

客户利润贡献度评价的数据挖掘方法

邹 鹏, 李一军, 叶 强

(哈尔滨工业大学管理学院, 哈尔滨 150001)

摘要: 讨论了客户关系管理中的客户利润贡献度评价这一关键问题. 为了提高客户利润贡献度评估的可操作性, 本研究在评价方法中引入数据挖掘技术, 给出了这一方法的步骤和基于判定树的分类模型. 最后结合实例对该方法的应用进行了说明.

关键词: 客户关系管理; 客户利润贡献度; 数据挖掘

中图分类号: F713.5; TP18 **文献标识码:** A **文章编号:** 1007-9807(2004)01-0053-07

0 引言

客户利润贡献度最初出现在管理会计和营销领域的研究文献中. 20世纪90年代初, 随着作业成本会计法的出现, 管理会计研究人员对影响和驱动客户服务成本及利润的过程和因素深感兴趣, 并开始用数据和信息来管理和控制客户服务及相关操作^[1,2].

到目前为止, 对客户利润贡献度的研究主要有两个派别: 成因学派和结果学派. 成因学派主要研究客户利润贡献度的形成机制及影响因素; 而结果学派是根据历史交易数据来评价客户利润贡献度.

成因学派的研究主要集中在营销和服务领域, 该学派对客户利润贡献度的研究主要集中在一些非财务指标对客户利润贡献度的影响上, 如顾客满意度对财务业绩的影响^[3]. 结果学派对客户利润贡献度的研究表现为客户利润贡献度模型. 在营销文献中, Berger 和 Nash 曾提出一系列客户赢利性模型^[4]来计算特定情况下的客户利润贡献度, 不过作者并没有提供这些客户利润贡献度模型的实证分析. Mulhem 提出了一个模型计算客户当前的利润贡献度, 这一模型是针对直销设计的, 在计算客户利润贡献度时, 仅仅考虑了直接营

销成本^[5]. Wayland 和 Cole 总结了计算客户利润贡献度的方法, 将前一期客户利润贡献度作为后一期客户利润贡献度的依据^[6]. 而在关系营销和客户关系管理中, 一个常用的作法是在每个计划期内, 预测所有当前顾客尚未实现的终身价值, 并按照价值的大小排序, 根据企业的资源约束选择尽可能多的价值尽可能大的客户作为企业重点考试的对象, 采用这种做法, 能够保证企业未来利润的最大化. Rakesh 和 Gupta 等人提出了计算现实客户利润贡献度的模型^[7]. 而杨永恒提出了一个理念公式来预测潜在客户利润贡献度^[8].

尽管在客户关系管理领域许多专家都对客户利润贡献度进行了研究, 但目前来看, 仍存在以下问题: 主要是针对现实客户利润贡献度提出了一些计算的模型和公式, 而对能为企业客户关系管理战略提供重要决策依据的潜在客户利润贡献度, 只提供了理念公式, 可操作性较差. 随着数据量加大, 不仅要考虑到潜在客户数量增加, 而且每个客户的特征也越来越多, 采用传统的方法已经难以胜任. 这时就需要引入先进的知识发现和数据挖掘技术, 探寻客户特征与购买行为之间的模式, 据此发动营销活动. 本文针对这一问题提出一种基于数据挖掘技术的客户利润贡献度的评价方法.

收稿日期: 2002-02-01; 修订日期: 2003-11-16.
基金项目: 国家自然科学基金资助项目(70171013).
作者简介: 邹 鹏(1975—), 湖北麻城人, 博士生.

1 基于数据挖掘技术的客户利润贡献度评价方法

1.1 基本思路

利用数据挖掘技术对企业数据仓库中客户的历史数据进行分析,用分类判定树归纳出客户的各种属性特征与其利润贡献度大小的关系的分类规则,这样建立了客户利润贡献度的评价模型.再把利润贡献度未知的客户的数据输入模型,运用已归纳出的分类规则对这些客户分类,即得到对这些客户利润贡献度的评价结果.

