Programmation III

Chaine de compilation & utilitaires

Basile Schaeli
Roger D. Hersch
Laboratoire de Systèmes Périphériques (LSP)
EPFL

Contenu

- Chaine de compilation
  - Préprocesseur
  - Compilateur
  - Editeur de lien
- Utilitaires
  - Make
  - Valgrind
  - gprof
  - CVS & Subversion

Chaine de compilation

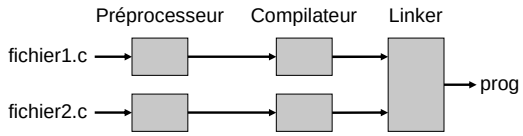

- Le préprocesseur, le compilateur et le linker (ou éditeur de liens) sont généralement des programmes séparés
  - GCC appelle à tour de rôle les programmes *cpp*, *cc1/cc1plus* et *ld*
  - Microsoft utilise *cl* (préprocesseur et compilateur) et *link* (édition de lien)

Chaine de compilation

- Il est possible de n'exécuter qu'une partie de la chaine
- Avec GCC
  - Préprocesseur seulement: *gcc –E*
  - Préprocesseur et compilateur: *gcc –c*
  - Si aucune option n'est spécifiée, l'extension du nom de fichier détermine si les phases de préprocessing et de compilation doivent être exécutées

Préprocesseur

- Transforme un fichier texte en fichier texte
  - Le préprocesseur travaille uniquement avec des chaines de caractères
- Le préprocesseur C/C++ traite les instructions commençant par #
- Le code vu par le compilateur n'est donc pas le même que le code vu par le programmeur
  - Une mauvaise utilisation d'instructions du préprocesseur sera donc généralement détectée uniquement lors de la compilation

#define

- Définit une macro, i.e. une règle de substitution de chaine de caractères

```
#define PI 3.14
```

- Une macro peut aussi prendre des arguments

```
#define PRINT(integer) printf("%d\n",integer);
int main() { int a=2; PRINT(a); }
```

- Par convention, les macros sont en MAJUSCULES
- Problèmes potentiels
  - Paramètres invalides (aucune vérification de type)
  - Pas de vérification de l'existence d'une macro
  - Certains caractères ne sont pas traités par le préprocesseur (e.g. templates)

#undef

- Permet d'effacer la définition d'une macro
- Comme une macro ne peut être redéfinie, on peut donc utiliser *#undef* pour en changer la valeur

```
#define PI 3
#undef PI
#define PI 3.14
```

- Utile lorsque certains headers définissent des macros avec des noms trop communs
  - Ex: #define max(a,b) (a<b) ? b : a
- Problèmes potentiels:
  - Définitions de valeurs différentes par différents header

#ifdef, #ifndef, #else, #endif

- Conserve certaines parties de code selon qu'une macro soit définie ou non

```
#define TEST
int main() {
#ifdef TEST
    printf("TEST is defined\n");
#else
    printf("TEST is not defined\n");
#endif
}
```

#ifdef, #ifndef, #else, #endif

- C'est aussi utilisable avec des macros

```
#include <stdio.h>
#ifdef DEBUG
#define PRINT(integer) \
   printf("%s %d: %d\n",__FILE__,__LINE__,integer);
#else
#define PRINT(integer) printf("%d\n",integer);
#endif

int main() { PRINT(4); }
```

- Affichage

```
file.c 9: 4
```

#if, #else, #endif

- Evalue une expression C simple
  - Opérateurs arithmétiques
  - Opérateurs logiques
- Conserve le code qui suit si l'expression est vraie (i.e. non nulle)

```
#if TEST==2 || TEST==3
    /* Do something */
#endif
```

#include

- Permet d'utiliser les fonctions, variables, et classes déclarées (ou prototypées) dans d'autre fichiers

```
#include <stdio.h>
#include "header.h"
```

- Le contenu du fichier à inclure est simplement copié à la place de l'instruction *#include*
  - Le compilateur peut trouver une erreur dans un fichier C alors qu'elle provient d'un fichier inclus
  - L'utilisation de l'extension .h (comme « header ») pour les fichiers contenant des déclarations n'est qu'une convention (qu'il est fortement recommandé de suivre)

<header.h> vs. *"header.h"*

- Les guillemets sont utilisés lorsque le fichier inclus est accessible depuis le répertoire courant

```
#include "path/to/header.h"
```

