdzielone dane
- zapisują własne (lokalne) dane

Zapis współdzielonych danych jest kłopotliwy (spowalnia)

Poprawne wykorzystanie współbieżności gdy:

- można podzielić problem na niezależne pod-problemy, np. ten sam algorytm na różnych danych, ale wtedy lepiej stosować operacje wektorowe, maszynę SIMD (jeden strumień instrukcji, wiele strumienie danych), np. GPU;
- kod, który jest podatny na wyścigi jest w sekcji krytycznej, z tym, że czas wewnątrz sekcji krytycznej powinien być jak najmniejszy;
- algorytm używa instrukcji atomowych, z tym, że konflikty powinny pojawiać się rzadko.

Wyścigi (race conditions)

Jeżeli wątki zapisują współdzielony obiekt, to może wystąpić niezdefiniowane zachowanie

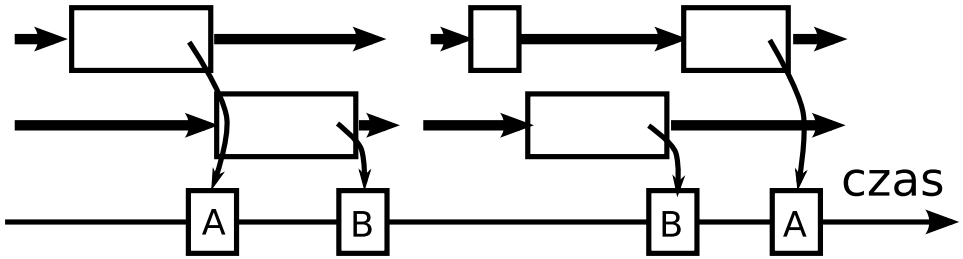

Jedno z rozwiązań: synchronizacja (blokady)

```
mutex m;
m.lock();
//Sekcja krytyczna
m.unlock();

std::mutex mutex_resource;
{
  std::lock_guard guard(mutex_resource);
  //sekcja krytyczna
}
```

Zakleszczenia (deadlock)

każdy z wątków czeka na jakiś inny (jest blokowany). Żaden z nich nie może dalej pracować.

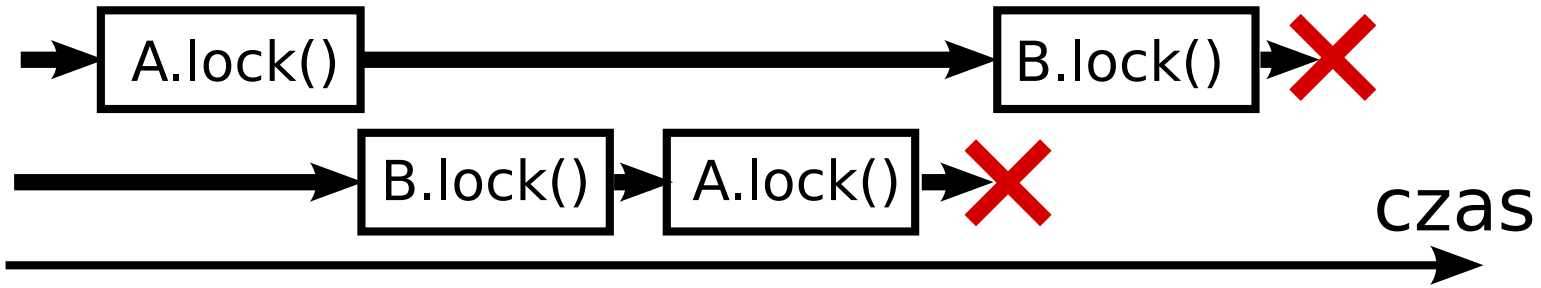

Rozwiązanie:

- zajmowanie blokad zawsze w tej samej kolejności
- stosowanie innych mechanizmów synchronizujących

Samo-zakleszczenie

brak zwalniania sekcji krytycznej (np. w algorytmach rekurencyjnych)

```
struct Foo {
  mutex m;
  void recFun(){
    std::lock_guard l(m);
    /* ...  */
    recFun();//Wołanie rekurencyjne
};
```

