

· 信息技术 ·



# 基于 BP-DS 证据理论的 航标状态识别模型研究\*

聂梓熠<sup>1,2</sup>, 蒋仲廉<sup>1</sup>, 初秀民<sup>1</sup>, 刘怀汉<sup>3</sup>

(1. 武汉理工大学, 国家水运安全工程技术研究中心, 湖北 武汉 430063;

2. 武汉理工大学 能源与动力工程学院, 湖北 武汉 430063; 3. 长江航道局, 湖北 武汉 430010)

**摘要:** 内河航标标示了可航行水域的边界, 是保障内河船舶安全航行的重要前提。面向内河航标不同故障模式, 构建一种基于 BP-DS 证据理论的航标状态识别模型。采用两个 BP 神经网络分别训练航标基础属性数据与环境因素数据, 计算独立的证据值; 通过 DS 证据理论实现航标运行状态识别结果的决策融合。结果表明, 基于 BP-DS 证据理论的航标状态识别模型精度达到 80% 以上, 高于传统经验阈值判别法。

**关键词:** 航标状态; BP(反向传播)神经网络; DS(Dempster-Shafer)证据理论; 决策融合

中图分类号: U 611

文献标志码: A

文章编号: 1002-4972(2022)01-0150-07

## Research on status recognition model of aids to navigation based on BP-DS evidence theory

NIE Zi-yi<sup>1,2</sup>, JIANG Zhong-lian<sup>1</sup>, CHU Xiu-min<sup>1</sup>, LIU Huai-han<sup>3</sup>

(1. National Engineering Research Center for Water Transport Safety, Wuhan University of Technology, Wuhan 430063, China;

2. School of Energy and Power Engineering, Wuhan University of Technology, Wuhan 430063, China;

3. Changjiang Waterway Bureau, Wuhan 430010, China)

**Abstract:** Inland aids to navigation mark the boundaries of navigable waters and play a significant role for ensuring the safe navigation of inland ships. Considering different failure modes of aids to navigation, we propose a status recognition model based on BP-DS evidence theory, use two BP neural networks to train the basic attribute data and environmental factor data, calculate the independent evidence values, and further apply the DS evidence theory to realize the decision-making fusion of aids to navigation operation state recognition results. The results show that the accuracy of status recognition model of aids to navigation based on BP-DS evidence theory is more than 80%, which is higher than the traditional empirical threshold judgment method.

**Keywords:** status of aids to navigation; back propagation neural network; Dempster-Shafer evidence theory; decision fusion

航标是内河水运常见的助航设施, 标示了船舶安全航行水域的边界。在内河智能航运系统<sup>[1]</sup>(shipping intelligent transportation system, SITS)中, 航标是感知层关键的信息采集与传输端口, 在岸岸协同的智能服务与智慧监管中发挥了至关重要

的作用。

早期的航标维护管理主要依赖人工定期巡检, 由于航标配布相对分散, 导致巡检过程耗时、耗力。随着通信技术快速发展, 国内外相关机构通过传统航标的基础上搭载多类型传感器, 研发

收稿日期: 2021-03-02

\*基金项目: 国家重点研发计划项目(2018YFB1600400); 国家自然科学基金项目(52071250、51709220)

作者简介: 聂梓熠(1996—), 男, 硕士研究生, 从事水路交通智能化领域研究。

通讯作者: 蒋仲廉(1986—), 男, 博士, 副研究员, 从事通航运行系统领域研究。E-mail: z. jiang@whut.edu.cn

了航标遥测遥控系统, 实现了航标状态的管理与监测<sup>[2-3]</sup>, 减少人为主观辨识且监测实时性更强。受内河复杂通航环境因素影响, 航标状态监测仍存在较大不确定性。根据长江武汉航道局辖区 2019 年下半年的统计数据, 设置航标遥测遥控终端总计 884 座, 因漂移、航标灯异常、航标灯电压异常等共报警 12.002 2 万次, 其中有效报警数量仅为 1.483 2 万次 (占比 12.4%), 存在大量的误报警现象。因此, 如何利用航标遥测遥感获取多源数据, 从而准确识别预判航标状态模式就显得尤为重要。

