

10-14-2020

Prediction of N-acetylglucosamine Content Based on RF-GA-BP Neural Network

Wenfeng Yang

Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China;

Wang Yan

Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China;

Zhichen Ji

Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Prediction of N-acetylglucosamine Content Based on RF-GA-BP Neural Network

Abstract

Abstract: In order to solve the problem that the content of N-acetylglucosamine (GlcNAc) in the process of preparing glucosamine (GlcN) by microbial fermentation is difficult to measure online, *an improved prediction algorithm based on stochastic forest algorithm, genetic algorithm and neural network algorithm is proposed. The algorithm utilizes the feature of decreasing average impurity in random forest algorithm to analyze the relevance of the input characteristics. The initial weights and thresholds of the neural networks are optimized by the genetic algorithm.* A prediction model based on the RF-GA-BP algorithm is established based on the data from the fermentation process of an ammonia sugar production enterprise. The results show that the model has a good prediction ability for the content of GlcNAc. The prediction model has a fast convergence rate and a high accuracy. The average error is less than 7%, which is better than the GA-BP model and the traditional BP model.

Keywords

n-acetylglucosamine, BP neural network, random forest, soft sensor

Recommended Citation

Yang Wenfeng, Wang Yan, Ji Zhichen. Prediction of N-acetylglucosamine Content Based on RF-GA-BP Neural Network[J]. Journal of System Simulation, 2020, 32(10): 2034-2040.

基于 RF-GA-BP 神经网络的 N-乙酰氨基葡萄糖含量预测

杨文峰, 王艳, 纪志成

(江南大学 教育部物联网技术应用工程研究中心, 江苏 无锡 214122)

摘要: 为解决微生物发酵法制取氨基葡萄糖(Glucosamine, GlcN)过程中 N-乙酰氨基葡萄糖(N-acetylglucosamine, GlcNAc)含量难以在线测量的问题, 提出一种由随机森林算法、遗传算法及神经网络算法相结合的改进预测算法。利用随机森林算法中平均不纯度下降的特点, 对输入特征进行关联性分析, 并通过遗传算法对神经网络初始权值、阈值进行优化。以某氨基糖生产企业发酵过程中的数据为基础, 建立基于 RF-GA-BP 算法的预测模型。结果表明: 该模型对发酵生产过程中 N-乙酰氨基葡萄糖含量具有良好的预测能力, 所提出的模型兼顾了高精度与快收敛的需求, 测试样本预测平均误差低于 7%, 优于 GA-BP 模型与传统 BP 模型。

关键词: N-乙酰氨基葡萄糖; BP 神经网络; 随机森林; 软测量

中图分类号: TP398.1 文献标识码: A 文章编号: 1004-731X (2020) 10-2034-07

DOI: 10.16182/j.issn1004731x.joss.20-FZ0335

Prediction of N-acetylglucosamine Content Based on RF-GA-BP Neural Network

Yang Wenfeng, Wang Yan, Ji Zhichen

(Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China)

Abstract: In order to solve the problem that the content of N-acetylglucosamine (GlcNAc) in the process of preparing glucosamine (GlcN) by microbial fermentation is difficult to measure online, an improved prediction algorithm based on stochastic forest algorithm, genetic algorithm and neural network algorithm is proposed. The algorithm utilizes the feature of decreasing average impurity in random forest algorithm to analyze the relevance of the input characteristics. The initial weights and thresholds of the neural networks are optimized by the genetic algorithm. A prediction model based on the RF-GA-BP algorithm is established based on the data from the fermentation process of an ammonia sugar production enterprise. The results show that the model has a good prediction ability for the content of GlcNAc. The prediction model has a fast convergence rate and a high accuracy. The average error is less than 7%, which is better than the GA-BP model and the traditional BP model.

