面向多维数据的异常点检测模型设计*

马勇1,杨敏2,朱琳1

(1. 内蒙古科技大学包头医学院 网络信息中心,内蒙古包头 014040;2. 内蒙古科技大学包头医学院 教务处,内蒙古包头 014040)

摘 要:为了在大数据环境下快速、精准地挖掘异常点,保障网络安全,提出了一种面向多维数据的异常点检测模型 设计方案。该方案利用长短期记忆网络 (LSTM) 存储任意时间段的多维数据,并使用图卷积网络提取完整数据结构, 同时加入惩罚参数和均方误差来缩小异常点出现范围。此外,还利用编码器和解码器构建变分自编码器函数模型,使 其能够解读正常数据子特征,并通过编码重建损失函数来计算数据异常度量,从而实现异常点检测。经过实验验证, 该方法表现出较高的检测正确率和运行效率,具有极高的应用价值。

关键词:编码损失函数;变分自编码器;异常点检测;长短期记忆网络;多维数据

中图分类号: TP995 文献标识码: A DOI: 10.19358/j.issn.2097 - 1788.2023.07.014

引用格式:马勇,杨敏,朱琳.面向多维数据的异常点检测模型设计 [J]. 网络安全与数据治理,2023,42(7):85--90.

Design of outlier detection model for multidimensional data

Ma Yong¹, Yang Min², Zhu Lin¹

(1. Network Information Center Inner Mongolia University of Science and Technology Baotou Medical College, Baotou 014040, China;

2. Dean's Office Inner Mongolia University of Science and Technology Baotou Medical College, Baotou 014040, China)

Abstract: In order to quickly and accurately mine outliers in the big data environment and ensure network security, we propose a design scheme for multidimensional data oriented outlier detection model. In this scheme, the long short memory network (LSTM) is used to store multi-dimensional data in any period of time, and the graph convolution network is used to extract the complete data structure. At the same time, penalty parameters and mean square error are added to narrow the range of outliers. In addition, we also use the encoder and decoder to build a variational self encoder function model, so that it can interpret the normal data sub features, and calculate the data anomaly measurement through the coding reconstruction loss function, so as to achieve outlier detection. After experimental verification, this method exhibits high detection accuracy and operational efficiency, and has high application value.

Key words: coding loss function; variational self encoder; abnormal point detection; long and short term memory network; multidimensional data

0 引言

针对目前异常数据检测方法占用空间内存大,且异 常点漏检率与误检率高问题^[1],建立一种面向多维数据 异常点挖掘方法是很有必要的,建立的方法必须要保证 在实际数据异常点检测过程中,既能够快速响应,又能 缩小异常检测范围、降低异常检测错误率,这是一个很 具有挑战性的问题。

*基金项目:包头医学院自然科学类青苗计划(BYJJ-ZRQM202320)

相关研究人员尝试了多种方法。其中,王燕华等 人^[2]提出基于遗忘因子和 LMBP 神经网络的混合试验在 线模型更新方法,将遗忘因子被应用在异常点检测中, 能够有效处理数据倾斜问题,但误检率和漏检率仍然较 高。王燕等人^[3]提出基于遗忘因子和 LMBP 神经网络的 混合试验在线模型更新方法,将卡尔曼滤波方法用于数 据去噪,能够提高检测效率和精度,但仅适用于单个异 常点检测,对于连续范围的异常点检测效果较差。李新 鹏等人^[4]提出了基于孤立森林算法的电力调度流数据异

2023 年第7期(第42卷总第555期) | 85

常检测方法,构建了一个包含历史数据集的子森林异常 检测器,通过滑动窗口中数据的异常情况对检测器进行 更新,并依据数据异常偏差率进一步更新,检测操作步 骤简单,但查全率较低。胡姣姣等人^[5]提出基于深度 学习的时间序列数据异常检测方法,能够对少数类数据 具有较高的检测精度,但面向多种类数据时检测效果不 佳,存在查准率不高的问题。

