修士学位論文

題目

ハッシュ値比較による Java バイトコードに含まれるライブラリの検出手法

指導教員
井上 克郎 教授

報告者
矢野 裕貴

平成 29 年 2 月 7 日

大阪大学 大学院情報科学研究科
コンピュータサイエンス専攻 ソフトウェア工学講座

平成 28 年度 修士学位論文

ハッシュ値の比較による Java バイトコードに含まれるライブラリの検出手法

矢野 裕貴

内容梗概

ソフトウェア開発では，開発コストの削減のためにライブラリの利用が一般的に行われている．ライブラリを利用することによって不具合を取り込んでしまうことがあるため，利用中のライブラリの出自に関する情報は常に管理しておく必要がある．しかし，ソフトウェアの中には，ライブラリのコードをコピーして内部に含んでいるものが存在する．このような再利用方法が取られている場合，利用中のライブラリに関する情報の管理が難しくなりがちである．

本研究では，Java のソフトウェアの内部に含まれるライブラリを検出する手法を提案する．Java においては，ソースコードではなく，ソースコードからコンパイラによって生成された，クラスファイルと呼ばれる Java バイトコードを含むファイルの再利用が主流である．そこで本手法では，バイトコードから抽出した情報をもとに計算したハッシュ値の比較に基づき，ライブラリの再利用を検出する．また，バイトコードから情報を抽出する際にパッケージ名に関する情報を取り除くことによって，パッケージリネームの検出を可能にしている．

提案手法の有効性を確認するために，再利用したライブラリを内部に含んでいるようなソフトウェアに対して提案手法の適用を行った．その結果，ソフトウェアのドキュメント中に再利用されたと記録されているライブラリを特定できていることを確認した．さらに，記録されていなかったライブラリの再利用も検出することができた．

主な用語

ソフトウェア再利用
Java バイトコード
Jar With Dependencies

目 次

1　まえがき

ソフトウェア開発において，外部のプロジェクトからコードを再利用することが一般的に行われている．また，ライブラリと呼ばれる再利用を行うためのコードも盛んに開発が行われており，数多くのオープンソースライブラリ (OSS ライブラリ) が配布されている．ライブラリの利用などによるコードの再利用によって，ソフトウェアの開発コストを大幅に削減することが可能になる一方で，再利用元にバグや脆弱性が含まれていた場合，開発中のプロジェクトにも同様の不具合を取り込んでしまう危険性が存在する．このような場合，利用の中止や修正版へのアップデートなどの対応を取ることで不具合を取り除かなくてはならない．そのためには再利用元のプロジェクト名とそのバージョン番号を正しく把握し，管理しておくことが重要となる．しかし，実際には再利用しているライブラリに関する情報が適切に管理されていないプロジェクトや，再利用しているライブラリが脆弱性を含んでいるプロジェクトが多数存在していることがわかっている [1].

再利用元がわからなくなってしまったコードの再利用元を特定する既存研究は数多く存在し，例えばソースコードが利用可能な場合には，コードの一部などを入力することによって一致するコード片を含むソースコードを検索する Inoue らの Ichi Tracker[2] や，再利用されたと思われるファイルを入力とし，ソースコードの類似度によって出自を高速に検索する川満らの手法 [3] などを利用することが可能である，

本研究の対象としている Java では，ソースコードではなくクラスファイルと呼ばれるバイトコードを再利用することが可能である．実際に，Heinemann らがオープンソースの Java のプロジェクトに対して行った調査によると，ソースコードの再利用よりもバイトコードの再利用が多く行われていることが判明している [4]．このような場合には，Davice らの Software Bertillonage[5] のような JAR（Java アーカイブ) の比較手法が出自検索に利用可能である．しかし，Java では様々なライブラリに由来する複数のファイルを，jar ファイルとしてまとめたものを配布することが一般的に行われている．このような場合には，どのファイルが再利用されたものなのか特定することが難しく，Davice らの手法は利用することができない．

複数のライブラリが含まれる jar ファイルから，バイトコードの比較に基づいて再利用元を特定する手法としては，Ishio らの Software Ingredients[6] が存在する．この手法を用いることで，例えば，Java のソフトウェアの内部から脆弱性が含まれるライブラリが検出された場合，利用をやめるなどの対処をとることが可能となる．しかし，この手法にはバイトコードの再利用を行う際に，パッケージ名が変更されていた場合には検出することができないという問題点がある．様々な理由によってパッケージのリネームは行われ，さらにそのようなコンポーネントは再利用元情報の管理が難しくなると考えられる．

本研究では，入力された Java ソフトウェアをあらかじめ作成しておいたデータベースと

比較することによって，内部に含まれるライブラリを検出する手法を提案する．提案手法では，クラスファイル (Java バイトコードを含むファイル) ごとに特徴となるような情報を抽出し，それを用いて計算したハッシュ値を比較に用いる．ハッシュ値の計算にパッケージ名の情報を用いないことによって，パッケージがリネームされていても出自が同じクラスファイルであれば同じハッシュ値となるようにしている．それを用いて比較を行うことによってパッケージのリネームを検出することを可能とする．

以降，2 章では本研究の背景について述べる．3 章では提案手法について述べる．4 章では提案手法の性能を評価するための実験について述べる．5 章ではオープンソースソフトウェアに含まれるライブラリの再利用を検出するケーススタディについて述べる．6 章では本研究のまとめと今後の課題を述べる．

2　背景

2.1　コードの再利用

ソフトウェア開発では，既存のプログラムからコードを再利用することが一般的になっている．本研究で対象としている Java におけるコードの再利用の方法としては，ソースコードの再利用とバイナリ再利用の 2 種類が存在する．Heinemann らがオープンソースの Java のプロジェクトに対して行った調査によると，ソースコードをコピーして再利用する whilte-box reuse よりも，バイナリを再利用する black-box reuse の方が優勢であったことが報告されている [4]．Java のライブラリにおいては，ライブラリ間の依存関係も複雑に存在しているため 1 つのライブラリを利用するために複数のライブラリを間接的に利用しなくてはならなくなる場合が多い．そのため，利用者があまり中身を意識することなく利用できるバイナリでの再利用が主流となっていると考えられる．

再利用を行うことによって，同じ動作をするプログラムを開発する必要がなくなり，開発コストを削減することが可能となる．また，再利用されたコードは比較的十分な検証がなされているため安全性が高いと考えられる．実際に，Mohagheghin らが行った調査により，システム内部に含まれる再利用されたコンポーネントに含まれている不具合の数はオリジナルのコンポーネントと比較して少ないということが判明している [7]．

しかし，再利用によってバグやセキュリティ上の脆弱性を含むコードを取り込んでしまう恐れもある．再利用したコードに不具合が発見された場合，利用の中止や修正の適用などの対応をとる必要がある．そのためには，再利用したコードに関する情報を適切に管理しておくことが必要となる．しかし，Xia らの調査により，約 24 %のプロジェクトにおいて再利用したライブラリの名前またはバージョン番号がわからない状態になっていると報告されている [1]．さらに，脆弱性を含むライブラリを使用しているソフトウェアや，実際に脆弱性の影響を受ける可能性の高い部分の機能を使用しているソフトウェアの例も Plate らによって開発されたツールによって検出されている [8]．また，再利用されたコードには手を入れづらく，プロジェクトの開発を進める上での障害となってしまうこともあると考えられる．

このような問題を回避するために，再利用を分析する研究が数多く行われている．

2.2　再利用分析

Java ではライブラリによるコードの再利用が主流である．実際に，Bavota らの調査 [9] によって Java のプロジェクトが利用するライブラリの数は開発が進むにつれて増加していくことが判明している．ライブラリの利用の分析を行うことによって，効率的で安全なライブラリの利用が可能になり，ソフトウェア開発の助けになると考えられる．

Kula らはプロジェクトにおける利用中のライブラリのアップデート履歴を可視化する手

法を提案した [10]．Maven リポジトリーにおけるライブラリの利用状況の統計情報と組み合わせて使用することで，アップデートを行うべきコンポーネントを特定することが可能になるとされている．

関連して我々の研究グループでは，ライブラリの利用状況の統計情報を組み合わせで検索可能なツールを提案した [11]．あるライブラリをアップデートしようとするときにはライブラリの後方互換性の問題により，他のライブラリが動作しなくなってしまう危険性がある．利用実績のある組み合わせを提示し，それに従って他のライブラリのアップデートも考慮することによって互換性による問題が発生するリスクを低減させることが可能になると考えられる．

これらの研究では，ライブラリの利用状況に関する情報を Maven というプロジェクト管理ツールの POM ファイルと呼ばれる設定ファイルから取得している．しかし，実際にはソースコードやバイナリをコピーすることで内部に取り込んでいるソフトウェア (ライブラリ) が数多く存在するため，設定ファイルからは取得不可能な再利用情報も考慮することが望ましい．そのため，ソフトウェアの内部に含まれるコードの情報を用いて，再利用の検出を行う研究と組み合わせることが必要であると考えられる．ここからは，再利用元の検出を行う関連研究をいくつか紹介する．

