

# 基于因果发现的神经网络集成方法\*

凌锦江, 周志华<sup>+</sup>

(南京大学 计算机软件新技术国家重点实验室, 江苏 南京 210093)

## Causal Discovery Based Neural Network Ensemble Method

LING Jin-Jiang, ZHOU Zhi-Hua<sup>+</sup>

(National Laboratory for Novel Software Technology, Nanjing University, Nanjing 210093, China)

+ Corresponding author: Phn: +86-25-83686268, E-mail: zhouzh@nju.edu.cn, <http://cs.nju.edu.cn/people/zhouzh/>

Received 2003-08-04; Accepted 2004-06-10

Ling JJ, Zhou ZH. Causal discovery based neural network ensemble method. *Journal of Software*, 2004, 15(10):1479~1484.

<http://www.jos.org.cn/1000-9825/15/1479.htm>

**Abstract:** Current neural network ensemble methods usually generate accurate and diverse component networks by disturbing the training data, and therefore achieve strong generalization ability. In this paper, causal discovery is employed to discover the ancestor attributes of the class attribute on the results of the sampling process. Then, component neural networks are trained on the samples with only the ancestor attributes being used as inputs. Thus, the mechanism of disturbing the training data and the input attribute is combined to help generate accurate and diverse component networks. Experiments show that the generalization ability of the proposed method is better than or comparable to that of the ensembles generated by some prevailing methods.

**Key words:** neural network ensemble; neural network; ensemble learning; causal discovery; generalization

**摘要:** 现有的神经网络集成方法主要通过扰动训练数据来产生精确且差异度较大的个体网络,从而获得较强的泛化能力.利用因果发现技术,在取样结果中找出类别属性的祖先属性,然后使用仅包含这些属性的数据生成个体网络,从而有效地将扰动训练数据与扰动输入属性结合起来,以产生精确度高且差异度大的个体.实验结果表明,该方法的泛化能力与当前一些流行的集成方法相当或更好.

**关键词:** 神经网络集成;神经网络;集成学习;因果发现;泛化

中图法分类号: TP18 文献标识码: A

神经网络集成<sup>[1]</sup>利用多个神经网络对同一个问题进行学习,集成在某输入示例下的输出由构成集成的各

---

\* Supported by the National Natural Science Foundation of China under Grant No.60273033 (国家自然科学基金); the National Outstanding Youth Foundation of China under Grant No.60325207 (国家杰出青年科学基金); the Natural Science Foundation of Jiangsu Province of China under Grant No.BK2004001 (江苏省自然科学基金); the Fork Ying Tung Education Foundation under Grant No.91067 (霍英东基金); the Excellent Young Teachers Program of the MOE of China (国家教育部优秀青年教师资助计划)

**作者简介:** 凌锦江(1979-),男,江苏苏州人,硕士生,主要研究领域为机器学习,数据挖掘;周志华(1979-),男,博士,教授,博士生导师,主要研究领域为机器学习,数据挖掘,模式识别,信息检索,神经计算,进化计算.

神经网络在该示例下的输出共同决定.该领域的工作可以追溯到 20 世纪 90 年代.1990 年,Hansen 和 Salamon<sup>[2]</sup>证明,可以简单地通过训练多个网络并将其结果进行投票合成,显著提高了神经网络系统的泛化能力.该方法易于使用且效果明显,被视为一种非常有效的学习方法.Krogh 和 Vedelsby<sup>[3]</sup>在 1995 年指出,神经网络集成的泛化误差等于集成中个体网络的平均泛化误差和平均差异度之差.因此,要增强神经网络集成的泛化能力,一方面应尽可能提高个体网络的泛化能力,另一方面应尽可能地增大集成中各网络之间的差异.现在常用的神经网络集成方法都是通过扰动训练数据来获得差异度较大的个体网络,例如,Boosting<sup>[4]</sup>中各网络的训练集决定于之前产生的网络的表现,被已有网络错误判断的示例将以较大的概率出现在新网络的训练集中.Bagging<sup>[5]</sup>的基础是可重复取样(bootstrap sampling),从原始训练集中随机抽取若干示例来训练网络.本文将因果发现技术引入神经网络集成的构建中,将扰动训练数据和扰动输入属性结合起来,以生成精确且差异度大的个体神经网络.实验表明,本文提出的 CNE(causal neural ensemble)方法的泛化能力与著名的 Boosting,Bagging 等方法相当或更好,从而显示出,从多方面引入扰动,将是获取神经网络集成中个体差异度的有效途径.

