# 深層学習による不具合混入コミットの予測と評価

近藤 将成[1,3,a)]　森 啓太[1,b)]　水野 修[2,c)]　崔 銀恵[3,d)]

**概要**：ソフトウェアの不具合予測は，ソフトウェアに潜む不具合を予測することで効率的なレビューやテストを可能にしようとするソフトウェア品質保証活動の 1 つである．従来の多くのソフトウェアの不具合予測では，ソースコード分析による不具合予測を行なっているが，粒度が荒くまた不具合予測の結果のフィードバックが遅い．この問題を解決するために，ソフトウェアの変更がコミットされた時に，その変更によって不具合が起きるかどうかを予測する手法が提案され，近年注目を集めている．ソフトウェアの変更コミットの不具合予測に関する既存研究では，その変更に対するメトリクス（例えば，修正されたファイル数，追加されたコード行数など）を計算した後に機械学習や深層学習を適用している．それに対して，本研究では，変更のソースコード片のみに対して深層学習を適用することで不具合を予測する手法（W-CNN）を提案する．我々は，評価実験によって，変更ソースコード片に対する深層学習を用いた不具合予測が可能であること，更に，提案手法 W-CNN は先行研究に比べて，学習の時間はかかるものの，不具合予測の精度が優れていることを示す．

## 1. はじめに

ソフトウェアの品質は現在の我々の生活に大きな影響を与えており，テストやレビューといった品質保証活動が重要である．ソフトウェアの品質保証を効率的に行うための 1 つの手法として，不具合予測手法の研究がなされてきている [2, 7, 10, 17, 24, 25, 27]．不具合予測とは，過去のソフトウェア開発の履歴情報やソースコードから取り出された特徴を用いて，不具合が混入しそうなソフトウェアのモジュールやファイルを予測する手法である．この予測結果を用いることで，効率的なテストやレビューを行い，リリース後のソフトウェアの不具合を減らすことが可能である．

近年，ツールの発展 [1, 6, 18] や潤沢でオープンアクセス可能なデータの公開 [9, 15, 20] により，機械学習を用いた不具合予測手法が盛んに研究されている [2, 7, 10, 24, 25, 27]．中でも，深層学習の他分野での発展 [4, 11, 13, 26] を受けて，深層学習を用いた不具合予測手法の研究にも注目が集まっている [24, 25]．

深層学習を用いた不具合予測の既存研究 [24, 25] では，深層学習アルゴリズムの 1 つであるディープビリーフネットワークを用いることで，従来の特徴セットから不具合予測に対して有効な特徴セットを生成できることを示している．Yang らの研究 [25] では，変更に対するソフトウェアメトリクスに対して深層学習を適用している．また，Wang らの研究 [24] では，ソースコードを抽象構文木によって解析し，その特徴を用いている．

しかし，我々が知る限り，変更のソースコード片に対して深層学習を適用した不具合予測手法の研究は未だ行われていない．変更に対する不具合予測は，ソフトウェアの変更コミット時に細かい粒度で不具合を予測でき，予測結果のフィードバックも速い，という利点がある [9]．また，ソースコードに対する不具合予測手法では，メトリクスを使用せずにテキストのみを利用して予測する手法が示されており [17]，同様に変更のソースコード片に対しても，メトリクスを用いずに予測することが可能である [2, 7, 10]．

そこで，本研究では，変更のソースコード片に対して深層学習を適用して不具合予測を行う手法を提案し，提案法の不具合予測性能を評価する．深層学習には，畳み込みニューラルネットワーク（Convolutional Neural Network: CNN）を用いる．CNN は主に画像のカテゴリ分類での成功が大きいが [13]，近年ではテキスト分類でも成果を示している [4, 11, 26]．我々はソースコード片をテキストと見なし，不具合を起こすか否かの分類に CNN を適用する．適用する CNN モデルは，Kim のモデル [11] を参考にして構築する．このモデルは，テキストの単語レベルの情報を用いて分類を行う．以上の特徴を備えた我々の提案手法を，W-CNN（Word-CNN）と呼ぶこととする．

[1] 京都工芸繊維大学 大学院工芸科学研究科 情報工学専攻
[2] 京都工芸繊維大学 情報工学・人間科学系
[3] 産業技術総合研究所 情報技術研究部門
[a)] m-kondo@se.is.kit.ac.jp
[b)] k-mori@se.is.kit.ac.jp
[c)] o-mizuno@kit.ac.jp
[d)] e.choi@aist.go.jp

本研究では，W-CNN を評価するために以下の 3 つの研究設問を設定する．

**RQ1:** 提案手法 W-CNN による不具合の学習・予測は可能か?

**RQ2:** 提案手法 W-CNN は既存の変更に対する深層学習を用いた不具合予測手法よりも予測精度が良いか?

**RQ3:** 提案手法 W-CNN の学習時間はどの程度か?

これらの研究設問に応えるために，我々は，提案手法の W-CNN と，ソースコードの変更メトリクスに対して深層学習を適用する既存の不具合予測手法である Yang ら [25] の手法（Deeper）との比較評価実験を行なう．実験では，7 つの Java もしくは C++で書かれたオープンソースソフトウェアプロジェクトを用いて，予測精度と学習時間を調査する．その結果，RQ1 に対して，提案手法 W-CNN は対象データに対する不具合の学習，及び，不具合の予測が可能であることがわかった．RQ2 に対して，W-CNN は既存の深層学習を用いた不具合予測手法 Deeper と比較して予測精度を計る一般的な尺度 AUC（Area Under the receiver operating characteristic Curve）の値を平均 22%程度上げることができた．RQ3 に対して，W-CNN は既存の手法 Deeper より学習に時間がかかるが，学習後の各コミットに対する予測時間は 0.0004 秒程度と非常に短く，変更数に対する実行時間のオーバーヘッドは少ないことがわかった．

本研究の主な貢献を以下にまとめる．

(1) ソフトウェアの変更コミット時のソースコード片に対して，深層学習を適用することで，不具合予測が可能であることを，我々が知る限り初めて示した．
(2) 提案手法 W-CNN は，既存の不具合予測手法よりも学習に時間がかかるが，高い不具合予測精度をもたらすことが可能であることを確認した．

以降の本稿の構成を紹介する．第 2 章では，不具合予測，及び，深層学習を適用した不具合予測の関連研究について述べる．第 3 章では，提案手法である W-CNN について説明する．第 4 章では，評価実験について説明する．第 5 章では，それぞれの研究設問に対する結果をまとめる．第 6 章では，本研究の妥当性の検証を行う．第 7 章では，本研究の結論を述べる．

## 2. 関連研究

### 2.1 不具合予測手法

不具合予測はソフトウェアの品質保証活動の 1 つとして重要な分野であり，これまでに様々な不具合予測手法が提案されてきている [2,7,10,17,24,25,27]．例えば，Zimmermann らの研究 [27] では，ソースコードに関する複雑度メトリクスを用いてロジスティック回帰モデルを作成し不具合の予測を行なっている．しかし，このように複雑度メトリクスなどを用いてファイルやパッケージレベルで不具合を予測する手法にはいくつかの問題が指摘されている [9]．例えば，予測する時期が遅いという問題がある．開発者は，ソースコードを書いている時に，その追加した機能に不具合が含まれているかを知りたい．しかし，ファイルやパッケージレベルではこの段階での予測が難しい．そのため，追加した機能の記憶が薄れてから修正を行うことになり，効率的であるとは言い難い．

