

Programování „bez vláken“

- „Tradiční“ přístup je vytvoření vícevláknového programu, kde se řekne, co má které vlákno dělat
- Ale jde to i jinak, lze vytvořit program tak, že se řekne, co se má udělat paralelně
- OpenMP, Intel Thread Building Blocks, MS Concurrency Runtime

OpenMP

- Open Multi-Processing
- Idea je, že se vezme sériový program a za použití speciálních knihoven se pomocí direktiv překladače řekne, co se má provádět paralelně
- Např. pokud se překladač vyvolá s direktivou openmp, program se přeloží jako paralelní, bez ní jako sériový

```
#pragma omp parallel
{
  for (int i=0; i<10; i++) {
    DoSomething();
  }
}
```

- Pokud se provádí paralelní výpočet, obvykle je nutná nějaká sdílená/redukční/uzamykaná proměnná
- Překladač se je může pokusit uhodnout, ale to se vždy nemusí podařit správně
 - Je lepší mu to prozradit pomocí speciálních direktiv
 - shared, private, reduction, default...
- To samé platí i pro synchronizaci a plánování

- Lze použít i direktivu `if`, která spustí výpočet paralelně pouze tehdy, je-li daná podmínka splněna
 - Např. pokud je počet prvků pole k součtu dostatečně velký, aby se vyplatilo sečíst je paralelně
- Výhodou je, že se dá „doparalelizovat“ sekvenční program, aniž by se do něho muselo nějak výrazně zasahovat
 - Např. výpočet statistiky

```
//#pragma omp parallel for
// reduction (+:localAvgDiff, localAvgAbsDiff)
// private(diff) shared(localMaxAbsDiff)

#pragma omp parallel
{
    floattype sublocalMaxAbsDiff = 0.0;
    //so that we do not need to declare localMaxAbsDiff
    //as shared, thus intruding wait penalty

    #pragma omp for nowait
        reduction (+:localAvgDiff, localAvgAbsDiff)
        private(diff)
    for (i=0; i<cnt; i++) {
        diff = leftBuf[i].y-rightBuf[i].y;

        localAvgDiff += diff;

        diff = fabs(diff);
        localAvgAbsDiff += diff;

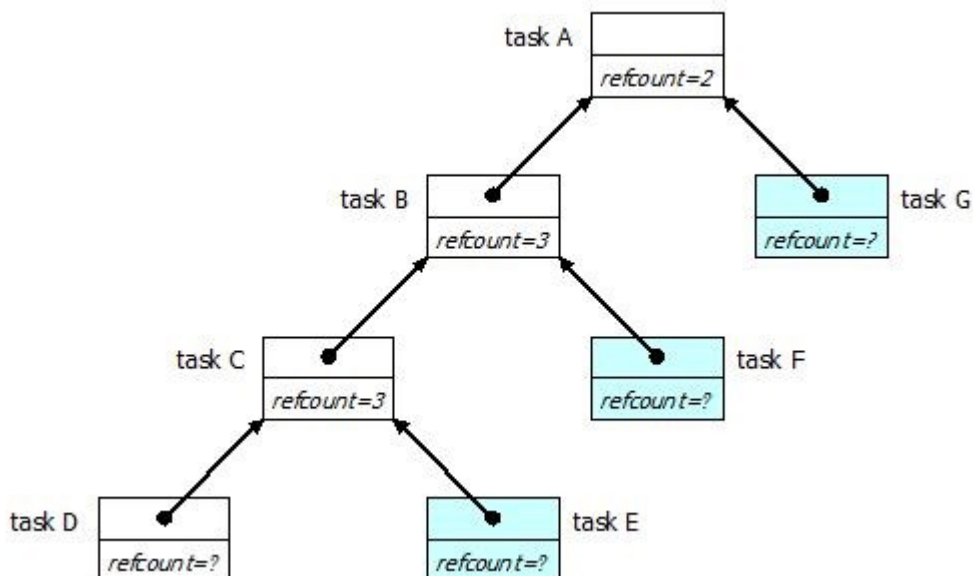
#ifdef _MSC_VER
        sublocalMaxAbsDiff = max(sublocalMaxAbsDiff,
                                diff);
#else
        sublocalMaxAbsDiff = fmax(sublocalMaxAbsDiff,
                                diff);
#endif
    } //for
    #pragma omp critical (localMaxAbsDiff)
```

```
    localMaxAbsDiff = max(localMaxAbsDiff,  
                          sublocalMaxAbsDiff);  
} //pragma omp parallel  
  
if (cnt) {  
    //if to avoid division by zero  
    floattype tmp;  
    tmp = valuescnt;  
    tmp = 1.0/tmp;  
  
    (*stats).AvgAbsDiff = localAvgAbsDiff*tmp;  
    (*stats).AvgDiff = localAvgDiff*tmp;  
    (*stats).MaxAbsDiff = localMaxAbsDiff;  
}
```