Rozwiązanie: **std::recursive_mutex**

Rodzaje prostych blokad w bibliotece standardowej

- std::mutex
  - **lock** wolny: zajmuje, zajęty: blokuje
  - **try_lock** wolny: zajmuje (zwraca true), zajęty (zwraca false)
- std::recursive_mutex
  - **lock** jak wyżej
  - **try_lock** jak wyżej
- std::timed_mutex
  - **lock** jak wyżej
  - **try_lock** jak wyżej
  - **try_lock_for**(time duration)
    wolny: zajmuje (zwraca true), zajęty: blokuje na dany czas
  - **try_lock_until**(time point)
    wolny: zajmuje (zwraca true), zajęty: blokuje na dany czas

Skalowalność z użyciem blokad (sekcji krytycznych)

Wyróżnia się „szybką” i „wolną” ścieżkę w funkcjach wykonywanych w wątkach

- brak blokad na "szybkiej ścieżce" (blokady, wykorzystywane nawet tylko do odczytu zapisują stan)
- usuwanie współdzielonych obiektów do zapisu (lepiej informację wyjściwą przechowywać lokalnie, a później scalać wynik)

```
  //Przykład:  singleton wielowątkowy
Singleton& Singleton::getInstance() {
  if(!pInstance_) { //wzorzec podwójnego sprawdzania
    std::lock_guard guard(mutex_); //tworzenie w sekcji krytycznej
    if(!pInstance_)
      pInstance_ = new Singleton;
  }
  return *pInstance_;
}
```

Instrukcje atomowe, std::atomic (C++11), Boost.Atomic

- niektóre operacje są transakcjami (wykonują się w całości, albo wcale)
- za pomocą takich operacji możemy tworzyć algorytmy współbieżne bez blokad (lock-free)
- takie algorytmy mogą działać szybciej, niż tworzenie sekcji krytycznych.

Operacje atomowe: gwarantuje sprzęt (procesor), ale nie tylko!

```
int y = 0;
++y; //nie jest atomowa!
std::atomic<int> x(0);
++x; //instrukcja atomowa, blokujący dostęp do pewnego obszaru pamięci
```

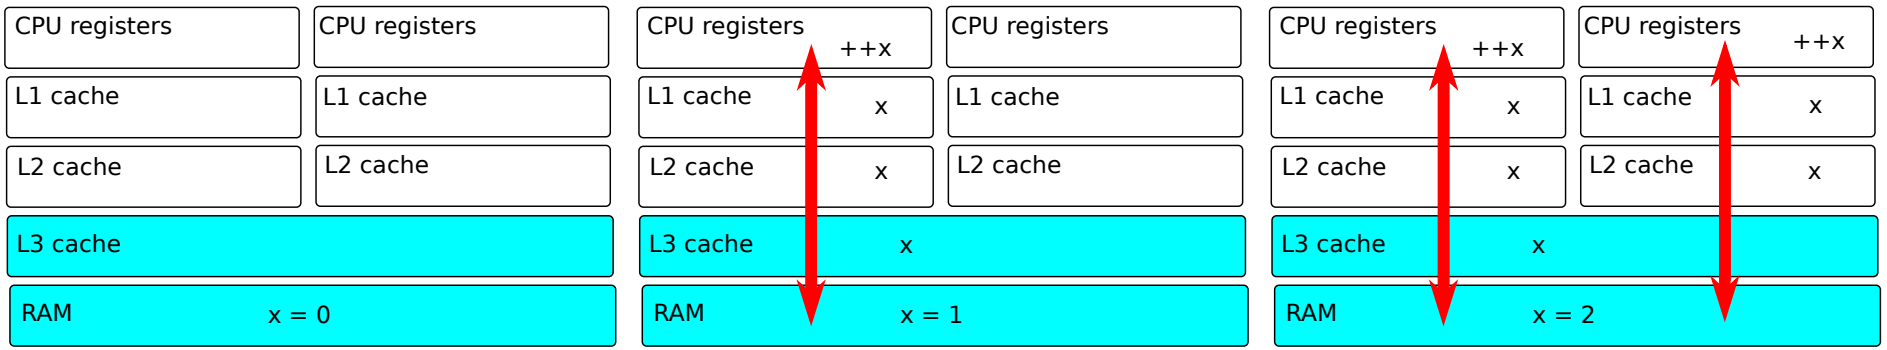

Typy danych, które mogą być atomowe

Atomowe mogą być wszystkie typy, dla których kopiowanie jest trywialne (obiekt to ciągły obszar pamięci, nie ma funkcji wirtualnych).

```
std::atomic<int> i=0; //OK
std::atomic<double> d=0.0; //OK
struct A { long x; long y; };
std::atomic<A> a; //OK, nie zawsze lock-free!
```