ソースコードが入手可能な場合には，コードの一部などを入力することによって一致するコード片を含むソースコードを検索する Inoue らの Ichi Tracker[2] や，LSH アルゴリズムを利用しソースファイル間の類似度を高速で推定する川満らのツール [3] などが再利用の分析に利用可能である．

ソースコードが利用できない場合には，バイナリファイルやその他の情報を用いて再利用分析を行う．Teyton らは jar ファイルに含まれるパッケージの名前を用いてライブラリ名を特定することによって，Java のソフトウェアにおける利用ライブラリの移行を検出する手法を提案している [12]．この手法を用いることでソフトウェア内部に含まれるライブラリ名の一覧の特定が可能であるが，バージョン番号までは特定することができない．

Davice らの Software Bertillonage[5] では，jar ファイル内部に含まれるクラスファイル (バイナリファイル) に含まれるシグネチャに関する情報を抽出し，比較を行うことによって，jar ファイル間の類似度を定義している．この手法を用いると，入力ソフトウェアと類似度が最も高いソフトウェア，つまり再利用元と考えられるソフトウェアの名前とバージョンを特定することが可能である．そのため，ライブラリを利用する際に jar ファイルの形のままで利用している場合には，そのバージョンを特定する方法として Software Bertillonage は優れている．しかし，全ての利用中のライブラリの jar ファイルを展開し，ソフトウェア固有のファイルとともに 1 つの jar ファイルにまとめているソフトウェアも存在する．このようなファイルは fat jar や jar with dependencies などと呼ばれ，Maven Assembly plug-in[13] や

eclipse[1] の実行可能 jar ファイルを作成する機能などといった一般的な手段によって簡単に生成することが可能である．そのため，複数ライブラリに由来するクラスファイルが混ざった jar ファイルが出回ることは珍しくない．

Ishio らの Software Ingredients[6] はコンポーネントが jar ファイルにまとめられていない場合でも同様にソフトウェア内部に含まれるライブラリの一覧の検出が可能なツールである．Software Bertillonage と同様にクラスファイルから抽出したシグネチャの情報を用いて jar ファイルの比較を行い，一致するクラス数の割合を計算した後，その値が大きい順に優先度をつける貪欲法と呼ばれるアルゴリズムによって再利用元を推定する．このツールは再利用元のライブラリからパッケージ名が変更されていた場合には検出することが不可能である．本研究では Software Ingredients で用いられていた方法をベースに，パッケージがリネームされていても再利用されたコンポーネントとして検出可能な手法を提案する．

2.3 パッケージのリネーム

Java では，クラス名の衝突を回避するために，パッケージと呼ばれる名前空間が存在する．Java のソフトウェア (.jar ファイル) に含まれているバイトコード (. クラスファイル) は，図 1 のようにパッケージで表されるディレクトリ構造の中に配置されるような構造になっている．これによって同じ名前のクラスが同一のソフトウェアに含まれていても区別することができ，両方利用することが可能となる．例えば図 1 では Example.jar の内部に X という名前のクラスが 2 つ存在するが，packageA.X，packageB.X といったようにそれぞれ区別することができる．

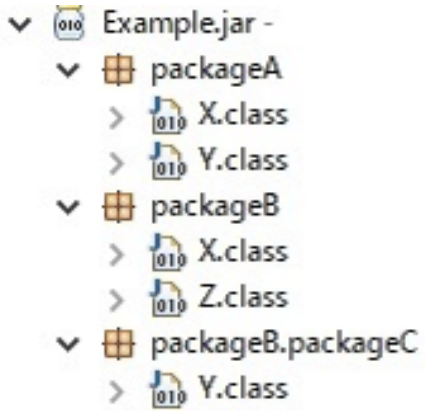

図 1: Java Archive(JAR) の構造

[1] https://eclipse.org/

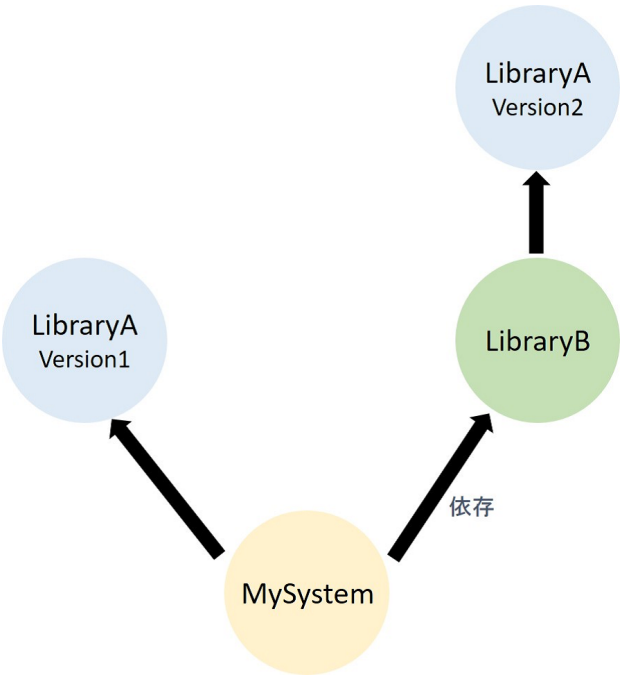

図 2: バージョンの競合

ライブラリを利用するにあたって，そのパッケージ名を変更するような場合が存在する．実際に，Maven Shade Plugin[14] や，Jar Jar Links[2] といった，利用するライブラリに含まれているパッケージの名前を自動で変更できるツールも開発されている．パッケージのリネームを行う理由としては以下の 2 つが考えられる．

- バージョンの競合
  図 2 のように利用ライブラリとその依存関係中でバージョン競合が発生する場合がある．図中の頂点はシステムやライブラリ，矢印は依存関係を示しており，開発中のプロジェクトでライブラリ A と，ライブラリ B を利用しようとしている状況を表している．ここで，自身のプロジェクトがライブラリ A のバージョン 1 を利用していて，ライブラリ B が内部でライブラリ A のバージョン 2 を利用していた場合を考える．このとき，ライブラリ A の 2 つのバージョンは同じパッケージ名とクラス名を持つファイルを持っており，同時に使用することが不可能である．このような場合に，パッケージ名を変更することによって同じライブラリの複数バージョンを同時に利用することが可能になる．

[2]https://code.google.com/archive/p/jarjar/

- 利用者への配慮
  ライブラリの開発者視点で見たときに，開発中のライブラリの利用者が，同時に利用するライブラリを気にすることなく利用できるようにするために行う．図 2 の例で説明すると，ライブラリ B がライブラリ A に含まれているパッケージの名前を変更して内部に取り込んでおくことによって，利用者がライブラリ A を利用する際に制限が発生しなくなる．

このようにライブラリに含まれるパッケージ名を変更することはメリットが存在するのだが，利用中のライブラリが把握しづらくなることにより，ライブラリの管理に悪影響を及ぼす危険性が存在する．

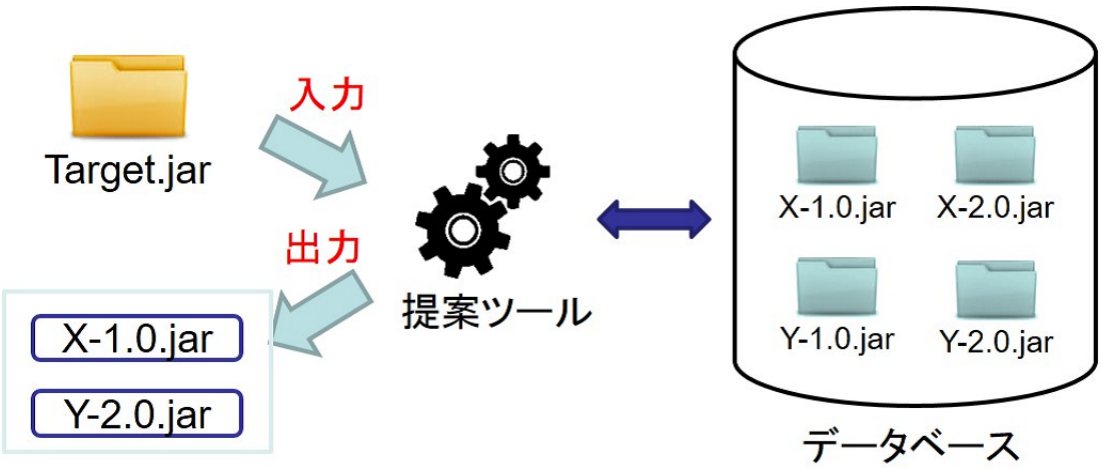

6

図 3: 手法の概要

3 提案手法

本研究では，Java のバイトコードに含まれる外部ライブラリを検出する手法を提案する．手法の概要は図 3 のようになる．入力として与えられたソフトウェア (.jar ファイル) を，あらかじめ用意しておいたデータベース内に含まれるライブラリ (.jar ファイル) と比較することによって，入力されたソフトウェアの内部に含まれると推定されるライブラリの一覧を得る．また，どのクラスがどのライブラリから再利用されたかについての情報も得ることができる．

jar ファイルには，コンパイルされた複数の Java バイトコードやそれが使用する画像などのリソースが含まれるが，本手法では内部に含まれるクラスファイルのみを比較に利用する．また，直接クラスファイルを比較するのではなく，クラスファイル毎にハッシュ値を計算し，比較に用いることで計算量を削減している．本章では，手法の具体的な手順について説明する．

