

# 基于水流分割的石油钻井水流异常检测

李衍志, 范勇, 高琳

(西南科技大学 计算机科学与技术学院, 四川 绵阳 621010)

**摘要:** 通过对钻井管道水流的智能监控技术实现, 可以解决石油钻井污染气体的自动监测问题, 最大程度的减少人工监测成本; 但是依然有以下几个难点需要攻克: (1) 传统的特征提取方式不能描述水流形态的变化过程; (2) 因为异常情况发生的概率很低, 所以异常样本稀少, 全监督的方法不再适用; 为解决特征提取问题, 提出了一种基于图像分割的新特征提取方式——形态流, 形态流可以从时序上描述水流形态的变化; 另一方面, 为克服异常样本稀少的问题, 通过无监督的方式——多元高斯建模, 来判别水流数据是否正常; 实验表明在水流异常数据检测任务中算法检测精度达到了 93.6%, 在使用 GPU 并行加速处理时可达 28 帧每秒的处理速度, 能够准确地检测出水流数据中的异常数据帧。

**关键词:** 视频异常事件检测; 石油钻井水流异常检测; 多元高斯; 水流分割

## Anomaly Detection of Oil Drilling Water Flow Based on Water Flow Segmentation

Li Yanzhi, Fan Yong, Gao Lin

(School of Computer Science and Technology, Southwest University of Science and Technology,  
Mianyang 621010, China)

**Abstract:** Through the realization of intelligent monitoring technology for the water flow of the drilling pipeline can solve the problem of automatic monitoring of polluted gas from oil drilling and minimize the cost of manual monitoring. However, there are still several difficulties that need to be overcome: (1) The traditional feature extraction method cannot describe the change process of the water flow pattern; (2) Because the probability of abnormal situations is very low, the method of full supervision with rare abnormal samples is not applicable. In order to solve the problem of feature extraction, proposes a new feature extraction method based on image segmentation—morphological flow, which can describe the change of water flow morphology in time series; on the other hand, in order to overcome the problem of rare abnormal samples, an unsupervised method—multivariate Gaussian modeling is used to determine whether the water flow data is normal. Experiments show that the detection accuracy of the algorithm in the water flow abnormal data detection task reaches 93.6%, and the processing speed of 28 frames per second can be reached when using GPU parallel acceleration, and it can accurately detect abnormal data frames in the water flow data.

**Keywords:** video anomaly detection; oil drilling flow anomaly detection; multivariate Gaussian; water flow segmentation

## 0 引言

石油在工业生产中有重要的用途, 是极其重要的化工原料<sup>[1]</sup>。石油开采和生产过程中, 会产生具有污染性的气体, 威胁生态安全, 为了保护绿水青山就必须要及时进行处理<sup>[2]</sup>。但是这些污染气体不是时时都有, 因此直接通过化学试剂实时检测必然会造成大量的浪费, 同时化学试剂本身也会加重污染。但是这些污染气体有一个共同点, 就是在水中的溶解度很低, 因此只要污染气体会在管道内积聚, 积聚的越多对管道的气压就越大管道口的水流变化也就越大。根据这一特性, 现在的生产过程中都是有长期工作经验的专家在后台通过摄像头进行实时的监测, 但是长时间的观看视频数据总会有视觉疲劳和处理不到的地方,

导致不能及时发现和处理异常。从理论上讲, 目前还没有与水流异常检测相关的研究。该课题主要难点主要在两个层面: 1) 水流与其他有固定形态的实物不同, 水流的形态一直在变化, 因此传统的用于表示视频行为变化的特征提取方法对水流不起作用; 2) 异常样本严重不足, 水流本身形态不固定, 再加上异常本身就是偶然的, 因此异常样本的获取及其困难。

针对特征提取方面的问题, 在视频异常事件检测领域常用的有光流特征、轨迹特征、骨架特征。首先水是没有骨架的, 所以骨架特征是没有用的。轨迹特征计算量很大, 不能满足实时性的需求。光流<sup>[3-4]</sup>特征在计算时假设了物体形态基本无变动, 运动缓慢, 而水流形态的变化强度超出

收稿日期: 2020-08-31; 修回日期: 2020-10-09。

基金项目: 四川省教育厅年科技项目(18ZA0501)。

作者简介: 李衍志(1994-), 男, 四川西昌人, 硕士, 主要从事计算机视觉、视频异常事件检测、图像处理方向的研究。

范勇(1972-), 男, 重庆人, 教授, 博士, 主要从事计算机视觉, 视觉测量、软件测试等方向的研究。

引用格式: 李衍志, 范勇, 高琳. 基于水流分割的石油钻井水流异常检测[J]. 计算机测量与控制, 2021, 29(3): 82-87, 92.