1.2 主要步骤(图 1)

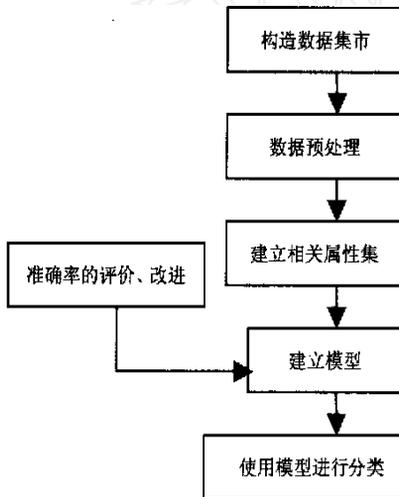


图1 客户利润贡献度评价方法流程图

1) 构造数据集市

从企业客户关系管理部门的数据集中采集客户记录建立以客户利润贡献度为主题的数据集合.根据业务需要收集尽可能多的描述客户特征的属性.

2) 数据预处理

(1) 离散化:对于数值型的连续属性值,通过将属性域划分为区间,区间的标号代替实际的数据值.

(2) 概化 (generalization)

根据业务要求采用面向属性归纳法 (attribute-oriented induction, AOI).

基本思路:首先收集任务相关数据,然后通过考察相关数据中每个属性的不同值的个数,进行概化.概化通过属性删除或属性概化进行.

(a) 属性删除:如果初始数据的某个属性有大量不同值,但对该属性没有定义概念分层,或它的较高层概念用其他属性可以表示,该属性应删除.

(b) 属性概化:如果初始信息的某个属性有大量不同值,并且该属性定义了概念分层,可以用较高层概念(如收入的高、中、低)替换低层概念(具体值)

3) 建立相关属性集

用于分析的数据包含大量属性,其中含有一些与挖掘任务不相关,是冗余的.通过属性相关性分析,过滤掉统计上不相关或弱相关的属性,这样就筛选出对挖掘任务最相关的属性组成相关属性集.

本文将信息增益分析技术和基于多维数据分析的方法集成在一起删除信息量较少的属性,收集信息量较多的属性^[9].方法简介如下:

设 S 是训练样本集合,其中每个样本的类标号是已知的.假定有 M 个类,设 S 包含 s_i 个 c_i 类样本, $i = 1, \dots, m$, 一个任意样本属于类 c_i 的可能性是 s_i/s ,其中 s 是集合 S 中对象的总数.对一个给定样本分类所需的期望信息是

$$I(s_1, s_2, \dots, s_m) = - \sum_{i=1}^m \frac{s_i}{s} \log_2 \frac{s_i}{s} \quad (1)$$

具有值 $\{a_1, a_2, \dots, a_v\}$ 的属性 A 可以用来将 S 划分为子集 $\{S_1, S_2, \dots, S_v\}$,其中 S_j 包含 S 中 A 值为 a_j 的那些样本.设 S_j 包含类 c_i 的 s_{ij} 个样本.根据 A 的这种划分的期望信息称为 A 的熵.它是加权平均

$$E(A) = \sum_{i=1}^v \frac{s_{1i} + \dots + s_{mi}}{s} I(s_{1i} + \dots + s_{mi}) \quad (2)$$

A 上该划分的获得的信息增益定义为

$$\text{Gain}(A) = I(s_1, s_2, \dots, s_m) - E(A) \quad (3)$$

利用这种方法可以计算出定义 S 中样本每个属性的信息增益度量,然后使用这一度量对属性排序,删除与利润贡献度分类不相关或弱相关的属性(可以设置一个阈值来定义“弱相关”) 阈值选取属于用有指导学习的方法进行属性选择,由于在冗余属性和相关属性之间没有绝对界限,所以在实际应用中阈值的确定是比较有难度的,理论上,一般采用预定初始值,使用分类器进行分类,再根据分类的准确度调整初始值.笔者查阅了关于阈值选取的文献^[10-12],结合在实际工作中与

技术人员和用户的共同研究会,提出一种实用的方法,称之为标志属性阈值确定法,这种方法的特点是:人机交互,数据挖掘技术和业务专家的知识相结合;多次测试,客观结果和主观判断相结合;该方法可以简述如下:

首先计算出初始属性集中每个属性的信息增益度,再用这一度量将属性排序.

