

## 版管理システムを用いたクローン履歴分析手法の提案

川口 真司<sup>†a)</sup>      松下 誠<sup>††</sup>      井上 克郎<sup>††</sup>

Clone History Analysis Using Configuration Management System

Shinji KAWAGUCHI<sup>†a)</sup>, Makoto MATSUSHITA<sup>††</sup>, and Katsuro INOUE<sup>††</sup>

あらまし ソフトウェアの保守工程における大きな問題の一つとしてクローンが指摘されている。コピーされて生成されたクローンは多少の編集が施されることが多く、そのような場合でも適切にクローンが検出できるようにするため様々なクローン検出手法が提案されている。これらの手法は最新時のソースコードに対して分析を行うが、より施された編集が少ない時点にさかのぼってクローン分析を適用することで、最新時の分析だけでは得られないクローンを得ることができる。このような過去にクローン関係にあったコードを抽出するためには過去のソースコードにおけるクローン解析結果に加えて、過去に存在したクローンが現在のソースコードのどこに対応するのかという情報、すなわちクローン履歴が必要である。本論文では、版管理システムに蓄積されたソースコードを対象としてクローンの履歴を抽出する手法を提案する。本手法ではまずクローン分析を過去の時点にさかのぼって順次適用し、各時点間のクローンについてクローン履歴を抽出する。また、PostgreSQL に対して提案手法を適用し、抽出できるクローンの有用性について考察を行う。

キーワード クローン, 履歴, ソフトウェアリポジトリ

### 1. ま え が き

近年、ソフトウェアの大規模化に伴いソフトウェアの開発工程において保守工程の占める割合は年々増加の一途をたどっている。保守工程における様々な問題の中でも非常に大きな問題の一つとして、ソースコード中に含まれる重複コード（以下、クローン）が挙げられる [1]。もしクローンの一つに不具合が見つかった場合、すべてのクローンを調査し、それぞれに対して同様の修正を施すことになる可能性が高い。この作業はソフトウェアが大規模であればあるほど困難となる。

この問題に対処するべく、これまでにクローンを検出するための様々な手法が提案されており、そのいくつかは実際に利用可能なシステムとして実用化されている [2]。このようなクローン抽出システムは、大規模なソフトウェアから自動的にクローンを発見すること

で、クローン解消作業の負担を減らすために利用されている。

しかし、実際には関連性が高いにもかかわらず、最新のバージョンを分析するだけではクローンとして抽出できないコード片が存在する。図 1 にそのようなコード片の例を示す。図 1 は時刻  $t-1$ ,  $t$  におけるソースコードに含まれるクローンを表している。時刻  $t-1$  において二つのクローンセット（互いにクローン関係にあるクローンの集合）が存在している。そして、時刻  $t$  においてクローンセット  $B$  のうち一部のクローンに編集が加えられた結果、二つのクローンセット  $B'$ ,  $C'$  に分かれている。

このとき、もしクローンセット  $B'$  に不具合が見つかった場合には、クローンセット  $B'$  だけではなく、若干の編集を加えられたクローンセット  $C'$  もまた見過ごせないコピーの一部である（以後、クローンセット  $C'$  をクローンセット  $B'$  の分岐クローンセットと呼ぶ。逆も同様）。しかし、これまでに提案されているクローン分析では現時点での情報のみを用いて分析を行うため、時刻  $t$  においてはクローンセット  $B'$  にとってクローンセット  $C'$  はクローンセット  $A'$  と同じく無関係なクローンセットではない。

このようなクローンセット同士の関係を抽出するに

<sup>†</sup> 奈良先端科学技術大学院大学情報科学研究科, 生駒市  
Graduate School of Information Science, Nara Institute of  
Science and Technology, 8916-5 Takayama-cho, Ikoma-shi,  
630-0101 Japan

<sup>††</sup> 大阪大学大学院情報科学研究科, 豊中市  
Graduate School of Information Science and Technology,  
Osaka University, 1-3 Machikaneyama-cho, Toyonaka-shi,  
560-8531 Japan