本文首先介绍因果发现的研究现状,然后提出 CNE 方法,接着给出实验结果,最后对进一步的研究内容进行讨论.

## 1 因果发现

示例的各个属性之间通常有一定的因果关系,例如,长江流域的洪水很可能与太阳的周期活动有关,图模型就是刻画这种属性之间因果关系的得力工具.简单地说,图模型包括两部分内容,即用定性描述属性之间相互关系的结构以及用定量描述该属性与其父亲属性的相关程度的参数.当图中各属性的连线是有向弧并且结构中无环时,该图模型称为 DAG(directed acyclic graph),有时也称为因果模型(causal models).因果模型不仅表示了不同属性之间的因果联系,而且还是进行概率推理的有效工具.

根据属性性质的不同可以将因果模型分为两类:线性因果模型(linear causal model)和贝叶斯网络(Bayesian network).线性因果模型又称为路径模型(path model),最早是 Wright<sup>[6]</sup>为了解决生物和社会科学中的一些问题而设计的,通过在属性集上构造线性函数来表示因果关系,其属性值通常是连续的.贝叶斯网络又称为贝叶斯信念网(Bayesian belief network),通过条件概率表来定量描述属性之间的关系,其属性值通常是离散的.

从训练数据中学习因果模型是近年来一个研究热点.对于这一问题通常可以从两个角度考虑:一是考虑网络结构,可以预先给定,也可以从训练数据中推得;二是考虑网络中的属性和属性值,某些可以从训练数据中直接获得,而某些可能不能直接观察到.

如果网络结构已知,并且所有属性和属性值可以从训练数据中获得,则直接通过计算就可以容易地得到条件概率表.若某些属性存在缺失值,则可用多种方法来近似.Geman 等人<sup>[7]</sup>提出了 Gibbs 取样方法(一种 Monte-Carlo 法),Kass 等人<sup>[8]</sup>采用了高斯近似(Gaussian approximation)方法,Saul<sup>[9]</sup>则采用了由 Dempster 等人<sup>[10]</sup>提出的 EM 算法.对于学习条件概率表中的项,Russell 等人<sup>[11]</sup>提出用梯度上升法可以得到较好的结果.

如果网络结构未知,则构造因果模型是非常困难的事情.因为如果属性的数目是  $n$ ,那么可能的结构数目至少是  $n$  的指数阶<sup>[12]</sup>.在这样巨大的搜索空间寻找出合理的因果模型是十分耗时的,必须通过一些评价标准从中进行挑选.常用的评价标准有 MDL(minimum description length),BIC(Bayesian information criteria)以及 Be(Bayesian likelihood equivalent)等.MDL 和 BIC 的基础都是信息论,其核心都是要构建较短的编码长度.而 Be 尺度适用于参数符合特定分布的情况,其中最著名的有 BDe(Bayesian dirichlet likelihood equivalent)和 BGe(Bayesian Gaussian likelihood equivalent)<sup>[13]</sup>.常用的搜索算法有贪心搜索(greedy search)、模拟退火(simulated annealing)、最好优先搜索(best-first search)等.Heckerman 等人<sup>[14]</sup>在 1995 年指出,若从搜索结果和计算开销综合考虑,贪心搜索是最好的策略.由于贪心搜索通常只能得到局部最优结果,一种解决方案是赋予多个随机初始值<sup>[15]</sup>.

值得一提的是,近年来一些学习因果模型的系统已被开发出来.Cooper 和 Herscovits<sup>[16]</sup>基于 BDe 设计了一个称为 K2 的启发式搜索算法,通过贪心搜索,在给定各属性的初始排序的情况下,成功地从 3 000 个训练样例中创建出了与正确网络结构几乎一样的贝叶斯网络.同年,Thomas,Spiegelhalter 和 Gilks<sup>[17]</sup>开发了 Bugs 系统,将

Gibbs 取样用于学习问题.不久,Badsberg<sup>[18]</sup>和 Højsgaard 等人<sup>[19]</sup>开发出了可以通过多种评价标准学习得到混合图模型的系统.Scheines 等人<sup>[20]</sup>开发出了基于条件独立的因果发现系统 TETRAD II.通过贪心搜索学习线性因果模型的系统也在近几年被开发出来<sup>[21]</sup>.

