Refactoring Support Environment Based on Code Clone Analysis

Yoshiki Higo[†], Toshihiro Kamiya[††], Shinji Kusumoto[†], and Katsuro Inoue[†]

[†] Graduate School of Information Science and Technology, Osaka University, Toyonaka-shi, 560-8531, Japan
[††] PRESTO, Japan Science and Technology Agency

Abstract

Recently, code clone has been regarded as one of factors that make software maintenance more difficult. A code clone is a code fragment in a source code that is identical or similar to another. For example, if we modify a code fragment which has code clones, it is necessary to consider whether we have to modify each of its code clones. It is generally said that code clone is one of *bad-smells* to be refactored. There are two ways of maintenance support for code clones. One is to comprehend and manage code clones, and the other is to remove them. For the former support, we have developed code clone analysis environment **Gemini**. For the latter support, several methods have been proposed. But, it is difficult to apply them to large software because of various reasons such as high time complexity. In this paper, we propose a method that detects refactoring-oriented code clone in practical use time. And, we develop a characterization of code clones by some metrics, which suggests how to remove them. Then, we develop refactoring support environment **Aries**. We expect Aries can support software maintenance more effectively.

keyword

Refactoring, Code clone, Software maintenance

論　文

コードクローンを対象としたリファクタリング支援環境

肥後　芳樹[†]　　神谷　年洋[††]　　楠本　真二[†]　　井上　克郎[†]

Refactoring Support Environment Based on Code Clone Analysis

Yoshiki HIGO[†], Toshihiro KAMIYA[††], Shinji KUSUMOTO[†], and Katsuro INOUE[†]

あらまし
作業の効率を悪化させている一要因として，コードクローンがあげられる．コードクローンとはソースコード中に存在する同一，または類似したコード片のことである．例えば，あるコード片にバグが含まれていた場合，そのコード片のコードクローン全てについて修正の是非を考慮する必要がある．このような理由によりソフトウェアからコードクローンを取り除くことはソフトウェアの保守性や複雑度などの面からみて有効である．これまでに，いくつかのコードクローン集約手法が提案されているが，解析時間コストが高いなどの理由により，大規模なソフトウェアに対しては適用が難しかった．本論文では，大規模ソフトウェアに対しても適用可能なコードクローンの集約支援手法の提案を行う．具体的には，実用的な時間でソースコード中から集約に適したコードクローンを検出し，メトリクスを用いてコードクローンの特徴を定量化し，それに基づきコードクローンの絞り込みを行う．本手法を用いることによって，各コードクローンに適した集約方法を提示することで，ユーザは効率的なリファクタリング作業を行なうことができる．また提案手法をリファクタリング支援環境 Aries として実装し，適用実験を行なうことで，本手法の有用性を確認した．

キーワード　リファクタリング，コードクローン，ソフトウェア保守

1. まえがき

近年，コードクローンがソフトウェア保守を困難にしている 1 つの要因といわれている．コードクローンとはソースコード中に存在する同一，または類似したコード片のことである．コードクローンが生成される原因としてはさまざまな理由が考えられるが，その最も大きな原因の 1 つとしてコピーアンドペーストによる修正，拡張作業があげられる．あるコード片にバグが含まれていた場合，そのコード片のコードクローン全てに対して修正の是非を考慮する必要がある．このような作業は，特に大規模ソフトウェアでは非常に手間のかかる作業である．従ってコードクローン検出の効率化はソフトウェア開発・保守工程の改善において有効である．これまでにコードクローンを自動的に検出するためのさまざまな手法が提案されている [2] [4] [5] [10] [13] [15] ．

その手法の 1 つとして，我々はコードクローン検出ツール **CCFinder** [10] と分析環境 **Gemini** [16] を開発してきている．ユーザは Gemini を用いることによりコードクローンの解析，ソースコードの修正を容易に行なうことができる．さまざまなコードクローンの把握・管理手法が提案されている一方で，ソフトウェアからコードクローンを取り除く研究はそれほど活発に行なわれてはいない．これまでにいくつかの提案がされているが [11] [12]，それらは時間的コストが非常に高いものであったりと，大規模ソフトウェア開発・保守現場での適用は困難である．

本論文では，実用的な時間でソースコード中からリファクタリングに適したコードクローンを検出し，さらに，検出したコードクローンの特徴をメトリクスを用いて定量化する手法を提案する．そして，提案手法に基づき，リファクタリング支援環境 Aries の試作を行なう．最後に適用実験を行ない，Aries の有効性を評価する．

[†] 大阪大学 大学院情報科学研究科，豊中市
Graduate School of Information and Science Technology, Osaka University, Toyonaka-shi, 560-8531 Japan
[††] 科学技術振興機構 さきがけ
PRESTO, Japan Science and Technology Agency

2. 準　　備

2.1 コードクローンの定義

あるトークン列中に存在する 2 つの部分トークン列 α，β が等価であるとき，α と β は互いにクローンであるという．またペア（α，β）をクローンペアと呼ぶ．α，β それぞれを真に包含する如何なるトークン列も等価でないとき，α，β を極大クローンと呼ぶ．また，クローンの同値類をクローンセットと呼ぶ．ソースコード中でのクローンを特にコードクローンという [9]．

2.2 CCFinder

CCFinder [10] はプログラムのソースコード中に存在する極大クローンを検出し，その位置をクローンペアのリストとして出力する．検出されるコードクローンの最小トークン数はユーザが前もって設定できる．

CCFinder のコードクローン検出手順（ソースコードを読み込んで，クローンペア情報を出力する）は以下の 4 つの STEP からなる．

STEP1（字句解析）：ソースファイルを字句解析することによりトークン列に変換する．入力ファイルが複数の場合には，個々のファイルから得られたトークン列を連結し，単一のトークン列を生成する．

