

# 基于全局相关性网络的文物安防复合感知 数据融合分析

项俊, 农高峰, 李旭锋

(中南民族大学 电子信息工程学院, 武汉 430074)

**摘要** 传感器感知技术在文物安防领域得到了广泛应用. 然而, 由于文物安防场景的复杂性, 基于单一线索感知的装备监测误报率较高, 制约了要地保护的智能化应用推广. 提出了一种装备复合感知数据融合分析方法, 设计基于自注意力机制的全局相关性神经网络, 对要地多传感器异常事件的联动触发规律进行时空域建模, 实现多传感器数据的联合优化和互补, 提升系统状态监测精度. 在三星堆祭祀坑示范地测试结果表明: 融合了多种传感器数据的成套复合装备误报率从原来的10.24%下降为1.10%, 验证了所提方法的有效性.

**关键词** 文物安防; 复合感知; 融合分析; 神经网络

中图分类号 TP391.4 文献标志码 A 文章编号 1672-4321(2025)01-0085-11

doi: 10.20056/j.cnki.ZNMDZK.20250715

## Data fusion analysis of cultural relic security compound perception based on global correlation neural network

XIANG Jun, NONG Gaofeng, LI Xufeng

(College of Electronic Information Engineering, South-Central Minzu University, Wuhan 430074, China)

**Abstract** Sensor-based IoT sensing technology has been extensively applied in the field of cultural relic security. However, due to the complexity of cultural relic security scenarios, equipment monitoring based on a single clue often results in a high false alarm rate, limiting the widespread adoption of intelligent applications for site protection. A data fusion analysis method for equipment compound perception is proposed. Specifically, a global correlation neural network is constructed with self-attention mechanisms, which models the spatial-temporal collaborative triggering patterns for multi-sensor abnormal events at key sites. The achieves joint optimization and complementation of multi-sensor data, enhancing the accuracy of the system state monitoring. The test results from the Sanxingdui sacrificial pit demonstration site show that by fusing multiple sensor data, the false alarm rate of the compound equipment has been reduced from the original 10.24% to current 1.10%, validating the effectiveness of the proposed method.

**Keywords** cultural relic security; compound perception; fusion analysis; neural network

文物安防是文物管理工作的重中之重. 受限于技术手段落后, 早期的文物安防手段大多采用保安人员巡逻和闭路电视监控的方式, 存在覆盖范围有限、人工依赖性强、智能化低等问题<sup>[1]</sup>. 随着传感器技术的不断发展, 从上世纪80年代起, 红外装置、微波和超声波声控探测器等现代化感知安防装备被

引入文物安防领域, 逐步形成了基于现代感知检测技术的文物安防体系, 一定程度上提高了文物保护工作的有效性和智能化<sup>[2]</sup>. 2012年, 国标《博物馆和文物保护单位安全防范系统要求 GB/T 16571-2012》发布, 为我国博物馆和文物保护单位在安全防范领域提供了科学规范的指导和标准<sup>[3]</sup>, 强调现代化感

收稿日期 2023-09-11

作者简介 项俊(1984-), 女, 副教授, 博士, 研究方向: 计算机视觉、模式识别, E-mail: junxiang@scuec.edu.cn

基金项目 国家重点研发计划资助项目(2020YFC1522905)

知防范技术在博物馆和文物保护单位实现文物安全防范措施中的重要性.许多学者基于现代化感知检测手段开展在文物安防领域的相关应用研究.如黄光伟面向博物馆安防问题的,提出了基于现代传感器技术的全方位、多层次纵深防护体系<sup>[4]</sup>.张悦<sup>[5]</sup>总结了红外传感器技术在文物科学保护中的应用.

近年来,复合感知,即多传感器数据融合分析技术,已成为文物安防领域的研究热点.多传感器感知技术协同利用多个传感器信息,实现多级别和多线索信息监测、关联和分析.如吕娇以文物安防、边防等为背景,设计了一种基于雷达指引的监控视频实时分析模型与算法,实现了对文物安防目标全自动、全方位、全天候的智能实时监控<sup>[6]</sup>.邢增波<sup>[7]</sup>结合了雷达和视频技术的优势,实现了非法入侵目标的探测定位和视频可见双重功能,提高了文物入侵目标的识别率、图像显示控制能力和预警手段.陈章<sup>[8]</sup>提出基于红外相机协同“声光电”感知检测技术的动物驱赶安防措施,缓解鸟类活动对石窟寺、古建等不可移动文物的破坏.杨俊淇<sup>[9]</sup>提出了基于分布式振动光纤结合声波传感的全天候盗掘立体监测技术,实现了在三星堆三号坑遗址的地下扰动信号现场测试,解决了考古现场全天候、无盲区、无人值守的盗掘探测与地下文物保护.

然而,由于技术上的差异和缺乏统一规划,基于多传感器感知技术的文保方案中存在“数据孤岛”问题<sup>[10]</sup>,也即各传感器往往独立工作,未能充分利用多数据之间的关联性,依旧缺乏对多种传感器数据的自主融合分析能力,独立的单一传感器检测技术难以满足文物感知场景的复杂多样性.例如分布式光纤传感器的工作原理是通过构造干涉仪进行振动信号的解调还原,本质是基于震动信号阈值触发的检测报警,这种通过阈值的设置具有极高的敏感性,如小动物的路过,雨滴的撞击等都会引起设备的误报,同样基于红外温度感知的传感器,极易受小动物以及检测环境温湿度影响.基于文物保护“零漏报”的预警要求,单一传感器检测技术在实际应用过程中易产生大量虚假警报,极大的增加了文保单位工作人员的复合工作量,智能化安防系统效率大打折扣.因此,如何充分利用多传感器检测技术,缓解现有系统中单传感器高误报率问题,有效提升基于现代感知检测技术的文物安防体系效率,是目前亟待解决的一个关键问题.