`std::atomic_flag` – gwarancja, że jest lock-free (to nie `atomic<bool>`)

Operacje atomowe na typach atomowych:

`is_lock_free`	bada, czy typ nie używa blokad
`(constructor)`	tworzy obiekt
`operator=`	
`store`	zast. wartość atomową, argument nieatomowy
`load`	zwraca wartość atomową jako obiekt nieatomowy
`compare_exchange_weak`	podstawowa operacja dla algorytmów lock-free
`compare_exchange_strong`	podstawowa operacja dla algorytmów lock-free

Dla niektórych typów (np. `atomic<int>`) mamy też inne operacje atomowe.

Modele synchronizacji pamięci

Parametr metod `load`, `store` obiektów atomowych, np.

```
atomic<int> x;
x.store(1, memory_order_relaxed);
```

nazwa	opis
`memory_order_relaxed`	brak gwarancji
`memory_order_consume`	zazwyczaj `load`
`memory_order_acquire`	zazwyczaj `load`
`memory_order_release`	zazwyczaj `store`
`memory_order_acq_rel`	jednocześnie 'acquire' i 'release';
`memory_order_seq_cst`	j.w. + wspólna kolejność, domyślny.

```
//Wątek 1
x.store(1);
y.store(2);
```

```
if(y.load() == 2) {
  assert( x.load() == 1);
  y.store(1); }
```

```
//Wątek 3
if( y.load() == 1)
  assert( x.load() == 1 );
```

Parametry platformy związane ze współbieżnością

- `std::thread::hardware_concurrency` – omówiony wcześniej
- `std::hardware_destructive_interference_size` (C++17) - minimalny odstęp pomiędzy obiektami, aby gwarantować różne linie w pamięci podręcznej (cache L1)
- `std::hardware_constructive_interference_size` (C++17) – maksymalny rozmiar obiektu, który jest możliwy do przechowyania w tej samej linii pamięci podręcznej (cache L1)

Obiekty związane z wątkami

`std::thread_local` (C++11), `boost::thread_specific`
obiekty związane z bieżącym wątkiem

```
int random_dice() {
  thread_local std::mt19937 engine; //obiekt związany z wątkiem
  //dla każdego wątka to inny obiekt, nie potrzebna synchronizacja
  uniformint_distribution<mt19937::result_type> dist(1,6);
  return dist(engine);
}
void thread_fun() {
  for(int i=0; i<10; ++i)
    random_dice();
}
int main() {
  std::thread th1(thread_fun);
  std::thread th2(thread_fun);

  th1.join(); th2.join();
  return 0;
}
```

Aktywny obiekt - asynchroniczne wołanie komend

Komenda wykonuje się w niezależnym wątku, wersje:

- komendy nie zwracające wyniku,
- komendy zwracające wynik.

