Makefile::Parallel
Uma ferramenta para paralelização de processos

Alberto Manuel Brandão Simões
ambs@di.uminho.pt

Trabalho realizado com
Rúben Fonseca e José João Almeida

Simpósio Doutoral da Linguateca 2007b

Necessidade de Paralelização

- processo de alinhamento e de extracção de exemplos demora demasiado tempo (uma semana...);
- afinação de parâmetros de algoritmos obriga ao re-cálculo de todo o processo;
- esperar uma semana é impensável;
- paralelizar o processo ao nível da instrução está fora do âmbito do doutoramento...
- ...no entanto a paralelização ao nível da aplicação não é tão dispendiosa...
- ...uma vez que a pipeline já é um conjunto de pequenos programas;
- mas é necessário um método expedito de especificar formalmente dependências entre as várias aplicações que constituem o processo de alinhamento e extracção de exemplos;

Corpus	PT–EN	PT–ES	PT–FR
Constituição	2 013	2 011	2 013
COMPARA	97 215	—	—
Le Monde Diplomatique	—	—	68 231
JRC	286 008	281 185	277 754
EuroParl	998 830	1 006 895	1 023 841
EurLex	10 394 893	1 111 068	1 710 760

Paralelização: abordagem

- utilizar uma linguagem conhecida para especificar dependências: makefile;
- dependências entre aplicações e não dependência de ficheiros;
- açucar sintáctico extra para alguns detalhes específicos;
- acções semânticas em Bash (como as makefiles)
- ou em Perl (linguagem de eleição).
- regras paramétricas:
  - instanciar regras em tempo de execução;
  - facilitar paralelismo da mesma aplicação;
  - facilitar execução com parâmetros diferentes;

Cada regra, inclui:

- nome do processo;
- lista de dependências;
- tempo de execução esperado;
- número de processadores necessários;
- acção: descrição do processo.

Example

```
initmat: codify  (20:00:00) [1]
    nat-initmat source.crp target.crp mat.in
```

Regras paramétricas

Instanciação de uma variável

```
foo: ...
    ...
    i <- sub{ $nr = ‘cat Eu...‘; printf("%03d\n",$_) for (1..$nr); }
```

Regra paramétrica

```
initmat$i: codify  (20:00:00)
    initmat EurLex/source.$i.crp EurLex/target.$i.crp EurLex/mat.$i.in
```

Regra expandida

```
initmat001: codify  (20:00:00)
    initmat EurLex/source.001.crp EurLex/target.001.crp EurLex/mat.001.in

initmat002: codify  (20:00:00)
    initmat EurLex/source.002.crp EurLex/target.002.crp EurLex/mat.002.in

initmat003: codify  (20:00:00)
    initmat EurLex/source.003.crp EurLex/target.003.crp EurLex/mat.003.in
...
```

Regras paramétricas

Instanciação de uma variável

```
foo: ...
    ...
    i <- sub{ $nr = `cat Eu...`; printf("%03d\n",$_) for (1..$nr); }
```

Regra paramétrica

```
initmat$i: codify  (20:00:00)
    initmat EurLex/source.$i.crp EurLex/target.$i.crp EurLex/mat.$i.in
```

Regra expandida

```
initmat001: codify  (20:00:00)
    initmat EurLex/source.001.crp EurLex/target.001.crp EurLex/mat.001.in

initmat002: codify  (20:00:00)
    initmat EurLex/source.002.crp EurLex/target.002.crp EurLex/mat.002.in

initmat003: codify  (20:00:00)
    initmat EurLex/source.003.crp EurLex/target.003.crp EurLex/mat.003.in
...
```

Regras paramétricas

Instanciação de uma variável

```
foo: ...
    ...
    i <- sub{ $nr = `cat Eu...`; printf("%03d\n",$_) for (1..$nr); }
```

Regra paramétrica

```
initmat$i: codify  (20:00:00)
    initmat EurLex/source.$i.crp EurLex/target.$i.crp EurLex/mat.$i.in
```

