© 2023 IEEE。本文为已发表于 IEEE 可视化与计算机图形学汇刊的文章作者版本。最终版本可通过以下地址获取：
10.1109/TVCG.2023.3243834

arXiv:2302.12983v1 [cs.GR] 25 Feb 2023

RipViz：通过学习路径线行为寻找离岸流

Akila de Silva、Mona Zhao、Donald Stewart、Fahim Hasan Khan、Gregory Dusek、James Davis 和 Alex Pang



图 1：**离岸流十分危险，却仍不为许多人所察觉：**我们提出了一种名为 RipViz 的特征检测方法，让这些不可见的离岸流变得可见。RipViz 将离岸流的位置突出显示为红色区域。它通过寻找能够生成偏离正常海洋流场的路径线序列的种子点来确定这些区域。非专业人士和专家都可以使用 RipViz 来可视化离岸流。

摘要——我们提出了一种结合机器学习与流动分析的特征检测方法 RipViz，用于从静态视频中提取离岸流。离岸流是一种危险的强劲海流，能够将海滩游客卷向外海。大多数人要么不了解离岸流，要么不知道它们是什么样子。在某些情况下，即使是救生员等受过训练的人员，也难以识别离岸流。RipViz 会在源视频上叠加离岸流位置的可视化结果，简单易懂。使用 RipViz 时，我们首先通过光流从静止视频中获取非定常二维矢量场，并分析每个像素随时间的运动。在每个种子点处，我们会跨视频帧追踪短路径线序列，而不是一条长路径线，从而更好地捕捉波浪活动的准周期流动行为。由于海滩、破浪带及周边区域存在运动，这些路径线仍可能显得十分杂乱、难以理解。此外，普通观众并不熟悉路径线，可能不知道如何解读。为解决这一问题，我们将离岸流视为正常流场中的流动异常。为学习正常流动行为，我们使用来自正常海洋、前景和背景运动的路径线序列训练长短期记忆网络自编码器。在测试阶段，我们使用训练好的长短期记忆网络自编码器检测异常路径线（即离岸流区中的路径线）。随后，将这些异常路径线在整个视频中的起始点作为离岸流区内的点呈现出来。RipViz 完全自动化，无需用户输入。领域专家的反馈表明，RipViz 有望得到更广泛的应用。

In索引词—流场可视化、二维非定常流场、路径线、LSTM 自编码器、异常检测

1 引言

离岸流是强劲而狭窄的水流通道，从近岸区 [3, 6, 20, 27]快速流向海洋。离岸流向海方向的流速可能非常快，可达每秒两米，比奥运游泳运动员还快。它们是一种危险的海滩灾害，但大多数人并未意识到这一点。因此，全球每年有数千人因离岸流而溺水身亡 [10, 25]。本研究旨在通过帮助海滩游客看见离岸流，提升公共安全。

离岸流形成的机制是平均水位升高，这种现象称为增水，发生在波浪拍打海岸时。增水会沿海岸线变化，具体取决于水量或破碎波的高度。水域往往会从增水较高的区域（波浪较大）流向增水较低的区域（波浪较小），离岸流便由此形成：海流汇聚并向海流动，形成一股离岸流。

使用机器学习（ML）检测离岸流颇具挑战性，因为离岸流有不同类型，且每种类型的外观各不相同。导致离岸流类型不同的三大因素是海岸线形状、水深地形和水动力因素（例如波高和方向、潮汐）。这些因素的组合会形成具有不同视觉特征的离岸流。离岸流在空间和时间上也可能是瞬态的或持续的。与检测汽车、人等其他物体相比，检测离岸流面临独特的挑战。离岸流形态不规则，没有明确的形状或边界；同时它们具有短暂性，也没有明确的时间界限。

使用目标检测器（例如近期综述[22], 中介绍的检测器），需要为每种类型的离岸流准备大量训练数据集。迄今为止，公开可用的离岸流检测训练数据集只有两个：逐帧标注图像 [11] 和时间平均图像 [29],，且两者都针对同一种类型的离岸流。目前尚无针对其他类型离岸流的训练数据集。

离岸流无论视觉外观如何，最终都会流向海洋。因此，我们提出了一种新颖的混合方法，将流动分析与机器学习相结合来进行离岸流检测，而不是依赖图像颜色。我们还提出将离岸流编码为具有异常流动行为的位置，从而将检测任务转化为区分正常行为与异常行为。这大大简化了训练数据的收集，因为只需要一个数据集。

• *Akila de Silva*、*Mona Zhao*、*Donald Stewart*、*Fahim Hasan Khan*、*James Davis* 和 *Alex Pang* 均来自加州大学圣克鲁兹分校。电子邮件：*audesilv@ucsc.edu*、*yzhao172@ucsc.edu*、*dolstewa@ucsc.edu*、*fkhan4@ucsc.edu*、*davis@cs.ucsc.edu*、*pang@soe.ucsc.edu*
• *Gregory Dusek* 就职于 *NOAA*。电子邮箱：*gregory.dusek@noaa.gov*。
• 通讯作者：*Akila de Silva* 和 *Alex Pang*

稿件收稿日期：*2022*年*9*月*5*日；修订日期：*2023*年*1*月*27*日；接收日期：*2023*年*2*月*4*日。数字对象唯一标识符：*10.1109/TVCG.2023.3243834*

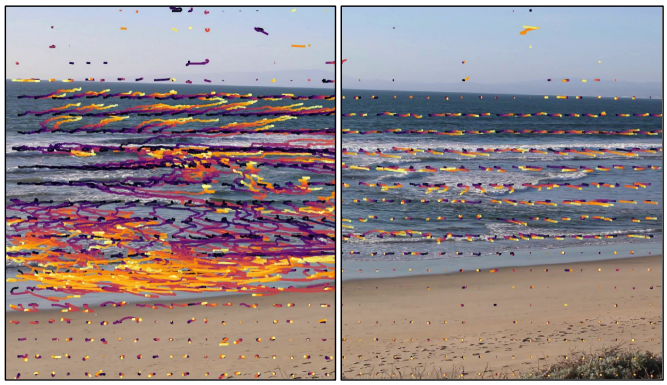

图2：**较长的路径线会变得杂乱，使机器学习难以学习：**左侧面板显示的是在整个视频时长内积分得到的较长路径线。右侧面板显示的是在900个时间步内积分得到的较短路径线。较长的路径线杂乱且噪声更多，使机器学习算法难以学习其行为。请注意，左侧面板的天空和海滩区域中有相对大量的噪声路径线。路径线按时间着色，黄色表示最新的路径线。

目前有两种从静态视频中检测离岸流的方法。第一种方法利用离岸流的外观来检测它们，包括由人类专家分析时间平均影像（时间平均影像），或运行自动目标检测器 [11, 29, 35, 36] 来检测离岸流。第二种方法依赖流动分析，即分析海浪的流动行为来检测离岸流。在这种方法中，会使用基于方向的流向量聚类 [30, 34] 以及沿平行于海滩的方向放置的时间线 [30] 。虽然这种方法能够检测较弱的离岸流，或外观不明显的离岸流，但时间线需要用户输入来指定其初始放置位置。

本文介绍了RipViz，这是一种完全自动化的混合方法，结合了深度学习、流动分析和特征检测，用于查找离岸流，如图1所示。我们首先使用光流从静止视频中获取随时间变化的流场。我们利用路径线序列来捕捉流动行为。我们可以简单地在每个点播种路径线，并在整个视频时长内追踪每条路径线。然而，由于波浪活动具有准周期性，这种简单的方法会产生过多杂乱内容，实用性不高，如图2所示。此外，在整个视频时长内积分得到的路径线会累积更多误差，在噪声较多的真实世界数据集中尤其如此。相反，我们为每个种子点生成一系列较短的路径线。通过错开路径线的起始时间，我们预期离岸流区以外的路径线序列会呈现不同的行为。例如，在波浪破碎处的破浪带中播种的路径线，其轨迹会有较大变化。在远海、海滩和天空中播种的路径线则会相对静止。在离岸流区内播种的路径线，其轨迹变化较小，但与静止路径线不同。

在 RipViz 中，我们将离岸流检测建模为流场异常检测问题。我们使用带有自定义加权损失函数的 LSTM 自编码器，学习正常海洋流场（即非离岸流）的路径线序列时空特征。训练完成的 LSTM 自编码器可以在测试阶段预测异常路径线序列（即离岸流）。通过识别并突出显示异常路径线的起始点，我们可以将离岸流区可视化。我们的目标用户是不了解离岸流动态，也不熟悉可视分析系统的普通大众。因此，我们的可视化输出设计力求尽可能简单明了、避免歧义。

本文的主要贡献是：

- 一种结合机器学习与流动分析技术的混合特征检测方法，可自动发现并可视化危险离岸流。

为实现这一目标，需要进行以下创新：

- 对于具有准周期行为的流场（例如海洋流动），使用由较短路径线组成的序列比使用单条长路径线更好。

- 与以往工作中使用的未加权二元交叉熵不同，加权二元交叉熵在学习由海洋流动生成的稀疏分布路径线时更有效。

2 相关工作

流线选择：流线选择和种子点布置在流场可视化领域已得到充分研究。Sane 等人 [39] 对过去二十年的相关研究进行了综述。这些研究与流线聚类 [5], 和流场简化 [23]在目标上有所重叠。它们都旨在呈现清晰、简洁的流场，同时保留其关键的流动特征和行为。例如，Marchesin 等人 [28] 提出动态选择一组流线，以实现易于理解且不杂乱的流线选择。Ma 等人 [26]采用一种基于重要性的方法进行视点相关流线选择，并确保视点逐渐变化时流线能够连贯更新。Yu 等人 [44] 提出了层次化流线束，通过在临界点附近生成流线，而不要求在整个体数据中进行密集种子点布置。他们将流线分组形成层次结构，并从中提取不同细节层次的流线束。Tao 等人 [41] 提出了候选流线与采样视点之间两个相互关联的通道。他们在选择流线时，考虑了流线对所有采样视点的贡献。然而，上述方法都使用手工设计的特征来定义流线的特征表示。要为复杂非定常流场（例如海洋流场）中的路径线设计手工特征表示，是一项颇具挑战的任务。相比之下，本文提出的方法无需手工设计特征，即可学习复杂的特征表示。

用于流场可视化的深度学习：近年来，可视化领域的研究者从两个方面应用机器学习：一是通过可视化来理解机器学习模型，二是在可视化任务中使用机器学习。在后者中，尤其是在流场可视化任务方面，Berenjkoub 等人 [2]使用 U-net（一种深度学习神经网络）识别涡旋边界。Kim 和 G¨unther [19] 使用神经网络，从非定常向量场中提取定常参考系。Han 等人 [17] 使用基于自编码器的深度学习模型 FlowNet，学习三维稳态流场中流线的特征表示，并据此对流线进行聚类。他们使用了更长的流线，这些流线贯穿整个数据范围进行积分。此外，每个种子点对应一条流线。本文提出的方法则为每个种子点使用一系列路径线，从含噪非定常二维流场中学习流动行为。本文使用 LSTM 自编码器，从含噪非定常二维流场中检测异常路径线序列。