a) E-mail: kawaguti@is.naist.jp

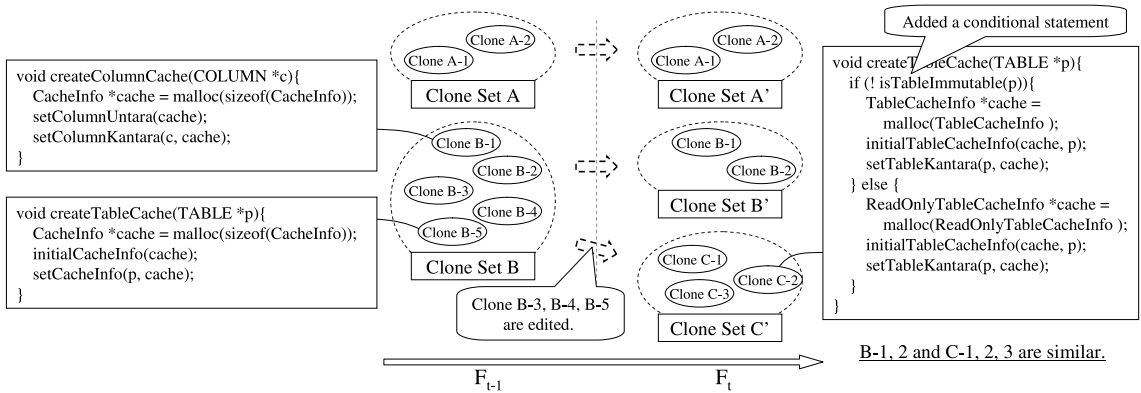


図 1 クローンの変更履歴  
Fig. 1 Clone evolution.

は、過去のソースコードにおけるクローン解析結果に加えて、過去に存在したクローンが現在のソースコードのどこかに対応しているのか、対応しているとすればそれがどこなのかという情報が必要である。

そこで、本研究では過去と現在のクローン間のつながりを分析するための手法として、クローン履歴分析を提案する。クローン履歴分析では、現時点のクローンが過去のバージョンのどのクローンに対応するのか、今あるクローンがどのような変遷をたどってきたのかを特定する。

## 2. 前提とするシステム

### 2.1 クローン分析システム

クローン分析手法には大きく分けてソースコードの字句解析に基づく手法 [1], [3], [4] と、特徴メトリックスに基づく手法 [5], [6] に分けられる。ソースコードの字句解析に基づく手法では、ソースコード中で同一の文字列を検索することでクローンの検出を行う。特徴メトリックスに基づく手法では、例えばクラスや関数、ファイルのようなプログラム中のある種の単位ごとに特徴メトリックスを定義・算出し、それらのメトリックス値が類似したものをクローンとして抽出する手法である。一般には字句解析に基づく手法の方がコストが増えるが、より細粒度なクローンを抽出できる。

本研究では、字句解析ベースの検出ツール CCFinder [1] を利用してクローン履歴の分析を行う。CCFinder は高いスケーラビリティを有しており、大規模なソフトウェアに対しても実用的な時間でクローンの抽出を行える。また、実際に様々な大規模ソフトウェアへ適用され、その有用性が確認されてい

る [7]。

クローン分析を行う際、CCFinder は空白や改行、コメント等を除去するとともに、入力テキスト中の変数名や関数名等を同一記号に縮退させる。その後、しきい値以上の長さの共通字句列を探索し、すべての対のリストを出力する。コピー & ペーストによってクローンが作られた場合、変数名などが変更されないことはまれであり、何らかの形で変数名などがコピー先のコンテキストに合致するように書き換えられることが多い。CCFinder では変数名、関数名を同一記号とみなすことによって適切にコピーを検出できる。また、長大な共通字句列が存在したときに、その部分字句列が併せて出力されるのを防ぐために、それぞれ互いに包含関係でないもののみをクローンとして出力する。

### 2.2 版管理システム

版管理システムとは CVS [8] や Subversion [9] のようにプロダクトの保管・管理に用いられるシステムである。版管理システムでは、管理下のプロダクトを任意の時点の状態に復元して取得する機能が提供されている。

冒頭で取り上げた分岐クローンセットを取得するためには、過去のソースコードにおけるクローン解析結果が必要であることは既に述べた。このような情報を得るためには、版管理システムを用いて過去のソースコードを取得し、そのソースコードに対してクローン分析手法を適用すればよい。

## 3. 諸定義

本章では分析対象となるクローンについて定義を与える。その上で異なる時点におけるコード片の対応関

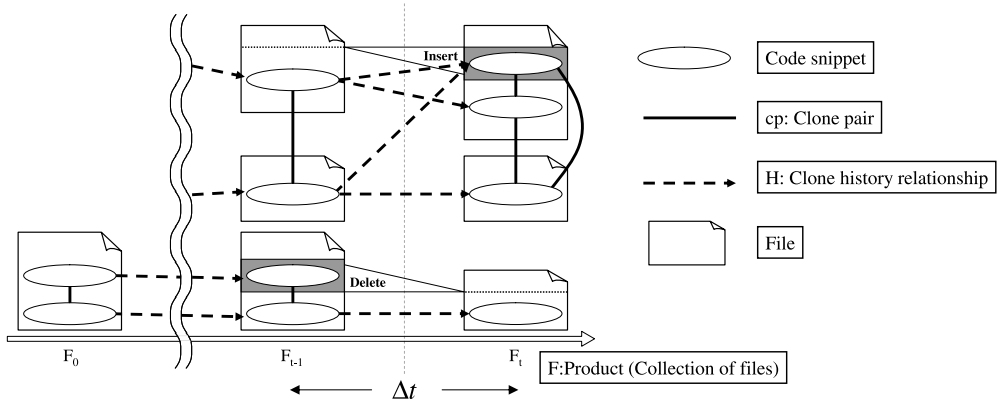


図 2 クローンとクローン履歴関係  
Fig. 2 Clone and clone history relationship.

