



## 基于气象因子深度学习的森林火灾预测方法

孙立研, 刘美玲, 周礼祥, 于洋

引用本文:

孙立研, 刘美玲, 周礼祥, 等. 基于气象因子深度学习的森林火灾预测方法[J]. 林业工程学报, 2019, 4(3): 132–136.

在线阅读 View online: <https://doi.org/10.13360/j.issn.2096-1359.2019.03.020>

---

### 您可能感兴趣的其他文章

Articles you may be interested in

#### 基于气象和时空因子的森林火险等级预测

Prediction of forest fire danger rating based on meteorological and space-time factors

林业工程学报. 2018, 3(3): 102–110 <https://doi.org/10.13360/j.issn.2096-1359.2018.03.017>

#### 基于卫星监测热点的林火分布及发生预报模型

Research on spatial distribution of forest fire based on satellite hotspots data and forecasting model

林业工程学报. 2017, 2(4): 128–133 <https://doi.org/10.13360/j.issn.2096-1359.2017.04.021>

#### 基于小波分析的我国森林草原火灾周期震荡研究

Studies on periodicity variation of forest and grassland fires in China based on wavelet analysis

林业工程学报. 2019, 4(2): 139–145 <https://doi.org/10.13360/j.issn.2096-1359.2019.02.022>

#### 基于粒子群算法和BP神经网络的多因素林火等级预测模型

A multi-factor forest fire risk rating prediction model based on particle swarm optimization algorithm and back-propagation neural network

林业工程学报. 2019, 4(3): 137–144 <https://doi.org/10.13360/j.issn.2096-1359.2019.03.021>

#### 广义线性模型在林火发生预报中的应用

Research on generalized linear models applied to forest fire forecast

林业工程学报. 2017, 2(1): 135–142 <https://doi.org/10.13360/j.issn.2096-1359.2017.01.024>

# 基于气象因子深度学习的森林火灾预测方法

孙立研<sup>1</sup>, 刘美玲<sup>1,2\*</sup>, 周礼祥<sup>1</sup>, 于洋<sup>1</sup>

(1. 东北林业大学信息与计算机工程学院, 哈尔滨 150040; 2. 哈尔滨工程大学计算机科学与技术学院, 哈尔滨 150001)

**摘要:** 森林火灾一旦发生将对生态系统造成严重的破坏, 间接导致气候的变化和极端天气频发。对森林火灾的发生进行准确预测可提前采取有效的防控措施, 具有重要意义。传统林火预测模型多为数学方法和浅层神经网络, 当数据量增大时易出现建模困难以及预测精度降低等问题。深度学习模型在处理大量非线性数据上具有一定的优势, 其模型具有多层网络结构, 通过训练大量数据可提取出具有代表性的特征值, 发现数据间的隐含关系, 达到准确分类预测的目的。因此, 本研究提出一种基于深度学习的林火预测方法, 将深度信念网络 (deep belief network, DBN) 作为预测模型, 气象因子作为输入数据, 以解决传统林火预测模型在面对大量数据时预测效果不佳的问题; 同时结合过采样 SMOTE (synthetic minority oversampling technique) 算法, 平衡林火数据集和增加训练数据量, 提升了森林火灾的预测准确度。结果表明, 在面对更大的数据量时, 该模型预测精度明显优于其他传统林火预测模型, 证明了将深度学习应用在林火预测的优越性。该研究可为深度学习在林业领域的应用提供参考。

**关键词:** 森林火灾; 预测模型; 气象因子; 深度信念网络; SMOTE 算法

**中图分类号:** S762.2      **文献标志码:** A      **文章编号:** 2096-1359(2019)03-0132-05

## Research on forest fire prediction method based on deep learning

SUN Liyan<sup>1</sup>, LIU Meiling<sup>1,2\*</sup>, ZHOU Lixiang<sup>1</sup>, YU Yang<sup>1</sup>

(1. College of Information and Computer Engineering, Northeast Forestry University, Harbin 150040, China;

