# Towards Higher-Order Syntax of C Programming Language

スタートC language面白論文紹介&読み会

発表者: kinaba

# Towards Higher-Order Syntax of C Programming Language

Kazuhiro Inaba
kMonos.net
kiki@kmonos.net

Kazuhiro Inaba
Google Inc.
kinaba@google.com

Kazuhiro Inaba
Free Researcher
binhzkr@gmail.com

## ABSTRACT

The grammar of the C programing language [1] is widely known to go beyond the expressive power of context free grammar. The main, and in fact, the sole cause of the context sensitivity is that the indistinguishability of type names and variable names.

The natural question arises here is, then what kind of grammar formalism can capture such kind of name declarations? As a candidate, we seek a way to describe the C syntax using higher-order grammars, which have much more power than context free grammar, yet still have clearly understandable formal definition. Unfortunately, the paper reports the failure of this attempt, but at the same time, explain what addition is needed for higher-order grammar to achieve the goal: expressing C syntax.

## Categories and Subject Descriptors

D.3.3 [**Programming Languages**]: Language Contructs and Features – *abstract data types, polymorphism, control structures.*

## General Terms

Algorithms, Languages, Theory, Verification.

## Keywords

Higher-Order Grammar, Parsing

## 1. INTRODUCTION

The grammar of the C programing language [1] is widely known to go beyond the expressive power of context free grammar. The main, and in fact, the sole cause of the context sensitivity is that the indistinguishability of type names and variable names.

The natural question arises here is, then what kind of grammar formalism can capture such kind of name declarations? As a candidate, we seek a way to describe the C syntax using higher-order grammars, which have much more power than context free grammar, yet still have clearly understandable formal definition. Unfortunately, the paper reports the failure of this attempt, but at the same time, explain what addition is needed for higher-order grammar to achieve the goal: expressing C syntax.

The proceedings are the records of the conference. ACM hopes to give these conference by-products a single, high-quality appearance. To do this, we ask that authors follow some simple guidelines. In essence, we ask you to make your paper look exactly like this document. The easiest way to do this is simply to down-load a template from [2], and replace the content with your own material.



## 2. MOTIVATING EXAMPLE

All material on each page should fit within a rectangle of 18 × 23.5 cm (7" × 9.25"), centered on the page, beginning 1.9 cm

```
1: size_t* ptr;
2: v = (time_t) *tp;
3: puts(str);
```

(0.75") from the top of the page and ending with 2.54 cm (1") from the bottom. The right and left margins should be 1.9 cm (.75"). The text should be in two 8.45 cm (3.33") columns with a .83 cm (.33") gutter.

## 3. REFERENCES

[1] Bowman, M., Debray, S. K., and Peterson, L. L. 1993. Reasoning about naming systems. *ACM Trans. Program. Lang. Syst.* 15, 5 (Nov. 1993), 795-825. DOI= http://doi.acm.org/10.1145/161468.16147.

[2] Ding, W. and Marchionini, G. 1997. *A Study on Video Browsing Strategies*. Technical Report. University of Maryland at College Park.

[3] Fröhlich, B. and Plate, J. 2000. The cubic mouse: a new device for three-dimensional input. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems* (The Hague, The Netherlands, April 01 - 06, 2000). CHI '00. ACM, New York, NY, 526-531. DOI= http://doi.acm.org/10.1145/332040.332491.

[4] Tavel, P. 2007. *Modeling and Simulation Design*. AK Peters Ltd., Natick, MA.

[5] Sannella, M. J. 1994. *Constraint Satisfaction and Debugging for Interactive User Interfaces*. Doctoral Thesis. UMI Order Number: UMI Order No. GAX95-09398., University of Washington.

[6] Forman, G. 2003. An extensive empirical study of feature selection metrics for text classification. *J. Mach. Learn. Res.* 3 (Mar. 2003), 1289-1305.

[7] Brown, L. D., Hua, H., and Gao, C. 2003. A widget framework for augmented interaction in SCAPE. In *Proceedings of the 16th Annual ACM Symposium on User Interface Software and Technology* (Vancouver, Canada, November 02 - 05, 2003). UIST '03. ACM, New York, NY,

面白い論文が
見つからなかった
ので
捏造

# Towards Higher-Order Syntax of C Programming Language

Kazuhiro Inaba
kMonos.net
kiki@kmonos.net

Kazuhiro Inaba
Google Inc.
kinaba@google.com

Kazuhiro Inaba
Free Researcher
binhzkr@gmail.com

## ABSTRACT

The grammar of the C programing language [1] is widely known to go beyond the expressive power of context free grammar. The main, and in fact, the sole cause of the context sensitivity is that the indistinguishability of type names and variable names.

The natural question arises here is, then what kind of grammar formalism can capture such kind of name declarations? As a candidate, we seek a way to describe the C syntax using higher-order grammars, which have much more power than context free grammar, yet still have clearly understandable formal definition. Unfortunately, the paper reports the failure of this attempt, but at the same time, explain what addition is needed for higher-order grammar to achieve the goal: expressing C syntax.

## Categories and Subject Descriptors

D.3.3 [**Programming Languages**]: Language Contructs and Features – *abstract data types, polymorphism, control structures.*

## General Terms

Algorithms, Languages, Theory, Verification.

## Keywords

Higher-Order Grammar, Parsing

## 1. INTRODUCTION

The grammar of the C programing language [1] is widely known to go beyond the expressive power of context free grammar. The main, and in fact, the sole cause of the context sensitivity is that the indistinguishability of type names and variable names.