近年来, 交通、土木等领域的学者已提出了多种有效的状态识别模型与状态判别方法<sup>[4]</sup>。其中 BP (back propagation, 反向传播) 神经网络作为一种主流的应用算法, 基于 BP 神经网络的状态识别研究中, 巫威眺等<sup>[5]</sup>针对道路交通状态的不确定性, 在选定状态的影响因素量化状态特征后, 提出一种基于 BP 神经网络的状态判别方法, 经算例验证该方法收敛速度快、识别准确度高。杨则英等<sup>[6]</sup>建立 BP 神经网络模型, 以有限元模型得到的桥梁结构固有频率和单元位移作为输入, 识别桥梁结构损伤位置并判别损伤程度; 但当损伤程度微小时, 模型识别效果不佳。样本数据质量 (如特征数据与状态映射关系等) 在一定程度上影响着模型的识别准确度, 相关优化思路主要通过以下途径实现: 1) 对数据进行属性约简<sup>[7-8]</sup>; 2) 结合决策融合算法, 如 DS (Dempster-Shafer) 证据理论等。孔慧芳等<sup>[9]</sup>以电动汽车的故障状态为研究对象, 提出一种粒计算的属性约简算法处理数据, 将 BP 和 RBF (radial basis function, 径向基函数) 神经网络两个子网络识别结果通过 DS 证据理论相融合, 经实例分析验证可提高识别精度。汪广洪等<sup>[10]</sup>针对航天器故障状态复杂的问题, 提出基于 BP 和 DS 证据理论的组合模型, 改进传统依赖主观化赋值的判别方法。李瑞敏等<sup>[11]</sup>提出一种基于 BP 神经网络与 DS 证据理论的交通路段平均速度“融合黑箱”, 充分发挥了融合模型的自主性和不确定性推理能力, 并验证模型的适用性。

本文提出一种基于 BP-DS 证据理论的状态识别方法并将其应用于内河航标状态的故障识别中,

并以长江中游武桥水道航标数据为例, 验证模型识别精确度及其在水路交通领域的适用性。

1 BP-DS 证据理论模型研究

1.1 BP 理论模型

人工神经网络是由多个神经元组成的复杂网络结构, 广泛应用于非线性研究领域<sup>[12]</sup>。BP 神经网络是一种误差反向传递的多层前馈网络, 在数据输入与输出训练过程中, 完成两个阶段的操作。三层神经网络拓扑结构见图 1, 其中隐含层的节点数  $s$  由输入层  $x$  与输出层  $y$  节点数决定,  $\gamma$  为小于 10 的任意常数, 常用的经验公式:

$$s \geq \sqrt{x+y} + \gamma$$

(1)




图 1 BP 神经网络三层拓扑结构

每个神经元节点之间的传递输出准则定义为:

$$h_i(x) = \sum_{i=1}^n x_i w_i + b$$

(2)

式中:  $h_i(x)$  为输出值;  $w_i$  为神经元输入值的权重;  $b$  为阈值;  $x_i$  为输入值。激活函数可选取 tansig 函数与 logsig 函数, 公式为:

$$\text{tansig}(x) = \frac{2}{1 + e^{-2x}} - 1$$

(3)

$$\text{logsig}(x) = \frac{1}{1 + e^{-x}}$$

(4)

1.2 DS 证据理论

DS 证据理论是由 Dempster 与 Shafer 创建的一种决策融合算法<sup>[13-14]</sup>, 该算法通过量化可信度来处理不确定性。当存在多个证据信息时, 算法可充分发挥多证据融合的优势, 综合分析识别结果, 提高识别准确度。

定义 DS 证据理论基本假设集合为  $\Theta$ , 基本信

度分配函数表示证据体对事件的最初信任程度，是证据理论描述事件的基本单元；定义  $m$  是集合  $2^\Theta$  到  $[0, 1]$  的一个映射， $A$  代表辨识框架  $\Theta$  中的任一子集，记  $A \in \Theta$ ，且满足：

$$\begin{cases} m(\Theta) = 0 \\ \sum_{A \in \Theta} m(A) = 1 \end{cases} \tag{5}$$