この問題を解決するために，ソフトウェアの変更に対するメトリクス（以降，変更メトリクス）を用いる手法を亀井らは提案している [9]．開発者が変更（コミット）を行なった際に，その変更に不具合が含まれているかどうかを判断する方法により，変更を行なったすぐ後に不具合が含まれていそうか否かがわかるため，素早いフィードバックや，品質保証活動を適切な開発者に割り当てられるなどの利点が期待できる [8]．よって，今回の我々の研究では，変更に対する不具合予測手法を提案する．

その他の不具合予測手法としては，ソースコードなどのテキストに注目している手法も研究されている [2,7,10,17]．テキストは複雑度メトリクスなどと比較して収集が容易であるという利点がある [17]．テキストとしてはソースコードが用いられることが多く，テキスト分類技術によって不具合が混入しているテキストと，そうではないテキストを分類する手法が研究されている．例えば水野らの研究 [17] では，ソースコードのみを学習データとし，スパムフィルタを用いて学習することで不具合予測を行なっている．また，提案手法に似た手法として，変更に関するテキスト情報を用いた不具合予測手法がいくつか提案されているが [2,7,10]，変更のソースコード片に対して深層学習を用いた不具合予測手法は提案されていない．

### 2.2 深層学習を用いた不具合予測手法

不具合予測手法においては，すでに深層学習を適用する研究が行われている．Yang らの研究 [25] では，亀井らの提案している変更メトリクス [9] から特徴を生成し，その特徴を入力としてディープビリーフネットワークを用いて不具合予測を行なっている．Wang らの研究 [24] は，ソースコードを抽象構文木で分析し，その特徴をディープビリーフネットワークで分析し，ソースコードの意味的な違いを表現することで，不具合予測の精度を向上できることを示している．Lam らの研究 [14] は，バグレポートからの不具合推定を行うために深層学習と IR 技術を結合する手法を提案し，既存の手法よりも推定精度がよくなることを示している．しかし，これらの研究では，変更に関するテキスト情報に対して深層学習を適用していない．我々は CNN のみからなる深層学習を用いた変更に対するシンプルなテキストベースの不具合予測手法を提案する．

提案手法との比較のために，我々と同様に変更に対する不具合予測手法であり，かつ深層学習を用いている Yang らの Deeper [25] を選択する．提案手法 W-CNN と Deeper

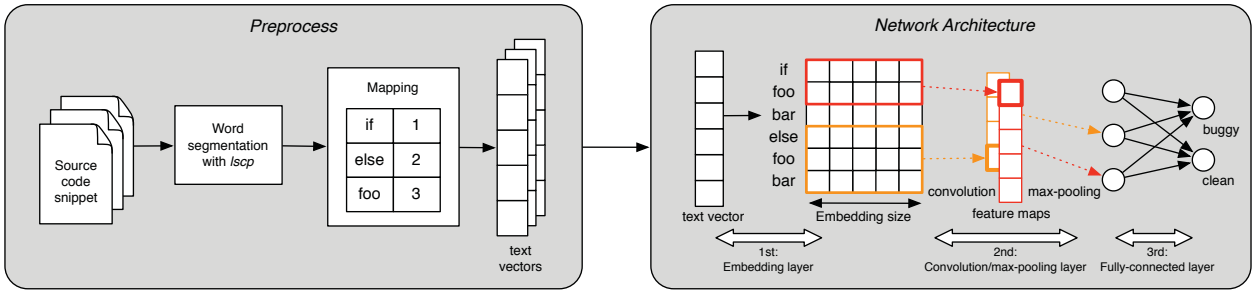


**図 1** 提案手法 W-CNN の構成の概要.

の大きな違いは以下の 3 点である.

(1) 深層学習のモデル：W-CNN は CNN を用いるが, Deeper はディープビリーフネットワークを用いている.

(2) 分類手法：W-CNN は深層学習を用いるが，Deeper はロジスティック回帰を用いている.

(3) 分析するデータ対象：W-CNN はソースコード片を用いるが，Deeper はメトリクスを用いている.

## 3. 提案手法

深層学習の一種である畳み込みニューラルネットワーク (CNN) は人の網膜を模倣したニューラルネットワークであり，画像分類で成功を収めてきたアルゴリズムである [13]. 最近ではテキスト分類においても高い精度が得られることがわかってきている [4, 11, 26]. 我々は不具合予測問題を，ソースコードを特徴として用いるテキスト分類問題として捉え，CNN を用いた解法を提案する.

一般に深層学習は層の数が多い程表現力がよくなる反面，大量の学習データと時間を要する傾向にあるため，大規模な深層学習はソフトウェアプロジェクトに適用することが難しい. 例えば，Zhang らの畳み込みニューラルネットワークを用いたテキスト分類モデル [26] では，隠れ層が 9 層の CNN を構成しており，100 万個程度の訓練データを用いている. しかし，我々が対象とするソフトウェアプロジェクトの不具合予測に用いる変更の学習データ数は，比較的に大きい場合でも数千から 1 万個程度である.

そのため，我々は Kim により提案されている比較的に小規模なテキスト分類モデル [11] を利用する. このモデルは隠れ層が 3 層の CNN であり，Zhang らの 9 層の CNN と比較して軽量である. また，Kim のモデルは 4,000 から 10,000 程度の訓練データでネットワークを学習可能であることから，ソフトウェアプロジェクトの不具合予測に対しても適用可能であると判断する. 我々は Kim のモデルを参考に，ソースコードの単語レベルの情報を用いた分類機を作成する.

**図 1** に提案する不具合予測手法 W-CNN の構成の概要を示す. 提案手法は，分析対象のリポジトリからソースコード片を取り出す前処理（Preprocess）と，ソースコード片から特徴を取り出し分類の処理を行うネットワーク（Network Architecture）から成る. 処理の流れを以下に説明する.

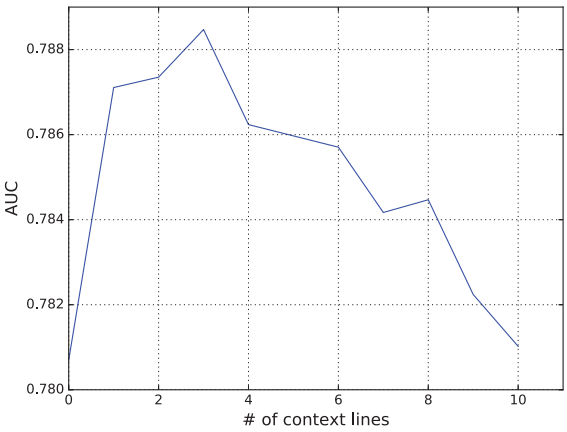


**図 2** 文脈数と W-CNN による分類精度の関係（Hadoop）. Context lines が文脈行を意味する.

(1) 前処理： 分析対象のリポジトリから得られた各コミットの追加・修正されたソースコードを単語分割し，それぞれのコミットの特徴とする.

(2) ネットワーク： コミットの単語分割されたソースコード片を入力とし，ネットワークで特徴の学習，及び，分類を行う.

