Sztuka Wytwarzania Oprogramowania

Wykład 14 - współbieżność. Współbieżne wzorce projektowe, cz 2

Robert Nowak

25Z

Plan wykładu

- procesy, wątki, wyścigi, blokady, skalowalność
- obsługa wejścia/wyjścia, pętla obsługi zdarzeń, asynchroniczna obsługa wejścia-wyjścia, boost::asio, reaktor, proaktor
- operacje atomowe, std::atomic, algorytmy bez blokad (lock-free)
- podsumowanie

powtórzenie: procesy, wątki, wyścigi, blokady (1)

- Procesor działa znacznie szybciej, niż inne urządzenia
- współczesne komputery są wieloprocesorowe (wielordzeniowe)

Wątek realizuje niezależne ciągi instrukcji w ramach procesu.

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

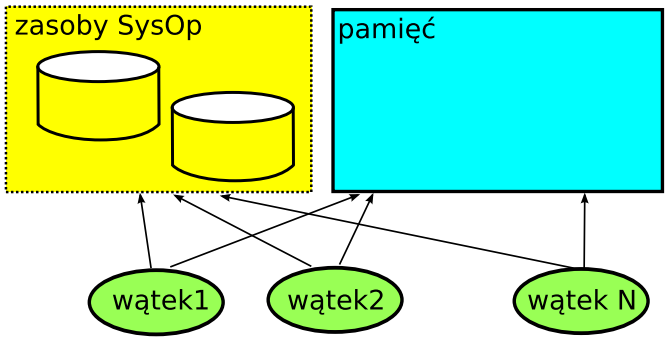

W aplikacjach współbieżnych mogą wystąpić wyścigi.

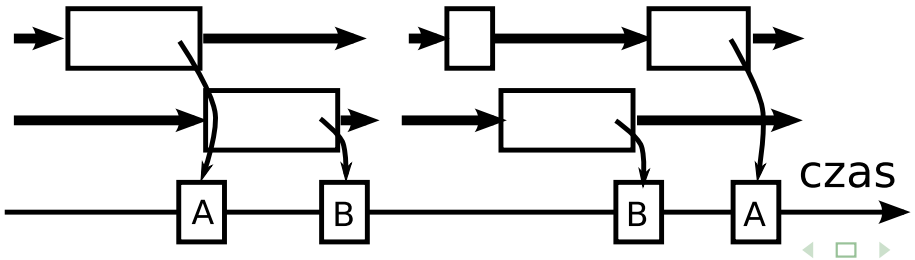

powtórzenie: procesy, wątki, wyścigi, blokady (2)

Wyścigom można zapobiegać wykorzystując sekcje krytyczne (blokady).

```
#include <mutex>
mutex.lock();
//Sekcja krytyczna, w danej chwili dostęp ma tylko jeden wątek
mutex.unlock();
```

Niewłaściwe stosowanie blokad może prowadzić do zakleszczeń.

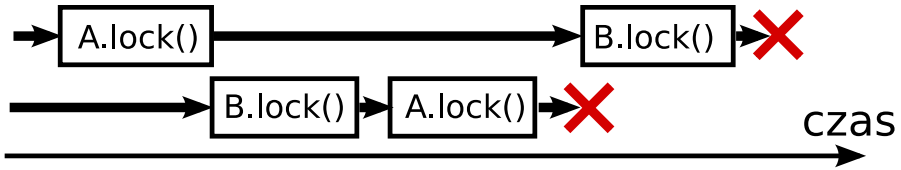

Skalowalność:

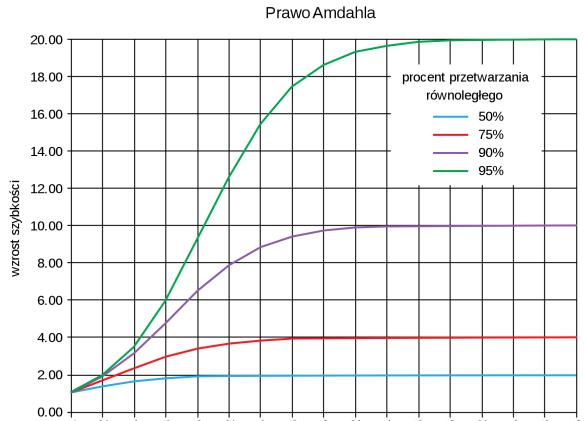

Obsługa urządzeń wejścia wyjścia

System operacyjny zapewnia 3 metody obsługi urządzeń wejścia/wyjścia:

- synchroniczne blokujące - sterowanie wraca, gdy operacja jest zakończona
- synchronicznie nieblokujące - sterowanie wraca natychmiast z informacją, czy udało się zrealizować operację (np. z informacją o ilości odczytanych bajtów), użytkownik może operację ponowić
- asynchroniczne - sterowanie wraca natychmiast, użytkownik dostarcza uchwyt (handler, callback), który będzie wołany, gdy operacja się zakończy

