PRZEWODNIK PO JĄDRZE SYSTEMU LINUX!

Wydanie II

LINUX
PROGRAMOWANIE SYSTEMOWE

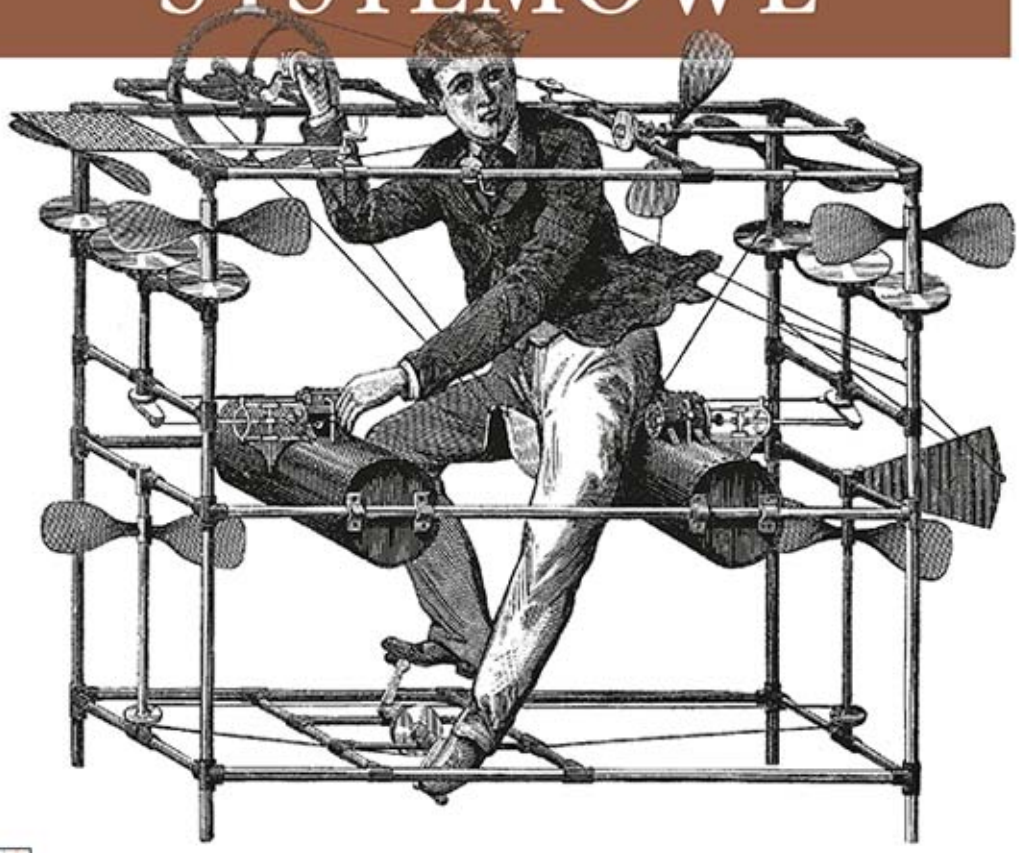

HELION

O'REILLY®

ROBERT LOVE

Tytuł oryginału: Linux System Programming: Talking Directly to the Kernel and C Library, 2nd Edition

Tłumaczenie: Jacek Janusz

ISBN: 978-83-246-8285-0

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/linps2
Możesz tam wpisać swoje uwagi, spostrzeżenia, recenzję.

Printed in Poland.

Spis treści

Przedmowa **13**

Wstęp **15**

1. Wprowadzenie — podstawowe pojęcia **21**

Programowanie systemowe 21
Dlaczego warto uczyć się programowania systemowego? 22
Kamienie węgielne programowania systemowego 23
Funkcje systemowe 23
Biblioteka języka C 24
Kompilator języka C 24
API i ABI 25
API 25
ABI 26
Standardy 27
Historia POSIX oraz SUS 27
Standardy języka C 28
Linux i standardy 28
Książka i standardy 29
Pojęcia dotyczące programowania w Linuksie 29
Pliki i system plików 30
Procesy 36
Użytkownicy i grupy 38
Uprawnienia 39
Sygnały 39
Komunikacja międzyprocesowa 40
Pliki nagłówkowe 40
Obsługa błędów 40
Początek programowania systemowego 43

2. Plikowe operacje wejścia i wyjścia 45
Otwieranie plików 46
Funkcja systemowa open() 46
Właściciele nowych plików 49
Uprawnienia nowych plików 49
Funkcja creat() 51
Wartości zwracane i kody błędów 52
Czytanie z pliku przy użyciu funkcji read() 52
Wartości zwracane 53
Czytanie wszystkich bajtów 54
Odczyty nieblokujące 55
Inne wartości błędów 55
Ograniczenia rozmiaru dla funkcji read() 56
Pisanie za pomocą funkcji write() 56
Zapisy częściowe 57
Tryb dopisywania 57
Zapisy nieblokujące 58
Inne kody błędów 58
Ograniczenia rozmiaru dla funkcji write() 59
Sposób działania funkcji write() 59
Zsynchronizowane operacje wejścia i wyjścia 60
Funkcje fsync() i fdatasync() 60
Funkcja sync() 62
Znacznik O_SYNC 63
Znaczniki O_DSYNC i O_RSYNC 63
Bezpośrednie operacje wejścia i wyjścia 64
Zamykanie plików 65
Kody błędów 65
Szukanie za pomocą funkcji lseek() 66
Szukanie poza końcem pliku 67
Kody błędów 67
Ograniczenia 68
Odczyty i zapisy pozycyjne 68
Kody błędów 69
Obcinanie plików 69
Zwielokrotnione operacje wejścia i wyjścia 70
Funkcja select() 71
Funkcja poll() 76
Porównanie funkcji poll() i select() 80
Organizacja wewnętrzna jądra 81
Wirtualny system plików 81
Bufor stron 82
Opóźniony zapis stron 84
Zakończenie 85

3. Buforowane operacje wejścia i wyjścia 87
Operacje wejścia i wyjścia buforowane w przestrzeni użytkownika 87
Rozmiar bloku 89
Typowe operacje wejścia i wyjścia 90
Wskaźniki do plików 90
Otwieranie plików 91
Tryby 91
Otwieranie strumienia poprzez deskryptor pliku 92
Zamykanie strumieni 93
Zamykanie wszystkich strumieni 93
Czytanie ze strumienia 93
Czytanie pojedynczego znaku 93
Czytanie całego wiersza 94
Czytanie danych binarnych 96
Pisanie do strumienia 97
Zapisywanie pojedynczego znaku 97
Zapisywanie łańcucha znaków 98
Zapisywanie danych binarnych 98
Przykładowy program używający buforowanych operacji wejścia i wyjścia 99
Szukanie w strumieniu 100
Otrzymywanie informacji o aktualnym położeniu w strumieniu 101
Opróżnianie strumienia 102
Błędy i koniec pliku 102
Otrzymywanie skojarzonego deskryptora pliku 103
Parametry buforowania 104
Bezpieczeństwo wątków 105
Nieautomatyczne blokowanie plików 106
Nieblokowane operacje na strumieniu 107
Krytyczna analiza biblioteki typowych operacji wejścia i wyjścia 108
Zakończenie 109

4. Zaawansowane operacje plikowe wejścia i wyjścia 111
Rozproszone operacje wejścia i wyjścia 112
Funkcje readv() i writev() 112
Odpytywanie zdarzeń 117
Tworzenie nowego egzemplarza interfejsu odpytywania zdarzeń 117
Sterowanie działaniem interfejsu odpytywania zdarzeń 118
Oczekiwanie na zdarzenie w interfejsie odpytywania zdarzeń 121
Zdarzenia przełączane zboczem a zdarzenia przełączane poziomem 122
Odwzorowywanie plików w pamięci 123
Funkcja mmap() 123
Funkcja munmap() 128

Przykład odwzorowania w pamięci 128
Zalety używania funkcji mmap() 130
Wady używania funkcji mmap() 130
Zmiana rozmiaru odwzorowania 131
Zmiana uprawnień odwzorowania 132
Synchronizacja odwzorowanego pliku 133
Dostarczanie porad dotyczących odwzorowania w pamięci 134
Porady dla standardowych operacji plikowych wejścia i wyjścia 137
Funkcja systemowa posix_fadvise() 137
Funkcja systemowa readahead() 138
Porada jest tania 139
Operacje zsynchronizowane, synchroniczne i asynchroniczne 140
Asynchroniczne operacje wejścia i wyjścia 141
Zarządcy operacji wejścia i wyjścia oraz wydajność operacji wejścia i wyjścia 142
Adresowanie dysku 142
Działanie zarządcy operacji wejścia i wyjścia 143
Wspomaganie odczytów 143
Wybór i konfiguracja zarządcy operacji wejścia i wyjścia 147
Optymalizowanie wydajności operacji wejścia i wyjścia 148
Zakończenie 154

5. Zarządzanie procesami 155
Programy, procesy i wątki 155
Identyfikator procesu 156
Przydział identyfikatorów procesów 156
Hierarchia procesów 157
Typ pid_t 157
Otrzymywanie identyfikatora procesu oraz identyfikatora procesu rodzicielskiego 158
Uruchamianie nowego procesu 158
Rodzina funkcji exec 158
Funkcja systemowa fork() 162
Zakończenie procesu 166
Inne sposoby na zakończenie procesu 167
Funkcja atexit() 167
Funkcja on_exit() 168
Sygnał SIGCHLD 169
Oczekiwanie na zakończone procesy potomka 169
Oczekiwanie na określony proces 171
Jeszcze wszechstronniejsza funkcja oczekiwania 173
BSD wkracza do akcji: funkcje wait3() i wait4() 175
Uruchamianie i oczekiwanie na nowy proces 177
Procesy zombie 179

Użytkownicy i grupy 179
Rzeczywiste, efektywne oraz zapisane identyfikatory użytkownika i grupy 180
Zmiana rzeczywistego lub zapisanego identyfikatora dla użytkownika lub grupy 181
Zmiana efektywnego identyfikatora dla użytkownika lub grupy 182
Zmiana identyfikatora dla użytkownika lub grupy w wersji BSD 182
Zmiana identyfikatora dla użytkownika lub grupy w wersji HP-UX 183
Zalecane modyfikacje identyfikatorów użytkownika i grupy 183
Wsparcie dla zapisanych identyfikatorów użytkownika 184
Otrzymywanie identyfikatorów użytkownika i grupy 184
Grupy sesji i procesów 184
Funkcje systemowe do obsługi sesji 186
Funkcje systemowe do obsługi grup procesów 187
Przestarzałe funkcje do obsługi grupy procesów 188
Demony 189
Zakończenie 191

6. Zaawansowane zarządzanie procesami 193
Szeregowanie procesów 193
Przedziały czasowe 194
Procesy związane z wejściem i wyjściem a procesy związane z procesorem 194
Szeregowanie z wywłaszczaniem 195
Completely Fair Scheduler 196
Udostępnianie czasu procesora 197
Prawidłowe sposoby użycia sched_yield() 198
Priorytety procesu 199
nice() 199
getpriority() i setpriority() 200
Priorytety wejścia i wyjścia 201
Wiązanie procesów do konkretnego procesora 202
sched_getaffinity() i sched_setaffinity() 203
Systemy czasu rzeczywistego 205
Systemy ścisłego oraz zwykłego czasu rzeczywistego 205
Opóźnienie, rozsynchronizowanie oraz parametry graniczne 206
Obsługa czasu rzeczywistego przez system Linux 207
Linuksowe strategie szeregowania i ustalania priorytetów 208
Ustawianie parametrów szeregowania 211
sched_rr_get_interval() 214
Środki ostrożności przy pracy z procesami czasu rzeczywistego 215
Determinizm 216
Ograniczenia zasobów systemowych 218
Ograniczenia 220
Ustawianie i odczytywanie ograniczeń 223

7. Wątkowość 225
Binaria, procesy i wątki 225
Wielowątkowość 226
Koszty wielowątkowości 228
Alternatywy dla wielowątkowości 228
Modele wątkowości 229
Wątkowość na poziomie użytkownika 229
Wątkowość mieszana 230
Współprogramy i włókna 230
Wzorce wątkowości 231
Wątkowość thread-per-connection 231
Wątkowość sterowana zdarzeniami 232
Współbieżność, równoległość i wyścigi 233
Sytuacje wyścigów 233
Synchronizacja 236
Muteksy 236
Zakleszczenia 238
Standard Pthreads 239
Implementacje wątkowości w Linuksie 240
Interfejs programistyczny dla standardu Pthreads 240
Konsolidowanie implementacji Pthreads 241
Tworzenie wątków 241
Identyfikatory wątków 243
Kończenie wątków 243
Łączenie i odłączanie wątków 246
Przykład wątkowości 247
Muteksy standardu Pthreads 248
Dalsze zdobywanie wiedzy 251

8. Zarządzanie plikami i katalogami 253
Pliki i ich metadane 253
Rodzina funkcji stat 253
Uprawnienia 257
Prawa własności 259
Atrybuty rozszerzone 261
Operacje dla atrybutów rozszerzonych 264
Katalogi 269
Aktualny katalog roboczy 270
Tworzenie katalogów 275
Usuwanie katalogów 276
Odczytywanie zawartości katalogu 278

Dowiązania 280
Dowiązania twarde 281
Dowiązania symboliczne 282
Usuwanie elementów z systemu plików 284
Kopiowanie i przenoszenie plików 286
Kopiowanie 286
Przenoszenie 286
Węzły urządzeń 288
Specjalne węzły urządzeń 289
Generator liczb losowych 289
Komunikacja poza kolejką 290
Śledzenie zdarzeń związanych z plikami 292
Inicjalizacja interfejsu inotify 292
Elementy obserwowane 293
Zdarzenia interfejsu inotify 295
Zaawansowane opcje obserwowania 298
Usuwanie elementu obserwowanego z interfejsu inotify 299
Otrzymywanie rozmiaru kolejki zdarzeń 300
Usuwanie egzemplarza interfejsu inotify 300

9. Zarządzanie pamięcią 301
Przestrzeń adresowa procesu 301
Strony i stronicowanie 301
Regiony pamięci 303
Przydzielanie pamięci dynamicznej 304
Przydzielanie pamięci dla tablic 306
Zmiana wielkości obszaru przydzielonej pamięci 307
Zwalnianie pamięci dynamicznej 309
Wyrównanie 310
Zarządzanie segmentem danych 315
Anonimowe odwzorowania w pamięci 315
Tworzenie anonimowych odwzorowań w pamięci 317
Odwzorowanie pliku /dev/zero 318
Zaawansowane operacje przydziału pamięci 319
Dokładne dostrajanie przy użyciu funkcji malloc_usable_size() oraz malloc_trim() 322
Uruchamianie programów używających systemu przydzielania pamięci 323
Otrzymywanie danych statystycznych 323
Przydziały pamięci wykorzystujące stos 324
Powielanie łańcuchów znakowych na stosie 326
Tablice o zmiennej długości 326
Wybór mechanizmu przydzielania pamięci 327

Operacje na pamięci 328
Ustawianie wartości bajtów 329
Porównywanie bajtów 329
Przenoszenie bajtów 330
Wyszukiwanie bajtów 331
Manipulowanie bajtami 332
Blokowanie pamięci 332
Blokowanie fragmentu przestrzeni adresowej 333
Blokowanie całej przestrzeni adresowej 334
Odblokowywanie pamięci 335
Ograniczenia blokowania 335
Czy strona znajduje się w pamięci fizycznej? 336
Przydział oportunistyczny 336
Przekroczenie zakresu zatwierdzenia oraz stan braku pamięci (OOM) 337

10. Sygnały 339
Koncepcja sygnałów 340
Identyfikatory sygnałów 340
Sygnały wspierane przez system Linux 341
Podstawowe zarządzanie sygnałami 346
Oczekiwanie na dowolny sygnał 347
Przykłady 348
Uruchomienie i dziedziczenie 349
Odwzorowanie numerów sygnałów na łańcuchy znakowe 350
Wysyłanie sygnału 351
Uprawnienia 352
Przykłady 352
Wysyłanie sygnału do samego siebie 353
Wysyłanie sygnału do całej grupy procesów 353
Współużywalność 354
Funkcje, dla których współużywalność jest zagwarantowana 354
Zbiory sygnałów 356
Inne funkcje obsługujące zbiory sygnałów 356
Blokowanie sygnałów 357
Odzyskiwanie oczekujących sygnałów 358
Oczekiwanie na zbiór sygnałów 358
Zaawansowane zarządzanie sygnałami 359
Struktura siginfo_t 361
Wspaniały świat pola si_code 363
Wysyłanie sygnału z wykorzystaniem pola użytkowego 366
Przykład wykorzystania pola użytkowego 367
Ułomność systemu Unix? 367

11. Czas 369
Struktury danych reprezentujące czas 371
Reprezentacja pierwotna 372
Następna wersja — dokładność na poziomie mikrosekund 372
Kolejna, lepsza wersja — dokładność na poziomie nanosekund 372
Wyłuskiwanie składników czasu 373
Typ danych dla czasu procesu 374
Zegary POSIX 374
Rozdzielczość źródła czasu 375
Pobieranie aktualnego czasu 376
Lepszy interfejs 377
Interfejs zaawansowany 377
Pobieranie czasu procesu 378
Ustawianie aktualnego czasu 379
Precyzyjne ustawianie czasu 379
Zaawansowany interfejs ustawiania czasu 380
Konwersje czasu 381
Dostrajanie zegara systemowego 382
Stan uśpienia i oczekiwania 385
Obsługa stanu uśpienia z dokładnością do mikrosekund 386
Obsługa stanu uśpienia z dokładnością do nanosekund 387
Zaawansowane zarządzanie stanem uśpienia 389
Przenośny sposób wprowadzania w stan uśpienia 390
Przepełnienia 391
Alternatywy stanu uśpienia 391
Liczniki 392
Proste alarmy 392
Liczniki interwałowe 392
Liczniki zaawansowane 394

A Rozszerzenia kompilatora GCC dla języka C 401

B Bibliografia 413

Skorowidz 417

ROZDZIAŁ 6.

Zaawansowane zarządzanie procesami

W rozdziale 5. wyjaśniono, czym jest proces i jakich elementów systemu dotyczy. Omówiono także interfejsy jądra użyte w celu jego tworzenia, kontroli i usuwania. W niniejszym rozdziale informacje te są wykorzystane podczas rozważań na temat *zarządcy procesów* (ang. *scheduler*) i jego algorytmu szeregowania, by zaprezentować zaawansowane interfejsy dla potrzeb zarządzania procesami. Te funkcje systemowe ustalają zachowanie szeregowania oraz semantykę procesu, wpływając na sposób działania zarządcy procesów w dążeniu do celu określonego przez aplikację lub użytkownika.

Szeregowanie procesów

Zarządca procesów jest składnikiem jądra, który dzieli ograniczony zasób czasu procesora pomiędzy procesy systemowe. Innymi słowy, zarządca procesów (lub mówiąc prościej: *zarządca*) jest podsystemem jądra, który decyduje, jaki proces powinien zostać uruchomiony w następnej kolejności. Podczas podejmowania decyzji, jakie procesy i kiedy mają być uruchomione, zarządca jest odpowiedzialny za maksymalizowanie użycia procesora oraz stwarzanie jednocześnie wrażenia, iż wiele procesów jest wykonywanych współbieżnie i płynnie.

W tym rozdziale będzie mowa o procesach uruchamialnych (ang. *runnable*). Proces uruchamialny to taki proces, który nie jest zablokowany. Proces *blokowany* (ang. *blocked*) jest to taki proces, który znajduje się w stanie uśpienia, czekając, aż jądro rozpocznie wykonywanie operacji wejścia i wyjścia. Procesy współdziałające z użytkownikami, intensywnie zapisujące lub czytające pliki, a także odpowiadające na sieciowe, mają tendencję do zużywania dużej ilości czasu, kiedy są zablokowane podczas oczekiwania na zasoby, które mają stać się dostępne. Nie są one aktywne w czasie tych długich okresów bezczynności. W przypadku tylko jednego procesu uruchamialnego zadanie zarządcy procesów jest trywialne: uruchomić ten właśnie proces! Zarządca udowadnia swoją wartość wówczas, gdy w systemie znajduje się więcej procesów uruchamialnych niż procesorów. W takiej sytuacji niektóre procesy będą działać, a inne muszą czekać na swoją kolej. Zarządca procesów bierze przede wszystkim odpowiedzialność za decyzję, jaki proces, kiedy i na jak długi czas powinien zostać uruchomiony.

System operacyjny zainstalowany w maszynie posiadającej pojedynczy procesor jest *wielozadaniowy*, gdy potrafi na przemian wykonywać wiele procesów, stwarzając złudzenie, iż więcej niż jeden proces działa w tym samym czasie. W maszynach wieloprocesorowych wielozadaniowy system operacyjny pozwala procesom faktycznie działać równolegle na różnych procesorach. System operacyjny, który nie jest wielozadaniowy, taki jak DOS, może uruchamiać wyłącznie jeden program w danym momencie.

Wielozadaniowe systemy operacyjne dzielą się na systemy *kooperacyjne* (ang. *cooperative*) oraz systemy *z wywłaszczaniem* (ang. *preemptive*). Linux implementuje drugą formę wielozadaniowości, w której zarządca decyduje, kiedy należy zatrzymać dany proces i uruchomić inny. Wywłaszczenie zwane jest też zawieszeniem działającego procesu. Jeszcze raz powtórzmy — długość czasu, w którym proces działa, zanim zarządca go wywłaszczy, nazywany jest *przedziałem czasowym* procesu (dosłowne tłumaczenie: „plasterek czasu" — *timeslice* — nazywany tak z powodu przydzielania przez zarządcę każdemu procesowi uruchamialnemu „plasterka" czasu procesora).

W wielozadaniowości kooperatywnej jest odwrotnie — proces nie przestaje działać, dopóki sam nie zadecyduje o swoim zawieszeniu. Samoczynne zawieszenie się procesu nazywa się *udostępnianiem czasu procesora* (ang. *yielding*). W sytuacji idealnej procesy często udostępniają czas procesora, lecz system operacyjny jest niezdolny do wymuszenia tego zachowania. Źle działający lub uszkodzony program może działać tak długo, że potrafi wyeliminować iluzję wielozadaniowości, a nawet zawiesić cały system. Z powodu tych problemów, związanych z zagadnieniem wielozadaniowości, nowoczesne systemy operacyjne są generalnie wielozadaniowe z wywłaszczaniem; Linux nie jest tu wyjątkiem.

Zarządca procesów Linuksa zmieniał się na przestrzeni lat. Bieżącym zarządcą procesów, dostępnym od wersji 2.6.23 jądra Linuksa, jest *Completely Fair Scheduler* (w skrócie *CFS*). Jego nazwa pochodzi od słów *fair queuing* (*sprawiedliwe kolejkowanie*) — nazwy algorytmu kolejkowania, który stara się sprawiedliwie udostępniać zasoby rywalizującym ze sobą konsumentom. CFS różni się znacząco od innych uniksowych zarządców procesów, włącznie z jego poprzednikiem, *zarządcą procesów O(1)*. Zarządcę CFS omówimy dokładniej w podrozdziale „Completely Fair Scheduler", znajdującym się w dalszej części tego rozdziału.

Przedziały czasowe

Przedział czasowy, który zarządca procesów przydziela każdemu procesowi, jest ważną wartością dla ogólnego zachowania i sprawności systemu. Jeśli przedziały czasowe są zbyt duże, procesy muszą oczekiwać przez długi czas pomiędzy uruchomieniami, pogarszając wrażenie równoległego działania. Może to być frustrujące dla użytkownika w przypadku zauważalnych opóźnień. I na odwrót, jeśli przedziały czasowe są zbyt małe, znacząca ilość czasu systemowego jest przeznaczana na przełączanie między aplikacjami i traci się na przykład czasową lokalizację (ang. *temporal locality*) i inne korzyści.

Ustalanie idealnego przedziału czasowego nie jest więc proste. Niektóre systemy operacyjne udzielają procesom dużych przedziałów czasowych, mając nadzieję na zwiększenie przepustowości systemu oraz ogólnej wydajności. Inne systemy operacyjne dają procesom bardzo małe przedziały czasowe w nadziei, iż zapewnią systemowi bardzo dobrą wydajność. Jak się okaże, zarządca CFS rozwiązuje ten problem w bardzo dziwny sposób: eliminuje przedziały czasowe.

Procesy związane z wejściem i wyjściem a procesy związane z procesorem

Procesy, które w ciągły sposób konsumują wszystkie możliwe przedziały czasowe im przydzielone, są określane mianem procesów *związanych z procesorem* (ang. *processor-bound*). Takie procesy ciągle żądają czasu procesora i będą konsumować wszystko, co zarządca im przydzieli. Najprostszym, trywialnym tego przykładem jest pętla nieskończona:

```
// 100% związanie z procesorem
while (1)
    ;
```

Inne, mniej ekstremalne przykłady to obliczenia naukowe, matematyczne oraz przetwarzanie obrazów.

Z drugiej strony, procesy, które przez większość czasu są zablokowane w oczekiwaniu na jakiś zasób, zamiast normalnie działać, nazywane są procesami *związanymi z wejściem i wyjściem* (ang. *I/O-bound*). Procesy związane z wejściem i wyjściem są często wznawiane i oczekują w plikowych lub sieciowych operacjach zapisu i odczytu, blokują się podczas oczekiwania na dane z klawiatury lub czekają na akcję użytkownika polegającą na ruchu myszką. Przykłady aplikacji związanych z wejściem i wyjściem to programy użytkowe, które robią niewiele poza tym, że generują wywołania systemowe żądające od jądra, aby wykonał operacje wejścia i wyjścia, takie jak `cp` lub `mv`, a także wiele aplikacji GUI, które zużywają dużo czasu oczekując na akcję użytkownika.

