

# Chamelon: un minimiseur de programmes pour et en OCaml !

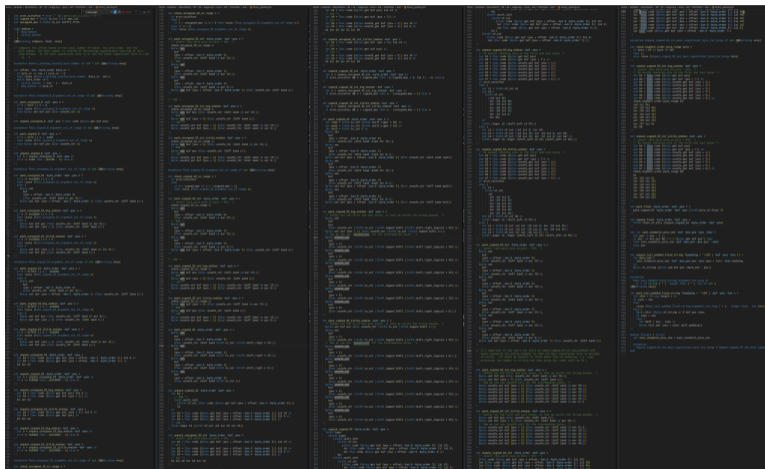
Milla Valnet<sup>1,2,3</sup>,

Nathanaëlle Courant<sup>3</sup>, Guillaume Bury<sup>3</sup>, Pierre Chambart<sup>3</sup>, Vincent Laviro<sup>3</sup>

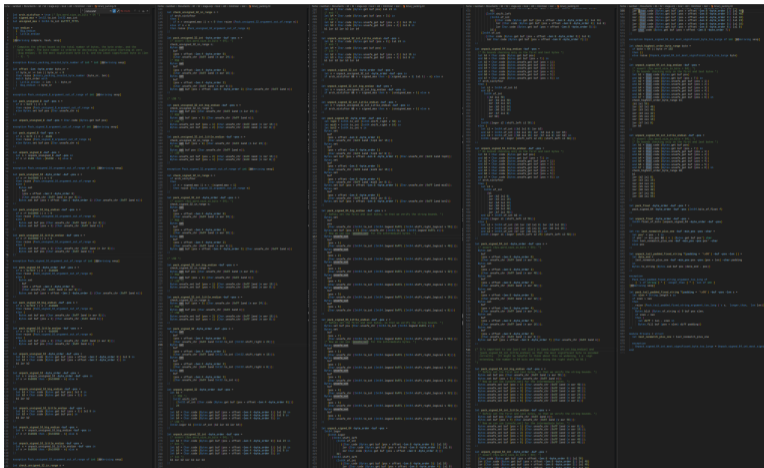
<sup>1</sup>ENS Ulm, <sup>2</sup>Sorbonne Université, <sup>3</sup>OCamlPro

JFLA 2024

# Motivation



# Motivation



Misc.fatal\_error

# Motivation : pour les compilateurs, mais pas seulement !

- ▶ Pour les développeurs d'un compilateur OCaml

## Motivation : pour les compilateurs, mais pas seulement !

- ▶ Pour les développeurs d'un compilateur OCaml
- ▶ Pour faire des bug reports sur du code confidentiel

## Motivation : pour les compilateurs, mais pas seulement !

- ▶ Pour les développeurs d'un compilateur OCaml
- ▶ Pour faire des bug reports sur du code confidentiel
- ▶ Mais aussi adaptable pour d'autres outils travaillant sur du code OCaml !

- ▶ Génération du `.cmt`
- ▶ Extraction de l'AST typé

- ▶ Génération du `.cmt`
- ▶ Extraction de l'AST typé
- ▶ 18 minimiseurs atomiques...



- ▶ Génération du `.cmt`
- ▶ Extraction de l'AST typé
- ▶ 18 minimiseurs atomiques...
- ▶ Chacun appliqué autant que possible par un itérateur...

- ▶ Génération du `.cmt`
- ▶ Extraction de l'AST typé
- ▶ 18 minimiseurs atomiques...
- ▶ Chacun appliqué autant que possible par un itérateur...
- ▶ Le tout répété tant que des modifications sont effectuées !