文物保护安防事件产生往往不是单一危险源引起的.从时间轴看,安防事件发生前一刻、发生

时、发生后一刻进行分析,往往会比基于单一时刻的考察更加有效;从空域角度看,文物异常行为发生路径特性,可以为分析复杂场景中的事件监测提供依据.因此从时空域角度出发,深入分析各安防环节中的信息流转、各安防环节异常事件触发和反馈,可以建模特定危险事件的发生规律,从而综合决判特定传感器的监测有效性,实现基于多线索数据智能融合的复合感知技术,有效缓解单一传感器误报率高的问题.

图1所示为三星堆祭祀坑保护区部署装备的效能区域和入侵路线示意图.该保护区针对防盗、防破坏监测任务设计了专属的行经路径.以行进路线1为例,首先跨越保护隔离区会触发振动光纤的入侵报警,沿途将会陆续触发安防雷达、红外激光雷达监测装备,在核心区域的盗掘、挖掘行为将触发土壤扰动监测装置报警.在此场景中,特定点位的特定传感器只针对某种特定事件进行检测,且时常出现漏检、误报,但从时空域角度考察该安防事件在各环节触发的一系列动作、并进行推理分析,可以获得该行经路线上危险行为的触发事件联动和衍生规律.以此作为综合决判特定传感器监测有效性的重要依据,有望有效缓解单一传感器高误报率问题.

基于上述分析和思路,本文针对单一传感器误报率高问题,开展基于装备复合感知融合分析技术的文物安防方法研究.通过设计基于全局相关性建模的神经网络模型,对多传感器监测状态在时空域上的触发联动机制进行建模,实现多感知数据的联合优化和融合推理.在三星堆祭祀坑示范地的测试结果表明,该方法综合了提升成套装备监测的有效性,达到了有效降低装备误报的目的.

## 1 基于全局相关性建模的复合传感器多线索数据融合算法

多路传感器数据融合分析是本文设计的关键.为了充分利用不同时间与空间的多传感器数据资源,本文采用深度学习技术建模要地多感知数据间的异常事件联动规律,并以此推断各路传感器状态有效性,降低误报,从而提升成套装备检测的精度.为此将多传感器决策融合分析问题转化为基于事件触发的多传感器决策联合优化与状态推理,算法执行流程如图2所示:输入数据为要地各感知传感器在特定时间窗口内的实时监测信息,首先经过数

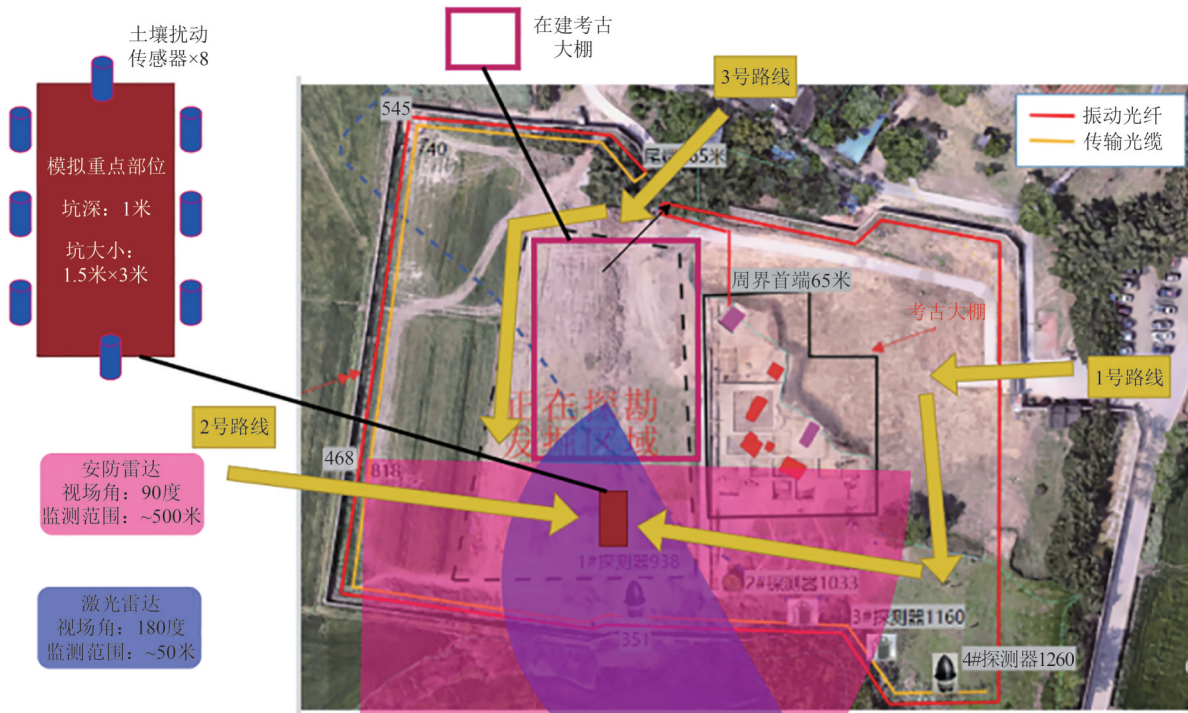


图 1 装备效能区域与入侵路线示意图

Fig. 1 Schematic of equipment effectiveness areas and incursion routes




图 2 多传感器数据决策融合分析示意图

Fig. 2 Schematic diagram of multi-sensor data decision fusion analysis

据预处理模块实现监测数据的平滑及时间对齐,其次将对齐以后的多感知信号并行拼接送入全局相关性网络,输出为该时段内各传感器异常事件的概率分布.下面逐一介绍算法构建的各环节.

### 1.1 数据预处理

在实际场景中,各传感器采集的状态信号往往夹杂大量的噪声,同时由于不同传感器采样频率的差异,各传感器信号存在时序上的不对齐现象.为了精确建模各传感器数据的相关性,必须首先进行数据的预处理,通过滤波和平滑采样技术实现不同传感器信号的平滑处理及时序对齐.对于资源受限的装备节点计算平台而言,数据预处理也是实时性和有效性的重要保障.

