

現実的な設定における メソッド粒度バグ予測モデルの構築及び精度評価

荻野 翔^{1,a)} 肥後 芳樹^{1,b)} 楠本 真二^{1,c)}

受付日 xxxx年0月xx日, 採録日 xxxx年0月xx日

概要：バグを予測する技術は品質保証に要するコストを低減できると期待されている。バグ予測はより細粒度で行えることが望ましく、メソッド粒度でのバグ予測が注目されている。メソッド粒度でバグを予測するモデルは、主に機械学習を用いて構築される。機械学習を用いて構築された、実用的なメソッド粒度バグ予測モデルについて調査する場合、下記の現実的な設定を満たすべきである。(1) モデルの目的変数はメソッドにバグが含まれているかどうかである。(2) データセット構築手法は実際のユースケースに基づいている。しかしながら、両者を満たす、メソッド粒度バグ予測モデルについての調査は未だなされていない。よって、著者らはまず現実的な設定のもとで、メソッド粒度バグ予測モデルの予測精度を計測した。その結果、F 値は平均で約 0.201, AUC は平均で約 0.746 と計測され、高精度のメソッド粒度バグ予測モデルを構築するには課題が残されていると判明した。また、適切な変更履歴の期間および学習に用いるメソッドの存在期間を採用することで、予測精度が F 値の観点で約 16.7%, AUC の観点で約 3.0%向上することが確認できた。

キーワード：品質保証, バグ予測, 機械学習

Evaluating Method-level Bug Prediction under Realistic Settings

SHO OGINO^{1,a)} YOSHIKI HIGO^{1,b)} SHINJI KUSUMOTO^{1,c)}

Received: xx xx, xxxx, Accepted: xx xx, xxxx

Abstract: Bug prediction is a promising technique to reduce the cost of quality assurance. Method-level bug prediction is drawing attention because bug prediction on such finer granularity is desirable. Most method-level bug prediction models are built based on machine learning. We should adopt realistic settings listed below to research practical bug prediction models built based on machine learning. (1) The dependent variable correctly represents the presence or absence of bugs. (2) Dataset-building method is based on realistic usage of bug prediction. However, no research has been conducted on bug prediction models built under the above realistic settings. Therefore, we first evaluate the capability of bug prediction models built under realistic settings. The experimented models resulted in low capability (F-measure of 0.201 and AUC of 0.746 on average). Thus, there are still some issues to be solved to build a high-capability bug prediction model under realistic settings. Next, we found it effective to change (a) interval of development history referenced when calculating process metrics, and (b) period of development history referenced when collecting method for training-dataset. The trial improves the prediction capability 16.7 % in terms of F-measure and 3.0% in terms of AUC.

Keywords: quality assurance, bug prediction, machine learning

¹ 大阪大学大学院情報科学研究科

^{a)} s-ogino@ist.osaka-u.ac.jp

^{b)} higo@ist.osaka-u.ac.jp

^{c)} kusumoto@ist.osaka-u.ac.jp

1. はじめに

近年、ソフトウェア開発の規模は増大し続けている [1]. この状況において、開発コストを低減するための技術は欠かせない. デバッグ等に要する品質管理コストは開発コストの中でも大きな割合を占める [2] ため、品質管理コストを低減するための技術は特に重要である.

品質管理に要するコストを低減できる技術の一つとして、バグ予測が存在する. バグ予測とは、ソフトウェアを構成するモジュール (例: ソースファイル) にバグが含まれるかどうかを予測する技術である. バグを含むモジュールを予測し、それらを優先的にレビュー・テストすることは効率的な品質管理を可能にし、品質管理コストの低減につながる. また、バグ予測後のレビューに要するコストを考慮するとバグ予測はより細粒度で行えることが望ましく、メソッド粒度でのバグ予測が注目されている [3-5].

メソッド粒度でバグを予測するモデルは、主に機械学習を利用してメソッドの特徴量とバグの有無との組 (レコード) の集合 (データセット) からバグメソッドの特徴を学習することで構築される. そして、そのモデルがどの程度正しくバグを予測できるかは別のデータセット (評価用データセット) に基づいて評価される. 従来、メソッド粒度バグ予測の調査においては下記のようにデータセットが構築されてきた [3,4].

- (1) ある時点 A で存在するメソッドについてレコードを算出する.
- (2) (1) で算出されたレコードを、学習用データセット・評価用データセットに振り分ける.

しかしながら、そのようにデータセットを構築する場合、予測時に存在するメソッドのバグの有無という実際のユースケースでは利用できないデータを学習用に利用していることになり、非現実的な実験結果につながると Pascarella らは主張した [5]. 彼らはその問題を解決できるリリースバイリリースという手法を提案し、その手法でデータセットを構築した場合の予測精度を調査した. 調査の結果、リリースバイリリースを採用した場合の予測精度は低く、十分な予測精度を達成するには課題が残されていると結論付けられた.

しかしながら、彼らによって構築されたデータセットの妥当性には議論の余地があると著者らは考える. Pascarella らの手法では、目的変数として「そのモジュールにバグが存在するかどうか (isBuggy)」ではなく、「そのモジュールは過去にバグが修正されたかどうか (hasBeenFixed)」が採用されており、これが現実的な設定とはいえない. なぜなら、hasBeenFixed が偽でありながら isBuggy が真であるようなメソッドが存在するために、hasBeenFixed を目的

変数とするモデル (hasBeenFixed モデル) は正しくバグの有無を予測出来ない可能性があるからである.

上記のように、メソッド粒度バグ予測についての先行研究では部分的に非現実的な設定を用いた調査がなされており、現実的な設定に基づいた調査は未だなされていない. よって、著者らはまず現実的な設定のもとでメソッド粒度バグ予測の予測精度を計測した. その結果、F 値は平均で約 0.201, AUC は平均で約 0.746 と計測され、高精度のメソッド粒度バグ予測モデルを構築するには課題が残されていると判明した. また、適切な変更履歴の期間および学習に用いるメソッドの存在期間を採用することで、予測精度が F 値の観点で約 16.7%, AUC の観点で約 3.0% 向上することが確認できた.