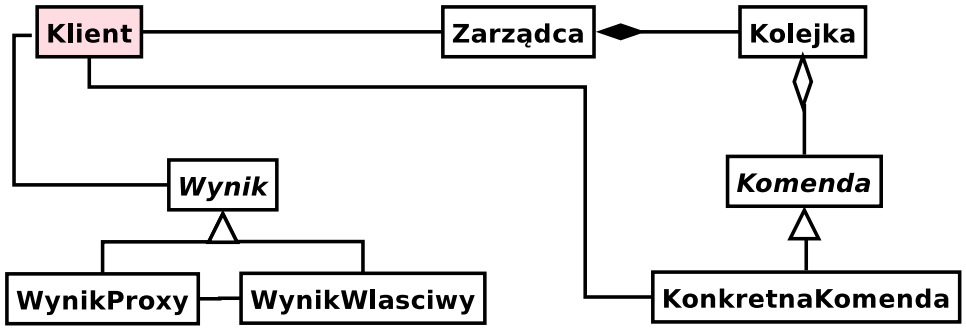

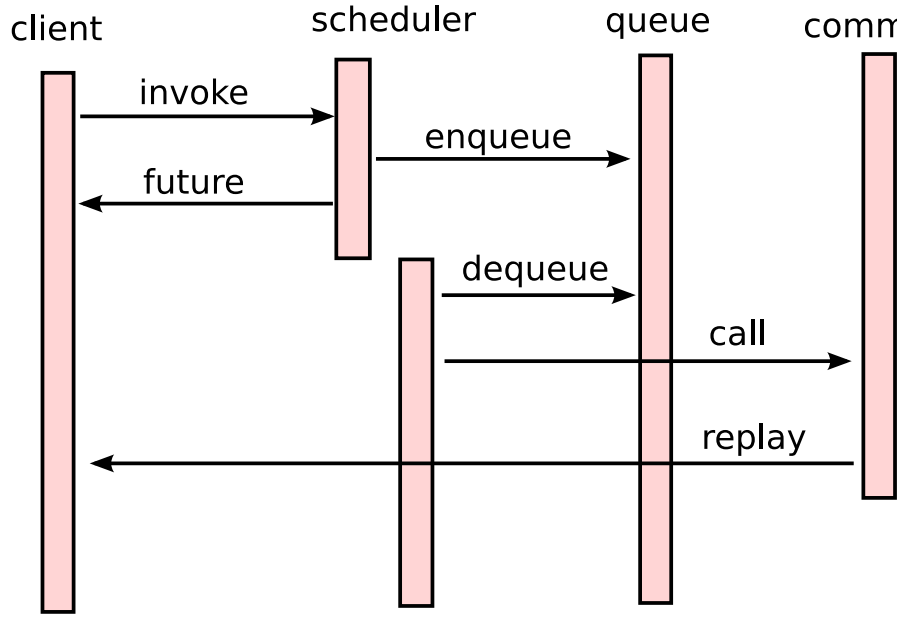

std::promise oraz std::future

Asynchroniczne przekazywanie obiektu:

- `std::future<T>` - wynik (typ lub wyjątek), z punktu widzenia odbiorcy (czytelnika)
- `std::promise<T>` - wynik z punktu widzenia nadawcy (pisarza)

```
Result long_computaton();
//uruchamia w oddzielnym wątku
future<Result> result = async( launch:async, long_computation );
//...
result.get(); //czeka na na wynik
```

- std::launch::async - wykonuje w oddzielnym wątku
- std::launch::deferred - wykonuje w tym samym wątku, leniwe wykonanie, gdy get na future

STL i współbieżność

- bezpiecznie czytanie – wiele wątków może równocześnie czytać z kontenera
- bezpieczne pisanie do różnych kontenerów – różne wątki mogą równocześnie pisać do różnych kontenerów

(od C++17) dostarcza algorytmy równoległe i wektorowe

`std::execution::sequenced_policy` – sekwencyjne
`std::execution::parallel_policy` – można używać wątków
`std::execution::unsequenced_policy` – można oper. wektorowe
`std::execution::parallel_unsequenced_policy`

```
vector<int> v(100);
fill( execution::unseq, v.begin(), v.end(), 1); //ustawia wartości w konten
std::mt19937_64 gen; //generator liczb pseudolosowych, Mersanne-Twister
std::uniform_int_distribution<> distr(0,99);
generate( v.begin(), v.end(), [&](){ return distr(gen);});
```

CUDA, Thrust, Boost.Compute

Thrust Umożliwia używanie GPU z architekturą CUDA w C++.

Kontenery:

`thrust::host_vector` – wektor w pamięci operacyjnej
`thrust::device_vector` – wektor na GPU

Boost.Compute Umożliwia używanie CPU i/lub GPU za pośrednictwem OpenCL.