3.1 クラスファイル毎のハッシュ値の計算

本手法ではソフトウェアの内部に含まれるバイトコード (. クラスファイル) の比較によって再利用の検出を行う．しかし，データベースに含まれる多数のライブラリを対象に，入力ソフトウェアとバイトコードの直接比較を行うと膨大な計算コストがかかる．そのため，バイトコードから得ることができる情報からハッシュ値を計算し，それを用いて比較を行うことで高速化を図っている．一般的に，MD5 や SHA-1 などによるファイルハッシュがファイ

ルが一致するかどうかの判定に用いられている．しかし同じソースコードから生成されたクラスファイルであっても，コンパイル時の環境によって違うバイトコード列を持つことがあり，ファイルから直接計算されたハッシュ値による比較では正確に再利用を検出できない恐れがある．そのため，コンパイル環境の影響を受けないと思われる情報をクラスファイルに含まれるバイトコード列から抽出し，連結した文字列からハッシュ値の計算を行う．

ハッシュ値の計算に用いる情報は，Davice らの Software Bertillonage[5] や Ishio らの Software Ingredients[6] でも用いられていたクラス名や，メソッド名などの情報に加えて，Java バイトコード命令の算術，論理演算の回数を用いている．ただしこの際にパッケージ名に関する情報を使用しないようにすることによって，クラスファイルが属するパッケージ名が違っていても同じファイルであると判定されるようにしている．これによって，パッケージのリネームの検出を可能にしている．

具体的には以下の情報を連結した文字列からハッシュ値を計算している．

- クラス名
- 親クラス名
- 実装しているインターフェース (順不同)
- フィールド宣言 (順不同)
  各フィールド宣言に対しては以下の情報を利用する．
  - フィールド名
  - フィールドの型
- メソッド宣言 (順不同)
  クラス内で宣言されているメソッドについては以下の情報を利用する．
  - メソッド名
  - アクセス修飾子
  - 引数の型
  - 返り値の型
  - メソッド呼び出し命令 (順不同)
    メソッド呼び出し命令である INVOKEVIRTUAL，INVOKESPECIAL，INVOKESTATIC，INVOKEINTERFACE によって呼ばれているメソッドの名前と引数の型を連結

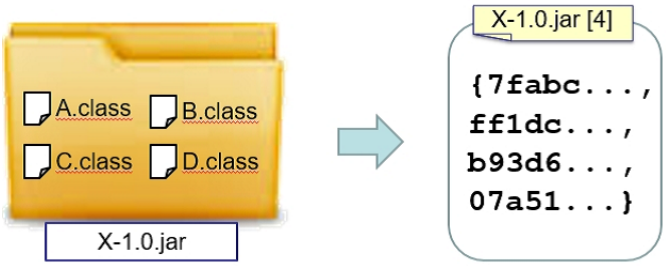

図 4: ハッシュ値の計算

– 算術，論理演算命令の回数
メソッド中に含まれる，算術演算命令*ADD,*SUB,*MUL,DIV，論理演算命令*AND,*OR,*XOR の数をそれぞれ数え，文字列として連結した．ここで，’*’ は型を表すアルファベットが入るが，省略している．

クラスファイルごとに計算されたハッシュ値が一致する場合，すなわち上に示したような情報がすべて一致するファイル同士を，本手法では同じクラスファイルであるとして扱う．

jar ファイル内部に含まれるクラスファイル毎にハッシュ値を計算した結果，図 4 のように，ハッシュ値の多重集合として jar ファイルを扱うことができる．ここで集合ではなく多重集合としているのは，パッケージ名のみが異なるクラスファイルが同一 jar ファイル内に含まれているような場合に，ハッシュ値の衝突が起こりうるからである．衝突が起こった場合には要素が重複して存在することになる．

以降，本論文で扱う全ての集合は多重集合であるとする．多重集合の和集合と共通部分 (積集合) は以下の例のように扱う．

- 和集合
$\{a, a, b\} \cup \{a, b\} = \{a, a, a, b, b\}$
- 共通部分
$\{a, a, b\} \cap \{a, b\} = \{a, b\}$

また，以降ハッシュ値の多重集合をハッシュ値集合と表記することがある．

3.2 再利用元の推定

前節の方法で計算したハッシュ値の多重集合を用いて，入力された jar ファイルとデータベース内の jar ファイルを比較することによって再利用元を推定する．基本的に，ライブラリの再利用は jar ファイル単位でまとめて行われることが多い．また，ハッシュ値集合の固

有性によるライブラリ名とバージョンの特定精度も高くなると考えられる．そのため，本手法では完全な形でコピーされたライブラリを優先的に検出する．

3.2.1 再利用元推定アルゴリズムの概要

再利用元を推定するアルゴリズムを Algorithm1 に示す．このアルゴリズムは検出対象となるソフトウェア (jar ファイル) t と比較対象となる複数のライブラリ (jar ファイル) を含むデータベース R を入力として，R から t に再利用されたと推定されるライブラリ群と，そのクラスファイルのハッシュ値の一覧を出力として得る．なお，入力データベースにおいて，ハッシュ値集合の全要素が完全に一致するようなライブラリの組はあらかじめ取り除かれているとする．また，Classes(x) は x の内部に含まれるクラスファイルのハッシュ値集合を返す関数である．x が複数の jar ファイルからなる場合にはそれらの和集合を返す．

このアルゴリズムは以下の 2 ステップの繰り返しによって構成される．

1. 共通部分の計算による再利用元候補の決定 (4-14 行目)
2. 再利用元の確定 (15-17 行目)

以降，各ステップについて説明する．

3.2.2 共通部分の計算による再利用元候補の決定

このステップではまず，入力 t が持つ再利用元が確定していないクラスファイルに対応するハッシュ値集合 A とライブラリが持つハッシュ値集合との比較によって，R に含まれる $r_1, r_2, ..., r_n$ それぞれに対して A との共通部分 $r'1, r'2, ..., r'_n$ を得る．この共通部分を用いて，各ライブラリが持つクラスファイルのうち A との共通部分がどれだけあるかの割合（以降，オーバーラップ値と呼ぶ) を計算する．オーバーラップ値は，

$$\frac{|A \cap r|}{|r|} = \frac{|r'|}{|r|}$$

によって得られ，ライブラリ r が持つクラスファイルのうち，t に含まれるクラスファイルとハッシュ値が一致する，つまり再利用された可能性のあるクラスファイルの数の割合を表す．

データベース内の全ライブラリに対してオーバーラップ値の計算が終わった後，オーバーラップ値が最大のライブラリを全て選択し，次のステップに入力することで再利用元を確定する．ただし，最大のオーバーラップ値が閾値よりも小さくなった場合，データベース内に再利用されたライブラリは残っていないと判定し，結果 $Result$ を出力し，アルゴリズムを終了する．

Algorithm 1 再利用元の推定アルゴリズム

INPUT: t : target jar file, $R = \{r_1, r_2, ..., r_n\}$: Database(Set of Library)

OUTPUT: Result: Subset of Repository(and overlapped classes)

$A \leftarrow Classes(t)$ ▷ 入力ファイルに含まれているクラスで再利用元が未確定のもの
$Result \leftarrow \{\}$
$i \in [i, |R|],\ r'_i = r$ ▷ r_i における A との共通部分を入れる変数
loop
  for $i = 1$ *to* $|R|$ **do**
    if $r'_i \in Result$ **then**
      continue
    end if
    $r'_i \leftarrow A \cap \text{Classes}(r_i)$
  end for
  $m \leftarrow \max_{i \in [i,|R|]} \dfrac{|r'_i|}{|r_i|}$
  if $m < threshold$ **then**
    break ▷ オーバーラップの最大値が閾値以下ならアルゴリズムを終了する
  end if
  $R'_{max} \leftarrow \left\{ r'_n | \ \dfrac{|r'_n|}{|r_n|} = m \right\}$
  $J \subseteq R'_{max} \wedge \text{Classes}(J) \subseteq A$ を満たし, $|\text{Classes}(J)|$ が最大となるような J を選択
  $Result \leftarrow\ Result \cup J$
  $A \leftarrow\ A \setminus J$
end loop
return $Result$