接下来需要用户或领域专家参与进行.首先根据专家的领域知识和经验确定哪些属性与挖掘任务不相关(依据不同的挖掘任务和数据集确定的结果也会不同):如在为客户利润贡献度的分类中,客户生日的具体日期,电话号码这样的属性会被业务专家认为与利润贡献度关系不大或基本无关,那么这样的属性就可以被排除出相关属性集,可以被称之为标志性可删除属性,就是说这样的属性的信息增益度的值可以成为一个选择的标准,即信息增益度的值比它小的属性也应被删除.

可以保守地先将信息增益度的值最小的标志性可删除属性选取为初始阈值,并将信息增益度的值比它小的属性都删除,这样形成一个相关属性集,接下来进行分类产生分类结果,对其准确度进行检验.

再按照选出的标志性可删除属性的信息增益度的值从小到大的顺序定为测试阈值,重复以上方法,得出的几种分类结果比较它们的准确度,选取最终阈值.

如果无法确定标志性可删除属性,则可采用 John G H 等人提出的 wrapper 模型^[13],该模型采用贪心算法和逐步反向删除(backward stepwise elimination, BSE)的策略,即从包含所有属性的集合开始,逐个删除属性直到再删除属性就会降低决策树的分类正确性为止.而这个使准确性开始降低的属性的信息增益值为阈值,信息增益值比这个阈值小的属性都被删除.这样保留下来的属性就构成了相关属性集.

4) 建立模型

模型的建立过程如图 2 所示.

通过分析由属性描述的数据库元组来构造模型,描述预定的数据类集.假定每个元组属于一个预定义的类,由一个称作类标号属性的客户利润贡献度属性确定.

模型构造分以下三步:

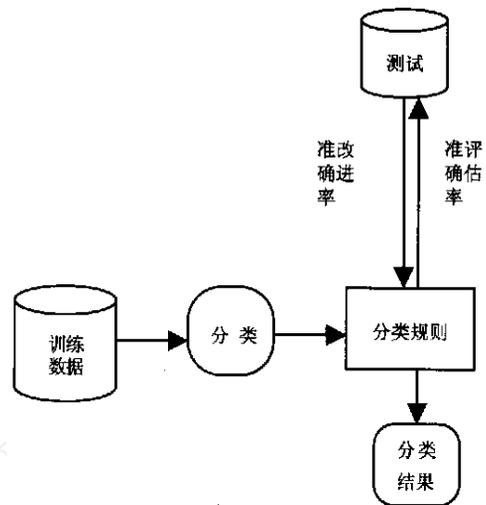


图 2 模型的建立过程

为建立模型而被分析的数据元组形成训练数据集;

分类判定树归纳,模型的学习在被告知训练样本属于哪个类的“指导”下进行;

由分类判定树提取分类规则;

训练数据集已通过步骤 1), 2), 3) 形成,下面介绍后两步:

1° 分类判定树归纳

判定树(decision-tree)是一个树结构.它的每个非叶节点表示在一个属性上的测试,每个分枝代表一个测试输出,而每个叶节点代表类或类分布.

需要指出:在树的每个节点上使用信息增益度量选择测试属性.选择具有最高信息增益的属性作为当前节点的测试属性.计算信息增益的方法在上文中建立相关属性集中已作介绍.

采用贪心算法产生一棵判定树,步骤如下:

算法:Generate. decision. tree 由给定的训练数据产生一棵判定树.

输入:训练样本 *samples*,由离散值属性表示;候选属性的集合 *attribute. list*.

方法:

- (1) 创建节点 *N*;
- (2) if *samples* 都在同一个类 *C* then
- (3) 返回 *N* 作为叶节点,以类 *C* 标记;
- (4) if *attribute. list* 为空 then
- (5) 返回 *N* 作为叶节点,标记为 *samples* 中最普通的类:// 多数表决

(6) 选择 *attribute. list* 中具有最高信息增益的属性 *test. attribute* ;

(7) 标记节点 *N* 为 *test. attribute* ;

(8)for each *test. attribute* 中的已知值 a_i // 划分 *samples*

(9) 由节点 *N* 长出一个条件为 *test. attribute* = a_i 的分支;