STEP2（変換処理）：実用上意味を持たないコードクローンを取り除くこと，及び，些細な表現上の違いを吸収することを目的とした変換ルールによりトークン列を変換する．例えば，この変換により変数名は同一のトークンに置換されるので，変数名が付け替えられたコード片もコードクローンであると判定することができる．

STEP3（検出処理）：トークン列の中から指定された長さ以上一致している部分をクローンペアとして全て検出する．

STEP4（出力整形処理）：検出されたクローンペアについて，ソースコード上での位置情報を出力する．

2.3 CCShaper

CCShaper [7] [8] は CCFinder の検出したコードクローンから，構造的なまとまりを持った部分をリファクタリングに適したコードクローンとして抽出する．図 1 はその例を示している．図 1 では，A と B の 2 つのコード片が示されている．A と B それぞれの灰色の部分は，その部分が A と B の間の最大長のコードクローンであることを示している．コード片 A ではいくつかのデータがリスト構造の先頭から順に連続して格納されている．一方コード片 B では，リスト構造の後方から順に連続してデータが格納されている．これら 2 つのコード片には，リスト構造を扱う共通のロジック（for 文）が含まれているが，コード片の最初と最後には，偶然クローンとなった部分（代入文）も含まれてしまっている．集約を目的とした場合，灰色の部分全体よりも for 文のみをコードクローンとして抽出する方が望ましい．CCShaper ではこのような場合，灰色で示されたコードクローンから構造的なまとまりを持った部分，つまり for 文の部分のみを抽出する．

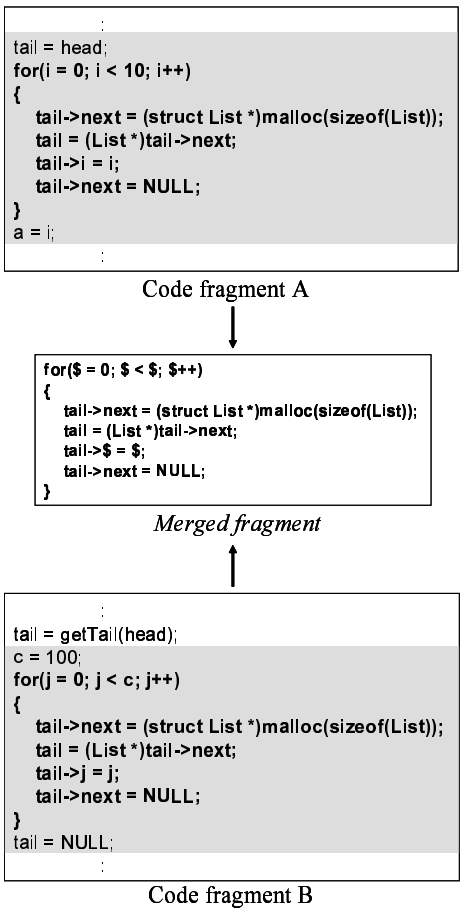

図 1　コードクローン集約の例
Fig. 1　Example of merging two code fragments

3. 提 案 手 法

上述のように，CCFinder が検出するコードクローンには，リファクタリングの適用対象にできないものも多く含まれる．CCShaper ではこのようなコードクローンの大部分を取り除いてはいるが，ユーザが自ら抽出されたコードクローンの除去方法を考えなければ

ならないため，リファクタリングを行なうには非効率的である．本論文ではこの除去方法の決定支援を行なうために，メトリクスを用いたコードクローンの絞り込み手法を提案する．以下ではまず，3.1 節において，本手法で提案するメトリクスを説明し，3.2 節では，提案したメトリクスを用いてのコードクローンの絞り込み方法を，例を用いて説明する．なお，本手法では，2.3 節で述べたような言語における構造的なまとまりをもったコードクローンを対象としている．

3.1 集約支援を目的としたメトリクス

これまでに様々なリファクタリングパターン [6] が提案されており，以下の 7 種類のリファクタリングパターンがコードクローンを除去するために用いることができる．

- Extract Class,
- Extract Method,
- Extract SuperClass,
- Form Template Method,
- Move Method,
- Parameterize Method,
- Pull Up Method.

本手法ではこれらのパターンを用いてコードクローンの集約を行なうリファクタリングの支援を目的とする．これらのパターンは，コードの一部を新たなモジュールとして抽出するものと，モジュールの移動を行なうものに分類できる．

まず，新たなモジュールとして抽出を行なう場合を “Extract Method” を例にとって考える．本来は “Extract Method” は長過ぎるメソッドや，複雑な処理の一部分に対して適用することによって，コードの可読性，保守性を向上させることができる．しかし，コードクローンに対して適用することにより，重複したコード片を集約することも可能である．コード片を新たなメソッドとして再定義することになるため，抽出部分は周囲との結合度が低いことが望ましい．つまり，抽出部分の外側で定義された変数を抽出部分でできるだけ用いていないことが望ましい．もしそのような変数を用いていた場合は，抽出したメソッドの引数として与える，あるいはメソッドの返り値として返す必要がある．抽出部分とその周囲の結合度を計測するために **NRV(S)**(the Number of Referred Variables) と **NSV(S)**(the Number of Substituted Variables) の 2 つのメトリクスを定義した．ここでは，クローンセット S は n 個のコード片 $f_1,\ f_2,\ \cdots,\ f_n$ を含んでおり，コード片 f_i では s_i 個の外部定義の変数を参照しており，t_i 個の外部定義の変数に対して代入を行なっているとする．この時 $NRV(S)$ と $NSV(S)$ はそれぞれ次の式で表される．

$$NRV(S) = \frac{1}{n}\sum_{i=1}^{n} s_i, \qquad NSV(S) = \frac{1}{n}\sum_{i=1}^{n} t_i,$$