为解决上述方法中存在的问题,提出一种基于卷 积长短期记忆网络的多维数据异常点检测模型设计方 法。随着机器学习算法的不断发展,异常检测技术得 到快速发展。卷积神经网络^[6]作为一种深度学习算法, 在数据异常点范围划分上具有很好的效果,将卷积神 经网络作为异常点出现范围的预测器,并加入惩罚函 数^[7]和均方误差,计算数据中预测值与真实值相差的 范围,得到的范围就是异常值范围,可节省数据大规 模检测消耗的时间。通过编码器与解码器构建变分自 编码器,用于解读正常数据子特征,利用编码重建损 失函数^[8],得到的重建误差值作为异常度量参考。通 过实验验证得出,本文方法能够有效对多维数据进行 异常点定量检测,实现对单个异常点与相邻异常点的 有效挖掘。

1 多维数据异常类型

由于多维数据内数据流信息量巨大,且实际应用场 景不同,因此,将多维数据异常点分为如下类型:

(1)时间点异常:描述多维数据实际背离序列数据 轨道而出现的异常。这种异常点会短期内假性恢复到正 常状态,如图1(a)所示,这些异常点一般由统计噪声 或者发生障碍的传感器所导致。

(2)上下文异常:数据段在大多数上下文中显示正 常运转,数据流持续正常,但在个别上下文中表现分歧 点。如图1(b)所示,分析多维数据中的上下文数据实 例点,这部分数据实例点会与正常点差异巨大。

(3)集体异常:时间点异常和上下文异常一起发生的情况称为集体异常。如图】(c)所示,可以将集体异常转变为上下文异常、通过提取多维数据中上下文的特征实现。



2 异常点范围预测

卷积长短期记忆网络是一种可以进行预测数据范围 的神经网络模型,建立相对应的图卷积框架,在复杂的 拓扑结构中提取数据的特征信息。原本的卷积神经网络 可显示空间特征,在语言、图像等方面处理效果优秀, 但是对于由边和顶点建立的拓扑网络^[9],用卷积神经网 络运算无法获得准确结果。为此,本文在卷积神经网络 中加入一阶多项式^[10]作为卷积核,用于解决在拓扑结构 中原本离散卷积预测结果不准确的问题。

针对多维数据中异常点预测范围精度低的问题,利 用图卷积网络聚类静态节点,能够提取出完整的数据结 构。然后将多个长短期记忆网络层,转变为长短期记忆 网络模块^[11],存储任意时间段多维空间数据。

输入学习模型的空间数据有权图 G = (V, E),其中, E 表示边的集合,V 表示数据的集合, e_{ij} 表示边的权重, $e_{ij} \in E$ (*i*, *j*=1, 2, 3, …),通过第*t*时刻、第*t*+*l*时刻

86 | 2023 年第7期(第42 卷总第555 期)

传输的数据,预测 t+l+1 时刻的数据。学习模型以编码 器为框架,首先通过图卷积网络提取动态数据之间的高 阶点,在第一层图卷积网络中,将多项式作为卷积核的 滤波器,卷积核参数 $(h(\lambda_1))$ 转换为 $(\theta_1, \theta_2, \cdots, \theta_l)$, h 为隐藏状态, U_2 表示 λ 相应的特征向量, T 为序 列时间, $U_2^T X$ 表示特征矩阵。图卷积层定义为:

$$y = \left(\boldsymbol{U}_{2} \begin{pmatrix} \boldsymbol{\theta}_{1}, 0, \cdots, 0\\ 0, \boldsymbol{\theta}_{1}, \cdots, 0\\ 0, 0, \cdots, \boldsymbol{\theta}_{1} \end{pmatrix} \boldsymbol{U}_{2}^{\mathrm{T}} \boldsymbol{X} \right)$$
(1)

