

Elman 神经网络在 ECT 系统流型辨识中的应用

宋 蕾, 陈德运, 姚玉梅, 林甲楠, 王莉莉

(哈尔滨理工大学 计算机科学与技术学院, 黑龙江 哈尔滨 150080)

摘 要: 针对电容层析成像系统 ECT (electrical capacitance tomography) 流型辨识问题, 在对 ECT 系统工作原理和流型的辨识方法分析的基础上, 提出了一种基于 Elman 神经网络的 ECT 系统流型辨识方法, 该方法通过对 ECT 系统采集的电容值特征值提取与处理, 将提取的特征值作为 Elman 神经网络的输入进行训练, 经训练后达到流型辨识的目的. 经仿真实验验证, 与传统的 BP 神经网络相比, 该方法具有结构简单, 收敛速度快, 不会因阶次未知而出现网络结构膨胀的问题, 为 ECT 系统流型辨识的提供一种的有效方法.

关键词: 电容层析成像; 流型辨识; Elman 神经网络; 收敛速度

中图分类号: TP216 **文献标志码:** A **文章编号:** 1007-2683(2014)05-0103-06

Application of Elman Neural Network in Pattern Identification for Electrical Capacitance Tomography

SONG Lei, CHEN De-yun, YAO Yu-mei, LIN Jia-nan, WANG Li-li

(School of Computer Science and Technology, Harbin University of Science and Technology, Harbin 150080, China)

Abstract: To solve the problem of electrical capacitance tomography (ECT) system of flow regime identification, this paper presents a new method based on Elman neural network for ECT system of flow pattern identification, which is on the basis of the work principle of ECT system and the method of flow pattern identification. This method uses part of capacitance to extract its feature, and uses the extracted data to train the Elman neural network to achieve the aim of recognize the type of the flow. After simulation, the result shows that this method is better than BP neural network. This method has a simple structure and a fast convergence speed, at the same time; it does not have the network expansion problem of the unknown order. It is an effective method for ECT system of flow pattern identification.

Key words: electrical capacitance tomography; flow regime identification; Elman neural network; convergence speed

收稿日期: 2014-03-27

基金项目: 国家自然科学基金(60572153, 60972127); 高等学校博士学科点专项科研基金(200802140001); 黑龙江省自然科学基金(QC2012C059); 黑龙江省教育厅计划项目(11541040, 12511097).

作者简介: 宋 蕾(1989—), 女, 硕士研究生;

陈德运(1962—), 男, 教授, 博士研究生导师; E-mail: chengdeyun@hrbust.edu.cn.

姚玉梅(1989—), 女, 硕士研究生.

0 引言

两相流系统广泛存在工业生产中,因此两相流的实时监测在工业生产中是及其重要,而流型识别是实现两相流检测的重要组成部分^[1]. 电容层析成像技术是近年来发展起来的一种过程成像技术. 因其具有结构件点,响应速度快,非侵入性和成本低等优点,被广泛应用在多相流检测识别中^[2-3].

两相流型识别方法主要有两种,一是直接根据重建流型图像来判别流型,二是间接根据反应两相流流型的信号进行识别. 方法二的优点是快速,省去了重建图像的环节^[4]. 在现有的间接判别法,神经网络得到了广泛的应用,而特征值提取是神经网络进行识别的第一步. 特征值的数量和辨识度直接关系到神经网络的识别率^[5-6]. 在现有的针对 ECT 的流行辨识的数据特征值提取中,文 [7] 等采用了相邻极板的电容平均值和均方误差,将输入数量降低到 13,周云龙等采用了小波能量和图像动态纹理特征提取了电容值特征值,虽然将输入数量降低到 6 和 8^[8-9],但小波分解和图像特征提取大大增加了神经网络的训练时间.

本文将一种反馈型神经网络——Elman 神经网络应用到 ECT 两相流的流型识别中,提出了一种针对 Elman 神经网络的特征值提取方法对 ECT 流型进行辨识,并通过仿真实验进行了验证.

1 电容层析成像基本原理

电容层析成像系统由电容传感器,电容数据采集系统和图像重建计算机三部分组成,如图 1 所示. 电容层析成像技术利用多相介质具有不同的介电常数,通过电容传感器获得相对介电常数分布从而获得介质的分布图像^[10].