The natural question arises here is, then what kind of grammar formalism can capture such kind of name declarations? As a candidate, we seek a way to describe the C syntax using higher-order grammars, which have much more power than context free grammar, yet still have clearly understandable formal definition. Unfortunately, the paper reports the failure of this attempt, but at the same time, explain what addition is needed for higher-order grammar to achieve the goal: expressing C syntax.

The proceedings are the records of the conference. ACM hopes to give these conference by-products a single, high-quality appearance. To do this, we ask that authors follow some simple guidelines. In essence, we ask you to make your paper look exactly like this document. The easiest way to do this is simply to down-load a template from [2], and replace the content with your own material.



## 2. MOTIVATING EXAMPLE

All material on each page should fit within a rectangle of 18 × 23.5 cm (7" × 9.25"), centered on the page, beginning 1.9 cm

```
1: size_t* ptr;
2: v = (time_t) *tp;
3: puts(str);
```

(0.75") from the top of the page and ending with 2.54 cm (1") from the bottom. The right and left margins should be 1.9 cm (.75"). The text should be in two 8.45 cm (3.33") columns with a .83 cm (.33") gutter.

## 3. REFERENCES

[1] Bowman, M., Debray, S. K., and Peterson, L. L. 1993. Reasoning about naming systems. *ACM Trans. Program. Lang. Syst.* 15, 5 (Nov. 1993), 795-825. DOI= http://doi.acm.org/10.1145/161468.16147.

[2] Ding, W. and Marchionini, G. 1997. *A Study on Video Browsing Strategies*. Technical Report. University of Maryland at College Park.

[3] Fröhlich, B. and Plate, J. 2000. The cubic mouse: a new device for three-dimensional input. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems* (The Hague, The Netherlands, April 01 - 06, 2000). CHI '00. ACM, New York, NY, 526-531. DOI= http://doi.acm.org/10.1145/332040.332491.

[4] Tavel, P. 2007. *Modeling and Simulation Design*. AK Peters Ltd., Natick, MA.

[5] Sannella, M. J. 1994. *Constraint Satisfaction and Debugging for Interactive User Interfaces*. Doctoral Thesis. UMI Order Number: UMI Order No. GAX95-09398., University of Washington.

[6] Forman, G. 2003. An extensive empirical study of feature selection metrics for text classification. *J. Mach. Learn. Res.* 3 (Mar. 2003), 1289-1305.

[7] Brown, L. D., Hua, H., and Gao, C. 2003. A widget framework for augmented interaction in SCAPE. In *Proceedings of the 16th Annual ACM Symposium on User Interface Software and Technology* (Vancouver, Canada, November 02 - 05, 2003). UIST '03. ACM, New York, NY,

# 1. Introduction

*Towards*
*Higher-Order Syntax of*
*C Programming Language*

# Cの文法は文脈自由ではないと言われる

なぜか。

# Cの文法は文脈自由ではないと言われる

なぜか。

```
FILE *fp;
```

```
width * height;
```

```
n = (size_t)*ptr;
```

```
f = (m) * a;
```

```
strdup(*argv)[9];
```

```
byte (*bufs)[9];
```

```
puts(str);
```

```
clock_t (t);
```

すごくどうでもいいんですけど、いろいろ面白いですね。

```
(a)*b*c;
(a*)b*c;
(a*b)*c;
(a*b*c);
a()*b*c;
a(*b)*c;
a(*b*c);
```

```
a*(b)*c;
a*(b*)c;
a*(b*c);
a*b()*c;
a*b(*c);
a*b*(c);
a*b*c();
```

```
(a*)(b*)c;
(a*)b(*c);
a(*b)(*c);
```

⋮

```
(a(*)(b))*c;
```

⋮

クイズ：a*b*c; に括弧を入れて
宣言文をつくることはできるか？

# Cの文法は文脈自由ではないと言われる

根本原因は、型名と変数/関数名が文脈情報を持ってないと区別できないこと。

cf.