这种形式的图卷积上传储存都要求解 U_2 、 $U_2^T X$ 、 (θ_1 , θ_2 , …, θ_i)的乘积,有一定困难的复杂度。采用K阶多项式为卷积核,将(θ_1 , θ_2 , …, θ_i)转换为 $\sum_{j=0}^{k} a_j \lambda^j$, λ 表示特征数值, a 表示即将变换的参数, j 为节 点, L 为序列长度, $(a_1, a_2, ..., a_k)$ 表示为任意参数, σ (·)表示激活函数,改进后图卷积输出 y 的公式为:

$$y = \sum_{j=0}^{K} a_{j} \lambda^{j} = \sigma \left(U_{2} \begin{pmatrix} \sum_{j=0}^{K} a_{j} \lambda^{j}, 0, \cdots, 0 \\ 0, \sum_{j=0}^{K} a_{j} \lambda^{j}, \cdots, 0 \\ 0, 0, \cdots, 0 & \sum_{j=0}^{K} a_{j} \lambda^{j} \end{pmatrix} \right) U_{2}^{T} \mathbf{x}$$
(2)

在优化图卷积框架的条件下,进一步将图卷积网络 层的输入转变为:

$$y = \sigma \Big(\sum_{j=0}^{k} a_j L^j x \Big)$$
(3)

图卷积网络经过迭代后,输入长短期记忆网络层, 长短期记忆网络是在其基础上加入输出门 o、输入门 i、 遗忘门 f 以及一个内部记忆单元^[12] c_i, v 表示节点。c¹_i 表 示图卷积网络状态, č¹_i 表示选择消息, o¹_i 表示输出门发 动值, iⁱ_i 表示输入门发动值, fⁱ_i 表示遗忘门发动值, b¹ 表示偏置量数, W 表示网络参数, h¹_i 表示隐藏点,则图 卷积网络公式为:

$$c_t^1 = f_t^1 \Theta c_t^1 + i_t^1 \Theta \tilde{c}_t^1$$
(4)

 $\tilde{c}_{t}^{1} = \tanh \left(W_{c}^{1} x_{t} + U_{c}^{1} h_{t} + b_{c}^{1} \right)$ (5)

$$p_{t}^{1} = \sigma \quad (W_{o}^{1} x_{t} + U_{o}^{1} h_{t} + b_{o}^{1})$$
(6)

$$i_{t}^{1} = \sigma \quad (W_{t}^{1} x_{t} + U_{t}^{1} h_{t} + b_{t}^{1})$$
(7)

$$f_{t}^{i} = \sigma \left(W_{f}^{1} x_{t} + U_{f}^{1} h_{t} + b_{f}^{1} \right)$$
(8)

 $h_t^1 = o_t^1 \Theta \tanh \tilde{c}_t^1$

数据信息是通过时间 t 与时间 t + l 连接的网络图

积,节点*V*在第*k*层第*t*时间中的网络图卷积^[13]公式为

$$h_t^k = o_t^k \Theta \tanh \tilde{c}_t^k$$
 (10)
 $o_t^k = \sigma (W_a^1 x_t + U_a^1 h_t + b_a^k)$
 (11)

以上模型为图卷积和长短记忆的网络层输出,在其模型上建立损失函数,加入惩罚参数,与均方误差概念, 最后得到预测结果。*G_{i+1+1}表示预测数据*,*G_{i+1+1}表示实际数据,确定异常点范围预测函数*:

$$M = L_{t+l} + \| (G_{t+l+1} - G_{t+l+1}) \quad \Theta y' \|^2$$
(12)

由于在上述异常点预测范围内的多维数据存在较多 干扰因素,如高频噪声等,因此,本文选用基于线性时 不变系统的滤波器多维数据预测范围中的数据进行去噪 处理。对于一个异常点预测范围 M 进行去噪处理得到去 噪后的异常点预测范围 x(t),其可以表示为:

 $x(t) = [x_1(t), x_2(t), \dots, x_M(t)]^T$ (13) 其中, t 表示时间, $x_1(t)$ 表示第1 维数据在时间 t 的取 值。去噪后的异常点预测范围 x(t), 经过卷积运算后得 到的输出 y(t) 可以表示为:

基于上述步骤,可以得到去噪后的异常点预测范围, 可以有效提高下文异常点检测的精准度。

3 异常点检测模型构建

3.1 构建变分自编码器函数

定义多维度空间数据 $\zeta = (V, \varepsilon, X)$,其中,V= $\{v_1, v_2, \dots, v_n\}$ 代表所有多维数据的集合,n代表数据 个数,|V| = n. ε 代表多维数据中点连接边的集合, $|\varepsilon| = m$. X表示数据 $n \times d$ 节点属性集合,X表示数据属 性。第*i*个数据节点属性为 $X_i \in \mathbb{R}^d$, $i = 1, 2, \dots, n$,连 接矩阵 $A \in \mathbb{R}^{d \times d}$ 表示多维数据与节点的连接,节点 $i \to j$ 有连接关系 $A_{i,j} = 1$;反之 $A_{i,j} = 0$,将有线连接转为无线连 接,连接矩阵 $A = \max(A, A^T)$ 。

变分图自编码器首先通过图卷集网络得到一个多维 高斯分布^[14],通过提取数据均值向量和协方差矩阵^[15], 得到隐藏层:

$$\begin{cases} \mu = GCN_{\mu} \quad (X, A) \\ \log_2 \sigma = GCN_{\sigma} \quad (X, A) \end{cases}$$
(15)

编码器首先读取多维数据中邻接矩阵 $A \in R^{n \times k}$ 与属性 矩阵 $X \in R^{n \times n}$ 把数据上传到编码器网络 $G_{E,E}$ 中,通过线 性函数激活,提取 G_E 的特征信息,将原本数据存为隐藏 层内,用 $z \in R^d$ 表示,d 表示数据特征最小维度。

解码器对多维数据结构和数据属性进行重新组建, X使用卷积网络两层进行处理, A使用一层卷积层进行解码。解码器 G_p 重新组建,得到了 $A \in R^{n \times k}$ 与 $X \in R^{n \times n}$ 和原本数据维度相同。过程通过式(14)描述:

$$\begin{cases} (\tilde{A}, \tilde{X}) = G_{\rm D} (z), \\ z = G_{\rm E}(A, X) \end{cases}$$
(16)

在编码器 F 中, 对 \hat{A} , \hat{X} 进行转换, 多维数据结构与 $G_{\rm E}$ 一样, 然后编码器 F 将 \hat{A} , \hat{X} 转换和 z 一样的数值, 得到数值 \hat{z} , 通过参数化学习描述数据的最小隐藏向量。

3.2 多维数据异常点关联检测

设定缩小范围后的数据 G, $G_{\rm E}$ 使数据结构信息与数 据属性信息隐藏在 z 里,通过变分自编码器得到 \hat{A} , \hat{X} , 因没有直接没有显示异常数据,证明 z 与 z 存在误差值。 一直输出的 \hat{A} , \hat{X} 值只含有正常运行数据,需要得到 A, X 与 \hat{A} , \hat{X} 接近的偏差值; z 与 z 接近的偏差值。所以建 立编码重建损失函数,这种方法可以正常解读数据的正 常子特征,重建损失函数。使用正则化范式^[16] 计算, α 代表误差加权值,重建数据与原本数据的误差公式为:

$$L_{\rm rec} = a \| X - \tilde{X} \|_{1} + (1 - \alpha) \| A - \tilde{A} \|_{1}$$
(17)

使用编码器 $G_{\rm E}$ 得到变量值 z, $G_{\rm E}$ (A, X) 代表使用 编码器得到隐藏层变量^[17], E (\tilde{A} , \tilde{X}) 代表第二部分编

2023 年第7期(第42卷总第555期) | 87

码器得到隐藏层变量,隐藏层表示为:

$$L_{\rm res} = \left\| G_{\rm F} \left(\boldsymbol{A}, \boldsymbol{X} \right) - F \left(\tilde{\boldsymbol{A}}, \tilde{\boldsymbol{X}} \right) \right\|$$
(18)

β代表两部分数据的相对权重,通过编码损失函数加 权得到:

$$R = \beta R_{\rm rec} + (1 - \beta) R_{\rm rec}$$
(19)