### 3.1 前処理

**(1) ソースコード片の作成：** ソースコード片は，変更により追加・修正された差分のソースコードをつなぎ合わせた文字列である. 作成方法について述べる. 取得する変更の差分はソースファイル [*1] のみからとする. これは，ドキュメントファイルなどは不具合に繋がる可能性が低いと考えられるためである. 不具合を混入したコミットを見つけることを目的とするため，対象のソースコードとして追加もしくは修正された行を集める.（ただし，削除行は含めない. 理由は後述する.）さらに，追加修正行の前後 3 行を文脈情報として集める. これは，変更におけるコード片

[*1] ここで，ソースファイルとは，分析対象が C++，及び，Java であったことから，拡張子が java, c, h, cpp, hpp, cxx, hxx のファイルとする.

**[Commit: d80f93cca26f82126f408179fdc8c3c6c1ccbc7f のソースコード片]**

components/camel-kafka/src/main/java/org/apache/camel/component/kafka/KafkaConfiguration.java } public String getSaslMechanism() { return saslMechanism; } public void setSaslMechanism(String saslMechanism) { this.saslMechanism = saslMechanism; } public String getSecurityProtocol() { return securityProtocol; }

**[Commit: 2645cc184f549da4c2ce398a8ea9704927524b2e のソースコード片より一部抜粋]**

components/camel-kafka/src/main/java/org/apache/camel/component/kafka/KafkaConfiguration.java private Integer reconnectBackoffMs = 50; @UriParam(label = "common", defaultValue = SaslConfigs.DEFAULT_SASL_MECHANISM) private String saslMechanism = SaslConfigs.DEFAULT_SASL_MECHANISM; @UriParam(label = "common", defaultValue = SaslConfigs.DEFAULT_KERBEROS_KINIT_CMD) private String kerberosInitCmd = SaslConfigs.DEFAULT_KERBEROS_KINIT_CMD; @UriParam(label = "common", defaultValue = "60000") private Integer kerberosBeforeReloginMinTime = 60000; @UriParam(label = "common", defaultValue = "0.05") private Double kerberosRenewJitter = SaslConfigs.DEFAULT_KERBEROS_TICKET_RENEW_JITTER;

**図 3** 変更のソースコード片の例（Camel Project，2 つのコミットから一部を抜粋）．

の情報のみを使う場合よりも，その前後のソースコードの文脈情報を追加する方が，より自然言語処理のようにソースコードの意味を学習可能であると仮説を立てたためである．我々が知る限り，文脈行を不具合予測に適用した先行研究はこれまでに存在しない．そこで，Hadoop プロジェクトに対して，0 行から 10 行までの文脈行数の不具合予測への影響を測定した．Git の diff コマンドで標準で出力される前後 3 行がもっとも良かったため，文脈行数は 3 とする（**図 2**）．より詳しくは妥当性の検証の構成概念妥当性にて述べる．ただし，コメント行はソフトウェアの動作に関係がないため取得しない．以上のソースコードを，変更されたファイルごとに取得し，それぞれのソースコードの先頭にそのソースコードを取得したファイル名を付与した文字列を連結することで 1 つのソースコード片とする．ソースコードのファイル名を付与する理由は，そのソースコード片がどのような機能をもつソースコードの一部であるのかを，もっとも端的に示すことができる文字列だからである．変更のソースコード片の例を**図 3** に示す．なお，ここでは 2 つのコミットからソースコード片の一部を抜粋している．赤で示されているのがファイル名，それ以外がソースコード片である．

提案法では，削除行そのものはソースコード片として考慮しない．ただし，削除行の文脈行は考慮する．これは，削除行そのものは，そのコミットを取得した際に削除されるため，直接の不具合の原因にはならないと考えられるためである．ただし，削除することによりその前後のソースコードに影響を与え不具合の原因となることは考えられるため，その文脈行はソースコード片として考慮する．

**（2）単語分割：**Kim のモデルでは，入力文書を単語分割しているため，我々もソースコード片を単語分割する必要がある．ソースコード片の単語分割には Thomas が公開している lscp[*2]（A lightweight source code preprocessor）[23] を用いる．lscp はソースコードを構文解析せずに経験則的に単語分割を行うためソースコード片にも適用可能である．

CNN は固定長の入力のみを受け付けるという制約が存在するため，分割された単語を持つソースコード片の単語数を固定長にする．ここでは，2,000 語を閾値としてそれ以上の場合は切り詰め，制限に満たない場合は足りない文字数を 0 で補う 0 埋めを行う．例えば，2,003 語を持つコミットは，先頭から 2,000 語までを用いて，残りの 3 語を切り捨てる．一方で，1,800 語のコミットは，2,000 語として処理するために足りない残りの 200 語を 0 として処理する．つまり，各コミットのソースコード片の単語数が全て 2,000 語で統一される．0 埋めは深層学習を用いる際に一般に用いられる手法である．一方で，切り詰めの処理は一般には行われないが，もっとも多くの単語数を持つコミットに合わせると，入力が非常に大きくなり計算が難しくなる．2,000 語を閾値とする場合，多くのプロジェクトで 90%以上のコミットの全ての単語を分析可能であるため，提案法では 2,000 を閾値として切り詰めの処理を行なう．切り詰め方法としては，先頭から数えて 2,000 文字以降を切り捨てる簡潔な方法を採用する．

**（3）マッピングとベクトル変換：**最後に，手に入れた 2,000 語の単語に対してこの 2,000 語内での頻出単語順に 1 から数字をマッピングし，マッピングテーブルを作成する．マッピングテーブルを利用して，訓練データ，及び，テストデータをテキストベクトル（Text vectors）へ変換する．ただし，マッピングテーブルにない単語は 0 とする．ここでマッピングテーブルにないとは，2,000 語の単語の中に含まれていない単語を指す．ここでの出力は，ソースコード片を持つコミットが 1 次元の数値ベクトルに変換される．数値ベクトルの各値はそのコミットのソースコード片の各単語に対応する．

数値へのマッピングは，CNN が数値ベクトルのみを処理可能であるため，必要である．マッピングの際，頻出単語順に 1 から数字をマッピングする理由は，数値の大きさによって単語の重要度に差をつけるためである．例えば，画像の認識では，数値の大きさは画素の色に対応しており，その数値の差をエッジとして捉えるなどが行われるが，提案法ではそれを模倣している．なお，提案法では，マッピングテーブルに存在しない単語は重要単語ではないと仮定し，0 へマッピングすることでその影響を無くす．

### 3.2 ネットワーク

前処理によって得られるテキストベクトルを各コミットの特徴とし，W-CNN のネットワークに入力する．ネットワークでは，特徴の抽出，及び，分類が CNN によって

[*2] https://github.com/doofuslarge/lscp

行われる．この CNN の実装は，Google が公開している Tensorflow [1] を用いる．これは，実装例やチュートリアルが豊富であり，また，我々の実験環境では，他のライブラリと比較して実行速度が高速であるためである．以下，分類に用いられる 3 層のネットワークについて説明する．

