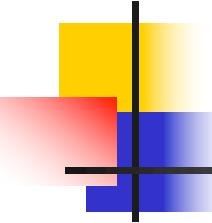


INF2440 – Effektiv Parallelprogrammering

Uke 2 våren 2018 - tidtaking

Eric Jul
PSE
Inst. for informatikk



Oppsummering – Uke1

- Vi har gjennomgått hvorfor vi får flere-kjerne CPUer
- Tråder er måten som et Java program bruker for å skape flere uavhengige parallelle programflyter i tillegg til main-tråden
- Tråder deler felles adresserom (data og kode)
- Vi kan gjøre mange typer feil, men det er alltid en løsning.
- Én stygg feil vi kan gjøre: Samtidig oppdatering (skriving) på delte data, på samme variabel (eks: `i++`)
- Samtidig skriving på en variabel **må synkroniseres**.
 - Alle objekter kan nyttes som en synkroniseringsvariabel, og da kan vi bruke enten en `synchronized` metode (treigt)for å gjøre det,
 - eller objekter av spesielle klasser som:
 - `CyclicBarrier`
 - `Semaphore` (undervises Uke2)
 - `Lock`
 - De har metoder som `await()` eller `lock()`, som gjør at tråder evt. må vente.

Tråder i Java (lett revidert og kompilerbar)

- En tråd er én programflyt, dvs. en serie med instruksjoner som oppfører seg som ett program – og kjører på en kjerne
- Det kan godt være (langt) flere tråder enn det er kjerner.
- En tråd er ofte implementert i form av en indre klasse i den klassen som løser problemet vårt (da får de greit **felles data**):

```
import java.util.concurrent.*;
class Problem { int [] fellesData ; // dette er felles, delte data for alle trådene
    public static void main(String [] args) {
        Problem p = new Problem(); // MÅ alltid lage ett objekt av den ytre klassen
        p.utfoer(); // før det lages objekter av indre klasser
    }
    void utfoer () { Thread t = new Thread(new Arbeider());
        t.start();
    }

    class Arbeider implements Runnable {
        int i, lokalData; // dette er lokale data for hver tråd
        public void run() {
            // denne kalles når tråden er startet
        }
    } // end indre klasse Arbeider
} // end class Problem
```

Flere tråder samtidig oppdatering av en variabel : i

- Alle trådene (1, 2 , 20 og 2000) prøver samtidig å utføre `i++` 100 000 ganger
- Vi skal se på programmet som produserte dette:

Antall tråder n Riktig svar:	1 100 000	2 200000	20 2000000	200 2000000	2000 200000000
Svar 1.gang 2. gang	100 000 100 000	200000 159234	1290279 1706068	16940111 16459210	170127199 164954894
Tap 1.gang 2. gang	0 % 0%	0% 20,4%	35,5% 14,6%	15,3% 17,7%	14,9% 17,5%

Programmet som laget tabellen

```
import java.util.*;  
import easyIO.*;  
import java.util.concurrent.*;  
/** Viser at manglende synkronisering på ett felles objekt gir feil – bare løsning 1) er riktig*/
```

```
public class Parallel {  
    int tall; // Sum av at 'antTraader' traader teller opp denne  
    CyclicBarrier b ; // sikrer at alle er ferdige når vi tar tid og sum  
    int antTraader, antGanger ,svar; // Etter summering: riktig svar er:antTraader*antGanger  
  
    //synchronized void inkrTall(){ tall++;} // 1) –OK fordi synkroniserer på samme objekt p  
    void inkrTall() { tall++;} // 2) - feil
```

```
public static void main (String [] args) {  
    if (args.length < 2) {  
        System.out.println("bruk >java Parallel <antTraader> <n= antGanger>");  
    }else{  
        int antKjerner = Runtime.getRuntime().availableProcessors();  
        System.out.println("Maskinen har "+ antKjerner + " prosessorkjerner.");  
        Parallel p = new Parallel();  
        p.antTraader = Integer.parseInt(args[0]);  
        p.antGanger = Integer.parseInt(args[1]);  
        p.utfor();  
    }  
} // end main
```

kode for main-tråden
kode for trådene

```

void utskrift (double tid) {
    svar = antGanger*antTraader;
    System.out.println("Tid "+antGanger+" kall * "+ antTraader+" Traader =" +
                        Format.align(tid,9,1)+" ms,");
    System.out.println(" sum:"+ tall +", tap:"+ (svar -tall)+" = "+
                        Format.align( ((svar - tall)*100.0 /svar),12,6)+"%");
}

} // end utskrift

void utfør () { // Denne kjøres bare av main-tråden
    b = new CyclicBarrier(antTraader+1);      //+1, ogsaa main
    long t = System.nanoTime();                // start klokke

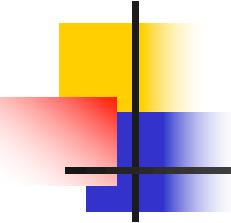
    for (int j = 0; j< antTraader; j++) {
        new Thread( new Para(j) ).start();
    }

    try{ // main thread venter på at alle trådene er ferdige
        b.await();
    } catch (Exception e) {return;}
    double tid = (System.nanoTime()-t)/1000000.0;
    utskrift(tid);
}

} // utfør

```

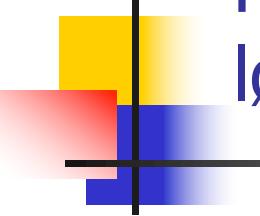
```
class Para implements Runnable{  
    int ind;  
    Para(int iind) { this.ind =ind;}  
  
    public void run() { // Kjøres av hver tråd  
        for (int j = 0; j< antGanger; j++) {  
            inkrTall();  
        }  
        try { // wait on all other threads + main  
            b.await();  
        } catch (Exception e) {return;}  
    } // end run  
  
    // void inkrTall() { tall++;}           // 3) Feil - usynkronisert  
    // synchronized void inkrTall(){ tall++;} // 4) Feil – kallene synkroniserer på  
                                              // hvert sitt objekt  
} // end class Para  
} // END class Parallel
```



Hvilke typer problem egner seg for parallele løsninger?