Aplikacje związane z procesorem oraz aplikacje związane z wejściem i wyjściem chcą wykorzystywać takie opcje zarządcy procesów, które najbardziej odpowiadają ich sposobowi działania. Aplikacje związane z procesorem wymagają możliwie największych przedziałów czasowych, pozwalających im na poprawienie współczynnika używania pamięci podręcznej (poprzez czasową lokalizację) oraz jak najszybciej kończą swoje działanie. W przeciwieństwie do nich procesy związane z wejściem i wyjściem nie wymagają koniecznie dużych przedziałów czasowych, ponieważ standardowo działają tylko przez krótki czas przed wysłaniem żądań związanych z wejściem i wyjściem oraz blokowaniem się na jakimś zasobie z jądra systemu. Procesy związane z wejściem i wyjściem czerpią jednak korzyści z tego, iż zarządca obsługuje je z wyższym priorytetem. Im szybciej jakaś aplikacja może ponownie uruchomić się po zablokowaniu się i wysłaniu większej liczby żądań wejścia i wyjścia, tym lepiej potrafi ona używać urządzeń systemowych. Co więcej, im szybciej aplikacja czekająca na akcję użytkownika zostanie zaszeregowana, tym bardziej sprawia ona wrażenie płynnego działania dla tego użytkownika.

Dopasowywanie potrzeb procesów związanych z procesorem oraz wejściem i wyjściem nie jest łatwe. W rzeczywistości większość aplikacji stanowi połączenie procesów związanych z procesorem oraz z wejściem i wyjściem. Kodowanie oraz dekodowanie strumieni dźwięku i obrazu jest dobrym przykładem typu aplikacji, który opiera się jednoznacznej kwalifikacji. Wiele gier to również aplikacje o typie mieszanym. Nie zawsze jest możliwa identyfikacja skłonności danej aplikacji; w określonym momencie dany proces może zachowywać się w różny sposób.

Szeregowanie z wywłaszczaniem

W tradycyjnej metodzie szeregowania procesów w Uniksie wszystkim uruchamialnym procesom zostaje przydzielony przedział czasu. Gdy dany proces wykorzysta swój przedział czasowy, jądro zawiesza go, a rozpoczyna wykonywanie innego procesu. Jeśli w systemie nie istnieje więcej procesów uruchamialnych, jądro pobiera grupę procesów z wykorzystanymi przedziałami czasowymi, uzupełnia te przedziały oraz uruchamia procesy ponownie. Cały proces jest powtarzalny: procesy wciąż tworzone pojawiają się na liście procesów uruchamialnych, a procesy kończone są z niej usuwane, blokują się na operacjach wejścia i wyjścia lub są budzone ze stanu uśpienia. W ten sposób wszystkie procesy ostatecznie są uruchamiane, nawet jeśli w systemie istnieją procesy o wyższym priorytecie; procesy niskopriorytetowe muszą czekać, aż procesy

o wysokim priorytecie wyczerpią swoje przedziały czasowe lub zablokują się. To zachowanie formułuje ważną, lecz ukrytą regułę szeregowania w systemach Unix: wszystkie procesy muszą kontynuować swoje działanie.

Completely Fair Scheduler

Zarządca Completely Fair Scheduler (CFS) znacząco różni się od tradycyjnych zarządców procesów spotykanych w systemie Unix. W większości systemów uniksowych, włącznie z Linuksem przed wprowadzeniem CFS, istniały dwie podstawowe zmienne, związane z procesem podczas jego szeregowania: priorytet i przedział czasu. Jak opisano we wcześniejszym podrozdziale w przypadku tradycyjnych zarządców procesom przypisuje się przedziały czasowe, które reprezentują „plasterek" procesora przydzielony dla nich. Procesory mogą działać aż do momentu, gdy wyczerpią ten przedział czasowy. W podobny sposób procesom przypisuje się priorytet. Zarządca uruchamia procesy o wyższym priorytecie przed tymi, które mają niższy. Algorytm ten jest bardzo prosty i sprawdzał się znakomicie w dawnych systemach uniksowych, które wymagały podziału czasu procesora. Nieco gorzej działa on w systemach wymagających wysokiej wydajności interaktywnej oraz sprawiedliwego podziału czasu, takich jak nowoczesne komputery stacjonarne i urządzenia mobilne.

W zarządcy CFS użyto całkiem innego algorytmu, zwanego *sprawiedliwym kolejkowaniem* (ang. *fair scheduling*), który eliminuje przedziały czasu jako jednostki dostępu do procesora. Zamiast nich CFS przypisuje każdemu procesowi *część* czasu procesora. Algorytm jest prosty: CFS rozpoczyna swoje działanie poprzez przypisanie *N* procesom po *1/N* czasu procesora. Następnie modyfikuje to przypisanie poprzez przydzielanie każdemu procesowi odpowiedniej wagi, związanej z jego poziomem uprzejmości. Procesy z domyślną wartością poziomu uprzejmości równą zero mają wagę jeden, dlatego ich proporcja nie zostaje zmieniona. Procesy z mniejszą wartością poziomu uprzejmości (wyższym priorytetem) uzyskują wyższą wagę, wskutek czego zwiększa się ich udział w wykorzystaniu czasu procesora, podczas gdy procesy z większą wartością poziomu uprzejmości (niższym priorytetem) otrzymują niższą wagę, a więc zmniejsza się ich udział w wykorzystaniu czasu procesora.

Zarządca CFS używa obecnie ważonej proporcji czasu procesora przypisanego do każdego procesu. Aby ustalić faktyczną długość odcinka czasu działania dla każdego procesu, CFS musi rozdzielić proporcje w określonym przedziale. Ten przedział jest zwany *docelowym opóźnieniem* (ang. *target latency*), ponieważ reprezentuje opóźnienie szeregowania w systemie. Aby zrozumieć działanie docelowego opóźnienia, załóżmy, że zostało ono zdefiniowane jako 20 milisekund, a w systemie znajdują się dwa uruchamialne procesy o tym samym priorytecie. Wynika z tego, że każdy proces ma tę samą wagę i przypisano mu taką samą część czasu procesora, czyli 10 milisekund. Tak więc CFS uruchomi pierwszy proces na 10 milisekund, drugi również na 10 milisekund, a następnie powtórzy całą operację. Jeśli w systemie byłoby 5 procesów uruchamialnych, CFS przydzielałby im po 4 milisekundy.

Do tej pory wszystko wydaje się proste. Co się jednak stanie, gdy będziemy mieli na przykład 200 procesów? Z docelowym opóźnieniem wynoszącym 20 milisekund CFS będzie mógł uruchamiać każdy z tych procesów na jedynie 100 mikrosekund. Z powodu kosztów przełączania kontekstu (zwanych po prostu *kosztami przełączania*) pomiędzy procesorami oraz ograniczonej czasowej lokalizacji wydajność systemu może się pogorszyć. Aby rozwiązać ten problem,

CFS wprowadza drugą kluczową zmienną: minimalną ziarnistość. *Minimalna ziarnistość* (ang. *minimum granularity*) jest najmniejszym przedziałem czasu, w jakim może działać dowolny proces. Wszystkie procesy, bez względu na przydzieloną im część czasu procesora, będą działać z przynajmniej minimalną ziarnistością (lub do czasu ich zablokowania). Dzięki temu przełączanie nie pochłania nadmiernej ilości całkowitego czasu systemu, dzieje się to jednak kosztem wartości docelowego opóźnienia. Oznacza to, że w przypadku gdy zaczyna być aktywna minimalna ziarnistość, zostaje naruszona zasada sprawiedliwego przydzielania czasu. Jeśli użyte zostaną typowe wartości docelowego opóźnienia i minimalna ziarnistość oraz najczęściej spotykana rozsądna liczba procesów uruchamialnych, minimalna ziarnistość nie zostaje aktywowana, docelowe opóźnienie jest zachowywane, a zasada sprawiedliwego przydzielania czasu realizowana.

Poprzez przydzielanie części procesora, a nie stałych przedziałów czasowych, CFS może stosować zasadę sprawiedliwości: każdy proces otrzymuje *sprawiedliwą część* procesora. Ponadto CFS potrafi używać konfigurowanego opóźnienia szeregowania, ponieważ *docelowe opóźnienie* może być modyfikowane przez użytkownika. W tradycyjnych zarządcach uniksowych procesy *z założenia* działają w stałych przedziałach czasowych, lecz opóźnienie szeregowania (określające, jak często są one uruchamiane) jest nieznane. W przypadku CFS procesy działają zgodnie z przydzielonymi im częściami i z opóźnieniem, a te wartości *z założenia* są znane. Jednakże przedział czasowy zmienia się, ponieważ jest funkcją liczby uruchamialnych procesów w systemie. Jest to znacząco inna metoda obsługi szeregowania procesów. Rozwiązuje ona wiele problemów dotyczących procesów interaktywnych oraz związanych z wejściem i wyjściem, nękających tradycyjnych zarządców procesów.

Udostępnianie czasu procesora

Chociaż Linux jest wielozadaniowym systemem operacyjnym z wywłaszczaniem, dostarcza również funkcję systemową, która pozwala procesom jawnie zawieszać działanie i informować zarządcę, by wybrał nowy proces do uruchomienia:

```
#include <sched.h>
int sched_yield (void);
```

Wywołanie funkcji `sched_yield()` skutkuje zawieszeniem aktualnie działającego procesu, po czym zarządca procesów wybiera nowy proces, aby go uruchomić, w taki sam sposób, jakby jądro samo wywłaszczyło aktualny proces w celu uruchomienia nowego. Warte uwagi jest to, że jeśli nie istnieje żaden inny proces uruchamialny, co jest częstym przypadkiem, wówczas proces udostępniający natychmiast ponowi swoje działanie. Z powodu przypadkowości połączonej z ogólnym przekonaniem, iż zazwyczaj istnieją lepsze metody, użycie tego wywołania systemowego nie jest popularne.

W przypadku sukcesu funkcja zwraca `0`; w przypadku porażki zwraca `-1` oraz ustawia `errno` na odpowiednią wartość kodu błędu. W Linuksie oraz — bardziej niż prawdopodobnie — w większości systemów Unix wywołanie funkcji `sched_yield()` nie może się nie udać i dlatego też zawsze zwraca wartość zero. Drobiazgowy programista może jednak ciągle próbować sprawdzać zwracaną wartość:

```
if (sched_yield ( ))
   perror ("sched_yield");
```

Prawidłowe sposoby użycia sched_yield()

W praktyce istnieje kilka prawidłowych sposobów użycia funkcji `sched_yield()` w poprawnym wielozadaniowym systemie z wywłaszczeniem, jak na przykład w Linuksie. Jądro jest w pełni zdolne do podjęcia optymalnych oraz najbardziej efektywnych decyzji dotyczących szeregowania — oczywiście, jądro jest lepiej niż sama aplikacja wyposażone w mechanizmy, które pozwalają decydować, co i kiedy należy wywłaszczyć. Oto, dlaczego w systemach operacyjnych odchodzi się od wielozadaniowości kooperatywnej na rzecz wielozadaniowości z wywłaszczeniem.

Dlaczego więc w ogóle istnieje funkcja systemowa „Przeszereguj mnie”? Odpowiedź można znaleźć w aplikacjach oczekujących na zdarzenia zewnętrzne, które mogą być spowodowane przez użytkownika, element sprzętowy albo inny proces. Na przykład, jeśli jeden proces musi czekać na inny, pierwszym narzucającym się rozwiązaniem tego problemu jest: „po prostu udostępnij czas procesora, dopóki inny proces się nie zakończy”. Jako przykład mogłaby wystąpić implementacja prostego konsumenta w parze producent-konsument, która byłaby podobna do następującego kodu:

```
/* konsument... */
do
{
   while (producer_not_ready ())
      sched_yield ();
   process_data ();
} while (!time_to_quit());
```

Na szczęście programiści systemu Unix nie są skłonni do tworzenia kodu tego typu. Programy uniksowe są zwykle sterowane zdarzeniami i zamiast stosować funkcję `sched_yield()` dążą do używania pewnego rodzaju mechanizmu blokowania (takiego jak potok — ang. *pipe*) pomiędzy konsumentem a producentem. W tym przypadku konsument próbuje czytać z potoku, będąc jednak zablokowanym, dopóki nie pojawią się dane. Z drugiej strony, producent zapisuje do potoku, gdy tylko dostępne stają się nowe dane. Przenosi to odpowiedzialność za koordynację z procesu należącego do poziomu użytkownika, na przykład z pętli zajmujących czas procesora do jądra, które może optymalnie zarządzać taką sytuacją przez przełączanie procesów w stan uśpienia oraz budzenie ich tylko w przypadku potrzeby. Ogólnie rzecz biorąc, programy uniksowe powinny dążyć do rozwiązań sterowanych zdarzeniami, które opierają się na blokowanych deskryptorach plików.

Jedna sytuacja do niedawna koniecznie wymagała `sched_yield()` — blokowanie wątku z poziomu użytkownika. Gdy jakiś wątek próbował uzyskać blokadę, która jest już w posiadaniu innego wątku, wówczas udostępniał on czas procesora dopóty, dopóki blokada nie została zwolniona. Bez wsparcia blokad z poziomu użytkownika ze strony jądra to podejście było najprostsze i najbardziej efektywne. Na szczęście nowoczesna implementacja wątków w Linuksie (*Native POSIX Threading Library* — NPTL) wprowadziła optymalne rozwiązanie przy użyciu mechanizmu *futex*, który dostarcza procesorowi wsparcia dla systemu blokowania z poziomu użytkownika.

Jeszcze innym przykładem użycia funkcji `sched_yield()` jest zagadnienie „sympatycznego działania”: program intensywnie obciążający procesor może wywoływać co jakiś czas `sched_yield()`, przez co minimalizuje swoje obciążenie w systemie. Rozwiązanie to ma być może szlachetny cel, lecz niestety posiada dwie wady. Po pierwsze, jądro potrafi podejmować globalne decyzje dotyczące szeregowania dużo lepiej niż indywidualne procesy i w konsekwencji odpowiedzialność za zapewnienie płynności operacji w systemie powinna spoczywać na zarządcy procesów, a nie na samych procesach. Po drugie, za zmniejszenie obciążenia aplikacji

korzystającej intensywnie z procesora z jednoczesnym wyróżnieniem innych programów odpowiada użytkownik, a nie pojedyncza aplikacja. Użytkownik może zmodyfikować swoje preferencje dotyczące wydajności aplikacji poprzez użycie komendy powłoki systemowej *nice*, która będzie omawiana w dalszej części tego rozdziału.

Priorytety procesu

Dyskusja w tym podrozdziale dotyczy zwykłych procesów, niebędących procesami czasu rzeczywistego. Procesy czasu rzeczywistego wymagają odmiennych kryteriów szeregowania oraz oddzielnego systemu priorytetów. Będzie to omówione w dalszej części rozdziału.

Linux nie szereguje procesów w sposób przypadkowy. Zamiast tego procesom przypisywane są *priorytety*, które wpływają na czas ich działania: jak pamiętasz, część procesora przypisana do procesu jest ważona przy użyciu wartości poziomu uprzejmości. Od początku swojego istnienia Unix nazywał te priorytety *poziomami uprzejmości* (ang. *nice values*), ponieważ ideą ukrytą za tą nazwą było to, aby „być uprzejmym" dla innych procesów znajdujących się w systemie poprzez obniżanie priorytetu aktualnego procesu, zezwalając przez to innym procesom na konsumowanie większej ilości czasu procesora.

Poprawne poziomy uprzejmości zawierają się w granicach od –20 do 19 włącznie, z domyślną wartością równą zeru. W pewien sposób dezorientujące jest to, iż im niższy poziom uprzejmości dla danego procesu, tym wyższy jego priorytet oraz większy przedział czasu; odwrotnie, im wyższa wartość, tym niższy priorytet procesu i mniejszy przedział czasu. Dlatego też zwiększanie poziomu uprzejmości dla procesu jest „uprzejme" dla reszty systemu. Odwrócenie wartości liczbowych wprawia niestety w zakłopotanie. Gdy mówi się, że proces ma „wyższy priorytet", oznacza to, że częściej zostaje wybrany do uruchomienia i może działać dłużej niż procesy niskopriorytetowe. Taki proces posiada jednak niższy poziom uprzejmości.

nice()

Linux dostarcza kilka funkcji systemowych w celu odczytania oraz ustawienia poziomu uprzejmości dla procesu. Najprostszą z nich jest funkcja `nice()`:

```
#include <unistd.h>
int nice (int inc);
```

Udane wywołanie funkcji `nice()` zwiększa poziom uprzejmości procesu o liczbę przekazaną przez parametr `inc` oraz zwraca uaktualnioną wartość. Tylko proces z uprawnieniami `CAP_SYS_NICE` (w rzeczywistości proces, którego właścicielem jest administrator) może przekazywać ujemną wartość w parametrze `inc`, zmniejszając swój poziom uprzejmości i przez to zwiększając swój priorytet. Zgodnie z tym procesy niebędące procesami należącymi do administratora mogą jedynie obniżać swój priorytet (poprzez zwiększanie swojego poziomu uprzejmości).

W przypadku błędu wykonania `nice()` zwraca wartość `-1`. Ponieważ jednak `nice()` zwraca nową wartość poziomu uprzejmości, `-1` jest równocześnie poprawną wartością zwrotną. Aby odróżnić poprawne wywołanie od błędnego, można wyzerować wartość `errno` przed wykonaniem wywołania, a następnie ją sprawdzić. Na przykład:

```
int ret;

errno = 0;
ret = nice (10); /* zwiększ nasz poziom uprzejmości o 10 */
if (ret == -1 && errno != 0)
   perror ("nice");
else
   printf ("Poziom uprzejmości wynosi aktualnie %d\n", ret);
```

Linux zwraca tylko jeden kod błędu: `EPERM`, informując, iż proces wywołujący spróbował zwiększyć swój priorytet (poprzez ujemną wartość parametru `inc`), lecz nie posiadał uprawnienia `CAP_SYS_NICE`. Inne systemy zwracają również kod błędu `EINVAL`, gdy `inc` próbuje ustalić nową wartość poziomu uprzejmości poza dopuszczalnym zakresem, lecz Linux tego nie robi. Zamiast tego Linux zaokrągla niewłaściwe wartości `inc` w razie potrzeby w górę lub w dół do wielkości będącej odpowiednią granicą dopuszczalnego zakresu.

Przekazanie zera w parametrze `inc` jest prostym sposobem na uzyskanie aktualnej wartości poziomu uprzejmości:

```
printf ("Poziom uprzejmości wynosi obecnie %d\n", nice (0));
```

Często proces chce ustawić bezwzględną wartość poziomu uprzejmości, zamiast przekazywać względną wielkość różnicy. Można to uzyskać poprzez wykonanie poniższego kodu:

```
int ret, val;

/* pobierz aktualną wartość poziomu uprzejmości */
val = nice (0);

/* chcemy ustawić poziom uprzejmości na 10 */
val = 10 - val;
errno = 0;
ret = nice (val);
if (ret == -1 && errno != 0)
   perror ("nice");
else
   printf ("Poziom uprzejmości wynosi aktualnie %d\n", ret);
```

getpriority() i setpriority()

Preferowanym rozwiązaniem jest użycie funkcji systemowych `getpriority()` oraz `setpriority()`, które udostępniają więcej możliwości kontroli, lecz są bardziej złożone w działaniu:

```
#include <sys/time.h>
#include <sys/resource.h>

int getpriority (int which, int who);
int setpriority (int which, int who, int prio);
```

Funkcje te działają na procesie, grupie procesów lub użytkowniku, co odpowiednio ustalają parametry `which` oraz `who`. Parametr `which` musi posiadać jedną z następujących wartości: `PRIO_PROCESS`, `PRIO_PGRP` lub `PRIO_USER`; w tym przypadku parametr `who` określa odpowiednio identyfikator procesu, identyfikator grupy procesów lub identyfikator użytkownika.

Wywołanie funkcji `getpriority()` zwraca najwyższy priorytet (najniższą liczbową wartość poziomu uprzejmości) dla każdego z podanych procesów. Wywołanie funkcji `setpriority()` ustawia priorytet wszystkich podanych procesów na wartość `prio`. Podobnie jak w przypadku funkcji `nice()`, tylko proces posiadający uprawnienia `CAP_SYS_NICE` może zwiększyć priorytet

procesu (zmniejszyć liczbową wartość poziomu uprzejmości). Co więcej, tylko proces z tym uprawnieniem może zwiększyć lub zmniejszyć priorytet procesu niebędącego w posiadaniu przez wywołującego go użytkownika.

Podobnie jak `nice()`, również `getpriority()` zwraca `-1` w przypadku błędu. Ponieważ jest to również poprawna wartość zwrotna, programiści powinni zerować `errno` przed wywołaniem funkcji, jeśli zamierzają obsługiwać przypadki błędów. Wywołanie `setpriority()` nie powoduje takich problemów —`setpriority()` zawsze zwraca `0` w przypadku powodzenia, natomiast `-1` w przypadku niepowodzenia.

Następujący kod zwraca aktualną wartość priorytetu procesu:

```
int ret;
ret = getpriority (PRIO_PROCESS, 0);
printf ("Poziom uprzejmości wynosi %d\n", ret);
```

Poniższy kod ustawia priorytet dla wszystkich procesów z aktualnej grupy procesów na wartość 10:

```
int ret;
ret = setpriority (PRIO_PGRP, 0, 10);
if (ret == -1)
   perror ("setpriority");
```

W przypadku błędu obie funkcje ustawiają `errno` na jedną z poniższych wartości:

`EACCES`
: Proces zamierzał zwiększyć priorytet, lecz nie posiada uprawnienia `CAP_SYS_NICE` (tylko dla `setpriority()`).

`EINVAL`
: Wartość przekazana przez parametr `which` nie była jedną z następujących: `PRIO_PROCESS`, `PRIO_PGRP` lub `PRIO_USER`.

`EPERM`
: Efektywny identyfikator użytkownika procesu branego pod uwagę nie zgadza się z efektywnym identyfikatorem użytkownika procesu działającego; proces działający dodatkowo nie posiada uprawnienia `CAP_SYS_NICE` (tylko dla `setpriority()`).

`ESRCH`
: Nie znaleziono procesu spełniającego wymagań, które zostały określone przez parametry `which` oraz `who`.

Priorytety wejścia i wyjścia

W ramach dodatku do priorytetów szeregowania Linux pozwala procesom określić *priorytety wejścia i wyjścia*. Ta wartość wpływa na względny priorytet żądań wejścia i wyjścia dla procesów. Zarządca wejścia i wyjścia z jądra systemu (omówiony w rozdziale 4.) obsługuje żądania pochodzące z procesów o wyższym priorytecie wejścia i wyjścia przed żądaniami z procesów o niższym priorytecie wejścia i wyjścia.

Zarządcy wejścia i wyjścia domyślnie wykorzystują poziom uprzejmości procesu, aby ustalić priorytet wejścia i wyjścia. Dlatego też ustawienie poziomu uprzejmości automatycznie zmienia priorytet wejścia i wyjścia. Jądro Linuksa dostarcza jednakże dodatkowo dwóch funkcji systemowych, w celu jawnego ustawienia i uzyskania informacji dotyczących priorytetu wejścia i wyjścia, niezależnie od wartości poziomu uprzejmości:

```
int ioprio_get (int which, int who)
int ioprio_set (int which, int who, int ioprio)
```

Niestety biblioteka *glibc* nie umożliwia żadnego dostępu do tych funkcji z poziomu użytkownika. Bez wsparcia przez *glibc* używanie ich jest w najlepszym przypadku niewygodne. Co więcej, w momencie, gdy biblioteka *glibc* zacznie udzielać wsparcia, może zdarzyć się, iż jej interfejs nie będzie kompatybilny z tymi funkcjami. Dopóki nie ma takiego wsparcia, istnieją dwa przenośne sposoby pozwalające modyfikować priorytety wejścia i wyjścia: poprzez poziomy uprzejmości lub program użytkowy o nazwie *ionice*, który jest składnikiem pakietu *util-linux*[1].

Nie wszyscy zarządcy wejścia i wyjścia wspierają priorytety wejścia i wyjścia. Wyjątkiem jest zarządca wejścia i wyjścia o nazwie *Complete Fair Queuing* (CFQ); inni typowi zarządcy aktualnie nie posiadają wsparcia dla priorytetów wejścia i wyjścia. W przypadku, gdy dany zarządca wejścia i wyjścia nie wspiera priorytetów wejścia i wyjścia, są one przez niego milcząco pomijane.

Wiązanie procesów do konkretnego procesora

Linux wspiera wieloprocesorowość dla pojedynczego systemu. Poza procesem ładowania systemu większość pracy niezbędnej dla zapewnienia poprawnego działania systemu wieloprocesorowego zrzucona jest na zarządcę procesów. Na maszynie wieloprocesorowej zarządca procesów musi decydować, który proces powinien uruchamiać na każdym procesorze.

Z tej odpowiedzialności wynikają dwa wyzwania: zarządca musi dążyć do tego, aby w pełni wykorzystywać wszystkie procesory w systemie, ponieważ sytuacja, gdy procesor jest nieobciążony, a proces oczekuje na uruchomienie, prowadzi do nieefektywnego działania. Gdy jednak proces został zaszeregowany dla określonego procesora, zarządca procesów powinien dążyć, aby szeregować go do tego samego procesora również w przyszłości. Jest to korzystne, gdyż *migracja* procesu z jednego procesora do innego pociąga za sobą pewne koszty.

Największa część tych kosztów dotyczy *skutków buforowania* (ang. *cache effects*) podczas migracji. Z powodu określonych konstrukcji nowoczesnych systemów SMP większość pamięci podręcznych przyłączonych do każdego procesora jest niezależna i oddzielona od siebie. Oznacza to, że dane z jednej pamięci podręcznej nie powielają się w innej. Dlatego też, jeśli proces przenosi się do nowego procesora i zapisuje nowe informacje w pamięci, dane w pamięci podręcznej poprzedniego procesora mogą stracić aktualność. Poleganie na tej pamięci podręcznej może wówczas spowodować uszkodzenie danych. Aby temu przeciwdziałać, pamięci podręczne *unieważniają* każde inne dane, ilekroć buforują nowy fragment pamięci. Zgodnie z tym określony fragment danych znajduje się dokładnie tylko w jednej pamięci podręcznej procesora w danym momencie (zakładając, że dane są w ogóle buforowane). Gdy proces przenosi się z jednego procesora do innego, pociąga to za sobą następujące koszty: dane buforowane nie są już dostępne dla procesu, który się przeniósł, a dane w źródłowym procesorze muszą być unieważnione. Z powodu tych kosztów zarządca procesów próbuje utrzymać proces na określonym procesorze tak długo, jak to jest możliwe.

