基于视觉质量评估与隐马尔可夫模型的高压水射流管路压力预警方法①

侯奔，符章捷
（长沙矿冶研究院有限责任公司 深海矿产资源开发利用技术国家重点实验室，湖南 长沙 410012）

摘　要：针对高压水射流管路，提出一种非侵入式的压力间接估计与预警方法。通过 EfficientNet 深度学习模型，对清理前后钢板表面图像进行质量等级评级，以评级和系统设定压力构建可观测序列，以隐马尔可夫模型建立该序列与水射流管路压力状态之间的隐含映射，解码出压力状态序列，以状态序列的特征实现压力异常预警。工业实验结果表明，本方法压力异常检测准确率达到 91.2%、F1 分数达到 88.3%，检测性能显著优于阈值法、逻辑回归法。该方法对高压水射流装置的智能运维具有实际指导意义。

关键词：高压水射流；压力预警；隐马尔可夫模型；深度学习；机器视觉；状态估计；表面图像
中图分类号：TG178；TP311　　**文献标志码**：A　　doi：10.3969/j.issn.0253-6099.2026.02.031
文章编号：0253-6099(2026)02-0190-05

An Early Warning for High-Pressure Water-Jet Pipelines Based on Visual Quality Assessment and Hidden Markov Model

HOU Ben，FU ZhangJie
(*State Key Laboratory of Exploitation and Utilization of Deep-Sea Mineral Resources*，*Changsha Research Institute of Mining and Metallurgy Co.*，*Ltd.*，*Changsha* 410012，*Hunan*，*China*)

Abstract：A non-intrusive indirect pressure estimation and early warning is proposed for high-pressure water-jet pipelines. The EfficientNet deep learning model is employed to evaluate the quality grade of steel plate surface before and after cleaning based on the images. Observable sequences are constructed by the quality grades and system-set pressure. A hidden Markov model (HMM) is then adopted to capture the latent mapping between such sequences and the pressure states of water-jet pipelines, and the pressure state sequences are decoded. Based on the characteristics of the decoded sequences, abnormal pressure can be detected and warned. Industrial experiments demonstrate that the proposed method can achieve an accuracy of 91.2% and an F1 score of 88.3% in abnormal pressure detection, with performance significantly superior to that of the threshold-based method and logistic regression. This method is of practical guiding significance for the intelligent operation and maintenance of high-pressure water-jet equipment.

Key words：high-pressure water jet；early warning of pressure；hidden Markov model (HMM)；deep learning；machine vision；state estimation；surface image

高压水射流装置因其高效、环保的特点，已应用于大型钢板、钢结构件表面清理除锈。该装置的清理效果直接取决于冲击动能，其核心影响因素是水射流管路的压力。若水射流管路压力出现下降或剧烈波动，这会导致钢材表面清理不均、除锈质量下降，严重时甚至会造成生产中断。目前，工业上通常采用开孔安装机械压力表或压电式传感器的方式[1]对金属高压管路进行压力监测，但在高压水射流清理装置中，为适应喷头的频繁拆装与角度调整，连接喷头的水射流管路材料常采用非金属材质，如果在此类管路上开孔安装传感器，不仅会显著削弱其耐压强度和结构完整性，容易引发泄漏风险，而且其测量点也无法真实反映因管路弯折、堵塞导致的终端压力损失。因此，开发一种非侵入、间接式的压力监测与预警方法，对提升清理装置

① **收稿日期**：2025-11-15
基金项目：国家重点研发计划(2023YFC2811300)
作者简介：侯奔(1980—)，男，湖南长沙人，硕士，正高级工程师，主要研究方向为信息技术、智能控制、计算机仿真。E-mail：329168671@qq.com

的可靠性与智能化水平具有重要意义。

本文创新性地提出了一种基于视觉质量评估[2]与隐马尔可夫模型[3]的高压水射流管路压力状态间接监测与智能预警方法。该方法摒弃了传统直接测量模式,利用计算机视觉技术实时采集钢板清理前后的表面图像数据,并以此作为推断水射流管路压力状态的依据;通过对清理效果的精确评估,结合时序建模,实现了对管路压力异常模式的非接触式感知和早期预警。