离岸流检测：传统的离岸流检测通常需要使用现场仪器，例如配备GPS的漂流浮标和流速计 [21, 27]。也可以通过遥感来检测离岸流，例如利用无人机对离岸流区荧光素染料扩散情况进行航空成像，或使用海洋雷达 [16, 21]。这些方法需要昂贵的设备或一支观察团队，因此不适用于离岸流监测或检测。不过，通过冲浪网络摄像头等设备进行简单的光学视频采集，可以利用时空（时间堆栈）显示或模拟长时间曝光图像（timex）显示来检测某些离岸流 [18]。时间曝光图像会将离岸流位置显示为图像中的较暗区域，这些区域对应于水深地形中的较深通道，水流可能经由此处流向海侧。相反，与破浪带内破碎波相关的向岸水流，在时间曝光图像中显得亮得多。这种离岸流称为水深地形控制型离岸流，其特征是离岸流通道内有一片平静区域，两侧则有破碎波

© 2023 IEEE。本文为已发表于 IEEE 可视化与计算机图形学汇刊的文章作者版本。本文记录的最终版本见：
10.1109/TVCG.2023.3243834

两侧。解读时间曝光图像需要一定的领域专业知识。Maryan等人 [29] 使用Viola-Jones框架在时间曝光图像上训练模型，并通过边界框标示离岸流的位置。同样，Rashid等人 [35, 36] 也使用了时间曝光图像，但采用了经过修改的Tiny-Yolo V3架构。类似地，Ellis和McGill [12] 结合时间曝光图像与潮汐、波高和周期等环境信息，将向海移动的对象聚类为离岸流。然而，当冲浪者、桨板运动者等非水域对象也向海移动时，他们的方法会产生假正例。de Silva 等人 [11]没有使用时间曝光图像，而是使用视频中的单个视频帧和累积缓冲区训练Faster R-CNN模型，以检测地形型离岸流。所有这些方法都根据海况的外观来检测地形型离岸流。然而，当外观有所不同或不明显时，这些方法便无法检测出离岸流。

另一种方法是根据观察到的行为检测离岸流。Philip和Pang [34] 从视频中获得非稳态流场，并提出假设：由于入射波运动，离岸流的方向与向量场中的主导流动方向正好相反。他们根据方向和大小对向量进行分组，以可视化离岸流。Mori等人 [30] 采用类似方法对向量进行分组，并通过将方向映射为颜色、将大小映射为色调，改进了离岸流的可视化。在同一项工作中，Mori等人 [30] 还使用时间线来可视化离岸流。他们将时间线平行于海滩放置，并观察其被离岸流拖曳时的形状。本文所述工作同样使用海况的光学视频来检测离岸流。其底层方法也基于流动行为，因此不局限于检测地形型离岸流。不过，本文提出的方法首次提出结合机器学习和流动分析来检测不同类型的离岸流。由于检测是基于将离岸流中的流动行为视为异常，因此收集和标注机器学习模型训练数据的任务得以统一并简化。相比之下，标准的机器学习离岸流检测模型需要为每种类型的离岸流分别准备一个训练数据集，这一过程既昂贵又耗时。

自编码器： 自编码器是一类无需任何监督即可学习对象表征的神经网络 [7, 45]。自编-码器通过损失函数进行训练，该损失函数利用重构误差比较输入与重构输出。长短期记忆（LSTM）自编码器是一类能够从序列数据中学习的专用自编码器。这类自编码器配备了能够学习数据时间关联性的LSTM层。此外，自编码器也用于异常检-测器 [38]。对于异常检测，自编码器首先使用正常数据进行训练。当输入异常数据时，训练好的自编-码器会产生较大的重构误差。我们利用这一特性来检测异常流动行为。

流场可视化领域使用自编码器来寻找对象的特征表示，随后可将这些特征表示用于聚类。在他们的工作中，Han 等人 [17] 提出使用带有二元交叉熵函数的自编码器，学习流线和三维稳态流场中流面的特征表示。随后，他们进一步降低了这些特征的维度，并利用降维后的特征生成簇。然而，他们的方法无法学习路径线之间的时间关联性。此外，他们的未加权二元交叉熵损失函数没有考虑稀疏分布的路径线。在我们的工作中，我们使用带有自定义加权二元交叉熵损失函数的LSTM自编码器，学习海洋场景中稀疏分布路径线序列的时空行为。

3 RIPVIZ

在复杂且混沌的海洋流动中识别离岸流颇具挑战。我们首先利用海洋视频中的光流重建二维非定常流场。我们通过使用短路径线序列来捕捉海洋流动的特征，并将这些序列表示为一组二值图像。我们使用 LSTM 自编码器学习这些路径线序列的时空特征。我们采用定制的加权二元交叉熵函数训练模型，以学习海洋流动的路径线序列，该函数适用于学习海洋流动的路径线序列。随后，我们使用训练好的 LSTM 自编码器识别异常海洋流场或离岸流的路径线序列。我们将这些异常路径线序列的种子点投影回视频帧，并在这些点周围扩展出透明的红色区域，从而将离岸流可视化。

3.1 流场重建

使用光流从静止视频中获取非稳态二维流场。许多光流算法利用视频中连续视频帧之间相邻像素的相对运动来计算局部流场。我们使用 OpenCV 库中的 Lucas-Kanade [24] 稀疏光流函数 [14] 来追踪路径线。我们通过比较流场的正向和反向积分，验证了每个积分步骤。

3.2 路径线序列

每条路径线都表示为一个一维向量，$\mathbf{p} = \{x_1, y_1, \cdots, x_n, y_n\}$，其中 (x_i, y_i) 是视频帧坐标系中的一个点，n 是路径线的长度。为了让长短期记忆网络自编码器学习路径线，我们将这些路径线转换到各自的二维路径线中心坐标系中。为此，每条路径线都表示为一幅 $L \times L$ 二值图像$\mathbf{I}$，其中$\mathbf{p}$ 中的每个点都经过平移，使种子点位于二值图像的中心。对于延伸至 $L \times L$以外的较长路径线，我们增大二值图像的尺寸，以容纳这些较长的路径线。随后，我们将所有这些较大的二值图像缩小至 $L \times L$。之所以不直接将所有路径线居中后缩小至 $L \times L$，是因为我们需要区分几乎没有偏离初始种子位置的路径线，以及实际移动超过 $L \times L$ 的路径线。还需注意的是，居中后，路径线的二维表示不再受位置影响。这种处理方式使我们能够比较视频不同区域中的路径线，并识别行为相似的路径线。如前所述，对由含噪光流计算得出的准周期运动视频进行全程路径线追踪，会产生无法使用的杂乱流场表示。相反，我们以固定时间间隔在同一位置重新设置路径线种子，从而生成长度为 S的路径线序列。我们将每个种子点对应的路径线序列表示为一组二值图像堆栈，其尺寸为 $S \times L \times L$。

3.3 LSTM 自编码器

我们使用 LSTM 自编码器从路径线序列中进行学习。如图3所示，LSTM 自编码器由两个部分组成：编码器和解码器。编码器学习路径线序列的时空特征。解码器利用学习到的时空特征表示重建路径线序列。

我们将 LSTM 自编码器的输入层设定为接收形状为 $S \times L \times L$ 的路径线序列。编码器的第一层和第二层是按时间分布的二维卷积层，分别包含 128 个和 64 个卷积滤波器。这些层分别处理序列中的每条路径线，并学习每条路径线的空间特征。第三层和第四层是二维卷积LSTM层，分别包含 64 个和 32 个卷积滤波器。这些卷积LSTM层共同处理路径线序列，并学习路径线序列的时间特征。解码器的第一层是包含 64 个卷积滤波器的卷积LSTM层。解码器的第二层和第三层是按时间分布的反卷积层，分别包含 64 个和 128 个卷积滤波器。LSTM 自编码器的最后一层是按时间分布的卷积层，包含 1 个卷积滤波器。除输入层和输出层外，每一层之后都接一个归一化层 [1]。输入体数据不进行填充，因此我们将所有层的步幅设为 1。自编码器输出形状为 $S \times L \times L$ 的路径线序列。隐藏层使用 ReLU激活函数 [31]。输出层使用 Sigmoid激活函数。

与近期基于自编码器的流线选择方法相比，我们的方法不仅能学习每条路径线的空间特征，还能学习同一路径线序列中各路径线之间的时间关系。通过学习这些时空特征

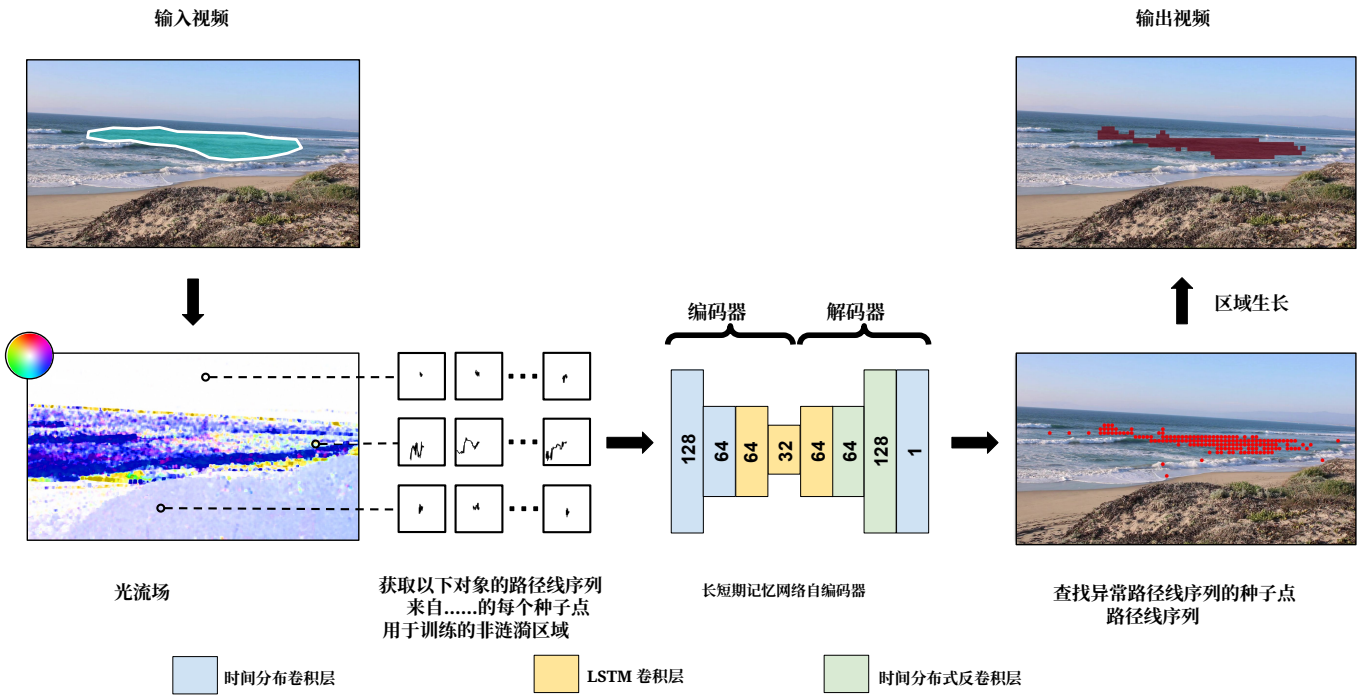

图 3：**RipViz 流程：** 首先，根据输入视频生成光流场（速度的大小和方向分别映射为明度和值域）。然后，为非涟漪区域中的每个种子点生成路径线序列（图中仅显示了三个种子点），其中每一帧都会生成一条新的路径线。最后，使用这些由非涟漪区域生成的路径线序列训练 LSTM 自编码器。在进行离岸流检测时，通过定期在视频帧中设置种子点，使用训练好的 LSTM 自编码器检测异常路径线序列。随后，我们对异常点应用区域生长算法，以寻找异常区域，同时滤除单独种子点。

