

通用场景火灾发展趋势实时预测技术研究

郭美丽¹,江 晓²

(1.烟台职业学院 电气与电子工程系,山东 烟台 264003;2.山东衡昊信息技术有限公司 研发部,山东 烟台 264003)

摘要:火灾发展趋势的预测对于火场人员疏散和制定灭火政策具有重要的指导意义,本文首先对火灾图像进行预处理以及强化处理,利用不同状态下火灾图像火苗强度的对比判定火灾类型,并在此基础上对监控区域进行网格处理;然后基于广义回归神经网络(general regression neural network,GRNN)进行模型构建,采用输入层、模式层和求和层神经元个数相同的网络结构,利用分类神经网络预测边缘网格的状态,进而对火灾发展趋势做出预测。本文提出的火灾发展趋势实时预测技术针对不同火灾场景不需要分别建立模型,可以广泛适用于各种火灾场景。

关键词:通用场景;火灾发展趋势;实时预测;神经网络;GRNN

中图分类号:TP183 **文献标志码:**A **文章编号:**1673-8020(2023)02-0172-07

火灾发展趋势的预测对于指导火场人员疏散和制定灭火决策具有重要的意义。目前应急和消防业内大批学者针对各类场景都进行了相关研究,并提出了理论上的方法。例如,辛晶等^[1]提出建筑物火灾蔓延机理及概率模型;黄维章等^[2]提出了城市火灾蔓延的数学模型和计算机模拟;黄奇晓^[3]通过皮尔逊相关分析法与斯皮尔曼相关分析方法对气象因子与森林火灾进行相关分析验证,构建气象因子—森林火灾预测模型,为森林火灾防范工作提供更为科学的理论依据。这些研究均较好地解决了特定场景下火灾蔓延的数学模型问题。卢岚^[4]提出的安全工程和范维澄等^[5]的火灾风险评估方法学对于同类研究具有很好的指导作用。但是实际中火灾现场往往比较复杂,不确定因素较多,采用理想状态下的数学模型往往造成较大误差,很难起到预先性的指导作用。

近几年随着计算机图像处理、神经网络和深度学习相关研究的发展,在火灾的隐患识别、初起火灾判断中已有较成熟的应用,且实际应用中的准确率已经达到了90%以上;另一方面,利用神经网络和深度学习技术良好的泛化性能,可很好地抵消火灾过程中影响因素突变对数学模型产生的影响。GRNN作为一种建立在数理统计基础上

的神经网络,具有学习速度快、逼近能力强、调节参数少等优点,在系统辨识和预测控制等方面有不少应用实例^[6-11]。为解决火灾发展趋势实时预测过于依赖火灾场景和干扰因素的问题,本文基于图像处理相关技术,采用网格模型,探索使用GRNN神经网络,利用分类神经网络预测边缘网格的状态,进而对火灾发展趋势做出预测。

1 系统概述

火灾发展趋势预测系统构成如图1所示。系统工作过程如下。

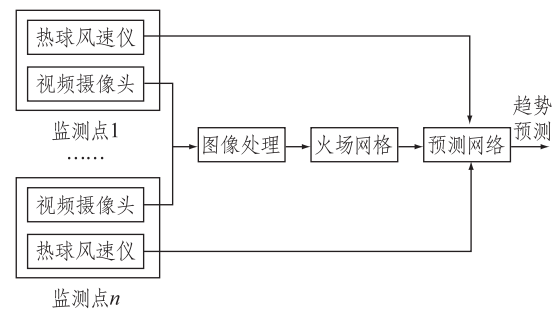


图1 火灾发展趋势预测系统构成

Fig.1 The composition of fire development trend prediction system

收稿日期:2022-11-01;修回日期:2023-02-15

基金项目:山东省自然科学基金(ZR2019PF018)

通信作者简介:郭美丽(1977—),女,讲师,硕士,研究方向为信息技术及通信技术。E-mail:419873131@qq.com

1) 火苗检测及图像传输

在火灾现场设置 n 个监测点,每个监测点安装热球风速仪和视频摄像头。热球风速仪检测风速以获取气流方向,视频摄像头实时获取图像数据以及视频图像数据。首先通过视频摄像头搭配现有图像识别软件精准检测出是否有火苗;当检测到火苗后,将采集到的火灾图像传送至图像处理模块。