1　高压水射流管路压力预警方法设计

1.1　总体设计

本文提出的高压水射流管路压力预警总体架构如图 1 所示。整个系统由 2 个串联的模型和 4 个主要功能模块组成。

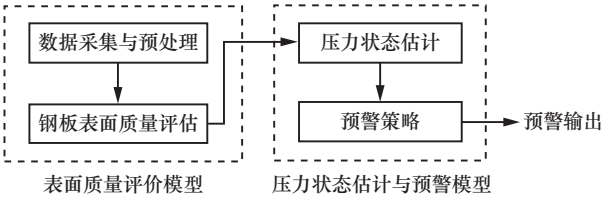


图 1　高压水射流管路压力预警总体架构

Fig. 1　Overall architecture of early-warning system for high-pressure water-jet pipeline

数据采集与预处理模块负责采集原始数据,包括钢板清理前后的表面图像和高压泵设定压力;钢板表面质量评估模块是一个离线训练好的 EfficientNet[4-5]深度学习模型,输入是钢板清理前后的实时子图像,输出是图像对应的表面质量等级标签;压力状态估计模块是一个预先通过无监督学习训练好的隐马尔可夫模型(hidden Markov model, HMM),将由质量等级标签构成的可观测序列解码为对应的水射流管路隐含压力状态;预警策略模块根据规则触发水射流管路压力报警信号。

1.2　基于深度学习的表面质量评价模型

1.2.1　数据集构建与预处理

数据集来自历史数据库和实验采集。实验采集中,在确保输送速度恒定的前提下,将高压泵的工作压力(36~50.5 MPa)以 0.5 MPa 为间隔划分为 30 个等级;在每个压力等级下,对 5 块实验钢板进行清理,在此过程中,使用固定安装的前置、后置相机采集每块钢板清理前后的高清图像,共收集钢板图像 300 张。此外,从历史数据库中调取相关图像 300 张,扩充图像样本至 600 张。根据表面清理装置中实际清理机位数量 m,将每张钢板图像沿宽度方向(输送方向)分割为 m 个矩形子图像,例如,使用 4 个清理机位($m=4$)的高压水射流装置进行表面清理时,钢板图像被分为区域 1~区域 4 共 4 个子图像,每个子图像对应 1 个清理机位的清理范围,如区域 1 表示 1 号清理机位负责的清理区域,依此类推。钢板图像分区方法见图 2。

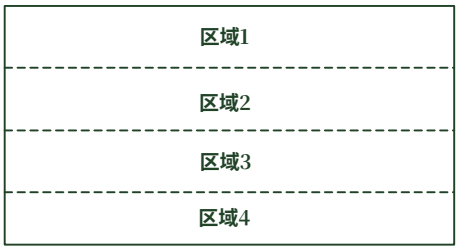


图 2　钢板图像分区方法

Fig. 2　Partitioning method for steel plate images

定义 1 个 7 分类的表面质量等级标签集合 Q:

$Q=\{$质量很差,质量差,质量较差,平均,质量较好,质量好,质量很好$\}$

根据经验对每 1 个子图像手动标注质量等级标签。最终构建包含清理前、清理后的 2 400 个子图像以及对应质量等级标签形成的数据集 $D1$。

1.2.2　模型网络与训练

选用 EfficientNet-B0[6] 作为模型骨干网络,EfficientNet 通过复合缩放方法在模型深度、宽度和分辨率之间实现平衡,从而在参数量和计算量较小的情况下取得卓越性能[8]。本文构建的表面质量评价模型的网络结构见图 3。

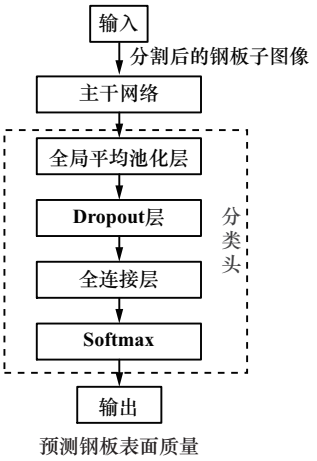


图 3　表面质量评价模型的网络结构

Fig. 3　Network architecture of surface quality evaluation model

网络的输入为分割后的钢板清理前后子图像。主干网络 EfficientNet-B0 由一系列卷积层堆叠而成,为加速模型训练,载入经过 ImageNet 图像集训练后的预训练权重。主干网络的尾部接分类头,见图 3 中的虚线框,由全局平均池化层后接一个丢弃率为 0.5 的

