

DOI: 10.11830/ISSN.1000-5013.202103025



采用 MEA-AdaBoost-BP 模型的 工程结构可靠性分析方法

胡启国, 李致明

(重庆交通大学 机电与车辆工程学院, 重庆 400074)

摘要: 针对工程结构可靠性设计中算法和计算存在的问题, 提出基于 MEA-AdaBoost-BP 神经网络算法模型的可靠性求解方法. 运用思维进化算法(MEA)求解训练集权值和阈值优化的 BP 神经网络, 并构造为弱预测器函数. 然后, 运用 AdaBoost 算法将多个优化后的 BP 神经网络弱预测器函数迭代训练, 形成 MEA-AdaBoost-BP 神经网络算法模型强预测器函数. 最后, 利用逼近隐性功能函数求解可靠性指标, 并将其与 AdaBoost-BP 算法和 Monte-Carlo 算法进行比较. 研究表明: 所提算法在计算中与 Monte-Carlo 算法相比, 其迭代次数分别仅为 16 次和 46 次, 效率高, 计算精度与 Monte-Carlo 法接近; 而和 AdaBoost-BP 法相比, 其可靠性指标误差分别仅为 1.59% 和 1.88%, 计算结果更精确.

关键词: 可靠性指标; 思维进化算法(MEA); AdaBoost-BP 神经网络; MEA-AdaBoost-BP 算法; 强预测器函数

中图分类号: TB 114.3; TP 183 文献标志码: A 文章编号: 1000-5013(2022)03-0291-06

Reliability Analysis Method of Engineering Structure Based on MEA-AdaBoost-BP Model

HU Qiguo, LI Zhiming

(School of Mechanical and Vehicle Engineering, Chongqing Jiaotong University, Chongqing 400074, China)

Abstract: Aiming at the algorithm and calculation in engineering structure reliability design, a reliability solving method was proposed based on MEA-AdaBoost-BP neural network algorithm model. The optimized BP neural network was constructed as a weak predictor function by solving the training set weights and threshold values through the Mind Evolutionary Algorithm (MEA). Then the AdaBoost algorithm was used to iteratively train several optimized BP neural network weak predictor functions to form the strong predictor function of the MEA-AdaBoost-BP neural network algorithm model. Finally, the approximate the implicit function was used to solve the reliability index, which was compared with AdaBoost-BP algorithm and the Monte-Carlo method. The results show that the proposed method is efficient because its number of iterations is only 16 and 46 respectively compared with the Monte-Carlo method and its calculation accuracy is close to that of the Monte-Carlo method; the error of reliability index is only 1.59% and 1.88% respectively compared with that of AdaBoost-BP method, and the calculation result is more accurate.

Keywords: reliability index; mind evolutionary algorithm (MEA); AdaBoost-BP neural network; MEA-AdaBoost-BP algorithm; strong predictor function

收稿日期: 2021-03-19

通信作者: 胡启国(1966-), 男, 教授, 博士, 主要从事机械可靠性分析及优化、机械系统动力学研究. E-mail: swpi-hqg@163.com.

基金项目: 国家自然科学基金资助项目(51375519); 重庆市基础科学与前沿技术研究专项(cstc2015jcyjBX0133)

在实际工程运用中,需要运用可靠性分析来预先评估机械结构的可靠指标.但结构工程实际可靠性分析中结构功能函数隐性表达,传统的分析方法如一次二阶矩^[1]、二次二阶矩^[2]法、蒙特卡洛(Monte-Carlo)^[3]和基于代理模型思想的响应面^[4]可靠性分析法,都存在计算时间长,精度受限等缺点,不能更好地进行可靠性指标求解.随着人工神经网络的发展,将神经网络算法应用于结构可靠度计算,有效避免了传统结构隐性功能函数,提高了可靠度计算精度.

随着结构工程可靠性算法的发展,Deng 等^[5]采用前馈神经网络,以最小的计算量逼近隐性功能函数和函数导数,有效应用于隐性功能函数的极限状态可靠性求解;温凯等^[3]采用模拟退火(SA)优化神经网络阈值和权值,再用神经网络逼近隐性功能函数;姜逢源等^[6]将 AdaBoost 算法与 BP 神经网络算法结合逼近隐性功能函数,进行板桩结构极限状态下的可靠性求解.这些方法为工程结构隐性功能函数可靠性求解提供了有益借鉴,但其对神经网络单一的优化,使构建的功能函数还具有局限性和误差性.