Keywords: n-acetylglucosamine; BP neural network; random forest; soft sensor

引言

N-乙酰氨基葡萄糖(N-acetylglucosamine,



收稿日期: 2020-03-27 修回日期: 2020-06-10;
基金项目: 国家自然科学基金(61973138), 国家重点
研发计划(2018YFB1701903);
作者简介: 杨文峰(1995-), 男, 江苏扬州, 硕士生, 研
究方向为系统建模与仿真; 王艳(1978-), 女, 江苏盐
城, 博士, 教授, 研究方向为制造系统能效优化。

GlcNAc)和氨基葡萄糖(glucosamine, GlcN)是重要的功能糖, 是生物体内多糖透明质酸(Hyaluronic acid, HA)、肝素、硫酸角质素等组成的重要单体之一, 同时也是母乳寡糖、神经氨酸、壳寡糖合成的前体物质, 可以维持生物体正常的生理功能。近年来, GlcNAc 被广泛应用于生物食品、医疗保健、化妆品等领域, 并且需求量逐年增加, 市场应用前

<http://www.china-simulation.com>

• 2034 •

景广阔^[1-2]。在欧美等发达国家, GlcNAc 作为保健品的重要组成部分, 为人体提供必需的生物活性物质而被广泛应用^[3]。

当前对于 GlcNAc 的生产方式主要包括化学法与微生物发酵法 2 种^[4]。化学法以虾蟹等动物的外骨骼为原材料, 利用浓盐酸、硫酸等化学试剂, 水解制取甲壳素。化学法的产能受制于虾蟹等原料的产量, 无法满足日益增长的市场需求, 并且在水解生产过程中会导致较为严重的环境污染。相较于化学法, 利用微生物发酵的方式生产 GlcNAc, 既可以摆脱对于虾蟹等原材料的依赖, 并且对环境污染小。因此利用微生物发酵法生产 GlcNAc 已渐渐成为行业趋势。

目前行业中对于 GlcNAc 含量的检测方法包括: 高效液相色谱法(HPLC)^[5-6], 比色法以及电位滴定法。这 3 种检测手段虽然检测精度高, 但都属于化学方法检测, 在实际运用过程中需要经过采样-送检的环节, 检测时间长、无法做到实时在线测量。导致车间技术人员对生产过程参数调节存在滞后。

针对上述问题, 可以通过软测量的方式, 建立发酵过程 GlcNAc 含量的预测模型。BP 神经网络算法是目前应用十分广泛的建模算法, 其结构简单, 能够实现复杂的非线性映射问题。白书华等^[7]利用 PSO-GA-BP 算法建立了林火预测模型。花亚梅等^[8]在传统 BP 神经网络的基础上, 利用自适应学习率的方式, 建立了厌氧发酵产气量的软测量模型。朱湘临等^[9]利用 CS-BP 算法建立了松茸发酵过程菌丝生物量的预测模型。国内外研究者已将 BP 神经网络运用到短时交通流量预测^[10]、空气质量预测^[11]、神经网络图像复原^[12]、股价预测^[13]等多种研究领域。以上这些研究多是从神经网络结构方向进行优化, 通过对神经网络的初始权值、阈值或神经网络的学习率进行优化, 提高预测精度。而在实际的应用过程, 还存在样本中特征种类过多的问题。在神经网络训练过程中, 输入特征过多会影响模型训练速度, 特别是当使用群优化算法优化初始权值、阈值时, 每个种群的适应度计算都是一次训

练过程。另外输入特征过多会导致模型结构复杂, 降低模型泛化能力。

针对上述问题本文将随机森林算法、遗传算法及改进 BP 神经网络相结合, 以某氨基糖生产企业发酵过程中的数据为基础, 建立基于 RF-GA-BP 算法的 GINAc 含量预测模型。首先通过随机森林算法, 对所有的输入特征与 GINAc 含量进行关联性分析, 选择出与 GINAc 含量关联度较高的特征, 从而降低模型的复杂程度、提高训练速度。再通过遗传算法对神经网络的初始权值及阈值进行优化, 避免神经网络陷入局部最优点。

1 基本原理及方法

1.1 BP 神经网络

BP 神经网络结构简单, 通过误差反向传播原理对各层神经元的权值、阈值进行迭代, 每次迭代权值、阈值会向着减小输出误差的方向进行调整^[14]。BP 神经网络运算公式:

$$f(\mathbf{X}) = \mathbf{W}^T \times \mathbf{X} + b \quad (1)$$

式中: \mathbf{X} 为输入矩阵; \mathbf{W} 为权重矩阵; b 为阈值。

3 层的 BP 神经网络已经能够解决复杂的非线性映射问题。网络结构如图 1 所示。




图 1 BP 网络结构图

Fig. 1 Structure chart of BP network

1.2 随机森林(RF)特征选择原理

随机森林算法运用集成学习的思想, 通过构建多个决策树按一定策略进行预测。在每个决策树每个节点的构建过程中, 需要对所有的候选特征进行比较, 选择引起不纯度下降最大的特征与分裂值。对于回归问题一般采用方差度量不纯度。对于分类问题采用基尼不纯度或信息增益度量不纯度。