式中： $m(A)$  为 mass 函数。在辨识框架  $\Theta$  中，对任意子集  $A$ ，如果存在  $m(A) > 0$ ，则称  $A$  为焦元。定义  $2^\Theta$  上的信任函数 Bel 和似然函数 Pl 满足：

$$\text{Bel}(A) = \sum_{B \in A} m(B) \tag{6}$$

$$\text{Pl}(A) = 1 - \text{Bel}(\bar{A}) = \sum_{A \cap B \neq \emptyset} m(B) \tag{7}$$

式中： $\text{Bel}(A)$  是事件  $A$  为真的信任度； $\text{Pl}(A)$  是事件  $A$  不为假的信任度，且  $\text{Bel}(A) \leq \text{Pl}(A)$ ， $\text{Pl}(A) - \text{Bel}(A)$  表示对  $A$  的不确定信任度。

假定  $m_1$ 、 $m_2$  是证据体  $A_i$  和  $B_j$  对应的两个信度分配函数，融合的过程可以表示为： $m(A) = m_1(A_i) \oplus m_2(B_j)$ 。融合规则的具体计算公式为：

$$m(A) = \frac{\sum_{A_i \cap B_j = A} m_1(A_i) \cdot m_2(B_j)}{1 - \sum_{A_i \cap B_j = \emptyset} m_1(A_i) \cdot m_2(B_j)} \tag{8}$$

2 状态识别模型构建

基于 BP-DS 证据理论的航标状态识别模型主要由 2 个主体部分构成：1) 以 BP 算法为核心的状态特征分类；2) 依据 DS 证据理论的决策融合。整体模型结构见图 2。

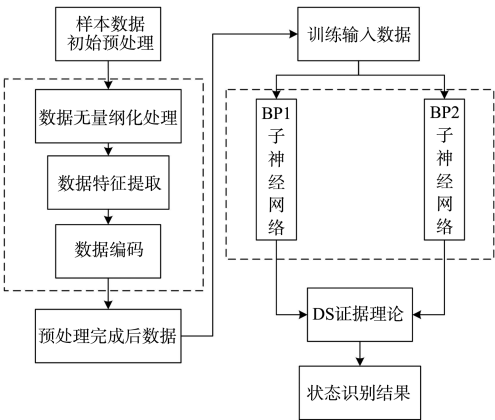


图 2 基于 BP-DS 证据理论识别结构框架

表征状态的样本数据具有时间、空间维度等

特征，样本数据预处理包括：无量纲化、数据特征提取等。

2.1 数据无量纲化

航标状态数据类型多、数值区间差异大，为挖掘状态数据信息，本文通过数据归一化实现无量纲化。数据归一化公式如下：

$$x^* = \frac{x - \min(x)}{\max(x) - \min(x)} \tag{9}$$

2.2 数据特征提取

对样本特征数据子集  $X = \{x_1, x_2, x_3, \dots, x_n\}$  进行二次去中心化(矩阵化)，即每一维特征数据都依次减去各自的中心特征值；计算样本集的协方差矩阵  $C = \frac{1}{n} X X^T$ ，并对协方差矩阵  $\frac{1}{n} X X^T$  进行二次特征分解，求得特征值和特征向量；将上述特征值由小到大依次进行排序，选择序列中最大的  $k$  个特征值，然后将其对应的  $k$  个特征向量进行提取组合成一个新的特征矩阵向量  $U$ 。

构建两个 BP 子神经网络，分别基于航标基础性数据特征量、环境因素特征量进行局部识别，输入层节点数依据各自的特征量个数决定，输出层节点个数对应 3 种状态类型，由于两个子网络输入特征维数并不多，隐含层节点数由式(1)可选定为 3 个，均采用三层 BP 神经网络，网络训练过程中学习率决定参数的更新幅度按照经验参数选值<sup>[15]</sup>，在初始尝试不同学习率 0.1、0.01、0.001 时不同参数取值的 BP 网络模型训练结果见表 1。综合比对模型收敛时的迭代次数与均方误差值，最终设计学习率为 0.01，目标均方误差为 0.025，激活函数选择 tansig 函数。

