

○ 厦门理工学院学术专著出版基金资助

# 基于数据挖掘的 软件缺陷预测技术

马 樱 朱顺痣 ◎ 著



厦门大学出版社  
XIAMEN UNIVERSITY PRESS

国家一级出版社  
全国百佳图书出版单位

# 基于数据挖掘的 软件缺陷预测技术

马 樱 朱顺痣 ◎ 著



厦门大学出版社

XIAMEN UNIVERSITY PRESS

国家一级出版社

全国百佳图书出版单位

图书在版编目(CIP)数据

基于数据挖掘的软件缺陷预测技术/马樱,朱顺慈著. —厦门:厦门大学出版社,2017.12  
ISBN 978-7-5615-6283-3

I. ①基… II. ①马…②朱… III. ①软件-测试 IV. ①TP311.5

中国版本图书馆 CIP 数据核字(2016)第 257380 号

出 版 人 郑文礼  
责任编辑 陈进才  
封面设计 蒋卓群  
技术编辑 许克华

出版发行 厦门大学出版社  
社 址 厦门市软件园二期望海路 39 号  
邮政编码 361008  
总 编 办 0592-2182177 0592-2181406(传真)  
营销中心 0592-2184458 0592-2181365  
网 址 <http://www.xmupress.com>  
邮 箱 [xmupress@126.com](mailto:xmupress@126.com)  
印 刷 虎彩印艺股份有限公司

开本 787 mm×1 092 mm 1/16  
印张 10.25  
插页 2  
字数 200 千字  
版次 2017 年 12 月第 1 版  
印次 2017 年 12 月第 1 次印刷  
定价 35.00 元

本书如有印装质量问题请直接寄承印厂调换



厦门大学出版社  
微信二维码



厦门大学出版社  
微博二维码

**本书由以下项目资助出版：**

国家自然科学基金（61502404）

福建省自然科学基金（2015J05132）

福建省教育厅A类科技项目（JA14234）

厦门理工学院学术专著出版基金

# 前 言

软件缺陷预测是软件工程中的一个非常重要的研究课题。它基于软件历史数据中的模块缺陷记录(包括了软件模块的静态代码特征)来对新的软件模块进行缺陷预测,还能提供决策支持,指导软件项目的规划和过程管理。本书从机器学习的角度分析了软件缺陷预测的特点。同时分析了当前已有的预测方法在应用过程中存在的三个主要问题:(1)因为数据集是来自不同的项目或不同的领域,它们具有不同的数据分布,因此,基于传统方法建立的预测模型具有较弱的适应能力。(2)通过代码审查来手工标记有缺陷的模块是既费资金又费时间的活动,因此,数据集中的正样本数据是有限的。当前的方法是基于监督学习算法建立的预测模型,是仅基于有标记的数据的学习过程。这些方法不能满足要求,因为数量有限的标记数据不具备建立合适的预测模型的足够信息。(3)软件缺陷数据通常是类不平衡的,正样例数远远高于负样例数。该类不平衡问题已经很大程度地影响了缺陷预测模型的性能。本书研究了软件缺陷预测中的最先进的方法技术,包括这些方法的动机,进展,特点和劣势。在此基础上提出了创新的实用技术,并为解决软件缺陷预测中上述的三个问题提供了有效方法。

本书在以下几个方面取得了一些有价值的研究成果。

## 1. 基于迁移学习的软件缺陷预测研究

提出了新的缺陷预测算法,基于朴素贝叶斯的迁移学习算法(TNB)。不同于已有的预测模型选择与测试数据相类似的训练数据,该算法使用了训练数据中所有特征的实用信息。TNB首先计算出测试数据的分布情况,并将跨公司待预测的数据信息通过赋权的方式作用于训练数据。然后基于这些加权数据,建立缺陷预测模型。笔者还对已有的方法进行了理论分析,并在来自不同组织的数据集上进行了实验比较。结果表明通过TNB建立的预测模型不仅能得到更好的AUC性能,同时具有较低的运行

时间。

## 2. 基于半监督学习的软件缺陷预测研究

提出了改进的半监督学习方法,用于解决软件缺陷预测中类不平衡和标记数据有限的问题。基于协同训练风范的半监督学习,该方法采用随机抽样技术来对原始训练数据集和每轮更新后训练数据集进行抽样。这能解决半监督学习中的类不平衡问题,使得缺陷预测模型更实用。我们的方法与传统的数据挖掘方法相比,具有更好的预测性能。实验结果还表明,通过解决半监督学习中的类不平衡问题,有可能设计出更好的半监督分类器。

