

文章编号: 0254-0096(2007)12-1354-06

内循环流化床生物质气化过程的神经网络模型

马隆龙^{1,2}, 陈 平², 原晓华², 阴秀丽², 吴创之², 颜涌捷¹

(1. 华东理工大学, 上海 200237; 2. 中国科学院广州能源研究所, 中国科学院可再生能源与天然气水合物重点实验室,
广东省新能源和可再生能源研究开发与应用重点实验室, 广州 510640)

摘要: 基于 BP 人工神经网络原理, 利用 MATLAB 神经网络工具箱, 以实验得到的 57 组气化实验数据作为样本, 建立了一个以加料量和送风量为输入变量, 以燃气热值、产气率、碳转化率和气化效率为输出变量, 用于描述连续稳定气化过程的内循环流化床生物质气化模型。对模型的隐层节点数和训练周期改变对模拟结果的影响进行了分析, 发现当隐层节点数为 20, 训练步骤为 50 步, 模型的 4 个输出变量的模拟结果与实验结果相关系数均超过 0.95; 同时对该模型的预测能力进行了考察, 模型预测结果与实验结果吻合良好, 证明了该模型具有较强的泛化能力, 为生物质内循环流化床气化系统的优化设计和自动控制提供新思路。

关键词: 生物质气化; 内循环流化床; BP 神经网络

中图分类号: TK6 **文献标识码:** A

0 引言

生物质流化床气化技术是一种先进的生物质能利用技术, 具有温度均匀、气化强度大、气化效率高、易于放大等优点, 但其产出气中带出物多、显热损失大、碳回流难以控制。为此我们和意大利合作设计了一种新型气化反应器——内循环流化床气化炉^[1]。该气化炉通过隔板可将气化炉分隔为两个不同区域, 从而将燃烧和气化过程分开。生物质在慢速区与来自快速区炽热的床料混合传热, 快速热解气化, 气化后残碳通过隔板底部狭缝进入快速区, 并在快速区燃烧放热以加热床料。其原理类似于双床流化床气化炉反应器, 由于隔板两侧操作气速不同, 从而构成有规律的内循环流动, 进而有可能解决生物质在流化床气化炉中炉内停留时间短和飞灰碳粒携带严重的问题。原晓华等^[1,2]对该气化炉的设计特点和运行特性已进行了较详细的介绍和分析。

为了对反应器的设计进行优化和实现系统自动控制, 需要对生物质在内循环流化床中的气化过程进行模拟。从建模原理上分类, 生物质流化床气化模型可分为 3 类: 1) 动力学模型, 如 Ranman P 等^[3]、

Fiashi D 等^[4]、Sadaka S S 等^[5~7]提出的一维两相流化床气化模型和阴秀丽等^[8,9]提出的一维单相循环流化床模型。此类模型从生物质气化机理出发, 综合考虑了生物质热解气化反应动力学特性和流化床反应器流体力学特性。然而由于生物质气化动力学的基础数据非常匮乏, 加上气固两相流气固之间传热和传质复杂性, 此类模型一般对生物质气化动力学和流化床流体力学特性都做了很大程度的简化, 因此利用该模型得到的模拟结果与实验结果差别一般比较大。2) 化学平衡模型(又称为 0 维模型), 假定气化过程中的多个异相和同相化学反应在离开气化反应器时都达到化学平衡状态, 因此不用考虑气化动力学和反应器的流体力学特性, 只要知道操作温度、压力和反应物浓度等数据即可快速给出反应器出口产物分布。但是由于气化炉操作温度一般都在 700~900℃, 在此温度下, 气固异相反应很难达到平衡状态。同时由于该模型未考虑反应器流体力学特性, 因此不能用于反应器结构的分析和优化设计。Li X T 等^[10]基于最小吉布斯自由能化学平衡原理, 结合实验结果引入非平衡因子, 给出一个半经验的化学平衡模型, 模型预测结果除了 H₂ 和 CO 与实验

收稿日期: 2006-10-10

基金项目: 国家高技术研究发展计划(863)项目(2003AA514010); 广东省自然科学基金团队项目(003045); 广东省科技计划项目(2004A11007002)