通过变分自编码器使异常点检测的目标函数不断减 小,使用得到的隐藏层对数据进行重建,使用重建误差 衡量数据中是否存在异常, *X*_i代表重建数据的属性向量, *a*_i代表数据*i*的连接向量, *a*_i代表重建数据的连接向量, 多维数据中异常点检测公式如下:

 $V = a \left(\boldsymbol{X}_{i} - \tilde{\boldsymbol{X}}_{i} \right) + (1 - a) \left(\boldsymbol{a}_{i} - \tilde{\boldsymbol{a}}_{i} \right)$ (20)

数据的重建误差越大,说明其为异常点的概率越高, 按照重建误差进行排序,最后得到数据中的异常点集合, 实现异常点检测。

4 实验检测与分析

为了验证本文提出的异常点检测模型有效性,选取 水位传感器网络中水位数据作为实验数据集。水位传感 器可以检测天气雨量、涨潮水位,根据这些多维信息, 提前探查环境异常,并发出告警信息,其中包含时间、 空间等多维度信息,但这些信息中会存在一部分异常点, 干扰检测人员正常决策。为此将方法应用在其中可以有 效证明方法的效果和适用能力。

4.1 多维度检测精度分析

水位传感器网络中包含 120 个传感器,从中选取 1 500个水位数据,在其数据区域内,选取 25 不相连接的 数据作为异常点,再选取相连接数据 15 条数据作为相连 异常点。本文方法在多维度空间下进行实验,从空间维 度、起源维度、时间维度分别检测异常点,检测结果如 表 1 所示。能够看出本文模型可检测出所有相邻和单独 的异常点,并且无论是单独维度还是多维度结合,都没 有对检测结果造成任何影响,这能够证明本文方法可以 应对存在大量多维度数据的网络环境,及时发现异常并 检测出来。

表	1	太	文	模	刑	检	测	结	果
~	1	4	\sim	.1大	土	19	0.1	20	\sim

维度向量	数据总量	不相连接异常点数	连续异常点
时间维度	500	10	5
空间维度	500	5	5
起源维度	500	10	5
多维结合	1 500	25	15

为验证本文方法的普适性,在120个传感器重新选取5万条数据,分别用本文、文献[4]与文献[5]方

88 | 2023 年第7期(第42 卷总第555期)

法对以上数据值进行异常点错误率检测,检测错误率如 图 2 所示。



由图2可得,文献[4]方法的独立异常点误检率 高;文献[5]方法对连续异常点的误检率高;本文的误 检率和漏检率都低,这主要是因为本文方法使用了卷积 长短期记忆网络,降低了计算复杂度,能够在少计算量 的基础之上,准确获得被检测目标,证明了本文方法在 异常点检测方面的有效性。

4.2 异常点范围预测效果分析

为了证明本文异常点范围预测的准确性,同时为降 低分析复杂度,经归一化处理后,原始数据和记忆网络 处理数据如图3所示。



图 3 原始预测误差与本文方法处理结果对比

由图 3 可得,原始数据中上下文浮动的异常举动会 降低异常点检测效率和检测正确率,使用卷积长短期记 忆网络处理后的数据,在不改变原本的轨迹的基础上, 稳定了波动,还去除了部分噪声和冗余信息,并且能够 明显看出归一化数值的异常位置在时间戳 370~415 间, 能够准确划分出异常点发生范围,提高检测效率和 精度。

4.3 异常点检测效率对比

对比各个方法的检测运行时间,用于验证模型复杂度,结果如图4所示。



由图 4 可知文献 [4] 方法异常点检测的运行时间较 长,3GB 的数据量检测需要 2.7 min,12 GB 检测需要 5.6 min,显示指数递增关系;文献 [5] 方法异常点检 测的运行时间虽然没有文献 [4] 方法的运行时间长,但 是也是呈现指数递增关系;本文方法的异常检测 3GB 仅 用了 1 min,12 GB 仅用了 1.7 min,本文方法不仅异常点 检测准确率高,而且异常点检测运行时间短,缩短了检 测时消耗时间。