Lad os kjøre programmet!

(Interaktive demo av programmet med og uten synkronisering).



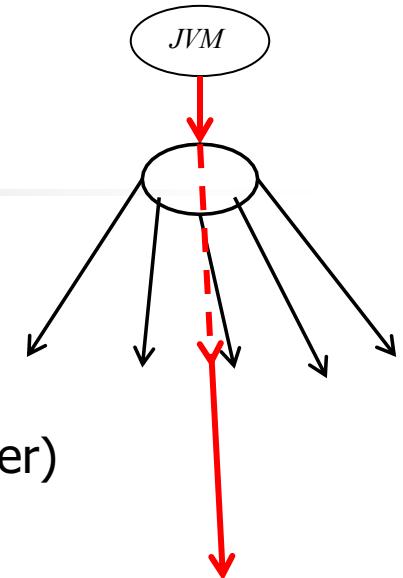
Hvilke typer problem egner seg for parallelle løsninger?

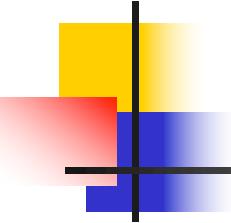
1. Kompleksitetsklasse:
 - $O(1)$, $O(\log n)$, $O(n)$, $O(n \cdot \log n)$, $O(n^{1.5})$, $O(n^2)$, ..., P, ..., NP
2. Størrelsen på data: n
 - Sorterer vi 100 eller 100 million tall?
 - Multipliserer vi to 4×4 matriser eller to 2000×2000 matriser?
3. Må vi synkronisere på delte data, må antall synkroniseringer være (minst) en orden lavere enn algoritmen pga. 'mye' overhead ved synkronisering.
4. Å starte flere tråder tar ca. 3-5 millisekunder – den første tråden tar lengst tid.

Dette skal vi se på utover i kurset, med unntak av $O(1)$ – (konstant eksekveringstid uavhengig av datamengden som klart **ikke** egner seg for parallelisering) kan det meste gis en mer effektiv parallel implementasjon ***hvis n er stor nok***
(eller sagt på en annen måte: ***hvis kjøretiden er > 10 millisekunder***).

Plan for resten av Uke2

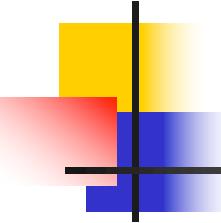
- I) Om å avslutte parallele tråder
 - La dem bli ferdige med run-metoden,
Hvordan teste at alle er ferdige ?
 - Synkronisert avslutning (Semaphore, CyclicBarrier)
 - new Thread – join() – avslutning
- II) Ulike synkroniseringsprimitiver
 - Vi skal bare lært oss noen få - ett tilstrekkelig sett
- III) Hvor mye tid bruker parallele programmer
 - JIT-kompilering
 - Overhead ved start
 - Synkronisering underveis i beregningene
 - Operativsystem og søppeltømming
- IV) 'Lover' om kjøretid
 - Amdahl lov
 - Gustafsons lov





1) Avslutning med en CyclicBarrier

- En CyclicBarrier (`cb= new CyclicBarrier (n+1)`)
 - Er tenkt som et ventested, en bom/grind for et antall (i dette tilfellet for $n+1$) tråder - de n 'nye' trådene + main. Alle må vente når de sier sier `cb.await()` til sistemann ankommer køen, og **da** kan alle fortsette.
 - Trådene kan da være ferdige med en beregning kan selv avslutte med å bli ferdige med sin `run()`-kode. Main-tråden forsetter, og vet at de andre trådene er ferdige. Main-tråden kan da bruke resultatene fra trådene.
 - Den sykliske barrieren cb er da strakt klar til å køe nye n tråder som sier `cb.await()` , .. osv
 - `cb.await()` sies inne i en try-catch blokk



2) Avslutning med en Semaphore

- En Semaphore (`sf = new Semaphore(-n+1)`)
 - Administrerer (i dette tilfellet) $-n+1$ stk. **tillatelser**.
 - To sentrale primitiver:
 - `sf.acquire()` – ber om **en** tillatelse. Antall tillatelser i sf blir da 1 mindre hvis antallet er >0 . Hvis det ikke er noen ledig tillatelse, må tråden vente i en kø (inne i en try-catch blokk)
 - `sf.release()` – gir **én** tillatelse tilbake til semaforen sf. Ikke try-catch blokk (Den tillatelsen som gis tilbake behøver ikke vært 'fått' ved hjelp av `acquire()` ; den er bare et tall).
 - Avlutning med Semaphore sf:
 - Maintråden sier `sf.acquire()` – og må vente på at det er minst en tillatelse i sf.
 - Alle de n nye trådene sier `sf.release()` når de terminerer, og når den siste sier `sf.release()` blir det 1 tillatelse ledig og main fortsetter.
 - Ikke syklistisk.

3) Avslutning med join() - enklest

- Logikken er her at i den rutinen hvor alle trådene lages, legges de også inn i en array. Main-tråden legger seg til å vente på den tråden som den har peker til skal terminere selv.
Venter på alle trådene etter tur at de terminerer:

```
// main –tråden i konstruktøren
Thread [] t = new Thread[n];
for (int i = 0; i < n; i++) {
    t[i] = new Thread (new Arbeider(..));
    t[i].start();
}

.....
// main vil vente her til trådene er ferdige
for(int i = 0; i < n; i++) {
    try{ t[i].join();
    }catch (Exception e){return;};
}
.....
```

II) Mange ulike synkroniserings primitiver Vi skal bare lære noen få !