作者简介: 颜涌捷(1943—), 男, 教授, 主要研究方向为生物质能利用。yyansc@online.sh.cn

值误差较大,其他与试验结果吻合较好。3)人工神经网络模型(属于黑盒子模型),该模型完全不用考虑气化机理、反应器结构与流体力学特性,利用人工神经网络对给定的输入直接给出预测输出。人工神经网络模型虽然比化学平衡模型显得更粗糙,但是如果有足够多的生物质气化数据,建立一个用于预测生物质在流化床气化反应器中气化特性的模型是完全可行的,且由于该模型是建立在大量实验数据基础上的,应此具有很高的可靠性。唐松涛等^[9]在其模型中以实验运行参数、生物质料的工业分析数据以及化学成分分析数据作为输入,利用人工神经网络模型给出了热解产率和热解气体成分数据,预测结果和实验结果吻合较好。郭兵等^[11]对神经网络应用于煤和生物质在流化床气化过程的不同生物质的产气率进行了研究,给出了比较满意的结果。然而由于其试验采用间歇式加料,外辅助加热,而且输入参数仅有温度和时间两个,这与本气化炉靠自身燃烧供热连续稳定运行的气化过程差别较大。唐松涛等^[12,13]在其研究基础上,通过引入原料的化学成分分析数据,得到一个可以跨越生物质种类界限的生物质热解神经网络模型,模拟值与实验值吻合较好。

为此本文在试验研究基础上,利用实验得到的57组现场气化实验数据作为训练样本,基于MATLAB神经网络工具箱,初步建立了内循环流化床生物质气化的BP神经网络模型,并给出了该模型模拟结果和试验值的比较。

1 试验系统

1.1 装置

图1给出了建于辽宁省营口市的160kW内循环流化床生物质气化发电系统示意图。该系统由特殊设计的内循环流化床气化炉、空气预热器、燃气冷却塔、燃气焦油净化系统、储气柜和内燃机及温度压力控制系统几个部分组成,关于系统详细介绍详见文献[1]。图2给出了内循环流化床生物质气化炉结构示意图。

1.2 原料

本试验中以营口某大米加工厂的稻壳废物作为反应物,其工业分析和元素分析分别见表1。

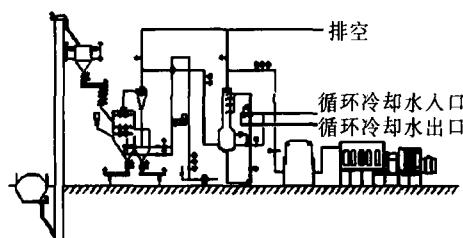


图1 160 kW 生物质内循环流化床气化发电系统示意图

Fig. 1 Layout of 160 kW biomass gasification and power generation system

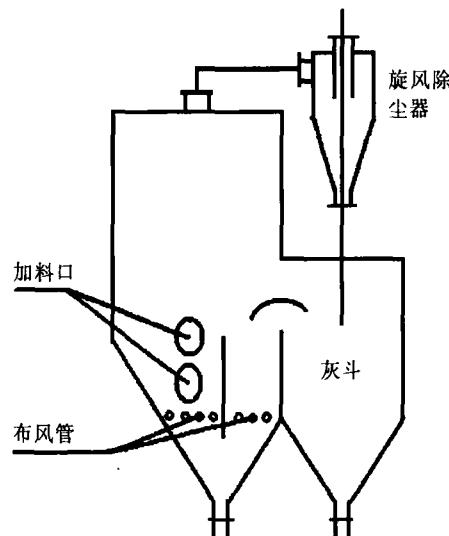


图2 内循环流化床气化炉结构示意图

Fig. 2 Structure of inner circulation gasifier

表1 原料元素分析和工业分析

Table 1 The proximate analysis and ultimate analysis of biomass

元素分析/%				
[C]	[H]	[O]	[N]	[S]
38.37	6.71	47.26	0.39	0.15
工业分析				
V/%	FC/%	A/%	M/%	$Q_{ar,dw}/MJ \cdot kg^{-1}$
66.69	10.49	15.86	6.96	15.073

2 神经网络模型的建立

2.1 网络模型原型的选择

本文选择BP神经网络作为模型原型。BP神经网络(Back Propagation Neural Net)是一种单向传播的多层前馈神经网络,结构比较简单且具有很强的自学习能力、高度非线性的映射能力和通过非线性函数(Sigmoid型)的多次复合可以任意精度逼近连续函数的信息处理和模式识别能力,也是目前被广泛