係を表す写像の概要と、クローン履歴関係の定義について述べる。

### 3.1 クローン

クローン履歴分析のために定義したクローン履歴モデルを図 2 に示す。本モデルでは時間とともに変更されるソースコードを  $\Delta t$  ごとに区切って考える。分析の対象を版管理システムの管理下にあるソースコードファイルの集合とし、ある時刻  $t$  における集合をプロダクト (Product)  $F_t$  と呼ぶ。

今、各ファイルを文字列と考え、その連続する部分列をコード片 (Code snippet) と呼ぶ。そして、 $F_t$  に含まれるコード片のうち、共通文字列となるコード片の対  $(a, b)$  を  $F_t$  に関するクローンペア (Clone pair)、 $a$  や  $b$  をそれぞれ  $F_t$  に関するクローン (Clone) と呼ぶ。このとき  $a$  と  $b$  はクローン関係 (Clone relationship) にあるという。また、クローン関係を同値関係と考え、その同値類をクローンセット (Clone set) と呼ぶ。

### 3.2 コード片の写像

次に時刻  $t$  より  $\Delta t$  だけ過去の時点におけるプロダクト  $F_{t-1}$  に含まれるコード片に対して、 $F_t$  に含まれるコード片への写像を定義する。例えば  $F_{t-1}$  にあるコード片がもし編集されていなければ、 $F_t$  にも同じ内容のコード片が必ず存在する。また、時刻  $t$  において編集されたテキストを含むコード片についても、図 4 のように編集操作を考慮して近似的に対応関係にあるコード片候補を求められる。このような両者の関係を写像として定義する。本写像によって  $F_{t-1}$  のコード片  $r$  が空文字列でない  $F_t$  のコード片  $s$  に写像される時、 $r$  を  $s$  の親、 $s$  を  $r$  の子とする。なお写像の詳細

な定義は 4.3 で述べる。

### 3.3 クローン履歴関係

$F_{t-1}$  のコード片  $a$  と  $F_t$  のコード片  $b$  が以下のいずれかを満たす場合、 $a, b$  間にはクローン履歴関係 (Clone history relationship) があるといい、クローン履歴関係が成り立つコード片の組  $(a, b)$  の集合を  $H_t$  と表す (図 3)。  $H_t$  は以下に述べる  $HC_t, HT_t, HA_t$  の和集合として定義される。

(1)  $HC_t: (a, a')$  が  $F_{t-1}$  に関するクローンペア、 $(b, b')$  が  $F_t$  に関するクローンペアで、 $b$  が  $a$  の、 $b'$  が  $a'$  の子となる  $a', b'$  が存在する。

(2)  $HA_t: a$  は  $F_{t-1}$  に関するクローン、 $b$  は  $F_t$  に関するクローンで、 $b$  と 1 行以上重複する位置にある  $b' \in Change_{\Delta t}$  について  $(a, b')$  が  $\{F_{t-1} \cup Change_{\Delta t}\}$  についてのクローンペアである。ただし、 $Change_{\Delta t}$  は  $F_t$  のコード片の集合のうち  $F_{t-1}$  からの変更時に追加、編集された部分、 $\{F_{t-1} \cup Change_{\Delta t}\}$  は  $F_{t-1}$  全体に  $Change_{\Delta t}$  のコード片を追加した部分とする。

(3)  $HT_t: a$  は  $F_{t-1}$  に関するクローン、若しくは  $F_{t-1}$  のコード片で  $\exists x, (x, a) \in HT_{t-1}$ 。  $b$  は  $a$  の子で  $a$  と  $b$  のテキスト類似度が高い (テキスト類似度の詳細は後述)。

$HC_t$  は  $F_{t-1}, F_t$  の両方に存在する同一のクローンを表す。本定義は  $F_{t-1}$  でクローンペアを構成するクローン  $a, a'$  が、写像先の  $b, b'$  においてもクローンペアを構成している、ということを表す。




図 3 3 種類の履歴関係

Fig. 3 Three types of clone history relationship.

