

粗神经网络及其在交通流预测中的应用

杨立才, 贾磊

(山东大学控制学院, 山东 济南 250061)

摘要: 实时准确的交通流量预测是实现智能交通诱导及控制的前提与关键, 也是智能化交通管理的客观需要。把粗集理论引入神经网络的构造, 应用粗神经元取代部分常规神经元, 给出了一种交通流量的粗神经网络预测模型。实验结果表明, 该模型在交通流量预测的精度和对交通路网的适应性方面明显优于常规神经网络, 具有较高的实用价值。粗神经网络具有极强的鲁棒性, 预测模型也可方便地处理季节、天气等随机因素对交通流量预测结果的影响。

关键词: 交通流预测; 粗神经网络; 智能交通系统

中图分类号: U491.14

文献标识码: A

Rough Neural Network and Its Application in Traffic Flow Forecast

YANG Li-cai, JIA Lei

(School of Control Science & Engineering, Shandong University, Shandong Jinan 250061, China)

Abstract: Real-time and accurate traffic flow forecast is very important to the intelligent traffic guidance, control and management. Combining together rough sets and neural network formation and replacing some traditional neural cells with rough neural cells, a traffic flow forecast model based on rough neural network concept is given in this paper. The experiment results show that this model is superior to the models constructed with traditional neural cells in terms of forecast precision and adaptability to the traffic road networks. The rough neural network is robust to the uncertain factors such as seasons and weather in traffic flow forecast and the model is of academic and practical value in forecasting applications.

Key words: Traffic flow forecasting; Rough neural network; Intelligent Transportation Systems (ITS)

0 引言

智能交通系统 ITS (Intelligent Transportation Systems) 是全方位解决交通运输安全和交通拥挤的有效手段, 交通诱导和交通控制是智能交通系统的重要组成部分, 实时准确的交通流量预测是实现交通诱导及控制的前提与关键, 也是智能化交通管理的客观需要。由于道路交通系统是一个有人参与的时变复杂大系统, 交通流的运行存在高度的复杂性、随机性和不确定性, 卡尔曼滤波、MA、ARIMA 等传统的预测模型已不能满足实践中越来越高的预测精度要求^[1]。人工神经网络具有极强的非线性映射能力, 在信息预测领域得到了广泛的应用。近年来, 一些学者把人工神

经网络引入交通流的预测, 取得了一定的成功^[2~5]。但是常规神经网络存在实时性差、寻优速度慢、交通流的预测结果对路网的依赖性强等不足之处。本文把粗集理论应用于人工神经网络的构造, 基于粗神经元的概念, 给出了一种交通流量的粗神经网络预测模型。

2 粗神经网络

2.1 粗集的基本概念

波兰学者 Pawlak Z 提出的粗集理论^[6,7], 是一种刻划不完整性和不确定性的数学工具, 能有效地分析和处理不精确、不一致、不完整等各种不完备信息, 从中发现隐含的知识, 揭示潜在的规律。

收稿日期: 2003-08-07

作者简介: 杨立才 (1962-), 男, 山东莘县人, 博士生, 副教授, 主要研究方向为智能交通系统、复杂系统理论与应用、粗集理论及应用。
(yanglc@sdu.edu.cn)

粗集理论是基于这样的假设：每个研究的对象都具有一定的属性，如果一些对象可以由同样的属性来表征，就说这些对象彼此之间是等价的或不可分辨的，而这种不可分辨关系是粗集理论的基石。基于不可分辨关系可以建立粗集的基本概念。用数学语言描述如下。

设等价关系 R 将论域 U 划分为互不相交的基本等价类，二元组 $K = (U, R)$ 就构成一个近似空间。设 X 为 U 的一个子集， x 为 U 中的一个对象， $[x]_R$ 表示所有与 x 不可分辨的对象组成的集合，即由 x 决定的等价类。如果集合 X 能表示成基本等价类组成的并集，则称集合 X 是可以精确定义的；否则，集合 X 只能通过逼近的方式来刻画。集合 X 关于 R 的下逼近 $R_*(X)$ 与上逼近 $R^*(X)$ 定义为

$$R_*(X) = \{x \in U \mid [x]_R \subseteq X\} \quad (1)$$

$$R^*(X) = \{x \in U \mid [x]_R \cap X \neq \emptyset\} \quad (2)$$

下逼近 $R_*(X)$ 是由那些根据已有知识判断肯定属于 X 的对象所组成的最大的集合，也称为 X 的正区，记作 $POS(X)$ ；由根据已有知识判断肯定不属于 X 的对象组成的集合称为 X 的负区，记作 $NEG(X)$ ；上逼近 $R^*(X)$ 是由所有与 X 相交非空的等价类 $[x]_R$ 的并集，是那些可能属于 X 的对象组成的最小集合。

