Anthony Williams

Odkryj wszystkie tajemnice wielowątkowych aplikacji!

Język C++
i przetwarzanie współbieżne w akcji

Tytuł oryginału: C++ Concurrency in Action: Practical Multithreading

Tłumaczenie: Mikołaj Szczepaniak

Projekt okładki: Anna Mitka
Materiały graficzne na okładce zostały wykorzystane za zgodą Shutterstock Images LLC.

ISBN: 978-83-246-5086-6

Original edition copyright © 2012 by Manning Publications Co.
All rights reserved.

Polish edition copyright © 2013 by HELION SA.
All rights reserved.

All rights reserved. No part of this book may be reproduced or transmitted in any form or by any means, electronic or mechanical, including photocopying, recording or by any information storage retrieval system, without permission from the Publisher.

Wszelkie prawa zastrzeżone. Nieautoryzowane rozpowszechnianie całości lub fragmentu niniejszej publikacji w jakiejkolwiek postaci jest zabronione. Wykonywanie kopii metodą kserograficzną, fotograficzną, a także kopiowanie książki na nośniku filmowym, magnetycznym lub innym powoduje naruszenie praw autorskich niniejszej publikacji.

Wszystkie znaki występujące w tekście są zastrzeżonymi znakami firmowymi bądź towarowymi ich właścicieli.

Autor oraz Wydawnictwo HELION dołożyli wszelkich starań, by zawarte
w tej książce informacje były kompletne i rzetelne. Nie biorą jednak żadnej odpowiedzialności ani za ich wykorzystanie, ani za związane z tym ewentualne naruszenie praw patentowych lub autorskich. Autor oraz Wydawnictwo HELION nie ponoszą również żadnej odpowiedzialności za ewentualne szkody wynikłe z wykorzystania informacji zawartych w książce.

Wydawnictwo HELION
ul. Kościuszki 1c, 44-100 GLIWICE
tel. 32 231 22 19, 32 230 98 63
e-mail: helion@helion.pl
WWW: http://helion.pl (księgarnia internetowa, katalog książek)

Drogi Czytelniku!
Jeżeli chcesz ocenić tę książkę, zajrzyj pod adres
http://helion.pl/user/opinie?gimpbi
Możesz tam wpisać swoje uwagi, spostrzeżenia, recenzję.

Printed in Poland.

- Kup książkę
- Poleć książkę
- Oceń książkę

- Księgarnia internetowa
- Lubię to! » Nasza społeczność

Spis treści

Słowo wstępne *11*
Podziękowania *13*
O tej książce *15*

Rozdział 1. Witaj, świecie współbieżności w C++! 19

1.1. Czym jest współbieżność? 20
1.1.1. Współbieżność w systemach komputerowych 20
1.1.2. Modele współbieżności 22
1.2. Dlaczego warto stosować współbieżność? 25
1.2.1. Stosowanie współbieżności do podziału zagadnień 25
1.2.2. Stosowanie współbieżności do podniesienia wydajności 26
1.2.3. Kiedy nie należy stosować współbieżności 27
1.3. Współbieżność i wielowątkowość w języku C++ 28
1.3.1. Historia przetwarzania wielowątkowego w języku C++ 29
1.3.2. Obsługa współbieżności w nowym standardzie 30
1.3.3. Efektywność biblioteki wątków języka C++ 30
1.3.4. Mechanizmy związane z poszczególnymi platformami 32
1.4. Do dzieła! 32
1.4.1. „Witaj świecie współbieżności” 32
1.5. Podsumowanie 34

Rozdział 2. Zarządzanie wątkami 35

2.1. Podstawowe zarządzanie wątkami 36
2.1.1 Uruchamianie wątku 36
2.1.2. Oczekiwanie na zakończenie wątku 39
2.1.3. Oczekiwanie w razie wystąpienia wyjątku 39
2.1.4. Uruchamianie wątków w tle 42
2.2. Przekazywanie argumentów do funkcji wątku 43
2.3. Przenoszenie własności wątku 46
2.4. Wybór liczby wątków w czasie wykonywania 49
2.5. Identyfikowanie wątków 52
2.6. Podsumowanie 54

Rozdział 3. Współdzielenie danych przez wątki 55

3.1. Problemy związane ze współdzieleniem danych przez wątki 56
3.1.1. Sytuacja wyścigu 58
3.1.2. Unikanie problematycznych sytuacji wyścigu 59
3.2. Ochrona współdzielonych danych za pomocą muteksów 60
3.2.1. Stosowanie muteksów w języku C++ 60
3.2.2. Projektowanie struktury kodu z myślą o ochronie współdzielonych danych 62

3.2.3. Wykrywanie sytuacji wyścigu związanych z interfejsami ... 63
3.2.4. Zakleszczenie: problem i rozwiązanie ... 71
3.2.5. Dodatkowe wskazówki dotyczące unikania zakleszczeń ... 73
3.2.6. Elastyczne blokowanie muteksów za pomocą szablonu std::unique_lock ... 79
3.2.7. Przenoszenie własności muteksu pomiędzy zasięgami ... 80
3.2.8. Dobór właściwej szczegółowości blokad ... 82
3.3. Alternatywne mechanizmy ochrony współdzielonych danych ... 84
3.3.1. Ochrona współdzielonych danych podczas inicjalizacji ... 84
3.3.2. Ochrona rzadko aktualizowanych struktur danych ... 88
3.3.3. Blokowanie rekurencyjne ... 90
3.4. Podsumowanie ... 91

Rozdział 4. Synchronizacja współbieżnych operacji 93

4.1. Oczekiwanie na zdarzenie lub inny warunek ... 94
4.1.1. Oczekiwanie na spełnienie warunku za pomocą zmiennych warunkowych ... 95
4.1.2. Budowa kolejki gwarantującej bezpieczne przetwarzanie wielowątkowe przy użyciu zmiennych warunkowych ... 97
4.2. Oczekiwanie na jednorazowe zdarzenia za pomocą przyszłości ... 102
4.2.1. Zwracanie wartości przez zadania wykonywane w tle ... 103
4.2.2. Wiązanie zadania z przyszłością ... 106
4.2.3. Obietnice (szablon std::promise) ... 109
4.2.4. Zapisywanie wyjątku na potrzeby przyszłości ... 111
4.2.5. Oczekiwanie na wiele wątków ... 112
4.3. Oczekiwanie z limitem czasowym ... 115
4.3.1. Zegary ... 115
4.3.2. Okresy ... 117
4.3.3. Punkty w czasie ... 118
4.3.4. Funkcje otrzymujące limity czasowe ... 120
4.4. Upraszczanie kodu za pomocą technik synchronizowania operacji ... 121
4.4.1. Programowanie funkcyjne przy użyciu przyszłości ... 122
4.4.2. Synchronizacja operacji za pomocą przesyłania komunikatów ... 127
4.5. Podsumowanie ... 131

Rozdział 5. Model pamięci języka C++ i operacje na typach atomowych 133

5.1. Podstawowe elementy modelu pamięci ... 134
5.1.1. Obiekty i miejsca w pamięci ... 134
5.1.2. Obiekty, miejsca w pamięci i przetwarzanie współbieżne ... 135
5.1.3. Kolejność modyfikacji ... 136
5.2. Operacje i typy atomowe języka C++ ... 137
5.2.1. Standardowe typy atomowe ... 138
5.2.2. Operacje na typie std::atomic_flag ... 141
5.2.3. Operacje na typie std::atomic<bool> ... 143
5.2.4. Operacje na typie std::atomic<T*> — arytmetyka wskaźników ... 146
5.2.5. Operacje na standardowych atomowych typach całkowitoliczbowych ... 147
5.2.6. Główny szablon klasy std::atomic<> ... 147
5.2.7. Wolne funkcje dla operacji atomowych ... 150
5.3. Synchronizacja operacji i wymuszanie ich porządku ... 151
5.3.1. Relacja synchronizacji ... 152
5.3.2. Relacja poprzedzania ... 154
5.3.3. Porządkowanie pamięci na potrzeby operacji atomowych ... 155
5.3.4. Sekwencje zwalniania i relacja synchronizacji ... 175

5.3.5. Ogrodzenia ... 178
5.3.6. Porządkowanie operacji nieatomowych za pomocą operacji atomowych ... 180
5.4. Podsumowanie ... 182

Rozdział 6. Projektowanie współbieżnych struktur danych przy użyciu blokad 183

6.1. Co oznacza projektowanie struktur danych pod kątem współbieżności? ... 184
6.1.1. Wskazówki dotyczące projektowania współbieżnych struktur danych ... 185
6.2. Projektowanie współbieżnych struktur danych przy użyciu blokad ... 186
6.2.1. Stos gwarantujący bezpieczeństwo przetwarzania wielowątkowego przy użyciu blokad ... 187
6.2.2. Kolejka gwarantująca bezpieczeństwo przetwarzania wielowątkowego przy użyciu blokad i zmiennych warunkowych ... 190
6.2.3. Kolejka gwarantująca bezpieczeństwo przetwarzania wielowątkowego przy użyciu szczegółowych blokad i zmiennych warunkowych ... 194
6.3. Projektowanie złożonych struktur danych przy użyciu blokad ... 207
6.3.1. Implementacja tablicy wyszukiwania gwarantującej bezpieczeństwo przetwarzania wielowątkowego przy użyciu blokad ... 207
6.3.2. Implementacja listy gwarantującej bezpieczeństwo przetwarzania wielowątkowego przy użyciu blokad ... 213
6.4. Podsumowanie ... 218

Rozdział 7. Projektowanie współbieżnych struktur danych bez blokad 219

7.1. Definicje i ich praktyczne znaczenie ... 220
7.1.1. Rodzaje nieblokujących struktur danych ... 220
7.1.2. Struktury danych bez blokad ... 221
7.1.3. Struktury danych bez oczekiwania ... 222
7.1.4. Zalety i wady struktur danych bez blokad ... 222
7.2. Przykłady struktur danych bez blokad ... 223
7.2.1. Implementacja stosu gwarantującego bezpieczeństwo przetwarzania wielowątkowego bez blokad ... 224
7.2.2. Eliminowanie niebezpiecznych wycieków — zarządzanie pamięcią w strukturach danych bez blokad ... 228
7.2.3. Wykrywanie węzłów, których nie można odzyskać, za pomocą wskaźników ryzyka ... 233
7.2.4. Wykrywanie używanych węzłów metodą zliczania referencji ... 242
7.2.5. Zmiana modelu pamięci używanego przez operacje na stosie bez blokad ... 247
7.2.6. Implementacja kolejki gwarantującej bezpieczeństwo przetwarzania wielowątkowego bez blokad ... 252
7.3. Wskazówki dotyczące pisania struktur danych bez blokad ... 264
7.3.1. Wskazówka: na etapie tworzenia prototypu należy stosować tryb std::memory_order_seq_cst ... 265
7.3.2. Wskazówka: należy używać schematu odzyskiwania pamięci bez blokad ... 265
7.3.3 Wskazówka: należy unikać problemu ABA ... 266
7.3.4. Wskazówka: należy identyfikować pętle aktywnego oczekiwania i wykorzystywać czas bezczynności na wspieranie innego wątku ... 267
7.4. Podsumowanie ... 267

Rozdział 8. Projektowanie współbieżnego kodu 269

8.1. Techniki dzielenia pracy pomiędzy wątki ... 270
8.1.1. Dzielenie danych pomiędzy wątki przed rozpoczęciem przetwarzania ... 271
8.1.2. Rekurencyjne dzielenie danych ... 272
8.1.3. Dzielenie pracy według typu zadania ... 276

8.2. Czynniki wpływające na wydajność współbieżnego kodu ... 279
8.2.1. Liczba procesorów ... 280
8.2.2. Współzawodnictwo o dane i ping-pong bufora ... 281
8.2.3. Fałszywe współdzielenie ... 284
8.2.4. Jak blisko należy rozmieścić dane? ... 285
8.2.5. Nadsubskrypcja i zbyt intensywne przełączanie zadań ... 285
8.3. Projektowanie struktur danych pod kątem wydajności przetwarzania wielowątkowego ... 286
8.3.1. Podział elementów tablicy na potrzeby złożonych operacji ... 287
8.3.2. Wzorce dostępu do danych w pozostałych strukturach ... 289
8.4. Dodatkowe aspekty projektowania współbieżnych struktur danych ... 291
8.4.1. Bezpieczeństwo wyjątków w algorytmach równoległych ... 291
8.4.2. Skalowalność i prawo Amdahla ... 298
8.4.3. Ukrywanie opóźnień za pomocą wielu wątków ... 300
8.4.4. Skracanie czasu reakcji za pomocą technik przetwarzania równoległego ... 301
8.5. Projektowanie współbieżnego kodu w praktyce ... 303
8.5.1. Równoległa implementacja funkcji std::for_each ... 304
8.5.2. Równoległa implementacja funkcji std::find ... 306
8.5.3. Równoległa implementacja funkcji std::partial_sum ... 312
8.6. Podsumowanie ... 322

Rozdział 9. Zaawansowane zarządzanie wątkami 323

9.1. Pule wątków ... 324
9.1.1. Najprostsza możliwa pula wątków ... 324
9.1.2. Oczekiwanie na zadania wysyłane do puli wątków ... 327
9.1.3. Zadania oczekujące na inne zadania ... 330
9.1.4. Unikanie współzawodnictwa w dostępie do kolejki zadań ... 333
9.1.5. Wykradanie zadań ... 335
9.2. Przerywanie wykonywania wątków ... 340
9.2.1. Uruchamianie i przerywanie innego wątku ... 340
9.2.2. Wykrywanie przerwania wątku ... 342
9.2.3. Przerywanie oczekiwania na zmienną warunkową ... 343
9.2.4. Przerywanie oczekiwania na zmienną typu std::condition_variable_any ... 346
9.2.5. Przerywanie pozostałych wywołań blokujących ... 348
9.2.6. Obsługa przerwań ... 349
9.2.7. Przerywanie zadań wykonywanych w tle podczas zamykania aplikacji ... 350
9.3. Podsumowanie ... 352

Rozdział 10. Testowanie i debugowanie aplikacji wielowątkowych 353

10.1. Rodzaje błędów związanych z przetwarzaniem współbieżnym ... 354
10.1.1. Niechciane blokowanie ... 354
10.1.2. Sytuacje wyścigu ... 355
10.2. Techniki lokalizacji błędów związanych z przetwarzaniem współbieżnym ... 357
10.2.1. Przeglądanie kodu w celu znalezienia ewentualnych błędów ... 357
10.2.2. Znajdowanie błędów związanych z przetwarzaniem współbieżnym poprzez testowanie kodu ... 359
10.2.3. Projektowanie kodu pod kątem łatwości testowania ... 361
10.2.4. Techniki testowania wielowątkowego kodu ... 363
10.2.5. Projektowanie struktury wielowątkowego kodu testowego ... 366
10.2.6. Testowanie wydajności wielowątkowego kodu ... 369
10.3. Podsumowanie ... 370

Dodatek A Krótki przegląd wybranych elementów języka C++11 371

A.1. Referencje do r-wartości 371
A.1.1. Semantyka przenoszenia danych 372
A.1.2. Referencje do r-wartości i szablony funkcji 375
A.2. Usunięte funkcje 376
A.3. Funkcje domyślne 377
A.4. Funkcje constexpr 381
A.4.1. Wyrażenia constexpr i typy definiowane przez użytkownika 382
A.4.2. Obiekty constexpr 385
A.4.3. Wymagania dotyczące funkcji constexpr 385
A.4.4. Słowo constexpr i szablony 386
A.5. Funkcje lambda 386
A.5.1. Funkcje lambda odwołujące się do zmiennych lokalnych 388
A.6. Szablony zmiennoargumentowe 391
A.6.1. Rozwijanie paczki parametrów 392
A.7. Automatyczne określanie typu zmiennej 395
A.8. Zmienne lokalne wątków 396
A.9. Podsumowanie 397

Dodatek B Krótkie zestawienie bibliotek przetwarzania współbieżnego 399

Dodatek C Framework przekazywania komunikatów i kompletny przykład implementacji systemu bankomatu 401

Dodatek D Biblioteka wątków języka C++ 419

D.1. Nagłówek <chrono> 419
D.1.1. Szablon klasy std::chrono::duration 420
D.1.2. Szablon klasy std::chrono::time_point 429
D.1.3. Klasa std::chrono::system_clock 431
D.1.4. Klasa std::chrono::steady_clock 433
D.1.5. Definicja typu std::chrono::high_resolution_clock 435
D.2. Nagłówek <condition_variable> 435
D.2.1. Klasa std::condition_variable 436
D.2.2. Klasa std::condition_variable_any 444
D.3. Nagłówek <atomic> 452
D.3.1. Definicje typów std::atomic_xxx 454
D.3.2. Makra ATOMIC_xxx_LOCK_FREE 454
D.3.3. Makro ATOMIC_VAR_INIT 455
D.3.4. Typ wyliczeniowy std::memory_order 455
D.3.5. Funkcja std::atomic_thread_fence 456
D.3.6. Funkcja std::atomic_signal_fence 457
D.3.7. Klasa std::atomic_flag 457
D.3.8. Szablon klasy std::atomic 460
D.3.9. Specjalizacje szablonu std::atomic 471
D.3.10. Specjalizacje szablonu std::atomic<typ-całkowitoliczbowy> 472
D.4. Nagłówek <future> 489
D.4.1. Szablon klasy std::future 490
D.4.2. Szablon klasy std::shared_future 495
D.4.3. Szablon klasy std::packaged_task 501
D.4.4. Szablon klasy std::promise 507
D.4.5. Szablon funkcji std::async 513

D.5. Nagłówek <mutex> 514
D.5.1. Klasa std::mutex 515
D.5.2. Klasa std::recursive_mutex 518
D.5.3. Klasa std::timed_mutex 520
D.5.4. Klasa std::recursive_timed_mutex 524
D.5.5. Szablon klasy std::lock_guard 529
D.5.6. Szablon klasy std::unique_lock 530
D.5.7. Szablon funkcji std::lock 540
D.5.8. Szablon funkcji std::try_lock 541
D.5.9. Klasa std::once_flag 541
D.5.10. Szablon funkcji std::call_once 542
D.6. Nagłówek <ratio> 543
D.6.1. Szablon klasy std::ratio 544
D.6.2. Alias szablonu std::ratio_add 544
D.6.3. Alias szablonu std::ratio_subtract 545
D.6.4. Alias szablonu std::ratio_multiply 545
D.6.5. Alias szablonu std::ratio_divide 546
D.6.6. Szablon klasy std::ratio_equal 547
D.6.7. Szablon klasy std::ratio_not_equal 547
D.6.8. Szablon klasy std::ratio_less 547
D.6.9. Szablon klasy std::ratio_greater 548
D.6.10. Szablon klasy std::ratio_less_equal 548
D.6.11. Szablon klasy std::ratio_greater_equal 548
D.7. Nagłówek <thread> 549
D.7.1. Klasa std::thread 549
D.7.2. Przestrzeń nazw std::this_thread 558

Materiały dodatkowe 561

Skorowidz 563

4 Synchronizacja współbieżnych operacji

W tym rozdziale zostaną omówione następujące zagadnienia:

- oczekiwanie na zdarzenie;
- oczekiwanie na jednorazowe zdarzenia za pomocą przyszłości;
- oczekiwanie z limitem czasowym;
- upraszczanie kodu za pomocą technik synchronizowania operacji.

W poprzednim rozdziale przeanalizowaliśmy rozmaite sposoby ochrony danych współdzielonych przez wiele wątków. Okazuje się jednak, że w pewnych przypadkach jest potrzebna nie tyle ochrona danych, co synchronizacja działań podejmowanych przez różne wątki. Wątek może na przykład czekać z realizacją własnej operacji na zakończenie pewnego zadania przez inny wątek. Ogólnie w wielu przypadkach wątek oczekujący na określone zdarzenie lub spełnienie pewnego warunku jest najwygodniejszym rozwiązaniem. Mimo że analogiczne rozwiązanie można zaimplementować w formie mechanizmu okresowego sprawdzania flagi zakończonego zadania lub innej wartości zapisanej we współdzielonych danych, taki model byłby daleki od ideału. Konieczność synchronizacji operacji wykonywanych przez różne wątki jest dość typowym scenariuszem, zatem biblioteka standardowa języka C++ oferuje mechanizmy ułatwiające obsługę tego modelu, w tym **zmienne warunkowe** i tzw. **przyszłości**.

W tym rozdziale omówię techniki oczekiwania na zdarzenia przy użyciu zmiennych warunkowych oraz sposoby upraszczania synchronizacji operacji za pomocą przyszłości.

4.1. Oczekiwanie na zdarzenie lub inny warunek

Przypuśćmy, że podróżujemy nocnym pociągiem. Jednym ze sposobów zagwarantowania, że wysiądziemy na właściwej stacji, jest unikanie snu i sprawdzanie wszystkich stacji, na których zatrzymuje się nasz pociąg. W ten sposób nie przegapimy naszej stacji, jednak po dotarciu na miejsce będziemy bardzo zmęczeni. Alternatywnym rozwiązaniem jest sprawdzenie rozkładu jazdy pod kątem godziny przyjazdu, ustawienie budzika z pewnym wyprzedzeniem względem tej godziny i pójście spać. To rozwiązanie jest dość bezpieczne — nie przegapimy naszej stacji, ale jeśli pociąg się spóźni, wstaniemy zbyt wcześnie. Nie można też wykluczyć sytuacji, w której wyczerpią się baterie w budziku — w takim przypadku możemy zaspać i przegapić swoją stację. Idealnym rozwiązaniem byłaby możliwość pójścia spać i skorzystania z pomocy czegoś (lub kogoś), co obudziłoby nas bezpośrednio przed osiągnięciem stacji docelowej.

Jaki to ma związek z wątkami? Jeśli jeden wątek czeka, aż inny wątek zakończy jakieś zadanie, ma do wyboru kilka możliwych rozwiązań. Po pierwsze, może stale sprawdzać odpowiednią flagę we współdzielonych danych (chronionych przez muteks); flaga zostanie ustawiona przez drugi wątek w momencie zakończenia zadania. Takie rozwiązanie jest nieefektywne z dwóch powodów: wątek, który wielokrotnie sprawdza wspomnianą flagę, zajmuje cenny czas procesora, a muteks zablokowany przez oczekujący wątek nie jest dostępny dla żadnego innego wątku. Oba te czynniki działają na niekorzyść oczekującego wątku, ponieważ ten wątek zajmuje zasoby potrzebne także do działania wątku, na który czeka, co opóźnia wykonanie zadania i ustawienie odpowiedniej flagi. Sytuacja przypomina unikanie snu przez całą podróż pociągiem i prowadzenie rozmowy z maszynistą — maszynista zajęty rozmową musi prowadzić pociąg nieco wolniej, zatem później dotrzemy na swoją stację. Podobnie wątek oczekujący zajmuje zasoby, które mogłyby być używane przez pozostałe wątki w systemie, przez co czas oczekiwania może być dłuższy, niż to konieczne.

