Paralelizace cyklů

- Sekvenční algoritmus musí cyklem projít přes všechny části dat
- Lze provést dekompozici dat, můžeme cykly paralelizovat a tím urychlit výpočet
- => datový paralelismus SPMD

```
sum:=0;
for i:=0 to High(Items) do
  begin
    a:=random(Items[i]);
    sum:=sum+a;
  end;
```

- Máme jeden programový kód, ale můžeme ho vykonávat na několika procesorech
  - Tj. vykonat co nejvíce smyček paralelně

- Je třeba určit
  - Lokální proměnné `//a`
    - jsou inicializována uvnitř smyčky
  - Sdílené proměnné
    - hodnoty se přenáší mezi jednotlivými iteracemi
    - dělí se na nezávislé a závislé
    - nezávislé jsou tehdy, když `//Items`
      - jsou využívána pouze pro čtení
      - v případě pole jde pouze o jeden prvek, se kterým se pracuje pouze v jedné iteraci
    - závislé proměnné se dělí na `//sum`
      - redukční
      - uzamykané
      - uspořádané

- Redukční proměnná `//sum`
  (reduction variable)
  - Nejprve je čtena, pak zapsána
  - Uvedené se odehraje v jedné iteraci

- Uzamykaná proměnná `//min`
  (locked variable)

```
min:=Items[0];
for i:=1 to High(Items) do
  if min<Items[i] then
    min:=Items[i];
```

  - Může být čtena i zapisována v několika iteracích
  - Může být čtena i zapisován několikrát po sobě v jedné iteraci
  - Pokud by se iterace neprováděly sekvenčně, ale v náhodném pořadí, výsledek by byl stále správný

```
for i:=1 to High(Items) do randomly
```

- Uspořádaná proměnná (ordered variable)
  - Správného výsledku je dosaženo pouze tehdy, jsou-li iterace vykonávány pouze ve stanoveném pořadí

```
for i:=1 to High(Items) do
  Items[i]:=Items[i] + Items[i-1];
```

  - Na rozdíl od předchozích cyklů, tento nelze urychlit tak, že vlákna současně vykonají operace nad svou částí pole (a pak jedno z nich zpracuje mezivýsledky). Ačkoliv… ne vždy.

Paralelizace součtu pole

```
var GlobalSum:integer = 0;
    Items:array of integer;
    Guard:TCriticalSection;

thread DoPartialSum(Offset, Size:integer);
var i:integer;
    sum:integer = 0;
begin
  for i:=Offset to Offset+Size do
    sum:=sum+Items[i];

  Guard.Acquire;
  GlobalSum:=GlobalSum+sum;
  Guard.Release;
end;

procedure RunThreads;
var i, j, k, offset, size:integer;
begin
  DivMod(Length(Items), NumberOfThreads, i, j);

  Offset:=0; Size:=i;
  for k:=1 to NumberOfThreads-1 do
    begin
      DoPartialSum(Offset, Size);
      Inc(Offset, Size);
    end;
  DoPartialSum(Offset, Size+j);
end;

begin program
  GetInputData;
  RunThreads;
  WaitForThreads;
  PrintGlobalSum;
end program;
```

Paralelizace výpočtu součtů prefixů

```
for i:=1 to High(Items) do
  Items[i]:=Items[i] + Items[i-1];
```

$$[a_0, a_1, \ldots, a_{n-1}]$$
$$[(a_0), (a_0+a_1), \ldots, (a_0+a_1+\ldots+a_{n-1})]$$

[4, 5, 3, 1, 6]
[4, 9, 12, 13, 19]

- Princip paralelizace výpočtu součtů prefixů se dá aplikovat i na některé další sekvenční výpočty, např.
  - Třídění
  - Lexikální analýza
  - Histogramy
  - Teorie grafů
  - Práce s řetězci

- I pro výpočet, který na první pohled vypadá jako beznadějně sekvenční, existuje šance, že ho bude možné paralelizovat

- První krok
  - Uspořádaná proměnná nám zabraňuje zapisovat do pole v jiném, než určeném pořadí
  - => zavedeme ještě jednu kopii pole
  - S `i-1` už přistupujeme do jiného pole, do kterého se v cyklu nezapisuje => zrušeno uspořádání

```
Move(Temp, Items, Length(Items));
for i:=1 to High(Items) do
  Items[i]:= Temp[i-1] + Items[i];
  //samozřejmě, že „něco“ chybí k úplnosti
```