2. College of Computer Science and Technology, Harbin Engineering University, Harbin 150001, China)

**Abstract:** In recent years, the number of occurrences of forest fire has been increased, which causes serious damage to the ecosystem, indirectly causing global warming and extreme weather. There is a clear feedback between climate change and forest fire. Climate change induces weather extremes, which leads to forest fires, while fire emissions contribute to climate change. Accurate prediction of the forest fire can enable relevant personnel to take effective prevention and control measures in advance. Controlling the occurrence of forest fire not only protects the ecological environment, but also greatly addresses climate issues, so accurate prediction of forest fires is of great significance. Traditional forest fire prediction models are mostly mathematical methods and shallow neural networks. They take the meteorological factors as the inputs to predict forest fire. When the amount of data increases, they are prone to be problems, such as modeling difficulties and reduced prediction accuracy. Deep learning has certain advantages in dealing with a large amount of nonlinear data, and its model has a multi-layer network structure. By training the deep learning model, more representative feature values can be extracted and the implicit relationship among data can be found, to achieve the purpose of accurate classification and prediction. Compared with the traditional fire prediction model, the deep learning model has a deep network, and the parameters can be adjusted autonomously through the training data, which is suitable for a large amount of nonlinear data. Therefore, this study used the deep belief network (DBN) in the deep learning model as the predictive model and the meteorological factor as the input data to solve the problem that the traditional forest fire prediction model could not predict well when faced with large amounts of data. In this study, the SMOTE (synthetic minority oversampling technique) algorithm was combined with DBN to balance the forest fire data set and increase the amount of training data, which made the forest fire data more suitable for DBN. As a result, the prediction accuracy of forest fire was improved. The prediction result of the model was compared with the support vector machine (SVM) and back propagation (BP) models. The modeling results showed that the prediction accuracy of the model can reach 84%, which was obviously better than SVM and BP network. It was demonstrated the

收稿日期: 2018-09-17

修回日期: 2018-12-14

基金项目: 国家自然科学基金(61702091); 中央高校基本科研业务费专项基金(2572018BH06)。

作者简介: 孙立研, 男, 研究方向为林业信息工程、机器学习、数据挖掘。通信作者: 刘美玲, 女, 讲师。E-mail: mlliu@nefu.edu.cn

superiority of applying deep learning to forest fire prediction. This study can provide a theoretical foundation for the application of deep learning in the field of forestry.

**Keywords:** forest fire; prediction model; meteorological factor; deep belief network; SMOTE algorithm

森林火灾危害巨大,不仅给社会经济造成了严重损失,更严重威胁到林业可持续发展和人民生命财产安全<sup>[1]</sup>。众多学者基于气象因子建立林火预测模型,实现对森林火灾的预测<sup>[2-3]</sup>。大量研究表明,温度、湿度和风速等是影响森林火灾发生的主要气象因子<sup>[4-6]</sup>。杨景标等<sup>[7]</sup>采用BP神经网络构建林火预测模型,将广东省2000年全年的气象因子作为输入,火灾情况作为输出,证明了利用BP网络预测林火发生的可行性。但受限于浅层网络结构,仅能保证处理少量数据的准确度,并且易出现过拟合现象。许志卿等<sup>[8]</sup>通过气象因子预测森林火险等级,采用自定义核函数的支持向量机构建预测模型,具有较高的预测准确率,但存在数据量增加时预测精度降低的问题。

深度学习是机器学习研究中的热门领域<sup>[9]</sup>,其实质是构建具有多个层次的机器学习架构模型,通过大量训练自主学习到具有代表性的特征信息<sup>[10]</sup>,再利用训练后的模型达到分类预测的目的。深度信念网络(deep belief network, DBN)作为一种热门的深度学习模型已经被广泛应用到人脸识别<sup>[11]</sup>、植物叶片识别<sup>[12]</sup>、情感分析<sup>[13]</sup>等各个领域,都取得了巨大的成功。该模型分类准确度高,适用于大量的、非线性的数据,无论是处理复杂图像还是大量无标签数据都能从中自动提取到有效的特征信息。但目前罕有学者利用深度学习模型进行森林火灾预测的研究报道。