直観的には，$NRV(S)$ はクローンセット S に含まれる各コード片内で参照されている外部定義変数の平均数を示し，同様に $NSV(S)$ は代入が行なわれている変数の平均数を示す．

次に，モジュールの移動を行なう場合を “Pull Up Method” を例にとって考える．“Pull Up Method” とは，ある親子クラス関係が存在した場合に，子クラスに存在するメソッドを親クラスに引き上げることである．もし共通の親クラスを持つ複数の子クラスに重複したメソッドが存在した場合は，それらを共通の親クラスに引き上げることによって集約を行なうことが可能である．つまり重複したメソッドを含むクラスは共通の親クラスを継承している必要がある．そのため，クローンセットのクラス階層内における位置関係を計測する．これについては，メトリクス **DCH(S)**(the Dispersion of Class Hierarchy) を定義する．すでに示したように，クローンセット S はコード片 $f_1,\ f_2,\ \cdots,\ f_n$ を含んでいるとする．またクラス C_i はコード片 f_i を含んでいるクラスとする．もしクラス $C_1,\ C_2,\ \cdots,\ C_n$ が共通の親クラスを持つ場合は，その共通の親クラスの中で，最もクラス階層的に下位に位置するクラスを C_p で表すとする．また $D(C_k,\ C_h)$ はクラス C_k と C_h のクラス階層における距離を表すとする．この時，

$$DCH(S) = max\ \{D(C_1,\ C_p),\ \cdots,\ D(C_n,\ C_p)\}$$

と表される．直観的には，メトリクス $DCH(S)$ はクローンセット S に含まれる各コード片間のクラス階層内における最大の距離を示す．例えば，クローンセット S 中の全てのコード片が 1 つのクラス内に存在する場合は $DCH(S)$ の値は 0，あるクラスとその直接の子クラス内に存在する場合は $DCH(S)$ の値は 1 となる．例外的に，コードクローンが存在するクラスが共通の親クラスを持たない場合は $DCH(S)$ の値は-1 とする．このメトリクスは，JDK のクラスライブラリ等の修正不可能なクラスを除外したクラスを対象として

計算される．これにより，分析対象のソフトウェア内に存在するメソッドを修正不可能なクラスに引き上げようとする場合は，$DCH(S)$ の値は-1 となり，そのようなリファクタリングが不可能であることがわかる．

3.2 メトリクスを用いた絞り込み

本節では，提案したメトリクスを用いてのコードクローンの絞り込み方法を例を用いて説明する．絞り込みでは前節で提案した３つのメトリクスに加え，$LEN(S)$, $POP(S)$, $DFL(S)$ [16] の 3 つのメトリクスも用いる．各メトリクスの簡単な説明を以下に示す．

LEN(S): クローンセット S に含まれるコード片のトークン数の平均値を表す．この値が大きいクローンセットは除去の候補となる．

POP(S): クローンセット S に含まれるコード片の数を表す．この値が大きいほど同形のコード片がより多くソースコード中に存在することになり，除去の候補となる．

DFL(S): クローンセット S を再構築した場合に減少するトークン数の予測値を表す．ここでの再構築とは，S 内のコード片集合から抜き出した共通のロジックを実装するサブルーチンを作り，各コード片をそのサブルーチンの呼び出しに置き換えることである．$DFL(S)$ は，再構築前のトークン数 (すなわち，S に含まれる全てのコード片のトークン数の和) から，再構築後のトークン数 (すなわち，全てのサブルーチン呼び出しのトークン数の和+共通ロジックを実装するサブルーチンのトークン数) を引いたものとして定義される．$DFL(S)$ は S を除去した場合のサイズ面における効果の指針として捉えることができるため，この値の大きいクローンセットは除去の候補となる．

以降，これらのメトリクスを用いた絞り込みについて，例を用いて説明する．

(1) “Pull Up Method”

例えば，以下のような条件が考えられる．

(PC1) 対象となる単位はメソッド本体,

(PC2) $DCH(S)$ の値が 1 以上.

“Pull Up Method” はメソッドが対象であるので，条件 (PC1) が必要である．また，重複したメソッドを含むクラスが共通の親クラスを継承している必要があることから条件 (PC2) が必要である．この条件でクローンセットの絞り込みを行なった場合，抽出されたクローンセットは以下の４つのグループに分類される．

(PG1) 単純に親クラスに引き上げるのみで集約可能なクローンセット.

(PG2) 外部定義の変数を引数として追加した後，親クラスに引き上げることによって集約可能なクローンセット.

(PG3) 外部定義の変数を引数として追加し，さらに返り値として返す処理を追加した後，親クラスに引き上げることによって集約可能なクローンセット.

(PG4) その他，すなわち，(PG1)〜(PG3) 以上の工夫が必要であるクローンセット.

(2)“Extract Method”

“Extract Method” を行なう際の条件としては例えば，以下のものが上げられる．

(EC1) 対象となる単位は文単位,

(EC2) $DCH(S)$ の値が 0,

(EC3) $NSV(S)$ の値が 1 以下,

“Extract Method” とはメソッド内のコード片に対して適用されるので，(EC1) が必要である．また，全てのコードクローンが同一のクラス内に存在する場合は容易に集約が可能であるので，条件 (EC2) を考慮している．コードクローンの内部において，外部定義変数に対して代入を行なっている場合は，その変数を引数として与え，返り値として返し，メソッドの呼び出し元に反映させなければならない．このような変数が複数あった場合は新たなデータクラスを定義し，そのオブジェクトを介して値を受け渡す必要がある．もしこのような変数が１つの場合は単に return 文を用いて返すだけで良く，容易に集約を行なうことができるので，条件 (EC3) を考慮している．

この条件でクローンセットの絞り込みを行なった場合，抽出されたクローンセットは以下の４つのグループに分類される．

(EG1) 単純にコードクローンをメソッドとしてくくり出すのみで集約可能なクローンセット.