实际工程中结构功能函数无法显性表达,在利用 BP 神经网络算法时,必须避免算法出现过拟合和预测精度低的缺点.因此,针对此缺点,本文运用思维进化算法(MEA)的群体特性,提出基于 MEA-AdaBoost-BP 神经网络算法模型的可靠性求解方法.

1 MEA-AdaBoost-BP 算法模型

1.1 思维进化算法

思维进化算法(MEA)是基于趋同和异化操作特性和记忆多代信息的特点,得到全局最优个体的一种群体寻优算法.在初始阶段,迭代生成相应大小的个体.根据得分,得到优秀的和临时的得分最高的个体.通过结构的并行性,在几个最优个体周围生成局部最优子群,在临时个体周围生成局部临时子群.然后,通过趋同和异化,构建上一代和优于上一代的子群体,将得分最高的个体视为全局最优个体.思维进化算法(MEA)流程图,如图 1 所示.




图 1 思维进化算法(MEA)流程图

Fig. 1 Flow chart of mind evolutionary algorithm (MEA)

目前,MEA-BP 神经网络算法模型优点在于运用思维进化算法(MEA)趋同和异化操作智能搜索全局最优个体,避免 BP 神经网络的局部搜索的缺点;同时,运用解码规则得到最优权值和阈值,避免 BP 神经网络局部预测精度差的问题.综上,基于文献[7]搭建了 MEA-AdaBoost-BP 神经网络算法模型,实现了对 BP 神经网络的全局优化.

1.2 AdaBoost-BP 神经网络

初始时,BP 神经网络经过训练得到随机初始权值和阈值,形成 T 个权重一致的弱预测器函数,再用 AdaBoost 算法将弱预测器反复迭代 t 次;每次迭代后预测,若预测结果误差大于设定误差,则赋予该组样本较大权重进行加权学习.最终由 AdaBoost 算法进行加权组合 T 组 BP 神经网络弱预测器,形成 AdaBoost-BP 强预测函数. AdaBoost-BP 算法流程图,如图 2 所示.

AdaBoost-BP 神经网络算法有如下 4 个具体的操作步骤.

步骤 1 数据初始化.随机选择 M 组训练数据集,运用已优化权值和阈值的 BP 神经网络构造 T 个弱预测器,并赋予相同的初始分布权值,即 $D_t(i)=1/M, i=1,2,\cdots,M; t=1,2,\cdots,T$.

步骤 2 弱预测器函数迭代.为了预测预测序列 $g(t)$ 和计算对应的预测误差和 e_t ,对 T 个 BP 神经




图 2 AdaBoost-BP 算法流程图

Fig. 2 Flow chart of AdaBoost-BP algorithm

网络弱预测器函数迭代训练. 即 $e_t = \sum_i D_i(i), i = 1, 2, \dots, M (|g(t) - \phi| > 0)$. 其中: ϕ 为期望预测输出结果.

步骤 3 权重预测与调整. 如果预测误差和 e_t 大于设定的误差, 根据权重 $D_i(i)$ 计算调整下一个权重 $D_{t+1}(i)$, 即,

$$a_t = \frac{1}{2} \ln \left(\frac{1 - e_t}{e_t} \right),$$
$$D_{t+1}(i) = \frac{D_t(i)}{B_t} \cdot \exp[-a_t \phi_i g_t(x_i)], \quad i = 1, 2, \dots, M.$$

上式中: B_t 为归一化因子.

步骤 4 构造强预测函数. T 组弱分类函数 $h(x)$ 加权组合得到强预测函数 $y(x)$. 即 $y(x) = \sum_{j=1}^t a_j h_j(x)$.

1.3 MEA-AdaBoost-BP 算法模型

AdaBoost-BP 神经网络模型受限于 BP 神经网络易过度拟合和泛化能力弱的特点, 在工程结构可靠性求解中具有局限性. 文中提出 MEA-AdaBoost-BP 算法模型, 运用 MEA 算法全局搜索最优个体并解码, 构造 T 个 BP 神经网络弱预测器函数; 然后, 运用 AdaBoost 加权组合得到 MEA-AdaBoost-BP 强预测器函数, 最终用强预测器函数代替功能函数求解结构可靠性. MEA-AdaBoost-BP 算法模型可靠性求解流程图, 如图 3 所示. MEA-AdaBoost-BP 算法模型有如下 8 个主要步骤.