采用的一种人工神经网络,关于BP神经网络的介绍详见文献[14],其结构如图3所示。

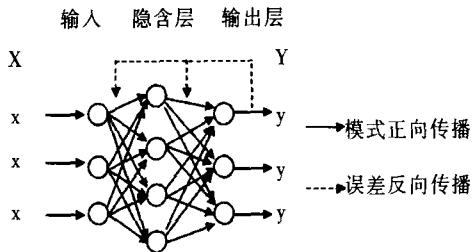


图3 BP 网络拓扑结构及算法原理示意图

Fig.3 Structure of principle of BP neural net

2.2 输入和输出变量的选择

生物质流化床气化过程中,影响生物质气化结果的因素很多。譬如:原料种类、原料粒径大小和粒度分布、原料水分含量、气化介质种类、气化介质预热温度、进料量、进风量(或当量比)、流化速度、气化炉结构(如布风板形式、加料位置)和尺寸、飞灰再循环等都会对生物质在流化床中的气化结果产生一定影响。在上述给定条件下,气化温度、燃气成分、燃气热值、产气率、碳转化率、气化效率、燃气中焦油含量等是我们最关心的。如果把上述影响因素全部作为输入变量引入神经网络中,必然非常复杂,直接影响其收敛性,而且有些变量之间彼此并非独立变量(如流化速度与当量比,流化速度与负荷等)。因此首先需要对这些因变量进行初步相关性分析,找出独立变量作为输入变量以使模型相对比较简化和实用。在本文中,从工程应用角度出发,初步把进料量和进风量作为输入参数,把燃气热值、产气率、碳转化率和气化效率作为输出变量。

2.3 隐含层和隐层神经元个数的选择

根据前人经验,对于大多数实际问题,一般采用3层网络就已足够,隐层增多不仅使训练的时间急剧增加,而且增加了网络在训练中陷入局部最小点而无法摆脱概率,从而网络的权重难以调整到全局最小误差处,因此本模型采用3层神经网络。

到目前为止,人工神经网络隐层神经元个数的选取还没有完整的理论指导,通常采用试凑法。首先将样本集分成两部分,一部分作为学习样本用于网络的训练,另一部分用作测试样本检验网络的预报误差。从较少神经元个数开始,训练并检验网络训练误差和预测误差;不断增加隐层神经元个数,重复训练和检验,直到训练和预测误差都小于预定值。

3 神经网络模型的训练和检验

3.1 数据归一化处理

所谓归一化,就是将具有不同尺度、属于不同区间的样本矢量的各个分量化到相同的区间,从而使样本的各分量具有相同的尺度。归一化在神经网络的训练中有重要作用,对输入样本,希望能够进行归一化处理。对 Sigmoid 函数,当输入在[-1,1]范围以外时,输出响应对输入不敏感,因此需要对输入数据进行归一化处理使那些比较大的输入仍能落在神经元转换函数梯度比较大的地方。为此首先将全部输入输出变量全部归一化到[-1,1]之间。

$$\text{归一化公式为: } x'_{ij} = \frac{x_{ij} - x_{i(\text{mid})}}{\frac{1}{2}(x_{i,\text{max}} - x_{i,\text{min}})}$$

其中, $x_{i(\text{mid})} = 0.5 \times (x_{i,\text{max}} + x_{i,\text{min}})$; x_{ij} ——第 i 个神经元输入的第 j 个样本值; x'_{ij} ——第 i 个神经元输入的第 j 个样本值经过归一化处理后值; $x_{i,\text{max}}$ ——第 i 个神经元所有输入样本中最大值; $x_{i,\text{min}}$ ——第 i 个神经元所有输入样本中最小值。

3.2 训练样本和检验样本的选择

从试验得到的 57 组实验数据中,随机选择 54 组作为训练样本,对神经网络模型进行训练。然后选择其余未训练的 3 组数据作为检验样本以考察网络的泛化能力。

3.3 训练周期的确定

本文中训练周期亦通过试凑法确定。首先给定隐含层节点数,然后给定平方和误差(SUM-squared Error)控制精度,并根据检验样本的网络输出结果相对偏差值来调整控制精度和隐层节点个数,以使网络输出结果相对偏差控制在合理范围内。

4 结果与讨论

4.1 隐层节点个数对模拟结果的影响

这里我们用相关系数来对模拟结果进行评价,相关系数越接近于 1,说明模拟结果越接近实验值,模拟结果越好。图 4 给出了隐含层节点数对模拟结果的影响。从图 4 可以看出,节点数逐步增加,相关系数开始迅速提高,然后逐步趋缓,当节点数达到 20 以后,相关系数几乎不再变化。