(EG2) コードクローン内部で使用されている外部定義の変数を抽出するメソッドの引数とすることによって集約可能なクローンセット.

(EG3) コードクローン内部で使用されている外部定義の変数を抽出するメソッドの引数とし，さらに返り値として返すことによって集約可能なクローンセット.

(EG4) その他，すなわち，(EG1)〜(EG3) 以上の工夫が必要なクローンセット.

(3) その他

例として上記の２つの条件を述べたが，絞り込みに使える条件はこれらの条件に限らず様々なものが考えられる．例えば “Extract Method” を行なう場合は，結

合度を $NSV(S)$ だけでなく $NRV(S)$ も併用して用いることができる．これによりある個数以下の引数しか持たないようなメソッドとしてくくり出すことができるクローンセットを得ることができる．また他のパターンに対しては，例えば，“Move Method” を行なう場合はクラス階層を考慮する必要がないので，メトリクス $DCH(S)$ では絞り込みを行なわず，メソッドとクラスとの結合度を計る $NRV(S)$ や $NSV(S)$ で絞り込みを行なうことが考えられる．また，除去することによって 10,000 トークン以上の減少がみこまれるクローンセットのみを $DFL(S)$ によって絞り込む，手間をかけずにリファクタリングを行ないたいので $POP(S)$ が 5 以下のクローンセットのみを対象とするなどといったことが可能である．つまり本手法では，用いる 6 つのメトリクスについて，ユーザが興味のあるメトリクスの上限や下限，またはその両方を用いて絞り込みを行なうことができる．

4. リファクタリング支援環境: Aries

4.1 概　　要

提案手法を，リファクタリング支援環境 **Aries** として実装した．現在のところ対象は Java 言語としている．また，構造的なコードクローンの検出には，既存のコードクローン検出ツール CCFinder と CCShaper を用いている．つまり，CCFinder を用いて，トークンの列としてのコードクローンを検出し，その中に含まれる構造的なまとまりを，CCShaper を用いて抽出している．Java 言語を対象としているため抽出する構造的なまとまりは以下の 12 種類である．

宣言 : class { }, interface { }
メソッド : メソッド本体, コンストラクタ, スタティックイニシャライザ
文 : if, for, while, do, switch, try, synchronized

図 2(a)，2(b) は Aries のスナップショットである．ユーザは図 2(a) の *Main Window* においてリファクタリング対象となるクローンセットの絞り込みを行なうことができる．また個々のクローンセットについてより詳細な情報を *Clone Set Viewer* を用いて得ることができる．

4.2 インターフェース

Aries の各インターフェースを簡単に紹介する．

4.2.1 Metric Graph View

図 3 を例にとって *Metric Gragh View* を説明する．

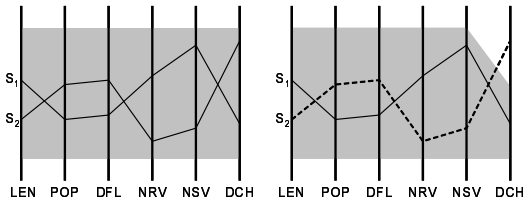

(a) 絞り込み前　　(b) 絞り込み後

図 3　Metric Graph を用いた絞り込み
Fig. 3　Refining clone sets using Metric Graph

Metric Graph View ではメトリクス毎に 1 本の並行座標軸が用意される．また，クローンセット毎に 1 本の折れ線が描画される．この例では 2 つのクローンセット S_1 と S_2 が描画されている．図 3(a) は *Metric Gragh View* の初期状態を表している．各並行座標軸には初期値として，その並行座標軸が表すメトリクス値を全て含むように上限と下限が設定される．クローンセットはそのメトリクス値の全てが各並行座標軸の上限と下限の間に収まっている場合は選択状態となり，それ以外の場合は非選択状態となる．図中の網がかかった部分が各並行座標軸の上限と下限の間を表している．つまり，初期状態では，すべてのクローンセットの各メトリクス値はその並行座標軸の上限と下限の間に収まっており，選択状態となっている．ユーザは各並行座標軸の上限，下限付近でマウスの左ボタンを押し，そのまま上下にドラッグすることによって，各上限，下限を変更可能である．例えば，図 3(b) ではユーザがメトリクス $DCH(S)$ の上限を下げた状態を表している．この状態では $DCH(S_2)$ が上限より大きくなってしまっており，クローンセット S_2 は非選択状態となっている．*Metric Graph View* を用いたクローンセットの選択・非選択状態は *Clone Set List* に反映される．

4.2.2 Checkbox of Used Variable

Checkbox of Used Variable では，ユーザはどの種類の変数をメトリクス $NRV(S)$，$NSV(S)$ の要素としてカウントするのかを決定することができる．変数は以下の 6 種類に分類されている．

