

用 KPCA-SVM 的方法检测垃圾标签的研究

习 扬, 苏一丹, 覃 希

(广西大学 计算机与电子信息学院, 广西 南宁 530004)

摘 要: 高维数据中进行各种处理时所需样本数量会成指数级增加, 同时样本间距离的价值也逐渐减小, 将导致维数灾问题。文本标签数据通常会面临数据维数过高的问题, 会影响用户对垃圾标签的检测。文中借助支持向量机的数学模型构建出针对 Folksonomy 的大规模垃圾标签检测模型。为了减少检测垃圾标签时维数过高的影响, 在核主成分分析理论的启发下, 将数据降维思想引入数据约简领域, 提出基于核主成分分析法的大规模 SVM 数据集约简模型。最终实例化形成一种新的垃圾标签检测方法, 即基于核主成分分析支持向量机 (KPCA-SVM) 的大规模垃圾标签检测模型。该模型在垃圾标签检测中可以在不影响数据特征的前提下, 缩短模型的测试时间且检测性能良好。

关键词: 数据降维; 核主成分分析法; 支持向量机; 垃圾标签

中图分类号: TP301

文献标识码: A

文章编号: 1673-629X(2014)05-0065-05

doi: 10.3969/j.issn.1673-629X.2014.05.016

Research on Detecting Social Spam with KPCA-SVM Method

XI Yang, SU Yi-dan, QIN Xi

(College of Computer and Electronic Information, Guangxi University, Nanning 530004, China)

Abstract: The needed sample will increase exponentially when processing high-dimensional data, the value of the distance between the sample also gradually reduced at the same time, which will lead to the dimension disaster problem. Text label data usually face this problem of high-dimensional data, it will affect the users to detect social spam. In this paper, take advantage of the mathematical model of Support Vector Machine (SVM) to construct the large-scale social spam detection model for Folksonomy. In order to reduce the influence of high-dimensional data, inspired by the kernel principal component analysis theory, the ideas of data dimension reduction are introduced, the large-scale SVM data set reduction model is proposed which is based on kernel principal component analysis. Finally form a new social spam detection method, the large-scale social spam detection model based on kernel principal component analysis and support vector machine. This model would not affect the characteristics in the social spam detection, and it will shorten the test time and have a good detection performance.

Key words: data dimension reduction; kernel principal component analysis theory; support vector machine; social spam

0 引 言

随着 Web 2.0 时代的到来, 新的 Web 个性化服务技术得到了推广。这给用户带来了真正的个性化和自主化, 使得普通网民直接参与并组织互联网信息成为可能。在此基础上, 一种新的结构分类方法即社会分类法 (Folksonomy) 应运而生。Thomas Vander Wal 认为 Folksonomy 包括三个重要组成部分, 即用户、被描述的资源以及标签或者标识符^[1]。标签系统采用的就是这种新型的分类方法。正是因为用户行为的自主化, 少数用户个体可能会肆意传播垃圾信息, 系统中必然会出现垃圾标签。如何快速有效地检测垃圾标签以

保证系统的正常运行成为了一个具有重要意义的研究课题。

当下主流的垃圾标签检测方法中, Chanju Kim 等人依据贝叶斯判别法去判断用户是否为垃圾标签投放人, 通过限制垃圾标签投放人的破坏行为来减少垃圾标签^[2]。R Krestel 等人则是通过用户所使用标签和资源的共现情况判断用户是否为垃圾标签投放人^[3]。A. Madkour 等人采用用户的语义特征建模与经典 SVM 算法相结合, 实现用户的分类^[4]。文献[5]是采用聚类算法和分类算法相结合的方法检测垃圾标签。然而以上几种垃圾标签检测方法只是实现了使用经典

收稿日期: 2013-07-16

修回日期: 2013-10-21

网络出版时间: 2014-02-11

基金项目: 教育部人文社会科学研究项目 (11YJAZH080)