Druga opcja polega na przechodzeniu wątku oczekującego w stan uśpienia na krótkie momenty i okresowym wykonywaniu testów za pomocą funkcji `std::this_thread::sleep_for()` (patrz punkt 4.3):

```
bool flag;
std::mutex m;

void wait_for_flag()
{
    std::unique_lock<std::mutex> lk(m);
    while(!flag)
    {
        lk.unlock();        ←❶ Odblokowuje muteks
        std::this_thread::sleep_for(std::chrono::milliseconds(100));  ←❷ Czeka 100 ms
        lk.lock();        ←❸ Ponownie blokuje muteks
    }
}
```

Wywołanie funkcji w pętli odblokowuje muteks ❶ przed przejściem w stan uśpienia ❷ i ponownie blokuje ten muteks po wyjściu z tego stanu ❸ — dzięki temu drugi wątek ma szanse uzyskania dostępu do flagi i jej ustawienia.

Opisane rozwiązanie jest o tyle dobre, że uśpiony wątek nie zajmuje bezproduktywnie czasu procesora. Warto jednak pamiętać, że dobór właściwego czasu uśpienia

jest dość trudny. Zbyt krótki czas przebywania w tym stanie spowoduje, że wątek będzie tracił czas procesora na zbyt częste testy; zbyt długi czas uśpienia będzie oznaczał, że wątek będzie przebywał w tym stanie nawet po zakończeniu zadania, na które oczekuje, zatem opóźnienie w działaniu wątku oczekującego będzie zbyt duże. Takie „zaspanie" wątku rzadko ma bezpośredni wpływ na wynik operacji wykonywanych przez program, ale już w przypadku szybkiej gry może powodować pominięcie niektórych klatek animacji, a w przypadku aplikacji czasu rzeczywistego może oznaczać pominięcie przydziału czasu procesora.

Trzecim, najlepszym rozwiązaniem jest użycie gotowych elementów biblioteki standardowej języka C++ umożliwiających oczekiwanie na określone zdarzenie. Najprostszym mechanizmem oczekiwania na zdarzenie generowane przez inny wątek (na przykład zdarzenie polegające na umieszczeniu dodatkowego zadania w potoku) jest tzw. **zmienna warunkowa**. Zmienna warunkowa jest powiązana z pewnym zdarzeniem lub **warunkiem** oraz co najmniej jednym wątkiem, który **czeka** na spełnienie tego warunku. Wątek, który odkrywa, że warunek jest spełniony, może **powiadomić** pozostałe wątki oczekujące na tę zmienną warunkową, aby je obudzić i umożliwić im dalsze przetwarzanie.

4.1.1. Oczekiwanie na spełnienie warunku za pomocą zmiennych warunkowych

Biblioteka standardowa języka C++ udostępnia **dwie** implementacje mechanizmu zmiennych warunkowych w formie klas `std::condition_variable` **i** `std::condition_variable_any`. Obie klasy zostały zadeklarowane w pliku nagłówkowym `<condition_variable>`. W obu przypadkach zapewnienie właściwej synchronizacji wymaga użycia muteksu — pierwsza klasa jest przystosowana tylko do obsługi muteksów typu `std::mutex`, natomiast druga klasa obsługuje wszystkie rodzaje muteksów spełniających pewien minimalny zbiór kryteriów (stąd przyrostek `_any`). Ponieważ klasa `std::condition_variable_any` jest bardziej uniwersalna, z jej stosowaniem wiążą się dodatkowe koszty w wymiarze wielkości, wydajności i zasobów systemu operacyjnego. Jeśli więc nie potrzebujemy dodatkowej elastyczności, powinniśmy stosować klasę `std::condition_variable`.

Jak należałoby użyć klasy `std::condition_variable` do obsługi przykładu opisanego na początku tego podrozdziału — jak sprawić, że wątek oczekujący na wykonanie jakiegoś zadania będzie uśpiony do momentu, w którym będą dostępne dane do przetworzenia? Na listingu 4.1 pokazano przykład kodu implementującego odpowiednie rozwiązanie przy użyciu zmiennej warunkowej.

Listing 4.1. Oczekiwanie na dane do przetworzenia za pomocą klasy std::condition_variable

```
std::mutex mut;
std::queue<data_chunk> data_queue;
std::condition_variable data_cond;

void data_preparation_thread()
{
    while(more_data_to_prepare())
    {
        data_chunk const data=prepare_data();
```

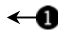

```
        std::lock_guard<std::mutex> lk(mut);
        data_queue.push(data);      ←❷
        data_cond.notify_one();     ←❸
    }
}

void data_processing_thread()
{
    while(true)
    {
        std::unique_lock<std::mutex> lk(mut);      ←❹
        data_cond.wait(
            lk,[]{return !data_queue.empty();});      ←❺
        data_chunk data=data_queue.front();
        data_queue.pop();
        lk.unlock();      ←❻
        process(data);
        if(is_last_chunk(data))
            break;
    }
}
```

Na początku kodu zdefiniowano kolejkę ❶, która będzie używana do przekazywania danych pomiędzy dwoma wątkami. Kiedy dane są gotowe do przetworzenia, wątek, który je przygotował, blokuje muteks chroniący kolejkę za pomocą klasy `std::lock_guard` i umieszcza nowe dane w kolejce ❷. Wątek wywołuje następnie funkcję składową `notify_one()` dla obiektu klasy `std::condition_variable`, aby powiadomić oczekujący wątek (jeśli taki istnieje) o dostępności nowych danych ❸.

W tym modelu drugą stroną komunikacji jest wątek przetwarzający te dane. Wątek przetwarzający najpierw blokuje muteks, jednak tym razem użyto do tego celu klasy `std::unique_lock` zamiast klasy `std::lock_guard` ❹ — przyczyny tej decyzji zostaną wyjaśnione za chwilę. Wątek wywołuje następnie funkcję `wait()` dla obiektu klasy `std::condition_variable`. Na wejściu tego wywołania wątek przekazuje obiekt blokady i funkcję lambda reprezentującą warunek, który musi zostać spełniony przed przystąpieniem do dalszego przetwarzania ❺. Funkcje lambda to stosunkowo nowy element (wprowadzony w standardzie C++11), który umożliwia pisanie funkcji anonimowych w ramach innych wyrażeń. Wspomniane rozwiązanie wprost idealnie nadaje się do wskazywania predykatów w wywołaniach takich funkcji biblioteki standardowej jak `wait()`. W tym przypadku prosta funkcja lambda `[]{return !data_queue.empty();}` sprawdza, czy struktura reprezentowana przez zmienną `data_queue` nie jest pusta, tj. czy kolejka zawiera jakieś dane gotowe do przetworzenia. Funkcje lambda zostaną szczegółowo omówione w części A.5 dodatku A.

Implementacja funkcji `wait()` sprawdza warunek (wywołując przekazaną funkcję lambda), po czym zwraca sterowanie, jeśli ten warunek jest spełniony (jeśli funkcja lambda zwróciła wartość `true`). Jeśli warunek nie jest spełniony (jeśli funkcja lambda zwróciła wartość `false`), funkcja `wait()` odblokowuje muteks i wprowadza bieżący wątek w stan blokady (oczekiwania). Kiedy zmienna warunkowa jest powiadamiana za pomocą funkcji `notify_one()` wywołanej przez wątek przygotowujący dane, wątek oczekujący jest budzony (odblokowywany), ponownie uzyskuje blokadę muteksu i jeszcze raz sprawdza warunek. Jeśli warunek dalszego przetwarzania jest spełniony, funkcja `wait()` zwraca

sterowanie z zachowaniem blokady muteksu. Jeśli warunek nie jest spełniony, wątek odblokowuje muteks i ponownie przechodzi w stan oczekiwania. Właśnie dlatego w przykładzie należało użyć klasy `std::unique_lock` zamiast klasy `std::lock_guard` — wątek oczekujący musi odblokować muteks na czas oczekiwania i zablokować go ponownie po otrzymaniu powiadomienia, a klasa `std::lock_guard` nie zapewnia takiej elastyczności. Gdyby muteks pozostał zablokowany przez cały czas uśpienia tego wątku, wątek przygotowujący dane nie mógłby zablokować tego muteksu i dodać elementu do kolejki, zatem warunek budzenia wątku oczekującego nigdy nie zostałby spełniony.

Na listingu 4.1 użyłem prostej funkcji lambda ❺, która sprawdza, czy struktura kolejki nie jest pusta. Okazuje się, że w tej roli równie dobrze można by użyć dowolnej funkcji lub obiektu wywoływalnego. Jeśli programista dysponuje już funkcją sprawdzającą odpowiedni warunek (funkcja może oczywiście być nieporównanie bardziej złożona niż prosty test z powyższego przykładu), może przekazać tę funkcję bezpośrednio na wejściu funkcji `wait()`, bez konieczności opakowywania jej w ramach wyrażenia lambda. Po wywołaniu funkcji `wait()` zmienna warunkowa może sprawdzić wskazany warunek na wiele różnych sposobów, jednak podczas tego testu muteks zawsze jest zablokowany, a funkcja `wait()` natychmiast zwraca sterowanie, pod warunkiem że przekazana funkcja sprawdzająca ten warunek zwróciła wartość `true`. Jeśli wątek oczekujący ponownie uzyskuje muteks i sprawdza warunek, mimo że nie otrzymał powiadomienia od innego wątku i jego działania nie są bezpośrednią odpowiedzią na takie powiadomienie, mamy do czynienia z tzw. **pozornym budzeniem** (ang. *spurious wake*). Ponieważ optymalna liczba i częstotliwość takich pozornych budzeń są z definicji trudne do oszacowania, funkcja sprawdzająca prawdziwość warunku nie powinna powodować żadnych skutków ubocznych. Gdyby ta funkcja powodowała skutki uboczne, programista musiałby przygotować swój kod na wielokrotne występowanie tych skutków przed spełnieniem warunku.

Możliwość odblokowania obiektu klasy `std::unique_lock` nie jest używana tylko dla wywołania funkcji `wait()` — analogiczne rozwiązanie zastosowaliśmy po uzyskaniu danych do przetworzenia, ale przed przystąpieniem do właściwego przetwarzania ❻. Przetwarzanie danych może być czasochłonną operacją, a jak wiemy z rozdziału 3., utrzymywanie blokady muteksu dłużej, niż to konieczne, nie jest dobrym rozwiązaniem.

Stosowanie struktury kolejki do przekazywania danych pomiędzy wątkami (jak na listingu 4.1) jest dość typowym rozwiązaniem. Jeśli projekt aplikacji jest właściwy, synchronizacja powinna dotyczyć samej kolejki, co znacznie ogranicza liczbę potencjalnych problemów i problematycznych sytuacji wyścigu. Spróbujmy więc wyodrębnić z listingu 4.1 uniwersalną kolejkę gwarantującą bezpieczne przetwarzanie wielowątkowe.

4.1.2. Budowa kolejki gwarantującej bezpieczne przetwarzanie wielowątkowe przy użyciu zmiennych warunkowych

Przed przystąpieniem do projektowania uniwersalnej kolejki warto poświęcić kilka minut analizie operacji, które trzeba będzie zaimplementować dla tej struktury danych (podobnie jak w przypadku stosu gwarantującego bezpieczeństwo przetwarzania wielowątkowego z punktu 3.2.3). Przyjrzyjmy się kontenerowi `std::queue<>` dostępnemu w bibliotece standardowej języka C++ (patrz listing 4.2), który będzie stanowił punkt wyjścia dla naszej implementacji.

Listing 4.2. Interfejs kontenera std::queue

```
template <class T, class Container = std::deque<T> >
class queue {
public:
    explicit queue(const Container&);
    explicit queue(Container&& = Container());

    template <class Alloc> explicit queue(const Alloc&);
    template <class Alloc> queue(const Container&, const Alloc&);
    template <class Alloc> queue(Container&&, const Alloc&);
    template <class Alloc> queue(queue&&, const Alloc&);

    void swap(queue& q);

    bool empty() const;
    size_type size() const;

    T& front();
    const T& front() const;
    T& back();
    const T& back() const;

    void push(const T& x);
    void push(T&& x);
    void pop();
    template <class... Args> void emplace(Args&&... args);
};
```

Jeśli pominiemy operacje konstruowania, przypisywania i wymiany, pozostaną nam zaledwie trzy grupy operacji: operacje zwracające stan całej kolejki (`empty()` i `size()`), operacje zwracające pojedyncze elementy kolejki (`front()` i `back()`) oraz operacje modyfikujące kolejkę (`push()`, `pop()` i `emplace()`). Mamy więc do czynienia z sytuacją analogiczną do tej opisanej w punkcie 3.2.3 (gdzie omawialiśmy strukturę stosu), zatem opisany interfejs jest narażony na te same problemy związane z sytuacjami wyścigów. W tym przypadku należy połączyć funkcje `front()` i `pop()` w jedno wywołanie, tak jak wcześniej połączyliśmy funkcje `top()` i `pop()` dla struktury stosu. Warto jeszcze zwrócić uwagę na pewien nowy element w kodzie z listingu 4.1 — podczas używania kolejki do przekazywania danych pomiędzy wątkami wątek docelowy zwykle musi czekać na te dane. Warto więc zaimplementować funkcję `pop()` w dwóch wersjach — pierwsza funkcja, `try_pop()`, próbuje pobrać wartość z kolejki, ale zawsze zwraca sterowanie bezpośrednio po wywołaniu, nawet jeśli kolejka nie zawierała żadnej wartości (wtedy funkcja sygnalizuje błąd); druga funkcja, `wait_and_pop()`, czeka na pojawienie się w kolejce wartości do pobrania. Po wprowadzeniu zmian zgodnie ze schematem opisanym już przy okazji przykładu stosu interfejs struktury kolejki powinien wyglądać tak jak na listingu 4.3.

Listing 4.3. Interfejs struktury danych threadsafe_queue

```
#include <memory>      ← Dla typu std::shared_ptr

template<typename T>
class threadsafe_queue
```

```
{
public:
    threadsafe_queue();
    threadsafe_queue(const threadsafe_queue&);
    threadsafe_queue& operator=(
        const threadsafe_queue&) = delete;   <-- Dla uproszczenia wyklucza możliwość przypisywania

    void push(T new_value);

    bool try_pop(T& value);   <-- 1
    std::shared_ptr<T> try_pop();   <-- 2

    void wait_and_pop(T& value);
    std::shared_ptr<T> wait_and_pop();

    bool empty() const;
};
```

Podobnie jak w przypadku stosu, na listingu 4.3 usunięto konstruktory i operator przypisania, aby uprościć analizowany kod. Tak jak wcześniej, także tym razem funkcje `try_pop()` i `wait_for_pop()` występują w dwóch wersjach. Pierwsza przeciążona wersja funkcji `try_pop()` (1) zapisuje pobraną wartość we wskazywanej zmiennej, tak aby można było użyć tej wartości w roli statusu; funkcja zwraca wartość `true`, jeśli uzyskała jakąś wartość — w przeciwnym razie funkcja zwraca wartość `false` (patrz część A.2 dodatku A). Druga przeciążona wersja (2) nie może działać w ten sam sposób, ponieważ natychmiast zwraca uzyskaną wartość. Jeśli jednak funkcja nie uzyskała żadnej wartości, może zwrócić wskaźnik równy `NULL`.

Jaki to ma związek z listingiem 4.1? Okazuje się, że możemy wyodrębnić kod funkcji `push()` i `wait_and_pop()` z tamtego listingu i na tej podstawie przygotować nową implementację (patrz listing 4.4).

Listing 4.4. Funkcje push() i wait_and_pop() wyodrębnione z listingu 4.1

```
#include <queue>
#include <mutex>
#include <condition_variable>

template<typename T>
class threadsafe_queue
{
private:
    std::mutex mut;
    std::queue<T> data_queue;
    std::condition_variable data_cond;
public:
    void push(T new_value)
    {
        std::lock_guard<std::mutex> lk(mut);
        data_queue.push(new_value);
        data_cond.notify_one();
    }

    void wait_and_pop(T& value)
    {
```

```
        std::unique_lock<std::mutex> lk(mut);
        data_cond.wait(lk,[this]{return !data_queue.empty();});
        value=data_queue.front();
        data_queue.pop();
    }
};

threadsafe_queue<data_chunk> data_queue;     ←❶

void data_preparation_thread()
{
    while(more_data_to_prepare())
    {
        data_chunk const data=prepare_data();
        data_queue.push(data);     ←❷
    }
}

void data_processing_thread()
{
    while(true)
    {
        data_chunk data;
        data_queue.wait_and_pop(data);     ←❸
        process(data);
        if(is_last_chunk(data))
            break;
    }
}
```

Muteks i zmienna warunkowa są teraz elementami składowymi obiektu klasy `threadsafe_queue`, zatem nie jest potrzebne stosowanie odrębnych zmiennych ❶, a wywołanie funkcji `push()` nie wymaga zewnętrznych mechanizmów synchronizacji ❷. Jak widać, także funkcja `wait_and_pop()` uwzględnia stan zmiennej warunkowej ❸.

Napisanie drugiej wersji przeciążonej funkcji `wait_and_pop()` nie stanowi żadnego problemu; także pozostałe funkcje można niemal skopiować z przykładu stosu pokazanego na listingu 3.5. Ostateczną wersję implementacji kolejki pokazano na listingu 4.5.

Listing 4.5. Kompletna definicja klasy kolejki gwarantującej bezpieczeństwo przetwarzania wielowątkowego (dzięki użyciu zmiennych warunkowych)

```
#include <queue>
#include <memory>
#include <mutex>
#include <condition_variable>

template<typename T>
class threadsafe_queue
{
private:
    mutable std::mutex mut;     ←❶ Muteks musi być modyfikowalny
    std::queue<T> data_queue;
    std::condition_variable data_cond;
public:
    threadsafe_queue()
    {}
```

```
    threadsafe_queue(threadsafe_queue const& other)
    {
        std::lock_guard<std::mutex> lk(other.mut);
        data_queue=other.data_queue;
    }

    void push(T new_value)
    {
        std::lock_guard<std::mutex> lk(mut);
        data_queue.push(new_value);
        data_cond.notify_one();
    }

    void wait_and_pop(T& value)
    {
        std::unique_lock<std::mutex> lk(mut);
        data_cond.wait(lk,[this]{return !data_queue.empty();});
        value=data_queue.front();
        data_queue.pop();
    }

    std::shared_ptr<T> wait_and_pop()
    {
        std::unique_lock<std::mutex> lk(mut);
        data_cond.wait(lk,[this]{return !data_queue.empty();});
        std::shared_ptr<T> res(std::make_shared<T>(data_queue.front()));
        data_queue.pop();
        return res;
    }

    bool try_pop(T& value)
    {
        std::lock_guard<std::mutex> lk(mut);
        if(data_queue.empty())
            return false;
        value=data_queue.front();
        data_queue.pop();
        return true;
    }

    std::shared_ptr<T> try_pop()
    {
        std::lock_guard<std::mutex> lk(mut);
        if(data_queue.empty())
            return std::shared_ptr<T>();
        std::shared_ptr<T> res(std::make_shared<T>(data_queue.front()));
        data_queue.pop();
        return res;
    }

    bool empty() const
    {
        std::lock_guard<std::mutex> lk(mut);
        return data_queue.empty();
    }
};
```

Mimo że `empty()` jest stałą funkcją składową i mimo że parametr `other` konstruktora kopiującego jest stałą referencją, pozostałe wątki mogą dysponować niestałymi referencjami do tego obiektu i wywoływać funkcje składowe zmieniające jego stan, zatem blokowanie muteksu wciąż jest konieczne. Ponieważ blokowanie muteksu jest operacją zmieniającą stan obiektu, obiekt muteksu należy oznaczyć jako modyfikowalny (ang. *mutable*) ❶, tak aby można było blokować ten muteks w ciele funkcji `empty()` i konstruktora kopiującego.

Zmienne warunkowe są przydatne także w sytuacji, w której wiele wątków czeka na to samo zdarzenie. Jeśli celem stosowania wątków jest dzielenie obciążenia i jeśli tylko jeden wątek powinien reagować na powiadomienie, można zastosować dokładnie taką samą strukturę jak ta z listingu 4.1 — wystarczy uruchomić wiele instancji wątku przetwarzającego dane. Po przygotowaniu nowych danych wywołanie funkcji `notify_one()` spowoduje, że jeden z wątków aktualnie wykonujących funkcję `wait()` sprawdzi warunek. Ponieważ do struktury `data_queue` właśnie dodano nowe dane, funkcja `wait()` zwróci sterowanie. Nie wiadomo, do którego wątku trafi powiadomienie ani nawet czy istnieje wątek oczekujący na to powiadomienie (nie można przecież wykluczyć, że wszystkie wątki w danej chwili przetwarzają swoje dane).

Warto też pamiętać o możliwości oczekiwania na to samo zdarzenie przez wiele wątków, z których każdy musi zareagować na powiadomienie. Opisany scenariusz może mieć związek z inicjalizacją współdzielonych danych, gdzie wszystkie wątki przetwarzające operują na tych samych danych i muszą czekać albo na ich inicjalizację (w takim przypadku istnieją lepsze mechanizmy — patrz punkt 3.3.1 w rozdziale 3.), albo na ich aktualizację (na przykład w ramach okresowej, wielokrotnej inicjalizacji). W opisanych przypadkach wątek przygotowujący dane może wywołać funkcję składową `notify_all()` dla zmiennej warunkowej (zamiast funkcji `notify_one()`). Jak nietrudno się domyślić, funkcja powoduje, że **wszystkie** wątki aktualnie wykonujące funkcję `wait()` sprawdzą warunek, na który czekają.

Jeśli wątek wywołujący w założeniu ma oczekiwać na dane zdarzenie tylko raz, czyli jeśli po spełnieniu warunku wątek nie będzie ponownie czekał na tę samą zmienną warunkową, być może warto zastosować inny mechanizm synchronizacji niż zmienna warunkowa. Zmienne warunkowe są szczególnie nieefektywne w sytuacji, gdy warunkiem, na który oczekują wątki, jest dostępność określonego elementu danych. W takim przypadku lepszym rozwiązaniem jest użycie mechanizmu **przyszłości**.

4.2. Oczekiwanie na jednorazowe zdarzenia za pomocą przyszłości

Przypuśćmy, że planujemy podróż samolotem. Po przyjeździe na lotnisko i przejściu rozmaitych procedur wciąż musimy czekać na komunikat dotyczący gotowości naszego samolotu na przyjęcie pasażerów (zdarza się, że pasażerowie muszą czekać wiele godzin). Możemy oczywiście znaleźć sposób, aby ten czas minął nieco szybciej (możemy na przykład czytać książkę, przeglądać strony internetowe lub udać się na posiłek do drogiej lotniskowej kawiarni), jednak niezależnie od sposobu spędzania czasu czekamy na jedno — sygnał wzywający do udania się na pokład samolotu. Co więcej, interesujący nas lot odbędzie się tylko raz, zatem przy okazji następnego wyjazdu na wakacje będziemy czekali na inny lot.