4.4 查准率与查全率对比

为了进一步验证本文方法的检测效果,以查准率与 查全率为实验指标,将其与文献[4]方法和文献[5] 方法进行对比,对比结果如表 2 和表 3 所示

多维数据量/GB	本文方法	文献 [4] 方法	文献 [5] 方法	
3	97.63	95.42	96.37	
6	97.05	94.66	94.28	
9	96.52	93.71	93.17	
12	96.14	93.08	92.12	
15	95.46	92.57	90.35	
18	95.37	92.43	89.63	
21	93.07	91.05	87.15	

表2 查准率对比结果 (%)◆

表3 查全率对比结果(%)

多维数据量/GB	本文方法	文献 [4] 方法	文献 [5] 方法
3	95.61	93.64	91.58
6	95.37	91.27	90.28
9	94.52	89.65	89.66
12	94.18	88.63	87.12
15	93.64	87.24	86.34
18	92.58	86.37	85.26
21	92.17	85.19	83.64

由表 2 和表 3 中的数据可知,随着多维数据量的增加,三种方法的查准率与查全率均呈现出逐渐下降的趋势,说明数据量的加大给异常数据检测带来了一定的影响。通过对比可知,本文方法的查准率最高值为 97.63% 和 95.61%,高于文献 [4]方法和文献 [5]方法,且不同数据量下,本文方法均保持着一定的优势,说明本文方法的异常数据检测效果更好,不仅能够实现对异常数据的准确检测,而且检测结果更加全面。

5 结论

为了在多维数据下建立最优异常点检测模型,本文 在水位数据异常点检测实验中,通过卷积长短期记忆网 络模型,有效缩减异常点范围预测,以解码器与编码器 构建变分自编码器函数模型,可以有效检测数据中的异 常点,且漏检率与误检率极低、运行时间短,具有极佳 的适用性,可以有效提高多维数据网络的安全性,避免 信息错误和异常对用户造成影响。

参考文献

- [1] 孟恒宇, 李元祥. 基于 Transformer 重建的时序数据异常检测与关系提取 [J]. 计算机工程, 2021, 47 (2): 69 76.
- [2] 王無华, 昌静, 吴京. 基于遗忘因子和 LMBP 神经网络的 混合试验在线模型更新方法 [J]. 振动与冲击, 2020, 39
 (9): 42-48, 56.
- 自伟华,张传斌,张塽旖,等.基于异常值识别卡尔曼滤波器的短期交通流预测 [J]. 计算机应用研究, 2021, 38 (3): 817-821.
- [4] 李新鹏,高欣,阎博,等.基于孤立森林算法的电力调度
 流数据异常检测方法 [J].电网技术,2019,43 (4):
 1447-1456.
- [5] 胡姣姣, 王晓峰, 张萌, 等. 基于深度学习的时间序列数 据异常检测方法 [J]. 信息与控制, 2019, 48 (1): 1-8.
- [6] 邱宁佳,王晓霞,王鹏,等.结合迁移学习模型的卷积神
 经网络算法研究 [J].计算机工程与应用,2020,56 (5):
 43-48.
- [7] 俞立平,王龙华.一种基于惩罚函数的降低影响因子操纵 方法:合理影响因子 [J].情报理论与实践,2022,45
 (6):67-73.
- [8] 陈志刚,杜小磊,王衍学,等.改进集成深层自编码器在 轴承故障诊断中的应用 [J].控制与决策,2021,36 (1): 135-142.
- [9] 富坤,高金辉,赵晓梦,等.融合全局结构信息的拓扑优化图卷积网络 [J]. 计算机应用,2022,42 (2):357-364.
- [10] 张艺雪.关于伯努利多项式和 Dirichlet L 函数的均值问题
 题[J].浙江大学学报(理学版), 2020, 47 (4): 435 441.