- 同クラスのフィールド変数,
- 親クラスのフィールド変数,
- インターフェースのフィールド変数,
- this 参照,
- super 参照,

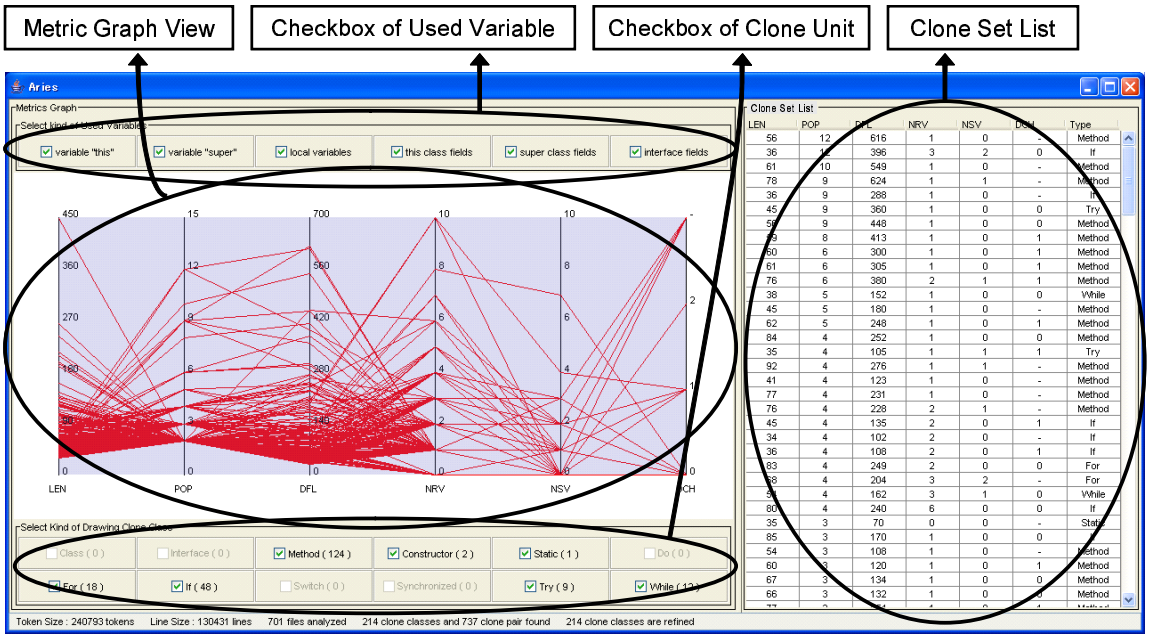

(a) Main Window

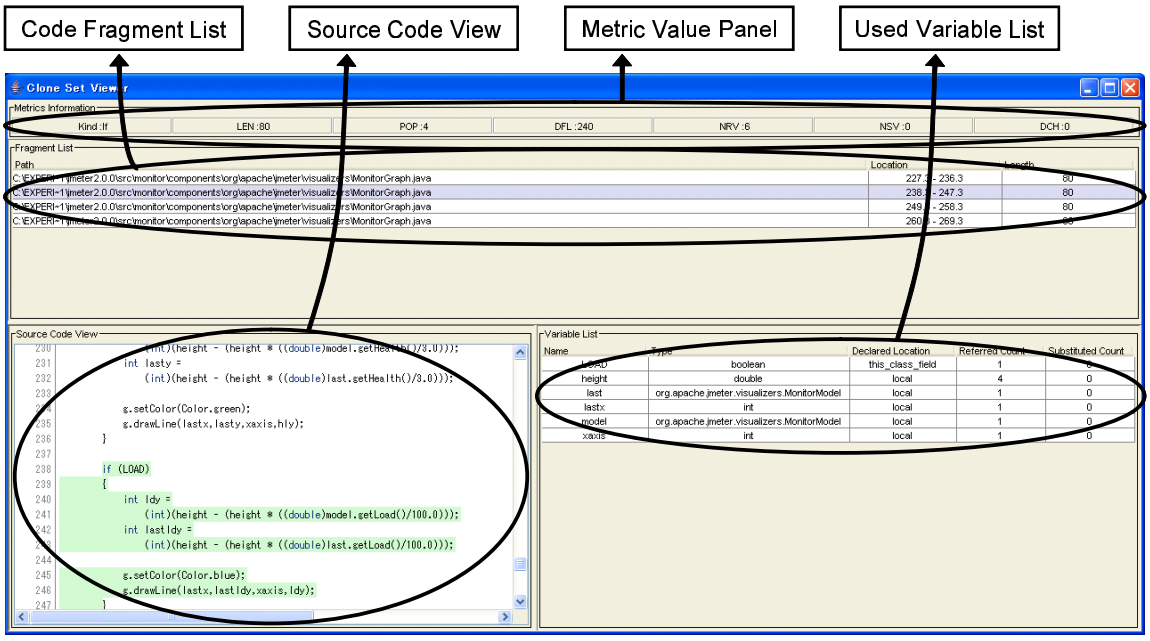

(b) Clone Set Viewer

図 2　Aries のスナップショット
Fig. 2　Snapshots of Aries

- ローカル変数.

4.2.3 Checkbox of Clone Unit

Checkbox of Clone Unit では，ユーザはどの単位のクローンセットを *Metric Graph View* における選択の対象とするのかを決定することができる．選択できる単位は 4.1 節で述べた 12 種類である．

4.2.4 Clone Set List

Clone Set List は *Metric Graph View* において選択状態にあるクローンセットの一覧を表示する．*Metric Graph View* において非選択状態となっているクローンセットはこのリストには表示されない．つまり，ユーザが *Metric Graph View* において興味のあるメトリクスを用いて絞り込みを行なった結果，全てのメトリクス値が絞り込みの範囲内となっているクローンセットのみがこのリストに表示される．例えば，*Metric Graph View* が図 3(a) の状態の場合は，*Clone Set List* にはクローンセット S_1 と S_2 が表示されているが，図 3(b) の場合はクローンセット S_1 のみが表示されることになる． このように *Metric Graph View* での選択・非選択状態を用いることによってユーザは，絞り込みに該当するクローンセットの一覧を *Clone Set List* 上で得ることができる．また，このリストに表示されているクローンセットは各メトリクス値に基づいて昇順・降順にソートが可能である．そしてこのリストに表示されている任意のクローンセット上でマウスの左ボタンをダブルクリックすることにより，そのクローンセットに関するより詳細な情報を示す *Clone Set Viewer*（図 2(b)）が表示される．

4.2.5 Metrics Value Panel

Metrics Value Panel はそのクローンセットの各メトリクス値を示す.