表 1 网络训练结果

隐含层	学习率	激活函数	迭代次数	均方误差值
3	0.1	tansig	103	0.194 4
3	0.1	logsig	89	0.147 0
3	0.01	tansig	141	0.031 7
3	0.01	logsig	179	0.064 2
3	0.001	tansig	274	0.047 0
3	0.001	logsig	262	0.065 4

依据网络输出和误差计算基本信度分配和不确定性信度，进行子神经网络局部识别；将神经





表 3 部分样本原始数据 2

水位/ m	水流流速/ (m·s <sup>-1</sup> )	船舶流量/ (艘·h <sup>-1</sup> )	江面 风力/级	正常 状态	航标灯 器失常	航标 离位
3.15	0.80	14	2	1	0	0
3.29	0.60	8	1	1	0	0
4.17	0.60	10	1	1	0	0
6.45	0.80	10	2	0	1	0
5.52	1.10	18	2	0	1	0
3.47	0.80	12	1	0	1	0
6.28	1.40	18	3	0	0	1
⋮	⋮	⋮	⋮	⋮	⋮	⋮
3.51	0.80	10	1	1	0	0
4.36	1.10	18	2	0	0	1
4.19	0.80	14	1	1	0	0

各成分特征值及累计方差贡献率计算结果见图 4。其中第 10 个成分的累计方差贡献率 SCR 为 86.265%，应当保留上述 10 个指标，说明这些指标能够反映出航标失常状态整体的 86% 特征。因此，从原始 19 个指标成分中选取该 10 个成分作为状态识别的样本数据集。成分 1~10 依次对应：位移距离、工作电流、充电电压、工作电压、充电电流、日光值、船舶流量、风力、流速、水位。结合航标报警类型，定义模型输出状态包括正常状态、航标灯器失常、航标离位状态。




图 4 成分特征值曲线

初始样本数据归一化处理后，条件属性 $\{R_1, R_2, R_3, R_4, R_5, R_6\}$ 分别代表当前日光值、位移距离、工作电压、工作电流、充电电压、充电电流； $\{E_1, E_2, E_3, E_4\}$ 分别代表当日水位、水流流速、船舶流量、江面风力级别。 $\{F_1, F_2, F_3\}$ 为决策属性，其中输出矩阵 $[1\ 0\ 0]$ 、 $[0\ 1\ 0]$ 、 $[0\ 0\ 1]$ 分别代表正常状态、航标灯器失常、航标离位状态。

3.3 结果分析与讨论

结合 3 种识别状态结果，各选取 3 组经归一化处理后的特征数据参数作为两个子神经网络的输入见表 4、5，测试输出结果见表 6。

表 4 BP<sub>1</sub>子网络特征数据输入

$R_1$	$R_2$	$R_3$	$R_4$	$R_5$	$R_6$	$F$
0.338	0.064	0.812	0.776	0.377	0.605	$F_1$
0.632	0.032	0.729	0.008	0.016	0.003	$F_2$
0.837	0.774	0.017	0.000	0.000	0.001	$F_3$


表 5 BP<sub>2</sub>子网络特征数据输入

$E_1$	$E_2$	$E_3$	$E_4$	$F$
0.171	0.071	0.191	0.000	$F_1$
0.299	0.429	0.238	0.334	$F_2$
0.241	0.732	0.619	0.667	$F_3$

表 6 识别结果

子网络	$F_1$	$F_2$	$F_3$	识别状态
BP <sub>1</sub>	0.684	0.015	0.298	$F_1$
	0.012	0.763	0.197	$F_2$
	0.003	0.091	0.892	$F_3$
BP <sub>2</sub>	0.531	0.336	0.104	$F_1$
	0.357	0.490	0.132	$F_2$
	0.018	0.113	0.847	$F_3$