针对上述问题,本研究提出基于深度学习的林火预测模型。该模型将过采样SMOTE算法与DBN网络结合,通过SMOTE算法平衡林火数据中的数据类别,增加DBN网络的训练数据量,提升预测精度,较好地解决了数据量增加的传统模型预测精度下降的问题。

## 1 数据采集与研究方法

### 1.1 数据来源

实验(一)数据来源于UCI<sup>[14]</sup>机器学习数据库,共517条林火数据。该数据为2000—2003年葡萄牙Montesinho自然森林公园中心气象站获得的气象资料,其中包括气温、相对湿度、风速和降雨量等气象数据及其对应的火灾面积。部分数据见表1。

表1 实验(一)部分数据集

Table 1 Experiment (1) partial data set

序号	气温/ ℃	相对湿度/ %	风速/ (km·h <sup>-1</sup> )	降雨量/ (mm·m <sup>-2</sup> )	起火面积/ hm <sup>2</sup>
1	8.2	51	6.7	0	0
2	18.0	33	0.9	0	0
3	14.6	33	1.3	0	0
4	8.3	97	4.0	0.2	0
5	21.2	70	6.7	0	11.16
6	22.2	29	5.4	0	0
7	24.1	27	3.1	0	0
8	8.0	86	2.2	0	0
...	...	...	...	...	...
517	13.1	63	5.4	0	0

实验(二)数据为黑龙江省大兴安岭塔河气象站(国家标准气象站号50246)1974—2008年的数据。该研究区地处北温带,属寒温带大陆性气候,受大陆和海洋季风更替的影响,季节变化显著。年均气温-2.4℃,年均降水量463.2mm,且主要集中在7—8月。该地区森林覆盖率为81%,为火灾易发区。

### 1.2 数据准备与预处理

将两种研究区的实验数据整理成相同形式的4种气象因子及火灾情况,一种进行正常的预测实验,另一种作为模型检验,两种实验流程基本一致。

将已有的气象数据以及过采样处理后的数据(日均气温、相对湿度、风速、降水量)使用MATLAB中的mapminmax函数归一化至数值[0, 1],使所有输入数据适用于本研究中的模型,归一化函数原理见公式(1)。

$$y = \frac{(y_{\max} - y_{\min}) \times (x - x_{\min})}{x_{\max} - x_{\min}} \quad (1)$$

式中: $x$ 为未处理的数据; $x_{\max}$ 、 $x_{\min}$ 为该类数据中的最大、最小值; $y$ 为归一化后的数据; $y_{\max}$ 、 $y_{\min}$ 分别为1、0(归一化至[0, 1])。

将火灾发生时赋予数值1,不发生火灾赋予数值0,即通过输出数值0或1来预测是否发生火灾。同时将数据集去噪,去除缺失值等。

### 1.3 SMOTE 算法

SMOTE是一种被广泛应用的过采样方法<sup>[15-17]</sup>。利用人工添加少数类样本的方法来解决数据集不平衡的问题。该算法的思想是随机选取少数类样本中一点作为中心样本点,并在该点与其

近邻的若干个样本的连线上,随机地插入若干个新合成的少数类别样本。随机插值原理如公式(2)所示。

$$y = \text{rand}(0,1) \times x + [1 - \text{rand}(0,1)] \times r \quad (2)$$

式中: $x$ 为选定的中心样本点; $r$ 为该中心点的任一近邻点; $y$ 为新合成的数据点。

### 1.4 深度信念网络 DBN

深度信念网络是由多个受限的 Boltzmann 机 (restricted Boltzmann machine, RBM) 和一层 BP 神经网络组成的深层神经网络<sup>[18-19]</sup>,基本结构如图1所示。每个 RBM 包含可视层和隐含层,层内神经元间无连接,两层之间神经元全连接。训练过程是从最底层的 RBM 开始接收数据,各层 RBM 无监督地逐层贪婪训练,获得生成模型的权值。在顶层利用 BP 网络引入标签数据,反向有监督地调整模型的判别性能。