■ `java.util.concurrent`

Classes

[AbstractExecutorService](#)

[ArrayBlockingQueue](#)

[ConcurrentHashMap](#)

[ConcurrentLinkedDeque](#)

[ConcurrentLinkedQueue](#)

[ConcurrentSkipListMap](#)

[ConcurrentSkipListSet](#)

[CopyOnWriteArrayList](#)

[CopyOnWriteArrayList](#)

[CountDownLatch](#)

[CyclicBarrier](#)

[DelayQueue](#)

[Exchanger](#)

[ExecutorCompletionService](#)

[Executor](#)

[ExecutorPoolExecutor](#)

[ThreadPoolExecutor.AbortPolicy](#)

[ThreadPoolExecutor.CallerRunsPolicy](#)

[ThreadPoolExecutor.DiscardOldestPolicy](#)

[ThreadPoolExecutor.DiscardPolicy](#)

[Semaphore](#)

[SynchronousQueue](#)

[ThreadLocalRandom](#)

[ThrExecutors](#)

[ForkJoinPool](#)

[ForkJoinTask](#)

[ForkJoinWorkerThread](#)

[FutureTask](#)

[LinkedBlockingDeque](#)

[LinkedBlockingQueue](#)

[LinkedTransferQueue](#)

[Phaser](#)

[PriorityBlockingQueue](#)

[RecursiveAction](#)

[RecursiveTask](#)

[ScheduledThreadPoolEx](#)

Interfaces

[BlockingDeque](#)

[BlockingQueue](#)

[Callable](#)

[CompletionService](#)

[ConcurrentMap](#)

[ConcurrentNavigableMap](#)

[Delayed](#)

[Executor](#)

[ExecutorService](#)

[ForkJoinPool.ForkJoinWorkerThreadFactory](#)

[ForkJoinPool.ManagedBlocker](#)

[Future](#)

[RejectedExecutionHandler](#)

[RunnableFuture](#)

[RunnableScheduledFuture](#)

[ScheduledExecutorService](#)

[ScheduledFuture](#)

[ThreadFactory](#)

[TransferQueue](#)

java.util.concurrent.atomic

De har samme virkning (semantikk) som volatile variable (forklaries senere), men kan gjøre mer sammensatte operasjoner. Mye raskere enn synchronized methods.

Eksempel på operasjoner i **AtomicIntegerArray**:

int

int

int

void

Classes

[AtomicBoolean](#)

[AtomicInteger](#)

[AtomicIntegerArray](#)

[AtomicIntegerFieldUpdater](#)

[AtomicLong](#)

[AtomicLongArray](#)

[AtomicLongFieldUpdater](#)

[AtomicMarkableReference](#)

[AtomicReference](#)

[AtomicReferenceArray](#)

[AtomicReferenceFieldUpdater](#)

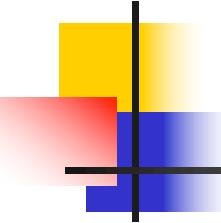
[AtomicStampedReference](#)

[get](#)(int i) Gets the current value at position i.

[getAndAdd](#)(int i, int delta) Atomically adds the given value to the element at index i.

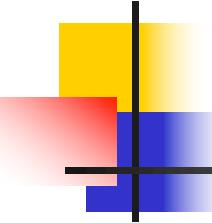
[getAndDecrement](#)(int i) Atomically decrements by one the element at index

[set](#)(int i, int newValue) Sets the element at position i to the given value.



Vi skal bare lære ett fåtall av dette

- Her er de vi skal koncentrere oss om:
 - new Thread – join()
 - synchronized method
 - Semaphore – acquire() og release()
 - CyclicBarrier – await()
 - ExecutorService pool = Executors.newFixedThreadPool(k);
med Futures - forklares senere
 - AtomicIntegerArray – get(), set(), getAndAdd(),..
 - ReentrantLock (i pakken: **[java.util.concurrent.locks](#)**)
 - volatile variable - forklares senere
- Alle de synkroniseringer vi trenger, kan gjøres med disse!
- De fleste andre har sine måter å gjøre det på, men man har neppe tid til å lære seg alle.
- Bedre å bli flink i et lite og tilstrekkelig sett av synkroniseringsprimitiver, enn halvgod i de fleste.



II) Tidtagning

- JIT –kompilering
 - Hvor mye betyr det egentlig
- Operativsystemet (Windows eller Linux)
 - Er de like raske?
- Søppeltømming i Java
 - Skjer under kjøring (med i tidene)

Tidsmålinger og JIT (Just In Time) -kompilering

- Tilbake til kompileringen av et Java-program:

javac kompilerer først vårt java-program til en .class fil. som består av **byte-kode**

java (JVM) starter vår program i 'main()', men følger med.

1. Kalles en metode flere ganger, kompileres den over fra bytekode til **maskinkode**.

2. Kalles den enda mange ganger kan denne koden igjen **optimaliseres** (flere ganger)

main().

Vårt program kjører først interpretert (byte-koden tolkes). Blir JIT-kompilert (mens koden kjører) en eller flere ganger. Går mye raskere

Optimalisering – ett eksempel

Original kode

```
class A {  
    B b;  
    public void newMethod() {  
        y = b.get();  
        ...do stuff...  
        z = b.get();  
        sum = y + z;  
    }  
}  
  
class B {  
    int value;  
    final int get() {  
        return value;  
    }  
}
```

1) Inline get

```
public void  
newMethod() {  
    y = b.value;  
    ...do stuff...  
    z = b.value;  
    sum = y + z;  
}
```

2) Fjern overflødige les

```
public void  
newMethod() {  
    y = b.value;  
    ...do stuff...  
    z = y;  
    sum = y + z;
```

3) Fjern overflødige variable

```
public void  
newMethod() {  
    y = b.value;  
    ...do stuff...  
    y = y;  
    sum = y + y;  
}
```

4) Fjern død kode

```
public void  
newMethod() {  
    y = b.value;  
    ...do stuff...  
    sum = y + y;
```

