

引用格式:郭荣欣,邹德勋,刘研萍. 基于人工神经网络的联合厌氧消化产气预测模型[J]. 北京化工大学学报(自然科学版), 2021, 48(1): 17-24.

GUO RongXin, ZOU DeXun, LIU YanPing. A predictive model for combined anaerobic digestion gas production based on an artificial neural network[J]. Journal of Beijing University of Chemical Technology (Natural Science), 2021, 48(1): 17-24.

基于人工神经网络的联合厌氧消化产气预测模型

郭荣欣 邹德勋 刘研萍*

(北京化工大学 化学工程学院, 北京 100029)

摘要: 有机固体废物厌氧消化为非均相体系, 预警调控对系统的稳定运行非常重要。为了准确预测负荷跨越式提升的联合厌氧消化体系的日产气量, 利用灰色关联分析方法量化了厌氧消化体系中常见因素间的关联度, 评估了厌氧消化体系的复杂程度, 构建了反向传播(back propagation, BP)神经网络对日产气量进行预测。结果表明, 各指标间的灰色关联度均大于0.7, 表明厌氧消化体系中各参数之间关系的高度的关联性和复杂性。利用试验获取的148组数据作为BP神经网络的训练集和测试集, 构建的BP神经网络精度较高, 对148组样本数据的平均预测准确率达到99.17%, 对日产气量具有较好的预测能力。

关键词: 厌氧消化; 人工神经网络; 产气量; 预测模型

中图分类号: X705 **DOI:** 10.13543/j.bhxbzr.2021.01.003

引言

厌氧消化技术是一种可以有效实现有机固体废物资源化利用的绿色方法, 传统厌氧消化体系中的单一物料由于受限于自身性质而缺乏一定的缓冲能力, 使实际生产中的反应体系往往无法达到理想的产气效果。联合厌氧消化通过利用不同物料的协同消化, 可提高产气效能^[1]。如何准确地预测联合厌氧消化反应体系的产气量对指导和管理实际的规模化沼气工程具有重要意义。厌氧消化是一个受多因素影响的动态体系, 对这种多因素且因素间关系复杂的体系进行有效建模一直是环境科学领域的研究难点。目前, 与产气量相关的估算模型有总固体(TS)估算模型、化学需氧量(COD)估算模型和挥发性固体(VS)估算模型等, 但是这些产气模型将厌氧消化体系过度简化, 预测误差通常较大。

针对产气模型存在的问题, 目前对厌氧消化的建模主要分为线性回归模型、动力学模型和人工神经网络(artificial neural network, ANN)模型三大类。线性回归模型是通过线性拟合的方法建立2种或2种以上不同因素之间定量关系的拟合曲线, 该类模型仅对于具有线性关系的体系具有较好的预测效果, 而对于厌氧消化这种非线性动态反应体系的拟合程度不高^[2]。动力学模型只适用于不存在延滞期或者延滞期之后阶段的产气预测^[3], 而且该种模型往往比较复杂, 其中的反应速率常数对环境的变化十分敏感, 使建模比较困难从而具有一定的局限性^[4-6]。因此, 需要开发一种系统的方法在各种条件下对厌氧消化体系的性能进行建模、优化、预测和控制。

ANN通过模拟大脑的结构, 在各个神经元之间进行信息的传递从而实现对输入信息的处理和分析。ANN具有自学习、自组织以及自适应的特点, 并且可以无限地逼近任意非线性映射, 被广泛应用于非线性体系的建模^[7-8]。基于ANN的特点, 其非常适合对厌氧消化体系进行建模并对产气量进行预测^[9-13]。但是目前使用ANN对厌氧消化体系进行建模的研究依然存在一些问题, 主要是: 未构建测试

收稿日期: 2020-07-21

基金项目: 北京市科技计划(Z181100002418017)

第一作者: 男, 1994年生, 硕士生

*通信联系人

E-mail: liuyp@mail.buct.edu.cn

集数据对模型精度进行测试;在构建测试集时,数据来源于训练集或是按照规律选取,从而未进行泛化能力评估;由于监测数据的局限,获取的影响因素不足,使最终的预测精度不高;另外,大多数预测所进行的厌氧消化试验较为简单,仅使用了一种底物且厌氧消化过程有机负荷保持不变。而在实际的沼气工程中为提升产气量并增强体系缓冲能力,大多采用多底物的联合厌氧消化,同时体系的有机负荷可能无法保证持续稳定或平稳变化,因此对联合厌氧消化过程中有机负荷发生改变的体系进行建模就显得尤为重要。