2. 準備

本章では、本調査と関わりが深い、バグ予測粒度・データセットの算出方法について述べる.

2.1 バグ予測粒度

バグ予測モデルを構築する上でしばしば用いられている予測粒度としては、ファイル粒度・メソッド粒度・コミット粒度の3つが存在する. メソッド粒度バグ予測はファイル粒度バグ予測よりデバッグコストを低減できるとされている [4]. また、本研究はメソッド粒度バグ予測モデルの予測精度には課題が残るという、Pascarella らの結論の正しさを確かめることを目的の一つとしている. よって、本研究はメソッド粒度でのバグ予測を対象とする.

2.2 実験用データセットの算出方法

メソッド粒度バグ予測モデルを構築し、予測精度を正しく評価するためには、学習用データセット・評価用データセットの組 (実験用データセット) を実際のユースケースに基づいて構築する必要がある. 本節では、従来手法とその問題点及びその問題点を解決できる手法であるリリースバイリリースについて述べる.

2.2.1 従来手法

従来のデータセット構築手法では、図 1 に示すように、ある時点に存在するメソッドについてその特徴量とバグの有無との組 (レコード) を算出し、それらのレコードを学習用データセット・評価用データセットに振り分けていた [3,4]. これでは、予測時に存在するメソッドのバグの有無という実際のユースケースでは利用できないデータを学習用に利用していることになり、非現実的な実験結果につながると Pascarella らは主張している [5].

2.2.2 リリースバイリリース

従来の実験用データセット構築手法の問題点を解決する手法として、リリースバイリリースと呼ばれる手法を Pascarella らは提案した. リリースバイリリースにより




図 1 データセット構築手法 (従来手法) の概要
Fig. 1 The traditional dataset-building method




図 2 データセット構築手法 (リリースバイリリース) の概要
Fig. 2 The novel dataset-building method (release-by-release)

データセットが構築される工程を図 2 と以下に示す。

- (1) n 番目のリリース (R_n) 時点で存在するメソッドについて、バグの有無を算出し、 R_n から R_{n-1} までの変更履歴を参照して特徴量を算出する (評価用レコード算出)。
- (2) R_{n-1} 時点で存在するメソッドについて、実際のユースケースを逸脱しないために R_n 時点で取得可能なデータのみを用いてバグの有無を算出し、 R_{n-1} から R_{n-2} までの変更履歴を参照して特徴量を算出する (学習用レコード算出)。
- (3) 評価用レコードを評価用データセットに振り分け、学習用レコードを学習用データセットに振り分ける。

リリースバイリリースでは、予測時に取得できるデータのみを用いてバグ予測モデルを構築し、そのバグ予測モデルを用いて予測時に存在するメソッドについてバグの有無を判定しており、従来手法の問題は発生しない。

3. Research Questions

本研究では、下記の 3 つの Research Question(RQ) について調査した。

RQ1. *hasBeenFixed* はバグ予測モデルの目的変数として適切か。

RQ1 の目的は、*hasBeenFixed* の目的変数としての妥当性を定量的に評価することである。もし大半のバグメソッドが *hasBeenFixed* により捕捉されなかった場合、*hasBeenFixed* を目的変数とするモデル (*hasBeenFixed* モデル) はバグメソッドを正確に予測できず、*hasBeenFixed* は目的変数として不適切であると言える。

RQ2. *isBuggy* を目的変数としたモデルは *hasBeenFixed* を目的変数としたモデルより予測精度が低いのか。

RQ2 の目的は、以下の 2 つである。

- 現実的な設定におけるメソッド粒度バグ予測モデルの予測精度を知ること。
- *isBuggy* モデルと *hasBeenFixed* モデルについて予測精度を評価する対照実験を行い、現実的な設定のもとでバグを予測することの難しさを明らかにすること。

RQ3. 現実的な設定におけるメソッド粒度バグ予測において、(1) プロセスメトリクス算出時に参照する変更履歴の期間・(2) 学習に用いるメソッドの存在期間についての変更は予測精度改善に有効か。

RQ3 の目的は、現実的な設定のもとでのメソッド粒度バグ予測の予測精度を改善する方法を見つけることである。その方法の一つとして、リリースバイリリースが抱える下記の 2 つの問題を解決することを考えた。

- (1) リリース間隔に一貫性がない場合、学習対象のバグメソッドと予測対象のバグメソッドとの間で変更履歴についての特徴が異なってしまう。その解決策は、メトリクス算出時に参照する変更履歴の期間として、ある時点から N コミット前まで・ある時点から N ヶ月前までといった固定長の期間を用いることである。
- (2) バグ予測モデルを構築するための学習データとして、予測時を基準として直近のリリース時点に存在するメソッドから算出されるレコードしか利用しておらず、それより過去のメソッドから算出できるレコードを利用していない。その解決策は、過去のメソッドから算出できるレコードも学習データとして利用することである。

しかしながら、具体的にプロセスメトリクス算出時にどの程度の長さの期間を参照すればよいのか、どの程度古いメソッドを学習に用いればよいのかは不明である。よって、それら 2 つの設定を変更し、その結果どの程度予測精度が向上するのかを調査する。

4. 実験設定

本章では、各実験に共通する設定について述べる。

4.1 対象プロジェクト

本研究における対象プロジェクトは、下記の 4 つの条件を満たすプロジェクトから無作為に選択された 8 つのプロジェクトである。その概要を表 1 に示す。

- 開発履歴 (Git リポジトリ) を取得可能。
- プログラミング言語として Java を用いている。
- セマンティックバージョンングを採用している。
- メジャーバージョンの 3 回以上連続したリリースが確認できる。