4.2.6 Code Fragment List

Code Fragment List はそのクローンセットに含まれるコード片の一覧を示す．各コード片について，そのコード片を含むファイルへのパス，ファイル内での位置（開始行，開始列，終了行，終了列），そのコード片のトークン数が表示される．

4.2.7 Source Code View

Source Code View は *Code Fragment List* において選択されたコードクローン片周辺のソースコードを示す．コードクローンは強調して表示される．

4.2.8 Used Variable List

Used Variable List は *Code Fragment List* において選択されたコード片内で用いられているが，その外部で定義されている変数の参照，代入回数を示す.

5. 適用実験

5.1 概　　要

Aries の有効性を評価するために，オープンソースの Java ソフトウェアである Ant [1] に対して適用実験を行なった．実験では，まず Ant のソースコードから構造的なコードクローンを検出し，次に，前述の絞り込み条件に従って，2 つのリファクタリングパターン “Pull Up Method” と “Extract Method” を適用するのに適したコードクローンを選出する．選出されたコードクローンについて，リファクタリングパターンが適用できるかを評価する．

実験の対象となった Ant のソースコードは 627 ファイルから成り，総行数は約 18 万行である．この適用実験では，検出する構造的なコードクローンの最小トークン数は 30 とした．Ant から構造的なコードクローンを検出するのに要した時間は約 1 分であった(注1)．この実験では Ant に対して，“Pull Up Method” と “Extract Method” の適用を試みた．コードクローン検出の結果 Aries は Ant から 154 個のクローンセットを検出した.

また，“Pull Up Method” と “Extract Method” の適用を試みたクローンセットの数は以下のとおりである.

All detected clones	154
“Pull Up Method”	20
“Extract Method”	59

“Pull Up Method” と “Extract Method” を適用するための絞り込み条件は 3.2 節で説明したものと同様である．以下 5.2 節，5.3 節では，絞り込んだ結果についてより詳細に述べる.

5.2 “Pull Up Method”

本節では “Pull Up Method” の条件の適用結果について述べる．すでに述べたように，絞り込んだ結果，20 個のクローンセットを抽出した．この 20 個のクローンセットのに含まれる全てのコードクローンのソースコードを閲覧し，3.2 節で述べた (PG1)〜(PG4) の 4 つのグループに分類した.

まず，(PG1) に分類されたクローンセットは全く存在しなかった.

10 個のクローンセットが (PG2) に分類された.

(注1)：Aries の実行環境: OS FreeBSD4.9, CPU Xeon 2.8GHz, メモリ 4GB

```
private void getCommentFileCommand(Commandline cmd) {
    if (getCommentFile() != null) {
        /* Had to make two separate commands here because
           if a space is inserted between the flag and the
           value, it is treated as a Windows filename with
           a space and it is enclosed in double quotes (").
           This breaks clearcase.
        */
        cmd.createArgument().setValue(FLAG_COMMENTFILE);
        cmd.createArgument().setValue(getCommentFile());
    }
}
```

図 4　(PG2) に分類されたコードクローンの例
Fig. 4　Example of Pull Up Method in (PG2)

図 4 はその一例を示している．このコードクローンでは，“this” が省略されている，なぜなら “getCommentFile” は同クラス内に定義されたメソッドだからである．このメソッド内では変数 “this” と “FLAG_COMMENTFILE” が外部定義である．つまり，このコードクローンに対して “Pull Up Method” を適用する場合はこれら 2 つの変数を引数として追加する必要がある．

```
public void verifySettings() {
    if (targetdir == null) {
        setError("The targetdir attribute is required.");
    }
    if (mapperElement == null) {
        map = new IdentityMapper();
    } else {
        map = mapperElement.getImplementation();
    }
    if (map == null) {
        setError("Could not set <mapper> element.");
    }
}
```

図 5　(PG3) に分類されたコードクローンの例
Fig. 5　Example of Pull Up Method in (PG3)

2 個のクローンセットが (PG3) に分類された．図 5 はその一例を示している．このコードクローンにおいて代入を行なわれている変数 “map” は外部で定義されている (“setError” は共通の親クラスで定義されたメソッド)．よって，このメソッドを親クラスに引き上げるには，この変数を引数として追加し，さらに代入結果をメソッド呼出元に反映させるために return 文を追加する必要がある．

8 個のクローンセットが (PG4) に分類された．図 6 はその一例を示している．このコードクローンでは，メソッド “checkOptions” を呼び出している．メソッド “checkOptions” は同クラス内で定義されている (“getProject”，“getViewPath”，“getLocation” は共通の親クラスで定義されている)．また，このメソッド呼び出しの引数となっている変数 “commandLine” はこの

```
public void execute() throws BuildException {
    Commandline commandLine = new Commandline();
    Project aProj = getProject();
    int result = 0;

    // Default the viewpath to basedir if it is not specified
    if (getViewPath() == null) {
        setViewPath(aProj.getBaseDir().getPath());
    }

    // build the command line from what we got. the format is
    // cleartool checkin [options...] [viewpath ...]
    // as specified in the CLEARTOOL.EXE help
    commandLine.setExecutable(getClearToolCommand());
    commandLine.createArgument().setValue(COMMAND_CHECKIN);

    checkOptions(commandLine);

    result = run(commandLine);
    if (Execute.isFailure(result)) {
        String msg = "Failed executing: " +
                     commandLine.toString();
        throw new BuildException(msg, getLocation());
    }
}
```