步骤 1 在 MEA-AdaBoost-BP 算法模型中用 MEA 算法初始化输入集, 对子种群 SG、初始种群 r 、优胜子种群 m 、临时子种群 n 进行种群编码. 即 $SG = r/(m+n)$.

步骤 2 筛选最优个体. 为得到得分函数中的最优个体, 进行多次迭代和执行趋同、异化操作, 最终通过均方误差 (SE) 计算 MEA 得分 (Val). 即 $Val = 1/SE$.

步骤 3 根据编码解码规则, 将最优个体依照编码解码得到权值和阈值, 并将其赋予 BP 神经网络构造弱预测器.

步骤 4 数据初始化. 随机选择 M 组训练数集, 运用已优化权值和阈值的 BP 神经网络构造 T 个弱预测器, 并赋予相同的初始分布权值, 即 $D_i(i) = 1/M, i = 1, 2, \dots, M; t = 1, 2, \dots, T$.

步骤 5 弱预测器函数迭代. 为了预测预测序列 $g(t)$ 和计算对应的预测误差和 e_t , 对 T 个 BP 神经网络弱预测器函数迭代训练. 即 $e_t = \sum_i D_i(i), i = 1, 2, \dots, M (|g(t) - \phi| > 0)$. 其中: ϕ 为期望预测输出结果.

步骤 6 权重预测与调整. 若预测误差和 e_t 大于设定误差, 根据权重 $D_i(i)$ 计算调整下一个权重 $D_{t+1}(i)$. 则有

$$a_t = \frac{1}{2} \ln \left(\frac{1 - e_t}{e_t} \right),$$
$$D_{t+1}(i) = \frac{D_t(i)}{B_t} \cdot \exp[-a_t \phi_i g_t(x_i)], \quad i = 1, 2, \dots, M.$$

上式中: B_t 为归一化因子.

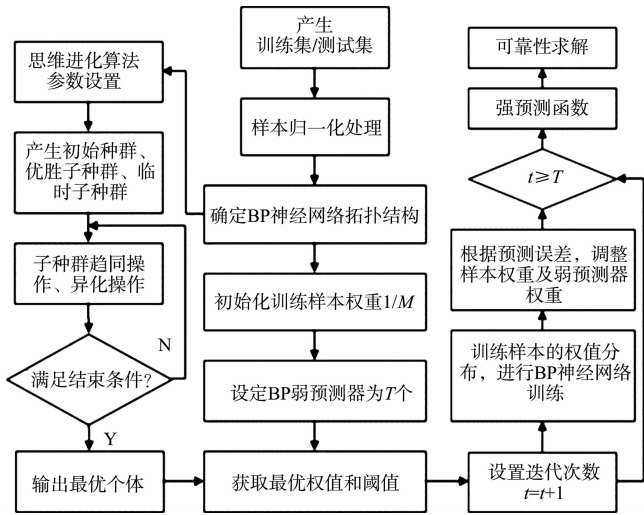


图 3 MEA-AdaBoost-BP 算法模型可靠性求解流程图
Fig. 3 Reliability solution flow chart of MEA-AdaBoost-BP algorithm model

步骤 7 构造强预测函数. T 组弱分类函数 $h(x)$ 加权组合得到强预测函数 $y(x)$. 即有 $y(x) =$

$$\sum_{j=1}^l a_j h_j(x).$$

步骤 8 功能函数的运用. 下式功能函数式 Z 由强预测函数 $y(x)$ 代替, 进行可靠度指标求解. 即有

$$Z \approx g(X) = f_L \{ \omega_L^T f_{L-1} [\omega_{L-1}^T f_{L-2} (\omega_{L-2}^T f_{L-3} (\cdots (f_3 (\omega_3^T f_2 (\omega_2^T f_1 (\omega_1^T X))))))] \}.$$

上式中: ω_L 为权矩阵; f_L 为传递函数.

