

Stručný obsah

1.	Hardware, procesory a vlákna	19
2.	Programování s ohledem na výkon	45
3.	Identifikování příležitostí pro paralelismus.....	93
4.	Synchronizace a sdílení dat	123
5.	Vlákna v rozhraní POSIX	145
6.	Práce s vlákny v systému Windows	199
7.	Automatická paralelizace a rozhraní OpenMP.....	243
8.	Ručně programovaná synchronizace a sdílení.....	289
9.	Škálování s vícejádrovými procesory	327
10.	Další techniky paralelizace	375
11.	Několik poznámek na závěr.....	403

Obsah

Úvodem	13
Komu je kniha určena	14
Cíle knihy	14
Struktura knihy	14
Poděkování.....	16
O autorovi.....	16
Zpětná vazba od čtenářů.....	17
Dotazy.....	17
Errata	17
Kapitola 1	
Hardware, procesory a vlákna.....	19
Prohlídka útrob počítače	20
Motivace pro vícejádrové procesory	21
Podpora pro více vláken na jediném čipu.....	23
Zvýšení rychlosti zpracování instrukcí pomocí proudových procesorových jader....	27
Použití mezipaměti pro uchovávání právě používaných dat.....	29
Použití virtuální paměti pro uložení dat	31
Překlad z virtuálních adres na fyzické adresy.....	32
Charakteristické vlastnosti víceprocesorových systémů.....	34
Vliv prodlevy a šírky pásma na výkon.....	36
Překlad zdrojového kódu do jazyka symbolických adres.....	37
Srovnání výkonu 32bitového a 64bitového kódu.....	38
Zajištění správného pořadí paměťových operací.....	40
Rozdíly mezi procesy a vlákny	41
Shrnutí	44
Kapitola 2	
Programování s ohledem na výkon	45
Definování výkonu	46
Algoritmická složitost.....	47
Příklady algoritmické složitosti.....	48

Význam algoritmické složitosti.....	51
S algoritmickou složitostí je třeba zacházet opatrně	52
Vliv struktury na výkon.....	53
Výkon a výhodné kompromisy ve zdrojovém kódu a strukturách sestavení	53
Strukturování aplikací pomocí knihoven.....	56
Vliv datových struktur na výkon	66
Role kompilátoru	71
Dva typy optimalizace kompilátoru	73
Výběr vhodných možností kompilátoru	74
Jak využít optimalizaci mezi soubory pro zlepšení výkonu	75
Použití optimalizace pomocí informací z profilu	78
Jak může potenciální aliasing ukazatelů bránit optimalizacím kompilátoru.....	80
Identifikování míst, kde se spotřebuje čas, pomocí profilování	83
Běžně dostupné profilovací nástroje	84
Jak neoptimalizovat.....	89
Výkon podle návrhu	90
Shrnutí	91

Kapitola 3

Identifikování příležitostí pro paralelismus 93

Použití více procesů pro zlepšení produktivity systému.....	94
Více uživatelů využívajících jediný systém	96
Zlepšování efektivity stroje prostřednictvím konsolidace	96
Použití kontejnerů pro izolování aplikací sdílejících jeden systém	97
Hostování více operačních systémů pomocí hypervizorů	98
Použití paralelizmu pro zlepšení výkonu jediné úlohy.....	100
Jeden přístup k vizualizaci paralelních aplikací	100
Jak může paralelní zpracování změnit výběr algoritmů	101
Amdahlův zákon	102
Stanovení maximálního praktického počtu vláken	103
Jak náklady na synchronizaci redukují škálování	105
Vzory paralelizace.....	106
Datový paralelismus pomocí instrukcí SIMD	106
Paralelizace pomocí procesů a vláken	108
Více nezávislých úloh	108
Více volně propojených úloh	109
Více kopií téže úlohy.....	110
Jediná úloha rozdělená na více vláken.....	110
Práce na jediném prvku pomocí proudu úloh	111