本文采用分段聚合逼近算法进行数据变换,实现不同采样频率的传感器信号滤波与时序对齐.分段聚合逼近算法是一种经典的分段采样算法,假设

第  $k$  个传感器在  $T$  时间段内的原始监测数据为  $C^k = \{x_1^k, x_2^k, \dots, x_n^k\}$ ,  $n$  为采样点数;定义分段聚合逼近算法的对齐序列为  $\tilde{C}^k = \{\tilde{x}_1^k, \tilde{x}_2^k, \dots, \tilde{x}_N^k\}$ :

$$\tilde{x}_i^k = \frac{n}{N} \sum_{j=\frac{n}{N}(i-1)}^{\frac{n}{N}i} x_j^k, \quad 1 \leq i \leq N, \quad (1)$$

$N$  是数据处理后该传感器在  $T$  时间窗口的数据个数.需要说明,由于采样频率不同,不同传感器在  $T$  时间窗的采样点数  $n$  不同,但经过(1)式预处理后的数据长度均为  $N$ ,为异构数据的时空对齐提供了保证.设要地保护区共覆盖  $M$  种传感器装备,则将  $T$  时间窗内所有感知传感器预处理后数据并行拼接,即得到当前窗口内时空域对齐的复合感知数据样本:

$$X = [\tilde{C}^1; \tilde{C}^2; \dots, \tilde{C}^M]^T = \begin{bmatrix} \tilde{x}_1^1 & \tilde{x}_2^1 & \dots & \tilde{x}_N^1 \\ \tilde{x}_1^2 & \tilde{x}_2^2 & \dots & \tilde{x}_N^2 \\ \vdots & \vdots & & \vdots \\ \tilde{x}_1^M & \tilde{x}_2^M & \dots & \tilde{x}_N^M \end{bmatrix} \quad (2)$$

为减轻边缘节点计算与存储负担,鉴于融合算法本质属于决策级融合,将数据做二值化处理为  $\{0, 1\}$  二元离散变量:当第  $k$  个传感器预处理数据  $\tilde{x}_j^k > 0.4$  则记为  $\tilde{x}_j^k = 1$ , 否则  $\tilde{x}_j^k = 0$ ; 这里数值 1 代表异常事件触发状态, 0 为正常状态.

### 1.2 全局相关性网络

本文构建基于自注意力机制的全局相关性神经网络,用于挖掘多线索传感器监测信号在时空域上的触发事件联动规律,以此实现多传感器联合状态的最优推理.该模型输入为多传感器预处理后的二元数据拼接,通过模型的训练学习,输出各传感器数据异常事件的联合状态概率分布.自注意力学习机制<sup>[11]</sup>因能有效建模数据间相关性被广泛应用于机器学习各领域,本文在 GoogLeNet<sup>[12]</sup>网络模型基础上,通过在 Inception v2 模块中嵌入基于自注意力学习机制(self-attention mechanism)的全局相关性建模特性,构建实现复合感知数据决策融合的相关性网络.

Inception 系列模型是 Google 公司 2015 年提出,初衷是针对卷积神经网络在深度增加时导致的网络退化问题,以及如何在不影响网络性能前提下,有效降低网络训练的参数和存储开销. Inception v2 是其第二个版本,网络结构示意图如图 3 所示.它利用  $1 \times 1$  卷积(convolution)、 $3 \times 3$  卷积、平均池化实现多尺度卷积、增强网络的特征学习适应能力.其中  $1 \times 1$  卷积通过减少特征图通道数以降低模型参数量;最右边支路中两个  $3 \times 3$  卷积核可以实现  $5 \times 5$  卷积核的感受野,在增强网络非线性拟合能力的同时也有效减少了参数量.除此之外, Inception v2 在每一个卷积层后都添加一个批归一化(Batch Normalization, BN)层<sup>[13]</sup>和一个激活函数 Relu 层<sup>[14]</sup>, BN 层用于统一每个卷积层(除第一个卷积层)输入分布,加快网络收敛.

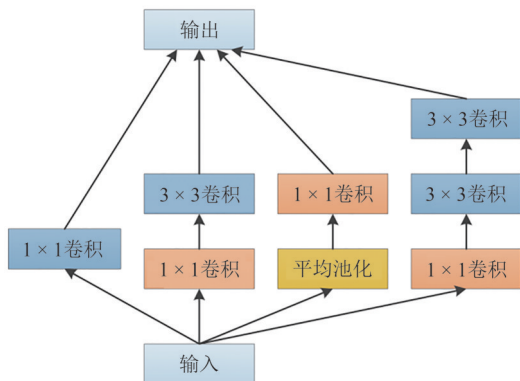


图 3 Inception v2 网络结构示意图

Fig. 3 Schematic diagram of the Inception v2 network architecture

如图 4 所示,为了增强全局相关性学习特性,本文设计的 Inception v2-SA 模型在 Inception v2 模块的最左边支路中嵌入了自注意力学习机制.之所以只在一条支路嵌入,是因为自注意力机制涉及的计算量较大,而装备节点计算资源有限边缘计算、无法支撑多支路嵌入注意力机制的计算负载;同时  $1 \times 1$  卷积核能够专注的学习到每个特征点在各通道上的信息.




图 4 Inception v2-SA 结构示意图

Fig. 4 Schematic of Inception v2-SA structure

基于自注意力机制的全局相关性网络结构如图 5 所示,通过在时空域逐元素计算各传感器数据间的相关性,建模全局特征之间的依赖关系,从而挖掘要地多传感器数据间的联动规律.需要指出,这种数据之间的相关性并不是由简单的代数运算得到的,而是利用卷积层在特征图上不断地学习而得到的非线性映射关系,呈现的是各感知数据在时空域上的拓扑依赖关系<sup>[15]</sup>.图 5 展示了自注意力机制的工作原理.