$HA_t$  は  $F_t$  において追加されたクローンの履歴を表す。このようなコード片は、既にあるクローンセットのどれとも等しくクローン履歴関係があると考えられる。これは、既存クローンのうちどれか一つを原本と決めることは難しく、またそうすることの意義も薄いからである。

このように本手法では  $HA_t$  を  $HC_t$  と分けて定義している。 $HC_t$  では親子関係が明示的に一意に定まるのに対して、 $HA_t$  では親が属するクローンセット内のクローンすべてとクローン履歴関係が存在することになる。そのため、 $HA_t$  と  $HC_t$  を分けることでクローン履歴関係がより正確なものとなる。

最後の  $HT_t$  は、かつてクローンを構成していたが最新版ではクローンペアであったコード片が削除、または編集されて別のクローンセットに属するようになったためにクローンでなくなった、いわば元クローンというべきコード片についてクローン履歴対応関係を抽出するための定義である。

ただし、クローンペアに一度でもなった部分すべてを追い続けるのは非効率である。また、何らかの変更が加わった場合には、その時点で過去のコードとの関連は希薄になる。そこで、テキストの変更度合を表す尺度としてテキスト類似度を定義する。このテキスト類似度はコード片中に占める同一テキストの割合を表す。そして、テキストがほとんど変更されていない場合にのみクローン履歴対応関係があるものとする。

## 4. クローン履歴関係抽出手法

### 4.1 概要

以下にクローン履歴対応関係抽出手法の手順を示す。なお、クローン履歴解析を適用する期間の始まりを時刻 0、終わりを時刻  $T$  で表し、 $C_t$  を  $F_t$  に関するクローンの集合、 $CT_t$  を  $HT_t$  を満たすコード片のうち

$F_t$  に属するコード片の集合とする。

- (0)  $H_0 = \emptyset, CT_0 = \emptyset$ .
- (1)  $t = 0$  の  $F_0$  を版管理システムから取得し、クローン解析手法を用いて  $C_0$  を求める。
- (2) for  $t = 1, 2, \dots, T$ 
  - (2-a) 版管理システムから  $F_t$  を取得し、クローン解析手法を用いて  $C_t$  を求める。
  - (2-b)  $F_{t-1}$  に関するすべてのクローンとそれぞれの子について、 $HC_t$  を求める。
  - (2-c)  $\{F_{t-1} \cup \text{Change}_{\Delta t}\}$  に対して CCFinder を適用して、 $HA_t$  を求める。
  - (2-d)  $C_{t-1}$  の残り と  $CT_{t-1}$  について  $HT_t$  を求める。

このように、本手法では解析を行う期間  $[0 \dots T]$  を  $\Delta t$  ごとに区切って考え、クローン履歴対応関係  $H_1, H_2, \dots, H_T$  を順次、抽出する。

以下に各手順の詳細、及び  $HC_t, HT_t$  の抽出時に利用する親子関係を定義するための写像について述べる。

### 4.2 各手順の詳細

本節では  $F_t$  の解析における各手順について、その詳細を述べる。なお、前節のアルゴリズムにより、時刻  $t$  についての解析を始める時点で  $t-1$  までの各情報 ( $F_{t-1}, C_{t-1}, H_{t-1}, CT_{t-1}$ ) は既知である。

(2-a) 版管理システムから  $F_t$  を取得し、クローン解析手法を用いて  $C_t$  を求める

入力:(版管理システム)

出力:  $F_t, C_t$

まず当該時刻のプログラム  $F_t$  を版管理システムから取得し、クローン解析を適用して  $C_t$  を得る。本研究においてはクローン解析手法として CCFinder を用

い、その解析結果を  $C_t$  とする。

(2-b)  $F_{t-1}$  に関するすべてのクローンについて  $HC_t$  を求める

入力:  $F_{t-1}, F_t, C_{t-1}, C_t$

出力:  $HC_t$

$F_{t-1}$  に含まれるすべてのクローンペアについて、それぞれのクローンの子が  $F_t$  に関するクローンペアとなっているかどうかを検証する。もしこの条件を満たしていれば、それぞれの親子ペアは  $HC_t$  に含まれるものとする。

(2-c)  $\{F_{t-1} \cup Change_{\Delta t}\}$  に対して CCFinder を適用して、 $HA_t$  を求める

入力:  $F_{t-1}, F_t, Change_{\Delta t}, C_{t-1}, C_t$

出力:  $HA_t$

次に  $F_{t-1}$  と  $Change_{\Delta t}$  の間にクローン解析を適用する。そして  $a \in F_{t-1}, b' \in Change_{\Delta t}$  なるクローンペア  $(a, b')$  があれば、 $b'$  が指す位置にあるクローン  $b \in C_t$  を考え  $(a, b)$  を  $HA_t$  に加える。

実際に適用する際には、編集された行とその前後 10 行を  $Change_{\Delta t}$  とする。本研究では CCFinder が検出するクローンの最小トークン数を初期設定の 30 トークンで適用しているため、差分が 30 トークンよりも小さい場合にはクローンとして検出されなくなる。前後 10 行を含めることで、このような差分を含むクローンを適切に扱うことができる。