4.2 リリース

リリースパイリリースという手法を用いて、学習用デー

タセット・評価用データセットを構築する。そのためには、プロジェクトについてリリース時点を特定する必要がある。我々は、Pascarella らによって提案された手法を用いて、セマンティックバージョンングを採用しているプロジェクトについてリリースを特定する。セマンティックバージョンングとは、プロジェクトのバージョンを $X.Y.Z$ (例: 1.2.1) の形式で表現する手法である。我々はセマンティックバージョンングにおけるメジャーバージョン (Y および Z が 0 であるリリース) をリリースとして利用する。

4.3 目的変数

hasBeenFixed・*isBuggy* というメトリクスを予測モデルの目的変数として利用する。それぞれの定義を以下に述べる。

4.3.1 hasBeenFixed

ある時点 T で存在する各メソッドについての *hasBeenFixed* は以下のように算出される。

step1 プロジェクトについて、修正済みのバグレポートとリポジトリを取得する。

step2 バグレポートはバグが発見された時に発行される。それぞれのバグレポートには ID が付与されている。本実験では、先行研究 [4] に倣ってコミットメッセージにバグレポートの ID が記載されているコミットをバグ修正コミットとし、リポジトリ内のバグ修正コミットを特定する。

step3 あるメソッドに対するバグ修正コミットが T 以前に存在するとき、そのメソッドを T 時点で *hasBeenFixed* について真であるとみなす。

step4 上記の操作が全てのバグレポートについて完了したとき、*hasBeenFixed* について真でないメソッドを *hasBeenFixed* について偽であるとみなす。

4.3.2 isBuggy

ある時点 T で存在する各メソッドについての *isBuggy* は SZZ アルゴリズム [6] を用いて以下のように算出される。SZZ アルゴリズムの実装としては Borg らによる実装を用

表 1 対象プロジェクト
Table 1 Target projects

プロジェクト名	開発期間	リリース数	コミット数	バグレポート数	メソッド数*	バグが有るメソッドの割合*
cassandra	4,529 日	3	26,172	5,582	15,893	8.0 %
egit	4,318 日	5	6,601	2,554	5,017	9.2 %
jgit	4,318 日	5	8,298	746	8,542	2.1 %
linuxtools	4,491 日	8	10,767	2,201	11,524	2.1 %
poi	7,116 日	3	10,881	2,673	19,408	16.3 %
realm-java	3,217 日	6	8,676	802	5,690	1.3 %
sonar-java	3,247 日	7	7,675	1,180	5,931	2.8 %
wicket	6,151 日	4	21,049	2,889	38,625	1.5 %

*各リリース時についての平均値

いた [7].

step1 *hasBeenFixed* 算出過程の step1 と同様である.

step2 *hasBeenFixed* 算出過程の step2 と同様である.

step3 メソッドのある行がバグ修正コミットにより変更されている場合, 変更された行を挿入したコミットを特定し, そのコミットをバグ混入コミットとみなす.

step4 メソッドに対するバグ修正コミットが T 以降に存在し, 対応するバグ混入コミットが T 以前に存在する場合, そのメソッドを T 時点で *isBuggy* について真であるとみなす.

step5 上記の操作が全てのバグレポートについて完了したとき, *isBuggy* について真でないメソッドを *isBuggy* について偽であるとみなす.

4.4 説明変数

我々は Giger らにより定義されたコードメトリクス・プロセスメトリクス [3] を説明変数として採用する. つまり, 各メソッドに対して算出されるこれらのメトリクスに基づいて, そのメソッドのバグの有無を予測する. それぞれの概要を表 2, 表 3 に示す.

4.5 学習アルゴリズム

学習アルゴリズムとしては, 多数の先行研究で採用されており [3-5, 8], 比較的高い精度で予測できている *Random Forest*(RF) [9] を採用した. その実装としては, *scikit-learn* [10] による実装を用いた.

4.6 ハイパーパラメータの最適化

ハイパーパラメータの最適化 (パラメータチューニング) は機械学習を用いて構築されるモデルの精度向上に有効である [11]. 本研究では学習用データセットに含まれるレコードの 1/5 をバリデーション用データセットとして用いる. そして, あるハイパーパラメータ群を採用して残りのレコードからモデルを構築し, その予測精度をバリデー

表 2 説明変数 (コードメトリクス)

Table 2 Independent variables(code metrics)

メトリクス名	概要
FanIn	そのメソッドを参照するメソッドの数
FanOut	そのメソッドが参照するメソッドの数
LocalVar	ローカル変数の数
Parameters	引数の数
CommentRatio	ソースコードに対するコメントの割合 (行単位)
CountPath	実行可能経路の数
Complexity	サイクロマティック数
execStmt	実行可能ステートメントの数
maxNesting	ネスト数の最大値

ション用データセットを用いて評価することでパラメータチューニングを行った. 探索対象のハイパーパラメータとその探索範囲は表 4 に示す. なおパラメータチューニングのアルゴリズムとしてはベイズ最適化 [12] を利用し, その実装としては *optuna* [13] を用いた. AMD Ryzen 9 3950X を搭載したコンピュータを用いて, モデルごとに 10 時間を費やしてパラメータチューニングを行った.

4.7 評価指標

バグ予測モデルを評価する指標を以下に示す.

$$\text{再現率} = \frac{|TP|}{|FN + TP|}$$

$$\text{適合率} = \frac{|TP|}{|FP + TP|}$$

$$F \text{ 値} = \frac{2 \times \text{再現率} \times \text{適合率}}{\text{再現率} + \text{適合率}}$$

$$AUC = \text{ROC 曲線の下側の面積}$$

TP はバグが存在すると予想され, 実際にバグが存在したメソッドの個数である. FN はバグが存在しないと予想され, 実際にはバグが存在したメソッドの個数である. FP はバグが存在すると予想され, 実際にはバグが存在しなかったメソッドの個数である. ROC 曲線は, 縦軸を TP , 横軸を FP とするグラフである.