在随机森林算法的基础上，利用 Mean decrease impurity (平均不纯度减少)的思想对所有特征进行关联性分析^[15]。通过计算随机森林构建过程中各个特征的平均不纯度下降值来对特征的重要程度进行排序，特征引起的不纯度下降越高则越重要。

随机森林算法决策树生成步骤如下：

step 1: 遍历所有特征，对于特征 f_i ，遍历所有可能分类情况，计算均方误差(MSE)。选择均方误差最小的特征和切分点 s 。均方误差、目标函数计算公式：

$$MSE = \sum_{x \in R} (y_i - c_1)^2 + \sum_{x \in R} (y_i - c_2)^2 \quad (2)$$

$$\min_{j,s} [\min_{x \in R} (y_i - c_1)^2 + \min_{x \in R} (y_i - c_2)^2] \quad (3)$$

式中： R_1, R_2 为按切分点 s 分割形成的样本空间； c_1, c_2 为两样本空间平均输出值； y_i 为第 i 个样本的输出值。

step 2: 用选定的对 (j,s) 划分区域并求取相应的输出值。

区域划分规则：

$$R_1(j,s) = \{x | x^{(j)} \leq s\} \quad (4)$$

$$R_2(j,s) = \{x | x^{(j)} > s\} \quad (5)$$

输出值计算公式：

$$c_m = \frac{1}{N_m} \sum_{x \in R(j,s)} y_i \quad (6)$$

step 3: 重复执行 step 1~2, 直到样本空间为空、无法分割或满足其他停止条件。

step 4: 将输入空间划分为 M 个区域生成决策树：

$$f(x) = \sum_{m=1}^M c_m I \quad (7)$$

1.3 GA-BP 算法

BP 神经网络结构简单，能够解决复杂非线性映射。但 BP 神经网络的预测效果会受到初始权值、阈值的影响，多次训练预测效果可能差距较大。本文采用遗传算法对初始的权值、阈值进行优化。GA-BP 算法流程如图 2 所示，具体步骤如下：

step 1: 确定 BP 神经网络基本结构。包括：输入神经元个数、输出神经元个数、隐含层层数、隐含层数量、传递函数、学习率。

step 2: 编码。编码长度计算公式：

$$S = R \times S_1 + R \times S_2 + S_1 + S_2 \quad (8)$$

式中： S 为编码长度； S_1 为隐含层神经元数量； S_2 为输出层神经元数量； R 为输入层神经元数量。

step 3: 设计适应度函数。适应度函数用以度量每个个体的优劣程度。本文以 BP 神经网络预测指标 R^2 为基础设计适应度函数。

step 4: 初始化种群。

step 5: 按照 step 3 设计的适应度函数，计算种群的适应度值。

step 6: 以适应度值为依据，对种群进行选择、交叉、变异。

step 7: 若满足终止条件，结束。不满足条件则返回 step 5，直至满足终止条件。

step 8: 解码种群中最优个体，作为 BP 神经网络初始权值、阈值。训练神经网络。

step 9: 测试应用训练完成的神经网络。

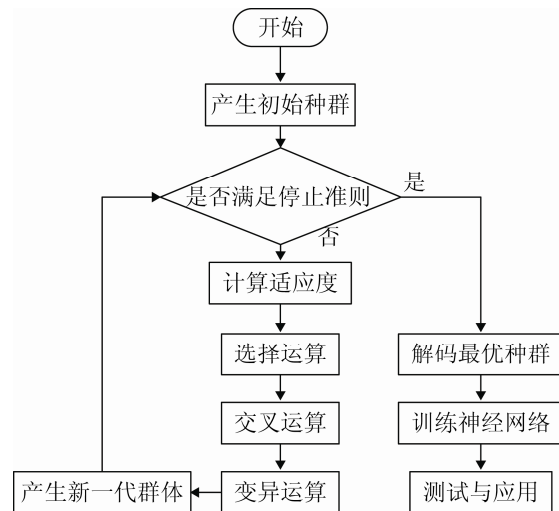


图 2 GA-BP 算法流程图

Fig. 2 Flow chart of GA-BP algorithm

1.4 BP 算法的改进

1.4.1 引入动量因子

传统 BP 神经网络采用梯度下降法进行权值修

正, 只考虑当前梯度方向。这种方法忽略了历史的梯度影响, 导致收敛速度慢。附加动量法基于指数加权平均的思想, 将历史梯度加权平均后附加在每次的更新中。若当前时刻梯度方向与历史时刻梯度方向相似, 则加强当前梯度变化; 反之则削弱当前时刻的梯度变化方向。通过引入动量因子可以有效的减小梯度下降过程中的震荡幅度, 提高收敛速度。

