

Predykcja defektów oprogramowania przy użyciu wybranych technik eksploracji danych

Autor:

mgr inż. DANIEL CZYCZYN-EGIRD

Opiekun naukowy:

dr hab. inż. profesor PK ADAM SŁOWIK

Plan prezentacji

1. Zapewnienie jakości w inżynierii oprogramowania
2. Modele predykcji defektów
3. Sformułowanie problemu
4. Koncepcja proponowanego rozwiązania
5. Podsumowanie
6. Dodatek: Lista osiągnięć

Zapewnienie jakości w inżynierii oprogramowania

Definicja jakości oprogramowania wg ISO/IEC 9126-1:2001 *:

1. Funkcjonalność
2. Niezawodność
3. Użyteczność
4. Efektywność
5. Konserwowalność
6. Przenośność



* 9126-3 Software Engineering – Product quality – Part 3: Internal metrics

Zapewnienie jakości w inżynierii oprogramowania

Definicja jakości oprogramowania w literaturze:

1. Zgodność z wymaganiami [Philip B. Crosby]
2. Przydatność do użytku [Frank M. Gryna]
3. **BRAK DEFECTÓW W PRODUKCIE** [Stephen H. Kan]



Zapewnienie jakości w inżynierii oprogramowania

Definicja defektu:




Przegląd działań wspierających jakość oprogramowania

➤ Testowanie oprogramowania

- Najobszerniejsze działania zapewniające wysoką jakość
- Koszty potrafią przekroczyć 50% całkowitych kosztów wytworzenia systemu informatycznego
- W metodykach zwinnych występuje tzw. programowanie przez testy (TDD), zaczyna się od przygotowania testów, a następnie wykonuje się implementacje
- Istnieje szereg narzędzi do zarządzania testami i raportowania, do automatyzacji oraz narzędzi do zarządzania incydentami.

Przegląd działań wspierających jakość oprogramowania

Jakiego narzędzia używasz?



Przegląd działań wspierających jakość oprogramowania

➤ Inspekcje oprogramowania

- Przegląd formalny stanu prac
- Statyczna analiza kodu programu lub dokumentacji projektowej
- Kilkugodzinne spotkanie, na którym autor dokumentu lub fragmentu programu relacjonuje wykonane przez siebie modyfikacje
- Popularna formuła inspekcji -> tzw. Inspekcje Fagana

PROJEKTOWANIE

I₁

IMPLEMENTACJA

I₂

TESTY
JEDNOSTKOWE

I₃

Przegląd działań wspierających jakość oprogramowania

➤ Modele przyrostu niezawodności

- Ukazanie poprawy niezawodności modułu lub systemu jako wyniku poprawiania defektów w czasie
- Przewidywanie przyszłej niezawodności oprogramowania na podstawie danych historycznych

Szacowania poziomu niezawodności

charakterystyki kodu (metryki)

statystyczne korelacje danych
(np. z funkcją wykładniczą)

Przegląd działań wspierających jakość oprogramowania

➤ Metryki oprogramowania

- Miara pewnej właściwości oprogramowania lub jego specyfikacji (miara atrybutu)
- Funkcja odwzorowująca jednostkę oprogramowania w wartość liczbową [IEEE 1061-1998]

METRYKI PRODUKTU	METRYKI PROCESU
np. - Number of Public Methods (NPM) - Data Access Metric (DAM) - etc.	np. - Number of Revisions (NR) - Number of Distinct Committers (NDC) - etc.

Modele predykcji defektów

- Narzędzia, które na podstawie wartości metryk danego artefaktu dokonują oszacowania (predykcji) liczby defektów znajdujących się w tym artefakcie
 - Modele takie są bardzo przydatne w procesie testowania, kiedy w wyniku ograniczeń budżetowych nie jesteśmy w stanie przetestować wszystkich wytworzonych artefaktów
 - Zasada 80:20 *
- część kodu źródłowego (20%) -> defekty (80%)

* Elaine J. Weyuker, Thomas J. Ostrand, Robert M. Bell, "Do too many cooks spoil the broth? Using the number of developers to enhance defect prediction models", Empirical Software Engineering, 13(5):539-559, 2008

Modele predykcji defektów

➤ Cel stosowania?



Sformułowanie problemu

➤ Dane

- ☐ Dostęp do kodu źródłowego
- ☐ Dostęp do systemów kontroli wersji (np. SVN)
- ☐ Dostęp do systemów zarządzania projektem i śledzenia defektów (np. JIRA)

➤ Ograniczenia

- ☐ Różnorodność metryk oprogramowania
- ☐ Zastosowanie do obiektowych języków programowania

➤ Pytanie

- ☐ Czy opierając się na kodzie źródłowym oraz danych historycznych dotyczących wykrytych wcześniej defektów, możliwe jest pozyskanie informacji o potencjalnych ukrytych defektach, które nie zostały jeszcze zdiagnozowane?