## 2 CNE 算法

假设训练集  $S$  由属性  $A_1, A_2, \dots, A_n$  组成,其中  $A_1, A_2, \dots, A_{n-1}$  为输入属性,而  $A_n$  为类别属性.通常方法使用所有的输入属性来训练个体网络,即希望建立从  $A_1 \times A_2 \times \dots \times A_{n-1}$  到  $A_n$  的映射.实际上,某些输入属性在对未知数据进行预测分类时可能是无用的.从因果模型的角度来说,类别属性在给定其祖先属性时是条件独立于其他属性的.举例来说,在如图 1 所示的因果模型中,类别属性  $A_8$  依赖于其祖先属性  $A_1, A_2, A_3, A_4$ ,而条件独立于  $A_5, A_6, A_7$ .




Fig.1 An example of causal model

图 1 因果模型的例子

在寻找类别属性的祖先属性方面,可以通过构造属性集上的可达矩阵  $P$  获得.为方便起见,用  $D$  表示 DAG 矩阵,其中元素  $d_{ij}(1 \leq i, j \leq n)$  定义如下:

$$d_{ij} = \begin{cases} 1, & \text{若 } A_i \text{ 有弧射向 } A_j \\ 0, & \text{否则} \end{cases}$$

这样, $D$  的  $l(l \geq 1)$  次幂中的元素  $d_{ij}^{(l)}$  表示属性集中  $A_i \sim A_j$  长度为  $l$  的通路数,而  $\sum_{i=1}^n \sum_{j=1}^n d_{ij}^{(l)}$  为图中长度为  $l$  的通路总数.又定义:

$$B_l = D + D^2 + \dots + D^l (l \geq 1),$$

则  $B_l$  中元素  $b_{ij}^{(l)}$  为属性集中  $A_i \sim A_j$  长度小于或等于  $l$  的通路数,而  $\sum_{i=1}^n \sum_{j=1}^n b_{ij}^{(l)}$  为图中长度小于或等于  $l$  的通路数.由于 DAG 中不存在环,因此路径长度最多为  $n-1$ ,于是只要计算出  $B_{n-1}$ ,由  $B_{n-1}$  中的元素  $b_{ij}^{(n-1)}(i, j = 1, 2, \dots, n \text{ 且 } i \neq j)$  是否为 0 就可以写出可达矩阵  $P$ ,然后再判断  $A_1 \sim A_{n-1}$  是否为  $A_n$  的祖先属性.

在构建神经网络集成时,可通过可重复取样获得多个训练集.由于可重复取样会改变数据分布,因此即使在原数据集中是类别属性的祖先属性,在新训练集中也可能变得不再是类别属性的祖先.所以,对个体网络仅用在训练集上发现的类别属性的祖先属性作为输入可能效果更好.这样,不同的个体网络可能使用了不同的输入神经元,其差异度会显著增加,而且由于不使用的属性均为在新训练集上对类别属性不起决定作用的属性,因此这样做不会损失个体网络的泛化能力.

CNE 的具体做法如下:给定训练集  $S$ ,通过可重复取样获得一系列子训练集  $S_1, S_2, \dots, S_T$ ,然后在各个子训练集上生成因果模型  $CM_1, CM_2, \dots, CM_T$ ,在每个因果模型中寻找出类别属性的祖先属性,用这些祖先属性作为输入神经元训练出个体网络,然后通过投票法进行集成.CNE 算法伪码描述如下:

Input: training set  $S$ , neural network algorithm  $N$ , trials  $T$

Output: neural network ensemble  $N^*$

Process:

for  $i=1$  to  $T$ {

$S_i$ =bootstrap sample from  $S$

```


$$CM_i = \text{CausalDisc}(S_i) \quad /*discover\ causal\ model\ from\ S_i$$


$$N_i = N(S_i, CM_i) \quad /*train\ a\ neural\ classifier\ using\ the\ ancestor\ attributes\ of\ the\ class\ attribute$$


$$N^*(x) = \arg \max_{y \in Y} \sum_{i: N_i(x)=y} 1$$


```

### 3 实验测试

本文将 CNE 算法、Bagging 算法和 Boosting 算法(本文使用的是 Adaboost 算法<sup>[22]</sup>)进行了比较.在生成因果模型的 DAG 图时用的是 Murphy 在 2001 年开发出的 BNT 包<sup>[23]</sup>.该包专为图模型设计,用 Matlab 实现,支持确切推理和近似推理、参数学习和结构学习,可用于静态和动态模型.在结构学习方面,本文采用的是基于 MDL 的贪心搜索法.由于该软件包只能处理离散属性,所以遇到连续属性时需将其离散化.但在产生了 DAG 图之后,可将连续属性恢复,从而在训练神经网络时使用原始值.每个神经网络集成均包含 10 个单隐层 BP 神经网络<sup>[24]</sup>,其隐层神经元数均设为 5.需要注意的是,由于本文关注的是 CNE 与其他神经网络的集成方法的相对优劣,因此,本文没有对个体神经网络的结构和训练过程进行优化.