例えば，5 のような入力がなされた場合を考える．図では，データベース内のライブラリに含まれるハッシュ値のうち，赤く表示されている部分が入力ファイル Target.jar との共通部分となっている．この場合に Target.jar に対するデータベース内のライブラリのオーバーラップ値を計算すると，A-1.0.jar の場合は要素数 2 に対して Target.jar との共通要素数が 2 であるため $2/2 = 1.0$，A-2.0.jar の場合は要素数 2 に対して共通要素数が 1 であるため $1/2 = 0.50$ となる．同様に計算すると，C-1.0.jar，B-1.0.jar，D-1.0.jar に対しては 1.0，B-2.0.jar に対しては 0.67 が得られる．

その後，各ライブラリに対して計算されたオーバーラップ値が最大のものを選択する．オーバーラップ値 1.0 が最大となるため，A-1.0.jar，C-1.0.jar，B-1.0.jar，D-1.0.jar が再利用元の候補として次のステップに入力される．

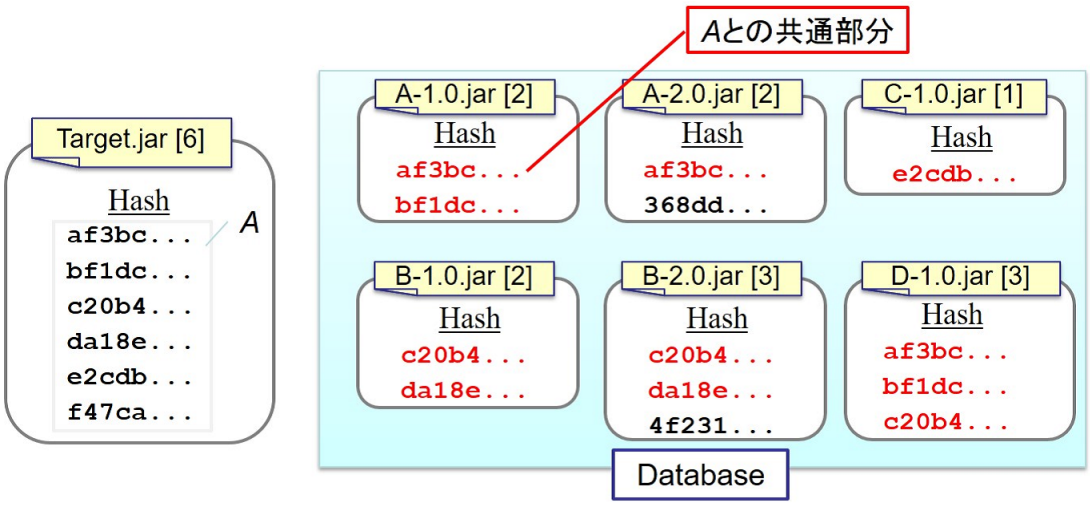

図 5: アルゴリズムへの入力例

3.2.3 再利用元の確定

このステップでは，前ステップによって得られた最大のオーバーラップ値を持つライブラリを候補とし，どれが再利用が行われたかの推定を行う．本手法では，入力 jar ファイルに含まれる 1 つのクラスファイルは，1 つのライブラリからのみ再利用されたものであるとしている．そのため，あるクラスファイルに対して同じハッシュ値のクラスファイルを持つライブラリが候補内に複数存在する場合には，再利用元となったものがどれなのかを特定する必要がある．例えば，図 6 のように，オーバーラップ値 1.0 を持つ 4 つのライブラリが再利用元候補であったとする．これらのライブラリ中で，ハッシュ値'af3bc...' を持つライブラリが A-1.0.jar と D-1.0.jar の 2 つあるのに対して，Target.jar には同じハッシュ値が 1 つし

か含まれていない．このような場合に，ハッシュ値’af3bc...’ に対応するクラスファイルが A-1.0.jar と D-1.0.jar のどちらから再利用されたかを特定する必要がある．

本ステップでは入力ソフトウェアに含まれるクラスファイルそれぞれを 1 つの再利用元に対応付けるため，Algorithm1 の 9 行目の条件の通り，各候補ライブラリの中から，A との共通部分の和が A の部分集合となるようなライブラリの組み合わせに対して探索を行う．その際，本手法においては，完全に近い形で再利用されているライブラリが再利用元であるとしているため，前述した条件のもとで要素数の合計が最大となるようなライブラリの組み合わせを求める組み合わせ最適化問題を解くことによって再利用元の推定を行う．このステップは以下のような手順に分けることができる．

1. 候補内で固有のハッシュ値しか持たないものを再利用元として確定
   基本的には条件を満たす組み合わせを全通り探索することによって要素数が最大となるものを特定するのだが，計算量削減のために，他のライブラリの選択に影響を与えないライブラリを固定で選択するようにする．具体的には，候補内で固有のハッシュ値のみが A との共通部分になっているようなライブラリを再利用元として確定する．

2. 条件を満たすライブラリの組み合わせを深さ優先探索によって求める
   前手順によって確定されたライブラリと合わせて，A との共通部分の和が A の部分集合とであるという条件を満たすようなライブラリの組み合わせを深さ優先探索によって全通り列挙する．深さ優先探索とは、あるノードから子のないノードに行き着くまで進んでいった後，最も近くの探索の終わっていないノードまで戻ることを繰り返すような探索方法である．この場合にはノードが選択されたライブラリとなり，その子ノードは共通部分の和が A の部分集合となるという条件のもとで選択可能なライブラリとなる．

3. 再利用元の確定
   全手順によって求めたライブラリの組み合わせの中から，含まれるハッシュ値の要素数が最大となるような組み合わせを選択する．その後，選択したライブラリ中に含まれるハッシュ値を A から取り除き，ステップ 1 の再利用元候補の決定に戻る．

図 6 は，本手法に図 5 のような入力がなされた場合の 1 回目のループにおける，再利用元が確定していないクラスに対応するハッシュ値の多重集合 A と，ステップ 1 で求められた再利用元候補の図となっている．再利用元候補となっている 4 つのライブラリはオーバーラップ値が 1.0 であるため，全要素が入力ソフトウェアとの共通部分となる．このような場合の検出例を示す．

まず，これら 4 つのライブラリを比較すると，C-1.0.jar は候補内の他のライブラリには含まれていない，ハッシュ値’e2cdb’ のクラスファイル 1 つのみを持っていることがわかる．

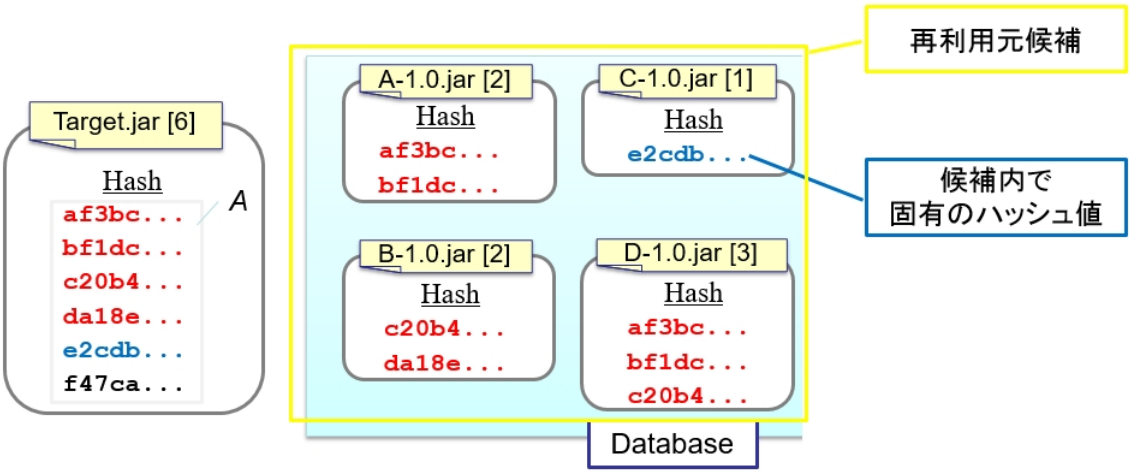

図 6: ループ 1 回目の再利用元候補

そのため，Target.jar には C-1.0.jar が再利用されていると判断し，検出結果として確定する．次に，深さ優先探索を行って条件を満たすライブラリの組み合わせを列挙する．C-1.0 を選択した状態では，他の全ての候補が選択可能であるため，これを初期状態として深さ探索を行うと図 7 に示したようなグラフを生成できる．その結果，条件を満たし，要素数の和が 5 で最大となるようなライブラリの組み合わせ {C-1.0,A-1.0,B-1.0} が特定される．これによって，A に含まれる 6 つのクラスファイルのうち 5 つの再利用元が特定されたため，対応するハッシュ値を取り除く．

