

TME2 : Langage C: étude de cas sur les tables de hachage

1. Objectif
2. Travail demandé
3. Evolution du programme
4. Description des sources fournies
5. Questions
 1. Le processus de construction : Makefile
 2. le programme principal : main
 3. Les fonctions de bases de la tables de hachage
 4. Le service *dejavu*
 5. Le service *dictionnaire*
 6. Le service allocateur de nom

Objectif

Pour la majorité d'entre-vous, vous connaissez déjà le C, mais certains ne le connaissent que superficiellement. Nous devons essayer de mettre tout le monde au niveau, en vous faisant étudier un petit programme. L'objectif de ce programme est double :

1. Il doit d'une part vous permettre de faire une auto-évaluation de vos connaissances des outils de développement C en vous posant des questions auxquelles vous devriez savoir répondre. Si ce n'est pas le cas, vous **devez** trouver les réponses dans les documentations (man, web), ou auprès de vos camarades.
2. Il vous offre un modèle de programme, avec makefile et man pour vos futurs développements.

Pour réaliser une application en C, vous devez savoir:

- Ecrire un programme C en respectant des conventions d'écriture.
- Compiler en plusieurs fichiers objet et en constituant une librairie.
- Décrire un makefile.
- Debugger en utilisant gdb ou xgdb.
- Faire des mesures de performances avec gprof.
- Ecrire un man sur l'outil.

Travail demandé

- Vous devez commencer par copier sur votre compte le répertoire :

```
cp -rp /users/enseig/encadr/cao/tme2 ~/cao/tme2
```

- Ce répertoire contient un programme utilisant une table de hachage.
- Le travail consiste:
 1. à répondre aux questions portant sur le code fourni. Les questions sont sur cette page. Vous rédigerez un compte rendu informatique pour vous même avec les réponses.
 2. à programmer des évolutions du programme:
- L'évaluation sera individuelle et orale au début du tme3.
- Commencez par lire le programme en entier et faites le tourner pour comprendre son fonctionnement.
- Répondez ensuite aux questions et faites les évolutions demandées.

Evolution du programme

Le programme fourni compte le nombre de mots d'un fichier texte et indique le nombre de mots présents et le nombre de mots différents. Votre programme devra indiquer pour chaque mot:

- le nombre d'occurrences
- les numéros de lignes où il est présent

Vous donnerez également des statistiques sur l'usage des tables de hachage:

- taux de remplissage.
- moyenne du nombre de comparaisons nécessaire lors de la recherche d'un mot

Description des sources fournies

- Makefile description du processus de construction de l'exécutable.
- main.c, main.h programme principal source et déclaration.
- count.c, count.h algorithme de parcours d'un fichier texte en vue de comptage.
- hte.c, hte.h fonction de création des tables de hachage et déclaration de toutes fonctions de gestion.
- dico.c, dejavu.c, namealloc.c .. fonctions de gestion des tables pour trois types d'usage
- man1/tool.1 fichier au format man

Questions

Le processus de construction : Makefile

1. Completez la liste des dépendances pour les cibles : `main.o ... namealloc.o`.
2. Réécrivez les commandes en utilisant les variables automatiques : `$(@) $< $^`
 - ♦ `$(@)` : désigne la cible d'une règle.
 - ♦ `$<` : désigne le premier fichier de la liste des sources d'une règle.
 - ♦ `$^` : désigne la liste des sources d'une règle.
3. Donnez une raison à la définition des commandes et paramètres au début du Makefile
4. A quoi servent les options `-p`, `-g`, `-Wall`, `-Werror`, `-ansi` ?
5. Comment demander l'optimisation maximale du compilateur ?
6. L'option `-p` est présente dans `LD_FLAGS` et `C_FLAGS`, pourquoi n'est-ce pas le cas de `-g` ?
7. Que fait la règle `indent` ? quelle est la signification des flags utilisés par le programme `indent` ?