Regra expandida

```
initmat001: codify  (20:00:00)
    initmat EurLex/source.001.crp EurLex/target.001.crp EurLex/mat.001.in

initmat002: codify  (20:00:00)
    initmat EurLex/source.002.crp EurLex/target.002.crp EurLex/mat.002.in

initmat003: codify  (20:00:00)
    initmat EurLex/source.003.crp EurLex/target.003.crp EurLex/mat.003.in
...
```

Makefile usada (1/3)

```
codify: (20:00:00)
    nat-codify -id=EurLex -tmx eurlex.tmx
    i <- sub{ $nr = `cat EurLex/nat.cnf |grep nr-chunks|cut -f 2 -d "="`; printf("%03d\n",$_) for (1..$nr)
    j <- sub{ print("$_\n") for (2..4); }

ngramsA$j: codify  (20:00:00)
    for a in @i; do nat-ngrams -n $j EurLex/source.${a}.crp /tmp/source.$j.ngrams; done
    mv /tmp/source.$j.ngrams EurLex/source.$j.ngrams

ngramsB$j: codify  (20:00:00)
    for a in @i; do nat-ngrams -n $j EurLex/target.${a}.crp /tmp/target.$j.ngrams; done
    mv /tmp/target.$j.ngrams EurLex/target.$j.ngrams

ngramsA: ngramsA$j (20:00:00)
    nat-joinGrams -tmp=/tmp -s EurLex

ngramsB: ngramsB$j (20:00:00)
    nat-joinGrams -tmp=/tmp -t EurLex

ngrams: ngramsA ngramsB (20:00:00)
    echo 'n-grams=1' >> EurLex/nat.cnf

initmat$i: codify  (20:00:00)
    nat-initmat EurLex/source.$i.crp EurLex/target.$i.crp EurLex/mat.$i.in

ipfp$i: initmat$i (20:00:00)
    nat-ipfp 5 EurLex/source.$i.crp EurLex/target.$i.crp EurLex/mat.$i.in EurLex/mat.$i.out
    rm -f EurLex/mat.$i.in
```