集合 X 的边界区定义为 X 的上逼近与下逼近之差，即

$$BN(X) = R^*(X) - R_*(X) \quad (3)$$

如果 $BN(X)$ 是空集，则称 X 关于 R 是清晰的；反之如果 $BN(X)$ 是非空集，则称集合 X 为关于 R 的粗集或粗糙集。

集合 X 的粗糙度可由下式度量

$$u_R(X) = \frac{card [R^*(X)]}{card [R_*(X)]} \quad (4)$$

2.2 粗神经元模型

基于粗集理论的集和近似概念建立的粗神经元可看作由两个存在重叠的常规神经元组成^[8,9]，如图1所示。 R^* 和 R_* 分别称作粗神经元 R 的上神经元和下神经元，重叠部分代表两者之间的信息交换。概念上，上、下神经元分别对应于粗集的上逼近和下逼近，描述研究对象或变量的上界和下界。

图1给出了2个粗神经元之间的3种可能联接形式及粗神经元与常规神经元的联接。图1(a)中的2个粗神经元有4个基本联接，称为粗神经元之间的全联接；图1(b)和图1(c)中的2个粗神经元各有2个基本联接，称为粗神经元之间的部分联接；图1

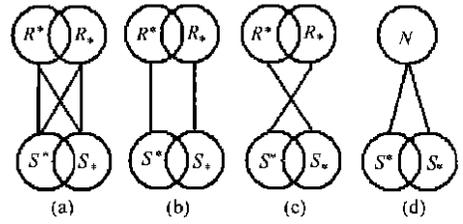


图1 粗神经元的联接方式

(d) 为粗神经元与常规神经元的联接方式。

图1(b)表示粗神经元 S 对粗神经元 R 产生激励作用，即神经元 S 的输出增大引起神经元 R 的输出增大；图1(c)表示粗神经元 S 对粗神经元 R 产生抑制作用，即神经元 S 的输出增大引起神经元 R 的输出减小。图1(a)表示粗神经元 S 对粗神经元 R 同时产生激励和抑制作用。对于部分联接的神经元，其兴奋或抑制特性由神经元之间的联接权动态决定。网络的初始状态则可以假设为抑制型或兴奋型。假设粗神经元 S 与粗神经元 R 初始为抑制型的部分联接，而且 S^* 与 R_* 的初始联接权、 S_* 与 R^* 的初始联接权均大于零，则当 S^* 与 R_* 的联接权等于 S^* 与 R^* 的联接权，同时 S_* 与 R^* 的联接权等于 S_* 与 R_* 的联接权时， S 对 R 的抑制就转化为激励；同理，假设粗神经元 S 与粗神经元 R 初始为激励型的部分联接，而且 S^* 与 R^* 的初始联接权、 S_* 与 R_* 的初始联接权均小于零，则当 S^* 与 R^* 的联接权等于 S^* 与 R_* 的联接权，同时 S_* 与 R_* 的联接权等于 S_* 与 R^* 的联接权时， S 对 R 的激励就转化为抑制。

粗神经元的输入、输出有上神经元和下神经元之分。

上神经元、下神经元的输入根据公式(5)计算

$$input_i = \sum w_{ji} \times output_j \quad (5)$$

式中， w_{ji} 为第 j 号神经元(粗神经元或常规神经元)与第 i 号上神经元或下神经元之间的联接权值； $output_j$ 为第 j 号神经元(粗神经元或常规神经元)的输出。

显然，粗神经网络中，粗神经元的输入计算与常规神经元相同。

上神经元、下神经元的输出根据公式(6)和(7)计算

$$output_{R^*} = \max \{f(input_{R^*}), f(input_{R_*})\} \quad (6)$$

$$output_{R_*} = \min \{f(input_{R^*}), f(input_{R_*})\} \quad (7)$$

式中， $f(\cdot)$ 为神经元的激发函数，一般取为 sigmoid 型函数，即

$$f(x) = \frac{1}{1 + \exp(-x/\alpha)} \quad (8)$$

式中, α 为激发函数的调整因子。

公式 (6) 和 (7) 表明: 上神经元的输出为上神经元和下神经元输出的最大值, 下神经元的输出为上神经元和下神经元输出的最小值。如果上神经元和下神经元完全重叠, 上述两式合而为一, 即为常规神经元输出的计算公式。

如果研究的对象或变量在一定范围内变化, 上、下神经元即对应于变量变化的上限和下限。如果研究的变量为确定值, 对应的上、下神经元将完全重叠, 粗神经元即退化为常规神经元。因此, 粗神经元是常规神经元的推广, 常规神经元是粗神经元的特例。应用粗神经元描述参数存在波动的变量, 可以避免具有重要性质数据的泛化, 提高神经网络的预测精度。