Twórcy biblioteki standardowej języka C++ rozwiązali problem jednorazowych zdarzeń za pomocą mechanizmu nazwanego **przyszłością** (ang. *future*). Wątek, który musi czekać na określone jednorazowe zdarzenie, powinien uzyskać przyszłość reprezentującą to zdarzenie. Wątek oczekujący na tę przyszłość może następnie okresowo sprawdzać, czy odpowiednie zdarzenie nie nastąpiło (tak jak pasażerowie co jakiś czas zerkają na tablicę odlotów), i jednocześnie pomiędzy tymi testami wykonywać inne zadanie (spożywać drogi deser w lotniskowej kawiarni). Alternatywnym rozwiązaniem jest wykonywanie innego zadania do momentu, w którym dalsze działanie nie jest możliwe bez określonego zdarzenia, i przejście w stan **gotowości** na przyszłość. Przyszłość może, ale nie musi być powiązana z danymi (tak jak tablica odlotów może wskazywać rękawy prowadzące do właściwych samolotów). Po wystąpieniu zdarzenia (po osiągnięciu **gotowości** przez przyszłość) nie jest możliwe wyzerowanie tej przyszłości.

W bibliotece standardowej języka C++ istnieją dwa rodzaje przyszłości zaimplementowane w formie dwóch szablonów klas zadeklarowanych w nagłówku biblioteki `<future>`: **przyszłości unikatowe** (`std::future<>`) oraz **przyszłości współdzielone** (`std::`
➥`shared_future<>`). Wymienione klasy opracowano na bazie typów `std::unique_ptr` i `std::shared_ptr`. Obiekt typu `std::future` jest jedyną instancją odwołującą się do powiązanego zdarzenia, natomiast do jednego zdarzenia może się odwoływać wiele instancji typu `std::shared_future`. W drugim przypadku wszystkie instancje są **gotowe** jednocześnie i wszystkie mogą uzyskiwać dostęp do dowolnych danych powiązanych z danym zdarzeniem. Właśnie z myślą o powiązanych danych zaprojektowano te szablony klas — tak jak w przypadku szablonów `std::unique_ptr` i `std::shared_ptr`, parametry szablonów `std::future<>` i `std::shared_future<>` reprezentują właśnie typy powiązanych danych. W razie braku powiązanych danych należy stosować następujące specjalizacje tych szablonów: `std:future<void>` i `std::shared_future<void>`. Mimo że przyszłości służą do komunikacji pomiędzy wątkami, same obiekty przyszłości nie oferują mechanizmów synchronizowanego dostępu. Jeśli wiele wątków potrzebuje dostępu do jednego obiektu przyszłości, należy chronić ten dostęp za pomocą muteksu lub innego mechanizmu synchronizacji (patrz rozdział 3.). Jak napiszę w punkcie 4.2.5 w dalszej części tego podrozdziału, wiele wątków może uzyskiwać dostęp do własnej kopii obiektu typu `std::shared_future<>` bez konieczności dodatkowej synchronizacji, nawet jeśli wszystkie te kopie odwołują się do tego samego asynchronicznego wyniku.

Najprostszym przykładem jednorazowego zdarzenia jest wynik obliczeń wykonywanych w tle. Już w rozdziale 2. napisałem, że klasa `std::thread` nie udostępnia prostych mechanizmów zwracania wartości wynikowych dla tego rodzaju zadań, i zapowiedziałem wprowadzenie odpowiednich rozwiązań w rozdziale 4. przy okazji omawiania przyszłości — czas zapoznać się z tymi rozwiązaniami.

4.2.1. Zwracanie wartości przez zadania wykonywane w tle

Przypuśćmy, że nasza aplikacja wykonuje czasochłonne obliczenia, które ostatecznie pozwolą uzyskać oczekiwany wynik. Załóżmy, że wartość wynikowa nie jest potrzebna na tym etapie działania programu. Być może udało nam się wymyślić sposób poszukiwania odpowiedzi na pytanie o życie, wszechświat i całą resztę stawiane w książkach

Douglasa Adamsa[1]. Moglibyśmy oczywiście uruchomić nowy wątek, który wykona niezbędne obliczenia, jednak takie rozwiązanie wiązałoby się z koniecznością przekazania wyników z powrotem do wątku głównego, ponieważ klasa `std::thread` nie oferuje alternatywnego mechanizmu zwracania wartości wynikowych. W takim przypadku sporym ułatwieniem jest użycie szablonu funkcji `std::async` (zadeklarowanego w pliku nagłówkowym `<future>`).

Asynchroniczne zadanie, którego wynik nie jest potrzebny na bieżącym etapie działania programu, można rozpocząć za pomocą funkcji `std::async`. Zamiast zwracania obiektu klasy `std::thread`, który umożliwi oczekiwanie na zakończenie danego wątku, funkcja `std::async` zwraca obiekt klasy `std::future`, który w przyszłości będzie zawierał wartość wynikową. W miejscu, w którym aplikacja będzie potrzebowała tej wartości, należy wywołać funkcję `get()` dla obiektu przyszłości — wywołanie tej funkcji zablokuje wykonywanie bieżącego wątku do momentu osiągnięcia **gotowości** przez przyszłość, po czym zwróci uzyskaną wartość. Prosty przykład użycia tych elementów pokazano na listingu 4.6.

Listing 4.6. Przykład użycia szablonu klasy std::future do uzyskania wartości wynikowej asynchronicznego zadania

```
#include <future>
#include <iostream>

int find_the_answer_to_ltuae();
void do_other_stuff();
int main()
{
    std::future<int> the_answer=std::async(find_the_answer_to_ltuae);
    do_other_stuff();
    std::cout<<"Odpowiedź brzmi "<<the_answer.get()<<std::endl;
}
```

Szablon funkcji `std::async` umożliwia przekazywanie dodatkowych argumentów na wejściu wywoływanej funkcji — wystarczy dodać te argumenty do wywołania (podobnie jak w przypadku klasy `std::thread`). Jeśli pierwszy argument reprezentuje wskaźnik do funkcji składowej, drugi argument zawiera obiekt, dla którego ma zostać wywołana ta funkcja składowa (bezpośrednio, za pośrednictwem wskaźnika lub poprzez opakowanie `std::ref`), a pozostałe argumenty są przekazywane na wejściu tej funkcji składowej. W przeciwnym razie drugi i kolejne argumenty są przekazywane na wejściu funkcji składowej lub wywoływalnego obiektu wskazanego za pośrednictwem pierwszego argumentu. Tak jak w przypadku klasy `std::thread`, jeśli argumenty mają postać r-wartości, zostaną utworzone kopie poprzez **przeniesienie** oryginalnych wartości. Dzięki temu możemy stosować typy oferujące tylko możliwość przenoszenia zarówno w roli obiektów funkcji, jak i w roli argumentów. Przykład takiego rozwiązania pokazano na listingu 4.7.

[1] W książce *Autostopem przez Galaktykę* zbudowano komputer Deep Thought, który miał odpowiedzieć na pytanie o życie, wszechświat i całą resztę. Odpowiedzią na to pytanie była liczba 42.

Listing 4.7. Przekazywanie argumentów na wejściu funkcji wątku std::async

```
#include <string>
#include <future>

struct X
{
    void foo(int,std::string const&);
    std::string bar(std::string const&);
};
X x;
auto f1=std::async(&X::foo,&x,42,"witaj");      ← Wywołuje p->foo(42,"witaj"), gdzie p jest reprezentowane przez &x
auto f2=std::async(&X::bar,x,"żegnaj");         ← Wywołuje tmpx.bar("żegnaj"), gdzie tmpx jest kopią x
struct Y
{
    double operator()(double);
};
Y y;
auto f3=std::async(Y(),3.141);                  ← Wywołuje tmpy(3.141), gdzie tmpy jest tworzone za pomocą konstruktora przenoszącego Y()
auto f4=std::async(std::ref(y),2.718);          ← Wywołuje y(2.718)
X baz(X&);
std::async(baz,std::ref(x));                    ← Wywołuje baz(x)
class move_only
{
public:
    move_only();
    move_only(move_only&&)
    move_only(move_only const&) = delete;
    move_only& operator=(move_only&&);
    move_only& operator=(move_only const&) = delete;

    void operator()();
};
auto f5=std::async(move_only());                ← Wywołuje tmp(), gdzie tmp jest konstruowany na podstawie wywołania std::move(move_only())
```

Domyślnie to od stosowanej implementacji zależy, czy funkcja `std::async` uruchamia nowy wątek, czy wskazane zadanie będzie wykonywane w sposób synchroniczny (wówczas bieżący wątek będzie czekał na osiągnięcie gotowości przez przyszłość). W większości przypadków standardowe rozwiązanie jest wystarczające, jednak programista może wybrać właściwy tryb za pomocą dodatkowego parametru funkcji `std::async` przekazywanego przed funkcją do wywołania. Wspomniany parametr typu `std::launch` może mieć albo wartość `std::launch::deferred` (wówczas wywołanie funkcji jest odkładane do momentu wywołania funkcji `wait()` lub `get()` dla danej przyszłości), albo wartość `std::launch::async` (wówczas funkcja musi być wykonywana w odrębnym wątku), albo wartość `std::launch::deferred | std::launch::async` (wówczas decyzja należy do implementacji). Ostatnia opcja jest stosowana w roli wartości domyślnej. Jeśli wywołanie funkcji jest odkładane na przyszłość, może nigdy nie nastąpić. Na przykład:

```
auto f6=std::async(std::launch::async,Y(),1.2);              ← Wykonywane w nowym wątku
auto f7=std::async(std::launch::deferred,baz,std::ref(x));   ← Wykonywane w ramach funkcji wait() lub get()
auto f8=std::async(                                          ← Wybór implementacji
    std::launch::deferred | std::launch::async,
    baz,std::ref(x));
auto f9=std::async(baz,std::ref(x));                         ← Wybór implementacji
f7.wait();                                                   ← Wywołanie odroczonej funkcji
```

Jak się przekonasz w dalszej części tego rozdziału (i ponownie w rozdziale 8.), funkcja std::async ułatwia dzielenie algorytmów na współbieżnie wykonywane zadania. Okazuje się jednak, że nie jest to jedyny sposób kojarzenia obiektu typu std::future z zadaniem — alternatywnym rozwiązaniem jest opakowanie zadania w ramach instancji szablonu klasy std::packaged_task<> lub napisanie kodu bezpośrednio ustawiającego wartości za pomocą szablonu klasy std::promise<>. Szablon klasy std::packaged_task jest abstrakcją wyższego poziomu (w porównaniu z szablonem std::promise), zatem właśnie ten szablon omówimy jako pierwszy.

4.2.2. Wiązanie zadania z przyszłością

Szablon klasy std::packaged_task<> wiąże przyszłość z funkcją lub wywoływalnym obiektem. W momencie wywołania obiektu typu std::packaged_task<> wywołana zostaje powiązana funkcja lub wywoływalny obiekt, a sama przyszłość przechodzi w stan **gotowości** (wartość wynikowa zostaje umieszczona w powiązanych danych). Opisaną strukturę można wykorzystać w roli elementu składowego podczas budowy puli wątków (patrz rozdział 9.) lub dowolnego innego schematu zarządzania zadaniami polegającego na przykład na wykonywaniu każdego zadania w osobnym wątku lub sekwencyjnym wykonywaniu zadań w jednym wątku działającym w tle. Jeśli jedną większą operację można podzielić na wiele autonomicznych podzadań, każde z tych podzadań można opakować w ramach obiektu klasy std::packaged_task<>, aby następnie przekazać ten obiekt do mechanizmu szeregowania zadań lub do puli wątków. W ten sposób można skutecznie ukryć szczegóły związane z poszczególnymi zadaniami — mechanizm szeregowania zadań operuje na obiektach klasy std::packaged_task<>, nie na poszczególnych funkcjach.

Parametr szablonu klasy std::packaged_task<> reprezentuje sygnaturę funkcji — na przykład dla funkcji, która nie otrzymuje żadnych parametrów i nie zwraca wartości, należałoby użyć sygnatury void(), natomiast dla funkcji otrzymującej niestałą referencję do wartości typu std::string i wskaźnik do wartości typu double oraz zwracającej wartość typu int należałoby użyć sygnatury int(std::string&,double*). Podczas konstruowania obiektu klasy std::packaged_task należy przekazać funkcję (lub wywoływalny obiekt) otrzymującą na wejściu wskazane parametry i zwracającą typ, który można przekonwertować na wskazany typ danych. Dokładne dopasowanie typów nie jest wymagane — istnieje możliwość skonstruowania obiektu klasy std::packaged_task<double(double)> na podstawie funkcji otrzymującej na wejściu wartość typu int i zwracającej wartość typu float, ponieważ wymienione typy mogą być automatycznie konwertowane.

Typ wartości zwracanych przez wskazaną funkcję identyfikuje typ zwracany przez funkcję składową get_future() konstruowanego obiektu klasy std::future<>, natomiast lista argumentów zdefiniowana w ramach sygnatury funkcji jest używana do wyznaczania sygnatury operatora wywołania funkcji zadania reprezentowanego przez ten obiekt. Przykład częściowej definicji klasy std::packaged_task<std::string(std::vector<char>*,int)> pokazano na listingu 4.8.

Instancja klasy std::packaged_task jest obiektem wywoływalnym i jako taka może być opakowana w ramach obiektu klasy std::function, przekazana do obiektu klasy std::thread w roli funkcji wątku, przekazana do dowolnej innej funkcji oczekującej wywoływalnego obiektu, a nawet bezpośrednio wywołana. W momencie wywołania

Listing 4.8. Częściowa definicja specjalizacji szablonu klasy std::packaged_task<>

```
template<>
class packaged_task<std::string(std::vector<char>*,int)>
{
public:
    template<typename Callable>
    explicit packaged_task(Callable&& f);
    std::future<std::string> get_future();
    void operator()(std::vector<char>*,int);
};
```

obiektu klasy `std::packaged_task` jako obiektu funkcji argumenty przekazane na wejściu operatora wywołania są przekazywane do opakowanej funkcji, a zwracana wartość jest zapisywana jako asynchroniczny wynik w obiekcie typu `std::future` (obiekt można następnie uzyskać za pomocą funkcji `get_future()`). Oznacza to, że możemy opakować zadanie w obiekcie klasy `std::packaged_task` i uzyskać przyszłość przed przekazaniem tego obiektu do miejsca, gdzie zostanie wywołany. W momencie, w którym program będzie potrzebował wyniku, wystarczy poczekać na osiągnięcie gotowości przez tę przyszłość. Praktyczny przykład takiego rozwiązania opisano w następnym podpunkcie.

Przekazywanie zadań pomiędzy wątkami

Wiele frameworków graficznego interfejsu użytkownika wymaga, aby aktualizacje tego interfejsu były wykonywane przez określone wątki. Oznacza to, że jeśli jakiś inny wątek musi zaktualizować graficzny interfejs użytkownika, powinien wysłać komunikat do właściwego wątku, aby wyznaczony wątek wykonał to zadanie w jego imieniu. Szablon klasy `std::packaged_task` oferuje odpowiednie rozwiązania bez konieczności stosowania niestandardowych komunikatów dla każdego zadania związanego z działaniem graficznego interfejsu użytkownika (patrz listing 4.9).

Listing 4.9. Uruchamianie kodu w wątku graficznego interfejsu użytkownika za pomocą szablonu klasy std::packaged_task

```
#include <deque>
#include <mutex>
#include <future>
#include <thread>
#include <utility>

std::mutex m;
std::deque<std::packaged_task<void()> > tasks;

bool gui_shutdown_message_received();
void get_and_process_gui_message();

void gui_thread()        <-❶
{
    while(!gui_shutdown_message_received())        <-❷
    {
        get_and_process_gui_message();        <-❸
        std::packaged_task<void()> task;
        {
```

```
            std::lock_guard<std::mutex> lk(m);
            if(tasks.empty())      ←❹
                continue;
            task=std::move(tasks.front());      ←❺
            tasks.pop_front();
        }
        task();      ←❻
    }
}

std::thread gui_bg_thread(gui_thread);

template<typename Func>
std::future<void> post_task_for_gui_thread(Func f)
{
    std::packaged_task<void()> task(f);      ←❼
    std::future<void> res=task.get_future();      ←❽
    std::lock_guard<std::mutex> lk(m);
    tasks.push_back(std::move(task));      ←❾
    return res;      ←❿
}
```

Powyższy kod jest bardzo prosty: wątek graficznego interfejsu użytkownika ❶ działa w pętli do momentu otrzymania komunikatu sygnalizującego konieczność zamknięcia tego interfejsu ❷. W ciele tej pętli wątek sprawdza komunikaty dotyczące graficznego interfejsu użytkownika ❸ (na przykład tego, że użytkownik kliknął jakiś element interfejsu) oraz ewentualne zadania w kolejce zadań. Jeśli kolejka nie zawiera żadnych zadań ❹, wątek przechodzi do następnej iteracji pętli; w przeciwnym razie wątek odczytuje zadanie z kolejki ❺, zwalnia blokadę tej kolejki, po czym uruchamia to zadanie ❻. W momencie zakończenia zadania powiązana z nim przyszłość przechodzi w stan gotowości.

Umieszczenie zadania w kolejce jest równie proste: nowe, opakowane zadanie jest tworzone na podstawie wskazanej funkcji ❼, przyszłość jest uzyskiwana z obiektu zadania ❽ za pomocą funkcji składowej `get_future()` i wreszcie zadanie jest umieszczane na liście ❾ przed zwróceniem przyszłości do kodu wywołującego ❿. Kod, który wysyłał komunikat do wątku interfejsu użytkownika, może albo poczekać na przyszłość (jeśli wykonanie zadania jest niezbędne do dalszego działania), albo porzucić tę przyszłość (jeśli nie potrzebuje wyniku przetwarzania).

W tym przykładzie użyliśmy do reprezentacji zadań klasy `std::packaged_task` ↪`<void()>`. Klasa opakowuje funkcję (lub inny obiekt wywoływalny), która nie otrzymuje żadnych parametrów i zwraca `void` (jeśli wskazana funkcja zwraca inną wartość, wynik zostanie porzucony). W tym przypadku zastosowano najprostsze możliwe zadanie, jednak (jak już wiemy) szablon klasy `std::packaged_task` może być równie dobrze stosowany w implementacjach bardziej złożonych rozwiązań — wystarczy w roli parametru szablonu użyć innej sygnatury funkcji, zmienić typ zwracanych wartości (a więc także typ danych przechowywanych w ramach stanu przyszłości) i zmienić typy argumentów operatora wywołania funkcji. Przedstawiony przykład można by łatwo rozszerzyć o możliwość przekazywania argumentów do zadań, które mają być wykonywane przez wątek graficznego interfejsu użytkownika, i zwracania wartości w ramach obiektu typu `std::future` (zamiast samego sygnału o zakończeniu zadania).

Co należy zrobić z zadaniami, których nie można wyrazić w formie prostych wywołań funkcji, i zadaniami, których wyniki mogą pochodzić z wielu różnych miejsc? Obsługa takich przypadków wymaga jeszcze innego sposobu tworzenia przyszłości — bezpośredniego ustawiania wartości za pomocą szablonu `std::promise`.

4.2.3. Obietnice (szablon std::promise)

Programiści pracujący nad aplikacjami, które muszą obsługiwać wiele połączeń sieciowych, często ulegają pokusie obsługi każdego połączenia w osobnym wątku, ponieważ takie rozwiązanie ułatwia zrozumienie i zaimplementowanie mechanizmów komunikacji sieciowej. Takie rozwiązanie sprawdza się w przypadku niewielkiej liczby połączeń (a więc także niewielkiej liczby wątków). Okazuje się jednak, że w razie wzrostu liczby połączeń opisany model staje się nieefektywny, ponieważ duża liczba wątków zajmuje zbyt wiele zasobów systemu operacyjnego, a częste przełączanie kontekstu (jeśli liczba wątków przekracza współbieżność sprzętową) ma negatywny wpływ na wydajność aplikacji. W skrajnych przypadkach aplikacja uruchamiająca dużo nowych wątków może wyczerpać zasoby systemu operacyjnego przed osiągnięciem limitu połączeń sieciowych. Właśnie dlatego nawet w aplikacjach obsługujących bardzo dużo połączeń sieciowych stosuje się stosunkowo niewiele wątków (czasem tylko jeden wątek) odpowiedzialnych za obsługę tych połączeń, zatem każdy wątek musi obsługiwać wiele połączeń jednocześnie.

Przeanalizujmy przykład wątku obsługującego połączenia. Pakiety danych przychodzą za pośrednictwem różnych połączeń w przypadkowej kolejności; podobnie pakiety danych przeznaczone do wysłania są kolejkowane w przypadkowej kolejności. W wielu przypadkach pozostałe elementy aplikacji będą oczekiwały albo na wysłanie danych, albo na otrzymanie nowego pakietu danych za pośrednictwem określonego połączenia sieciowego.

Szablon klasy `std::promise<T>` umożliwia ustawienie wartości (typu `T`), którą w przyszłości będzie można odczytać za pośrednictwem powiązanego obiektu klasy `std::`
`➥future<T>`. Para klas `std::promise` i `std::future` to jeden z mechanizmów umożliwiających implementację interesującego nas rozwiązania — wątek oczekujący może wstrzymać działanie w oczekiwaniu na przyszłość, natomiast wątek udostępniający dane może użyć obiektu obietnicy do ustawienia powiązanej wartości, tak aby odpowiednia przyszłość przeszła w stan **gotowości**.

Obiekt klasy `std::future` powiązany z danym obiektem klasy `std::promise` można uzyskać za pomocą funkcji składowej `get_future()`, a więc tak samo jak w przypadku obiektu klasy `std::packaged_task`. W momencie ustawienia wartości obiektu obietnicy (za pomocą funkcji składowej `set_value()`) obiekt przyszłości przechodzi w stan **gotowości** i jako taki może zostać użyty do pobrania zapisanej wartości. Jeśli nastąpi zniszczenie obiektu klasy `std::promise` bez wcześniejszego ustawienia wartości, zamiast oczekiwanej wartości zostanie ustawiony stosowny wyjątek. Sposób przekazywania wyjątków pomiędzy wątkami zostanie opisany w punkcie 4.2.4.

Na listingu 4.10 pokazano przykład kodu wątku, który przetwarza połączenia w opisany powyżej sposób. W prezentowanym przykładzie użyliśmy pary klas `std::promise`
`➥<bool>` i `std::future<bool>` do identyfikacji udanej transmisji bloku danych wychodzących; wartość powiązana z obiektem przyszłości ma postać prostej flagi sukcesu

lub niepowodzenia. W przypadku pakietów przychodzących funkcję danych powiązanych z obiektem przyszłości pełni właściwa treść tych pakietów.