- Krok druhý
  - V sekvenční verzi jsme s každým součtem získali jeden prefix
  - Výpočet n-tého prefixu se skládá z n-1 součtů
  - Protože už jsme se ale zbavili uspořádanosti, můžeme součet n-tého prvku rozložit do jiné posloupnosti součtů než v sekvenční verzi

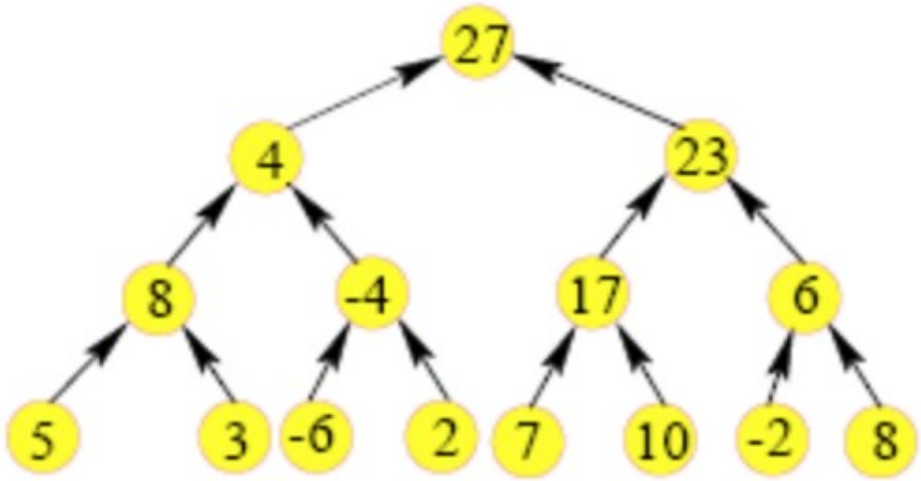

http://download.informatik.uni-freiburg.de/lectures/AdvancedAlgorithmsDatastructures/2006SS/Slides/thm14%20-%20parallel%20prefix.ppt

  - Pokud bychom měli k dispozici dva procesory, uvedený strom ukazuje, že výpočet posledního prvku můžeme paralelizovat

- Krok třetí
  - Jestliže lze paralelizovat výpočet posledního prvku, pak lze paralelizovat i výpočet ostatních prvků
  - Mezisoučty vznikají postupně v krocích – *d*
  - Významná část mezisoučtů je využita jako mezihodnota dva dalších mezisoučtů