本文以玉米秸秆和猪粪联合厌氧消化反应过程中的运行数据作为样本数据,采用灰色关联分析方法对各指标之间的关联度进行量化分析,然后构建了玉米秸秆和猪粪联合厌氧消化产气人工神经网络预测模型。在模型构建时随机抽取数据作为测试集以评估模型的精确度以及泛化能力,以期为今后沼气工程过程中的参数优化及产气量的准确预测提供参考。

1 实验部分

1.1 原料与装置

选用玉米秸秆和猪粪作为联合厌氧消化的底物。玉米秸秆来自北京顺义某农田,将其粉碎过筛(筛孔尺寸为 0.850 mm);猪粪来自北京延庆某养殖场,收集后去除掉较大的杂物和猪毛;接种物来自北京延庆沼气站的厌氧消化液,静置 1 周后倒掉上清液。各原料的基本性质见表 1。

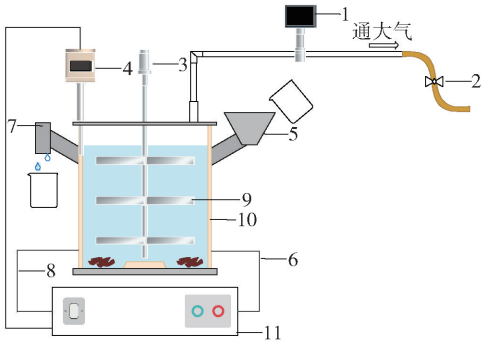
表 1 原料的主要基本性质

基本参数	数值		
	玉米秸秆	猪粪	接种物
TS 质量分数 ^{a)} /%	93.9±0.1	29.9±0.1	11.7±0.1
VS 质量分数 ^{a)} /%	77.7±0.3	23.5±0.3	6.0±0.1
碳氮质量比 ^{b)} (C/N)	46.24	8.58	8.87
木质素质量分数 ^{b)} /%	5.8±1.0	3.1±0.8	-
纤维素质量分数 ^{b)} /%	37.2±1.2	12.3±0.9	-
半纤维素质量分数 ^{b)} /%	30.5±0.3	28.7±0.4	-

表中数据为平均值±标准偏差($n=3$);a—鲜物质含量;b—干物质含量;-为无此项。

试验装置使用自制的全混合厌氧反应器(CSTR),主要由水箱、主罐体以及流量计构成。其

中反应罐的工作体积为 8 L,在外层加装了加热保温层并将温度设定为 $(35\pm2)\text{ }^{\circ}\text{C}$ 以保证反应罐的温度恒定。反应罐体内加装全自动搅拌桨,每隔 2 h 搅拌一次以保证物料混合均匀,具体装置如图 1 所示。在试验开始前对整个装置进行气密性检查,检查无误后开始试验。



1—气体流量计;2—止水夹;3—搅拌电机;4—温度计;
5—进料口;6—进水管;7—出料口;8—出水管;
9—搅拌桨;10—保温夹层;11—加热水箱。

图 1 CSTR 示意图

Fig.1 Schematic diagram of the CSTR

1.2 联合厌氧消化试验

试验设计的水力停留时间(HRT)为 32 d,秸秆与猪粪的质量比为 3:1(基于 TS),发酵启动负荷为 50 g/L(基于 TS),接种物的接种量为 20 g/L(基于混合液悬浮固体(MLSS))。试验共进行 173 d,前 25 d 为微生物驯化阶段,后 148 d 为稳定运行的试验阶段。微生物驯化阶段不进出料,仅记录日产气情况,当日产气量小于最大产气量的 1%(体积分数)时驯化结束。之后开始每日定时进出料一次,进出料体积均为 250 mL,使用自来水作为调节水。试验过程中有机负荷(均基于 TS)进行了两次阶段式提升:50 g/L(低负荷)—70 g/L(中负荷)—90 g/L(高负荷)。各阶段在日产气量变化率小于 5% 达到稳定运行后,将反应负荷提升至下一阶段。第 1~51 天低负荷运行 51 d,第 52~100 天中负荷运行 49 d,第 101~148 天高负荷运行 48 d。