Listing 4.10. Obsługa wielu połączeń w jednym wątku przy użyciu obiektów obietnic

```
#include <future>

void process_connections(connection_set& connections)
{
    while(!done(connections))          ←❶
    {
        for(connection_iterator          ←❷
                connection=connections.begin(),end=connections.end();
            connection!=end;
            ++connection)
        {
            if(connection->has_incoming_data())          ←❸
            {
                data_packet data=connection->incoming();
                std::promise<payload_type>& p=
                    connection->get_promise(data.id);          ←❹
                p.set_value(data.payload);
            }
            if(connection->has_outgoing_data())          ←❺
            {
                outgoing_packet data=
                    connection->top_of_outgoing_queue();
                connection->send(data.payload);
                data.promise.set_value(true);          ←❻
            }
        }
    }
}
```

Funkcja `process_connections()` wykonuje pętlę do momentu, w którym funkcja `done()` zwróci wartość `true` ❶. W każdej iteracji tej pętli kod aplikacji sprawdza kolejno każde połączenie ❷ i pobiera dane przychodzące (jeśli istnieją) ❸ lub wysyła kolejkowane dane wychodzące ❺. Zakładamy, że pakiet przychodzący zawiera jakiś identyfikator i właściwe dane. Identyfikator jest odwzorowywany na odpowiedni obiekt klasy `std::promise` (na przykład metodą odnajdywania w kontenerze asocjacyjnym) ❹, natomiast wartość jest przypisywana do ciała pakietu. W przypadku pakietów wychodzących zastosowano mechanizm kolejki pakietów oczekujących na wysłanie — program sprawdza stan kolejki i wysyła ewentualne pakiety dla danego połączenia. Po wysłaniu pakietu w obiekcie obietnicy powiązanym z tymi danymi wychodzącymi jest ustawiana wartość `true`, która oznacza pomyślną transmisję danych ❻. Zgodność opisanego modelu z rzeczywistymi protokołami komunikacji sieciowej zależy tylko od tych protokołów. Struktura na bazie obietnicy i przyszłości nie pasuje co prawda do każdego scenariusza, ale pod wieloma względami przypomina model asynchronicznych operacji wejścia-wyjścia stosowany w niektórych systemach operacyjnych.

W dotychczas prezentowanym kodzie całkowicie ignorowaliśmy problem wyjątków. Wyobrażenie świata, w którym wszystko działa, jak należy, jest być może kuszące, ale nie ma wiele wspólnego z rzeczywistością. Nie można wykluczyć, że dysk zostanie

zapełniony, że program nie będzie mógł znaleźć potrzebnych danych, że nastąpi awaria połączenia sieciowego lub że w wyniku błędu nie będzie dostępna baza danych. Jeśli operacja wykonywana w jednym wątku potrzebuje do działania wyniku innego wątku, warto uwzględnić możliwość zasygnalizowania błędu w formie wyjątku — zakładanie, że w kodzie stosującym obiekty klasy `std::packaged_task` czy `std::promise` wszystko zawsze będzie działało prawidłowo, byłoby zbyt optymistyczne. Biblioteka standardowa języka C++ oferuje wygodne mechanizmy obsługi wyjątków w tego rodzaju scenariuszach i umożliwia zapisywanie wyjątków w ramach wyników powiązanych z tymi obiektami.

4.2.4. Zapisywanie wyjątku na potrzeby przyszłości

Przeanalizujmy następujący fragment kodu. Jeśli na wejściu funkcji `square_root()` przekażemy wartość `-1`, zgłoszony zostanie wyjątek (to on trafi do kodu wywołującego tę funkcję):

```
double square_root(double x)
{
    if(x<0)
    {
        throw std::out_of_range("x<0");
    }
    return sqrt(x);
}
```

Przypuśćmy teraz, że zamiast wywołać funkcję `square_root()` w bieżącym wątku, jak w poniższym wierszu:

```
double y=square_root(-1);
```

użyjemy wywołania asynchronicznego w następującej formie:

```
std::future<double> f=std::async(square_root,-1);
double y=f.get();
```

Idealnym rozwiązaniem byłoby zapewnienie dokładnie takiego samego zachowania jak w przypadku kodu jednowątkowego — skoro zmiennej `y` w obu przypadkach jest przypisywany wynik funkcji, wątek wywołujący funkcję `f.get()` powinien mieć dostęp także do ewentualnych wyjątków (tak jak odpowiedni kod jednowątkowy).

Okazuje się, że właśnie tak działa prezentowane rozwiązanie: jeśli funkcja `square_root` wywołana za pośrednictwem funkcji `std::async` zgłosi jakiś wyjątek, wyjątek ten zostanie zapisany w obiekcie przyszłości (w miejscu dla wartości wynikowej), przyszłość przejdzie w stan **gotowości**, a funkcja `get()` spowoduje ponowne zgłoszenie zapisanego wyjątku. (Uwaga: standard języka C++ nie określa, czy ponowne zgłoszenie dotyczy oryginalnego obiektu wyjątku, czy jego kopii; różne kompilatory i biblioteki stosują w tym względzie odmienne rozwiązania). To samo dotyczy funkcji opakowanej w ramach obiektu klasy `std::packaged_task` — jeśli po wywołaniu zadania opakowana funkcja zgłosi jakiś wyjątek, wyjątek jest zapisywany w obiekcie przyszłości zamiast właściwego wyniku. Aby ponownie zgłosić ten wyjątek, wystarczy wywołać funkcję `get()`.

Szablon klasy `std::promise` oferuje oczywiście analogiczne rozwiązanie, które wymaga bezpośredniego wywołania funkcji. Aby zapisać wyjątek zamiast wartości wynikowej, wystarczy wywołać funkcję składową `set_exception()` zamiast funkcji `set_value()`.

Wspomniana funkcja jest zwykle stosowana w bloku `catch` odpowiedzialnym za obsługę wyjątku zgłoszonego w trakcie działania algorytmu — wyjątek jest umieszczany w obiekcie obietnicy:

```
extern std::promise<double> some_promise;

try
{
    some_promise.set_value(calculate_value());
}
catch(...)
{
    some_promise.set_exception(std::current_exception());
}
```

W powyższym kodzie użyto funkcji `std::current_exception()` do pobrania zgłoszonego wyjątku; alternatywnym rozwiązaniem byłoby wywołanie funkcji `std::copy_exception()` w celu zapisania nowego wyjątku bez jego bezpośredniego zgłaszania:

```
some_promise.set_exception(std::copy_exception(std::logic_error("foo ")));
```

Opisane rozwiązanie jest nieporównanie bardziej czytelne niż stosowanie bloku `try-catch`, jeśli tylko potencjalny wyjątek jest znany z wyprzedzeniem. W ten sposób można nie tylko uprościć kod, ale też ułatwić optymalizację tego kodu przez kompilator.

Innym sposobem zapisywania wyjątku w przyszłości jest zniszczenie obiektu klasy `std::promise` lub `std::packaged_task` powiązanego z obiektem przyszłości bez uprzedniego wywołania funkcji ustawiającej (w przypadku obiektu obietnicy) lub uruchomienia opakowanego zadania. Jeśli obiekt przyszłości nie będzie **gotowy**, w obu przypadkach destruktor klasy `std::promise` lub `std::packaged_task` zapisze w powiązanym stanie wyjątek typu `std::future_error` z kodem błędu `std::future_errc::broken_promise`. Tworząc przyszłość, zapowiadamy (składamy obietnicę), że udostępnimy jakąś wartość lub jakiś wyjątek; zniszczenie źródła tej wartości lub tego wyjątku bez uprzedniego dostarczenia zapowiedzianego zasobu łamie tę obietnicę. Gdyby w opisanym przypadku kompilator niczego nie zapisał w obiekcie przyszłości, wątki oczekujące mogłyby czekać w nieskończoność.

Do tej pory we wszystkich przykładach stosowałem szablon klasy `std::future`. Warto jednak pamiętać o pewnych ograniczeniach szablonu `std::future`, w tym o możliwości oczekiwania na wynik przez zaledwie jeden wątek. W razie konieczności zaimplementowania modelu, w którym na jedno zdarzenie będzie oczekiwało wiele wątków, należy użyć raczej szablonu klasy `std::shared_future`.

4.2.5. Oczekiwanie na wiele wątków

Mimo że szablon klasy `std::future` obsługuje wszystkie mechanizmy synchronizacji potrzebne do przesyłania danych pomiędzy wątkami, wywołania funkcji składowych określonego obiektu klasy `std::future` nie są synchronizowane z wywołaniami funkcji pozostałych obiektów tej klasy. Jeśli wiele wątków uzyskuje dostęp do jednego obiektu klasy `std::future` bez stosowania dodatkowych mechanizmów synchronizacji, aplikacja jest narażona na **wyścig danych** i niezdefiniowane zachowania. Problem wynika z projektu tego rozwiązania — szablon klasy `std::future` modeluje unikatową własność asynchronicznego wyniku, a jednorazowy charakter funkcji `get()` i tak wyklucza sens

współbieżnego dostępu. Skoro po pierwszym wywołaniu funkcji `get()` nie można już pobrać żadnych danych, z natury rzeczy dane mogą być pobrane tylko przez jeden wątek.

Jeśli jednak projekt naszej aplikacji współbieżnej wymaga, aby wiele wątków mogło czekać na to samo zdarzenie, nie wszystko stracone — wystarczy użyć szablonu klasy `std::shared_future`. O ile szablon klasy `std::future` oferuje tylko możliwość **przenoszenia**, zatem własność przyszłości można przenosić pomiędzy różnymi obiektami, ale tylko jeden obiekt może się jednocześnie odwoływać do jednego asynchronicznego wyniku, o tyle szablon klasy `std::shared_future` oferuje możliwość **kopiowania**, zatem może istnieć wiele obiektów odwołujących się do tego samego stanu.

W przypadku szablonu `std::shared_future` funkcje składowe wywoływane dla pojedynczego obiektu wciąż nie są synchronizowane, zatem warunkiem unikania wyścigów danych w związku z dostępem do tego samego obiektu z poziomu wielu wątków jest ochrona tego dostępu za pomocą blokady. Najlepszym sposobem jest kopiowanie tego obiektu, tak aby każdy wątek uzyskiwał dostęp do własnej kopii. Dostęp do współdzielonego, asynchronicznego stanu z poziomu wielu wątków jest bezpieczny, jeśli tylko każdy z tych wątków uzyskuje dostęp do stanu za pośrednictwem własnego obiektu klasy `std::shared_future`. Przykład takiego rozwiązania pokazano na rysunku 4.1.

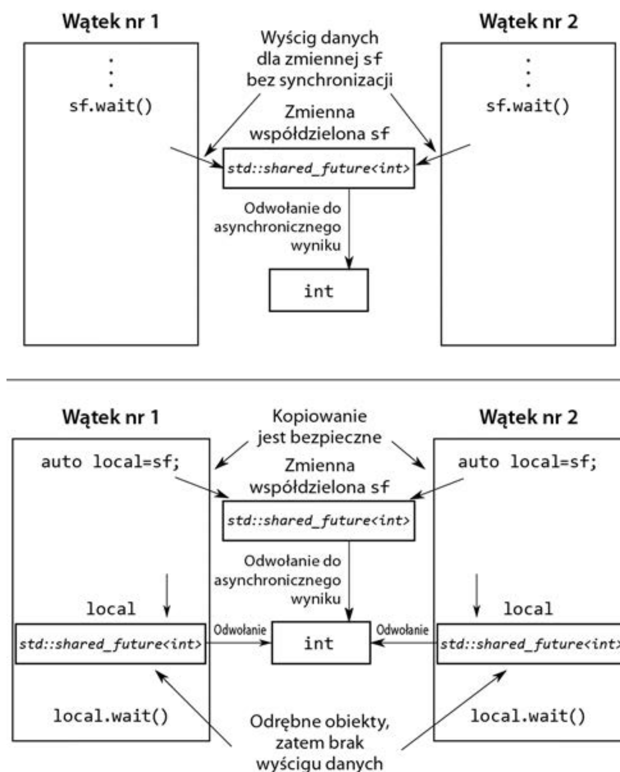

Rysunek 4.1. Użycie wielu obiektów klasy std::shared_future w celu uniknięcia wyścigów danych

Jednym z możliwych zastosowań szablonu klasy `std::shared_future` jest implementacja równoległego wykonywania jakiejś operacji w modelu zbliżonym do złożonego arkusza kalkulacyjnego, gdzie każda komórka zawiera wartość, która może być używana

we wzorach w wielu pozostałych komórkach. Wzory potrzebne do obliczania wyników w komórkach zależnych mogą używać obiektu klasy `std::shared_future` podczas odwoływania się do pierwszej komórki. Jeśli wzory we wszystkich komórkach będą przetwarzane równolegle, zadania odwołujące się do gotowych wartości zostaną zrealizowane natychmiast, natomiast zadania zależne od innych, jeszcze przetwarzanych komórek będą musiały poczekać na osiągnięcie gotowości przez tamte komórki. Takie rozwiązanie umożliwia maksymalne wykorzystanie dostępnej współbieżności sprzętowej.

Obiekty klasy `std::shared_future`, które wskazują pewien asynchroniczny stan, są konstruowane na podstawie obiektów klasy `std::future` odwołujących się do tego stanu. Ponieważ obiekty klasy `std::future` nie współdzielą własności tego asynchronicznego stanu z żadnymi innymi obiektami, własność należy przenieść do obiektu klasy `std::`
`↪shared_future` za pomocą funkcji `std::move`, pozostawiając oryginalny obiekt klasy `std::future` z pustym stanem (jak w przypadku użycia konstruktora domyślnego):

```
std::promise<int> p;
std::future<int> f(p.get_future());
assert(f.valid());            ← 1 Przyszłość f jest prawidłowa
std::shared_future<int> sf(std::move(f));
assert(!f.valid());           ← 2 Przyszłość f już nie jest prawidłowa
assert(sf.valid());           ← 3 Przyszłość sf jest teraz prawidłowa
```

Obiekt przyszłości `f` jest początkowo prawidłowy ❶, ponieważ odwołuje się do asynchronicznego stanu obietnicy `p`, jednak po przeniesieniu tego stanu do obiektu `sf` to obiekt `sf` jest prawidłowy ❸, natomiast obiekt `f` jest już nieprawidłowy ❷.

Jak w przypadku wszystkich obiektów z możliwością przenoszenia, przeniesienie własności jest wykonywane automatycznie dla r-wartości, zatem możemy skonstruować obiekt klasy `std::shared_future` bezpośrednio na podstawie wartości zwróconej przez funkcję składową `get_future()` obiektu klasy `std::promise`:

```
std::promise<std::string> p;
std::shared_future<std::string> sf(p.get_future());     ← 1 Automatyczne przeniesienie własności
```

W powyższym kodzie własność jest przenoszona automatycznie — obiekt klasy `std::`
`↪shared_future<>` jest konstruowany na podstawie r-wartości typu `std::future<std::`
`↪string>` ❶.

Szablon klasy `std::future` oferuje jeszcze inne rozwiązanie ułatwiające stosowanie obiektów klasy `std::shared_future` przy użyciu nowego mechanizmu automatycznego określania typu zmiennej na podstawie inicjalizatora (patrz część A.6 dodatku A). Szablon klasy `std::future` definiuje funkcję składową `share()`, która tworzy nowy obiekt klasy `std::shared_future` i bezpośrednio przenosi własność do tego obiektu. Użycie tego rozwiązania może nam oszczędzić sporo pisania i znacznie ułatwia modyfikowanie kodu:

```
std::promise< std::map< SomeIndexType, SomeDataType, SomeComparator,
SomeAllocator>::iterator> p;
auto sf=p.get_future().share();
```

W tym przypadku typ zmiennej `sf` jest identyfikowany jako `std::shared_future< std::map< SomeIndexType, SomeDataType, SomeComparator, SomeAllocator>::iterator>`, czyli konstrukcja, której wielokrotne stosowanie w kodzie byłoby dość kłopotliwe.

W razie zmiany komparatora lub alokatora wystarczy zmodyfikować typ obiektu obietnicy; typ obiektu przyszłości zostanie automatycznie zaktualizowany i dostosowany do tej zmiany.

W pewnych przypadkach dobrym rozwiązaniem jest ograniczanie maksymalnego czasu oczekiwania na zdarzenie (z uwagi na ograniczony czas działania określonej sekcji kodu lub ze względu na istnienie innych ważnych zadań, którymi dany wątek może się zająć, jeśli oczekiwane zdarzenie nie wystąpi odpowiednio wcześnie). Z myślą o takich przypadkach wiele funkcji oczekiwania oferuje wersje z możliwością określenia limitu czasowego.

4.3. Oczekiwanie z limitem czasowym

Wszystkie wywołania blokujące, które stosowaliśmy w dotychczasowych przykładach, blokowały wykonywanie wątków przez nieokreślony czas, tj. do momentu wystąpienia oczekiwanego zdarzenia. W wielu przypadkach takie rozwiązanie jest wystarczające, jednak w niektórych sytuacjach lepszym wyjściem jest określenie maksymalnego czasu oczekiwania. Stosowanie takich limitów czasowych może mieć na celu potwierdzenie prawidłowego działania aplikacji (w formie komunikatu dla użytkownika lub innego procesu) lub przerwanie oczekiwania, jeśli na przykład użytkownik kliknął przycisk *Anuluj*.

Istnieją dwa rodzaje limitów czasowych stosowanych dla operacji blokujących: limity określające maksymalny **czas blokowania** wątku (na przykład 30 milisekund) oraz limity **bezwzględne**, gdzie oczekiwanie nie może trwać dłużej niż do określonego punktu w czasie (na przykład do godziny 17:30:15.045987023 dnia 30 listopada 2012 roku). Większość funkcji oczekujących występuje w wersjach obsługujących obie formy limitów czasowych. Wersje obsługujące względne limity czasowe (określające czas trwania operacji) są oznaczane przyrostkiem `_for`, natomiast bezwzględne limity czasowe oznacza się przyrostkiem `_until`.

Na przykład klasa `std::condition_variable` definiuje dwie przeciążone wersje funkcji składowej `wait_for()` i dwie przeciążone wersje funkcji składowej `wait_until()`, czyli odpowiedniki obu wersji funkcji `wait()` uzupełnione o obsługę względnych i bezwzględnych limitów czasowych — pierwsza wersja czeka na sygnał, upłynięcie limitu czasowego lub bezpośrednie budzenie; druga wersja w momencie budzenia sprawdza przekazany predykat i zwraca sterowanie, pod warunkiem że albo ten predykat jest prawdziwy (w wyniku sygnału umieszczonego w zmiennej warunkowej), albo osiągnięto limit czasowy.

Zanim przeanalizujemy szczegółowe aspekty stosowania funkcji uwzględniających limity czasowe, warto poświęcić chwilę na omówienie sposobu określania czasu w języku C++, w tym dostępnych zegarów.

4.3.1. Zegary

W kontekście elementów biblioteki standardowej języka C++ zegar jest dla programu źródłem informacji o bieżącej godzinie. W szczególności zegar jest klasą udostępniającą cztery odrębne informacje:

- **bieżąca** godzina;
- typ wartości używanych do reprezentowania godzin uzyskiwanych z obiektu zegara;
- okres reprezentowany przez jeden takt zegara;
- to, czy takty zegara mają stałą długość, czyli możliwość traktowania zegara jako **stabilnego**.

Bieżącą godzinę reprezentowaną przez zegar można uzyskać, wywołując statyczną funkcję składową `now()` klasy zegara; na przykład funkcja `std::chrono::system_clock::now()` zwróci bieżącą godzinę reprezentowaną przez zegar systemowy. Typ punktów w czasie dla poszczególnych zegarów jest reprezentowany przez składową definicję typu `time_point`, zatem każda funkcja `zegar::now()` zwraca wartość typu `zegar::time_point`.

Okres taktu zegara jest wyrażany w formie ułamka sekundy reprezentowanego przez składową definicję typu `period` — w przypadku zegara wykonującego 25 taktów w ciągu sekundy `period` definiuje typ `std::ratio<1,25>`, natomiast w przypadku zegara wykonującego jeden takt na 2,5 sekundy składowa `period` definiuje typ `std::ratio<5,2>`. Jeśli określenie okresu taktu nie jest możliwe do momentu uruchomienia programu lub jeśli ten okres może się zmieniać w czasie działania aplikacji, okres można zdefiniować w formie średniego czasu trwania taktu, najkrótszego możliwego taktu lub innej wartości przewidzianej przez twórców biblioteki. Nie można jednak zakładać, że obserwowany okres taktu zegara podczas jednej próby uruchomienia programu będzie odpowiadał rzeczywistemu okresowi danego zegara.

Jeśli **takty zegara mają stałą częstotliwość** (niezależnie od tego, czy ta częstotliwość pasuje do przyjętego okresu) i jeśli **nie możemy zmienić długości taktu**, mamy do czynienia z tzw. **stabilnym zegarem** (ang. *steady clock*). Składowa statyczna `is_steady` klasy stabilnego zegara ma wartość `true` (w przypadku niestabilnego zegara ta sama składowa ma wartość `false`). Zegar systemowy (reprezentowany przez klasę `std::chrono::system_clock`) zwykle **nie** jest stabilny, ponieważ można dostosowywać jego częstotliwość (nawet jeśli zmiany częstotliwości są wprowadzane automatycznie z uwzględnieniem przesunięć względem zegara lokalnego). Każda taka zmiana może spowodować, że wywołanie funkcji `now()` zwróci wartość wcześniejszą niż zwrócona przez poprzednie wywołanie tej funkcji, co oczywiście narusza wymaganie stałej częstotliwości zegara (i długości taktu). Jak się za chwilę przekonasz, stabilne zegary są szczególnie przydatne podczas obliczeń z uwzględnieniem limitów czasowych — z myślą o tych i podobnych zastosowaniach twórcy biblioteki standardowej udostępnili taki zegar w formie klasy `std::chrono::steady_clock`. Biblioteka standardowa języka C++ zawiera też inne klasy zegarów: wspomnianą wcześniej klasę `std::chrono::system_clock`, która reprezentuje zegar „czasu rzeczywistego" w danym systemie i która udostępnia funkcję konwersji punktów w czasie na i z wartości typu `time_t`, oraz klasę `std::chrono::high_resolution_clock`, która zapewnia najkrótszy możliwy takt zegara (a więc także najwyższą możliwą częstotliwość) spośród wszystkich zegarów tej biblioteki. Drugi z zegarów można wykorzystać w roli punktu wyjścia dla definicji alternatywnych rozwiązań. Wymienione zegary zdefiniowano (wraz z pozostałymi elementami związanymi z obsługą czasu) w pliku nagłówkowym <chrono>.

Zanim przystąpimy do omawiania metod reprezentowania punktów w czasie, warto poświęcić chwilę analizie technik reprezentowania okresów.

4.3.2. Okresy

Okres (czas trwania) to najprostszy aspekt obsługi czasu. Okres zaimplementowano w szablonie klasy `std::chrono::duration<>` (wszystkie elementy języka C++ związane z obsługą czasu i używane przez bibliotekę wątków należą do przestrzeni nazw `std::chrono`). Pierwszy parametr tego szablonu określa typ reprezentacji (na przykład `int`, `long` lub `double`); drugi parametr jest ułamkiem określającym liczbę sekund reprezentowanych przez jednostkę okresu. Na przykład liczba minut przechowywana w wartości typu `short` jest reprezentowana przez klasę `std::chrono::duration<short,std::ratio<60,1>>`, ponieważ minuta składa się z 60 sekund. Liczba milisekund przechowywanych w wartości typu `double` jest reprezentowana przez klasę `std::chrono::duration<double,std::ratio<1,1000>>`, ponieważ każda milisekunda trwa jedną tysięczną część sekundy.