## 3. 基于主动学习的软件缺陷预测研究

引入主动学习策略,用于减少缺陷预测中标记缺陷模块的代价。本书提出了一种主动学习的方法——两阶段主动学习算法(TAL),用于预测软件缺陷模块。该方法结合聚类方法和支持向量机技术,提高了预测性能并具有较少的标记代价,并通过实验验证了其有效性。

## 4. 基于核理论的软件缺陷预测研究

提出了基于核理论的非对称分类器用于建立软件缺陷预测模型。核方法能有效地解决线性不可分数据的分类问题。笔者从理论上分析了类不平衡问题对核主成分分析的影响。在此基础上,提出了非对称核主成分分类器(AKPCC),试图解决核主成分分析中的类不平衡问题。由于在核主成分分析的基础上弥补了类不平衡问题带来的性能影响,这种方法提高了类不平衡数据集上的预测性能。因此这种方法较其他知名方法具有较优的 F-measure 性能。

作者

2017年10月

# ABSTRACT

Developing a good and stable software defect predictor has become a domestic and international scientific frontier, and attracts more and more attention of software industry. We make an analysis of software defect prediction problem from a machine learning perspective, where software characteristics are represented with static code features and defect predictors are learned from historical defect logs. We observe that the present existing defect predictors have reached a limit performance, due to three main problems in the application: (1) Data distributions are different among data sets, which come from different projects or different domains. Therefore, the predictor built with traditional method has weak adaptive ability. (2) Manual labeling defective modules is both costly and time consuming, so the positive data is limited. Recent approaches are based on supervised learning algorithms, which learn predictors with labeled data only. These methods cannot satisfy the requirements, since the limited labeled data are not enough to learning predictors. (3) The software defect data are always class imbalanced data where the number of positive examples is much higher than that of others. Class imbalance problem has greatly influenced the performance of the defect predictor. In the thesis, we survey the state of the art in software defect prediction research, including motivations, progress, characteristics, and disadvantages. This thesis presents innovative and practical techniques for addressing the three problems mentioned above in software defect prediction as follows:

1. Research on predictive model on transfer learning method

Unlike the prior works selecting training data which are similar from the test data, we propose a novel algorithm called Transfer Naive Bays

(TNB), by using the information of all the proper features in training data. Our solution estimates the distribution of the test data, and transfers cross-company data information into the weights of the training data. On these weighted data, the defect prediction model is built. We also present a theoretical analysis for the comparative methods, and show the experiment results on the data sets from different organizations. It indicates that TNB is more accurate in terms of AUC, within less runtime than the state of the art methods.

## 2. Research on predictive model on semi-supervised learning method

We present an improved semi-supervised learning approach for defect prediction involving class imbalanced and limited labeled data problem. This approach employs random undersampling technique to resample the original training set and updating training set in each round for co-train style algorithm. It makes the defect predictor more practical for real applications, by combating these problems. In comparison with conventional machine learning approaches, our method has significant superior performance. Experimental results also show that with the proposed learning approach, it is possible to design better method to tackle the class imbalanced problem in semi-supervised learning.

## 3. Active learning for software defect prediction

We introduce active learning strategies into the defect prediction. An active learning method, called Two-stage Active Learning algorithm (TAL), is developed for software defect prediction. Combining the clustering and support vector machine techniques, this method improves the performance of the predictor with less labeling effort. The experiments validate its effectiveness.

## 4. Kernel based asymmetric learning for software defect prediction

A kernel based asymmetric learning method is developed for software defect prediction. Kernel method can deal with nonlinearly separable classification problem effectively. We also analyse the effect of class imbalance problem on kernel principal component analysis. The proposed meth-

od Asymmetric Kernel Principal Component Classification (AKPCC) improves the performance of the predictor on class imbalanced data, since it is retrieve the loss caused by class imbalance problem, based on kernel principal component analysis. This method has better F-measure performance than other well-known methods.