隐含层的神经元个数越多,模型的非线性映射能力越强。隐含层神经元个数太少,网络就会不够

强壮,容错性差,因此模拟效果较差。但是神经元个数过多有可能造成拟合过度现象,使预测误差反而增大,因此存在一个最佳节点数范围,在该范围内模型获得最佳模拟结果,并具有较好的预测能力。本实验发现当节点数为15~25时,模型模拟结果和预测结果都相对较好。

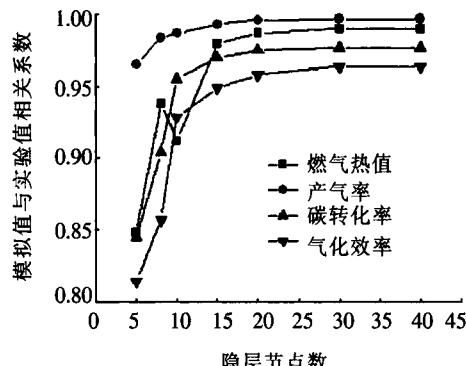


图4 隐含层节点数对模拟结果影响

Fig.4 Effect of node number of hidden layer on simulation results

另外,样本的分散程度也是影响模拟结果的一个重要因素。从图中可以看出,由于产气率样本数据比较集中,因此在相同节点时,其模拟结果要明显好于其他3个气化指标的模拟结果,即使节点数为5,其相关系数仍达到0.95。

4.2 训练周期对训练结果的影响

图5给出了训练周期对模拟结果的影响。从图中可以看出,模拟值与实验值之间的相关系数随着训练周期增加,开始迅速提高,大约经过50步训练以后,4个输出模拟结果基本趋于稳定。训练周期过少,存在训练不足问题,然而也不是训练周期越多越好,系统误差收敛于局部最小点后,再增加训练周期对改善模拟结果并无益处。训练周期过大,有可能造成训练过度,从而造成模型对未训练数据的预报能力下降,因此存在一个比较合理的训练周期。在本实验中,选择训练周期为50步时,模型具有最佳的预测能力。

4.3 模型模拟结果

图6~图9给出了以进料量和进风量为输入变量,燃气热值、产气率、碳转化率和气化效率为输出变量时,隐含层节点数为20,模型经过50步训练后得到的模拟结果与实验值之对比。从图中可以看出,以实验得到的57组气化实验数据中随机抽取的54组数据作为训练样本,人工神经网络模型在经过训练后,模拟值与实验值吻合非常好,各输出变量相关系数都超过0.95,这是其他模型都很难做到的。