了光流计算所需的假设前提, 所以在水流异常检测的过程中, 光流特征起不了作用。其他的视频图像数据特征提取表示方法如纹理特征<sup>[5-6]</sup>、颜色<sup>[7-8]</sup>、MoSIF<sup>[9]</sup>特征等都只能表示单幅图像的空间结构信息, 不能表示水流在时间序列上的变化。所以需要提供一种新的表示方式, 用以刻画水流在时间轴上的变化过程。

针对视频中水流异常数据帧检测方面的问题, 按照训练过程中所使用的正常数据和异常数据比例不同可以分为基于全监督的算法和非全监督的算法。全监督的算法对异常样本的依赖性很大, 异常样本数据量越大训练之后得到的模型检测精度越高, 其基本要求就是要列举所有的异常和正常数据样本<sup>[10-12]</sup>。但是水流随时都在改变, 再加上发生异常是由多种因素引起的, 所以水流的异常没有固定的表现模式, 在加上异常不是随时发生的所以要从几万帧正常数据中挑选出几个异常数据帧很困难, 所以全监督的算法实用价值很低。为了克服传统的全监督算法在视频异常事件检测任务中的缺点, 研究者们对非全监督的算法进行了研究, 这些算法按照其检测异常的方式和学习方式的不同, 可以被划分成基于重建的方法, 基于事件预测的方法还有基于表示建模的算法。基于重建的方法, 其核心是重建, 需要在测试之前学习到一个庞大的重建字典, 在测试阶段直接根据字典里的数据进行重建, 最后根据重建误差来判别异常, 该类算法检测精度高, 但是实时性低<sup>[13-14]</sup>, 所以实际应用很少用到。基于事件预测的方法<sup>[15]</sup>, 判断差异的方式是峰值信噪比, 对于阈值的依赖很大, 同一个阈值不能适用于多个场景, 因此不能满足水流异常检测中场景兼容性的需求。基于表示建模的方法<sup>[16-18]</sup>, 其本质就是对视频正常数据的一种表示方式进行建模, 由于建模过程中使用的所有样本都是正常样本, 所以该模型是符合正常样本的表示分布的, 而异常样本就会偏离这个模型。但是该类方法训练过程耗时, 且时间复杂度较高。

总而言之, 目前在视频异常检测领域的相关算法研究都集中在对人的异常行为上的研究, 而没有与水流异常检测相关的算法研究, 由于人的行为变化和水流形态变化的不同现有的异常检测算法无法直接用到石油钻井的排污检测上。因此本文提出了一种基于水流分割的石油钻井污染气体自动检测方法。在视频中水流数据的特征提取上, 本文提出了一种新的特征提取方式用于提取水流的时空域特征; 在异常检测算法层面, 残差结构优化了 U-net 模型, 同时在损失函数中加入了常数项, 解决分割目标为空的问题。实验结果表明, 本文的方法相对于现有的相关算法检测精度更高达到了 93.6%, 同时能达到每秒 28 帧的检测速度。

## 1 水流异常检测流程

该部分将从建模和测试两个阶段来介绍水流异常检测的流程。水流异常检测流程图如图 1 所示, 在建模阶段首

先根据水流分割的样本和标签训练 U-net 得到水流分割的模型, 然后再提取形态流特征, 最后结合形态流特征和当前数据帧的信息进行多元高斯建模; 在测试阶段直接使用训练好的模型分割水流并提取形态流特征, 最后根据多元高斯模型输出的概率值判断当前数据帧异常与否。