表 3 説明変数 (プロセスメトリクス)

Table 3 Independent variables(process metrics)

メトリクス名	概要
MethodHistories	コミット回数
Authors	そのメソッドを編集した人数
StmtAdded	追加されたステートメントの総数
MaxStmtAdded	追加されたステートメントの最大値
AvgStmtAdded	追加されたステートメントの平均値
StmtDeleted	取り除かれたステートメントの総数
MaxStmtDeleted	取り除かれたステートメントの最大値
AvgStmtDeleted	取り除かれたステートメントの平均値
Churn	StmtAdded - StmtDeleted
MaxChurn	Churn の最大値
AvgChurn	Churn の平均値
Decl	メソッド宣言の変更回数
Cond	条件文の変更回数
ElseAdded	else 文の追加回数
ElseDeleted	else 文の削除回数

表 4 ハイパーパラメータと探索範囲

Table 4 Target hyperparameters and the range of values

パラメータ	探索範囲
RF モデルを構成する決定木の数	2~256
決定木の深さの最大値	2~256
決定木の葉ノード数の最大値	2~256
葉ノードを構成するサンプルの最小数	2~256
ノードを構成するサンプルの最小数	2~256




図 3 実験の概要 (RQ1)

Fig. 3 Summary of experiment (RQ1)

5. 実験

5.1 RQ1

RQ1 では, *hasBeenFixed* がバグの存在するメソッドを正確に捕捉できるかを実験により調査する. 実験工程を図 3 と以下に示す.

- (1) 対象プロジェクトの各リリース時点に存在するメソッドについて, *isBuggy* 及び *hasBeenFixed* を算出する.
- (2) *isBuggy* に対する *hasBeenFixed* のカバレッジの値を計測する. 計測されたカバレッジの値が 0.5 以下であれば, *hasBeenFixed* モデルは半数以上のバグメソッドを予測できないため, *hasBeenFixed* はバグ予測モデルの目的変数として不適切であると判定する.

5.1.1 評価指標

我々は, *hasBeenFixed* がバグ予測モデルの目的変数として妥当かを調査するための評価指標として, 以下にカバレッジを定義する.

$$\text{カバレッジ} = \frac{|X_{hasBeenFixed} \cap X_{isBuggy}|}{|X_{isBuggy}|}$$

$X_{hasBeenFixed}$ は, *hasBeenFixed* について真であるメソッドの集合である. $X_{isBuggy}$ は *isBuggy* について真であるメソッドの集合である. 例えば, 図 3 にあるメソッド *initialize* は R_n 時点で *hasBeenFixed* について真であり, *isBuggy* について偽であるため, *initialize* は R_n 時点で $X_{hasBeenFixed}$ の要素であり, $X_{isBuggy}$ の要素ではない.

5.1.2 実験結果

表 5 は *hasBeenFixed* がバグメソッドを捕捉できた割合であるカバレッジを対象プロジェクトの各リリース時点について算出した結果を示す. 全 38 件のリリース中, 35 件でカバレッジの値は 0.5 を下回っており, 平均的にカバレッジの値は 0.5 を大きく下回っている. よって, *hasBeenFixed* は大半のバグメソッドを捕捉できず, バグ予測モデルの目的変数として不適切である.

表 5 対象プロジェクトの各リリース時点についてのカバレッジ

Table 5 coverage on each target project & release

プロジェクト	リリース	バグメソッド数	カバレッジ
cassandra	R1	803	0.375
cassandra	R2	1239	0.337
cassandra	R3	1715	0.232
egit	R1	221	0.656
egit	R2	254	0.350
egit	R3	532	0.265
egit	R4	658	0.612
egit	R5	734	0.451
jgit	R1	72	0.181
jgit	R2	140	0.143
jgit	R3	171	0.111
jgit	R4	248	0.109
jgit	R5	269	0.093
linuxtools	R1	446	0.058
linuxtools	R2	272	0.121
linuxtools	R3	209	0.115
linuxtools	R4	273	0.205
linuxtools	R5	239	0.427
linuxtools	R6	142	0.169
linuxtools	R7	100	0.210
linuxtools	R8	2	1.000
poi	R3	2584	0.091
poi	R4	2500	0.322
realm-java	R1	74	0.243
realm-java	R2	82	0.134
realm-java	R3	248	0.020
realm-java	R4	36	0.083
realm-java	R5	22	0.000
realm-java	R6	6	0.000
sonar-java	R1	16	0.000
sonar-java	R2	53	0.057
sonar-java	R3	151	0.139
sonar-java	R4	394	0.142
sonar-java	R5	194	0.253
sonar-java	R6	194	0.180
wicket	R7	370	0.359
wicket	R8	184	0.196
wicket	R9	32	0.188
平均値		15879	0.254




図 4 実験の概要 (RQ2)
Fig. 4 Summary of experiment (RQ2)




図 5 n 個のリリースが存在する場合に算出される実験用データセット

Fig. 5 Calculated datasets on the project that has n releases

5.2 RQ2

RQ2 では、各対象プロジェクトの各リリースについて *hasBeenFixed* モデル及び *isBuggy* モデルを構築し、それらの予測精度を比較する。実験工程を図 4 と以下に示す。

- (1) 比較対象の目的変数である *hasBeenFixed*・*isBuggy* のそれぞれについて、以下の工程を行う。
 - (a) その目的変数を採用した場合の実験用データセットを対象プロジェクトの各リリースごとに構築する。データセット構築手法は 5.2.1 項で述べる。
 - (b) 実験用データセットごとにバグ予測モデルを構築し、予測精度を評価する。
- (2) 各目的変数を採用した場合の予測精度 (平均値) を比較評価する。

5.2.1 データセット構築

リリースバイリリースに従って学習用データセット及び評価用データセットを構築する。図 5 に示すように、プロジェクトの R_n について、学習用データセット S_{n-1} と評価用データセット T_{n-1} との組 (実験用データセット D_{n-1})