2 MEA-AdaBoost-BP 算法验证

2.1 理论模型验证

为验证和优化 MEA-AdaBoost-BP 模型, 考虑乘积形式的非线性结构功能函数 $Z(H, W)$, 结构功能函数为 $Z=g(X)=H \cdot W-1 \ 140=0$, H 和 W 相互独立, 均服从正态分布, 均值为 $\mu_H=38, \mu_W=54$, 标准差为 $\sigma_H=3.8, \sigma_W=2.7$, 进行可靠指标 β 和失效概率 P_f 求解. 采用 MEA-AdaBoost-BP 算法模型生成精确有效的 MEA-AdaBoost-BP 强预测器函数, 运用 MEA-AdaBoost-BP 算法模型生成 2 000 个 $\{x_i, g(x_i)\}$ 数据集. MEA 参数设定为种群数 $r=200$, 优胜子种群数 $m=5$, 和临时子种群数 $n=5$, 迭代训练参数设置为 20 次. BP 神经网络参数设置迭代次数为 100、学习率为 0.1、目标误差为 1×10^{-8} .

根据 MEA-AdaBoost-BP 算法模型设置参数, 此时误差性能曲线迭代平滑, 迭代次数为 16 次, 网络预测精度为 $2.377 \ 9 \times 10^{-5}$, 达到预测精度要求. MEA-AdaBoost-BP 算法模型的误差性能曲线, 如图 4 所示. 图 4 中: N 为迭代数; ϵ_{MS} 为均方误差.

多算法计算结果对比, 如表 1 所示. 表 1 中: β 为可靠度指标; ϵ 为误差; ϵ_a 为误差绝对值; P_f 为失效概率. 从表 1 可知: AdaBoost-BP 预测器误差绝对值较大, 可靠性指标计算精度较差, 通过 MEA-AdaBoost-BP 对弱预测器进行优化构成强预测器其误差绝对值仅为 0.005 7, 可靠性指标 $\beta=5.282 \ 7$, 误差值仅为 1.59%, 精度有大幅提升.




图 4 理论模型的误差性能曲线
Fig. 4 Error performance curve of theoretical model

表 1 不同算法的计算结果对比

Tab. 1 Comparison of calculation results of different algorithms

算法	ϵ_a	β	$\epsilon/\%$	P_f
Monte-Carlo 算法	—	5.199 9	—	$1.000 \ 0 \times 10^{-7}$
AdaBoost-BP 算法	0.021 7	4.605 3	11.40	$2.398 \ 5 \times 10^{-5}$
MEA-AdaBoost-BP 算法	0.005 7	5.282 7	1.59	$0.996 \ 4 \times 10^{-7}$

2.2 桁架工程模型验证

2.2.1 参数设定 选用文献[8-9]中的 23 杆桁架, 桁架结构如图 5 所示. 图 5 的 10 个随机变量: 横杆和斜杆的横截面积和杨氏模量分别为 A_1, A_2, E_1, E_2 , 随机荷载 $P_1 \sim P_6$. 假设所有变量独立, 其分布、均值、标准差如表 2 所示.

该结构在载荷 $P_1 \sim P_6$ 作用下, 点 C 位移最大, 参考文献[8]结构功能函数为

$$Z=G(x)=0.14-|V_c(x)|.$$

将 2 000 个 $\{x_i, g(x_i)\}$ 数据集设种群数 $r=200$, 优胜子种群数 $m=5$, 和临时子种群数 $n=5$, 迭代训练参数设置为 20 次, 其最终解码优化个体权值为 ω_1, ω_2 , 阈值为 B_1, B_2 . 神经网络根据输入 10 个随机变量来输入层节点 $\kappa=10$, 输出随机变量 $g(X)$ 来设置输出层节点 $\lambda=1$, 和 $l < \sqrt{(\kappa+\lambda)}+a, (a=1 \sim$




图 5 桁架结构图

Fig. 5 Truss structure drawing

表 2 桁架结构的随机参数变量分布

Tab. 2 Distribution of random

parameter variables of truss structure


随机变量	分布类型	均值标准差
A_1 (m ²) 对数正态	2.0×10^3	2.0×10^4
A_2 (m ²) 对数正态	1.0×10^3	1.0×10^4
E_1, E_2 (Pa) 对数正态	2.1×10^{11}	2.1×10^{10}
$P_1 \sim P_6$ Gumbel 分布	5.0×10^4	7.5×10^3

10) 的选取原则来搭建隐含层为 $l=2$ 的三层网络。


根据多次训练比较,BP 神经网络参数设置迭代次数为 100、学习率为 0.1、目标误差为 1×10^{-8} ,权值为 ω_1,ω_2 ,阈值为 B_1,B_2 . 通过 MEA-AdaBoost-BP 算法模型将 10 组弱预测器函数迭代训练组合成一个 MEA-AdaBoost-BP 强预测器函数. 根据设置参数,MEA-AdaBoost-BP 算法模型桁架结构的误差性能曲线图,如图 6 所示. 从图 6 可知:此时误差性能曲线迭代平滑,迭代次数 46 次,网络预测精度为 $9.773\ 1\times 10^{-7}$,达到预测精度要求.