Fichier Makefile

```
# Definition des commandes
CC      = gcc
AR      = ar
RM      = rm
INDENT  = indent

# Definition des parametres
LD_FLAGS = -p
C_FLAGS  = -g -p -Wall -ansi -Werror
AR_FLAGS = -r
ID_FLAGS = -gnu -bli0 -npsl -l90
```

```
# Definition de la liste des librairies necesaires a l'edition de lien
LDLIBS = -L. -lhte

.PHONY: all clean realclean

stat : main.o count.o libhte.a
      $(CC) $(LDFLAGS) main.o count.o -o stat $(LDLIBS)

libhte.a : hte.o dico.o dejavu.o namealloc.o
      $(AR) $(ARFLAGS) libhte.a hte.o dico.o dejavu.o namealloc.o

main.o:
count.o:
hte.o:
dejavu.o:
namealloc.o:

all: clean stat

clean:
      $(RM) *.o *.a *.out *~ 2> /dev/null || true

realclean: clean
      $(RM) stat 2> /dev/null || true

indent:
      $(INDENT) $(IDFLAGS) *.c *.h
```

le programme principal : main

- A quoi servent les lignes 1, 2 et 11 ?
- Pourquoi inclure `stdio.h` ici ?

Fichier main.h

```
#ifndef _MAIN_H_
#define _MAIN_H_

#include <stdio.h>

struct mainarg_s
{
    FILE *INFILE;
    FILE *OUTPUTFILE;
    char VERBOSE;
};
extern struct mainarg_s MAINARG;

#endif
```

1. A quoi sert chaque include ?
2. Pourquoi a-t-on un fichier main.h ?
3. Expliquez le fonctionnement de la fonction `getopt` (`man 3 getopt`)
Ajoutez l'option `-h` qui affiche l'usage du programme et un petit texte de description du comportement (très court, c'est juste pour l'exercice).
Vous ajouterez plus tard l'option `-s` qui demande les statistiques d'usage de la tables de hachage.
4. A quoi sert l'appel de `return` a la fin de la fonction `main()` ?
5. Pourquoi y-a-t-il `exit()` a la fin de la fonction `usage()` ?
6. Qu'est ce qu'un appel `systeme`, en voyez-vous dans ce fichier, si oui lesquels, citez en d'autres,
7. Quelle precaution doit on prendre lors de leur utilisation ?

8. Ou sont definiies les fonctions standards ?
9. Qu'est-ce qu'un filtre unix ?
10. Que faut-il faire pour transformer ce programme en filtre ?

Fichier main.c

```

include <stdlib.h>
#include <stdio.h>
#include <getopt.h>
#include "main.h"
#include "count.h"
#include "hte.h"

struct mainarg_s MAINARG;

void usage (char *command)
{
    printf ("\nStatistique Diverses\n");
    printf ("Usage   : %s [-v] [-o OutFile] InFile\n", command);
    printf ("-v           verbose mode\n");
    printf ("-o OutFile   output file (stdout by default)\n\n");
    exit (EXIT_FAILURE);
}

void getarg (int argc, char **argv)
{
    extern char *optarg;
    extern int optind;
    char option;

    MAINARG.OUTPUTFILE = NULL;
    while ((option = getopt (argc, argv, "vo:")) != EOF)
        switch (option)
        {
            case 'v':
                MAINARG.VERBOSE = 1;
                fprintf (stderr, "Verbose mode\n");
                break;

            case 'o':
                if (MAINARG.VERBOSE)
                    fprintf (stderr, "Fichier de sortie : %s\n", optarg);

                MAINARG.OUTPUTFILE = fopen (optarg, "w");
                if (MAINARG.OUTPUTFILE == NULL)
                {
                    fprintf (stderr, "%s: %s: \n", argv[0], optarg);
                    perror ("fopen");
                    exit (EXIT_FAILURE);
                }
                break;

            case '?':
            default:
                usage (argv[0]);
        }
    if ((optind + 1) != argc)
    {
        usage (argv[0]);
    }
    else
    {
        if (MAINARG.VERBOSE)
            fprintf (stderr, "Fichier d'entr e : %s\n", argv[optind]);
    }
}