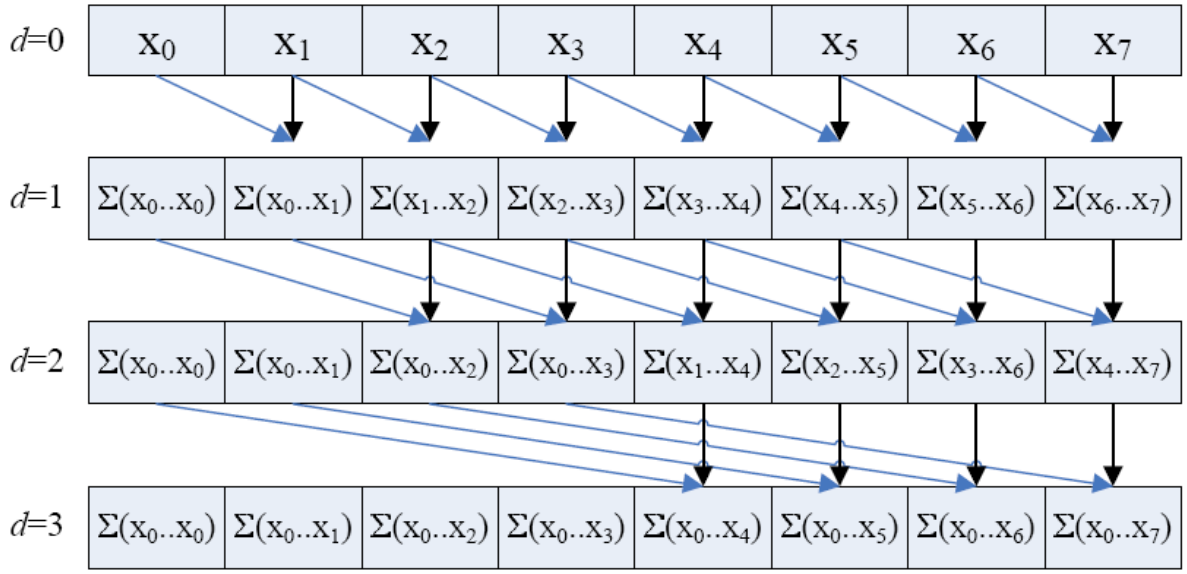

http://beowulf.lcs.mit.edu/18.337/lectslides/scan.pdf

- Čtvrtý krok
  - Programový kód pro jedno vlákno
  - Hranice dat každého vlákna je daná rozmezím `Offset` a `Size`

```
step:=1;
while step<High(Items) do
  begin
    Move(Temp^, @Items[Offset], Size);

    Barrier;
    for i:=max(step, Offset) to Offset+Size do
      Items[i]:= Temp[i-step] + Items[i];

    Barrier;
    step:=step shl 1; //*2
  end;
```

  - S rostoucím krokem, **`for`** cyklus u některých vláken nebude probíhat
  - `Step` by mohla být sdílená proměnná, kterou by zapisovalo např. výhradně první vlákno
  - Poslední bariéra v poslední iteraci není třeba

- Uspořádanost
  - Zbavili jsme se původní uspořádanosti
  - Nicméně, původní uspořádanou proměnnou jsme jenom nahradili jinou uspořádanou proměnnou
    - `Step, d`
  - V paralelizované podobě
    - Hlavní cyklus řízený uspořádanou proměnnou má nyní méně iterací
    - V každé iteraci se udělá více práce, kterou už lze paralelizovat
    - V původní verzi byl pouze hlavní cyklus

- Urychlení
  - Sekvenčně $O(n)$
  - Paralelní verze vykonaná pouze jedním vláknem $\sim O(0,5 \bullet n \bullet log_2 n)$
  - Část celého pole hodnot, se kterými se bude počítat, nám "utíká" doprava
    - Další urychlení dynamicky přerozdělit meze, ve kterých jednotlivá vlákna počítají tak, aby všechny počítaly stejný objem práce
  - Paralelizace má smysl tehdy, běží-li všechna vlákna paralelně
    - Každé dvě vlákna, které se střídají o stejný procesor znamenají pouze nárůst instrukcí k vykonání, bez urychlení
  - Splníme-li podmínky vhodné paralelizace, pak s m procesory dostáváme $\sim O((0,5 \bullet n \bullet log_2 n)/m)$
    - Se zanedbanou režií plánovače, nově přidaným kopírováním obsahu paměti – kopie pole, atd.