2) 图像处理及火灾类型判断

(1) 火灾图像预处理。在图像处理模块中,通过对原始火灾图像进行灰度化预处理得到灰度图像,完成对火灾图像的降维,以提高后续图像处理运算速度。

(2) 火灾图像强化处理。将灰度化后的火灾图像进行强化处理:先对灰度图像的像素值求取中值序列,再对像素值的中值序列求取均值,最后利用均值对灰度图像进行二值处理,得到滤波后强化处理的火灾图像。

(3) 火灾类型判断。强化后的火灾图像突出了火苗部分的特征,根据前后两个状态的火苗扩散状态对比进一步判断当前火灾类型。

3) 划分火场网格

根据火灾现场监控区域关注方向进行合适的网格划分。每个网格具有两个状态:状态 1 表示该网格过火,状态 0 表示该网格尚未过火。对火灾发展趋势的预测,实际变为对网格状态值的计算与预测。

4) 构建预测网络

利用影响网格状态值的因素(火灾类型、气流矢量(流向、流速)、网格风口状态、阻挡状态)作为输入构建预测网络,预测火苗边缘网格的状态,进一步得到火灾发展趋势的预测结果。

2 火灾图像处理

2.1 火灾图像预处理

在对火灾图像进行相关处理时,不需要对原始火灾图像进行色彩分析,只需对火苗形态特征信息进行提取。为此,先对原始火灾图像进行灰度化预处理,再进行降维,在保留图像的梯度信息的同时运算速度可大幅度提高。

采用移位灰度处理法将火灾图像转换成灰度图像,公式如下:

$$\begin{cases} Gray^s(g^s) = F(F(R,G,B)), \\ F(F(R,G,B)) = (76R+151G+28B) \gg 8, \end{cases} \quad (1)$$

其中, $F^s(R,G,B)$ 表示状态 s 下的火灾源图像; $Gray^s(g^s)$ 表示状态 s 下的灰度图像, $R = G = B = g^s$; $F(\cdot)$ 表示移位灰度处理法的移位函数。

火灾图像的灰度处理效果对比如图 2 所示。



(a) 火灾原始图像



(b) 火灾图像的灰度图像

图 2 火灾图像的灰度处理效果对比

Fig.2 Comparison of grayscale processing effects of fire images

2.2 火灾图像强化处理

假设灰度图的像素为 $m \times n$, 对灰度图像 $Gray^s(g^s) 5 \times 5$ 像素框中的 25 个像素依次求中值,具体滤波处理的过程如下:

1) 求取中值序列

设像素框中第 i 个像素的灰度值为 $g_i^s, i \in [1, 25]$ 。依次求得 5×5 像素框的中值,从灰度图像中的 5×5 像素框中,取 25 个像素的灰度值 $g_i^s, i \in [1, 25]$,并按从小到大排序,得到序列 $[g_1^{s'}, g_2^{s'}, g_3^{s'} \dots, g_{13}^{s'}, \dots, g_{25}^{s'}]$,取序列中间值 $g_{13}^{s'}$ 。

对灰度图像采用 5×5 像素框循环取中值,循环次数为 $c = \max(\frac{m}{5}, \frac{n}{5})$,可得到 c 个中值 $[(g_{13}^{s'})_1, (g_{13}^{s'})_2, \dots, (g_{13}^{s'})_j, \dots, (g_{13}^{s'})_c]$,其中 $1 \leq j \leq c$ 。

2) 求中值序列的均值

$$E_{avr} = \frac{\sum_{u=1}^c (g_{13}^s)_u}{c} \quad (2)$$

3) 利用均值 E_{avr} , 对灰度图像进行二值处理, 具体如下:

$$g_v^s = \begin{cases} 255, & (g_v^s > E_{avr}), \\ 0, & (g_v^s < E_{avr}), \end{cases} \quad (3)$$

其中: $v \in [1, m \times n]$ 。

经上述火灾图像强化处理后, 得到灰度图像的火苗特征强化后的图像, 如图 3 所示。



图 3 火苗特征强化后的图像

Fig.3 The image after the flame feature being strengthened

3 火灾类型判定

火灾类型有多种, 如阴燃火、轰燃火、非轰燃火。根据火灾发展的实验证明, 一个 0.85 m 厚的木锯末堆, 从堆角发生阴燃火到燃烧到堆表面至少需要 10 d 的时间, 可见阴燃火发展速度缓慢, 威胁性相对较低。因此本文在研究火灾发展趋势实时预测方向时, 仅考虑轰燃火和非轰燃火两大类。