第 1 層は埋め込み表現層（Embedding layer）で，lscp で分割したそれぞれの単語（作成されたテキストベクトルの各値）の埋め込み表現を学習する．埋め込み表現とは各単語を表現するベクトルを求めることであり，Mikolov ら [16] や Pennington ら [19] によって提案されている．Kim のモデル [11] では埋め込み表現学習ツール word2vec [16] を利用しているが，word2vec の学習には大量のデータが必要である．Kim のモデルでは Google News のデータを用いることで 1,000 億の単語を持つコーパスを利用しているが，我々の分類対象はソースコード片であり，Google News のような自然言語のコーパスでは良い識別結果を得られなかった．また，トレーニングデータのコード片を word2vec の学習に用いる実験も行なったが，トレーニングデータ不足により，こちらも良い識別結果を得られなかった．そのため，本研究では埋め込み表現を CNN のネットワークに組み込み，CNN の一部として学習させる．この層では単語を 128 次元のベクトルへと変換するためのルックアップテーブルを作成する．この 128 が埋め込み表現のベクトルサイズ（Embedding size）である．Kim のモデルでは 300 次元の埋め込み表現を採用している．しかし，計算時間が長くなるため，今回はサイズを縮小する．一般的に 2 の階乗のサイズがよく使われるため，256 もしくは 128 を検討し，256 では 300 との大幅な差が期待できなかったため，その 1 つ下の 128 次元を利用する．

第 2 層は畳み込み・プーリング層（Convolution/max-pooling layer）である．畳み込み（Convolution）では，新しい特徴を抽出するためのフィルターを学習する．本手法では n-gram [3] のように複数の単語の共起を加味するため，複数の単語ベクトルを同時に処理できるようなフィルターを適用する．ここで用いるフィルターは，横幅が埋め込み表現のベクトルサイズの 128 で高さが 3，4，5 の 3 種類のフィルター各 128 個である．つまり，3，4，5 単語の共起を考慮している．それぞれ 128 個のフィルタを持つ 3 種類のフィルタをかけるため，フィルター適用の結果として計 384 個の特徴マップ（Feature maps）が得られる．フィルタの高さは，Kim のモデルと同じ設定にしている．フィルタの個数は，Kim のモデルにおけるフィルタ数よりも数を増やし，2 の階乗となるようにしている．

次に，プーリングでは，フィルターから得られた特徴マップから重要な特徴を抽出するためにマックスプーリング（Max-pooling）を適用する．ここでのマックスプーリングは各フィルターから得られた特徴マップの最大値を最も重要な情報として保存する手法である．そのため，畳み込みによりフィルタが適用された後の 384 個の特徴マップを 384 個のノードに変換することができる．この設定は Kim のモデルと同じである．

第 3 層は全結合層であり，出力のノードを 2 つとして，不具合である確率をソフトマックス関数を用いて計算する．

### 3.3 ハイパーパラメータと訓練データ

本研究におけるハイパーパラメータは，Kim のモデルを参考にして設定している．ただし，学習におけるパラメータの更新の際の最適化アルゴリズムには Adam [12] を利用する．Adam はニューラルネットワークの学習でよく利用されている確率的勾配降下法（SGD）よりも早く誤差を収束させることが出来るアルゴリズムであると報告されている．そのため，より高速な学習が可能と考えたためである．また，Kim のモデルは正規化項として CNN の重みに上限を設ける手法を採用しているが，この正規化では良い識別結果が得られなかった．そのため，より単純な 2 乗ノルムを採用する．また，ミニバッチサイズを 64 とし，64 データずつパラメータの更新を行う．

## 4. 評価実験

提案手法の評価実験では，Yang らの Deeper [25] と比較評価を行う．評価実験の概要を**図 4** に示す．実験の主要なステップを以下にまとめる．

(1) 提案手法に関しては，リポジトリから変更（コミット）を取得し，Commit Guru [9, 20] を用いて，変更が不具合を混入したかどうかのラベル情報を基に変更にラベル付けをする．各変更に対し，変更されたソースコードを収集し変更のソースコード片を作成する．
(2) Deeper に関しては，Commit Guru から 14 個の変更メトリクスを取得する．
(3) どちらに対しても同じリサンプリングを行う．
(4) 提案手法 W-CNN と比較対象の不具合予測手法 Deeper に対して 10×10 重交差検証による予測精度の評価を行いその結果をまとめる．

以降，それぞれの方法について詳細を説明する．

### 4.1 Commit Guru による分析データの準備

不具合予測手法の評価において実験データの公開性と透明性は重要である [8]．そのため，我々は Rosen らが公開している Commit Guru [9, 20] から得られるデータを利用する．Commit Guru は Git のリポジトリを指定すると変更メトリクス [9]，及び，不具合混入コミットの情報を自動で計算可能な Web アプリケーションである．

本研究では，不具合混入コミットの情報をコミットのラベル付けに利用する．また，メトリクスを比較評価のための不具合予測手法 Deeper の入力で用いる．Commit Guru が行う（1）不具合混入コミットのラベル付けと（2）メト

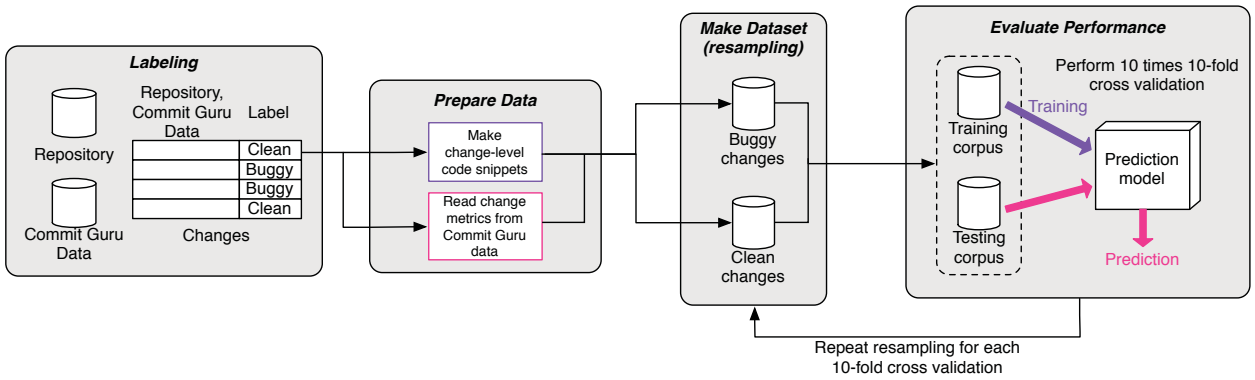


**図 4**　評価実験の概要.

**表 1**　変更メトリクスの説明.

| 分類 | 名称 | 定義 |
|---|---|---|
| Diffusion | NS | 修正されたサブシステムの数 |
| | ND | 修正されたディレクトリの数 |
| | NF | 修正されたファイルの数 |
| | Entropy | 修正されたコードの各ファイルごとの分布 |
| Size | LA | 追加されたコード行数 |
| | LD | 削除されたコード行数 |
| | LT | 変更される前のファイルのコード行数 |
| Purpose | FIX | バグ修正の変更か否か |
| History | NDEV | 修正に関わった開発者の人数 |
| | AGE | 最後の変更から最新の変更までの平均時間 |
| | NUC | ユニークな変更の数 |
| Experience | EXP | 開発者の経験 |
| | REXP | 最近の開発者の経験 |
| | SEXP | サブシステムについての開発者の経験 |

リクスの収集方法について以下に述べる.