- Si le fichier se trouve à un emplacement connu du compilateur (i.e. dans son *path*), on peut utiliser <>

```
#include <header.h>
```

- On peut ajouter des répertoires au *path* du compilateur en utilisant l'option `-I`

```
gcc –Ipath/to –o prog prog.c
```

Inclusion en boucle
toto.h inclut tata.h qui inclut toto.h…

- Prototyper les classes et fonctions utilisées, ainsi que les méthodes qui les utilisent
  - tata.h avant:

```
#include "toto.h"
class Tata {
  public: int f(Toto& t) { t.print(); }
};
```

  - tata.h après:

```
class Toto;
class Tata { public: int f(Toto& t); };
```

- Cas extrême: utiliser pour chaque classe ou fonction un fichier en-tête et un fichier de définitions

Inclusions multiples

- Si un fichier est inclus plusieurs fois, les déclarations qu'il contient seront dupliquées

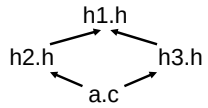

- On évite ceci en utilisant la construction suivante

```
#ifndef H1_H
#define H1_H
// Declare things
#endif
```

Compilateur

- Le compilateur transforme un fichier texte en un fichier objet contenant deux éléments
  - Les instructions correspondantes compréhensibles par un processeur (ou par une famille de processeurs)
  - Une table de symboles décrivant les différents éléments (classes, variables, fonctions) définis dans le fichier compilé
- Sources d'erreurs
  - Erreurs de syntaxe
  - Utilisation incorrectes de types
  - Utilisation de fonctions/classes non prototypées

Editeur de liens

- Crée un fichier exécutable à partir d'un ou de plusieurs fichiers objets
  - Combine les tables de symboles
  - Remplace les références aux symboles utilisés par les pointeurs correspondants
- Sources d'erreurs
  - Définition multiple de symboles (e.g. deux fichiers incluent le même header définissant une variable)
  - Symbole manquant (e.g. une fonction est prototypée mais pas implémentée)

Edition de lien

- linkerror.h

```
void f() { /* Do something */ }
```

- linkerror1.cpp

```
#include "linkerror.h"
int main() { f(); }
```

- linkerror2.cpp

```
#include "linkerror.h"
/* Some other things */
```

Edition de lien (correct)

- linkerror.h

```
void f();
```

- linkerror1.cpp

```
#include "linkerror.h"
int main() { f(); }
```

- linkerror2.cpp

```
#include "linkerror.h"
void f() { /* Do something */ }
/* Some other things */
```

Contrôler la table de symbole

- Le mot-clé *static* empêche un symbole de figurer dans la table. Celui-ci n'est donc visible qu'à l'intérieur du fichier.
  - Valable pour les variables et les fonctions
  - ATTENTION! *static* n'a pas la même signification lorsqu'il qualifie un membre d'une classe!
- Le mot-clé *extern* indique qu'un symbole est définit dans un autre fichier, et qu'aucune mémoire ne doit donc être allouée pour ce symbole
  - Utile pour les variables
  - Les prototypes de fonctions et de classes sont implicitement définis comme *extern*

static

- static.h

```
int f();
```

- static1.cpp

```
#include <stdio.h>
#include "static.h"
static int counter=0;
int main() { f(); printf("%d\n",counter); }
```

- static2.cpp

```
#include "static.h"
static int counter=0;
void f() { ++counter; }
```

static II

- static_header.h

```
static int counter=0;
void f();
```

- static_header1.cpp

```
#include <stdio.h>
#include "static_header.h"
int main() { f(); printf("%d\n",counter); }
```

- static_header2.cpp

```
#include "static_header.h"
void f() { ++counter; }
```

extern

- extern.h

```
extern int counter;
void f();
```

- extern1.cpp

```
#include <stdio.h>
#include "extern.h"
int main() { f(); printf("%d\n",counter); }
```

- extern2.cpp

```
#include "extern.h"
int counter=0;
void f() { ++counter; }
```

C vs. C++

- C
  - 1973: C
  - 1978: C K&R (Kernighan & Ritchie)
  - 1989: ANSI C
  - 1999: ISO/ANSI C99
- C++
  - 1983: C++ (Bjarne Stroustrup)
  - 1998: ISO C++
  - 200x: C++0x
- Des différences de syntaxe existent entre versions du langage
- Il est possible que le même code puisse être compilé ou non selon le compilateur (ou la version du compilateur) utilisé