Dropout 层,防止过拟合,Dropout 层后是 7 个神经元组成的全连接层,并使用 Softmax 函数激活。网络的输出是输入图像对应的表面质量等级标签,且标签值属于集合 Q。

将数据集 $D1$ 按照 8:1:1的比例划分成训练集、验证集、测试集对网络进行训练,损失函数 L 为交叉熵损失,训练目标是使损失函数 L 最小,使用 AdamW 作为优化器,使用验证集评估网络性能,指标包括准确率和 F1 分数。

损失函数 L 定义为:

$$L = -\sum_{i=1}^{c}\left[y_i \lg(\hat{\boldsymbol{y}}_i)\right] \tag{1}$$

式中:c 为表面质量评级的标签类别总数,$c=7$;y_i 为真实标签的 One-hot 编码,即样本真实类别为 i,则 $y_i=1$,否则 $y_i=0$;预测的概率分布$\hat{\boldsymbol{y}}_i=(\hat{y}_1,\hat{y}_2,\cdots,\hat{y}_c)$ 是一个概率向量,每个元素表示对应表面质量等级的预测概率。

1.3 基于 HMM 的压力状态估计与预警模型

基于 HMM 的压力状态估计与预警模型如图 4 所示。模型分为离线训练阶段和在线估计阶段。离线训练阶段是将原始可观测数据通过 Baum-Welch 算法进行训练,得到模型最优参数阶段;在线估计阶段是使用最优参数和实时采集的可观测序列,针对水射流管路压力进行评估和预警的阶段。

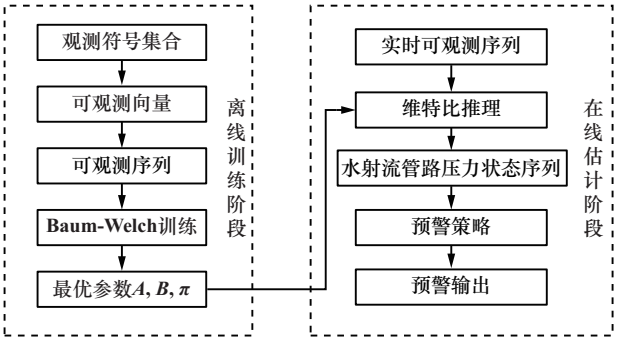


图 4 基于 HMM 的水射流管路压力状态估计与预警模型

Fig. 4 HMM-based pressure state estimation and early-warning model

1.3.1 HMM 估计模型设计

HMM 是一个双重随机过程模型,具有强大的时序建模能力以及对隐含状态的推断机制[7-8],该模型由五元组($\boldsymbol{S}$, $\boldsymbol{O}$, $\boldsymbol{\pi}$, $\boldsymbol{A}$, $\boldsymbol{B}$)定义,其中 $\boldsymbol{S}$ 为隐含状态,$\boldsymbol{O}$ 为观测符号集合,$\boldsymbol{\pi}$、$\boldsymbol{A}$、$\boldsymbol{B}$ 均为模型关键参数,其中 $\boldsymbol{\pi}$ 为初始状态概率分布,$\boldsymbol{A}$ 为状态转移概率矩阵,$\boldsymbol{B}$ 为观测概率分布。

在本文模型中,隐含状态 $\boldsymbol{S}$ 定义为水射流管路在某一时刻的实际压力状态,是不可直接观测的,将其离散化为 5 个状态:$\boldsymbol{S}=\{S_1,S_2,S_3,S_4,S_5\}$,分别表示(压力低,较低,平均,较高,高)。观测符号集合 $\boldsymbol{O}$ 表示在某一时刻系统可观测到的特征,需要根据应用场景设计。在本文中,可观测特征被定义为表面质量评价模型输出的钢板清理前后的表面质量等级以及高压泵设定压力。初始状态概率分布 $\boldsymbol{\pi}$ 表示水射流管路压力在初始时刻处于状态 S_i($i\in[1,5]$)的概率;状态转移概率矩阵 $\boldsymbol{A}$ 表示水射流管路压力从状态 S_i 转移到状态 S_j($j\in[1,5]$)的概率;观测概率分布 $\boldsymbol{B}$ 表示水射流管路压力在时刻 t 处于状态 S_j 时,观测到可观测向量 $\boldsymbol{O}_t$ 的概率,$\boldsymbol{O}_t$ 由可观测特征组成。