その後はステップ 1 の再利用元候補決定に戻ることになる．このときの状態が図 8 となっている．2 回目のループで A に含まれるのは，ハッシュ値'f47ca...' のみとなるが，同じハッシュ値のクラスファイルを持つライブラリはデータベース内に存在しない．そのため，各ライブラリのオーバーラップ値は 0 となり，アルゴリズムを終了する．以上により，検出結果として A.1.0.jar の 2 つのクラスファイル，B-1.0.jar の 2 つのクラスファイル C-1.0.jar の 1 つのクラスファイルが得られる．

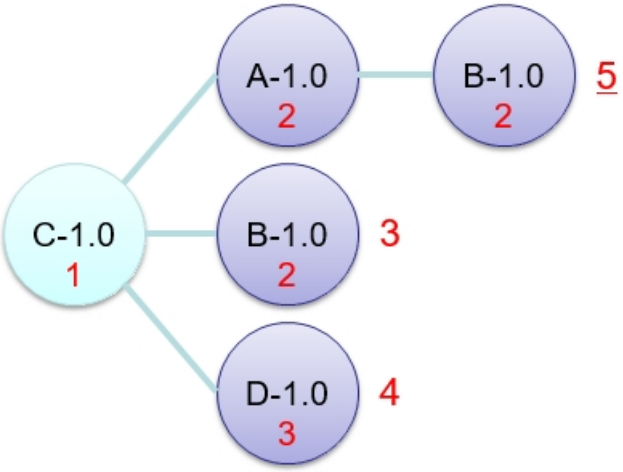

図 7: 深さ優先探索による組み合わせの列挙

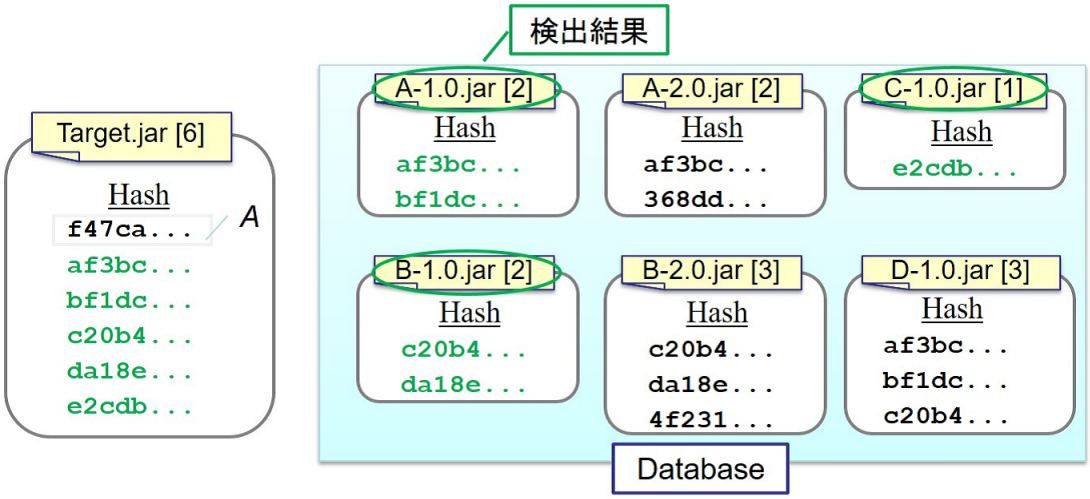

図 8: ループ 1 回目終了後

4　実験

4.1　提案手法の実装

Java を用いて提案手法の実装を行った．バイトコードの解析には SOBA[15] を利用しており，ハッシュ値の計算は Sha-1 ハッシュ関数によって行っている．

ツールの出力としては，入力ソフトウェア中で再利用されていると推定されるライブラリの一覧と，クラスファイルと利用元の対応表の 2 つが得られる．ライブラリ一覧中の 1 項目は，以下の 3 つの情報によって構成される．

- 同じハッシュ値集合を持つライブラリ名一覧
- ライブラリが持つクラスの数
- 入力ソフトウェアに再利用されたクラスの数

また，検出結果として得られたライブラリ中には，入力ソフトウェアと同一のものなど，明らかに誤った結果が含まれる場合がある．そのため，指定したライブラリを比較対象から除外して再検索を行う機能を実装している．

データセットとして，Maven Central Repository[3] のスナップショット (2015/11) に含まれる，破損しているファイルを除いた 239817 個のライブラリの jar ファイルを使用した．データセットには 29388 種類のドメインが含まれており，各ドメインには平均 8 つのバージョンが存在する．このデータセットをデータベースとし，実験に用いる．

本章では，生成したハッシュ値を用いてデータベースに関する調査，検出ステップの精度評価を行っている．以降，詳細を述べる．

4.2　ハッシュ値について

提案手法の方法で計算したハッシュ値を用いて，データセットに対して以下の 2 つの調査を行った．

調査 1 パッケージ名だけが異なるクラスファイルは存在するか

調査 2 ハッシュ値によってライブラリのバージョンの特定が可能か

本節では調査方法と結果について述べる．

[3] https://repo1.maven.org/maven2/

4.2.1 調査 1: パッケージ名だけが異なるクラスファイルは存在するか

本研究の背景として述べた，ライブラリの再利用におけるパッケージのリネームが実際にどれだけ行われているかどうかの調査を行った．提案手法では，クラスファイルを比較するための情報として，パッケージ名を使用しないとしていた．それによって，パッケージのリネームのみが行われたクラスファイルから同一のハッシュ値が計算されるようにしている．逆に，提案手法で利用した情報に加えてパッケージ名を使用してハッシュ値を計算した場合には，パッケージのリネームが行われたクラスファイルは異なるハッシュ値を持つはずである．

これを用いて，データセット内の jar ファイル内部に含まれるクラスファイルに対して，パッケージ名を用いた場合，パッケージ名を用いない場合，の 2 つのハッシュ値の計算を行う．この際にファイル名に'$' が含まれるようなクラスファイル (無名クラスや内部クラス) に関しては取り除いている．このようなクラスファイルは対応する外部クラスのソースコードがコンパイルされることによって生成される．そのため，対応する外部クラスが所属するパッケージ名が変更された場合，内部クラスも自動的に違うパッケージに所属することになるため，リネーム数の調査には不要であると考えられる．基本的には異なる文字列から生成されたハッシュ値の衝突は発生しないと考えると，2 通りの方法で計算したハッシュ値についてハッシュ値のパターン数を比較することによって，パッケージ名のみが異なるクラスファイルがどの程度存在するのかを調査する．

結果として得られたデータセット内に含まれる 28,654,988 個のクラスファイルに対するハッシュ値のパターン数を表 1 に示した．パッケージ名に関する情報を用いずハッシュ値を生成した場合，約 14%程度パターン数が減少している．この結果からは具体的にパッケージのリネームが行われたクラスファイルの数は知ることができないが，パッケージ名のリネームは実際に行われている可能性が高いことがわかる．

表 1: ハッシュ値のパターン数

計算方法	パターン数
パッケージ名あり	2,679,171
パッケージ名なし	2,294,336

4.2.2 調査 2: ハッシュ値によってライブラリのバージョンの特定が可能か

提案手法では，jar ファイルをハッシュ値の多重集合に変換することで比較を行うが，本手法におけるハッシュ値の生成は，クラスファイルからその特徴となる数種類の情報のみを

抜き出して用いている．つまり，比較に用いていない情報のみが異なるクラスファイルに対しては同一のハッシュ値が生成される．そのため，ライブラリのアップデートにおいて，軽微な変更のみが行われた場合にはその差を区別することができないことがある．提案手法において 2 つの jar ファイルを区別するためには，ハッシュ値集合が一致しない必要がある．ここで，ハッシュ値集合が一致するとは，jar ファイルから生成された 2 つのハッシュ値集合 R_1, R_2 に対して，$R_1 \subset R_2$ かつ $R_2 \subset R_1$ であるときのことを表す．

以上の理由から，各ライブラリのバージョン数に対して，異なるハッシュ値集合のパターンがどれだけ存在するかについて調査を行った．これによって，あるハッシュ値集合のライブラリを検出した際のバージョン番号の特定精度を調べる．比較対象として，Software Ingredients で用いられているハッシュ値の計算方法でも同様の調査を行っている．

データセットに含まれる 29388 種類のライブラリに対する調査結果を表 2 に示す．表中の，パターン数/バージョン数 の値は，1 バージョンあたりにハッシュ値集合のパターン数がどれだけ存在するか，つまり，仮に提案手法によってハッシュ値集合の完全一致によってライブラリの再利用を検出したとしたとすると，平均 2.04 個のバージョンが再利用元候補として提示されることになる．SoftwareIngredients と比較すると，ハッシュ値集合のパターン数が増加している．演算命令に関する情報をクラスファイルの比較に用いているため，違いを区別できないクラスファイルの数が減少し，

比較的再利用されることが多いと考えられる，利用されている数が上位 100 位のライブラリに絞った調査結果を表 3 に示した．1 バージョンあたりの平均のハッシュ値集合のパターン数は 1.22，中央値だと 1 バージョンあたりのハッシュ値集合のパターン数は 1.08 となった．