- goto のラベル名
- struct や enum の名前

は文法的に区別できる。

# Cの文法は文脈自由ではないと言われる

文脈自由じゃないなら、BNFより強力な文法記述言語で書けばいいじゃない！

# Cの文法は文脈自由ではないと言われる

文脈自由じゃないなら、BNFより強力な文法記述言語で書けばいいじゃない！

**ISO/IEC 9899:1999**　自然言語で書いてある

**gcc, clang, …** ： C や C++ で書いてある

**CompCert (Coqで証明されたCコンパイラ)** ：パーサだけ OCaml で書いてあった

Elsa/Elkhound C++ Parser ： GLR構文解析で頑張るが結局最後はC++。

# Cの文法は文脈自由ではないと言われる

文脈自由じゃないなら、BNFより強力な文法記述言語で書けばいいじゃない！

**ISO/IEC 9899:1999**　自然言語で書いてある

**gcc, clang, …** ： C や C++ で書いてある

**CompCert (Coqで証明されたCコンパイラ)** ：パーサだけ OCaml で書いてあった

Elsa/Elkhound C++ Parser ： GLR構文解析で頑張るが結局最後はC++。

なぜ揃いも揃ってチューリング完全な言語を使うのか。根性が足りない。

# チューリング完全脳の恐怖

∞: チューリングマシン

2: 文脈自由文法

1: 正規表現

# 現実を見よう

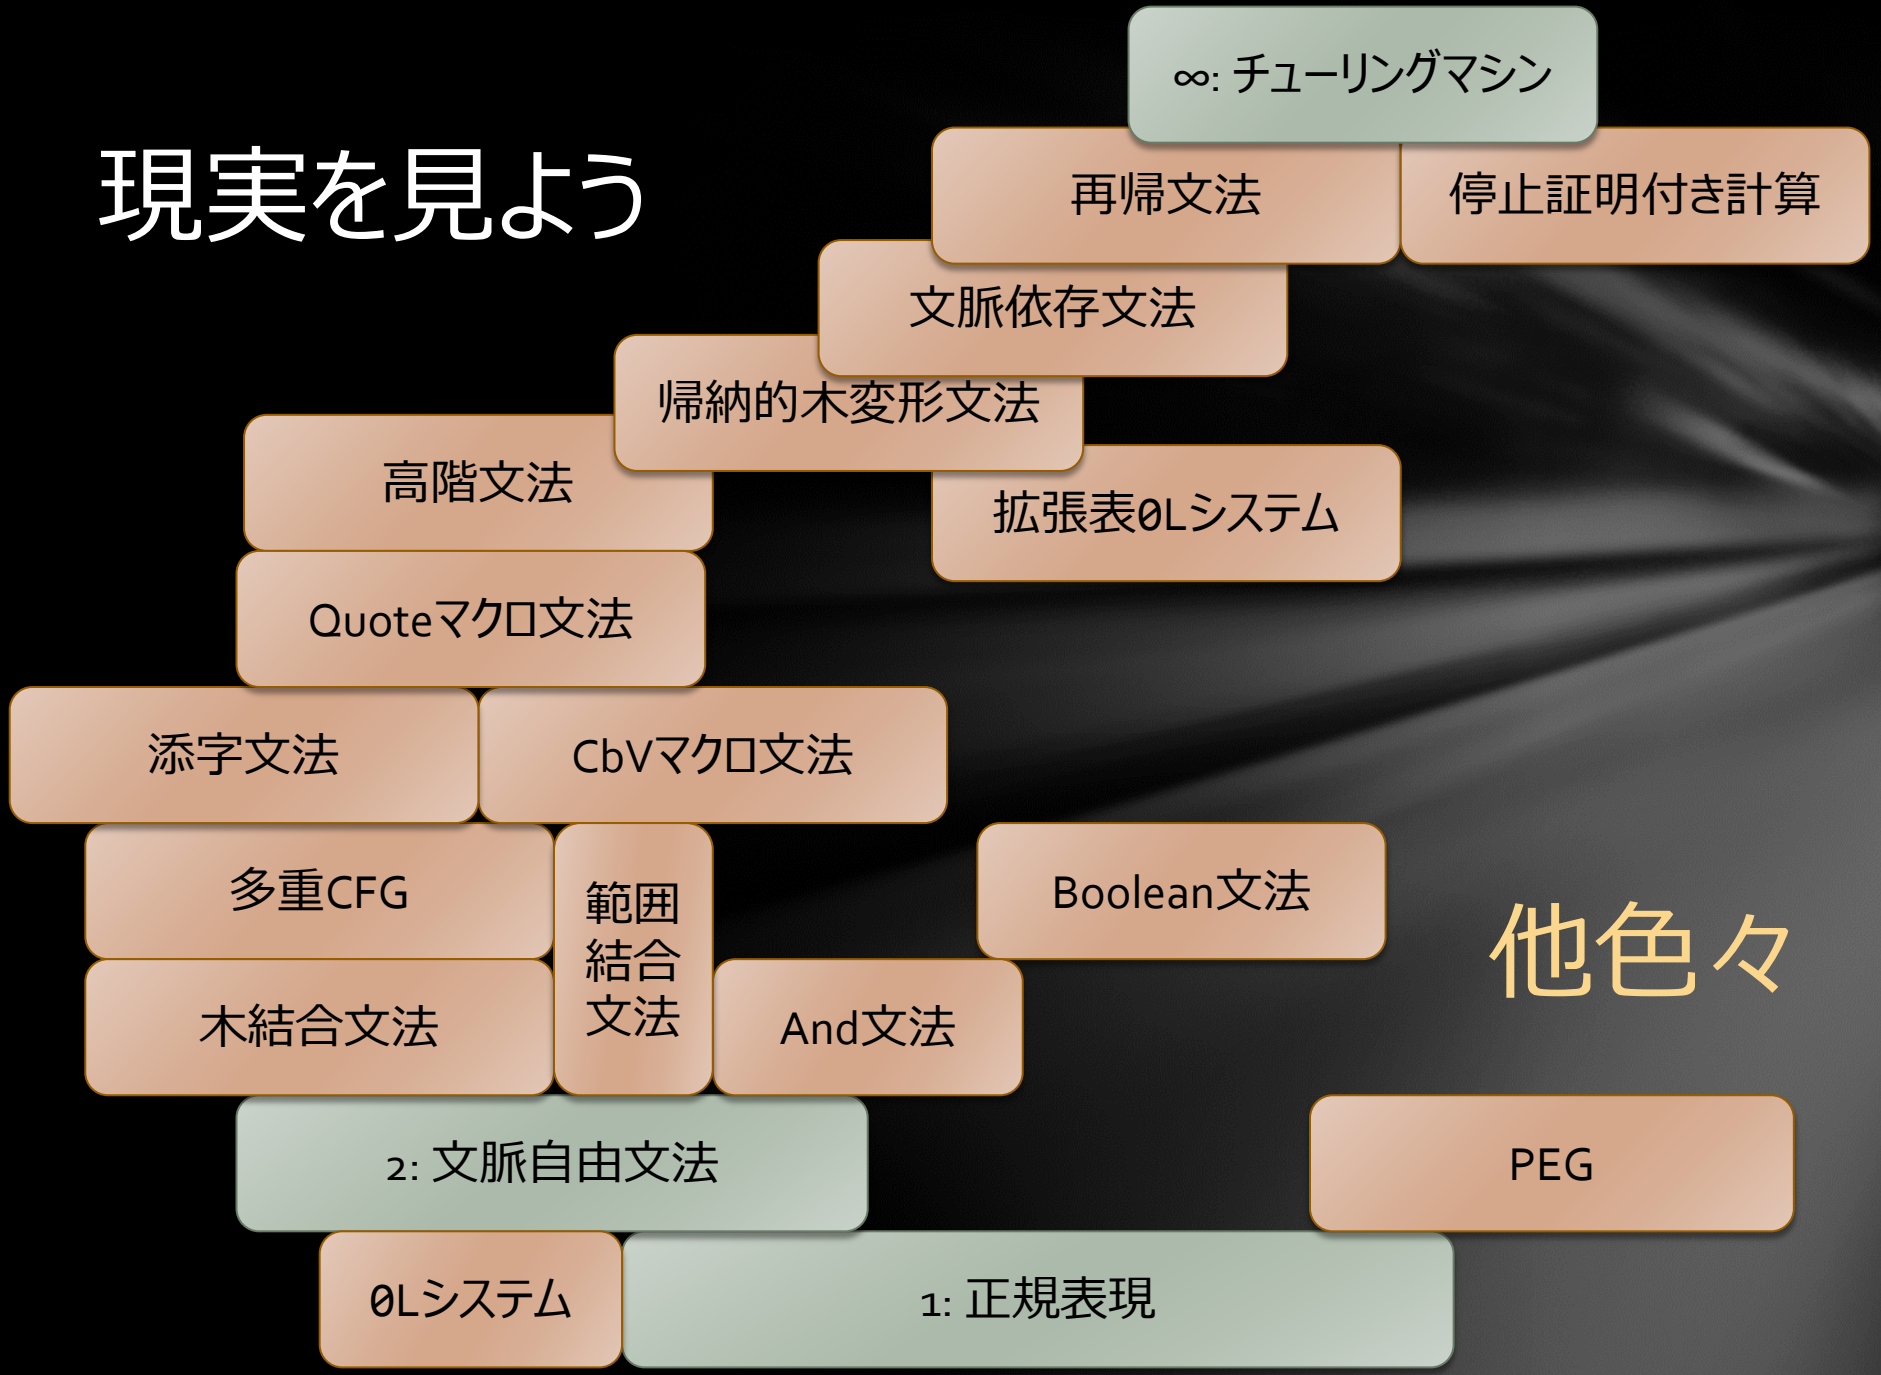
∞: チューリングマシン
再帰文法
停止証明付き計算
文脈依存文法
帰納的木変形文法
高階文法
拡張表0Lシステム
Quoteマクロ文法
添字文法
CbVマクロ文法
多重CFG
範囲結合文法
Boolean文法
木結合文法
And文法
他色々
2: 文脈自由文法
PEG
0Lシステム
1: 正規表現