2.3 粗神经网络的结构及学习算法

粗神经网络由常规神经元和粗神经元相互连接构成, 神经元的连接形式及神经网络的结构取决于网络的应用场合。

粗神经网络由一个输入层、一个或多个隐含层和一个输出层构成。输入层神经元接受外界的信息输入, 隐含层神经元把输入信息映射到输出层并由输出层神经元输出至外界, 输入和输出之间通过转移函数联接。输入、输出层神经元的个数等于网络输入、输出量的维数, 隐含层神经元的个数可通过网络优化给出。网络一般采用输入层和隐层之间、隐层和输出层之间的全联接方式。用于模式识别、预测或趋势产生时, 输入层和隐含层的神经元可以部分或全部为粗神经元, 输出层一般只含常规神经元。

图2为具有一个隐含层的BP粗神经网络的结构示意图。网络的常规神经元对应于确定性变量, 如某时刻的平均交通流量; 粗神经元描述不确定性变量或变量的波动情况, 在交通流预测系统中可以描述交通事故、天气等因素引起的交通流量的波动。

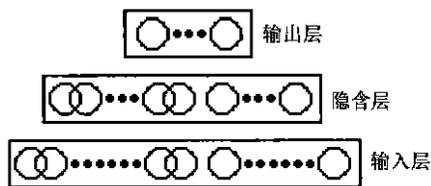


图2 粗神经网络的典型构成

粗神经网络的训练和测试过程类似于常规神经网络, 但由于其结构比常规网络相对复杂, 为减少计算量, 需特别注意学习算法的选择。

BP粗神经网络的学习算法简述如下:

(1) 神经网络初始化, 粗神经元按2.2节的方法处理。

(2) 提供训练集, 给定输入向量和期望的目标输出。

(3) 计算各层神经元的状态。常规神经元、粗神经元中上、下神经元的输入根据公式(5)计算; 上神经元、下神经元的输出根据公式(6)和(7)计算; 常规神经元的输出根据公式(9)计算

$$output_j = f(input_j) \quad (9)$$

(4) 计算目标值与实际输出的偏差。

(5) 判断系统误差是否小于控制量, 如果为真, 结束学习; 否则计算权系数的调整量。

(6) 修正输入层和隐含层之间、隐含层和输出层之间的联接权值, 转(3)继续学习。这里, 算法的目标评价函数为

$$E = \frac{1}{2} \sum_{k=1}^p (d_k - y_k)^2 \quad (10)$$

式中, d_k 、 y_k 分别为第 k 个样本点的期望输出和实际输出。

针对基本BP算法收敛速度慢和易陷入局部最小点等问题, 采用了自适应学习率和动量法加以解决。前者根据误差的变化趋势调整学习率; 后者在原有权值修正公式的基础上, 增加一个动量项, 利用权值修改的惯性避免收敛于局部最小点。

3 交通流量预测模型与实例分析

3.1 预测模型的实现

本文利用粗神经网络对城市交通路网中的路段交通流进行实时预测。研究表明, 交通路段上某时刻的交通流量与本路段前几个时段的交通流量有关, 并受其上下游路段交通状况的影响。因此, 可以利用预测路段前几个时段与其上下游路段前几个时段的交通流数据预测特定路段的交通流量。但是, 由于不同道路交通状况存在差异, 所以不能简单地选取相关路段前几个连续时段的交通流作为神经网络输入, 为提高预测精确度, 在交通流预测中, 需要对不同路段、不同时段的交通数据进行相关性分析, 选择与预测路段相关性强的不同路段、不同时段的交通流信息作为神经网络的输入。

交通流预测模型采用3层BP网络结构。网络输入层由常规神经元构成, 神经元的个数对应于输入变量的维数, 经交通数据的相关性分析决定; 输出层为一个常规神经元, 对应于预测的交通流量; 隐含层由粗神经元构成, 粗神经元的个数经网络优化分析确定。网络输入层与隐含层之间、隐含层与输出层之间均为全联接。神经元之间的联接形式如图1所示, 神

经元之间的联接权值由测量数据经训练得到。

网络的预测精度用交通流量的预测值与实际值的平均相对误差度量, 定义如下

$$MRERR = \frac{1}{N} \sum_t \frac{|V_f(t) - V(t)|}{V(t)} \quad (11)$$

其中, $V_f(t)$ 和 $V(t)$ 分别为交通流量的预测值和实际值; N 为数据个数。

3.2 实例分析

济南市经十路是一条重要的东西交通主干道。作者基于“城市交通智能控制技术研究”课题的需要, 建立了经十路交通流测量数据库, 从中取出连续3个路段的2周12h交通流测量数据组, 用于仿真实验。交通流量数据是每15min一组, 共有672个纪录, 从中随即抽取600个记录用于训练, 余下72个记录用于验证预测模型。