Rozdělení práce na klienta a server	112
Rozdělení odpovědnosti mezi producentem a konzumentem	113
Kombinování strategií paralelizace.....	113
Jak závislosti ovlivňují schopnost kódu běžet paralelně	114
Antizávislosti a výstupní závislosti	115
Rozbití závislostí pomocí spekulování.....	117
Kritické cesty	121
Identifikování příležitostí pro paralelizaci.....	121
Shrnutí	122

Kapitola 4

Synchronizace a sdílení dat **123**

Soupeření o data.....	124
Nástroje pro detekci soupeření o data.....	126
Jak se soupeření o data vyhnout.....	128
Synchronizační primitiva	128
Mutexy a kritické oblasti.....	129
Zámky spinlock	130
Semafora.....	130
Zámky čtenáři-zapisovač	131
Bariéry	132
Atomické operace a kód bez zámku	132
Uváznutí typu deadlock a livelock	134
Komunikace mezi vlákny a procesy.....	135
Paměť, sdílená paměť a soubory mapované do paměti.....	135
Podmínková proměnná.....	136
Signály a události.....	139
Fronty zpráv	139
Pojmenované roury	140
Komunikace prostřednictvím vrstev sítě	141
Další přístupy ke sdílení dat mezi vlákny	142
Soukromá data vlákna	142
Shrnutí	143

Kapitola 5

Vlákna v rozhraní POSIX **145**

Tvorba vláken	146
Ukončení vlákna.....	147
Předávání dat do a z podřízených vláken.....	148

Oddělená vlákna.....	149
Nastavení atributů pro vlákna v rozhraní POSIX.....	150
Kompilování vícevláknového kódu.....	153
Ukončení procesu.....	155
Sdílení dat mezi vlákny.....	156
Ochrana přístupu pomocí zámků mutexu.....	156
Atributy mutexu.....	158
Použití zámků spinlock.....	158
Zámky pro čtení a zápis	160
Bariéry.....	163
Semaforey.....	164
Podmínkové proměnné	171
Proměnné a paměť	175
Víceprocesové programování	179
Sdílení paměti mezi procesy	180
Sdílení semaforů mezi procesy.....	183
Fronty zpráv.....	184
Roury a pojmenované roury	186
Komunikace mezi procesy pomocí signálů	188
Sokety	193
Reentrantní kód a příznaky kompilátoru	196
Shrnutí	197

Kapitola 6

Práce s vlákny v systému Windows 199

Tvorba nativních vláken systému Windows.....	200
Ukončování vláken.....	205
Tvorba a obnova běhu pozastavených vláken	207
Popisovače na prostředky jádra	207
Metody synchronizace a sdílení prostředků	208
Příklad nutnosti synchronizace mezi vlákny	209
Ochrana přístupu ke kódu pomocí kritických sekcí	210
Ochrana oblastí kódu pomocí mutexů.....	212
Malé zámky pro čtení a zápis.....	213
Semaforey.....	215
Podmínkové proměnné	217
Signalizace dokončení události dalším vláknům či procesům	218
Práce s širokými řetězci ve Windows	220
Tvorba procesů	221

Sdílení paměti mezi procesy	224
Dědění popisovačů v podřízených procesech.....	226
Pojmenování mutexů a jejich sdílení mezi procesy.....	228
Komunikace pomocí rour.....	230
Komunikace pomocí soketů.....	233
Atomické aktualizace proměnných.....	237
Alokování lokálního úložiště vlákna	238
Nastavení priority vlákna	241
Shrnutí	242