Obsługa urządzeń bazująca na wątkach

Wykorzystuje synchroniczne metody obsługi wejścia/wyjścia

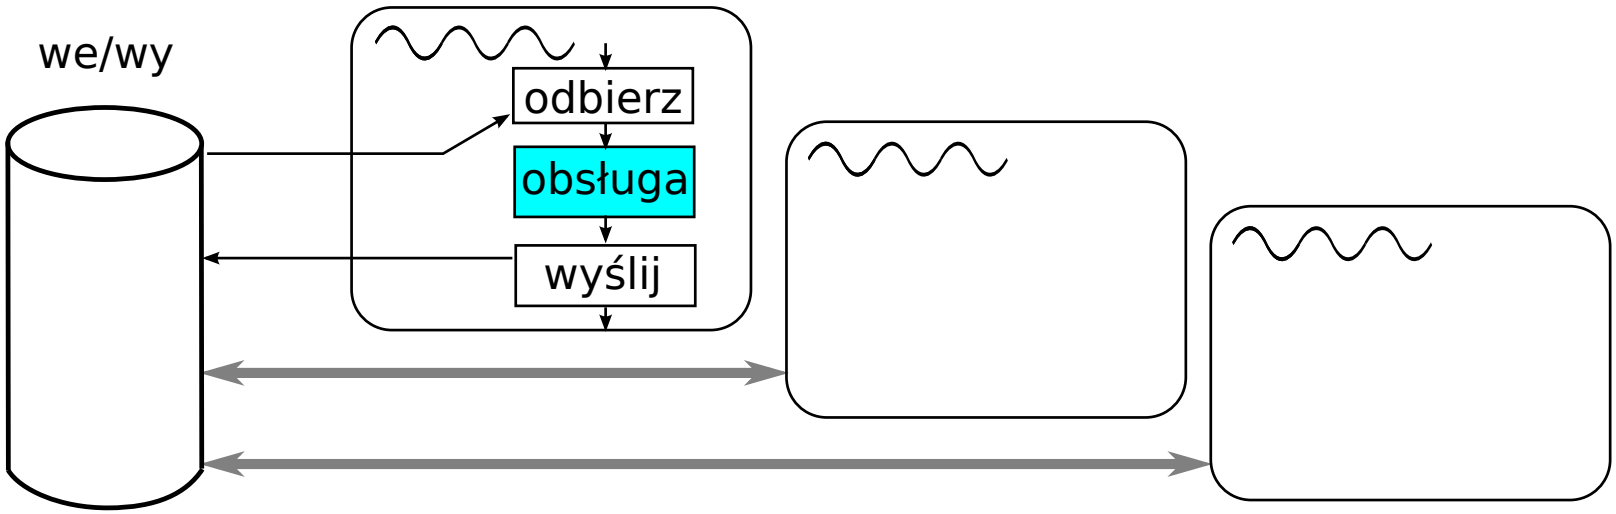

Właściwości:

- sekwencyjna (prosta) struktura sterowania
- narzuty: synchronizacja, blokady, mechanizm przełączania wątków

Obsługa urządzeń bazująca na zdarzeniach

Wykorzystuje synchroniczne lub asynchroniczne metody obsługi wejścia/wyjścia

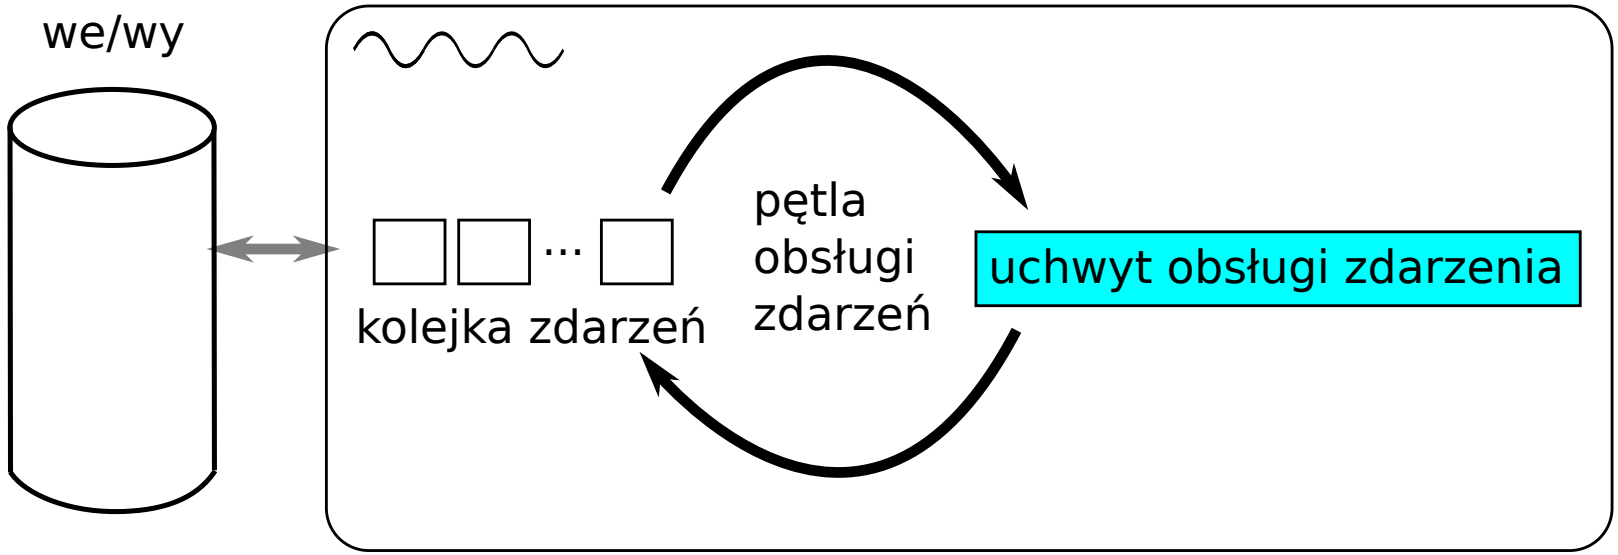

- odwrócenie sterowania: rejestrujemy uchwyty, które będą wykonywane
- brak kontroli nad kolejnością obsługi
- brak narzutów na synchronizację, blokady, wątki