Dwa cele zarządcy procesów są oczywiście potencjalnie sprzeczne ze sobą. Jeśli jeden procesor jest znacząco bardziej obciążony niż drugi albo, co gorsza, jeśli jeden procesor jest całkowicie zajęty, podczas gdy drugi jest bezczynny, wówczas zaczyna mieć sens przeszeregowanie

[1] Pakiet *util-linux* jest osiągalny pod adresem *http://kernel.org*. Jest on licencjonowany zgodnie z Powszechną Licencją Publiczną GNU w wersji 2.

niektórych procesów do procesora mniej obciążonego. Decyzja, kiedy należy przenieść procesy w przypadku takiego braku równowagi, zwana *wyrównywaniem obciążenia*, odgrywa bardzo ważną rolę w wydajności maszyn SMP.

Wiązanie procesów dla konkretnego procesora odnosi się do prawdopodobieństwa, że proces zostanie konsekwentnie zaszeregowany do tego samego procesora. Termin *miękkie wiązanie* (ang. *soft affinity*) określa naturalną skłonność zarządcy, aby kontynuować szeregowanie procesu na tym samym procesorze. Jak już powiedziano, jest to wartościowa cecha. Zarządca linuksowy szereguje te same procesy na tych samych procesorach przez tak długi czas, jak to jest możliwe, przenosząc proces z jednego procesora na inny jedynie w przypadku wyjątkowego braku równowagi. Pozwala to zarządcy zmniejszać skutki buforowania w przypadku migracji procesów i zapewnia, że wszystkie procesory w systemie są równo obciążone.

Czasami jednak użytkownik lub aplikacja chcą wymusić powiązanie proces-procesor. Dzieje się tak często, gdy sam proces jest wrażliwy na buforowanie i wymaga pozostawienia go na tym samym procesorze. Wiązanie procesu do konkretnego procesora, które zostaje wymuszone przez jądro systemu, nazywa się *twardym wiązaniem* (ang. *hard affinity*).

sched_getaffinity() i sched_setaffinity()

Procesy dziedziczą wiązania do procesora od swych rodziców, a także — domyślnie — mogą działać na dowolnym procesorze. Linux udostępnia dwie funkcje systemowe pozwalające na odczytanie oraz ustawienie twardego wiązania dla procesu:

```
#define _GNU_SOURCE
#include <sched.h>

typedef struct cpu_set_t;

size_t CPU_SETSIZE;

void CPU_SET (unsigned long cpu, cpu_set_t *set);
void CPU_CLR (unsigned long cpu, cpu_set_t *set);
int CPU_ISSET (unsigned long cpu, cpu_set_t *set);
void CPU_ZERO (cpu_set_t *set);

int sched_setaffinity (pid_t pid, size_t setsize, const cpu_set_t *set);

int sched_getaffinity (pid_t pid, size_t setsize, cpu_set_t *set);
```

Wywołanie funkcji `sched_getaffinity()` odczytuje wiązanie do procesora dla procesu o identyfikatorze `pid` i zapisuje go w zmiennej specjalnego typu `cpu_set_t`, która jest dostępna poprzez specyficzne makra. Jeśli `pid` jest równe zeru, funkcja zwraca wiązanie dla aktualnego procesu. Parametr `setsize` określa rozmiar typu `cpu_set_t`, który może być używany przez *glibc* dla potrzeb kompatybilności z przyszłymi modyfikacjami dotyczącymi rozmiaru tego typu. W przypadku sukcesu `sched_getaffinity()` zwraca `0`; w przypadku błędu zwraca `-1` oraz ustawia `errno`. Oto przykład:

```
cpu_set_t set;
int ret, i;

CPU_ZERO (&set);
ret = sched_getaffinity (0, sizeof (cpu_set_t), &set);
if (ret == -1)
   perror ("sched_getaffinity");
```

```
for (i = 0; i < CPU_SETSIZE; i++)
{
   int cpu;

   cpu = CPU_ISSET (i, &set);
   printf ("procesor = %i jest %s\n", i, cpu ? "ustawiony" : "wyzerowany");
}
```

Na początku kodu następuje użycie makra `CPU_ZERO`, by wyzerować wszystkie bity w zmiennej `set`. W dalszej części przeprowadzana jest iteracja w pętli po wszystkich elementach tej zmiennej. Ważne jest to, iż `CPU_SETSIZE` nie jest rozmiarem zmiennej `set` (*nigdy* nie należy używać tej wartości w `setsize`!), lecz liczbą procesorów, które mogłyby być potencjalnie reprezentowane przez `set`. Ponieważ aktualna implementacja definiuje przedstawienie każdego procesora jako jeden bit, `CPU_SETSIZE` jest dużo większe niż `sizeof(cpu_set_t)`. `CPU_ISSET` jest używane, aby sprawdzić, czy dany procesor o numerze `i` jest związany (albo nie) z danym procesem. Makro zwraca zero, gdy nie jest związany, lub wartość niezerową, gdy jest związany.

Tylko procesory zainstalowane fizycznie w systemie są rozpoznawane jako związane. Dlatego też powyższy fragment kodu uruchomiony w systemie z dwoma procesorami zwróci następujący wynik:

```
procesor = 0 jest ustawiony
procesor = 1 jest ustawiony
procesor = 2 jest wyzerowany
procesor = 3 jest wyzerowany
...
procesor = 1023 jest wyzerowany
```

Jak wynika z rezultatów zadziałania kodu, wartość `CPU_SETSIZE` (o indeksie rozpoczynającym się od zera) wynosi aktualnie `1024`.

W przykładzie mieliśmy do czynienia wyłącznie z procesorem nr 0 i 1, ponieważ są to jedyne obecne fizycznie procesory w systemie. Być może zaistnieje potrzeba, aby zapewnić konfigurację, w której dany proces działa wyłącznie na procesorze o numerze 0, a w ogóle nie działa na procesorze o numerze 1. To zadanie realizuje poniższy kod:

```
cpu_set_t set;
int ret, i;

CPU_ZERO (&set); /* wyzeruj struktury dla wszystkich procesorów */
CPU_SET (0, &set); /* zezwól na procesor 0 */
CPU_CLR (1, &set); /* zablokuj procesor 1 */
ret = sched_setaffinity (0, sizeof (cpu_set_t), &set);
if (ret == -1)
   perror ("sched_setaffinity");

for (i = 0; i < CPU_SETSIZE; i++)
{
   int cpu;

   cpu = CPU_ISSET (i, &set);
   printf ("procesor = %i jest %s\n", i, cpu ? "ustawiony" : "wyzerowany");
}
```

Program rozpoczyna się, jak zawsze, od zerowania zmiennej `set` za pomocą makra `CPU_ZERO`. Następnie ustawia się procesor 0 przy użyciu `CPU_SET` oraz zeruje procesor 1 przy użyciu `CPU_CLR`. Operacja `CPU_CLR` jest nadmiarowa, gdyż wcześniej już wyzerowano całą strukturę `set`; jest ona jednak użyta, aby zapewnić kompletność kodu.

Uruchomienie tego programu na tym samym dwuprocesorowym systemie zakończy się trochę innymi niż poprzednio wynikami:

```
procesor = 0 jest ustawiony
procesor = 1 jest wyzerowany
procesor = 2 jest wyzerowany
...
procesor = 1023 jest wyzerowany
```

Obecnie procesor 1 jest wyzerowany. Proces będzie działać wyłącznie na procesorze 0, bez względu na wszystko!

Możliwe są cztery wartości `errno`:

`EFAULT`
: Dostarczony wskaźnik znajdował się poza przestrzenią adresową procesu lub był ogólnie nieprawidłowy.

`EINVAL`
: W tym przypadku w systemie nie istniały fizycznie procesory, które zostały odblokowane w zmiennej `set` (tylko dla `sched_setaffinity()`) lub też `setsize` było mniejsze niż rozmiar wewnętrznej struktury danych jądra użytej w celu reprezentacji zbioru procesorów.

`EPERM`
: Proces reprezentowany przez `pid` nie zgadza się z aktualnym efektywnym identyfikatorem użytkownika procesu wywołującego; proces dodatkowo nie posiada uprawnienia `CAP_SYS_NICE`.

`ESRCH`
: Nie znaleziono procesu posiadającego identyfikator `pid`.

Systemy czasu rzeczywistego

W systemach komputerowych termin *czas rzeczywisty* (ang. *real-time*) jest często powodem pewnego zamieszania i niezrozumienia. System jest systemem czasu rzeczywistego, jeśli jego parametry mieszczą się w zakresie *granicznych parametrów operacyjnych* (ang. *operational deadlines*): czasach reakcji — minimalnym oraz narzuconym — pomiędzy zdarzeniem i odpowiedzią na to zdarzenie. Znanym systemem czasu rzeczywistego jest ABS (ang. *antilock braking system*), spotykany obecnie w prawie wszystkich nowoczesnych samochodach. W tym systemie, jeśli nastąpi rozpoczęcie procesu hamowania, komputer zaczyna odpowiednio regulować docisk hamulców, impulsowo zwiększając go do maksimum i następnie zmniejszając wiele razy na sekundę. Chroni to koła przed zablokowaniem, które mogłoby spowodować pogorszenie warunków hamowania lub nawet wprowadzić samochód w niekontrolowany poślizg. W takim układzie granicznymi parametrami operacyjnymi są: szybkość reakcji systemu na stan zablokowania koła oraz szybkość uzyskania przez system określonego nacisku w hamulcach.

Większość nowoczesnych systemów operacyjnych, także Linux, zapewnia pewien poziom wsparcia dla operacji czasu rzeczywistego.

Systemy ścisłego oraz zwykłego czasu rzeczywistego

Systemy czasu rzeczywistego dzielą się na: systemy ścisłego czasu rzeczywistego oraz zwykłego czasu rzeczywistego. *System ścisłego czasu rzeczywistego* (ang. *hard real-time system*) wymaga dokładnego przestrzegania granicznych parametrów operacyjnych. Przekroczenie tych parametrów

prowadzi do błędu i jest bardzo poważnym problemem. Z drugiej strony, dla *systemu zwykłego czasu rzeczywistego* (ang. *soft real-time system*) przekroczenie granicznych parametrów operacyjnych nie jest błędem krytycznym.

Aplikacje działające w systemach ścisłego czasu rzeczywistego są łatwe do wykrycia: należą do nich systemy ABS, wojskowe systemy obronne, urządzenia medyczne oraz generalnie przetwarzanie sygnałów. Aplikacje zwykłego czasu rzeczywistego nie zawsze można łatwo zidentyfikować. Jednym z oczywistych elementów tej grupy są aplikacje przetwarzające dane wideo: użytkownik zauważa chwilowe pogorszenie jakości, gdy graniczne parametry operacyjne są przekroczone, lecz tych kilka pominiętych ramek obrazu może być w tym momencie tolerowane.

Wiele innych aplikacji posiada ograniczenia czasowe, które (jeśli nie są przestrzegane) pogarszają wrażenia użytkownika. Przykładami są tu aplikacje multimedialne, gry oraz programy sieciowe. A co z edytorami tekstu? Jeśli program nie może szybko reagować na naciśnięcia klawiszy, odpowiedź użytkownika na to zjawisko jest negatywna. Czy jest to więc aplikacja zwykłego czasu rzeczywistego? Oczywiście, gdy projektanci tworzyli tę aplikację, zdawali sobie sprawę, iż reakcja na naciskanie klawiszy musi być możliwie szybka i determinowana czasowo. Ale czy jest to już granicznym parametrem operacyjnym? Granica pomiędzy systemami zwykłego czasu rzeczywistego a systemami standardowymi nie jest wyraźna.

W przeciwieństwie do powszechnego przekonania system czasu rzeczywistego nie musi być szybki. Jeśli uwzględni się porównywalny sprzęt, można stwierdzić, że system czasu rzeczywistego jest prawdopodobnie wolniejszy niż zwykły system, co najmniej z powodu zwiększonego nakładu pracy na wsparcie procesów czasu rzeczywistego. Ponadto, podział pomiędzy systemami ścisłego i zwykłego czasu rzeczywistego nie zależy od wielkości granicznych parametrów operacyjnych. Reaktor atomowy przegrzeje się, jeśli system zabezpieczający przed przegrzaniem nie opuści prętów kontrolnych w ciągu kilku sekund po wykryciu nadmiernego strumienia neutronów. Jest to system ścisłego czasu rzeczywistego ze stosunkowo długim czasem (jak na komputery) parametru granicznego. Przeciwnie, odtwarzacz wideo może opuścić ramkę obrazu lub przerwać dźwięk, jeśli bufor odtwarzania nie będzie wypełniony w ciągu 100 milisekund. Jest to system zwykłego czasu rzeczywistego z krytycznym parametrem granicznym.

Opóźnienie, rozsynchronizowanie oraz parametry graniczne

Termin *opóźnienie* (ang. *latency*) odnosi się do okresu między wystąpieniem zdarzenia a momentem reakcji na to zdarzenie. Jeśli opóźnienie jest mniejsze lub równe wartości parametru granicznego, system działa poprawnie. W wielu systemach ścisłego czasu rzeczywistego operacyjny parametr graniczny oraz opóźnienie są sobie równe — system obsługuje zdarzenia w ściśle ustalonych przedziałach czasowych, w określonych momentach. W systemach zwykłego czasu rzeczywistego żądany czas odpowiedzi jest mniej dokładny i opóźnienie wykazuje pewien rodzaj rozbieżności — należy dążyć do tego, aby odpowiedź mieściła się w zakresie założonego parametru granicznego.

Pomiar opóźnienia jest często trudny, gdyż jego obliczenie wymaga danych na temat czasu, kiedy nastąpiło zdarzenie. Zdolność do oznaczenia dokładnego momentu wystąpienia zdarzenia często jednak pogarsza zdolność poprawnej reakcji na niego. Dlatego też wiele metod obliczania opóźnienia nie działa w ten sposób: zamiast tego mierzy się odchylenie synchronizacji pomiędzy odpowiedziami na zdarzenia. Odchylenie synchronizacji pomiędzy kolejnymi zdarzeniami nazywane jest *rozsynchronizowaniem* (ang. *jitter*), a nie opóźnieniem.

Na przykład, można rozważyć zdarzenie występujące co 10 milisekund. Aby uzyskać charakterystykę sprawności w takim systemie, należałoby mierzyć czasy wystąpień odpowiedzi na te zdarzenia, by upewnić się, że występują faktycznie co 10 milisekund. Odchylenie od tej wartości nie jest jednak opóźnieniem, lecz rozsynchronizowaniem. To, co jest mierzone, jest rozbieżnością kolejnych odpowiedzi. Bez wiedzy o tym, kiedy wystąpiło zdarzenie, nie można znać rzeczywistej różnicy czasu pomiędzy zdarzeniem a odpowiedzią na nie. Nawet wiedząc, że zdarzenie występuje co 10 milisekund, nie ma się pewności, kiedy nastąpił *pierwszy* przypadek tego zdarzenia. Być może jest to zaskakujące, ale wiele metod pomiaru opóźnienia działa błędnie i zwraca wartość rozsynchronizowania, a nie opóźnienia. Oczywiście rozsynchronizowanie to też użyteczny parametr i takie pomiary na pewno są przydatne. Mimo to należy nazywać rzeczy po imieniu!

Systemy ścisłego czasu rzeczywistego często wykazują bardzo małe rozsynchronizowanie, ponieważ odpowiadają na zdarzenie po, a *nie w zakresie* określonego przedziału czasowego. Takie systemy dążą do wartości rozsynchronizowania równej zeru, a opóźnienie równe jest czasowi granicznego opóźnienia operacyjnego. Jeśli to opóźnienie przekracza graniczną wartość opóźnienia operacyjnego, system przestaje działać.

Systemy zwykłego czasu rzeczywistego są bardziej wrażliwe na opóźnienia. W nich czas odpowiedzi znajduje się dokładnie w zakresie dopuszczalnej wartości opóźnienia operacyjnego — nierzadko jest krótszy, czasami dłuższy. W pomiarach sprawności systemu wartość rozsynchronizowania jest często doskonałym zamiennikiem dla parametru opóźnienia.

Obsługa czasu rzeczywistego przez system Linux

Linux umożliwia aplikacjom korzystanie ze wsparcia dla systemu zwykłego czasu rzeczywistego poprzez rodzinę funkcji systemowych zdefiniowanych przez *IEEE Std 1003.1b-1993* (nazwa często jest skracana do *POSIX 1993* lub *POSIX.1b*).

Mówiąc językiem technicznym, standard POSIX nie wymusza tego, by udostępniany system czasu rzeczywistego był zwykły lub ścisły. W rzeczywistości to, co naprawdę robi standard POSIX, jest opisem kilku strategii szeregowania, które biorą pod uwagę priorytety. Od projektantów systemu operacyjnego zależy to, jakie metody ograniczeń czasowych zostaną wymuszone przez system dla tych strategii.

Przez lata jądro Linuksa ulepszało swoje wsparcie dla systemu czasu rzeczywistego, dostarczając coraz mniejsze opóźnienia oraz bardziej spójną wartość rozsynchronizowania, przy jednocześnie niezmniejszonej wydajności systemu. Zawdzięczamy te zmiany w większości temu, iż poprawienie opóźnienia wpłynęło pozytywnie na działanie wielu innych grup aplikacji, na przykład procesów powiązanych ze środowiskiem graficznym czy też wejściem i wyjściem, a nie wyłącznie samych aplikacji czasu rzeczywistego. Ulepszenia związane są także z sukcesem Linuksa na polu systemów *wbudowanych* (ang. *embedded*) oraz systemów czasu rzeczywistego.

Niestety wiele z tych modyfikacji, które zostały wprowadzone w jądrze Linuksa dla celów systemów wbudowanych oraz czasu rzeczywistego, istnieje tylko w niestandardowych rozwiązaniach, poza podstawową i oficjalną wersją jądra. Niektóre z tych ulepszeń zapewniają dalsze ograniczenia opóźnienia, a nawet zachowanie charakterystyczne dla systemów ścisłego czasu rzeczywistego. W kolejnych podrozdziałach omówione zostaną tylko oficjalne interfejsy oraz zachowanie standardowego jądra. Na szczęście większość zmian dotyczących wspierania czasu rzeczywistego opiera się w dalszym ciągu na interfejsach POSIX. Zatem dalsze dyskusje odnoszą się również do systemów zmodyfikowanych.

Linuksowe strategie szeregowania i ustalania priorytetów

Zachowanie zarządcy Linuksa w odniesieniu do procesu zależy od *strategii szeregowania* (ang. *scheduling policy*) dla tego procesu, zwanej również *klasą szeregowania* (ang. *scheduling class*). Jako uzupełnienie zwykłej, domyślnej strategii Linux dostarcza dwie strategie szeregowania dla czasu rzeczywistego. Makra preprocesora z pliku nagłówka `<sched.h>` reprezentują każdą z tych strategii i zwane są `SCHED_FIFO`, `SCHED_RR` oraz `SCHED_OTHER`.

Każdy proces posiada *priorytet statyczny* (ang. *static priority*), niezależny od wartości poziomu uprzejmości. Dla zwykłych aplikacji priorytet ten jest zawsze równy zeru. Dla procesów czasu rzeczywistego wynosi on od 1 do 99 włącznie. Linuksowy zarządca zawsze wybiera proces o najwyższym priorytecie, aby go uruchomić (tzn. ten, który posiada priorytet statyczny posiadający największą wartość liczbową). Jeśli proces działa z wartością priorytetu statycznego równą 50, a kolejny proces o priorytecie 51 staje się uruchamialny, zarządca natychmiast wykonuje przeszeregowanie poprzez przełączenie się na tenże uruchamialny proces. I odwrotnie, jeśli w systemie działa już proces o priorytecie 50, a proces o priorytecie 49 staje się uruchamialny, zarządca nie uruchomi go, dopóki proces o priorytecie 50 nie zablokuje się, czyli przestanie działać. Ponieważ normalne procesy mają priorytet 0, każdy proces czasu rzeczywistego, który jest uruchamialny, zawsze wywłaszczy zwykły proces i zacznie działać.

Strategia FIFO (first in, first out)

Klasa „pierwszy na wejściu, pierwszy na wyjściu” (ang. *first in, first out class*), inaczej zwana też *klasą FIFO* (ang. *FIFO class*), jest bardzo prostą strategią czasu rzeczywistego bez przedziałów czasowych. Proces z klasy FIFO będzie działać tak długo, jak długo nie będzie istnieć żaden inny proces o większym priorytecie. Klasa FIFO jest opisywana przez makro `SCHED_FIFO`.

Ponieważ ta strategia nie używa przedziałów czasowych, zasady działań są raczej proste:

- Proces uruchamialny klasy FIFO będzie zawsze działać, jeśli jest procesem o najwyższym priorytecie w systemie. Gdy tylko proces klasy FIFO stanie się uruchamialny, od razu wywłaszczy proces zwykły.
- Proces klasy FIFO będzie kontynuować swoje działanie, dopóki się nie zablokuje lub wywoła `sched_yield()` albo dopóki proces o wyższym priorytecie nie stanie się uruchamialny.
- Gdy proces klasy FIFO zablokuje się, zarządca usunie go z listy procesów uruchamialnych. Gdy znów staje się on uruchamialny, jest umieszczany na końcu listy procesów odpowiadającej jego priorytetowi. Dlatego też nie będzie on uaktywniony, dopóki wszystkie inne procesy o wyższym lub *równym* priorytecie nie przerwą swojego działania.
- Gdy proces klasy FIFO wywoła funkcję `sched_yield()`, zarządca przesunie go na koniec listy procesów odpowiadającej jego priorytetowi. Dlatego też nie będzie on uruchomiony, dopóki wszystkie inne procesy o równym jemu priorytecie nie zakończą swego działania. Jeśli proces wywołujący funkcję `sched_yield()` będzie jedynym procesem posiadającym taki priorytet, wywołanie tej funkcji systemowej nie odniesie żadnego skutku.
- Gdy proces o wyższym priorytecie wywłaszczy proces klasy FIFO, pozostanie on na takiej samej pozycji w liście procesów odpowiadającej jego priorytetowi. Zatem gdy proces o wyższym priorytecie zostanie zawieszony, wywłaszczony proces klasy FIFO będzie mógł w dalszym ciągu kontynuować swoje działanie.

- Gdy proces przystępuje do klasy FIFO lub gdy priorytet statyczny procesu zmienia się, jest on umieszczany na początku listy procesów pasującej do jego priorytetu. W rezultacie proces klasy FIFO otrzymujący nowy priorytet może wywłaszczyć inny działający proces posiadający ten sam priorytet.

Zasadniczo można powiedzieć, iż procesy klasy FIFO działają tak długo, jak chcą, dopóki są procesami posiadającymi najwyższy priorytet w systemie. Ciekawe reguły dotyczą natomiast tych procesów klasy FIFO, które posiadają identyczne priorytety.

Strategia cykliczna

Klasa cykliczna (ang. *round-robin class*) jest identyczną klasą jak FIFO, z wyjątkiem tego, że posiada dodatkowe reguły w przypadku zarządzania procesami o takim samym priorytecie. Klasa cykliczna jest opisywana przez makro `SCHED_RR`.

Zarządca przypisuje każdemu procesowi klasy cyklicznej przedział czasowy. Gdy proces klasy cyklicznej wykorzysta swój przedział czasu, zarządca przesuwa go na koniec listy procesów odpowiadającej jego priorytetowi. W ten sposób procesy klasy cyklicznej, posiadające dany priorytet, są regularnie szeregowane w pętli. Jeśli istnieje tylko jeden proces o danym priorytecie, wówczas klasa cykliczna działa identycznie jak klasa FIFO. W takim przypadku, gdy przedział czasowy ulegnie zużyciu, proces po prostu wznawia swoje działanie.

Można uważać proces klasy cyklicznej za identyczny do klasy FIFO, z wyjątkiem tego, iż dodatkowo wstrzymuje on swoje działanie, gdy zużyje przedział czasowy należący do niego, kiedy jest przenoszony na koniec listy procesów odpowiadającej jego priorytetowi.

Decyzja, czy należy użyć klasy `SCHED_FIFO` lub `SCHED_RR` jest kwestią dotyczącą zachowania się samych priorytetów. Przedziały czasowe klasy cyklicznej mają znaczenie tylko pomiędzy procesami o takim samym priorytecie. Procesy klasy FIFO będą działać niezagrożone; procesy klasy cyklicznej będą wywłaszczać się pomiędzy sobą w przypadku wystąpień takich samych priorytetów. W żadnym przypadku proces o mniejszym priorytecie nie będzie mógł zostać uruchomiony, gdy działa proces o wyższym priorytecie.

Strategia zwykła

Makro `SCHED_OTHER` opisuje standardową strategię szeregowania, będącą domyślną strategią dla klasy niespełniającej wymagań czasu rzeczywistego. Wszystkie procesy *klasy zwykłej* (ang. *normal class*) posiadają priorytet statyczny równy zeru. Dlatego też każdy uruchamialny proces należący do klasy FIFO lub klasy cyklicznej będzie wywłaszczać proces działający w klasie normalnej.

Zarządca używa poziomów uprzejmości, aby ustalać priorytety procesów wewnątrz klasy zwykłej. Poziom uprzejmości nie oddziałuje na priorytet statyczny, który dla tej klasy pozostaje zawsze równy zeru.