C vs. C++

- On peut généralement compiler du code C avec un compilateur C++
  - La vérification de type est plus stricte en C++
  - Le C++ était une extension du C…
- En C, il est possible de lier des fichiers compilés avec différents compilateurs
  - Ce n'est pas le cas en C++
- On peut lier des fichiers C dans un programme C++
  - Utiliser des fonctions C dans un programme C++

Combiner C et C++

- Il est nécessaire d'informer le compilateur C++ qu'une fonction a été compilée avec un compilateur C
- stdlib.h

```
#ifdef __cplusplus   /* starts with two _ */
extern "C" {
#endif
double atof(const char *nptr);
#ifdef __cplusplus
}
#endif
```

Références

- GCC

http://gcc.gnu.org/onlinedocs/

- Compilateur Microsoft

http://msdn.microsoft.com/visualc/vctoolkit2003/

- Historiques et incompatibilités entre C et C++

http://www.jakeo.com/words/clanguage.php
http://en.wikipedia.org/wiki/C_programming_language
http://en.wikipedia.org/wiki/C_Plus_Plus
http://david.tribble.com/text/cdiffs.htm

Makefiles

- Automatiser la compilation de programmes
  - Ou processus de traitement de fichiers
- Le processus à automatiser est décrit par un ensemble de *règles* contenant des *instructions*
- Chaque règle peut être soumise à un ensemble de *dépendances*

```
rule: dependencies
<tab>instruction1
<tab>instruction2
```

Makefiles

- Un makefile est interprété à l'aide de la commande

```
make
```

- Make essaie d'interpréter un fichier nommé *makefile* ou *Makefile*
  - Le nom de ce fichier peut être spécifié avec *-f*
- On peut spécifier la règle à évaluer sur la ligne de commande, sinon la première règle du fichier est interprétée

```
make someRule
```

- Il y a *make* et *GNU make* (ou *gmake*)
  - On parle ici de la version GNU, mais les principes de base restent valables

Dépendances

- Les dépendances d'une règle peuvent être des fichiers, des répertoires ou d'autres règles
  - La plupart des règles ont pour but de générer un fichier portant le même nom que la règle
- Une règle est exécutée si
  - Aucun fichier ne porte le même nom que la règle
  - La règle et une dépendance correspondent à des noms de fichiers, et le fichier correspondant à la dépendance est plus récent que celui de la règle
  - Au moins une de ses dépendances est invalidée, i.e. il s'agit d'une règle qui vient d'être exécutée

Exemple

```
# Makefiles can contain arbitrary instructions
someRule: someDir
   @echo Create a dummy file
   touch someDir/dummyfile
   ls someDir

someDir:
   mkdir someDir
```

Treedictionary

- Implémentation d'un dictionaire en arbre
  - treedictionary.cpp et treedictionary.h
- Deux fonctions *main()* différentes
  - main.cpp et treedictmain.cpp
- Deux types de compilation
  - Avec et sans mesures de performances
- Quatre exécutables à générer
  - treedict et mydict
  - treedictM et mydictM

Makefile simple

```
# Build all executables
all: treedict treedictM mydict mydictM

treedict: treedictionary.cpp treedictmain.cpp treedictionary.h
    g++ -Wall -o treedict treedictionary.cpp treedictmain.cpp

mydict: treedictionary.cpp main.cpp treedictionary.h
    g++ -Wall -o mydict treedictionary.cpp main.cpp

treedictM: treedictionary.cpp treedictmain.cpp treedictionary.h timer.h
    g++ -Wall -DMEASURE_PERF -o treedictM treedictionary.cpp treedictmain.cpp

mydictM: treedictionary.cpp main.cpp treedictionary.h timer.h
    g++ -Wall -DMEASURE_PERF -o mydictM treedictionary.cpp main.cpp

clean:
    rm -f *.o treedict treedictM mydict mydictM
```

Variables

- Il est possible d'utiliser des variables
  - Affectation: *CXX=g++*
  - Utilisation: *$(CXX)*
- Noms de variables "réservés"
  - CC: compilateur C
  - CXX: compilateur C++
  - CFLAGS/CXXFLAGS: option de compilation
  - LDFLAGS: options de lien
- Make sait compiler des fichiers .c et .cpp en fichier .o en utilisant ces variables