Mediantider for finnMax fra ukeoppgavene:

n= 10 000

Vi ser at kjøretidene (para) synker dramatisk fra 1.ste til neste kjøring.
Pga JIT-optimalisering

M:\INF2440Para\FinnMax>java FinnMaxMulti 10000 7

Kjøring:0, ant kjerner:8, antTråder:8

Max para = a:9853, paa: 13.24 msek. , nanosek/n: 1324.41

Max sekv = a:9853, paa: 0.13 msek. , nanosek/n: 12.59

Kjøring:1, ant kjerner:8, antTråder:8

Max para = a:9853, paa: 0.20 msek. , nanosek/n: 20.22

Max sekv = a:9853, paa: 0.11 msek. , nanosek/n: 10.94

Kjøring:2, ant kjerner:8, antTråder:8

Max para = a:9853, paa: 0.26 msek. , nanosek/n: 25.78

Max sekv = a:9853, paa: 0.11 msek. , nanosek/n: 11.18

Kjøring:3, ant kjerner:8, antTråder:8

Max para = a:9853, paa: 0.21 msek. , nanosek/n: 21.39

Max sekv = a:9853, paa: 0.24 msek. , nanosek/n: 23.91

Kjøring:4, ant kjerner:8, antTråder:8

Max para = a:9853, paa: 0.22 msek. , nanosek/n: 21.99

Max sekv = a:9853, paa: 0.20 msek. , nanosek/n: 19.74

Kjøring:5, ant kjerner:8, antTråder:8

Max para = a:9853, paa: 0.25 msek. , nanosek/n: 25.00

Max sekv = a:9853, paa: 0.23 msek. , nanosek/n: 22.95

Kjøring:6, ant kjerner:8, antTråder:8

Max para = a:9853, paa: 0.20 msek. , nanosek/n: 19.56

Max sekv = a:9853, paa: 0.21 msek. , nanosek/n: 20.52

Median seq time: 0.205, median para time: 0.250,

Speedup: **0.82**, n = 10 000

M:\INF2440Para\FinnMax>java FinnMaxMulti 10000000 5

n= 10 mill

Kjøring:0, ant kjerner:8, antTråder:8

Max para = a:9999216, paa: 21.93 msec. , nanosek/n: 2.19

Max sekv = a:9999216, paa: 7.65 msec. , nanosek/n: 0.76

Kjøring:1, ant kjerner:8, antTråder:8

Max para = a:9999216, paa: 3.04 msec. , nanosek/n: 0.30

Max sekv = a:9999216, paa: 5.95 msec. , nanosek/n: 0.59

Kjøring:2, ant kjerner:8, antTråder:8

Max para = a:9999216, paa: 3.20 msec. , nanosek/n: 0.32

Max sekv = a:9999216, paa: 7.33 msec. , nanosek/n: 0.73

Kjøring:3, ant kjerner:8, antTråder:8

Max para = a:9999216, paa: 2.67 msec. , nanosek/n: 0.27

Max sekv = a:9999216, paa: 5.10 msec. , nanosek/n: 0.51

Kjøring:4, ant kjerner:8, antTråder:8

Max para = a:9999216, paa: 2.88 msec. , nanosek/n: 0.29

Max sekv = a:9999216, paa: 5.57 msec. , nanosek/n: 0.56

Median seq time: 5.945, median para time: 3.042,

Speedup: **1.95**, n = 10000000

M:\INF2440Para\FinnMax>java -Xint FinnMaxMulti 10000000 5

Kjøring:0, ant kjerner:8, antTråder:8

Max para = a:9999216, paa: 53.13 msek. , nanosek/n: 5.31

Max sekv = a:9999216, paa: 144.08 msek. , nanosek/n: 14.41

JIT-kompilering
avslått :
> java -Xint
.....

n= 10 mill

Kjøring:1, ant kjerner:8, antTråder:8

Max para = a:9999216, paa: 44.94 msek. , nanosek/n: 4.49

Max sekv = a:9999216, paa: 144.86 msek. , nanosek/n: 14.49

Kjøring:2, ant kjerner:8, antTråder:8

Max para = a:9999216, paa: 33.83 msek. , nanosek/n: 3.38

Max sekv = a:9999216, paa: 137.45 msek. , nanosek/n: 13.75

Kjøring:3, ant kjerner:8, antTråder:8

Max para = a:9999216, paa: 53.63 msek. , nanosek/n: 5.36

Max sekv = a:9999216, paa: 136.90 msek. , nanosek/n: 13.69

Kjøring:4, ant kjerner:8, antTråder:8

Max para = a:9999216, paa: 50.09 msek. , nanosek/n: 5.01

Max sekv = a:9999216, paa: 137.71 msek. , nanosek/n: 13.77

Median seq time: 137.714, median para time: 50.088,

Speedup: **2.75**, n = 10000000

M:\INF2440Para\FinnMax>java FinnM 100000000 5

Kjoering:0, ant kjerner:8, antTraader:8

Max verdi parallel i a:99989305, paa: 41.913504 ms.

n= 100 mill

Max verdi sekvensiell i a:99989305, paa: 238.799921 ms.

Kjoering:1, ant kjerner:8, antTraader:8

JIT-kompilering +optimalisering

Max verdi parallel i a:99989305, paa: 26.78024 ms.

Max verdi sekvensiell i a:99989305, paa: 235.431219 ms.

Kjoering:2, ant kjerner:8, antTraader:8

Max verdi parallel i a:99989305, paa: 27.791271 ms.

Max verdi sekvensiell i a:99989305, paa: 248.066478 ms.

Søppel-tømming

Kjoering:3, ant kjerner:8, antTraader:8

Max verdi parallel i a:99989305, paa: 26.86283 ms.

Max verdi sekvensiell i a:99989305, paa: 236.013201 ms.

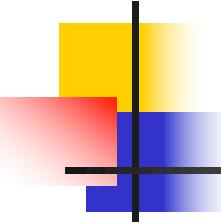
Kjoering:4, ant kjerner:8, antTraader:8

Max verdi parallel i a:99989305, paa: 27.755575 ms.

