

Optymalizacja kodu

Ze wszystkich metod optymalizacji kodu programowego zwrócimy uwagę na:

- **Usunięcie (po możliwości) „skoków” danych**
- **Rozwijanie pętli**
- **Opcje kompilatora**

Usunięcie skoków danych:

```
for(i=1; i<=N; i++)
{
    for(j=1; j<=N; j++)
    {
        ij = N*(j-1)+i;
        A[ij] = .....
    }
}
```

Ten fragment kodu będzie wykonany bardzo wolno, dla tego że elementy dużej tablicy są pobierane z pamięci nie ciągle. To powoduje N^2 odczytów stron pamięci, przy czym z każdej strony będzie pobrane tylko jedno słowo (zakładamy, że $N > M$, gdzie M – ilość słów, które można umieścić w stronie pamięci głównej).

$$A = \begin{pmatrix} 1 & N+1 & 2N+1 & : & (N-1)N+1 \\ 2 & N+2 & 2N+2 & : & (N-1)N+2 \\ 3 & N+3 & 2N+3 & : & (N-1)N+3 \\ : & : & : & : & : \\ N & 2N & 3N & : & N^2 \end{pmatrix}$$

Taki fragment kodu jest zdecydowanie lepiej:

```
for(j=1, ij = 0; j<=N; j++)
{
    for(i=1; i<=N; i++, ij++)
    {
        A[ij] = .....
    }
}
```


Teraz elementy tablicy A będą pobierane z pamięci ciągle, przy odczycie każdej strony będą użyte wszystkie słowa, znajdujące się w stronie, i tylko po tym będzie odczyt nowej strony. Ilość odczytów stron: $N^2/M \ll N^2$.

➤ Rozwijanie pętli – potoki procesora nie w stanie zacząć opracowywać instrukcji z następnej iteracji dopóki nie skończą instrukcji w bieżącej iteracji – nie znają wartości indeksu po inkrementowaniu (wykład 2, Przykł. 1). Dla tego krótkie instrukcje pętli powodują zaburzenie potoków procesora. Rozwijanie pętli w sposób sztuczny przedłuża instrukcje, co nadaje możliwość pełnego wciągnięcia potoków procesora.

➤ Przykład mnożenia macierzy przez wektor: $r = r + A \cdot V$, przy czym macierz jest umieszczona w pamięci jako tablica jednowymiarowa kolumna po kolumnie:

//Brak rozwijania pętli

```
memset((void *)R, 0, sizeof(double)*dim);
for(j=0; ij=0; j<dim; j++)
{
    for(i=0; i<dim; i++, ij++)
    {
        R[i] += A[ij]*V[j];
    }
}
```



➤ **A teraz rozwiniemy pętlę 6 razy:**

**//Dostęp do elementów tablicy przez
//indeksy**

```
int rest = dim%6;
for(j=0; ij=0; j<dim; j++)
{
    for(i=0; i<rest; i++, ij++)
    {
        R[i] += A[ij]*V[j];
    }

    for(i=rest; i<dim; i+=6, ij+=6)
    {
        R[i]   += A[ij] * V[j];
        R[i+1] += A[ij+1]*V[j];
        R[i+2] += A[ij+2]*V[j];
        R[i+3] += A[ij+3]*V[j];
        R[i+4] += A[ij+4]*V[j];
        R[i+5] += A[ij+5]*V[j];
    }
}
```

Opcje kompilatora

- **Kompilator Visual Studio 2005 C++ (Visual Studio 8.0), jak i jego poprzedniki (Visual Studio 6.0,) tworzy dwie wersje – debug i release.**
- **Wersja debug jest przeznaczona do debugowania programu, przecież kod wysokiej wydajności można osiągnąć tylko w wersji release.**

Mulm Property Pages



Configuration: Active(Release) ▼

Platform: Active(Win32) ▼

Configuration Manager...