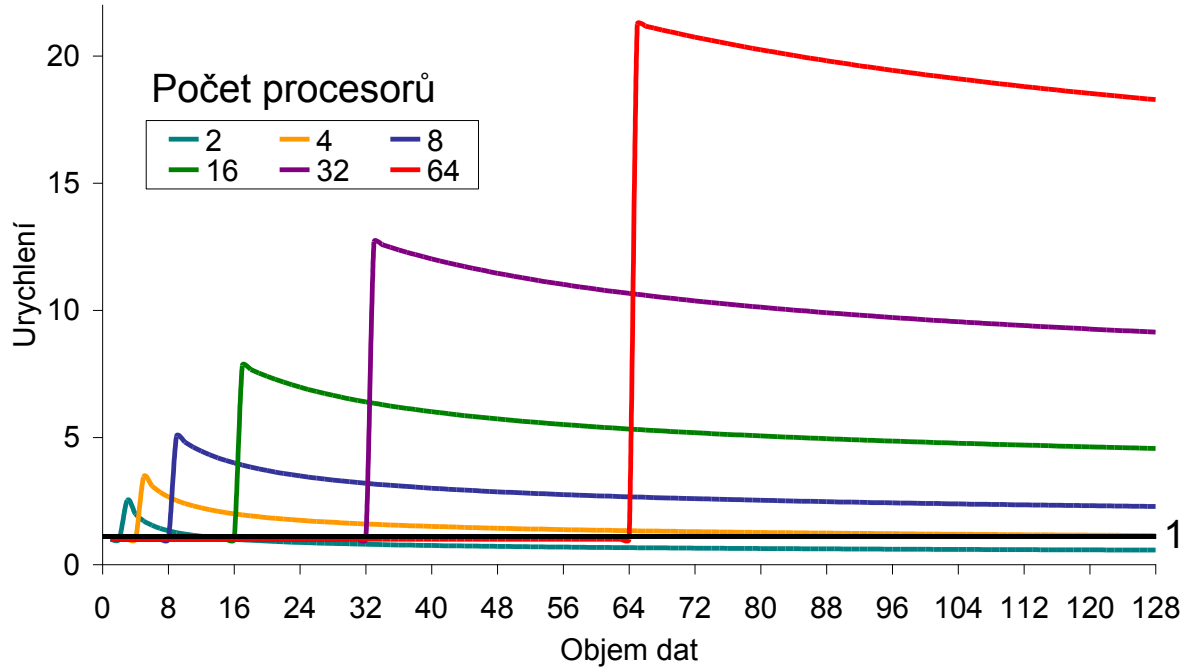

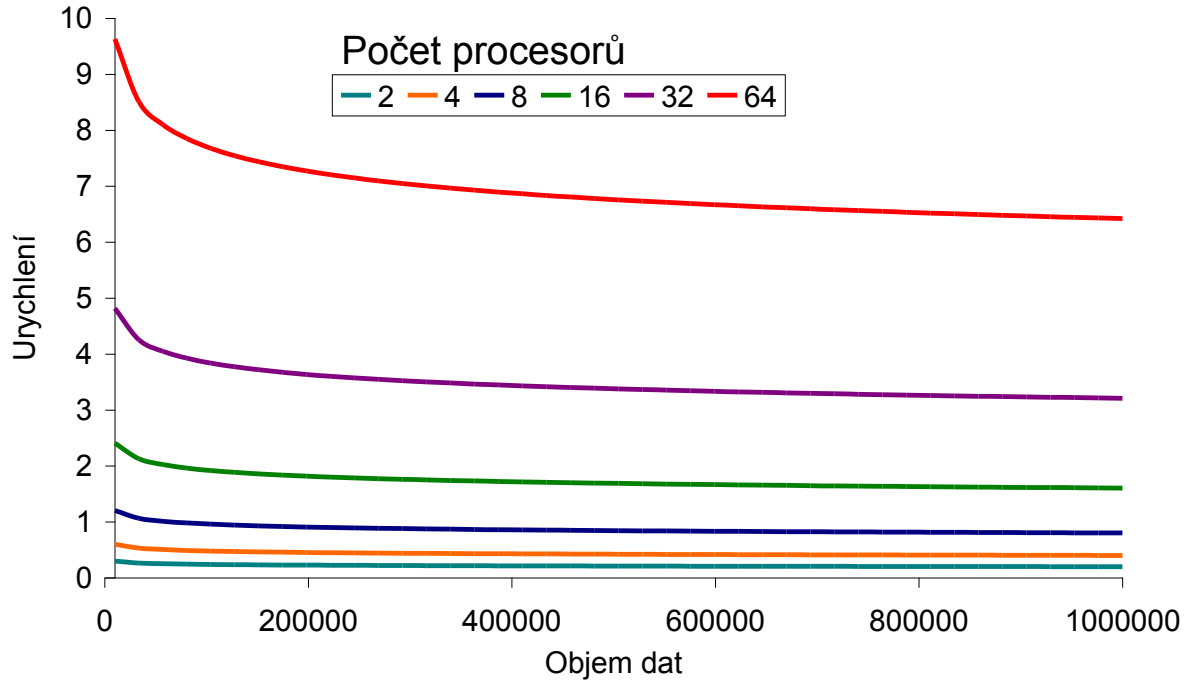

- Algoritmus je evidentně závislý na počtu procesorů a objemu zpracovávaných dat
- Hodí se spíše k HW akceleraci; např. nvidia G80 má limit pole 512, paralelně na ní běží 32 vláken
- Nicméně, podařilo se urychlit původní sekvenční algoritmus alespoň za nějakých podmínek – cena řešení?