我们的方法能够更好地学习混沌海洋流的准周期性。

3.4 加权损失函数

我们通过最小化每个训练样本与相应模型预测之间的差异来训练 LSTM 自编码器。用于计算该差异的损失函数是加权二元交叉熵损失函数。由于每个训练样本都是由大小为 $S \times L \times L$ 的二值图像堆叠表示的路径线序列，因此我们将每个样本视为一个二值体，其中当路径线穿过该体素时，p_i 为 1，否则为 0。$\hat{}p_i$ 是预测体数据中的对应值。损失函数在所有体素上计算（即 $N = S \times L \times L$）。

$$\mathcal{L} = -\frac{1}{N}\sum_{i=1}^{N}[w_1 \cdot p_i \log \hat{p_i} + w_0 \cdot (1 - p_i)\log(1 - \hat{p_i})] \quad (1)$$

w_1 是 $p_i = 1$时分配给体素的权重。 w_0 是 $p_i = 0$时分配给体素的权重。相比之下，以前用于流场可视化任务的基于自编码器的神经网络架构使用的是同一损失函数的未加权版本（即 $w_1 = w_0 = 1$）。出于第 4.2 节讨论的原因，我们发现加权二元交叉熵函数更适合我们的应用领域。

3.5 离岸流检测与可视化

在推理／测试阶段，我们使用前文定义的损失函数，计算每条路径线序列的重构误差。如果误差大于阈值 T，我们就将这些路径线序列标记为异常（即离岸流）。否则，则将这些序列标记为属于正常流场。我们在第 4.2 节讨论了如何选择 T。找到异常路径线序列后，我们使用区域生长算法将相应的种子点连接起来，生成一个区域。没有邻居的孤立种子点会被丢弃。为了直观呈现离岸流区，我们将该区域投影回视频中的视频帧，如图1所示。

3.6 网络训练

我们使用 Keras 应用程序编程接口（API）[9]，在 TensorFlow 中实现了神经网络。我们使用 NVIDIA Tesla A100 图形处理器（GPU）训练该网络。在训练过程中，我们使用正态分布 $\mathcal{N}(\mu,\ \sigma^2)$初始化神经网络所有层中的参数，其中均值为 $\mu = 0$，方差为 $\sigma^2 = 0.01$。我们使用 Adam 优化器 [38] 以 10^{-6}的学习率更新参数。我们采用 10 的小批量大小，并对模型进行了 100 个训练轮次。

4 结果与讨论

我们介绍数据集，分析 RipViz 中使用的组件和参数，并与其他方法进行比较。

4.1 数据集

我们的数据集由 55 个静态视频组成。每个视频时长为 1.5 至 4 分钟，尺寸为 1920×1080 像素。我们于 2022年冬季 在加利福尼亚州的 Salinas、Marina 和 Davenport 海滩采集了数据。我们使用安装在三脚架上的佳能 EOS Rebel T7 数码单反相机或三星安卓手机采集数据。我们选取了 4 个视频，采用第 4.2 节中讨论的播种策略，生成了 16000 个非离岸流路径线序列，用于训练模型。我们的验证数据集由从 3 个视频生成的 12000 条路径线组成。其余视频用于测试。请注意，我们的训练数据并不包含多种离岸流类型的示例，仅包含正常海洋流场的示例。这大大简化了训练数据的收集。每个视频都在离岸流专家的指导下进行了标注

© 2023 IEEE。本文为已发表于 IEEE 可视化与计算机图形学汇刊的文章作者版本。本文的最终版本可在以下网址获取：
10.1109/TVCG.2023.3243834

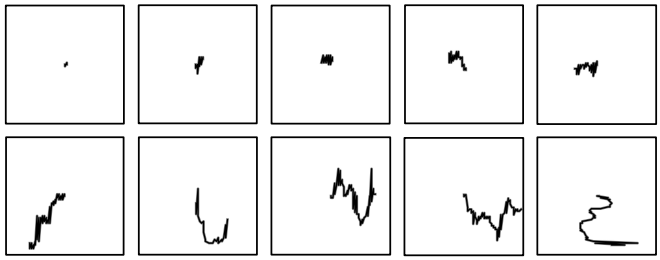

图 4：**二值图像中稀疏分布的路径线：**此图展示了我们数据中的一组路径线。请注意，二值图像中 0（白色）与 1（黑色）的数量并不平衡。如公式 1 所述，加权损失函数使自编码器能够利用不平衡数据进行学习。

在离岸流专家的指导下进行标注。播种于离岸流区域的路径线被标记为“离岸流”，其他路径线则被标记为“非离岸流”。

这些视频的取景方式（包括摄像机与水域之间的距离，以及镜头的焦距或变焦系数）旨在代表可能有助于离岸流检测的冲浪网络摄像头（例如 surfline.com）的拍摄效果。积分长度 n 和二值图像尺寸 L 等参数均根据此类取景方式设定。第 4.2 节讨论了这些参数对不同取景方式的敏感性。

请注意，我们假设视频源稳定，因此未进行任何视频稳定化处理。风可能导致摄像机轻微移动，也会造成草、云等物体的移动。此外，视频处理很少使用原始视频，而通常使用压缩视频。在压缩视频上计算光流场也可能引入一些运动伪影，尤其是在天空或空旷的沙滩等高度压缩的区域。对于我们的数据集，RipViz比现有方法更好地处理了这类运动伪影。

4.2 RipViz组件分析

RipViz方法相较于先前的方法包含两项重要改进：使用加权损失函数，以及使用一系列路径线而非单条路径线。我们发现，如果没有这些改进，机器学习将无法学习海洋流动。此外，该方法还包含检测阈值、 T和二值图像尺寸 L 等参数，这些参数可能取决于我们的特定应用领域。本节将分析其中的每个因素，说明这些改进的必要性，并介绍我们确定参数所采用的方法。

阈值 T： 阈值 T 用于根据第 3.5 节所述的重构误差，筛除异常路径线（即离岸流）。为找到最优阈值 T，我们在部分数据中计算了不同阈值下的 F_1 分数。 F_1 分数的定义如下：

$$F_1 = \frac{2}{\frac{1}{recall} + \frac{1}{precision}} = \frac{2}{\frac{FNs+TPs}{TPs} + \frac{FPs+TPs}{TPs}} \qquad (2)$$

如果检测到的路径线位于离岸流的专家标注边界内，则计为真正例。否则，视为假正例。假设一条起源于离岸流内的路径线未被检测到，则它是假负例。 F_1 分数的范围为 0 到 1。如果大多数路径线都位于离岸流边界内，分数就会接近 1；否则会接近 0。我们发现，阈值 $T = 1.0$ 产生了最高的 F_1 分数，因此在本文实验中将其用作 T。

损失函数的权重 w_0 和 w_1：我们使用光流从视频中重建了流场。如第 3.2 节所述，所有路径线都表示在二值图像 **I** 中。我们观察到，一些路径线较短，无法从种子点延伸得很远；而另一些路径线较长，能够从种子点延伸得更远，如图 4 所示。我们需要让模型学习这些较短和较长路径线的分布，因为这使模型能够学习海洋场景中的正常流动行为。然而，这会导致

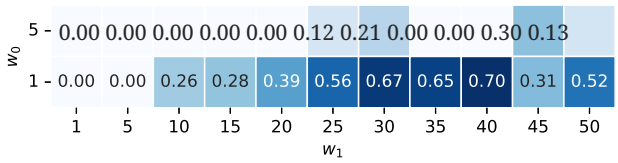

图 5： F_1 **不同 w_0 和 w_1组合的得分：**请注意，当 w_0 和 w_1 相等时，该方法无法收敛。最高的 F_1 得分为 0.70，此时 w_0 设为 1， w_1 设为 40。

1 和 0 体素数量不平衡，尤其是对于较短的路径线。为了让深度学习模型有效学习这些细小特征/路径线，我们需要在目标概率（p_i）为 1 时增大损失函数的权重。如第 3.4 节所述，损失函数会在训练过程中，对模型预测目标概率为 1 的像素时所犯的错误施加更大的惩罚。使用加权二元交叉熵函数使模型能够更好地学习较短路径线与较长路径线的分布。相比之下，在 FlowNet [17], 中，流线在其输入体积中分布得较为均匀，因此无需使用加权损失函数。

为了找到适用于我们应用领域的最佳 w_0 和 w_1，我们随机选取一小部分路径线序列，其中有些较短，有些较长，并使用不同的 w_0 和 w_1组合来训练模型。每个模型训练 100 个训练轮次，采用第 3.6 节中指定的相同训练条件。对于每个训练完成的模型，我们观察正确重建的体素数量。如果某个目标概率为 1 的体素，其预测概率大于 0.7，我们就将该体素标记为真阳性；否则，将其视为假阴性。如果模型在没有路径线的区域预测出路径线体素，我们就将其标记为假阳性。我们使用公式 2，计算各模型在不同权重组合下的 F_1 得分。我们发现，非均匀加权是必要的；如图 5 所示，当 $w_0 = 1$ 和 $w_1 = 40$ 时， F_1 得分最高。请注意，像先前的工作那样使用未加权交叉熵，相当于将 $w_0 = w_1 = 1$ 设为相应取值。在这种情况下，我们发现模型完全无法学习海洋流动。

在模型未能收敛的某些情况下，真阳性为 0，因此 F_1 分数未定义。在这种情况下，我们遵循 Scikit-learn Python 库的默认报告惯例，将这些情况报告为 0.00。

路径线长度 n 和序列长度 S： 在 RipViz 中，我们使用路径线序列来学习流动行为。为了找到适用于我们应用领域的最佳路径线长度 n 和序列长度 S，我们训练了多个模型，在训练过程中改变 n 和 S，并观察了图 6 所示的 F_1 分数。我们从这项实验中发现了两种规律。首先，增加路径线长度会提高准确率，直至达到最佳长度；超过这一长度后，准确率便会下降。其次，与每个种子点仅使用一条路径线相比，使用路径线序列能得到更准确的结果。我们发现，对于我们的数据集， $n = 900$ 和 $S = 100$ 是最佳选择。