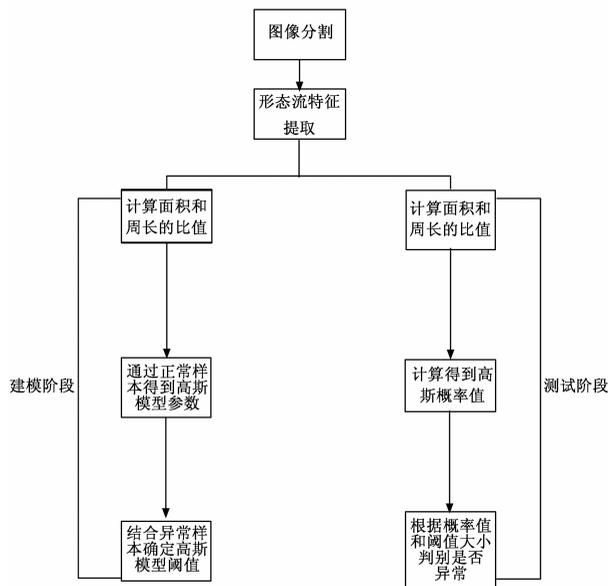


图 1 水流异常检测流程图

## 2 形态流特征提取

### 2.1 水流分割

如图 2 所示水流数据中除了水流之外还包含大量的背景信息, 比如工厂的生产工具、钻井附近的花草树木、以及排水的水池等。直接使用原图进行异常检测这些背景噪声就会造成干扰, 同时也会耗费大量的计算资源。因此在异常检测之前需要对数据进行特征提取消除背景干扰, 将视频数据表示为特征序列。



图 2 水流数据样本

水流与普通的物体相比有着不同的特性: 1) 水无常形, 水流没有固定的结构特征; 2) 水流会因为水中的介质不同而显示不同的颜色。换句话说就是不能通过自身的结构特征和颜色特征将水流与周围的背景物体分割。所以单从 HSV<sup>[19-20]</sup>、RGB<sup>[21-22]</sup>等不同的颜色空间上无法找到一个合适的阈值来分割水流, 也不能根据外部轮廓走向来勾勒出水流。所幸深度学习的出现解决了场景和模式兼容的问题。众所周知神经网络模型的深度越深特征提取能力也就越强, 但是在实际应用中也不得不注意的是网络深度越深测试过程花费的时间就越多, 因此在选择模型时要综合考

考虑这两个因素。常用的分割模型如 Deeplab<sup>[23]</sup>、AdaptSeg-Net<sup>[24]</sup>、DFN<sup>[25]</sup>、Mask-RCnn<sup>[26]</sup>等算法网络深度较深，因此分割起来很耗时，而 FCN<sup>[27]</sup>算法又太浅特征提取能力不强，综合各种因素选择了 U-net<sup>[28]</sup>神经网络来做水流分割。文献[29]表明残差网络能够在加深网络深度的同时缓解神经网络训练过程中梯度不稳定的问题，所以本文中使用了残差网络对 U-net 进行了优化，残差网络中的 BN 层能够在特征图像梯度信息不明显时对数据起到归一化作用<sup>[30]</sup>，使学习过程中的特征图像素点之间的梯度信息更加明显，也能有效提升网络的学习能力。

U-net 原文使用交叉熵作为损失函数不能真实的表述生成数据于标签图像之间的对应重合关系。因此本文中使用了图像分割领域更为常用的 Dice 作为损失函数，Dice coefficient 可以评估两个样本的相似性，用于衡量两个样本的重叠程度，比起交叉熵作为图像分割的损失函数更合适。训练过程中 Dice 损失函数定义如下：

$$I_p = \sum_{i,j} p_r(i,j) \quad (1)$$

$$I_t = \sum_{i,j} p_l(i,j) \quad (2)$$

$$Loss = 1 - \sum_i^n \left( \frac{2 * I_t * I_p + \beta}{I_t^2 + I_p^2 + \beta} \right) \quad (3)$$

式中， $I_p$  表示 U-net 对水流数据进行分割的结果， $I_t$  代表神经网络学习过程中用到的标签， $Loss$  表示学习过程中的损失， $i$  和  $j$  两个值是指一幅图像中像素点所在位置的坐标。公式 (3) 中  $i = 0, n$  表示参与计算的图像数量， $\beta$  为非零常数。 $\beta$  的存在是为了防止  $I_p$  和  $I_t$  同时为零的情况下训练不能正常进行，两者同时为零也就是对应实际情况中拍摄到的图像没有水流的情况。图像中没有水流可能出现的原因有以下两个，第一工厂停工，第二水流剧烈喷射后也会有一两帧数据中并没有水流出现。通过多次实验  $\beta$  取值为  $1 * 10^{-5}$  时可以取得良好的分割效果，本文分割结果的展示如图 3 所示，图 3 中包含来自不同场景的样本和最终的图像分割结果。