Strategia szeregowania wsadowego

Makro `SCHED_BATCH` opisuje *strategię szeregowania wsadowego* (ang. *batch scheduling policy*), inaczej zwaną też *strategią jałowego szeregowania* (ang. *idle scheduling policy*). Jej zachowanie jest jakby przeciwieństwem strategii czasu rzeczywistego: procesy należące do tej klasy mogą działać tylko wtedy, gdy nie istnieją żadne inne uruchamialne procesy w systemie, nawet jeśli te procesy wykorzystały już swoje przedziały czasowe. Różni się to od zachowania w przypadku procesów

z największymi wartościami poziomów uprzejmości (tzn. procesów o najniższych priorytetach) — te procesy w końcu zaczną działać, gdy procesy o wyższych priorytetach wykorzystają swoje przedziały czasowe.

Ustalanie strategii szeregowania dla systemu Linux

Procesy mogą zmieniać strategię szeregowania Linuksa poprzez wywołanie funkcji systemowych `sched_getscheduler()` oraz `sched_setscheduler()`:

```
#include <sched.h>

struct sched_param
{
   /* ... */
   int sched_priority;
   /* ... */
};
int sched_getscheduler (pid_t pid);
int sched_setscheduler (pid_t pid, int policy, const struct sched_param *sp);
```

Poprawne wywołanie funkcji `sched_getscheduler()` odczytuje strategię szeregowania dla procesu określonego poprzez parametr `pid`. Jeśli `pid` wynosi `0`, funkcja zwraca strategię szeregowania dla procesu ją wywołującego. Liczba całkowita zdefiniowana w *<sched.h>* opisuje strategię szeregowania: strategia FIFO określona jest przez `SCHED_FIFO`, strategia cykliczna przez `SCHED_RR`, a strategia normalna przez `SCHED_OTHER`. W przypadku błędu funkcja zwraca `-1` (co nie jest żadną poprawną wartością strategii szeregowania) i odpowiednio ustawia `errno`.

Użycie tej funkcji jest proste:

```
int policy;
/* pobierz strategię szeregowania */
policy = sched_getscheduler (0);
switch (policy)
{
   case SCHED_OTHER:
      printf ("Strategia normalna\n");
      break;
   case SCHED_RR:
      printf ("Strategia cykliczna\n");
      break;
   case SCHED_FIFO:
      printf ("Strategia FIFO\n");
      break;
   case -1:
      perror ("sched_getscheduler");
      break;
   default:
      fprintf (stderr, "Strategia nieznana!\n");
}
```

Wywołanie funkcji `sched_setscheduler()` ustawia strategię szeregowania dla procesu wskazanego przez `pid` na strategię o wartości przekazanej w parametrze `policy`. Dodatkowe parametry związane ze strategią ustawiane są poprzez parametr `sp`. W przypadku poprawnego wywołania funkcja zwraca `0`, natomiast w przypadku błędu zwraca `-1` oraz odpowiednio ustawia `errno`.

Poprawność pól wewnątrz struktury `sched_param` zależy od strategii szeregowania zapewnianych przez system operacyjny. Strategie `SCHED_RR` oraz `SCHED_FIFO` wymagają jednego pola — `sched_priority`, które reprezentuje priorytet statyczny. `SCHED_OTHER` nie używa żad-

nego pola, natomiast strategie, które mogą zostać użyte w przyszłości, będą być może wymagać nowych pól. Dlatego też przenośne i poprawne programy nie mogą czynić żadnych założeń dotyczących formatu tej struktury.

Ustawianie strategii oraz parametrów szeregowania dla procesu jest proste:

```
struct sched_param sp = { .sched_priority = 1 };
int ret;

ret = sched_setscheduler (0, SCHED_RR, &sp);
if (ret == -1)
{
   perror ("sched_setscheduler");
   return 1;
}
```

Ten fragment kodu ustawia strategię szeregowania dla procesu wywołującego na strategię cykliczną oraz ustala priorytet statyczny równy 1. Zakłada się w tym momencie, iż wartość 1 jest poprawną wartością priorytetu — z technicznego punktu widzenia nie zawsze tak musi być. W następnym podrozdziale zostanie omówione, jak należy określać prawidłowy zakres priorytetów dla danej strategii.

Ustawianie strategii innej niż `SCHED_OTHER` wymaga posiadania uprawnienia `CAP_SYS_NICE`. Dlatego też najczęściej administrator ma prawo do uruchamiania procesów czasu rzeczywistego. Od wersji jądra 2.6.12 parametr ograniczeń zasobów `RLIMIT_RTPRIO` pozwala także innym użytkownikom na ustawianie strategii czasu rzeczywistego aż do pewnej określonej granicy priorytetów.

Kody błędów

W przypadku błędu możliwe są cztery wartości `errno`:

`EFAULT`
: Zmienna wskaźnikowa `sp` wskazuje na błędny lub niedostępny obszar pamięci.

`EINVAL`
: Strategia szeregowania określona przez parametr `policy` jest nieprawidłowa albo też wartość przekazywana przez `sp` nie ma sensu dla danej strategii (tylko dla `sched_setscheduler()`).

`EPERM`
: Proces wywołujący nie posiada odpowiednich uprawnień.

`ESRCH`
: Wartość przekazana w `pid` nie odzwierciedla żadnego istniejącego procesu.

Ustawianie parametrów szeregowania

Funkcje systemowe `sched_getparam()` oraz `sched_setparam()`, zdefiniowane przez POSIX, odczytują oraz ustawiają parametry związane z ustaloną już strategią szeregowania:

```
#include <sched.h>
struct sched_param
{
   /* ... */
   int sched_priority;
   /* ... */
};
int sched_getparam (pid_t pid, struct sched_param *sp);
int sched_setparam (pid_t pid, const struct sched_param *sp);
```

Funkcja sched_getscheduler() zwraca wyłącznie strategię szeregowania, natomiast nie zwraca związanych z nią parametrów. Wywołanie sched_getparam() dla procesu określonego w parametrze pid zwraca parametry szeregowania w zmiennej sp:

```
struct sched_param sp;
int ret;
ret = sched_getparam (0, &sp);
if (ret == -1)
{
   perror ("sched_getparam");
   return 1;
}
printf ("Nasz priorytet wynosi %d\n", sp.sched_priority);
```

Jeśli pid wynosi 0, funkcja podaje parametry dla procesu wywołującego. W przypadku sukcesu funkcja zwraca 0, w przypadku niepowodzenia zwraca −1 oraz odpowiednio ustawia errno.

Ponieważ sched_setscheduler() również ustawia parametry szeregowania, sched_setparam() jest użyteczna tylko w celu późniejszych modyfikacji tych parametrów:

```
struct sched_param sp;
int ret;
sp.sched_priority = 1;
ret = sched_setparam (0, &sp);
if (ret == -1)
{
   perror ("sched_setparam");
   return 1;
}
```

W przypadku sukcesu parametry szeregowania dla procesu pid są ustawiane poprzez zmienną sp, a funkcja zwraca 0. W przypadku niepowodzenia funkcja zwraca −1 oraz odpowiednio ustawia errno.

Po uruchomieniu tych dwóch fragmentów kodu otrzyma się następujący wynik:

```
Nasz priorytet wynosi 1
```

Przykład ten także jest oparty na założeniu, że 1 określa prawidłową wartość priorytetu. Tak przeważnie jest, lecz podczas tworzenia programów przenośnych należy to wcześniej sprawdzić. Za chwilę zostanie pokazane, jak ustalać zakres poprawnych priorytetów.

Kody błędów

W przypadku błędu możliwe są cztery wartości errno:

EFAULT
: Zmienna wskaźnikowa sp wskazuje na błędny lub niedostępny obszar pamięci.

EINVAL
: Wartość przekazana przez sp nie ma sensu dla danej strategii (tylko sched_getparam()).

EPERM
: Proces wywołujący nie posiada niezbędnych uprawnień.

ESRCH
: Wartość przekazana w pid nie odpowiada żadnemu istniejącemu procesowi.

Określanie zakresu poprawnych priorytetów

Poprzednie przykłady kodów przekazywały sztywno ustalone wartości priorytetów do odpowiednich funkcji systemowych. POSIX nie gwarantuje, że dane wartości priorytetów szeregowania istnieją w określonym systemie, z wyjątkiem tego, że muszą istnieć przynajmniej 32 różne priorytety pomiędzy najniższą a najwyższą wartością. Jak wspomniano już wcześniej w punkcie „Linuksowe strategie szeregowania i ustalania priorytetów", Linux przypisuje zakres wartości od 1 do 99 włącznie dla dwóch strategii czasu rzeczywistego. Poprawny i przenośny program zwykle definiuje swój własny obszar wartości priorytetów i mapuje je w odpowiedni zakres, właściwy dla systemu operacyjnego. Na przykład, jeśli zaistnieje potrzeba uruchomienia procesów o czterech różnych poziomach priorytetów czasu rzeczywistego, można dynamicznie określić zakres priorytetów i wybrać cztery konkretne wartości.

Linux udostępnia dwie funkcje systemowe dla odczytu zakresu poprawnych wartości priorytetów. Jedna z nich zwraca wartość minimalną, a druga maksymalną:

```
#include <sched.h>
int sched_get_priority_min (int policy);
int sched_get_priority_max (int policy);
```

W przypadku sukcesu wywołanie funkcji `sched_get_priority_min()` zwraca wartość minimalną, natomiast wywołanie `sched_get_priority_max()` zwraca maksymalny poprawny priorytet powiązany ze strategią szeregowania, przekazaną w parametrze `policy`. W przypadku niepowodzenia obie funkcje zwracają `-1`. Jedyny możliwy błąd, jaki może wystąpić, dotyczy błędnego parametru `policy` — wówczas `errno` ustawiane jest na `EINVAL`.

Użycie funkcji jest proste:

```
int min, max;
min = sched_get_priority_min (SCHED_RR);
if (min == -1)
{
   perror ("sched_get_priority_min");
   return 1;
}
max = sched_get_priority_max (SCHED_RR);
if (max == -1)
{
   perror ("sched_get_priority_max");
   return 1;
}
printf ("Zakres wartości priorytetów dla strategii SCHED_RR wynosi: %d - %d\n", min,
max);
```

W standardowym systemie Linux powyższy fragment kodu spowoduje wyświetlenie następującego wyniku:

```
Zakres wartości priorytetów dla strategii SCHED_RR wynosi: 1 - 99
```

Jak już wcześniej wspominano, większe wartości liczbowe oznaczają wyższe priorytety. Aby przypisać procesowi najwyższy priorytet dla jego strategii szeregowania, należy posłużyć się następującym kodem:

```
/*
* set_highest_priority — dla procesu pid ustawia priorytet
* szeregowania na największą wartość, dopuszczaną przez jego
* aktualną strategię szeregowania.
* Jeśli wartość pid wynosi zero, następuje ustawienie priorytetu
* dla aktualnego procesu.
```

```
 *
 * W przypadku sukcesu funkcja zwraca zero.
 */
int set_highest_priority (pid_t pid)
{
   struct sched_param sp;
   int policy, max, ret;

   policy = sched_getscheduler (pid);
   if (policy == -1)
      return -1;

   max = sched_get_priority_max (policy);
   if (max == -1)
      return -1;

   memset (&sp, 0, sizeof (struct sched_param));
   sp.sched_priority = max;
   ret = sched_setparam (pid, &sp);

   return ret;
}
```

Programy zwykle zwracają minimalną lub maksymalną wartość dla systemu, a następnie modyfikują te wielkości o 1 (np. `max - 1`, `max - 2` itd.), aby odpowiednio przypisać priorytety procesom.

sched_rr_get_interval()

Jak już zostało wcześniej powiedziane, procesy klasy `SCHED_RR` zachowują się tak samo jak procesy klasy `SCHED_FIFO`, z wyjątkiem tego, że zarządca przydziela tym procesom przedziały czasowe. Gdy proces należący do klasy `SCHED_RR` wyczerpie swój przedział czasowy, zarządca przesuwa go na koniec listy procesów działających, zawierającej również inne procesy o priorytecie równym jego aktualnemu priorytetowi. W ten oto sposób wszystkie procesy klasy `SCHED_RR` o tym samym priorytecie są wykonywane cyklicznie. Te o wyższym priorytecie (oraz procesy klasy `SCHED_FIFO` o takim samym lub wyższym priorytecie) będą zawsze wywłaszczać działający proces klasy `SCHED_RR`, bez względu na to, czy pozostał mu jakiś przedział czasowy do wykorzystania.

POSIX definiuje interfejs w celu odczytania wielkości przedziału czasowego dla danego procesu:

```
#include <sched.h>
struct timespec
{
   time_t tv_sec;    /* liczba sekund */
   long   tv_nsec;   /* liczba nanosekund */
};
int sched_rr_get_interval (pid_t pid, struct timespec *tp);
```

Poprawne wywołanie funkcji systemowej o skomplikowanej nazwie `sched_rr_get_interval()` zapisuje w strukturze `timespec` wskazywanej przez parametr `tp` czas trwania przedziału czasowego przydzielonego dla procesu `pid` oraz zwraca zero. W przypadku błędu funkcja zwraca `-1` oraz odpowiednio ustawia `errno`.

Zgodnie ze standardem POSIX funkcja ta jest wymagana wyłącznie dla pracy z procesami klasy `SCHED_RR`. Jednak w systemie Linux może ona udostępniać długość przedziału czasowego dowolnego procesu. Programy przenośne powinny zakładać, że funkcja ta działa tylko z proce-

sami cyklicznymi; programy dedykowane dla Linuksa mogą nadużywać tej funkcji. Oto przykład:

```
struct timespec tp;
int ret;
/* pobierz wielkość przedziału czasowego dla aktualnego zadania */
ret = sched_rr_get_interval (0, &tp);
if (ret == -1)
{
   perror ("sched_rr_get_interval");
   return 1;
}
/* zamień liczbę sekund i nanosekund na milisekundy */
printf ("Nasz kwant czasowy wynosi %.2lf milisekund\n", (tp.tv_sec * 1000.0f) +
(tp.tv_nsec / 1000000.0f));
```

Jeśli proces działa w klasie FIFO, wartości zmiennych `tv_sec` oraz `tv_nsec` wynoszą `0`, co symbolizuje w tym przypadku nieskończoność.

Kody błędu

W przypadku błędu wartości `errno` są następujące:

`EFAULT`
: Zmienna wskaźnikowa `tp` wskazuje na błędny lub niedostępny obszar pamięci.

`EINVAL`
: Wartość przekazana przez `pid` jest błędna (np. ujemna).

`ESRCH`
: Wartość przekazana w `pid` jest poprawna, lecz nie odnosi się do żadnego istniejącego procesu.

Środki ostrożności przy pracy z procesami czasu rzeczywistego

Z powodu samej natury procesów czasu rzeczywistego projektanci powinni być ostrożni podczas tworzenia i uruchamiania takich programów. Gdy program czasu rzeczywistego zaczyna się dziwnie zachowywać, cały system może się zawiesić. Każda pętla związana z procesorem w programie czasu rzeczywistego, to znaczy dowolny kawałek kodu, który nie może się zatrzymać, będzie kontynuować swoje działanie w nieskończoność, tak długo, dopóki procesy czasu rzeczywistego o wyższym priorytecie nie staną się uruchamialne.

Dlatego też projektowanie programów czasu rzeczywistego wymaga ostrożności oraz szczególnej uwagi. Takie programy rządzą w sposób absolutny i mogą w prosty sposób spowodować zawieszenie całego systemu. Oto kilka wskazówek i ostrzeżeń:

- Należy pamiętać, że każda pętla programowa wykonywana przez proces związany z procesorem będzie działać bez jakiegokolwiek przerwania pracy, dopóki się naturalnie nie zakończy, jeśli w systemie nie pojawi się żaden proces o wyższym priorytecie. Jeśli pętla jest nieskończona, system zawiesi się.
- Ponieważ procesy czasu rzeczywistego działają kosztem całego systemu, należy zwrócić szczególną uwagę na sposób ich zaprojektowania. Trzeba zadbać, aby nie dopuścić do trwałego zablokowania systemu z powodu poświęcenia mu zbyt małej ilości czasu procesora.

- Należy być bardzo ostrożnym w przypadku oczekiwania w pętli (ang. *busy-wait*). Jeśli proces czasu rzeczywistego oczekuje w pętli na zasób zajmowany przez proces o niższym priorytecie, będzie niestety czekać w nieskończoność.
- Podczas projektowania procesu czasu rzeczywistego zalecane jest używanie terminala, który posiada wyższy priorytet niż proces projektowany. Dzięki temu w przypadku problemu terminal pozostanie w dalszym ciągu aktywny i umożliwi usunięcie procesu, który wymknął się spod kontroli (dopóki terminal pozostanie w stanie jałowym, oczekując na dane z klawiatury, nie będzie przeszkadzać innym procesom).
- Program użytkowy *chrt*, jeden z elementów pakietu narzędziowego *util-linux*, upraszcza odczytywanie i ustawianie atrybutów czasu rzeczywistego dla innych procesów. Narzędzie to ułatwia uruchamianie dowolnych programów w trybie szeregowania czasu rzeczywistego, na przykład wyżej wspomnianego terminala, jak również pozwala na zmianę priorytetów czasu rzeczywistego dla istniejących aplikacji.

Determinizm

Procesy czasu rzeczywistego są pełne determinizmu. W obliczeniach czasu rzeczywistego czynność jest *deterministyczna* (ang. *deterministic*), jeśli przy takich samych danych wejściowych generuje zawsze ten sam wynik w tym samym przedziale czasu. Nowoczesne komputery są bardzo dobrym przykładem systemów niedeterministycznych: wielopoziomowe pamięci podręczne (poddające się trafieniom i chybieniom bez żadnej przewidywalności), wieloprocesorowość, stronicowanie (ang. *paging*), wymiana danych (ang. *swapping*) oraz wielozadaniowość niszczą każde oszacowanie zmierzające do tego, aby ustalić, jak długo dana czynność będzie się wykonywać. Oczywiście osiągnięto już punkt, w którym praktycznie każda czynność (za wyjątkiem dostępu do twardego dysku) jest „niesamowicie szybka", ale jednocześnie nowoczesne systemy utrudniły dokładne sprecyzowanie, ile czasu zajmie jej wykonanie.

Aplikacje czasu rzeczywistego często próbują ogólnie ograniczyć nieprzewidywalność, a w szczególności najbardziej niekorzystne opóźnienia. Kolejne podrozdziały omówią dwie metody, które używane są w tym celu.

Wcześniejsze zapisywanie danych oraz blokowanie pamięci

Rozważmy następującą sytuację: zostaje wygenerowane przerwanie sprzętowe, pochodzące od niestandardowego monitora śledzącego międzykontynentalne pociski balistyczne, co powoduje, że sterownik urządzenia chce szybko skopiować dane z układu sprzętowego do jądra systemu. Sterownik zauważa jednak, że proces jest uśpiony, blokując się na elemencie sprzętowym i czekając na dane. Powiadamia jądro, aby obudziło ten proces. Jądro, zauważając, że działa on w strategii czasu rzeczywistego i posiada wysoki priorytet, natychmiast wywłaszcza aktualnie działający proces, decydując o natychmiastowym zaszeregowaniu procesu czasu rzeczywistego. Zarządca uruchamia tenże proces i przełącza kontekst do jego przestrzeni adresowej. Proces zaczyna działać. Cała akcja trwa 0,3 milisekundy, przy zakładanej wartości najgorszego przypadku opóźnienia równej 1 milisekundzie.

Proces, będąc obecnie na poziomie użytkownika, zauważa nadlatujący międzykontynentalny pocisk balistyczny i zaczyna przetwarzać jego trajektorię. Gdy balistyka zostanie wyliczona, proces czasu rzeczywistego uruchamia wystrzelenie pocisku służącego do niszczenia głowic rakiet o dalekim zasięgu. Minęło kolejne 0,1 milisekundy — wystarczające, aby uruchomić

odpowiedź systemu obronnego i ocalić życie ludzi. Jednak w tym momencie kod zarządzający wystrzeleniem pocisku zostaje przerzucony na dysk! Następuje błąd dostępu do strony, procesor z powrotem przełącza się w tryb jądra, jądro rozpoczyna operacje dyskowe wejścia i wyjścia w celu przeniesienia zapisanych danych z powrotem do pamięci. Zarządca przełącza proces w tryb uśpienia na czas obsługi błędu dostępu. Mijają kolejne sekundy. Jest już za późno…

Stronicowanie i wymiana danych wprowadzają oczywiście całkiem niedeterministyczne zachowanie, które może spowodować zniszczenia w procesie czasu rzeczywistego. Aby uchronić się przed taką katastrofą, aplikacje czasu rzeczywistego często „blokują" lub „wiążą na stałe" wszystkie strony ze swojej przestrzeni adresowej z pamięcią fizyczną, zapisując je wstępnie do niej i chroniąc przed wymieceniem na dysk. Gdy tylko strony zostaną zablokowane w pamięci, jądro już ich nie zapisze na dysk. Dowolny dostęp do tych stron nie spowoduje żadnych błędów. Większość aplikacji czasu rzeczywistego blokuje niektóre lub nawet wszystkie swoje strony w fizycznej pamięci operacyjnej.

Linux dostarcza funkcji systemowych w celu wcześniejszego zapisywania oraz blokowania danych. W rozdziale 4. omówione zostały interfejsy używane dla zapisywania danych do pamięci fizycznej. W rozdziale 9. przedstawione będą funkcje systemowe przeznaczone dla blokowania danych w fizycznej pamięci operacyjnej.

Wiązanie do procesora a procesy czasu rzeczywistego

Drugim problemem aplikacji czasu rzeczywistego jest wielozadaniowość. Choć jądro Linuksa działa w trybie wywłaszczenia, jego zarządca nie zawsze potrafi na żądanie przeszeregować jeden proces, by udostępnić czas drugiemu. Czasami aktualnie działający proces wykonuje się wewnątrz regionu krytycznego w jądrze i zarządca nie potrafi wywłaszczyć go, dopóki nie opuści on tego regionu. Jeśli jest to proces, który oczekuje na uruchomienie w czasie rzeczywistym, to opóźnienie może być nie do zaakceptowania i istnieje niebezpieczeństwo, że szybko przekroczy graniczny parametr operacyjny.

Zatem wielozadaniowość wprowadza niedeterminizm podobny w naturze do nieprzewidywalności spotykanej w stronicowaniu. Rozwiązanie, które bierze pod uwagę wielozadaniowość, jest jedno: należy ją po prostu wyeliminować. Niestety jest prawdopodobne, że nie da się łatwo usunąć wszystkich innych procesów. Gdyby było to możliwe w danym środowisku, prawdopodobnie nie byłoby potrzeby użycia systemu Linux — wystarczyłby dowolny prosty system operacyjny. Jeśli jednak system posiada wiele procesorów, można przeznaczyć jeden lub więcej z tych procesorów dla procesu (lub procesów) czasu rzeczywistego. W praktyce można chronić procesy czasu rzeczywistego przed wielozadaniowością.

Wcześniej w tym rozdziale omówiono funkcje systemowe, używane w celu kontroli wiązania procesora dla danego procesu. Możliwą optymalizacją dla aplikacji czasu rzeczywistego jest zarezerwowanie po jednym procesorze dla każdego z procesów czasu rzeczywistego oraz zezwolenie wszystkim innym procesom na dzielenie swojego czasu na pozostałym procesorze.

Najprostszą metodą, aby to osiągnąć, jest takie zmodyfikowanie jednej z wersji głównego programu inicjalizującego („ojca procesów") *init* o nazwie *SysVinit*[2], aby wykonywał coś podobnego do kodu zamieszczonego poniżej, zanim rozpocznie proces startowania systemu:

[2] Źródła *SysVinit* znajdują się pod adresem *http://freecode.com/projects/sysvinit/*. Program jest licencjonowany zgodnie z Powszechną Licencją Publiczną GNU v2.

```
cpu_set_t set;
int ret;

CPU_ZERO (&set); /* wyzeruj wszystkie procesory */
ret = sched_getaffinity (0, sizeof (cpu_set_t), &set);
if (ret == -1)
{
   perror ("sched_getaffinity");
   return 1;
}

CPU_CLR (1, &set); /* nie dopuszczaj procesora o numerze 1 */
ret = sched_setaffinity (0, sizeof (cpu_set_t), &set);
if (ret == -1)
{
   perror ("sched_setaffinity");
   return 1;
}
```

Ten fragment kodu pobiera aktualny zestaw dozwolonych procesorów dla programu *init*. Zestaw ten zawiera (jak się tego oczekuje) wszystkie dostępne procesory. W dalszej części kodu następuje usunięcie z tego zbioru procesora o numerze 1 oraz aktualizacja listy dopuszczonych procesorów.

Ponieważ lista dozwolonych procesorów jest dziedziczona przez potomstwo, a program *init* jest patronem wszystkich procesów, wszystkie procesy systemowe będą działać z takim zestawem dozwolonych procesorów, na jaki zezwoli program *init*. Dlatego też w tym przypadku żaden z procesów nie będzie używać procesora o numerze 1.

Następnie należy tak zmodyfikować proces czasu rzeczywistego, aby działał wyłącznie na procesorze nr 1:

```
cpu_set_t set;
int ret;

CPU_ZERO (&set); /* wyzeruj wszystkie procesory */
CPU_SET (1, &set); /* pozwalaj na procesor o numerze 1 */
ret = sched_setaffinity (0, sizeof (cpu_set_t), &set);
if (ret == -1)
{
   perror ("sched_setaffinity");
   return 1;
}
```

Wynikiem użycia powyższych fragmentów kodu jest to, iż procesy czasu rzeczywistego działają tylko na procesorze nr 1, a wszystkie inne procesy używają pozostałych procesorów.

Ograniczenia zasobów systemowych

Jądro Linuksa narzuca na procesy pewne *ograniczenia zasobów systemowych* (ang. *resource limits*). Te ograniczenia ustalają bezwzględne górne granice dotyczące wielkości zasobów jądra, których proces może używać, na przykład liczby otwartych plików, stron pamięci, zawieszonych sygnałów itd. Ograniczenia są stosowane bezwarunkowo; jądro nie zezwoli na działanie, które pozwoliłoby procesowi użyć jakiegoś zasobu powyżej dopuszczalnej górnej granicy. Na przykład, jeśli otwarcie nowego pliku pozwoliłoby procesowi posiadać więcej otwartych plików, niż zezwolono

w odpowiednim ograniczeniu zasobów systemowych, wywołanie funkcji `open()` nie powiedzie się[3].