**(1) 不具合混入コミットのラベル付け：**Commit Guru はコミットに対し，不具合が混入したコミット（buggy）とそれ以外のコミット（clean）にラベル付けをする．不具合混入コミットは不具合を修正したコミットから推定する．Commit Guru は，まずコミットメッセージを解析し，Hindle らの研究 [5] におけるコミットを分類するためのキーワード（例えば bug や fix など）があれば，そのコミットが不具合を修正しているコミットであると決める．次に，その修正を行ったコミットの修正行を特定し，その行が追加されたコミットを不具合が混入したコミットとしてラベル付けする．他の不具合コミットを推定する一般的な手法として SZZ アルゴリズム [21] があるが，公開されている信頼性の高いライブラリなどが無く，それぞれの研究で独自の実装が試みられているため，公開性という観点で SZZ アルゴリズムではなく Commit Guru を利用する．

**(2) メトリクスの収集：**収集されるメトリクスは亀井らの 14 個の変更メトリクス [9] である（**表 1**）．これらのメトリクスを，比較評価のための不具合予測手法 Deeper の入力として用いる．

**表 2**　対象プロジェクトの詳細.

| Project | Language | The Total Number of Changes | Buggy Rate |
|---|---|---|---|
| Hadoop | Java | 13,920 | 24.8% |
| Camel | Java | 24,740 | 23.2% |
| Gerrit | Java | 18,794 | 20.1% |
| Osmand | Java | 31,366 | 14.0% |
| CMake | C++ | 28,400 | 10.1% |
| Bitcoin | C++ | 11,093 | 14.4% |
| Gimp | C++ | 37,116 | 22.5% |

### 4.2　対象とするプロジェクトデータ

本研究では，不具合予測手法を作成するために十分な履歴のある 7 つのオープンソースソフトウェアプロジェクト（Hadoop，Camel，Gerrit，Osmand，CMake，Bitcoin，Gimp）のリポジトリを利用する．また，プロジェクトは，それぞれすでに Commit Guru で解析され，14 個の変更メトリクスと不具合混入コミットかどうかのラベルが利用可能である．対象プロジェクトの詳細を**表 2** に示す．

なお，Commit Guru で分析可能なデータは Git リポジトリで管理されているデータであるが，比較対象の先行研究 [25] で分析されているほとんどのプロジェクトのソースコード管理システムが Git ではないため，先行研究と同じプロジェクトのセットを使用することはできなかった．我々は，Commit Guru を利用可能なプロジェクトの中から様々な分野（サーバやアプリ）のプログラムでかつ異なる言語で書かれているプロジェクトを利用する．

### 4.3　比較手法 Deeper

比較手法の Deeper [25] では，ディープビリーフネットワークが採用されている．この論文から得られた Yang らが採用しているディープビリーフネットワークについての

**表 3** リサンプリング済みのプロジェクトの変更数.

| Project | Buggy Changes | Clean Changes |
|---|---|---|
| Hadoop | 3,280 | 3,280 |
| Camel | 5,620 | 5,620 |
| Gerrit | 3,470 | 3,470 |
| Osmand | 4,150 | 4,150 |
| CMake | 2,790 | 2,790 |
| Bitcoin | 1,450 | 1,450 |
| Gimp | 8,080 | 8,080 |

情報は，ネットワークのアーキテクチャ，及び，メトリクスの前処理についてである．Deeper のディープビリーフネットワークは以下のネットワークが指定されている．

- 3 つの隠れ層を持つ．
- 各層のノード数は，入力層から出力層まで順番に 14, 20，12，12，2 である．
- 学習時のミニバッチサイズは 100 である．

また，前処理として，各メトリクスを 0-1 範囲にスケーリングする．計算式は以下である．

$$\mathbf{X}_{0-1} = \frac{\mathbf{X}_{org} - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

各メトリクスに対して，$\mathbf{X}_{org}$ は全変更に対するそのメトリクス値のベクトル，$X_{\min}$ は全変更の中で最小のメトリクス値, $X_{\max}$ は最大のメトリクス値である．

学習の繰り返し回数は，Deeper の説明に記載されていない．そのため，誤差をプロットし繰り返し回数を決定する．結果，50 回の繰り返しにより，Deeper の汎化を十分行えることがわかったため，Deeper の繰り返し回数を 50 とする．

### 4.4 データのリサンプリング

表 2 に示す通り，不具合を混入した変更は全体の変更の数に対して少ない傾向にある．クラスごとのデータ数の不均一は多数派のクラスにバイアスをかけ，予測モデルの学習精度を下げてしまう可能性がある．不具合予測においては，データのリサンプリングにより精度を上げることが可能であると知られており [22]，その評価においてもデータ数を均一にするためのリサンプリング技術が用いられている [9, 22, 25].

本研究では各クラスのデータ数を統一する手法として，ランダムアンダーサンプリングを用いる．ランダムアンダーサンプリングは，データ数が各クラスで均一になるまで，データ数の多いクラスからランダムにデータを削除していく手法である．**表 3** にリサンプリング後のプロジェクトごとの変更数を示す．ここで，変更数が表 2 から計算できる変更数と異なることがわかる．例えば，Hadoop であれば，不具合を含んだ変更が 24.8%あり，各クラスのデータが 3,452 個に揃わなくてはならない．これは，全ての変更にソースコードの変更が含まれている訳ではないためである．そのため，各プロジェクトで，表 2 から計算できる変更数よりも少ない変更数となっている．また，全てのプロジェクトで 1 桁目の端数は丸めている．

### 4.5 10×10 重交差検証

本研究では実験におけるデータの選択の偏りを減らすために，訓練データ，及び，テストデータの選択に 10×10 重交差検証を利用する．10×10 重交差検証 は，10 重交差検証を 10 回実行する評価手法であり，不具合予測手法の研究で多く利用されている [25].

それぞれの回でランダムアンダーサンプリングを再度実行することでデータの偏りを出来る限り減らすことを行う．最後に，10×10 重交差検証の結果の平均値を計算し，各々の手法の評価値とする．評価値には閾値に依存しない ROC（Receiver Operating Characteristic）曲線から得られる AUC（Area Under the Curve）を利用する．

## 5. 結果

### 5.1 RQ1: 提案手法 W-CNN による不具合の学習・予測は可能か?

#### 5.1.1 動機

我々の知る限り，今までに変更のソースコード片に対して深層学習を適用した研究は行われていない．そのため，まず，提案手法 W-CNN が変更のソースコード片に対する不具合予測に適用可能かどうかを調べる．

また，学習が可能であるならば，どの程度の W-CNN の学習の繰り返し回数（本研究ではエポック数を単位としている）が適切であるのかを調査する．エポック数とは，W-CNN における学習を何回繰り返すかの値である．通常，エポック数が大きければ大きいほど，より訓練データに適合した CNN を生成できる．しかし，エポック数が大きすぎると，ネットワークが訓練データに特化しすぎてしまい，テストデータに対して精度が悪くなる（汎化性能が悪くなる）という過適合の問題が発生する．従って，汎化性能を大きくし，かつ，過適合を起こさない最大のエポック数を求める．

#### 5.1.2 アプローチ

W-CNN が不具合を学習可能か，また過適合を起こさずに汎化できているかを調査するため，学習精度を示す訓練誤差（Train loss），及び，汎化性能を示すテスト誤差（Test loss）を計算する．この計算のために，我々の手法では交差エントロピーを用いている．50 エポックまで学習を進めて，訓練誤差，及び，テスト誤差をプロットし，その学習精度，及び，汎化性能を調べる．エポック数が増えているにも関わらず，テスト誤差が一定か大きくなる場合は過適合の恐れがあると判断する．

さらに，AUC の値を 5 エポックごとに記録することで，分類精度の推移を調べる．これにより，適切なエポック数を選択する．AUC の値は 10×10 重交差検証によりプロ