图 3 水流分割结果图 (左侧为原图, 右侧为分割结果)

## 2.2 形态流特征提取

水流时空域特征的提取是多元高斯建模的基础，评价一个特征提取方式好坏的标准就是在不破坏有用信息的前提下，对视频中行为或者运动过程变化的描述的准确度以及包含信息的丰富程度。在视频图像领域使用光流<sup>[15-16]</sup>作

为模型的输入是一种常见手段，其原因在于光流包含了时间和空间两个维度的丰富信息。因此在实践中本文也首先对光流进行了研究和实验，两个相邻数据帧原图和光流提取结果分别如图 4 和图 5 所示。



图 4 两个相邻数据帧

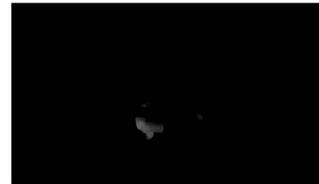


图 5 光流计算结果

如图 5 所示，光流特征的计算结果很混乱，并不能看出水流在时间轴上的变化，也不能看出水流的形态。这是由光流特征本身的计算条件所限制的，即光流计算时首先假设了计算目标运动时缓慢的时间是短暂的物体形变不大<sup>[3-4]</sup>，但是水流形态时时刻刻都在发生变化，且变化程度相对较大。因此需要新的特征表示方式（形态流）来描述水流形态的变化。因为本文是通过水流形态在时间轴上的变化来表示视频中水流的变化所以取名为形态流。

形态流特征的提取，也借鉴了光流描述视频数据变化的思路。形态流特征和光流一样都是从时间域和空间域两个层面来描述视频数据变化。不同之处在于，形态流特征考虑了人工进行异常数据判断过程，从水流形态的变化上来刻画数据。其依据在于在工业生产中专业人员判断数据是否异常是根据监控视频中水流形态的变化过程来进行的，而水流的形态体现在图像中就是目标区域（水流区域）像素点的位置分布。本文根据分割后的水流数据，结合其前后两帧数据之间的形态变化提出了形态流特征。一个视频序列的形态流特征提取流程图如图 6 所示。设原有的视频序列为  $I_0, I_1, \dots, I_n$ ，则经过分割后的视频图像序列为  $\bar{I}_0, \bar{I}_1, \dots, \bar{I}_n$ ，其中  $I_0$  表示第一帧  $I_n$  表示最后一帧。虽然水流的形态是不固定的在短时间内也会发生形态上的变化，但是在短时间内的同一场景下正常的水流数据形态变化并不剧烈。也就是说，在正常数据中相邻的两个数据帧，形态上随便化相对动物走动和爬行较大，但是在分割后的数据上相邻两帧之间对应位置上还是有很大一部分像素点是重合的。所以如果是正常的水流数据经过分割后相邻两个数据帧  $\bar{I}_i, \bar{I}_{i+1}$  相异部分较少，而在包含异常数据帧的数据中相邻两帧之间的相异部分则很大。这也就为从时间轴上描述水流形态的变化提供了基础。

水流时空域特征提取第一步就是对视频序列中的水流进行分割提取到其中的有用信息屏蔽背景影响；然后从头

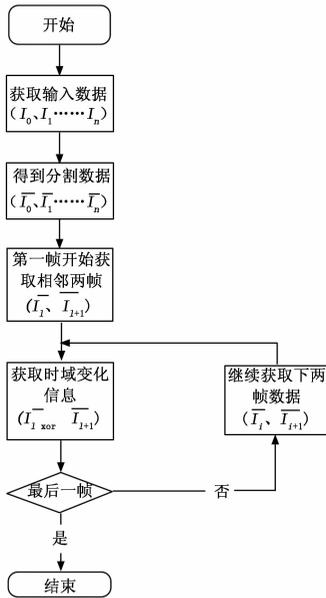


图 6 形态流特征提取流程图

开获取  $\bar{I}_i$ 、 $\bar{I}_{i+1}$  两个相邻数据帧的分割结果, 最后将获取到的数据按照位置对两个数据求取异或值 ( $\bar{I}_i \text{ xor } \bar{I}_{i+1}$ ) 用以表示前后两帧水流数据的变化情况。按照上述方法, 逐帧计算, 直到视频数据的最后一帧。相邻两帧数据及其水流时空域特征如图 7 中 (a), (b) 所示。