- ▶ Supprimer les définitions en commençant par la fin

- ▶ Supprimer les définitions en commençant par la fin
- ▶ Remplacer les valeurs des définitions par des valeurs *dummy*

- ▶ Supprimer les définitions en commençant par la fin
- ▶ Remplacer les valeurs des définitions par des valeurs *dummy*
- ▶ Supprimer le code mort

- ▶ Supprimer les définitions en commençant par la fin
- ▶ Remplacer les valeurs des définitions par des valeurs *dummy*
- ▶ Supprimer le code mort
- ▶ Remplacer les expressions par des valeurs *dummy*

- ▶ Supprimer les définitions en commençant par la fin
- ▶ Remplacer les valeurs des définitions par des valeurs *dummy*
- ▶ Supprimer le code mort
- ▶ Remplacer les expressions par des valeurs *dummy*
- ▶ Retirer les attributs des fonctions, modules, etc.

- ▶ Supprimer les définitions en commençant par la fin
- ▶ Remplacer les valeurs des définitions par des valeurs *dummy*
- ▶ Supprimer le code mort
- ▶ Remplacer les expressions par des valeurs *dummy*
- ▶ Retirer les attributs des fonctions, modules, etc.
- ▶ Ajouter les attributs `[local never|always]` et `[inline never|always]`



- ▶ Supprimer les constructeurs de types construits

- ▶ Supprimer les constructeurs de types construits
- ▶ Supprimer les champs de types enregistrement

- ▶ Supprimer les constructeurs de types construits
- ▶ Supprimer les champs de types enregistrement
- ▶ Supprimer les champs de constructeurs

- ▶ Supprimer les constructeurs de types construits
- ▶ Supprimer les champs de types enregistrement
- ▶ Supprimer les champs de constructeurs
- ▶ Supprimer les expressions de type `unit`

- ▶ Supprimer les constructeurs de types construits
- ▶ Supprimer les champs de types enregistrement
- ▶ Supprimer les champs de constructeurs
- ▶ Supprimer les expressions de type `unit`
- ▶ Simplifier les pattern matching

- ▶ Supprimer les constructeurs de types construits
- ▶ Supprimer les champs de types enregistrement
- ▶ Supprimer les champs de constructeurs
- ▶ Supprimer les expressions de type `unit`
- ▶ Simplifier les pattern matching
- ▶ Simplifier les séquences

- ▶ Inliner les fonctions

- ▶ Inliner les fonctions
- ▶ Séquentialiser les applications de fonctions



- ▶ Inliner les fonctions
- ▶ Séquentialiser les applications de fonctions
- ▶ Aplatir les modules

- ▶ Inliner les fonctions
- ▶ Séquentialiser les applications de fonctions
- ▶ Aplatir les modules
- ▶ Simplifier les applications de fonction

- ▶ Inliner les fonctions
- ▶ Séquentialiser les applications de fonctions
- ▶ Aplatir les modules
- ▶ Simplifier les applications de fonction
- ▶ Supprimer les `rec` inutilisés

- ▶ Inliner les fonctions
- ▶ Séquentialiser les applications de fonctions
- ▶ Aplatir les modules
- ▶ Simplifier les applications de fonction
- ▶ Supprimer les `rec` inutilisés
- ▶ Supprimer les arguments inutilisés

Étant donné un indice  $i$ , un minimiseur unitaire tente de minimiser le  $i$ -ème point de programme qu'il peut simplifier.

Étant donné un indice  $i$ , un minimiseur unitaire tente de minimiser le  $i$ -ème point de programme qu'il peut simplifier.

Trois options :

- ▶ Cette simplification ne supprime pas l'erreur : on a minimisé le programme !

Étant donné un indice  $i$ , un minimiseur unitaire tente de minimiser le  $i$ -ème point de programme qu'il peut simplifier.

Trois options :

- ▶ Cette simplification ne supprime pas l'erreur : on a minimisé le programme !
- ▶ Cette simplification supprime l'erreur : on ne souhaite pas l'appliquer.

Étant donné un indice  $i$ , un minimiseur unitaire tente de minimiser le  $i$ -ème point de programme qu'il peut simplifier.