在稳定运行期间,每日定时记录产气情况,分析气体组分和出料液的相关性质。日产气量使用排水集气法记录,并通过理想气体状态方程(式(1))换算为标准状况下的体积:

$$pV=nRT \tag{1}$$

式中, p 为气体的压强, V 为气体的体积, n 为物质的

量, T 为热力学温度, R 为摩尔气体常数; 甲烷含量采用配备有热导检测器和 TDX-01 柱的气相色谱仪 (SP-2100 型, 北分瑞利公司) 测定; 挥发性脂肪酸 (VFAs) 含量利用气相色谱仪 (GC-2014 型, 日本岛津公司) 测定; pH 值利用酸度计 (S40 型, 瑞士梅特勒-托利多公司) 测定; 碱度利用电位滴定法测定; 氨氮浓度利用高精度多参数浓度测定仪 (HI83206 型, 意大利 HANNA 公司) 测定; TS 和 VS 含量分别采用恒定质量法和灼烧法测定。选取稳定运行期的 148 组数据作为人工神经网络的训练以及测试数据。

1.3 各指标间的灰色关联度

灰色关联度分析是基于不同指标之间变化趋势的相似或者相异程度, 作为衡量不同指标之间关联度的方法^[14], 是基于灰色理论的一种应用, 通过灰色关联度这种量化指标来描述各指标之间关系的强度。本文通过 Matlab 构建灰色关联分析算法并计算出各指标间的灰色关联度, 以量化厌氧消化体系的复杂性^[15]。主要计算过程如下: 1) 确定指标体系, 包括日产气量、甲烷含量、pH 值、碱度、氨氮浓度、VFAs 含量、TS 含量及 VS 含量; 2) 将各指标的数据依次作为参考数列; 3) 对确立的指标体系进行无量纲化处理; 4) 计算出各指标之间的灰色关联度。由于各阶段中温度与有机负荷基本保持不变, 故本文对此不做分析。

1.4 厌氧消化产气量预测模型的建立

1.4.1 反向传播 (back propagation, BP) 神经网络算法

BP 神经网络是 ANN 中的一种多层前馈神经网络 (MLFNN), 相较于多层感知器 (MLP), BP 神经网络的特点在于信号是前向传播, 而误差却是逆向传播的。它的学习规则是最速下降法, 通过误差的逆向传播来依次不断地调整隐含层至输出层的权重 (w) 和偏置 (b)、输入层到隐含层的权重 (w) 和偏置 (b)^[16]。本文采用 Matlab 来构建具有单隐含层结构的 BP 人工神经网络, 将试验过程中获得的各项指标数值作为输入变量, 日产气量作为输出值。通过人工神经网络的自我学习和修正, 实现输入变量与输出值之间映射的构建, 达到预测产气量的目的。

1.4.2 BP 神经网络的构建

使用 ANN 构建厌氧消化产气预测模型时, 由于旧函数、采集的样本数量等的限制, 在输入变量的选

择上, 要尽可能选择与输出值具有较强相关关系的适量指标, 否则过多的输入变量会使训练的时间大大增加, 并带来较大的全局误差; 而过少的输入变量会使最后模型的精度不足。因此选择合适的输入变量对提升模型精度至关重要^[17]。

本文为进一步提升模型的预测精度, 在前人研究的基础上^[9-13]不但对产气性质进行监测, 同时对出料的性质进行了分析并作为输入变量引入模型之中。同时考虑到各个指标的检测难度, 将检测难度较大的指标剔除。隐含层节点数 h 通过经验公式 (式 (2)) 确定:

$$h = \sqrt{m + n} + a, a \in [1, 10]$$
 (2)

式中, m 为输入层节点数, n 为输出层节点数, a 为 1~10 之间的自然数, 将计算结果取整。然后使用试凑法来确定具体的隐含层层数。同时为了消除不同量纲带来的影响, 设定神经网络自动进行对输入变量的归一化无量纲处理以及输出值的反归一化处理。输入层与隐含层之间选用双曲正切 Sigmoid 函数, 隐含层与输出层之间选用 Trainlm 函数进行训练。算法的具体训练流程见图 2。