作者简介: 习 扬 (1990-), 男, 硕士研究生, 研究方向为 Web 标签挖掘、模式识别; 苏一丹, 教授, 研究方向为电子政务、Web 标签挖掘。

网络出版地址: <http://www.cnki.net/kcms/detail/61.1450.TP.20140211.1717.059.html>

模型实现检测,仍然存在一定的局限性。目前垃圾标签检测的研究无法快速有效检测维数过高的数据,而且检测高维稀疏数据时间代价高,准确度不足。文中使用核主成分分析法(Kernel Principal Components Analysis, KPCA)进行垃圾标签数据的维度约简,结合支持向量机(Support Vector Machine, SVM)数据集优化的思想,形成了基于KPCA-SVM的大规模垃圾标签检测模型。在来自于UCI的EailSpam(ES)数据集上进行实验,结果表明基于KPCA-SVM的垃圾标签检测模型对于标签系统的垃圾标签检测效果比现有的检测模型效果更优,花费时间更少。

1 核主成分分析法与支持向量机

1.1 核主成分分析法

主成分分析(Principal Components Analysis, PCA)是最为常用的特征提取方法之一,它通过对原始数据进行降维处理,使问题得到简化。但是它有一个缺陷,主成分分析在本质上是一种线性映射,所以在处理非线性问题时,往往不能取得好的效果。核主成分分析法(KPCA)是通过使用核函数的方法将原始向量映射到高维的特征空间,在此基础上用传统的线性主成分分析法(PCA)处理,核空间下PCA的应用赋予了KPCA进行非线性映射的性能^[6]。近年来,用核方法将线性技术进行重造已经衍生出了诸如核岭回归法和支持向量机这些成功的技术。

KPCA是PCA的进一步优化,它的基本原理是把原始数据 x 通过一个非线性映射 $\Phi(x)$ 映射到特征空间 F ,然后在特征空间 F 上执行线性PCA^[7]。

设给定原始数据集 $X = \{x_1, x_2, \dots, x_N\}$, $x_i \in R^D$, 由一个非线性映射函数 $x \rightarrow \Phi(x) \in F$, 把原始空间中每个数据点 x 映射到特征空间 F 。定义核函数 $k(x_i * x_j) = \Phi(x_i) \Phi(x_j)$, 对原始空间中任意两个数据点 $x_i * x_j$ 在 F 空间中的距离用它们的内积 $\Phi(x_i) \Phi(x_j)$ 表示。假设在特征空间 F 上映射数据的协方差矩阵为 C 。解 C 的特征值 λ 和特征向量 v

$$\Phi_k C v = \lambda \Phi_k v, k = 1, 2, \dots, N \quad (1)$$

而特征向量 v 是在 $\{\Phi_i\}$ 生成的空间中,所以 v 可以表示为

$$v = \sum_i \alpha_i \Phi_i \quad (2)$$

将式(2)代入(1),有

$$K \alpha = \bar{\lambda} \alpha \quad (3)$$

其中, $K_{i,j} = \Phi_i \Phi_j$ 为核矩阵; $\bar{\lambda} = N \lambda$ 。

对式(3)求解可以获得需要要求的特征值和特征向量。

因为在一般情况下 $\sum_{i=1}^N \Phi(x_i) \neq 0$, 故可用

$$\tilde{k}_{ij} = k_{ij} - \frac{1}{n} \sum_l k_{il} - \frac{1}{n} \sum_l k_{jl} + \frac{1}{n^2} \sum_{lm} k_{lm} \quad (4)$$

代替式(3)中的 K 。数据被投影到协方差矩阵的特征向量 v_i 上,便得到了原始数据的低维表示,低维数据可表示为

$$Y = \left\{ \sum_j \alpha_1 k(x_j, x), \sum_j \alpha_2 k(x_j, x), \dots, \sum_j \alpha_d k(x_j, x) \right\} \quad (5)$$

综上所述,KPCA降维算法在本质上就是求解一个特征值问题,所以比较容易得到全局最优解。

1.2 支持向量机

1995年,V. Vapnik等人经过研究在统计学习理论的基础上,发展了一种新的机器学习算法——支持向量机(Support Vector Machine)。研究发现它在解决小样本、非线性及高维模式识别问题中表现出许多特有的优势。支持向量机根据有限的样本信息在模型的复杂性和学习能力之间寻求最佳折衷,以获得最好的推广能力。它的一个重要优点是使用简单的线性分类器划分样本空间,可以处理非线性不可分的情况。

支持向量机基于统计学习理论的结构风险最小化原则之上,能通过寻找最优分类超平面有效地解决二值分类的模式识别问题,将两类数据点分开^[8]。图1展示了SVM的平面分类模型。