实验数据 Balance, Diabetes, House-votes-84 以及 Vote 都来自著名的 UCI 的机器学习数据库<sup>[25]</sup>,有关信息见表 1.

Table 1 Details of experimental data

表 1 实验数据有关信息

| Data set       | # Instances | Discrete attributes | Continuous attributes | Classes |
|----------------|-------------|---------------------|-----------------------|---------|
| Balance        | 625         | 4                   | 0                     | 3       |
| Diabetes       | 768         | 0                   | 8                     | 2       |
| House-votes-84 | 232         | 16                  | 0                     | 2       |
| Vote           | 435         | 16                  | 0                     | 2       |

为了得到准确的测试结果,本文在每个数据集上使用 10 倍交叉验证方法,将原始数据集划分为相近大小以及相近分布的 10 个子数据集,在每轮实验中用 1 个子数据集作为测试集而其余 9 份子数据集的合集作为训练集,轮转一遍,共进行 10 次实验,并记录平均值.实验结果见表 2.为了进行比较,表 2 中还记录了单一 BP 神经网络的测试结果.

Table 2 Comparison of testing error

表 2 测试误差比较

|                | Single (%) | Boosting (%) | Bagging (%) | CNE (%) |
|----------------|------------|--------------|-------------|---------|
| Balance        | 9.09       | 8.30         | 8.61        | 8.94    |
| Diabetes       | 27.10      | 25.92        | 25.27       | 25.14   |
| House-votes-84 | 7.42       | 6.10         | 4.79        | 3.52    |
| Vote           | 7.61       | 6.89         | 6.43        | 5.97    |

从表 2 可以看出,CNE 的泛化能力在 4 个数据集上均显著优于单一神经网络.在 Diabetes, House-votes-84 以及 Vote 这 3 个数据集上分类效果都显著优于 Bagging 和 Boosting.特别是在 House-votes-84 上,CNE 的误差比 Bagging 减少了 26.5% $((4.79\% - 3.52\%) / 4.79\% = 26.5\%)$ ,比 Boosting 减少了 42.3% $((6.10\% - 3.52\%) / 6.10\% = 42.3\%)$ ;在 Vote 上,CNE 的误差比 Bagging 减少了 7.3% $((6.43\% - 5.97\%) / 6.43\% = 7.3\%)$ ,比 Boosting 减少了 13.4% $((6.89\% - 5.97\%) / 6.89\% = 13.4\%)$ .在 Balance 上,Bagging 和 Boosting 优于 CNE,这可能是因为该数据集属性较少,因此对属性的扰动作用不大,但 CNE 仍然显著优于单一神经网络.总的来说,CNE 的泛化能力与 Bagging 和 Boosting 方法相当或者优于这两种方法.

### 4 结束语

本文提出的 CNE 方法通过扰动训练数据和扰动属性这两方面来获得差异度较大的个体,从而提高神经网络集成的泛化能力.在扰动训练数据方面,采用可重复取样方法;在扰动输入属性方面,采用因果发现技术.实验结果表明,CNE 的泛化能力与常用的 Bagging 和 Boosting 方法相当或者优于这两种方法.进一步的工作主要包

括如何从输出表示、内部结构等更多方面进行扰动以获取泛化能力强且差异度大的个体,从而进一步提高神经网络集成的泛化能力。

值得一提的是,最近,Dai<sup>[26]</sup>等人将集成学习技术引入线性因果发现领域,获得了比以往最佳方法更好的结果.而本文工作则是将因果发现技术引入集成学习中,也取得了较好的效果.这在一定程度上说明,将集成学习与因果发现技术进行适当的结合,是一个值得进一步研究的方向。