训练过程中，两个 BP 子神经网络的误差曲线见图 5。子网络 BP<sub>1</sub>在训练步长 259 次时收敛，均方误差 0.032 86；子网络 BP<sub>2</sub>在训练步长 180 次时收敛，均方误差值 0.097 74。由表 6 子神经网络的识别结果可见：针对航标灯器失常的状态  $F_2$ ，子网络 BP<sub>1</sub>识别率为 0.763，而子网络 BP<sub>2</sub>识别率为 0.490，说明以单一环境指标为数据输入的网络 2，并不能有效识别  $F_2$  状态。



a) BP<sub>1</sub>子网络




图 5 误差训练曲线

利用神经网络输出结果, 计算每个证据对每种状态的基本可信度  $M$ , 即:

$$M = \sum_{i=1}^n \sigma(A_i) + e_1 \tag{11}$$

$$e_1 = \frac{1}{n} \sum_{i=1}^n [\sigma(A_i) - y_i]^2 \tag{12}$$

式中:  $\sigma(A_i)$  为神经网络对每一种状态类型的识别结果;  $e_1$  为误差值;  $y_i$  为期望输出结果。

证据对不同状态类型的信度值  $m(A_i)$  与不确定度值  $m(\Theta)$  的表达式为:

$$m(A_i) = \frac{\sigma(A_i)}{M} \tag{13}$$

$$m(\Theta) = \frac{e_1}{M} \tag{14}$$

根据式(13)(14), 计算可得不同子网络的可信度值, 见表 7。

表 7 可信度分配值				
子网络	$m_1(F_1)$	$m_1(F_2)$	$m_1(F_3)$	$m_1(\Theta)$
BP <sub>1</sub>	0.645	0.014	0.281	0.059
	0.012	0.759	0.196	0.032
	0.003	0.091	0.894	0.012
BP <sub>2</sub>	0.488	0.309	0.096	0.108
	0.321	0.441	0.119	0.121
	0.018	0.114	0.855	0.012

由信度分配结果可知: 以环境因素为特征输入量的子网络 BP<sub>2</sub>对状态  $F_1$  和  $F_2$  的识别不确定度分别是 0.108 和 0.121。通过证据融合规则, 对子网络 1 和 2 中各状态的可信度分配值进行融合计算, 见式(8); 结合 DS 证据理论决策融合, 航标运行状态识别结果见表 8。

表 8 决策融合状态识别结果			
状态 $F_1$	状态 $F_2$	状态 $F_3$	不确定度
0.815	0.107	0.065	0.012
0.058	0.896	0.041	0.003
0.015	0.024	0.959	0.001

对比融合后的识别结果, 3 组测试数据的状态识别率分别为 0.815、0.896、0.959, 与子网络 BP<sub>1</sub>、BP<sub>2</sub>识别结果相比, 可信度明显提高, 状态辨识更准确。

4 结语

1) 面向内河智能航运和智能服务技术发展, 本文提出了一种基于 BP-DS 证据理论的内河航标状态识别模型。模型将影响内河航标运行状态的因素分为两类输入神经网络模型, 输出各状态的基本信度函数, 借助 DS 证据理论实现决策融合。以长江干线武桥水道航标运行数据为例, 测试验证了该模型在水路交通领域的适用性。

2) 与传统依赖经验阈值识别航标状态方法不同, 通过 BP 神经网络与 DS 证据理论对判别航标失常状态的数据进行量化分析, 相比主观化赋值的识别结果更具有可靠性。

3) 在单一 BP 子网络的识别基础上, 结合 DS 证据理论有效提高了航标运行状态的识别准确度, 经过决策融合后识别率可达 80% 以上, 且整体不确定度低于 2%。

4) 针对状态研究成果可为航道基础设施运行状态在线监测与智能辨识提供参照。

参考文献:

[1] 严新平, 柳晨光. 智能航运系统的发展现状与趋势[J]. 智能系统学报, 2016, 11(6): 807-817.

[2] 陆敏. 基于无线传感网络与 AIS 的航标遥测遥控系统设计与实现[D]. 武汉: 武汉理工大学, 2012.

[3] 桑凌志, 洪四雄. 南海海区航标遥测遥控系统完善与优化[J]. 中国航海, 2020, 43(2): 35-40.

[4] 常丽君, 郑黎黎, 杨帆. 基于 (SAGA-FCM)-PNN 的交通状态判别方法研究[J]. 交通信息与安全, 2019, 37(2): 120-127.

[5] 巫威眺, 靳文舟, 林培群. 基于 BP 神经网络的道路交通

状态判别方法研究[J].交通信息与安全, 2011, 29(4): 71-74, 79.