图1 电容层析成像系统的构成

一般的对于一个 N 电极的 ECT 系统,在一个采样周期可获得 M 个独立电容^[11].

$$M = N(N-1)/2 \quad (1)$$

以典型的 12 电极 ECT 系统为例,以某个极板为起点,依次为 12 个极板编号. 采取单电极激励方式,先将 1 号电极作为激励电极时,2-12 号依次作为检测电极,测量电极板对 1-2,1-3,...,1-12 间的电容,其中闲置的电极接地. 然后 2 号电极作为激励电极,2-12 号作为检测电极,测量电极板对 2-3,2-4,...,2-12 电极. 以此类推,直到 11 号电极激励,12 号电极检测为止. 这样,12 电极 ECT 系统在一个采样周期内共获得 66 个独立测量值^[12,13].

为了减小理论分析数据和测量数据间的误差,采用归一化电容进行数据分析及实验,本文采用并联模型对电容进行归一化,归一化公式定义如下:

$$C = \frac{C_m - C_l}{C_h - C_l} \quad (2)$$

式中, C_h 及 C_l 分别为传感器内放置高、低介电物质时的电容值,亦即系统标定的高、低界限值, C_m 为实际测量的电容值^[14].

2 Elman 神经网络

2.1 Elman 神经网络基本结构

Elman 神经网络由 J. L. Elman 于 1990 年提出,它是一种典型的局部回归网络,属于反馈神经网络,具有动态特性和递归特性. 与前向神经网络相比,具有更强的计算能力和全局稳定性^[15].

Elman 网络有部分递归网络和完全递归网络两种,主要区别在于是否对反馈的权值进行修正,但网络的结构相同. 图 2 为 Elman 网络的标准结构,其中 ω^1 、 ω^2 为相应的层间权值矩阵, $u(\tau-1)$ 为 $\tau-1$ 时刻网络的输入向量, $x(\tau)$ 为 τ 时刻网络输出向量.




图2 Elman 网络标准结构

Elman 网络由输入层、隐含层、结构层和输出层组成. 结构层记忆隐含单元前一时刻的输出值,并在当前时刻输出,可认为是一步延迟算子,Elman 网络

具有动态记忆功能. 对图 2 所示的 Elman 网络, 可用如下非线性状态空间表达式

$$\left. \begin{aligned} x(t) &= f(w^1 x^c(t) + w^2 u(t-1)) \\ x^c(t) &= x(t-1) \\ y(t) &= g(w^3 x(t)) \end{aligned} \right\} \quad (3)$$

其中, $x(\tau)$ 为结构层输出, $f(\cdot)$ 和 $g(\cdot)$ 分别为输出层单元和隐含层单元的激发函数所组成的非线性向量函数^[14].

当隐含层单元和输出层单元采用线性函数, 并且令隐含层和输出层的阈值都为 1, 则式(3)变化为:

$$\left. \begin{aligned} x(\tau) &= \omega^1 x(\tau-1) + \omega^2 u(\tau-1) \\ y(\tau) &= \omega^3 x(\tau) \end{aligned} \right\} \quad (4)$$

隐含层单元的个数就是状态变量的个数, 这样看来, 对于单输入单输出来说, 只需要一个输入单元和一个输出单元, 即使有 n 个结构单元, 隐含层的输入也只有 $n+1$ 个, 这与静态神经网络要求的神经元个数相比, 有了较大的减少. 另外, 由于 Elman 网络自身含有动态环节, 因此, 它无需使用较多的系统状态作为输入, 从而减少了输入层单元数^[17].

2.2 Elman 网络的学习方法

Elman 网络的学习算法采用动态反向传播学习算法, 由式(4)可知,

$$x^c(\tau) = x(\tau-1) = f(\omega_{k-1}^1 x^c(\tau-1) + \omega_{k-1}^2 u(\tau-2)) \quad (5)$$

由于 $x^c(\tau-1) = x(\tau-2)$, 将式 5 如此展开下去, 说明 x^c 依赖于过去不同时刻的连接权 ω_{k-1}^1 , $\omega_{k-2}^1, \dots$, 即 x^c 的计算是一个动态递推过程, 因此 $x^c(\tau)$ 的计算是一个动态递推过程.