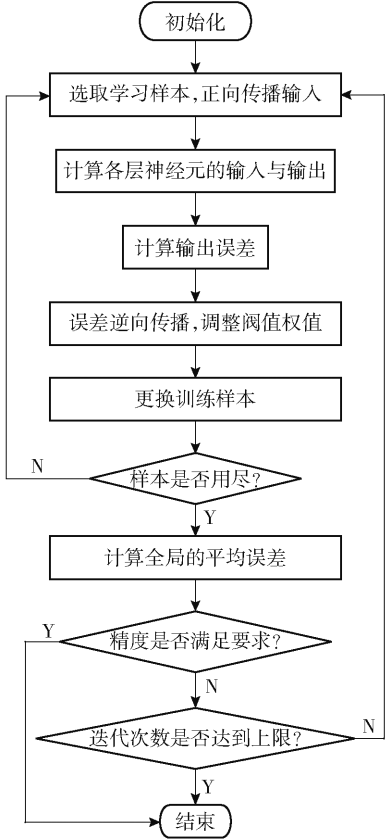


图 2 BP 神经网络训练流程图

Fig. 2 Training flow chart of the BP neural network

1.4.3 BP 神经网络的训练与测试

选取稳定运行期的 3 个负荷阶段(前 147 d)的数据作为样本,并将数据按序等分为 A、B、C 组(A 组为第 1、4、7、⋯、145 天,B 组为第 2、5、8、⋯、146 天,C 组为第 3、6、9、⋯、147 天)进行 3 折交叉验证,1 份被保留作为验证模型的测试集,其他 2 份作为训练集。交叉验证重复 3 次,每份均被验证 1 次,3 次的平均结果即为对模型的最终估测。

同时,为了更好地对该模型的精度和泛化能力进行评估,对 A、B、C 组进行了平均绝对误差(MAE)、均方误差(MSE)、均方根误差(RMSE)、平均绝对百分比误差(MAPE)和相关系数(R)的计算并作为模型的评价指标。

1.4.4 BP 神经网络的验证

在 BP 神经网络的测试完成后,将所有样本数据导入 BP 神经网络中,进行模型验证,并将得到的输出值与试验的实测值进行对比。

2 结果与讨论

2.1 厌氧消化各指标的灰色关联度

各指标间的灰色关联度见图 3。由图 3 可知,厌氧消化过程中常见的检测指标之间的关联度均处于较强的范围(>0.7),表明厌氧消化体系中各指标之间关系的高度的关联性和复杂性。

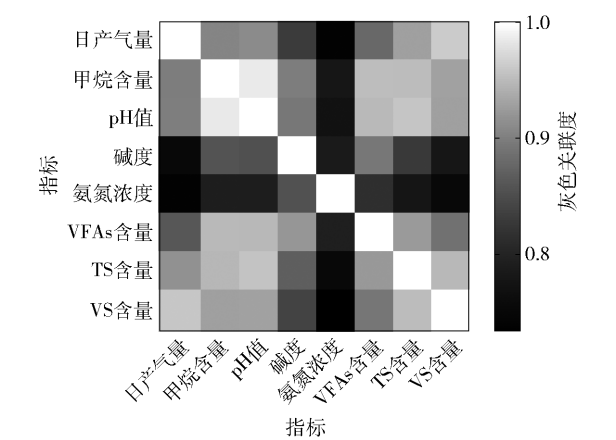


图 3 各指标的灰色关联度热图

Fig. 3 Gray correlation heat map of each index

2.2 BP 神经网络的建立

2.2.1 隐含层层数的确定

考虑到实际生产过程中指标检测的难易程度,最终选取了在厌氧消化过程中常见的 5 项检测指标作为输入变量,分别为 pH 值、氨氮浓度、VFAs 含

量、TS 含量和 VS 含量;同时将日产气量作为输出值。

根据经验公式(2),得出隐含层节点数为 3 ~ 12。为了使最终结果更加精确,每种组合测试 1 000 次,将 1 000 次的误差取平均值(表 2),从中选取均方误差最小的作为最终隐含层层数。

表 2 不同隐含层层数的测试结果
Table 2 Test results for different hidden layers

隐含层节点数	均方误差
3	0.004 266 7
4	0.007 733 4
5	0.005 813 7
6	0.006 660 6
7	0.008 750 4
8	0.008 870 3
9	0.006 305 8
10	0.058 903 0
11	0.004 874 3
12	0.003 353 8

由表 2 可知,当隐含层节点数为 12 时,模型的训练误差最小,为 0.003 353 8。因此确定所用的 BP 神经网络结构为 5-12-1 型结构,如图 4 所示。在此基础上确定了模型的其余参数:最高训练次数 10 000 次、学习速率 0.01、目标误差 0.001、动量因子 0.01。

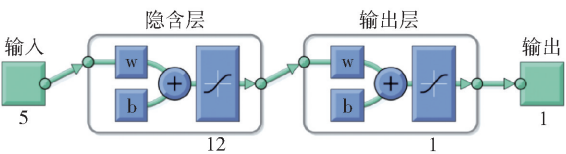


图 4 BP 神经网络结构图

Fig. 4 Structure diagram of the BP neural network

2.2.2 BP 神经网络的训练与测试

对 BP 神经网络的 3 次训练过程如图 5 所示,可以看出各组训练过程变化平稳并且收敛性很好,均在迭代 5 次内误差达到 0.1 左右,在 50 次内误差达到 0.001 的训练要求,说明达到目标要求。从各组的最优回归曲线(图 6)上得出各组的相关系数 R 分别为 0.998 94、0.998 95 和 0.998 85,平均相关系数 $\bar{R}=0.998 91$,表明已经达到了很好的精度,因此 BP 神经网络的训练结束。