二值图像的大小 $I = L \times L$： 如 3.2 节所述，我们将每条路径线表示在二值图像中。我们使用二值图像大小不同的训练数据集训练了多个模型，如图 7 所示。我们通过计算 F_1得分来比较各个模型，其方式类似于计算 F_1 得分以调节阈值 T。实验表明，小型二值图像（$L \times L$ =5 × 5）无法充分捕捉路径线运动的变化，导致 F_1 得分较低。我们还发现，较大的二值图像（$L \times L = 128 \times 128$）同样会导致略低的 F_1 得分。此外，较大的二值图像会带来较高的内存使用量和更长的训练时间。我们发现， $L \times L = 64 \times 64$ 足以捕捉路径线的变化，从而获得较高的 F_1 得分。在实验中，我们使用 $L \times L = 64 \times 64$ 作为二值图像的大小

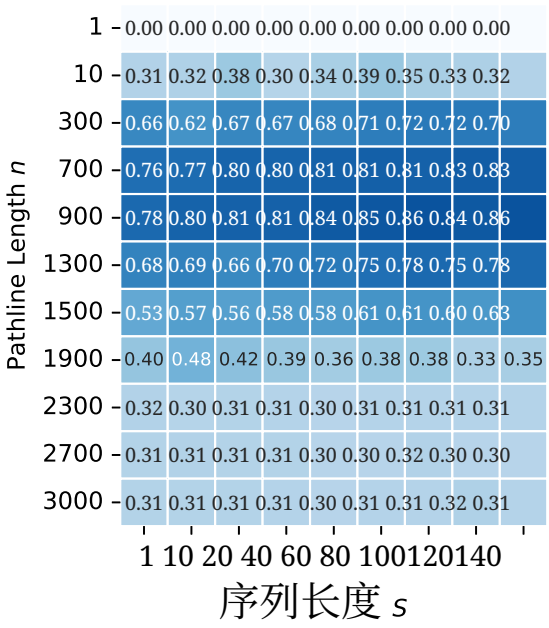

图 6：**路径线长度 (n) 与序列长度 (S)**：F_1 种不同组合的得分，包括 n nd 和 S。第一列表示传统路径线，后续各列表示路径线序列。请注意，增加路径线长度可提高准确率，直至达到最佳长度；超过该长度后，准确率会下降。还请注意，与每个种子点使用单条路径线相比，使用路径线序列可获得更高的准确率。我们发现，对于我们的数据集，$n = 900$ 和 $S = 100$ 是最佳选择。

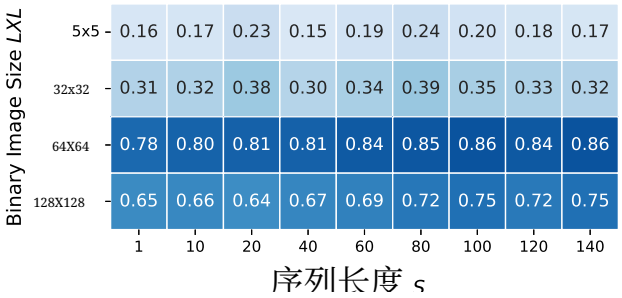

图 7：**二值图像尺寸（$L \times L$）：**请注意，二值图像尺寸为 64×64 时，产生了最高的 F_1 分数，且计算量最少。



（a）规则网格播种　　（b）重要性播种

图 8：**播种策略：**测试时，我们使用规则网格播种路径线。训练时，我们使用重要性播种。

图像 I。

播种策略：各种播种策略旨在优化不同目标，例如美观性、杂乱减少、捕捉流动特征等 [39]。在本文中，路径线播种的主要考量是：在何处能够获得关于水体运动的信息价值最大。由于我们的训练数据以及网上随机获取的海滩图像大多采用横向模式拍摄，因此种子沿水平轴均匀分布。相反，水域通常位于画面中部，天空在上半部分，海滩在下半部分。因此，我们沿垂直轴使用高斯分布来分布种子。这是一种重要性采样 [4]。在训练过程中，我们使用重要性播种，以最大化跟踪水体运动的路径线，并减少海滩或天空中云朵运动等无关信息。在测试过程中，我们使用常规采样，因为无法保证测试数据也采用横向模式。

4.3 使用单条长路径线和路径线序列与 FlowNet 进行比较

我们将 RipViz 与 FlowNet [17]，（一种基于深度学习的流线聚类方法）进行了比较。在 FlowNet 中，$3D$ 流线特征由自编码器学习得到。这些三维流线沿数据的整个范围进行追踪。此外，每个种子点都追踪一条流线。训练好的自编码器用于生成三维流线的一维表示。这些 $1D$表示的维度进一步通过 t分布随机邻域嵌入（t-SNE） [43]降低。随后使用 DBSCAN [13]对生成的低维向量进行聚类。研究人员使用交互式用户界面，通过更改两个特征描述符之间的最大距离 (eps) 和每个簇中的最小样本数（ms）。FlowNet 中的自编码器采用无权重二元交叉熵函数进行训练（即 $w_0 = w_1 = 1$）。为了与 FlowNet 进行比较，我们将长 $2D$ 路径线转换为 $3D$，方法是将时间轴设为 z 轴 [42]。然而，由于我们的路径线在 $3D$ 二值体中分布稀疏，我们发现，使用无权重二元交叉熵的 FlowNet 模型无法学会区分这些路径线，导致所有路径线都被归为同一个簇。我们在图 9 中展示了聚类结果。此外，训练时间也相对较长。要进行恰当的比较，需要修改 FlowNet，使其适用于我们的应用领域。相关修改详见附录A。

我们使用长路径线（在整个视频范围内进行积分）以及单条短路径线（$n = 900$）训练修改后的 FlowNet 模型。修改后的 FlowNet 的输出如图 9 所示。第一列展示了每个视频的一帧代表性视频帧。我们看到，在未进行修改的情况下，FlowNet 会将所有路径线归入同一个簇。当输入贯穿整个视频的单条路径线时，修改后的 FlowNet 和 RipViz 同样无法识别离岸流。当输入较短的路径线（$n = 900$）时，修改后的 FlowNet 开始呈现出离岸流的迹象，但同时也包含大量假阳性。只有像 RipViz 一样使用路径线序列时，我们才能清晰地看到离岸流。

为了定量比较使用较短路径线的修改后的FlowNet 与 RipViz，我们计算了它们的 F_1 得分。如果任一方法标记的种子点位于专家标注的离岸流边界内，则将其标记为真阳性；否则标记为假阳性。如果离岸流内的种子点未被选中，则将这些点标记为假阴性。我们发现，如表 1 所示，修改后的 FlowNet 的 F_1 得分为 0.32，而 RipViz 的 F_1 得分为 0.85。我们推测，修改后的 FlowNet 的 F_1 得分较低，是因为其假阳性率较高。

此外，我们发现，调整聚类步骤中的两个超参数 eps 和 ms 对于找到合适的簇至关重要。我们注意到，具备一些领域知识有助于用户探索这两个超参数，从而找到理想的聚类结果。相比之下，RipViz 是自动化的，运行时无需任何用户输入。

修改后的 FlowNet 和 RipViz 都基于自编码器。然而，RipViz 通过学习路径线序列的时空特征，来学习同一种子点的各条路径线在时间上的关联。这使 RipViz 能够更有效地学习海洋流动行为。在

© 2023 IEEE。本文为已发表于 IEEE 可视化与计算机图形学汇刊的作者版本。该记录的最终版本可在以下地址获取：
10.1109/TVCG.2023.3243834