火灾图像经预处理以及强化处理后, 在单位采样时间内, 获得状态 s 和状态 $s+1$ 的火苗特征强化后的图像(见图 4)。

计算火势蔓延变化率 r ; 记两个状态图像中灰度值等于 255 的像素数分别为 C_s 和 C_{s+1} , 则有

$$r = \frac{C_{s+1} - C_s}{t} \times 100\% \quad (4)$$

其中, t 为单位采样时间。

单位采样时间内, 设置阈值 ϑ , 当 $r \geq \vartheta$ 时, 火灾类型为轰燃火; 当 $r < \vartheta$ 时, 火灾类型为非轰燃火。在实际中, 若 $t = 1$ s, 则 ϑ 取 350% ~ 550% 为宜。



(a) 状态 s



(b) 状态 $s+1$

图 4 状态 s 和 $s+1$ 火苗特征强化后图像

Fig.4 The images of state s and $s+1$ after the flame feature being strengthened

4 网格处理

根据监控区域的关注方向划分网格。室外空旷地区的火灾关注方向为水平方向, 对监控区域按平面位置划分网格; 楼宇地区关注方向为水平和垂直两个方向, 则对监控区域按水平和垂直两个方向划分两套网格。

根据黄维章等^[2]的研究, 对于城市火灾网格的大小一般取 1.295 或 2.590 km^2 ; 对于室内火灾, 为了兼顾计算量和反应房间基本特征两方面要求, 本文网格取 1 m^2 。按照行列数对网格中的任一网格进行编号, 如图 5 所示, (p, q) 表示第 p 行、第 q 列的网格。在火灾发展趋势研究中, 每个网格具有两个状态, 状态值为 1 表示该网格过火, 状态值为 0 表示该网格尚未过火。因此对火灾发展趋势的预测, 实际上是对网格状态值的计算与预测。

影响网格状态值的因素有: 火灾类型 S_f 、气流矢量(流向、流速) A 、网格风口状态 S_A 和阻挡状态 S_b 。火灾类型 S_f 的判定参照第 3 章; 气流矢量 A 根据热球风速仪传感数据得到, $A = (D, V)$ 。

网格风口状态 S_A 表示网格相对于着火点网

格位置和气流流速是否位于下风口, $S_A = 0$ 表示位于上风口, $S_A = 1$ 表示位于下风口。在有多个着火点的情况下,只要相对某一个着火点位于下风口,那么该网格风口状态即为下风口。




图 5 监控区域网格图

Fig.5 The grid diagram of monitoring area

阻挡状态 S_s 表示网格内是否有建筑构件等阻挡物以及阻挡物的状态,计算公式为:

$$S_s = \frac{t_f}{t_e}, \quad (5)$$

其中: t_f 为阻挡物的受火时间,在火灾情况下由计时器计算得出; t_e 为阻挡物的等效耐火时间,根据国际通用标准曲线 CIB W14,并考虑火灾边界的热惯性,计算公式为

$$t_e = 0.0672 \times q_f \times \sqrt{K_s} \times w_f, \quad (6)$$

其中: q_f 为着火空间的火灾载荷密度,单位为 $\text{MJ} \cdot \text{m}^{-2}$; K_s 为边界材料的热惯性系数; w_f 为通风因子。

着火空间的火灾载荷密度 q_f 采用查表法按照空间类型选取平均值(见表 1),以保证比典型值具有更好的安全冗余度。

表 1 着火空间的火灾载荷密度
Tab.1 Fire load density of fire space
($\text{MJ} \cdot \text{m}^{-2}$)

空间类型	q_f	空间类型	q_f
住宅	780	车间	300
医院	230	仓储	1180
储藏室	2000	图书馆	1500
办公室	420	学校	285
商店	600	其它可燃元素	200~300

热惯性系数 K_s 由燃烧材料的密度、比热容和热导率 3 个参数共同决定,本文根据经验设定取

值范围为 0.04~0.07,一般建筑物火灾取 0.07,室外场景取值 0.05,进一步由神经网络自身的泛化特性来抵消经验值选取所造成的误差。

通风因子 w_f 反映了火场通风情况,计算公式为:

$$w_f = \left(\frac{6}{H}\right)^{0.3} \times \left\{ 0.62 + \frac{90 \times \left(0.4 - \frac{A_v}{A_f}\right)^4}{1 + 12.5 \times \left[1 + 10 \times \frac{A_v}{A_f} - \left(\frac{A_v}{A_f}\right)^2 \times \frac{A_h}{A_f}\right]} \right\}, \quad (7)$$