が算出される。プロジェクトの R_n についての実験用データセット D_{n-1} は下記のように算出される。

- (1) R_n 時点で存在する各メソッドについて、説明変数と目的変数の組 (レコード) を R_{n-1} から R_n までの変更履歴に基づいて算出し、評価用データセット T_{n-1} に振り分ける。
- (2) R_{n-1} 時点で存在する各メソッドについて、レコードを R_{n-2} から R_{n-1} までの変更履歴に基づいて算出し、学習用データセット S_{n-1} に振り分ける。
- (3) S_{n-1} にバグメソッドについてのレコードが 100 件以上存在する場合、 D_{n-1} を実験用データセットとして用いる。そうでなければ、バグメソッドの特徴を学習するにはデータ量が不十分であるとみなし、実験用データセットとして用いない。
- (4) 目的変数の値についてレコードの数に大きく偏りがある学習用データセットから構築されたモデルは、予測対象を多数派の目的変数の値へしか分類しないという問題が存在する (class-imbalance problem)。例えば、目的変数である *isBuggy* について偽であるレコードが多数派のデータセットに基づいてモデルを構築した場合、そのモデルへどのような説明変数を入力しても *isBuggy* について偽であると分類されてしまう。この問題を回避するために、学習用データセット S_{n-1} に含まれる *isBuggy* について真であるレコードを、*isBuggy* について偽であるレコードと同じ件数になるまで無作為にオーバーサンプリングする [14]。

5.2.2 実験結果

対象プロジェクトの各リリース時点について、*isBuggy* モデル・*hasBeenFixed* モデルをそれぞれ構築した。予測精度を評価した結果を表 6 に示す。

isBuggy モデルの F 値は平均で約 0.201, AUC は平均で




図 6 実験の概要 (RQ3)

Fig. 6 Summary of the experiment(RQ3)

約 0.746 と低い値が計測された。よって、現実的な設定のもとで高精度のメソッド粒度バグ予測モデルを構築するには課題が残ると言える。

また, *isBuggy* モデルの F 値 (平均値) は *hasBeenFixed* モデルより約 53.0% 低く, AUC については約 17.3% 低い。よって, 非現実的な設定と比較して, 現実的な設定のもとでバグを予測することは難しいと言える。

5.3 RQ3

RQ3 では, データセット構築手法をリリースバイリリースから部分的に変更した場合の予測精度の変化を調査する。具体的には, プロセスメトリクス算出時に参照する変更履歴の期間 (interval)・学習に用いるメソッドの存在期間 (period) を変更した場合の予測精度を評価する。RQ3 の実験工程を図 6 と以下に示す。

- (1) interval の値と period の値の組み合わせ (設定パターン) について, 以下の操作を行う。

表 6 対象プロジェクトの各リリースについての予測結果

Table 6 Prediction capability on each target project & release

プロジェクト名	学習→評価	isBuggy				hasBeenFixed			
		適合率	再現率	F 値	AUC	適合率	再現率	F 値	AUC
cassandra	R1 → R2	0.207	0.634	0.312	0.762	0.319	0.740	0.446	0.887
cassandra	R2 → R3	0.178	0.718	0.285	0.802	0.259	0.905	0.403	0.930
egit	R1 → R2	0.465	0.640	0.538	0.784	0.160	0.451	0.237	0.491
egit	R2 → R3	0.502	0.557	0.528	0.763	0.661	0.968	0.786	0.969
egit	R3 → R4	0.389	0.658	0.489	0.792	0.845	1.000	0.916	0.956
egit	R4 → R5	0.233	0.598	0.336	0.757	0.697	0.928	0.796	0.927
jgit	R2 → R3	0.155	0.566	0.243	0.719	0.067	0.965	0.125	0.916
jgit	R3 → R4	0.104	0.559	0.175	0.678	0.153	0.764	0.255	0.943
jgit	R4 → R5	0.045	0.730	0.085	0.671	0.036	0.957	0.070	0.781
linuxtools	R1 → R2	0.058	0.604	0.105	0.716	0.146	0.806	0.247	0.807
linuxtools	R2 → R3	0.043	0.407	0.077	0.685	0.151	0.226	0.181	0.849
linuxtools	R3 → R4	0.085	0.594	0.149	0.659	0.396	0.523	0.451	0.920
linuxtools	R4 → R5	0.102	0.773	0.181	0.817	0.310	0.791	0.445	0.950
linuxtools	R5 → R6	0.082	0.502	0.141	0.729	0.290	0.965	0.446	0.983
linuxtools	R6 → R7	0.018	0.337	0.033	0.670	0.153	0.938	0.264	0.976
poi	R3 → R4	0.107	0.678	0.185	0.607	0.353	0.933	0.512	0.769
realm-java	R3 → R4	0.021	0.366	0.039	0.618	0.081	0.359	0.132	0.756
sonar-java	R3 → R4	0.116	0.523	0.190	0.731	0.080	0.820	0.146	0.850
sonar-java	R4 → R5	0.075	0.736	0.136	0.812	0.477	0.673	0.559	0.951
sonar-java	R5 → R6	0.044	0.886	0.084	0.802	0.147	0.980	0.256	0.946
wicket	R7 → R8	0.032	0.503	0.061	0.696	0.296	0.586	0.393	0.939
wicket	R8 → R9	0.007	0.656	0.014	0.768	0.127	0.970	0.224	0.952
平均値		0.120	0.635	0.201	0.746	0.285	0.860	0.428	0.902

- (a) その設定パターンを採用した場合の実験用データセットを対象プロジェクトの各リリースごとに構築する. データセット構築手法は 5.3.3 項で述べる.
- (b) 実験用データセットごとにモデルの構築・精度評価を行い, その設定パターンを採用した場合の予測精度の平均値を算出する.