为了便于理解,实现自注意力机制的伪代码如表 1 所示:

伪代码中特征图理解为输入数据经卷积操作以后的输出张量,本文针对解决多传感器决策融合分析,对应示范地数据输入为三种维度,其网络架构见表 2 所示.

从表 2 可以看出,模型的结构相对简单,  $7 \times 30$  输入网络模型参数为 91652 个(32 位浮点型),模型训练占用内存 80 M.模型设计一方面适应示范地小样本集采集的可行性,另一方面满足边缘节点装备算法的低内存消耗处理可行性.本文中涉及所有学习算法均采用“模型驱动”的在线学习策略,即将模型训练与推理的计算任务分开,在边缘节点装备仅执行优化后的模型计算.

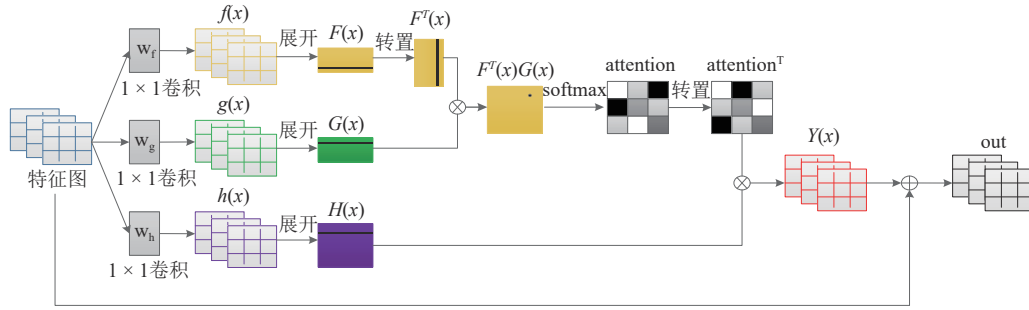


图 5 自注意力机制模块网络结构图

Fig. 5 Diagram of the network structure of the self-attention mechanism module

表 1 自注意力学习机制算法伪代码

Tab. 1 Self-attentive learning mechanism algorithm pseudo-code

输入:特征图 $x \in \mathbb{R}^{W \times H \times C}$ , $W, H, C$ 代表特征图宽、高、通道数;
输出:output.
1 $x$ 分别经过 3 个 $1 \times 1$ 卷积层(通道数为 $c = C/8$ ), 得到 $f(x), g(x), h(x)$ ; 卷积核个数为 $c$ ( $c=C/8$ );
2 将 $f(x), g(x), h(x)$ 沿空域拉伸, 分别得到二维矩阵 $F(x), G(x), H(x)$ , 尺寸均为 $c \times N$ , 其中 $N = W \times H$ ;
3 $F(x)$ 转置后与 $G(x)$ 做矩阵乘法, 再经过 Softmax 操作得到 attention 矩阵 $\in \mathbb{R}^{N \times N}$
4 attention 矩阵转置得到 $\text{attention}^T \in \mathbb{R}^{N \times N}$ ;
5 $H(x)$ 与 $\text{attention}^T$ 做矩阵乘法, 再进行形变, 得到注意力加权后的张量 $Y(x) \in \mathbb{R}^{c \times W \times H}$
6 $Y(x)$ 与原特征图相加, 得到最终输出结果 output.

表 2 对应三种输入尺寸的相关性网络模型架构

Tab. 2 Correlation network model architecture corresponding to three input dimensions

输入(7×30)	卷积核/步长	输出
卷积	1×1/1	7×30×64
最大池化	3×3/1	5×28×64
inception v2-SA	/	5×28×256
平均池化	3×3/1	1×1×256
linear	/	1×1×2
softmax	/	1×1×2
输入(6×30)	卷积核/步长	输出
卷积	1×1/1	6×30×64
最大池化	3×3/1	4×28×64
inception v2-SA	/	4×28×256
平均池化	3×3/1	1×1×256
linear	/	1×1×2
softmax	/	1×1×2
输入(4×30)	卷积核/步长	输出
卷积	3×3/1	4×30×64
最大池化	3×3/1	2×28×64
inception v2-SA	/	2×28×256
平均池化	3×3/1	1×1×256
linear	/	1×1×2
softmax	/	1×1×2

## 2 实验

### 2.1 数据生成

本文依托科技攻关项目“不可移动文物安防(防盗、防破坏)关键技术及装备研究”,在三星堆祭祀坑示范地开展基于复合感知融合分析的方法研究,目的是验证本文所提相关性网络对成套装备感知数据融合决判算法降低误报的有效性.其中部署装备的效能区域和入侵路线见图 1,图 6 给出了各实验点位的分布,具体实验描述见表 3.

实验地点为四川省广汉市三星堆村.测试天气涉及雨天、晴天、大雾天;复合传感器涉包括分布式光纤监测装备、红外激光雷达装备、土壤扰动监测装置、安防雷达监测装备;测试工具包括铁锹、洋镐(锄头)、对讲机、梯子、皮尺、秒表、鞭炮等.测试记录人员为当地文保单位工作人员,测试时间为 2023 年 7 月 3 日至 2023 年 10 月 20 日,9:00-22:00.

表 3 中的 A 操作表示模拟真实的异常事件,实施细节如下:

(1)人员侵入测试:测试人员在指定测试点来回走动,每个测试点做 5 组测试,每组测试在距离振动光纤埋设处正上方  $\pm 20$  cm 内来回走动 10 s.

(2)人员挖掘测试:测试人员在指定测试点做挖掘测试,每个测试点做 5 组测试,每组测试在距离振动光纤埋设处 20 cm 位置挖掘 10 s;如果为地下增敏探头,分别在距离地下增敏探头埋设处 1 m/2 m/3 m 位置挖掘 10 s.