图 3 为动态系统 Elman 神经网络模型的辨识结构, 网络的输入层下标变元为 $i(i=1, 2, 3)$, 隐含层下标变元为 $j(j=1, 2, \dots, m)$, 结构层变元为 $l(l=1, 2, \dots, m)$, 输出层仍为 $k(k=1, 2, \dots, n)$. ω_{ji} 为输入层到隐含层的连接权值, ω_{jl} 为结构层到隐含层的连接权值, ω_{kj} 为隐含层到输出层的连接权值^[18].




图 3 动态系统 Elman 神经网络模型辨识结构

网络的误差函数为:

$$E_n(\tau) = \frac{1}{2P} \sum_{p=1}^P \sum_{k=1}^n (y_{dk} - y_k)^2 \quad (6)$$

其中: y_{dk} 为输出层各节点的期望值; P 为样本数. 于是对于第 $p(p=1, 2, \dots, P)$ 个样本, 图 3 所示的输入输出关系为:

输入层:

$$\text{输入: } I_{ip}^{(1)}(\tau) = [\tau-1, d(\tau-1), \dots, u(\tau-1)]^T$$

$$\text{输出: } O_{ip}^{(1)}(\tau) = I_{ip}^{(1)}(\tau), i=1, 2, 3$$

隐含层:

$$\text{输入: } I_{jp}^{(2)}(\tau) = \sum_{i=1}^3 \omega_{ji} O_{ip}^{(1)}(\tau) + \sum_{i=1}^m \omega_{ji} O_{ip}^{(c)}(\tau) - \theta_j$$

$$\text{输出: } O_{jp}^{(2)}(\tau) = f^{(2)}(I_{jp}^{(2)}(\tau))$$

结构层:

$$\text{输入: } I_{lp}^{(c)}(\tau) = O_{jp}^{(2)}(\tau-1)$$

$$\text{输出: } O_{lp}^{(c)}(\tau) = I_{lp}^{(c)}(\tau)$$

输出层:

$$\text{输入: } I_{kp}^{(3)}(\tau) = \sum_{j=1}^m \omega_{kj} O_{jp}^{(2)}(\tau) - \theta_k$$

$$\text{输出: } y_{kp}(\tau) = O_{kp}^{(3)}(\tau) = f^{(3)}(I_{kp}^{(3)}(\tau)) \quad (7)$$

由式(7)可以看出, Elman 神经网络的输出仅与 $\tau-1$ 时刻的变量有关^[19]. 于是, 隐含层到输出层的权值 $\omega_{kj}(\tau+1)$ 和输出层阈值 $\theta_k(\tau+1)$ 的调整方法为:

$$\left. \begin{aligned} \Delta \omega_{kj}(\tau+1) &= -\eta \frac{\partial E_n}{\partial \omega_{kj}} = -\frac{\eta}{P} \sum_{p=1}^P \delta_p^{(3)} O_{jp}^{(2)}(\tau) \\ \omega_{kj}(\tau+1) &= \omega_{kj}(\tau) + \Delta \omega_{kj}(\tau+1) \\ \Delta \theta_k(\tau+1) &= \frac{\eta}{P} \sum_{p=1}^P \delta_p^{(3)} \\ \theta_k(\tau+1) &= \theta_k(\tau) + \Delta \theta_k(\tau+1) \end{aligned} \right\} \quad (8)$$

其中, $\delta_p^{(3)} = [y_k(t) - y_{dk}(t)] f'(I_{kp}^{(3)}) [-f'(I_{kp}^{(3)})]$.

同样, 输入层到隐含层的权值 $\omega_{ji}(\tau+1)$ 和隐含层阈值 $\theta_j(\tau+1)$ 调整方法为:

$$\left. \begin{aligned} \Delta \omega_{ji}(\tau+1) &= -\frac{\eta}{P} \sum_{p=1}^P \delta_p^{(2)} O_{ip}^{(1)}(\tau) \\ \omega_{ji}(\tau+1) &= \omega_{ji}(\tau) + \Delta \omega_{ji}(\tau+1) \\ \Delta \theta_j(\tau+1) &= \frac{\eta}{P} \sum_{p=1}^P \delta_p^{(2)} \\ \theta_j(\tau+1) &= \theta_j(\tau) + \Delta \theta_j(\tau+1) \end{aligned} \right\} \quad (9)$$

其中, $\delta_p^{(2)} = 2 \sum_{k=1}^n (\delta_p^{(3)} \omega_{kj}) f'(I_{jp}^{(2)}) [-f'(I_{jp}^{(2)})]$.