Kapitola 7

Automatická paralelizace a rozhraní OpenMP 243

Vytvoření paralelní aplikace pomocí automatické paralelizace.....	244
Identifikace a paralelizace redukcí	248
Automatická paralelizace kódů obsahujících volání	249
Jak pomoci kompilátoru při automatické paralelizaci kódu	251
Vytvoření paralelní aplikace pomocí rozhraní OpenMP.....	254
Použití rozhraní OpenMP pro paralelizaci cyklů	255
Chování aplikace využívající rozhraní OpenMP	255
Stanovení oboru platnosti proměnných uvnitř paralelních oblastí rozhraní OpenMP	256
Paralelizace redukcí pomocí rozhraní OpenMP	258
Přístup k soukromým datům mimo paralelní oblast.....	259
Zlepšení rozdělení práce pomocí plánování.....	260
Použití paralelních sekcí k provádění nezávislé práce	264
Vnořený paralelizmus.....	265
Použití rozhraní OpenMP pro dynamicky definované paralelní úlohy	266
Udržení dat jako soukromých pro vlákna.....	270
Řízení běhového prostředí OpenMP	272
Čekání na dokončení práce	275
Omezení vláken provádějících určitou oblast kódu.....	277
Provádění kódu v paralelní oblasti v určitém pořadí	281
Sbalování cyklů pro lepší vyvážení pracovního zatížení.....	282
Zajištění konzistence paměti.....	283
Příklad paralelizace	284
Shrnutí	288

Kapitola 8

Ručně programovaná synchronizace a sdílení 289

Atomické operace.....	290
Tvorba složitějších atomických operací pomocí instrukcí porovnání a prohození	292
Vynucení pořadí paměťových operací pro zajištění správné operace	295
Podpora direktiv pro uspořádání paměťových operací ze strany komplikátorů	298
Přeusporeádání operací komplikátorem	298
Proměnné deklarované pomocí klíčového slova volatile.....	302
Atomické operace poskytované operačním systémem	303
Algoritmy bez zámků	306
Dekkerův algoritmus	306
Producent-konzument s kruhovou pamětí.....	309
Škálování k více konzumentům či producentům	312
Škálování modelu producent-konzument na více vláken.....	313
Model producent-konzument s atomickými operacemi.....	320
Problém ABA	322
Shrnutí	325

Kapitola 9

Škálování s vícejádrovými procesory 327

Omezení škálování aplikací.....	328
Výkon limitovaný sériovým kódem	328
Superlineární škálování	331
Nevyvážené pracovní zatížení	332
Pretížené zámky	333
Škálování knihovního kódu	339
Nedostatečná práce.....	340
Algoritmické omezení.....	343
Omezení škálování ze strany hardwaru.....	345
Sdílení šířky pásma mezi jádry	346
Falešné sdílení.....	348
Konflikt a kapacita u mezipaměti	351
Hladovění po prostředcích proudu	356
Omezení škálování ze strany operačního systému	361
Pretížení	361
Zlepšení umístění v paměti pomocí svázání s procesorem.....	363
Inverze priority	371
Vícejádrové procesory a škálování	372
Shrnutí	373

Kapitola 10

Další techniky paralelizace 375

Výpočty pomocí jednotky GPU	376
Rozšíření jazyků	379
Stavební bloky pro práci s vlákny.....	379
Jazyk Cilk++	381
Technologie GCD	385
Funkce navrhované pro následující standardy jazyků C a C++.....	386
Jazyk C++/CLI společnosti Microsoft	389
Alternativní jazyky.....	391
Technologie clusteringu.....	393
Rozhraní MPI.....	394
Algoritmus MapReduce jako strategie pro škálování	397
Výpočetní soustavy.....	398
Transakční paměť.....	399
Vektorizace	400
Shrnutí	401

Kapitola 11

Několik poznámek na závěr 403

Programování paralelních aplikací	404
Identifikování úloh	404
Odhad nárůstu výkonu.....	405
Zjištění závislostí.....	405
Soupeření o data a omezení škálování u zámků mutexu.....	405
Granularita zamykání	406
Paralelní kód na vícejádrových procesorech	406
Optimalizace programů pro vícejádrové procesory.....	407
Budoucnost.....	408

Rejstřík 409