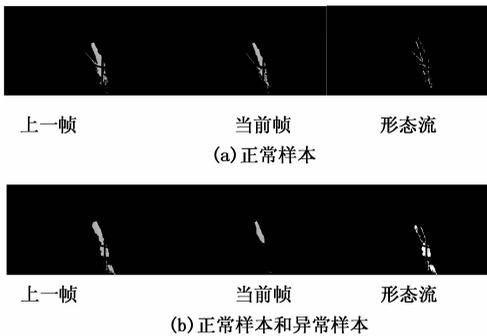


图 7 相邻两帧数据及其水流时空域特征

如图 7 中 (a) 所示, 正常数分后的图像前后两帧形态差异不大, 异常样本当前帧和上一帧差别较大。因此正常数据计算得到的水流时空域特征中有效像素点 (白色区域) 相对较少, 异常数据由于突变所以相同位置的像素点少, 在水流时空域特征中的体现就是有效像素点所占的区域面积更大。

### 3 水流异常检测多元高斯建模

异常事件发生的概率很低, 且水流的形态本身就在随时发生变化, 所以想要列举所有的异常的情况是极其困难的, 因此不能通过全监督的方式来检测水流的异常情况。另一方面正常的水流数据是很容易获取的, 所以通过无监督的方式对正常水流数据进行建模, 然后再根据数据是否偏离该模型来判断异常与否是一个可行的方式。同时考虑

到时间复杂度和算法自身的复杂度问题, 多元高斯建模检测异常点<sup>[31-33]</sup>是一个优选方式。

如上文所述正常数据的形态流特征, 白色的像素点少, 而异常数据的形态流特征, 白色像素点相对较多。这就是高斯模型能区别正常数据与异常数据的基础。同时在实际的工程中场景是多样的, 每个场景的水流量大小也是不一样的, 所以不能直接根据像素点的多少来判别异常点, 而是根据其变化的剧烈程度来判别异常与否。实际生产中工作人员根据水流形态的变化来判别数据异常与否。本文仿照人工操作的流程也通过水流形态在时间轴上的变化来建模。另一方面, 最能代表体现一个二维物体形状的量就是物体的周长和面积, 所以我们可以依据这两个量的变化情况来建立多元高斯模型。我们首先通过计算形态流特征的周长和面积, 就能得到上一帧和当前帧的周长和面积的变化量; 然后再计算当前数据真的周长和面积的值; 最后两者相比就能得到前后两帧数据之间的变化值。如果是正常数据得到的值会比较小, 因为差异部分很小; 如果是异常数据就会得到一个比较大的值, 因为两者的差异部分比较大。这也是本文多元高斯模型建立的基础, 多元高斯模型的表达式如公式 (4) 所示。

$$\rho(x, y, \Sigma) = \frac{1}{(2\pi)^{n/2} |\Sigma|^{1/2}} e^{-1/2(x-u)^T \Sigma^{-1}(x-u)} \quad (4)$$

多元高斯的概率密度公式如公式 (4) 所示,  $x$ : 代表输入的变量, 是一个矩阵,  $u$ : 代表均值是与  $x$  相对应的均值矩阵,  $n$ : 代表多元高斯的维度, 即变量的个数,  $\Sigma$ : 代表协方差矩阵。

由于在实际应用中所使用的多元高斯变量是周长和面积在时序上的变化量与当前帧的比值两个量, 所以公式 (4) 中  $n$  的值为 2, 所以公式 (4) 可以化为如下公式 (5) 所示。

$$\rho(x, y, \Sigma) = \frac{1}{2\pi |\Sigma|^{1/2}} e^{-1/2(x-u)^T \Sigma^{-1}(x-u)} \quad (5)$$