(2-d)  $C_{t-1}$  の残り  $CT_{t-1}$  について  $HT_t$  を求める

入力:  $F_{t-1}, F_t, C_{t-1}, HC_t, HA_t, CT_{t-1}$

出力:  $HT_t$

最後に  $C_{t-1}$  に含まれるコード片のうち  $HC_t, HA_t$  内のペアに含まれないコード片、及び  $CT_{t-1}$  に含まれるコード片  $a$  について、その子  $b$  とのテキスト類似度を計測して  $HT_t$  の抽出を行う。テキスト類似度は以下の式で定義する。

$$TextSim(a, b) = \frac{2|a \cap b|}{|a| + |b|}$$

ただし  $|a| = a$  の行数、 $|a \cap b|$  は GNU diff によって同一と判定された行数とする。そしてテキスト類似度が 0.7 以上のコード片  $b$  が存在したとき、 $(a, b) \in HT_t$  とする。なお、コード片  $a$  に対して子は複数あり得るため、 $HT_t$  の条件を満たすコード片も複数存在し得る。このときには類似度が最大のコード片のみを  $HT_t$  の対象とする。

このように  $HT_t$  の判定条件は、ほぼ同一のテキストかどうかの判定となっている。もしクローン自身も何

らかの変更があった場合には、この部分は  $Change_{\Delta t}$  に含まれるため  $HA_t$  の解析対象となる。したがって  $HT_t$  の解析を行う際には、そのようなケースを考慮する必要はない。

### 4.3 コード片の写像

本研究ではコード片  $a \in F_{t-1}$  からコード片  $b \in F_t$  への写像を、各ファイルの行番号の対応関係に基づいて定義する。CCFinder の出力には、コード片がどのファイルの何文字目から始まるか、という情報が含まれているため、行番号に基づく対応関係を適用することができる。

まず時刻  $t-1$  と時刻  $t$  において、コード片  $a$  が含まれるファイルに変更がなかった場合、 $a$  の写像先  $b$  の開始行、終了行は  $a$  と全く同じとする。

次に、コード片  $a$  が含まれるファイルに何らかの編集操作が行われていた場合を考える。もし  $a$  よりも前の部分に変更箇所があれば、その内容に応じて写像先  $b$  の開始行、終了行を調整する。図 4 の Case 1 はコード片  $a$  の前で編集操作が行われた場合の例である。このとき、 $a$  の前で行われた編集操作のすべてを勘案して  $a$  の写像先  $b$  の開始行、終了行は  $a$  のそれぞれ 4 行後とする。また  $a$  に含まれる部分に変更が加えられていた場合には、その内容に応じて  $b$  の終了行を調整する。図 4 の Case 2 では  $a$  内に 2 行新しい行が追加されているため、 $b$  の終了行は  $a$  のそれに対して 2 行追加した値とする。

最後に、クローン片の端の部分で書換え操作が発生した場合について述べる。図 4 の Case 3 ではコード片  $a$  の開始行をまたがる形で書き換えされている。このような場合、「コード片  $a$  の上に 2 行挿入があった」という解釈と、「コード片  $a$  に 2 行の挿入がされた」という解釈、及びその中間（1 行がコード片の上に、1 行はコード片  $a$  中に挿入された）が成り立つ。そこで、これらすべてのケースをコード片  $a$  の子とする。このように複数の子が生成されるケースは以下の三つである。

- 開始行、終了行が編集されている箇所を含む (図 4 Case 3)
- 開始行の 1 行前に挿入
- 終了行に挿入

本研究においては  $F_{t-1} \rightarrow F_t$  への写像のみを扱うため、削除操作ではこのような複数候補を考える必要はない。

以上述べた三つの編集操作による影響をすべて足し

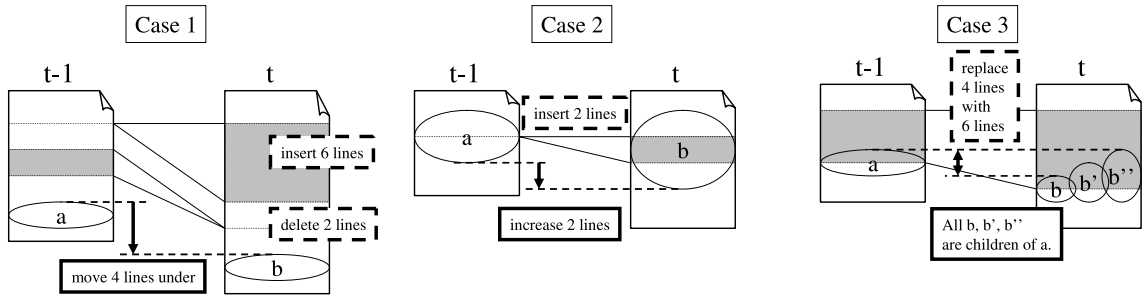


図 4 コード片の写像  
Fig. 4 Mapping of code snippet.