- Optimalizace
  - Ve skutečnosti lze provést ještě další úpravu algoritmu, kterou se s paralelní verzí dostaneme na složitost *O(n)*
    - Tj. stejně jako u sekvenční verze, jenomže už ji můžeme spustit paralelně
      - *O(n/m)*
  - Navíc to celé provedeme in-place, stejně jako sekv.

  - Krok první
    - Redukční fáze – od zdola nahoru

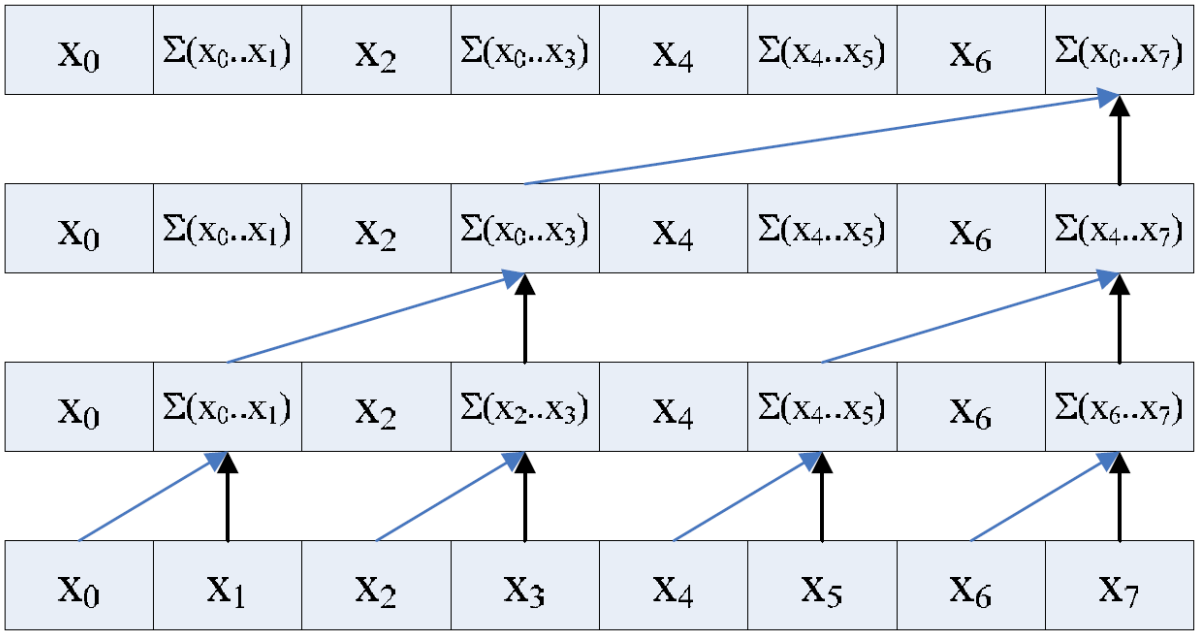

http://beowulf.lcs.mit.edu/18.337/lectslides/scan.pdf

```
d:=1;
while d<High(Items) do
 begin
   for i:=max(d, Offset) to Offset+Size by d do
     Items[i]:= Items[i-d] + Items[i];

   Barrier;
    d:=d shl 1;
 end;
```

- Krok druhý
  - Záloha součtu posledního prvku
  - Vynulování posledního prvku pole
    - I když to ve skutečnosti dělat nemusíme

```
SavedSum:=Items[High(Items)];
Items[High(Items)]:=0;
```

