

# 基于BP神经网络的煤炭含水率预测研究

刘 强<sup>1</sup>, 李 娜<sup>1</sup>, 张 淼<sup>1</sup>, 李 昊<sup>2\*</sup>, 栾佳星<sup>2</sup>, 张 帆<sup>2</sup>

<sup>1</sup>国能黄骅港务有限责任公司(河北), 河北 沧州

<sup>2</sup>中国矿业大学(北京)机电与信息工程学院, 北京

Email: 17110025@chnenergy.com.cn, 11330389@chnenergy.com.cn, miao.zhang.z@chnenergy.com.cn, \*lrt0335@163.com

收稿日期: 2020年12月16日; 录用日期: 2021年1月19日; 发布日期: 2021年1月27日

## 摘 要

长期以来, 环境监测和洒水抑尘是煤炭行业在煤炭存储环节重点关注的问题。加强煤炭堆场抑尘、防尘技术研究对解决煤尘排放, 减少空气污染, 实现绿色工业建设具有重要意义。为了加强对煤炭抑尘技术的研究和优化, 本文提出了一种基于深度学习BP神经网络的煤炭表层含水率预测方法。该方法通过分析和学习煤炭堆场周围环境变化对煤炭的影响, 实现了根据环境信息预测煤炭含水率变化的功能。实验结果表明, 该方法能够较为准确的预测煤炭表层含水率变化值, 预测误差小于20%。通过深度学习的预测方法代替传统的通过人为观测定时洒水, 能够实现高效抑尘和节约用水, 为堆场的防尘、抑尘工作提供了一种新的思路和重要的判断依据。

## 关键词

BP神经网络, 深度学习, 煤尘治理, 环境监测

# Research on Prediction of Coal Moisture Content Based on BP Neural Network

Qiang Liu<sup>1</sup>, Na Li<sup>1</sup>, Miao Zhang<sup>1</sup>, Hao Li<sup>2\*</sup>, Jiaying Luan<sup>2</sup>, Fan Zhang<sup>2</sup>

<sup>1</sup>Huanghua Harbor Administration Corp. (Ltd.), Cangzhou Hebei

<sup>2</sup>School of Electrical and Information Engineering China University of Mining and Technology (Beijing), Beijing

Email: 17110025@chnenergy.com.cn, 11330389@chnenergy.com.cn, miao.zhang.z@chnenergy.com.cn, \*lrt0335@163.com

Received: Dec. 16<sup>th</sup>, 2020; accepted: Jan. 19<sup>th</sup>, 2021; published: Jan. 27<sup>th</sup>, 2021

\*通讯作者。

文章引用: 刘强, 李娜, 张淼, 李昊, 栾佳星, 张帆. 基于BP神经网络的煤炭含水率预测研究[J]. 矿山工程, 2021, 9(1): 65-70. DOI: 10.12677/me.2021.91010

## Abstract

For a long time, environmental monitoring and water spraying to suppress dust have been the key concerns of the coal industry in the coal storage link. Strengthening the research of dust suppression and dust prevention technology in coal storage yard is of great significance to solve coal dust emission, reduce air pollution, and realize the construction of green industry. In order to strengthen the research and optimization of coal dust suppression technology, this paper proposes a coal surface moisture content prediction method based on deep learning BP neural network. This method realizes the function of predicting changes in coal surface moisture content based on environmental information by analyzing and learning the impact of environmental changes around the coal storage yard on coal. Experimental results show that this method can predict the change value of coal surface moisture content more accurately, and the prediction error is less than 20%. The prediction method of deep learning replaces the traditional timed sprinkling through artificial observations, which can achieve high-efficiency dust suppression and water conservation, and provide a new idea and important basis for the dust prevention and dust suppression work of the storage yard.