```

```

    MAINARG.INFILE = fopen (argv[optind], "r");
    if (MAINARG.INFILE == NULL)
    {
        fprintf (stderr, "%s: %s ", argv[0], argv[optind]);
        perror ("fopen");
        exit (EXIT_FAILURE);
    }
    if (MAINARG.OUTPUTFILE == NULL)
        MAINARG.OUTPUTFILE = stdout;
}

int main (int argc, char **argv)
{
    getarg (argc, argv);
    count (MAINARG.INFILE);
    fclose (MAINARG.OUTPUTFILE);
    return EXIT_SUCCESS;
}

```

Les fonctions de bases de la tables de hachage

1. Les types `hte_item_t` et `hte_data_t` sont des structures dont le contenu n'est pas défini ici. Leur contenu n'est pas défini non plus dans le fichier `hte.c`, en revanche il est défini dans les fichiers `dico.c`, `dejavu.c` et `namealloc.c`. Quelle est alors la contrainte d'usage de ces types dans le fichier `hte.c`? Quel est l'intérêt de cette écriture?
2. Dans la définition des prototypes de fonctions, le nom des paramètre est-il nécessaire? si non pour les mettre?

Fichier `hte.h`

```

#ifndef _HTE_H_
#define _HTE_H_

#include <stdlib.h>

/*
 * Les deux structures ci-dessous ne sont pas définies ici
 * elles seront redéfinies dans chaque fichier
 */
typedef struct hte_item_s hte_item_t;
typedef struct hte_data_s hte_data_t;

/*
 * structure définissant la table de hachage
 * On y trouve le nombre de liste de liste et
 * un pointeur vers le tableau de liste
 */
typedef struct hte_root_s
{
    size_t NB_LIST; /* nombre de liste d'ITEM du dictionnaire */
    hte_item_t **LIST; /* pointeur sur un tableau de liste d'ITEM */
} hte_root_t;

/*
 * Calcul de l'index de hachage de Donald Knuth
 * Elle produit un nombre entier à partir d'une chaîne de caractères.
 */
extern unsigned hte_hash (char *key);

/*

```

```

* hte_create fabrique une table de hachage vide
* parametres:
*     nb_item = nombre d'item maximum prévu dans la table de hachage
*/
extern hte_root_t *hte_create (size_t nb_item);

/*
* hte_add ajoute l'item (key,data)
* parametres:
*     root = pointeur sur la table de hachage
*     key  = pointeur sur une chaine de caractères (la clé)
*     data = donnée associée à key
* comportement:
*     La clé key passée en parametre est comparée à celles présentes dans
*     la table. Si la clé n'est pas trouvée alors un nouvel item est créé
*     avec le couple (key,data). La clé key est en fait duppliquée.
*     Si la clé est trouvée, le champ DATA de l'item présent dans la
*     table est remplacé par le paramètre data de la fonction.
* retour:
*     Si l'item n'a pu etre créé faute d'espace, on sort du programme.
*/
extern void hte_add (hte_root_t * root, char *key, hte_data_t * data);

/*
* hte_get recherche item, et en cas d'absence l'ajoute
* parametres:
*     root = pointeur pour la table de hachage
*     key  = pointeur sur une chaine de caractères (la clé)
* comportement:
*     La clé passée en parametre est comparé a celles présentes dans la
*     table de hachage.
* retour:
*     Si la clé est trouvée alors la fonction retourne le champ data
*     sinon la fonction rend NULL.
*/
extern hte_data_t *hte_get (hte_root_t * root, char *key);

/*
* namealloc permet de garantir l'unicité des chaines de caractères
* parametres:
*     name = chaine de caractères
* comportement:
*     name est recherché dans la table,
*     s'il est absent on ajoute une copie de name dans la table
* retour:
*     un pointeur sur la copie de la table
*/
char *namealloc (char *name);

/* nombre maximum de noms dans la table */
#define MAX_NAMEALLOC 1000

/*
* dejavu permet de savoir si un nom a déjà été vu
* parametres:
*     name = chaine de caractères
* comportement:
*     name est recherché dans la table,
*     s'il est absent on ajoute une copie de name dans la table
* retour:
*     rend 1 s'il était déjà présent sinon 0
*/
unsigned dejavu (char *name);

/* nombre maximum de noms dans la table */