Linux udostępnia dwie funkcje systemowe służące kontroli ograniczeń zasobów systemowych. Co prawda POSIX znormalizował oba interfejsy, lecz Linux wspiera dodatkowo jeszcze inne ograniczenia zasobów, uzupełniając te, które istnieją już zgodnie ze standardem. Ograniczenia mogą być odczytane poprzez wywołanie funkcji `getrlimit()`, a ustawione przez funkcję `setrlimit()`:

```
#include <sys/time.h>
#include <sys/resource.h>

struct rlimit
{
   rlim_t rlim_cur; /* ograniczenie miękkie */
   rlim_t rlim_max; /* ograniczenie twarde */
};
int getrlimit (int resource, struct rlimit *rlim);
int setrlimit (int resource, const struct rlimit *rlim);
```

Zasoby reprezentowane są przez stałe całkowitoliczbowe, takie jak na przykład `RLIMIT_CPU`. Struktura `rlimit` opisuje bieżące ograniczenia. Definiuje dwie górne granice: *ograniczenie miękkie* (ang. *soft limit*) oraz *ograniczenie twarde* (ang. *hard limit*). Jądro wymusza miękkie ograniczenie zasobów na procesach, lecz proces może swobodnie zmieniać je na dowolną wartość w zakresie od zera aż do granicy określanej przez ograniczenie twarde. Proces nieposiadający uprawnienia `CAP_SYS_RESOURCE` (czyli niebędący procesem administratora) może jedynie obniżyć swoje ograniczenie twarde. Proces bez przywilejów nie może nigdy zwiększyć swoich ograniczeń twardych, nawet do wyższej wartości, którą poprzednio posiadał — obniżanie ograniczeń twardych jest nieodwracalne. Proces uprzywilejowany może ustawić swoje ograniczenie twarde na dowolną poprawną wartość.

Od konkretnego zasobu zależy, co naprawdę reprezentuje jego ograniczenie. Jeśli zasobem jest na przykład `RLIMIT_FSIZE`, wówczas ograniczenie opisuje maksymalny rozmiar pliku w bajtach, który proces może stworzyć. W tym przypadku, jeśli `rlim_cur` wynosi `1024`, proces nie może utworzyć ani powiększyć pliku większego niż rozmiar jednego kilobajta.

Wszystkie ograniczenia zasobów systemowych posiadają dwie specjalne wartości: `0` oraz nieskończoność. Pierwsza wartość zupełnie blokuje użycie danego zasobu. Na przykład, jeśli `RLIMIT_CORE` jest równe zeru, jądro nigdy nie stworzy pliku zrzutu systemowego. I odwrotnie, druga wartość likwiduje wszelkie ograniczenia dla danego zasobu. Jądro rozpoznaje nieskończoność poprzez specjalną wartość `RLIM_INFINITY`, która wynosi dokładnie `-1` (może to spowodować pewne nieporozumienia, gdyż `-1` jest również wartością zwracaną w przypadku błędu). Jeśli `RLIMIT_CORE` jest równy nieskończoności, jądro będzie tworzyć pliki zrzutu systemowego o dowolnym rozmiarze.

Funkcja `getrlimit()` pobiera aktualne ograniczenia miękkie oraz twarde dla zasobu określanego poprzez parametr `resource` i umieszcza je w strukturze opisywanej przez `rlim`. W przypadku poprawnego wywołania funkcja zwraca `0`, natomiast w przypadku błędu zwraca `-1` oraz odpowiednio ustawia `errno`.

[3] W tym przypadku wywołana funkcja systemowa ustawi `errno` na wartość `EMFILE`, informując, iż proces osiągnął graniczną dopuszczalną wartość dla liczby otwartych plików. Funkcja systemowa `open()` omówiona jest w rozdziale 2.

Funkcja systemowa setrlimit() ustawia odpowiednio ograniczenia miękkie i twarde dla zasobu resource na wartości wskazywane przez strukturę rlim. W przypadku poprawnego wywołania funkcja zwraca 0, a jądro stosownie uaktualnia ograniczenia zasobów systemowych. W przypadku błędu funkcja zwraca −1 oraz ustawia errno na właściwą wartość.

Ograniczenia

Linux aktualnie udostępnia 16 ograniczeń zasobów systemowych:

RLIMIT_AS
: Ogranicza w bajtach maksymalny rozmiar przestrzeni adresowej procesu. Próba zwiększenia rozmiaru przestrzeni adresowej poza to ograniczenie (poprzez funkcje systemowe takie jak mmap() oraz brk()) nie powiedzie się, a funkcje zwrócą wartość błędu ENOMEM. Jeśli stos procesu, który automatycznie rośnie w miarę potrzeby, przekracza to ograniczenie, jądro wysyła temu procesowi sygnał SIGSEGV. Limit ten wynosi zwykle RLIM_INFINITY.

RLIMIT_CORE
: Ustala maksymalny rozmiar w bajtach pliku zrzutu systemowego (core). Jeśli ograniczenie jest niezerowe, pliki zrzutu systemowego większe od tej wielkości obcinane są do maksymalnego dopuszczanego rozmiaru. Jeśli ograniczenie wynosi zero, pliki zrzutu systemowego nie są nigdy tworzone.

RLIMIT_CPU
: Wyznacza maksymalną ilość czasu procesora w sekundach, która może być zużyta przez proces. Jeśli proces działa dłużej niż to ograniczenie, jądro wysyła procesowi sygnał SIGXCPU, który może być jednak przechwycony i obsłużony przez tenże proces. Programy przenośne powinny zakończyć swoje działanie po otrzymaniu takiego sygnału, ponieważ POSIX nie definiuje żadnej akcji dla jądra po jego wysłaniu. Jednak Linux zezwala procesom, by kontynuowały swoje działanie, a następnie wysyła regularnie co jedną sekundę kolejne sygnały SIGXCPU. Gdy tylko nastąpi osiągnięcie granicy ograniczenia twardego, do procesu zostaje wysłany sygnał SIGKILL, który powoduje zakończenie jego działania.

RLIMIT_DATA
: Zarządza maksymalnym rozmiarem w bajtach segmentu danych i stosu dla danego procesu. Próba zwiększenia rozmiaru segmentu danych poza to ograniczenie przy pomocy funkcji systemowej brk() kończy się niepowodzeniem i zwraca ENOMEM.

RLIMIT_FSIZE
: Określa maksymalny rozmiar w bajtach dla pliku, który może być stworzony przez dany proces. Jeśli proces spróbuje rozszerzyć plik ponad tę granicę, jądro wyśle mu sygnał SIGXFSZ. Sygnał ten domyślnie kończy działanie procesu. Proces może jednak przechwycić go i obsłużyć, co spowoduje, że kolejne próby wywołania funkcji systemowej poszerzającej rozmiar pliku będą kończyć się niepowodzeniem i zwracać błąd EFBIG.

RLIMIT_LOCKS
: Zarządza maksymalną liczbą blokad pliku, które mogą być w posiadaniu przez dany proces (w rozdziale 8. można zapoznać się z dyskusją na temat blokad pliku). Gdy tylko ograniczenie zostaje osiągnięte, dalsze próby otrzymania dodatkowych blokad pliku powinny kończyć się niepowodzeniem i zwracać błąd ENOLCK. Jądro Linuksa w wersji 2.4.25 likwiduje jednak tę cechę. Obecne wersje jądra pozwalają na ustawienie ograniczenia, lecz nie powoduje to żadnych zmian.

RLIMIT_MEMLOCK
: Określa maksymalny rozmiar w bajtach dla pamięci, która może być zablokowana przy pomocy funkcji systemowych `mlock()`, `mlockall()` lub `shmctl()` przez proces nieposiadający uprawnienia `CAP_SYS_IPC` (czyli tak naprawdę przez proces niebędący administratorem). Jeśli to ograniczenie zostaje przekroczone, wywołania tych funkcji kończą się błędem i zwracają kod `EPERM`. W praktyce rzeczywiste ograniczenie jest zaokrąglone w dół, do liczby całkowitej będącej wielokrotnością liczby stron. Procesy posiadające uprawnienie `CAP_SYS_IPC` mogą zablokować dowolną liczbę stron w pamięci i ograniczenie to nie powoduje w ich przypadku żadnych zmian. Zanim pojawiła się wersja jądra 2.6.9, limit ten dotyczył procesów z uprawnieniem `CAP_SYS_IPC`, a procesy bez przywilejów w ogóle nie mogły blokować żadnych stron. Ograniczenie to nie jest częścią standardu POSIX, wprowadził je system BSD.

RLIMIT_MSGQUEUE
: Określa maksymalną wielkość obszaru w bajtach, który może być przydzielony przez użytkownika dla potrzeb kolejek wiadomości w standardzie POSIX. Jeśli nowo utworzona kolejka wiadomości przekroczy to ograniczenie, funkcja systemowa `mq_open()` wykona się niepoprawnie i zwróci kod błędu `ENOMEM`. Ograniczenie to nie jest częścią standardu POSIX; zostało dodane w jądrze wersji 2.6.8 i jest specyficzne dla Linuksa.

RLIMIT_NICE
: Określa maksymalną wartość, do której dany proces może obniżyć swój poziom uprzejmości (czyli podnieść swój priorytet). Jak zostało to już wcześniej omówione w niniejszym rozdziale, procesy zwykle mogą jedynie zwiększać wartość swojego poziomu uprzejmości (zmniejszać swój priorytet). To ograniczenie umożliwia administratorowi ustalenie maksymalnej wartości (czyli dolnej granicy poziomu uprzejmości), do której procesy mogą poprawnie zwiększać swój priorytet. Ponieważ poziomy uprzejmości mogą być ujemne, jądro interpretuje wartość jako `20 - rlim_cur`. Zatem jeśli ograniczenie ustawione jest na 40, proces może obniżyć wartość swojego poziomu uprzejmości do minimalnej wartości równej –20 (jest to jednocześnie najwyższy możliwy priorytet). To ograniczenie zostało wprowadzone w jądrze w wersji 2.6.12.

RLIMIT_NOFILE
: Ustala liczbę będącą wartością o jeden większą od maksymalnej liczby deskryptorów plików, które dany proces może mieć otwarte. Próba ominięcia tego ograniczenia kończy się błędem i odpowiednia funkcja systemowa zwraca kod `EMFILE`. To ograniczenie jest również znane pod nazwą `RLIMIT_OFILE`, która pochodzi z systemu BSD.

RLIMIT_NPROC
: Określa maksymalną liczbę procesów, które mogą działać, podczas gdy są uruchomione w danym momencie przez użytkownika w systemie. Próba przekroczenia tego ograniczenia kończy się niepowodzeniem, a funkcja systemowa `fork()` zwraca kod błędu `EAGAIN`. Ograniczenie to nie jest częścią standardu POSIX, wprowadził je system BSD.

RLIMIT_RSS
: Określa maksymalną liczbę stron, które proces może umieścić w pamięci (ta wielkość znana też jest pod nazwą *rozmiaru grupy rezydentnej*, ang. *resident set size* — RSS). Tylko wczesne wersje 2.4 jądra systemu egzekwowały to ograniczenie. Obecne wersje jądra zezwalają co prawda na ustawienie tej wartości, ale nie powoduje to żadnych zmian. To ograniczenie nie jest częścią standardu POSIX; wprowadził je system BSD.

RLIMIT_RTTIME
: Określa ograniczenie (w mikrosekundach) czasu procesora, jaki może zostać zużyty przez proces czasu rzeczywistego, niewykonujący blokującego wywołania systemowego. Gdy proces wykonuje blokujące wywołanie systemowe, czas procesora zostaje wyzerowany. Chroni to system operacyjny przed zawieszeniem przez procesy czasu rzeczywistego, które wymknęły się spod kontroli. Ograniczenie zostało dodane w wersji jądra 2.6.25 i jest specyficzne dla Linuksa.

RLIMIT_RTPRIO
: Określa maksymalny poziom priorytetu czasu rzeczywistego, który może być zażądany przez proces nieposiadający uprawnienia CAP_SYS_NICE (czyli w rzeczywistości proces niebędący administratorem). Zwykle procesom bez przywilejów nie wolno żądać żadnej klasy szeregowania czasu rzeczywistego. Ograniczenie to nie jest częścią standardu POSIX; zostało dodane w wersji jądra 2.6.12 i jest specyficzne dla Linuksa.

RLIMIT_SIGPENDING
: Ustala maksymalną liczbę sygnałów (standardowych oraz czasu rzeczywistego), które mogą być umieszczone w kolejce dla danego użytkownika. Próba dodania do kolejki następnych sygnałów nie powiedzie się, a funkcje systemowe takie jak `sigqueue()` zwrócą wartość błędu EAGAIN. Należy zwrócić uwagę, że bez względu na to ograniczenie zawsze możliwe jest dodanie do kolejki jednego egzemplarza sygnału o typie, który jeszcze się w niej nie znajduje. Dzięki temu zawsze istnieje możliwość wysłania procesowi sygnałów takich jak SIGKILL czy SIGTERM. Ograniczenie to nie jest częścią standardu POSIX; jest specyficzne dla Linuksa.

RLIMIT_STACK
: Ustala maksymalny rozmiar w bajtach stosu dla procesu. Próba ominięcia tego ograniczenia kończy się wysłaniem sygnału SIGSEGV.

Jądro zarządza ograniczeniami zasobów, przydzielając je procesom. Proces potomny dziedziczy ograniczenia po swoim rodzicu podczas operacji rozwidlenia. Ograniczenia są zachowywane w trakcie użycia funkcji typu *exec*.

Ograniczenia domyślne

Ograniczenia domyślne dostępne dla procesu zależą od trzech zmiennych: wstępnego ograniczenia miękkiego, wstępnego ograniczenia twardego oraz administratora systemu. Jądro narzuca wstępne ograniczenia miękkie i twarde, pokazane w tabeli 6.1. Jądro ustawia te ograniczenia dla procesu `init`, a ponieważ potomkowie dziedziczą ograniczenia od swoich rodziców, wszystkie dalsze procesy przejmują ograniczenia miękkie i twarde od procesu `init`.

Dwa przypadki mogą zmienić te domyślne wartości ograniczeń:

- Każdy proces może swobodnie zwiększyć ograniczenie miękkie do dowolnej wartości od 0 do wielkości ograniczenia twardego. Potomkowie będą dziedziczyć te uaktualnione ograniczenia podczas rozwidlenia procesu.
- Proces uprzywilejowany może swobodnie ustawiać ograniczenie twarde na dowolną wartość. Potomkowie odziedziczą te uaktualnione ograniczenia podczas rozwidlenia procesu.

Tabela 6.1. Domyślne miękkie i twarde ograniczenia zasobów systemowych

Symbol ograniczenia	Ograniczenie miękkie	Ograniczenie twarde
RLIMIT_AS	RLIM_INFINITY	RLIM_INFINITY
RLIMIT_CORE	0	RLIM_INFINITY
RLIMIT_CPU	RLIM_INFINITY	RLIM_INFINITY
RLIMIT_DATA	RLIM_INFINITY	RLIM_INFINITY
RLIMIT_FSIZE	RLIM_INFINITY	RLIM_INFINITY
RLIMIT_LOCKS	RLIM_INFINITY	RLIM_INFINITY
RLIMIT_MEMLOCK	8 stron	8 stron
RLIMIT_MSGQUEUE	800 kB	800 kB
RLIMIT_NICE	0	0
RLIMIT_NOFILE	1024	1024
RLIMIT_NPROC	0 (oznacza brak ograniczeń)	0 (oznacza brak ograniczeń)
RLIMIT_RSS	RLIM_INFINITY	RLIM_INFINITY
RLIMIT_RTPRIO	0	0
RLIMIT_SIGPENDING	0	0
RLIMIT_STACK	8 MB	RLIM_INFINITY

Jest raczej mało prawdopodobne, że prawidłowo utworzony proces administratora zmieni jakieś ograniczenia twarde. Dlatego też pierwszy przypadek jest dużo bardziej prawdopodobnym źródłem modyfikacji ograniczeń niż drugi. Istotnie, faktyczne ograniczenia udostępniane procesowi są w większości ustawiane przez powłokę systemową użytkownika, która może być w taki sposób dopasowana przez administratora, aby ustalać różne restrykcje. Na przykład, w powłoce systemowej Bourne-again shell (*bash*) administrator uzyskuje dostęp do parametrów ograniczeń dzięki komendzie `ulimit`. Należy zwrócić uwagę, że administrator nie potrzebuje niższych wartości; może on również podnieść ograniczenia miękkie do poziomu ograniczeń twardych, dostarczając użytkownikom rozsądniejszych wielkości domyślnych. Jest to często stosowane w przypadku ograniczenia `RLIMIT_STACK`, które w wielu systemach ustawia się na wartość `RLIM_INFINITY`.

Ustawianie i odczytywanie ograniczeń

Definicje różnych ograniczeń systemowych zostały już objaśnione, dlatego też można przystąpić do ich odczytywania i ustawiania. Odczytywanie wartości ograniczenia systemowego jest całkiem proste:

```
struct rlimit rlim;
int ret;

/* pobierz ograniczenie dla rozmiarów pliku zrzutu systemowego */
ret = getrlimit (RLIMIT_CORE, &rlim);
if (ret == -1)
{
   perror ("getrlimit");
   return 1;
}
printf ("Ograniczenie RLIMIT_CORE: miękkie=%ld twarde=%ld\n", rlim.rlim_cur,
rlim.rlim_max);
```

Skompilowanie tego fragmentu kodu i jego uruchomienie udostępnia następujący wynik:

```
Ograniczenie RLIMIT_CORE: miękkie=0 twarde=-1
```

Ograniczenie miękkie ustawione jest na `0`, natomiast twarde na nieskończoność (`-1` oznacza `RLIM_INFINITY`). Dlatego też możliwe jest ustawienie limitu miękkiego na dowolną wartość. Poniższy przykład ustawia maksymalny rozmiar pliku zrzutu systemowego na 32 MB:

```
struct rlimit rlim;
int ret;
rlim.rlim_cur = 32 * 1024 * 1024; /* 32 MB */
rlim.rlim_max = RLIM_INFINITY; /* zostawiamy tak, jak jest */
ret = setrlimit (RLIMIT_CORE, &rlim);
if (ret == -1)
{
   perror ("setrlimit");
   return 1;
}
```

Kody błędów

W przypadku błędów możliwe są trzy wartości `errno`:

`EFAULT`
: Obszar pamięci wskazywany przez `rlim` jest błędny lub niedostępny.

`EINVAL`
: Wartość określona przez parametr `resource` jest nieprawidłowa albo wartość `rlim.rlim_cur` jest większa od `rlim.rlim_max` (tylko dla `setrlimit()`).

`EPERM`
: Proces wywołujący nie posiadał uprawnień `CAP_SYS_RESOURCE`, a próbował zwiększyć ograniczenie twarde.

Skorowidz

#define, 41, 42
/bin/init, 156
/bin/sh, 156
/dev/full, 289
/dev/null, 289
/dev/random, 289
/dev/urandom, 289
/dev/zero, 88, 289, 318
/etc/group, 38, 157
/etc/init, 156
/etc/passwd, 38, 157
/sbin/init, 156
__attribute__, 411
__builtin_return_address, 402, 410
_exit(), 165, 166
_IOFBF, 104
_IOLBF, 104
_IONBF, 104
_POSIX_SAVED_IDS, 184
_SC_ATEXIT_MAX, 168
_SC_PAGESIZE, 126
_XOPEN_SOURCE, 386
1:1 threading, 229

A

ABI, 17, 25, 26
abort(), 340, 342
ABS, 205
absolute pathname, 32, 270
absolute section, 36
abstrakcja, 22
abstrakcja programistyczna, 226
access control lists, 39
ACL, 39
addr, 123
adjtime(), 383
adjtimex(), 384, 385
administrator, 38
adresowanie
  bloków logicznych, 143
  CHS, 142
  dysku, 142
advice, 134, 137
aio, 141
aktualny czas, 376
  ustawianie, 379
aktualny katalog roboczy, 32, 270
alarm(), 342, 392, 394
alarm_handler(), 392
alarmy, 392
algorytm cykliczny, 146
aligned, 406
alignment, 311
alignof, 408
alloca(), 324, 325, 326
alternatywny
  stan uśpienia, 391
  stos sygnałowy, 360
American National Standards Institute, 28
anonimowe odwzorowanie w pamięci, 315, 316
ANSI C, 28
Anticipatory I/O Scheduler, 146
antilock braking system, 205
anulowanie, 244
  asynchroniczne, 245
API, 21, 25
API Pthreads, 241
aplikacja, 155
  odpowiedzialna, 179
  sposób działania stronicowania systemowego, 332
  ścisłego czasu rzeczywistego, 206
  wstrzymanie wykonania, 75
  związana z procesorem, 195
  związana z wejściem i wyjściem, 195
  zwykłego czasu rzeczywistego, 206
aplikacje GUI, 21, 195

append mode, 47
Application Binary Interface, 25
Application Programming Interface, 21, 25
architektura i386, 24
arytmetyka wskaźników do funkcji, 411
asctime(), 381
asctime_r(), 381
asynchroniczne operacje, 140, 141
  aio, 141
async-safe, 40
atexit(), 166, 167, 168
atrybuty autoryzacji, 39
atrybuty rozszerzone, 261
  klucze, 262
  lista atrybutów, 267
  odczyt, 264
  operacje, 264
  przestrzenie nazw, 263
  security, 263
  system, 263
  trusted, 263
  user, 263
  ustawianie, 265
  usuwanie, 268
  wartości, 262
atrybuty wątku
  obiekt pthread_attr_t, 242
automatyczne przechwytywanie potomków, 360
automatyczne zmienne, 324

B

bajty, 301
  manipulowanie, 332
  porównywanie, 329
  przenoszenie, 330
  ustawianie wartości, 329
bash, 223
batch scheduling policy, 209
bcmp(), 330
bcopy(), 330
bdflush, 84
bezpieczeństwo, 333
  wątków, 105
bezpośrednie operacje wejścia i wyjścia, 64
  O_DIRECT, 64
biblioteka
  aio, 141
  C++, 25
  GNU C, 17
  iostream, 90
  języka C, 24
  libpthread, 241
  libstdc++, 25
  typowych operacji wejścia i wyjścia, 90
    analiza, 108
    bezpieczeństwo wątków, 105
    błędy, 102
    czytanie ze strumienia, 93
    koniec pliku, 102
    opróżnianie strumienia, 102
    otwieranie plików, 91
    otwieranie strumienia, 92
    parametry buforowania, 104
    podwójne kopiowanie, 108
    skojarzony deskryptor pliku, 103
    szukanie w strumieniu, 100
    użycie, 109
    wskaźniki do plików, 90
    zamykanie strumieni, 93
    zapis do strumienia, 97
  wątkowości, 241
binaria, 225
bit NX, 124
bitowy zestaw uprawnień, 49
bity uprawnień, 39
block devices, 34
block started by symbol, 36
blocked, 193
blok, 35, 87, 143
  częściowe operacje, 87
  rozmiary, 89
  rozpoczęty od symbolu, 36
  wpływ wielkości na wydajność, 88
blok fizyczny, 142
blok logiczny, 143
blok systemu plików, 143
blok urządzenia, 142
blokada, 236
  typu mutex, 237
  w kontekście wątków, 236
blokada strumienia, 107
blokady
  globalne, 251
  o określonym zakresie widoczności, 250
  the_mutex, 251
  zależne, 250
blokowane operacje wejścia i wyjścia, 227
blokowanie, 105
  całej przestrzeni adresowej, 334
  danych, 237
  drobnoziarniste, 251
  fragmentu przestrzeni adresowej, 333
  muteksów, 249
  odczytów przez zapisy, 144
  pamięci, 216, 332, 335
  plików, 106
  sygnałów, 357

błędy, 40
  opisy, 41, 42
  segmentacji, 344
  strony, 302
boundary, 312
Bourne shell, 156
Bourne-again shell, 223
break point, 315
brk(), 220, 315
broken link, 33
bss, 303
buddy memory allocation scheme, 316
buf, 52
buffer_head, 84
bufor
  brudny, 59, 84
  funkcje systemowe, 24
  maksymalny wiek, 60
  obsługiwany przez bibliotekę języka C, 102
  podręczny katalogu, 32
  rozmiar, 89
  synchronizacja na dysku, 62
  zdeaktualizowany, 60
bufor stron, 81, 82
  lokalizacja sekwencyjna, 83
  obcinanie, 83
  odczyt z wyprzedzeniem, 83
  przerzucanie stron, 83
  rozmiar, 82
buforowane operacje wejścia i wyjścia, 87
  bezpieczeństwo wątków, 105
  blokowanie plików, 106
  błędy, 102
  brak buforowania, 104
  buforowanie
    blokowe, 104
    pełne, 104
    w przestrzeni użytkownika, 87
    wierszowe, 104
  czytanie
    całego wiersza, 94
    danych binarnych, 96
    dowolnych łańcuchów, 95
    ze strumienia, 93
  deskryptor pliku, 103
  informacja o aktualnym położeniu
    w strumieniu, 101
  koniec pliku, 102
  nieblokowane operacje na strumieniu, 107
  opróżnianie strumienia, 102
  otwieranie
    plików, 91
    strumienia, 92
  parametry buforowania, 104
  przykładowy program, 99
  rozmiar bloku, 88, 89
  szukanie w strumieniu, 100
  wycofywanie znaku, 94
  zamykanie strumieni, 93
  zapis
    danych binarnych, 98
    do strumienia, 97
    łańcucha znaków, 98
    pojedynczego znaku, 97
buforowanie
  blokowe, 104
  pełne, 104
  przeprowadzane przez jądro, 102
  tryby, 104
  w przestrzeni użytkownika, 88
  wierszowe, 104
  zapisów, 60
BUFSIZ, 105
busy-wait, 216
bzero(), 329