## Keywords

BP Neural Network, Deep Learning, Coal Dust Control, Environmental Monitoring

Copyright © 2021 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

煤炭堆存是煤炭供应链中不可缺少的加工环节之一。党的十八大以来，中央提出“创新、协调、绿色、开放、共享”五大发展理念，对环境保护给予史无前例的准确度。同时，国家对环保工作施以重拳，严管理、严标准，煤炭相关行业都处在风口浪尖。长期以来，煤炭堆场的粉尘污染抑制是环保整治的难题[1]。一方面，粉尘直接危害现场作业人员身体健康，造成难以估量的健康经济损失；另一方面，煤炭堆场扬尘会造成严重的空气污染，严重影响在周边地区生态建设。特别对于煤炭港口而言，近些年国内大力倡导生态港口建设，对煤炭港口的堆场抑尘方案提出了很高的要求[2]。在这种背景下，迫切需要加强堆场抑尘技术的优化研究，提升堆场抑尘流程的技术水平和工作效率。以国家能源集团黄骅港为例，随着京津冀地区环保建设需求的增加，黄骅港不断扩大投资开发清洁生产技术[3]。然而，很多技术应用在设备层的自动控制方面，未实现堆存煤炭随环境改变自适应的抑尘模式，煤炭港口在特殊天气下仍然受到粉尘污染的困扰。在抑尘策略方面，堆场采用洒水抑尘方案。具体而言，堆场每天固定三个时段对场内堆垛进行循环洒水，并在特殊天气采取人工控制的方式以调整洒水频次。线性的方案难以实现精准抑尘，并且会大大增加用水成本，甚至造成严重的水资源浪费。

近些年，随着计算机技术水平的进步，数据驱动的深度学习方法受到越来越多的关注。深度学习善于处理高度非线性的问题，因此也越来越多的被应用于工业工程领域[4] [5]。而本文针对抑尘流程优化问题，提出了基于深度学习 BP 神经网络算法的煤炭表层含水率预测方法。尝试通过该方法预测煤炭表层含水率的实时变化情况，以此取代人工靠经验观测起尘的方法，使得抑尘工作更加科学、高效。

## 2. 煤炭表层含水率预测流程

### 2.1. BP 神经网络概述

BP (Back Propagation)神经网络是一种使用梯度下降算法进行学习的多层前馈神经网络。它具有很强的非线性映射能力和泛化能力,可以从大量复杂的数据中学习规律[6] [7]。这也是为什么神经网络在高度非线性的工业过程建模中很受欢迎的原因。BP 神经网络是层结构的,它包含三个基本层:输入层、隐含层和输出层。隐含层可随意定义层数和神经元节点数。神经元节点是神经网络的基本单元,并且相邻两层神经元节点之间通过权重  $\omega$  和阈值  $\theta$  相互连接[8]。图 1 所示为 BP 神经网络基本结构图。注意,图 1 的这种三层网络结构图在用于解释 BP 神经网络机理的文献中很常见。BP 神经网络在训练过程中将不断更新权重,是能量函数值越来越小,预测结果也会越来越接近实际值。




Figure 1. Three-layer BP neural network structure principle  
图 1. 三层 BP 神经网络结构原理

### 2.2. 数据获取及数据预处理

本文针对黄骅港露天煤炭堆场内的煤炭堆垛进行分析,认为影响煤炭表层含水率变化的扰动因素主要为现场的环境和气象条件。因此,我们通过港内气象监测站和当地气象局数据中心收集到了大量气象、环境数据。此外,为了使环境变化与煤炭含水率变化建立关系,我们采集了大量堆垛表层煤样,通过烘干法获得其含水率数值,采样间隔为 1 小时。随后,我们将两类数据按照时间维度进行整合,整合结果如表 1 所示。

Table 1. Data set structure  
表 1. 数据集结构

煤种	时间	温度	风速	...	降水量	含水率
精块 2	08:30:00	23.9	8.9	...	0	10.7
精块 2	09:30:00	24.2	9.8	...	0	9.8
精块 2	10:30:00	24.1	8.5	...	0	8.5
精块 2	11:30:00	24.3	7.1	...	0	7.1
...	...	...	...	...	...	...