(10) 设 s_i 是 *samples* 中 *test. attribute* = a_i 的样本的集合 ;// 一个划分

(11)if s_i 为空 then

(12) 加上一个树叶,标记为 *samples* 中最普通的类;

(13)else 加上一个由 *Generate. decision. tree*(s_i , *attribute. list-test. attribute*) 返回的节点;

2°规则提取,提取判定树表示的知识,以 IF - THEN 形式的分类规则表示.对从根到树叶的每条路径创建一个规则,沿着给定路径上每个属性 - 值对形成规则前件(“IF”部分)的合取项,叶节点包含利润贡献度预测,形成规则后件(“THEN”部分).通过删除前件中无助于改进规则评估准确性的条件,可以对规则“剪枝”,对于每一类,类中规则可以按它们的估计准确排序.由于一个给定样本可能不满足任何规则前件,通常将一个指定多数类的缺省规则添加到结果规则中.

3°评估,改进模型预测准确率.将给定数据随机划分成两个独立的训练集和测试集.使用训练集导出分类规则,用测试集评估规则的准确率.

5) 使用模型进行分类.

如果认为模型的准确率可以接受,就可以用它对类标号未知的客户进行分类.

2 客户利润贡献度评价方法示例

举简例说明

(1) 建立主题数据集市

根据对客户利润贡献度的研究,数据集中应包括以下属性.

客户人口统计特征属性:如客户收入,居住地

客户行为属性:如一年内客户购买次数(频率)

客户满意度属性:客户对产品/服务是否满意(满意)

直接与客户利润相关属性:客户一年内创造的利润值(利润贡献度)

客户初始信息如表 1:

表 1 客户初始信息

姓名	居住地	收入	利润贡献度	满意	频率
A	法国	10 000	145	是	18
B	英国	9 000	95	否	9
C	日本	13 000	170	是	22
...

(2) 数据预处理

姓名:存在大量不同值,且无法进行概念分层,该属性被删除.

满意:只有两个不同值,该属性保留,不进行概化.

居住地:该属性有大量不同值,应进行概化,假定存在居住地的概念分层,定义为国家 < 洲,则将居住地概化到洲.

利润贡献度:是连续数值,将其离散化,区间划分为 $C_1 > 100$, $C_2 < 100$ 而且利润贡献度作为分类的标识属性, C_1 , C_2 为类标号.

收入:连续数值,可进行离散化,区间划分为 (0,500) , (500,1 000) , (1 000, +)

每个区间再按描述值{低,中,高}概化.

频率:连续数值,进行离散化, F_1 (0,10) , F_2 (10,20) , F_3 (20, +)

通过预处理得到广义关系表,从中随机抽取若干元组组成训练数据集.(表 2)

表 2 训练数据集

标识	频率	收入	满意	居住地	类:利润贡献度
1	F_1	高	否	亚洲	C_2
2	F_1	高	否	欧洲	C_2
3	F_2	高	否	亚洲	C_1
4	F_3	中	否	亚洲	C_1
5	F_3	低	是	亚洲	C_1
6	F_3	低	是	欧洲	C_2
7	F_2	低	是	欧洲	C_1
8	F_1	中	否	亚洲	C_2
9	F_1	低	是	亚洲	C_1
10	F_3	中	是	亚洲	C_1
11	F_1	中	是	欧洲	C_1
12	F_2	中	否	欧洲	C_1
13	F_2	高	是	亚洲	C_1
14	F_3	中	否	欧洲	C_2

(3) 建立相关属性集

类标号属性利润贡献度有两个不同值{ C_1 , C_2 },因此有 2 个不同类 $m = 2$, C_1 有 9 个样本, C_2

有 5 个样本,使用式(1)