Max verdi sekvensiell i a:99989305, paa: 223.535073 ms.

Median sequential time:236.013201, median parallel time:27.755575,

n= 100000000, **Speedup: 8.59**



Hva betyr dette for tidsmålingene

- Første gangen vi gjører er tiden vi måler en sum av:
 - Først litt interperetering av bytekode
 - Så oversetting(kompilering) av hyppig brukte metoder til maskinkode
 - kjøring av resten av programmet dels i maskinkode.
- Andre gang vi kjører, kan følgende skje:
 - JVM finner at noen av maskinkompilerte metodene må optimaliseres ytterligere
 - Kjøretiden synker ytterligere
- Tredje gang er som oftest optimaliseringa ferdig, men ytterligere optimalisering kan bli gjort
- Tidtakningen vår må endres !
- Vi kjører det sekvensielle og parallelle programmet f.eks 9 ganger i en løkke , noterer alle kjøretider i to arrayer som så sorteres og vi velger medianverdien = $a[a.length/2]$
- Du får aldri samme svaret to ganger – mye variasjon !!

FinnMax, 3 ulike kjøringer (samme parametre , varierer antall tråder: 8, 16, 4)

Uke2>java FinnM 1000000 9

Kjøring:0, **ant kjerner:8, antTråder:8**

Max verdi parallel i a:999216, paa: 23.860968 ms.

Max verdi sekvensiell i a:999216, paa: 3.468803 ms.

Kjøring:1, ant kjerner:8, antTråder:8

Max verdi parallel i a:999216, paa: 0.311465 ms.

Max verdi sekvensiell i a:999216, paa: 0.549437 ms.

.....

Kjøring:8, ant kjerner:8, antTråder:8

Max verdi parallel i a:999216, paa: 0.422752 ms.

Max verdi sekvensiell i a:999216, paa: 0.532639 ms.

Median sequential time:0.52004,

median parallel time:0.429051,

Speedup: **1.26**, n = 1000000

Uke2>java FinnM 1000000 9

Kjøring:0, **ant kjerner:8, antTråder:4**

Max verdi parallel i a:999216, paa: 16.154151 ms.

Max verdi sekvensiell i a:999216, paa: 3.75507 ms.

Kjøring:1, ant kjerner:8, antTråder:4

Max verdi parallel i a:999216, paa: 1.280854 ms.

Max verdi sekvensiell i a:999216, paa: 0.520741 ms.

Kjøring:2, ant kjerner:8, antTråder:4

Max verdi parallel i a:999216, paa: 0.557136 ms.

Max verdi sekvensiell i a:999216, paa: 0.509191 ms.

.....

Kjøring:8, ant kjerner:8, antTråder:4

Max verdi parallel i a:999216, paa: 0.628527 ms.

Max verdi sekvensiell i a:999216, paa: 0.52354 ms.

Median sequential time:0.520741, median parallel time:0.628527,

Speedup: **0.88**, n = 1000000

Uke2>java FinnM 1000000 9

Kjøring:0, **ant kjerner:8, antTråder:16**

Max verdi parallel i a:999216, paa: 18.808946 ms.

Max verdi sekvensiell i a:999216, paa: 3.558043 ms.

Kjøring:1, ant kjerner:8, antTråder:16

Max verdi parallel i a:999216, paa: 1.847439 ms.

Max verdi sekvensiell i a:999216, paa: 0.453898 ms.

.....

Kjøring:8, ant kjerner:8, antTråder:16

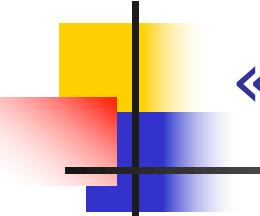
Max verdi parallel i a:999216, paa: 0.502542 ms.

Max verdi sekvensiell i a:999216, paa: 0.471396 ms.

Median sequential time:0.509891,

median parallel time:0.646726,

Speedup: **0.90**, n = 1000000



«Aldri» samme resultatet to ganger

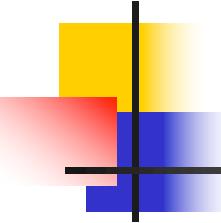
Uke2>java FinnM 1000000 9
ant kjerner:8, antTråder:8, n = 1mill

Med antall kjøringer for median = 9

- 1) Speedup: **0.68**, n = 1000000
- 2) Speedup: 0.96, n = 1000000
- 3) Speedup: 0.84, n = 1000000
- 4) Speedup: 0.71, n = 1000000
- 5) Speedup: 1.06, n = 1000000
- 6) Speedup: 1.26, n = 1000000

Med antall kjøringer for median = 21

- 7) Speedup: 1.00, n = 1000000
- 8) Speedup: 0.84, n = 1000000
- 9) Speedup: 0.88, n = 1000000
- 10) Speedup: **1.75**, n = 1000000
- 11) Speedup: 0.87, n = 1000000
- 12) Speedup: 1.11, n = 1000000
- 13) Speedup: 1.03, n = 1000000



Konklusjon på JIT-kompilering

- JIT-kompilering kan skrues av med `>java -Xint MittProg ..`
 - Brukes bare for debugging
- JIT kompilering kan gi 10 til 30 ganger så rask eksekvering for liten n (en god del mer for stor n)
- Første, andre (og tredje) kjøring er tidsmessig sterkt misvisende
- Vi må:
 - Kjøre programmet i en løkke f.eks 9 (eller 7 eller 11) ganger
 - Legge tidene i hver sin array (sekvensielt og parallel tid)
 - Sortere arrayene
 - Ta ut medianen (element `a.length/2`), som blir vår tidsmåling