Intel Thread Building Blocks

- Open Source, podpora více platforem
 - Stejně jako OpenMP
- Ačkoliv si je TBB vědoma vláken poskytovaných OS, myšlenka je takový, že programátor už s vlákny nepracuje
- Namísto vláken specifikuje úlohy, tasks, a jejich návaznosti
- Důvodem je mj. redukce efektu cache-cooling
 - Uvažujeme tradičních m vláken na n procesorů, kde $m > n$
 - Jak vlákno běží, jeho pracovní data se dostávají do cache procesoru (tzv. hot data)
 - Jak se vlákna přepínají, do cache procesoru se dostávají pracovní data nového vlákna a pracovní data předchozích vláken jsou z cache odstraňována
 - Takže až takové vlákna přijde opět na řadu, každý cache-miss ho bude stát stovky cyklů čekání, než se jeho pracovní data znovu nahrají do cache (protože byly tzv. cooled)
 - S TBB programátor nepíše vlákna, ale úlohy
 - Vlákna poskytuje TBB tak, aby $m \leq n$
 - Vlákno TBB pracuje na jedné úloze, dokud není dokončena => redukuje efekt cache-cooling
 - Tradiční vlákna ani thread-pool nic takového neumí!
 - =>tradiční vlákna jsou dobrá na GUI a I/O, ale ne na výpočty

- Task Stealing je způsob plánování úloh



http://software.intel.com/sites/products/documentation/doclib/tbb_sa/help/tbb_userguide/How_Task_Scheduling_Works.htm

- Úlohy A, B, C vytvořily podúlohy, na které čekají
- Úloha D běží
- Úlohy E, F, G ještě neběží

- Nejhlouběji zanořené úlohy jsou nejvíce cache-hot
- Breadth-first co nejdříve rozbalí celý strom, takže maximalizuje paralelismus
- Depth-first zase udržuje omezený počet uzlů stromu
- Takže je to v praxi kompromis, protože počet procesorových jader je omezený

- Na každý procesor je zásobník úloh
- Pokud jeden procesor dokončí svůj zásobník, může zkusit „ukrást“ cool data z vrcholu zásobníku jiného procesoru

- Aneb FIFO ani priority nejsou vždy ta nejlepší strategie

- TBB vykonává úlohy paralelně, jak nejlépe to se současným know-how jde
 - Obsahuje různé další optimalizace v jakém pořadí úlohy vykonávat
 - Lze si napsat vlastní plánovač
- Stejně jako STL, i TBB intenzivně používá C++ šablony
 - Tj. nelze ji použít v C jako OpenMP
- Základní konstrukce TBB jsou
 - `parallel_for`, `parallel_reduce`, `parallel_scan`
 - `parallel_while`, `parallel_do`, `pipeline`, `parallel_sort`
 - paralelní kontainery, které jsou v STL
 - `mutex`, `spin_mutex`, `queuing_mutex`, `spin_rw_mutex`, `queuing_rw_mutex`, `recursive_mutex`
 - `fetch_and_add`, `fetch_and_increment`, `fetch_and_decrement`, `compare_and_swap`, `fetch_and_store`
- TBB dokáže použít vlastní paměťový manažer, který je optimalizovaný na paradigma výpočtu úloh
- TBB je náročnější se naučit, ale zase se to vyplatí na výkonu, pokud se začíná psát nová aplikace, než např. paralelizovat s OpenMP
 - Navíc TBB se nespolehá na direktivy pro překladač, takže podmínka `if OpenMP` se dá realizovat libovolně složitá, nebo se dají udělat konstrukce, který by šli s OpenMP udělat jen velmi obtížně – např. `cancellation` výpočtu v OpenMP není

- Např. chceme-li spustit na pozadí několik výpočetně náročných úloh paralelně

```
tbb::task* CMasterCalculationTBBLLogic::execute() {
    tbb::task_list list;

    for (int i=gaiFirst; i<=gaiLast; i++)
        list.push_back(*new(allocate_child()) CTask(i));

    set_ref_count(gaiLast-gaiFirst+2); //počet úloh +1
    spawn_and_wait_for_all(list);

    return NULL; //non-NULL by byla úloha, která by měla
} //být spuštěna jako další/závislá na téhle
```