- (2) 各設定パターンを採用した場合の予測精度 (平均値) を比較し, 精度が最も高くなる設定パターンを特定する. また, そのときリリースバイリリースと比較して予測精度がどの程度改善したかを評価する.

5.3.1 プロセスメトリクス算出時に参照する変更履歴の期間 (interval)

リリースバイリリースでは, あるリリースからその直前のリリースまでの変更履歴を参照して, メソッドについてのレコードを算出する. このとき, リリース間隔に一貫性がなければ, 学習対象のバグメソッドの特徴と予測対象のバグメソッドの特徴が異なり, 予測精度が悪くなると考えられる. 一方で, ある時点から N ヶ月前まで, ある時点から N コミット前までといった固定長の期間を参照する場合, そのような問題は起こらないと思われる. しかしながら, どの程度の期間を参照すればよいのかは不明であるため, 本実験では下記の 10 パターンについて調査する. 各パターンを採用した場合の具体的なデータセット算出工程は 5.3.3 項で述べる.

- N コミット (ただし, N の候補値は 500, 1000, 1500, 2000, 2500 である.)
- N ヶ月 (ただし, N の候補値は 1, 2, 3, 6, 12 である.)

5.3.2 学習に用いるメソッドの存在期間 (period)

リリースバイリリースは, R_n 時点で存在するメソッドを評価用とした場合, 学習用に用いるメソッドは直前のリリースである R_{n-1} 時点で存在するメソッドのみである. リリースバイリリースのように直前のバグメソッドだけではなく, 昔のバグメソッドについての特徴も学習することで予測精度が向上する可能性がある.

しかしながら, どの程度古いメソッドを学習に用いればよいのかは不明であるため, 本実験では下記の 5 パターンについて調査する. なお, ある時点で存在するメソッドについて算出されたレコードの集合をデータブロックと定義し, 各パターンを採用した場合の具体的なデータセット算出過程は 5.3.3 項で述べる.

- $\text{last}(N_1/5)$: N_2 個存在するデータブロックのうち, 最新の $N_2 * N_1/5$ 個 (ただし, 小数点以下の数値は切り上げる. N_1 の候補値は 1, 2, 3, 4, 5 である.)




図 7 算出されるデータブロックの例 (interval = N コミット)

Fig. 7 Datablock calculation (interval = N commits)




図 8 データブロックの振り分け (period = $\text{last}(N/5)$)

Fig. 8 Datablock distribution (period = $\text{last}(N/5)$)

5.3.3 実験用データセット構築

本実験では, 対象とする interval・period・プロジェクト・リリース R_n に基づいて, 以下の手順で学習用データセット S_n と評価用データセット T_n との組 (実験用データセット D_n) を構築する.

- (1) 対象プロジェクトから, 以下の条件を満たすリリースを特定し, それを評価対象リリース R_n とおく.
 - 過去に 1 回以上のリリースを経ている.
 - 過去に 5,000 回以上のコミットを経ている.
 - 開発開始から 24 ヶ月以上経過している.
- (2) interval に従ってデータブロックを算出する. 算出例を図 7 に示す.
 - (a) R_n 時点をも t_0 とおく. t_0 から interval だけ前の時点 t_1 を特定し, t_1 から interval だけ前の時点 t_2 を特定する, というふうに再帰的に参照時点を特定する.
 - (b) 参照時点 t_k で存在するメソッドについて, バグの有無を算出し, t_{k+1} から t_k までの変更履歴を参照してレコードを算出し, それらのレコードをデータブロック B_k とする.
- (3) 算出されたデータブロックを, period に従って評価用データセット T_n ・学習用データセット S_n に振り分ける. 振り分けの例を図 8 に示す.
 - (a) データブロック B_0 を評価用データセット T_n に振り分ける.
 - (b) $\text{last}(N_1/5)$ が採用されている場合, B_0 以外のデータブロック N_2 個のうち最新の $N_2 * N_1/5$ 個 (小数点以下切り上げ) を学習用データセット S_n に振り分ける. 例えば, データブロックとして B_1, B_2, B_3, B_4 が存在し, $\text{last}(1/5)$ が採用されている場合, 最新の $4 * (1/5) = 0.8 \approx 1$ 個である B_1 のみが学習用データ

セットに振り分けられ、last(4/5) が採用されている場合、最新の $4 * (4/5) = 3.2 \approx 4$ 個である全てのデータブロックが学習用データセットに振り分けられる。

- (4) S_n にバグメソッドについてのレコードが 100 件以上存在する場合、それらを実験用データセットとして用いる。そうでなければ、バグメソッドの特徴を学習するにはデータ量が不十分であるとみなし、実験用データセットとして用いない。
- (5) 目的変数の値についてレコードの数に大きく偏りがある学習用データセットから構築されたモデルは、予測対象を多数派の目的変数の値へしか分類しないという問題が存在する (class-imbalance problem)。例えば、目的変数である *isBuggy* について偽であるレコードが多数派のデータセットに基づいてモデルを構築した場合、そのモデルへどのような説明変数を入力しても *isBuggy* について偽であると分類されてしまう。この問題を回避するために、学習用データセット S_n に含まれる *isBuggy* について真であるレコードを、*isBuggy* について偽であるレコードと同じ件数になるまで無作為にオーバーサンプリングする [14]。

5.3.4 実験結果

各設定パターンに基づいて、バグ予測モデルを構築した場合の予測精度の平均値を表 7 に示す。最も予測精度 (F 値・AUC) が高くなるのは interval として 12 ヶ月を、period として last(5/5) を採用したときであった。このとき、F 値は約 0.196 であり、リリースバイリリースを用いた場合と比較して約 16.7% の精度向上が見られた。また、AUC は約 0.773 であり、約 3.0% の精度改善が見られた。