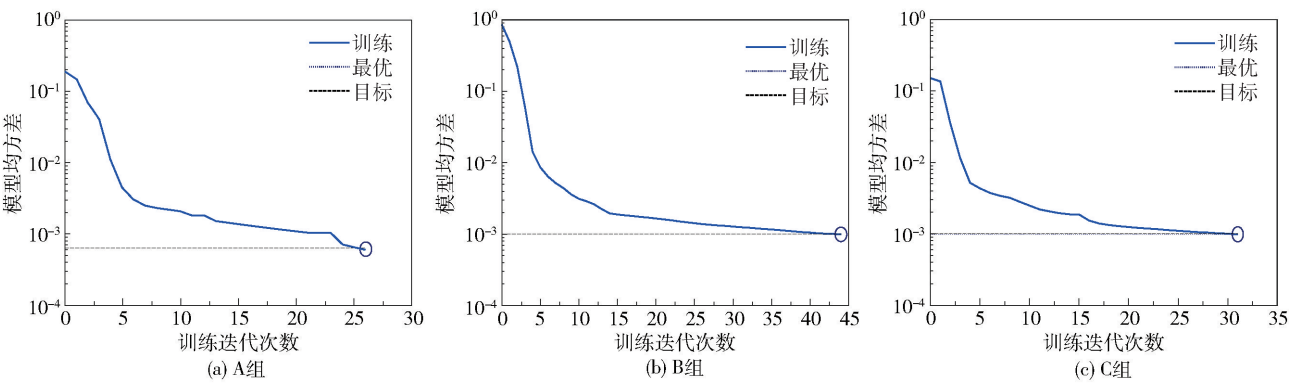


图 5 各组别的 BP 神经网络训练过程

Fig. 5 Training processes of the BP neural network for each group

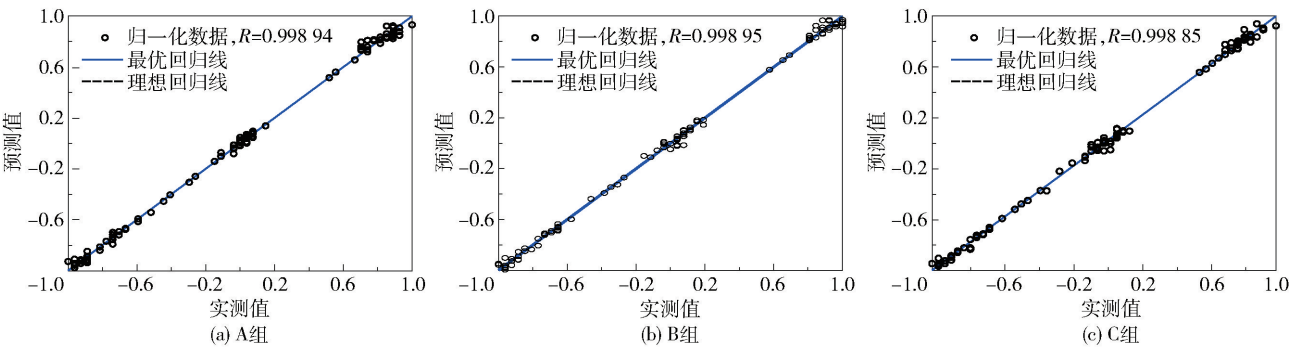


图 6 不同组别的样本数量及最优回归曲线

Fig. 6 Numbers of training set samples and optimal regression curves for different groups

将 A、B、C 组测试集依次导入训练完成的 BP 神经网络中进行交叉验证,结果如图 7 所示。可以看出 BP 神经网络对日产气量的预测值与实测值十分接近,与实际产气过程中日产气量的变化趋势是基本吻合的。说明训练完成的 BP 神经网络对负荷阶段式提升情况下的厌氧消化过程依然具有非常好的

预测能力。各组测试数据的 MAPE 基本保持在 3% 左右(图 8),可见该 BP 神经网络很好地完成了预测目标,预测结果比较准确。该模型的其余评价指标结果见表 3。虽然各测试集的数据对于构建的人工神经网络而言是完全陌生的数据,但依然取得了很好的预测精度,说明该模型具有很好的泛化能力。