1.3.2 可观测向量的构建与预处理

在时刻 t,可观测向量 $\boldsymbol{x}_t$ 定义为:

$$\{\boldsymbol{x}_t=(Q_{bt},Q_{at},\Delta Q,P_t)\} \tag{2}$$

$$\Delta Q = Q_{bt}-Q_{at} \tag{3}$$

式中:Q_{bt}为钢板清理前的表面质量评级;Q_{at}为清理后的表面质量评级;ΔQ 表示清理效果;P_t 表示高压泵设定压力。

对于表面质量评级的 Q_{bt}和 Q_{at}的归一化方法为:

$$Q' = \frac{Q}{7} \tag{4}$$

式中:Q'为归一化后的表面质量评级;Q 为清理前或清理后的表面质量评级的离散值。如:当评价为“质量差”时,归一化结果为 $Q'=2/7$。

对于高压泵设定压力采用 Z-score 进行归一化,将数据缩放到均值为 0,标准差为 1 的分布:

$$P_t' = \frac{P_t-\mu}{\sigma} \tag{5}$$

式中:P_t'为归一化后的高压泵设定压力;P_t 为原始的高压泵设定压力值;μ 为高压泵设定压力的均值;σ 为高压泵设定压力的标准差。

经过预处理后,得到能用于模型训练的可观测向量 $\boldsymbol{x}'_t$:

$$\{\boldsymbol{x}_t'=(Q_{bt}',Q_{at}',\Delta Q_t',P_t')\} \tag{6}$$

其中:

$$\Delta Q_t' = Q_{bt}'-Q_{at}'$$

1.3.3 模型训练

采用 Baum-Welch 算法进行无监督学习,从大量可观测向量 $\boldsymbol{x}_t'$组成的可观测序列$\{x_1',x_2',\ldots,x_n'\}$中估计出最优的模型参数 $\lambda^*=(\boldsymbol{A},\boldsymbol{B},\boldsymbol{\pi})$,使得该模型在最优参数下产生此观测序列的概率最大,处理过程分为参数初始化和迭代优化两部分[9]。

1）初始化模型关键参数 $\boldsymbol{A}$,$\boldsymbol{B}$,$\boldsymbol{\pi}$。

状态转移概率矩阵 $\boldsymbol{A}$。考虑到高压水射流管路压力通常不会在短时间内突变,故采用平滑初始化,即:

$$\boldsymbol{A}=\begin{bmatrix}0.6 & 0.3 & 0.1 & 0.0 & 0.0\\ 0.2 & 0.5 & 0.2 & 0.1 & 0.0\\ 0.1 & 0.2 & 0.4 & 0.2 & 0.1\\ 0.0 & 0.1 & 0.2 & 0.5 & 0.2\\ 0.0 & 0.0 & 0.1 & 0.3 & 0.6\end{bmatrix} \tag{7}$$

由于本模型是长时间运行的,初始状态的概率分布可以设置为均匀分布,即:

$$\boldsymbol{\pi}=[0.2,0.2,0.2,0.2,0.2] \tag{8}$$

观测概率分布 $\boldsymbol{B}$ 表示每个隐含状态 $\boldsymbol{S}$ 产生可观测向量的概率,由于本文中可观测向量 $\boldsymbol{x}_t'$ 是四维特征向量,由高斯分布可知,$\boldsymbol{B}$ 由每个隐含状态的均值向量 $\boldsymbol{\mu}_i$ 和协方差矩阵 $\sum_i$ 组成,即:

$$\boldsymbol{B}=\begin{bmatrix}S_1 & \mu_1 & \sum_1\\ S_2 & \mu_2 & \sum_2\\ S_3 & \mu_3 & \sum_3\\ S_4 & \mu_4 & \sum_4\\ S_5 & \mu_5 & \sum_5\end{bmatrix} \tag{9}$$