Dette mÅler tidene for 9 trÅder kjørt etter hverandre

```
import java.util.concurrent.*;
import java.util.*;
class Problem2 { int [] fellesData ; // dette er felles, delte data for alle trådene
    double [] tidene ;
    int ant, svar;
    public static void main(String [] args) {
        ( new Problem()).utfør(args);
    }
    void utfør (String [] args) {
        ant = new Integer(args[0]);
        fellesData = new int [ant];
        tidene = new double[9];
        for (int m = 0; m <9; m++) {
            long tid = System.nanoTime();
            Thread t = new Thread(new Arbeider());
            t.start();
            try{t.join();}catch (Exception e) {return;}
            tidene[m] = (System.nanoTime() -tid)/1000000.0;
            System.out.println("Tid for "+m + ", tråd:"+tidene[m]+“ ms");
        }
        Arrays.sort(tidene);
        System.out.println("Median med svar:"+svar+", for trådene:"+tidene[(tidene.length)/2]+“ ms");
    } // end utfør

    class Arbeider implements Runnable {
        int i,lokaldata; // dette er lokale data for hver tråd
        public void run() { int sum =0;
            for (int i = 0; i < ant; i++) sum +=fellesData[i];
            svar =sum;
        }
    } // end indre klasse Arbeider
} // end class Problem
```

M:\INF2440Para\Powerpoint\Uke2>java Problem2 1000000

Tid for 0, tråd:22.26 ms

Tid for 1, tråd: 1.12ms

Tid for 2, tråd: 3.19ms

Tid for 3, tråd: 0.58ms

Tid for 4, tråd: 0.65ms

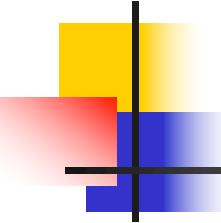
Tid for 5, tråd: 0.49ms

Tid for 6, tråd: 0.48ms

Tid for 7, tråd: 0.53ms

Tid for 8, tråd: 0.85ms

Median med svar:0, for trådene:0.65 ms



Hva med operativsystemet:

- Linux og Windows har om lag like rask implementasjon av Java og trådprogrammering,
- Dag Langmyhr testet to helt like maskiner med hhv. Linux og Windows, og resultatene tidsmessig (medianer) var nesten helt like, men
 - Ulike maskiner som Ifis store servere (diamant, safir,...) har en annen Linux og en noe langsommere ytelse for korte, trådbaserte programmer.

Hva med søppeltømming – garbage collection:

- Søppeltømming (=opprydding i lageret og fjerning av objekter vi ikke lenger kan bruke) kan slå til når som helst under kjøring:

Kjøring:2, ant kjerner:8, antTråder:8

Max para = a:9853, paa: 0.35 msek. , nanosek/n: 35.07

Max sekv = a:9853, paa: 0.01 msek. , nanosek/n: 1.36

Kjøring:3, ant kjerner:8, antTråder:8

Max para = a:9853, paa: 0.57 msek. , nanosek/n: 56.87

Max sekv = a:9853, paa: 0.01 msek. , nanosek/n: 0.66

Kjøring:4, ant kjerner:8, antTråder:8

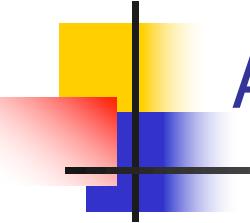
Max para = a:9853, paa: 0.43 msek. , nanosek/n: 43.47