- niezależna od dostawcy sprzętu (ponieważ używa OpenCL)
- bezpośredni dostęp do równoległego sprzętu (nie jest to warstwa abstrakcji)
- pozwala wykorzystywać typowe kontenery (np. vector<T>)
- pozwala wykorzystywać typowe algorytmy (np. std::transform)

```
g++ compute.cpp -lOpenCL
```

Struktury danych bez blokad (lock-free)

```
bool compare_exchange(atomic<T>* obj, T* exp, T val)
    if(obj==exp) { obj = val; return true;}
    else { exp = obj; return false; }
```

```
struct Node { int value; Node* next; };
std::atomic<Node*> head(nullptr);

void push_front(int val) { //może być wołane w różnych wątkach
  Node* old_head = head.load();
  Node* new_node = new Node {val,old_head};
  //założenie - konflikty występują rzadko
  while (! head.compare_exchange_weak(old_head,new_node))
    new_node->next = old_head;
}
```

Struktury danych bez blokad (lock-free) (2)

```
void push_front(int val) { //może być wołane w różnych wątkach
  Node* old_head = head.load();
  Node* new_node = new Node {val,old_head};
  //założenie - konflikty występują rzadko
  while (! head.compare_exchange_weak(old_head,new_node))
    new_node->next = old_head;
}
```

Przed CAS (bez konfliktu):

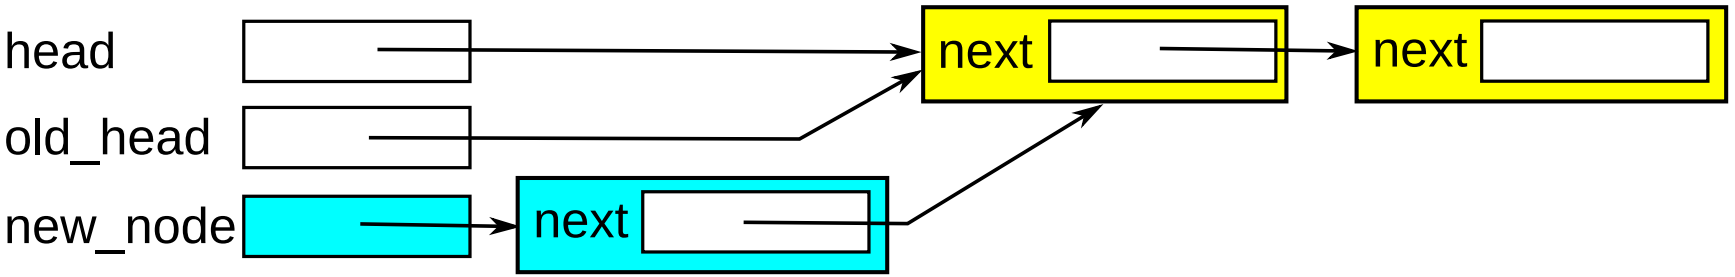

Po CAS:

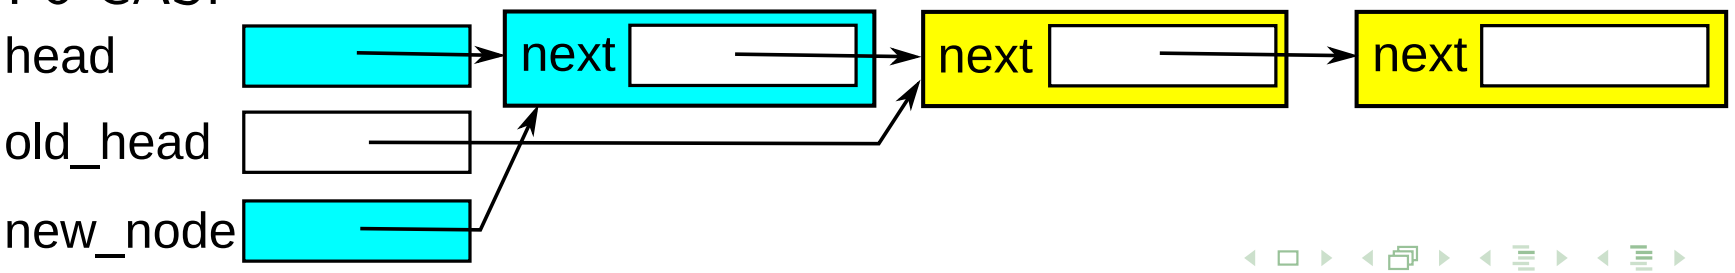

Struktury danych bez blokad (lock-free) (3)

```
void push_front(int val) { //może być wołane w różnych wątkach
  Node* old_head = head.load();
  Node* new_node = new Node {val,old_head};
  //założenie - konflikty występują rzadko
  while (! head.compare_exchange_weak(old_head,new_node))
    new_node->next = old_head;
}
```