Makefile v2

```
CXX=g++
CXXFLAGS=-Wall
EXECS=treedict treedictM mydict mydictM

all: $(EXECS)
# Specify dependency using object files built with implicit rule
treedict: treedictionary.o treedictmain.o treedictionary.h
    $(CXX) -o treedict treedictionary.o treedictmain.o
mydict: treedictionary.o main.o treedictionary.h
    $(CXX) -o mydict treedictionary.o main.o

treedictM: treedictionary.cpp treedictmain.cpp treedictionary.h timer.h
    $(CXX) $(CXXFLAGS) -DMEASURE_PERF -o treedictM treedictionary.cpp \
    treedictmain.cpp
mydictM: treedictionary.cpp main.cpp treedictionary.h timer.h
    $(CXX) $(CXXFLAGS) -DMEASURE_PERF -o mydictM treedictionary.cpp \
    main.cpp
clean:    rm -f *.o $(EXECS)
```

Variables automatiques et patterns

- Variables automatiques
  - *$@*: Nom de la règle
  - *$<*: Nom de la première dépendance
  - *$^*: Nom de toutes les dépendances
- Pattern '*%*'
  - Correspond à n'importe quelle chaine de caractères
  - La substitution est faite de la même manière dans la règle est dans les dépendances
- *%.o: %.c*
  - fichier.o dépend de fichier.c
  - Le premier et le deuxième '%' prennent la même valeur

Makefile v3

```
CXX=g++
CXXFLAGS=-Wall
EXECS=treedict treedictM mydict mydictM

all: $(EXECS)

treedict: treedictionary.o treedictmain.o
    $(CXX) -o $@ $^
mydict: treedictionary.o main.o
    $(CXX) -o $@ $^
treedictM: treedictionaryM.o treedictmainM.o
    $(CXX) -o $@ $^
mydictM: treedictionaryM.o mainM.o
    $(CXX) -o $@ $^

%.o: %.cpp treedictionary.h
    $(CXX) $(CXXFLAGS) -c -o $@ $<
%M.o: %.cpp treedictionary.h timer.h
    $(CXX) $(CXXFLAGS) –DMEASURE_PERF -c -o $@ $<
```

Génération de dépendances

- Il est possible de générer automatiquement les dépendances entre .o, .c/.cpp et .h
  - gcc –MM fichier.c
- Il suffit d'inclure le fichier contenant les dépendances, et d'ajouter une règle pour générer ce fichier

```
include depend
depend:
    $(CXX) -MM *.cpp > depend
```

Makefile générique

```
CXX=g++
CXXFLAGS=-Wall
EXEC=prog
OBJS=prog.o progmain.o

$(EXEC): $(OBJS)
    $(CXX) -o $@ $^

include depend
depend:
    $(CXX) -MM *.cpp > depend

clean:
    rm -f depend $(OBJS) $(EXEC)
```

Référence

- http://www.gnu.org/software/make/manual/

Valgrind

- Débuggeur et profiler d'utilisation mémoire
  - Utilisation de mémoire non initialisée
  - Lecture/écriture de blocs libérés (free)
  - Lecture/écriture après la fin de blocs alloués (malloc)
  - Fuites de mémoire (perte de pointeurs sur blocs alloués)
  - Graphes de consommation mémoire
- Exécution beaucoup plus lente (10x-20x)
- Consommation de mémoire beaucoup plus importante
- Linux x86 seulement

val.c

```
 1: #include <malloc.h>
 2:
 3:  int main()
 4: {
 5:     int *a=(int*)malloc(2*sizeof(int));
 6:     a[0]=0;
 7:     a[1]=1;
 8:     a[2]=2;
 9:     return 0;
10: }
```

Utiliser *valgrind*

```
% gcc -Wall -g val.c
% valgrind a.out
…
==20954==
==20954== Invalid write of size 4
==20954==    at 0x804837F: main (val.c:8)
==20954==  Address 0x1BA50030 is 0 bytes after a block of size 8 alloc'd
==20954==    at 0x1B8FEA39: malloc (vg_replace_malloc.c:149)
==20954==    by 0x804835D: main (val.c:5)
==20954==
…
==20954==
==20954== LEAK SUMMARY:
==20954==    definitely lost: 8 bytes in 1 blocks.
==20954==      possibly lost: 0 bytes in 0 blocks.
==20954==    still reachable: 0 bytes in 0 blocks.
==20954==         suppressed: 0 bytes in 0 blocks.
==20954== Use --leak-check=full to see details of leaked memory.
```