Biblioteka standardowa oferuje zbiór predefiniowanych definicji typów w przestrzeni nazw `std::chrono` dla różnych okresów (wyrażanych w nanosekundach, mikrosekundach, milisekundach, sekundach, minutach i godzinach). Wszystkie te definicje stosują na tyle elastyczne typy całkowitoliczbowe, że mogą reprezentować na przykład okresy ponad 500-letnie w wybranych jednostkach czasu. Przestrzeń nazw zawiera także definicje typów dla rzędów wielkości układu SI: od `std::atto` (10^{-18}) do `std::exa` (10^{18}) (i więcej, jeśli tylko dana platforma obsługuje 128-bitowe typy całkowitoliczbowe). Za pomocą tych typów można operować na niestandardowych okresach, na przykład klasa `std::duration<double,std::centi>` obsługuje liczbę setnych części sekundy reprezentowanych przez liczbę typu `double`.

Konwersja pomiędzy okresami jest wykonywana automatycznie, pod warunkiem że nie wymaga obcięcia wartości źródłowej — oznacza to, że konwersja godzin na sekundy jest możliwa, ale już konwersja sekund na godziny nie zostanie wykonana automatycznie. Konwersję można też wykonać jawnie za pomocą funkcji `std::chrono::duration_cast<>`:

```
std::chrono::milliseconds ms(54802);
std::chrono::seconds s=
    std::chrono::duration_cast<std::chrono::seconds>(ms);
```

Ponieważ wynik jest obcinany (nie zaokrąglany), zmienna `s` będzie zawierała wartość 54.

Okresy obsługują działania arytmetyczne, zatem możemy dodawać i odejmować okresy, aby otrzymywać nowe okresy, bądź mnożyć lub dzielić okresy przez stałe wybranego typu danych (czyli pierwszego parametru szablonu klasy). Oznacza to, że wyrażenie `5*seconds(1)` ma taką samą wartość jak wyrażenia `seconds(5)` i `minutes(1) - seconds(55)`. Liczbę jednostek składających się na dany okres można uzyskać za pomocą funkcji składowej `count()`. Oznacza to, że wywołanie `std::chrono::milliseconds(1234).count()` zwróci wartość `1234`.

Wymuszanie oczekiwania na podstawie okresu (czasu trwania) wymaga stosowania instancji typu `std::chrono::duration<>`. Możemy na przykład spowodować, że czas oczekiwania na gotowość obiektu przyszłości wyniesie 35 milisekund:

```
std::future<int> f=std::async(some_task);
if(f.wait_for(std::chrono::milliseconds(35))==std::future_status::ready)
do_something_with(f.get());
```

Wszystkie funkcje oczekiwania zwracają status określający, czy koniec oczekiwania wynika z wyczerpania limitu czasowego, czy z wystąpienia zdarzenia, na które czekał dany wątek. W tym przypadku wątek czeka na przyszłość, zatem funkcja zwraca wartość `std::future_status::timeout` w przypadku wyczerpania limitu czasowego; wartość `std::future_status::ready`, jeśli przyszłość jest gotowa; lub wartość `std::future_status::deferred`, jeśli zadanie przyszłości zostało odłożone na później. Czas oczekiwania okresowego jest mierzony przy użyciu stabilnego, wewnętrznego zegara biblioteki, zatem 35 milisekund oznacza właśnie 35 milisekund, nawet jeśli w czasie oczekiwania zegar systemowy zostanie przestawiony (w przód lub w tył). Nie można oczywiście zapominać o kaprysach systemu szeregowania zadań i o zróżnicowanej precyzji zegarów systemów operacyjnych, które mogą spowodować, że rzeczywisty czas dzielący wywołanie funkcji `wait()` od zwrócenia sterowania będzie dużo dłuższy niż 35 ms.

Skoro potrafimy już stosować okresy, możemy przejść do analizy modelu punktów w czasie.

4.3.3. *Punkty w czasie*

Punkt w czasie jest reprezentowany przez instancję szablonu klasy `std::chrono::time_point<>`. Pierwszy parametr tego szablonu wskazuje zegar, natomiast drugi parametr określa jednostki miary (w tej roli należy użyć specjalizacji szablonu klasy `std::chrono::duration<>`). Wartość punktu w czasie reprezentuje czas (w formie wielokrotności wskazanego okresu) od konkretnego punktu w czasie nazywanego **epoką** zegara. Epoka zegara jest prostą właściwością, która jednak nie jest bezpośrednio dostępna ani wprost definiowana przez standard języka C++. Do najczęściej stosowanych epok należy północ 1 stycznia 1970 roku i moment uruchomienia komputera, na którym działa dana aplikacja. Zegary mogą stosować jedną epokę lub różne, niezależne epoki. Jeśli dwa zegary stosują tę samą epokę, definicja typu `time_point` w klasie jednego zegara może wskazywać drugą klasę jako typ zegara powiązanego z daną definicją `time_point`. Mimo że nie można bezpośrednio uzyskać epoki, **mamy do dyspozycji** funkcję `time_since_epoch()`, którą możemy wywołać dla danej instancji typu `time_point`. Funkcja składowa `time_since_epoch()` zwraca wartość okresu reprezentującą czas od epoki zegara do określonego punktu w czasie.

Punkt w czasie można zdefiniować na przykład w formie obiektu klasy `std::chrono::time_point<std::chrono::system_clock, std::chrono::minutes>`. Tak skonstruowany obiekt zawiera czas względem zegara systemowego, tyle że mierzony w minutach (nie według standardowej precyzji zegara systemowego, czyli sekund lub części sekundy).

Na obiektach klasy `std::chrono::time_point<>` można wykonywać operacje dodawania i odejmowania okresów, których wynikiem są nowe punkty w czasie. Oznacza to, że na przykład w wyniku dodawania `std::chrono::high_resolution_clock::now() + std::chrono::nanoseconds(500)` otrzymamy punkt w czasie, który nastąpi za 500 nanosekund (licząc od teraz). Wyrażenia tego typu są przydatne podczas obliczania bezwzględnego limitu czasowego w sytuacji, gdy maksymalny czas wykonywania bloku kodu jest znany z wyprzedzeniem. Takie rozwiązanie wymaga jednak wielu wywołań funkcji oczekujących lub funkcji poprzedzających funkcję oczekującą i zaliczanych do bloku, który podlega ograniczeniu czasowemu.

Istnieje też możliwość odjęcia jednego punktu w czasie od innego, pod warunkiem że oba punkty bazują na tym samym zegarze. Wynikiem tej operacji jest okres, który reprezentuje czas dzielący oba punkty. W ten sposób można na przykład sprawdzać czas wykonywania bloków kodu:

```
auto start=std::chrono::high_resolution_clock::now();
do_something();
auto stop=std::chrono::high_resolution_clock::now();
std::cout<<"Wykonanie funkcji do_something() zajęło "
  <<std::chrono::duration<double,std::chrono::seconds>(stop-start).count()
  <<" sekund."<<std::endl;
```

Parametr zegara szablonu klasy `std::chrono::time_point<>` decyduje nie tylko o epoce. W przypadku przekazania punktu w czasie na wejściu funkcji oczekującej, która stosuje bezwzględny limit czasowy, wybrany zegar będzie używany do mierzenia czasu. Warto pamiętać o możliwości zmiany wskazań zegara i o tym, że funkcja oczekująca nie zwróci sterowania do momentu, w którym funkcja `now()` tego zegara nie zwróci wartości późniejszej od wskazanego limitu czasowego. Jeśli zegar zostanie przestawiony w przód, łączny czas oczekiwania może być krótszy (w porównaniu z czasem mierzonym przez stabilny zegar); a jeśli zegar zostanie cofnięty, łączny czas oczekiwania zostanie wydłużony.

Jak nietrudno odgadnąć, punkty w czasie są używane w wersjach funkcji oczekujących z przyrostkiem `_until`. Typowym zastosowaniem tego rozwiązania jest wyznaczanie przesunięcia względem godziny zwracanej przez wywołanie *`jakiś-zegar`*`::now()` w wybranym punkcie programu. Punkty powiązane z zegarem systemowym można uzyskiwać, konwertując instancje typu `time_t` za pomocą statycznej funkcji składowej `std::chrono::system_clock::to_time_point()`. Jeśli na przykład maksymalny czas oczekiwania na zdarzenie powiązane ze zmienną warunkową wynosi 500 milisekund, można zastosować konstrukcję podobną do tej z listingu 4.11.

Listing 4.11. Oczekiwanie na zmienną warunkową z uwzględnieniem limitu czasowego

```
#include <condition_variable>
#include <mutex>
#include <chrono>

std::condition_variable cv;
bool done;
std::mutex m;

bool wait_loop()
{
    auto const timeout= std::chrono::steady_clock::now()+
        std::chrono::milliseconds(500);
    std::unique_lock<std::mutex> lk(m);
    while(!done)
    {
        if(cv.wait_until(lk,timeout)==std::cv_status::timeout)
            break;
    }
    return done;
}
```

Rozwiązanie z listingu 4.11 jest zalecanym sposobem oczekiwania na zmienne warunkowe z uwzględnieniem limitu czasowego w sytuacji, gdy funkcja oczekująca nie otrzymuje na wejściu żadnego predykatu. Maksymalny czas wykonywania pętli jest ograniczony. Jak napisałem w punkcie 4.1.1, jeśli nie stosujemy dodatkowego predykatu, operowanie na zmiennych warunkowych wymaga użycia pętli, która obsługuje nietypowe sposoby budzenia wątku. W przypadku wywołania funkcji `wait_for()` w ciele pętli może się zdarzyć, że warunek wznowienia działania zostanie spełniony bezpośrednio przed upływem limitu czasowego, a w następnej iteracji czas oczekiwania będzie liczony od początku. Taka sytuacja może mieć miejsce wielokrotnie, zatem łączny czas oczekiwania byłby nieograniczony.

Skoro dysponujemy już podstawowymi narzędziami umożliwiającymi stosowanie limitów czasowych, pora omówić funkcje, w których można używać tych limitów.

4.3.4. Funkcje otrzymujące limity czasowe

Najprostszym zastosowaniem limitu czasowego jest dodanie opóźnienia do przetwarzania określonego wątku, tak aby ten wątek nie zajmował czasu procesora (potrzebnego innym wątkom) w czasie, gdy nie wykonuje żadnych wartościowych zadań. Przykład takiego rozwiązania opisałem w podrozdziale 4.1, gdzie kod wielokrotnie sprawdzał stan flagi gotowości w pętli. Do opóźniania działania (usypiania) wątków służą funkcje `std::this_thread::sleep_ for()` i `std::this_thread::sleep_until()`. Obie funkcje działają jak proste budziki — wątek jest usypiany albo na określony okres (za pomocą funkcji `sleep_for()`), albo do wskazanego punktu w czasie (za pomocą funkcji `sleep_`
`↪until()`). W przykładowych rozwiązaniach z podrozdziału 4.1 należałoby użyć funkcji `sleep_for()`, ponieważ w przypadku okresowo wykonywanych operacji wątek powinien być wstrzymywany na pewien czas (nie do określonego punktu w czasie). Funkcja `sleep_until()` umożliwia planowanie budzenia wątku w określonym punkcie w czasie. Funkcja `sleep_until()` może więc służyć na przykład do uruchamiania procedury tworzenia kopii zapasowej o północy, drukowania listy płac o 6 rano lub wstrzymywania wątku do momentu wyświetlenia następnej klatki podczas odtwarzania zapisu wideo.

Usypianie wątku to oczywiście nie jedyne zastosowanie limitów czasowych — jak już wspomniałem, limity tego typu można stosować łącznie ze zmiennymi warunkowymi i przyszłościami. Istnieje nawet możliwość stosowania limitów czasowych podczas prób uzyskania blokady muteksu, jeśli tylko użyty muteks obsługuje takie działanie. Standardowe muteksy typów `std::mutex` i `std::recursive_mutex` nie obsługują limitów czasowych dla operacji blokowania, ale już muteksy typów `std::timed_mutex` i `std::recursive_timed_mutex` dopuszczają takie działanie. Oba te typy udostępniają funkcje składowe `try_lock_for()` i `try_lock_until()`, które próbują uzyskać blokadę muteksu odpowiednio w określonym czasie lub przed osiągnięciem określonego punktu w czasie. W tabeli 4.1 opisano funkcje biblioteki standardowej języka C++, które obsługują limity czasowe, wraz z ich parametrami i typami zwracanych wartości. W miejsce parametru opisanego jako *`okres`* należy przekazać obiekt klasy `std::duration<>`, natomiast parametr *`punkt_w_czasie`* należy zastąpić obiektem klasy `std::time_point<>`.

Skoro wiemy już, jak działają zmienne warunkowe, obiekty przyszłości i obietnic oraz opakowane zadania, czas przeanalizować te mechanizmy w nieco szerszym kontekście, w szczególności przyjrzeć się technikom upraszczania (za pomocą tych mechanizmów) synchronizacji operacji wykonywanych przez różne wątki.

Tabela 4.1. Funkcje otrzymujące limity czasowe

Klasa lub przestrzeń nazw	Funkcje	Zwracane wartości
Przestrzeń nazw `std::this_thread`	`sleep_for(`*okres*`)` `sleep_until(`*punkt_w_czasie*`)`	Nie dotyczy
`std::condition_variable` lub `std::condition_variable_any`	`wait_for(`*blokada*`,` *okres*`)` `wait_until(`*blokada*`,` *punkt_w_czasie*`)`	`std::cv_status::timeout` lub `std::cv_status::no_timeout`
	`wait_for(`*blokada*`,` *okres*`,` *predykat*`)` `wait_until(`*blokada*`,` *punkt_w_czasie*`,` *predykat*`)`	`bool` — wartość zwrócona przez *predykat* po obudzeniu wątku.
`std::timed_mutex` lub `std::recursive_timed_mutex`	`try_lock_for(`*okres*`)` `try_lock_until` ↪`(`*punkt_w_czasie*`)`	`bool` — wartość `true`, jeśli udało się uzyskać blokadę; w przeciwnym razie wartość `false`
`std::unique_lock<`*Typ* ↪*ZMożliwościąBlokady* ↪*Czasowej*`>`	`unique_lock` ↪`(`*typ_blokowalny*`,` *okres*`)` `unique_lock(`*typ_blokowalny*`,` *punkt_w_czasie*`)`	Nie dotyczy — funkcja `owns_lock()` wywołana dla nowo skonstruowanego obiektu zwraca wartość `true`, jeśli udało się uzyskać blokadę (w przeciwnym razie zwraca wartość `false`).
	`try_lock_for(`*okres*`)` `try_lock_until` ↪`(`*punkt_w_czasie*`)`	`bool` — wartość `true`, jeśli udało się uzyskać blokadę; w przeciwnym razie wartość `false`
`std::future<`*TypWartości*`>` lub `std::shared_future<` ↪*TypWartości*`>`	`wait_for(`*okres*`)` `wait_until(`*punkt_w_czasie*`)`	Jeśli wyczerpano limit czasu funkcji oczekującej, zwraca wartość `std::future_status::timeout`; jeśli obiekt przyszłości jest gotowy, zwraca wartość `std::future_status::ready`; jeśli przyszłość zawiera odroczoną funkcję, która nie została jeszcze wywołana, zwraca wartość `std::future_status::deferred`.

4.4. Upraszczanie kodu za pomocą technik synchronizowania operacji

Stosowanie mechanizmów synchronizacji, które opisałem w poprzednich podrozdziałach, w roli gotowych elementów składowych umożliwia programiście koncentrowanie się na samych operacjach wymagających synchronizacji, nie na mechanice tej synchronizacji. Mechanizmy synchronizacji pozwalają uprościć kod aplikacji choćby dlatego, że wprowadzają do świata programowania współbieżnego dużo więcej elementów znanych z **programowania funkcyjnego**. Zamiast bezpośrednio współdzielić dane pomiędzy wątkami, każde zadanie może otrzymywać potrzebne dane, a wynik przetwarzania może być przekazywany do wielu innych wątków za pośrednictwem obiektów przyszłości.

4.4.1. Programowanie funkcyjne przy użyciu przyszłości

Termin **programowanie funkcyjne** (ang. *functional programming* — *FP*) odnosi się do stylu programowania, w którym wynik wywołania funkcji zależy wyłącznie od parametrów przekazanych na jej wejściu. Oznacza to, że na wynik funkcji nie ma wpływu zewnętrzny stan. Opisane działanie jest więc zgodne z matematycznym pojęciem funkcji, gdzie każde użycie jednej funkcji z tymi samymi parametrami spowoduje otrzymanie dokładnie takiego samego wyniku. W ten sposób działa wiele matematycznych funkcji biblioteki standardowej języka C++, jak `sin`, `cos` czy `sqrt`, oraz prostych operacji na typach podstawowych, jak `3+3`, `6*9` czy `1.3/4.7`. **Typowa** funkcja nie **modyfikuje** zewnętrznego stanu; skutki wykonywania tej funkcji ograniczają się tylko do zwracanej wartości.

Opisany model programowania ułatwia interpretację kodu, szczególnie jeśli program zawiera elementy przetwarzania współbieżnego, ponieważ wiele problemów związanych z pamięcią współdzieloną (opisanych w rozdziale 3.) w ogóle nie występuje w świecie programowania funkcyjnego. Skoro dane współdzielone nie są modyfikowane, nie mogą wystąpić sytuacje wyścigów, zatem ochrona tych danych za pomocą muteksów jest po prostu niepotrzebna. Właśnie prostota tego modelu powoduje, że takie języki programowania jak Haskell[2], gdzie wszystkie funkcje **domyślnie** spełniają warunek programowania funkcyjnego, zyskują coraz większą popularność wśród programistów systemów współbieżnych. Ponieważ niemal cały kod jest zgodny z zasadami programowania funkcyjnego, nieliczne funkcje, które **modyfikują** współdzielony stan, na tyle wyróżniają się spośród pozostałych elementów, że można bez trudu ocenić ich udział w całej strukturze aplikacji.

Zalety programowania funkcyjnego nie ograniczają się tylko do języków, w których ten model jest domyślnym paradygmatem. Język C++ łączy w sobie wiele paradygmatów, zatem także pisanie programów według zasad programowania funkcyjnego jest możliwe w tym języku. W wersji C++11 programowanie funkcyjne jest jeszcze prostsze niż w standardzie C++98 dzięki wprowadzeniu funkcji lambda (patrz część A.5 dodatku A), integracji funkcji `std::bind` zaczerpniętej z biblioteki Boost i dokumentu TR1 oraz dodaniu automatycznego wnioskowania typów zmiennych (patrz część A.7 dodatku A). Ostatnim elementem, który ułatwia programowanie funkcyjne w języku C++, są obiekty przyszłości — obiekt przyszłości można przekazywać pomiędzy wątkami, tak aby wynik jednej operacji mógł zależeć od wyniku innej operacji i aby ta zależność **nie wymagała bezpośredniego dostępu do współdzielonych danych**.

SZYBKIE SORTOWANIE W MODELU PROGRAMOWANIA FUNKCYJNEGO

Aby lepiej zrozumieć możliwe zastosowania przyszłości w modelu programowania funkcyjnego, przeanalizujmy prostą implementację algorytmu sortowania szybkiego (ang. *quicksort*). Podstawowa koncepcja tego algorytmu jest dość prosta — należy z listy wartości wybrać element dzielący, osiowy (ang. *pivot*), po czym podzielić listę na dwa zbiory, z których jeden zawiera elementy mniejsze od elementu dzielącego, a drugi zawiera elementy większe od wybranego elementu. Posortowana kopia listy jest uzyskiwana poprzez sortowanie obu podzbiorów i połączenie odpowiednio posortowanej listy złożonej z wartości mniejszych od elementu dzielącego, samego elementu dzielącego

---

[2] Patrz *http://www.haskell.org/*.

i posortowanej listy większej od elementu dzielącego. Przykład sortowania listy dziesięciu liczb całkowitych według opisanego schematu pokazano na rysunku 4.2. Na listingu 4.12 pokazano sekwencyjną implementację tego algorytmu opracowaną zgodnie z zasadami programowania funkcyjnego; funkcja `sequential_quick_sort()` otrzymuje listę i zwraca jej posortowaną kopię przez wartość (zamiast sortować listę przekazaną przez referencję, jak w przypadku funkcji `std::sort()`).

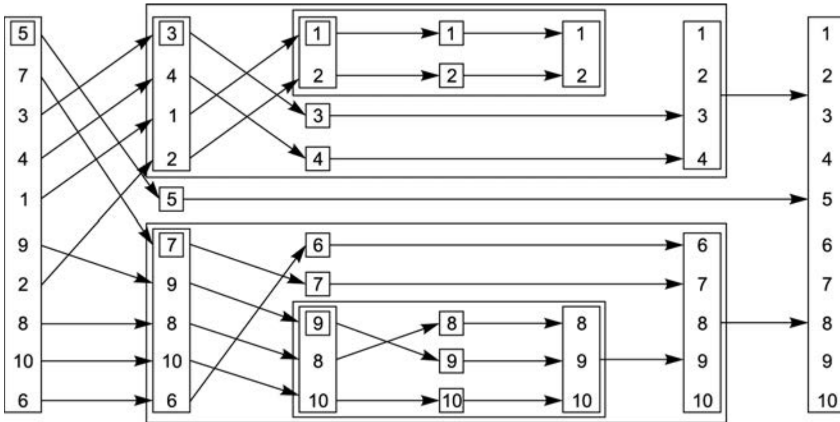

Rysunek 4.2. Rekurencyjne sortowanie w modelu programowania funkcyjnego

Listing 4.12. Sekwencyjna implementacja algorytmu sortowania szybkiego

```
template<typename T>
std::list<T> sequential_quick_sort(std::list<T> input)
{
    if(input.empty())
    {
        return input;
    }
    std::list<T> result;
    result.splice(result.begin(),input,input.begin());    ← ❶
    T const& pivot=*result.begin();    ← ❷

    auto divide_point=std::partition(input.begin(),input.end(),
            [&](T const& t){return t<pivot;});    ← ❸

    std::list<T> lower_part;
    lower_part.splice(lower_part.end(),input,input.begin(),
        divide_point);    ← ❹

    auto new_lower(
        sequential_quick_sort(std::move(lower_part)));    ← ❺
    auto new_higher(
        sequential_quick_sort(std::move(input)));    ← ❻

    result.splice(result.end(),new_higher);    ← ❼
    result.splice(result.begin(),new_lower);    ← ❽
    return result;
}
```

Mimo że zewnętrzny interfejs tej implementacji jest zgodny z regułami programowania funkcyjnego, wewnętrzne mechanizmy zaimplementowano w „tradycyjny" sposób, ponieważ konsekwentne stosowanie modelu funkcyjnego wymagałoby wielu dodatkowych operacji kopiowania. W roli elementu dzielącego jest wybierany pierwszy element, który jest wyodrębniany z listy za pomocą funkcji `splice()` ❶. Chociaż sortowanie na bazie tak wybranego elementu dzielącego może nie być optymalne (liczba operacji porównania i wymiany może być większa, niż to konieczne), pozostałe operacje na strukturze typu `std::list` będą wykonywane szybciej dzięki efektywnemu przeszukiwaniu listy. Wiadomo, że wyodrębniony element dzielący musi się znaleźć na liście wynikowej, zatem jest od razu umieszczany w odpowiedniej strukturze. Ponieważ element dzielący będzie teraz porównywany z pozostałymi elementami, przekazujemy referencję do tego elementu, aby uniknąć wielokrotnego kopiowania ❷. Możemy następnie użyć funkcji `std::partition` do podzielenia sekwencji na wartości **mniejsze** od elementu dzielącego i wartości **nie mniejsze** od tego elementu ❸. Najprostszym sposobem określenia kryterium podziału jest użycie funkcji lambda — aby uniknąć kopiowania wartości elementu dzielącego, zastosowano tutaj technikę przechwytywania referencji (więcej informacji na temat funkcji lambda można znaleźć w części A.5 dodatku A).