图1 DBN 结构图

Fig. 1 Deep belief network structure chart

整个训练过程分成两个阶段:预训练和微调。第1阶段无监督地训练 RBM,保留特征信息;第2阶段通过 BP 网络接收特征信息并有监督微调整个 DBN 网络。

### 1.5 S-DBN 模型

传统 DBN 模型虽然具有多层网络结构,但在训练数据不足以及数据类别不平衡的条件下,模型分类预测的效果欠佳。因此,本研究在传统 DBN 的输入数据层添加 SMOTE 算法,对输入数据进行过采样处理,平衡数据集的同时增加了训练数据量。将融合 SMOTE 算法的 DBN 模型命名为 S-DBN 预测模型,其网络结构如图2所示。

在数据输入前先经过 SMOTE 算法进行过采样处理,然后逐层训练 RBM,获取其可视层和隐含层

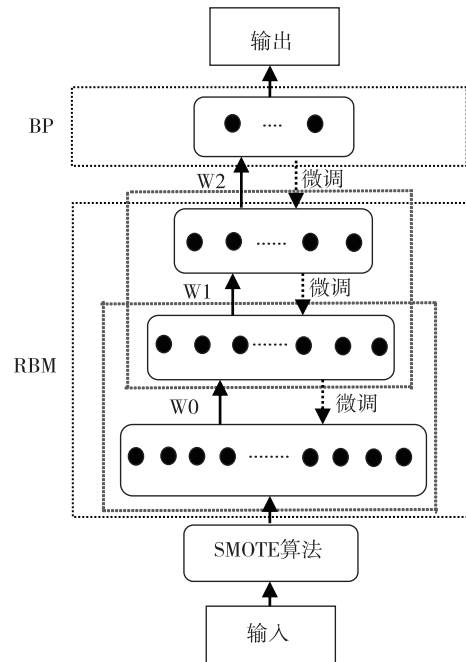


图2 S-DBN 结构图

Fig. 2 S-DBN structure chart

间的权值和偏置值。其训练的本质是 RBM 可视层接收数据并通过一个向量将特征值传到隐含层,确定了可视层和隐含层间的权重参数。训练完毕的 RBM 隐含层将作为下一层未经训练 RBM 的可视层接收数据,重复之前的步骤,直到所有 RBM 都被训练,完成模型各个参数的初始化工作。其中, RBM 神经元设定为二值变量,能量函数如公式(3)所示。

$$E(v, h | \theta) = - \sum_{i=1}^n \sum_{j=1}^m v_j W_{ij} h_i - \sum_{j=1}^m b_j v_j - \sum_{i=1}^n c_i h_i \quad (3)$$

式中: $v$ 为可见层神经单元; $h$ 为隐含层神经单元; $\theta = \{W, b, c\}$ ,为 RBM 参数集; $W$ 为可见层神经元与隐含层间的连接权值; $b$ 和  $c$  分别为显层和隐层的偏置; $m$ 和  $n$  分别为该层的神经元个数。

顶层 BP 网络作为有监督的分类器,激励函数选取 Sigmoid 函数。该函数如公式(4)所示。

$$f(x) = \frac{1}{1 + e^{-x}} \quad (4)$$

## 2 结果与分析

### 2.1 林火预测流程

首先构造 S-DBN 林火预测模型,将预处理(归一化以及过采样处理)完毕的数据分为训练集和测试集,其中训练集和测试集都分为普通数据集和标签集。通过带有标签的训练数据集训练 S-DBN 模型,使其通过训练具有分类预测的能力,之后将