在构建数据集时,我们将煤种、时间、温度、湿度、气压、风速、降水量等作为样本特征,将含水率作为样本标签。为了使气象变化与含水率变化建立联系,我们将上一时刻样本的含水率添加为当前时刻的一项样本特征值,并称之“上一时刻含水率”。由于样本时间间隔固定为 1 小时,所以本文所能实现的即为预测未来 1 小时的煤炭含水率变化。

本例中，样本的特征变量是不同数量级的。为了提高数据的可比性同时削弱它们的解释性，我们引入 Z-score 数据标准化方法。Z-score 表示给定度量值偏离平均值的标准偏差数。换句话说，它只是重新缩放或标准化您的数据。Z-score 用于指定分布中每个观测值的精确位置。通过它能够将不同量级的数据转化为统一度量的分值。避免了大数项覆盖小数项导致小数项信息丢失问题。计算公式如下：

$$Z = \frac{X - \mu}{\sigma} \quad (1)$$

其中，X 表示原始分值，即样本原始特征值；μ 表示总体样本空间的分值均值，即特征 X 的均值；σ 表示总体样本空间的标准差，特征 X 的标准差。

本文所使用的数据集包含 2000 条数据，我们从中随机取 180 条数据作为测试数据集，其余作为训练数据集。

### 2.3. 算法流程

对于多层网络，开发人员首先需要对网络隐含层数和隐含层节点数进行选择，以达到尽可能理想的训练效果。理论上，三层神经网络可以在任何维度上完成映射。隐含层数越多网络解决问题的能力越强，但网络结构复杂化会使训练时间增加[9]。结合实际情况对比分析不同层数网络的收益，我们最终选择了 5 层神经网络结构。同样，通过对比不同隐含层节点数收益，我们最终将隐含层节点数设置为 8-16-32-16-1 的结构。

神经网络算法的工作流程大致可分为：数据预处理、训练模型、测试和优化模型。本文所搭建的 BP 神经网络算法流程如图 2 所示。

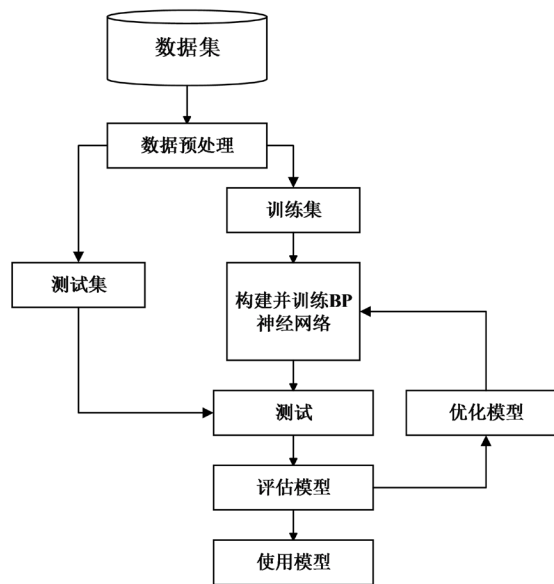


Figure 2. Neural network workflow

图 2. 神经网络工作流程

首先按照 2.2 节的方法对获取到的数据集进行预处理，使其更容易被神经网络读取和学习。随后，程序会将数据集划分成训练集和测试集，并将训练集按批次输入给搭建好的神经网络模型。经过反复训练，神经网络模型所输出的含水率预测值将不断的接近样本真实和含水率值。我们通过观察和记录二者间的误差变化，可以判断出模型的训练程度。待模型训练到设定好的批次后，使用测试集数据对其进行

测试和评估。若评估结果不理想，则通过调整模型隐含层结构、调整批大小、降低学习率等手段对其进行优化。反复训练直至模型达到预期效果。

### 3. 结果与分析

在训练阶段，我们将训练参数设置如下：模型训练运行 20,000 个 Epochs。批处理大小为 32。初始学习率为 0.01，每 5000 个 Epochs 指数衰减为原来的 0.1。由于数据量并不大，因此使用权重衰减的方法来减弱每个特征之间的过度交互，从而减轻过度拟合。使用随机梯度下降优化算法来优化权重。在训练过程中，我们记录每个 Epoch 的平均损失，并将其绘制成如图 3 所示的损失曲线。可以看出，随着训练批次的增加，损失值会不断降低，最终维持在 0.05 左右。