ジェクトごとに 100 回実行が行われた結果の平均とする．

#### 5.1.3 結果

**学習が進むごとに訓練誤差，及び，テスト誤差が減少していることから，提案手法 W-CNN は変更のソースコード片に対する不具合予測に適用可能である．**

**図 5** に，各プロジェクトの学習過程における訓練誤差，及び，テスト誤差を示す．この図から，学習を進めるごとに全てのプロジェクトにおいて訓練誤差，及び，テスト誤差が減少していることがわかる．訓練誤差が小さければ学習が進んでいることを示し，テスト誤差が小さければテストデータに適合（汎化）していることを示している．

ただし，15 エポック以降は学習データに対する学習は進んでいるが，汎化は進みにくくなることが確認できる．これは，図 5 より 4 つのプロジェクト（Hadoop，Camel，Gerrit，Osmand）でエポック数が 15 を超える程度で訓練誤差，及び，テスト誤差の差が大きくなり始めていることから確認できる．また，残りの 3 つのプロジェクト（CMake，Bitcoin，Gimp）ではより早い段階でこの傾向が見られる．これらより，エポック数 15 を学習が進んだ W-CNN として以降の RQ で利用する 1 つ目のエポック数とする．

**学習が進むごとに AUC の値が上昇していることが確認でき，最高で平均 AUC 0.817 が得られる．**

**表 4** は各プロジェクトで得られた AUC の値の平均を 5 エポックごとにまとめた表である．学習が進むごとに AUC の値が上昇していることがわかる．一方で，進むごとに上昇幅は小さくなることも確認できる．エポック数 40 から 50 の範囲ではほとんど変化が見られない．そこで，エポック数 50 を学習を十分進めた W-CNN として以降の RQ で利用する 2 つ目のエポック数とする．

提案手法 W-CNN の学習過程を記録した結果，W-CNN は本実験で用意した学習データに対して適用可能であり，平均 AUC は最高で 0.817 であることから，提案手法による不具合分類が可能であることがわかる．また，得られた結果からエポック数 15 と 50 の時点のモデルを以降の RQ で用いることとする．

### 5.2 RQ2: 提案手法 W-CNN は既存の変更に対する深層学習を用いた不具合予測手法よりも予測精度が良いか?

#### 5.2.1 動機

提案手法 W-CNN が不具合予測として既存の手法よりも精度が良いか否かを調べる．これにより，W-CNN による不具合予測が効果的であるかを調べる．

#### 5.2.2 アプローチ

比較対象として，従来の不具合予測手法で我々の手法とアプローチが最も近い Yang らの Deeper [25] を用いる．Deeper も，変更に対して深層学習を用い不具合予測を行うが，変更メトリクスを用いた点や，深層学習のモデルなどが異なる．

提案手法に関しては，RQ1 で示した 2 つのエポック数（15，及び，50）における W-CNN（以降，それぞれ W-CNN 15，及び，W-CNN 50 と呼ぶ）を用いる．

評価値には AUC を用いる．この値は 10×10 重交差検証を行った平均値として計算する．

#### 5.2.3 結果

**W-CNN 15，及び，W-CNN 50 は，既存の深層学習による変更に対する不具合予測手法よりも予測精度が良い．**

**表 5** は，W-CNN 15，W-CNN 50，及び，Deeper から得られた AUC の値をまとめた表である．全てのプロジェクトにおいて，W-CNN 50 が最良であることがわかる．また，W-CNN 15 も Deeper より予測精度が高いことが確認できる．以上より，W-CNN は既存の手法より高い精度をソースコード片のみから学習可能であることがわかる．

### 5.3 RQ3: 提案手法 W-CNN の学習時間はどの程度か?

#### 5.3.1 動機

一般に深層学習はロジスティック回帰などの軽量な機械学習よりも学習の時間を必要とする．また，巨大なネットワークを持つ深層学習は，小規模なネットワークを持つ深層学習よりも学習時間がかかる．我々は，W-CNN と Yang らの Deeper [25] の学習時間を比較して，提案手法を考察する．

#### 5.3.2 アプローチ

学習が終了するまでの時間を学習時間として 1 重交差検証ごとに計測する．つまり，W-CNN 15 ならば，15 回の学習のエポックが終了するまでの時間である．この時間を，10×10 重交差検証を行い 100 回計測し，その平均値を評価する．実行環境は，Intel Xeon CPU E5-1620 v3 @ 3.50GHz, NVIDIA GeForce GTX TITAN X (3584 cuda cores, 12GB) である．

#### 5.3.3 結果

**W-CNN 15，及び，W-CNN 50 は既存手法よりも長い学習時間が必要である．**

**表 6** は，W-CNN 15，W-CNN 50，及び，Deeper から得られた 1 フォールドの学習時間をまとめた表である．W-CNN 15 は Deeper よりも，また，W-CNN 50 は W-CNN 15 よりも，長い学習時間がかかる．そのため，学習時間の点では，Deeper が最も良い．ただし，最も学習に時間がかかる Gimp であっても，学習時間は 23 分程度であり，また，一度学習すれば，その後の各コミットに対する予測時間は，

**表 4** 学習過程における W-CNN の AUC のプロジェクト間での平均値.

| エポック数 | 5 | 10 | 15 | 20 | 25 | 30 | 35 | 40 | 45 | 50 |
|---|---|---|---|---|---|---|---|---|---|---|
| AUC | 0.788 | 0.797 | 0.803 | 0.807 | 0.811 | 0.813 | 0.815 | 0.816 | 0.816 | 0.817 |