图1 SVM平面分类示意图

图中的白点和黑点分别代表待分的两类数据点, H 为分类面, H_1, H_2 分别为 H 向右、左水平移动直到与第一个数据点相切时所得的平面, H_1, H_2 的距离称为分类间隔(Margin)。在确保两类数据点正确分开的同时,若Margin能取得最大值,则此时的 H 称为最优分类面。

实际研究时,数据集可以分为线性可分和线性不可分两种情况。

1.2.1 线性可分情况

假设输入的样本数据集为 $\{(x_1, y_1), \dots, (x_n, y_n)\} \in (X \times Y)^n$, $x_i \in X = R^n$, $y_i \in Y = \{1, -1\}$, $i = 1, \dots, n$ 。若数据集完全线性可分,则必然存在分类超平面,此超平面可用公式(6)描述:

$$w \cdot x + b = 0 \quad (6)$$

其中, w 为 n 维向量; b 为偏移量;“ \cdot ”为内积。

当 Margin 取得最大值时,超平面为最优,即 $\frac{2}{\|\mathbf{w}\|}$ 最大,等价表示为: $\frac{1}{2} \|\mathbf{w}\|^2$ 最小。所以可以把分类问题转化为如下最优化问题,通过求解公式(7)来求得最优分类超平面:

$$\min \varphi(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|^2 \quad (7)$$

$$\text{s. t. } y^i[(\mathbf{w} \cdot \mathbf{x}_i) + b] - 1 \geq 0, i = 1, \dots, n$$

而在多数问题中,数据完全线性可分是不可能的,故要对上式引入松弛变量和惩罚系数,经 Lagrange 优化方法处理后得到下列凸二次规划问题:

$$\begin{aligned} \max W(\boldsymbol{\alpha}) &= \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j (x_i, x_j) \\ \text{s. t. } \sum_{i=1}^n y_i \alpha_i &= 0 \quad 0 \leq \alpha_i \leq C, i = 1, \dots, n \end{aligned} \quad (8)$$

$$\mathbf{w}^* = \sum_{i=1}^n \alpha_i y_i x_i \quad (9)$$

$$b^* = y_i - \mathbf{w} \cdot \mathbf{x}_i \quad (10)$$

其中, \mathbf{w}^* 是最优分类超平面的法向量; b^* 是最优分类超平面的偏移量。

利用下列 KKT 条件

$$\begin{cases} \text{若 } \alpha_i = 0, \text{ 则 } \xi_i = 0, y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1 \\ \text{若 } 0 < \alpha_i < C, \text{ 则 } \xi_i = 0, y_i(\mathbf{w} \cdot \mathbf{x}_i + b) = 1 \\ \text{若 } \alpha_i = C, \text{ 则 } \xi_i = 0, y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \leq 1 \end{cases} \quad (11)$$

可得该问题的最优解 $\boldsymbol{\alpha}^* = (\alpha_1^*, \dots, \alpha_n^*)^T$, 则对应决策函数为:

$$f(x) = \sum_{i=1}^n y_i \alpha_i^* (x \cdot x_i) + b^* \quad (12)$$

由决策函数 $f(x)$ 的符号可以确定 X 的分类。由于最优解 $\boldsymbol{\alpha}^*$ 的每一个分量都对应一个训练点,从公式(9)可以看出构造的分类超平面只取决于那些对应 $\alpha_i^* > 0$ 的训练点,这些训练点称之为支持向量,而对应于 $\alpha_i^* = 0$ 的训练点则称之为非支持向量。

1.2.2 线性不可分情况

当数据集线性不可分时,通过寻找合适的内积函数,将输入的数据点映射到高维特征空间中,化非线性问题为线性问题来求解。

称这些内积函数为核函数,引进核函数后,二次规划问题转化为:

$$\begin{aligned} \max W(\boldsymbol{\alpha}) &= \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j K(x_i, x_j) \\ \text{s. t. } \sum_{i=1}^n y_i \alpha_i &= 0 \quad 0 \leq \alpha_i \leq C, i = 1, \dots, n \end{aligned} \quad (13)$$