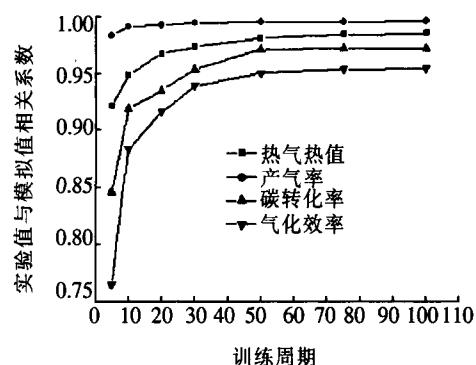


图5 训练周期对模拟结果影响

Fig.5 Effect of training echoes on simulation results

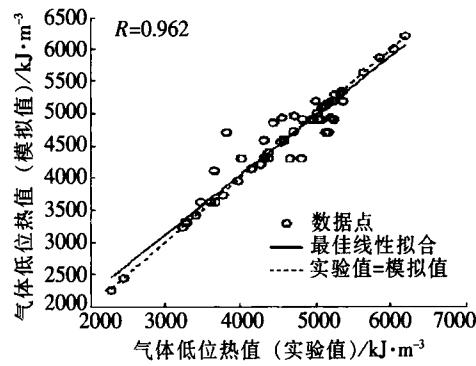


图6 燃气热值实验值和模拟值对比

Fig.6 Comparison of gas LHV of experiment and simulation

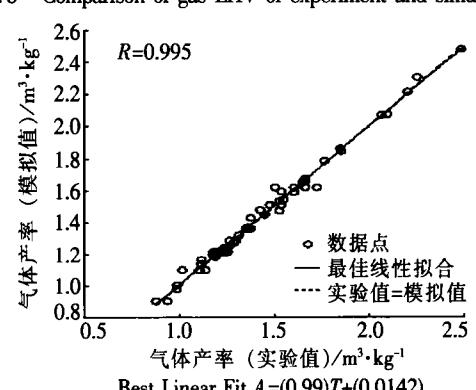


图7 产气率实验值和模拟值对比

Fig.7 Comparison of gas productivity of experiment and simulation

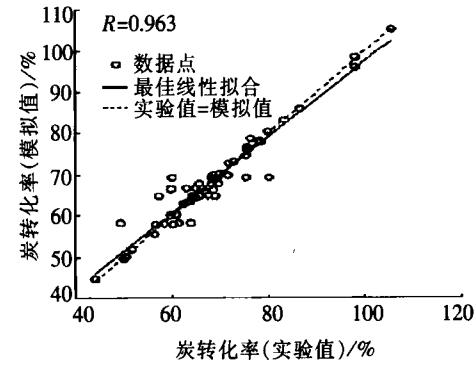


图8 碳转化率实验值和模拟值对比

Fig.8 Comparison of carbon conversion efficiency of experiment and simulation

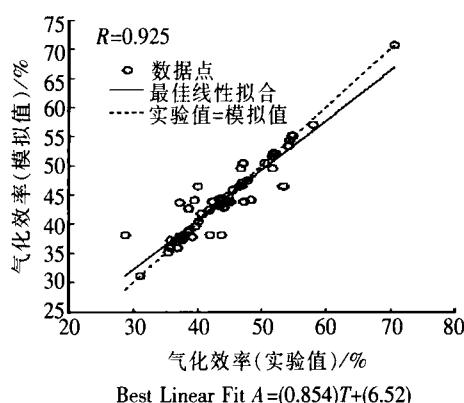


图 9 气化效率实验值和模拟值对比

Fig. 9 Comparison of gasification efficiency of experiment and simulation

4.4 模型的泛化能力的检验

表 2 则给出了当模型的隐含层节点数为 20, 利用随机抽取的 54 组数据作为训练样本, 其他 3 组未经训练的实验数据作为检测样本, 经过 50 步训练后, 模型预测结果与实验值之对比。

从表中可以看出, 对 3 组检测样本数据, 人工神经网络模型都给出了比较满意的预测结果, 预测误差都小于 20%。考虑到大型生物质气化实验中, 原料变化造成的实验数据的波动, 能给出如此好的预测结果, 这也是其他模型都比较难以做到的。

表 2 模型预测结果与实验值对比^①

Table 2 Comparison of simulation results and experimental data

输入参数	输出参数			
	参数 ^②	实验值	预测值	相对误差
进料量 303 kg·h ⁻¹	燃气热值	6189.20	5320.4	-14.038
进风量 207 m ³ ·h ⁻¹	气体产率	1.03	1.1382	10.503
进风量 157 kg·h ⁻¹	碳转化率	54.72	58.267	6.4824
进风量 161 m ³ ·h ⁻¹	气化效率	42.43	43.395	2.2755
进料量 293 kg·h ⁻¹	燃气热值	5102.90	5853.6	14.71
进风量 212 m ³ ·h ⁻¹	气体产率	1.41	1.1497	-18.461
进风量 212 m ³ ·h ⁻¹	碳转化率	64.60	58.568	-9.337
进风量 212 m ³ ·h ⁻¹	气化效率	47.76	44.777	-6.2467
进料量 293 kg·h ⁻¹	燃气热值	4893.60	4700.4	-3.9471
进风量 212 m ³ ·h ⁻¹	气体产率	1.26	1.1799	-6.3537
进风量 212 m ³ ·h ⁻¹	碳转化率	66.33	57.786	-12.88
进风量 212 m ³ ·h ⁻¹	气化效率	45.41	42.015	-7.4753

注:①隐层节点数:20, 训练周期:50; ②燃气热值, kJ·Nm⁻³; 气体产率, m³·kg⁻¹; 碳转化率, %; 气化效率, %; 相对误差, %

5 结 论

基于 BP 人工神经网络模型, 利用 MATLAB 神经

网络工具箱, 以先前气化实验得到的 57 组气化实验数据作为样本, 建立了一个以加料量和送风量为输入变量, 以燃气热值、产气率、碳转化率和气化效率为输出变量时, 用于描述连续稳定气化过程的内循环流化床生物质气化模型。