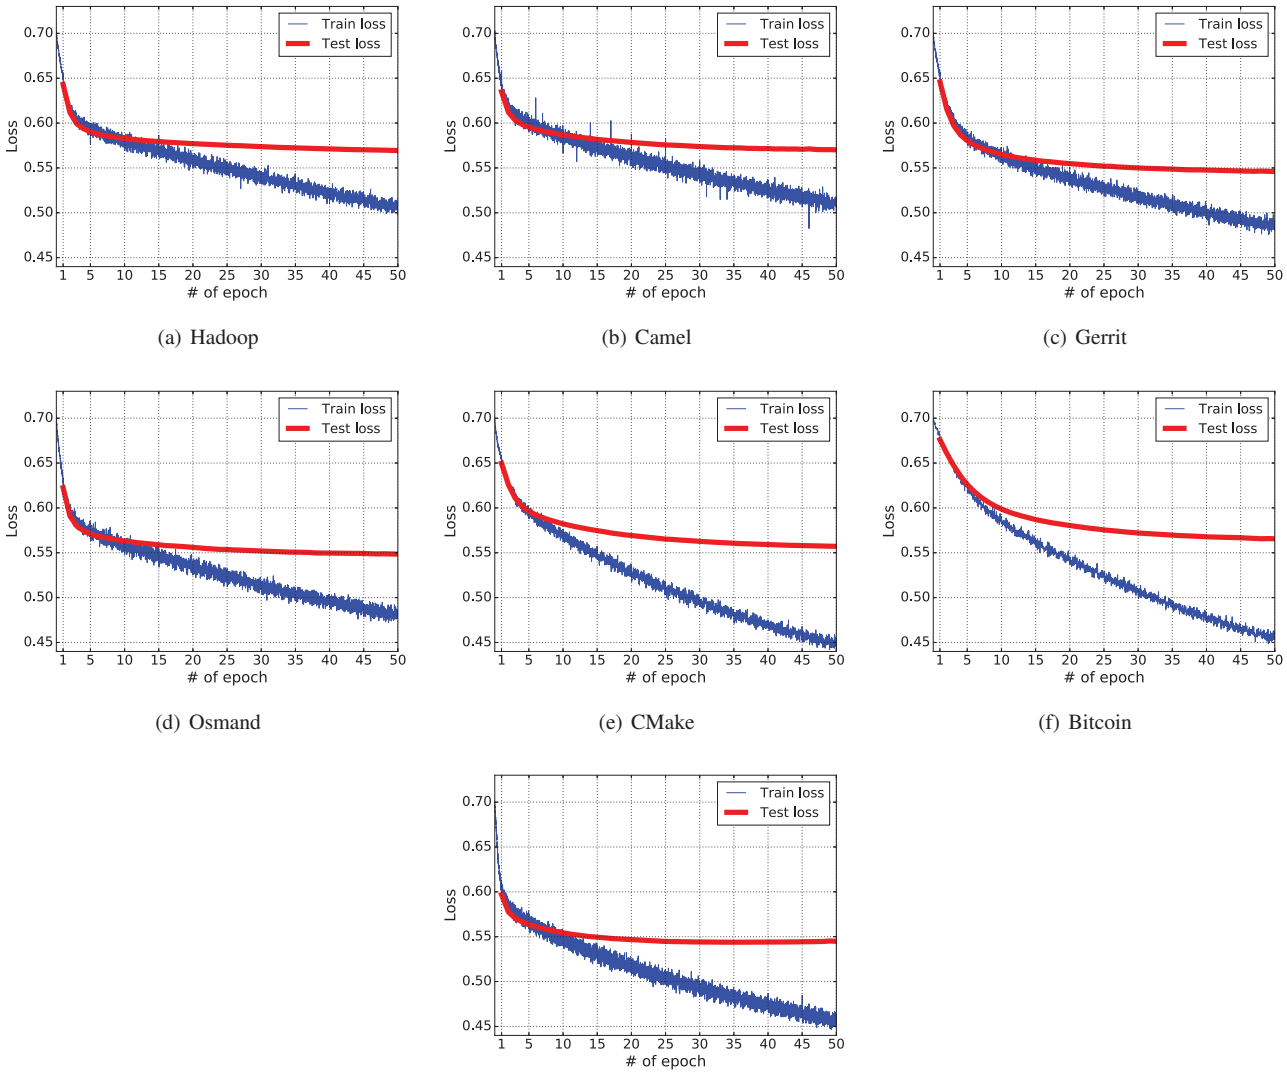


(a) Hadoop (b) Camel (c) Gerrit

(d) Osmand (e) CMake (f) Bitcoin

(g) Gimp

**図 5** 各プロジェクトの学習過程における W-CNN の訓練誤差（Train loss），及び，テスト誤差（Test loss）.

**表 5** W-CNN 15，W-CNN 50，及び，Deeper の AUC.

| | 提案手法 | | 従来手法 |
|---|---|---|---|
| プロジェクト | W-CNN 15 | W-CNN 50 | Deeper |
| Hadoop | 0.788 | 0.802 | 0.684 |
| Camel | 0.783 | 0.798 | 0.630 |
| Gerrit | 0.817 | 0.832 | 0.752 |
| Osmand | 0.810 | 0.825 | 0.698 |
| CMake | 0.803 | 0.821 | 0.622 |
| Bitcoin | 0.793 | 0.811 | 0.675 |
| Gimp | 0.825 | 0.830 | 0.624 |
| AVG | 0.803 | 0.817 | 0.669 |

**表 6** W-CNN 15，W-CNN 50，及び，Deeper の学習時間（s）.

| | 提案手法 | | 従来手法 |
|---|---|---|---|
| プロジェクト | W-CNN 15 | W-CNN 50 | Deeper |
| Hadoop | 260.5 | 625.4 | 54.6 |
| Camel | 363.9 | 1006.2 | 92.7 |
| Gerrit | 300.9 | 692.8 | 71.4 |
| Osmand | 350.5 | 830.0 | 118.1 |
| CMake | 263.0 | 588.7 | 107.7 |
| Bitcoin | 219.0 | 384.1 | 45.5 |
| Gimp | 502.6 | 1439.6 | 138.3 |
| AVG | 322.9 | 795.3 | 89.8 |

提案手法で 0.0004 秒程度（Bitcoin）などと短い．そのため，変更に対する実行時間のオーバーヘッドは少ない．

**W-CNN の学習時間は，変更数（コミット数）によらないが，既存手法である Deeper は変更数と強く関係がある．**

表 3 と合わせて考えると，従来手法である Deeper は変更数が多いプロジェクトほど多くの学習時間がかかる傾向があるが，W-CNN にはその傾向が小さい．これは，W-CNN の分析対象が変更のソースコード片であり，その長さが学習時間に影響を与えているためである．

## 6. 妥当性の検証

### 6.1 構成概念妥当性

評価指標として AUC を用いている．他に不具合予測で一般的に利用される評価指標として Precision や Recall，これらの組み合わせである F1 値があるが，AUC はこれらの指標の要素を表現可能な指標であり，不具合予測の評価指標として妥当であると考える．

また，本実験では，データの選択の偏りを取り除くために 10×10 重交差検証を行なっている．そのため，データの選択の偏りも小さくできていると考える．

本実験では，考慮する文脈行数を 3 行として実験を行なっている．これは，Hadoop プロジェクトに対して文脈行数が 3 行のときにもっとも良い識別結果であったこと，及び，Git の diff コマンドで標準で出力される行数が 3 行であるからである．一方で，実験時間の関係上全ての他のプロジェクトでは試せていないが，他の文脈行数がもっとも良い識別性能を出す場合もある．（Bitcoin プロジェクトの場合がそうである．）そのため，文脈行数 3 がもっとも良い文脈行数であるとは言い難い．しかし，本研究の目的は，変更のソースコード片に対して深層学習を適用し不具合予測を行うことであり，どの文脈行がもっとも優れているかを検証することではない．そのため，最適な文脈行に関する検証は今後の研究課題として考えている．

### 6.2 外的妥当性

本実験では 7 つのソフトウェアプロジェクトを選択し，それらから収集した変更を実験データとして利用している．選択したプロジェクトは，C，及び，Java の 2 つの言語のどちらかで書かれており，また，様々な分野（サーバ，Web アプリケーション，モバイルアプリケーション，開発ツール，デスクトップアプリケーション）をカバーしている．しかし，これらのプロジェクトだけでは，世にある全てのソフトウェアプロジェクトに対しての一般的な結果を示せていない可能性がある．より対象プロジェクトを増やすことで，外的妥当性を高めることができる．また，本実験の対象プロジェクトは全て OSS であるため，実開発組織と共同研究による妥当性の向上が必要である．

### 6.3 内的妥当性

本研究の実験ではデータへのラベル付けに Commit Guru を利用している．しかし，Commit Guru による不具合混入コミットの網羅率は完全ではない．例えば，不具合を修正したコミットのコミットメッセージに特定のキーワードが含まれていなかった場合は，その不具合を見逃してしまう．一方で，公開されている Web アプリケーションであり，実験の再現性が高く，また今後の応用も行い易いと考える．