Boost.Asio - synchroniczne/asynchroniczne we/wy w C++

Przenośna obsługa:

- zegarów (timer)
- gniazd (socket) UDP, TCP (oraz strumieni z nimi związanych)
- portów szeregowych
- sygnałów
- synchronicznych/asynchronicznych operacjach na uchwytach do plików

Wsparcie dla:

- Win64, Win32 (np. Windows NT), Windows 95, 98, Me
- Linux (jądra od 2.4), 32 i 64bit,
- Mac OS X, Solaris, QNX i inne.

Boost.Asio - zegary

```
//Funkcja wołana, gdy zajdzie odpowiednie zdarzenie
void event(const boost::system::error_code&) {
  cout << "timer 2 event" << endl;
}

int main() {
  boost::asio::io_service io; //obiekt obsługujący zdarzenia
  boost::asio::deadline_timer t1(io, boost::posix_time::seconds(3));
  t1.wait(); //rejestracja zdarzenia i wykonanie synchroniczne
  cout << "timer 1 event" << endl;

  boost::asio::deadline_timer t2(io, boost::posix_time::seconds(3));
  t2.async_wait(event); //rejestracja zdarzenia i wykonanie synchr.
  io.run(); //obsługa zdarzeń asynchronicznych
  return 0;
}
```

Wzorzec projektowy reaktora (reactor)

Obsługa urządzeń oparta o zdarzenia. Odwrócenie sterowania.

Wykorzystuje nieblokujące, synchroniczne operacje wejścia-wyjścia.

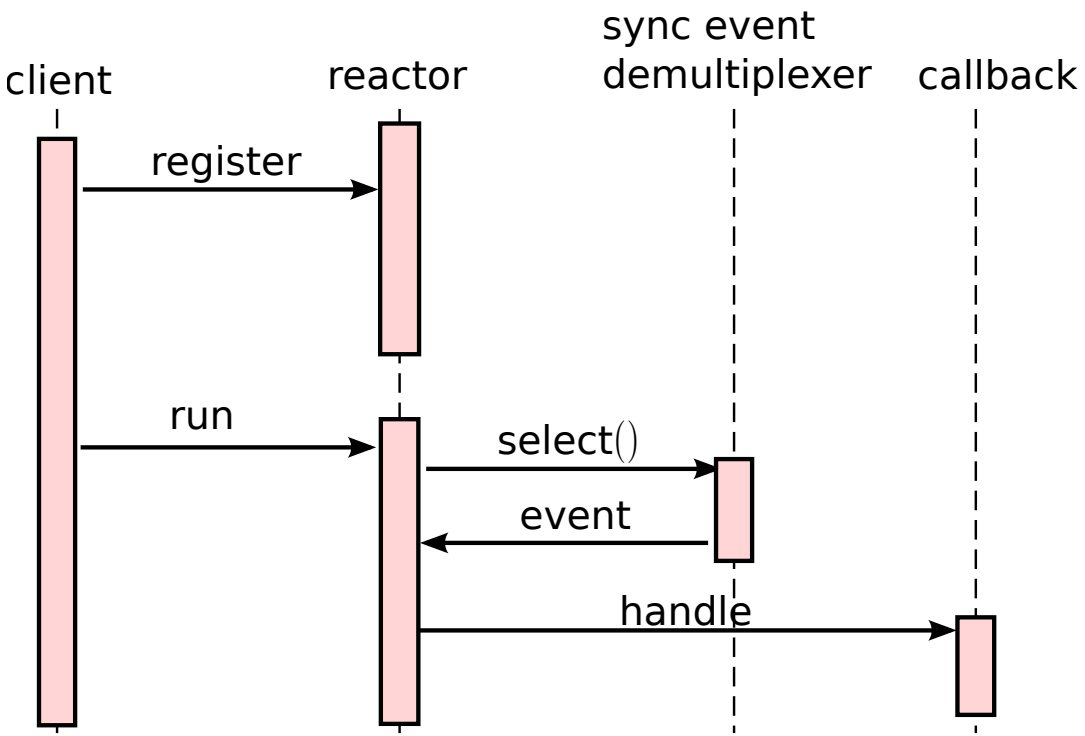

Wzorzec projektowy proaktora (proactor)

Obsługa urządzeń oparta o zdarzenia. Odwrócenie sterowania.

Wykorzystuje asynchroniczne operacje wejścia-wyjścia.

