

基于改进全卷积神经网络的医疗数据表面重建算法^①



李晓峰¹, 李 东²

¹(黑龙江外国语学院 信息工程系, 哈尔滨 150025)

²(哈尔滨工业大学 计算机科学与技术学院, 哈尔滨 150001)

摘 要: 为了实现对医疗数据的快速检测和分类识别, 需要对医疗数据进行表面重建设计, 首先, 提出一种基于改进全卷积神经网络的医疗数据表面重建算法. 采用无线射频识别技术进行医疗数据的大数据采样, 对 RFID 采集的医疗数据进行信息融合处理, 采用多元回归分析方法提取医疗数据的相关性统计特征量, 然后, 针对医疗数据中的冗余特征采用匹配滤波检测器进行冗余滤波处理, 对提纯后的医疗数据采用相空间重构技术实现医疗数据重构, 最后, 对重构数据采用改进全卷积神经网络分类器进行分类识别, 实现医疗数据的表面重建和自动识别. 仿真结果表明, 所提方法的医疗数据冗余特征处理效果较好, 数据分类精度可高达 90% 以上, 且医疗数据重建误差小, 耗时少.

关键词: 全卷积神经网络; 医疗数据; 表面重建; 相空间重构

引用格式: 李晓峰, 李东. 基于改进全卷积神经网络的医疗数据表面重建算法. 计算机系统应用, 2019, 28(10): 157-163. <http://www.c-s-a.org.cn/1003-3254/7095.html>

Surface Reconstruction Algorithm of Medical Data Based on Improved Total Convolution Neural Network

LI Xiao-Feng¹, LI Dong²

¹(Department of Information Engineering, Heilongjiang International University, Harbin 150025, China)

²(School of Computer Science and Technology, Harbin Institute of Technology, Harbin 150001, China)

Abstract: In order to realize the rapid detection and classification of medical data, the surface reconstruction design of medical data needs to be carried out. A surface reconstruction algorithm of medical data based on improved total convolution neural network is proposed. The big data sampling of medical data was carried out by using radio frequency identification technology, the medical data collected by RFID was processed by information fusion, and the correlation statistical characteristics of medical data were extracted by multiple regression analysis. According to the characteristics of medical data, matching filter detector is used for redundant filtering, and phase space reconstruction technology is used to reconstruct medical data after purification. In order to realize the surface reconstruction and automatic recognition of medical data, an improved total convolution neural network classifier is used to classify and recognize the reconstructed data. The simulation results show that the proposed method has a good effect on the redundant feature processing of medical data. The accuracy of data classification is more than 90%, and the error of medical data reconstruction is smaller and the time consuming is less.

Key words: total convolution neural network; medical data; surface reconstruction; phase space reconstruction

① 基金项目: 黑龙江省自然科学基金面上项目 (F2016038); 中国管理科学研究院 (CMAS180305)

Foundation item: General Project of Natural Science Foundation of Heilongjiang Province (F2016038); China Academy of Management Sciences (CMAS180305)

收稿时间: 2019-03-17; 修改时间: 2019-04-17; 采用时间: 2019-04-19; csa 在线出版时间: 2019-10-15

引言

随着大数据信息处理技术的发展,相关领域逐渐采用大数据信息处理和数据挖掘方法,进行医疗信息管理系统设计,以此来提高医疗信息管理的智能性和自动化水平^[1,2].在进行医疗数据的信息化管理中,需要对医疗数据进行优化检索和识别,提取大数据信息库中的医疗数据特征量,采用统计特征分析和数据聚类挖掘技术,进行医疗数据的大数据挖掘和聚类处理,提高医疗数据的模糊聚类和特征分析能力^[3].

目前,已经有相关研究人员对医疗数据的重建方法进行了研究.文献[4]提出了一种针对多类医疗数据的挖掘算法,在统计方法的基础上对医疗数据的安全模式和诱因模式进行准确定义,同时,采用分类器对医疗数据进行重建,根据实验结果可知,该算法可有效对数据进行挖掘,但是没有考虑到数据冗余度问题,不能实现快速识别.文献[5]提出了一种基于LLE和MP的空间数据重建方法,首先对空间数据重建中的不确定性进行定量分析,根据分析结果采用多点信息统计方法将非线性数据进行降维,最后采用LLE和MP方法对空间数据进行重建,根据实验结果可知,该方法可以实现对空间数据的重建,但是由于该方法没有考虑到对不同数据类型进行分类,因此存在重建速率较低的问题.