Funkcja `std::partition()` przetwarza przekazaną listę i zwraca iterator wskazujący pierwszy element, który **nie** jest mniejszy od wartości elementu dzielącego. Kompletny typ iteratora może być dość długi, zatem w powyższym kodzie użyto mechanizmu automatycznej identyfikacji typów, aby to kompilator automatycznie określił odpowiedni typ (patrz część A.7 dodatku A).

Ponieważ analizowana implementacja udostępnia interfejs zgodny z zasadami programowania funkcyjnego, warunkiem rekurencyjnego posortowania obu „połówek" listy jest utworzenie dwóch odrębnych list. Do tego celu możemy ponownie użyć funkcji `splice()`, aby skopiować wartości z listy wejściowej (do elementu `divide_point`) i umieścić na nowej liście: `lower_part` ❹. Reszta wartości pozostanie na liście wejściowej. Obie listy można następnie posortować za pomocą rekurencyjnych wywołań funkcji `sequential_quick_sort()` ❺ ❻. Użycie funkcji `std::move()` podczas przekazywania list na wejściu rekurencyjnych wywołań pozwala uniknąć kopiowania tych struktur (wyniki obu wywołań są kopiowane automatycznie). I wreszcie możemy ponownie użyć funkcji `splice()` w celu uporządkowania list reprezentujących podzbiory elementów oryginalnej struktury. Wartości z listy `new_higher` trafiają na koniec listy wynikowej ❼ (za element dzielący), natomiast wartości z listy `new_lower` są umieszczane na początku listy ❽ (przed elementem dzielącym).

SZYBKIE SORTOWANIE RÓWNOLEGŁE W MODELU PROGRAMOWANIA FUNKCYJNEGO

Ponieważ już w poprzednim przykładzie zastosowano reguły programowania funkcyjnego, konwersja tego algorytmu na wersję równoległą (korzystającą z obiektów przyszłości) nie jest specjalnie trudna (patrz listing 4.13). Zbiór operacji jest taki sam jak w poprzedniej wersji, tyle że teraz część tych operacji jest wykonywana równolegle. W tej wersji użyto implementacji algorytmu sortowania szybkiego łączącej obiekty przyszłości i model programowania funkcyjnego.

Jedną z najważniejszych różnic dzielących obie wersje jest to, że w wersji współbieżnej część listy sprzed elementu dzielącego nie jest sortowana w bieżącym wątku, tylko w dodatkowym wątku — w tym celu zastosowano funkcję `std::async()` ❶. Druga

Listing 4.13. Równoległe sortowanie szybkie z wykorzystaniem przyszłości

```
template<typename T>
std::list<T> parallel_quick_sort(std::list<T> input)
{
    if(input.empty())
    {
        return input;
    }
    std::list<T> result;
    result.splice(result.begin(),input,input.begin());
    T const& pivot=*result.begin();

    auto divide_point=std::partition(input.begin(),input.end(),
         [&](T const& t){return t<pivot;});

    std::list<T> lower_part;
    lower_part.splice(lower_part.end(),input,input.begin(),
        divide_point);

    std::future<std::list<T> > new_lower(        ←❶
        std::async(&parallel_quick_sort<T>,std::move(lower_part)));

    auto new_higher(
        parallel_quick_sort(std::move(input)));        ←❷

    result.splice(result.end(),new_higher);        ←❸
    result.splice(result.begin(),new_lower.get());        ←❹
    return result;
}
```

część listy jest sortowana tak jak w poprzedniej wersji, a więc przy użyciu bezpośredniego wywołania rekurencyjnego ❷. Rekurencyjne wywołanie funkcji `parallel_quick_sort()` pozwala wykorzystać dostępną współbieżność sprzętową. Jeśli wywołanie funkcji `std::async()` za każdym razem uruchamia nowy wątek, wystarczą trzy poziomy rekurencji, aby program został podzielony na osiem wątków; w przypadku dziesięciu poziomów rekurencji (czyli około tysiąca elementów) program w tej formie uruchomi 1024 wątki (o ile stosowany sprzęt poradzi sobie z taką liczbą). W razie wykrycia zbyt dużej liczby uruchomionych zadań (jeśli na przykład liczba równolegle realizowanych zadań przekroczy dostępną współbieżność sprzętową) biblioteka może przejść w tryb synchronicznego uruchamiania nowych zadań. Zadania będą wykonywane w wątku wywołującym funkcję `get()`, nie w nowym wątku, zatem program uniknie kosztów przekazywania zadania pomiędzy wątkami, jeśli koszty tej operacji nie są rekompensowane przez wzrost wydajności. Jeśli nie przekazano wprost wartości `std::launch::deferred`, uruchamianie nowego wątku dla każdego zadania jest w pełni zgodne z założeniami implementacji `std::async` (nawet jeśli prowadzi do nadsubskrypcji); podobnie jeśli nie przekazano wartości `std::launch::async`, najlepszym rozwiązaniem jest synchroniczne wykonywanie wszystkich zadań. W przypadku stosowania biblioteki oferującej mechanizmy automatycznego skalowania warto sprawdzić w dokumentacji, jak te mechanizmy będą działały w kontekście tego algorytmu.

Zamiast funkcji `std::async()` moglibyśmy użyć własnej funkcji `spawn_task()` w roli prostego opakowania szablonu klasy `std::packaged_task` i klasy `std::thread` (patrz

listing 4.14). W takim przypadku należałoby utworzyć obiekt klasy std::packaged_task dla wyniku wywołania funkcji, odczytać obiekt przyszłości z obiektu zadania, uruchomić zadanie w odpowiednim wątku, po czym zwrócić obiekt przyszłości. Takie rozwiązanie samo w sobie nie przyniosłoby co prawda żadnych korzyści (prowadziłoby raczej do dużej nadsubskrypcji), ale może stanowić punkt wyjścia dla bardziej zaawansowanych implementacji, które będą dodawały zadania do kolejki w celu przetworzenia przez wątki robocze dostępne w puli. Zagadnienia związane z pulami wątków zostaną omówione w rozdziale 9. Wybór tego kierunku (zamiast stosowania funkcji std::async) jest uzasadniony tylko w przypadku programistów, którzy mają pełną świadomość skutków podejmowanych działań i chcą mieć pełną kontrolę nad sposobem budowy puli wątków i wykonywania zadań.

Listing 4.14. Prosta implementacja funkcji spawn_task

```
template<typename F,typename A>
std::future<std::result_of<F(A&&)>::type>
    spawn_task(F&& f,A&& a)
{
    typedef std::result_of<F(A&&)>::type result_type;
    std::packaged_task<result_type(A&&)>
        task(std::move(f)));
    std::future<result_type> res(task.get_future());
    std::thread t(std::move(task),std::move(a));
    t.detach();
    return res;
}
```

Wróćmy teraz do funkcji parallel_quick_sort(). Ponieważ do uzyskania listy new_higher użyliśmy bezpośredniego wywołania rekurencyjnego, możemy użyć funkcji splice() tak jak w algorytmie jednowątkowym ❸. Okazuje się jednak, że zmienna new_lower zawiera obiekt klasy std::future<std::list<T>>, nie listę, zatem przed wywołaniem funkcji splice() musimy wywołać funkcję get(), aby uzyskać odpowiednią wartość ❹. Wywołanie w tej formie czeka na zakończenie zadania wykonywanego w tle, po czym **przenosi** wynik do wywołania funkcji splice(). Funkcja get() zwraca referencję do r-wartości wyniku, zatem lista może zostać przeniesiona (więcej informacji na temat referencji do r-wartości i operacji przenoszenia można znaleźć w części A.1.1 dodatku A).

Nawet jeśli przyjąć, że funkcja std::async() w optymalny sposób wykorzystuje dostępną współbieżność sprzętową, proponowana implementacja równoległego algorytmu sortowania szybkiego wciąż nie jest optymalna. Funkcja std::partition realizuje co prawda znaczną część zadań związanych z działaniem tego algorytmu, ale jej wywołanie ma charakter typowo sekwencyjny. Czytelnicy zainteresowani możliwie najszybszą, równoległą implementacją powinni sięgnąć po odpowiednią literaturę akademicką.

Programowanie funkcyjne nie jest jedynym paradygmatem programowania współbieżnego eliminującym problem współdzielenia zmiennych danych; innym przykładem takiego paradygmatu jest komunikacja procesów sekwencyjnych (ang. *Communicating Sequential Processes — CSP*)[3], gdzie wątki są w założeniu całkowicie niezależne i nie

[3] C.A.R. Hoare, *Communicating Sequential Processes*, Prentice Hall, 1985. Książka jest dostępna za darmo pod adresem *http://www.usingcsp.com/cspbook.pdf*.

operują na współdzielonych danych — zamiast tego wymieniają komunikaty za pośrednictwem kanałów komunikacyjnych. Paradygmat CSP zastosowano w języku programowania Erlang (*http://www.erlang.org/*) oraz w środowisku MPI (od ang. *Message Passing Interface*) stosowanym w systemach implementowanych w językach C i C++, które muszą gwarantować najwyższą wydajność (*http://www.mpi-forum.org/*). Po tym, co już napisałem, jestem pewien, że wiadomość o możliwości implementacji tego paradygmatu także w języku C++ nie będzie dla czytelnika żadnym zaskoczeniem — wystarczy odrobina dyscypliny. Sposób implementacji tego modelu omówię w następnym punkcie.

4.4.2. Synchronizacja operacji za pomocą przesyłania komunikatów

Koncepcja paradygmatu CSP jest prosta — nie istnieją żadne współdzielone dane, a każdy wątek można traktować jako zupełnie niezależny byt. Zachowanie wątku zależy wyłącznie od komunikatów, które do niego trafiają. Każdy wątek jest więc swoistą maszyną stanów, która po otrzymaniu komunikatu aktualizuje swój stan i która może (ale nie musi) wysłać co najmniej jeden komunikat do pozostałych wątków. Sposób przetwarzania komunikatu zależy od stanu początkowego „maszyny". Jednym ze sposobów pisania wątków tego typu jest stworzenie formalnego modelu i implementacja skończonej maszyny stanów, jednak istnieją też lepsze rozwiązania — do wyrażenia maszyny stanów można użyć odpowiedniej struktury aplikacji. To, która metoda sprawdza się lepiej w danym scenariuszu, zależy od szczegółowych wymagań dotyczących zachowań budowanego systemu i od umiejętności zespołu programistów. Jeśli jednak zdecydujemy się na implementację odrębnych wątków, sam podział na niezależne procesy może prowadzić do wyeliminowania wielu komplikacji związanych ze współbieżnym przetwarzaniem danych współdzielonych i tym samym ułatwić programowanie oraz ograniczyć liczbę błędów.

Procesy w pełni zgodne z paradygmatem CSP nie operują na żadnych współdzielonych danych, a cała komunikacja odbywa się za pośrednictwem kolejek komunikatów. Ponieważ jednak wątki języka C++ współdzielą przestrzeń adresową, wymuszenie tego wymagania jest niemożliwe. W tej sytuacji bardzo duże znaczenie ma dyscyplina autorów aplikacji i bibliotek, ponieważ to od nas zależy, czy nasze wątki będą się odwoływać do współdzielonych danych. Same kolejki komunikatów oczywiście muszą być współdzielone (w przeciwnym razie wątki nie mogłyby się komunikować), jednak szczegóły implementacji tych kolejek można opakować w ramach bibliotek.

Wyobraźmy sobie, że implementujemy kod dla bankomatu. Kod tego systemu musi obsługiwać interakcję z użytkownikiem, czyli osobą wypłacającą gotówkę, musi komunikować się z systemem odpowiedniego banku oraz musi sterować fizycznymi urządzeniami odpowiedzialnymi za akceptację karty, wyświetlanie stosownych komunikatów, obsługę klawiatury, wypłatę pieniędzy i zwracanie karty.

Jednym ze sposobów obsługi wszystkich tych zadań jest podzielenie kodu na trzy niezależne wątki: jeden obsługujący fizyczne urządzenia, drugi implementujący logikę samego bankomatu i trzeci odpowiedzialny za komunikację z bankiem. Wątki mogą się komunikować wyłącznie poprzez przekazywanie komunikatów (nie poprzez współdzielenie jakichkolwiek danych). Na przykład wątek obsługujący fizyczne urządzenia mógłby wysłać do wątku logiki bankomatu komunikat o włożeniu karty lub naciśnięciu

przycisku przez użytkownika, natomiast wątek logiki mógłby wysłać do wątku obsługującego fizyczne urządzenia komunikat określający kwotę do wypłacenia.

Jednym ze sposobów modelowania logiki bankomatu jest opracowanie maszyny stanów. W każdym stanie wątek oczekuje na określony komunikat, który jest następnie odpowiednio przetwarzany. W wyniku przetwarzania tego komunikatu wątek może przejść w nowy stan i kontynuować cały cykl. Stany składające się na tę prostą implementację pokazano na rysunku 4.3. W tej uproszczonej implementacji system oczekuje na umieszczenie karty w bankomacie. Po włożeniu karty system czeka, aż użytkownik wpisze kod PIN, naciskając kolejno cyfry tego kodu. Użytkownik może usunąć ostatnią wpisaną cyfrę. Po wpisaniu odpowiedniej liczby cyfr system weryfikuje kod PIN. Jeśli PIN jest nieprawidłowy, cykl działania kończy się — bankomat zwraca kartę i przechodzi w stan oczekiwania na wsunięcie karty przez klienta. Jeśli kod PIN jest prawidłowy, system czeka na anulowanie transakcji albo na wybór kwoty do wypłacenia. W razie anulowania transakcji cykl pracy bankomatu kończy się i urządzenie zwraca kartę. Jeśli klient wybrał kwotę, przed wypłaceniem gotówki system czeka na potwierdzenie ze strony banku, po czym albo wypłaca gotówkę, albo wyświetla komunikat „brak środków" i (niezależnie od wyniku weryfikacji stanu konta) wysuwa kartę. Systemy prawdziwych bankomatów są oczywiście bardziej skomplikowane, jednak opisana powyżej maszyna stanów dobrze ilustruje istotę tego rozwiązania.

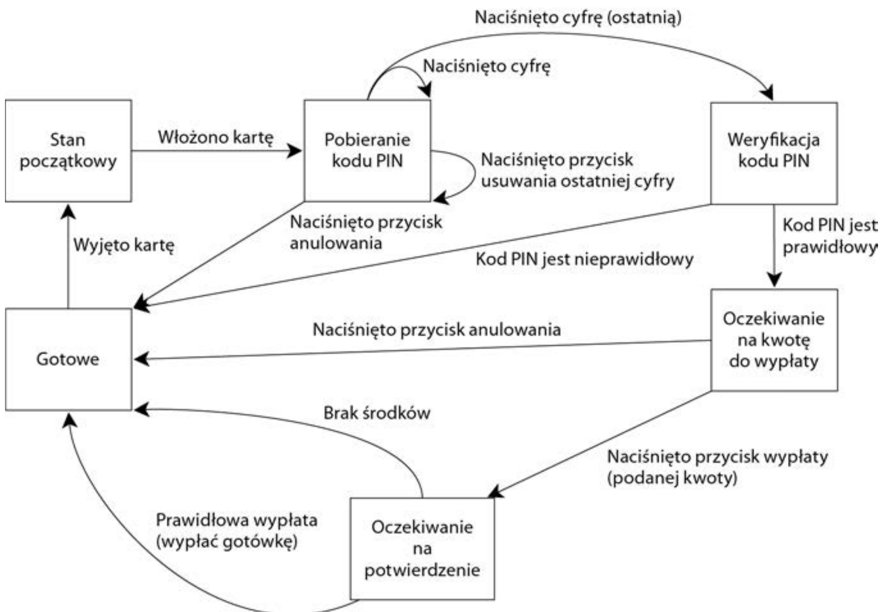

Rysunek 4.3. **Prosty model maszyny stanów dla bankomatu**

Po zaprojektowaniu maszyny stanów dla logiki bankomatu możemy przystąpić do implementacji tego rozwiązania w formie klasy, która będzie definiowała po jednej funkcji składowej dla każdego stanu. Każda funkcja składowa może czekać na określony zbiór komunikatów przychodzących i odpowiednio obsługiwać te komunikaty (obsługa może polegać na przechodzeniu do innego stanu). Każdy typ komunikatów jest reprezentowany

przez odrębną strukturę. Na listingu 4.15 pokazano fragment prostej implementacji logiki takiego systemu, w tym główną pętlę oraz implementację pierwszego stanu, w którym system oczekuje na włożenie karty.

Listing 4.15. Prosta implementacja klasy logiki systemu bankomatu

```
struct card_inserted
{
    std::string account;
};
class atm
{
    messaging::receiver incoming;
    messaging::sender bank;
    messaging::sender interface_hardware;
    void (atm::*state)();

    std::string account;
    std::string pin;

    void waiting_for_card()     ←❶
    {
        interface_hardware.send(display_enter_card());     ←❷
        incoming.wait()     ←❸
            .handle<card_inserted>(
                [&](card_inserted const& msg)     ←❹
                {
                    account=msg.account;
                    pin="";
                    interface_hardware.send(display_enter_pin());
                    state=&atm::getting_pin;
                }
                );
    }
    void getting_pin();
public:
    void run()     ←❺
    {
        state=&atm::waiting_for_card;     ←❻
        try
        {
            for(;;)
            {
                (this->*state)();     ←❼
            }
        }
        catch(messaging::close_queue const&)
        {
        }
    }
};
```

Jak widać, wszystkie niezbędne operacje związane z synchronizacją przekazywania komunikatów zostały ukryte w odpowiedniej bibliotece (implementacja tej biblioteki zostanie pokazana w dodatku C wraz z kompletnym kodem tego przykładu).

Jak już wspomniałem, opisana tutaj implementacja jest mocno uproszczona w stosunku do logiki obowiązującej w prawdziwych bankomatach, jednak przykład w tej formie wystarczy do zrozumienia stylu programowania na bazie przekazywania komunikatów. Nie musimy tracić czasu na projektowanie synchronizacji i rozwiązywanie problemów związanych z przetwarzaniem współbieżnym — wystarczy ustalić, jakie komunikaty mogą być odbierane i przetwarzane na poszczególnych etapach oraz które komunikaty należy wysyłać. Maszyna stanów logiki bankomatu jest przetwarzana przez jeden wątek; pozostałe elementy systemu, jak interfejs łączący się z bankiem czy interfejs terminala, są obsługiwane przez odrębne wątki. Ten styl projektowania oprogramowania określa się mianem **modelu aktorów** — w systemie istnieje wiele odrębnych **aktorów** (każdy działa w osobnym wątku), które wymieniają pomiędzy sobą komunikaty niezbędne do realizacji swoich zadań. W modelu aktorów nie istnieje współdzielony stan (wyjątkiem jest mechanizm potrzebny do bezpośredniego przekazywania komunikatów).

Działanie programu rozpoczyna się od funkcji składowej `run()` ❺, która ustawia stan początkowy, czyli `waiting_for_card` ❻, po czym wielokrotnie wywołuje funkcję składową reprezentującą bieżący stan ❼ (niezależnie od tego, który to stan). Funkcje stanów mają postać prostych funkcji składowych klasy `atm`. Także funkcja stanu `waiting_for_card` ❶ jest dość prosta — jej działanie ogranicza się do wysłania komunikatu do interfejsu w celu wyświetlenia na ekranie tekstu *Czekam na kartę* ❷; zaraz potem funkcja rozpoczyna oczekiwanie na komunikat do obsłużenia ❸. Jedynym rodzajem komunikatów, który może być obsługiwany w tej części kodu, jest komunikat `card_inserted`. Do jego obsługi używamy funkcji lambda ❹. Na wejściu funkcji `handle` można przekazać dowolną funkcję lub dowolny obiekt funkcji, jednak najprostszym rozwiązaniem jest użycie funkcji lambda. Łatwo zauważyć, że wywołanie funkcji `handle()` znalazło się w łańcuchu obejmującym wywołanie funkcji `wait()`, zatem w razie otrzymania komunikatu, który nie pasuje do wskazanego typu, wątek zignoruje ten komunikat i będzie dalej czekał na komunikat właściwego typu.

Sama funkcja lambda zapisuje numer konta w zmiennej składowej, zeruje bieżący kod PIN, wysyła komunikat do sprzętu odpowiedzialnego za obsługę interfejsu bankomatu, aby wyświetlić prośbę o podanie kodu PIN, po czym przechodzi w stan pobierania tego kodu. Po zakończeniu działania przez funkcję obsługującą komunikat funkcja stanu zwraca sterowanie, a główna pętla programu wywołuje funkcję nowego stanu ❼.

Funkcja stanu `getting_pin` jest nieco bardziej skomplikowana, ponieważ może obsługiwać trzy różne typy komunikatów (patrz rysunek 4.3). Kod tej funkcji pokazano na listingu 4.16.

Listing 4.16. Funkcja stanu getting_pin na potrzeby prostej implementacji systemu bankomatu

```
void atm::getting_pin()
{
    incoming.wait()
        .handle<digit_pressed>(        ❶
            [&](digit_pressed const& msg)
            {
                unsigned const pin_length=4;
                pin+=msg.digit;
                if(pin.length()==pin_length)
```

```
                {
                    bank.send(verify_pin(account,pin,incoming));
                    state=&atm::verifying_pin;
                }
            }
            )
        .handle<clear_last_pressed>(      ←❷
            [&](clear_last_pressed const& msg)
            {
                if(!pin.empty())
                {
                    pin.resize(pin.length()-1);
                }
            }
            )
        .handle<cancel_pressed>(      ←❸
            [&](cancel_pressed const& msg)
            {
                state=&atm::done_processing;
            }
            );
}
```

Tym razem funkcja musi przetwarzać trzy różne typy komunikatów, zatem łańcuch wywołania funkcji `wait()` obejmuje aż trzy wywołania funkcji `handle()` ❶ ❷ ❸. Każde wywołanie funkcji `handle()` określa typ komunikatu w formie parametru szablonu, po czym przekazuje funkcję lambda, która otrzymuje na wejściu komunikat określonego typu. Ponieważ wszystkie te wywołania umieszczono w jednym łańcuchu wywołań, implementacja funkcji `wait()` „wie”, że czeka na komunikat `digit_pressed`, `clear_last_pressed` lub `cancel_pressed`. Komunikaty wszystkich innych typów będą (tak jak wcześniej) ignorowane.