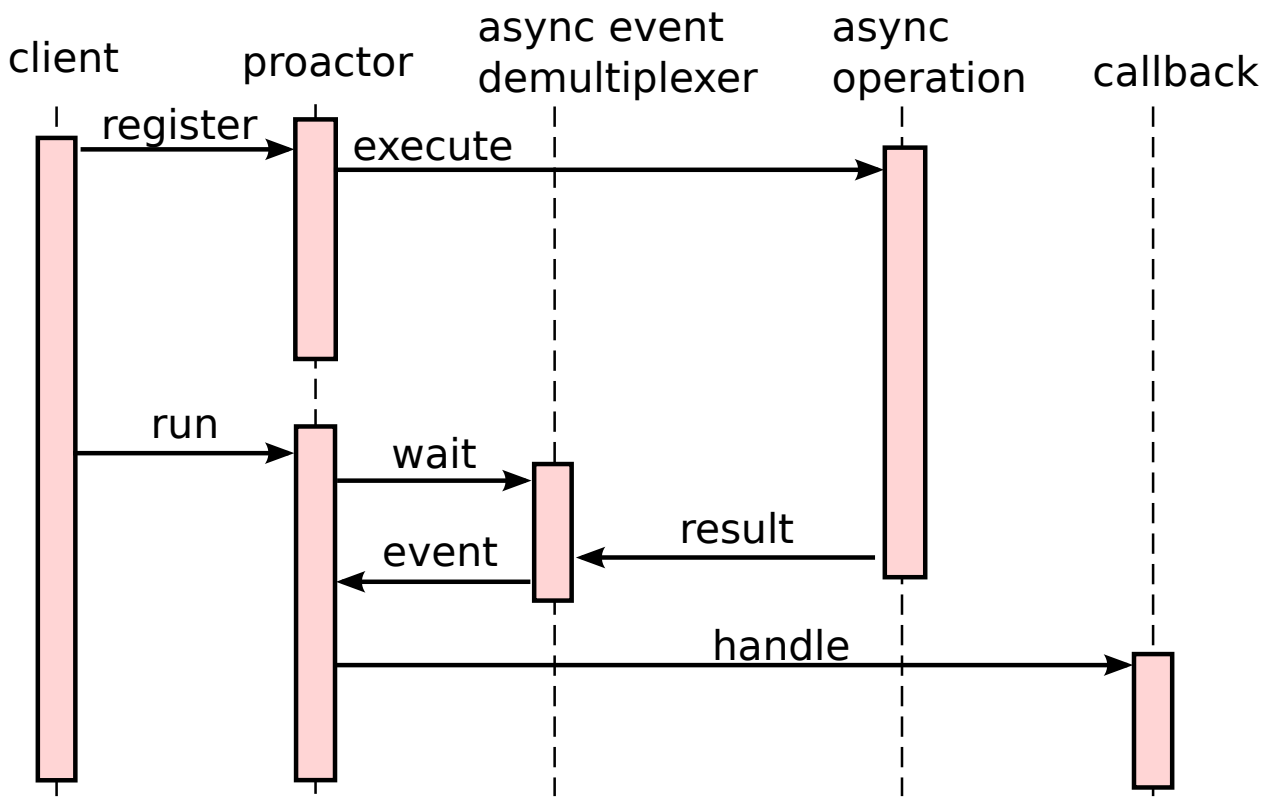

Boost.Asio, porty szeregowe

```
using Time = steady_timer::duration; using Error = const error_code&;
class SerialPort {
public:
  SerialPort(const string& n,Time t):io(),timeout(t),port(io,n),timer(io){}
  ~SerialPort() { port.close(); }
  const vector<char>& read_n(int n) { //petla obsl. zdarzen
    timer.expires_from_now( timeout);
    timer.async_wait([=](Error e){this->timerEvent(e);});
    readSomeCall(n);
    io.run();
    return buffer;
  }
private:
  io_service io_; Time timeout;
  serial_port port;//port szeregowy
  steady_timer timer; //zegar
  char tab [1]; //bufor transmisji
  vector<char> buffer; //bufor odczytu
  //...
```

Boost.Asio, porty szeregowe (2)

```
  //...
  void readSomeCall(int n) {
    port.async_read_some(tab,[=](Error e,int n){this->readEvent(e,n);});
  }
  void readEvent(Error error, int n) {
    if( error ) return; //jeżeli wystąpił błąd odczytu
    buffer_.push_back(tab[0]);
    if(buffer_.size()>=n){ //koniec czytania
      timer.cancel();
      return;
    }
    readSomeCall(n);
  }
  void timerEvent(Error error) {
    if( error ) return; //jeżeli zdarzenie wycofane, to nic nie rób
    port.cancel(); //wygeneruje zdarzenie odczytu z błędem
  }
};
```