```

```
#define MAX_DEJAVU 1000

#endif
```

Fichier hte.c

1. Faîte un dessin représentatif de la valeur de la variable locale `root` de la fonction `hte_create` si `nb_list==10` juste avant l'appel `return`.
2. La fonction `hte_hash` peut-elle provoquer une erreur de segment ? Comment y remédier proprement ?
3. Dans la fonction `hte_create` comment fait-on pour tester le retour de `malloc` ? à quoi cela sert-il ?

```
#include <stdio.h>
#include <string.h>
#include <stdlib.h>
#include "hte.h"

/*
 * Calcul de l'index de hachage de Donald Knuth
 * Elle produit un nombre entier à partir d'une chaîne de caractères.
 */
unsigned hte_hash (char *key)
{
    char *c = key;
    unsigned h;
    for (h = 0; *c; c++)
    {
        h += (h ^ (h >> 1)) + 314159 * (unsigned char) *c;
        while (h >= 516595003)
            h -= 516595003;
    }
    return h;
}

/*
 * Création d'un dictionnaire vide
 */
hte_root_t *hte_create (size_t nb_item)
{
    hte_root_t *root;
    unsigned i, nb_list;
    static unsigned primes[] = { /*suite croissante de nombres premiers */
        101, 149, 223, 347, 499, 727, 1163, 1697, 2503, 3989, 5839, 8543,
        12503, 20143, 29483, 43151, 63179, 92503, 101747, 148961, 218107,
        319313, 514243, 752891, 1212551, 1613873, 2599153, 3805463,
        5571523, 8157241, 11943011, -1
    };

    /* détermination de la taille réelle du dictionnaire */
    for (i = 0; primes[i] < nb_item; i++);
    nb_list = primes[i];
    if (nb_item != -1)
    {
        /* allocation et initialisation du dictionnaire */
        if ((root = malloc (sizeof (hte_root_t))))
        {
            root->NB_LIST = nb_list;
            if ((root->LIST = calloc (nb_list, sizeof (hte_item_t *))))
                return root;
        }
    }
    fprintf (stderr, "hte_create: not enough memory\n");
    exit (1);
}
```

Le service *dejavu*

1. Pourquoi définit on la structure `hte_item_s` ici ?
2. La variable `root_namealloc` est `static`. Qu'est-ce que cela veut dire ?
3. Donner les autres usages du mots clé `static` en langage C.
4. A quoi sert la fonction `perror` ?

Fichier `dejavu.c`

```
#include "hte.h"
#include <stdio.h>
#include <string.h>
#include <stdlib.h>

/*
 * structure définissant un item du dictionnaire
 * Un item est formé d'un couple (clé,valeur) plus un pointeur
 * permettant de chainer les items ayant le meme index de hachage
 */
struct hte_item_s
{
    struct hte_item_s *NEXT;    /* pointeur sur l'item suivant */
    char KEY[];                /* tableau flexible contenant la clé */
};

unsigned dejavu (char *key)
{
    unsigned index;
    hte_item_t *curr;
    static hte_root_t *root_namealloc;

    if (key)
    {
        /* création du dictionnaire la première fois */
        if (root_namealloc == NULL)
            root_namealloc = hte_create (MAX_NAMEALLOC);

        /* calcul de l'index pour trouver la liste ou devrait être l'item */
        index = hte_hash (key) % root_namealloc->NB_LIST;

        /* recherche et l'item dans sa liste et sortie si trouvé */
        for (curr = root_namealloc->LIST[index]; curr; curr = curr->NEXT)
            if (strcmp (curr->KEY, key) == 0)
                return 1;

        /* création d'une nouvelle entrée */
        curr = malloc (sizeof (struct hte_item_t *) + strlen (key) + 1);
        if (curr)
        {
            strcpy (curr->KEY, key);
            curr->NEXT = root_namealloc->LIST[index];
            root_namealloc->LIST[index] = curr;
            return 0;
        }
    }
    perror ("dejavu");
    exit (1);
}
```