合わせて写像先を決定する。

### 5. 実 験

4. で述べた手法を用いることで図 1 におけるクローンセット  $B'$ ,  $C'$  間のような分岐クローンセットを抽出することができる。本章では、PostgreSQL を対象として本手法を適用し、実際に分岐クローンセットをどの程度抽出できているかの検証を行う。

#### 5.1 実験方法

PostgreSQL リポジトリの中から、ソースコードが格納されている `src` ディレクトリ以下のすべてのファイルを対象とした。これらのファイルを 2005/01/01 ~ 2005/6/30 までの 6 か月間について  $\Delta t$  を 1 週間として、計 24 時点についてクローン履歴関係の抽出を行った。

PostgreSQL を対象とした理由は、第一に提案手法で用いている CVS リポジトリが公開されていること、第二に PostgreSQL が非常に広く活用されており、開発も活発に行われているからである。

そして各バージョンに含まれるクローン  $c_t$ 、及び  $c_t$  とクローン履歴対応関係にある  $c_{t-1}$  について、 $c_t$  が属するクローンセットと  $c_{t-1}$  が属するクローンセットを考え、図 1 における Clone Set B と Clone Set B' のようにクローンセット中のクローン数が減少している箇所を“クローン減少箇所”として抽出した。

次に、それぞれのクローン減少箇所において、そこに含まれるクローンセットが分岐クローンセットであるかどうかの判定を人手により行い、もし分岐クローンセットが存在すればクローン履歴関係を正しく抽出できているかどうかを検証した。

このように本実験ではクローンセット内のクローン数の減少が確認できたクローンセットのみに着目した。

表 1 クローン減少箇所の調査結果  
Table 1 Clone decreasing places.

Branched clone set	4
Branched clone set (miss)	0
Deleted clone set	5
Useless clone set	15

これは、実際に開発されているソフトウェアには数百から数万もの大量のコードクローンが存在し、更に CCFinder では検出できない潜在的に存在するコードクローンもかなりの数に上るため、すべてのクローンセットを検証することは現実的ではないからである。

#### 5.2 実験結果

実験手法を適用した結果、クローン減少箇所は計 24 箇所あった(表 1)。そのうち四つのクローンセットに分岐クローンセットが存在し (Branched clone set)、それらのクローン履歴関係が適切に抽出できていることを確認した。そして、実際には分岐クローンセットであるにもかかわらず、分岐クローンセット内のクローンについてクローン履歴関係が適切に抽出できていなかったケース (Branched clone set (miss)) は存在しなかった。また、5 箇所がクローンセット内のクローンのいくつか削除されたもの (Deleted clone set)、残り 15 箇所はそもそもクローンとして有用でないものであった (Useless clone set)。

有用でないクローンとは、printf 文が連続している部分や数十、数百の定数定義が続いている部分などのように、単純な構文が 10 行以上連続している部分を指す。CCFinder は構文木として同形であればクローンとして検出を行うため、このような単純な構文が繰り返されている箇所もクローンとして検出される。しかし、このような部分はそもそもクローンとして検出する必要がなく、実際にユーザにとっても中身を検討

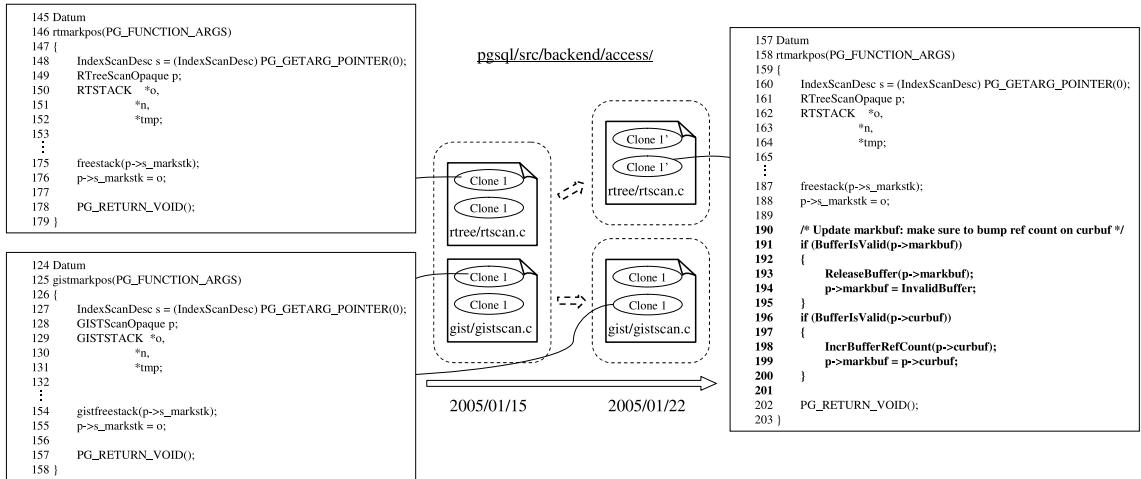


図 5 過去にクローンペアであったコード片の例  
 Fig. 5 Example of code snippets used to be clone pair.