W tym przypadku otrzymanie komunikatu nie musi prowadzić do zmiany stanu. Jeśli na przykład wątek otrzyma komunikat `digit_pressed` i jeśli wpisana cyfra nie będzie ostatnią cyfrą kodu, wystarczy tę cyfrę dopisać do łańcucha `pin`. Główna pętla na listingu 4.15 ❼ ponownie wywoła funkcję `getting_pin()`, aby czekać na następną cyfrę (bądź wyzerować kod PIN lub anulować całą operację).

Opisana procedura jest zgodna ze schematem pokazanym na rysunku 4.3. Każdy stan przedstawiony na tym rysunku jest implementowany przez inną funkcję składową, która czeka na odpowiednie komunikaty i na tej podstawie aktualizuje stan systemu.

Jak widać, opisany styl programowania może znacznie uprościć zadanie projektowania systemu współbieżnego, ponieważ każdy wątek można traktować całkowicie niezależnie od pozostałych. W opisanym modelu wiele wątków ma za zadanie oddzielanie zagadnień i jako takie wymagają od projektanta jasnych decyzji o podziale zadań pomiędzy wątki.

4.5. Podsumowanie

Synchronizacja operacji pomiędzy wątkami jest ważnym aspektem pisania aplikacji stosującej techniki przetwarzania współbieżnego — w razie braku synchronizacji wątki działałyby całkowicie niezależnie, zatem równie dobrze mogłyby mieć postać odrębnych aplikacji uruchamianych w formie pewnej grupy (z racji pokrewnych zadań). W tym

rozdziale omówiłem rozmaite sposoby synchronizacji operacji, w tym podstawowe zmienne warunkowe, przyszłości, obietnice i opakowywane zadania. Opisałem też sposoby rozwiązywania problemów związanych z synchronizacją, w szczególności programowanie funkcyjne, gdzie każde zadanie generuje wynik wyłącznie na podstawie danych wejściowych (nie uwzględnia zewnętrznego środowiska), oraz przekazywanie komunikatów, gdzie komunikacja pomiędzy wątkami odbywa się za pośrednictwem asynchronicznych komunikatów (wysyłanych przy użyciu podsystemu przekazywania komunikatów).

Skoro omówiłem już wiele wysokopoziomowych rozwiązań dostępnych w języku C++, czas przyjrzeć się odpowiednim elementom niskopoziomowym, dzięki którym opisane mechanizmy mogą funkcjonować — w następnym rozdziale skoncentrujemy się na modelu pamięci języka C++ i operacjach atomowych.

Skorowidz

A

accumulate_block, 293, 294
add_to_list(), 61
add_to_reclaim_list(), 239
aktywne oczekiwanie, 261
algorytm sortowania szybkiego, 330
analiza kodu, 357
 próba szczegółowego wyjaśnienia komuś, 358
 przeglądanie kodu, 357
 pytania dotyczące przeglądanego kodu, 358
asynchroniczne zadanie, 104

B

bariera, 316
bariery pamięci, *Patrz* ogrodzenia
biblioteki języka C++, 29
 ACE, 29
 Boost, 29
 Boost Thread Library, 30
 C++ Thread Library, 30
 efektywność klas, 30
 mechanizm przyszłości, 103
 okres, 117
 przyszłości unikatowe, 103
 przyszłości współdzielone, 103
 punkt w czasie, 118
 RAII, 29
 standardowa, 31
 typy wywoływalne, 36
 wolne funkcje, 150
 zegar, 115
blokady wirujące, 221
błądzenie, *Patrz* uwięzienie
Boost Thread Library, 30
buffer, 44

C

C++ Thread Library, 30
clear(), 138, 141
compare_exchange_strong(), 140, 144, 236, 248, 263
compare_exchange_weak(), 140, 144, 225, 247

D

data.push(), 188
data_cond.notify_one(), 191
definicja klasy stosu, 68
delete_nodes_with_no_hazards(), 238, 240
detach(), 38, 42
dispatch(), 405
do_something(), 63
do_sort(), 275, 333
done(), 110
Double-Checked Locking, 85
drzewo binarne, 209
dyndający wskaźnik, 226

E

empty(), 64, 102, 188
exchange(), 140, 143

F

fałszywe współdzielenie, 284, 287
fetch_add(), 140, 146, 249
fetch_and(), 147
fetch_or(), 140, 147
fetch_sub(), 146, 176
fetch_xor(), 147
find_entry_for(), 212
find_first_if(), 217
for_each(), 213, 216
frameworki aplikacji, 29
  MFC, 29
free_external_counter(), 260
front(), 98
funkcja lambda, 122
funkcja początkowa, 33
funkcje
  accumulate_block, 293, 294
  add_to_list(), 61
  add_to_reclaim_list(), 239
  clear(), 138, 141
  compare_exchange_strong(), 140, 144, 236, 248, 263
  compare_exchange_weak(), 140, 144, 225, 247
  constexpr, 381
    wymagania, 385
  data.push(), 188
  data_cond.notify_one(), 191
  delete_nodes_with_no_hazards(), 238, 240
  detach(), 38, 42
  dispatch(), 405
  do_something(), 63
  do_sort(), 275, 333
  domyślne, 377
    dokumentacja, 378
    wymuszanie generowania funkcji, 378
    wymuszenie deklarowania konstruktora kopiującego, 378
    wymuszenie generowania destruktora wirtualnego, 378
    zmiana dostępności funkcji, 378
  done(), 110
  empty(), 64, 102, 188
  exchange(), 140, 143
  fetch_add(), 140, 146, 249
  fetch_and(), 147
  fetch_or(), 140, 147
  fetch_sub(), 146, 176
  fetch_xor(), 147
  find_entry_for(), 212
  find_first_if(), 217
  foo<int&>(), 375
  for_each(), 213, 216
  free_external_counter(), 260
  front(), 98
  get(), 125
  get_event(), 301
  get_future(), 106, 114
  get_hazard_pointer_for_current_thread(), 234, 236
  get_id(), 52
  get_lock(), 80
  get_tail(), 200
  getting_pin(), 130
  handle(), 130, 407
  head.get(), 197
  hello(), 33
  interrupt(), 340, 342, 349
  interruptible_wait(), 343, 348
  interruption_point(), 341, 344, 351
  is_lock_free(), 138
  joinable(), 295
  lambda, 386
    wyrażenie lambda, 386
    z konstrukcją rozpoczynającą, 388
  list_contains(), 61
  load(), 140, 143
  lock(), 60, 79, 80, 142
  main(), 33, 36
  memcmp(), 148
  memcpy(), 148
  my_thread, 37
  my_x.do_lengthy_work(), 45
  native_handle(), 32
  nieskładowe, 150
  notify_one(), 96
  now(), 116
  open_connection(), 87
  parallel_accumulate(), 291, 296, 329
  parallel_quick_sort(), 126, 275
  początkowa, 33
  pop(), 64, 188, 226, 228, 235, 245, 247, 254, 257, 261
  pop_head(), 205
  pop_task_from_other_thread_queue(), 339
  process(), 82, 301

process_connections(), 110
process_data(), 81
push(), 64, 100, 191, 197, 201, 225, 229, 247, 254, 255, 261, 337
push_front(), 216
reclaim_later(), 236, 238, 239
remove_if(), 217
run(), 130
run_pending_task(), 331, 335
send_data(), 87
sequential_quick_sort(), 124
set(), 343
set_condition_variable(), 344
set_exception(), 111
set_new_tail(), 264
share(), 114
size(), 64
sleep_for(), 120
sleep_until(), 120
some_function, 47
spawn_task(), 125
splice(), 124
square_root(), 111
std::accumulate, 49
std::async(), 104, 125, 273, 281, 297
std::atomic_compare_exchange_strong, 469
std::atomic_compare_exchange_strong_explicit, 469
std::atomic_compare_exchange_weak, 470
std::atomic_compare_exchange_weak_explicit, 471
std::atomic_exchange, 467
std::atomic_exchange_explicit, 467
std::atomic_fetch_add, 476, 486
std::atomic_fetch_add_explicit, 476, 486
std::atomic_fetch_and, 478
std::atomic_fetch_and_explicit, 479
std::atomic_fetch_or, 479
std::atomic_fetch_or_explicit, 480
std::atomic_fetch_sub, 477, 487
std::atomic_fetch_sub_explicit, 478, 487
std::atomic_fetch_xor, 480
std::atomic_fetch_xor_explicit, 481
std::atomic_flag_clear, 459
std::atomic_flag_clear_explicit, 460
std::atomic_flag_test_and_set, 459
std::atomic_flag_test_and_set_explicit, 459
std::atomic_flag::clear, 459
std::atomic_flag::test_and_set, 458
std::atomic_init, 463
std::atomic_is_lock_free, 464
std::atomic_load, 465
std::atomic_load_explicit, 465
std::atomic_signal_fence(), 457
std::atomic_store, 466
std::atomic_store_explicit, 466
std::atomic_thread_fence(), 456
std::atomic<t*>::fetch_add, 486
std::atomic<t*>::fetch_sub, 487
std::atomic<typ-całkowitoliczbowy>::fetch_add, 476
std::atomic<typ-całkowitoliczbowy>::fetch_and, 478
std::atomic<typ-całkowitoliczbowy>::fetch_or, 479
std::atomic<typ-całkowitoliczbowy>::fetch_sub, 477
std::atomic<typ-całkowitoliczbowy>::fetch_xor, 480
std::atomic::compare_exchange_strong, 468
std::atomic::compare_exchange_weak, 469
std::atomic::exchange, 467
std::atomic::is_lock_free, 464
std::atomic::load, 464
std::atomic::store, 466
std::bind(), 45, 333
std::call_once, 86
std::chrono::duration_cast, 428
std::chrono::duration::count, 423
std::chrono::duration::max, 426
std::chrono::duration::min, 426
std::chrono::duration::zero, 425
std::chrono::steady_clock::now, 434
std::chrono::system_clock::from_time_t, 433
std::chrono::system_clock::now, 432
std::chrono::system_clock::to_time_t, 433
std::chrono::time_point::max, 431
std::chrono::time_point::min, 431
std::chrono::time_point::time_since_epoch, 430
std::condition_variable_any::notify_all, 446
std::condition_variable_any::notify_one, 446
std::condition_variable_any::wait, 447
std::condition_variable_any::wait_for, 448
std::condition_variable_any::wait_until, 450
std::condition_variable::notify_all, 437
std::condition_variable::notify_one, 437
std::condition_variable::wait, 344, 438
std::condition_variable::wait_for, 439
std::condition_variable::wait_until, 441
std::copy_exception(), 112
std::current_exception(), 112
std::find, 306

funkcje
- std::for_each, 51, 304
- std::future::get, 494
- std::future::share, 492
- std::future::valid, 492
- std::future::wait, 493
- std::future::wait_for, 493
- std::future::wait_until, 494
- std::kill_dependency(), 174
- std::lock(), 72
- std::move(), 46, 124, 329, 333
- std::mutex::lock, 516
- std::mutex::try_lock, 516
- std::mutex::unlock, 517
- std::notify_all_at_thread_exit, 443
- std::packaged_task::get_future, 504
- std::packaged_task::make_ready_at_thread_exit, 506
- std::packaged_task::reset, 505
- std::packaged_task::swap, 504
- std::packaged_task::valid, 505
- std::partial_sum, 312
- std::partition(), 124
- std::promise::get_future, 510
- std::promise::set_exception, 512
- std::promise::set_exception_at_thread_exit, 512
- std::promise::set_value, 510
- std::promise::set_value_at_thread_exit, 511
- std::promise::swap, 509
- std::recursive_mutex::lock, 519
- std::recursive_mutex::try_lock, 519
- std::recursive_mutex::unlock, 519
- std::recursive_timed_mutex::lock, 526
- std::recursive_timed_mutex::try_lock, 526
- std::recursive_timed_mutex::try_lock_for, 526
- std::recursive_timed_mutex::try_lock_until, 527
- std::recursive_timed_mutex::unlock, 528
- std::ref, 45
- std::shared_future::get, 500
- std::shared_future::valid, 498
- std::shared_future::wait, 498
- std::shared_future::wait_for, 499
- std::shared_future::wait_until, 499
- std::terminate(), 37, 349
- std::this_thread::get_id, 52, 558
- std::this_thread::sleep_for, 559
- std::this_thread::sleep_until, 559
- std::this_thread::yield, 559
- std::thread::detach, 557
- std::thread::get_id, 558
- std::thread::hardware_concurrency, 49, 273, 276, 280, 324, 558
- std::thread::join, 557
- std::thread::joinable, 556
- std::thread::native_handle, 553
- std::thread::swap, 556
- std::timed_mutex::lock, 521
- std::timed_mutex::try_lock, 522
- std::timed_mutex::try_lock_for, 522
- std::timed_mutex::try_lock_until, 523
- std::timed_mutex::unlock, 524
- std::unique_lock::lock, 536
- std::unique_lock::mutex, 539
- std::unique_lock::operator, 539
- std::unique_lock::owns_lock, 539
- std::unique_lock::release, 539
- std::unique_lock::swap, 535, 536
- std::unique_lock::try_lock, 536
- std::unique_lock::try_lock_for, 537
- std::unique_lock::try_lock_until, 538
- std::unique_lock::unlock, 537
- store(), 140, 143, 177
- submit(), 326, 329, 335
- swap(), 64
- test_and_set(), 138, 141
- thread_a(), 76
- thread_b(), 76
- time_since_epoch(), 118
- top(), 64
- try_lock(), 76, 80
- try_lock_for(), 120
- try_lock_until(), 120
- try_pop(), 98, 191, 197, 200, 202, 337
- try_reclaim(), 230
- try_steal(), 337
- trywialne, 379
- unlock(), 60, 80, 348
- update_data_for_widget, 44
- wait(), 96, 102, 318, 344, 348, 403
- wait_and_dispatch(), 405, 407
- wait_and_pop(), 98, 191, 202, 204
- wait_for(), 115, 120, 344
- wait_for_data(), 205
- wait_until(), 115
- worker_thread(), 326, 335
- zegar::now(), 116

G

- get(), 125
- get_event(), 301
- get_future(), 106, 114
- get_hazard_pointer_for_current_thread(), 234, 236
- get_id(), 52
- get_lock(), 80
- get_tail(), 200
- getting_pin(), 130

H

- handle(), 130, 407
- head.get(), 197
- hello(), 33

I

- identyfikowanie wątków, 52
  - identyfikatory wątków, 52
- interrupt(), 340, 342, 349
- interruptible_wait(), 343, 348
- interruption_point(), 341, 344, 351
- is_lock_free(), 138
- iteratory jednokrotnego przebiegu, 52
- iteratory postępujące, 52

J

- język C++, 19
  - automatyczne określanie typu zmiennej, 395
  - biblioteka operacji atomowych, 31
  - biblioteka standardowa, 31
  - biblioteka wątków, 30
  - biblioteki, 29
  - efektywność klas, 30
  - frameworki aplikacji, 29
  - mechanizm deklarowania funkcji jako usuniętej, 376
  - mechanizm przyszłości, 103
  - miejsce w pamięci, 134
  - model pamięci, 133
  - muteks, 60
  - obiekty, 134
  - obsługa współbieżności, 28, 30
  - operacje atomowe, 137
  - porządek modyfikacji, 136
  - RAII, 29
  - referencje do r-wartości, 371
    - semantyka przenoszenia danych, 372
  - szablony zmiennoargumentowe, 391
    - paczka parametrów, 392
    - rozwinięcie paczki, 392
  - typy definiowane przez użytkownika, 382
    - inicjalizacja statyczna, 384
  - warstwy abstrakcji, 30
  - wyrażenia stałe, 381
    - zastosowania, 381
  - wyrażenie lambda, 37
  - wyścig danych, 58
  - zmienne lokalne wątków, 396
- join(), 39
- joinable(), 295

K

- klasy
  - dispatcher, 404
  - receiver, 403
  - scoped_thread, 48
  - sender, 402
  - std::thread, 36
  - std::atomic_flag, 457
  - std::chrono::high_resolution_clock, 116
  - std::chrono::steady_clock, 116, 433
  - std::chrono::system_clock, 116, 431
  - std::condition_variable, 95, 436
  - std::condition_variable_any, 95, 444
  - std::future<>, 103
  - std::mutex, 60, 515
  - std::once_flag, 541
  - std::recursive_mutex, 90, 517
  - std::recursive_timed_mutex, 524
  - std::shared_future<>, 103
  - std::thread, 549
  - std::thread::id, 550
  - std::timed_mutex, 520
  - thread_guard, 48
  - thread_pool, 331
- komunikacja procesów sekwencyjnych, 126, 127
  - maszyna stanów, 127, 128
  - model aktorów, 130
  - model maszyny stanów, 128
- konstruktor domyślny, 52
- konstruktor przenoszący, 45
- kontenery
  - std::map<>, 207
  - std::multimap<>, 207
  - std::queue<>, 97
  - std::stack, 64, 66
  - std::unordered_map<>, 207
  - std::unordered_multimap<>, 207

L

leniwa inicjalizacja, 85
linie pamięci podręcznej, 284
list_contains(), 61
load(), 140, 143
lock(), 60, 79, 80, 142
l-wartość, 80

M

main(), 33, 36
mechanizm przyszłości, 52, 102, 103
 asynchroniczne zadanie, 104
 obietnice, 109
 oczekiwanie na wiele wątków, 112
 przyszłości unikatowe, 103
 przyszłości współdzielone, 103
 wiązanie zadania z przyszłością, 106
 wynik obliczeń wykonywanych w tle, 103
 wyścig danych, 112
 zapisywanie wyjątku, 111
memcmp(), 148
memcpy(), 148
model aktorów, 130
model pamięci języka C++, 133
 analiza podstawowych cech strukturalnych, 134
 mechanizmy przetwarzania współbieżnego, 134
 miejsce w pamięci, 134
 modele porządkowania spójnego niesekwencyjnie, 159
 niezdefiniowane zachowanie, 136
 obiekty, 134
 ogrodzenia, 178
 operacje atomowe, 136
 podział struktury, 135
 porządek modyfikacji, 136
 porządkowania pamięci, 155
 porządkowanie poprzez wzajemne wykluczanie, 155, 166
  operacje uzyskiwania, 166
  operacje zwalniania, 166
 porządkowanie spójne sekwencyjnie, 155, 156
 porządkowanie złagodzone, 155, 160
  wyjaśnienie porządkowania, 164
 relacja poprzedzania, 152, 154
  poprzedzanie według zależności, 173
  przechodniość, 170
  relacja wprowadzania zależności, 173
 relacja synchronizacji, 152
  sekwencja zwalniania, 175
 wyścig danych, 136
muteks, 59, 60, 220
 blokowanie, 60
 blokowanie rekurencyjne, 90
 czytelników-pisarzy, 88
 elastyczne blokowanie, 79
 hierarchiczny, 77
 l-wartość, 80
 niezdefiniowane zachowanie, 90
 ochrona listy, 61
 odblokowywanie, 60
 przenoszenie własności, 80
 rekurencyjny, 90
 r-wartość, 80
 stosowanie w języku C++, 60
 szczegółowość blokady, 82
 wirujący, 142
 zakleszczenie, 71
my_thread, 37
my_thread.detach(), 39
my_thread.join(), 39
my_x.do_lengthy_work(), 45

N

nadsubskrypcja, 51, 280, 285
native_handle(), 32
niezdefiniowane zachowanie, 58, 86, 90, 136
niezmienniki, 56, 355
niskie współzawodnictwo, 282
notify_one(), 96
now(), 116

O

obiekty przyszłości, 122
ochrona współdzielonych danych, 56
 blokowanie rekurencyjne, 90
 definicja klasy kolejki, 100, 190
 definicja klasy stosu, 68, 187
 Double-Checked Locking, 85
 elastyczne blokowanie muteksu, 79
 hierarchia blokad, 75
 implementacja listy z obsługą iteracji, 214
 implementacja tablicy wyszukiwania, 210
 jednowątkowa implementacja kolejki, 195
 kolejka z mechanizmami blokowania i oczekiwania, 203
 kolejka ze szczegółowymi blokadami, 198

kolejka ze sztucznym węzłem, 196
leniwa inicjalizacja, 85
lista jednokierunkowa, 194
metody zapewniania bezpieczeństwa, 185
muteks, 59, 60
muteks czytelników-pisarzy, 88
niezdefiniowane zachowanie, 58
niezmienniki, 56
ochrona listy, 61
pamięć transakcyjna, 59
programowanie bez blokad, 59
przekazywanie referencji, 66
przenoszenie własności muteksu, 80
stosowanie konstruktora, 67
struktury danych bez blokad, 220
sytuacja wyścigu, 58
szczegółowość blokady, 82
szeregowanie, 185
tablica wyszukiwania, 207
unikanie zakleszczeń, 71
wykrywanie sytuacji wyścigu, 63
zakleszczenie, 71
zwracanie wskaźnika, 67
ogrodzenia, 178
open_connection(), 87
operacje atomowe, 136, 137
funkcje nieskładowe, 150
główny szablon, 147
modele porządkowania spójnego niesekwencyjnie, 159
ogrodzenia, 178
operacje dostępne dla typów atomowych, 149
operacje ładowania (odczytu), 140, 143
operacje odczyt-modyfikacja-zapis, 140, 141, 143,
operacje porównania-wymiany, 144
operacje wymiany i dodania, 146
operacje zapisu, 140, 141, 143
porównywanie bitowe, 148
porządkowanie pamięci, 155
porządkowanie poprzez wzajemne wykluczanie, 155, 166
operacje uzyskiwania, 166
operacje zwalniania, 166
porządkowanie spójne sekwencyjnie, 155, 156
porządkowanie złagodzone, 155, 160
wyjaśnienie porządkowania, 164
pozorny błąd, 144
relacja poprzedzania, 152, 154
poprzedzanie według zależności, 173
przechodniość, 170
relacja wprowadzania zależności, 173
relacja synchronizacji, 152
sekwencja zwalniania, 175
rozkazy porównywania i wymiany podwójnego słowa, 149
sekwencja zwalniania zasobów, 147
standardowe definicje typów atomowych, 139
standardowe typy atomowe, 138
stos bez blokad, 250
tworzenie typów niestandardowych, 147
wolne funkcje, 150
operator przypisania z przenoszeniem, 45