- Krok třetí
  - Fáze smetení (down sweep), od shora dolů

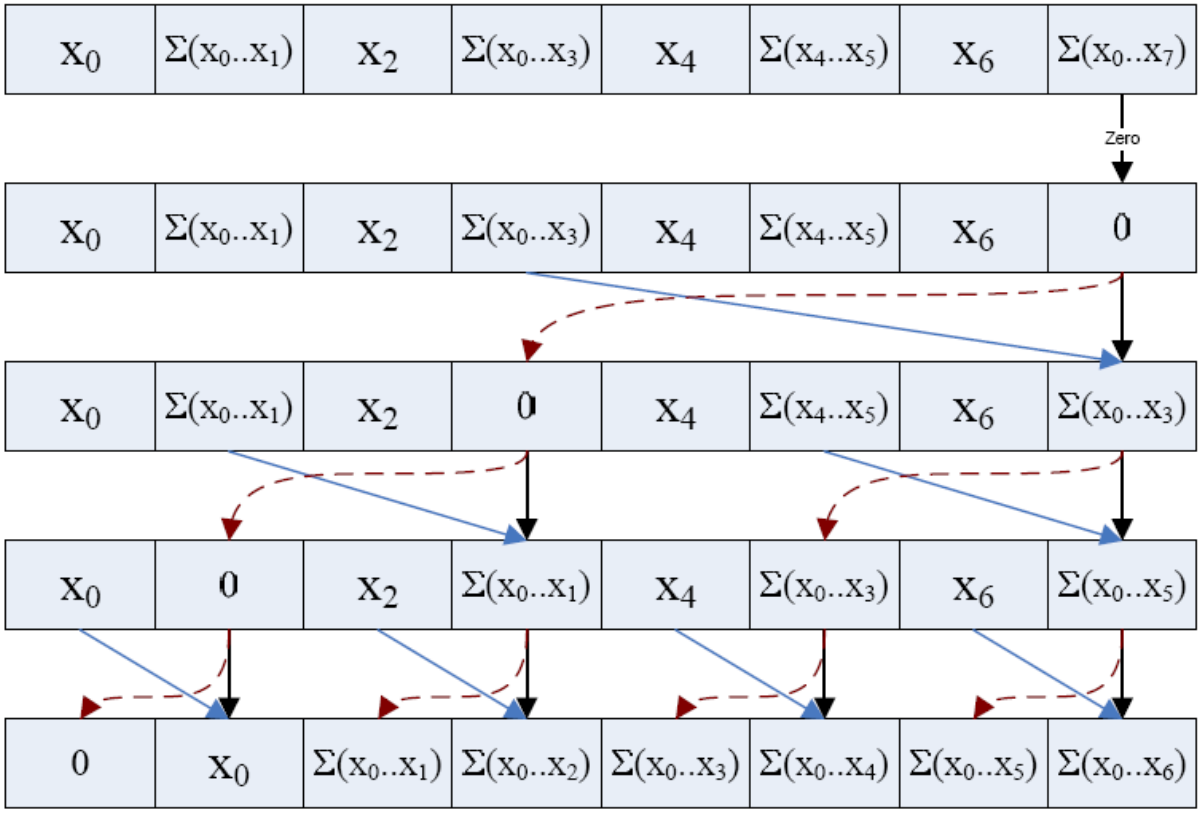

http://beowulf.lcs.mit.edu/18.337/lectslides/scan.pdf

```
d:=d shr 2; //d zůstala jeho hodnota
while d>1 do
 begin
   for i:=max(d, Offset) to Offset+Size by d do
    begin
      temp:=Items[i];
      Items[i]:=Items[i+d];
      Items[i+d]:=Items[i+d]+temp;
    end;
   Barier;
   d:=d shr 1;
 end;
```

- Krok čtvrtý
  - Posunutí všech součtů o jeden doleva
  - Obnovení součtu posledního prvku

```
Temp:=Items[Offset];
for i:=Offset to Offset+Size-1 do
  Items[i]:=Items[i+1];
Barrier;
if Offset>0 then          //kromě prvního úseku
   Items[Offset-1]:=Temp; //zápis do cizích dat
if Offset+Size=High(Items) then //poslední úsek
   Items[Offset+Size]:=SavedSum;
```

- Závěrem o paralelních součtech prefixů – alias „scan“
  - Má dvě varianty
    - Inclusive – první verze
    - Exclusive – nula z optimalizace na začátku, neobsahuje finální součet
  - Podporováno např. v MPI (později) fcí MPI_Scan
  - Nemusí se jenom sčítat
  - Aneb, i některé úlohy s „defaultně“ uspořádanými proměnnými lze paralelizovat – jen vymyslet jak:-)

Plánování vláken

- KIV/OS
- Dále budeme uvažovat plánování několika vláken na víceprocesorovém systému

- Z pohledu algoritmu
  - Klíčové otázky
    - Kolik vláken máme vytvořit?
    - Jak jim rozdělíme práci?
    - Jak poznat, že už je vše spočítáno?