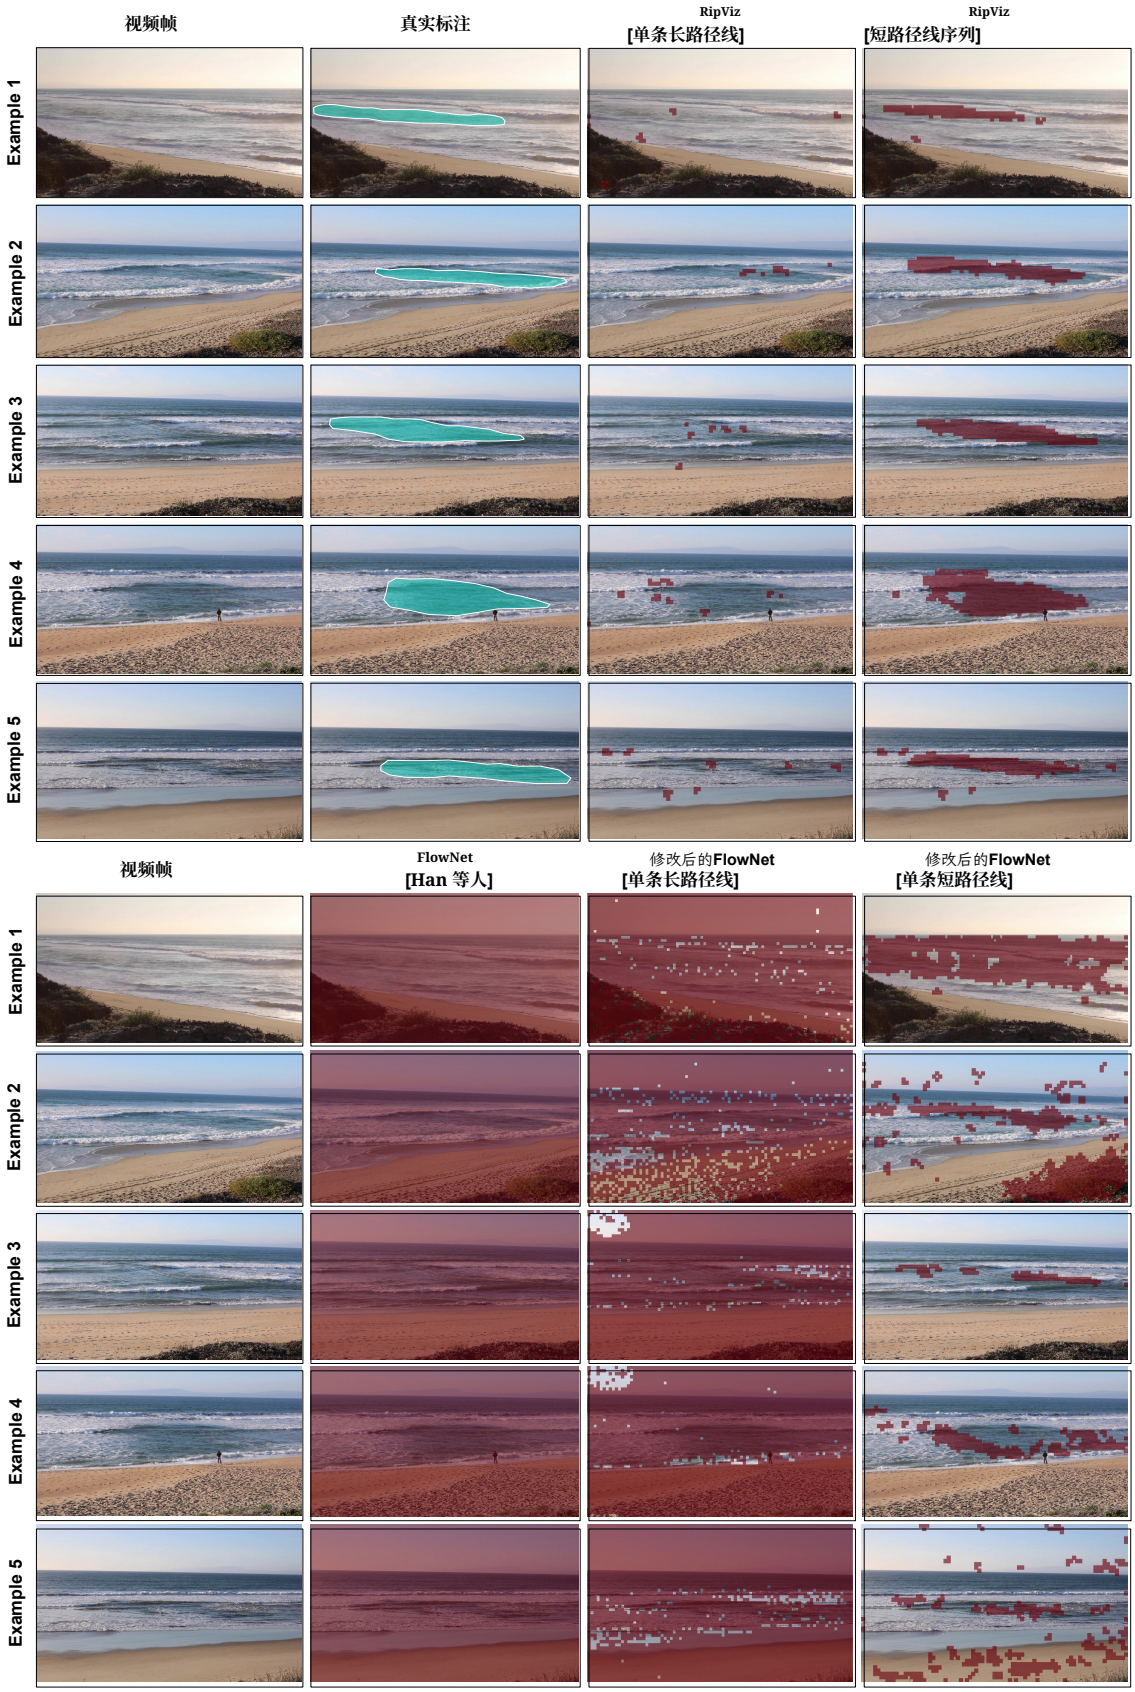

图 9：**使用 FlowNet 和不同路径线参数进行比较：**视频帧列显示视频片段中的一个代表性视频帧，而真实标注列显示专家的真实标注估计结果。请注意，未经修改的 FlowNet（*FlowNet* 列）错误地将所有种子点聚为一个簇。使用较长路径线进行训练时，修改后的Flownet 和 RipViz 都无法检测到离岸流。当修改后的FlowNet 使用单条较短路径线（$n = 900$）进行训练时，我们能够找到一个代表离岸流的簇，但结果不够明确。使用较短路径线序列训练的 RipViz 能够更精确地检测出离岸流。彩色观看效果最佳。

另一方面，修改后的 FlowNet 并未学习路径线在时间上的关联。因此，我们假设，使用路径线序列更有利于学习准周期行为，例如海洋流动中的准周期行为。

4.4 与现有离岸流检测方法的比较

我们将 RipViz 与现有离岸流检测方法进行了比较，如图10所示。图10的第一列和第二列分别展示了视频中的一个代表性视频帧和专家绘制的真实标注。其余各列依次展示了目标检测器 [11],RipViz、滤波箭头图元 [30], 筛选后的彩色映射 [30], 和时间线 [30], 的输出。

4.4.1 与基于行为的方法比较

时间线： Mori等人 [30] 提出使用时间线检测并可视化离岸流。他们将时间线平行于海滩放置，并使用光流追踪时间线上的点，以更新其位置。他们观察时间线被离岸流拖动时的形状变化。如图10所示，时间线会发生变形，并向上延伸至离岸流通道，超出其初始位置。

然而，时间轴的初始放置位置是决定时间轴能否成功发挥作用的一个重要因素。图10中所示的所有时间轴都放置在了最佳位置。为了将时间轴方法与 RipViz 进行比较，我们计算了 F_1 分数。如果时间轴能够在视频中可视化离岸流，我们就将其计为真阳性（TP）；否则计为假阴性（FN）。我们发现，放置得当的时间轴在大多数情况下都能可视化离岸流。然而，用户必须为每个视频指定合适的初始放置位置。相比之下，RipViz 是自动化的，运行时无需用户输入，如表 1 所示。

基于方向的聚类： Philip和Pang [34]假设，离岸流的方向与向量场中的主导流向正好相反，而主导流向对应于入射波方向。向量方向与多数流向相反的位置是潜在的离岸流区域。具有足够多此类向量且其幅值足够大的区域会被标记为离岸流区域。

Mori等人 [30] 采用了类似的方法，将方向映射为颜色、将幅值映射为色调，以获得更好的可视化效果。如图10的“滤波颜色图”列所示，该方法能够检测离岸流的位置。然而，该方法也会突出显示冲浪带和海滩的浅水区域，这一点在示例1至3中显而易见。我们发现，尽管该方法在大多数情况下都能突出显示离岸流，但假阳性像素的数量往往较多。为了与RipViz进行比较，我们计算了 F_1 分数。如表 1 所示，滤波颜色图的 F_1 分数为0.28，这是由于其假阳性率较高。

Mori等人 [30] 也提出了用于可视化离岸流的箭头符号。该方法的输出如图10的箭头图元列所示。我们注意到，与其他方法和 RipViz 相比，箭头符号方法更容易受到流场中噪声的影响。从投射到天空和海滩上的箭头可以明显看出这一点，尽管视频中这些区域只有轻微移动。虽然箭头符号方法在大多数视频中都标出了离岸流，但也产生了大量假阳性检测。同样，我们计算了 F_1 分数。如表 1 所示，滤波箭头符号的 F_1 分数为 0.16，这是由于其假阳性率相对较高。

4.4.2 与基于外观的方法比较

目标检测器： de Silva 等人 [11] 使用目标检测器来检测离岸流。他们利用离岸流图像训练了一个基于深度学习的目标检测器 Faster R-CNN [37], 。他们使用的图像中，受水深地形控制的离岸流具有明显的视觉特征：破碎波之间有一片较暗的区域。随后，他们使用该模型预测离岸流的位置，在视频中的离岸流上叠加边界框。该方法的输出如图10的目标检测器列所示。

我们注意到，目标检测器能够检测出离岸流的部分区域，如图10中的示例2至5所示。然而，离岸流的外观各不相同 [6]。如示例1所示，目标检测器可能会漏掉离岸流的实际位置。相比之下，RipViz 是基于能够捕捉行为 而非

方法	Automated?	F_1 Score
目标检测器 [11]	***yes***	0.43
时间线 [30]	*no*	0.72
滤波颜色图 [30]	***yes***	0.28
滤波箭头符号 [30]	***yes***	0.16
FlowNet [17]	*no*	0.16
修改后的FlowNet [单条长路径线]	*no*	0.19
修改后的FlowNet [单条短路径线]	*no*	0.32
RipViz [单条长路径线]	***yes***	0.08
RipViz [短路径线序列]	***yes***	**0.85**

表 1：**结果摘要：** 请注意，RipViz 的 F_1 得分最高，且在运行时不依赖用户输入。

离岸流外观的路径线进行训练的。因此，它能够在所有示例中检测到离岸流。

此外，我们注意到，边界框只能检测出离岸流的大致区域。有时，边界框会覆盖部分海滩，或者漏掉部分离岸流，尤其是细长的离岸流。我们还注意到，仅凭边界框无法获取离岸流的曲率等信息。为了与 RipViz 进行比较，我们计算了 F_1 得分。我们统计了边界框覆盖的像素数量，其中离岸流像素计为真阳性，其余像素计为假阳性。如果目标检测器未预测出边界框，则将边界内的像素计为假阴性。如表 1 所示，边界框的 F_1 得分为 0。43，而 RipViz 的得分为 0。85。我们认为，这一较低的 F_1 得分是由于边界框的非离岸流区域产生了大量假阳性，以及边界框未覆盖部分离岸流而产生了大量假阴性。

此外，我们还在其他类型的离岸流上测试了 RipViz，而目前尚无针对这些类型的已发表目标检测器。图11展示了几种此类离岸流类型的示例。专家将第一行和第二行中的离岸流归类为泥沙羽流离岸流和结构型离岸流。然而，如图11所示，无论这些离岸流的外观如何，RipViz 都能够检测到它们。更重要的是，泥沙羽流离岸流和结构型离岸流无需额外的训练数据。示例3和4展示了两种离岸流，其中目标检测器由于缺乏预期的视觉特征而未能检测成功。在这两个示例中，RipViz 能够检测到离岸流，因为它使用行为而非外观来检测离岸流。

4.5 专家利用 RipViz 做出的发现

离岸流研究人员通过观察破碎波中的间隙或泥沙羽流等视觉特征的外观，利用其专业知识识别离岸流的边界。然而，离岸流的某些部分有时缺乏这些视觉特征，使专家难以识别离岸流的完整范围。

与基于外观的识别不同，RipViz依据离岸流的行为而非外观来检测离岸流。当缺少视觉特征时，专家可以使用RipViz这一可视化工具来确定离岸流的完整边界。在图12中，我们展示了几个应用案例：离岸流专家查看RipViz提供的可视化结果后，更新了其对原始边界的估计。更新后的边界现在涵盖了近岸附近的馈流，以及发现1和发现3中更远近海处似乎呈环流的模式；还包括发现2中与主离岸流合并的一股较弱的邻近离岸流。顺带一提，发

© 2023 IEEE。本文为作者版本，已发表于 IEEE 可视化与计算机图形学汇刊。该记录的最终版本可获取于：
10.1109/TVCG.2023.3243834