(3)机械挖掘测试:测试人员在指定测试点开挖掘机做挖掘测试,每个测试点做 5 组测试,每组测试在距离地下增敏探头埋设处 5 m 位置挖掘 1 min.

(4)模拟地下爆破测试:测试人员在指定测试点做地下爆破测试,每个测试点做 5 组测试,每组测试在距离地下增敏探头埋设处 15 m 位置挖 30 cm 深的坑埋入鞭炮引爆.




图6 入侵路线和测试点位示意图

Fig. 6 Intrusion route and test points schematic

表3 测试点位实验操作说明

Tab. 3 Test point experimental operation instructions

测试点位编号	点位简介	拟测试的设备	模拟操作类型	具体操作A (模拟真实事件的异常)	具体操作B (模拟虚假事件的异常)	备注
1-1	围墙东侧入口	分布式光纤监测装备	人员侵入、人员挖掘、机械挖掘、爆破	人员在测试点来回走动、模拟人员挖掘、模拟挖掘机挖掘、模拟地下爆破	探测范围外人员活动、小动物在测试点活动、远距离的挖掘机作业、空中鞭炮	
1-2	围墙东侧入口和重点区域之间	分布式光纤监测装备	人员侵入、人员挖掘、机械挖掘、爆破	人员在测试点来回走动、模拟人员挖掘、模拟挖掘机挖掘、模拟地下爆破	探测范围外人员活动、小动物在测试点活动、远距离的挖掘机作业、空中鞭炮	
1-3	围墙西侧入口和重点区域之间	分布式光纤监测装备、红外激光雷达装备、安防雷达监测装备	人员侵入、人员挖掘、机械挖掘、爆破	人员在测试点来回走动、模拟人员挖掘、模拟挖掘机挖掘、模拟地下爆破	探测范围外人员活动、小动物在测试点活动、远距离的挖掘机作业、空中鞭炮	
1-4	围墙西侧入口和重点区域之间	分布式光纤监测装备、红外激光雷达装备、安防雷达监测装备	人员侵入、人员挖掘、机械挖掘、爆破	人员在测试点来回走动、模拟人员挖掘、模拟挖掘机挖掘、模拟地下爆破	探测范围外人员活动、小动物在测试点活动、远距离的挖掘机作业、空中鞭炮	
1-5、2-3、3-3	模拟重点部位	分布式光纤监测装备、红外激光雷达装备、土壤扰动监测装置、安防雷达监测装备	人员侵入、人员挖掘、机械挖掘、爆破	人员在测试点来回走动、模拟人员挖掘、模拟挖掘机挖掘、模拟地下爆破	探测范围外人员活动、小动物在测试点活动、远距离的挖掘机作业、空中鞭炮	所有入侵路线的目的
2-1	围墙北侧入口	分布式光纤监测装备	人员侵入、人员挖掘、机械挖掘、爆破	人员在测试点来回走动、模拟人员挖掘、模拟挖掘机挖掘、模拟地下爆破	探测范围外人员活动、小动物在测试点活动、远距离的挖掘机作业、空中鞭炮	
2-2	围墙北侧入口和重点区域之间	分布式光纤监测装备、红外激光雷达装备、安防雷达监测装备	人员侵入、人员挖掘、机械挖掘、爆破	人员在测试点来回走动、模拟人员挖掘、模拟挖掘机挖掘、模拟地下爆破	探测范围外人员活动、小动物在测试点活动、远距离的挖掘机作业、空中鞭炮	
3-1	围墙南侧入口	分布式光纤监测装备	人员侵入、人员挖掘、机械挖掘、爆破	人员在测试点来回走动、模拟人员挖掘、模拟挖掘机挖掘、模拟地下爆破	探测范围外人员活动、小动物在测试点活动、远距离的挖掘机作业、空中鞭炮	
3-2	围墙南侧入口和重点区域之间	分布式光纤监测装备、红外激光雷达装备、安防雷达监测装备	人员侵入、人员挖掘、机械挖掘、爆破	人员在测试点来回走动、模拟人员挖掘、模拟挖掘机挖掘、模拟地下爆破	探测范围外人员活动、小动物在测试点活动、远距离的挖掘机作业、空中鞭炮	

表 3 中的 B 操作表示模拟虚假异常事件,实施细节包括:

(1)探测范围外人员活动:测试人员在指定测试点做正常走动测试,每个测试点做 5 组测试,每组测试在距离振动光纤埋设处 40 cm 位置沿光纤路线走动 30 s.

(2)小动物在测试点活动:测试人员将小动物(猫、狗)驱赶至指定测试点,做 5 组测试.

(3)远距离的挖掘机作业:测试人员在指定测试点外开挖掘机做挖掘测试,每个测试点做 5 组测试,每组测试在距离振动光纤埋设处 5 m 位置挖掘

1 min.

(4)空中鞭炮测试:测试人员在指定测试点燃放鞭炮,每个测试点做 5 组测试,每组测试在距离空气探头埋设处 2 m 范围内燃放鞭炮.

以上测试过程中,协调人员用对讲机和爆破测试人员下达指令,数据记录人员记录每组测试报警情况.

上述测试结果记录到实验测试表 4、5,其中“是”表示对应传感器触发报警,“否”表示对应传感器未触发报警,“/”表示对应传感器未覆盖该测试点.