Przed CAS, z konfliktem:

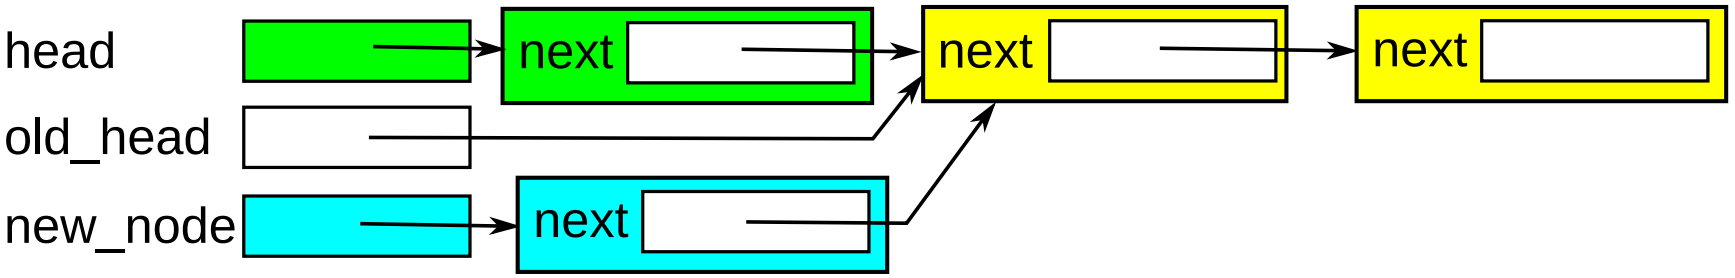

Po CAS:

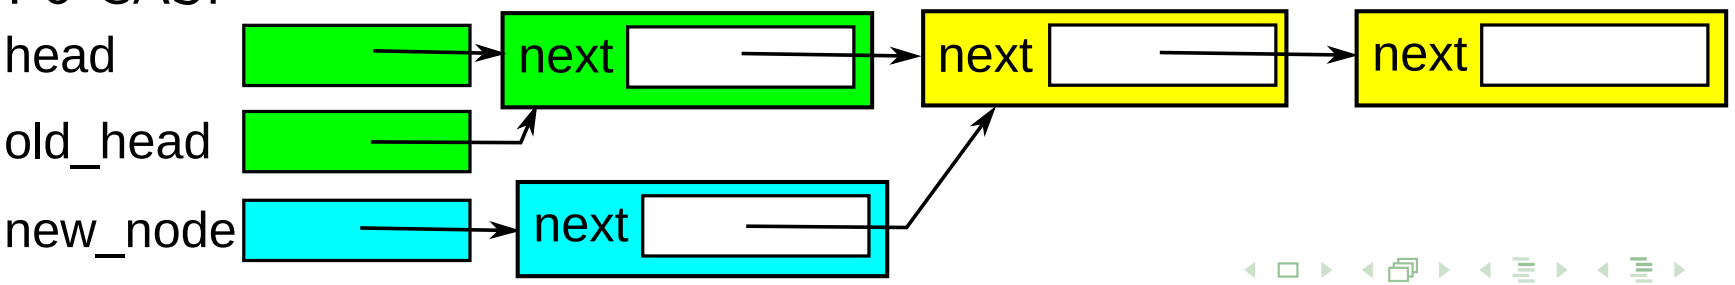

Bufor cykliczny lock-free

Bufor cykliczny – bardzo dobry wybór w przypadku jeden producent danych, jeden konsument. Kolejka (FIFO) o ustalonym rozmiarze.