Trois options :

- ▶ Cette simplification ne supprime pas l'erreur : on a minimisé le programme !
- ▶ Cette simplification supprime l'erreur : on ne souhaite pas l'appliquer.
- ▶ L'indice est plus grand que celui du dernier emplacement qu'on peut modifier.



```
type 'a minimized_step_result =  
  | New_state of 'a  
  (* New (smaller) state that produces an error *)  
  | Change_removes_error  
  (* This change removes the error, but other might be possible *)  
  | No_more_changes  
  (* The last possible position for changes has been reached *)
```

```
let minimize_basic (state : 'a)
  (f : 'a -> pos:int -> 'a minimized_step_result) : 'a * bool =
  let rec aux (state : 'a) (pos : int) (ever_changed : bool) =
    match f state ~pos with
    | New_state nstate -> aux nstate pos true
    | Change_removes_error -> aux state (pos + 1) ever_changed
    | No_more_changes -> (state, ever_changed)
  in
  aux state 0 false
```

# La boucle principale



`pos=0`

# La boucle principale



`pos=0`

# La boucle principale



`pos=0`

# La boucle principale



pos=0

# La boucle principale



`pos=0`

# La boucle principale



pos=0



# La boucle principale



`pos=0`

# La boucle principale



`pos=0`

# La boucle principale



`pos=1`

# La boucle principale



pos=1

# La boucle principale



pos=1

# La boucle principale



pos=1

# La boucle principale



pos=1

# La boucle principale



pos=1



# La boucle principale



pos=2

# La boucle principale



pos=2

# La boucle principale



pos=2

# La boucle principale



pos=2



pos=2



pos=2

# La boucle principale



pos=2

# La boucle principale



pos=3





pos=3

# La boucle principale



pos=4

# La boucle principale



pos=4

# La boucle principale



pos=4

# La boucle principale



pos=4

- ▶ 18 minimiseurs

- ▶ 18 minimiseurs
- ▶ Basés sur `Tast_mapper` pour parcourir l'ast typé

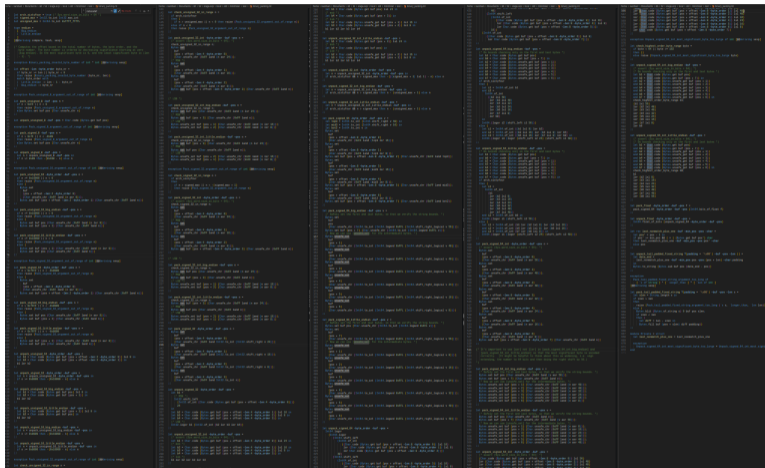
- ▶ 18 minimiseurs
- ▶ Basés sur `Tast_mapper` pour parcourir l'ast typé
- ▶ Représentant 3000 lignes de code



- ▶ 18 minimiseurs
- ▶ Basés sur `Tast_mapper` pour parcourir l'ast typé
- ▶ Représentant 3000 lignes de code
- ▶ Déclinés en version compatible `ocamlc` ou `flambda2`


- ▶ 18 minimiseurs
- ▶ Basés sur `Tast_mapper` pour parcourir l'ast typé
- ▶ Représentant 3000 lignes de code
- ▶ Déclinés en version compatible `ocamlc` ou `flambda2`
- ▶ Déclinables à faible coût vers une version différente de l'AST via une librairie de compatibilité

- ▶ 18 minimiseurs
- ▶ Basés sur `Tast_mapper` pour parcourir l'ast typé
- ▶ Représentant 3000 lignes de code
- ▶ Déclinés en version compatible `ocamlc` ou `flambda2`
- ▶ Déclinables à faible coût vers une version différente de l'AST via une librairie de compatibilité
- ▶ Et donnant des résultats sur des exemples réels !



The screenshot shows a debugger window with several panes. The main pane displays assembly code with a red arrow pointing to a faulting instruction. The faulting instruction is a `mov` instruction that attempts to write to a memory location that is not mapped in the current address space, causing a `fatal_error`. The error message in the right pane reads: `fatal_error: invalid memory access at address 0x00000000`. The assembly code shows the instruction `mov [0], 0` at address `00401000`. The registers pane shows the `EIP` register pointing to `00401000`. The stack pane shows the current stack frame for the `main` function.