する価値がない。したがって、本実験においてはそのような箇所を評価から除外している。

図 5 に分岐クローンセットとなったクローン減少箇所の例を示す。2005 年 1 月 15 日の時点では四つのコード片がクローンであった。1 週間後、そのうちの二つに編集が加えられ、それぞれ独立したクローンセット Clone 1 と Clone 1' になった。図 5 右側は新しい Clone 1' の抜粋である。このように Clone 1' は太字で示した処理が追加されただけで、本質的には Clone 1 同様のことを行っており、これらのコード片の間には依然として強い類似性がある。本手法により過去の履歴をたどることで、これらのコード片の関係を抽出することができる。

## 6. 関連研究

クローンの履歴を調査する研究としては、Kim らの研究 [10] が挙げられる。Kim らは我々の手法と同様に CCFinder を用いてクローンの履歴抽出を試みており、クローンセットの生存期間に着目して生存期間の分布がどのようになっているか、生存期間の違いによってクローンにどのような特徴があるかを調査している。Kim らの研究では、履歴抽出の対象となっているのはクローンセットであり、個々のクローンについての詳細な履歴は対象としていない。それに対して本研究では一つひとつのクローンを単位とした履歴を抽出しており、より具象的な解析を行っている。また、本研究の目的は分岐クローンセットの発見による要修正箇所

の提示という開発者に焦点を当てたものであるのに対して、Kim らの研究はクローンを生存期間という観点から分類することで、クローンの性質を探索することを目的としている。

任意のコード片ではなく、関数を対象とする履歴追跡手法もいくつか提案されている [11], [12]。Godfrey ら [11] は関数のペアを対象とした五つの評価基準を定義している。これらは関数名の類似度、関数宣言部の類似度、LOC 等のメトリックスの類似度、呼出し元や呼出し先の類似度、及び上記四つをユーザが組み合わせたものから構成され、ユーザが指定した計算尺度に基づいてバージョン間の関数同士の対応関係を求めている。また Antoniol ら [13] は、クラス単位での履歴追跡手法を提案している。

このほかの関連研究として版管理システムを利用して何らかの有益な情報を引き出そうとする研究が挙げられる。これまでに、版管理システムに存在する開発履歴から関連性の高い関数を提示する研究 [14], [15] や、バグ修正支援 [16]、行数の変化や開発者ごとの編集を行った行数などを図示する試み [17], [18] が行われている。

## 7. むすび

本論文では、クローン履歴解析手法を提案した。また PostgreSQL を対象に適用実験を行い、クローン履歴関係を用いて、かつてクローンだったコード片が正しく抽出できること、抽出したコード片は派生元の

コード片と強い関連をもっていることを確認した。

今後の課題としては、まず、より目的に沿った形でクローン履歴情報閲覧システムの構築が挙げられる。クローンの履歴は開発プロセス全体の把握やクローン発生源の特定、クローンの管理等様々な応用が考えられるが、抽出結果を活用するためには分析した結果を目的に沿う形で表示する必要がある。

また分析手法そのものについても評価、改善が必要である。クローンの履歴となり得るもののうち本手法で分析できる範囲、できない範囲を厳密に調査する必要がある。また既存の類似手法との結果比較も重要であると考えられる。

現時点で判明している取得できないクローン履歴としては、一度削除されたクローンが、その後の変更により復活したことがある。前述したとおりすべてのバージョン間においてクローン履歴分析をするのは現実的ではないため、例えば削除されたクローンについても逐次記録していき、過去の削除されたクローンも差分解析の対象として加えることが考えられる。しかし、この手法は削除されたクローン数によっては膨大な計算量を要するため、既存の開発パターンを調査して削除されたクローン数の推移傾向を調査したい。

謝辞 本研究において多大な御協力を頂いた産業技術総合研究所神谷年洋氏に深く感謝する。また、本論文の一部は文部科学省「e-Society 基盤ソフトウェアの総合開発」及び日本学術振興会の科学研究費補助金基盤研究(A)(課題番号:17200001)の助成を得た。