2）迭代优化。

初始化完成后进行迭代优化,Baum-Welch 算法包含两个步骤:E 步 (Expectation)根据当前的参数估计,计算在给定观测序列下,隐含状态序列的后验概率;M 步 (Maximization)利用 E 步计算的后验概率,重新估计 HMM 参数($\boldsymbol{A}$, $\boldsymbol{B}$, $\boldsymbol{\pi}$),使观测序列的似然概率最大化。在每次迭代中,依次执行 E 步和 M 步,直到参数变化小于预设的收敛阈值或达到最大迭代次数。最终获得将表面质量观测序列映射到高压水射流管路压力状态的 HMM 模型的最优参数,$\lambda^*=(\boldsymbol{A},\boldsymbol{B},\boldsymbol{\pi})$。

1.3.4　状态解码与预警

使用已部署的 HMM 模型,对实时输入的表面质量可观测序列进行估计,得到水射流管路压力状态序列,序列长度定义为 n,可由经验调整。使用维特比算法对隐含状态进行解码,找到最可能的水射流管路压力状态序列 S_t,即最大化 $P(S_1,S_2,\cdots,S_n|x_1',x_2',\cdots,x_n')$。

根据设备的运行经验,设定的压力低和压力波动两类预警策略分别如下:

若水射流管路压力状态序列 $S^*=\{S_1,S_2,\cdots,S_n\}$ 中状态值出现连续两次下降,且后续状态持续维持在“较低”或“低”水平超过 h 个时间点(h 为可设定阈值),则触发压力低报警;

若序列 S^* 中状态在非相邻等级间,如“较高”与“较低”之间频繁跳变超过一定次数 k(k 为可设定阈值),则触发压力波动报警。

2　实验验证与结果分析

2.1　实验设置

在一个拥有 4 个清理机位的高压磨料水射流表面清理装置(见图 5)上验证预警系统。由输送辊带动钢板从右到左依次通过 4 个清理机位进行表面清理,每个清理机位清理钢板的一部分区域(参见图 2)。该清理装置配备 4 台变频器控制的高压泵,分别用于调节每个机位中水射流管路压力,图中仅画出 1 号机位中的水射流管路,其他机位中的水射流管路与 1 号机位中的布置方式相同。人为模拟两种故障工况:在 3 号机位水射流管路上安装节流阀以模拟堵塞导致压力下降;周期性上下调节 4 号机位的变频器设定值调节水射流压力,模拟泵源不稳定导致的水射流管路压力波动。

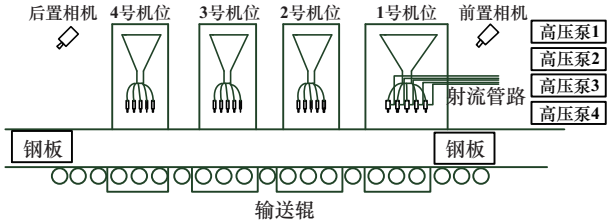


图 5　高压磨料水射流表面清理装置

Fig. 5　Surface cleaning device by high-pressure water-jet with abrasive blasting

2.2　结果与分析

在实验过程中,前置、后置相机分别拍摄清理前后的板材表面图像,并将图像输入已训练好的表面质量评价模型,分别得到表面质量预测结果,结合高压泵设定压力值,构建可观测向量,由 8 个可观测向量构成一个可观测序列 $\{x_1',x_2',\cdots,x_8'\}$,并输入训练好的基于 HMM 的压力状态估计与预警模型,按照维特比算法的初始化、递推、终止、回溯 4 个步骤进行计算,得到预测的水射流管路压力状态序列。

1）初始化。

$$\delta_1(i)=\pi_i B_i(x_1'),\ i\in\{1,2,3,4,5\} \tag{10}$$

2）递推。

$$\delta_t(j)=\max_i \delta_{t-1}(i)A_{ij}B_j(x_t') \tag{11}$$

$$\psi_t(j)=Arg\max_i \delta_{t-1}(i)A_{ij} \tag{12}$$

其中 $j\in\{1,2,3,4,5\}$, $t=2,3,\cdots,8$。

3）终止。

$$S_t=Arg\max_i \delta_t(i) \tag{13}$$

4）回溯。还原最大可能的水射流管路压力状态序列$\{S_t\}$，从S_t开始，利用$\psi_t(j)$变量反向回溯，即可恢复出最可能隐含的水射流管路压力状态序列$S^*=\{S_1^*,S_2^*,\cdots,S_8^*\}$；式（10）~（13）中的$\boldsymbol{\pi}$、$\boldsymbol{A}$、$\boldsymbol{B}$即为1.3.3节所得HMM模型最优模型参数。