$$I(s_1, s_2) = I(9, 5) = 0.971$$

计算每个属性的熵:频率

$$F_1 : S_{11} = 2 \quad S_{21} = 3 \quad I(S_{11}, S_{21}) = 0.971$$

$$F_2 : S_{12} = 4 \quad S_{22} = 0 \quad I(S_{12}, S_{22}) = 0$$

$$F_3 : S_{13} = 3 \quad S_{23} = 2 \quad I(S_{13}, S_{23}) = 0.971$$

使用式(2),如果样本按频率划分,对一个给定样本分类所需的期望信息为

$$E(F) = \frac{5}{14} I(s_{11}, s_{21}) + \frac{4}{14} I(s_{12}, s_{22}) +$$

$$\frac{5}{14} I(s_{13}, s_{23}) = 0.694$$

因此这种划分的信息增益是

$$Gain(F) = I(S_1, S_2) - E(F) = 0.246$$

类似计算出 $Gain(收入) = 0.029$,

$$Gain(满意) = 0.151, Gain(居住地) = 0.048$$

假定用于识别弱相关的标志性可删除属性为收入,则相关阈值设为 0.029[$Gain(收入) = 0.029$],本例中恰好收入的信息增益度最小,只有它被删除.

这样产生相关属性集(表 3).

表 3 相关属性集

标识	频率	满意	居住地	Class: 利润贡献度
1	F ₁	否	亚洲	C ₂
2	F ₁	否	欧洲	C ₂
3	F ₂	否	亚洲	C ₁
4	F ₃	否	亚洲	C ₁
5	F ₃	是	亚洲	C ₁
6	F ₃	是	欧洲	C ₂
7	F ₂	是	欧洲	C ₁
8	F ₁	否	亚洲	C ₂
9	F ₁	是	亚洲	C ₁
10	F ₃	是	亚洲	C ₁
11	F ₁	是	欧洲	C ₁
12	F ₂	否	欧洲	C ₁
13	F ₂	是	亚洲	C ₁
14	F ₃	否	欧洲	C ₂

(4) 建立模型

由于频率在属性中有最高的信息增益,它作为判定树根节点的测试属性,并对于每个属性值引出一个分支,选择信息增益次高的属性为下一级节点的测试属性,这样递归的构造判定树,经过剪枝,最终判定树如图 3 所示.

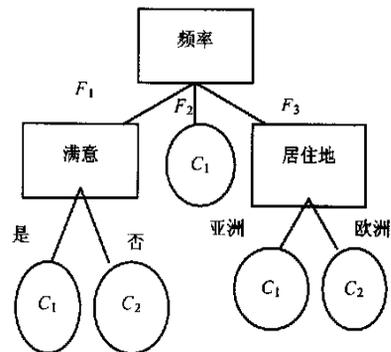


图 3 客户利润贡献度最终判定树

根据判定树提取规则(删去无助改进准确率的规则和规则的前件)

- (a) IF 频率 10 AND 满意 = 是 THEN 利润贡献度 > 100
 - (b) IF 频率 > 20 AND 居住地 = 亚洲 THEN 利润贡献度 > 100
 - (c) IF 10 < 频率 20 THEN 利润贡献度 > 100
 - (d) IF 频率 10 AND 满意 = 否 THEN 利润贡献度 100
 - (e) IF 频率 > 20 AND 居住地 = 欧洲 THEN 利润贡献度 100
- (5) 使用模型分类

用测试集中的数据评估分类规则的准确率,达到要求后,输入类标号未知的客户数据,得到客户利润贡献度的评价结果.

本文在一个有 867 条记录的客户数据集上测试了该方法.经过处理,客户属性集包括:利润贡献度、购买频率、满意、居住地区、收入、年龄、性别、职业,其中利润贡献度作为用于分类的类标志属性.随机抽取 578 条记录作为训练数据集,另外 289 条作为测试集,测试结果为:

将客户按照利润贡献度分为两类时准确率为 87 %;

将客户按照利润贡献度分为三类时准确率约为 78 %;

将客户按照利润贡献度分为四类时准确率约为 64 %

将客户按照利润贡献度分为五类时准确率约为 52 %;

当客户分类数在三类以下时,其准确率可以被用户接受,但是超过三类准确率较差,但对于这

种规模的企业,就其经营能力来说很难同时为超过三个具有不同利润贡献能力的客户群分别制定不同的客户关系战略并完全贯彻实施,所以对于这一数据集来说,该方法的结果还是有实用价值的.如果有规模更大的企业,它的客户记录应该更多,这样用更多的数据训练可能会提高该方法在分类数较多时的准确性.