其权值更新公式为:

$$\Delta v(n) = -\eta \frac{\partial E}{\partial v(n)} + \alpha \Delta v(n-1) \quad (9)$$

$$\Delta w(n) = -\eta \frac{\partial E}{\partial w(n)} + \alpha \Delta w(n-1) \quad (10)$$

式中: α 为动量系数, $\alpha \in (0, 1)$ 。

1.4.2 引入自适应学习率

传统 BP 神经网络, 学习率为固定值, 容易导致训练时间过长或震荡。在神经网络训练初期由于远离最优点, 需要采用较大的学习率, 缩短训练时间; 在训练后期靠近最优点时, 需要采用较小的学习率来逼近最优值。

引用自适应学习率, 可以加速收敛过程, 增加稳定性。修正公式为:

$$\eta(n+1) = \eta(n) \times 2^{-\text{sign}[e(n)-e(n-1)]} \quad (11)$$

式中: $\eta(n)$ 为修正之前的学习率; $\eta(n+1)$ 为修正之后的学习率; $e(n)$ 为输出误差值。

2 RF-GA-BP 预测模型建立

2.1 数据来源

本次仿真所用数据来自某氨基糖生产企业, 选取该公司发酵过程中 25 批次(共 158 个样本)。每个样本中包含 14 个数据: 发酵周期、离线 PH、在线 PH、罐温、罐压、通气量、搅拌转速、DO 值、补糖速度、糖流量累计、OD 值、葡萄糖含量、谷氨酸含量、N-乙酰氨基葡萄糖含量。

2.2 模型构建流程

预测模型构建流程如图 3 所示。

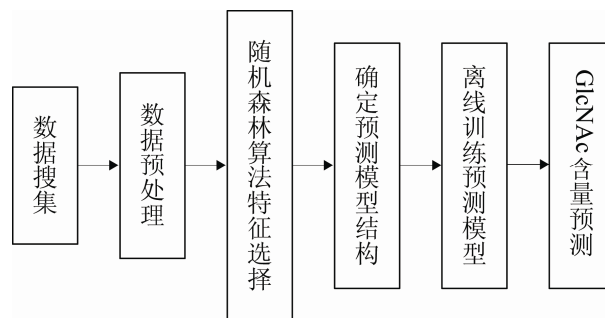


图 3 预测模型构建流程图

Fig. 3 Flow chart of constructing prediction model

2.3 数据预处理

2.3.1 样本筛选

目前该公司对于发酵过程中 N-乙酰氨基葡萄糖的测量采用的是采样-送检的方法, 无法做到在线测量。该公司一个发酵批次中只对部分周期的 N-乙酰氨基葡萄糖含量进行了测量。BP 神经网络是一种监督学习的算法, 需要去除掉没有含量的样本。

2.3.2 归一化

样本中的 13 个特征之间存在不同的量纲, 特征分散程度差异大, 无法直接进行比较。若不进行处理, 部分特征可能被忽视, 影响模型的预测精度。需要对每个特征序列的样本进行归一化。

归一化是一种简化计算的方式, 通过归一化将有量纲的表达式经过变换, 化为无量纲的表达式, 成为纯量^[16]。数据归一化计算公式:

$$X_{f_i_norm} = \frac{X_{f_i} - X_{f_i_min}}{X_{f_i_max} - X_{f_i_min}} \quad (12)$$

式中: X_{f_i} 为输入矩阵 X 中特征 f_i 的原始数据; $X_{f_i_max}$, $X_{f_i_min}$ 分别为输入矩阵 X 中特征 f_i 的最大值和最小值; $X_{f_i_norm}$ 为特征 f_i 归一化后的数据。