6. 妥当性の脅威

6.1 内的妥当性

6.1.1 メトリクス算出アルゴリズムの妥当性

説明変数であるコードメトリクス・プロセスメトリクス及び目的変数である *isBuggy*・*hasBeenFixed* を算出するツールは、調査にあたって一から実装した。Giger らによるメトリクスの説明 [3] に従って実装したものの、正確な値が算出できていない可能性がある。

また、目的変数の算出については、下記の 2 つの問題がある。

- (1) *isBuggy* は SZZ アルゴリズムを用いて算出されており、SZZ アルゴリズムには精度の面で改善の余地がある [15, 16]。SZZ アルゴリズムはバグ修正に基づいて、そのバグが混入した時点を特定する。過去の調査では、その特定精度が約 77% であった [15]。
- (2) バグが顕在化していないメソッドを、バグが存在しな

表 7 採用した設定パターンに対する予測精度 (AUC について降順)

Table 7 Prediction capability on each setting (descending order on AUC)

interval	period	適合率	再現率	F 値	AUC
12 ヶ月	last(5/5)	0.117	0.601	0.196	0.773
6 ヶ月	last(1/5)	0.104	0.672	0.180	0.772
6 ヶ月	last(3/5)	0.110	0.635	0.187	0.770
12 ヶ月	last(4/5)	0.117	0.609	0.196	0.768
2000 コミット	last(5/5)	0.109	0.602	0.185	0.765
6 ヶ月	last(2/5)	0.108	0.627	0.184	0.764
6 ヶ月	last(4/5)	0.103	0.630	0.178	0.763
12 ヶ月	last(3/5)	0.109	0.607	0.185	0.763
12 ヶ月	last(2/5)	0.109	0.599	0.185	0.762
2000 コミット	last(4/5)	0.111	0.589	0.187	0.760
6 ヶ月	last(5/5)	0.113	0.615	0.191	0.760
2000 コミット	last(3/5)	0.110	0.580	0.184	0.760
1500 コミット	last(5/5)	0.105	0.595	0.179	0.757
3 ヶ月	last(4/5)	0.105	0.639	0.180	0.756
2000 コミット	last(1/5)	0.103	0.636	0.177	0.755
2500 コミット	last(4/5)	0.106	0.590	0.180	0.755
2000 コミット	last(2/5)	0.102	0.613	0.175	0.754
2500 コミット	last(2/5)	0.104	0.597	0.177	0.754
1000 コミット	last(3/5)	0.102	0.626	0.175	0.754
1 ヶ月	last(1/5)	0.103	0.651	0.177	0.754
2 ヶ月	last(4/5)	0.101	0.648	0.174	0.754
2500 コミット	last(5/5)	0.108	0.583	0.183	0.753
3 ヶ月	last(5/5)	0.102	0.641	0.175	0.753
2500 コミット	last(3/5)	0.104	0.584	0.177	0.752
2 ヶ月	last(2/5)	0.103	0.602	0.177	0.752
1000 コミット	last(5/5)	0.102	0.616	0.176	0.751
リリースバイリリース		0.096	0.658	0.168	0.751
2 ヶ月	last(3/5)	0.103	0.634	0.177	0.750
3 ヶ月	last(2/5)	0.099	0.620	0.171	0.750
3 ヶ月	last(3/5)	0.106	0.596	0.180	0.749
2 ヶ月	last(5/5)	0.100	0.638	0.173	0.748
1500 コミット	last(4/5)	0.106	0.598	0.180	0.748
1 ヶ月	last(3/5)	0.100	0.626	0.172	0.748
500 コミット	last(3/5)	0.103	0.595	0.175	0.747
1000 コミット	last(4/5)	0.103	0.619	0.176	0.746
2500 コミット	last(1/5)	0.100	0.611	0.171	0.746
1 ヶ月	last(4/5)	0.097	0.639	0.169	0.746
1000 コミット	last(2/5)	0.101	0.603	0.173	0.745
1500 コミット	last(1/5)	0.099	0.619	0.171	0.745
1500 コミット	last(3/5)	0.105	0.600	0.178	0.745
1 ヶ月	last(5/5)	0.099	0.626	0.170	0.745
1500 コミット	last(2/5)	0.100	0.615	0.172	0.744
500 コミット	last(2/5)	0.100	0.601	0.171	0.743
2 ヶ月	last(1/5)	0.096	0.630	0.167	0.742
1000 コミット	last(1/5)	0.102	0.604	0.175	0.742
3 ヶ月	last(1/5)	0.095	0.601	0.164	0.742
12 ヶ月	last(1/5)	0.105	0.593	0.178	0.742
500 コミット	last(4/5)	0.101	0.596	0.173	0.741
500 コミット	last(5/5)	0.100	0.595	0.172	0.739
1 ヶ月	last(2/5)	0.096	0.622	0.166	0.739
500 コミット	last(1/5)	0.092	0.595	0.159	0.727

いメソッドとみなしてしまっている。本研究では、実際に行われたバグ修正に基づいて、バグメソッドを特定している。よって、バグが潜在しているメソッドが存在し、それらのメソッドの特徴をバグが存在しないメソッドの特徴としてモデルが学習してしまっている恐れがある。

6.1.2 パラメータチューニングの不足

パラメータチューニングは機械学習を用いて構築されたモデルの精度向上に有効である [11]。本調査では各モデルの構築時に 10 時間のパラメータチューニングを行ったが、より多くの時間を費やせば、より高精度のバグ予測モデルが構築される可能性がある。

6.2 外的妥当性

6.2.1 対象言語

本調査では Java で開発されているプロジェクトを対象としており、他の言語で記述されたプロジェクトに対しては、本調査で得られた知見が当てはまらない可能性がある。

6.2.2 対象プロジェクト

本調査では 4.1 項に記載された条件を満たす、比較的大規模な OSS プロジェクトのみを実験対象としており、その他のプロジェクトに関しては本調査で得られた知見が当てはまらない可能性がある。