2.2.2 模型预测结果 AdaBoost-BP 算法和 MEA-AdaBoost-BP 算法的预测误差绝对值对比,如图 7 所示. 图 7 中: ϵ_a 为误差绝对值; n 为预测样本数.

从图 7 可知:运用传统的 AdaBoost-BP 预测器函数进行预测其误差绝对值为 0.004 7,预测误差绝对值只有 50%左右,在 0.05 以下,且误差绝对值曲线波动幅度相对较大,从而可知预测效果较差;而运用 MEA 算法进一步优化 AdaBoost-BP 预测器函数,由于采用多个 AdaBoost-BP 弱预测器函数构建 MEA-AdaBoost-BP 强预测器函数进行预测,其预测误差绝对值为 0.002 0,且预测误差绝对值 90%,也在 0.05 以下,但误差绝对值曲线波动幅度较小,具有更好的泛化能力和预测性.



(a) AdaBoost-BP 算法



(b) MEA-AdaBoost-BP 算法

图 7 两种算法的预测误差绝对值

Fig. 7 Absolute value of prediction error of two algorithms

为验证 MEA-AdaBoost-BP 神经网络算法模型的可行性,将两者的预测误差绝对值进行对比,可知 MEA-AdaBoost-BP 预测器具有更好的预测效果,能够更好的构造功能函数.

将文献[8]的计算结果和 Monte-Carlo 法计算结果设置为标准解,证明 MEA-AdaBoost-BP 算法模型的精确性和可行性. 采用 Monte-Carlo 法、AdaBoost-BP 神经网络法、MEA-AdaBoost-BP 神经网络算法模型,分别对桁架结构功能函数进行可靠性指标求解分析,可靠度计算指标如表 3 所示. 表 3 中: β 为可靠度指标; ϵ 为误差; ϵ_a 为误差绝对值; P_f 为失效概率.

表 3 不同算法的可靠性计算结果

Tab. 3 Reliability calculation results of different algorithms

算法	ϵ_a	β	$\epsilon/\%$	P_f
文献[8]算法	—	3.980	—	$3.445\ 8\times 10^{-5}$
Monte-Carlo 算法	—	3.975	—	$3.519\ 0\times 10^{-5}$
AdaBoost-BP 算法	0.004 0	73.771	5.13	$8.129\ 7\times 10^{-5}$
MEA-AdaBoost-BP 算法	0.002 0	3.900	1.88	$4.809\ 6\times 10^{-5}$

由表 3 可知,MEA-AdaBoost-BP 算法模型求解可靠性指标值较 AdaBoost-BP 算法模型求解可靠性指标值更为接近文献[8]和 Monte-Carlo 法解值,可靠性指标 $\beta=3.900$,误差仅为 1.88%. 由此可知,文中所提方法能更好地逼近结构功能函数求解可靠性指标,比传统方法具有更优异的精度性和可行性.

3 结论

基于 MEA-AdaBoost-BP 神经网络算法模型逼近结构功能函数求解可靠性指标,并通过与不同算法比较验证,得到以下 3 点主要结论.

1) 采用 MEA-AdaBoost-BP 神经网络算法模型,运用思维进化算法(MEA)赋予 BP 弱预测器最优初始权值和阈值,并用 AdaBoost 算法加权组合多个 BP 弱预测器形成 MEA-AdaBoost-BP 强预测器.与 AdaBoost-BP 算法相比,有效提升了 BP 神经网络的预测精准性.

2) 在前人可靠性研究中,对运用 BP 神经网络构造隐性功能函数求解可靠度指标,提出一种基于 MEA-AdaBoost 优化 BP 神经网络权值和阈值的新思路,提高构建隐性功能函数的精确度.

