版管理システムを用いたクローン履歴分析手法

○川口真司(奈良先端大), 松下誠(阪大)
kawaguti@is.naist.jp,
matusita@ist.osaka-u.ac.jp

レジュメ

- コードクローンとは?
- コードクローン履歴とは?
- コードクローン履歴の抽出方法
- PostgreSQL を対象にした分析
- 今後の展開

コードクローンとは?

- プログラム中に何度も類似した箇所が現れるコード片
- 主に、安易なコピー & ペーストによって生まれる
- 大規模ソフトウェアの保守において問題となっている
  - ある一箇所のクローンにバグがあった場合，すべての類似箇所について同じ修正が必要かどうか，検討が必要
  - 若干の修正が加わっていることが多く，網羅的に把握することが困難

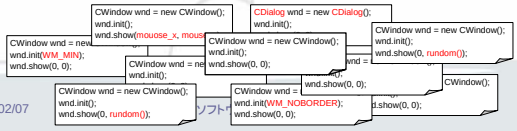

コードクローン分析

- CCFinder: クローン自動抽出システム
  - 大規模ソフトウェアに対して適用可能
  - 文法エラーに対して頑健
  - 実用的な時間で計算可能
- 解析結果から全体的な傾向は把握できる
- 実際にクローンを削除し，コード品質向上を図るのは難しい
  - 膨大なクローン
  - クローンの多様性
  - 分析者の知識

問題点1: 膨大なクローン情報

- クローンが検出されないソフトウェアは稀
  - オープンソフトウェアでも1割程度はクローン
  - 100万行規模なら10万行程度は検出される
- 「どの部分から見ていけばいいのか・・・」
  - クローンが多数含まれているところから?

問題点2: クローンの多様性

- クローンが発生した理由はさまざま
  - コピー&ペーストされたコード
  - ソースファイルの編集権限の都合，コピーせざるをえなかったコード
  - ある種のイディオム
  - デザインパターンを構成しているコード
- 区別して対処しなくてはいけない
- 「なぜクローンができたのか?」の提示が必要

問題点3: 分析者の知識

- 個々人の分析者の知識は限られている
  - 開発者と分析者が別の人
  - 開発者であっても全領域を把握している人はいない (担当外のところは細かくわからない)
- 分析者は少数

- 「なぜクローンができたのか?」
  →「わからない」

クローンのコンテキスト

- なに(What)がクローンか，は判明している
- クローンがなぜ(Why)生まれたか，を知るには・・
  - クローンがいつ(When)作成されたのか
  - クローンをだれ(Who)が作成したのか
  - そのオリジナルはどこ(Where)にあったのか
  - クローンがどのように(How)発展したかを知ること
    - どの程度の頻度でコピーされているのか
    - 各クローンに対して編集操作はどの程度行われているのか

コードクローン履歴とは?

- コードクローンの過去を提示するためのもの
  - いつコードクローンができたのか
  - だれがコードクローンを作ったのか

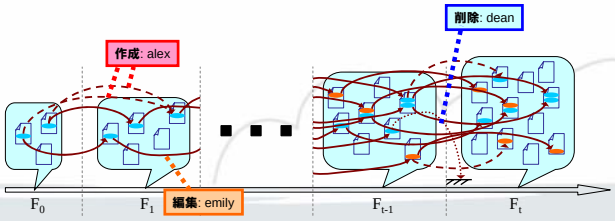

クローン履歴関係の定義

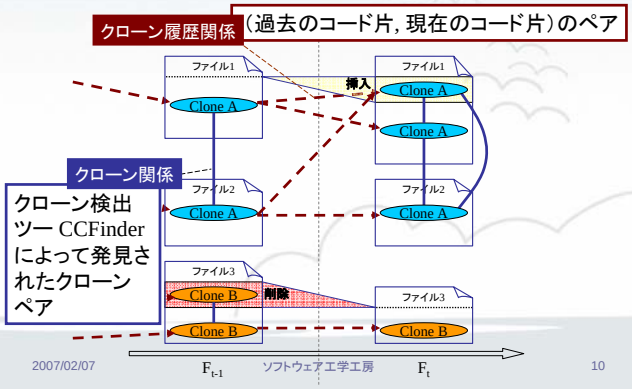

クローン履歴抽出手法(1/2)

- 版管理システム(ex. CVS, Subversion, ...)を用いて過去の時点のプロダクトを取得
- となりあう2時点間について逐次的に分析
  - F_0, F_1 をリポジトリから取得
  - F_0, F_1 間のクローン履歴関係を分析
  - F_t をリポジトリから取得
  - F_{t-1}, F_t 間を分析