## References:

- [1] Zhou ZH, Chen SF. Neural network ensemble. *Chinese Journal of Computers*, 2002,25(1):1~8 (in Chinese with English abstract).
- [2] Hansen LK, Salamon P. Neural network ensembles. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1990,12(10): 993~1001.
- [3] Krogh A, Vedelsby J. Neural network ensembles, cross validation, and active learning. In: Tesauro D, Touretzky D, Leen T, eds. *Advances in Neural Information Processing Systems 7*. Cambridge: MIT Press, 1995. 231~238.
- [4] Schapire RE. The strength of weak learnability. *Machine Learning*, 1990,5(2):197~227.
- [5] Breiman L. Bagging predictors. *Machine Learning*, 1996,24(2):123~140.
- [6] Wright S. Correlation and causation. *Journal of Agricultural Research*, 1921,20:557~585.
- [7] Geman S, Geman D. Stochastic relaxation, gibbs distribution and the bayesian restoration of images. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1984,6(6):721~741.
- [8] Kass R, Tierney L, Kadane J. Asymptotics in bayesian computation. In: Bernardo J, DeGroot M, Lindley D, Smith A, eds. *Bayesian Statistics 3*. Oxford: Oxford University Press, 1988. 261~278.
- [9] Saul LK, Jaakkola TS, Jordan MI. Mean field theory for sigmoid belief networks. *Journal of Artificial Intelligence Research*, 1996, 4:61~76.
- [10] Dempster AP, Laird NM, Rubin DB. Maximum likelihood from incomplete data via the EM algorithm. *Journal of Royal Statistical Society*, 1977,39(1):1~38.
- [11] Russell S, Norvig P. *Artificial Intelligence: An Modern Approach*. Englewood Cliffs: Prentice-Hall, 1995.
- [12] Robinson RW. Counting unlabeled acyclic digraphs. In: Little CHC, ed. *Lecture Notes in Mathematics 622*. Berlin: Springer-Verlag, 1977. 28~43.
- [13] Heckerman D, Geiger D. Learning Bayesian networks. Technical Report, MSR-TR-95-02, Microsoft Research Advanced Technology Division, 1995.
- [14] Heckerman D, Geiger D, Chichering M. Learning Bayesian networks: The combination of knowledge and statistical data. *Machine Learning*, 1995,20(3):197~234.
- [15] Chickering M. Learning equivalence classes of bayesian networks structures. In: Horvitz E, Jensen F, eds. *Proc. of the 12th Conf. on Uncertainty in Artificial Intelligence*. Portland, OR, 1996. 150~157.
- [16] Cooper G, Herskovits E. A Bayesian method for the induction of probabilistic networks from data. *Machine Learning*, 1992,9(4): 309~347.
- [17] Thomas A, Spiegelhalter D, Gilks W. Bugs: A program to perform Bayesian inference using gibbs sampling. In: Bernardo J, Berger J, Dawid A, Smith A, eds. *Bayesian Statistics 4*. Oxford: Oxford University Press, 1992. 837~842.
- [18] Badsberg J. Model search in contingency tables by CoCo. In: Dodge Y, Whittaker J, eds. *Computational Statistics*. Heidelberg: Physica Verlag, 1992. 251~256.
- [19] Højsgaard S, Skjøth F, Thiesson B. User's guide to BIOFROST. Technical Report, Aalborg: Department of Mathematics and Computer Science, 1994.
- [20] Scheines R, Spirtes P, Glymour C, Meek C. *Tetrad II: Tools for causal modeling*. Hillsdale: Lawrence Erlbaum Associates, 1994.
- [21] Wallace C, Korb K, Dai H. Causal discovery via MML. In: Saitta L, ed. *Proc. of the 13th Int'l Conf. on Machine Learning*. 1996. 516~524.
- [22] Freund Y, Schapire R. Experiments with a new boosting algorithm. In: Saitta L, ed. *Proc. of the 13th Int'l Conf. on Machine Learning*. 1996. 148~156.
- [23] Murphy K. The bayes net toolbox for Matlab. *Computing Science and Statistics*, 2001,33:331~351.

- [24] Rumelhart D, Hinton G, Williams R. Learning representations by backpropagating errors. *Nature*, 1986,323(9):533~536.
- [25] Blake C, Keogh E, Merz C. UCI repository of machine learning data bases. Department of Information and Computer Science, University of California, 1998. <http://www.ics.uci.edu/~mllearn/MLrepository.html>
- [26] Dai H, Li G, Zhou ZH. Ensembling MML causal discovery. In: Dai H, Srikant R, Zhang C, eds. *Lecture Notes in Artificial Intelligence* 3056. Berlin: Springer-Verlag, 2004. 260~271.

#### 附中文参考文献:

- [1] 周志华,陈世福.神经网络集成.计算机学报,2002,25(1):1~8.