在人为注入故障后某个时刻，由维特比算法解码得到的4组水射流管路压力状态序列如表1所示。

表1 四组水射流管路压力状态序列

Table 1 Pressure state sequences of four sets of water jet pipes

清理机位	压力状态序列 S^*	故障类型
1号机位	$\{S_1,S_3,S_3,S_4,S_4,S_3,S_3,S_3\}$	无
2号机位	$\{S_1,S_2,S_3,S_4,S_3,S_3,S_4,S_3\}$	无
3号机位	$\{S_1,S_3,S_3,S_4,S_3,S_2,S_2,S_2\}$	压力低
4号机位	$\{S_1,S_3,S_3,S_4,S_2,S_4,S_1,S_4\}$	压力波动

图6为各机位时序可视化压力状态图。横轴“时间步”为序列编号。1号与2号机位在实验中未注入故障，其压力序列主要在S_3、S_4等正常工作压力区间内波动，尽管存在S_1这种短时低压状态，但随后迅速恢复，并未形成持续的异常模式；在3号机位水射流管路中，出现压力连续两次下降（S_4-S_3-S_2）并持续维持在较低的压力区间超过3次，有可能出现压力低的故障，因此对3号机位水射流管路发出压力低的预警；在4号机位水射流管路中，出现压力反复波动（S_4-S_2-S_4-S_1-S_4）4次，且状态在非相邻等级间改变，因此对4号机位水射流管路发出压力波动的预警。以上结果与实验设计的压力异常注入现象吻合。

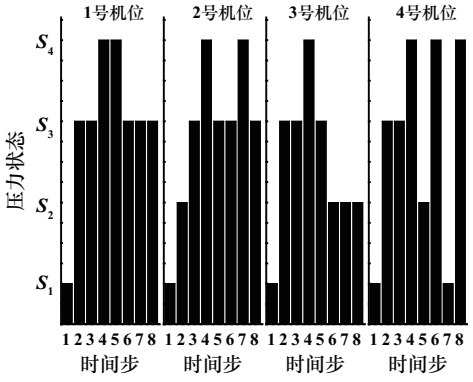


图6 各机位时序可视化压力状态图

Fig. 6 Pressure state diagram

将本文方法与阈值法、逻辑回归法进行了对比，结果见表2。阈值法是直接对1.3.2节中的表面质量等级差值ΔQ_t设定阈值，低于阈值即报警；逻辑回归法则使用逻辑回归模型，根据钢板清理前的表面质量评级Q_{bt}、清理后的表面质量评级Q_{at}，训练一个分类器预测压力正常或异常。评价指标包括准确率、精确率、召回率和F1分数。

表2 不同方法在压力异常检测上的性能对比

Table 2 Performance comparison of different methods in abnormal pressure detection

方法	准确率/%	精确率/%	召回率/%	F1分数/%
阈值法	62.3	58.1	55.4	51.5
逻辑回归	68.5	64.2	63.8	62.1
本文方法	91.2	86.4	89.5	88.3

从表2可见，本文提出的HMM方法在所有指标上均显著优于其他两种方法，其中F1分数相较阈值法提升36.8百分点，较逻辑回归法提升26.2百分点，验证了HMM在处理含时序依赖的工业信号中的优越性。阈值法每次评估都是独立地查看当前的差值是否超过预设阈值，一个小的波动就可能被误判，而且由于缺乏时序信息，无法有效处理缓慢劣化过程，召回率仅55.4%，存在较高的漏检率；逻辑回归法虽能学习简单的非线性关系，但处理的是离散的、独立的数据点，无法建立状态间的时序依赖关系来判断当前压力状态的趋势或异常，由于忽略了状态连续性，精确率为64.2%，误报率偏高。

以上实验验证结果表明，视觉质量评估-HMM状态估计方法能够以较高的准确率和F1分数实现对水射流管路压力的非接触式预警。

3 结论

1）提出了一种视觉质量评估-HMM状态估计方法，利用表面质量作为压力间接表征，实现了对高压水射流管路压力的非侵入式在线估计与预警，解决了传统传感器不便安装、测量位置失真的工程难题。