计算结构层的权值 $\omega_{jl}(\tau+1)$

$$\left. \begin{aligned} \Delta \omega_{jl}(\tau+1) &= -\frac{\eta}{P} \sum_{p=1}^P \delta_p^{(c)} \\ \omega_{jl}(\tau+1) &= \omega_{jl}(\tau) + \Delta \omega_{jl}(\tau+1) \end{aligned} \right\} \quad (10)$$

其中,

$$\delta_p^{(c)} = \delta_p^{(2)} \left[O_{jp}^{(2)}(\tau-1) + \sum_{l=1}^m \omega_{jl}(\tau) \frac{\partial O_{jp}^{(2)}(\tau-1)}{\partial \omega_{jl}} \right]$$

由公式(8),(9),(10)即可实现 Elman 网络层键连接权和阈值的调整,完成 Elman 神经网络的学习^[2]。

3 流型的特征分析和特征提取

不同流型的特征性质也不同,神经网络的输入样本过多会增加神经网络的训练时间,故特征提取会大大减少神经网络的输入数量,同时提高神经网络辨识的准确度。经过仿真 ECT 系统中的七种不同典型流型的 66 个电容值,并计算相邻极板电容方差,相邻极板电容平均值,相对极板电容方差,相对极板电容平均值。可以得到如下几点结论:

1) 相邻极板的电容值方差可以将层流从环流、中心流中进行辨识,进一步查看原始数据得知,其中差异最大的是最上方两块相邻极板间的电容值 $C_{3,4}$ 和最下方的两块相邻极板间的电容值 $C_{9,10}$ 两对相邻极板间的电容值,这是因为层流中的一种介质主要分布在管道底部,而另一种介质主要分布在管道顶部,因此管道顶部的相邻极板和管道顶部相邻极板间电容值差异很大。

2) 对于中心流,环流,满管,空管这四种流型来说,相对极板电容方差,相对极板电容平均值,等差异均较大,经反复比对和筛选,发现 $C_{3,9}$, $C_{4,10}$ 两个对向极板间电容的平均值能够有效辨识这几种流型,这是因为虽然几种流型的相邻极板间电容值差别不大,但是由于其介质分布原因,相对极板电容值差异很大。

3) 对于 1/4, 1/2, 3/4 层流,以上 3 个特征值的差异并不是很大,需再增加特征值,由于三种流型一种介质的高度不同,所以用 $C_{1,7}$, $C_{6,12}$ 两组相对极板电容可以进行明显的辨识。并且用平均值的方法减弱流型上下浮动给测量带来的误差。

4) 对于对向极板的电容值由于其过于微小且与相邻极板电容值大约是 10 倍关系,故将其进行放大 10 倍处理。

为验证特征提取方法的准确性,仿真不同 7 种流型的 4 种特征值,如图 4 所示。




图 4 特征值提取显示

可以看出,通过特征值 1,可以将高位层流和满管的两种流型与其他 5 种流型分开,而这两种流型则是通过特征值 3 划分,特征值 2 将核心流及空管的情况与其他 5 种流型分开,而这两种流型则是通过特征值 4 进行划分,特征值 3 可以将中位层流,环流,低位层流进行区分。所以,本文特征提取方法可以有效的区分以上 7 种流型。

4 仿真和验证

针对典型的 12 电极 ECT 系统的 7 种典型流型(空管,满管,1/4 层流,1/2 层流,3/4 层流,中心流,环流)的 140 组样本(每种 20 组样本),基于 Matlab7 的实验环境进行训练,使用 140 组样本进行检测(每种 20 组样本)。由于软件仿真环境每次测得的电容值都唯一,本文采取高斯噪声法来确定 280 组试验样本,具体确定输入节点如公式 8 所示,设 N_g 代表 5dBm 的高斯噪声,用 x_i ($i=1,2,3,4$) 表示神经网络的 4 个输入,则有:

$$\left. \begin{aligned} x_1 &= C_{3,4} + N_g \\ x_2 &= C_{3,4} + N_g \\ x_3 &= 10C_{9,10} + N_g \\ x_4 &= 10C_{1,7} + N_g \end{aligned} \right\} \quad (11)$$

Elman 神经网络的输出为 7 种不同流型,为了进行识别,我们用 1×7 的矩阵的每一位代表 7 种不同流型,7 种流型在其对应位置上的输出为 1,在其他位置的输出为 0,实验中噪声的出现可能会导致网络的 0 或 1 的输出不正确,为增强神经网络在辨

识目标有噪声的情况下的抗干扰能力,在网络的训练后增加一层竞争网络函数进行处理,可以保证网络的输出在最可能出现 1 的位置出现 1,即识别出的流型.