一方で，ハッシュ値集合のパターン数が公開されているバージョン数に対して極端に少ないライブラリもいくつか見られた．例えば，jsp-api というライブラリはデータセット中に 15I のバージョンが存在するのに対して，提案手法によって得られたハッシュ値集合は 4 パターンであった．このように，一部のライブラリでは新しいバージョンのリリースが行われる際に，提案手法がクラスファイルの比較に用いている情報に影響を及ぼすような変更がなされていない傾向にある．

結果から，多くのライブラリに対してはハッシュ値集合が完全に一致した場合にはバージョン番号が 1 つに定まる可能性が高いことがわかる．つまり，提案手法のツールによって完全な形でライブラリの再利用が検出された場合にはバージョン番号が高い精度で特定できるといえる．

4.3 検出精度の評価

本研究の検出アルゴリズムを用いて，入力した jar ファイル中に含まれるライブラリの再利用を検出可能であるかどうかの評価を行う．本節では評価方法とその結果について述べる．

4.3.1 評価方法

一般に公開されているソフトウェア中にはライブラリが再利用されていることが多いが，ライブラリ名とバージョン番号が全て正確に公開されているものは少なく，十分な量のデータセットを用意することが難しい．そのため，SoftwareIngredients で行われていた評価実験と同様に，複数のライブラリを含む jar ファイルを自身で作成し，その内部に含まれるライブラリの一覧を正確に出力することが可能であるかどうかの評価を行う．

実験用の入力データは，データベースに登録されているものと同じ，Maven Repository のスナップショットに含まれる 239817 個のライブラリから N 個のライブラリをランダムに選択し，1 つのフォルダの内部に展開したもの jar ファイルとして圧縮することで作成する．入力とする実験用 jar ファイルに含まれるライブラリの数 N は，5 から 100 まで 5 刻み (N=5,10,15...,100) で変化させる．基本的にはランダムに選択した jar ファイルの内部に含まれるクラスファイルを全て実験用 jar にコピーすることでデータセットを作成するが，ファイル名が衝突した場合には先にコピーされたファイルものを残すようにしている．また，選択された jar ファイル宙に含まれる全てのクラスファイルの名前が衝突していた場合，1 つもファイルのコピーが行われないため，改めて別のライブラリを選択する．

実験用 jar に含まれる N 個の jar ファイルに対応する名前のリストは，正解リストとして記録しておく．ただし，ファイルハッシュが等しい jar ファイル，つまり中身が完全に同じ jar ファイルは 1 つの jar ファイルに複数の名前が対応づけられているとする．

作成したデータセットを，提案手法と Software Ingredients にそれぞれ入力として与え，結果 $Result$ を得る．その後，$Result$ と正解リスト $Answer$ の比較により，検出結果に正解セットに記載されているライブラリ名が含まれるかどうかを基準とし $Precision$(適合率), $Recall$(再現率) を求める．$Precision$，$Recall$ は以下の式によって得られる．

$$Precision = \frac{|Result \cap Answer|}{|Result|}$$

$$Recall = \frac{|Result \cap Answer|}{|Answer|}$$

また，検出結果としては，入力ソフトウェアに含まれる，どのクラスが再利用されたかの情報も得ることが可能であるため，そのクラス数が実際にコピーされたクラスファイル数と

表 2: ハッシュ値集合のパターン数 (全ライブラリ)

	バージョン数平均	パターン数平均	パターン数/バージョン数
提案手法	8.15	4.00	2.04
Software Ingredients	8.15	3.50	2.33

一致するような場合のみを正解と判定した場合の再現率を $Recall_{class}$ とし，同様の方法で計算している．

4.3.2 結果

実験用 jar ファイルを含まれるライブラリの数ごとに 10 個ずつ，合計 200 個のファイルを作成した．ただし，提案手法が実装しているアルゴリズムでは部分的に全組み合わせを探索するため，入力ソフトウェアの大きさやデータベースに登録されているデータなどの要因で，検出実用的な時間内に完了しない場合が存在した．そのため，提案手法において検出が 30 分以内に終了しなかったものについては検出失敗として，新たに別の jar ファイルを作成することでデータ数を補完している．検索が時間内に終了するデータセットの数が 10 に到達するまでの間に検出を失敗したデータセットの数を表 9 に示す．基本的にはデータセットのサイズが大きくなるほど失敗するものの数が多くなっているが，選ばれたライブラリのサイズがとても大きく，内部に多数のライブラリを含んでいるような場合には探索が終わらないような場合が存在した．例えば，N=5 のときにも探索が終わらなかったものが 1 つ存在しているが，これには easybeans というソフトウェアの uberjar(依存関係をすべて含むような jar ファイル) が含まれており，7175 個のクラスファイルがコピーされていた．

提案手法と Software Ingredients に対して，提案手法において 30 分以内に検出が完了した 200 ファイルを入力した際の実行時間の分布を図 10 に，検出精度の平均値を表 4 に示す．提案手法ではクラスファイルの比較にパッケージ名を利用していないが，検出精度はほとんど低下していない．また，再利用元にクラスファイルの対応付けに関しては，図 13，図 14 に示した $Recall_{class}$ の分布からも，提案手法の方が正しく行うことができている場合が多いことがわかる．

一方で検出にかかる時間に関しては，提案手法では入力データによって大きなばらつきが見られた．その原因としては，提案手法の再利用元確定ステップにおける深さ優先探索において，最悪の場合では再利用元候補数に対して指数オーダーで探索すべき組み合わせが増加してしまうことが挙げられる．

表 3: ハッシュ値集合のパターン数 (利用者数 Top100 ライブラリ）

	バージョン数平均	パターン数平均	パターン数/バージョン数
提案手法	8.15	15.0	1.22
Software Ingredients	18.3	14.9	1.26