Fuites mémoire

```
% valgrind --leak-check=full --show-reachable=yes a.out
…
==20922== Invalid write of size 4
==20922==    at 0x804837F: main (val.c:8)
==20922==  Address 0x1BA50030 is 0 bytes after a block of size 8 alloc'd
==20922==    at 0x1B8FEA39: malloc (vg_replace_malloc.c:149)
==20922==    by 0x804835D: main (val.c:5)
==20922==
…
==20922==
==20922== 8 bytes in 1 blocks are definitely lost in loss record 1 of 1
==20922==    at 0x1B8FEA39: malloc (vg_replace_malloc.c:149)
==20922==    by 0x804835D: main (val.c:5)
==20922==
…
```

Utilisation mémoire

- Spécifier l'utilisation de l'outil *massif*
  - Génère un fichier texte et une image postscript

% valgrind --tool=massif lineardict list-full.txt 3 t.me
Heap allocation functions accounted for 99.9% of measured spacetime
Called from:
 99.9% : 0x8048941: main (lineardict.cpp:65)
 and 1 other insignificant place

% valgrind --tool=massif treedict list-full.txt 3 t.me
Heap allocation functions accounted for 93.2% of measured spacetime
Called from:
 93.2% : 0x8048C1E: TreeDictionary::addWord(char const*)
 (treedictionary.cpp:110)
 and 3 other insignificant places

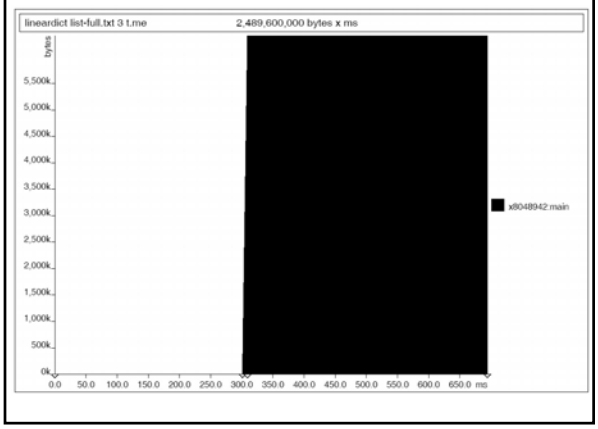

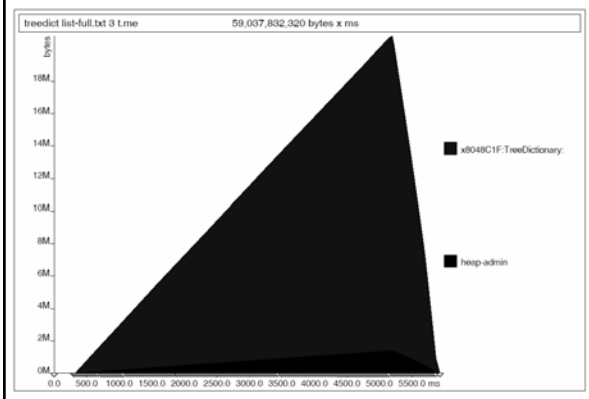

Références

- http://www.valgrind.org
- Liste des outils disponibles
  http://www.valgrind.org/info/tools.html

Optimisation de performance

- Votre programme compile et s'exécute correctement, mais il est trop lent
- Les options de compilation peuvent significativement améliorer le code généré
  - -O1, -O2, -O3
    - Différents niveaux d'optimisation
  - -march=*procname*
    - Génère du code spécifique au processeur spécifié
  - -funroll-loops
    - Essaie de dérouler les boucles (évite les sauts)