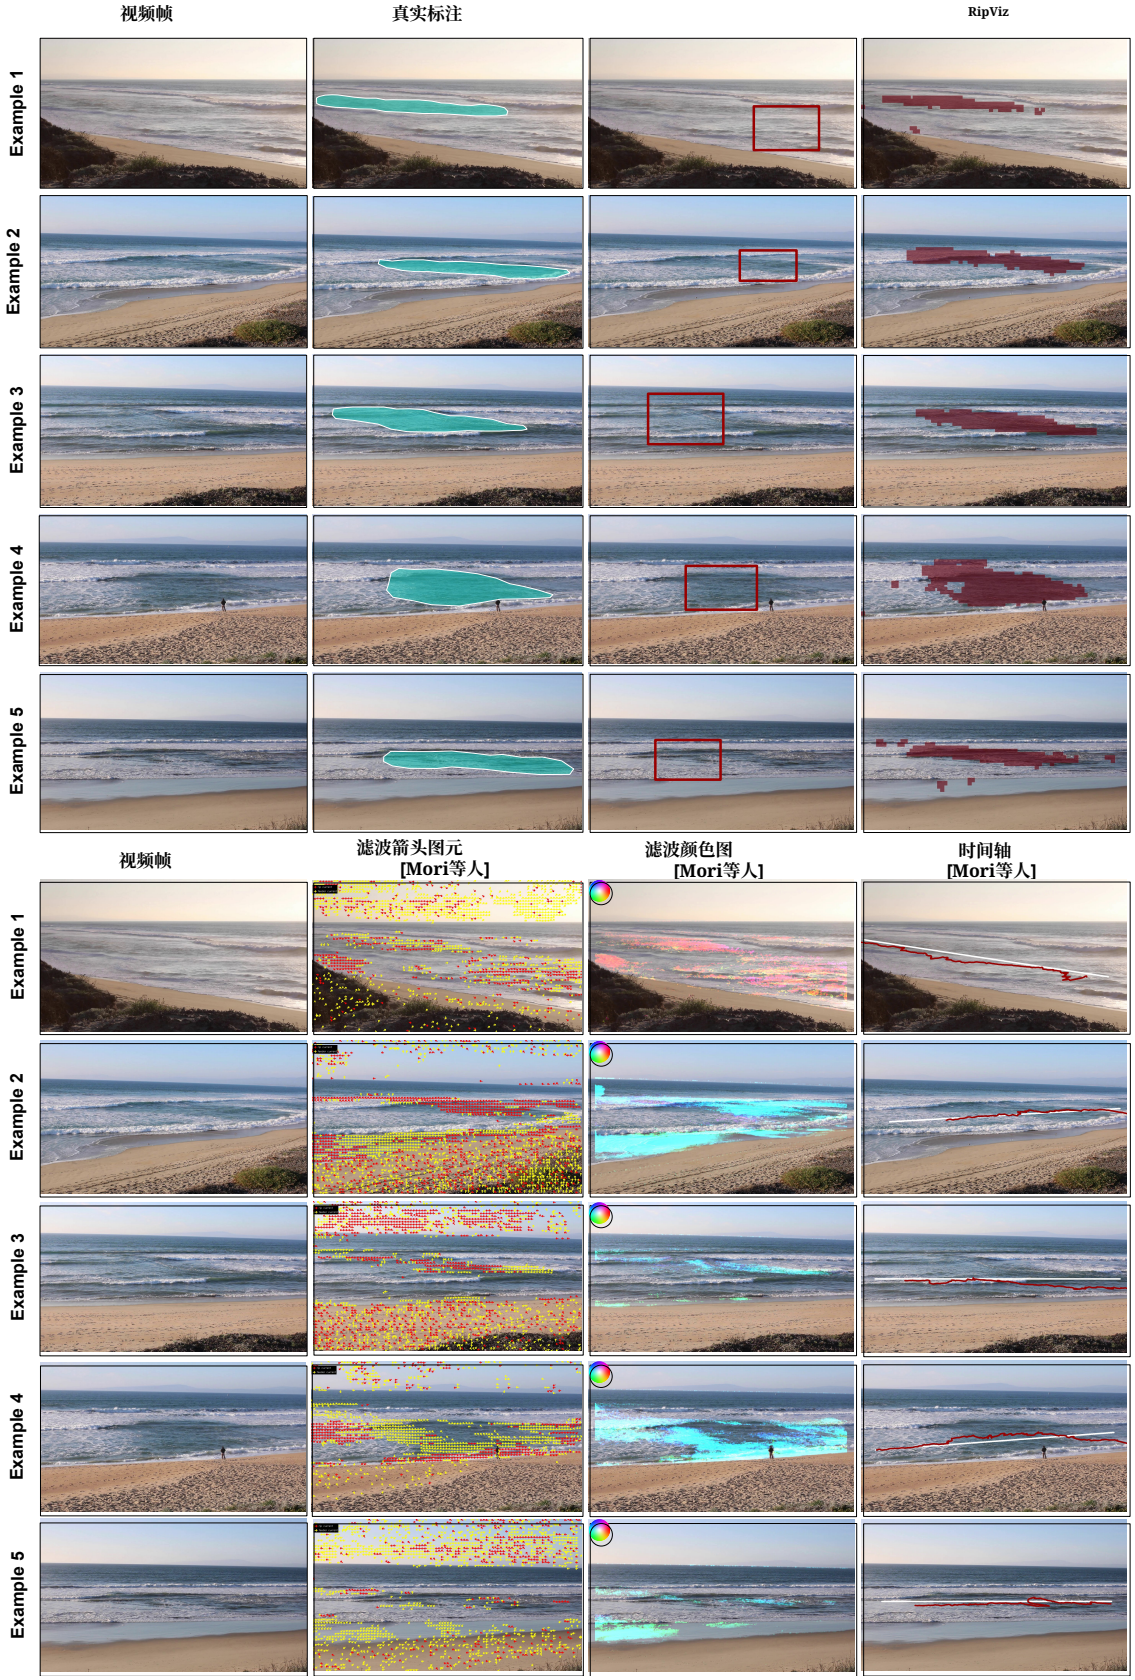

图10：**与既有离岸流检测方法的比较：**视频帧和真实标注列分别展示了该视频片段的一个代表性视频帧和专家真实值估计。其余各列依次展示目标检测器、时间轴、颜色映射、箭头符号和 RipViz。请注意，时间轴方法需要用户输入以指定其初始放置位置；而滤波箭头图元未能滤除天空、海滩和水域非离岸流区域中的错误符号。建议以彩色查看。

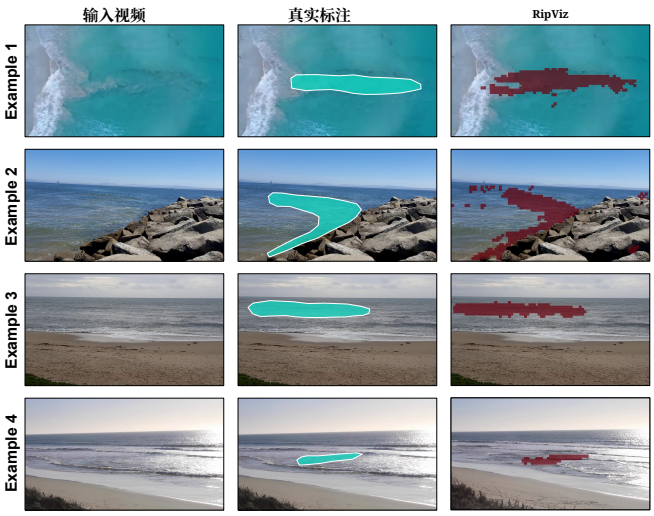

图11：**RipViz 在新型离岸流类型上的表现：**示例1和2分别为沉积物离岸流和结构性离岸流。请注意，与地形型离岸流相比，它们的视觉特征截然不同。目前尚无针对这两类离岸流的已发表目标检测器。然而，请注意，RipViz 能够不受外观变化影响地检测离岸流。示例3和4展示了两处离岸流，由于缺乏预期的视觉特征，目标检测器未能检测到它们。在这两个示例中，RipViz 仍能检测到离岸流，因为它利用行为而非外观来检测离岸流。建议以彩色模式查看。

发现1和3均展示了环流型离岸流，在这种情况下，海滩标识中沿海岸平行游泳的指引可能并不总是有效 [27]。我们在补充材料中提供了基于测试数据所得发现的完整表格。

4.6 用户研究

我们开展了一项用户研究，以更好地了解非专业人士如何使用 RipViz 这一工具来提升对离岸流的认知。我们将 400 名非专业人士分为两组：一组只接受了有关离岸流的海滩警示标志培训，另一组则接受了 RipViz 培训。随后，我们向每位参与者展示一段随机选取的离岸流视频，并询问他们视频中是否存在离岸流。在接受海滩警示标志培训的组中，24% 的参与者未能识别出视频中存在离岸流。在接受 RipViz 培训的组中，只有 14% 的参与者未能识别出视频中的离岸流。

我们开展了第二项实验，以更好地了解参与者能否在视频中定位离岸流。两组参与者都获得了多个离岸流边界估计选项，并被要求选出正确的一项。在接受海滩警示标志培训的组中，只有 34% 的参与者能够选出正确的边界。在接受 RipViz 培训的组中，78% 的参与者能够选出正确的边界。我们通过 Mechanical Turk 招募非专业人士 [8, 32], , 并对可靠的工作人员进行基本筛选；每项任务支付 0.10 至 0.20 美元。

4.7 对视频取景的敏感性

有些参数取决于摄像机取景，包括摄像机与水域之间的距离，以及镜头的焦距或变焦系数。或者，我们也可以考虑视频帧中可见的海滩宽度。我们通过查看现有的若干冲浪网络摄像头（例如 webcoos.com）以及计划安装的网络摄像头，来确定取景范围。我们测试了参数对摄像机取景变化的敏感程度。在图13中，我们展示了在保持当前参数组不变的情况下，改变取景范围所产生的影响。回想一下，测试期间，我们追踪了相同数量、按规则网格分布的种子点。根据结果

如图13所示，我们认为，即使摄像机取景变化20%至30%，这些参数仍然有效。我们发现，所有示例中的 F_1 得分均为 0.82 ± 0.3，且没有明显偏差。

5 总结与讨论

正如 Ben Schneiderman 在其引言中精辟地指出：“可视化的目的是获得洞见，而不是呈现图像。”我们的目标是让未经训练的眼睛可能无法察觉的事物显现出来。本研究首先致力于找出感兴趣的特征（离岸流），然后通过直接在视频中突出显示其位置，以简单易懂的方式呈现这些特征。RipViz 将这一能力融入其中：它是一种混合特征检测方法，结合机器学习与流动分析，从静止视频中提取离岸流。我们使用较短的路径线序列，以捕捉噪声准周期流场中的流动行为。随后，我们使用 LSTM 自编码器学习正常海洋流线序列的行为。通过比较重构误差，训练后的模型能够将属于离岸流的路径线序列标记为异常。将离岸流检测问题转化为异常流动检测问题，也大幅减轻了为每种离岸流类型寻找并标注训练数据集这一繁重任务。

可视化领域已利用深度学习方法从路径线中学习流动行为。具体而言，现有文献使用自编码器从流场数据中学习。作者将每个种子点的一条长路径线/流线作为其深度学习模型的输入。然而，由于破浪带附近存在的准周期流场，基于传统路径线的直接学习并不适用于我们的应用。因此，我们对现有深度学习方法进行了调整和创新，改为对每个种子点使用路径线序列