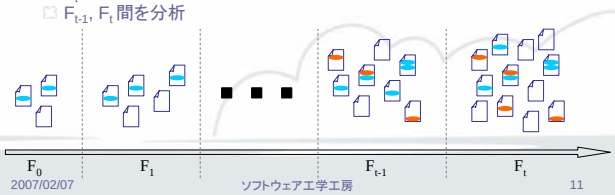

クローン履歴抽出手法(2/2)

隣あう二時点のソースコード F_{t-1}, F_t について

1. クローン分析
   クローン分析には CCFinder を使用する
   クローンの行数、総行数に対する割合も計算
2. クローン履歴関係分析
   1. HC_t: バージョン間でクローン関係に変化のない履歴関係
   2. HA_t: F_t において新規に追加されたクローンの履歴関係
   3. HT_t: F_t において片方が削除されたクローンの履歴関係
3. クローン履歴関係者分析
   CVSのコミットログから，クローンを編集した開発者を特定する

行番号の調整

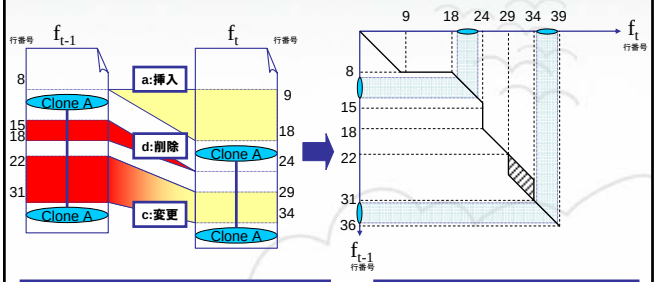

衝突時には対応行が一意でない ➡ 最小、最大の推定値を考慮

クローン履

版管理シ…いて
1. f_{t-1} に編…
2. f_t に編集…
があれば、…する

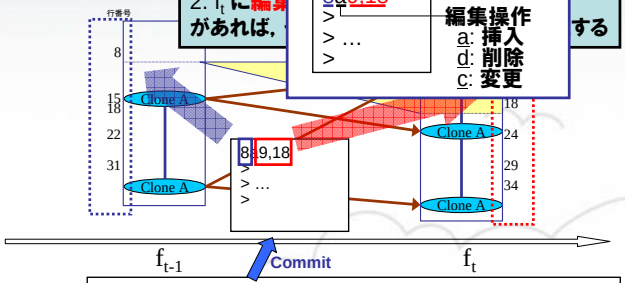

revision 1.82
date: 2003/07/20 21:56:32; author: tgl;
state: Exp; lines: +51 -29
Another round of error message editing, covering backend/commands/.

複数回のコミットがあった場合

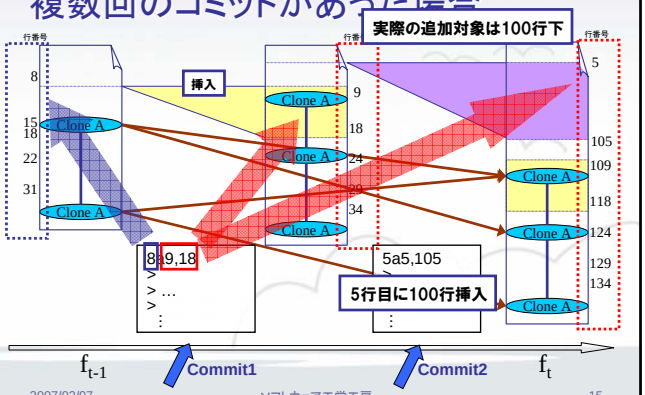

コードクローン履歴で実現できること

クローンの観点からみた成果物・開発プロセスの評価

- 危険な兆候を持つモジュールの提示
  - クローンが増えつつある → 設計に問題があるのでは
- 削除すべきクローンの提示
  - クローンの生存期間を用いた分析
  - クローンの作成者や編集者の情報からのクローン品質推定
- 開発者にもとづいたクローンの評価
  - クローンを不用意に大量コピーしている開発者
  - 正当な理由があるクローンを作成している開発者

分析事例

1. クローン量変遷のグラフとその分析
2. 分岐しているクローンの例
3. コミットと，そこで編集されたクローンの性質との関連
4. 開発者と，クローン作成回数との関連

分析対象

- 1: PostgreSQL 全体
  1998年1月から2006年1月まで
- 2-4: PostgreSQL のDB処理実装部
  (src/backend/commands)
  2004年1月から2005年1月まで