3 结论

该方法的特点主要体现在它的实用性:

(1)将客户利润贡献度以分类的形式表示.当企业对客户进行分析时,如果要把每个客户的利润贡献度的精确值都计算出来,那么这样做往往成本过高,花费时间,更重要的是会错过转瞬即逝的市场机会.而在本文提出的方法中,客户利润贡献度的评价结果不是以具体的连续型数值表示,而是把客户按其利润贡献度大小分类,每一类以一个标号作为类标识.那么评价结果是把目标客

户归入某一类,以相应的类标号表示其客户利润贡献度的大小,再对各类客户的特征采取有针对性的措施就可以达到企业的预期目标,这样可以节约成本和时间.

(2)具有预测功能.传统的方法基本是根据历史的数据计算已实现的客户利润贡献度,本文在此基础上,根据分类产生的规则中所描述的客户特征与其利润贡献度的关系可以预测客户未来或潜在的利润贡献度.

(3)分类结果易于理解,可以直接用于制定策略.判定树算法的一个优点是,在保证准确度的前提下,它的工作过程和结果更直观,易于理解.所以用户可以根据该方法评估的结果直接制定相应的客户关系策略.

(4)模型有很强的适应性.在构造模型之前的数据预处理阶段,通过对属性和数据的概化,离散化等方法,不仅提高建模的速度和质量,而且使所建的模型可以根据不太精确的客户数据也能做出比较准确的评价结果.

参考文献:

- [1] Shields Michael D. Research in management accounting by north americans in 1990s[J]. Journal of Management Accounting Research, 1990, 9: 3—6.
- [2] Joseph A Ness, Micheael J Schroeck, et al. The role of ABM in measuring customer value[J]. Strategic Finance, 2001, April: 38—49.
- [3] Foster George, Mahendra Gupta. The Customer Profitability Implications of Customer Satisfaction[R]. John M. School of Business, Washington University in St. Louis, 1999.
- [4] Berger Paul D, Nash Nada I. Customer lifetime value: Marketing models and applications[J]. Journal of Interactive Marketing, 1998, 12(1): 17—31.
- [5] Mulhem Framis J. Customer profitability analysis measurement, concentration, and research directions[J]. Journal of Interactive Marketing, 1999, 13(1): 25—40.
- [6] Wayland Robert, Paul Michael Cole. Customer Connections: New Strategies for Growth Boston[M]. Harvard: Harvard Business School Press, 1997. 267.
- [7] Rakesh Niraj Gupta. Customer profitability in supply chain[J]. Journal of Marketing, 2001, 65: 1—16.
- [8] 杨永恒. 客户关系管理—价值导向及使能技术[M]. 大连: 东北财经大学出版社, 2002.
- [9] Jiawei Han, Micheline Kamber. Data Mining Concepts and Techniques[M]. San Mateo: Morgan Kaufmann Publishers Inc, 2001.
- [10] 庞剑锋, 卜东波. 基于向量空间模型的文本自动分类系统的研究与实现[EB/OD]. <http://www.ict.ac.cn/xueshu/2001/115.doc>. 2001.
- [11] 冯是聪. 搜索引擎个性化查询服务研究[EB/OD]. <http://162.105.80.84/directory.htm>.
- [12] 张宁. 顾客满意阈值及市场营销策略属性的离散估计[J]. 管理科学学报, 2002, 5(3): 62—66.
- [13] John G H, Kohavi R, Pflieger K. Irrelevant Features and the Subset Selection Problem, Machine Learning[C]. Proceedings of the Eleventh International Conference, San Francisco, CA: Morgan Kaufman, 1994.

Study on method of evaluating customer profitability based on data mining

ZOU Peng , LI Yi-jun , YE Qiang

School of Management , Harbin Institute of Technology , Harbin 150001 , China

Abstract: This paper discusses the customer profitability in CRM. It uses the data mining technique in order to supplement the lack of the operational method in evaluation of customer profitability. Then the process of the evaluation and the decision-tree model of classification are proposed.