为确定各层节点个数,用实验的方法进行验证,经验证当隐含层节点个数为 9 时开始,网络的整体识别率百分比曲线趋于稳定,而过多的隐含层节点数会导致网络的训练时间增加,故隐含层节点个数确定为 9 个. 学习率也经过反复试验选择设置为 0.01. 训练函数采用梯度下降自适应学习率训练函数(`traingdx`). 激活函数采用非线性激活函数双极 S 型激活函数(`tansig`), 双极 S 形函数与 S 形函数(`logsig`) 主要区别在于函数的值域, S 形函数值域是 (0,1), 而双极 S 形函数值域是 (-1,1), 而这对于 ECT 中可能出现的负敏感场电容值提供了更精确的辨识.

神经网络初始化时会随机对权值进行选择,导致网络不稳定,为了验证特征提取方法的有效性,分别用 BP 神经网络和 Elman 神经网络对特征提取后的 ECT 流型进行 5 次辨识,迭代次数上限为 500 次,识别率如表 1 所示.


表 1 经特征提取的电容值在不同神经网络下的整体识别率

神经网络	整体识别率/%									
BP 神经网络	81.4	82.1	77.5	79.2	77.7	72.8	84.2	77.1	76.4	
Elman 神经网络	80.7	82.1	80.7	85.7	80.7	82.8	80.1	82.8	82.8	


由表 1 可以看出, BP 神经网络和 Elman 神经网络对经特征提取电容值的整体识别率都在 72% 以上,证实了特征提取方法的有效性,而 Elman 神经网络的总体识别率高于 BP 神经网络,达到了 82%,验证了 Elman 神经网络在 ECT 的流型辨识中效果优于 BP 神经网络.

将两种神经网络的迭代上限都设置为 5000,神经网络训练的目标误差设置为 0.01,两种神经网络训练曲线如图 5 所示.

由图 5 中可以看出, BP 神经网络进行 124 次迭代后达到训练目标,而 Elman 神经网络仅经过 93 次迭代就达到了训练目标,且训练曲线更加平滑,另一方面, BP 神经网络对初值敏感,不同初值每次训练结果都不相同,而 Elman 神经网络对初值不太敏感,初值的改变对 Elman 神经网络的训练结果影响较小,每次训练结果的曲线较为稳定,综合来说, Elman 神经网络在 ECT 流型的辨识上明显优于 BP 神经网络.



(a) BP



(b) Elman

图 5 BP 神经网络和 Elman 神经网络的训练曲线

将 Elman 神经网络与 BP 神经网络训练结果进行对比. 如表 2 所示.

表 2 Elman 神经网络训练效果与 BP 网络训练效果

管内流型	识别率/%	
	BP 神经网络	Elman 神经网络
空管	90	100
满管	95	100
高位层流	80	95
中位层流	95	100
低位层流	90	100
环流	65	80
中心流	30	50

由表 2 可以看出, Elman 神经网络在各种流型的辨识中效果均优于 BP 神经网络,在实际管道中常见的高位层流,中位层流,低位层流中, Elman 的辨识能力很高,对于常见的堵管现象(满管) 中, Elman 神经网络的辨识率达到了 100%, 在实际工作中有重要意义,能够有效监测堵管避免经济损失.

在环流和中心流的辨识中,二者的识别率都不是很高,归其原因是特征值提取方式过于简单导致,但这两种流型在实际 ECT 管道中出现概率很低,故

对全局流型辨识的影响很小.

5 结 论

本文提出了一种基于 Elman 神经网络和特征提取的 ECT 流型辨识方法,该方法首先进行特征值提取,然后将提取后的特征值作为 Elman 神经网络的输入进行训练,经仿真实验验证,该方法能够减少现有 ECT 流型识别中特征提取的计算量,与传统的 BP 神经网络网络对比后发现,本文方法能够有效提高 ECT 系统流型辨识的准确率,为 ECT 系统流型辨识提供了新的思路,但由于特征值提取方式限定,对环流和中心流的辨识度略低,未来的工作重点放在特征值提取优化和网络权值的修正及阈值的优化.

