

Projet de Compilation

Licence d'informatique

—2025-2026—

Le but du projet est d'écrire un compilateur en langage C.

Le langage source est un petit langage de programmation appelé TPC, qui est presque un sous-ensemble du langage C.

Le langage cible est l'assembleur **nasm** dans sa syntaxe pour Unix (option de compilation **-f elf64**) et avec les conventions d'appel AMD 64.

Vous vérifierez le résultat de la compilation de vos jeux d'essais en exécutant le code **nasm** obtenu.

Le projet est à faire en binôme ou seul. Vous pouvez vous choisir un binôme librement dans n'importe quel groupe. Si vous n'en avez pas trouvé, vous pouvez contacter Eric Laporte. Chaque binôme réutilisera son projet d'analyse syntaxique du premier semestre en **flex** et **bison** et pourra le modifier ⁽¹⁾.

La date limite de rendu est le 24 mai 2026 à 18 h.

1 Définition du langage source TPC

La syntaxe du TPC est celle du projet d'analyse syntaxique de 2025-2026, y compris l'extension autorisant les types structures.

En cas d'erreur lexicale ou syntaxique, on ne demande pas que le compilateur redémarre après l'erreur.

Votre compilateur doit aussi détecter les erreurs sémantiques. La sémantique des expressions et instructions du langage est la sémantique habituelle en langage C, sauf indication contraire. Dans le cas d'une erreur sémantique, votre compilateur doit émettre un message d'erreur, puis s'arrêter ou continuer la compilation, ce choix est libre.

1.1 Identificateurs

Comme en C, tout identificateur utilisé comme variable ou paramètre ou dans un nom de type structure doit être déclaré avant son utilisation et dans la partie de déclaration appropriée.

Comme en C, une variable globale et une fonction ne peuvent pas avoir le même nom, et deux fonctions non plus.

Comme en C, une variable locale et un paramètre d'une même fonction ne peuvent pas avoir le même nom.

Une variable globale ne peut être déclarée qu'une fois ⁽²⁾.

Le nom d'un type structure est de la forme **struct** <identificateur>, donc cet identificateur peut être le même qu'un nom de variable, de paramètre ou de fonction (même si ce n'est pas une bonne pratique du point de vue de la lisibilité du code).

1.2 Fonctions

Tout programme doit comporter la fonction particulière **main** par laquelle commence l'exécution et qui renvoie obligatoirement un **int**.

(1). Si vous avez déjà validé Analyse syntaxique une autre année, mais pas Compilation, vous devez quand même faire le projet d'analyse syntaxique (on ne peut pas faire de compilateur sans analyseur syntaxique).

(2). En C, une variable globale peut être déclarée plusieurs fois dans le même fichier, pourvu que ce soit avec le même type et qu'elle ne soit initialisée qu'une fois.

L'utilisation des instructions **return** doit être conforme au type de retour de la fonction dans laquelle elles apparaissent. Un appel de fonction ne peut pas être utilisé comme expression si le type de retour de la fonction appelée est **void**.

Les arguments d'une fonction sont transmis par valeur. Les fonctions récursives directes et indirectes sont autorisées.

Le langage C n'impose pas que toute exécution d'une fonction passe par une instruction **return** ⁽³⁾. Le langage TPC non plus, donc on ne demande pas que votre compilateur le vérifie. Mais si votre compilateur émet un avertissement s'il arrive à détecter que ce n'est pas le cas, ce n'est pas un défaut du compilateur.

Les fonctions **getchar()** et **getint()** permettent de lire un caractère et un entier en notation décimale saisis au clavier par l'utilisateur. Elles renvoient le caractère ou l'entier comme valeur de retour. **getint()** doit accepter (et consommer) une suite de chiffres, éventuellement précédée d'un signe plus ou moins, et suivie directement d'un saut de ligne. On ne demande pas que **getint()** saute les caractères blancs : si le premier caractère lu n'est pas un chiffre ni un signe moins ni plus, ou que les chiffres ne sont pas suivis d'un saut de ligne, **getint()** doit terminer l'exécution du programme et le programme doit renvoyer le code de retour 5, qui code une erreur d'entrées-sorties.