  - Statické
    - Vytvoří se pevně daný počet vláken bez ohledu, kolik jich může fyzicky běžet najednou
    - Každé vlákno má pevně přidělenou část práce
    - Až ji vykoná, počká na ostatní vlákna, která ještě počítají

  - Dynamické
    - Vytvoří se tolik vláken, kolik jich fyzicky může běžet najednou
    - Vytvoří se seznam prací, ze kterého si budou vlákna postupně vybírat jednotlivé úkoly po dokončení předchozích úkolů
    - Zavedeme čítač aktivních vláken; poslední vlákno zjistí, že čítač je 1 (ono samo) a že seznam prací je prázdný

  - Dynamické plánování má sice nějakou režii navíc, lze ji však zanedbat, ale je univerzální
    - Vede k rovnoměrnému zatížení procesorů
    - Vlákna se nevytvářejí do zásoby – velká režie

- Z pohledu jádra OS a vyvažování zátěže
  - Statické
    - Dopředu jsou známy informace o vláknech, která budeme plánovat
      - Informace jsou s nějakou přesností považovány za dostatečně přesné
    - Na základě informací se vypočítá optimální plán, na kterém procesoru bude které vlákno spouštěno
    - Vlákna jsou pak za běhu alokována podle tohoto plánu na jednotlivé procesory
    - Jenže, který OS vám to umožní?
    - Jenže, optimální plán je úměrný přesnosti informací
  - Dynamické
    - Další režie s plánováním vláken za běhu
      - Lze zanedbat
    - Zajištěno jádrem OS
    - Počítá se se zatížením, které generují ostatní procesy v systému

Granularita

- Poměr objemu výpočtu k objemu komunikace
- Čím jemnější (Fine-Grained), tím menší objem dat je vypočítán mezi komunikací dvou vláken => častá komunikace o malých objemech
- Čím hrubší (Coarse-Grained) – opak jemnější
- Jemnější umožňuje vyšší paralelizaci, ale je třeba „zjemňování zastavit včas“, jinak se výpočet začne zpomalovat díky komunikační režii a režii synchronizace

Urychlení součtu hodnot pole

- Co je rychlejší?
  - Postupný součet všech hodnot pole
  - Nebo fáze odspoda – nahoru součtů prefixů?

Výpočet druhé diference

- V praxi může být funkce zadána konečnou posloupností hodnot, místo předpisem
- Diferenční počet je analogie k diferenciálnímu počtu

- Máme reálnou funkci f
- $x, h, \in R$
- diferenční krok: $h>0$

- Diference funkce f v bodě x
  - $\Delta f = f(x+h) - f(x)$

- Druhá diference posloupnosti a_n
  - $\Delta^2 a_n = \Delta(\Delta a_n)$

- $\Delta^0 a_n = a_n$
- $\Delta^k a_n = \Delta(\Delta^{k-1} a_n)$

- Algoritmus výpočtu druhé diference

```
for i:=1 to High(Items) do
  begin
    d1[i]:=Items[i]-Items[i-1];
    d2[i]:=d1[i]-d1[i-1];
  end;
```

- Co je lepší?
  - Použít velmi jemnou granularitu pro dva procesory
    - Jeden bude počítat d1, druhý d2
    - Jakou režii bude mít synchronizace?
  - Nebo nasadit řešení producent-konzument
    - Items jsou hodnoty vkládané do bufferu
    - d1 je buffer
    - d2 jsou hodnoty zkonzumované z bufferu
    - Kolik procesorů dokážeme tímhle způsobem využít? 2?
  - Anebo nasadit řešení podle výpočtu sum prefixů?
    - Dva průchody, jeden vypočte d1, druhý d2
    - Nebo využít, že je možné paralelně vypočítat 3 sousední hodnoty d1 a z nich 2 sousední hodnoty d1
      - A navrhnout vlastní řešení, které to vypočítá na jeden průchod?