2）构建了融合清理前后表面质量差值与系统设定压力的多维观测序列，并利用HMM建立时序映射模型，有效反映了压力与清理效果之间的动态耦合关系，工程实验中准确率达91.2%、F1分数达88.3%，本预警方法显著优于阈值法、逻辑回归法。

3）通过维特比解码得到的压力状态序列，能够基于时序模式进行早期预警，既能识别持续性压力衰减，又能区分高频波动引起的非稳定工况，可为设备运维提供有效参考。

参考文献（References）：

[1] 李小松，赵承佑，秦帅，等. 自流充填系统的管道压力与流量特征研究[J]. 矿冶工程，2024，44(3)：6-10.
LI Xiaosong，ZHAO Chengyou，QIN Shuai，et al. Pressure and flow-rate characteristics of free fall backfill system[J]. Mining and Metallurgical Engineering，2024，44(3)：6-10.

（下转第199页）

composites[J]. Journal of Synthetic Crystals, 2022,51(4):716-722.
[5] 汪海涛,张志远,张远鹏,等. 氮化钛陶瓷力学性能与结构关系[J]. 功能材料, 2018,49(7):7099-7105.
WANG Haitao, ZHANG Zhiyuan, ZHANG Yuanpeng, et al. The relationship between dynamic mechanical properties and structure of TiN cermet[J]. Journal of Functional Materials, 2018, 49(7): 7099-7105.
[6] SHOBU K, WATANABE T, ENOMOTO Y, et al. Frictional properties of sintered TiN-TiB_2 and Ti(CN)-TiB_2 ceramics at high temperature[J]. Journal of the American Ceramic Society, 1987,70(5):C-103-C-104.
[7] 王晓楠,陶强,左斌,等. B_4C-TiB_2 复相陶瓷材料研究进展[J]. 陶瓷学报, 2020,41(6):783-795.
WANG Xiaonan, TAO Qiang, ZUO Bin, et al. Research progress of B_4C-TiB_2 composite ceramics [J]. Journal of Ceramics, 2020, 41(6):783-795.
[8] 刘明明,胡美华,毕宁,等. TiB_2-B_4C 陶瓷复合材料高压烧结与性能表征[J]. 硅酸盐通报, 2020,39(3):910-915.
LIU Mingming, HU Meihua, BI Ning, et al. High-pressure sintering and performance characterization of TiB_2-B_4C ceramic composites[J]. Bulletin of the Chinese Ceramic Society, 2020,39(3):910-915.
[9] 覃波,周后明,曾国章,等. TiB_2/TiN/WC 复合陶瓷刀具材料力学性能及其摩擦磨损性能[J]. 中国陶瓷, 2019,55(5):7-13.
QIN Bo, ZHOU Houming, ZENG Guozhang, et al. Mechanical properties and friction and wear performance of TiB_2/TiN/WC composite ceramic tool materials[J]. China Ceramics, 2019,55(5):7-13.
[10] 黎军军,赵学坪,陶强,等. 二硼化钛的高温高压制备及其物性[J]. 物理学报, 2013,62(2):491-497.
LI Junjun, ZHAO Xueping, TAO Qiang, et al. Characterization of TiB_2 synthesized at high pressure and high temperature[J]. Acta Physica Sinica, 2013,62(2):491-497.
[11] 赵鹏铎,王琪,张磊,等. B_4C-TiB_2-SiC 复合陶瓷的 SPS 制备及组织性能研究[J]. 北京理工大学学报, 2022,42(6):658-664.
ZHAO Pengduo, WANG Qi, ZHANG Lei, et al. Microstructure and mechanical properties of B_4C-TiB_2-SiC ceramics fabricated by spark plasma sintering[J]. Transactions of Beijing Institute of Technology, 2022,42(6):658-664.
[12] 崔正浩,李宗家,程焕武,等. 二硼化钛陶瓷研究进展及展望[J]. 陶瓷, 2021(9):12-18.
CUI Zhenghao, LI Zongjia, CHENG Huanwu, et al. Research progress and prospect of titanium diboride ceramics[J]. Ceramics, 2021(9): 12-18.
[13] 黄樱,睢利铭,李坤. B_4C-PrB_6/CeB_6 汽车材料的制备及性能研究[J]. 矿冶工程, 2023,43(6):169-173.
HUANG Ying, SUI Liming, LI Kun. Preparation and properties of automobile material B_4C-PrB_6/CeB_6[J]. Mining and Metallurgical Engineering, 2023,43(6):169-173.
[14] RUSSIAS J, CARDINAL S, FONTAINE J, et al. Bulk titanium nitride material obtained from SHS starting powder: Densification, mechanical characterization and tribological approach[J]. International Journal of Refractory Metals and Hard Materials, 2005,23(4/5/6): 344-349.
[15] LI L H, KIM H E, KANG E S. Sintering and mechanical properties of titanium diboride with aluminum nitride as a sintering aid[J]. Journal of the European Ceramic Society, 2002,22(6):973-977.