测试数据集代入训练好的 S-DBN,使最终的输出结果与测试标签集进行比对,得出预测准确度。预测流程如图 3 所示。

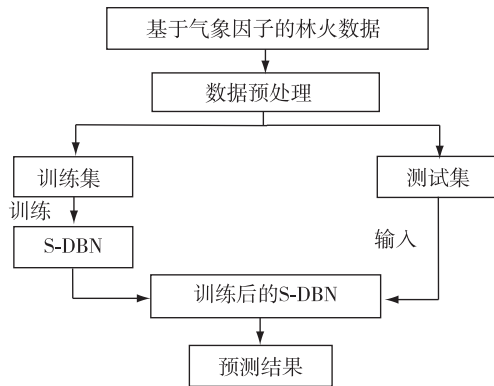


图 3 预测流程图  
Fig. 3 Forecast flow chart

S-DBN 的各个训练参数需要被提前设置。本研究中,输入层节点数设置为 4(4 种气象数据),输出层节点数为 2,即两种火灾情况(火灾发生或火灾不发生),其余模型参数需根据实验确定。

2.2 实验内容

实验硬件环境为 Windows 7 专业版 64 位, Intel (R) Core(TM) i7-6700 CPU@ 3.40GHz, 4 G 内存, MATLAB 2015b 深度学习工具箱 (<https://github.com/rasmusbergpalm/DeepLearnToolbox>)。

通过 S-DBN 将研究区(一)的数据量添加扩充到 5 000 条带标签的林火数据,其中起火数据 2 400 条,非起火数据 2 600 条。部分数据见表 2,其中火灾情况 0 表示未发生火灾,1 表示发生火灾。

将所有数据预处理,整理为适用于 S-DBN 的数据集。实验使用 K 折交叉验证方法,将 K 取 10。即将所有气象数据随机等分为 10 份,9 份输入到 S-DBN 作为训练数据,最后一份为测试数据,取 10 次实验结果的平均值作为最终结果。使模型从有限的数据集中得到充分训练,获取更多有效的信息,同时可以在一定程度上减小过拟合现象。

需通过大量实验,确定 S-DBN 模型的初始参数(RBM 层数,每层 RBM 的隐含层结点等)。将 1~5 分别设置为 RBM 层数,5~20 设置为隐含层节点数,其余参数设置为工具箱内默认值。经过多次实验,确定出得到最高预测精度的各个参数值。再将确定的参数值略微调整,如调整参数后的预测精度低于参数调整前的预测精度,则将原参数值确定为最优参数值,避免了偶然现象的发生。在实验(一)中,最终的参数设定为 3 层 RBM 结构,隐含层节点 10,迭代次数 50,学习率 0.001。

表 2 添加后的部分数据  
Table 2 Partial data table after addition

序号	气温/ ℃	相对湿度/ %	风速/ (km·h <sup>-1</sup> )	降雨量/ (mm·m <sup>-2</sup> )	火灾情况 (0,1)
1	8.2	51	6.7	0	0
2	18.0	33	0.9	0	0
...	...	...	...	...	...
1 000	27.3	63	4.9	0	1
...	...	...	...	...	...
4 995	27.8	35	2.7	0	1
4 996	27.8	32	2.7	0	1
4 997	21.9	71	5.8	1.4	0
4 998	21.2	70	6.7	0	0
4 999	25.6	42	4.0	0	0
5 000	11.8	31	4.5	0	0

本研究中将塔河研究区的数据作为实验(二)来进行模型检测,其实验流程同实验(一)基本一致。将 1974—2007 年数据作为训练数据,将 2008 年数据作为测试数据,得出预测精度。最终的参数设定为 5 层 RBM,隐含层节点 10,学习率 0.01。

2.3 预测结果对比

本研究将预测精度,即预测正确率表示为林火预测结果,具体方式见公式(5)。

$$r = s/n \tag{5}$$

式中:s 为输出结果与测试标签集对比结果相同的个数;n 为标签集总个数;r 为预测精度。

运用 MATLAB 工具箱中 BP 神经网络和 SVM 支持向量机模型,将相同数据集代入其中,并将各模型预测结果进行比对,将实验(二)的预测结果与文献[2]中的随机森林算法进行比较。比对结果见表 3。其中,上标 1 代表使用研究区(一)的数据,2 代表使用研究区(二)的数据。