C

C, 28
C99, 402
cache effects, 202
call(), 240
calloc(), 306, 318
całkowity czas oczekiwania dla operacji wejścia i wyjścia, 63
cancellation, 244
CAP_CHOWN, 259
CAP_FOWNER, 258
CAP_IPC_LOCK, 335
CAP_KILL, 352
CAP_SYS_ADMIN, 263
CAP_SYS_NICE, 199, 200, 222
CAP_SYS_RAWIO, 153
CAP_SYS_RESOURCE, 219
case, 410
CD-ROM, 34
CDROMEJECT, 291
CFQ, 146, 202
cfree(), 310
CFS, 194
character devices, 34
chdir(), 190, 273
chmod(), 257, 258
chown(), 259
chrt, 216
CHS, 142, 143
CHS addressing, 142

chwila, 370
clearerr(), 103
clock_getres(), 375
clock_gettime(), 377, 380, 389
CLOCK_MONOTONIC, 374, 375
clock_nanosleep(), 389
CLOCK_PROCESS_CPUTIME_ID, 375
CLOCK_REALTIME, 374, 389
clock_settime(), 380
clock_t, 374
CLOCK_THREAD_CPUTIME_ID, 375
clockid_t, 374
CLOCKS_PER_SEC, 371
clone(), 229, 240
close(), 65
  kody błędów, 65
closedir(), 279
close-on-exec, 47, 117, 292
command, 177
Complete Fair Queuing I/O Scheduler, 146
Completely Fair Scheduler, 194, 196
concurrency, 233
congestion avoidance, 84
const, 314, 403
constant function, 403
cooperative, 194
copy-on-write, 164
core, 220
coroutines, 230
count, 56, 114
COW, 164, 303
CPU_CLR, 204
CPU_SET, 204
CPU_SETSIZE, 204
CPU_ZERO, 204
creat(), 51
  wartości zwracane, 52
critical region, 233
ctime(), 381
ctime_r(), 381
current working directory, 270
cwd, 270
czas, 369
  absolutny, 370
  aktualny, 376
    ustawianie, 379
  alternatywy stanu uśpienia, 391
  clock_t, 374
  dokładność na poziomie mikrosekund, 372
  dokładność na poziomie nanosekund, 372
  GMT, 370
  interfejs ustawiania czasu, 380
  jądra, 63
  konwersje, 381
  licznik chwil, 370
  liczniki, 392
  monotoniczny, 369
  obsługa stanu uśpienia, 387
  opóźnienie licznika, 392
  precyzyjne ustawianie czasu, 379
  procesu, 369, 378
  przepełnienia, 391
  rozdzielczość źródła czasu, 375
  rzeczywisty, 205, 369
  stan oczekiwania, 385
  stan uśpienia, 385, 386
  struktury danych, 371
    reprezentacja pierwotna, 372
  systemowy, 369
  time_t, 372
  timespec, 372
  timeval, 372
  timex, 384
  tm, 373
  UTC, 370
  użytkowy, 369
  użytkownika, 63
  wprowadzanie w stan uśpienia, 390
  wygaśnięcia licznika, 392
  wyłuskiwanie składników, 373
  względny, 370
  zarządzanie stanem uśpienia, 389
  zegar
    POSIX, 374
    sprzętowy, 371
    systemowy, 370, 382
czasowa lokalizacja, 82
czytanie
  całego wiersza, 94
  danych binarnych, 96
  pojedynczego znaku, 93
  z pliku, 52
    wszystkie bajty, 54
  ze strumienia, 93
    całe wiersze, 94
    dane binarne, 96
    dowolne łańcuchy, 95
    katalogu, 278
    pojedyncze znaki, 93

D

daemon(), 191
dane
  lokalne dla wątku, 105
  synchronizowanie dostępu, 105

dangling symlink, 283
data race, 233
date, 379
dd, 88
Deadline I/O Scheduler, 144, 145
deadlock, 238
demony, 185, 189
dentry, 32
dentry cache, 32
deprecated, 405
deskryptor, 31
  elementu obserwowanego, 293
  pliku, 30, 45, 72
    otwieranie strumienia, 92
    tablice, 73
  procesu, 36
  wątki, 70
determinizm, 216, 332
difftime(), 382
directory, 269
directory entry, 269
directory resolution, 32
directory stream, 278
dirfd(), 278
dnotify, 292
docelowe opóźnienie, 196
domyślna powłoka użytkownika, 185
dostęp
  do pliku, 30
  równoległy, 31
dostrajanie zegara systemowego, 382
dowiązania, 31, 269, 280
  licznik użycia, 281
  miękkie, 282
  plik docelowy, 282
  symboliczne, 33, 281, 282
  twarde, 32, 280, 281
  tworzenie, 281, 283
  uszkodzone, 33
drugoplanowa grupa procesów, 185
drzewo
  katalogów, 32
  procesów, 37
duch, 179
dynamiczne przydzielanie pamięci, 306
dyski SSD, 147
dziedziczenie priorytetu, 239

E

E2BIG, 41, 161
EACCES, 201, 255
EACCESS, 41, 127, 132, 161
EAGAIN, 41, 55, 127, 131, 136, 163, 181, 183
EBADF, 41, 55, 58, 61, 65, 67, 74, 78, 100, 120, 121, 127, 136, 255, 258
EBUSY, 41
ebx, 24
ECHILD, 41, 169, 172
ECHLD, 175
ecx, 24
EDEADLK, 247, 249
edge-triggered, 122
edi, 24
EDOM, 41
EDQUOT, 266
edx, 24
edytor tekstowy
  Unix, 15
EEXIST, 120, 266
EEXIT, 41
EFAULT, 41, 55, 58, 78, 121, 131, 161, 205, 255, 258
EFBIG, 41, 58
efektywny
  GID, 38
  identyfikator użytkownika, 38, 180
  UID, 38
effective UID, 38
EINTR, 41, 53, 74, 78, 121, 169, 173, 175
EINVAL, 41, 55, 58, 62, 67, 74, 78, 100, 113, 118, 120, 121, 127, 131, 132, 134, 136, 153, 173, 175, 188, 201, 205, 247, 249, 335
EIO, 41, 56, 58, 62, 65, 136, 162, 258
EISDIR, 41, 162
element katalogu, 269
ELF, 36
  sekcja bss, 36
  sekcja danych, 36
  sekcja tekstu, 36
  sekcje, 36
  sekcje absolutne, 36
  sekcje niezdefiniowane, 36
ELOOP, 162, 255, 258
embedded, 207
EMFILE, 41, 118, 162
EMLINK, 41
ENAMETOOLONG, 255, 258
ENFILE, 41, 118, 127, 162
ENODEV, 41, 127
ENOENT, 41, 120, 162, 255, 258
ENOEXEC, 41, 162
ENOMEM, 41, 74, 78, 118, 120, 127, 131, 133, 134, 136, 162, 163, 255, 258, 335
ENOSPC, 41, 58, 267, 289
ENOTDIR, 41, 162, 255, 258, 265, 267
ENOTSUP, 265, 267

ENOTTY, 42
entropy pool, 289
ENXIO, 42
EOF, 34, 53, 103
EOVERFLOW, 67, 127
EPERM, 42, 120, 128, 162, 181, 183, 187, 188, 201, 205, 249, 258, 335
EPIPE, 42, 58
epoll, 111, 117
EPOLL_CLOEXEC, 117
epoll_create(), 117
epoll_create1(), 117, 118
epoll_ctl(), 118, 122
EPOLL_CTL_ADD, 119
EPOLL_CTL_DEL, 119, 120
EPOLL_CTL_MOD, 119
epoll_wait(), 121, 122
EPOLLERR, 119
EPOLLET, 119, 122
EPOLLHUP, 119
EPOLLIN, 119
EPOLLONESHOT, 119
EPOLLOUT, 119
EPOLLPRI, 119
ERANGE, 42, 265
EROFS, 42, 258, 282
errno, 40, 43, 52
errnum, 42
esi, 24
ESPIPE, 42, 68
ESRCH, 42, 187, 188, 201, 205, 244, 247
ETXTBSY, 42, 162
euid, 182, 183
EUID, 38
event loop, 232
event poll, 117
EXDEV, 42, 282
exec(), 158
execl(), 159, 160
    atrbuty procesu, 159
execle(), 160
execlp(), 160
    problem bezpieczeństwa, 161
executing, 158
execv(), 160
execve(), 160, 161
execvp(), 160, 161
    problem bezpieczeństwa, 161
exit(), 166, 167, 190
EXIT_FAILURE, 166
EXIT_SUCCESS, 166
ext3, 263
ext4, 35, 261
extern, 41
external fragmentation, 316

F

fast bins, 320
FAT, 35
fchdir(), 273
fchmod(), 257, 258
fchown(), 259
fclose(), 93
fcloseall(), 93
fcntl(), 47
fd, 52
FD_CLR, 73
FD_ISSET, 73
FD_SET, 73
FD_SETSIZE, 73
FD_ZERO, 73
fdatasync(), 60, 61, 62
    wartości zwracane, 61
fdopen(), 92
fds, 45
feof(), 96, 103
ferror(), 96, 103
fflush(), 102
fgetc(), 93, 95, 97, 108
fgetpos(), 101
fgets(), 94, 95
fgetxattr(), 264
fibers, 230
FIBMAP, 151, 153
FIFO, 34, 208
FILE, 90, 92
file descriptor, 30
file offset, 30
file pointer, 90
file position, 30
file table, 45
fileno(), 103
filesystem, 35
filesystem UID, 38
find_file_in_dir(), 279
fine-grained locking, 251
first in, first out class, 208
flags, 46
flistxattr(), 267
flockfile(), 106, 107
fopen(), 91, 92
fork(), 37, 158, 162, 190
forking, 158
format wykonywalny, 36
forward compatibility, 29
fputc(), 97, 98

fputs(), 98
fragmentacja
  wewnętrzna, 316
  zewnętrzna, 316
fread(), 96
Free Software Foundation, 27
Free Standards Group, 29
free(), 309
fremovexattr(), 268
fseek(), 100, 101
fsetpos(), 100
fsetxattr(), 265, 266
fstat(), 254
fsync(), 60, 62
  wartości zwracane, 61
ftell(), 101
ftruncate(), 69
ftrylockfile(), 107
full device, 289
fully qualified, 32
funkcje
  _exit(), 165, 166
  abort(), 340, 342
  adjtime(), 383
  adjtimex(), 384, 385
  alarm(), 342, 392, 394
  alarm_handler(), 392
  alloca(), 324, 325, 326
  asctime(), 381
  asctime_r(), 381
  atexit(), 166, 167, 168
  bcmp(), 330
  bcopy(), 330
  bezpieczne dla sygnałów, 354
  brk(), 220, 315
  bzero(), 329
  call(), 240
  calloc(), 306, 318
  cfree(), 310
  chdir(), 190, 273
  chmod(), 257, 258
  chown(), 259
  clearerr(), 103
  clock_getres(), 375
  clock_gettime(), 377, 380, 389
  clock_nanosleep(), 389
  clock_settime(), 380
  close(), 65
  closedir(), 279
  creat(), 51, 52
  ctime(), 381
  ctime_r(), 381
  czyste, 403
  daemon(), 191
difftime(), 382
dirfd(), 278
epoll_create(), 117
epoll_create1(), 117, 118
epoll_ctl(), 118
epoll_wait(), 121
exec(), 158
execl(), 159
execle(), 160
execlp(), 160
execv(), 160
execve(), 160, 161
execvp(), 160, 161
exit(), 166, 167, 190
fchdir(), 273
fchmod(), 257, 258
fchown(), 259
fclose(), 93
fcloseall(), 93
fcntl(), 47
fdatasync(), 60, 62
fdopen(), 92
feof(), 96, 103
ferror(), 96, 103
fflush(), 102
fgetc(), 93, 95, 97, 108
fgetpos(), 101
fgets(), 94, 95
fgetxattr(), 264
fileno(), 103
find_file_in_dir(), 279
flistxattr(), 267
flockfile(), 106, 107
fopen(), 91, 92
fork(), 37, 158, 162, 190
fputc(), 97, 98
fputs(), 98
fread(), 96
free(), 309
fremovexattr(), 268
fseek(), 100, 101
fsetpos(), 100
fsetxattr(), 265, 266
fstat(), 254
fsync(), 60, 62
ftell(), 101
ftruncate(), 69
ftrylockfile(), 107
funlockfile(), 106, 107
get_block(), 153
get_current_dir_name(), 272
get_inode(), 150
get_nr_blocks(), 153
get_thread_area(), 23

funkcje
getcwd(), 271, 272
getdents(), 280
getegid(), 184
geteuid(), 184
getgid(), 184
getitimer(), 392, 393
getpagesize(), 126, 312
getpgid(), 188
getpgrp(), 189
getpid(), 158
getpriority(), 200, 201
getrlimit(), 219
gets(), 108
getsid(), 187, 188
gettimeofday(), 377, 380
getuid(), 184
getwd(), 272
getxattr(), 264
gmtime(), 381
gmtime_r(), 381
inline, 401, 402
inotify_add_watch(), 293
inotify_init1(), 292
inotify_rm_watch(), 299
ioctl(), 151, 290
ioprio_get(), 202
ioprio_set(), 202
kill(), 345, 351
killpg(), 353
lchown(), 259
lgetxattr(), 264
link(), 281
listxattr(), 267
llistxattr(), 267
localtime(), 382
localtime_r(), 382
lock(), 237
lremovexattr(), 268
lseek(), 66
lsetxattr(), 265, 266
lstat(), 254, 283
madvise(), 134
mallinfo(), 323
malloc(), 304, 306
malloc_stats(), 324
malloc_trim(), 322
malloc_usable_size(), 322
mallopt(), 319, 321
memalign(), 312
memchr(), 331
memcmp(), 329
memcpy(), 331
memfrob(), 332
memmem(), 332
memmove(), 330
mempcpy(), 331
memrchr(), 331
memset(), 307, 329
mincore(), 336
mkdir(), 275
mktime(), 381
mlock(), 221, 333
mlockall(), 221, 334
mmap(), 123, 130, 317
mprotect(), 132
mq_open(), 221
mremap(), 131
msync(), 133
munlock(), 335
munlockall(), 335
munmap(), 128, 317, 318
nanosleep(), 387
nice(), 199
on_exit(), 166, 168
open(), 24, 46, 52
open_sysconf(), 327
opendir(), 47, 278
oznaczanie, 405
pause(), 347
perror(), 42, 54
poll(), 76, 79, 80
posix_fadvise(), 137
posix_memalign(), 311
ppoll(), 80
pread(), 68, 69
przydzielanie pamięci, 404
pselect(), 75
psignal(), 351
pthread_cancel(), 244
pthread_create(), 241
pthread_detach(), 247
pthread_equal(), 243
pthread_exit(), 244
pthread_join(), 246
pthread_mutex_lock(), 249, 251
pthread_mutex_unlock(), 249, 251
pthread_self(), 243
pthread_setcancelstate(), 245
pthread_setcanceltype(), 245
Pthreads, 241
ptrace(), 170
pure, 403
pwrite(), 68, 69
raise(), 353
read(), 23, 52
readahead(), 137, 138
readdir(), 278, 280

readv(), 112, 115
realloc(), 307
remove(), 285
removexattr(), 268
rename(), 286
rewind(), 101
rmdir(), 276, 285
rodzina exec
  elementy, 160
  kody błędów, 161
sbrk(), 315
sched_get_priority_max(), 213
sched_get_priority_min(), 213
sched_getaffinity(), 203
sched_getparam(), 211, 212
sched_getscheduler(), 210
sched_rr_get_interval(), 214
sched_setaffinity(), 203
sched_setparam(), 211
sched_setscheduler(), 210
sched_yield(), 197, 198
select(), 71, 74, 80, 390
set_tid_address(), 23
setegid(), 182
seteuid(), 182, 183, 184
setgid(), 181
setitimer(), 342, 344, 345, 392, 393
setpgid(), 187
setpgrp(), 189
setpriority(), 200, 201
setregid(), 182
setresgid(), 183
setresuid(), 183
setreuid(), 182
setrlimit(), 219, 224
setsid(), 186, 190
settimeofday(), 379, 380
setuid(), 181, 184
setvbuf(), 104, 105
setxattr(), 265
shmctl(), 221
sigaction(), 169, 359
sigaddset(), 356
sigandset(), 356
sigdelset(), 356
sigemptyset(), 356
sigfillset(), 356
sigisemptyset(), 356
sigismember(), 356
signal(), 169, 346, 347, 359
signalstack(), 360
sigorset(), 356
sigpending(), 358
sigprocmask(), 357, 358
sigqueue(), 366
sigsuspend(), 358
sizeof(), 409
sleep(), 385
stałe, 403
start_routine(), 242
stat(), 151, 253, 255
stime(), 379
strdupa(), 326
strerror(), 42
strerror_r(), 42
strndupa(), 326
strsignal(), 351
symlink(), 283
sync(), 62
sysconf(), 126, 168
system(), 177
time(), 376
timer_create(), 394, 395, 397
timer_delete(), 394, 399
timer_getoverrun(), 398
timer_gettime(), 397
timer_settime(), 394, 396
times(), 378
tmpfile(), 166
tryb uśpienia, 53
typeof(), 408
ungetc(), 94
unlink(), 284
unlock(), 237
usleep(), 386
valloc(), 312
vfork(), 165
wait(), 169, 170, 171, 343
wait3(), 175
wait4(), 175
waitid(), 173
waitpid(), 170, 171, 175, 378
write(), 23, 56
writev(), 109, 112, 114
xmalloc(), 307
funkcje nieblokujące, 107
funkcje nieużywane, 405
funkcje niezalecane, 405
funkcje obsługi sygnału, 40
funkcje systemowe, 23
  procesy, 36
  wywoływanie, 23
funkcje wplatane, 402
funkcje współużywalne, 354
funlockfile(), 106, 107
futex, 198

G

gcc, 17, 24
GCC, 401
generator liczb losowych, 289
get_block(), 153
get_current_dir_name(), 272
get_inode(), 150
get_nr_blocks(), 153
get_thread_area(), 23
getcwd(), 271, 272
getdents(), 280
getegid(), 184
geteuid(), 184
getgid(), 184
getitimer(), 392, 393
getpagesize(), 126, 312
getpgid(), 188
getpgrp(), 189
getpid(), 158
getpriority(), 200, 201
getrlimit(), 219
gets(), 108
getsid(), 187, 188
gettimeofday(), 377, 380
getuid(), 184
getwd(), 272
getxattr(), 264
GID, 38
  grupy właścicielskie, 49
glibc, 17, 24, 29, 240
global register variables, 407
globalne zmienne rejestrowe, 407
główny system plików, 35
GMT, 370
gmtime(), 381
gmtime_r(), 381
gniazda, 34
GNU C, 401
GNU C Compiler, 24
GNU Compiler Collection, 24, 401
GNU libc, 24
Go-routines, 231
graniczne parametry operacyjne, 205
group ID, 38
groups, 38
grupy, 38, 179
  /etc/group, 38
  dodatkowe, 38
  GID, 38
  identyfikator, 38
  podstawowa, 38
  procesów, 157, 184
  drugoplanowe, 185
  identyfikator, 184, 187
  lider, 184
  obsługa, 187
  pierwszoplanowe, 185
  przestarzałe funkcje obsługi, 188
  sesji, 184
  wheel, 157
  właścicielskie, 49
    procesu, 157
GUI, 21

H

handler, 23
hard affinity, 203
hard limit, 219
hard link, 32, 280
hard real-time system, 205
hasła, 38
hierarchia procesów, 37, 157
hole, 67
hooks, 81
HP-UX, 183
hwclock, 371
hybrid threading, 230

I

I/O control, 290
I/O scheduler, 81
I/O schedulers, 142
I/O-bound, 195
i386, 24
id_t, 174
identyfikator
  grupy, 38, 180
  grupy procesów, 184, 187
  i-węzła, 149
  procesu, 37, 156
    otrzymywanie, 158
    przydział, 156
    rodzicielskiego, 157, 158
  pthread_t, 243
  sesji, 185, 186, 187
  sygnału, 340
  użytkownika, 38, 180
    dla systemu plików, 38
  wątku, 243
    porównywanie, 243
idle scheduling policy, 209
IEEE, 27
IEEE Std 1003.1-1990, 27

ignorowanie sygnału, 340
implementacja
  API, 25
  NPTL, 240
  wątków, 37
implementacje wątkowości w Linuksie, 240
IN_ACCESS, 294
IN_ALL_EVENTS, 295
IN_ATTRIB, 294
IN_CLOEXEC, 292
IN_CLOSE, 295
IN_CLOSE_NOWRITE, 294
IN_CLOSE_WRITE, 294
IN_CREATE, 294
IN_DELETE, 294
IN_DELETE_SELF, 294
IN_DONT_FOLLOW, 298
IN_IGNORED, 297, 299
IN_ISDIR, 297
IN_MASK_ADD, 298
IN_MODIFY, 294
IN_MOVE, 295
IN_MOVE_SELF, 294
IN_MOVED_FROM, 294, 298
IN_MOVED_TO, 294, 298
IN_NONBLOCK, 292
IN_ONESHOT, 298
IN_ONLYDIR, 299
IN_OPEN, 294
IN_Q_OVERFLOW, 297
IN_UNMOUNT, 297
informacje
  o aktualnym położeniu w strumieniu, 101
  o pliku, 254
inicjalizowanie
  licznika, 396
  muteksów, 248
inicjowanie przy pozyskaniu zasobu, 250
init, 156
init process, 37
inline function, 402
ino, 31
inode, 31
inode number, 31
inotify, 292
  elementy obserwowane, 293
    deskryptor, 293
    dodawanie, 293
    maska, 293, 294
    usuwanie, 299
  IN_ACCESS, 294
  IN_ALL_EVENTS, 295
  IN_ATTRIB, 294
  IN_CLOSE, 295
  IN_CLOSE_NOWRITE, 294
  IN_CLOSE_WRITE, 294
  IN_CREATE, 294
  IN_DELETE, 294
  IN_DELETE_SELF, 294
  IN_DONT_FOLLOW, 298
  IN_IGNORED, 297, 299
  IN_ISDIR, 297
  IN_MASK_ADD, 298
  IN_MODIFY, 294
  IN_MOVE, 295
  IN_MOVE_SELF, 294
  IN_MOVED_FROM, 294, 298
  IN_MOVED_TO, 294, 298
  IN_ONESHOT, 298
  IN_ONLYDIR, 299
  IN_OPEN, 294
  IN_Q_OVERFLOW, 297
  IN_UNMOUNT, 297
  inicjalizacja interfejsu, 292
  łączenie zdarzeń przenoszenia, 298
  odczytywanie zdarzeń, 296
  rozmiar kolejki zdarzeń, 300
  usuwanie egzemplarza interfejsu, 300
  zaawansowane opcje obserwowania, 298
  zasysanie, 296
  zdarzenia, 295
    zaawansowane, 297
inotify_add_watch(), 293
inotify_event, 295, 300
inotify_init1(), 292
inotify_rm_watch(), 299
int, 23, 30, 45
interfejs
  binarny aplikacji, 17, 25, 26
  odpytywania zdarzeń, 117
    epoll_create(), 117
    epoll_ctl(), 118
    epoll_wait(), 121, 122
    oczekiwanie na zdarzenie, 121
    sterowanie działaniem, 118
    tworzenie egzemplarza, 117
    zdarzenia przełączane poziomem, 122
    zdarzenia przełączane zboczem, 122
  programistyczny dla standardu Pthreads, 240
  programowania aplikacji, 25
  programowy, 24
  systemowy, 29
    Linuksa, 17
    standardy, 27
  systemu operacyjnego
    przenośny, 27
  ustawiania czasu, 380
  źródłowy, 25

internal fragmentation, 316
interprocess communication, 34
interval timers, 392
intmax_t, 158
i-number, 31
invalid page, 302
ioctl(), 151, 290
  numer bloku fizycznego, 151
ionice, 202
ioprio_get(), 202
ioprio_set(), 202
iosched, 147
IOV_MAX, 113
IPC, 34, 36, 40
ISO, 28
ISO C++, 28
ISO C11, 28
ISO C95, 28
ISO C99, 28
ISO9660, 35
ITIMER_PROF, 393
ITIMER_REAL, 393
ITIMER_VIRTUAL, 393
itimerspec, 397
itimerval, 393
i-węzły, 31, 253
  dowiązania symboliczne, 33
  sortowanie operacji wejścia i wyjścia, 149
  katalogi, 32

J

jądro, 13, 17
jądro Linuksa, 415
jednostka pracy, 231
język C, 28
język C++, 25
jiffies counter, 370
jiffy, 370
jitter, 206
job, 157

K

katalogi, 31, 253, 269
  aktualny katalog roboczy, 270
  czytanie ze strumienia, 278
  dwie kropki, 270
  elementy, 269
  funkcje systemowe, 280
  główny, 32, 270
  kropka, 270
  nadrzędne, 269
  odczyt zawartości, 278
  podkatalog, 269
  strumień, 278
  ścieżki, 270
  tworzenie, 275
  usuwanie, 276
  zamykanie strumienia, 279
  zmiana aktualnego katalogu roboczego, 272
kernel-level threading, 229
kill(), 345, 351
killpg(), 353
klasa
  cykliczna, 209
  FIFO, 208
  szeregowania, 208
  zwykła, 209
klucze, 262
  niezdefiniowany, 262
  wartość niepusta, 262
  zdefiniowany, 262
kod przykładowy
  używanie, 19
kolejka FIFO
  dla odczytów, 144
  dla zapisów, 144
kolejność zapisów, 59
kompatybilność
  binarna, 26
  w przód, 29
  źródłowa, 26
kompilator
  GNU C, 17
  GNU C++, 25
  języka C, 24
komunikacja międzyprocesowa, 34, 40
  blokowanie deskryptora, 71
komunikacja poza kolejką, 290
konfiguracja zarządcy operacji wejścia i wyjścia, 147
konsolidowanie implementacji Ptreads, 241
konwencja wywołań, 26
konwencje typograficzne, 18
konwersje czasu, 381
kończenie wątków, 243
kopiowanie
  plików, 286
  podczas zapisu, 164, 302
koszty
  przełączania, 196
  wielowątkowości, 228