对应的决策函数为:

$$f(x) = \sum_{i=1}^n y_i \alpha_i K(x \cdot x_i) + b^* \quad (14)$$

2 基于 KPCA-SVM 的垃圾标签检测模型

文中针对当前主流的 Folksonomy 标签系统存在大量垃圾信息的问题^[9],在总结前人研究经验的基础上,提出了基于 KPCA-SVM 模型的垃圾标签检测方法。传统的垃圾标签检测方法在一定程度上忽视了 Folksonomy 的数据集偏大而且维度过高可能会导致的检测效率不高或者检测时间过长等问题^[10]。文中的模型首先采用 KPCA 降维算法,对原始数据进行降维,在不影响数据主要特征的基础上可以获得原始数据的低维表示,即在维度上对原始数据集进行约简。然后将此约简模型结合经典支持向量机依据 Folksonomy 和文本的定义为用户建模,最终形成基于 KPCA-SVM 的大规模垃圾标签检测模型。

2.1 KPCA 数据降维

降维算法就是对原始高维数据进行分析,以获得高维数据有意义的低维表示的一种方法。KPCA 降维算法是线性降维算法 PCA 的推广,在核空间内对 PCA 进行重建,可以处理非线性数据。算法的性能依赖于核函数的选择,核函数选择不当, KPCA 降维算法的性能将受到影响。

2.1.1 核函数的选取

由于目前的研究成果对于核函数的选择问题并没有形成统一的指导思想,所以对于不同特点的数据集,可以适当依据研究时经验选择合适的核函数^[11]。该算法可供选择的核函数有以下几种:

多项式核函数:

$$K(x_i, x_j) = [(x_i \cdot x_j) + 1]^q \quad (15)$$

径向基核函数(RBF):

$$K(x_i, x_j) = \exp\left\{-\frac{|x_i - x_j|^2}{\sigma^2}\right\} \quad (16)$$

Sigmoid 核函数:

$$K(x_i, x_j) = \tanh(v(x_i \cdot x_j) + c) \quad (17)$$

文中实验中默认使用 RBF 核函数^[12]。

2.1.2 KPCA 算法步骤

输入:原始数据集 X ,核函数 $K(x, y)$;

输出:维度约简后的数据集 Y 。

Step1: 设 X_i, X_j 是原始空间中任意的两个数据点,定义核矩阵 \mathbf{M} ,使 $M_{ij} = K(X_i, X_j)$,其中 K 为核函数,并记由核函数构造的特征空间的映射数据协方差矩阵为 \mathbf{C} ;

Step2: 将核矩阵 \mathbf{M} 用下述计算公式进行修正,

$$k_{ij} = k_{ij} - \frac{1}{n} \sum_l k_{il} - \frac{1}{n} \sum_l k_{jl} + \frac{1}{n^2} \sum_{lm} k_{lm}$$

得到核矩阵 \mathbf{M}^* ;

Step3: 计算得到核矩阵 \mathbf{M}^* 的特征向量 \mathbf{v}_i 和特征值 λ_i ;

Step4: 由 Step3 中求出的 \mathbf{v}_i 和 λ_i 可求出协方差矩阵 \mathbf{C} 的特征向量 α_i , 其中

$$\alpha_i = \frac{1}{\sqrt{\lambda_i}} \mathbf{v}_i$$

Step5: 将数据投影到协方差矩阵的特征向量 α_i 上, 则获得原始数据的低维表示。即

$$\mathbf{Y} = \left\{ \sum_j \alpha_1 k(x_j, x), \sum_j \alpha_2 k(x_j, x), \dots, \sum_j \alpha_d k(x_j, x) \right\}$$

2.2 KPCA-SVM 垃圾标签检测模型

该模型的主体思想是先根据 Folksonomy 的定义构造出用户模型^[13], 然后利用 KPCA 对处理后的数据集进行维度约简, 再使用支持向量分类机对用户进行分类, 检测出垃圾标签投放人。

输入: 原始训练集 X , 原始测试集 Y ;

输出: 检测精度 P 。

Step1: 根据用户模型处理原始数据集 X 和 Y , 得到用户训练集 X^* 和用户测试集 Y^* ;

Step2: 将 X^* 和 Y^* 中的数据利用 KPCA 降维算法得到维度约简后的用户训练集 X' 和用户测试集 Y' ;