同时这两个量是相互独立的, 所以公式 (5) 中的协方差矩阵形式如下公式 (6) 所示。

$$\Sigma = \begin{pmatrix} \sigma_1^2 & 0 \\ 0 & \sigma_2^2 \end{pmatrix} \quad (6)$$

用  $x, y$  代替公式 (5) 中的输入变量  $x$ , 用  $u_1, u_2$  代表两个变量的均值, 然后再将公式 (6) 带入公式 (5) 可以得到本文高斯模型的最终表达式如下公式 (7) 所示。

$$\rho(x, y) = \frac{1}{2\pi\sigma_1\sigma_2} e^{-\left(\frac{x-u_1}{\sigma_1}\right)^2 - \left(\frac{y-u_2}{\sigma_2}\right)^2} \quad (7)$$

得到了多元高斯模型之后就要考虑异常临界值  $\epsilon$  的问题, 即确定一个阈值  $\epsilon$  当高斯模型输出的概率值小于该值将其判定为异常数据帧, 多元高斯模型阈值的选取依据如下公式 (8) 所示。

$$F_1 = \frac{2TP}{2TP + FP + FN} \quad (8)$$

阈值的确定就是为了更好的区分正常样本和异常样本,

对于检测任务来说就是要在误检和漏检中找到一个平衡。误检也就是公式 (8) 中的  $FP$  表示正常样本被错误的判别为了异常样本；漏检就是  $FN$ ；表示异常片段没有检测出来； $TP$  则表示检测无误的异常数据片段。为了防止异常样本过少而导致的单纯使用检测精度来衡量一个模型的好坏可能出现的偏差，引入了  $F1$ ，从公式 (8) 中可以看出  $F1$  的值越大，错误判别的水流视频数据片段就越少。

## 4 实验

本文的实验采用的是开源的 Linux 系统，为了加快运算的速度，在训练和测试过程中都使用了 2 块显存为 12 G 的 Titan V 的 GPU。第一部分的实验是与水流分割相关的实验，用于找到上文中所述的最适用于分割的  $\beta$  值；第二部分实验是针对水流异常数据点检测和水流时空域特征验证的实验。

### 4.1 评价指标

视频的异常检测任务中，要评价一个新算法的好坏最直接的方式就是检测的精度 ( $precision$ )， $precision$  计算方法如公式 (9) 所示。

$$precision = \frac{TP}{TP + FP} \quad (9)$$

公式 (9) 中， $TP$ ：判别正确的异常的片段，也就是将异常的水流片段判别为异常， $FP$ ：判别错误的正常判断，也就是将正常片段判别为了异常片段。

### 4.2 实验设计

#### 4.2.1 数据集介绍

为了保证实验数据的准确性和丰富性，实验过程中用到不同场景的实验数据都是在实地采集得到的。异常的样本也是长期积累采集到的，异常样本是由工厂工作经验丰富的专家挑选的，专家根据水流变化的剧烈程度判断一个视频片段中的水流数据是否异常。在训练和测试的过程一共用到了 50 000 个训练数据和 2 000 个测试数据，这些数据来源于 7 个不同的场景。测试数据中包含 1 000 张正常数据和 1 000 张异常数据。

#### 4.2.2 水流分割实验

本文中通过 U-net 算法来分割视频中的水流，图像分割领域常常通过 IoU (交并比，分割结果与标签的交集与并集) 来评价分割的结果。公式 (3) 中  $\beta$  是一个经验值，确定一个经验值的最佳取值的方法就是进行多次的对比和实验，为了得到  $\beta$  的最佳取值，本文对不同  $\beta$  取值情况下的分割结果进行了对比和实验，其结果如表 1 所示。

表 1 U-net 中不同  $\beta$  值下的 IoU 对比结果

$\beta$ 值	IoU
$1 \times 10^{-1}$	0.90
$1 \times 10^{-2}$	0.92
$1 \times 10^{-3}$	0.94
$1 \times 10^{-5}$	0.95
$1 \times 10^{-6}$	0.93

如表 1 所示， $\beta$  取值较大时对损失的计算结果影响也较大，所以分割效果不好，通过实验结果可以发现随着  $\beta$  减小，分割结果先变好后变坏，其最佳取值为  $1 \times 10^{-5}$ 。