表 3 预测结果对比  
Table 3 Comparison of prediction results

预测方法	平均预测精度/%
文献[7]的 BP <sup>1</sup>	57
S-BP <sup>1</sup>	55
文献[8]的 SVM <sup>1</sup>	79
S-SVM <sup>1</sup>	75
DBN <sup>1</sup>	73
S-DBN <sup>1</sup>	84
文献[2]的随机森林 <sup>2</sup>	83
S-DBN <sup>2</sup>	85

由表 3 可知,经过 SMOTE 算法提升数据量以后,传统预测模型 BP、SVM 的预测精度均有下降,而本研究提出的 S-DBN 林火预测模型的预测精度明显优于其他预测模型;实验(二)中的结果同样证明了在采用相同数据的条件下,S-DBN 具有较高的预

测精度。其主要原因是过采样处理后数据类别达到平衡,训练数据充足,深度信念网络的多层训练网络逐层学习提取有效的特征值,优化分类预测的结果。充分表明深度学习模型更适用于大量数据的分类预测,符合林业大数据时代的研究趋势。

### 3 结 论

本研究将 SMOTE 算法与 DBN 结合,通过将气象因子作为输入,对葡萄牙 Montesinho 自然森林公园和塔河地区的林火情况进行预测。实验结果表明,在数据量增加的情况下,该模型具有较高的林火预测准确度,明显优于其他传统林火预测模型;多层网络结构可逐层学习特征信息,自主调整训练参数,解决了传统预测模型在面对大量数据时预测精度不高以及建模困难等问题。实验结果也从侧面表明将深度学习应用在林业大数据分析领域的可行性。

本研究主要基于气象因子对林火进行预测,对其他诱火因子(如植被可燃物因子、地形地貌因子等)考虑较少,S-DBN 预测精度仍有较大的提升空间。下一步将利用更多的诱火数据,优化深度学习模型,进一步提升对森林火灾的预测准确度。