本文的主要贡献是：

- 一种结合机器学习和流动分析技术的混合特征检测方法，用于自动发现并可视化危险离岸流。

为实现这一目标，以下创新是必要的：

- 对于具有准周期行为的流场，例如海洋流动，使用较短路径线的序列优于使用单条长路径线。

- 与先前工作中使用的未加权二元交叉熵不同，加权二元交叉熵在从由海洋场景生成的稀疏分布路径线中学习时更为有效。

关于静态视频的一个关键假设是，摄像机距离水域足够近，使光流算法能够检测到可测量速度。出于类似原因，我们假设摄像机主要朝向海面，而不是与海滩平行。将摄像机沿着绵延的海滩拍摄，会产生缺乏代表性的光流，尤其是对于距离摄像机较远的点。在计算光流之前对视频帧进行校正，或许能稍微扩大可用范围，但不足以抵消额外的计算成本。因此，摄像机靠近水域且主要朝向海面时，RipViz 的效果最佳。

我们的训练数据主要是来自人烟稀少海滩的视频。我们确实研究了沿着一名慢跑者路径布置的种子点。这些种子点并未被标记为异常。这很可能是因为后续序列中的路径线表明，最初的种子点大多属于正常情况。我们认为，放置在冲浪者、鸟类或场景中其他物体上的种子点也很可能会被标记为正常。我们计划利用更多测试数据对此进行进一步研究。

扩展与未来工作：上述列出的部分贡献并非专门针对离岸流检测。我们计划研究如何结合加权交叉熵损失函数，利用非定常流场的路径线序列来区分层流与非层流，并可能训练模型将涡旋检测为异常行为。

© 2023 IEEE。本文为已发表于 IEEE 可视化与计算机图形学汇刊的文章作者版本。最终版本可通过以下地址获取：
10.1109/TVCG.2023.3243834

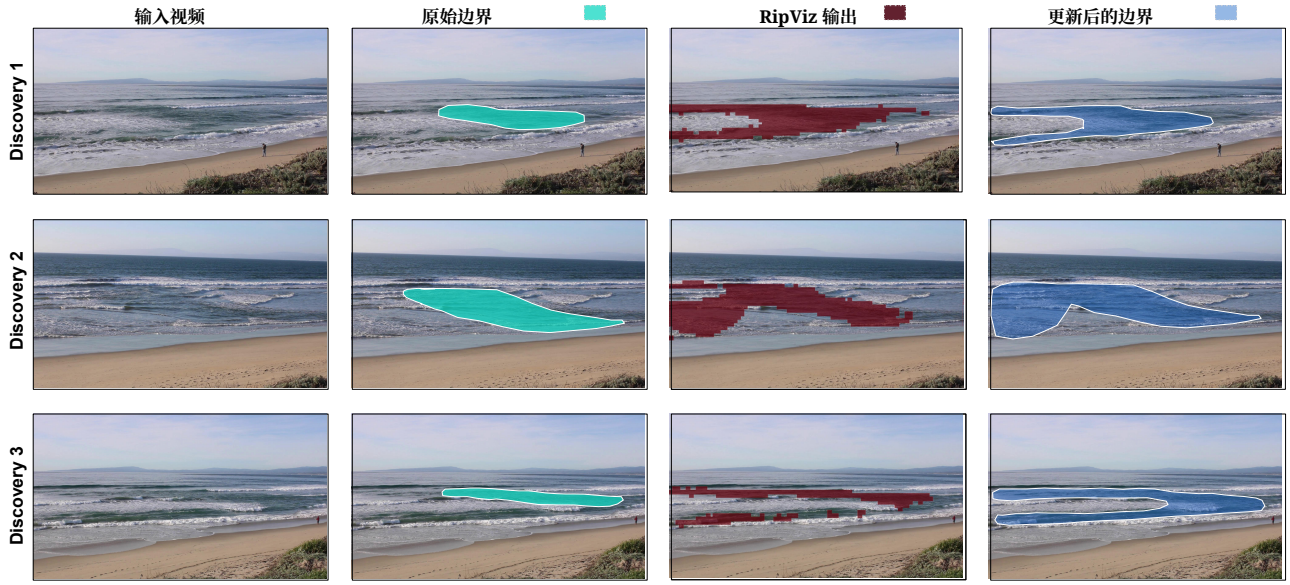

图12：**专家使用 RipViz 的发现：**专家仅通过观察输入视频（原始边界列）估计离岸流边界。查看 RipViz 的输出（*RipViz* 输出列）后，专家更新了原先对离岸流边界的估计，将输入视频中因缺乏明显视觉特征而难以观察到的部分离岸流也纳入其中（更新后的边界列）。补充材料中收录了我们在测试数据上所得发现的完整表格。彩色显示效果最佳。

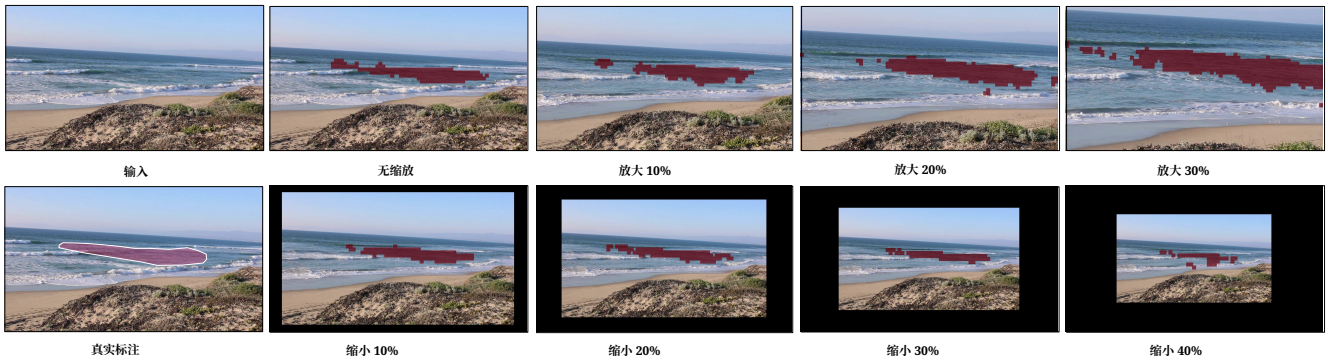

图13：**RipViz 对不同视频取景的敏感度较低：**我们通过对原始视频进行放大和缩小，改变离岸流特征的尺度，同时保持视频的宽高比不变。请注意，即使离岸流特征比训练数据中的更大或更小（在合理范围内），RipViz 仍能够检测到该特征。

我们推测，除本文涉及的流场数据外，路径线序列分析也可能有益于某些类别的流场数据。事实上，我们正在探索这一方向，并计划在另一篇论文中报告结果。简言之，离岸流检测的特定需求促使我们开发了本文介绍的方法，该方法也为可视化领域提供了另一种潜在工具，可用于研究某些类别的流场。

附录A：修改后的 FlowNet

Han 等人 [17] 提出了 FlowNet，这是一种基于深度学习的流线聚类与筛选方法。他们首先将每条流线转换为长度为 1024 的一维特征向量。然后，他们使用 t分布随机邻域嵌入（t-SNE） [43]将该一维向量的维度从 1024 降至 2。随后使用 DBSCAN [13], 对生成的向量进行聚类；DBSCAN 是一种适用于含噪声数据的基于密度的空间聚类方法。作者提供了一个用户界面，可通过调整 DBSCAN算法中两个特征描述符之间的最大距离（eps）以及每个簇中的最小样本数（ms）来改变聚类结果。

我们在这项工作中以 FlowNet 架构为基础，但根据应用需求对其进行了修改。FlowNet 的主要目标是对三维稳态流场中的流线进行聚类。因此，作者设计的深度神经网络架构以三维流线作为输入。然而，在我们的应用领域中，路径线是二维的。为了使 FlowNet 适用于我们的应用领域，我们修改了 FlowNet 的架构，使其以二维路径线作为输入。同样，为适应二维路径线，我们将原始神经网络架构中的三维卷积层和三维批归一化层分别替换为二维卷积层和二维批归一化层。我们还相应地更新了全连接层的输入和输出尺寸。我们保留了与 FlowNet 论文中定义相同的层数、激活函数以及卷积滤波器数量。我们将新的神经网络架构称为修改后的 FlowNet。

我们还发现，出于第 4.2 节讨论的原因，FlowNet 论文中使用的无权重二元交叉熵函数不足以学习海洋流动路径线的变化。因此，在训练修改后的 FlowNet 时，我们使用了第 3.4 节定义的加权二元交叉熵损失函数。我们采用与文中讨论相同的方法训练修改后的 FlowNet。

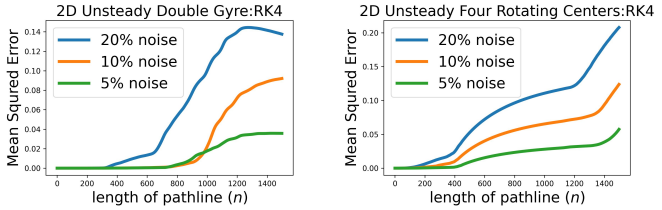

图 14：**含噪声与不含噪声的路径线对比：**在不同长度下计算路径线的均方误差（MSE），并对随机选取的 200 条路径线取平均。请注意，对于两个数据集，较长路径线的均方误差均高于较短路径线。

FlowNet 论文 [17]。我

e 使用d th[们训练] i

了修改后的FlowNet，通过从自动编码器中提取潜在特征描述符，找出路径线的一维表示。我们使用 t-SNE 将一维向量的维度降至 3。随后，我们使用 DBSCAN 对得到的向量进行聚类。聚类前，用户需要设置两个特征描述符之间的最大距离（eps）以及每个簇中的最小样本数（ms）。我们选取与真实标注重叠最多的簇。

附录 B：论证在含噪数据集中使用较短路径线的合理性。

我们使用光流从视频中估计流场。我们假设光流估计存在少量误差或噪声。即使采用设计精良的高阶方法，数值积分也会受到误差累积的影响。在处理含噪数据集时，这一问题会更加严重。对于路径线积分，我们假设，在含噪流场中，较短的路径线序列比单条较长路径线更能准确地捕捉流动行为。

我们使用两个合成数据集间接验证了我们的假设：二维非定常双涡旋 数据集 [40] 和二维非定常四旋转中心数据集 [15]。

我们分别向每个数据集的各个矢量分量添加了 5%、10% 和 20% 的噪声。我们比较了从同一种子点出发的路径线的相似度。我们观察到，较短的路径线与完全无噪声时的路径线更为相似。为量化这一观察结果，我们在每个数据集中随机设置了 200 条路径线，并对其进行追踪。我们计算了不同长度路径线的均方误差（MSE），如图14所示。我们观察到，与较短路径线相比，较长路径线的 MSE 更高。因此，我们预计，较短的路径线能够更准确地呈现重建的含噪流场（例如我们的流场）中的流动行为。

此外，我们通过可视化展示了路径线序列如何因噪声而在较长积分时间内累积误差，如图15所示。这里展示了两条路径线序列，一条以天空为种子点，另一条以海滩为种子点。我们原本预计这两条路径线序列会

由于种子点周围缺乏运动，路径线非常短，并且保持在种子点附近。然而，当积分超过 900 个时间步后，我们注意到，尽管视频中看不到任何明显运动，路径线似乎仍会远离种子点。我们认为这是在较长时间内积分时噪声/误差累积所致。噪声可能来自光流估计或视频压缩损失。