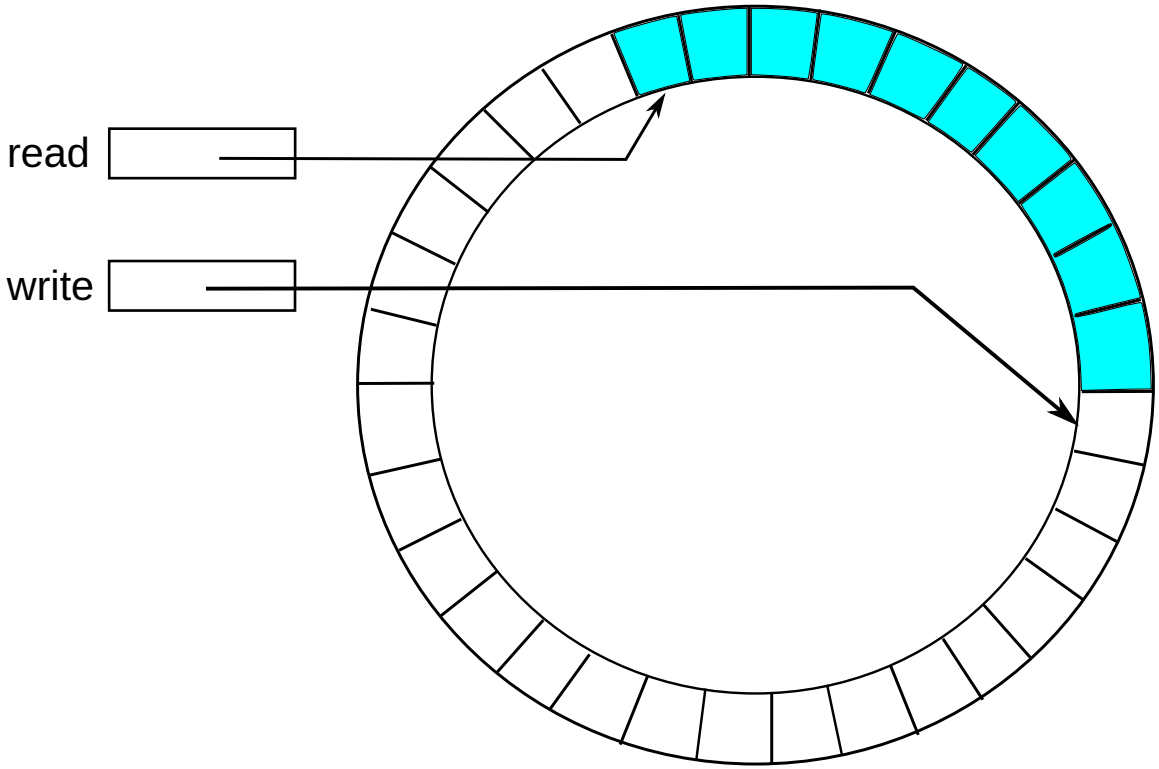

Można się zgłosić, zaimplementować i zbadać, w ramach zadania dodatkowego.

Aplikacje współbieżne, podsumowanie

Mogą wystąpić wyścigi:

- błędy są niepowtarzalne,
- różne zachowanie się wersji debug od release,
- różne zachowanie się na platformach jedno i wielo-procesorowych.

Niezbędny poprawny projekt – nie da się wychwycić w statycznej analizie kodu (kompilacja) i w testach!

Zapobieganie wyścigom: sekcje krytyczne lub operacje atomowe

- operacje atomowe są wolniejsze niż te same operacje nieatomowe, nawet dla typów takich jak 'int' (czekają na dostęp do linii cache),
- operacje atomowe mogą być szybsze lub wolniejsze niż sekcje krytyczne
- sekcje krytyczne zawsze zmniejszają skalowalność

Biblioteki związane ze współbieżnością

- **Boost.Interprocess** komunikacja pomiędzy procesami
  Przenośne mechanizmy komunikacji pomiędzy procesami (aplikacjami).
  - pamięć dzielona (shared memory)
  - mechanizmy synchronizujące w tej pamięci (semafory, zmienne warunkowe
  - komunikacja przez pliki
  - kolejki komunikatów
- **OpenMP** - interfejs do tworzenia aplikacji wykorzystujących współbieżność
- **Boost.Asio** asynchroniczna obsługa urządzeń wejścia-wyjścia

Dziękuję