表 4 2023 年 8 月 18 日示范地测试报警数据记录表 A

Tab. 4 August 18, 2023 demonstration site test alarm Ddata log sheet A

序号	测试点位	执行的测试操作	单项开始 时间(到秒)	单项结束 时间(到秒)	分布式光纤 监测装备	红外激光 雷达装备	土壤扰动 监测装备	安防雷达 监测装备
路径 1	测试点 1-1	人员入侵测试	9:34:30	9:35:00	是	/	/	/
	测试点 1-2	人员入侵测试	9:36:45	9:37:10	是	/	/	/
	测试点 1-2	人员挖掘(距探头 20 cm 挖 10 s)	9:38:00	9:38:25	是	/	/	/
	测试点 1-2	人员挖掘(距探头 1 m 挖 10 s)	9:39:00	9:39:20	是	/	/	/
	测试点 1-3	人员入侵测试	9:43:20	9:43:50	是	/	/	/
	测试点 1-3	人员挖掘(距探头 20 cm 挖 10 s)	9:44:50	9:45:05	是	/	/	/
	测试点 1-3	人员挖掘(距探头 1 m 挖 10 s)	9:45:30	9:45:50	是	/	/	/
	测试点 1-3	人员挖掘(距探头 2 m 挖 10 s)	9:46:10	9:46:30	是	/	/	/
	测试点 1-3	人员挖掘(距探头 3 m 挖 10 s)	9:46:50	9:47:05	是	/	/	/
	测试点 1-4	人员入侵测试	9:48:00	9:48:20	是	/	/	是
	测试点 1-4	人员挖掘(距探头 20 cm 挖 10 s)	9:48:50	9:49:05	是	/	/	是
	测试点 1-4	人员挖掘(距探头 1 m 挖 10 s)	9:49:30	9:49:50	是	/	/	是
	测试点 1-4	人员挖掘(距探头 2 m 挖 10 s)	9:50:10	9:50:30	是	/	/	是
	测试点 1-4	人员挖掘(距探头 3 m 挖 10 s)	9:50:50	9:51:10	是	/	/	是
	测试点 1-5	人员入侵测试	9:52:10	9:52:35	/	是	/	是
测试点 1-5	人员挖掘(敲击 10 s)	9:52:50	9:53:05	/	是	/	是	
路径 2	测试点 2-1	人员入侵测试	9:54:40	9:55:00	是	/	/	/
	测试点 2-1	人员挖掘(间距 20 cm, 挖 10 s)	9:55:20	9:55:45	是	/	/	/
	测试点 2-2	人员入侵测试	9:56:25	9:56:59	是	/	/	是
	测试点 2-3	人员入侵测试	9:58:15	9:58:40	/	是	是	是
测试点 2-3	人员挖掘(敲击 10 s)	9:59:00	9:59:15	/	是	是	是	
路径 3	测试点 3-1	人员入侵测试	10:01:10	10:01:40	是	/	/	/
	测试点 3-1	人员挖掘(间距 20 cm, 挖 10 s)	10:02:00	10:02:25	是	/	/	/
	测试点 3-2	人员入侵测试	10:03:50	10:04:10	/	/	/	是
	测试点 3-3	人员入侵测试	10:04:50	10:05:15	/	是	/	是
测试点 3-3	人员挖掘(敲击 10 s)	10:05:30	10:05:45	/	是	/	是	

定义数据预处理时间窗  $T = 5 \text{ min}$ , 对齐数据采样间隔为 10 s, 则时间窗内样本点个数  $N = 30$ . 示范地 3 条入侵路径如图 6 所示, 分别是途径测试点 1-1, 1-2, 1-3, 1-4, 1-5; 2-1, 2-2, 2-3; 3-1, 3-2, 3-3; 其中测试点 1-5、2-3 及 3-3 对应同一点位(即核心保护区). 不难理解, 同一行经路线上的传感器监测数据存在

特定的时空域联动规律, 即时空域相关性, 因此将该时间窗内同一路径上的所有传感器数据拼接后构成一个数据样本. 以表 4 中的人员入侵路径 2 为例, 对应预处理训练样本数据见表 6:

第一行数据: 测试点 2-1、时段 9:54:40 至 9:55:00、分布式光纤传感器报警信息;

表5 2023年8月18日示范地测试报警数据记录表B  
Tab. 5 August 18, 2023 demonstration site test alarm data log sheet B

序号	测试点位	执行的测试操作	单项开始 时间(到秒)	单项结束 时间(到秒)	分布式光纤 监测装备	红外激光 雷达装备	土壤扰动 监测装备	安防雷达 监测装备
	测试点 1-1	小动物在测试点活动	10:10:15	10:10:45	否	/	/	/
	测试点 1-1	远距离的挖掘机作业(距离 20 m 以上)	10:11:10	10:12:30	是	/	/	/
	测试点 1-1	空中鞭炮测试(距离 5 m)	10:12:30	10:12:50	否	/	/	/
	测试点 1-2	小动物在测试点活动	10:14:05	10:14:25	否	/	/	/
	测试点 1-2	远距离的挖掘机作业(距离 20 m 以上)	10:15:45	10:17:25	否	/	/	/
	测试点 1-2	空中鞭炮测试(距离 5 m)	10:18:50	10:19:30	否	/	/	/
	测试点 1-3	小动物在测试点活动	10:21:15	10:21:45	否	/	/	/
路径 1	测试点 1-3	远距离的挖掘机作业(距离 20 m 以上)	10:23:20	10:24:30	否	/	/	/
	测试点 1-3	空中鞭炮测试(距离 5 m)	10:25:35	10:25:55	否	/	/	/
	测试点 1-4	小动物在测试点活动	10:27:05	10:27:45	是	/	/	否
	测试点 1-4	远距离的挖掘机作业(距离 20 m 以上)	10:28:35	10:29:55	否	/	/	否
	测试点 1-4	空中鞭炮测试(距离 5 m)	10:30:15	10:30:45	否	/	/	否
	测试点 1-5	小动物在测试点活动	10:32:10	10:32:50	/	否	/	否
	测试点 1-5	远距离的挖掘机作业(距离 20 m 以上)	10:33:45	10:34:55	/	否	/	否
	测试点 1-5	空中鞭炮测试(距离 5 m)	10:35:25	10:35:45	/	否	/	否
	测试点 2-1	小动物在测试点活动	10:38:15	10:38:50	否	/	/	/
	测试点 2-1	远距离的挖掘机作业(距离 20 m 以上)	10:39:55	10:41:05	否	/	/	/
	测试点 2-1	空中鞭炮测试(距离 5 m)	10:41:30	10:42:05	否	/	/	/
	测试点 2-2	小动物在测试点活动	10:43:25	10:43:55	是	/	/	否
路径 2	测试点 2-2	远距离的挖掘机作业(距离 20 m 以上)	10:44:10	10:45:20	是	/	/	否
	测试点 2-2	空中鞭炮测试(距离 5 m)	10:45:50	10:46:35	否	/	/	否
	测试点 2-3	小动物在测试点活动	10:47:40	10:48:20	/	否	否	否
	测试点 2-3	远距离的挖掘机作业(距离 20 m 以上)	10:50:10	10:52:00	/	否	是	否
	测试点 2-3	空中鞭炮测试(距离 5 m)	10:52:20	10:52:55	/	否	否	否
	测试点 3-1	小动物在测试点活动	10:55:15	10:55:45	否	/	/	/
	测试点 3-1	远距离的挖掘机作业(距离 20 m 以上)	10:56:50	10:57:55	是	/	/	/
	测试点 3-1	空中鞭炮测试(距离 5 m)	10:58:10	10:58:40	否	/	/	/
	测试点 3-2	小动物在测试点活动	11:00:25	11:01:05	/	/	/	否
路径 3	测试点 3-2	远距离的挖掘机作业(距离 20 m 以上)	11:02:10	11:03:25	/	/	/	否
	测试点 3-2	空中鞭炮测试(距离 5 m)	11:04:15	11:04:45	/	/	/	否
	测试点 3-3	小动物在测试点活动	11:06:00	11:06:30	/	否	/	否
	测试点 3-3	远距离的挖掘机作业(距离 20 m 以上)	11:07:45	11:09:05	/	否	/	否
	测试点 3-3	空中鞭炮测试(距离 5 m)	11:09:30	11:09:55	/	否	/	否