Instrukcje atomowe

- 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 x = 0;
++x; //nie jest atomowa!
//1.odczyt z pamięci do rejestru, 2.wykonanie ++x, 3.zapis do pamięci
```

Przykłady dla C++ `std::atomic`.

- typy danych, które mogą być atomowe,
- narzuty przy operacjach na typach atomowych,
- algorytmy bez blokad.

Instrukcje atomowe - przykład (1)

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

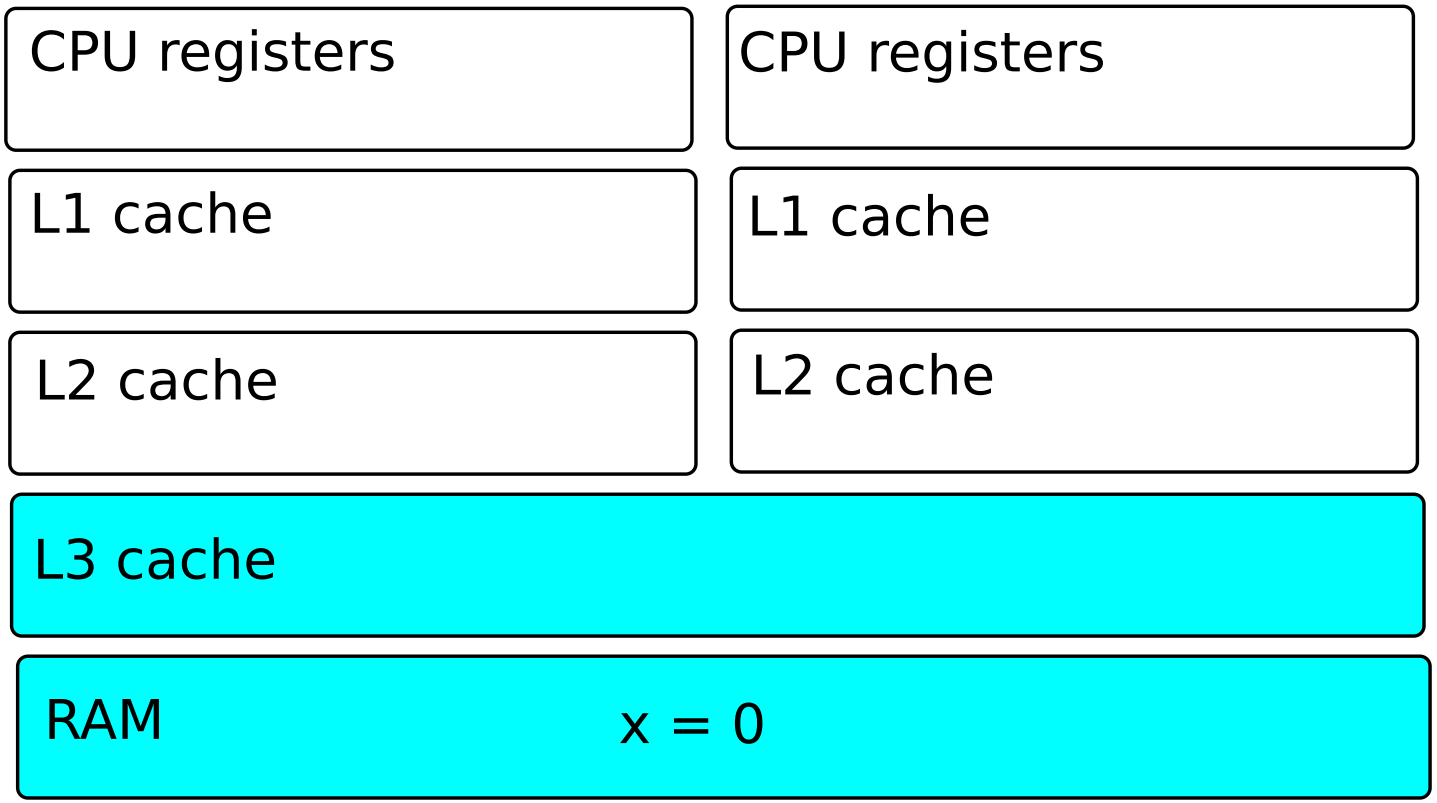

Instrukcje atomowe - przykład (1)

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

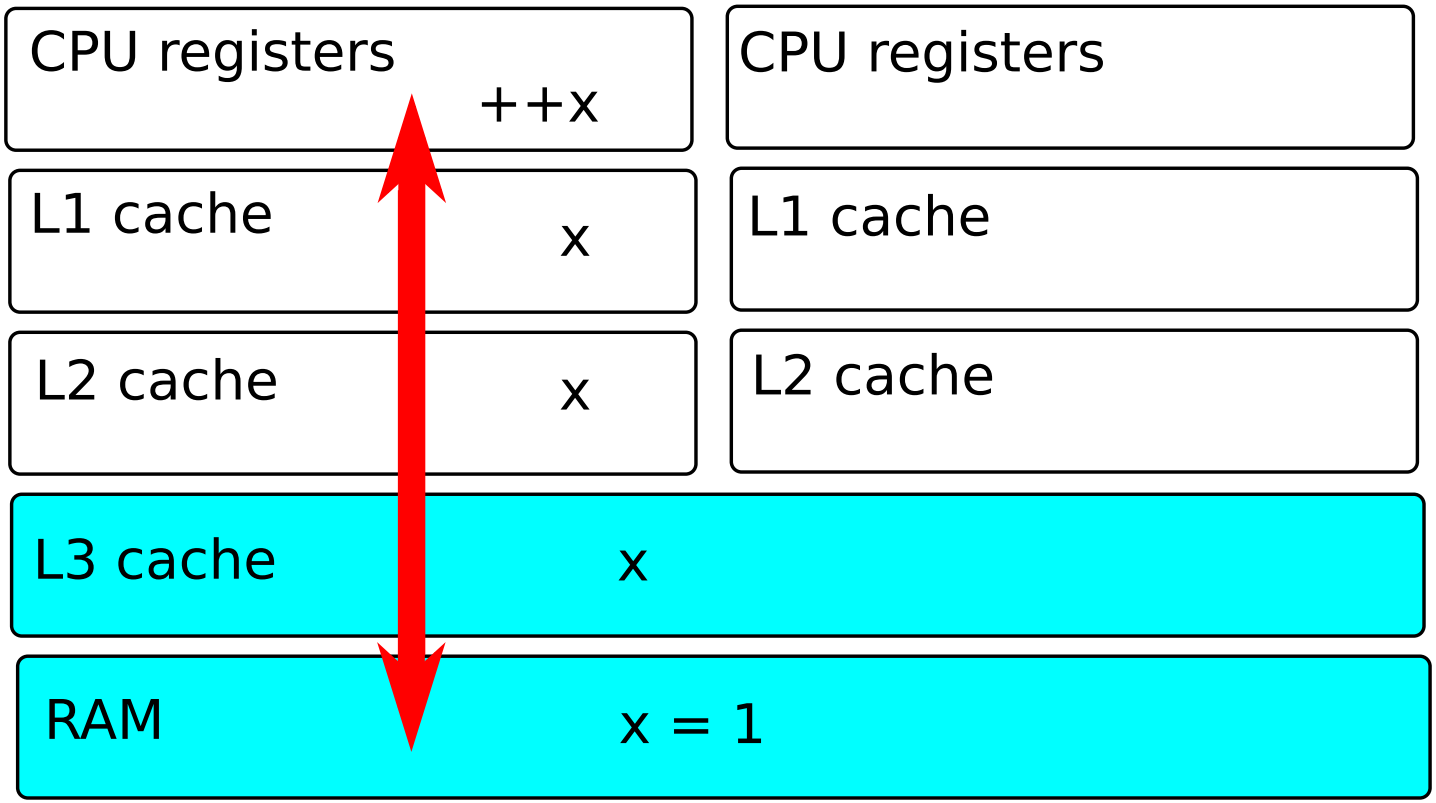

Instrukcje atomowe - przykład (1)

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

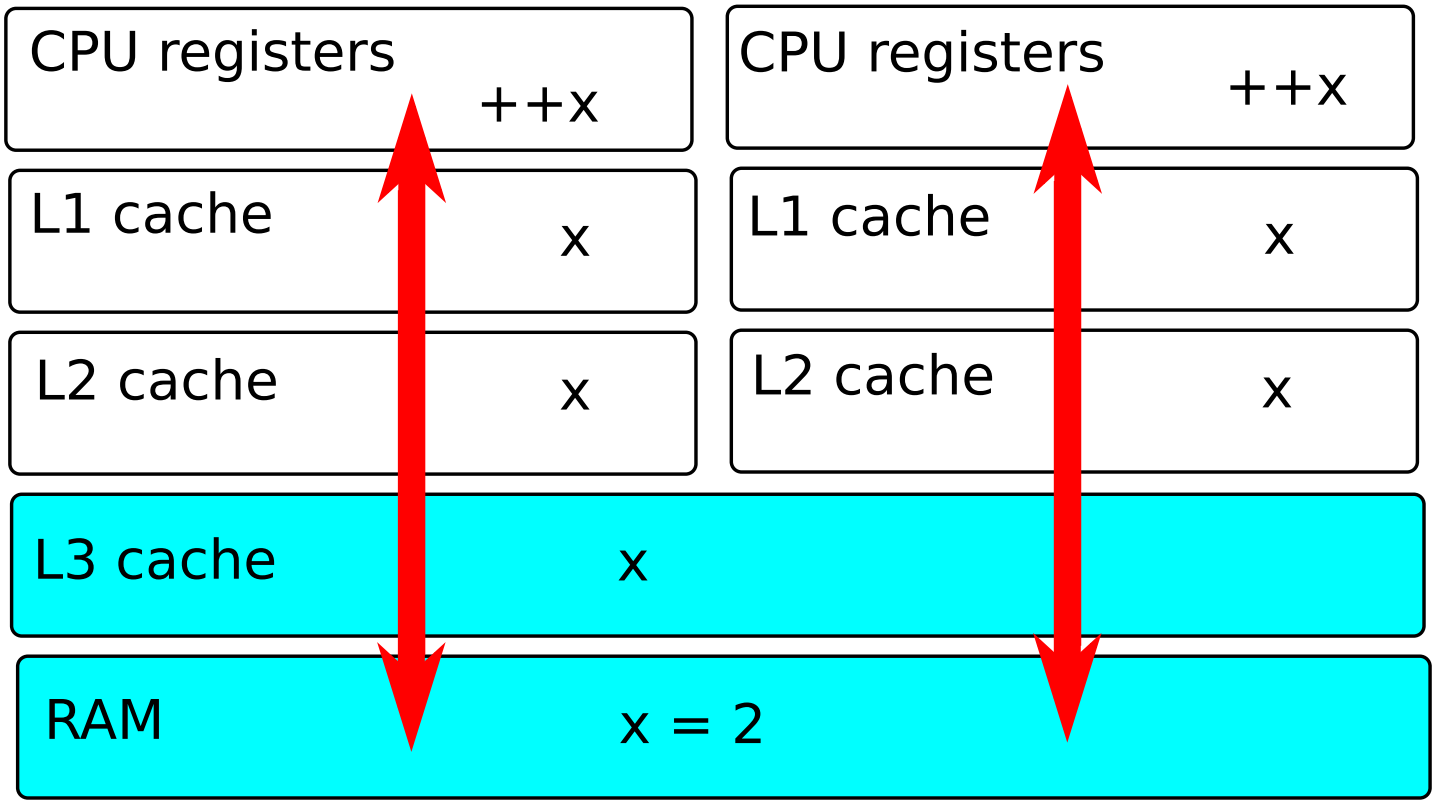

Typy danych, które mogą być atomowe

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!
```