对模型的隐层节点数和训练周期对模拟结果的影响进行了分析, 给出该模型最佳的网络结构和训练步骤。同时对该模型的预测能力进行了考察。模型预测结果与实验结果吻合良好, 因此人工神经网络模型作为一种新的气化过程模拟手段, 为实现生物质气化过程的优化设计及自动化操作提供了一条新的现实可行的途径。

[参考文献]

- [1] 原晓华, 马隆龙, 陈平, 等. 生物质在隔板式内循环流化床中的气化[J]. 太阳能学报, 2005, 26(6): 743—746.
- [2] 原晓华, 马隆龙, 吴创之, 等. 隔板式内循环流化床气化炉关键尺寸的设计和炉内温度特性[J]. 可再生能源, 2005, (2): 12—15.
- [3] Raman P, Walawender W P, Fan L T, et al. Mathematical model for the fluidized bed gasification of biomass materials application to feedlot manure[J]. Ind Eng Chem Process Des Dev, 1981, 20: 686—692.
- [4] Daniele Fiaschi, Marco Michelini. A two-phase one-dimensional biomass gasification kinetics model[J]. Biomass and Bioenergy, 2001, 21 (2): 121—132.
- [5] Sadaka Samy S, Ghaly A E, Sabbah M A. Two phase biomass air-steam gasification model for fluidized bed reactors: Part I—model development[J]. Biomass and Bioenergy, 2002, 22(6): 439—462.
- [6] Sadaka Samy S, Ghaly A E, Sabbah M A. Two phase biomass air-steam gasification model for fluidized bed reactors: Part II—model sensitivity[J]. Biomass and Bioenergy, 2002, 22(6): 463—477.
- [7] Sadaka Samy S, Ghaly A E, Sabbah M A. Two-phase biomass air-steam gasification model for fluidized bed reactors: Part III—model validation[J]. Biomass and Bioenergy, 2002, 22(6): 479—487.
- [8] 阴秀丽, 徐冰燕, 吴创之, 等. 生物质循环流化床气化炉的数学模型研究[J]. 太阳能学报, 1996, 17(1): 1—8.
- [9] 阴秀丽. 生物质循环流化床气化炉的数学模型研究[D]. 广州: 中国科学院广州能源研究所, 1993.
- [10] Li X T, et al. Biomass gasification in a circulating fluidized bed[J]. Biomass and Bioenergy, 2004, 26(2): 171—193.

- [11] Guo Bing, Li Dingkai, Cheng Congming, et al. Simulation of biomass gasification with a hybrid neural network model[J]. *Bioresource Technology*, 2001, 76(2): 77—83.
- [12] 唐松涛, 李定凯, 吕子安, 等. 流化床中生物质热解过程的混沌神经网络模拟[J]. *化工学报*, 2003, 54(6): 783—789.
- [13] 唐松涛. 生物质能热化学升级过程的混沌动力学分析与神经网络模拟[D]. 清华大学, 2003.
- [14] 韩力群. 人工神经网络理论设计及应用[M]. 北京: 化学工业出版社, 2002.

BP NEURAL NETWORK SIMULATION OF BIOMASS GASIFICATION IN AN INNER CIRCULATING FLUIDIZED BED

Ma Longlong^{1,2}, Chen Ping², Yuan Xiaohua², Yin Xiuli², Wu Chuangzhi², Yan Yongjie¹

(1. East China University of Science & Technology, Shanghai 200237, China;

2. The Renewable Energy and Gas Hydrate Key Laboratory of Chinese Academy of Sciences;

The New and Renewable Energy Key Laboratory of Guangdong Province; Guangzhou Institute of Energy Conversion, CAS, Guangzhou 510640, China)

Abstract: A three layers back propagation (BP) Neural Network model was built to simulate the biomass gasification process in an inner circulating fluidized bed. Two input variables, i.e. feeding rates, air flow rate, and four output variables, i.e. gas heating value, gas productivity, carbon conversion rate, and gasification efficiency were selected. 57 experimental data were taken as training and checking samples, the effects of nodes of hidden layer and training echoes on simulation results were investigated. The results showed that correlation coefficient of the four output variables between simulation results and experimental data exceeded 0.95, when the nodes of hidden layer were 20 and training echoes was 50. Model-predicted results were in agreement with the experimental data, showing good generalization capacity. This model will be the basis of automatic control of biomass gasification process in fluidized bed.

Keywords: biomass gasification; inner circulating fluidized bed; BP neural network