Key words: customer relationship management ; customer profitability ; data mining

本刊 2003 年度论文评审专家名单(排名不分先后)

韩立岩	李明志	于景元	孙艳丰	刘 鲁	陈国青	任若恩	冯允成	潘承烈	郑晓齐	王殿福
张 宁	彭 赓	王永县	刘建一	王惠文	黄海军	袁著祉	安利平	杨晓光	邱菀华	张一弛
赵纯均	周 泓	周寄中	刘 克	夏国平	黄京华	戴汝为	陈 剑	刘丽文	赵 平	吕本富
陈伯成	孙卫东	官建成	朱 涛	陈锡康	韦 琳	周子康	乌家培	金占明	夏绍纬	高远洋
朱世武	张景增	刘建庸	陈良猷	闫永新	杨翠红	何 清	徐伟宣	穆荣平	范秀成	江明华
时 勘	戴 锋	王丹力	黄鲁成	沈利生	魏一鸣	李洪兴	魏法杰	方卫国	刘善存	李书全
陈增强	李泊溪	唐锡晋	姜旭平	陈国权	张汉勤	杨新苗	陈光亚	王浣尘	王宗军	马 俊
黄丽华	李楚霖	杨朝军	徐天亮	汪寿阳	赵 平	陈宏民	谢 赤	仝允恒	李京文	刘海龙
曾 勇	龚其国	冯 芸	梁 樑	王其文	朱道立	陈 收	翟东升	宋华岭	芮明杰	陈 劲
宋逢明	李志强	洪剑峭	宋学锋	卢祖帝	柳卸林	司春林	陶学禹	田大山	徐剑刚	赖明勇
陈黎明	骆品亮	张维明	陈 铎	陈 安	顾新一	陈晓红	杨国梁	李汉东	胡树华	唐小我
方俐洛	王永贵	胡继灵	谭跃进	佟仁城	刘国新	达庆利	王先甲	仲伟俊	谢 滨	陈荣秋
赵曙明	蓝伯雄	徐绪松	徐泽水	盛昭瀚	刘树林	张 黎	吴冲锋	张 帏	韩伯棠	吴文锋
陈学彬	凌文铨	钱省三	王其藩	周 蓉	谢 康	杨 明	黄 丞	余光胜	孙文瑜	唐元虎
周国华	周 晶	伍青生	缪柏其	郭耀煌	刘传哲	易 江	简志宏	范龙振	胡汉辉	刘 洪
黄 兴	杨立洪	汪贤裕	赵林度	郑祖康	井润田	吴瑞明	华中生	周德群	陈工孟	吴晓波
齐安甜	马士华	王金桃	韩乔明	俞 樵	谭力文	陈俊芳	彭建刚	李新春	王志江	杨 珏
吴健中	曾德明	李绪红	聂 锐	胡代平	王槐林	黄中祥	冯俊文	徐学军	黄登仕	黎志成
胡 培	程国平	陈伟忠	黎 实	何 静	方兆本	田新时	欧阳令南	廖建桥	朱启贵	何建敏
李仕明	陈志祥	严广乐	曹 兴	陈文伟	谭德庆	顾海英	李一智	艾兴政	王重鸣	姚 莉
吴广谋	李 垣	赵振全	何荣天	叶民强	王刊良	原毅军	李善民	王慧敏	席西民	刘士新
汪传旭	仲伟周	秦学志	胡振华	邓贵仕	孙林岩	赵增耀	杨招军	田也壮	胡奇英	叶 强
党延忠	杨德礼	石春生	王延章	高铁梅	梁 磊	汤兵勇	唐焕文	冯玉强	王众托	苏卫东
胡祥培	郭菊娥	段兴民	李仲飞	郭亚军	崔文田	刘艳春	田立新	黄 敏	李汉铃	张朋翥
蒲勇健	高利群	胡运权	杨秀苔	樊治平	冯耕中	黄小原	惠晓峰	庄贵军	蓝海林	唐加福
荣莉莉	庄新田	顾 锋	汪定伟	李怀祖	胡毓达	潘德惠	徐 渝	李延喜	黄梯云	曲晓飞
卢 涛	冯英俊	李向阳	西 宝	李一军	徐寅峰	徐国华	万迪昉	汪应洛	顾培亮	张世英
张 维	李敏强	郑丕谔	贺国光	唐万生	韩文秀	詹原瑞	杜 纲	史道济		

以上专家为《管理科学学报》的论文评审工作做出了重要贡献,特向他们表示深深谢意。