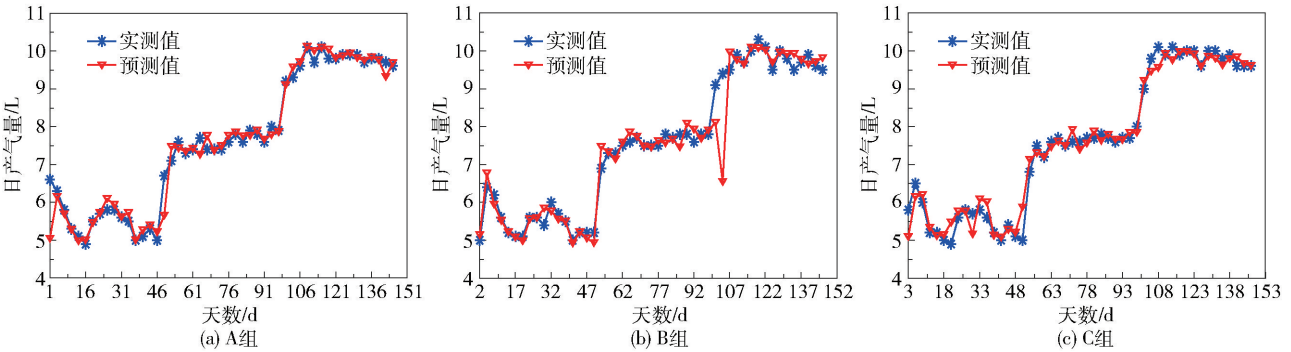


图 7 测试集日产气量的预测值与实测值对比

Fig. 7 Comparison of predicted and measured daily gas production of the test sets

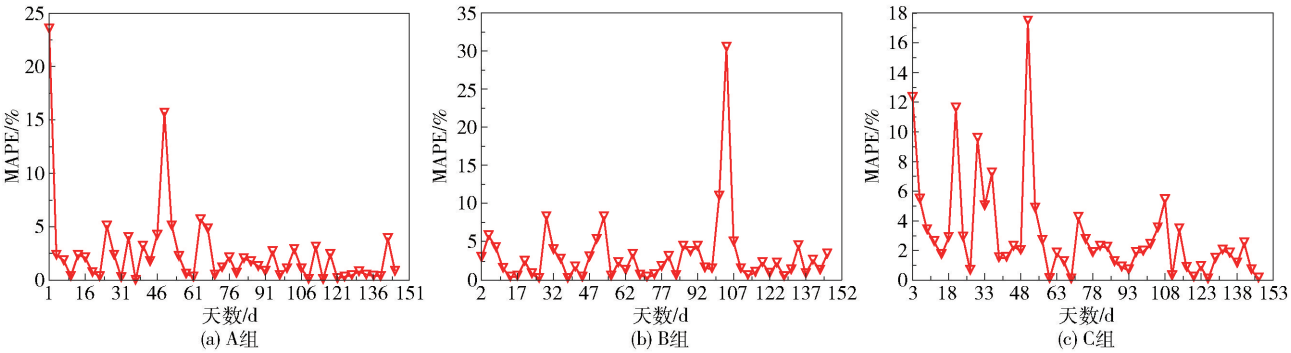


图 8 各测试集的 MAPE
Fig. 8 MAPE of each test set

表 3 评价指标
Table 3 Evaluation indexes

评价指标	数值			
	A 组	B 组	C 组	均值
MAE	0.193 21	0.236 83	0.199 55	0.209 86
MSE	0.079 64	0.231 23	0.073 98	0.128 29
RMSE	0.282 22	0.480 86	0.272 00	0.358 18
MAPE/%	2.685 5	3.018 3	2.990 5	2.898 1
R	0.987 36	0.963 83	0.988 99	0.980 06

2.2.3 BP 神经网络的验证

通过日产气量的实测值和预测值的对比(图 9)可以看出,该 BP 神经网络的输出值很好地表现出了实际日产气量的变化趋势,对不同负荷过程下的日产气量、各阶段波峰波谷的出现都体现出了很好的预测能力。在厌氧消化体系刚开始运行时的非稳定期以及第 52 天和第 101 天负荷改变时都做出了十分准确的预测。