本文对经十路舜耕路口至千佛山路口的路段进行了交通流预测研究。通过测量数据的相关性分析, 该路段在 $(t + \tau)$ 时段的预测流量可表示为

$$V(t + \tau) = F\{V(t), V(t - \tau), V(t - 2\tau), V_U(t - \tau), V_U(t - 2\tau), V_D(t - 2\tau)\} \quad (12)$$

式中, F 表示一种非线性函数关系; τ 为一个计时时段, 此处为15min; V_U 、 V_D 分别为上、下游路段的交通流量。

利用粗神经网络拟合上述非线性函数关系, 对路段交通流实时预测。网络输入层为6个常规神经元, 对应于式(12)右侧的各历史交通数据; 经过优化分析, 采用8个粗神经元构成网络的隐含层。交通流预测模型为6-8-1的3层BP网络结构。

用2.3节的方法训练网络。经训练的粗神经网络对路段交通流预测的结果如图3所示。为便于比较, 图4给出了同样结构的常规神经网络的预测结果。两种网络的交通流量预测值与实际值的平均相对误差分别为5.48%和9.41%。结果表明, 粗神经网络的预测精度明显好于常规神经网络。作者采用同样的模型对经十路其它路段的交通流量进行了预测仿真, 表明粗神经网络对路网的适应性也好于常规神经网络。

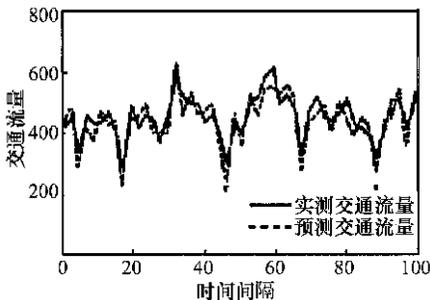


图3 粗神经网络预测结果

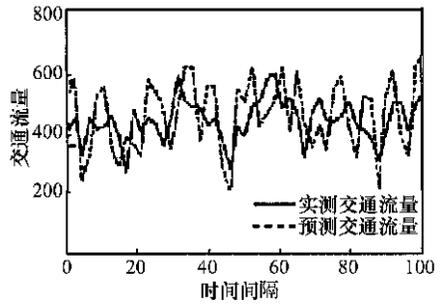


图4 常规神经网络预测结果

4 结语

本文把粗集理论引入神经网络的构造, 应用粗神经元取代部分常规神经元, 建立了一种交通流量的粗神经网络预测模型。实验结果表明, 该模型在交通流预测的精度和对交通流预测的适应性方面明显优于常规神经网络, 具有较高的实用价值。交通流量随季节、天气、节假日等众多因素的变化而波动, 具有较大的随机性。粗神经网络具有极强的鲁棒性, 可方便地处理交通流的波动对预测结果的影响。进一步的工作是研究各种随机因素对交通流预测的影响, 建立更加高效的粗神经网络预测模型。

参考文献:

- [1] Smith B L, Demetsky M J. Traffic Flow Forecasting: Comparison of Modeling Approaches [J]. J. of Transportation Engineering, 1997, 123 (4): 262-266.
- [2] Long Chen, Fei-yue Wang. A Neuro-fuzzy System Approach for Forecasting Short Term Freeway Traffic Flows [C]. Proc of the IEEE 5th International Conference on Intelligent Transportation Systems, 2002: 451-471.
- [3] 朱中, 杨兆升. 实时交通量人工神经网络预测模型 [J]. 中国公路学报, 1998, 11 (4): 89-92.
- [4] 杨兆升, 谷远利. 实时动态交通流预测模型研究 [J]. 公路交通科技, 1998, 15 (3): 4-7.
- [5] 裴玉龙, 张宇. 城市道路网结点短时段交通量预测模型研究 [J]. 土木工程学报, 2003, 36 (1): 11-15.
- [6] Pawlak Z. Rough Sets [J]. International Journal of Information and Computer Sciences, 1982, 11 (5): 341-356.
- [7] Pawlak Z. Rough Set Theory for Intelligent Industrial Applications [C]. Honolulu: Proc of the Second International Conference on Intelligent Processing and Manufacturing of Materials, 1999: 37-44.
- [8] 王玮, 蔡莲红. 基于粗集理论的神经网络 [J]. 计算机工程, 2001, 27 (5): 65-67.
- [9] Hassan Y, Tazaki E, Egawa S. Rough Neural Classifier System [C]. Yokohama: Proc of the IEEE Conference on Systems, Man and Cybernetics, 2002, 1-6.