简略字表

| 缩写    | 完整英文                                                       | 中文名称         | 页码  |
|-------|------------------------------------------------------------|--------------|-----|
| AKPCC | Asymmetric Kernel Principal Component Classifier           | 非对称主成分分类器    | 98  |
| APLSC | Asymmetric Partial Least Squares Classifier                | 非对称偏最小二乘分类   | 103 |
| AUC   | the Area Under the receiver operating characteristic Curve | 受试者工作特征曲线下面积 | 31  |
| CA    | Cluster Assumption                                         | 聚类假设         | 61  |
| CC    | Cross Company                                              | 跨公司模型        | 45  |
| CCA   | Canonical Correlation Analysis                             | 典型相关分析       | 103 |
| CD    | Chebyshev Distance                                         | 切比雪夫距离       | 18  |
| ED    | Euclidean Distance                                         | 欧氏距离         | 18  |
| EM    | Expectation Maximization                                   | 最大期望         | 25  |
| GM    | Generative Model                                           | 生成式模型        | 59  |
| KCCA  | Kernel Canonical Correlation Analysis                      | 核典型相关分析      | 98  |
| KLDA  | Kernel Linear Discriminant Analysis                        | 核线性判别分析      | 98  |
| KLPP  | Kernel Locality Preserving Projections                     | 核保局投影        | 98  |
| KNN   | K-Nearest Neighbor algorithm                               | K 近邻算法       | 17  |
| KPCA  | Kernel Principal Component Analysis                        | 基于核的主成分分析    | 98  |
| KPLS  | Kernel Partial Least Squares regression                    | 核偏最小二乘回归     | 98  |
| LDA   | Linear Discriminant Analysis                               | 线性判别分析       | 103 |
| MAD   | MANhattan Distance                                         | 曼哈顿距离        | 18  |
| MA    | Manifold Assumption                                        | 流形假设         | 61  |
| MDP   | Metrics Data Program                                       | 软件度量数据项目     | 2   |

续表

| 缩写     | 完整英文                                        | 中文名称            | 页码  |
|--------|---------------------------------------------|-----------------|-----|
| MID    | Minkowski Distance                          | 闵可夫斯基距离         | 18  |
| NASA   | National Aeronautics & Space Administration | 美国国家航空航天局器      | 1   |
| NB     | Naive Bays                                  | 朴素贝叶斯           | 40  |
| OO     | Object Oriented                             | 面向对象            | 12  |
| PCA    | Principal Component Analysis                | 主成分分析           | 30  |
| PLS    | Partial Least Squares                       | 偏最小二乘           | 103 |
| RKHS   | Reproducing Kernel Hilbert Spaces           | 再生核希尔伯特空间       | 96  |
| ROC    | Receiver Operating Characteristic1          | 受试者工作特征         | 33  |
| Rus    | Random Under Sampling                       | 随机抽样            | 75  |
| RusTri | Random undersampling Tri-training           | 随机抽样三分类器的协同训练方法 | 65  |
| SC     | Schwarz Criterion                           | 施瓦茨信息准则         | 24  |
| SMOTE  | Synthetic Minority Over-sampling TEchnique  | 少数类生成过抽样技术      | 106 |
| SSA    | Semi-supervised Smoothness Assumption       | 半监督平滑假设         | 61  |
| SVM    | Support Vector Machine                      | 支持向量机           | 21  |
| TAL    | Two-stage Active Learning                   | 两阶段主动学习         | 84  |
| TNB    | Transfer Naive Bays                         | 基于朴素贝叶斯的迁移学习    | 36  |
| YATSI  | Yet Another Two Stage Idea                  | 两步分类法           | 27  |

# 主要符号表

| 符号                                    | 定义             | 符号             | 定义               |
|---------------------------------------|----------------|----------------|------------------|
| $\mathbf{x}_i$                        | 模块 $i$ 的度量属性向量 | $H(C A)$       | 每个特征对该数据集划分时的信息量 |
| $y_i$                                 | 模块标记           | $\lambda$      | 拉格朗日算子           |
| $a_i$                                 | 模块第 $i$ 个属性    | $D_S$          | 源域               |
| $\mathfrak{R}^d$                      | 原属性空间          | $T_S$          | 源域学习任务           |
| $V(G)$                                | 圈复杂度属性         | $D_T$          | 目标域              |
| $b$                                   | 偏移量            | $T_T$          | 目标域学习任务          |
| $\theta$                              | 预测模型           | $P(c)$         | 先验概率             |
| $\langle \cdot, \cdot, \cdot \rangle$ | 内积             | $P(a_j c)$     | 条件概率             |
| $EV(G)$                               | 基本圈复杂度属性       | $P(c u)$       | 后验概率             |
| $IV(G)$                               | 设计复杂度属性        | $ \cdot $      | 集合的成员数目          |
| $\delta(a, b)$                        | 指示函数           | $(\cdot)^T$    | 矩阵转置             |
| $k(\cdot, \cdot, \cdot)$              | 核函数            | $E\{\cdot\}$   | 取期望值             |
| $\mu$                                 | 均值参数           | $H(C)$         | 每类信息熵            |
| $\sum_j$                              | 协方差矩阵          | $(\cdot)^{-1}$ | 求逆运算             |
| $D_t$                                 | 带标记的数据集        | $s_i$          | 相似属性个数           |
| $D_u$                                 | 未标记的数据集        | $w_i$          | 样本权重             |
| $\max\{\cdot\}$                       | 取最大值           | $O(\cdot)$     | 算法复杂度            |
| $\min\{\cdot\}$                       | 取最小值           | $error_{rate}$ | 整体误差度量           |
| $P_S(X)$                              | 源域数据边缘分布       | $P_T(X)$       | 目标域数据边缘分布        |
| $E_T$                                 | 输出结果方差         | $H$            | 类间散布矩阵           |
| $\operatorname{argmax}\{\cdot\}$      | 取极大时值运算        | $E$            | 类内散布矩阵           |