Profiling avec *gprof*

- Si les options de compilations ne suffisent pas, il est nécessaire d'analyser l'exécution du programme
  - D'où vient le problème?
  - Quelle partie faut-il optimiser?
- Un *profiler* exécute le programme et calcule le temps passé dans les différentes fonctions
- Compiler le programme avec *-pg*
  - Si vous utilisez des librairies dynamiques, ajoutez *-static* lorsque vous liez le programme
- Exécutez le programme normalement
  - Un fichier *gmon.out* est généré
- Analysez le résultat
  - *gprof progName*

lineardict

```
void matchPattern(const char *pat, const char *word, size_t patLength) {
    If(patLength!=strlen(word))
        return;
    for(size_t i=0;i<patLength;++i)
        if(pat[i]!='.' && pat[i]!=word[i])
            return;
    …
}

int main(int argc,char *argv[]) {
    …
    double st=Timer::get();
    for(int j=0;j<1000;++j)
        for(int i=0;i<wordCount*MAX_LENGTH;i+=MAX_LENGTH)
            matchPattern(argv[3],words+i,strlen(argv[3]));
    double et=Timer::get();
    std::cout << "Pattern matching time: " << et-st << " s" << std::endl;
}
```

Sortie de *gprof*

```
 %       self
time   seconds    calls   name
87.03    9.19             strlen
 8.71    0.92         1   main
 4.17    0.44  75273000   matchPattern(…)
 0.09    0.01             fgets
 0.00    0.00         2   Timer::get()
 0.00    0.00         1
             _GLOBAL__I__Z12matchPatternPKcS0_j
 0.00    0.00         1
    _static_initialization_and_destruction_0(…)
 0.00    0.00         1   __tcf_0
```

lineardict, v2

```
void matchPattern(const char *pat, const char *word, size_t patLength) {
    If(patLength!=strlen(word))
        return;
    for(size_t i=0;i<patLength;++i)
        if(pat[i]!='.' && pat[i]!=word[i])
            return;
    …
}
int main(int argc,char *argv[]) {
    …
    size_t len=strlen(argv[3]);
    double st=Timer::get();
    for(int j=0;j<1000;++j)
        for(int i=0;i<wordCount*MAX_LENGTH;i+=MAX_LENGTH)
            matchPattern(argv[3],words+i,len);
    double et=Timer::get();
    std::cout << "Pattern matching time: " << et-st << " s" << std::endl;
}
```

Sortie de *gprof*

```
 %       self
time   seconds    calls   name
82.99    4.88             strlen
 9.61    0.56  75273000   matchPattern(…)
 7.06    0.41         1   main
 0.17    0.01             memcpy
 0.17    0.01             strtok
 0.00    0.00         2   Timer::get()
 0.00    0.00         1
             _GLOBAL__I__Z12matchPatternPKcS0_j
 0.00    0.00         1
    _static_initialization_and_destruction_0(…)
 0.00    0.00         1   __tcf_0
```

Méthode d'échantillonage

- Toutes les 10 ms, *gprof* regarde quelle fonction est en cours d'exécution et construit un histogramme
  - Deux exécutions peuvent donner des résultats différents pour des fonctions très courtes
  - Les profils obtenus sur un programme dont l'exécution est très courte ne sont pas fiables
- Fondamentalement, est-il utile d'optimiser un programme lorsque son exécution est très courte?

Références

- Pense-bête

http://www.cs.duke.edu/~ola/courses/programming/gprof.html

- Exemple d'utilisation

http://www.tldp.org/linuxfocus/Francais/March2005/article371.shtml

- Manuel de référence

http://www.gnu.org/software/binutils/manual/gprof-2.9.1/gprof.html

CVS et Subversion

- Permettent à plusieurs utilisateurs de travailler simultanément sur les mêmes fichiers
  - Peut aussi être utile pour une personne travaillant avec plusieurs ordinateurs
- Contrôle de révisions

- Architecture clients-serveur (connectionless)
  - On crée un dépôt (repository) sur le serveur dans lequel on place les fichiers du projet
  - Chaque utilisateur récupère une copie des fichiers (checkout)
  - Après modifications, on stocke les changements sur le serveur (commit)
    - Les modifications sont stockées sous forme de différences
  - On met à jour sa copie locale avec les modifications des autres utilisateurs (update)

Références

- CVS (le standard)
  - http://www.nongnu.org/cvs/
  - http://ximbiot.com/cvs/manual/
  - http://www.tortoisecvs.org/ (Client Windows)
  - http://www.wincvs.org/ (Liste de clients et utilitaires)
- Subversion (le challenger)
  - http://subversion.tigris.org/
  - http://svnbook.red-bean.com/
  - http://tortoisesvn.tigris.org/ (Client Windows)
  - http://esvn.umputun.com/ (Client multiplateformes)