第二行数据:测试点 2-2、时段 9:56:25 至 9:56:59、分布式光千传感器报警信息;

第三行数据:测试点 2-2、时段 9:56:25 至 9:56:59、安防雷达报警信息;

第四行数据:测试点 2-3、时段 9:58:15 至 9:58:40、红外激光雷达报警信息;

第五行数据:测试点 2-3、时段 9:58:15 至 9:58:40、土壤扰动检测传感器报警信息.

第六行数据:测试点 2-3、时段 9:58:15 至 9:58:40、安防雷达报警信息.

样本的训练标签定义为相应传感器在该时间窗口内的真实预警标签,当某传感器在时间窗口内出

现持续触发报警 10 秒以上的真实事件时,其异常事件标签记为“1”,否则为“0”.由于表 6 中报警事件为人为模拟的真实入侵事件,且各传感器持续报警时间均大于 10 s,则该样本真实类别标签定义为  $Y = \{y_1 = 1, y_2 = 1, y_3 = 1, y_4 = 1, y_5 = 1, y_6 = 1\}$ ,其中  $y_1, y_2, y_3, y_4, y_5, y_6$  分别表示路径 2 中六个传感器(测试点 2-1 一个、测试点 2-2 二个、测试点 2-3 三个)的报警标签.

表 7 给出了人员入侵路径 3 的三个数据样本及标签,该路径有四个传感器分别位于测试点 3-1、3-2、3-3.样本 1 为正常报警样本,  $Y_1 = \{y_1 = 1, y_2 = 1, y_3 = 1, y_4 = 1\}$ .分析观察样本 2,1 号点位(第一行数据)与 3 号点位(第三行数据)有报警信息、且两者间隔时间戳较



据,其中状态为“1”的监测数据个数定义为该复合感知数据(即数据样本)的报警次数;例如表 6 样本 1、2、3 中的异常事件触发次数分别为 21、6、45。

测试过程中,统计所有测试联动样本(100 条)的异常事件触发次数  $Q$ ,设真实异常报警次数为  $S$ ,则融合分析决策前测试集上误报率为  $\frac{Q-S}{Q}$ 。同理,统计经融合分析后联动样本(100 条)的异常事件触发次数  $Q'$ ,融合分析后测试集上误报率为  $\frac{Q'-S}{Q'}$ 。

为验证基于自注意力机制的 Inception v2-SA 模块的有效性,分别将基于 Inception v2-SA 和未加入自注意力机制的原始 Inception v2 模块构建的全局相关性网络进行对比,即围绕 Inception v2-SA 模块进行消融分析实验。将前期阶段(2023 年 7 月 3 日、7 月 13 日、7 月 19 日、7 月 28 日、8 月 4 日、8 月 11 日、8 月 18 日、8 月 25 日)所统计的数据预处理后用于模型的消融实验,模型训练与测试策略同上,实验结果如表 8 所示。

表 8 Inception v2-SA 模块消融实验结果  
Tab. 8 Inception v2-SA module ablation experiment results

样本采集日期	训练集报警数据 (条)	测试集报警数据 (条)	融合分析前误报率 (%)	融合分析后误报率 (Inception v2)(%)	融合分析后误报率 (Inception v2-SA)(%)
2023-7-3	100	100	21.39	12.13	8.93
2023-7-13	100	100	26.15	11.03	8.81
2023-7-19	100	100	11.66	10.41	6.16
2023-7-28	100	100	10.57	8.85	5.49
2023-8-4	100	100	10.49	6.73	4.85
2023-8-11	100	100	10.45	5.32	3.25
2023-8-18	100	100	10.31	3.28	2.25
2023-8-25	100	100	10.38	3.15	1.02

观察表 8 可以看出,模型在两种方式构建上均呈现收敛性,但是基于全局注意力构建的 Inception v2-SA 模块较原始 Inception v2 模块大约有 2%~4% 的性能提升,实验结果进一步验证了全局相关性网络模型的有效性。