3) 通过 Monte-Carlo 法、AdaBoost-BP 神经网络算法、MEA-AdaBoost-BP 神经网络算法求解可靠性指标 β 的比较,可知基于 MEA-AdaBoost-BP 改进一次二阶矩模型可靠性求解中,可靠度指标 β 值与 Monte-Carlo 法解值相近,达到求解精度.同时,文中所提方法仅两次分别迭代 16 次和 46 次,与 Monte-Carlo 法相比减少大量的数值计算次数.

参考文献:

- [1] HUANG Xiyong, ALIABADI F M H. A boundary element method for structural reliability[J]. Key Engineering Materials, 2015, 627: 453-456. DOI: 10. 4028/ www. scientific. net/ KEM. 627. 453.
- [2] LOW B K, PHOON K K. Reliability-based design and its complementary role to Eurocode 7 design approach[J]. Computers and Geotechnics, 2015, 65: 30-44. DOI: 10. 1016/ j. compgeo. 2014. 11. 011.
- [3] WEN Kai, HE Lei, LIU Jing, *et al.* An optimization of artificial neural network modeling methodology for the reliability assessment of corroding natural gas pipelines[J]. Journal of Loss Prevention in the Process Industries, 2019, 60: 1-8.
- [4] GOSWAMI S, GHOSH S, CHAKRABORTY S. Reliability analysis of structures by iterative improved response surface method[J]. Structural Safety, 2016, 60: 55-56. DOI: 10. 1016/ j. strusafe. 2016. 02. 002.
- [5] DENG J, GU Desheng, LI Xibing, *et al.* Structural reliability analysis for implicit performance functions using artificial neural network[J]. Structural Safety, 2005, 27(1): 25-48. DOI: 10. 1016/ j. strusafe. 2004. 03. 004.
- [6] 姜逢源, 董胜, 张鑫. 基于改进神经网络的板桩结构可靠性分析[J]. 海洋湖沼通报, 2018(2): 103-109.
- [7] WANG Wenxu, TANG Ruichun, LI Cheng. A BP neural network model optimized by mind evolutionary algorithm for predicting the ocean wave heights[J]. Ocean Engineering, 2018, 162: 98-107. DOI: 10. 1016/ j. oceaneng. 2018. 04. 039.
- [8] ROUSSOULY N, PETITJEAN F, SALAUN M. A new adaptive response surface method for reliability analysis[J]. Probabilistic Engineering Mechanics, 2013, 32: 103-115. DOI: 10. 1016/ j. probengmech. 2012. 10. 001.
- [9] BLATMAN G, SUDRET B. An adaptive algorithm to build up sparse polynomial chaos expansions for stochastic finite element analysis[J]. Probabilistic engineering mechanics, 2010, 25(2): 183-197. DOI: 10. 1016/ j. probengmech. 2009. 10. 003.
- [10] 张小庆, 康海贵, 王复明. 求解隐式功能函数可靠度的一种新方法[J]. 大连理工大学学报, 2003, 43(5): 650-653. DOI: 10. 3321/ j. issn: 1000-8608. 2003. 05. 024.
- [11] 张明. 结构可靠度分析: 方法与程序[M]. 北京: 科学出版社, 2009: 190-192
- [12] NGUYEN H D, SHIN M, TORBOL M. Reliability assessment of a planar steel frame subjected to earthquakes in case of an implicit limit-state function[J]. Journal of Building Engineering, 2020, 32: 101782. DOI: 10. 1016/ j. jobe. 2020. 101782.
- [13] 朱晨飞, 黄淑华, 王怀聪, 等. 一种改进的 BP-AdaBoost 算法及应用研究[J]. 现代电子技术, 2019, 42(19): 64-67, 72. DOI: 10. 16652/ j. issn. 1004-373x. 2019. 19. 015.
- [14] 吴俊利, 张步涵, 王魁. 基于 AdaBoost 的 BP 神经网络改进算法在短期风速预测中的应用[J]. 电网技术, 2012, 36(9): 221-225. DOI: 10. 13335/ j. 1000-3673. pst. 2012. 09. 037.
- [15] 刘阔, 李晓雷, 王健. 一种基于 Kriging 模型的机械结构可靠性分析方法[J]. 东北大学学报(自然科学版), 2017, 38(7): 1002-1006. DOI: 10. 12068/ j. issn. 1005-3026. 2017. 07. 019.

(责任编辑: 黄仲一 英文审校: 崔长彩)