L

latency, 206
LBA, 143
lchown(), 259
level-triggered, 122
lgetxattr(), 264
libc, 24
libpthread, 241
libstdcxx, 25
licznik chwil, 370
licznik dowiązań, 33
liczniki, 392
  alarmy, 392
  czas wygaśnięcia, 392
  inicjalizowanie, 396
  interwałowe, 392
  itimerspec, 397
  itimerval, 393
  odczyt czasu wygaśnięcia, 397
  odczyt wartości przepełnienia, 398
  opóźnienie, 392
  sigevent, 395
  timespec, 397
  timeval, 393
liczniki
  tworzenie, 395
  usuwanie, 399
  zaawansowane, 394
lider grupy procesów, 184
lider sesji, 185
likely(), 407
LINE_MAX, 95
link, 31, 280
link(), 281
linker, 26
Linus Elevator, 144
Linux, 13, 21
  pliki specjalne, 33
  standardy, 28
Linux Foundation, 29
Linux Standard Base, 29
LinuxThreads, 240
lista, 160
  atrybutów rozszerzonych, 267
listxattr(), 267
listy kontroli dostępu, 39
llistxattr(), 267
localtime(), 382
localtime_r(), 382
lock(), 237
login, 38
logowanie użytkownika, 38
lokalizacja sekwencyjna, 83
LONG_MAX, 56
lremovexattr(), 268
LSB, 29
lseek(), 66
  kody błędów, 67
  ograniczenia, 68
lsetxattr(), 265, 266
lstat(), 254, 283
luka, 67

Ł

łączenie wątków, 246

M

M_CHECK_ACTION, 320
M_MMAP_MAX, 320
M_MMAP_THRESHOLD, 320
M_MXFAST, 320
M_TOP_PAD, 320
M_TRIM_THRESHOLD, 321
MADV_DOFORK+, 135
MADV_DONTFORK, 135
MADV_DONTNEED, 135
MADV_NORMAL, 134, 135
MADV_RANDOM, 134, 135
MADV_SEQUENTIAL, 135
MADV_WILLNEED, 135, 136
madvise(), 134
  kody błędów, 136
  wartości powrotne, 136
major number, 289
make, 22, 382
maksymalny wiek bufora, 60
mallinfo, 323
malloc, 404
malloc(), 304, 306
MALLOC_CHECK_, 323
malloc_stats(), 324
malloc_trim(), 322
malloc_usable_size(), 322
mallopt(), 319
  parametry, 321
man pages, 242
manipulowanie bajtami, 332
MAP_ANONYMOUS, 318
MAP_FAILED, 127, 131
MAP_FIXED, 124
MAP_PRIVATE, 125, 318
MAP_SHARED, 125, 126
mappings, 303

maska uprawnień tworzonych plików, 50
maximum buffer age, 60
MCL_CURRENT, 334
MCL_FUTURE, 334
mechanizmy
  blokowania, 106
  IPC, 40
  przydzielania pamięci, 327
memalign(), 312
memchr(), 331
memcmp(), 329
memcpy(), 331
memfrob(), 332
memmem(), 332
memmove(), 330
memory areas, 303
memory leak, 310
memory regions, 303
mempcpy(), 331
memrchr(), 331
memset(), 307, 329
metadane, 253
  i-węzeł, 31
  pozycja w pliku, 30
miękkie wiązanie, 203
migracja procesu, 202
MIME type sniffing, 262
mincore(), 336
minimalna ziarnistość, 197
minimum granularity, 197
minor number, 289
mkdir(), 275
mktime(), 381
mlock(), 221, 333
mlockall(), 221, 334
mmap(), 123, 317
  kody błędów, 127
  parametry, 317
  strony, 126
  wady używania, 130
  wartości powrotne, 127
  zalety używania, 130
MMU, 126, 164
mode, 49
mode_t, 257
modele wątkowości, 229
  wątkowość mieszana, 230
  wątkowość na poziomie użytkownika, 229
  współprogramy i włókna, 230
monitorowanie plików, 292
monotonic time, 369
montowanie, 35
mounting, 35
mounting point, 35
mprotect(), 132
  kody błędów, 132
  wartości powrotne, 132
mq_open(), 221
mremap(), 131
  kody błędów, 131
  wartości powrotne, 131
MREMAP_MAYMOVE, 131
MS_ASYNC, 133
MS_INVALIDATE, 133
MS_SYNC, 133
msync(), 133
  kody błędów, 134
  wartości powrotne, 134
multiplexed I/O, 71
multithreaded, 37, 225
munlock(), 335
munlockall(), 335
munmap(), 128, 317, 318
muteksy, 236
  blokowanie, 249
  inicjalizowanie, 248
  odblokowywanie, 249
  standardu Pthreads, 248
  użycie, 250
  zakleszczenia, 238
mutex, 237

N

N:1 threading, 229
N:M threading, 230
named pipes, 34
namespace, 34
nanosleep(), 387
Native POSIX Thread Library, 240
Native POSIX Threading Library, 37
nazwane potoki, 34
nazwy użytkowników, 38
Next Generation POSIX Threads, 240
NFS, 35
NGPT, 240
nice, 199
nice values, 199
nice(), 199
nieautomatyczne blokowanie plików, 106
nieblokowane operacje na strumieniu, 107
nieblokujące operacje wejścia i wyjścia, 55
niedeterminizm, 217
no-execute, 124
noinline, 410
nonblocking I/O, 55

Noop I/O Scheduler, 147
noreturn, 404
normal class, 209
notacja przedziałów, 131
NPTL, 37, 198, 240
null device, 289
numer
  bloku, 142
  i-węzła, 31, 253
NX, 124

O

O_APPEND, 47, 57
O_ASYNC, 47
O_CLOEXEC, 47
O_CREAT, 47
O_DIRECT, 47, 64
O_DIRECTORY, 47
O_DSYNC, 48, 63
O_EXCL, 47
O_LARGEFILE, 48
O_NOATIME+, 48
O_NOCTTY, 48
O_NOFOLLOW, 48
O_NONBLOCK, 48, 55, 58
O_RDONLY, 46
O_RDWR, 46
O_RSYNC, 48, 63
O_SYNC, 48, 63, 141
O_TRUNC, 48
O_WRONLY, 46
obcięcie bufora, 82
obcinanie, 31
  plików, 69
obiekt
  pthread_mutex_t, 248
  z plikiem zależnym, 250
obracanie, 383
obsługa
  błędów, 40
  grup procesów, 187
  procesu zombie, 169
  sesji, 186
  stanu uśpienia, 386, 387
  sygnału, 340
obsłużenie procesu, 37
obszary pamięci, 303
oczekiwanie
  na określony proces, 171
  na sygnał, 347
  na zakończone procesy potomka, 169
  na zbiór sygnałów, 358
  w pętli, 216
odblokowywanie
  muteksów, 249
  pamięci, 335
odczyt
  aktualnego katalogu roboczego, 271
  atrybutu rozszerzonego, 264
  czasu wygaśnięcia licznika, 397
  plików, 52
  pozycyjny, 68
  wartości przepełnienia licznika, 398
  z wyprzedzeniem, 83, 136
  zawartości katalogu, 278
odczyty nieblokujące, 55
odłączanie wątków, 246, 247
odłączenie pliku, 33
odmontowanie, 35
odpytywanie zdarzeń, 117
odwrócenie priorytetów, 239
odwzorowania, 303
  numerów sygnałów na łańcuchy znakowe, 350
  pliku na przestrzeń adresową procesu, 125
odwzorowywanie plików w pamięci, 123
  dodatkowe sygnały, 128
  madvise(), 134
  mmap(), 123, 130
  mprotect(), 132
  mremap(), 131
  msync(), 133
  munmap(), 128
  odczyt z wyprzedzeniem, 136
  porady, 134
  przykład, 128
  rozmiar strony, 126
  synchronizacja odwzorowanego pliku, 133
  usuwanie odwzorowania, 128
  zmiana rozmiaru odwzorowania, 131
  zmiana uprawnień odwzorowania, 132
odzyskiwanie oczekujących sygnałów, 358
offsetof(), 409, 410
ogólny model pliku, 81
ograniczenia domyślne, 222
ograniczenia zasobów systemowych, 218
  miękkie, 219, 223
  odczytywanie, 223
  ograniczenia domyślne, 222
  RLIMIT_AS, 220
  RLIMIT_CORE, 220
  RLIMIT_CPU, 220
  RLIMIT_DATA, 220
  RLIMIT_FSIZE, 220

ograniczenia zasobów systemowych
RLIMIT_LOCKS, 220
RLIMIT_MEMLOCK, 221
RLIMIT_MSGQUEUE, 221
RLIMIT_NICE, 221
RLIMIT_NOFILE, 221
RLIMIT_NPROC, 221
RLIMIT_RSS, 221
RLIMIT_RTPRIO, 222
RLIMIT_RTTIME, 222
RLIMIT_SIGPENDING, 222
RLIMIT_STACK, 222
twarde, 219, 223
ustawianie, 223
oldstate, 245
on_exit(), 166, 168
OOM, 337
OOM killer, 337
op, 119
Open Software Foundation, 27
open(), 24, 46
wartości zwracane, 52
znaczniki, 46
open_sysconf(), 327
opendir(), 47, 278
operacje
asynchroniczne, 140
atomowe, 236
dla atrybutów rozszerzonych, 264
na pamięci, 328
niezsynchronizowane, 140
synchroniczne, 140
zbioru sygnałów, 356
zsynchronizowane, 140, 141
operacje wejścia i wyjścia
asynchroniczne, 111, 141, 228
bezpośrednie, 64
buforowane, 87
w przestrzeni użytkownika, 87
całkowity czas oczekiwania, 63
dla deskryptorów, 71
liniowe, 112
nieblokujące, 55, 71
odwzorowane w pamięci, 111
optymalizowanie wydajności, 148
porada dla operacji plikowych, 111
przenoszenie, 108
rozproszone, 109, 111, 112
sortowanie
wg numeru fizycznego bloku, 151
wg numeru i-węzła, 149
wg ścieżki, 149
standardowe, 106
szeregowanie w przestrzeni użytkownika, 148
typowe, 90
wektorowe, 112
wydajność, 142
wykonywanie, 66
zaawansowane, 111
zarządcy, 142
działanie, 143
niesortujący, 147
przewidujący, 145
wspomaganie odczytów, 143
wybór i konfiguracja, 147
z terminem nieprzekraczalnym, 144
ze sprawiedliwym szeregowaniem, 146
zsynchronizowane, 48, 60
zwielokrotnione, 70, 228
operational deadlines, 205
operator postinkrementacji, 234
opóźnienie, 206
odczytu, 143
opóźniony zapis, 59
stron, 81, 84
oprogramowanie systemowe, 15, 21
opróżnianie strumienia, 102
options, 172
optymalizacja
gałęzi kodu, 407
wartości licznika, 114
wydajności operacji wejścia i wyjścia, 148
organizacja wewnętrzna jądra, 81
origin, 66
OSF, 27
oszczędzanie pamięci, 227
otoczenie linuksowe, 30
otrzymywanie
identyfikatora grupy, 184
identyfikatora użytkownika, 184
otwieranie plików, 46, 91
tryb dopisywania, 47
tryb nieblokujący, 48
tryb zapisu, 48
zsynchronizowane operacje wejścia i wyjścia, 48
otwieranie strumienia poprzez deskryptor pliku, 92
overcommitment, 337

P

P_ALL, 174
P_GID, 174
P_PID, 174
packed, 405
page fault, 302

PAGE_SIZE, 127
paging, 216
pakowanie struktury, 405
pamięć, 301
  dynamiczna, 304
  flash, 34
  wirtualna, 225
parallelism, 233
parametry graniczne, 206
parent directory, 269
partitionable, 35
partycjonowane urządzenia, 35
path injection, 161
pathname, 270
pathname resolution, 32
pathnames, 32
pause(), 347
per-process namespaces, 35
perror(), 42, 54
pętla nieskończona, 194
pętla zdarzeń, 232
PGID, 184
pid, 172
PID, 37, 156, 157
pid_max, 157
pid_t, 157, 174
pierwszoplanowa grupa procesów, 185
pipe, 198
pliki, 30, 253
  atrybuty rozszerzone, 261
  bezpośrednie operacje wejścia i wyjścia, 64
  binarne, 24, 155
  blokowanie, 106
  czytanie, 52
    wszystkich bajtów, 54
  deskryptor, 30, 45
  długość, 31
  dowiązania, 31, 32, 280
  fds, 45
  informacje, 254
  i-węzły, 31, 253
  kompilowanie plików źródłowych, 19
  kopiowanie, 286
  licznik dowiązań, 33
  metadane, 253
  monitorowanie, 292
  nagłówkowe, 40
  obcinanie, 31, 69
  odczyt
    nieblokujący, 55
    pozycyjny, 68
  odłączenie, 33
  odwzorowywanie w pamięci, 123
  operacje wejścia i wyjścia, 45
  otwieranie, 46, 91
  pozycja, 30
  prawa własności, 259
  przechowywanie typu MIME, 262
  przenoszenie, 286
    wyniki, 288
  puste, 31
  rozmiar, 31, 255
  rzadkie, 67
  skrót, 33
  specjalne, 33
  specjalne FIFO, 34
  szukanie, 66
    poza końcem pliku, 67
  śledzenie zdarzeń, 292
  tablica plików, 45
  tryb
    do odczytu, 47, 92
    dopisywania, 47, 57, 91
    dostępu, 46
    nieblokujący, 48
    otwarcia, 30
    zapisu, 48
  tworzenie, 51
  uprawnienia, 39, 49, 257
  urządzenia
    blokowe, 34
    znakowe, 34
  urządzeń, 34
  usuwanie, 33, 284
  właściciel, 49
  wskaźnik, 90
  xattrs, 261
  zamykanie, 65
  zapis, 56
    pozycyjny, 68
  zapisy
    częściowe, 57
    nieblokujące, 58
  znacznik końca, 34
  zsynchronizowane operacje wejścia i wyjścia, 60
  zwielokrotnione operacje wejścia i wyjścia, 70
  zwykłe, 30
plikowe operacje wejścia i wyjścia, 45
pmap, 303
pobieranie
  aktualnego czasu, 376
  czasu procesu, 378
podajniki szybkie, 320
podkatalog, 269
podział, 315

poll(), 76, 79, 80
  kody błędów, 78
  wartości powrotu, 78
POLLER, 77
POLLHUP, 77
POLLIN, 77
POLLMSG, 77
POLLNVAL, 77
POLLOUT, 77
POLLPRI, 77
POLLRDBAND, 77
POLLRDNORM, 77
POLLWRBAND, 77
POLLWRNORM, 77
połączone wątki, 246
pomnożenie, 158
poprawa czasu reakcji, 226
porady, 137, 139
  odwzorowywanie plików w pamięci, 134
  standardowe plikowe operacje wejścia i wyjścia, 137
porównywanie
  bajtów, 329
  identyfikatorów wątków, 243
Portable Operating System Interface, 27
POSIX, 27
  identyfikator pthread_t, 243
POSIX 1003.1c, 37
POSIX 1988, 27
POSIX 1990, 27
POSIX 1993, 207
POSIX 1995, 239
POSIX 2008, 28
POSIX threads, 239
POSIX.1, 27
POSIX.1b, 28, 207
POSIX.1c, 28, 239
POSIX_FADV_DONTNEED, 137, 138, 139
POSIX_FADV_NOREUSE, 137, 138
POSIX_FADV_NORMAL, 137, 138
POSIX_FADV_RANDOM, 137, 138, 139
POSIX_FADV_SEQUENITAL, 139
POSIX_FADV_SEQUENTIAL, 137, 138
POSIX_FADV_WILLNEED, 137, 138, 139
posix_fadvise(), 137
  kody błędów, 138
  wartości powrotne, 138
posix_memalign(), 311
potok, 34, 46, 198
potomek, 37
powielanie łańcuchów znakowych na stosie, 326
powłoka, 21
  systemowa, 38
powrotny adres funkcji, 410
poziomy uprzejmości, 199
pozycja
  elementu w strukturze, 409
  w pliku, 30
PPID, 157
ppoll(), 80
prawa własności, 259
prawdziwa równoległość, 233
prawdziwa współbieżność, 226
pread(), 68, 69
  kody błędów, 69
precyzyjne ustawianie czasu, 379
preemptive, 194
primary group, 38
PRIO_PGRP, 200
PRIO_PROCESS, 200
PRIO_USER, 200
priorytet statyczny, 208
priorytety procesu, 199
  getpriority(), 200
  nice(), 199
  setpriority(), 200
priorytety wejścia i wyjścia, 201
process descriptor, 36
process ID, 37, 156
process time, 369
process tree, 37
processor-bound, 194
procesy, 36, 155, 225
  blokowane, 193
  child, 37, 157
  demony, 189
  deskryptor, 36
  drzewo, 37
  duch, 179
  format wykonywalny, 36
  grupa, 157, 179
  grupy procesów, 157, 184
  hierarchia, 37, 157
  identyfikator, 37, 156
    procesu rodzicielskiego, 158
  inicjalizujący, 37, 156
  jałowy, 156
  jednowątkowe, 37, 155, 225
  klasy FIFO, 208
  kończenie, 166, 167
  kopiowanie podczas zapisu, 164
  lekkie, 227
  migracja, 202
  obsłużenie, 37
  oczekiwanie
    na określony proces, 171
    na zakończone procesy potomka, 169
  ograniczenia zasobów systemowych, 218
  otrzymywanie identyfikatora procesu, 158

parent, 37, 157
PID, 37, 156, 157
pid_t, 157
pomnożenie, 158
potomek, 37, 157, 162
potomny, 37, 157
powiązania, 186
PPID, 157
priorytety, 199
przydział identyfikatorów, 156
rodzic, 157, 162
rodzicielski, 37, 157
rozwidlenie, 158
strategie szeregowania, 211
sygnały, 39
szeregowanie, 193
z wywłaszczaniem, 195
tworzenie, 37
uruchamialne, 193
uruchamianie, 158
i oczekiwanie na nowy proces, 177
użytkownik, 157, 179
wątki, 37
wejście do powłoki systemowej, 177
wiązanie do konkretnego procesora, 202
wielowątkowe, 37, 105, 155, 225
z N wątkami, 229
zalecane modyfikacje identyfikatorów użytkownika i grupy, 183
zarządca, 193
zarządzanie, 155, 230
zaawansowane, 193
znaczniki kontekstu, 45
zombie, 37, 169, 179
związane z procesorem, 194
związane z wejściem i wyjściem, 1957
program, 155
programowanie
aplikacji, 22
systemowe, 15, 21, 43
a programowanie aplikacji, 22
obsługa błędów, 40
podstawy, 23
w Linuksie, 18
w języku C, 413
w Linuksie, 29, 414
programy wielowątkowe, 37
projektowanie
systemu operacyjnego, 415
wysokopoziomowe, 22
prot, 124
PROT_EXEC, 124
PROT_NONE, 124
PROT_READ, 124, 318
PROT_WRITE, 124, 318
przedział czasowy, 194
przekierowania, 46
przekroczenie zakresu zatwierdzenia, 337
przełączanie
poziomem, 122
wewnątrzprocesowe, 227
zboczem, 122, 123
przełączanie kontekstu, 227
procesy i wątki, 227
wątki na poziomie użytkownika, 229
przełącznik pliku wirtualnego, 81
przenoszenie
bajtów, 330
plików, 286
przepełnienia, 391
licznika, 391
przerwania
generowane poziomem, 123
generowane zboczem, 123
przerwanie programowe, 23
przerzucanie stron, 83
przestrzeń adresowa procesu, 301
przestrzeń nazw, 34
dla atrybutów rozszerzonych, 263
dla procesu, 35
security, 263
system, 263
trusted, 263
user, 263
przeszukiwanie pliku, 66, 67
przydział identyfikatorów procesów, 156
przydział oportunistyczny, 336
przydzielanie, 301
przydzielanie pamięci
anonimowe odwzorowania, 316
dla tablic, 306
dynamicznej, 304
sposoby, 328
wyrównanej, 311
pselect(), 75
psignal(), 351
pthread, 241
pthread_attr_t, 242
pthread_cancel(), 244
PTHREAD_CANCEL_ASYNCHRONOUS, 245
PTHREAD_CANCEL_DEFERRED, 245
PTHREAD_CANCEL_DISABLE, 245
PTHREAD_CANCEL_ENABLE, 245
pthread_create(), 241
pthread_detach(), 247
pthread_equal(), 243
pthread_exit(), 244

pthread_join(), 246
pthread_mutex_lock(), 249, 251
pthread_mutex_unlock(), 249, 251
pthread_self(), 243
pthread_setcancelstate(), 245
pthread_setcanceltype(), 245
pthreads, 37
Pthreads, 240
ptrace(), 170
pula entropii, 289
punkt
  anulowania, 245
  montowania, 35
  podziału, 315
  wywołania, 81
pure, 403
pure function, 403
pwrite(), 68, 69
  kody błędów, 69

R

race condition, 233
RAII, 250
raise(), 353
raport o błędach, 42
read(), 23, 52
  czytanie wszystkich bajtów, 54
  odczyty nieblokujące, 55
  ograniczenia rozmiaru, 56
  stany wyjściowe, 53
  wartości błędów, 55
  wartości zwracane, 53
readahead, 83
readahead(), 137, 138
readdir(), 278, 280
readv(), 112
  implementacja, 116
  użycie, 115
  wartości powrotne, 113
real time, 369
real UID, 38
realloc(), 307
  sprawna obsługa, 132
real-time, 205
region krytyczny, 106
regiony pamięci, 303
regular files, 30
rejestry maszynowe, 24
rejon krytyczny, 233
rekordy, 30
relative pathname, 32, 270
remove(), 285
removexattr(), 268
rename(), 286
resident set size, 221
Resource Acquisition Is Initialization, 250
resource limits, 218
rewind(), 101
RLIM_INFINITY, 219, 220, 223
rlimit, 163
RLIMIT_AS, 220
RLIMIT_CORE, 219, 220
RLIMIT_CPU, 219, 220
RLIMIT_DATA, 220
RLIMIT_FSIZE, 219, 220
RLIMIT_LOCKS, 220
RLIMIT_MEMLOCK, 221
RLIMIT_MSGQUEUE, 221
RLIMIT_NICE, 221
RLIMIT_NOFILE, 78, 221
RLIMIT_NPROC, 163, 221
RLIMIT_OFILE, 221
RLIMIT_RSS, 221
RLIMIT_RTPRIO, 222
RLIMIT_RTTIME, 222
RLIMIT_SIGPENDING, 222
RLIMIT_STACK, 222, 223
rmdir(), 276, 285
root, 38, 179
root directory, 32, 270
root filesystem, 35
round-robin, 146
round-robin class, 209
rozdzielczość źródła czasu, 375
rozliczanie ścisłe, 338
rozmiar
  bloku, 88, 89
  bufora, 89
  grupy rezydentnej, 221
  pliku, 31, 255
  słowa, 68
  strony, 35, 126, 302
rozpoznawanie typu MIME, 262
rozproszone operacje wejścia i wyjścia, 109, 112
  niepodzielność, 112
  readv(), 112, 115
  sprawność, 112
  writev(), 112
  wydajność, 112
  wzorzec kodowania, 112
rozsynchronizowanie, 206
rozwidlenie, 158
równoległość, 233
  prawdziwa, 233
RSS, 221
ruid, 182, 183

runnable, 193
rusage, 176
rzeczywisty GID, 38
rzeczywisty identyfikator użytkownika, 38, 180
rzeczywisty UID, 38