実験に利用したスクリプトに対して検証は行なっているが，我々が気づいていない不具合が含まれている可能性はある．特に，比較評価に用いた Yang らの Deeper はスクリプトなどが公開されておらず，実装が完全に再現できているかを確認する手段がない．

## 7. 結論

本論文では，深層学習の分類モデルである畳み込みニューラルネットワークを用いた不具合予測手法 W-CNN を提案した．我々の知る限り，提案手法は，変更のソースコード片に対して深層学習を適用し不具合予測を行なった初めての研究である．また，提案手法の評価のために 7 つのソフトウェアプロジェクトに対して，提案手法と従来の変更に対する深層学習を用いた不具合予測手法 Deeper の比較実験を行なった．実験から得られた本研究の貢献を以下にまとめる．

(1) 提案手法 W-CNN の学習過程の訓練誤差，及び，テスト誤差を調べることにより，変更のソースコード片のみを用いた深層学習によって不具合の予測が可能であり，さらに，その分類精度が高いことを示した．
(2) 提案手法 W-CNN は，既存の変更に対する深層学習を用いた不具合予測手法と比較して，学習に時間がかかるが，高い不具合予測精度をもたらすことが可能であることを確認した．

以上の結果から，W-CNN は分類精度の高い不具合予測手法として期待できる．また，W-CNN は学習に時間がかかるが，1 度学習を終えると以降の各コミットに対しての確率計算は 0.0004 秒程度と非常に短い時間で実行することが可能であり，実用に足る効率的な不具合予測手法に成り得ると考える．

### 参考文献

[1] Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., Corrado, G. S., Davis, A., Dean, J., Devin, M. et al.: Tensorflow: Large-scale machine learning on heterogeneous distributed systems, *arXiv preprint arXiv:1603.04467* (2016).
[2] Aversano, L., Cerulo, L. and Del Grosso, C.: Learning from

bug-introducing changes to prevent fault prone code, *in proceedings of the 9th International Workshop on Principles of Software Evolution (IWPSE)*, ACM, pp. 19–26 (2007).

[3] Brown, P. F., Desouza, P. V., Mercer, R. L., Pietra, V. J. D. and Lai, J. C.: Class-based n-gram models of natural language, *Computational linguistics*, Vol. 18, No. 4, pp. 467–479 (1992).

[4] Dos Santos, C. N. and Gatti, M.: Deep Convolutional Neural Networks for Sentiment Analysis of Short Texts., *in proceedings of the 25th International Conference on Computational Linguistics (COLING)*, pp. 69–78 (2014).

[5] Hindle, A., German, D. M. and Holt, R.: What do large commits tell us?: a taxonomical study of large commits, *in proceedings of the 2008 International Working Conference on Mining Software Repositories (MSR)*, ACM, pp. 99–108 (2008).

[6] Ihaka, R. and Gentleman, R.: R: a language for data analysis and graphics, *Journal of Computational and Graphical Statistics*, Vol. 5, No. 3, pp. 299–314 (1996).

[7] Jiang, T., Tan, L. and Kim, S.: Personalized defect prediction, *in proceeding of the 28th International Conference on Automated Software Engineering (ASE)*, IEEE, pp. 279–289 (2013).

[8] Kamei, Y. and Shihab, E.: Defect prediction: Accomplishments and future challenges, *in proceeding of the 23th International Conference on Software Analysis, Evolution, and Reengineering (SANER)*, Vol. 5, IEEE, pp. 33–45 (2016).

[9] Kamei, Y., Shihab, E., Adams, B., Hassan, A. E., Mockus, A., Sinha, A. and Ubayashi, N.: A Large-Scale Empirical Study of Just-in-Time Quality Assurance, *IEEE Transactions on Software Engineering*, Vol. 39, No. 6, pp. 757–773 (2013).

[10] Kim, S., Whitehead Jr, E. J. and Zhang, Y.: Classifying software changes: Clean or buggy?, *IEEE Transactions on Software Engineering*, Vol. 34, No. 2, pp. 181–196 (2008).

[11] Kim, Y.: Convolutional neural networks for sentence classification, *arXiv preprint arXiv:1408.5882* (2014).

[12] Kingma, D. and Ba, J.: Adam: A method for stochastic optimization, *arXiv preprint arXiv:1412.6980* (2014).

[13] Krizhevsky, A., Sutskever, I. and Hinton, G. E.: Imagenet classification with deep convolutional neural networks, *in proceeding of the 2012 Advances in Neural Information Processing Systems (NIPS)*, pp. 1097–1105 (2012).

[14] Lam, A. N., Nguyen, A. T., Nguyen, H. A. and Nguyen, T. N.: Combining deep learning with information retrieval to localize buggy files for bug reports (n), *in proceeding of the 30th International Conference on Automated Software Engineering (ASE)*, IEEE, pp. 476–481 (2015).

[15] Menzies, T., Caglayan, B., Kocaguneli, E., Krall, J., Peters, F. and Turhan, B.: The promise repository of empirical software engineering data, *West Virginia University, Department of Computer Science* (2012).

[16] Mikolov, T.: word2vec: Tool for computing continuous distributed representations of words (2015).

[17] Mizuno, O. and Kikuno, T.: Training on errors experiment to detect fault-prone software modules by spam filter, *in proceedings of the 6th Joint Meeting of the European Software Engineering Conference and the ACM SIGSOFT Symposium on The Foundations of Software Engineering*, ACM, pp. 405–414 (2007).

[18] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V. et al.: Scikit-learn: Machine learning in Python, *Journal of Machine Learning Research*, Vol. 12, No. 10, pp. 2825–2830 (2011).

[19] Pennington, J., Socher, R. and Manning, C. D.: Glove: Global Vectors for Word Representation., *in proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, Vol. 14, pp. 1532–1543 (2014).

[20] Rosen, C., Grawi, B. and Shihab, E.: Commit Guru: Analytics and Risk Prediction of Software Commits, *in proceedings of the 10th Joint Meeting on Foundations of Software Engineering*, ESEC/FSE 2015, ACM, pp. 966–969 (2015).

[21] Śliwerski, J., Zimmermann, T. and Zeller, A.: When do changes induce fixes?, *Sigsoft Software Engineering Notes*, Vol. 30, No. 4, ACM, pp. 1–5 (2005).

[22] Tan, M., Tan, L., Dara, S. and Mayeux, C.: Online defect prediction for imbalanced data, *in proceedings of the 37th International Conference on Software Engineering*, IEEE, pp. 99–108 (2015).

[23] Thomas, W., S.: lscp: A lightweight source code preprocesser (2015).

[24] Wang, S., Liu, T. and Tan, L.: Automatically learning semantic features for defect prediction, *in proceedings of the 38th International Conference on Software Engineering*, ACM, pp. 297–308 (2016).

[25] Yang, X., Lo, D., Xia, X., Zhang, Y. and Sun, J.: Deep learning for just-in-time defect prediction, *in proceedings of the 2015 Software Quality, Reliability and Security (QRS), IEEE*, IEEE, pp. 17–26 (2015).

[26] Zhang, X., Zhao, J. and LeCun, Y.: Character-level convolutional networks for text classification, *in proceedings of the 28th International Conference on Neural Information Processing Systems (NIPS)*, pp. 649–657 (2015).

[27] Zimmermann, T., Premraj, R. and Zeller, A.: Predicting defects for eclipse, *in proceedings of the 3th International Workshop on Predictor Models in Software Engineering*, IEEE, p. 9 (2007).