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

Specjalne typy atomowe

`atomic<Integral>` (bool, char, short, int, long, ... unsigned int, ...)	`operator++`, `operator--`, `operator+=`, `operator-=`, `operator&=`, `operator|=`, `operator^=` `fetch_add`, `fetch_sub`, `fetch_and`, `fetch_or`, `fetch_xor`
`atomic_signed_lock_free`, `atomic_unsigned_lock_free`	wydajne
`atomic<float>`, `atomic<double>`, `atomic<long double>`	`fetch_add`, `fetch_sub`
`atomic<U*>`, `atomic<shared_ptr>`, `atomic<weak_ptr>`	wskaźnik i sprytne wskaźniki, operacje na licznikach będą atomowe

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):

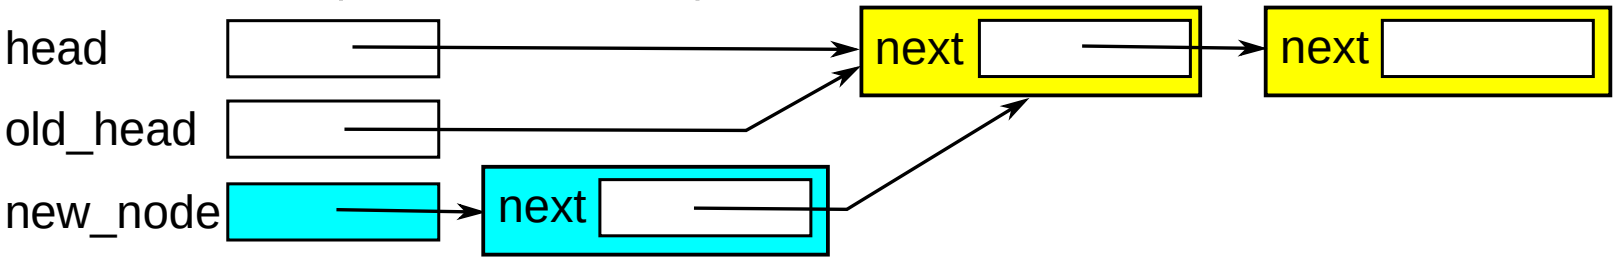

Po CAS:

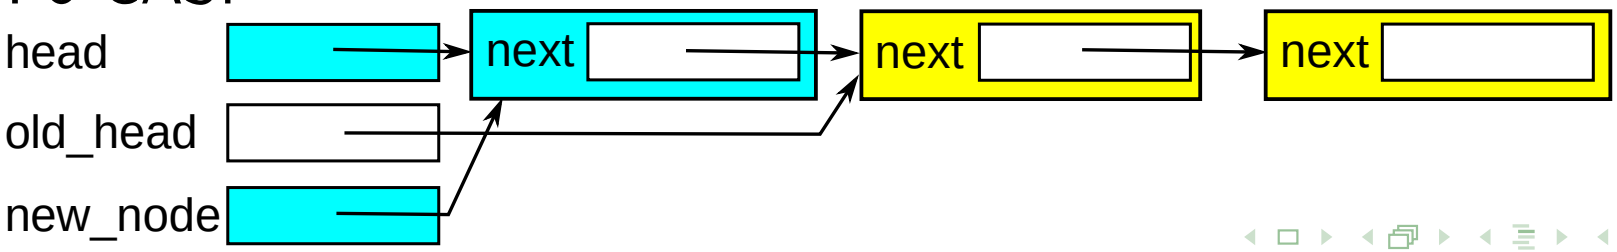

Struktury danych bez blokad (lock-free) (3)

```
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:

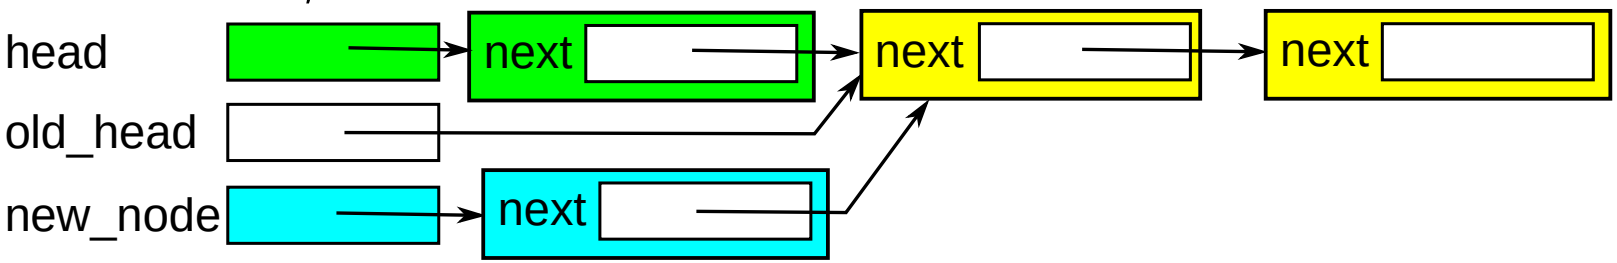

Po CAS:

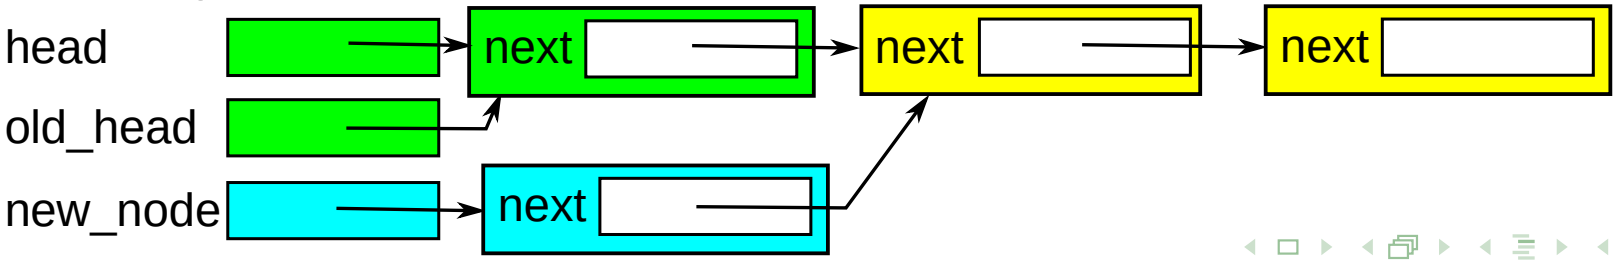

Instrukcje atomowe - podsumowanie

- Operacje atomowe są znacznie wolniejsze niż te same operacje nieatomowe, nawet dla typów takich jak 'int' (czekają na dostęp do linii cache),
- warto je stosować do tworzenia współbieżnych struktur danych (lock-free),
- algorytmy lock-free są trudne do implemtacji
- algorytmy lock-free są także trudne do zrozumienia.

Operacje atomowe mogą być szybsze lub wolniejsze niż sekcje krytyczne.

Powtórzenie

Wyścig?