7. おわりに

本研究が最終目的として見据えているのは、実用的なバグ予測モデルの構築であり、本研究はその第一歩である。

本研究では、まず先行研究でバグ予測モデルの目的変数として採用された *hasBeenFixed* の妥当性を調査した。その結果、*hasBeenFixed* が補足できたバグメソッドの割合は 0.5 を大きく下回っているため、*hasBeenFixed* はバグ予測モデルの目的変数として妥当ではないと判明した。次に、現実的な設定のもとでメソッド粒度バグ予測モデルを構築・評価した。その結果、予測精度は F 値が平均で約 0.201、AUC は平均で約 0.746 とかなり低く、現実的な設定のもとで実用的なバグ予測モデルを構築するには課題が残されていると判明した。また、適切な変更履歴の期間および学習に用いるメソッドの存在期間を採用することで、予測精度が F 値の観点で約 16.7%、AUC の観点で約 3.0% 向上することが確認できた。

現在、我々は現実的な設定のもとでバグ予測モデルの予測精度を改善する方法を模索している。特に、ヒューリスティックに基づいて算出されたメトリクスを説明変数として利用するのではなく、深層学習を用いてソースコードやコミット履歴から抽出される特徴量を説明変数として利用することを考えている。

謝辞 本研究は、日本学術振興会科学研究費補助金基盤

研究 (B) (課題番号：20H04166) の助成を得て行われた。

参考文献

- [1] 情報処理推進機構. ソフトウェア開発分析データ集 2020. <https://www.ipa.go.jp/files/000085879.pdf>.
- [2] Tom Britton, Lisa Jeng, Graham Carver, Paul Cheak, and Tomer KKatzenellenbogen. Increasing software development productivity with reversible debugging. https://undo.io/media/uploads/files/Undo_ReversibleDebugging_Whitepaper.pdf.
- [3] Emanuel Giger, Marco D'Ambros, Martin Pinzger, and Harald Gall. Method-level bug prediction. In *International Symposium on Empirical Software Engineering and Measurement*, pp. 171–180, 2012.
- [4] Hideaki Hata, Osamu Mizuno, and Tohru Kikuno. Bug prediction based on fine-grained module histories. *Proceedings - International Conference on Software Engineering*, pp. 200–210, 2012.
- [5] L. Pascarella, F. Palomba, and A. Bacchelli. Re-evaluating method-level bug prediction. In *2018 IEEE 25th International Conference on Software Analysis, Evolution and Reengineering (SANER)*, pp. 592–601, 2018.
- [6] Jacek Sliwinski, Thomas Zimmermann, and Andreas Zeller. When do changes induce fixes? *SIGSOFT Software Engineering Notes*, Vol. 30, No. 4, pp. 1–5, 2005.
- [7] Markus Borg, Oscar Svensson, Kristian Berg, and Daniel Hansson. Szz unleashed: An open implementation of the szz algorithm - featuring example usage in a study of just-in-time bug prediction for the jenkins project. In *Proceedings of the 3rd ACM SIGSOFT International Workshop on Machine Learning Techniques for Software Quality Evaluation*, pp. 7–12, 2019.
- [8] Stefan Lessmann, Bart Baesens, Christophe Mues, and Swantje Pietsch. Benchmarking classification models for software defect prediction: A proposed framework and novel findings. *IEEE Transactions on Software Engineering*, Vol. 34, No. 4, pp. 485–496, 2008.
- [9] A. Liaw and M. Wiener. Classification and regression by randomforest. In *R news*, Vol. 2, pp. 18–22, 2002.
- [10] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, Vol. 12, pp. 2825–2830, 2011.
- [11] 尾崎嘉彦, 野村将寛, 大西正輝. 機械学習におけるハイパパラメータ最適化手法: 概要と特徴. 電子情報通信学会論文誌 D, Vol. 103, No. 9, pp. 615–631, 2020.
- [12] J. Moćkus. On bayesian methods for seeking the extremum. In *Optimization Techniques IFIP Technical Conference Novosibirsk*, pp. 400–404, 1975.
- [13] Takuya Akiba, Shotaro Sano, Toshihiko Yanase, Takeru Ohta, and Masanori Koyama. Optuna: A next-generation hyperparameter optimization framework. In *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, pp. 2623–2631, 2019.
- [14] Nitesh V. Chawla. *Data Mining and Knowledge Discovery Handbook*, pp. 875–886. Springer, 2010.
- [15] Chadd Williams and Jaime Spacco. Szz revisited: Verifying when changes induce fixes. In *Proceedings of the 2008 Workshop on Defects in Large Software Systems*,

pp. 32-36, 2008.

- [16] D. A. da Costa, S. McIntosh, W. Shang, U. Kulesza, R. Coelho, and A. E. Hassan. A framework for evaluating the results of the szz approach for identifying bug-introducing changes. *IEEE Transactions on Software Engineering*, Vol. 43, No. 7, pp. 641-657, 2017.

荻野 翔

令和2年大阪大学基礎工学部情報科学科卒業。現在、大阪大学大学院情報科学研究科博士前期課程在学中。ソフトウェアリポジトリマイニングに関する研究に従事。

肥後 芳樹 (正会員)

2002年大阪大学基礎工学部情報科学科中退。2006年同大学大学院博士後期課程修了。2007年同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助教。2015年同准教授。博士(情報科学)。ソースコード分析、特にコードクローン分析、リファクタリング支援、ソフトウェアリポジトリマイニングおよび自動プログラム修正に関する研究に従事。電子情報通信学会、日本ソフトウェア科学会、IEEE 各会員。

楠本 真二 (正会員)

1988年大阪大学基礎工学部卒業。1991年同大学大学院博士課程中退。同年同大学基礎工学部助手。1996年同講師。1999年同助教授。2002年同大学大学院情報科学研究科助教授。2005年同教授。博士(工学)。ソフトウェアの生産性や品質の定量的評価に関する研究に従事。電子情報通信学会、IEEE、IFPUG 各会員。