利用公式(12)将输入样本中所有的数据映射到[0,1]之间。消除由量纲问题引起的误差。

2.4 特征选择

为了提高模型的泛化能力、防止出现过拟合的情况, 需对采集到的 13 个输入特征进行分析, 从

中选择出与预测目标关联度最大的特征。采用随机森林算法进行建模,计算各输入特征的平均不纯度减少值,计算结果如表 1 所示。

表 1 各特征平均不纯度减少值
Tab. 1 Mean-decrease-impurity of each feature

序号	特征	平均不纯度减少
1	糖流量累计	0.434 4
2	周期	0.416 6
3	通气量	0.061 3
4	补糖速度	0.044 0
5	OD	0.035 0
6	罐温	0.003 6
7	葡萄糖含量	0.001 7
8	谷氨酸含量	0.000 9
9	在线 PH	0.000 7
10	离线 PH	0.000 7
11	搅拌转速	0.000 4
12	DO 值	0.000 3
13	罐压	0.000 3

对于输入特征的选择,过多会导致模型泛化能力弱,影响解空间的稳定性。过少会丢失有效信息,影响模型预测精度。本文根据表 1,选择平均不纯度减少最大的 5 个特征(糖流量累计、周期、通气量、补糖速度、OD)作为模型的输入特征。

2.5 预测模型训练

通过遗传算法对神经网络初始权值、阈值进行优化,采用神经网络拟合性能指标 R^2 作为适应度函数,设置种群规模 50,最大进化次数 100,交叉概率 0.4,变异概率 0.08。

本文神经网络的拓扑结构为 5-9-1,输入层神经元采用平均不纯度下降最大的 5 个特征;隐含层神经元个数为 9,隐含层神经元个数通过经验公式与试凑法确定;输出层神经元个数为 1,代表 N-乙酰氨基葡萄糖含量。神经网络参数设置如下:训练步数 1 000,目标误差 0.001,学习率 0.01。

为了对 RF-GA-BP 算法性能进行评估,利用相同的训练集分别建立了基于传统 BP 算法、GA-BP 算法与 RF-BP 算法的含量预测模型。

2.6 模型对比

GA-BP 模型与 RF-GA-BP 模型适应度值迭代情况如图 4 所示。GA-BP 模型经过 85 次迭代达到最大值,RF-GA-BP 模型经过 37 次迭代达到最大值。相较于 GA-BP 模型,RF-GA-BP 模型训练速度更快并且最终的适应度值更高。

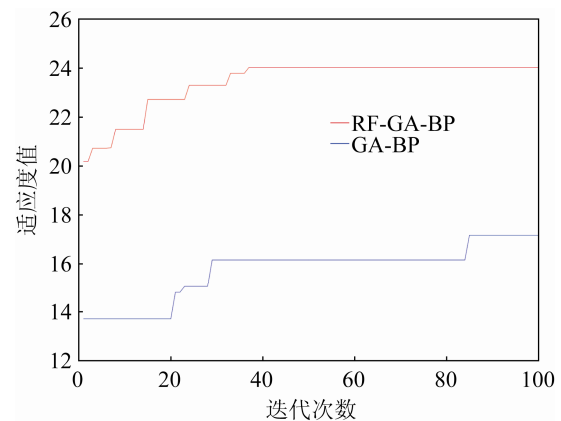


图 4 预测模型适应度曲线

Fig. 4 Adaptability curves of prediction models

运用训练好的 BP 模型、RF-GA-BP 模型、GA-BP 模型与 RF-BP 模型分别对同一测试集(共 25 样本)的数据进行预测。

利用平均绝对百分比误差(MAPE)与均方误差(MSE)对模型误差进行评价,计算公式分别为:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (13)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (14)$$

表 2 为 4 种预测模型的误差情况。可以看出,RF-BP 模型与 RF-GA-BP 模型的预测效果远好于 BP 模型与 GA-BP 模型。RF-GA-BP 模型的预测误差最小,平均误差小于 7%。

表 2 4 种模型均方误差、绝对百分比误差对比
Tab. 2 Comparison of MSE and MAPE between four models

预测模型	MSE	MAPE/%
BP 神经网络	87.06	17.74
GA-BP 神经网络	73.28	15.51
RF-BP 神经网络	21.42	8.37
RF-GA-BP 神经网络	13.64	6.29