参 考 文 献:

- [1] 杨道业,施源,徐铨锋. 基于双截面 ECT 的气/固两相流参数检测系统 [J]. 仪器仪表学报, 2013, 34(9): 1968-1969.
- [2] 赵玉磊,郭宝龙,闫允一. 电容层析成像技术的研究进展与分析 [J]. 仪器仪表学报, 2012, 33(8): 1909-1916.
- [3] CHEN Deyun, WANG Lili, CHEN Yu. Analyses and Simulation of Sensor Structure Parameters for Electrical Capacitance Tomography System [J]. Proceedings of SPIE(The International Society for Optical Engineering), 2008, 66(21): 575-578.
- [4] DEYUN C, MING G, LEI S, et al. Image Fusion Method Based on Edge Feature Detection in Electrical Capacitance Tomography [J]. International Journal of Signal Processing, Image Processing and Pattern Recognition, 2014, 7(1): 67-76.
- [5] 陈德运,高明,李伟. 新型 ECT 数据采集系统设计与实现 [J]. 电机与控制学报, 2013, 17(5): 87-92.
- [6] 李岩,朱艳丹,袁小花. 基于 ANSYS 电容层析成像结构参数分析与优化 [J]. 哈尔滨理工大学学报, 2012, 17(1): 54-57.
- [7] 王莉莉,乔立勇,陈宇. 基于特征提取和 RBF 神经网络的 ECT 流型识别 [J]. 计算机工程与应用, 2011, 47(5): 175-178.
- [8] 王强,周云龙,程思勇. 基于小波和 Elman 神经网络的气液两相流流型识别方法 [J]. 热能动力工程, 2007, 22(2): 168-171.
- [9] 周云龙,衣得武,高云鹏. 用于气液两相流流型识别的 ECT 传感器的优化设计 [J]. 电机与控制学报, 2011, 15(6): 62-66.
- [10] LI L, ZHANG Y, SONG L. An Image Fusion Algorithm for ECT based on Tikhonov Algorithm and Wavelet Transform [J]. International Journal of Signal Processing, Image Processing & Pattern Recognition, 2014, 7(2): 51-60.
- [11] HJERTAKER B T. Static Characterization of a Dual Sensor Flow Imaging System [J]. Flow Measurement and Instrumentation, 1998, 9: 183-191.
- [12] 郭志恒,律德才,邵富群. 基于差分灵敏度模型的电容层析成像图像重建方法 [J]. 中国电机工程学报, 2012, 32(23): 75-77.
- [13] AZZOPARDI J, JACKSON K, JP R. Fluctuations in Dense Phase Pneumatic Conveying of Pulverised Coal Measured Using Electrical Capacitance Tomography [J]. Chemical Engineering Science, 2008, 63(9): 2548-2558.
- [14] 张立峰,田沛,马平,等. 一种新的电容层析成像电容测量值归一化模型 [J]. 中国电机工程学报, 2011, 31(17): 86-90.
- [15] PHAM D T, LIU X. Training of Elman networks and dynamic system modelling [J]. International Journal of Systems Science, 1996, 27(2): 221-226.
- [16] 刘荣,方鹏飞. 改进 Elman 神经网络的综合气象短期负荷预测 [J]. 电力系统保护与控制, 2012, 40(22): 114-116.
- [17] 陈法法,汤宝平,黄庆卿. 免疫遗传优化 Elman 神经网络的旋转机械故障诊断 [J]. 重庆大学学报, 2012, 35(5): 8-11.
- [18] 周子民,朱再兴,刘艳军. 基于 Elman 神经网络的动力配煤发热量及着火温度的预测 [J]. 中南大学学报(自然科学版), 2011, 42(12): 3872-3875.
- [19] 王晓霞,马良玉,王兵树. 进化 Elman 神经网络在实时数据预测中的应用 [J]. 电力自动化设备, 2011, 31(12): 77-80.
- [20] 曹萍,陈福集. GA-灰色神经网络的区域物流需求预测 [J]. 北京理工大学学报, 2012, 14(1): 67-69.

(编辑: 关 毅)