Les fonctions **putchar()** et **putint()** permettent d'afficher sur la sortie standard un caractère et un entier passés en paramètre. L'entier est affiché en notation décimale et suivi d'un saut de ligne. Les fonctions **putchar()** et **putint()** ne renvoient pas de valeur. Le compilateur écrira ces fonctions directement en **nasm**, et le code **tpc** ne pourra pas les redéfinir.

1.3 Types

Le typage des expressions est à peu près comme en C :

- Le type **int** doit pouvoir représenter les entiers signés codés sur 4 octets.
- Toute expression de type **char** à laquelle on applique une opération est implicitement convertie en **int**. Par exemple, si **count** est de type **int**, **count='a'** est correct et ne doit pas provoquer d'avertissement.
- Toute expression peut être interprétée comme booléenne, avec la convention que 0 représente "faux" et tout autre valeur "vrai", et le résultat de toute opération booléenne est de type **int**. En particulier, l'opérateur de négation produit comme résultat 1 quand on l'applique à 0.
- Si on affecte une expression de type **int** à une LValue de type **char**, le compilateur doit émettre un avertissement (*warning*) mais produire un programme cible fonctionnel. Par exemple, si **my_char** est de type **char**, **my_char=97** doit provoquer un avertissement.
- Dans les appels de fonctions, on considère que chaque paramètre effectif correspond à une affectation pour ce qui concerne le typage ; l'instruction **return Exp** est aussi considérée comme une affectation. Par exemple, dans une fonction qui renvoie un **int**, **return 'a'** est correct, mais dans une fonction qui renvoie un **char**, **return 97** doit provoquer un avertissement.

2 Spécifications

2.1 Travail demandé

On demande :

- un compilateur qui détecte les erreurs lexicales et syntaxiques, et émet des messages d'erreur lexicales ou syntaxiques qui donneront le numéro de ligne, et le numéro dans la ligne d'un caractère proche de l'erreur,
- les erreurs sémantiques, avec des messages d'erreur sémantique qui donneront le numéro de ligne ;

(3). Même si la fonction a un type de retour non vide.

- les avertissements, avec le numéro de ligne ;⁽⁴⁾
- quatre jeux d’essais :
 - un pour les programmes TPC corrects sans avertissements,
 - un pour les programmes avec des erreurs lexicales ou syntaxiques,
 - un pour les programmes avec des erreurs sémantiques,
 - un pour les programmes TPC corrects avec des avertissements ;
- un script de déploiement des tests, qui produit un rapport unique donnant les résultats de tous les tests et quatre scores globaux, un pour chacun des quatre jeux d’essais listés ci-dessus (nous utilisons nos propres jeux d’essais pour l’évaluation) ;
- la génération du code cible en `nasm`, y compris si le programme utilise des variables de type structure et contient plusieurs fonctions et des appels de fonctions ;
- un rapport sur vos choix et les difficultés que vous avez rencontrées.

2.2 Organisation

Nous vous demandons de respecter l’organisation suivante. *Pour évaluer vos projets, nous supposons que vous l’aurez fait.* Le répertoire que vous déposerez doit s’appeler `ProjetCompilationL3_NOM1_NOM2`, contenir à la racine un `makefile` nommé `makefile` et au moins les 5 sous-répertoires suivants :

- `src` pour les fichiers sources écrits par les humains,
- `bin` pour le fichier binaire (votre compilateur doit être nommé `tpcc`),
- `obj` pour les fichiers intermédiaires entre les sources et le binaire,
- `rep` pour votre rapport,
- `test` pour les jeux d’essais, avec des sous-répertoires :
 - `good`
 - `syn-err`
 - `sem-err`
 - `warn`

Votre compilateur doit avoir l’interface utilisateur suivante.