#### 4.2.3 水流异常检测和形态流验证实验

本文的主要目的是水流的异常检测，为了验证本文算法的有效性和先进性除了进行自我验证外还与其他算法进行了对比。参与对比的模型包括本文的算法、Ganomaly<sup>[16]</sup>、EGBAD<sup>[17]</sup>、AnoGAN<sup>[18]</sup> 4 种；另外为了验证形态流的有效性，本文也在 Ganomaly 算法上进行了不同特征检测的对比验证。本文的提出的算法相对于其他 3 种深度学习的模型算法在场景的兼容性上有所不足，但是其在检测过程中只需要预先得到高斯参数，不需要加载 200 M 的模型，所以运算速度很快。为了解决场景的兼容性问题，本文首先在不同的场景下分别建立高斯模型，然后在检测时再依次判断输入数据属于哪一个模型，如果输入数据不属于任何一个模型，则为异常。详细的场景兼容性验证和分析结果如表 2 所示，各个算法的检测结果如表 3 所示。

表 2 包含不同场景数据的检测结果

场景个数	本文算法	Ganomaly
1	96.3%	85.2%
2	92.6%	84.5%
3	88.1%	83.8%
5	84.2%	83.6%
7	82.1%	83.5%

表 3 各个算法的水流异常检测精度对比

名称	Feature	precision	FPS
本文算法	形态流	93.6%	28
Ganomaly <sup>[25]</sup>	形态流	83.5%	18
EGBAD <sup>[32]</sup>	形态流	76.3%	—
AnoGAN <sup>[33]</sup>	形态流	55.6%	—

表 3 中 Feature 代表输入的特征，precision 代表精度，FPS 代表每秒的处理速度 (单位是：帧/每秒)，由于 EGBAD<sup>[17]</sup>、AnoGAN<sup>[18]</sup> 两种算法检测精度较低不满足实际的需求所以没有设计检测速度的验证实验。从表 3 可以看出，本文所提算法明显高于 EGBAD<sup>[17]</sup>、AnoGAN<sup>[18]</sup> 两种算法精度达到了 93.6%，相对于 Ganomaly 算法精度也提升了 10.1%。时间效率方面，同时使用 Titan V 的 GPU 加速时，可以达到 28 帧每秒的检测速度，比 Ganomaly 每秒能多检测 10 帧数据。

由于在前期的验证中 EGBAD<sup>[17]</sup>、AnoGAN<sup>[18]</sup> 两种算法检测精度低不满足需求，所以没有形态流特征验证时没有在这两种算法上做更多的对比，同时本文算法也不适用于原图分割图像和光流等，所只在 Ganomaly 算法上进行了形态流特征的验证实验，实验结果如表 4 所示。

如表 4 所示形态流特征在水流异常检测任务中，相对于其他 3 种特征都有更好的表现，也说了形态流特征在水

流异常检测任务中的优越性。其原因在于, 光流特征不能适应水流形态的快速变化所以表现最低, 同时原图和分割图像两者均不能表示水流形态在时间轴上的变化, 所以表现不如形态流特征。

表 4 形态流特征验证结果

名称	Feature	precision
Ganomaly	原图	69.5%
Ganomaly	分割图像	73.2%
Ganomaly	光流	63.1%
Ganomaly	形态流	83.5%

算法能够在多个场景中使用是实际项目需要考虑的问题, 因此本文对表二中表现比较好的两种方法做了进一步实验。在加入不同场景数据的情况下, 对数据进行训练和测试, 实验中输入特征都是形态流, 其结果如表 2 所示。

从表 2 中可以看出, Ganomaly 算法对场景的兼容性更强, 增加不同场景的数据, 其检测的精度下降不明显。而本文的算法虽然在单个场景的检测中表现突出, 但是随着场景数的增多, 算法的检测精度下降比较明显。但是在实际的项目处理过程中, 我们可以通过其他的方法来解决场景问题, 这样既可以保证检测精度也可以保证检测速度。比如我们可以预先建立多个多元高斯模型, 再逐一检查输入的数据是符合哪个模型的分布。这样做的基础在石油工厂钻井的数目有限, 也就是说场景的个数是有限的。表 3 中本文算法的检测精度就是这样计算得来的。表 2 中是用一个模型去拟合不同场景的数据, 而表 3 中则是用多个高斯模型去拟合数据, 所以当场景数为 7 时表 2 检测精度达到 93.6%, 而表 3 只有 82.1%。