## 《软件学报》投稿指南

一、《软件学报》是中国科学院软件研究所和中国计算机学会联合主办的学术性期刊,创刊于1990年.主要报道计算机软件各领域的研究成果;尤其注重刊登能反映计算机软件发展方向的综述性文章,具有创造性的研究报告和研究简报,软件新理论、新方法和新技术介绍.欢迎踊跃投稿.

二、本刊刊登的内容主要包括(但不限于):理论计算机科学、算法设计与分析、系统软件与软件工程、模式识别与人工智能、数据库技术、计算机网络、信息安全、计算机图形学与计算机辅助设计、多媒体技术及其他与计算机软件领域相关的内容等.

### 三、投稿要求和注意事项

1. 来稿要求论点明确,数据可靠,论证合理,层次分明,文字精炼.

2. 各类文稿具体要求如下:

学术论文:具有重大创新,有新的观点和见解,可推动或丰富该课题领域的研究与发展.

综述:针对计算机科学技术的活跃领域,对国内外发展状况及趋势的全面、系统的综合评述.

短文:有创造性的见解,但不要求是全部完整的工作.

技术报告:具有重大的实用、推广价值,技术上先进、内容完整的研究报告.

简报:技术上先进,对具有一定实用或推广价值的研究成果(包括阶段性成果)的扼要报道.

通讯:有关本刊已发表文章的问题讨论或简短表达的新思想以及对学科发展的建议等.

要求以上各类文稿应与国内外同类工作进行详细讨论和比较.在参考文献方面应查新、查全并明确标引,以利于审稿人在审稿过程中清楚地判断作者所做工作的创新程度.

3. 本刊特别要求作者保证投稿文章的合法性(无抄袭、剽窃、侵权等不良行为).如发现有上述不良行为者,本刊会据实将其行为通知其所在单位的最高领导层,并不再接受第一作者的投稿等.

4. 本刊不接受任何语种的翻译稿.来稿未在正式出版物上发表过,且不存在一稿多投现象.

### 5. 稿件写作要求

(1) 排版格式请参考网站上提供的写作模板和近期《软件学报》.(2) 来稿做到清稿定稿.文中插图精绘,图中文字清楚,应有图序、图题和图注.(3) 参考文献部分,作者应将对自己的工作有所启发、帮助和教益的国内外文献列出,以示对同行工作的尊重和补充.所列文献顺序应以在文中出现的先后为序,著录项目应全面,也请参考近期《软件学报》.

### 6. 作者须知

(1) 为联系顺畅,请另纸提供联系人的通讯地址、邮编、E-mail地址和联系电话.审稿期间若有变更,请及时通知编辑部.(2) 在我刊网站上列举了我们在审稿过程中经常遇到的一些问题,建议作者在投稿之前,阅读网站上“投稿指南”一栏.(3) 作者自收到正式收稿通知之日起,6个月之后无消息,在通知编辑部并得到编辑部确认信之后,可自行处理.(4) 作者可通过网站上提供的“稿件处理流程”了解我刊处理稿件的程序和大致时间进度.(5) 投稿之后,请登录到本刊网站,在“投稿查询”一栏中查询稿件处理状况.(6) 对于本刊不拟刊登的稿件,将有相应的审查意见返回给作者.原稿不退还,请自留底稿.(7) 录用稿件将按投稿时间排序安排发表.稿件一经刊发,将酌致稿酬(所付稿酬包括印刷版、光盘版和网络版稿酬),并赠送样刊及单行本.

### 7. 投稿方法

(1) 欢迎作者选择网站上提供的“在线投稿”方式.投稿方法及注意事项如下:(a) 登录到我刊的网址<http://www.jos.org.cn>,通过“在线投稿”一栏进行投稿;(b) 稿件请用Word软件编辑排版;(c) 当文件过大时,在上传稿件之前请进行压缩;(d) 在传送稿件之前,请务必检查文件是否染有病毒,如有病毒,本刊将拒绝接受投稿;(e) 同一篇稿件请不要反复传送;(f) 在收到网上投稿之后,编辑部会立即反馈给作者一个收稿信息.

(2) 若选择邮寄方式投稿,需邮寄打印稿一式3份,同时另纸提供详细联系方式.

通讯地址:100080 北京 8718 信箱 中科院软件所 《软件学报》编辑部

联系电话:(010)62562563

E-mail: [jos@iscas.ac.cn](mailto:jos@iscas.ac.cn)

<http://www.jos.org.cn>