# 現実を見よう

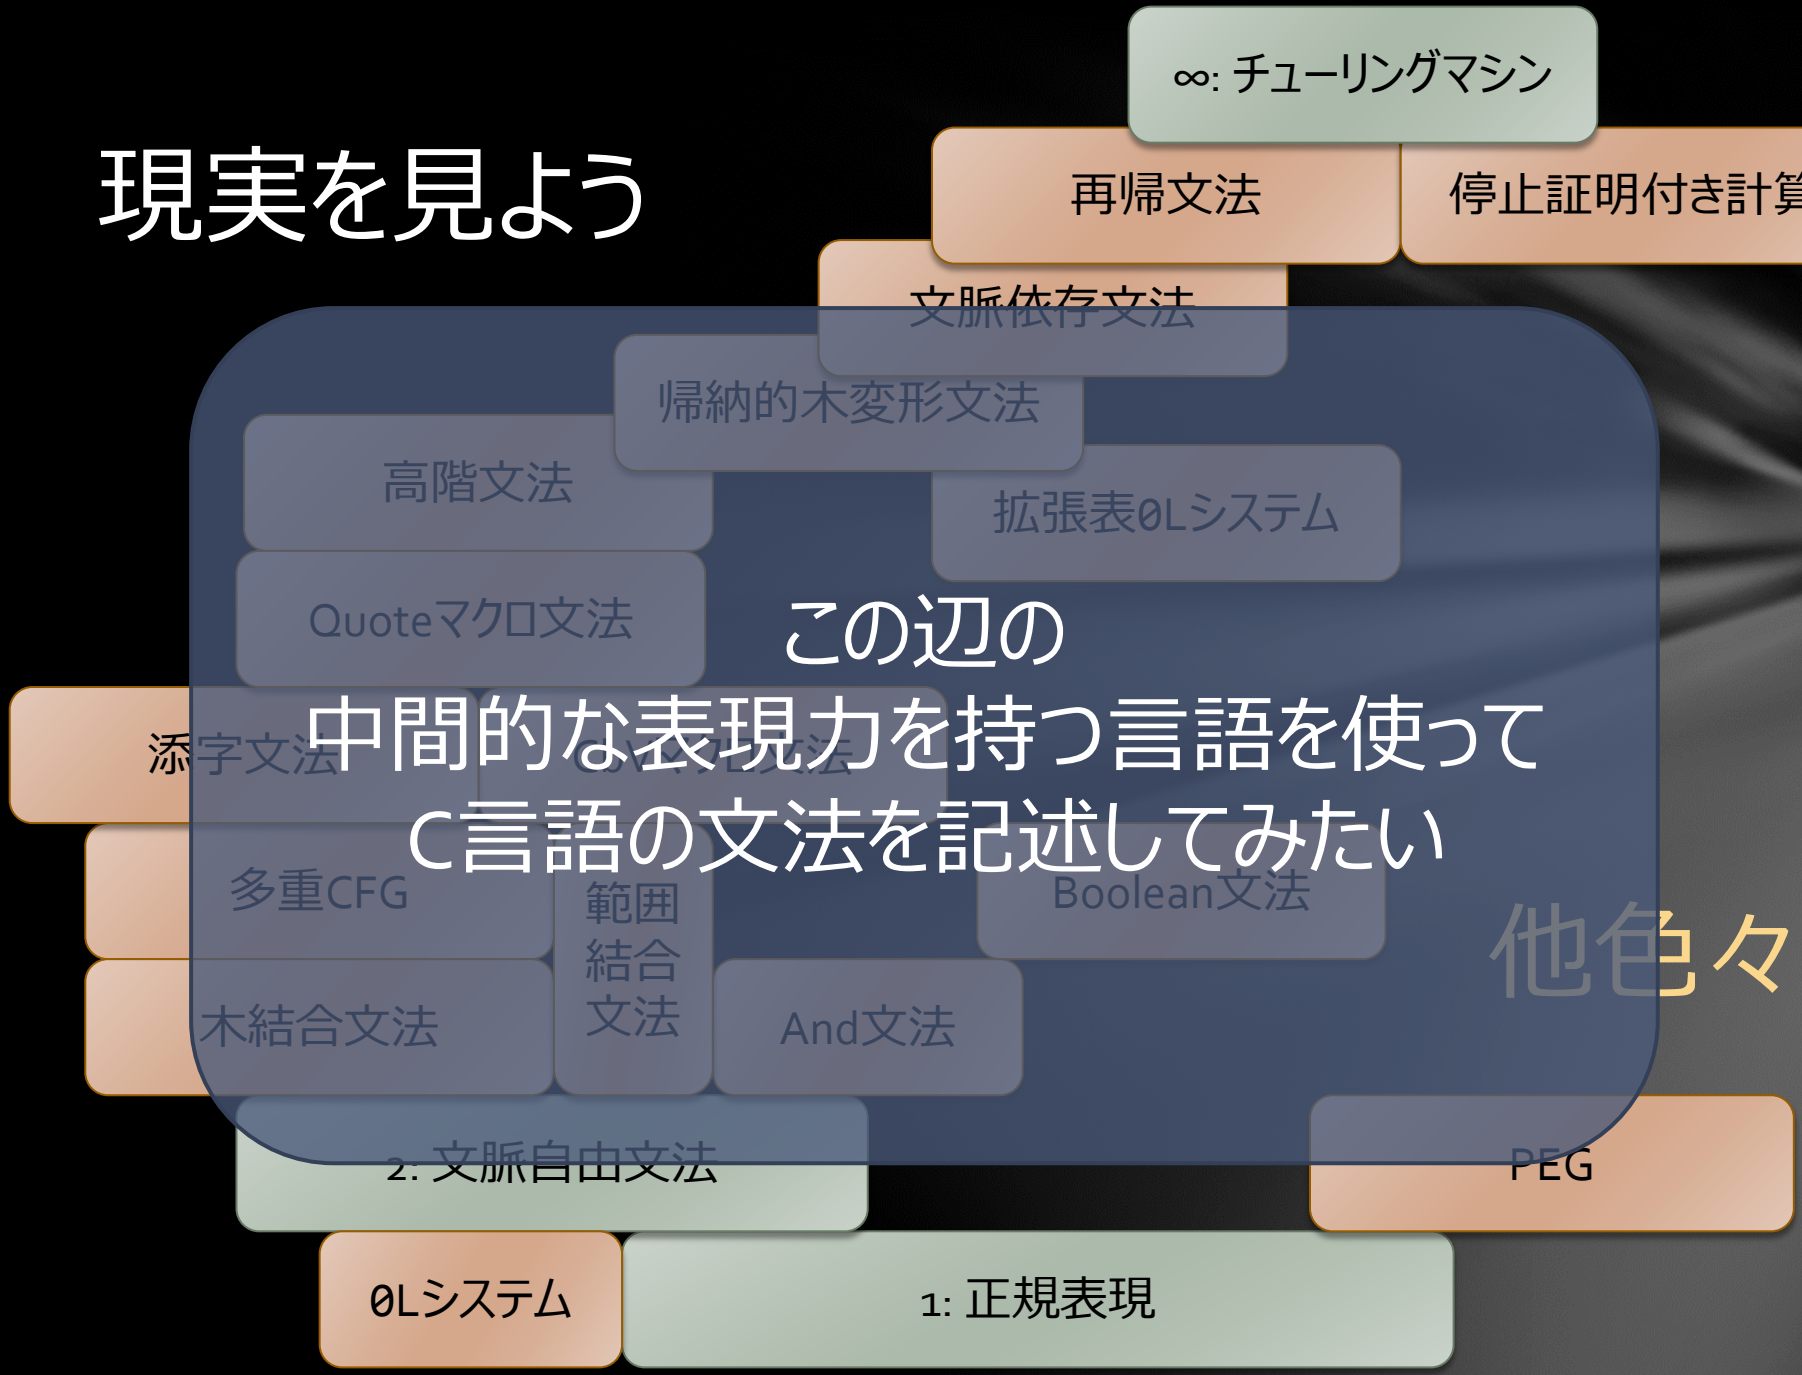
∞: チューリングマシン
再帰文法
停止証明付き計算
文脈依存文法
帰納的木変形文法
高階文法
拡張表0Lシステム
Quoteマクロ文法
この辺の
中間的な表現力を持つ言語を使って
C言語の文法を記述してみたい
添字文法
多重CFG
範囲
結合
文法
Boolean文法
他色々
木結合文法
And文法
2: 文脈自由文法
PEG
0Lシステム
1: 正規表現