将 13 天示范要地工作人员模拟真实入侵、挖掘以及虚假异常事件产生总异常报警数据通过随机扰动和噪声添加等处理后送入全局相关性网络模型进行训练,最终模型收敛稳定后报警定量结果如表 9 所示。

表 9 复合感知装备数据融合分析有效性  
Tab. 9 Effectiveness of data fusion analysis for composite sensing equipment

样本采集日期	训练集报警数据 (条)	测试集报警数据 (条)	误报率(融合分 析前)(%)	报警次数 (融合分析前)	误报率(融合分 析后)(%)	报警次数 (融合分析后)	误报率 降低(%)
2023-7-3	100	100	21.39	2730	8.93	2617	12.46
2023-7-13	100	100	26.15	2822	8.81	2745	17.34
2023-7-19	100	100	11.66	2539	6.16	2439	5.5
2023-7-28	100	100	10.57	2419	5.49	2379	5.08
2023-8-4	100	100	10.49	2336	4.85	2317	5.64
2023-8-11	100	100	10.45	2461	3.25	2293	7.2
2023-8-18	100	100	10.31	2314	2.25	2248	8.06
2023-8-25	100	100	10.38	2319	1.02	2265	9.36
2023-8-31	100	100	10.42	2432	1.21	2270	9.21
2023-9-15	100	100	10.32	2346	1.05	2266	9.27
2023-9-22	100	100	10.59	2306	1.11	2273	9.48
2023-10-07	100	100	10.33	2365	1.10	2260	9.23
2023-10-20	100	100	10.24	2324	1.10	2267	9.14

由实验结果可知,随着新样本的不断加入,融合分析模型得到不断优化,装备各传感器误报率逐

渐降低,于 2023 年 8 月 25 日模型迭代趋于收敛稳定(误报率 1.02%~1.21%),以 2023 年 10 月 20 日为例,

在融合分析前,测试样本集100条报警信息中,总报警次数 $Q = 2324$ ,真实异常报警次数 $S = 2086$ ,误报次数为238,误报率为10.24%。经过复合感知决策融合分析后,误报次数由原来的238次减少到25次,误报率由原来的10.24%下降为1.10%。以上结果验证了本文复合感知装备数据分析技术的有效性。

图7是2023年8月25日迭代后的模型二元交叉熵损失收敛曲线,其中纵坐标为交叉熵损失函数值,横轴为样本训练周期,模型收敛时训练集损失降低为0.05,验证集上异常事件标签识别精度为95%。

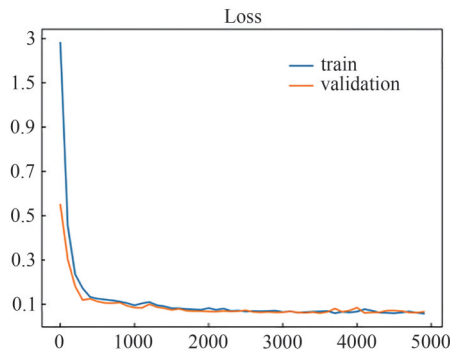


图7 相关性网络第13次训练损失曲线收敛图

Fig. 7 Convergence plot of the 13th training loss curve of the correlation network

### 3 结论

针对文物安防场景中基于单一线索感知的装备监测误报率较高的问题,从融合复合感知传感器数据的思路出发,提出了一种基于注意力机制的时空域融合决策的相关性网络,通过建模要地多传感器异常报警信息间的联动相关性,有效提升成套装备预警的精确性。在三星堆祭祀坑示范地开展基于复合感知融合分析的实验结果表明,模型经过13天更新迭代学习后的误报率显著降低,证明了本文方法的可行性和有效性。

#### 参 考 文 献

[1] 李晓羽. 中国博物馆安防技防发展进程研究[J]. 博物

馆管理, 2021(2): 78-86.

- [2] 郑涛. 博物馆安防体系建设分析与探讨[J]. 中国博物馆, 2019, 36(1): 3-7.
- [3] GB/T 16571-2012, 博物馆及文物保护单位安全防范系统要求[S].
- [4] 黄光伟. 博物馆安全防范系统纵深防护体系架构的设计研究[D]. 广州: 华南理工大学, 2019.
- [5] 张悦, 黄继忠. 红外技术在文物科学保护中的应用[J]. 自然杂志, 2021, 43(3): 217-224.
- [6] 吕娇. 多雷达指引的综合视频联动监控模型与算法[D]. 西安: 长安大学, 2021.
- [7] 邢增波, 潘礼梅. 雷达光电联动技术在不可移动文物保护中的应用[J]. 中国科技信息, 2020(9): 69-70, 14.
- [8] 陈章, 李隆, 武发思, 等. 红外相机技术在石窟寺与古建筑动物活动监测中的应用[J]. 文物保护与考古科学, 2023, 35(2): 106-115.
- [9] 杨竣淇, 王照勇, 叶青, 等. 三星堆遗址分布式光纤全天候盗掘立体监测技术[J]. 中国激光, 2020, 47(7): 421-422.
- [10] 李月, 赵连江, 王波, 等. 文物保护单位安全监测信息集成共享模式研究[J]. 科技促进发展, 2022, 18(6): 776-783.
- [11] KIM Y, DENTON C, HOANG L, et al. Structured attention networks[J]. arXiv: 2017, 1702.00887.
- [12] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions [C]//IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston: IEEE, 2015: 1-9.
- [13] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift [C]//IEEE International Conference on Machine Learning. Quebec: IEEE, 2015: 448-456.
- [14] AGARAP AF. Deep learning using rectified linear units (relu)[J]. arXiv: 2018, 1803.08375.
- [15] HARA K, KATAOKA H, SATOH Y. Learning spatio-temporal features with 3d residual networks for action recognition [C]//IEEE International Conference on Computer Vision. Venice: IEEE, 2017: 3154-3160.

(责编&校对 雷建云)