Misc.fatal\_error

```
test >  binary_packing_min.ml
1  let offset ~byte_order byte_nr =
2  | match byte_order with | `Little_endian -> 0 | `Big_endian -> byte_nr
3
4  let pack_unsigned_16 ~byte_order =
5  | __ignore__ ((offset ) ~byte_order 0);
6  | __ignore__ ((__dummy2__ ()) ((offset ) ~byte_order 1));
7  | __dummy2__ ( )
```

`Misc.fatal_error`

# D'un fichier seul à un projet complet: le multifichier

- ▶ Suppression d'autant de fichiers que possible

# D'un fichier seul à un projet complet: le multifichier

- ▶ Suppression d'autant de fichiers que possible
- ▶ Fusion d'autant de fichiers que possible



## D'un fichier seul à un projet complet: le multifichier

- ▶ Suppression d'autant de fichiers que possible
- ▶ Fusion d'autant de fichiers que possible
- ▶ Représentation de l'ensemble des fichiers via une map

## D'un fichier seul à un projet complet: le multifichier

- ▶ Suppression d'autant de fichiers que possible
- ▶ Fusion d'autant de fichiers que possible
- ▶ Représentation de l'ensemble des fichiers via une map
- ▶ Adaptation de tous les minimiseurs existants pour propager les modifications

# D'un fichier seul à un projet complet: le multifichier

- ▶ Suppression d'autant de fichiers que possible
- ▶ Fusion d'autant de fichiers que possible
- ▶ Représentation de l'ensemble des fichiers via une map
- ▶ Adaptation de tous les minimiseurs existants pour propager les modifications

On fournit au minimiseur la liste des fichiers - `ocamldep` nous donne l'ordre de compilation.

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=0 ^ lgth=1`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=0 ^ lgth=1`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=0 ^ lgth=2`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=0 ^ lgth=2`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=0 ^ lgth=4`



On remplace notre méthode d'itération linéaire en dichotomique :



`pos=0 ^ lgth=4`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=0 ^ lgth=8`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=0 ^ lgth=8`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=0 ^ lgth=4`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=0 ^ lgth=4`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=0 ^ lgth=2`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=0 ^ lgth=2`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=0 ^ lgth=2`



On remplace notre méthode d'itération linéaire en dichotomique :



$\text{pos}=0 \wedge \text{lgth}=1$

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=0 ^ lgth=1`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=0 ^ lgth=1`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=1 ^ lgth=1`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=1 ^ lgth=1`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=1 ^ lgth=2`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=1 ^ lgth=2`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=1 ^ lgth=4`



On remplace notre méthode d'itération linéaire en dichotomique :



`pos=1 ^ lgth=4`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=1 ^ lgth=2`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=1 ^ lgth=2`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=1 ^ lgth=1`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=1 ^ lgth=1`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=1 ^ lgth=1`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=2 ^ lgth=1`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=2 ^ lgth=1`



On remplace notre méthode d'itération linéaire en dichotomique :



`pos=2 ^ lgth=1`

On remplace notre méthode d'itération linéaire en dichotomique :



`pos=2 ^ lgth=1`

On gagne jusqu'à un facteur 10 pour un fichier de 4000 lignes !

Parfois, le plantage n'a pas lieu à la compilation, mais à l'exécution du code produit !

Parfois, le plantage n'a pas lieu à la compilation, mais à l'exécution du code produit !

⇒ Restriction du minimiseur à des transformations safe

Parfois, le plantage n'a pas lieu à la compilation, mais à l'exécution du code produit !

- ⇒ Restriction du minimiseur à des transformations safe
- ⇒ Modification des valeurs *dummy*, qui utilisent une primitive unsafe : les expressions sont plutôt remplacées par des expressions simplifiées du même type !

- ▶ Rendre le minimiseur compatible avec un projet dune

- ▶ Rendre le minimiseur compatible avec un projet dune
- ▶ Plus de tests, sur plus de fichiers, pour en améliorer la précision, la robustesse, l'efficacité !

- ▶ Un minimiseur pour assister le développement d'un projet manipulant du code OCaml...



- ▶ Un minimiseur pour assister le développement d'un projet manipulant du code OCaml...
- ▶ Qui minimise de manière efficace des exemples réels...

- ▶ Un minimiseur pour assister le développement d'un projet manipulant du code OCaml...
- ▶ Qui minimise de manière efficace des exemples réels...
- ▶ Et qui fait gagner du temps à ses utilisateurs !

Merci pour votre attention !