- Když bychom např. násobili vektor

```
class CMulVect {
    floattype *mA, *mB;
    int mLen;
public:
    floattype mProduct;

    CMulVect(floattype *a, floattype *b, int len) :
        mA(a), mB(b), mLen(len), mProduct(0.0) {}
    CMulVect(CMulVect& x, tbb::split) : mA(x.mA),
        mB(x.mB), mLen(x.mLen), mProduct(0.0) {}

    void join(const CMulVect& y) {
        mProduct += y.mProduct;
    }

    void operator()( const
        tbb::blocked_range<size_t>& r ) {
        int r_end = r.end();

        //Taken from Intel's tutorial on TBB
        //by declaring these variables, we make it
        //obvious to the compiler that they
        //can be held in registers instead in memory
```

```
        // => speedup

        floattype *a = mA;
        floattype *b = mB;
        floattype sum = 0.0;

        for (int i=r.begin(); i!=r_end; ++i)
            sum += a[i]*b[i];

        mProduct += sum;
    }
};

floattype MulVect(floattype *a, floattype *b,
                  int len) {

    floattype result = 0.0;

    //Jsou data tak velká, aby se je vůbec
    //vyplatilo počítat paralelně?
    if (len<=rmSerialThreshold) {
        for (int i=0; i<len; i++)
            result += a[i]*b[i];
    } else {
        CMulVect mul(a, b, len);

        tbb::parallel_reduce(
            tbb::blocked_range<size_t>(0,len), mul);
        result = mul.mProduct;
    }
    return result;
}
```

- U redukčních operací je třeba při inicializaci mezivýsledku rozlišovat mezi konstruktorem a funkčním operátorem ()
 - Konstruktory jsou dva
 - Normální, který bere parametry výpočtu
 - A split konstruktor, který bere referenci na druhý objekt a na `tbb::split`

- V konstruktorech se vždy inicializují dílčí mezivýsledky celé operace
- Návrhově to totiž může svádět k tomu, aby se mezivýsledek inicializoval v těle funkčního operátoru
- Jenže funkční operátor se může volat několikrát na stejné instanci, a pak by to dávalo špatné výsledky

Případová studie použití TBB

- Uvažujme výpočetně náročnou aplikaci nad rozsáhlými daty s GUI
- Jedno vlákno bude obsluhovat GUI
- Jedno vlákno bude obsluhovat I/O
 - Naivní přístup je jedno vlákno pro zápis a jedno pro čtení
 - Lepší je jenom jedno vlákno a použití asynchronních I/O operací
 - OS si je uspořádá sám pro lepší výkon
 - Např. disky mají Native Command Queuing
 - Ale co s výpočetní částí?
 - Určitě v tom bude alespoň jedno vlákno, aby výpočet běžel na pozadí a GUI bylo responsive
- Přístup s psaním vláken by znamenal postarat se
 - Vytváření a rušení vláken, což je další režie pro OS
 - Jejich správnou synchronizaci, což je náročné, jakmile se program stává složitější
 - Výkonnostně je rozdíl, jestli se synchronizuje v kernel-mode, nebo v user-mode address space
 - Výkonnostně hraje roli, zda se k datům přistupuje ze stejného procesoru – thread affinity

- Optimální počet vláken odpovídá počtu procesorových jader v systému, což ale není přístup, který je vždy možný při psaní vláken
 - Např. počet vláken může odpovídat tomu, jaká je metoda výpočtu – problém škálovatelnosti
 - S TBB se taková vlákna nahradí úlohami

- S TBB
 - O výše uvedené problémy se TBB postará
 - Programátor napíše jedno vlákno, ve kterém pak spustí výpočet úloh TBB
 - Nicméně programátor si stále musí být vědom toho, jak se píšou paralelní programy s vlákny, aby mohl správně používat synchronizační primitiva TBB
 - Optimálně se naprogramují pouze úlohy s tím, že každá úloha po dokončení vrátí další úlohu, která se má vykonat jako navazující
 - Jako bariéra na dokončení více úloh se pak použije task list
 - Úlohy však mohou sdílet proměnné, a proto je třeba znát teorii o psaní vláken
 - Aby byla představa, že 2 úlohy mohou, ale i nemusí, běžet paralelně, např. když se má správně použít mutex, podmínka...

Concurrency Runtime

- Proprietární technologie MS
- Ideově podobná TBB, je to novější knihovna
- Jenže TBB běží nejen pod Windows a výkonově nezaostává

- Spuštění více úloh

```
void Task1() {}  
void Task2() {}
```

```
void Main() {  
    task_group tg;  
  
    tg.run(&Task1);  
    tg.run(&Task2);  
  
    tg.wait();  
}
```

- Výpočet součtu sum
 - <http://msdn.microsoft.com/en-us/magazine/ee309514.aspx>

```
combinable<int> localSums;  
  
parallel_for_each(myVec.begin(), myVec.end(),  
                 [&localSums] (int element) {  
    SomeFineGrainComputation(element);  
    localSums.local() += element;  
});
```

- Násobení matic
 - <http://msdn.microsoft.com/en-us/library/dd728073.aspx>

```
void parallel_matrix_multiply(double** m1,
double** m2, double** result, size_t size)
{
    parallel_for (size_t(0), size, [&](size_t i)
    {
        for (size_t j = 0; j < size; j++)
        {
            double temp = 0;
            for (int k = 0; k < size; k++)
            {
                temp += m1[i][k] * m2[k][j];
            }
            result[i][j] = temp;
        }
    });
}
```