図 6　(PG4) に分類されたコードクローンの例
Fig. 6　Example of Pull Up Method in (PG4)

コードクローンの内部で定義されており，このクローンに対して “Pull Up Method” を適応することは困難である．しかし，“checkOptions” は各子クラスで定義されていることから，“Form Template Method” [6] を適応することが可能であると考えられる．手順としては，このコードクローンを親クラスにそのままの形で引き上げ，次に親クラスに “checkOptions” の抽象メソッドを定義する．

5.3　“Extract Method”

絞り込みの結果，59 個のクローンセットを抽出した．抽出した全てのコードクローンのソースコードを閲覧し，3.2 節で述べた (EG1)〜(EG4) の 4 つのグループに分類した．

```
if (!isChecked()) {
    // make sure we don't have a circular reference here
    Stack stk = new Stack();
    stk.push(this);
    dieOnCircularReference(stk, getProject());
}
```

図 7　(EG1) に分類されたコードクローンの例
Fig. 7　Example of Extract Method in (EG1)

3 個のクローンセットが (EG1) に分類された．図 7 はその一例を示している．このコードクローンでは外部定義の（ローカル）変数を全く用いていなかった．このコードクローンはそのままメソッドとして抽出するのみでリファクタリング可能である．

34 個のクローンセットが (EG2) に分類された．図 8

```
if (javacopts != null && !javacopts.equals("")) {
    genicTask.createArg().setValue("-javacopts");
    genicTask.createArg().setLine(javacopts);
 }
```

図 8　(EG2) に分類されたコードクローンの例
Fig. 8　Example of Extract Method in (EG2)

はその一例を示している．このコードクローンでは外部定義の変数 “javacopts” と “genicTask” を参照している．“javacopts” は同クラス内に定義されたフィールドであるのに対し，“genicTask” はローカル変数であるため，このコードクローンをメソッドとして抽出するためには，この変数を引数とする必要がある．

```
if (iSaveMenuItem == null) {
    try {
        iSaveMenuItem = new MenuItem();
        iSaveMenuItem.setLabel("Save BuildInfo To Repository");
     } catch (Throwable iExc) {
        handleException(iExc);
     }
}
```

図 9　(EG3) に分類されたコードクローンの例
Fig. 9　Example of Extract Method in (EG3)

15 個のクローンセットが (EG3) に分類された．図 9 はその一例を示している．このコードクローンでは外部定義の変数 “iSaveMenuItem” に対して代入処理を行なっている．よって，このコードクローンをメソッドとして抽出するには，この変数を抽出するメソッドの引数とし，さらに返り値として返す必要がある．

```
if (name == null) {
    if (other.name != null) {
        return false;
    }
} else if (!name.equals(other.name)) {
    return false;
}
```

図 10　(EG4) に分類されたコードクローンの例
Fig. 10　Example of Extract Method in (EG4)

7 個のクローンセットが (EG4) に分類された．図 10 はその一例を示している．このコードクローンでは return 文が使用されている．これにより，このコードクローンをメソッドとして抽出する場合は，上記以上の工夫が必要である．

6. 関 連 研 究

Komondoor ら [11] や Krinke ら [12] はプログラム依存グラフを用いる手法を提案している．この手法では，グラフ上での類似部分がコードクローンとして検出される．この手法ではソースコード中の制御依存やデータ依存を解析しているため，非常に精度が高いのが特徴である．さらに，reordered クローンや interwined クローンなどの特殊なコードクローンを検出することができる．このようなコードクローンは本手法では検出することが不可能である．ただし，グラフ構築の時間コストが $O(n^2)$ である(注2) ため，大規模ソフトウェアに対しての適用は難しい．それに対して本手法では，簡単な意味解析までにとどめているため，例え対象が大規模であっても実用的な時間で解析を行なうことが可能である．実際に，J2SDK Standard Edition のソースコード (約 127 万行) に対して Aries を実行したところ約 4 分 20 秒で構造的なクローンを検出することができた(注3)．

また Balazinska ら [3] は，サイクロマチック数 [14] など 21 種類のメトリクスを用い，各メトリクス値の一致や近似に基づきコードクローン検出を行なっている．各メトリクスは関数・メソッドに対して計測されるので，検出されるコードクローンもその単位に限定される [13]．本手法では，関数・メソッド単位だけではなく対象言語の構造的なまとまり全てをコードクローンの単位としているので，Balazinska らの手法よりもリファクタリング候補のコードクローンをより多く検出すると期待できる．

7. ま と め

本論文では，コードクローンを対象としたリファクタリング手法を提案した．また，提案手法をリファクタリング支援ツール Aries として実装した．Aries ではプログラム依存グラフを構築するなどの複雑な解析を行なっておらず，簡単な意味解析までにとどめているため，大規模なソフトウェアに対しても実用的な時間で適用可能である．また，適用実験では，Aries を用いて，オープンソースのソフトウェアである Ant のソースコードから，リファクタリング手法の “Pull Up Method” と “Extract Method” を適用可能なコードクローンを特定することができた．

現在の解析はリファクタリングの可能性について述べているが，積極的にすべきかの判断はしていない．今後は，ソフトウェアの品質の面からリファクタリングの是非を判断するように拡張を行なう予定である．また，影響波及解析を行ない，リファクタリングによる影響波及箇所の特定を試みる．これにより，より効率的なリファクタリング支援環境を提案することがで

(注2)：n はソースコード中の文や式の数
(注3)：Aries の実行環境: OS FreeBSD4.9, CPU Xeon 2.8GHz, メモリ 4GB

きると考えられる．

謝辞 本研究は一部，文部科学省リーディングプロジェクト「eSociety 基盤ソフトウェアの総合開発」，文部科学省科学研究費若手研究 (B)(課題番号: 15700031) の支援を受けている．

文　献

[1] Ant, `http://ant.apache.org`, 2003.