根据上述分析可以得出,研究医疗数据的优化检索应该建立在对医疗数据的表面重建基础上,通过对医疗数据进行自适应的特征重构,提取医疗数据的统计特征值,结合模糊网格聚类技术,实现医疗数据采样和特征提取,挖掘医疗数据的谱特征量,根据特征挖掘结果进行数据聚类 and 表面重建.为解决传统方法存在的缺陷,本文提出一种基于改进全卷积神经网络的医疗数据表面重建算法,首先进行医疗数据特征分析和融合处理,然后进行数据统计特征量提取,采用改进全卷积神经网络分类器对重构数据进行分类识别和重建,最后进行仿真实验分析,展示了本文方法在提高医疗数据表面重建能力方面的优越性能.

1 医疗数据的大数据采样和信息融合

1.1 基于无线射频识别的医疗数据采样

为了实现对医疗数据表面重建,需要首先构建医疗数据的大数据采样模型,结合RFID技术,挖掘医疗数据谱的关联规则项,数据采样系统结构模型如图1所示.




图1 数据采样系统结构模型

根据图1所示的医疗数据采样系统结构,采用无线RFID和ZigBee组网技术^[6,7],进行医疗数据采样的网络节点分布式设计,采用多维传感跟踪拾贝方法进行医疗数据采样后的信息融合和大数据特征分析,提取医疗数据的谱特征量,采用向量量化编码方法进行医疗数据结构重组,得到医疗数据的信息特征量为:

$$P_i(t) = \sum_{n=1}^N \frac{A}{r} e^{-jkr} R_{in} \frac{1}{r} e^{-ikr} \quad (1)$$

采用RFID信息融合技术,构建医疗数据分布的标量时间序列为 $x(t), t = 0, 1, \dots, n-1$,给定医疗数据信息流的二维统计特征分布模型为 $x_1, x_2, \dots, x_n \in C^m$ (m 维复数空间),在医疗数据的大数据分布模型中,采用模糊聚类方法,得到医疗数据关联规则分布集的簇模型描述为:

$$\Sigma = \text{diag} \{ \max \{ |\rho_1^+|, |\rho_1^-| \}, \dots, \max \{ |\rho_n^+|, |\rho_n^-| \} \} \\ = \text{diag} \{ \rho_1, \dots, \rho_n \} \quad (2)$$

$$\Sigma_1 = \text{diag} \{ \rho_1^+ \rho_1^-, \dots, \rho_n^+ \rho_n^- \} \quad (3)$$

其中, ρ_1, \dots, ρ_n 为一组医疗数据的主成分特征,结合多元回归分析方法,构建医疗数据的关联规则集为 $O(d)$ 和 $O(N^{1/d})$,根据模糊的回归分析结果,在 $m \rightarrow 1$ 时, $sn\xi \rightarrow \tanh\xi$,提取医疗数据统计特征值,在邻域空间 (t, f) 内,得到医疗数据采样输出的统计指数集为:

$$f(x) = \begin{cases} f(x), & x \in \text{Levf} \\ a, & x \in \text{Levf} \end{cases} \quad (4)$$

根据上述对医疗数据的采集结果,对医疗数据进行信息融合处理.