分析1: PostgreSQL 全体のコード量

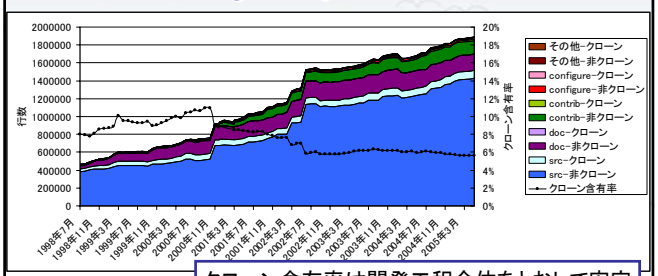

クローン含有率は開発工程全体をとおして安定

src 以下が全体の8割を占めている

分析1: PostgreSQL コア部分のコード量

2000年11月、utils 以下のクローン含有率

utils には文字コード変換用データの大量追加

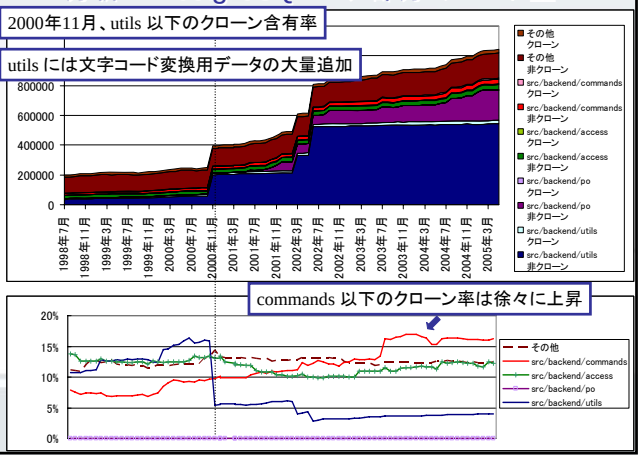

commands 以下のクローン率は徐々に上昇

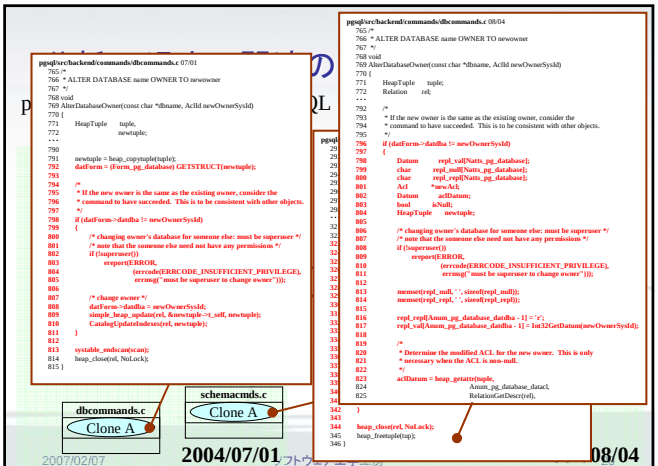

分析3: コミットから見た特性

- 大多数のコミットでは，そのとき編集されたクローンセットは一つ
- ただし，いくつかのコミットでは多数のクローンセットを一斉に編集している

大量のクローン編集時の編集内容

```
<       elog(WARNING, "DefineAggregate: attribute ¥"%s¥" not recognized",
<            defel->defname);
---
>       ereport(WARNING,
>               (errcode(ERRCODE_SYNTAX_ERROR),
>                errmsg("aggregate attribute ¥"%s¥" not recognized",
>                       defel->defname)));
```

"Another round of error message editing, covering backend/commands/."

- 機械的な変換作業
  - エラーメッセージ出力部の一括変換
- クローンの発見が困難でなかったと考えられる
  - grep 等を利用した文字列検索可能なクローン
- このようなクローンは対処優先度が低い
  - 機械的に処理をすべき対象を同定可能
  - 保守工程において障害とならない

分析4: 開発者ごとの特性

- 対象サブモジュールに関係した開
- クローンの変更に関わっていたの

全コミット数に対して，クローン追加が多い

	momjian	petere	tgl
クローン追加	6	10	32
クローン削除	2	3	17
クローン編集	35	27	135
(小計)	43	40	184
総コミット数	1317	143	1428

今後の展開

クローン解析の"とっかかり"を作る

- 分析仮説の立案
  - 履歴に基づいた分析
    - 開発者
  - 履歴と他のデータを組み合わせた分析
    - クローンそのもののメトリクス，バグ帳票，
- さまざまなソフトウェアにおいて仮説の検証
  - オープンソースソフトウェアを対象とした解析のみ
    実際の開発現場との乖離が大きい
- クローン履歴閲覧システムの作成
  - クローンの昔を容易に閲覧できる

クローン履歴閲覧システム

- 対象
  - CCFinder が対応する言語
- 動作環境
  - Eclipse 上で動作（Eclipse プラグイン）
- 主な機能
  - クローン行数の変遷グラフ
  - クローンヒストリーグラフ
  - 各時点でのクローン内容を表示
  - （どの開発者が編集したかの表示）
  - （開発者ごとのクローン追加・編集・削除回数等のメトリクス表示）