## 文 献

- [1] T. Kamiya, S. Kusumoto, and K. Inoue, "CCFinder: A multi-linguistic token-based code clone detection system for large scale source code," *IEEE Trans. Softw. Eng.*, vol.28, no.7, pp.654-670, 2002.
- [2] E. Burd and J. Bailey, "Evaluating clone detection tools for use during preventative maintenance," *Proc. 2nd IEEE Int. Workshop on Source Code Analysis and Manipulation (SCAM 2002)*, pp.36-43, Montreal, Canada, Oct. 2002.
- [3] B.S. Baker, "A program for identifying duplicated code," *Computing Science and Statistics*, vol.24, pp.49-57, 1992.
- [4] Z. Li, S. Lu, S. Myagmar, and Y. Zhou, "CP-Miner: A tool for finding copy-paste and related bugs in operating system code," *Proc. Sixth Symposium on Operating System Design and Implementation (OSDI'04)*, pp.289-302, 2004.
- [5] J.H. Johnson, "Identifying redundancy in source code using fingerprints," *Proc. Centre for Advanced Studies on Collaborative research (CASCON'93)*, pp.171-183, Toronto, Ontario, Canada, Oct. 1993.
- [6] E. Merlo, G. Antoniol, M.D. Penta, and V.F. Rollo, "Linear complexity object-oriented similarity for clone detection and software evolution analyses," *Proc. 20th IEEE Int. Conf. on Software Maintenance (ICSM'04)*, pp.412-416, Chicago, Illinois, USA, Sept. 2004.
- [7] 門田暁人, 佐藤慎一, 神谷年洋, 松本健一, "コードクローンに基づくレガシーソフトウェアの品質の分析," *情報処理*, vol.44, no.8, pp.2178-2188, Aug. 2003.
- [8] CVS, <http://www.cvshome.org/>
- [9] Subversion, <http://subversion.tigris.org/>
- [10] M. Kim and D. Notkin, "Using a clone genealogy extractor for understanding and supporting evolution of code clones," *Proc. 2nd Intl. Workshop on Mining Software Repositories (MSR 2005)*, pp.17-21, Saint Louis, Missouri, May 2005.
- [11] M.W. Godfrey and L. Zou, "Using origin analysis to detect merging and splitting of source code entities," *IEEE Trans. Softw. Eng.*, vol.31, no.2, pp.166-181, Feb. 2005.
- [12] N. Gold and A. Mohan, "A framework for understanding conceptual changes in evolving source code," *Proc. 19th Intl. Conf. on Software Maintenance (ICSM 2003)*, pp.22-26, Amsterdam, 2003.
- [13] G. Antoniol, M.D. Penta, and E. Merlo, "An automatic approach to identify class evolution discontinuities," *Proc. 7th Int. Workshop on Principles of Software Evolution (IWPSE'04)*, pp.31-40, Kyoto, Japan, Sept. 2004.
- [14] T. Zimmermann, P. Weissgerber, S. Diehl, and A. Zeller, "Mining version histories to guide software changes," *IEEE Trans. Softw. Eng.*, vol.31, no.6, pp.429-445, June 2005.
- [15] D. Cubranic, G.C. Murphy, J. Singer, and K.S. Booth, "Hipikat: A project memory for software development," *IEEE Trans. Softw. Eng.*, vol.31, no.6, pp.446-465, June 2005.
- [16] C.C. Willams and J.K. Hollingsworth, "Automatic mining of source code repositories to improve bug finding techniques," *IEEE Trans. Softw. Eng.*, vol.31, no.6, pp.466-480, June 2005.
- [17] S.G. Eick, T.L. Graves, A.F. Karr, A. Mockus, and P. Schuster, "Visualizing software changes," *IEEE Trans. Softw. Eng.*, vol.28, no.4, pp.396-412, April 2002.
- [18] C. Collberg, S. Kobourov, J. Nagra, J. Pitts, and K. Wampler, "A system for graph-based visualization of the evolution of software," *Proc. ACM symposium on Software visualization (SOFTVIS 2003)*, pp.77-86, San Diego, California, USA, June 2003.

(平成 18 年 1 月 11 日受付, 3 月 29 日再受付)





川口 真司

平 13 阪大・基礎工・情報卒．平 18 同大大学院博士課程了．同年奈良先端大・情報・情報システム・助手．博士（情報科学）．ソフトウェアプロセス，ソフトウェア開発支援の研究に従事．情報処理学会会員．



松下 誠

平 5 阪大・基礎工・情報卒．平 10 同大大学院博士課程了．同年同大・基礎工・情報・助手．平 14 阪大・情報・コンピュータサイエンス・助手．平 17 阪大・情報・コンピュータサイエンス・助教授．博士（工学）．ソフトウェアプロセス，オープンソースソフトウェア開発の研究に従事．情報処理学会，日本ソフトウェア科学会，ACM 各会員．



井上 克郎（正員）

昭 54 阪大・基礎工・情報卒．昭 59 同大大学院博士課程了．同年同大・基礎工・情報・助手．昭 59～61 ハワイ大マノア校・情報工学科・助教授．平元阪大・基礎工・情報・講師．平 3 同学科・助教授．平 7 同学科・教授．平 14 阪大・情報・コンピュータサイエンス・教授．博士（工学）ソフトウェア工学の研究に従事．情報処理学会，日本ソフトウェア科学会，IEEE，ACM 各会員．