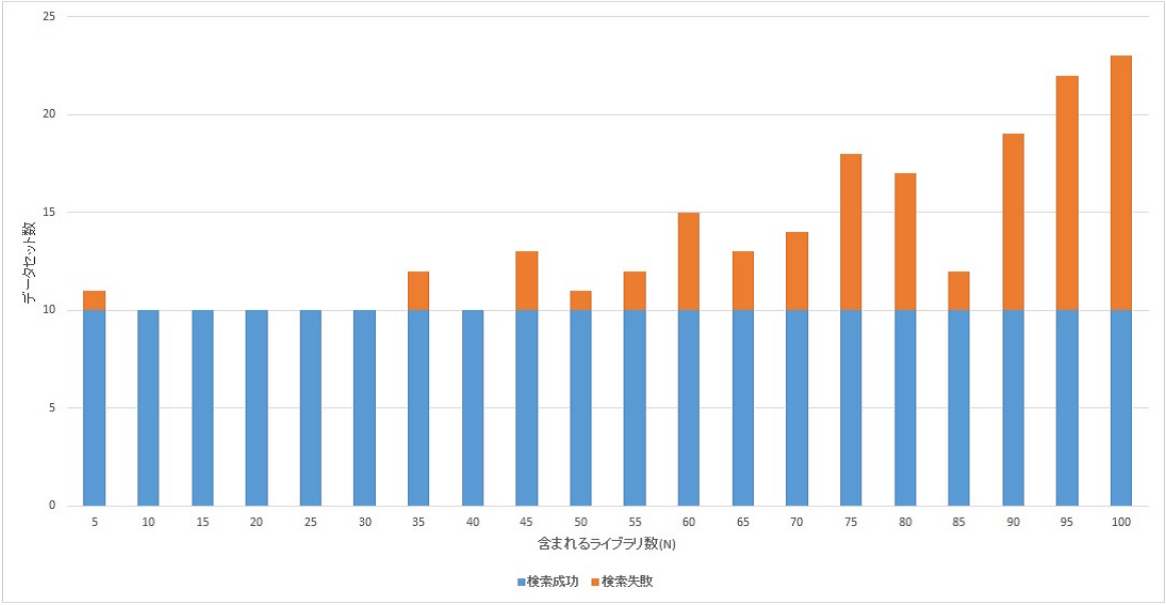

図 9: データセットの作成

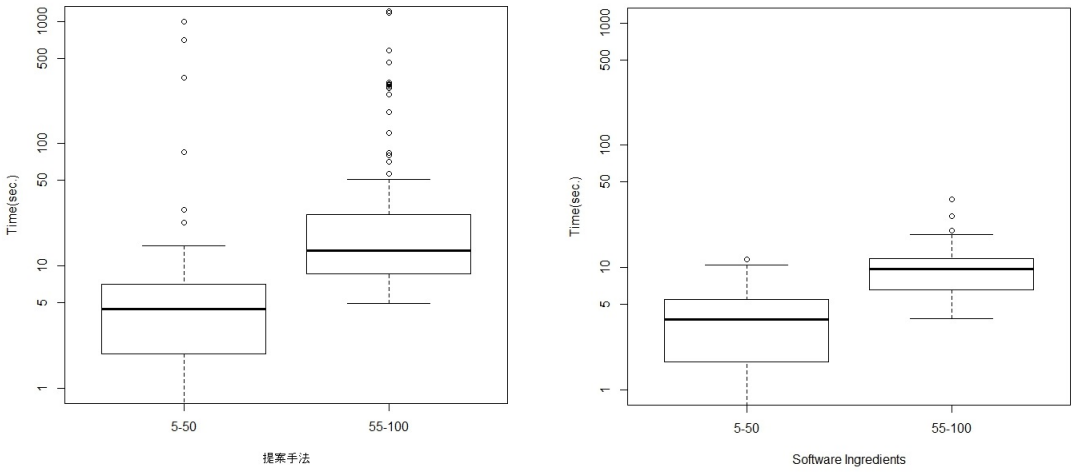

図 10: 検出時間

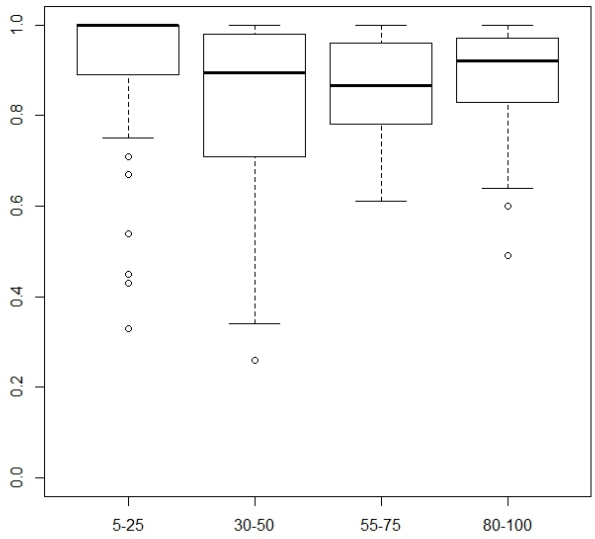

図 11: 提案手法の *Precision* の分布

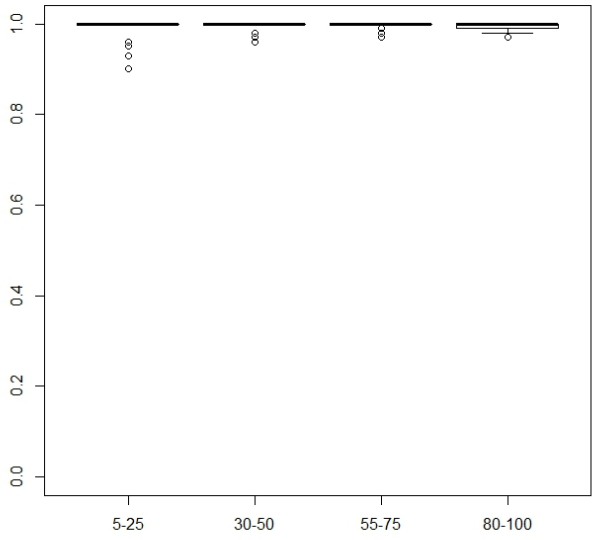

図 12: 提案手法の *Recall* の分布

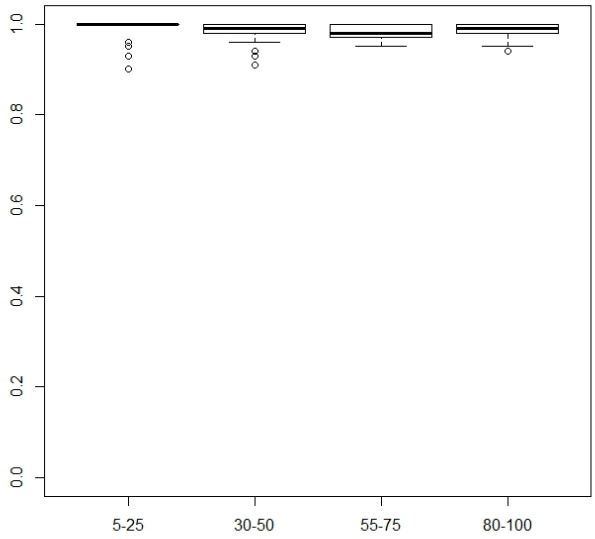

図 13: 提案手法の $Recall_{class}$の分布

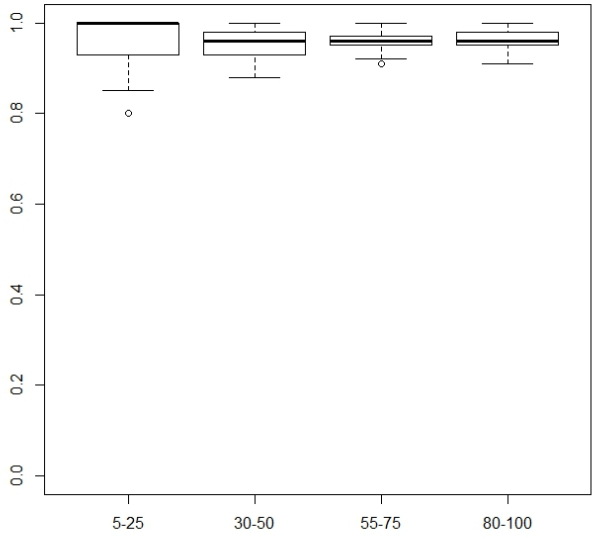

図 14: Software Ingredients の $Recall_{class}$の分布

表 4: 検出精度の比較

	$Precision$	$recall$	$Recall_{class}$
提案手法	0.87	0.99	0.98
Software Ingredients	0.87	0.99	0.96

5 ケーススタディ

本章では，提案手法のツールがパッケージのリネームを検出できるのかどうか調べるために，実際にライブラリを再利用する際にパッケージのリネームを行っている java のソフトウェアに対して提案手法を適用するとどのような結果が得られるかを調べた．

5.1 調査対象

Elastic Search[4] のバージョン 0.90.5 に対して調査を行った．SoftwareIngredients にこのライブラリの jar ファイルを入力した結果，ライブラリの再利用は検出されなかった．

Elastic Search0.90.5 では，プロジェクトに関する設定などが記述されているファイル (pom.xml) 中の記述から，Maven Shade Plugin[14] を用いて 9 つのライブラリに含まれるファイルを内部に展開して利用していることが判明している．それらのライブラリが使用していると思われるパッケージ名の変更設定も記述されていた．また，生成する Jar に含めるクラスファイルに関する設定である，MinimizeJar が使用されていた．

Maven Shade Plugin では，MinimizeJar オプションによって，動作が可能な最小の Jar ファイルを生成することが可能である．通常は生成 Jar ファイル中に，選択したライブラリに含まれる全てのクラスファイルがコピーされるが，このオプションを使用した場合，実際に使用されているクラスファイルのみを生成 Jar ファイルに含めるような仕組みになっている．そのため，Elastic Search の jar ファイル中には，9 つのライブラリに含まれるクラスファイルの一部が含まれていることになる．

再利用されているライブラリの一覧とそのパッケージ名を表 5 に示した．なお，これらのライブラリのバージョンに関する記述は発見することができなかった．

5.2 結果

提案手法を実装したツールにおいて，検索終了の閾値を 0.1 に設定し，elasticsearch-0.90.5.jar に対して内部に含まれるライブラリの検出を行った．結果として出力されたライブラリのリストを表 6 に示す．表 6 の各列は左から順に，検出されたライブラリ名，バージョン，含ま

[4]https://www.elastic.co/products/elasticsearch

表 5: Elastic Search 0.90.5 に含まれるライブラリ

ライブラリ名	変更前パッケージ名	変更後パッケージ名
guava	com.google.common	org.elasticsearch.common
trove4j	gnu.trove	org.elasticsearch.common.trove
mvel2	org.mvel2	org.elasticsearch.common.mvel2
jackson-core	com.fasterxml.jackson	org.elasticsearch.common.jackson
jackson-dataformat-smile	com.fasterxml.jackson	org.elasticsearch.common.jackson
jackson-dataformat-yaml	com.fasterxml.jackson	org.elasticsearch.common.jackson
joda-time	org.joda	org.elasticsearch.common.joda
netty	org.jboss.netty	org.elasticsearch.common.netty
compress-lzf	com.ning.compress	org.elasticsearch.common.compress

れるクラスファイル数，その中で入力ソフトウェア内に再利用されていると判定されたクラスファイルの数，にそれぞれ対応している．バージョン番号については，ハッシュ値集合が等しいバージョンが複数ある場合には複数の候補を示している．例えば，reader-files のバージョン 1.1.2 には，31 個ハッシュ値集合が等しいバージョンが存在するため，表中にそれを記載している．