S

S_IRGRP, 50
S_IROTH, 50
S_IRUSR, 50
S_IRWXG, 50
S_IRWXO, 50
S_IRWXU, 50
S_ISREG(), 129
S_ISVTX, 277
S_IWGRP, 50
S_IWOTH, 50
S_IWUSR, 50
S_IXGRP, 50
S_IXOTH, 50
S_IXUSR, 50
SA_NOCLDSTOP, 360
SA_NOCLDWAIT, 360
SA_NODEFER, 360
SA_NOMASK, 360
SA_ONESHOT, 360
SA_ONSTACK, 360
SA_RESETHAND, 361
SA_RESTART, 360
SA_SIGINFO, 360
saved UID, 38
sbrk(), 315
scalanie, 143
scatter-gather I/O, 109
SCHED_BATCH, 209
SCHED_FIFO, 208, 209, 210
sched_get_priority_max(), 213
sched_get_priority_min(), 213
sched_getaffinity(), 203
sched_getparam(), 211, 212
sched_getscheduler(), 210
SCHED_OTHER, 208, 209, 210
SCHED_RR, 208, 209, 210, 214
sched_rr_get_interval(), 214
sched_setaffinity(), 203
sched_setparam(), 211
sched_setscheduler(), 210
sched_yield(), 197, 198
scheduler, 193
Scheduler Activations, 230
scheduling class, 208
scheduling policy, 208
schemat przydziału wspieranej pamięci, 316
ScopedMutex, 250
security, 263
SEEK_CUR, 66, 100
SEEK_END, 66, 100
SEEK_SET, 66, 100, 101
segment przechowywania bloku, 36
segmenty
  bss, 303
  dane, 303
  stos, 303
  tekst, 303
sekcje, 36
  absolutne, 36
  bss, 36
  danych, 36
  niezdefiniowana, 36
  tekstu, 36
sektor, 35
select(), 71, 80, 390
  kody błędów, 73
  przenośny sposób wstrzymania wykonania aplikacji, 75
  użycie funkcji, 74
  wartości powrotu, 73
sesja, 185
  identyfikator, 186, 187
  obsługa, 186
  tworzenie, 186
set group ID, 49
set_tid_address(), 23
setegid(), 182
seteuid(), 182, 183, 184
setgid(), 181
setitimer(), 342, 344, 345, 392, 393
setpgid(), 187
setpgrp(), 189
setpriority(), 200, 201
setregid(), 182
setresgid(), 183
setresuid(), 183
setreuid(), 182
setrlimit(), 219, 224
setsid(), 186, 190
settimeofday(), 379, 380
setuid, 180
setuid(), 181, 184
setvbuf(), 104, 105
setxattr(), 265
SGID, 49, 161, 275
shell, 21
shmctl(), 221
shortcut, 33
si_code, 175, 363
si_pid, 174

si_signo, 175
si_status, 175
si_uid, 174
sieciowy system plików, 35
SIG_BLOCK, 357
SIG_DFL, 347
SIG_IGN, 347
SIG_SETMASK, 357
SIG_UNBLOCK, 357
SIGABRT, 341, 342
sigaction, 359
sigaction(), 169, 359
sigaddset(), 356
SIGALRM, 341, 342
sigandset(), 356
SIGBUS, 128, 341, 343
SIGCHLD, 169, 177, 341, 343
SIGCONT, 341, 343
sigdelset(), 356
sigemptyset(), 356
SIGEV_NONE, 396
SIGEV_SIGNAL, 396
SIGEV_THREAD, 396
sigevent, 395
sigfillset(), 356
SIGFPE, 341, 343
sighandler_t, 347
SIGHUP, 40, 341, 343
SIGILL, 341, 343
siginfo_t, 174, 361
SIGINT, 177, 185, 340, 341, 344
SIGIO, 47, 341, 344
sigisemptyset(), 356
sigismember(), 356
SIGKILL, 40, 220, 340, 341, 344
    kończenie procesu, 167
sigmask, 76
signal(), 169, 346, 347, 359
signal-safe, 40
signalstack(), 360
sigorset(), 356
sigpending(), 358
SIGPIPE, 58, 341, 344
sigprocmask(), 357, 358
SIGPROF, 341, 344
SIGPWR, 342, 344
sigqueue(), 366
SIGQUIT, 177, 342, 344
SIGSEGV, 128, 220, 342, 344
SIGSTKFLT, 342
SIGSTOP, 40, 340, 342, 345
sigsuspend(), 358
SIGSYS, 342, 345
SIGTERM, 340, 342, 345
    kończenie procesu, 167
SIGTRAP, 342, 345
SIGTSTP, 342, 345
SIGTTIN, 342, 345
SIGTTOU, 342, 345
SIGURG, 342, 345
SIGUSR1, 342, 345
SIGUSR2, 342, 345
sigval, 366
SIGVTALRM, 342, 345
SIGWINCH, 342, 346
SIGXCPU, 220, 342, 346
SIGXFSZ, 342, 346
single threaded, 225
Single UNIX Specification, 27
single-threaded, 37
SIZE_MAX, 56
size_t, 56
sizeof(), 409
skrót, 33
skutki buforowania, 202
sleep(), 385
slurping, 296
SMT, 227
sockets, 34
soft affinity, 203
soft limit, 219
soft links, 282
soft real-time system, 206
Solid State Drives, 147
sortowanie, 143, 148
    wg numeru fizycznego bloku, 151
    wg numeru i-węzła, 149
    wg ścieżki, 149
sparse files, 67
special files, 33
specjalne węzły urządzeń, 289
sposoby przydzielania pamięci, 328
sprawiedliwe kolejkowanie, 196
SSIZE_MAX, 56, 59
ssize_t, 56
st_atime, 255
st_blksize, 254
st_blocks, 255
st_ctime, 255
st_dev, 254
st_gid, 254, 259
st_ino, 254
st_mode, 254, 257
st_mtime, 255
st_nlink, 254
st_rdev, 254
st_size, 254
st_uid, 254, 259
stacje CD-ROM, 34

stack, 37
stan anulowania, 245
  state, 245
  włączony, 245
  wyłączony, 245
stan braku pamięci, 337
stan oczekiwania, 385
stan uśpienia, 385
standard error, 45
standard I/O library, 90
standard in, 45
standard out, 45
standard Pthreads, 239
  API, 241
  call(), 240
  clone(), 240
  exit_group(), 240
  futex (), 240
  identyfikatory wątków, 243
  implementacje wątkowości w Linuksie, 240
  interfejs programistyczny, 240
  konsolidowanie implementacji Ptreada, 241
  kończenie wątków, 243
    przez inne wątki, 244
  łączenie i odłączanie wątków, 246
  muteksy, 248
  przykład wątkowości, 247
  strony z pomocą, 242
  synchronizacja, 241
  tworzenie wątków, 241
  typ pthread_t, 243
  współdzielenie zasobów przez wątki, 242
  zarządzanie wątkami, 241
standardowe operacje wejścia i wyjścia, 137
standardowe wejście, 45
standardowe wyjście, 45
standardowe wyjście błędów, 45
standardowy strumień błędów, 42
standardy, 27, 29
  języka C, 28
  K&R, 28
start_routine, 241, 243
start_routine(), 242
start_thread(), 247
stat, 89, 254
stat(), 151, 253, 255
  numer i-węzła, 150
static priority, 208
stderr, 42, 45
STDERR_FILENO, 46
stdin, 45, 70
STDIN_FILENO, 46
stdio, 90
stdout, 45
STDOUT_FILENO, 46
sterowanie operacjami wejścia i wyjścia, 290
sterta, 303
sticky, 277
stime(), 379
stos, 37, 324
strategia FIFO, 208
strategia jałowego szeregowania, 209
strategia szeregowania, 208
strdupa(), 326
strerror(), 42
strerror_r(), 42
strict accounting, 338
strndupa(), 326
strona, 126, 301
  nieprawidłowa, 302
  prawidłowa, 302
  wyrzucanie, 302
  zerowa, 36
stronicowanie, 216, 301
  na żądanie, 332
strsignal(), 351
struct, 314
struktura
  account, 234
  buffer_head, 84
  epoll_event, 119, 121
  inotify_event, 295, 300
  itimerspec, 397
  itimerval, 393
  pirate, 99
  pirate_ship, 304
  pollfd, 77
  rlimit, 219
  rowboat, 409
  rusage, 176
  sched_param, 210
  sigaction, 359
  siginfo_t, 361
  stat, 254
  time_t, 372
  timespec, 76, 372
  timeval, 72, 372
  timezone, 377
  tm, 373
  tms, 378
strumienie, 91, 144
  czytanie, 93
  deskryptor pliku, 103
  informacja o aktualnym położeniu, 101
  nieblokowane operacje, 107
  opróżnianie, 102
  otwieranie poprzez deskryptor pliku, 92
  szukanie, 100

strumienie
wejściowe, 91
wejściowo-wyjściowe, 91
wyjściowe, 91
zamykanie, 93
zapis, 97
zapis pojedynczego znaku, 97
zwracanie znaków, 94
strumień bajtów, 30
strumień katalogu, 278
subdirectory, 269
suid, 180, 183
SUID, 161
supplemental groups, 38
SUS, 27
SUSv4, 28
swapping, 216
sygnały, 39, 339, 341, 342
akcja domyślna, 340
blokowanie, 357
dziedziczenie, 349
funkcje współużywalne, 355
identyfikatory, 340
ignorowane, 40
ignorowanie, 340
obsługa, 340
oczekiwanie
na sygnał, 347
na zbiór sygnałów, 358
oczekujące, 358
odwzorowanie numerów na łańcuchy znakowe, 350
odzyskiwanie oczekujących sygnałów, 358
si_code, 363
SIGCHLD, 169
SIGHUP, 40
siginfo_t, 361
SIGINT, 340
SIGKILL, 40, 340
SIGSTOP, 40, 340
SIGTERM, 340
uprawnienia, 352
uruchamianie, 349
wspierane przez system Linux, 341
współużywalność, 354
wygenerowanie, 340
wysyłanie, 340, 351
do grupy procesów, 353
do samego siebie, 353
z wykorzystaniem pola użytkowego, 366
zarządzanie, 346, 359
zbiory, 356
zerowy, 341
zgłoszenie, 340
symbolic links, 33, 282
symlink(), 283
symlinks, 33, 282
sympatyczne działanie, 198
sync(), 62
synchroniczne operacje, 140
synchronizacja, 236
buforów na dysku, 62
dla operacji odczytu, 141
dla operacji zapisu, 140
dostępu do danych, 105
funckje Pthreads, 241
muteksy, 236
odwzorowanego pliku, 133
operacji wejścia i wyjścia, 60
zakleszczenia, 238
sys_siglist[], 350
syscalls, 23
sysconf(), 126, 168
sysctl, 337
system, 263
system calls, 23
system czasu rzeczywistego, 205
blokowanie pamięci, 216
determinizm, 216
klasa szeregowania, 208
określanie zakresu poprawnych priorytetów, 213
opóźnienie, 206
parametry graniczne, 206
priorytet statyczny, 208
projektowanie programów, 215
rozsynchronizowanie, 206
SCHED_BATCH, 209
SCHED_OTHER, 209
strategia
cykliczna, 209
FIFO, 208
szeregowania, 208
szeregowania wsadowego, 209
zwykła, 209
ścisłego, 205
środki ostrożności przy pracy, 215
ustalanie
priorytetów, 208
strategii szeregowania, 210
ustawianie parametrów szeregowania, 211
wcześniejsze zapisywanie danych, 216
wiązanie do procesora, 217
wspieranie przez system Linux, 207
zwykłego, 206
system operacyjny
definiowanie ABI, 26
kooperacyjny, 194

wielozadaniowy, 193
z wywłaszczaniem, 194
system opóźnionego zapisu, 60
system plików, 30, 34
atrybuty rozszerzone, 262
ext4, 35
FAT, 35
główny, 35
ISO9660, 35
montowanie, 35
NFS, 35
odmontowanie, 35
organizacja wewnętrzna jądra, 81
przechowywanie typu MIME, 262
punkt montowania, 35
sektor, 35
sieciowy, 35
VFS, 81
wirtualny, 35, 81
XFS, 35
system programming, 21
system przydzielania pamięci
uruchamianie programów, 323
system software, 21
system timer, 370
system uprawnień, 38
system(), 177
problemy bezpieczeństwa, 178
systemy wbudowane, 207
SysVinit, 217
sytuacja wyścigu, 233
szeregowanie operacji wejścia i wyjścia
w przestrzeni użytkownika, 148
szeregowanie procesów, 193
procesy związane z procesorem, 194
procesy związane z wejściem i wyjściem, 194
przedział czasowy, 194
sched_yield(), 198
szeregowanie z wywłaszczaniem, 195
udostępnianie czasu procesora, 194, 196, 197
wielozadaniowe systemy operacyjne, 194
szukanie w strumieniu, 100

Ś

ścieżki, 32, 142, 270
bezwzględne, 32, 270
pełne, 32
względne, 32, 270
śledzenie zdarzeń związanych z plikami, 292

T

tablica plików, 45
tablice, 306
o długości zerowej, 296
o zmiennej długości, 326
takt, 370
target latency, 196
temporal locality, 194
terminal, 48
terminal sterujący, 185
The Open Group, 27
thread pool
abstrakcja programistyczna, 226
thread-per-connection
abstrakcja programistyczna, 226
threads of execution, 37
tick, 370
TID, 243
time(), 376
TIME_BAD, 385
TIME_DEL, 385
TIME_INS, 385
TIME_OK, 385
TIME_OOP, 385
time_t, 372, 377
TIME_WAIT, 385
timeout, 72
TIMER_ABSTIME, 389
timer_create(), 394, 395, 397
timer_delete(), 394, 399
timer_getoverrun(), 398
timer_gettime(), 397
timer_settime(), 394, 396
times(), 378
timeslice, 194
timespec, 372, 397
timeval, 372, 393
timex, 384
TLB, 227
TLS, 240
tłumaczenie
katalogu, 32
ścieżki, 32
tm, 373
tmpfile(), 166
tms, 378
toolchain, 26
translation lookaside buffer, 227
trap, 23
truncation, 31
trusted, 263

tryb
automatycznego zamykania, 117
dopisywania, 58
otwierania plików, 91
twarde wiązanie, 203
tworzenie
anonimowe odwzorowanie w pamięci, 317
dowiązania, 281
dowiązania symboliczne, 283
katalogów, 275
kontekst interfejsu odpytywania zdarzeń, 117
liczniki, 395
pliki, 51
procesy, 37
sesja, 186
wątków, 241
typ
long, 68
unsigned long, 52
typ anulowania, 244
asynchroniczny, 245
opóźniony, 245
typedef, 157
typeof(), 408
typowe operacje wejścia i wyjścia, 90

U

udostępnianie czasu procesora, 194, 196, 197
futex, 198
sched_yield(), 197
UID, 38, 49
ulimit, 223
umask, 50
umieszczanie zmiennych globalnych
w rejestrach, 407
undefined section, 36
ungetc(), 94
unikanie przeciążenia, 84
unikanie zakleszczeń, 239
union, 314
Unix, 15, 30
unlikely(), 407
unlink(), 284
unlinking, 33
unlock(), 237
unmounting, 35
unsigned long, 314
unused, 405
uprawnienia, 38, 257
ACL, 39
bity uprawnień, 39
CAP_CHOWN, 259, 261
CAP_FOWNER, 258, 277
CAP_KILL, 352
CAP_SYS_ADMIN, 263
listy kontroli dostępu, 39
nowe pliki, 49
standardowe, 39
sygnały, 352
współdzielonych danych, 302
uruchamianie procesu, 158
urządzenia, 34
generator liczb losowych, 289
partycjonowane, 35
puste, 289
zapełnione, 289
zerowe, 289
urządzenia blokowe, 34
pliki, 34
sektor, 35
urządzenia terminalowe, 48
urządzenia znakowe, 34
pliki, 34
urządzenie tty, 185
useconds_t, 386
user, 263
user ID, 38
user-level threading, 229
usernames, 38
users, 38
usleep(), 386
ustalanie strategii szeregowania, 210
ustawianie
aktualnego czasu, 379
atrybutu rozszerzonego, 265
parametrów szeregowania, 211
wartości bajtów, 329
usuwanie
atrybuty rozszerzone, 268
elementu z systemu plików, 284
katalogów, 276
licznik, 399
pliki, 33
UTC, 370
util-linux, 216
uzupełnienie, 321
uzyskiwanie typu dla wyrażenia, 408
użytkownicy, 38, 179
/etc/passwd, 38
administrator, 38
efektywny identyfikator, 38
EUID, 38
grupy, 38
hasła, 38
identyfikator, 38
logowanie, 38

nazwy, 38
procesu, 157
root, 38, 179
rzeczywisty identyfikator, 38
UID, 38
zapisany identyfikator, 38
użytkownik API, 26
używanie zasobów po ich zwolnieniu, 310

V

Valgrind, 310
valid page, 302
valloc(), 312
variable-length arrays, 326
variadic, 159
vfork(), 165
VFS, 81, 82
virtual file switch, 81
VLA, 326
vm.overcommit_memory, 337
vm.overcommit_ratio, 338
VMS, 30
void, 411
volatile, 314

W

wait(), 169, 170, 171, 343
wait3(), 175
wait4(), 175
waitid(), 173
waiting on, 37
waitpid(), 170, 171, 175, 378
wall time, 369
warn_unused_result, 404
wątki, 37, 105, 155, 225
bezpieczeństwo, 105
blokowanie
plików, 106
z poziomu użytkownika, 198
brak zsynchronizowania, 228
domyślny, 241
flusher, 84
główny, 241
implementacja, 37
kończenie, 243
innych wątków, 244
samego siebie, 244
wszystkich wątków, 244
łączenie, 246
odłączanie, 246
pdflush, 84
pthreads, 37
stan anulowania, 244
stos, 37
typ anulowania, 244
zmiana, 245
wykonawcze, 37
wątkowość, 225
1:1, 229
implementacja wątkowości w Linuksie, 240
mieszana, 230
modele, 229
N:1, 229
N:M, 230
na poziomie jądra, 229
na poziomie użytkownika, 229
przydzielania wątku do połączenia, 231
standard Pthreads, 247
sterowana zdarzeniami, 232
thread-per-connection, 231
współbieżność, 233
wzorce, 231
WCONTINUED, 172, 174
wejście do powłoki systemowej, 177
wektor, 113, 160
WEXITED, 174
WEXITSTATUS, 177
węzeł informacji, 31
węzły urządzeń, 288
generator liczb losowych, 289
numer drugorzędny, 289
numer główny, 289
specjalne węzły, 289
urządzenie puste, 289
wheel, 157
which, 200
wiązanie procesów do konkretnego procesora, 202
wielkość wyrównania dla danego typu, 408
wieloprocesorowość, 216
wielowątkowość, 226
alternatywy, 228
koszty, 228
wielozadaniowe systemy operacyjne, 194
wielozadaniowość kooperatywna, 194
WIFCONTINUED, 170
WIFEXITED, 170
WIFSIGNALED, 170
WIFSTOPPED, 170
wirtualizacja, 36
wirtualna przestrzeń adresowa, 301
wirtualny procesor, 225
wirtualny system plików, 35, 81
ogólny model pliku, 81
przełącznik pliku wirtualnego, 81
punkty wywołania, 81

właściciel pliku, 49
właściwości lokalizacji, 82
włókna, 230
WNOHANG, 172, 174
WNOWAIT, 174
-Wpadded, 313
wprowadzanie w stan uśpienia, 390
wrapper, 305
wrappers, 24
write(), 23, 56
  kody błędów, 58
  ograniczenia rozmiaru, 59
  sposób działania, 59
  tryb dopisywania, 57
  zapis nieblokujący, 58
  zapisy częściowe, 57
writeback, 59, 84
writev(), 109, 112
  implementacja, 116
  użycie, 114
  wartości powrotne, 113
wskaźniki
  do funkcji, 411
  do pliku, 90
  void, 411
wspomaganie odczytów, 143
współbieżność, 226, 228, 233
  działanie, 235
współdzielenie danych, 302
współprogramy, 230
współużywalność, 354
WSTOPPED, 174
wstrzykiwanie ścieżki, 161
WUNTRACED, 172
wycieki pamięci, 310
wycofywanie znaku, 94
wydajność operacji wejścia i wyjścia, 142, 148
  sortowanie wg numeru fizycznego bloku, 151
  sortowanie wg numeru i-węzła, 149
  sortowanie wg ścieżki, 149
  szeregowanie w przestrzeni użytkownika, 148
wyłuskiwanie składników czasu, 373
wymiana danych, 216
wymuszanie sprawdzania wartości powrotnej dla procedur wywołujących, 404
wypełnienia, 313
wyrównanie
  dla struktury, 313
  dla tablicy, 313
  dla unii, 313
  zasada ścisłego wyrównania, 314
wyrównanie danych, 97, 310
  reguły, 313
  sposób naturalny, 97
wyrównywanie obciążenia, 203
wyrzucanie stron, 302
wysyłanie sygnału, 351
  do grupy procesów, 353
  do samego siebie, 353
  z wykorzystaniem pola użytkowego, 366
wyszukiwanie, 142
  bajtów, 331
wyścig do danych, 233
wyścigi, 233
wywłaszczanie, 195
wywoływanie funkcji systemowych, 23
wzajemne wykluczanie, 236
wzorce wątkowości, 231
  thread-per-connection, 231
  wątkowość sterowana zdarzeniami, 232
wzorzec
  przydzielania wątku do połączenia, 232
  RAII, 250
  sterowania zdarzeniami, 232

X

X/Open, 27
XATTR_CREATE, 266
XATTR_REPLACE, 266
xattrs, 261
XFS, 35
xmalloc(), 307
XOR, 332

Y

yield, 230
yielding, 194

Z

zabójca stanu braku pamięci, 337
zadania, 157
zakleszczenie, 238
  ABBA, 239
  śmiertelny uścisk, 239
  unikanie, 239
zakończenie procesu, 166, 167
zalecane modyfikacje identyfikatorów użytkownika i grupy, 183
zamknięcie w wątku, 105
zamykanie
  pliku, 65
  strumieni, 93
  strumienia katalogu, 279

zapis do pliku, 56
zapisy częściowe, 57
zapis do strumienia, 97
dane binarne, 98
łańcuch znaków, 98
pojedyncze znaki, 97
zapis nieblokujący, 58
zapis pozycyjny, 68
zapisany GID, 38
zapisany identyfikator użytkownika, 38, 180, 184
zapobieganie wplataniu funkcji, 402
zarządca operacji wejścia i wyjścia, 81, 142
Anticipatory I/O Scheduler, 146
CFQ, 146
Complete Fair Queuing I/O Scheduler, 146
Deadline I/O Scheduler, 144, 145
działanie, 143
konfiguracja, 147
Linus Elevator, 144
niesortujący, 147
Noop I/O Scheduler, 147
przewidujący, 145
scalanie, 143
sortowanie, 143
sprawiedliwe szeregowanie, 146
termin nieprzekraczalny, 144
wspomaganie odczytów, 143
wybór, 147
zarządca procesów, 193
zarządzanie
katalogami, 253
obciążeniem, 139
plikami, 253
procesami, 155, 193, 230
segmentem danych, 315
stanem uśpienia, 389
sygnałami, 346, 359
wątkami, 241
zadaniami, 184
zarządzanie pamięcią, 301
/dev/zero, 318
anonimowe odwzorowanie w pamięci, 315, 316
blokowanie
całej przestrzeni adresowej, 334
fragmentu przestrzeni adresowej, 333
pamięci, 332
błąd strony, 302
dane statystyczne, 323
fragmentacja
wewnętrzna, 316
zewnętrzna, 316
kopiowanie podczas zapisu, 302
MALLOC_CHECK_, 323
niskopoziomowa kontrola działania systemu przydzielania pamięci, 322
odblokowywanie pamięci, 335
ograniczenia blokowania, 335
operacje na pamięci, 328
pliki odwzorowane, 303
powielanie łańcuchów znakowych na stosie, 326
przekroczenie zakresu zatwierdzenia, 337
przestrzeń adresowa procesu, 301
przydział oportunistyczny, 336
przydzielanie pamięci
dla tablic, 306
dynamicznej, 304
wyrównanej, 311
regiony pamięci, 303
rozliczanie ścisłe, 338
schemat przydziału wspieranej pamięci, 316
stan braku pamięci, 337
stos, 324
stronicowanie, 301
na żądanie, 332
strony, 301
tablice o zmiennej długości, 326
współdzielenie danych, 302
wybór mechanizmu przydzielania pamięci, 327
wycieki pamięci, 310
wyrównanie danych, 310
zaawansowane operacje przydziału pamięci, 319
zarządzanie segmentem danych, 315
zmiana wielkości obszaru przydzielonej pamięci, 307
zwalnianie pamięci dynamicznej, 309
zasada przydzielania najmniej uprzywilejowanych uprawnień, 179
zasada ścisłego wyrównania, 314
zasoby procesu, 36
zasysanie, 296
zawieszone dowiązania symboliczne, 283
zbiory sygnałów, 356
zdarzenia
inotify, 295
przełączane poziomem, 122
przełączane zboczem, 122
zegar POSIX, 374
zegar sprzętowy, 371
zegar systemowy, 370, 382
zero device, 289
zero page, 36
zestaw narzędzi, 26

zmiana
aktualnego katalogu roboczego, 272
identyfikatora dla użytkownika lub grupy
efektywnego, 182
rzeczywistego, 181
w wersji BDS, 182
w wersji HP-UX, 183
zapisanego, 181
wielkości obszaru przydzielonej pamięci, 307
zmienne naturalnie wyrównane, 311
znacznik końca pliku, 34
znacznik zamykania, 47, 292
znaczniki dostępu, 124
zombie, 37, 169, 179
zsynchronizowane operacje, 140
zsynchronizowane operacje wejścia i wyjścia, 60
fdatasync(), 61
fsync(), 60
kody błędów, 61
O_DSYNC, 63
O_RSYNC, 63
O_SYNC, 63
sync(), 62
zwalnianie, 249
pamięci dynamicznej, 309
związek jeden do jednego, 229
zwielokrotnione operacje wejścia i wyjścia, 70, 228
implementacja, 71
poll(), 76, 80
ppoll(), 80
pselect(), 75
select(), 71, 80
wątkowość sterowana zdarzeniami, 232
zwiększanie wartości wyrównania dla zmiennej, 406

Linux

O'REILLY®

LINUX. PROGRAMOWANIE SYSTEMOWE

Jądro systemu Linux to jeden z największych projektów rozwijanych przez ogromną społeczność. Setki wolontariuszy dniami i nocami rozwijają najważniejszy element tego systemu operacyjnego. I robią to naprawdę skutecznie! Każde kolejne wydanie Linuksa zawiera dziesiątki nowinek oraz ulepszeń – jest coraz szybsze, bezpieczniejsze i po prostu lepsze. Jednak początkujący programiści mogą mieć problemy z wykorzystaniem usług dostarczanych przez kernel. Masz obawy, że nie odnajdziesz się w gąszczu możliwości współczesnego jądra systemu Linux?

Ta książka rozwieje je w mig. Jest to wyjątkowa pozycja na rynku wydawniczym. W trakcie lektury nauczysz się tworzyć niskopoziomowe oprogramowanie, które będzie się komunikowało bezpośrednio z jądrem systemu. Operacje wejścia i wyjścia, strumienie, zdarzenia, procesy to tylko część elementów, które błyskawicznie opanujesz. Ponadto nauczysz się zarządzać katalogami i plikami oraz poznasz koncepcję sygnałów. Książka ta jest niezastąpionym źródłem informacji dla wszystkich programistów pracujących z jądrem Linuksa. Docenisz tę lekturę!

Poznaj:

- metody zarządzania procesami
- zastosowanie sygnałów
- zaawansowane interfejsy wejścia i wyjścia
- jądro systemu od podszewki

Jądro systemu Linux od podszewki!

Robert Love – od wielu lat jest użytkownikiem i współtwórcą systemu Linux. Rozwija środowisko graficzne GNOME oraz jądro systemu. Pracuje jako projektant oprogramowania w firmie Google, był też członkiem zespołu projektującego system operacyjny Android. Jest autorem licznych książek poświęconych programowaniu w systemie Linux.

helion.pl
księgarnia internetowa

Nr katalogowy: 17000

Księgarnia internetowa:
http://helion.pl

Zamówienia telefoniczne:
0 801 339900
0 601 339900

Helion

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

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

Informatyka w najlepszym wydaniu

sięgnij po WIĘCEJ
KOD KORZYŚCI

ISBN 978-83-246-8285-0
9 788324 682850
Cena 79,00 zł