P

pamięć transakcyjna, 59
paradygmat CSP, *Patrz* komunikacja procesów sekwencyjnych
parallel_accumulate(), 291, 296, 329
parallel_quick_sort(), 126, 275
ping-pong buforów, 282
podział zagadnień, 25
pop(), 64, 188, 226, 228, 235, 245, 247, 254, 257, 261
pop_head(), 205
pop_task_from_other_thread_queue(), 339
porównywanie bitowe, 148
potok, 278
pozorne budzenie, 97
prawo Amdahla, 299
problem ABA, 266
process(), 82, 301
process_connections(), 110
process_data(), 81
procesy demonów, 42
programowanie bez blokad, 59
programowanie funkcyjne, 122
algorytm sortowania szybkiego, 122
funkcja lambda, 122
obiekty przyszłości, 122
rekurencyjne sortowanie, 123
równoległe sortowanie szybkie, 125
wnioskowanie typów zmiennych, 122
projektowanie uniwersalnej kolejki, 97
projektowanie współbieżnego kodu, 269
bezpieczeństwo wyjątków, 291, 293, 297
algorytmy równoległe, 291
czynniki wpływające na wydajność kodu, 279
fałszywe współdzielenie, 284
liczba procesorów, 280
nadsubskrypcja, 280, 285
niskie współzawodnictwo, 282

projektowanie współbieżnego kodu
ping–pong buforów, 282
przełączanie zadań, 285
współzawodnictwo o dane, 281
wybór najlepszego algorytmu, 281
wysokie współzawodnictwo, 282
zmiana elementu danych, 280
fałszywe współdzielenie, 287
łatwość testowania, 361
eliminacja współbieżności, 362
warunki struktury kodu, 361
mnożenie macierzy, 287
podział elementów tablicy, 287
potok, 278
praktyka, 303
bariera, 316
implementacja równoległego algorytmu wyszukiwania, 307
równoległa implementacja funkcji partial_sum, 319
równoległa wersja funkcji std::for_each, 304
równoległe obliczanie sum częściowych, 313
prawo Amdahla, 299
pula wątków, 276
sąsiedztwo danych, 287
skalowalność, 291, 298
techniki dzielenia pracy pomiędzy wątki, 270
dzielenie przed rozpoczęciem przetwarzania, 271
dzielenie sekwencji zadań, 278
dzielenie według typu zadania, 276
podział sąsiadujących fragmentów danych, 272
rekurencyjne dzielenie danych, 272, 273
równoległy algorytm sortowania szybkiego, 273
sposób izolowania zagadnień, 277
techniki przetwarzania równoległego, 301
ukrywanie opóźnień, 300
współzawodnictwo, 286
wzorce dostępu do danych, 289
przekazywanie argumentów do funkcji wątku, 43
konstruktor przenoszący, 45
kopiowane, 43
operator przypisania z przenoszeniem, 45
przenoszenie, 45
przełączanie kontekstu, 21
przełączanie zadań, 21, 22
przenoszenie własności wątku, 46, 47
przetwarzanie współbieżne, 29
bezpieczeństwo, 184
definicja klasy kolejki, 190
definicja klasy stosu, 68
implementacja listy z obsługą iteracji, 214
implementacja tablicy wyszukiwania, 210
kolejka z mechanizmami blokowania i oczekiwania, 203
kolejka ze szczegółowymi blokadami, 198
mechanizmy przyszłości, 102
międzywątkowa relacja poprzedzania, 155
niechciane blokowanie, 354
oczekiwanie na zewnętrzne dane wejściowe, 355
uwięzienie, 354
zakleszczenie, 354
oczekiwanie na zdarzenie, 94
stos bez blokad, 227, 250
synchronizacja operacji, 93
sytuacje wyścigu, 355
naruszone niezmienniki, 355
problemy związane z czasem życia, 356
wyścig danych, 355
tablica mieszająca, 209
tablica wyszukiwania, 207
techniki lokalizacji błędów, 357
analiza kodu, 357
próba szczegółowego wyjaśnienia komuś, 358
pytania dotyczące przeglądanego kodu, 358
testowanie współbieżnego kodu, 359
współdzielenie danych przez wątki, 55
wywołanie blokujące z limitem czasowym, 115
zarządzanie wątkami, 36
identyfikowanie wątków, 52
mechanizm przyszłości, 52
oczekiwanie na zakończenie wątku, 39
oczekiwanie w razie wystąpienia wyjątku, 39
odłączenie wątku, 41
przekazywanie argumentów do funkcji wątku, 43
przenoszenie własności wątku, 46
uruchamianie wątków w tle, 42
uruchamianie wątku, 36
wątki demonów, 42
wybór liczby wątków, 49
zmienna warunkowa, 95
pula wątków, 106, 276, 324
wiązanie zadania z przyszłością, 106
push(), 64, 100, 191, 197, 201, 225, 229, 247, 254, 255, 261, 337
push_front(), 216

R

RAII, 29
reclaim_later(), 236, 238, 239
referencje do r-wartości, 371
semantyka przenoszenia danych, 372
konstruktor kopiujący, 374
konstruktor przenoszący, 374
relacja poprzedzania, 154
poprzedzanie według zależności, 173
przechodniość, 170
relacja wprowadzania zależności, 173
relacja synchronizacji, 152
sekwencja zwalniania, 175
remove_if(), 217
Resource Acquisition Is Initialization, *Patrz* RAII
RIAA, 40
rozkazy porównywania i wymiany podwójnego słowa, 149
równoległość, *Patrz* zrównoleglanie zadań
równoległość danych, 26
run(), 130
run_pending_task(), 331, 335
r-wartość, 80

S

sąsiedztwo danych, 287
scoped_thread, 48
sekwencja zwalniania, 175
send_data(), 87
sequential_quick_sort(), 124
set(), 343
set_condition_variable(), 344
set_exception(), 111
set_new_tail(), 264
share(), 114
size(), 64
skalowalność, 298, 369
sleep_for(), 120
sleep_until(), 120
some_function, 47
spawn_task(), 125
splice(), 124
square_root(), 111
std::accumulate, 49
std::async, 104, 125, 273, 281, 297, 513
std::atomic, 138, 140, 147, 460
std::atomic_compare_exchange_strong, 469
std::atomic_compare_exchange_strong_explicit, 469
std::atomic_compare_exchange_weak, 470
std::atomic_compare_exchange_weak_explicit, 471
std::atomic_exchange, 467
std::atomic_exchange_explicit, 467
std::atomic_fetch_add, 476, 486
std::atomic_fetch_add_explicit, 476, 486
std::atomic_fetch_and, 478
std::atomic_fetch_and_explicit, 479
std::atomic_fetch_or, 479
std::atomic_fetch_or_explicit, 480
std::atomic_fetch_sub, 477, 487
std::atomic_fetch_sub_explicit, 478, 487
std::atomic_fetch_xor, 480
std::atomic_fetch_xor_explicit, 481
std::atomic_flag, 138, 141, 457
std::atomic_flag_clear, 459
std::atomic_flag_clear_explicit, 460
std::atomic_flag_test_and_set, 459
std::atomic_flag_test_and_set_explicit, 459
std::atomic_flag::clear, 459
std::atomic_flag::test_and_set, 458
std::atomic_init, 463
std::atomic_is_lock_free, 464
std::atomic_load, 465
std::atomic_load_explicit, 465
std::atomic_signal_fence(), 457
std::atomic_store, 466
std::atomic_store_explicit, 466
std::atomic_thread_fence(), 456
std::atomic<bool>, 143
std::atomic<int>, 147
std::atomic<T*>, 146
std::atomic<t*>::fetch_add, 486
std::atomic<t*>::fetch_sub, 487
std::atomic<typ-całkowitoliczbowy>::fetch_add, 476
std::atomic<typ-całkowitoliczbowy>::fetch_and, 478
std::atomic<typ-całkowitoliczbowy>::fetch_or, 479
std::atomic<typ-całkowitoliczbowy>::fetch_sub, 477
std::atomic<typ-całkowitoliczbowy>::fetch_xor, 480
std::atomic<unsigned long long>, 147
std::atomic::compare_exchange_strong, 468
std::atomic::compare_exchange_weak, 469
std::atomic::exchange, 467
std::atomic::is_lock_free, 464
std::atomic::load, 464
std::atomic::store, 466

std::bind, 45, 333
std::call_once, 86, 542
std::chrono::duration, 117, 420
std::chrono::duration_cast, 428
std::chrono::duration::count, 423
std::chrono::duration::max, 426
std::chrono::duration::min, 426
std::chrono::duration::zero, 425
std::chrono::high_resolution_clock, 116
std::chrono::steady_clock, 116, 433
std::chrono::steady_clock::now, 434
std::chrono::system_clock, 116, 431
std::chrono::system_clock::from_time_t, 433
std::chrono::system_clock::now, 432
std::chrono::system_clock::to_time_t, 433
std::chrono::time_point, 118, 429
std::chrono::time_point::max, 431
std::chrono::time_point::min, 431
std::chrono::time_point::time_since_epoch, 430
std::condition_variable, 95, 436
std::condition_variable_any, 95, 444
std::condition_variable_any::notify_all, 446
std::condition_variable_any::notify_one, 446
std::condition_variable_any::wait, 447
std::condition_variable_any::wait_for, 448
std::condition_variable_any::wait_until, 450
std::condition_variable::notify_all, 437
std::condition_variable::notify_one, 437
std::condition_variable::wait, 344, 438
std::condition_variable::wait_for, 439
std::condition_variable::wait_until, 441
std::copy_exception(), 112
std::current_exception(), 112
std::find, 306
std::for_each, 51, 304
std::future, 103, 106, 109, 112, 490
std::future::get, 494
std::future::share, 492
std::future::valid, 492
std::future::wait, 493
std::future::wait_for, 493
std::future::wait_until, 494
std::kill_dependency(), 174
std::lock, 72, 540
std::lock_guard, 60, 528
std::map<>, 207
std::move(), 46, 124, 329, 333
std::multimap<>, 207
std::mutex, 60, 515
std::mutex::lock, 516
std::mutex::try_lock, 516
std::mutex::unlock, 517
std::notify_all_at_thread_exit, 443
std::once_flag, 86, 541
std::packaged_task, 106, 391, 501
std::packaged_task::get_future, 504
std::packaged_task::make_ready_at_thread_exit, 506
std::packaged_task::reset, 505
std::packaged_task::swap, 504
std::packaged_task::valid, 505
std::partial_sum, 312
std::partition(), 124
std::promise, 109, 507
std::promise::get_future, 510
std::promise::set_exception, 512
std::promise::set_exception_at_thread_exit, 512
std::promise::set_value, 510
std::promise::set_value_at_thread_exit, 511
std::promise::swap, 509
std::queue<>, 97
std::ratio, 421, 544
std::ratio_equal, 546
std::ratio_greater, 548
std::ratio_greater_equal, 548
std::ratio_less, 547
std::ratio_less_equal, 548
std::ratio_not_equal, 547
std::recursive_mutex, 90, 517
std::recursive_mutex::lock, 519
std::recursive_mutex::try_lock, 519
std::recursive_mutex::unlock, 519
std::recursive_timed_mutex, 524
std::recursive_timed_mutex::lock, 526
std::recursive_timed_mutex::try_lock, 526
std::recursive_timed_mutex::try_lock_for, 526
std::recursive_timed_mutex::try_lock_until, 527
std::recursive_timed_mutex::unlock, 528
std::ref, 45
std::shared_future, 103, 113, 495
std::shared_future::get, 500
std::shared_future::valid, 498
std::shared_future::wait, 498
std::shared_future::wait_for, 499
std::shared_future::wait_until, 499
std::stack, 64, 66
std::string, 44
std::terminate(), 37, 349
std::this_thread::get_id, 52, 558
std::this_thread::sleep_for, 120, 559
std::this_thread::sleep_until, 120, 559
std::this_thread::yield, 559

std::thread, 43, 549
std::thread::detach, 557
std::thread::get_id, 558
std::thread::hardware_concurrency, 49, 273, 276, 280, 324, 558
std::thread::id, 550
std::thread::join, 557
std::thread::joinable, 556
std::thread::native_handle, 553
std::thread::swap, 556
std::timed_mutex, 520
std::timed_mutex::lock, 521
std::timed_mutex::try_lock, 522
std::timed_mutex::try_lock_for, 522
std::timed_mutex::try_lock_until, 523
std::timed_mutex::unlock, 524
std::try_lock, 541
std::unique_lock, 79, 80, 530
std::unique_lock::lock, 536
std::unique_lock::mutex, 539
std::unique_lock::operator, 539
std::unique_lock::owns_lock, 539
std::unique_lock::release, 539
std::unique_lock::swap, 535, 536
std::unique_lock::try_lock, 536
std::unique_lock::try_lock_for, 537
std::unique_lock::try_lock_until, 538
std::unique_lock::unlock, 537
std::unordered_map<>, 207
std::unordered_multimap<>, 207
store(), 140, 143, 177
submit(), 326, 329, 335
swap(), 64
synchronizacja współbieżnych operacji, 93
definicja klasy kolejki, 100
funkcje otrzymujące limity czasowe, 121
komunikacja procesów sekwencyjnych, 126
mechanizmy przyszłości, 102
obietnice, 109
oczekiwanie na wiele wątków, 112
oczekiwanie na zdarzenie, 94
operacje atomowe, 137
porządek modyfikacji, 136
pozorne budzenie, 97
programowanie funkcyjne, 122
projektowanie uniwersalnej kolejki, 97
prosta kolejka komunikatów, 401
przekazywanie zadań pomiędzy wątkami, 107
upraszczanie kodu, 121
wiązanie zadania z przyszłością, 106
wynik obliczeń wykonywanych w tle, 103
wyścig danych, 112
wywołanie blokujące z limitem czasowym, 115
zapisywanie wyjątku na potrzeby przyszłości, 111
zmienna warunkowa, 95
sytuacja wyścigu, 58, 355
definicja klasy stosu, 68
przekazywanie referencji, 66
stosowanie konstruktora, 67
zwracanie wskaźnika, 67
szablon klasy
std::atomic, 138, 140, 147, 460
std::chrono::duration, 117, 420
std::chrono::time_point, 118, 429
std::future, 103, 109, 112, 490
std::lock_guard, 60, 528
std::packaged_task, 106, 391, 501
std::promise, 109, 507
std::ratio, 421, 544
std::ratio_equal, 546
std::ratio_greater, 548
std::ratio_greater_equal, 548
std::ratio_less, 547
std::ratio_less_equal, 548
std::ratio_not_equal, 547
std::shared_future, 103, 113, 495
std::unique_lock, 79, 80, 530
TemplateDispatcher, 405
szczegółowość blokady, 82
szeregowanie, 185

T

tablica mieszająca, 209
kubełek, 209
tablica posortowana, 209
tablica wyszukiwania, 207
operacje, 208
test_and_set(), 138, 141
testowanie współbieżnego kodu, 360
biblioteka podstawowych mechanizmów, 365
czynniki dotyczące środowiska testowego, 361
projektowanie struktury wielowątkowego kodu testowego, 366
identyfikacja odrębnych fragmentów poszczególnych testów, 366
przykład testu dla struktury kolejki, 367
scenariusze testowania kolejki, 360
testowanie symulowanych kombinacji, 364
wady, 365

testowanie współbieżnego kodu
testowanie wydajności, 369
skalowalność, 369
testy siłowe, 363
wady, 364
thread_a(), 76
thread_b(), 76
thread_guard, 48
thread_pool, 331
time_since_epoch(), 118
top(), 64
try_lock(), 76, 80
try_lock_for(), 120
try_lock_until(), 120
try_pop(), 98, 191, 197, 200, 202, 337
try_reclaim(), 230
try_steal(), 337
try-catch, 40
typy wywoływalne, 36

U

unlock(), 60, 80, 348
update_data_for_widget, 44
uwięzienie, 223, 354

V

void(), 106

W

wait(), 96, 102, 318, 344, 348, 403
wait_and_dispatch(), 405, 407
wait_and_pop(), 98, 191, 202, 204
wait_for(), 115, 120, 344
wait_for_data(), 205
wait_until(), 115
warstwy abstrakcji, 30
wątki demonów, 42
wątki sprzętowe, 21
wnioskowanie typów zmiennych, 122
worker_thread(), 326, 335
wskaźniki ryzyka, 233
współbieżne struktury danych, 184
aktywne oczekiwanie, 261
algorytmy blokujące, 220
bezpieczeństwo przetwarzania wielowątkowego, 184
blokady wirujące, 221
definicja klasy kolejki, 190
definicja klasy stosu, 187
drzewo binarne, 209
implementacja listy z obsługą iteracji, 214
implementacja tablicy wyszukiwania, 210
jednowątkowa implementacja kolejki, 195
kolejka bez blokad, 252
uzyskiwanie nowej referencji, 259
zwalnianie licznika zewnętrznego węzła, 260
zwalnianie referencji do węzła, 258
kolejka nieograniczona, 206
kolejka ograniczona, 206
kolejka z mechanizmami blokowania i oczekiwania, 203
kolejka ze szczegółowymi blokadami, 198
kolejka ze sztucznym węzłem, 196
kolejką z jednym producentem i jednym konsumentem, 253
lista jednokierunkowa, 194
problem ABA, 266
projektowanie przy użyciu blokad, 186
stos bez blokad, 227, 250
struktury bez blokad, 220, 221
eliminowanie niebezpiecznych wycieków, 228
kolejka, 252
mechanizm odzyskiwania pamięci, 230
problem ABA, 266
stos, 227
uwięzienie, 223
wskazówki dotyczące pisania struktur, 264
zalety i wady, 222
zarządzanie pamięcią, 228
zliczanie referencji, 242
zwalnianie węzłów, 229
struktury bez oczekiwania, 222
szeregowanie, 185
tablica mieszająca, 209
kubełek, 209
tablica posortowana, 209
tablica wyszukiwania, 207
wskazówki dotyczące projektowania, 185
wskaźniki ryzyka, 233
implementacja funkcji odzyskujących węzły, 238
strategie odzyskiwania węzłów, 240
wykrywanie węzłów, 233
wywołania blokujące, 220
zagłodzenie, 221
zliczanie referencji, 242
współbieżność, 20
bezpieczeństwo przetwarzania, 184
mechanizm przyszłości, 102
modele, 22
nadsubskrypcja, 280
oczekiwanie na zdarzenie, 94

operacje atomowe, 136, 137
podniesienia wydajności, 26
podział zagadnień, 25
projektowanie struktury danych, 184
przełączanie kontekstu, 21
przełączanie zadań, 21, 22
przykład programu, 32
równoległość danych, 26
synchronizacja operacji, 93
w języku C++, 28
wątki sprzętowe, 21
współbieżne struktury danych, 184
z wieloma procesami, 23
z wieloma wątkami, 24
zarządzanie wątkami, 36
zmienna warunkowa, 95
zrównoleglanie zadań, 26
współdzielenie danych przez wątki, 55
blokowanie rekurencyjne, 90
definicja klasy stosu, 68
Double-Checked Locking, 85
elastyczne blokowanie muteksu, 79
leniwa inicjalizacja, 85
lista dwukierunkowa, 56
muteks, 59
niezmienniki, 56
ochrona danych za pomocą muteksów, 60
pamięć transakcyjna, 59
problemy, 56
programowanie bez blokad, 59
przenoszenie własności muteksu, 80
sytuacja wyścigu, 58
szczegółowość blokady, 82
wyścigu danych, 58
zakleszczenie, 71
współzawodnictwo, 286
wybór liczby wątków, 49
nadsubskrypcja, 51
wyrażenie lambda, 37
wysokie współzawodnictwo, 282
zwiększenie prawdopodobieństwa, 283
wyścig danych, 58, 112, 136, 355
niezdefiniowane zachowanie, 58
wywołanie blokujące z limitem czasowym, 115
funkcje otrzymujące limity czasowe, 121
limity bezwzględne, 115
maksymalny czas blokowania wątku, 115
okres, 117
punkt w czasie, 118
wymuszanie oczekiwania na podstawie okresu, 117
zastosowanie limitu czasowego, 120
zegar, 115

Z

zaawansowane zarządzanie wątkami, 323
przerywanie wykonywania wątków, 340
monitorowanie systemu plików w tle, 350
obsługa przerwań, 349
oczekiwanie na zmienną, 343, 346
pozostałe wywołania blokujące, 348
przerywanie zadań wykonywanych w tle, 350
punkt przerwania, 341
wykrywanie przerwania, 342
pula wątków, 324
algorytm sortowania szybkiego, 330
implementacja algorytmu sortowania szybkiego, 332
implementacja prostej puli wątków, 325
kolejka umożliwiająca wykradanie zadań, 336
lokalne kolejki zadań, 334
z mechanizmem oczekiwania na zadanie, 327
z mechanizmem wykradania zadań, 337
unikanie współzawodnictwa w dostępie do kolejki, 333
wątek roboczy, 324
wykradanie zadań, 335
zakleszczenie, 71, 354
hierarchia blokad, 75
unikanie, 71, 73
zasada jednej odpowiedzialności, 277
zegar, 115
czasu rzeczywistego, 116
epoka zegara, 118
najkrótszy możliwy takt, 116
okres taktu, 116
stabilny, 116
zegar::now(), 116
zliczanie referencji, 242
licznik wewnętrzny, 243
licznik zewnętrzny, 243
stos bez blokad, 250
umieszczanie węzła na stosie bez blokad, 243
wykrywanie używanych węzłów, 242
zdejmowanie węzła ze stosu bez blokad, 245
zmienna warunkowa, 95
definicja klasy kolejki, 100
oczekiwanie na spełnienie warunku, 95
pozorne budzenie, 97
projektowanie uniwersalnej kolejki, 97
zrównoleglanie zadań, 26

PROGRAM PARTNERSKI

GRUPY WYDAWNICZEJ HELION

1. ZAREJESTRUJ SIĘ
2. PREZENTUJ KSIĄŻKI
3. ZBIERAJ PROWIZJĘ

Zmień swoją stronę WWW
w działający bankomat!

Dowiedz się więcej i dołącz już dzisiaj!

http://program-partnerski.helion.pl

GRUPA WYDAWNICZA
Helion SA

Sprawdź, jak tworzyć niezawodne oprogramowanie wielowątkowe!

Współbieżne przetwarzanie danych to największe wyzwanie dla programisty. Na każdym kroku czyhają na niego najbardziej wymyślne pułapki, a wykrycie pomyłki stanowi nie lada wyzwanie. Każdy programista wzdryga się na samą myśl o implementacji wielowątkowych rozwiązań. Nie musi tak być!

Dzięki tej książce poradzisz sobie z większością zadań i zwinnie ominiesz zastawione pułapki. W trakcie lektury dowiesz się, jak zidentyfikować zadania, w których zastosowanie współbieżności ma sens, oraz jak zarządzać wątkami. Ponadto nauczysz się chronić współdzielone dane oraz synchronizować współbieżne operacje. Duży nacisk został tu położony na zagadnienia związane z projektowaniem współbieżnych struktur danych oraz kodu. Osobny rozdział poświęcono debugowaniu aplikacji wielowątkowych. Książka ta jest długo oczekiwaną pozycją, która ułatwi codzienne życie programistom C++.

Dzięki tej książce:

1. zaprojektujesz współbieżny kod oraz struktury
2. ochronisz współdzielone dane
3. poznasz zaawansowane metody zarządzania wątkami
4. bez problemu przeprowadzisz debugowanie Twojej wielowątkowej aplikacji

Nr katalogowy: 12297

Księgarnia internetowa: http://helion.pl

Zamówienia telefoniczne: 0 801 339900 0 601 339900

helion.pl księgarnia internetowa

Sprawdź najnowsze promocje: http://helion.pl/promocje
Książki najchętniej czytane: http://helion.pl/bestsellery
Zamów informacje o nowościach: http://helion.pl/nowosci

Helion

Helion SA
ul. Kościuszki 1c, 44-100 Gliwice
tel.: 32 230 98 63
e-mail: helion@helion.pl
http://helion.pl

cena 89,00 zł
ISBN 978-83-246-5086-6

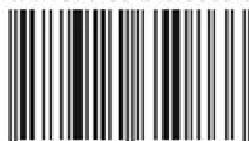

Informatyka w najlepszym wydaniu