- ⊕ Common Properties
- ⊖ Configuration Properties
 - General
 - Debugging
 - ⊖ C/C++
 - General
 - Optimization
 - Preprocessor
 - Code Generation
 - Language
 - Precompiled Header
 - Output Files
 - Browse Information
 - Advanced
 - Command Line
- ⊕ Linker
- ⊕ Manifest Tool
- ⊕ Resources
- ⊕ XML Document Genera
- ⊕ Browse Information
- ⊕ Build Events
- ⊕ Custom Build Step
- ⊕ Web Deployment

Additional Include Directories	
Resolve #using References	
Debug Information Format	Disabled
Suppress Startup Banner	Yes (/nologo)
Warning Level	Level 3 (/W3)
Detect 64-bit Portability Issues	No
Treat Warnings As Errors	No
Use UNICODE Response Files	Yes

Additional Include Directories

Specifies one or more directories to add to the include path; use semi-colon delimited list if more than o...

OK

Отмена

Применить

Mulm Property Pages



Configuration: Active(Release) ▼

Platform: Active(Win32) ▼

Configuration Manager...

- Common Properties
- Configuration Properties
 - General
 - Debugging
 - C/C++
 - General
 - Optimization**
 - Preprocessor
 - Code Generation
 - Language
 - Precompiled Header
 - Output Files
 - Browse Information
 - Advanced
 - Command Line
- Linker
- Manifest Tool
- Resources
- XML Document Genera
- Browse Information
- Build Events
- Custom Build Step
- Web Deployment

Optimization	Maximize Speed (/O2)
Inline Function Expansion	Default
Enable Intrinsic Functions	Yes (/Oi)
Favor Size or Speed	Favor Fast Code (/Ot)
Omit Frame Pointers	Yes (/Oy)
Enable Fiber-safe Optimizations	No
Whole Program Optimization	Enable link-time code generation (/GL)

Optimization

Select option for code optimization; choose Custom to use specific optimization options. (/Od, /O1, ...)

OK

Отмена

Применить

➤ Opcje /O1 (minimalizacja rozmiaru kodu), /O2 (maksymalna szybkość) .
Włączenie tej flagi powoduje ustawienie szeregu opcji. Na przykład,
włączenie /O2 powoduje ustawienie opcji: /Og /Oi /Ot /Oy /Ob2 /Gs /GF /Gy

/Og – optymalizacja globalna.

Kod do optymalizacji	Kod po optymalizacji
<pre>a = b + c; d = b + c; e = b + c;</pre>	<pre>tmp = b + c; a = d = e = tmp;</pre>

- Optymalizacja lokalna – są przeszukiwane tylko sąsiednie linie kodu, globalna – w obszarze całej funkcji.
- Kluczowe słowo register jest ignorowane. Zamiast tego kompilator umieszcza w rejestry zmienne, które mają częste powtarzania.
- Usunięcie wyrażeń, które nie zależą od indeksu iteracji, poza pętle:

<pre>i = -100; while(i) i += x+y;</pre>	<pre>i = -100; tmp = x+y; while(i) i += tmp;</pre>
---	--

- **Optymalizuje działanie konstruktora kopiującego i destruktora przy zwracaniu funkcją wartości.**

/Oi – funkcje wbudowane (fabs(), labs(), strlen(),...) są wywołane jako intrinsic – narzuty przy wywołaniu są usunięte.

/Ot – maksymalizację szybkości wykonania *.exe, *.dll


/Oy – przyspiesza działania na stacku przy wywołaniu funkcji, zwalnia jeden lub więcej rejestrów dla umieszczenia często powtarzalnych zmiennych (tylko dla x86).

/Ob2 – rozwinięcie inline funkcji.

.....

Superskalarność procesora – możliwość wykonywania wektoryzacji elementów obliczeń przy technologii potokowej i istnieniu rejestrów specjalnych.

➤ **Przykad: $f = a+b+c+d$;**



IF – instruction fetching

ID – decoding

OF – operand fetching

E – execution

WB – Write-back

Floating point model:

- Domyślnie (bez flagi /fp:presize) kompilator tworzy kod, który dobiera kolejność obliczeń tak, żeby przyspieszyć wykonanie kodu. Przy tym w arytmetyce zmiennie-przyczynkowej może się okazać, że kolejność operacji istotnie wpływa na wynik.
- Przykład: $S = S_1 + S_2 + S_3 + S_4 + \dots$. Przy sumowaniu dwóch liczb zmiennie-przyczynkowych wyrównanie jest wykonane po wartości bezwzględnej większej liczby: $1000 + 0.01 = 1.0 \times 10^3 + 0.00001 \times 10^3$. Jeśli nasz komputer nie utrzymuje wystarczający rozmiar mantysy, a różnica rzędu tych liczb jest dużą, mniejsza liczba po prostu się gubi. A teraz przedstawimy, że nasz szereg zbiega się wolno, $S_{k+1} < S_k$ ($k=1,2,\dots$), a kompilator tworzy kod:

$S = S_1;$

$S = S + S_2;$

.....