其中: H 为过火间空间高度; A_v 为开口面积; A_f 为过火间地板面积; A_h 为水平开口面积。

当 $A_h = 0$ 时,

$$w_f = \left(\frac{6}{H}\right)^{0.3} \times \left[0.62 + 90 \times \left(0.4 - \frac{A_v}{A_f}\right)^4\right]. \quad (8)$$

综上,即可计算出阻挡状态 S_s 。

5 构建预测网络

构建 GRNN 预测网络,如图 6 所示。GRNN 分为 4 层:输入层、模式层、求和层和输出层^[12]。




图 6 GRNN 神经网络结构

Fig.6 GRNN neural network structure

该神经网络采用输入层、模式层和求和层的神经元个数均为 5 的网络结构。输入参数为原始网格状态 N^0 、火灾类型 S_f 、气流矢量 A 、网格风口状态 S_A 、阻挡状态 S_s ,输出为下一状态的网格状态 N^1 。

神经网络的输入为 $X = [x_1, x_2, x_3, x_4, x_5] =$

$[N, S_f, A, S_A, S_s]$; 模式层神经元传递函数为 $P_i (i = 1, 2, 3, 4, 5)$; S_D 为求和层对所有模式层神经元的输出进行算术求和的传递函数, 为第一类神经元; $S_{N_j} (j = 1, 2, 3, 4)$ 为求和层对所有模式层神经元的输出进行加权求和的传递函数, 为第二类神经元。

具体计算过程如下:

模式层与输入层全连接, 层内无连接, 模式层神经元与样本具有相同个数, 各神经元对应不同的样本, 模式层神经元传递函数为:

$$P_i = \exp \left[- \frac{(\mathbf{X} - \mathbf{X}_i)^T (\mathbf{X} - \mathbf{X}_i)}{2\sigma^2} \right], \quad (9)$$

其中: $i = 1, 2, 3, 4, 5$, σ 为样本标准差; \mathbf{X} 为网络输入变量; \mathbf{X}_i 为第 i 个神经元对应的学习样本, 即第 i 个神经元的输出为输入变量与其对应的学习样本之间 Euclid 距离平方的指数形式。

求和层中有两类神经元: 第一类神经元为每个模式层神经元的输出和, 其模式层与各神经元的连接权值为 1; 第二类神经元为预期的结果与每个模式层神经元的加权和。第一类求和公式^[13]为:

$$\sum_{i=1}^5 \mathbf{X}_i = \sum_{i=1}^5 \exp \left[- \frac{(\mathbf{X} - \mathbf{X}_i)^T (\mathbf{X} - \mathbf{X}_i)}{2\sigma^2} \right], \quad (10)$$

即对所有模式层神经元的输出进行算术求和, 其模式层与各神经元的连接权值为 1。传递函数^[14]为:

$$S_D = \sum_{i=1}^5 P_i. \quad (11)$$

第二类求和公式^[13]为:

$$\sum_{i=1}^5 \mathbf{X}_i = \sum_{i=1}^5 \mathbf{Y}_i \exp \left[- \frac{(\mathbf{X} - \mathbf{X}_i)^T (\mathbf{X} - \mathbf{X}_i)}{2\sigma^2} \right], \quad (12)$$

即对所有模式层的神经元进行加权求和, 模式层中第 i 个神经元与求和层第 j 个分子求和神经元之间的连接权值为第 i 个输出样本 \mathbf{Y}_i 的第 j 个元素, 传递函数^[15]为:

$$S_{N_j} = \sum_{i=1}^5 y_{ij} P_i, j = 1, 2, 3, 4. \quad (13)$$

输出层中的神经元数目为 1, 输出是求和层的第二类节点除以第一类节点, 即

$$Y = \frac{\sum_{j=1}^4 S_{N_j}}{4S_D}. \quad (14)$$

网络建成后, 先用训练集数据进行训练。本文采用了 Durham University 的开放数据集 Collec-

tions fires 进行训练和验证, 经过 5 次随机选取验证集, 网络的预测误差范围为 $[5.1284 \times 10^{-6}, 1.9699 \times 10^{-3}]$, 实验证明具有较好的预测准确性。