续表

| 符号                                 | 定义             | 符号                        | 定义                        |
|------------------------------------|----------------|---------------------------|---------------------------|
| $\operatorname{argmin}\{\bullet\}$ | 取极小时值运算        | $n_i$                     | 第 $i$ 个类的样本数              |
| $\Omega$                           | 模型成员组          | $\bar{x}$                 | 总样本集的平均向量                 |
| $\varepsilon$                      | 泛化误差           | $x_{ij}$                  | 第 $i$ 类中的第 $j$ 个样本        |
| $\bar{x}_i$                        | 类平均向量          | $S_b^{\Phi}$              | 基于核的类间散度矩阵                |
| $C_j$                              | 第 $j$ 个聚类质心    | $S_w^{\Phi}$              | 基于核的类内散度矩阵                |
| $\Psi_R(D)$                        | 代表性数据集         | $\bar{u}_i$               | 基于核的各类平均向量                |
| $\Psi_I(D)$                        | 关键信息数据集        | $\bar{u}$                 | 基于核的所有样本的平均向量             |
| $e$                                | 最大错误率          | $\Phi(x_j^i)$             | 基于核表示的第 $i$ 类的第 $j$ 个样本   |
| $H_i$                              | 第 $i$ 个分类器     | $\mu_{ji}^m$              | 样本模糊数值                    |
| $\Phi(x)$                          | 特征映射函数         | $\{x_i\}_{i=n+1}^{n+n_t}$ | 测试数据集                     |
| $K$                                | Gram 矩阵(或者核矩阵) | $K_t$                     | 测试数据集核矩阵                  |
| $\hat{C}$                          | 对角化协方差矩阵       | $p_k$                     | 模型的后验概率                   |
| $\widetilde{u}^k$                  | 第 $k$ 个主成分     | $\hat{I}_k(D)$            | 是当聚类数目为 $k$ 时的模型对应的对数似然概率 |
| $\{x_i\}_{i=1}^n$                  | 训练点集           | $J^{j,+}$                 | 将样本 $x_j$ 标记为正类的风险        |
| $\beta_k$                          | 第 $k$ 个非线性主成分  | $J^{j,-}$                 | 将样本 $x_j$ 标记为负类的风险        |
| $\widetilde{\Lambda}$              | 对角矩阵           |                           |                           |

# 目 录

|                              |      |
|------------------------------|------|
| 第一章 绪论 .....                 | (1)  |
| 一、软件可靠性面临的挑战 .....           | (1)  |
| 二、软件缺陷预测技术研究内容及意义 .....      | (2)  |
| (一)软件缺陷预测基本概念 .....          | (3)  |
| (二)软件缺陷预测研究的基本内容 .....       | (4)  |
| (三)软件缺陷预测的研究意义 .....         | (6)  |
| 三、本书研究内容与创新点 .....           | (7)  |
| (一)研究内容 .....                | (7)  |
| (二)研究成果与创新点 .....            | (9)  |
| 四、本书结构 .....                 | (10) |
| 第二章 软件缺陷预测相关技术 .....         | (12) |
| 一、预测模型的发展 .....              | (12) |
| 二、预测模型的特征属性 .....            | (13) |
| 三、软件缺陷预测的模型及相关算法 .....       | (16) |
| (一)基于监督学习的缺陷预测算法 .....       | (16) |
| (二)基于无监督的软件缺陷预测模型及相关算法 ..... | (23) |
| (三)基于半监督的软件缺陷预测模型及相关算法 ..... | (25) |
| (四)基于回归模型的软件缺陷预测方法 .....     | (27) |
| (五)基于属性约简的缺陷预测方法 .....       | (29) |
| 四、预测模型的评估指标 .....            | (31) |
| 五、本章小结 .....                 | (33) |
| 第三章 基于迁移学习的软件缺陷预测 .....      | (34) |
| 一、迁移学习 .....                 | (34) |
| (一)简述 .....                  | (36) |
| (二)相关研究 .....                | (36) |