- [11]杨智伟,刘灏,毕天妹,等.基于长短期记忆网络的PMU不良数据检测方法[J].电力系统保护与控制,2020,48(7):1-9.
- [12] 陈兴蜀,金逸灵,王玉龙,等.基于长短期记忆神经网络的容器内进程异常行为检测 [J].电子学报,2021,49 (1):149-156.
- [13] 杨瑞朋, 屈丹, 朱少卫, 等. 基于改进时间卷积网络的日志序列异常检测 [J]. 计算机工程, 2020, 46 (8): 50-57.
- [14]周荣艳,陈建峰,李晓强,等.基于目标高斯分布的定位 系统节点最优部署方法 [J].系统工程与电子技术, 2021,43 (7):1791-17967.
- [15] 杨鑫, 郭英. 基于空时频协方差矩阵重构的高效跳频信号 DOA 估计 [J]. 信号处理, 2020, 36 (2): 250-256.
- (上接第72页)
- [8] MIURA M, OKAICHI N, ARAI J, et al. Integral three-dimensional capture system with enhanced viewing angle by using camera array [J].
 Proceedings of SPIE-The International Society for Optical Engineering, 2015 (9391); 939106.1 - 939106.7.
- [9] XING Y, XIONG Z L, ZHAO M, et al. Real-time integral imaging pickup system using camera array [C]//Advances in Display Technologies VIII. International Society for Optics and Photonics, 2018 (10556): 105560D.
- [10] JANG J S, JAVIDI B. Three-dimensional synthetic aperture integral imaging [J]. Optics Letters, 2002, 27 (13): 1144-1146.
- [11] 杨墨轩,赵源萌,朱凤霞,等.基于多视角合成孔径的太赫 兹光场成像去遮挡算法研究 [J].光学学报,2023,42 (9): 96-103.
- [12] PIAO Yongri, ZHANG Miao, KIM E.S. Effective reconstruction of a partially occluded 3-D target by using a pixel restoration scheme in computational integral-imaging [N]. Optics and Lasevs in Engineering, 2012, 50 (11): 1602 - 1610.
- [13] 黄慧华. 基于集成成像技术的局部遮挡物体识别研究 [D]. 广州: 华南理工大学, 2020.
- [14] ZHANG M, PIAO Y, WEI C, et al. Occlusion removal based on

- [16] 宋鹏,刘程程,胡永宏.稳健高维协方差矩阵估计及其投资组合应用——基于中心正则化算法 [J].统计研究, 2020,37 (7):116-128.
- [17] 张聪,朱永生,杨敏燕,等.采用多变量耦合网络与变分 图自编码器的机械设备异常检测方法 [J].西安交通大学 学报,2021,55 (4):20-28.

(收稿日期: 2023-04-23)

作者简介:

马勇 (1986 -), 男, 硕士, 讲师, 主要研究方向: 信息 化、计算机应用。

杨敏(1984-),通信作者,女,硕士,副教授,主要研究 方向:计算机应用技术、图像处理。E-mail: 281929119@ qq.com。

epipolar plane images in integral imaging system [J]. Optics & Laser Technology, 2019 (120): 105680.

 [15] 陈先锋, 郭正华, 伍俊龙, 等. 基于区域先验信息的去遮挡 立体匹配算法 [J]. 激光与光电子学进展, 2019, 56 (19): 95-101.

16] 九素萍, 卢昱丞, 张薇, 等. 基于光场成像数字重聚焦过程
 的性能分析 [J]. 系统仿真学报, 2017, 29 (11): 2875 - 2880, 2889.

- 17] 毛菁菁, 吴智慧, 冯鑫浩. 数码 3D 打印木纹图像清晰度的调整
 与评价 [J]. 林业工程学报, 2020, 5 (5): 164-171.
- [18] HONG S, JANG J, JAVID B. Three-dimensional volumetric object reconstruction using computational integral imaging [J]. Optical Express, 2004 (12): 483-491.

(收稿日期: 2023-03-31)

作者简介:

邢毓华(1966-),男,硕士,副教授,主要研究方向:通 信电子技术、物联网大数据处理。

杨广福 (1995-),男,硕士研究生,主要研究方向:图像 处理。