Figure 3. Loss curve of neural network training

图 3. 神经网络训练的损失曲线

损失值较低能够说明网络能够很好的拟合训练集数据，但对测试集的拟合效果并不能很好的预判。为了判断模型是否对训练集存在过拟合现象，我们使用测试集数据对其进行性能评估。我们将测试集数据的含水率实际值与模型的预测值进行了比较，并绘制了如图 4 所示的对比图。图中灰色柱体表示测试集数据的含水率实际值，红色曲线表示模型的预测结果。可以看出，模型对测试集数据的预测效果整体表现良好，少量样本的预测结果偏差较大。




Figure 4. Comparison of the model's prediction results on the test set and the actual value of the test set

图 4. 模型对测试集的预测结果与实际值的对比图

此外，我们计算了模型对测试集样本预测值的误差百分比，并绘制了如图 5 所示的误差分布图。该图能够更加清晰的观察模型预测误差的分布情况。可以看出，BP 神经网络对模型的预测误差整体小于 20%。对于堆场洒水抑尘问题，20% 的误差至多会带来约  $\pm 3$  的含水率偏差，满足洒水控制系统的准确度需求。极少量的样本点受极端天气因素影响，造成测试集气象数据异常，导致误差大于 30%。对于此类极端天气，本文建议堆场采用其他针对性的防尘措施，例如全局洒水等。




Figure 5. The model's prediction error distribution on the test set  
图 5. 模型对测试集的预测误差分布图

通过对图 3、图 4 和图 5 进行分析比较可以看出，BP 神经网络的预测结果较准确，预测精度较好，预测效果比较理想。基本能够满足工业生产对于煤炭表层含水率预测的准确度要求。

#### 4. 结论

该研究利用新颖的深度学习 BP 神经网络数据建模工具建立了煤的水分含量与风速，湿度和温度等环境因素之间的关系。结果表明该方法能够较好的实现对露天堆场煤炭表层含水率的预测，且预测结果较好，基本能够满足工业生产过程中洒水防尘的需求。通过预测煤中的水分含量，我们可以进一步预测何时煤堆会产生扬尘，引起粉尘污染，并通过及时开启洒水装置解决该问题。与传统的现行的洒水抑尘策略相比，我们的方法具有节省宝贵水资源和人力资源的潜力。

#### 参考文献

- [1] 卢斯琦, 赵廷宁, 辛智鸣, 段瑞兵, 肖辉杰. 矿区堆煤场不同煤尘抑制措施对比研究[J]. 生态与农村环境学报, 2020, 36(7): 945-952.
- [2] 张宇. 港口煤尘污染治理相关方式的分析与探究[J]. 四川水泥, 2020(3): 131.
- [3] 李艳明. 黄骅港生态港口建设思考与实践[J]. 港口科技, 2019(10): 9-12+48.
- [4] Ren, S., He, K., Girshick, R. and Sun, J. (2017) Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **39**, 1137-1149, <https://doi.org/10.1109/TPAMI.2016.2577031>
- [5] Redmon, J., Divvala, S., Girshick, R. and Farhadi, A. (2016) You Only Look Once: Unified, Real-Time Object Detection. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, 27-30 June 2016, 779-788. <https://doi.org/10.1109/CVPR.2016.91>
- [6] 杨丽, 吴雨茜, 王俊丽, 刘义理. 循环神经网络研究综述[J]. 计算机应用, 2018, 38(S2): 1-6+26.
- [7] 尹宝才, 王文通, 王立春. 深度学习研究综述[J]. 北京工业大学学报, 2015, 41(1): 48-59.
- [8] 常力丹, 梁志剑. 基于 BP 神经网络的煤炭成本预测研究[J]. 煤炭技术, 2019, 38(4): 180-182.
- [9] 杜严飞, 吴财芳, 杨庆龙, 薛佳佳. 基于人工神经网络的煤层气井产能预测研究[J]. 中国煤炭, 2012, 38(12): 9-13+17.