## 5 结束语

本文结合实际的应用, 提出了一种视频中水流异常数据片段检测的算法, 解决了石油生产中污染气体的排放的自动检测问题。为了解决异常的水流数据片段难以获取的问题, 本文采用了无监督学习的策略, 通过建立正常数据的多元高斯模型来判别异常数据。通过实验的对比和验证本文所提算法水流异常片段检测的精度达到了 93.6% 优于其他算法, 在实时性上在 24 G 的 Titan V GPU 上使用加速策略可以达到 28 帧每秒的处理速度。另一方面视频中水流的异常变化是一个过程, 而本文只考虑了连续两个数据帧的变化, 接下来可以考虑更多连续帧的水流形态变化情况。

## 参考文献:

[1] 刘翔宇. 石油化工工艺及其废水处理研究 [J]. 石化技术, 2019, 26 (2): 115-117.

[2] 马兴华, 黄光利, 陶恩生. 井下废弃油井影响区域硫化氢综合治理技术研究 [J]. 能源与环保, 2019, 41 (12): 1-4.

[3] Brox T, Bregler C, Malik J. Large displacement optical flow [J]. IEEE Computer Society, 2009, 33 (3): 41-48.

[4] Ummenhofer B. Large Displacement Optical Flow for Volumetric Image Sequences [M]. Pattern Recognition. Springer Berlin Heidelberg, 2011: 432-437.

[5] Batool F E, Attique M, Sharif M, et al. Offline signature verification system: a novel technique of fusion of GLCM and geometric features using SVM [J]. Multimedia Tools and Applications, 2020: 1-20.

[6] Liu G H, Yang J Y. Image retrieval based on the text on co-occurrence matrix [J]. Pattern Recognition, 2008, 41 (12): 3521-3527.

[7] Aaron A. R. Tobian, David Serwadda, Thomas C. Quinn, et. Male Circumcision for the Prevention of HSV-2 and HPV Infections and Syphilis [J]. New England Journal of Medicine, 2009.

[8] Zhengyang Z, Runhong Z, Wei H, et al. Histidine-rich Modification of a Scorpion-derived Peptide Improves Bioavailability and Inhibitory Activity against HSV-1. [J]. Theranostics, 2018, 8 (1): 199-211.

[9] Stramaccioni D, Battaglia D, Schilke J, et al. BepiColombo MOSIF 10 SC Solar Simulation Test [A]. International Conference on Environmental Systems [C]. 2013.

[10] Miao Y Y, Song J X. Abnormal event detection based on SVM in video surveillance [A]. IEEE Workshop on Advanced Research and Technology in Industry Applications [C]. Ottawa, Canada, 2014: 1379-1383.

[11] Kim H, Lee S, Kim Y, et al. Weighted joint-based human behavior recognition algorithm using only depth information for low-cost intelligent video-surveillance system [J]. Expert Systems with Applications, 2016, 45 (3): 131-141.

[12] Sabokrou M, Fayyaz M, Fathy M, et al. Deep-cascade: cascading 3D deep neural networks for fast anomaly detection and localization in crowded scenes [J]. IEEE Transactions on Image Processing, 2017, 26 (4): 1992-2004.

[13] Liu P T, Ye Z W, Tang X L. Abnormal crowd motion detection using double sparse representation [J]. Neurocomputing, 2017, 269: 3-12.

[14] Yuan Y, Feng Y C, Lu X Q. Structured dictionary learning for abnormal event detection in crowded scenes [J]. Pattern Recognition, 2018, 73: 99-110.

[15] Liu W, Luo W, Lian D, et al. Future frame prediction for anomaly detection - a new baseline [A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition [C]. 2018: 6536-6545.

[16] Akcay S, Atapour-Abarghouei A, Breckon T P. Ganomaly: Semi-supervised anomaly detection via adversarial training [A]. Asian Conference on Computer Vision. Springer, Cham [C]. 2018: 622-637.

[17] Zenati H, Foo C S, Lecouat B, et al. Efficient GAN-based anomaly detection [J]. arXiv preprint arXiv: 1802.06222 (2018).

(下转第 92 页)