Step3: 将数据集 X' 代入林智仁开发的 libsvm 工具包中训练, 并用训练得到的结果对 Y' 进行预测, 得到分类预测结果和检测精度 P , 以此结果可以找出垃圾标签投放用户;

Step4: 输出检测精度 P 。

3 实验结果与比较

文中所使用的实验数据集是一个源于 UCI 的 EailSpam 数据集。该数据集的数据实例有 58 个属性, 降维后保留 39 个属性, 而且都是分为 2 类, 即正类和负类。

3.1 评价指标

在评价此检测模型效果时, 综合 F-measure 值和测试时间这两个方面来进行评价。

(1) F-measure 值。

通常采用准确率 (Precision) 和召回率 (Recall) 这两个指标评价检测模型的性能, 但由于准确率和召回率会彼此制衡, 所以使用这两个指标的加权调和平均值 (F-measure 值) 来评价检测模型。F-measure 值越高, 文中模型的垃圾标签检测效果越好。

准确率:

$$P = \frac{\text{模型检测到的正确垃圾投放用户数}}{\text{模型检测到的垃圾投放用户数}} \times 100\% \quad (18)$$

召回率:

$$R = \frac{\text{模型检测到的正确垃圾投放用户数}}{\text{实际投放垃圾用户数}} \times 100\% \quad (19)$$

F-measure 值:

$$F = \frac{2 \times P \times R}{P + R} \quad (20)$$

(2) 检测时间。

检测时间指使用支持向量机对样本进行训练与测试以识别垃圾标签投放人该阶段所消耗的时间。检测时间越少, 说明检测模型速度更快、效率更高。

3.2 实验结果分析

将文中提出的垃圾标签检测模型与文献[4]中采用的基于语义特征的原始 SVM 方法的 F-measure 值进行对比实验, 其结果如图 2 所示。




图 2 基于 SVM 的垃圾标签检测模型的 F-measure 值对比

实验是在同一垃圾标签数据集上通过基于 SVM 的两种不同的检测模型来检测垃圾标签投放人。通过对比实验发现, 文中提出的基于 KPCA-SVM 的垃圾标签检测模型的 F-measure 值为 0.86, 而基于语义特征的原始 SVM 检测模型的 F-measure 值只有 0.84。显然, 虽然两种方法都是使用经典 SVM 对用户进行分类以检测出垃圾标签投放人, 但文中的检测效果更佳。

经过测算两种模型所花费的检测时间, 其对比结果如图 3 所示, 文中模型检测耗时 2.45 s, 而语义 SVM 模型的检测时间为 3.13 s, 检测效率提高了 21.72%。显然, 对数据集维度进行约简后, 检测效率得到了提升, 这表明文中模型具有更好的检测性能。

4 结束语

文中提出了基于 KPCA-SVM 的方法进行垃圾标签检测, 先构造出 SVM 垃圾标签检测模型^[14], 利用支持向量机的理论对用户进行分类, 识别垃圾标签投放人, 以限制垃圾标签投放人行为的方式减少垃圾标签。




图3 基于 SVM 的垃圾标签检测模型的检测时间对比

然后首次将数据降维的思想引入到垃圾标签检测领域,用 KPCA 降维算法优化此检测模型,克服原始模型处理高维数据时结果不理想、训练时间长等缺点。最后,在来源于 UCI 的 EailSpam 数据集上进行垃圾标签检测实验,并与语义 SVM 检测模型作对比,实验结果表明,文中提出的垃圾标签检测模型具有更快速高效的检测效果,且检测性能良好。虽然基于 KPCA-SVM 的垃圾标签检测模型拥有较好的检测性能,但是目前的技术环境下,该模型在处理大规模数据时需要占用较多内存和计算大规模矩阵,当样本点数目多、维度高时,数据处理速度不理想。因此,如何解决大规模数据处理速度慢的问题将是未来的研究方向。

参考文献:

[1] 刘 丹.近年来国外 Folksonomy 的改进研究进展[J].图书情报工作,2010,54(8):55-59.

[2] Kim Chanju,Hwang Kyu-Baek. Naive Bayes classier learning with feature selection for spam detection in social bookmarking [C]//Proc of Europe conf on machine learning and principles and practice of knowledge discovery in databases. [s. l.]:[s. n.],2008.