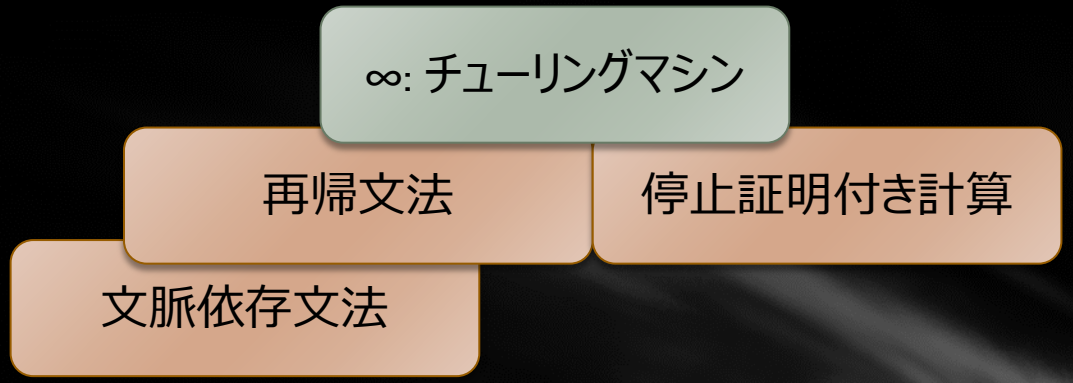


この辺なら書けるはずだけど
人類には難しい

# この辺では無理そうな気がなんとなくする

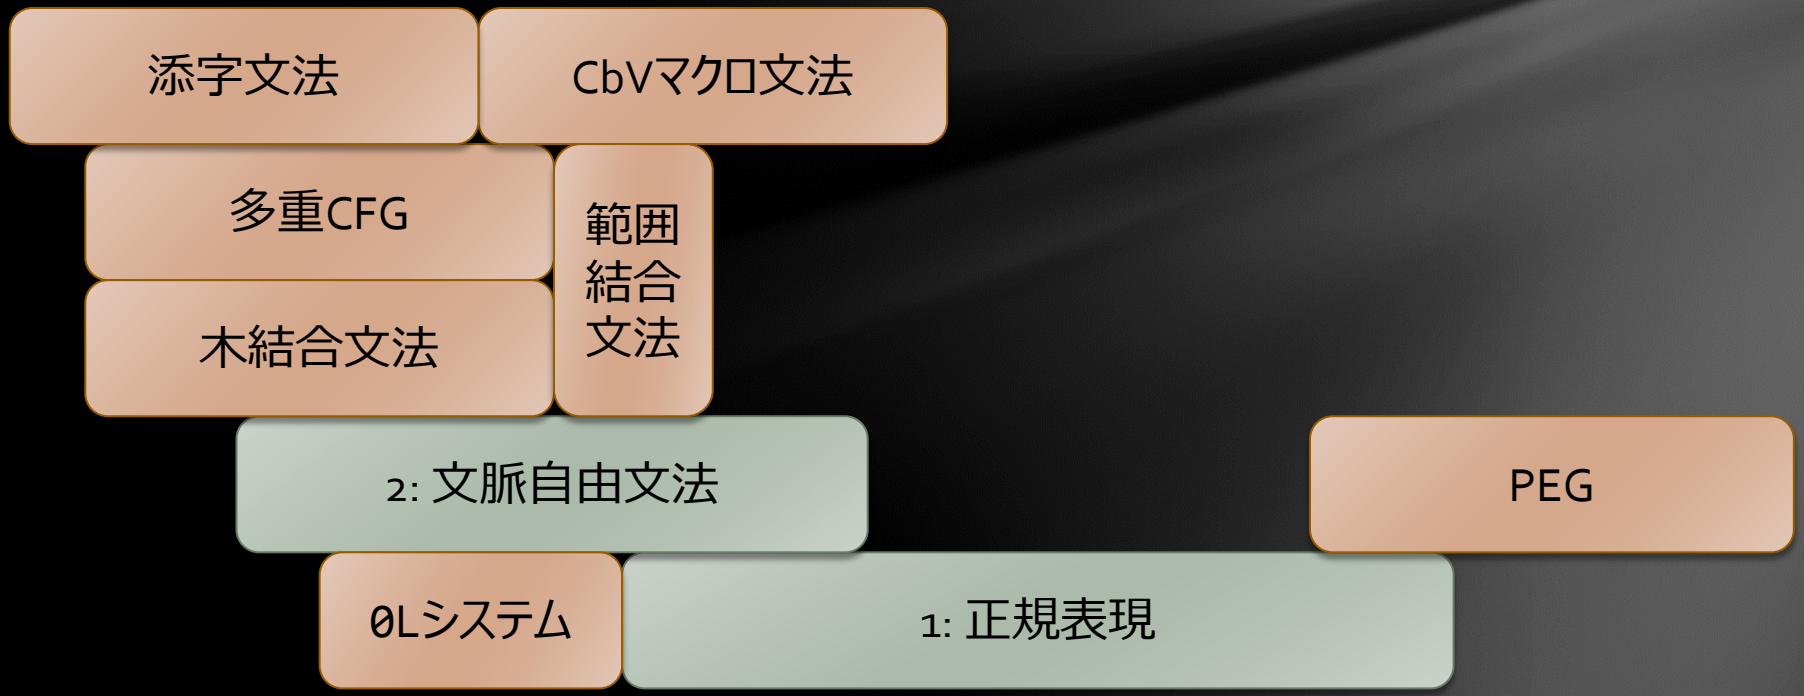

# この辺で頑張ってみる

帰納的木変形文法

高階文法

Quoteマクロ文法

# Q. その前に、なぜ強力すぎる文法記述言語ではいけないのか

A. ツールで扱えない。

BNFで書いてあればそのままほぼコピペで yacc (など) に持って行ける。
IDE, エディタ, 静的解析器, lint, 構造化diff, 色分けマークアップツール 等のパーサに即座に転用できる。

A. 他言語に自動的に持って行くのが難しい。

Eclipse上の開発環境作りたいのにC++で書いたコンパイラが仕様書しかない等々。

A. 抽象性・非決定性がないことが多い

どこまでが仕様でどこまでが実装の都合なのか境界が曖昧。

A. 安全でない

コードジェネレータの吐くコードが意図した通りにparseされることの証明をどう書けば良いのか？どう検証すればよいのか？

A. 文法の複雑さをなんとなくの感覚でしか議論できない。

現状「Regular」「LALR」「CF」「その他」の４分類しか無いに等しいが、
実際はほとんどが「その他」なので、現実の言語はほとんど何も分類されていない。

# そういうわけで、この辺で頑張ってみる

帰納的木変形文法

高階文法

Quoteマクロ文法

# 2. Preliminaries

*Towards*
*Higher-Order Syntax of*
*C Programming Language*

# Macro Grammar [Fischer 68] とは

パラメタ付き文脈自由文法

（↓はインデントの深さでブロックを表現する文法簡易バージョン）

**BLOCK(*x*)** ::= **STATEMENT(*x*)** | **STATEMENT(*x*) BLOCK(*x*)**
**STATEMENT(*x*)** ::= **S_IF(*x*)** | **S_WHILE(*x*)** | **S_EXPR(*x*)**
**S_IF(*x*)** ::= ***x*** if **EXPR** ¥n **BLOCK(*x* ¥t)**
**S_WHILE(*x*)** ::= ***x*** while **EXPR** ¥n **BLOCK(*x* ¥t)**
**S_EXPR(*x*)** ::= ***x*** **E**
**E** ::= **E** + **E** | **E** * **E** | ...
**PROGRAM** ::= **BLOCK()**

# Macro Grammar [Fischer 68] とは

Fischer さんが提案したのは 3 種類

OI Macro Grammar ： パラメタを call-by-name で遅延評価する

IO Macro Grammar : パラメタを call-by-value で正格評価する

**AORB** ::= a | b
**PAIR(*x*)** ::= < *x* , *x* >
**S** ::= **PAIR( AORB )**

Quoted Macro Grammar : quoteとunquoteでどっちの評価モードか明示できる

# Higher-Order Grammar

Context Free Grammar

　各規則の型は :: string

Macro Grammar

　各規則は、文字列を返す式を引数としてとって、文字列を返す :: string→string