#### 参考文献(References):

- [1] 苏立娟,何友均,陈绍志. 1950—2010年中国森林火灾时空特征及风险分析[J]. 林业科学, 2015, 51(1): 88-96. DOI: 10.11707/j.1001-7488.20150110.
- SU L J, HE Y J, CHEN S Z. Temporal and spatial characteristics and risk analysis of forest fires in China from 1950 to 2010[J]. Scientia Silvae Sinicae, 2015, 51(1): 88-96.
- [2] 梁慧玲,林玉蕊,杨光,等. 基于气象因子的随机森林算法在塔河地区林火预测中的应用[J]. 林业科学, 2016, 52(1): 89-98. DOI: 10.11707/j.1001-7488.20160111.
- LIANG H L, LIN Y R, YANG G, et al. Application of random forest algorithm on the forest fire prediction in Tahe area based on meteorological factors[J]. Scientia Silvae Sinicae, 2016, 52(1): 89-98.
- [3] 潘登,郁培义,吴强,等. 基于气象因子的随机森林算法在湘中丘陵区林火预测中的应用[J]. 西北林学院学报, 2018, 33(3): 169-177. DOI: 10.3969/j.issn.1001-7461.2018.03.26.
- PAN D, YU P Y, WU Q, et al. Application of random forest algorithm on the forest fire prediction based on meteorological factors in the hilly area, central Hunan province[J]. Journal of Northwest Forestry University, 2018, 33(3): 169-177.
- [4] 郑琼,邸雪颖,金森,等. 伊春地区 1980—2010 年森林火灾时空格局及影响因子[J]. 林业科学, 2013, 49(4): 157-163. DOI: 10.11707/j.1001-7488.20130424.
- ZHENG Q, DI X Y, JIN S, et al. Temporal and spatial patterns of forest fires in Yichun area during 1980-2010 and the influence of meteorological factors[J]. Scientia Silvae Sinicae, 2013, 49(4): 157-163.
- [5] BONORA L, CHECCACCI E, ROMANI M, et al. Correlation between meteorological data and fire occurrence in a Mediterranean area (Tuscany Region)[J]. Forest Ecology and Management, 2006, 234: S63. DOI: 10.1016/j.foreco.2006.08.091.
- [6] 陈锋,林向东,牛树奎,等. 气候变化对云南省森林火灾的影响[J]. 北京林业大学学报, 2012, 34(6): 7-15. DOI: 10.13332/j.1000-1522.2012.06.010.
- CHEN F, LIN X D, NIU S K, et al. Influence of climate change on forest fire in Yunnan Province, southwestern China[J]. Journal of Beijing Forestry University, 2012, 34(6): 7-15.
- [7] 杨景标,马晓茜. 基于神经网络预测广东省森林火灾的发生[J]. 林业科学, 2005, 41(4): 127-132. DOI: 10.3321/j.issn:1001-7488.2005.04.022.
- YANG J B, MA X X. On the basis of artificial neural network to forecast the forest fire in Guangdong province[J]. Scientia Silvae Sinicae, 2005, 41(4): 127-132.
- [8] 许志卿,苏喜友,张颐,等. 基于支持向量机方法的森林火险预测研究[J]. 中国农学通报, 2012, 28(13): 126-131. DOI: 10.3969/j.issn.1000-6850.2012.13.023.
- XU Z Q, SU X Y, ZHANG Y, et al. Forest fire prediction based on support vector machine[J]. Chinese Agricultural Science Bulletin, 2012, 28(13): 126-131.
- [9] 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. DOI: 10.11936/bjtxb2014100026.
- YIN B C, WANG W T, WANG L C. Review of deep learning[J]. Journal of Beijing Polytechnic University, 2015, 41(1): 48-59.
- [10] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444. DOI: 10.1038/nature14539.
- [11] 柴瑞敏,曹振基. 基于 Gabor 小波与深度信念网络的人脸识别方法[J]. 计算机应用, 2014, 34(9): 2590-2594. DOI: 10.11772/j.issn.1001-9081.2014.09.2590.
- CHAI R M, CAO Z J. Face recognition algorithm based on Gabor wavelet and deep belief networks[J]. Journal of Computer Applications, 2014, 34(9): 2590-2594.
- [12] 刘念,阙江明. 基于多特征融合和深度信念网络的植物叶片识别[J]. 北京林业大学学报, 2016, 38(3): 110-119. DOI: 10.13332/j.1000-1522.20150267.
- LIU N, KAN J M. Plant leaf identification based on the multi-feature fusion and deep belief networks method[J]. Journal of Beijing Forestry University, 2016, 38(3): 110-119.
- [13] MANNEPALI K, SASTRY P N, SUMAN M. A novel adaptive fractional deep belief networks for speaker emotion recognition[J]. Alexandria Engineering Journal, 2017, 56(4): 485-497. DOI: 10.1016/j.aej.2016.09.002.
- [14] MERZ C, MURPHY P. UCI repository of machine learning databases[DB/OL]. ftp://ftp.ics.uci.edu/pub/machinelearning-databases.
- [15] 封化民,李明伟,侯晓莲,等. 基于 SMOTE 和 GBDT 的网络入侵检测方法研究[J]. 计算机应用研究, 2017, 34(12): 3745-3748. DOI: 10.3969/j.issn.1001-3695.2017.12.051.
- FENG H M, LI M W, HOU X L, et al. Study of network intrusion detection method based on SMOTE and GBDT[J]. Application Research of Computers, 2017, 34(12): 3745-3748.
- [16] VERBIEST N, RAMENTOL E, CORNELIS C, et al. Preprocessing noisy imbalanced datasets using SMOTE enhanced with fuzzy rough prototype selection[J]. Applied Soft Computing, 2014, 22: 511-517. DOI: 10.1016/j.asoc.2014.05.023.
- [17] DOUZAS G, BACAO F, LAST F. Improving imbalanced learning through a heuristic oversampling method based on k-means and SMOTE[J]. Information Sciences, 2018, 465: 1-20. DOI: 10.1016/j.ins.2018.06.056.
- [18] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554. DOI: 10.1162/neco.2006.18.7.1527.
- [19] HINTON G E. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507. DOI: 10.1126/science.1127647.

(责任编辑 田亚玲)