```
using Counter = int;
struct MTCounter { //wsk. na Counter z mutexem
  MTCounter() : counter(new Counter(0)) {}
  void inc() { lock_guard lock(m_); *counter += 1; }
  int get() { lock_guard lock(m_); return *counter; }
  shared_ptr<Counter> counter; //wskaźnik
  mutex m_;
};
struct Thread {
  Thread(MTCounter counter) : c(counter) {}
  void operator()() { for(int i=0;i<1000000;++i) c.inc(); }
  MTCounter c;
};
int main() {
  MTCounter counter; Thread t1(counter), t2(counter);
  thread thrd1(ref(t1)), thrd2(ref(t2));
  thrd1.join(); thrd2.join();
  return 0;
}
```

Rozwiązanie

```
//Rozwiązanie - sekcja krytyczna
struct CounterSync {
  CounterSync() : value(0) {}
  int value; mutex m;
};
struct MTCounterSync {
  MTCounterSync() : counter(new CounterSync) {}
  void inc() { lock_buard lock(counter->m); counter->value += 1; }
  int get(){ lock_guard(counter->m); return counter->value; }
  shared_ptr<CounterSync> counter; //współdzielony licznik
};
//Rozwiązanie - licznik wykorzystuje operacje atomowe
using CounterAtomic = std::atomic<int>;
struct MTCounterAtomic {
  MTCounterSync() : counter(new CounterAtomic(0)) {}
  void inc() { *counter += 1; }
  int get(){ return *counter; }
  shared_ptr<CounterAtomic> counter; //współdzielony licznik
};
```

Zadanie 2: popraw wydajność. Funkcja main

```
class Data {/* składowe nieistotne */}; using PData = shared_ptr<Data>;
struct Out {
    Out(int size) : size_(size) {}
    int size_;
    std::vector<PData> v_;
    mutex m_;
};
int main() {
    Out out(10000);
    boost::asio::io_service io;
    boost::asio::deadline_timer t01(milliseconds(8) );
    //...
    boost::asio::deadline_timer t99(milliseconds(8) );
    t01.async_wait([&](const error_code& e){ serve_event(out,t01,e);});
    //...
    t99.async_wait([&](const error_code& e){ serve_event(out,t99,e);});
    io.run();
    return 0;
}
```

Zadanie 2: popraw wydajność. Obługa urządzenia

```
struct Out { //powtórzona z poprzedniego slajdu
    Out(int size) : size_(size) {}
    int size_;
    std::vector<PData> v_;
    mutex m_;
};

void serve_event( Out& out, deadline_timer& t, const error_code& error) {
  if( error ) return;
  //obliczenia lokalne, tworzy dane dla nowej paczki
  lock_guard<mutex> guard(out.m_);
  PData data = PData(new Data()); //tworzy nową paczkę, kopiuje dane
  out.v_.push_back(data);
  if(out.v_.size() < out.size_) {
    t.async_wait([&](const error_code& error){ serve_event(out,t,error);});
  }
}
```

Zadanie 2: popraw wydajność. Rozwiązanie

```
struct Out { //powtórzona z poprzedniego slajdu
    Out(int size) : size_(size) {}
    int size_;
    std::vector<PData> v_;
    mutex m_;
};

//pętla zdarzeń, nie ma konieczności stosowania sekcji krytycznej!
void serve_event( Out& out, boost::asio::deadline_timer& t, const error_cod
  if( error ) return;
  //obliczenia lokalne, tworzy dane dla nowej paczki
  PData data = PData(new Data()); //tworzy nową paczkę, kopiuje dane
  out.v_.push_back(data);
  if(out.v_.size() < out.size_) {
    t.async_wait([&](const error_code& error){ serve_event(out,t,error);});
  }
}
```

Dziękuję

robert.nowak@pw.edu.pl