- Ligne de commande :
 - on doit au moins pouvoir lancer le compilateur par `./tpcc [OPTIONS]` (dans ce cas, la bonne façon de donner le fichier d’entrée TPC en ligne de commande est de faire une redirection par `<`) ; *pour évaluer vos projets, nous lançons des tests automatiques qui utilisent cette commande* ;
 - vous pouvez aussi implémenter, en plus, la ligne de commande `./tpcc [OPTIONS] FILE.tpc`
- Options⁽⁵⁾ : au moins
 - `-t, --tree` affiche l’arbre abstrait sur la sortie standard
 - `-h, --help` affiche une description de l’interface utilisateur et termine l’exécution
 - `-s, --syntabs` affiche toutes les tables des symboles sur la sortie standard ;
- Valeur de retour :
 - 0 si le programme source ne contient aucune erreur (même s’il y a des avertissements)
 - 1 s’il contient une erreur lexicale ou syntaxique⁽⁶⁾
 - 2 s’il contient une erreur sémantique⁽⁷⁾
 - 3 ou plus pour les autres sortes d’erreurs : ligne de commande, fonctionnalité non implémentée,

(4). La division par 0 est une erreur à l’exécution : normalement elle ne concerne pas le compilateur, qui en général ne peut pas connaître la valeur de `y` dans une expression `x/y`. On ne demande donc pas que votre compilateur vérifie si les dénominateurs sont nuls. Mais si votre compilateur émet un avertissement dans un cas où il le détecte, ce n’est pas un défaut du compilateur.

(5). Pour analyser la ligne de commande vous pouvez utiliser la fonction `getopt()`.

(6). Si votre compilateur redémarre après une ou plusieurs erreurs et qu’ensuite l’exécution se termine normalement, il devra renvoyer un code 1 dans le cas d’erreurs lexicales ou syntaxiques.

(7). Si votre compilateur redémarre après une ou plusieurs erreurs et qu’ensuite l’exécution se termine normalement, ou qu’il détecte une erreur sémantique avant une erreur lexicale ou syntaxique, il devra renvoyer un code 1 ou 2 correspondant à au moins une des erreurs détectées.

mémoire insuffisante...

Quand nous évaluerons votre projet, nos tests automatiques enregistreront chaque valeur de retour, et votre compilateur gagnera des points s'il renvoie les bonnes valeurs.

— Fichier cible :

- si la ligne de commande ne donne pas de nom de fichier d'entrée (`./tpcc [OPTIONS] < FILE.tpc`), le compilateur lit sur l'entrée standard et par défaut le nom du fichier cible est `_anonymous.asm`
- si la ligne de commande donne le nom d'un fichier d'entrée `FILE.tpc` (exemple : `./tpcc [OPTIONS] FILE.tpc`), par défaut le nom du fichier cible est `FILE.asm`.

2.3 Modifications de la grammaire

En plus d'autoriser les types structures, vous pouvez modifier la grammaire fournie, par exemple pour lever des conflits d'analyse ou pour faciliter la traduction, mais vos modifications ne doivent pas changer le langage engendré.

2.4 Nommage et dépôt

Déposez votre projet sur la plateforme e-learning dans la zone prévue à cet effet, sous la forme d'une archive tar compressée nommée `ProjetCompilationL3_NOM1_NOM2.tar.gz`, qui, au désarchivage, crée un répertoire contenant le projet. L'utilisation du bac à sable ne dépose pas votre projet et ne vous dispense pas de le déposer vous-même.

3 Évaluation

Comme pour le projet d'analyse syntaxique, l'évaluation du projet de compilation comporte une évaluation automatique et une évaluation manuelle. Le barème est donné ici à titre indicatif.

L'évaluation automatique (8 points) reprend les tests du projet d'analyse syntaxique et y ajoute des tests sur la détection d'erreurs sémantiques. Ces tests sont orthogonaux autant que possible afin qu'une erreur ne soit pénalisée qu'à sa juste valeur. Sauf exception, les résultats représentent votre avancée dans l'implantation des fonctionnalités demandés.

Seront évalués manuellement :

- la production de code assembleur (3 points)
- l'arbre abstrait et les tables de symboles (3 points)
- les messages d'avertissement et d'erreur (2 points)
- l'organisation, votre rapport et votre banc de tests (4 points)

Il est essentiel que l'interface de votre programme respecte les consignes données ci-dessus dans la partie 2, et notamment qu'il fonctionne par défaut en analysant son entrée standard. Ainsi doivent par exemple fonctionner :

```
$ ./tpcc < ../tests/good/09-init-simple.tpc
$ cd ..
$ cat tests/sem-err/12-double-declaration.tpc | bin/tpcc
```

Bon travail !