Sformułowanie problemu

➤ Cel

Opracowanie oraz zweryfikowanie zestawu modeli klasyfikacyjnych służących do predykcji defektów oprogramowania w projektach programistycznych opartych na paradygmacie programowania obiektowego.

Wynik klasyfikacji opisujący predykcję możliwych defektów oprogramowania w oparciu o dane wejściowe **przyczyni się do zapewnienia lub utrzymania jakości tworzonego oprogramowania.**

Sformułowanie problemu

➤ Teza

Hybrydowe klasyfikatory pozwalają na efektywniejszą predykcję defektów oprogramowania w projektach informatycznych tworzonych według paradygmatu programowania obiektowego.

Są one skuteczniejsze w stosunku do typowo stosowanych modeli klasyfikacyjnych zapewniając tym samym utrzymanie lub poprawę jakości tworzonego oprogramowania.


Cele szczegółowe

- ▣ Przegląd i porównanie metod budowy modeli predykcji defektów w oprogramowaniu
- ▣ Opracowanie hybrydowego (=>BARDZIEJ SKUTECZNEGO) modelu opisującego wystąpienie możliwych defektów
- ▣ Zastosowanie wybranych(i zmodyfikowanych autorsko) technik eksploracji danych do budowy modelu (np. do redukcji wymiarowości zadania, odrzucanie najmniej istotnych atrybutów itp.)
- ▣ Opracowanie modelu matematycznego predykcji defektów
- ▣ Wykonanie eksperymentów testowych (jakość, skuteczność)
- ▣ Analiza i ocena otrzymanych wyników, sformułowanie wniosków końcowych

Hipotezy robocze

- ▣ Ocena metryk oprogramowania wraz z analizą danych historycznych pozwolą na predykcję defektów w badanym oprogramowaniu.
- ▣ Zaproponowane rozwiązania techniczne pozwolą na częściową automatyzację procesu akwizycji danych.
- ▣ Modele predykcji defektów będą możliwe do zastosowania dla technologii obiektowych.

Koncepcja proponowanego rozwiązania



Przykładowa predykcja

UCZENIE




Liczba klas w pliku	Śr. ilość metod w klasie	Ryzyko defektu
12	5	NISKIE
15	20	WYSOKIE
19	13	NISKIE
50	8	WYSOKIE
7	17	WYSOKIE

if Liczba klas w pliku > 20
or Śr. il. metod w klasie > 15
then Ryzyko = „WYSOKIE”

Przykładowa predykcja

➤ TESTOWANIE




Liczba klas w pliku	Śr. ilość metod w klasie	Ryzyko defektu
18	7	NISKIE
22	12	WYSOKIE
16	6	WYSOKIE
37	8	WYSOKIE

Ryzyko defektu
NISKIE
WYSOKIE
NISKIE
WYSOKIE

Dokładność = $3/4 = 75\%$


Przykładowa predykcja

➤ PREDYKCJA



Aktualny stan prac

Szacunkowo



Przewidywany termin zamknięcia przewodu doktorskiego:
rok akademicki 2019/2020

Plan dysertacji

❖ Zapewnienie jakości w inżynierii oprogramowania

- Wstęp
- Aspekty dotyczące jakości oprogramowania
- Opis metryk oprogramowania
- Modele predykcji defektów
- Cel i teza pracy
- Opis rozdziałów

❖ Przegląd stanu wiedzy o modelach predykcji defektów

- Metryki produktu
- Metryki procesu
- Opis czynników istotnych dla procesu predykcji defektów
- Predykcja pomiędzy projektami

❖ Przegląd stanu wiedzy o wybranych technikach eksploracji danych

- Opis wybranych technik

❖ Pozyskiwanie danych do badań

- Informacje o przebadanych projektach
- Przykłady użytych metryk produktu
- Przykłady użytych metryk procesu
- Opis narzędzi zastosowanych do zbierania i analizowania danych

Plan dysertacji c.d.

❖ Zastosowanie hybrydowych modeli predykcji defektów

- Definicja hybrydowego modelu predykcji defektów
- Opis eksperymentu
- Wyniki eksperymentu
- Walidacja uzyskanych wyników
- Podsumowanie

❖ Zastosowanie uzyskanych wyników w praktyce

- Motywacja zastosowania
- Wdrożenie modelu predykcji defektów na konkretnym przykładzie
- Podsumowanie efektów wdrożenia

❖ Podsumowanie

- Część badawcza
- Część implementacyjna

❖ Literatura

Podsumowanie prac

➤ Publikacje w języku polskim:

1. Daniel Czyczyn-Egird: „Eksploracja danych na podstawie szacowania informacji z wykorzystaniem regresji liniowej”, Modele Inżynierii Teleinformatyki, 2015
2. Daniel Czyczyn-Egird, Rafał Wojszczyk: „Zastosowanie technik eksploracji danych na przykładzie badania popularności wzorców projektowych w serwisie społecznościowym Stackoverflow.com”, Zeszyty Naukowe WEiI, 2016
3. Daniel Czyczyn-Egird, Rafał Wojszczyk: „Predykcja ataków DDoS za pomocą technik eksploracji danych” Zeszyty Naukowe WEiI (przyjęte do druku), 2017

Podsumowanie prac

➤ Publikacje w języku angielskim:

1. Daniel Czyczyn-Egird, Rafał Wojszczyk: „Determining the Popularity of Design Patterns Used by Programmers Based on the Analysis of Questions and Answers on Stackoverflow.com Social Network”, **Springer International Publishing, 2016**
2. Daniel Czyczyn-Egird, Rafał Wojszczyk: „The effectiveness of data mining techniques in the detection of DDoS attacks”, **Springer International Publishing, 2017**
3. Daniel Czyczyn-Egird, Rafał Wojszczyk: „DDoS Attacks Prediction in a Simulation Environment by means of Data Mining Techniques”, **Studia Informatica Politechnika Śląska, 2017**

Podsumowanie prac

➤ Konferencje:

1. „Krajowa Konferencja Studentów i Młodych Pracowników Nauki” w Unieściu w dniach 20-22 maja 2015
2. „Krajowa Konferencja Studentów i Młodych Pracowników Nauki” w Szczecinie w dniach 20-21 kwietnia 2016
3. „23rd International Science Conference on Computer Networks CN2016” w Brunowie w dniach 14-17 czerwca 2016
4. „Krajowa Konferencja Studentów i Młodych Pracowników Nauki” w Mielnie w dniach 20-22 maja 2017
5. „14th International Conference on Distributed Computing and Artificial Intelligence (DCAI'17)” Polytechnic of Porto - Porto (Portugal) | 21st-23rd June, 2017

Dziękuję za uwagę

Bibliografia

- Barry W. Boehm, Philip N. Papaccio. Understanding and controlling software costs. IEEE Transactions on Software Engineering, 14:1462–1477, Październik 1988.
- Elaine J. Weyuker, Thomas J. Ostrand, Robert M. Bell. Do too many cooks spoil the broth? Using the number of developers to enhance defect prediction models. Empirical Software Engineering, 13(5):539–559, 2008.
- Elaine J. Weyuker, Thomas J. Ostrand, Robert M. Bell. Using developer information as a factor for fault prediction. PROMISE '07: Proceedings of the Third International Workshop on Predictor Models in Software Engineering, Washington, DC, USA, 2007. IEEE Computer Society
- Stephen H. Kan. Metrics and Models in Software Quality Engineering. Addison-Wesley Longman Publishing Co., Inc., Boston, MA, USA, 2002.
- Cagatay Catal, Banu Diri. Review: A systematic review of software fault prediction studies. Expert Systems with Applications, USA, 2009.
- Lionel C. Briand, Jurgen Wust, John W. Daly, D. Victor Porter. Exploring the relationship between design measures and software quality in object-oriented systems. Journal of Systems and Software, 51:245–273, Maj 2000

DODATEK: MDA

➤ **MDA - Model Driven Architecture**

Zbiór metod porządkujących proces tworzenia systemów komputerowych opartych na budowie modeli i ich transformacji.

Cykl życia oprogramowania:


1. **CIM** (ang. Computational Independent Model) - model domenowy, środowisko, czy też wymagania.
2. **PIM** (ang. Platform-Independent Model) - perspektywa logiczna (projektowa) systemu.
3. **PSM** (ang. Platform-Specific Model) – opis systemu w perspektywie implementacyjnej
4. **PDM** (ang. Platform Description Model) – opis szczegółów technicznych perspektywy wdrożeniowej

DODATEK: METODY KLASYFIKACJI

➤ PRZYKŁADOWE METODY

- Klasyfikacja poprzez indukcję drzew decyzyjnych
- Klasyfikatory Bayes'owskie
- Sieci Neuronowe
- Analiza statystyczna
- Metaheurystyki (np. algorytmy genetyczne)
- Zbiory przybliżone
- k-NN – k-najbliższe sąsiedztwo

DODATEK: Proces „życia” defektu w systemie



DODATEK: Definicja defektu w JIRA

Create Issue

⚙️ Configure Fields ▾

Project*
Projekt Kuvert (PK) ▾

Issue Type*
Bug ▾ ?

Summary*
Błąd pamięci podczas sortowania listy kontaktów

Reporter*
Daniel
Start typing to get a list of possible matches.

Component/s
None

Description

Style ▾ B I U A ▾ ^A ▾ ▾ ☰ ☷ ☺ ▾ + ▾ ≡

Opis problemu....

☰ ?

☐ Create another

Create

Cancel