[3] Krestel R,Chen L. Using co-occurrence of tags and resources to identify spammers[C]//Proc of machine learning and principles and practice of knowledge discovery. [s. l.]:[s. n.],2008.

[4] Madkour A,Hefni T,Hefny A,et al. Using semantic features to detect spamming in social bookmarking systems[C]//Proc of ECML PKDD discovery challenge workshop. [s. l.]:[s. n.],2008.

[5] 覃 希,苏一丹.用双层减样法优化大规模 SVM 垃圾标签检测模型[J]. 计算机应用研究,2011,28(6):2095-2098.

[6] Osuna E,Freund R,Girosi F. Training support vector machines:An application to face detection[C]//Proceedings of computer vision and pattern recognition'97. [s. l.]:[s. n.],1997:130-136.

[7] 丁鸿弼,阮 俊.基于 KPCA-SVM 的入侵检测模型研究[J]. 科技创新导报,2011(1):33-33.

[8] 覃 希,夏宁霞,苏一丹.基于支持向量机的垃圾标签检测模型[J]. 计算机应用研究,2010,27(10):3893-3895.

[9] 张新伦,苏一丹,惠刚刚.核 K-Means 聚类在 Folksonomy 标签模糊和冗余中的应用[J]. 计算机应用,2011,31(3):680-682.

[10] 王 英. Folksonomy 与传统分类法的比较分析及其完善研究[J]. 图书馆学研究,2010(3):45-47.

[11] 邓乃阳,田英杰.数据挖掘中的新方法-支持向量机[M]. 北京:科学出版社,2004.

[12] 吴崇明,王晓丹,白冬婴,等.利用 KKT 条件与类边界包向量的 SVM 增量学习算法[J]. 计算机工程与设计,2010,31(8):1792-1794.

[13] 袁 柳,张龙波.个性化搜索中的用户特征模型研究[J]. 计算机工程与应用,2011,47(15):19-24.

[14] Platt J C. Sequential minimal optimization:A fast algorithm for training support vector machines[R]. [s. l.]:[s. n.],1999.

(上接第 64 页)

toration[J]. Journal of Information Science and Engineering, 2006,22:189-198.

[7] Rodríguez-Cuenca B, Malpica J A, Alonso M C. A spatial contextual postclassification method for preserving linear objects in multispectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing,2013,51(1):174-183.

[8] Gonzalez R C,Woods R E. Digital image processing[M]. 2nd ed. Beijing:Publishing House of Electronics Industry,2009.

[9] Bar L,Sochen N,Kiryati N. Image deblurring in the presence of salt-and-pepper noise[J]. Lecture Notes in Computer Science,2005,3459:107-118.

[10] Yu Qian,Kang Zhang,Fang Qiu. Spatial contextual noise removal for post classification smoothing of remotely sensed images[C]//Proceedings of the ACM symposium on applied computing. Santa Fe,New Mexico,USA:[s. n.],2005:524-528.

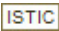
[11] Kong N S P,Ibrahim H. Color image enhancement using brightness preserving dynamic histogram equalization [J]. IEEE Transactions on Consumer Electronics,2008,54(4):1962-1968.

[12] 金良海,李德华.基于噪声检测的图像去噪算法[J]. 模式识别与人工智能,2008,21(3):298-302.

[13] Farbman Z,Fattal R,Lischinski D,et al. Edge-preserving decompositions for multi-scale tone and detail manipulation[J]. ACM Transactions on Graphics,2008,27(3):1-10.

[14] Kao Wen-Chung,Chen Yingju. Multistage bilateral noise filtering and edge detection for color image enhancement [J]. IEEE Transactions on Consumer Electronics,2005,51(4):1346-1351.

用KPCA-SVM的方法检测垃圾标签的研究

作者: [习扬](#), [苏一丹](#), [覃希](#), [XI Yang](#), [SU Yi-dan](#), [QIN Xi](#)
作者单位: [广西大学 计算机与电子信息学院, 广西 南宁, 530004](#)
刊名: [计算机技术与发展](#) 
英文刊名: [Computer Technology and Development](#)
年, 卷(期): 2014 (5)

本文链接: http://d.g.wanfangdata.com.cn/Periodical_wjfz201405016.aspx