Elastic Search　0.90.5 において再利用されたとされている 9 つのライブラリは，表 6 中に太字で示した通りすべて検出結果に表れていることがわかる．Trove4j などは，ライブラリが持つクラスファイル数に対して検出されたクラスファイル数が少なくなっている．しかし，入力 jar ファイル中のディレクトリ org/elasticsearch/common/trove に含まれるクラスファイル数を確認した結果，103 個のファイルが含まれていることが確認できた．そのため，103 個のうち 98 個のクラスファイルを再利用元に対応付けることができており，再利用されたものの大部分を検出することに成功しているといえる．このディレクトリに含まれる残り 5 ファイルに関しては再利用元が特定できなかった．原因としては，再利用された trove4j のバージョンがデータベース内に含まれていなかったことが考えられる．

各ライブラリについて提案ツールによってバージョン番号が示されているが，全てのクラスファイルが再利用されたと判定されたものが存在しないため，これらのバージョン番号は一致するクラスファイルの数を元にデータベース内で一番近いものを選択した推定値となる．joda-time や jackson-core は大部分のクラスファイルが一致しているため比較的バージョン番号の特定精度も高いと思われるが，trove4j のようにライブラリ中のクラスファイルのうちのごく一部しか一致していないものは正しいバージョン番号が特定されている可能

性は低い．

検出結果として，再利用されたとの記述がなされていた 9 個のライブラリの他に，guice とその関連ライブラリが多く表れている．これらのライブラリを比較対象から除外して再検索を行うと，guice から再利用されていたと判定されていたクラスファイルの再利用元が見つからなくなった．つまり，guice が設定ファイル中に記述されていた 9 個のライブラリに含まれていた可能性は低い．そのため，このライブラリは設定ファイル中には記載されていなかったが，実際には再利用が行われている可能性が高い．

このケーススタディによって，誤検出が行われるような例も発見することができた．全てのクラスファイルが一致するとして guava-annotation が検出されているが，これは guava の一部機能のみを持つライブラリである．提案手法ではクラスファイルの一致する割合によって検出の優先度を定めているため，今回のようにあるライブラリの一部のみの再利用が行われている場合，このように一部機能のみを持つライブラリがデータベースに登録されていた場合に誤検出してしまうことが判明した．

表 6: Elastic Search 0.90.5 から検出されたライブラリ一覧

ライブラリ名	バージョン	クラス数	検出クラス数
guava-annotations	r03	4	4
guice-multibindings	2.0	4	4
guice-annotations	2.0.1	10	10
joda-time	2.3	157	144
jackson-core	2.2.3	69	63
mvel2	2.1.5.Final	349	253
guice-assisted-inject	2.0	7	5
guice	2.0-no_aop	184	123
jackson-dataformat-smile	2.2.2	12	8
	2.2.3		
jackson-dataformat-yaml	2.2.2	112	70
reader-files	1.1.2 *and 31 versions*	2	1
hadoop-job-builder	1.0	6	3
guava	15.0	453	205
	15.0-rc1		
	15.0-cdi1.0		
jsr166y	1.7.0	9	4
netty	3.7.0	546	239
compress-lzf	0.9.6	26	10
jellydoc-annotations	1.0 *and 4 versions*	3	1
trove4j	3.0.3	691	98

6　まとめと今後の課題

本研究では，Java バイトコードから抽出した情報から計算したハッシュ値の比較によって，Java のソフトウェア内部に含まれるライブラリの再利用を検出する手法を提案した．提案手法では，バイトコードの比較を行う際にパッケージ名に関する情報を取り除くことによって，パッケージのリネームが行われていた場合でも再利用の検出を可能にした．

また，提案手法を実装したツールに複数個のライブラリを含む jar ファイルを入力することによって，再利用元を特定することが可能であるかどうか，既存研究との比較実験を行った．その結果，検出精度が向上していることが確認できた．一方で，検索にかかる時間については既存研究よりも増加していることが判明した．

今後の課題としては，検出アルゴリズムの改善が挙げられる．提案手法では，一致するクラスファイルの割合が大きいライブラリを再利用元として優先的に検出するアルゴリズムを採用している．しかし，実際に jar ファイルを生成する際には，ファイルサイズの削減のためにライブラリの一部のみを再利用しているような例が存在する．その結果，あるライブラリの一部機能のみを実装したライブラリなどの，規模の小さいライブラリが誤って検索結果として判定されてしまうような例が見られた．検出を行う際にライブラリ間の包含関係を考慮することによってこのような誤検出を減らすことが可能となるかもしれない．

謝辞

本研究において，常に適切な御指導および御助言を賜りました大阪大学大学院情報科学研究科コンピュータサイエンス専攻井上克郎教授に心より深く感謝いたします．

本研究において，適切な御指導および御助言を賜りました大阪大学大学院情報科学研究科コンピュータサイエンス専攻松下誠准教授に深く感謝いたします．

本研究において，研究の方針や論文の書き方など，様々な御指導を頂きました大阪大学大学院情報科学研究科コンピュータサイエンス専攻石尾隆助教に深く感謝いたします．

本研究において，様々な御指導および御助言を頂きました大阪大学大学院情報科学研究科コンピュータサイエンス専攻 Raula Gaikovina Kula 特任助教に深く感謝いたします．

最後に，その他様々な御指導，御助言等を頂いた大阪大学大学院情報科学研究科コンピュータサイエンス専攻井上研究室の皆様に深く感謝いたします．

参考文献

[1] Pei Xia, Makoto Matsushita, Norihiro Yoshida, and Katsuro Inoue. Studying reuse of out-dated third-party code in open source projects. *JSSST Computer Software*, Vol. 30, No. 4, pp. 98–104, 2013.

[2] K. Inoue, Y. Sasaki, Pei Xia, and Y. Manabe. Where does this code come from and where does it go? – integrated code history tracker for open source systems –. In *Proceedings of the 34th IEEE/ACM International Conference on Software Engineering*, pp. 331–341, 2012.

[3] 川満直弘, 石尾隆, 井上克郎ほか. Lsh アルゴリズムを利用した類似ソースコードの検索. 研究報告ソフトウェア工学 (SE), Vol. 2016, No. 7, pp. 1–8, 2016.

[4] Lars Heinemann, Florian Deissenboeck, Mario Gleirscher, Benjamin Hummel, and Maximilian Irlbeck. On the extent and nature of software reuse in open source java projects. In *Proceedings of the 12th International Conference on Software Reuse*, Vol. 6727 of *Lecture Notes in Computer Science*, pp. 207–222, 2011.

[5] Julius Davies, Daniel M. German, Michael W. Godfrey, and Abram Hindle. Software bertillonage: Finding the provenance of an entity. In *Proceedings of the 8th Working Conference on Mining Software Repositories*, pp. 183–192, 2011.

[6] Takashi Ishio, Raula Gaikovina Kula, Tetsuya Kanda, Daniel M German, and Katsuro Inoue. Software ingredients: detection of third-party component reuse in java software release. In *Proceedings of the 13th International Conference on Mining Software Repositories*, pp. 339–350. ACM, 2016.

[7] P. Mohagheghi, R. Conradi, O.M. Killi, and H. Schwarz. An empirical study of software reuse vs. defect-density and stability. In *Proceedings of the 26th International Conference on Software Engineering*, pp. 282–291, May 2004.

[8] H. Plate, S. E. Ponta, and A. Sabetta. Impact assessment for vulnerabilities in open-source software libraries. In *2015 IEEE International Conference on Software Maintenance and Evolution (ICSME)*, pp. 411–420, Sept 2015.

[9] Gabriele Bavota, Gerardo Canfora, Massimiliano Di Penta, Rocco Oliveto, and Sebastiano Panichella. The Evolution of Project Inter-dependencies in a Software Ecosys-

tem: The Case of Apache. In *Proceedings of the 29th IEEE International Conference on Software Maintenance*, pp. 280–289, 2013.

[10] Raula Gaikovina Kula, Coen De Roover, Daniel German, Takashi Ishio, and Katsuro Inoue. Visualizing the evolution of systems and their library dependencies. In *Proceedings of the 2nd IEEE Working Conference on Software Visualization*, pp. 127–136, 2014.

[11] Yuki Yano, Raula Gaikovina Kula, Takashi Ishio, and Katsuro Inoue. Verxcombo: An interactive data visualization of popular library version combinations. In *Proceedings of the 23rd IEEE International Conference on Program Comprehension*, pp. 291–294, 2015.

[12] Cédric Teyton, Jean-Rémy Falleri, Marc Palyart, and Xavier Blanc. A study of library migrations in java. *Journal of Software: Evolution and Process*, Vol. 26, No. 11, pp. 1030–1052, 2014.

[13] Apache Maven Project. Apache maven assembly plugin. `http://maven.apache.org/plugins/maven-assembly-plugin/`.

[14] Apache Maven Project. Apache maven shade plugin. `https://maven.apache.org/plugins/maven-shade-plugin/`.

[15] 秦野智臣, 石尾隆, 井上克郎. Soba: シンプルな java バイトコード解析ツールキット. コンピュータ ソフトウェア, Vol. 33, No. 4, pp. 4_4–4_15, 2016.