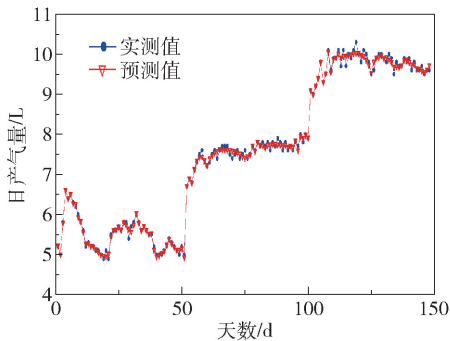


图 9 日产气量的预测值与实测值对比
Fig. 9 Comparison of predicted and measured daily gas production

确率达到 99.17%,这说明该模型对厌氧消化产气量具有非常好的预测能力。

3 结论

(1)厌氧消化过程中常见指标之间的灰色关联度均大于 0.7,处在较强的范围内,表明厌氧消化体系中各指标之间关系的高度的关联性和复杂性。

(2)构建了 5-12-1 结构的 BP 神经网络,并进行了 3 折交叉验证,各组测试数据的 MAPE 基本保持在 3% 左右,说明该模型具有较好的预测精度和泛化能力。

(3)训练完成的 BP 神经网络的输出值很好地反映了实际日产气量,并且在负荷阶段式提升的情况下依然做出了准确的预测,148 组数据的平均预测准确率高达 99.17%。说明该模型能够较好地预测联合厌氧消化产气量。

参考文献:

[1] 刘建伟,周晓,闫旭,等. 城市生活垃圾和污水厂剩余污泥联合厌氧消化产气性能研究[J]. 可再生能源, 2015, 33(6): 933-937.
LIU J W, ZHOU X, YAN X, et al. Biogasification performance of anaerobic co-digestion of municipal solid waste and excess sludge of sewage plant[J]. Renewable Energy Resources, 2015, 33(6): 933-937. (in Chinese)
[2] 胡克勤,李连华,孙永明,等. 基于原料组分的能源草厌氧发酵产气预测模型[J]. 新能源进展, 2016, 4(2): 100-104.
HU K Q, LI L H, SUN Y M, et al. The methane yield forecasting model of energy crops in anaerobic digestion based on feedstock components[J]. Advances in New