引用本文:曹辉,张一彬. TiN-TiB_2 复合材料的原位合成及其力学性能研究[J]. 矿冶工程, 2026,46(2):195-199.
CAO Hui, ZHANG Yibin. In-situ synthesis and mechanical properties of TiN-TiB_2 composites [J]. Mining and Metallurgical Engineering, 2026, 46(2):195-199.

(上接第 194 页)

[2] 宋紫棋,毛桂庭,侯奔. 基于 YOLO 网络的无酸除鳞带钢表面缺陷实时检测[J]. 矿冶工程, 2022,42(2):136-140.
SONG Ziqi, MAO Guiting, HOU Ben. Real-time detection of surface defects of acid-free descaled steel strip based on YOLO network[J]. Mining and Metallurgical Engineering, 2022, 42(2):136-140.
[3] WU Q Q, ZHANG C D, HONG Q Q, et al. Topic evolution based on LDA and HMM and its application in stem cell research[J]. Journal of Information Science, 2014,40(5):611-620.
[4] GUO X D, ZHANG L L, HAO Y G, et al. Multiple abnormality classification in wireless capsule endoscopy images based on EfficientNet using attention mechanism[J]. The Review of Scientific Instruments, 2021,92(9):094102.
[5] ISUNURI B V, KAKARLA J. EfficientNet and mixed convolution network for three-class brain tumor magnetic resonance image classification[J]. Soft Computing, 2024,28(17):10741-10750.
[6] ALIA A, MAREE M, CHRAIBI M. A hybrid deep learning and visualization framework for pushing behavior detection in pedestrian dynamics[J]. Sensors, 2022, 22(11):4040.
[7] 韩振宇,金鸿宇,富宏亚. 基于 ESPRIT 频谱估计和隐马尔可夫模型的铣削颤振辨识系统建模[J]. 计算机集成制造系统, 2016, 22(8):1937-1944.
HAN Zhenyu, JIN Hongyu, FU Hongya. Modeling of chatter recognition system in CNC milling based on ESPRIT and hidden Markov model [J]. Computer Integrated Manufacturing Systems, 2016, 22(8):1937-1944.
[8] 陈维高,贾鑫,朱卫纲,等. 基于 HMM 的雷达状态转移估计方法[J]. 北京航空航天大学学报, 2017,43(10):2171-2180.
CHEN Weigao, JIA Xin, ZHU Weigang, et al. Radar state transfer estimation method based on HMM[J]. Journal of Beijing University of Aeronautics and Astronautics, 2017,43(10):2171-2180.
[9] 张洪海,周锦伦,于文娟,等. 基于 HMM 和 DT 的无人机异常检测方法[J]. 中国安全生产科学技术, 2022,18(3):193-198.
ZHANG Honghai, ZHOU Jinlun, YU Wenjuan, et al. Anomaly detection method of UAV based on hidden Markov model and decision tree[J]. Journal of Safety Science and Technology, 2022,18(3): 193-198.

引用本文:侯奔,符章捷. 基于视觉质量评估与隐马尔可夫模型(HMM)的高压水射流管路压力预警方法[J]. 矿冶工程, 2026,46(2):190-194.
HOU Ben, FU Zhangjie. An early warning for high-pressure water-jet pipelines based on visual quality assessment and hidden Markov model[J]. Mining and Metallurgical Engineering, 2026,46(2):190-194.