图 15：**数据集中噪声的可视化：**我们在此展示两组路径线序列，一组的种子点位于天空中（左图），另一组的种子点位于海滩上（右图）。每组序列均由 10 条路径线组成。我们展示了在四个积分时间步（n）下的路径线序列。我们原以为这些路径线会非常短，并且保持在种子点附近。然而，随着路径线积分时间延长（n），它们却远离了种子点，这与我们的预期相悖。我们认为这是在噪声较多的真实世界数据集中进行较长时间积分时噪声/误差累积所致。

致谢

本报告部分基于东南沿海海洋观测区域协会（SECOORA）资助开展的工作编制，该协会获得了NOAA的财政援助奖项编号NA20NOS0120220。报告中的陈述、研究结果、结论和建议仅代表作者观点，不一定反映SECOORA或NOAA的意见。

© 2023 IEEE。这是作者版本的文章，已发表于 IEEE 可视化与计算机图形学汇刊。该记录的最终版本见：
10.1109/TVCG.2023.3243834

参考文献

[1] J. L. Ba、J. R. Kiros 和 G. E. Hinton。层归一化。arXiv 预印本 arXiv: *1607 06450*, 2016 3。M. Berenjkoub、G. Chen 和 T. G¨unther。使用卷[2]积神经网络识别涡旋边界。载于 2020 IEEE Visualization Conference (VIS)，第 261 265 2020 2 – 页。IEEE，。A. J. Bowen。离岸流：[3]理论研究。《地球物理研究杂志》，74 23 5467 5478, 1969 1（）：–。K. Burger、P. Kondratieva、J. Kruger 和 R. Westermann。面向流场可[4]视化的重要性驱动粒子技术。载于 2008 IEEE太平洋可视化研讨会，第 71 78 2008 6 – 页。IEEE，。B. S. Carmo、[5]Y. H. P. Ng、A. Prugel-Bennett 和 G.-Z. Yang。一种用于三维磁共振流场矢量场简化的数据聚类与流线简化方法。载于 C. Barillot、D. R. Haynor 和 P. Hellier 编，《医学图像计算与计算机辅助干预——MICCAI 2004》，第 451 458 2004 2 – 页。施普林格·[6]柏林·海德堡，柏林，海德堡，。B. Castelle、T. Scott、R. Brander 和 R. McCarroll。离岸流类型、环流与危险。《地球科学评论》，163 1 21, 2016 1, 8：–。J. Chen、[7]B. Xie、H. Zhang 和 J. Zhai。模式识别中的深度自编码器：综述。载于《仿生计算模型与算法》，第 229 255 2019 3 – 页。世界科学出版社，。[8]J. J. Chen、N. J. Menezes、A. D. Bradley 和 T. North。利用 Amazon Mechanical Turk 开展众包研究的机遇。《Interfaces》，5 1，2011 3 10（）：。[9] 2015 4 F. Chollet 等。Keras，。A. H. da F. Klein、G.[10]G. Santana、F. L. Diehl 和 J. T. de Menezes。海水浴相关危险分析：巴西南部圣卡塔琳娜州海洋海滩五年工作成果。Journal of Coastal Research，第 107 116, 2003 1 – 页。A. de Silva、I. Mori、G. Dusek、[11]J. Davis 和 A. Pang。使用基于区域的卷积神经网络自动检测离岸流。《海岸工程》，166 103859, 2021 1, 2, 3, 8：。S. Ellis 和 S. McGill。使用海滩摄像[12]机和光流检测离岸流与水道。《Shore & Beach》，90 1 50 58, 08 2022 3（）：–。M. Ester、[13]H.-P. Kriegel、J. Sander、X. Xu 等。一种用于在含噪大型空间数据库中发现簇的基于密度的算法。载于 kdd，第 96, 226 231, 1996 6, 11 卷，第 – 页。B. Gary 和 A. Kaehle。OpenCV。[14]《Dr. Dobb's Journal of Software Tools》，3, 2000 3。[15] T. G¨unther、M. Gross 和 H. Theisel。用于流场可视化的通用客观涡旋。《ACM Transactions on Graphics》（SIGGRAPH 论文集），36 4 141 1 141 11, 2017 12（）：：–：。M. Haller、D. Honegger 和 P.[16]Catal´an。通过海洋雷达观测离岸流。《Journal of Waterway Port Coastal and Ocean Engineering》，140 115 124, 03 2014 10 1061 1943 5460 0000229 2：–。doi：。/[17](ASCE)WW。-。J. Han、J. Tao 和 C. Wang。FlowNet：用于流线和流面的聚类与选择的深度学习框架。《IEEE 可视化与计算机图形学汇刊》，26 1744，2018 4 1732 2、3、5、6、8、11、12（）：–。[18] R. Holman 和 M. Haller。近岸区遥感。《海洋科学年度评论》，5，12 2011。doi：10.1146/annurev-marine-121211 - 172408 2[19] B. Kim 和 T. G¨unther。使用卷积神经网络从非定常二维矢量场中稳健提取参考系。载于《Computer Graphics Forum》，第 38, 285 295 2019 2 卷，第 – 页。Wiley[20]Online Library，。S. Leatherman 和 J. Fletemeyer 编。《离岸流：海滩安全、物理海洋学与波浪建模》（第 1 版）。CRC Press，2011。doi：10.1201/b10916 1[21] S. Leatherman 和 S. Leatherman。离岸流检测与测量技术。《International Journal of Earth Science and Geophysics》（ISSN：*2631 5033* 3 1 2017 10 35840 2631 5033 1814 2 -），（），。doi：[22]DOI：。/-/L. Liu、W. Ouyang、X. Wang、P. Fieguth、J. Chen、X. Liu 和 M. Pietik¨ainen。通用目标检测的深度学习：综述。《International Journal of Computer Vision》，128(2):261–318，2020。doi：10. 1007/s11263-019-01247-4 1[23] S. Lodha、J. Renteria 和 K. Roskin。二维矢量场的保拓扑压缩。载于《Proceedings Visualization 2000. VIS 2000》（Cat. No.00CH37145），第 343–350 页，2000。doi：10.1109/VISUAL.2000.885714 2[24] B. Lucas 和 T. Kanade。一种迭代式图像配准技术及其在立体视觉中的应用。《国际人工智能联合会议》，第 674–679 页，1981。3[25] J. B. Lushine。离岸流溺水事故及相关天气因素研究。《National Weather Digest》，第 13 19, 1991 1 – 页。J. Ma、C.[26]Wang 和 C.-K. Shene。用于重要性驱动流场可视化的相干视点相关流线选择。载于《Visualization and Data Analysis 2013》，第 8654 卷，第 865407 页。International Society for Optics and Photonics，2013。2[27] J. MacMahan、A. Reniers、J. Brown、R. Brander、E. Thornton、T. Stanton、J. Brown 和 W. Carey。基于现场观测的离岸流简介。《Journal of Coastal Research》，27(4), 2011。doi：10. 2112 11 00024 1 1, 2, 10 /JCOASTRES-D--。S.[28]Marchesin、C.-K. Chen、C. Ho 和 K.-L. Ma。面向三维向量场的视点相关流线。《IEEE 可视化与计算机图形学汇刊》，16 6 1578 1586, 2010 2（）：–。C. Maryan、M. T. Hoque、C. Michael、E. Ioup 和 M. Abdelguerfi。[29]机器学习在从图像检测离岸流通道中的应用。《Applied Soft Computing》，78 84 93, 2019 1, 2, 3：–。I. Mori、A. De Silva、G. Dusek、[30]J. Davis 和 A. Pang。基于流的离岸流检测与可视化。《IEEE Access》，2022。2、3、8[31] V. Nair 和 G. E. Hinton。修正线性单元改进受限玻尔兹曼机。载于 ICML，2010。3[32] G. Paolacci、J. Chandler 和 P. G. Ipeirotis。在 Amazon Mechanical Turk 上开展实验。《Judgment and Decision Making》，5 419, 2010 5 411 10（）：–。[33] F. Pedregosa、G. Varoquaux、A. Gramfort、V. Michel、B. Thirion、O. Grisel、M. Blondel、P. Prettenhofer、R. Weiss、V. Dubourg 等。Scikit-learn：Python 机器学习库。《Journal of Machine Learning Research》，12:2825–2830，2011。5[34] S. Philip 和 A. Pang。使用光流检测和可视化离岸流。载于 EuroVis（短文），第 19 23, 2016 2, 3, 8 – 页。A. H. Rashid、I.[35]Razzak、M. Tanveer 和 A. Robles-Kelly。RipNet：一种用于识别离岸流的轻量级单类深度神经网络。载于《Communications in Computer and Information Science》，第 172–179 页。Springer International Publishing，2020。doi：10.1007/978-3 -030-63823-8 21 2、3[36] A. H. Rashid、I. Razzak、M. Tanveer 和 A. Robles-Kelly。RipDet：一种用于离岸流检测的快速轻量级深度神经网络。载于 2021 International Joint Conference on Neural Networks (IJCNN)。IEEE，2021 年 7 月 2021 10 1109 52387 2021 9533849 2, 3 。doi：。/ijcnn。。[37]S. Ren、K. He、R. Girshick 和 J. Sun。Faster R-CNN：借助区域建议网络实现实时目标检测。载于《Advances in Neural Information Processing Systems》，28, 2015 8 。M. Ribeiro、A. E. Lazzaretti 和[38]H. S. Lopes。用于视频异常检测的深度卷积自编码器研究。《Pattern Recognition Letters》，105 13 22, 2018 3：–。S. Sane、R. Bujack、C. Garth 和[39]H. Childs。种子点放置与流线选择技术综述。《Computer Graphics Forum》，39 3 785 809, 2020 10 1111 14036 2, 6（）：–。doi：。/cgf。S. C.[40]Shadden、F. Lekien 和 J. E. Marsden。二维非周期流中基于有限时间李雅普诺夫指数的拉格朗日相干结构定义与性质。《Physica D: Nonlinear Phenomena》，212 3 4 271 304, 2005 10 1016 2005 10 007 12（-）：–。doi：。/[41]j.physd。。。J. Tao、J. Ma、C. Wang 和 C.-K. Shene。用于三维流场可视化的流线选择与视点选择统一方法。《IEEE 可视化与计算机图形学汇刊》，19(3):393–406, 2012。2[42] H. Theisel 和 H.-P. Seidel。特征流场。载于《Proceedings of the symposium on Data visualisation》*2003*, 141 148, 2003 6 – 页。L. Van der[43]Maaten 和 G. Hinton。使用 t-SNE 可视化数据。《Journal of Machine Learning Research》，9 11 2008 6, 11（），。H. Yu、C.[44]Wang、C.-K. Shene 和 J. H. Chen。层次化流线束。《IEEE 可视化与计算机图形学汇刊》，18 8 1353 1367, 2011 2（）：–。J. Zhai、S. Zhang、J. Chen 和 Q.[45]He。自编码器及其各种变体。载于 2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC)，第 415–419 页，2018。doi：10.1109/SMC.2018.00080 3