148 组样本数据的 MAPE 为 0.826 12%,预测准

- and Renewable Energy, 2016, 4(2): 100 – 104. (in Chinese)
- [3] 李东, 孙永明, 袁振宏, 等. 有机垃圾组分中温厌氧消化产甲烷动力学研究[J]. 太阳能学报, 2010, 31(3): 385 – 390.
- LI D, SUN Y M, YUAN Z H, et al. Kinetic study of the mesophilic anaerobic digestion of organic waste components[J]. Acta Energaiae Solaris Sinica, 2010, 31(3): 385 – 390. (in Chinese)
- [4] 熊菊元, 李轶, 张大雷, 等. 颗粒有机物厌氧消化动力学研究进展[J]. 可再生能源, 2011, 29(3): 67 – 72.
- XIONG J Y, LI Y, ZHANG D L, et al. Kinetics study on anaerobic degradation of particulate organic material [J]. Renewable Energy Resources, 2011, 29(3): 67 – 72. (in Chinese)
- [5] 台明青, 陆浩洋, 袁可佳. 剩余污泥与酒精糟液高温共厌氧消化能量平衡及动力学研究[J]. 可再生能源, 2015, 33(6): 915 – 920.
- TAI M Q, LU H Y, YUAN K J. Energy balance and kinetics assessment of anaerobic thermophilic co-digestion of waste activated sludge and alcohol distillery vinasse [J]. Renewable Energy Resources, 2015, 33(6): 915 – 920. (in Chinese)
- [6] 黄月, 赵明星, 杨莉丽, 等. 餐厨垃圾与剩余污泥混合消化产甲烷性能及动力学分析研究[J]. 食品与生物技术学报, 2017, 36(5): 486 – 493.
- HUANG Y, ZHAO M X, YANG L L, et al. Methane generation performance and kinetic analysis of food waste and excess sludge treatruant by anaerobic co-digestion technology[J]. Journal of Food Science and Biotechnology, 2017, 36(5): 486 – 493. (in Chinese)
- [7] HE Y, MENG Z Y, XU H, et al. A dynamic model of e-valuating differential automatic method for solving plane problems based on BP neural network algorithm [J]. Physica A: Statistical Mechanics and its Applications, 2020, 556: 124845.
- [8] YAN C, LI M X, LIU W, et al. Improved adaptive genetic algorithm for the vehicle insurance fraud identification model based on a BP neural network[J]. Theoretical Computer Science, 2020, 817: 12 – 23.
- [9] 张文阳, 张良均, 李娜, 等. 多元回归和 BP 人工神经网络在预测混合厌氧消化产气量过程中的应用比较[J]. 环境工程学报, 2013, 7(2): 747 – 752.
- ZHANG W Y, ZHANG L J, LI N, et al. Comparing multiple regression and BP artificial nerve net model used on prediction of anaerobic co-digestion gas-producing process[J]. Chinese Journal of Environmental Engineering, 2013, 7(2): 747 – 752. (in Chinese)
- [10] 赖夏颀, 张文阳, 张良均, 等. 基于人工神经网络的半连续式混合厌氧消化产气量预测[J]. 环境工程学报, 2015, 9(1): 459 – 463.
- LAI X J, ZHANG W Y, ZHANG L J, et al. Prediction of gas production of semi-continuous anaerobic co-digestion based on artificial neural network[J]. Chinese Journal of Environmental Engineering, 2015, 9(1): 459 – 463. (in Chinese)
- [11] 花亚梅, 赵贤林, 王效华, 等. 基于改进 BP 神经网络的厌氧发酵产气量预测模型[J]. 环境工程学报, 2016, 10(10): 5951 – 5956.
- HUA Y M, ZHAO X L, WANG X H, et al. Prediction modeling for gas production of anaerobic fermentation based on improved BP neural network[J]. Chinese Journal of Environmental Engineering, 2016, 10(10): 5951 – 5956. (in Chinese)
- [12] 温沁雪, 李奕芯, 杨硕, 等. 基于数据挖掘和人工神经网络的厌氧产气模型构建[J]. 中国给水排水, 2019, 35(1): 77 – 81.
- WEN Q X, LI Y X, YANG S, et al. Anaerobic co-digestion biogas production model based on data mining and artificial neural network[J]. China Water & Wastewater, 2019, 35(1): 77 – 81. (in Chinese)
- [13] 严文峰, 李晓东, 高智花, 等. 污泥厌氧消化的人工神经网络模型[J]. 环境工程学报, 2015, 9(5): 2425 – 2429.
- YAN W F, LI X D, GAO Z H, et al. Artificial neural network model for sludge anaerobic digestion [J]. Chinese Journal of Environmental Engineering, 2015, 9(5): 2425 – 2429. (in Chinese)
- [14] DENG J L. Introduction to grey system theory[J]. The Journal of Grey System, 1989, 1: 1 – 24.
- [15] 田兵, 冉雪琴, 薛红, 等. 贵州 42 种野生牧草营养价值灰色关联度分析[J]. 草业学报, 2014, 23(1): 92 – 103.
- TIAN B, RAN X Q, XUE H, et al. Evaluation of the nutritive value of 42 kinds of forage in Guizhou Province by grey relational grade analysis[J]. Acta Prataculturae Sinica, 2014, 23(1): 92 – 103. (in Chinese)
- [16] 马春娟. 基于流形学习的面向对象的软件缺陷预测方法研究[D]. 天津: 河北工业大学, 2013.

MA C J. Research on prediction method based on manifold learning for object oriented software defect [D]. Tianjin: Hebei University of Technology, 2013. (in Chinese)

[17] DING S F, SU C Y, YU J Z. An optimizing BP neural network algorithm based on genetic algorithm[J]. Artificial Intelligence Review, 2011, 36(2): 153 – 162.

A predictive model for combined anaerobic digestion gas production based on an artificial neural network

GUO RongXin ZOU DeXun LIU YanPing*

(College of Chemical Engineering, Beijing University of Chemical Technology, Beijing 100029, China)

Abstract: Anaerobic digestion of organic solid waste is a heterogeneous system, and early warning and control are very important factors in ensuring stable operation of the system. In order to accurately predict the daily gas production of a combined anaerobic digestion system with a large increase in load, the gray correlation analysis method was used to quantify the correlation between common factors in the anaerobic digestion system, and to evaluate the complexity of the anaerobic digestion system. A back propagation (BP) neural network was constructed to predict daily gas production. The results show that the gray correlation degree between each index is greater than 0.7, indicating a high degree of correlation and the complexity of the relationship between the parameters in the anaerobic digestion system. By using the 148 sets of data obtained in the experiments as the training set and testing set for the BP neural network, the resulting BP neural network has high accuracy, with the average prediction accuracy for the 148 sets of sample data being 99.17%, confirming its excellent ability to predict daily gas production.

Key words: anaerobic digestion; artificial neural networks; gas production; predictive model

(责任编辑:于少云)