[6] 杨则英, 张亚磊, 曲建波, 等. 基于 BP 神经网络的中等跨径桥梁损伤识别探讨[J].公路与汽运, 2020(3): 136-140, 155.

[7] 苗夺谦, 胡声丹. 基于粒计算的不确定性分析[J].西北大学学报(自然科学版), 2019, 49(4): 487-495.

[8] KONG H, ZHANG X, BAO W, et al. The application of granular computing in electric vehicle fault diagnosis[J]. Australian journal of electrical and electronics engineering, 2014, 11(3): 327-337.

[9] 孔慧芳, 罗京, 闫嘉鹏. 基于 GrC-NN 和 DS 证据理论的电动汽车故障诊断[J].合肥工业大学学报(自然科学版), 2020, 43(5): 629-633, 672.

[10] 汪广洪, 陈险峰. 基于 BP 神经网络和 DS 证据理论的航天器故障诊断方法[J].遥测遥控, 2009, 30(6): 52-55.

[11] 李瑞敏, 马玮. 基于 BP 神经网络与 D-S 证据理论的路段平均速度融合方法[J].交通运输工程学报, 2014, 14(5): 111-118.

[12] 李赞恒. 基于 BP 神经网络的采煤机截割部故障诊断研究[D].西安: 西安科技大学, 2017.

[13] DEMPSTER A P. Upper and lower probabilities induced by a multivalued mapping[J]. Annals of mathematical statistics, 1967, 38(2): 325-339.

[14] SHAFER G.A mathematical theory of evidence[M].Princeton: Princeton University Press, 1976.

[15] 玄扬, 王汝凉. BP 神经网络的双重优化的改进研究[J].广西师范学院学报(自然科学版), 2018, 35(1): 60-65.

[16] 陈建, 张文江, 曾涛. 长江中游武桥水道航道整治方案研究[J].水运工程, 2012(10): 87-91.

[17] 马瑞, 康仁, 罗斌, 等. 基于改进主成分分析法的火电机组能耗特征识别方法[J].电网技术, 2013, 37(5): 1196-1201.

(本文编辑 王璁)

~~~~~

(上接第 99 页)

[4] 长江航道规划设计研究院、长江重庆航运工程勘察设计院. 长江三峡工程航道泥沙原型观测 2011—2012 年度分析报告[R].重庆: 长江重庆航运工程勘察设计院, 2012.

[5] 长江航道规划设计研究院, 长江重庆航运工程勘察设计院. 长江三峡工程航道泥沙原型观测 2012—2013 年度分析报告[R].重庆: 长江重庆航运工程勘察设计院, 2013.

[6] 长江航道规划设计研究院, 长江重庆航运工程勘察设计院. 长江三峡工程航道泥沙原型观测 2013—2014 年度分析报告[R].重庆: 长江重庆航运工程勘察设计院, 2014.

[7] 长江航道规划设计研究院, 长江重庆航运工程勘察设计院. 长江三峡工程航道泥沙原型观测 2014—2015 年度分析报告[R].重庆: 长江重庆航运工程勘察设计院, 2015.

[8] 长江航道规划设计研究院, 长江重庆航运工程勘察设计院. 长江三峡工程航道泥沙原型观测 2015—2016 年度分析报告[R].重庆: 长江重庆航运工程勘察设计院, 2016.

[9] 长江航道规划设计研究院, 长江重庆航运工程勘察设计院. 长江三峡工程航道泥沙原型观测 2017—2018 年度分析报告[R].重庆: 长江重庆航运工程勘察设计院, 2018.

[10] 长江航道规划设计研究院, 长江重庆航运工程勘察设计院. 长江三峡工程航道泥沙原型观测 2018—2019 年度分析报告[R].重庆: 长江重庆航运工程勘察设计院, 2019.

[11] 袁晶, 许全喜, 董炳江. 输沙量法与断面法差别原因及其适用性研究-以三峡水库为例[J].水文, 2011, 31(S1): 87-91.

[12] 胡江, 杨胜发, 王兴奎. 三峡水库 2003 年蓄水以来库区干流泥沙淤积初步分析[J].泥沙研究, 2013(1): 39-44.

(本文编辑 武亚庆)