Higher-Order Grammar

　((string → string) → string) → string → string みたいな高階規則を考えよう

```
TYPE1(h, b) ::= h { b }
TYPE2(h, b) ::= h begin b end
SS(t) ::= | S(t) SS(t)
 S(t)      ::= IF(t) | WHILE(t) | UBE
 IF(t)     ::= t(if E, SS(t))
 WHILE(t)  ::= t(while E, SS(t))
 UBE       ::= beginend S(TYPE2)
PROGRAM ::= SS(TYPE1)
```

# 3. Formalizing C Syntax

*Towards*
*Higher-Order Syntax of*
*C Programming Language*

# 期待

パラメタ渡しを使って、「今宣言された変数の名前」とか「型の名前」とか
持ち回っていけば文脈情報が表現できそうな気がする！

それだけで難しくても、なんかハイヤーオーダーパワーで
どうにかなりそうな気がする！

# やってみる

（優先順位とか複雑な型とか無視して簡略化）

「今使える型名と変数名」をパラメタに持たせる

```
EXPR ::= ( TYPE ) EXPR
       | * EXPR
       | EXPR * EXPR
       | VAR
       | ( EXPR )
```

```
EXPR(t, v) ::= ( t ) EXPR(t, v)
             | * EXPR(t, v)
             | EXPR * EXPR(t, v)
             | v
             | ( EXPR(t, v) )
```

# やってみる

わりとよい

```
EXPR(t, v) ::= ( t ) EXPR(t, v)
             | * EXPR(t, v)
             | EXPR * EXPR(t, v)
             | v
             | ( EXPR(t, v) )
```

EXPR( size_t, ptr | m | a ) は曖昧性無く以下を区別する。

引数は call-by-name で解釈

```
n = (size_t)*ptr;
```

キャスト式

```
f = (m) * a;
```

かけ算

# 宣言の扱い

（いろいろ無視して簡略化）

```
BlockItems ::= (S | D)
             | (S | D) BlockItems
D ::= typedef TYPE ID ;
    | TYPE VAR ;
S ::= EXPR ;
```

```
BlockItems(t, v) ::= (S | D)(t, v, Empty)
                   | (S | D)(t, v, BlockItems)
D(t, v, k) ::= TDecl(ID, t, v, k)
             | VDecl(ID, t, v, k)
S(t, v, k) ::= EXPR(t, v) ; k(t, v)
 where Empty(t, v) ::=
       TDecl(tp, t, v, k) ::= typedef t tp ; k(t|tp, v)
       VDecl(x, t, v, k)  ::= t x ; k(t, v|x)
```