|                                    |             |
|------------------------------------|-------------|
| 二、软件缺陷预测的迁移学习模型 .....              | (36)        |
| (一)预测模型的适应性问题阐述 .....              | (36)        |
| (二)软件缺陷预测的迁移学习模型 .....             | (37)        |
| 三、基于朴素贝叶斯的迁移学习算法 .....             | (40)        |
| (一) NB 预测算法 .....                  | (40)        |
| (二) TNB 算法 .....                   | (41)        |
| (三) TNB 算法分析 .....                 | (44)        |
| 四、实验与分析 .....                      | (45)        |
| (一)比较的算法 .....                     | (45)        |
| (二)数据集介绍 .....                     | (46)        |
| (三)性能评估参数 .....                    | (47)        |
| (四)实验结果及分析 .....                   | (47)        |
| 五、本章小结 .....                       | (57)        |
| <b>第四章 基于抽样与集成的半监督软件缺陷预测 .....</b> | <b>(58)</b> |
| 一、半监督软件缺陷预测 .....                  | (58)        |
| (一)半监督软件缺陷预测模型 .....               | (59)        |
| (二)半监督学习概述 .....                   | (60)        |
| (三)半监督学习存在的问题分析 .....              | (64)        |
| 二、基于抽样与集成的预测算法 .....               | (64)        |
| (一)算法描述 .....                      | (64)        |
| (二)基础分类器 .....                     | (68)        |
| (三)算法分析 .....                      | (68)        |
| 三、实验与分析 .....                      | (70)        |
| (一)数据集 .....                       | (70)        |
| (二)实验结果 .....                      | (70)        |
| 四、本章小节 .....                       | (80)        |
| <b>第五章 基于主动学习的软件缺陷预测 .....</b>     | <b>(81)</b> |
| 一、研究背景 .....                       | (81)        |
| 二、两阶段主动学习算法 .....                  | (83)        |
| (一)第一阶段获取代表性数据 .....               | (84)        |
| (二)第二阶段获取关键信息数据 .....              | (86)        |

|                             |       |
|-----------------------------|-------|
| 三、实验与分析 .....               | (88)  |
| 四、本章小结 .....                | (90)  |
| 第六章 基于核理论的软件缺陷预测 .....      | (91)  |
| 一、缺陷预测中类不平衡问题 .....         | (91)  |
| (一)类不平衡问题的研究意义 .....        | (91)  |
| (二)解决类不平衡问题的方法 .....        | (92)  |
| 二、核理论 .....                 | (93)  |
| (一)核理论简述 .....              | (94)  |
| (二)基于核理论的属性约简方法 .....       | (97)  |
| 三、基于非对称的核主成分分析分类算法 .....    | (98)  |
| (一)线性映射与非线性映射 .....         | (98)  |
| (二)核方法中类不平衡问题的影响分析 .....    | (98)  |
| (三)非对称的核主成分分类算法 .....       | (105) |
| 四、实验与分析 .....               | (106) |
| (一)性能评价的度量 .....            | (106) |
| (二)实验结果与分析 .....            | (106) |
| 五、本章小结 .....                | (108) |
| 第七章 静态代码属性与软件缺陷的相关性分析 ..... | (109) |
| 一、代码静态属性与模块缺陷数的关系 .....     | (109) |
| (一)偏相关系数 .....              | (110) |
| (二)偏相关实验分析 .....            | (111) |
| (三)性能评估 .....               | (113) |
| (四)实验结果 .....               | (113) |
| 二、代码静态属性与模块缺陷倾向的关系 .....    | (114) |
| (一)软件缺陷预测 .....             | (115) |
| (二)秩相关系数 .....              | (116) |
| (三)偏相关系数 .....              | (117) |
| (四)实验分析 .....               | (117) |
| 三、结束语 .....                 | (121) |
| 第八章 结束语 .....               | (123) |
| 一、全文总结 .....                | (123) |

- (一)提出了基于迁移学习方法的预测模型 ..... (123)
- (二)提出了基于半监督学习方法的缺陷预测算法 ..... (124)
- (三)提出了基于主动学习的软件缺陷预测模型 ..... (124)
- (四)提出了基于核理论的软件缺陷预测方法 ..... (124)
- 二、进一步研究工作 ..... (125)
  - (一)研究软件模块的内部结构表示方法 ..... (125)
  - (二)研究目前半监督学习方法在软件缺陷预测领域的应用 ... (125)
  - (三)研究各种属性约简方法对预测性能的影响 ..... (125)
  - (四)软件数据噪声和数据偏斜研究 ..... (125)
- 后 记 ..... (126)
- 附录 软件缺陷定义 ..... (127)
- 参考文献 ..... (131)