Le service *dictionnaire*

Fichier dico.c

```
#include <stdio.h>
#include <string.h>
#include <stdlib.h>
#include "hte.h"

/*
 * structure définissant un item du dictionnaire
 * Un item est formé d'un couple (clé,valeur) plus un pointeur
 * permettant de chainer les items ayant le meme index de hachage
 */
struct hte_item_s
{
    struct hte_item_s *NEXT;    /* pointeur sur l'item suivant */
    hte_data_t *DATA;          /* valeur associée à l'item */
    char KEY[];                 /* tableau flexible contenant la clé */
};

/*
 * Recherche d'un item de clé key dans le dictionnaire root
 */
hte_data_t *hte_get (hte_root_t * root, char *key)
{
    int index;
    hte_item_t *curr;

    if (key)
    {
        /* calcul de l'index pour trouver la liste ou devrait être l'item */
        index = hte_hash (key) % root->NB_LIST;

        /* recherche et l'item dans sa liste et sortie si trouvé */
        for (curr = root->LIST[index]; curr; curr = curr->NEXT)
            if (strcmp (key, curr->KEY) == 0)
                return curr->DATA;

        return NULL;
    }
    perror ("hte_get");
    exit (1);
}

/*
 * Recherche d'un item de clé key dans le dictionnaire root
 * avec création en cas d'absence
 * et affectation d'une nouvelle donnée data
 */
void hte_add (hte_root_t * root, char *key, hte_data_t * data)
{
    int index;
    hte_item_t *curr;

    if (key)
    {
        /* calcul de l'index pour trouver la liste ou devrait être l'item */
        index = hte_hash (key) % root->NB_LIST;

        /* recherche et l'item dans sa liste et sortie si trouvé */
        for (curr = root->LIST[index]; curr; curr = curr->NEXT)
        {
            if (strcmp (curr->KEY, key) == 0)
```

```

        {
            curr->DATA = data;
            return;
        }
    }

    /* création d'une nouvelle entrée */
    curr = malloc (sizeof (struct hte_item_t *) + sizeof (void *) + strlen (key) + 1);
    if (curr)
    {
        strcpy (curr->KEY, key);
        curr->NEXT = root->LIST[index];
        root->LIST[index] = curr;
        curr->DATA = data;
        return;
    }
}
perror ("hte_add");
exit (1);
}

```

Le service allocateur de nom

Fichier namealloc.c

```

#include "hte.h"
#include <stdio.h>
#include <string.h>
#include <stdlib.h>

/*
 * structure définissant un item du dictionnaire
 * Un item est formé d'un couple (clé,valeur) plus un pointeur
 * permettant de chaîner les items ayant le meme index de hachage
 */
struct hte_item_s
{
    struct hte_item_s *NEXT;    /* pointeur sur l'item suivant */
    char KEY[];                /* tableau flexible contenant la clé */
};

char *namealloc (char *key)
{
    int index;
    hte_item_t *curr;
    static hte_root_t *root_namealloc;

    if (key)
    {
        /* création du dictionnaire la première fois */
        if (root_namealloc == NULL)
            root_namealloc = hte_create (MAX_NAMEALLOC);

        /* calcul de l'index pour trouver la liste ou devrait être l'item */
        index = hte_hash (key) % root_namealloc->NB_LIST;

        /* recherche et l'item dans sa liste et sortie si trouvé */
        for (curr = root_namealloc->LIST[index]; curr; curr = curr->NEXT)
        {
            if (strcmp (curr->KEY, key) == 0)
                return curr->KEY;
        }

        /* création d'une nouvelle entrée */
    }
}

```

```

curr = malloc (sizeof (struct hte_item_t *) + strlen (key) + 1);
if (curr)
{
    strcpy (curr->KEY, key);
    curr->NEXT = root_namealloc->LIST[index];
    root_namealloc->LIST[index] = curr;
    return curr->KEY;
}
}
perror ("namealloc");
exit (1);
}

```