Max sekv = a:9853, paa: 0.01 msek. , nanosek/n: 1.33

Kjøring:5, ant kjerner:8, antTråder:8

Max para = a:9853, paa: 0.49 msek. , nanosek/n: 49.20

Max sekv = a:9853, paa: 0.01 msek. , nanosek/n: 1.36



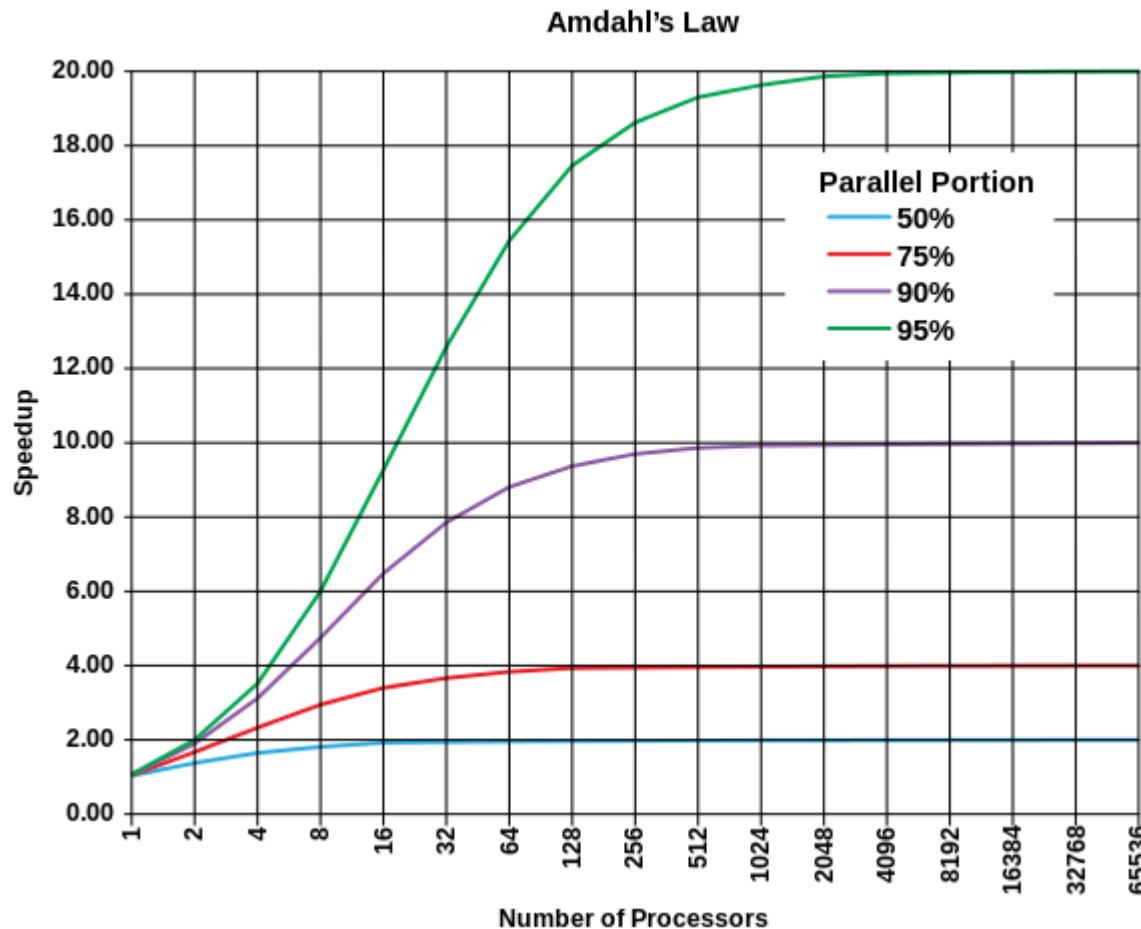
Amdahl lov for parallelle beregninger

- Amdahl lov: Har du **seq** andel sekvensiell kode og da **p** andel paralleliserbar kode i et parallelt program, **seq+p=1**, er den største speedup S du kan få med k kjerner:

$$S = \frac{\text{tid(sekvensiell)}}{\text{tid(parallell)}} = \frac{1}{\text{seq} + p/k} = \frac{1}{1-p+p/k}$$

- Når k → ∞, vil S → $\frac{1}{1-p}$.
- Er p=0.9, så er S ≤ 10 uansett hvor mange kjerner du har, og har du 'bare' 50, er $S = \frac{1}{1-0.9+0.9/50} = 8,5$.
- Amdahls lov er pessimistisk- antar fast størrelse på problemet
- «Hvis du først har brukt 10% av tida på en sekvensiell del, så kan resten av programmet ikke gå fortare enn 0.00 sekunder uansett hvor mange prosessorer du bruker på det. Dvs. at speedup ≤ 10»

Amdahl for ulike verdier av p



Amdahl – viktig å parallelisere største del

Two independent parts

A **B**

Original process



Make **B** 5x faster



Make **A** 2x faster



Gustafsons lov for parallelle beregninger

- La S være speedup, P antall kjerner og α være andel sekvensiell kode (tidsmessig), så er:

$$S(P) = P - \alpha(P-1)$$

Parallel løsning er: $a + b$ (a = sekvensiell tid, b = parallel tid)

Sekvensiell løsning er da: $a + P * b$

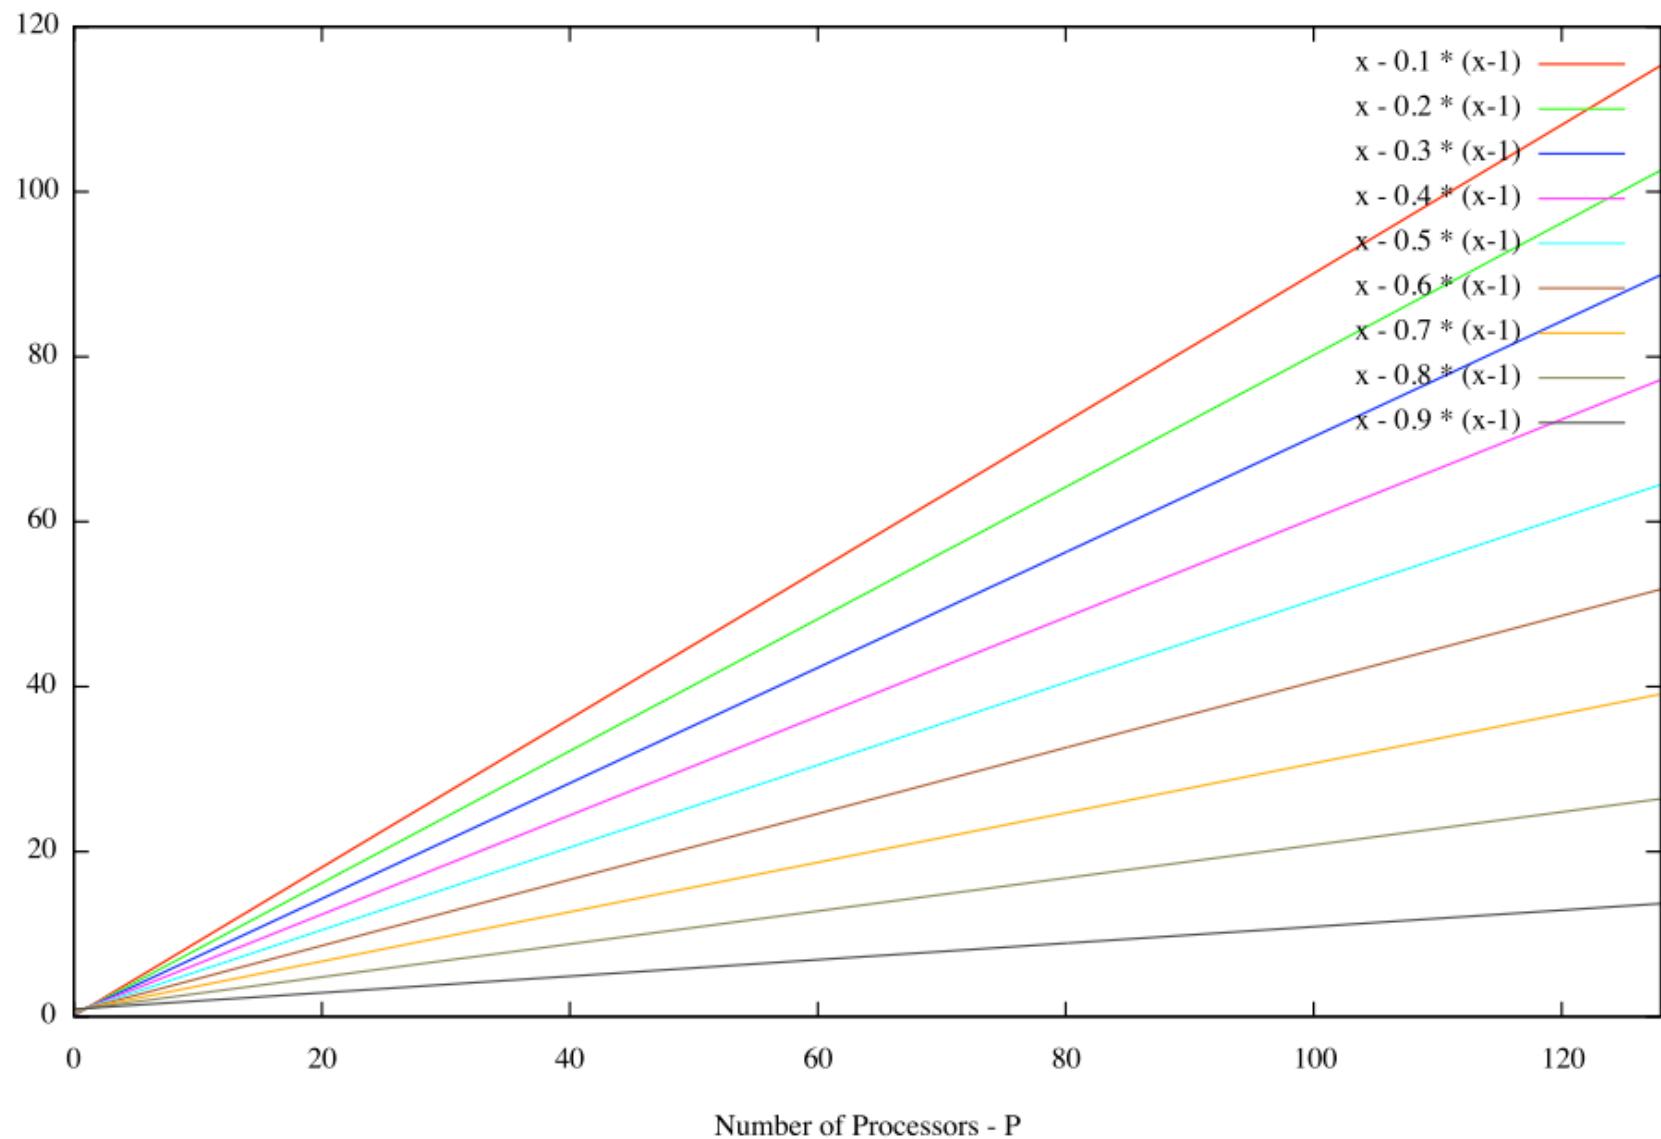
Speedup er da:

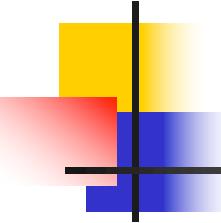
$$\frac{a+P*b}{a+b}, \text{ og har at } \alpha = \frac{a}{a+b} \text{ og da er:}$$

$$\begin{aligned} S(P) &= \frac{a + P * b}{a + b} = \frac{a}{a + b} + P * \frac{b}{a + b} = \alpha + P * \frac{b}{a + b} \\ &= \alpha + P * \frac{a+b-a}{a+b} = \alpha + P * (1 - \alpha) = P - \alpha(P - 1) \end{aligned}$$

- «Hvis du tidligere brukte 1 time på å løse et problem sekvensielt, vil du nå også bruke 1 time på å løse et større, mer nøyaktig problem parallelt, da med større speedup – for eksempel i meteorologi»

Gustafson's Law: $S(x) = x - \alpha(x - 1),$

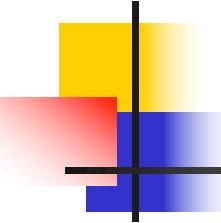




Sammenligning av Amdahl og Gustafson + egne betrakninger

- Amdahl antar at oppgaven er fast av en gitt lengde(n)
- Gustafson antar at du med parallelle maskiner løser større problemer (større n) og da blir den sekvensielle delen mindre.
- Min betraktning:
 1. En algoritme består av noen sekvensielle deler og noen paralleliserbare deler.
 2. Hvis de sekvensielle delene har lavere orden – f.eks $O(\log n)$, men de parallelle har en større orden – eks $O(n)$ så vil de parallelle delene bli en stadig større del av kjøretida hvis n øker (Gustafson)
 3. Hvis de parallelle og sekvensielle delene har samme orden, vil et større problem ha samme sekvensielle andel som et mindre problem (Amdahl).
 4. I tillegg kommer alltid et fast overhead på å starte k tråder (1-4 ms.)
Algoritmer vi skal jobbe med er mer av type 2 (Gustafson) enn type 3(Amdahl) men vi har alltid overhead, så små problemer løses best sekvensielt.

Konklusjon: For store problemer bør vi ha håp om å skalere nær lineært med antall kjerner hvis ikke vi får kø og forsinkelser når alle kjernene skal lese/skrive i lageret.



Hva har vi sett på i Uke2

- I) Tre måter å avslutte tråder vi har startet.
 - join(), Semaphor og CyclicBarrier.
- II) Mange ulike synkroniseringsprimitiver
 - Vi skal bare lært oss noen få - ett tilstrekkelig sett
- III) Hvor mye tid bruker parallele programmer
 - JIT-kompilering, Overhead ved start, Synkronisering, Operativsystem og søppeltømming,
 - Bruk mediantida av flere kjøringer
- IV) 'Lover' om Kjøretid
 - Amdahl lov
 - Gustafsons lov
- V) Samtidig skriving i naboelementer i en array er OK.