[2] B.S. Baker, *Parameterized duplication in strings: algorithms and an application to software maintenance*, SIAM Journal on Computing, vol.26, no.5 pp.1343-1362, 1997.

[3] M. Balazinska, E. Merlo, M. Dagenais, B. Lague and K. Kontogiannis, "Advanced clone-analysis to support object-oriented system refactoring", *Proc. the 7th Working Conference on Reverse Engineering*, pp98-107, Brisbane, Australia, Nov. 2000.

[4] I.D. Baxter, A. Yahin, L. Moura, M.S. Anna, and L. Bier, *Clone Detection Using Abstract Syntax Trees*, Proc. International Conference on Software Maintenance 98, pp368-377, Bethesda, Maryland, Mar. 1998.

[5] S. Ducasse, M. Rieger, and S. Demeyer, *A Language Independent Approach for Detecting Duplicated Code*, Proc. International Conference on Software Maintenance 99, pp109-118, Oxford, England, Aug. 1999.

[6] M. Fowler, *Refactoring: improving the design of existing code*, Addison Wesley, 1999.

[7] Y. Higo, Y. Ueda, T. Kamiya, S. Kusumoto and K. Inoue, *On software maintenance process improvement based on code clone analysis*, Proc. 4th International Conference on Product Focused Software Process Improvement, pp.185-197, Rovaniemi, Finland, Dec. 2002.

[8] 肥後 芳樹, 神谷 年洋, 楠本 真二, 井上 克郎, "コードクローン解析に基づくリファクタリングの試み", 情報処理学会論文誌, Vol.45, No.5,pp1357-1366.

[9] 井上克郎, 神谷年洋, 楠本真二, "コードクローン検出法", コンピュータソフトウェア, vol.18, no.5, pp.47-54, Sep. 2001.

[10] T. Kamiya, S. Kusumoto, and K. Inoue, *CCFinder: A multi-linguistic token-based code clone detection system for large scale source code* IEEE Transactions on Software Engineering, vol.28, no.7, pp.654-670, Jul. 2002.

[11] R. Komondoor and S. Horwitz, *Using slicing to identify duplication in source code*, Proc. the 8th International Symposium on Static Analysis, pp.40-56, Paris, France, Jul. 2001.

[12] J. Krinke, *Identifying similar code with program dependence graphs*, Proc. the 8th Working Conference on Reverse Engineering, pp.301-309, Suttgart, Germany, Oct. 2001.

[13] J. Mayland, C. Leblanc, and E.M. Merlo *Experiment on the automatic detection of function clones in a software system using metrics*, Proc. International Conference on Software Maintenance 96, pp.244-253, Monterey, California, Nov. 1996.

[14] T.J. McCabe, C.W. Butler *design complexity measurement and testing*, Communication of the ACM 32, pp1415-1425, Dec. 1989.

[15] M. Rieger, S. Ducasse, *Visual detection of duplicated code*, Proceedings ECOOP Workshop on Experiences in Object-Oriented Re-Engineering, pp.75-76, Brussels, Belgium, Jul. 1998.

[16] 植田泰士, 神谷年洋, 楠本真二, 井上克郎 "開発保守支援を目指したコードクローン分析環境", 電子情報通信学会論文誌 D-I, Vol.86-D-I, No.12, pp.863-871, Jun. 2003.

（平成年月日受付，月日再受付）

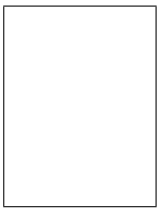

肥後　芳樹

平 14 阪大・基礎工・情報中退．平 16 同大大学院博士前期課程修了，現在同大大学院博士後期課程 1 年．コードクローン分析の研究に従事．情報処理学会会員．

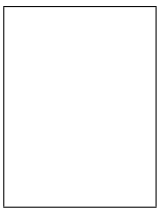

神谷　年洋　（正員）

平 8 阪大・基礎工・情報中退．平 13 同大大学院博士課程了．現在，科学技術振興機構 さきがけ研究者．博士 (工学)．オブジェクト指向関連技術，ソフトウェア保守 (メトリクス，コードクローン)，認知科学に関する研究に従事．情報処理学会，電気学会，IEEE，各会員．

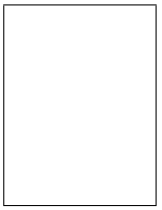

楠本　真二　（正員）

昭 63 阪大・基礎工・情報卒．平 3 同大学院博士課程中退．同年同大・基礎工・情報・助手．平 8 同大講師．平 11 同大助教授．平 14 阪大・情報・コンピュータサイエンス・助教授．博士 (工学)．ソフトウェアの生産性や品質の定量的評価，プロジェクト管理に関する研究に従事．情報処理学会，IEEE，JFPUG，PM 各会員．

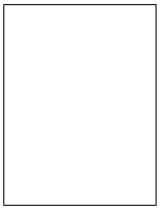

井上　克郎　（正員）

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〜昭 61 ハワイ大マノア校・情報工学科・助教授．平 1 阪大・基礎工・情報・講師．平 3 同学科・助教授．平 7 同学科・教授．博士 (工学)．平 14 阪大・情報・コンピュータサイエンス・教授．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．