图 5 为 4 种模型实际值与预测值拟合曲线。可以看出, RF-GA-BP 模型拟合效果最佳, 决定系数 (R^2) 达到 0.993 14。




图 5 4 种模型预测结果

Fig. 5 Prediction results of four models

图 6 为 4 种模型测试样本绝对误差。GA-BP 模型与传统 BP 模型相比, MAPE 降低了 2.23%。RF-GA-BP 模型与 RF-BP 模型相比, MAPE 降低了 2.08%。

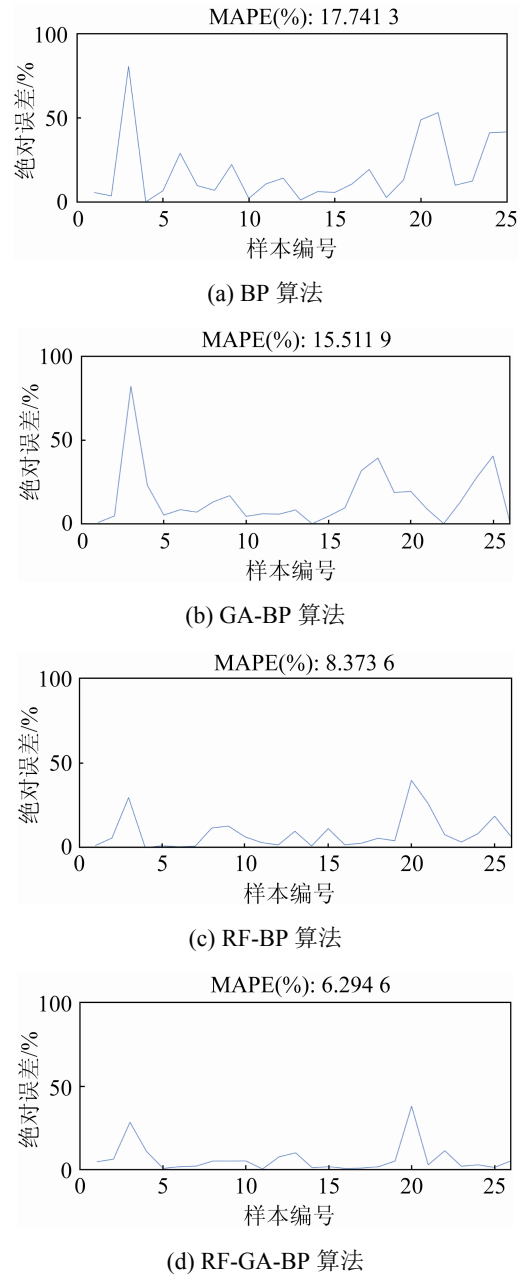


图 6 4 种模型预测绝对百分比误差

Fig. 6 MAPE of four models

通过加入 RF 算法进行特征选择后, BP 模型与 GA-BP 模型的 MAPE 分别降低了 9.36% 和 9.22%。

3 结论

本文针对氨糖发酵生产过程中, N-乙酰氨基葡萄糖含量难以在线的测量的问题, 提出了一种基于 RF-GA-BP 算法的预测模型。通过 Matlab 建模仿真, 该预测模型的预测平均绝对误差低于 7%, 预

测效果优于传统 BP 算法与 GA-BP 算法建立的模型。由于加入了 RF 算法进行特征选择, 模型的预测精度和收敛速度都得到了提升。

参考文献:

- [1] Dostrovsky N R, Towheed T E, Hudson R W, et al. The effect of glucosamine on glucose metabolism in humans: a systematic review of the literature[J]. *Osteoarthritis Cartilage* (S1063-4584), 2011, 19(4): 375-380.
- [2] Igarashi M, Sakamoto K, Nagaoka I. Effect of glucosamine, a therapeutic agent for osteoarthritis, on osteoblastic cell differentiation[J]. *Int J Mol Med* (S1107-3756), 2011, 28(3): 373-379.
- [3] El Sayed H El Ashry, Mohamed R E Aly. Synthesis and biological relevance of N-acetylglucosamine-containing oligosaccharides[J]. *Pure and Applied Chemistry* (S0033-4545), 2007, 79(12): 2229-2242.
- [4] 郑昭奕. 生物法生产 N-乙酰氨基葡萄糖[D]. 北京: 北京化工大学, 2018.
Zheng Shaoyi. Production of GlcNAc by biosynthesis[D]. Beijing: Beijing University of Chemical Technology, 2018.
- [5] 沈丹丹, 曾杰, 王玥, 等. HPLC 测定盐酸氨基葡萄糖有关物质与含量[J]. *中国药学杂志*, 2017, 52(4): 314-318.
Shen Dandan, Zeng Jie, Wang Yue, et al. Determination of Related Substances and Content of Glucosamine Hydrochloride by HPLC[J]. *Chinese Pharmaceutical Journal*, 2017, 52(4): 314-318.
- [6] 刘升涛, 李师, 尹鸿萍, 等. 高效液相色谱法测定氨基葡萄糖中的乙酰氨基葡萄糖[J]. *药物分析杂志*, 2015, 35(5): 900-905.
Liu Shengtao, Li Shi, Yin Hongping, et al. Determination of acetylglucosamine in glucosamine by HPLC[J]. *Chinese Journal of Pharmaceutical Analysis*, 2015, 35(5): 900-905.
- [7] 白书华, 况明星. 基于 PSO-GA-BP 神经网络的林火预测设计与研究[J]. *系统仿真学报*, 2018, 30(5): 1739-1748.
Bai Shuhua, Kuang Mingxing. Design and Study of Forest Fire Forecasting Based on PSO and GA-BP Neural Network[J]. *Journal of System Simulation*, 2018, 30(5): 1739-1748.
- [8] 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): 5951-5956.
Hua Yamei, Zhao Xianlin, Wang Xiaohua, et al. Prediction modeling for gas production of anaerobic fermentation based on improved BP neural network[J]. *Chinese Journal of Environmental Engineering*, 2016(10): 5951-5956.
- [9] 朱湘灵, 宋彦, 王博, 等. 基于改进布谷鸟算法-BP 神经网络的松茸发酵过程软测量建模[J]. *计算机测量与控制*, 2019, 27(5): 39-43.
Zhu Xiangling, Song Yan, Wang Bo, et al. Soft Sensor Modeling of Matsutake Fermentation Based on Improved CS-BPNN[J]. *Computer Measurement & Control*, 2019, 27(5): 39-43.
- [10] 黄小龙. 基于改进 BP 神经网络的城市客运班线客流预测研究[D]. 哈尔滨: 哈尔滨工业大学, 2019.
Huang Xiaolong. Study on Passenger Flow Prediction of Intercity Passenger Line Based on Improved BP Network[D]. Harbin: Harbin Institute of Technology, 2019.
- [11] 刘丹. 基于神经网络的哈尔滨城市空气质量预测研究[D]. 哈尔滨: 哈尔滨工业大学, 2018.
Liu Dan. Neural Network Based Prediction of Harbin Urban Air Quality[D]. Harbin: Harbin Institute of Technology, 2018.
- [12] 王海峰, 李萍, 王博, 等. 灰狼算法优化 BP 神经网络的图像去模糊复原[J]. *液晶与显示*, 2019, 34(10): 992-999.
Wang Haifeng, Li Ping, Wang Bo, et al. Image deblurring restoration of BP neural network based on grey wolf algorithm[J]. *Chinese Journal of Liquid Crystals and Displays*, 2019, 34(10): 992-999.
- [13] Zhang L, Wang F L, Xu B, et al. Prediction of stock prices based on LM-BP neural network and the estimation of over fitting point by RDCI[J]. *Neural Computing and Applications* (S0941-0643), 2018, 30(5): 1425-1444.
- [14] 孙禹. 基于神经网络和蚁群算法的木材干燥过程含水率预测研究[D]. 哈尔滨: 东北林业大学, 2018.
Sun Yu. Prediction of Moisture Content in Wood Drying based on Neural Network and Ant Colony Algorithm[D]. Harbin: Northeast Forestry University, 2018.
- [15] 周子程. 基于 Stacking 模型融合的电话客户信用度模型研究与设计[D]. 广州: 华南理工大学, 2011.
Zhou Zicheng. The Research and Design of Telecom Customer Credit Model Based on Stacking Model Fusion[D]. Guangzhou: South China University of Technology, 2011.
- [16] 李晨. 基于蚁群算法的改进型 BP 神经网络与应用[D]. 咸阳: 西北农林科技大学, 2018.
Li Chen. Improved BP Neural Network Based on Ant Colony Algorithm and Its Application[D]. Xianyang: Northwest A&F University, 2018.