6 预测效果及分析

为了验证本文所述方法的预测效果, 根据两组不同场景火灾数据, 将本文方法与室外火灾预测专用的网格概率模型(简称“GPM 法”)以及建筑物火灾预测专用的蔓延概率模型(简称“DPM 法”)进行对比。其中 GPM 法主要思想是: 首先利用适当大小的网格将研究区域划分成等同的若干网格, 然后根据每个网格中的物体属性、块间距、长度等详细参数为每个网格设置一个基本特征量, 最后根据火灾蔓延机理和实时参数, 计算每个网格蔓延的期望。具体计算过程示例可参照文献[2]。而 DPM 法的主要思想是: 首先根据火灾发展机理计算每个防火分区内火灾增长为充分发展火灾的概率, 然后根据建筑物边界构件的失效概率模型并结合影响因子计算建筑物边建构件失效的概率, 最后结合以上两种概率结果, 计算火灾蔓延概率。该方法的具体工程算例可参照文献[1]。

对比分析数据中, 室外火灾数据采用 2019 年 3 月四川凉山森林火灾充分发展阶段起计 10'46" 的记录数据; 室内火灾采用两间 21 m² 模拟民居实验房在 10'46" 时间内, 由一间起火点起火到爆燃以及充分发展到两间房间都完全过火的实验过程数据。在时间同步前提下, GPM 法、DPM 法以及本文方法对火灾发展进行同步模拟。效果评价由网格预测准确率 ε 来表示, 若以起火时间点为原点, 在关注时间点 t_i 时, 预测过火网格数为 α , 实际过火网格数为 β , 则 $\varepsilon = \frac{|\alpha - \beta|}{\beta} \times 100\%$ 。

对比结果如图 7 所示, 图 7(a) 为室外火灾预测准确率对比图, 图 7(b) 为室内火灾预测准确率对比图。

从图 7(a) 可看出, 对于室外火灾的预测, GPM 方法在前 170 s 准确率最高; 随着火灾态势发展, 外界复杂因素的波动, 在约 200 s 时, 风向突变, 对 GPM 的准确率造成较大负面影响; 因其模型的输入因子较为完善, 在影响因素恢复初始状态时, GPM 模型的准确率又持续回升; 但因累

积误差的作用,最终在 646 s 时,其准确率下降为约 62%。而 DPM 方法,因几乎不适用于室外火灾预测,因此除了在火灾初起时 50 s 左右,准确率约为 48%,其后预测准确率一路下降至约 8%的水平。




图7 不同场景下火灾预测准确率对比
Fig.7 Comparison of fire prediction accuracy
in different scenarios

对室内火灾的预测,从图7(b)可以看出,DPM方法在火灾初起时达到78%的水平,是3种方法中最高的,直至350s左右,仍能保持最好的预测准确性;然而在400s附近,因实验房两房间之间的窗户烧穿,气流的快速流动引起爆燃现象,突发外因的变动对DPM方法造成了非常大的负面影响,其预测准确率由350s时78%骤降至54%;其后随着外因的稳定,DPM方法的预测准确率有所回升,但由于累计误差,最终其预测准确率维持在约60%。而GPM方法因为几乎不适用于室内火灾预测,其准确率最终仅有约3%。

由图7可以看出:本文所述方法在两种场景下均具有较好的预测效果,预测准确率维持在68%~75%之间;特别是在外因发生突变时,因本文方法具有很好的泛化性能,故某个外因突变并

不会对整体预测准确性造成致命影响。因此可在两种场景下都保持较高且非常稳定的预测性能。

7 结语

本文提出的火灾发展趋势实时预测技术不受火灾现场复杂参数的关联影响,且广泛适用于各种火灾场景。采用室外室内两种火灾场景进行预测验证,结果证明对于不同场景均具有较好的预测准确性。但本方法对于预测网络的泛化性能要求较高,在实际使用中可采用多次训练好的网络并行使用,根据实际场景数据从中筛选最优网络。另外,本文所提预测方法准确率在68%~75%之间,对输入变量进行完善可进一步提高预测准确率,这也是作者今后需要继续研究的方向。

参考文献:

- [1] 辛晶,黄崇福.建筑物火灾蔓延机理及概率模型[J].消防科学与技术,2011,30(10):886-888.
- [2] 黄维章,张锁春,雷光耀,等.城市火灾蔓延的数学模型和计算机模拟[J].计算物理,1993,10(1):9-19.
- [3] 黄奇晓.福建省森林火灾对气候变化的响应及趋势预测[D].福州:福建农林大学,2020.
- [4] 卢岚.安全工程[M].天津:天津大学出版社,2003.
- [5] 范维澄,孙金华,陆守香,等.火灾风险评估方法学[M].北京:科学出版社,2004.
- [6] 崔恺,许宜菲,李雪松,等.基于广义回归神经网络的风电机组性能预测模型及状态预警[J].科学技术与工程,2020,20(32):13220-13228.
- [7] 丁硕,常晓恒,巫庆辉.GRNN与BPNN的函数逼近性能对比研究[J].现代电子技术,2014,37(7):114-117.
- [8] 陈焯,高亚静,张建成.基于离散Hopfield模式识别样本的GRNN非线性组合短期风速预测模型[J].电力自动化设备,2015,35(8):31-136.
- [9] 喻华,卢继平,曾燕婷,等.基于不同优化准则和广义回归神经网络的风电功率非线性组合预测[J].高电压技术,2019,45(3):1002-1008.
- [10] 金杉,金志刚.基于自适应模糊广义回归神经网络的区域火灾数据推理预测[J].计算机应用,2015,35(5):1499-1504.
- [11] 吴秋平.基于神经网络的森林火灾预报系统[J].信息化建设,2016,2:33-34.
- [12] SURESH P, MURIMUTHU K, RANGANATHAN S, et al. Optimization of machining parameters in turning of

- Al-SiC-Gr hybrid metal matrix composites using grey-fuzzy algorithm [J]. Transactions of Nonferrous Metals Society of China, 2014, 24(9): 2805-2814.
- [13] 王吉凯. 广义回归神经网络高程插值方法研究 [J]. 中国新产品新技术, 2022, 10: 8-11.
- [14] 李鸿志. 提高密度泛函理论计算 Y-NO 体系均裂能精度: 神经网络和支持向量机方法 [D]. 长春: 东北师范大学, 2011.
- [15] 杜兰萍, 肖学锋, 邢强. 建筑物火灾蔓延风险的量化分析: 性能化设计的一个实例 [J]. 消防科学与技术, 1999, 18(2): 26-29.

Real Time Prediction Technology of Fire Development Trend on General Scene

GUO Meili¹, JIANG Xiao²

(1. Department of Electrical and Electronic Engineering, Yantai Vocational College, Yantai 264003, China;

2. R&D department, Shandong HongHorn Information Technology Co, Ltd, Yantai 264003, China)

Abstract: The prediction of fire development trend has important guiding significance for fire evacuation and fire extinguishing policy. In this paper, fire images were preprocessed and enhanced and the fire type was determined by comparing the fire intensity of fire images in different states at first, and on this basis the grid processing was carried out for monitoring area. Then the model was constructed based on GRNN, the network structure with the same number of neurons in input layer, mode layer and summation layer were adopted, and the classified neural network was used to predict the state of edge grid, so as to predict the fire development trend. The real-time prediction technology of fire development trend proposed in this paper does not need to build models for different fire scenarios, and can be widely applied to various fire scenarios.

Keywords: general scene; fire development trend; real-time prediction; neural network; GRNN

(责任编辑 李秀芳)

版权声明

根据《中华人民共和国著作权法》《信息网络传播权保护条例》等法律法规的规定,本刊作如下声明:

1. 作者向本刊投稿,即表明同意将作品的发表权、删改权、信息网络传播权、数字化汇编权、数字化复制权、数字化制品形式(包括光盘、互联网出版物)出版发行权等权利授予本刊,并视同许可本刊官方新媒体免费转载以及与有关数据库的合作(本刊不再另行支付费用)。如不同意以上授权,请在投稿时说明。

2. 本刊刊载的全部编辑内容归《鲁东大学学报(自然科学版)》编辑部所有,非经书面同意,任何单位和个人不得转载、摘编、刊印或以其他方式使用。如有违反,本刊保留一切法律追究的权利。

3. 本刊版面、栏目等受著作权保护,对复制、仿制、假冒者将追究法律责任。

4. 已在本刊发表的论文,本刊具有免费结集出版精华本、合订本以及相关电子产品的权利,有特别声明者除外。

《鲁东大学学报(自然科学版)》编辑部