Zaczynając od jakiegoś indeksu k suma $S \gg S_{k+1}$, i ostatnie składowe szeregu są pominięty.

- Teraz będziemy liczyć tak:

$S = S_N$

$S = S + S_{N-1}$

.....

Ostatnie składowe szeregu są uwzględnione

Ten przykład demonstruje, że bywają zagadnienia, w których wynik istotnie zależy od kolejności operacji, więc **zmiana porządku operacji przy optymalizacji kodu może być dość niebezpieczną.**

Wyjściem z takiej sytuacji może być przedstawienie wyniku pośredniego z większą precyzją. Jeśli typ składowych – float, to wynik poprzedni może być double, jeśli double – long double, i t. p.

- **/fp:precise** na procesorach x86 oznacza, że kompilator będzie wykonywał tylko bezpieczną optymalizację na kodzie floating-point, obliczenia pośrednie (intermediate) będą wykonane z największą praktyczną dokładnością. Program, skompilowany z opcją /fp:precise, będzie wolniej i większy od programu, skompilowanego bez tej opcji. Będzie pominięta opcja /Oi (intrinsic functions), zamiast tego standardowa biblioteka runtime routines będzie użyta.
- **/fp:fast** – tworzy najszybszy kod w większości wypadków. Przecież może to powodować nieoczekiwane wyniki.
- **/fp:strict** – najbardziej ścisły model operacji zmiennie przyczynkowych. Uwzględnia wszystkie korekcje /fp:precise plus do tego poprzedza nieprawidłowe przetwarzania.

/GL – nadaje możliwość link-time code generation. Jeśli w opcjach linkera jest ustawione (a są ustawienia domyślne dla wersji release), linker i kompilator wspólnie optymalizują kod.

To jest tak zwana technika profile-guided optimization (PGO). Przy zwykłej kompilacji kompilator kompiluje jednostki kompilacji rozdzielnie, i nic nie wie o związku pomiędzy tymi jednostkami. W technice PGO na podstawie wspólnej analizy (kompilator-linker) struktury programu (związku pomiędzy funkcjami i innymi jednostkami kompilacji) jest tworzony kod z optymalizowanym wywołaniem funkcji, a do tego jeszcze wielu rzeczy.

Dla użycia PGO są konieczne etapy:

- Kompilacje w trybie instrumentation code (opcje Linker/Optimization/Link Time Code Generation/ LTCG:PGINSTRUMENT)**
- Jednokrotne wykonanie programu ze zbiorem informacji w osobny plik**
- Przetawienie opcji linkera /LTCG:PGOPTIMIZE i ponowny rebuild programu. Optymalizacja jest wykonana automatycznie na podstawie informacji przy testowym wykonaniu programu.**

Mulm Property Pages



Configuration: Active(Release)



Platform: Active(Win32)



Configuration Manager...

- + Common Properties
- Configuration Properties
 - General
 - Debugging
 - + C/C++
 - Linker
 - General
 - Input
 - Manifest File
 - Debugging
 - System
 - Optimization**
 - Embedded IDL
 - Advanced
 - Command Line
 - + Manifest Tool
 - + Resources
 - + XML Document Genera
 - + Browse Information
 - + Build Events
 - + Custom Build Step
 - + Web Deployment



References

	Default
Enable COMDAT Folding	Default
Optimize for Windows98	Default
Function Order	
Profile Guided Database	\$(TargetDir)\$(TargetName).pgd
Link Time Code Generation	Use Link Time Code Generation (/ltcg)



References

Enables elimination of functions and/or data that are never referenced. (/OPT:REF, /OPT:NOREF)

OK

Отмена

Применить