Paralelização da Extracção de Exemplos

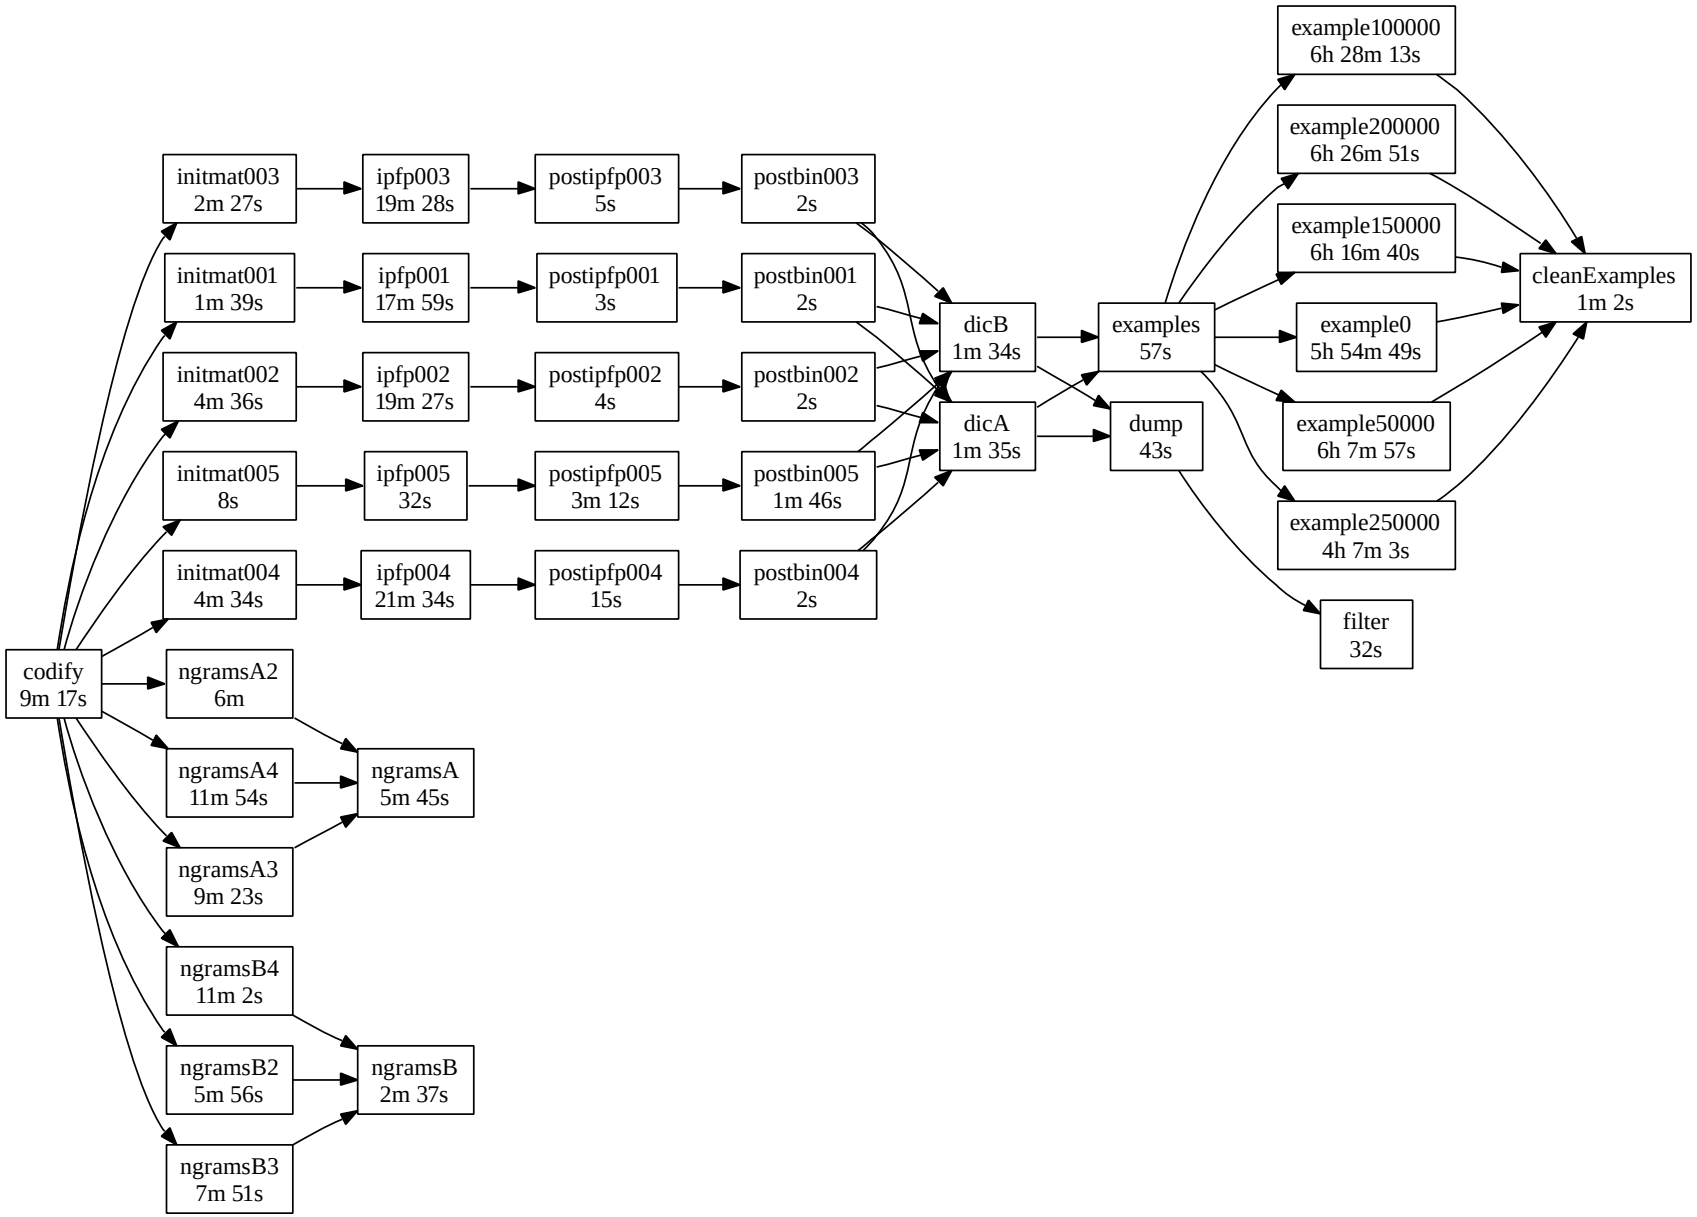

Paralelização da Extracção de Exemplos: a sério

Na verdade, os processos típicos que têm sido executados, compreendem:

- mais de 150 trabalhos (mais de 1000 para EurLex);
- mais de 25 níveis de paralelismo (mais de 100 para EurLex);
- mais de 16 milhões de exemplos extraídos;
- mais de 1 milhão de nominais;
- mais de 10 GB de informação produzida;
- tempo crítico de execução: 4h 30m
- bottleneck: acesso a disco

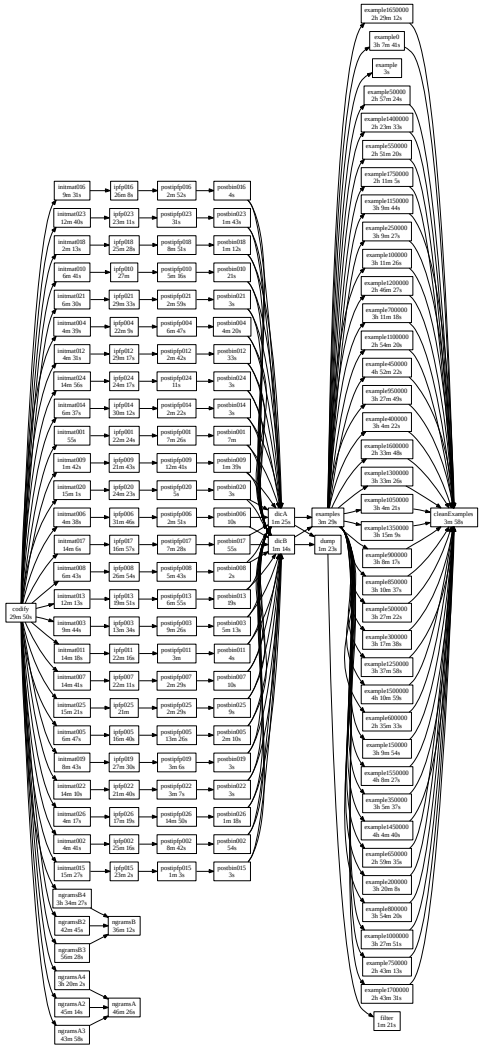

- Computação paralela...
  - não é só ao nível da instrução;
  - é simples partir processos em processos mais pequenos;
  - se estes processos mais pequenos forem independentes, pode-se tirar partido de paralelismo;
- Para despoletar processos paralelos...
  - manualmente é uma dor de cabeça;
  - escrever uma script é uma solução... para poucos processos;
  - o aumento de escala leva à necessidade de uma linguagem de especificação;
- Linguagem de especificação que...
  - é orientada ao processo;
  - é genérica (está a ser utilizada por físicos da UM);
  - suporta regras dinâmicas (paramétricas);