# 宣言の扱い

変数宣言は、

```
VDecl(x, t, v, k)  ::= t x ; k(t, v|x)
```

宣言される変数名(cbv)と、今既にある型名(cbn) 、変数名(cbn)を受け取って

変数宣言 “t x;” を生成して、更新された名前環境を継続 k に渡す。

型宣言も同様。

```
TDecl(tp, t, v, k) ::= typedef t tp ; k(t|tp, v)
```

注目ポイント：

cbv と cbn 引数、どっちも必要そう。

継続渡し形式なのは、趣味で高階関数使いたかっただけで、別に要らないと思います。

# 宣言の扱い

```
BlockItems(t, v) ::= (S | D)(t, v, Empty)
                   | (S | D)(t, v, BlockItems)
D(t, v, k) ::= TDecl(ID, t, v, k)
             | VDecl(ID, t, v, k)
S(t, v, k) ::= EXPR(t, v) ; k(t, v)
 where Empty(t, v) ::=
       TDecl(tp, t, v, k) ::= typedef t tp ; k(t|tp, v)
       VDecl(x, t, v, k)  ::= t x ; k(t, v|x)
```

BlockItems(LPCSTR, {}) が以下を一通りにparseすることが確かめられる

```
typedef LPCSTR x;
x y;
(x)*y;
```

# 4. Conflicting Names

*Towards*
*Higher-Order Syntax of*
*C Programming Language*

# 問題点

これはエラー

```
int main() {
 typedef int x;
 int x;
}
```

これは OK

```
typedef int x;
int main() {
  int x;
}
```

# 問題点

```
int main() {
 typedef int x;
 int x;
}
```

```
typedef int x;
int main() {
   int x;
}
```

- inner scope での定義と outer scope での定義は区別する必要がある
- inner scope での衝突はエラーにする必要がある
- outer scope との衝突は、外の scope を「隠す」必要がある
  - ＞ “int x;” より後で x を型名として使うコードは構文エラーにする必要あり

# 高階文法パワーでどうにかなるか？

# 高階文法パワーでどうにかなるか？

- inner scope での定義と outer scope での定義は区別する必要がある
  - ＞ どうにでもなる
- inner scope での衝突はエラーにする必要がある
  - ＞ 無理
- outer scope との衝突は、外の scope を「隠す」必要がある
  - ＞ 無理

# 5. Future Work

*Towards*
*Higher-Order Syntax of*
*C Programming Language*

# 結論

・inner scope での衝突はエラーにする必要がある

　　＞ 無理

・outer scope との衝突は、外の scope を「隠す」必要がある

　　＞ 無理

高階文法でもまだ無理なことがわかりました。

では、文法へのさらなる拡張として、何が必要か？

# 提案

nondeterminism

Foo にマッチするものか Bar にマッチするものか、どっちか

```
Foo | Bar
```

CFG やその上の高階文法は、非決定性の足し算しかできない

anti-nondeterminism

Foo にマッチするもののうち Bar にマッチしないもの 。引き算が必要。

```
Foo - Bar
```

# 提案

- inner scope での衝突はエラーにする必要がある

  ＞引き算あればできる

- outer scope との衝突は、外の scope を「隠す」必要がある

  ＞ 引き算あればできる

```
D(ot, ov, it, iv, k) ::= TDecl(ID-it-iv, ot, ov, it, iv, k)
                       | VDecl(ID-it-iv, ot, ov, it, iv, k)
TDecl(tp, ot, ov, it, iv, k) ::= typedef (ot|it) tp ;
                                 k(ot-tp, ov-tp, it|tp, iv)
VDecl(x,  ot, ov, it, iv, k) ::= (ot|it) x ;
                                 k(ot-x, ov-x, it, iv|x)
```

# 提案

高階文法

Quoteマクロ文法

引き算的なものが
できる人たち↓

パラメタ渡し的なものが
できる人たち↑

Boolean文法

PEG

# 最終結論

このようなものを考えるとよいのではないでしょうか！

高階 PEG

Quoteマクロ Boolean文法

注意：
引き算的なもの入りの文法の意味論を綺麗に定めるのは難しいので、
うかつにやるとチューリング完全な言語で書くのと何もかわらなくなってしまいます。注意。

# Towards Higher-Order Syntax of C++

次回予告

発表者: kinaba

# C++の文法は文脈自由ではないと言われる

なぜか。

```
FILE *fp;
```

```
width * height;
```

```
n = (size_t)*ptr;
```

```
f = (m) * a;
```

```
strdup(*argv)[9];
```

```
byte (*bufs)[9];
```

```
puts(str);
```

```
clock_t (t);
```

# そんなものは大した問題ではない

「C++ は、どれだけ文脈情報を持っていても、上から順には parse できない」

```
class Foo {
  Foo() {
    hello * world;
  }
  typedef int hello;
  int world;
};
```

```
class Foo {
  Foo() {
    hello * world;
  }
  int hello;
  int world;
};
```

曖昧性の問題はCと本質的にはほぼ同じ（優先度付き非決定性で書けそう）

template による複雑化は、まあどうにかなる。

ので、根本問題は上のパターンだと思われる。

# 次回

Towards C++ Parsing by

## Higher-Order-Delimited-Continuation PEG

お楽しみに（？）