1.2 医疗大数据的信息融合处理

根据医疗数据的主成分特征,获取医疗数据的特征值,进行信息融合,在融合惯性空间分布矩阵 $G = [E_{k \times k} | A]$ 中,参数初始值设置为 (x_1, x_2, \dots, x_n) ,采集的医疗数据包括 n 个变量,可以用 $\{y_1, y_2, \dots, y_n\}$ 表示,调整医疗数据的关联规则项,构建医疗数据的模糊信息融合模型:

$$\begin{cases} a(H_{ac}) = 1 - \frac{H_{ac}}{\max(H_{ac}) + l} \\ \max(H_{ac}) = \log_2 k \end{cases} \quad (5)$$

在强干扰下医疗数据频域检测的边值收敛条件满足如下边界函数为:

$$w_{ji}(k+1) = w_{ji}(k) - \alpha \frac{\partial F}{\partial w_{ji}} \quad (6)$$

$$z_{kj}(k+1) = z_{kj}(k) - \alpha \frac{\partial F}{\partial z_{kj}} \quad (7)$$

在医疗数据分布的最小共享资源分配区域内,采用优先级调度方法进行医疗数据的特征融合,融合方程描述为:

$$\dot{x}(t) = Ax(t) + Bx(t - d_1(t) - d_2(t)) \quad (8)$$

其中, $x(t) = \phi(t), t \in [-h, 0]$, 医疗数据挖掘采用整体的规划方法, 得到输出的训练特征集为:

$$x(t) = (x_0(t), x_1(t), \dots, x_{k-1}(t))^T \quad (9)$$

对于 $x(t)$, 采用密集型模糊迭代方法, 进行医疗数据的融合处理, 采用卷积神经网络学习算法进行医疗数据动态迁移均衡调度^[8,9], 卷积神经网络学习函数为:

$$\begin{cases} \min \sum_{1 \leq i \leq K} \sum_{e \subseteq k(e)} \frac{f(e(i))}{C(e, i)} \\ 0 \leq f(e, i) \leq C(e, i) \\ F = \text{const} \\ \sum_{1 \leq i \leq K, e \subseteq k(e)} \frac{f(e(i))}{C(e, i)} + \sum_{e \subseteq k(e)} \frac{f(e'(i))}{C(e', i)} \leq k(v) \end{cases} \quad (10)$$

根据式 (10), 结合随机负载均衡分配方法, 进行医疗数据动态迁移负载均衡控制^[10,11], 得到负载量为:

$$\begin{aligned} \text{Computation}(n_j) &= (E_{elec} + E_{DF})l\delta + E_{Tx}(l, d_j) \\ &= (E_{elec} + E_{DF})l\delta + lE_{elec} + l\varepsilon_{fs}d_j^2 \\ &= [(E_{elec} + E_{DF})\delta + E_{elec} + \varepsilon_{fs}d_j^2]l \end{aligned} \quad (11)$$

医疗大数据存储介质 OD 对 w 间路径 k 上传递衰减为 ω , 初始化轮询任务, 在模糊约束控制下, 医疗数据的融合负载均衡调度模型可以描述为:

$$\eta_k^w(\omega) = E(T_k^w | T_k^w > \xi_k^w(\omega)), k \in R_w, w \in W \quad (12)$$

其中, 多队列调度任务误差 $\xi_k^w(\omega)$ 可以表示为:

$$\begin{aligned} \xi_k^w(\omega) &= \min \left\{ \xi \mid \Pr(T_k^w \leq \xi) \geq \omega \right\} \\ &= E(T_k^w) + \gamma_k^w(\omega) k \in R_w, w \in W \end{aligned} \quad (13)$$

提取医疗数据的统计特征量, 采用相关性融合检测

方法, 得到信息融合输出为 $E(T_k^w - \xi_k^w(\omega) | T_k^w \geq \xi_k^w(\omega))$, 各个医疗数据融合作业队列中的开销 s_h^w 可以表示为:

$$\begin{aligned} s_h^w &= E \left[\min_{k \in R_w} \{H_{h,k}^w\} | \eta^w \right] \\ &= -\frac{1}{\theta} \ln \sum_{k \in R_w} \exp(-\theta \eta_{h,k}^w(\omega)) w \in W, h \in H \end{aligned} \quad (14)$$

根据上述分析, 结合自适应的反馈调节方法进行医疗数据表面特征的重建, 采用多元回归分析方法提取医疗数据的相关性统计特征量, 对提取的特征量进行贯序采样和信息融合, 以此来提高数据挖掘和重建的准确性.

2 医疗数据表面重建优化

2.1 特征提取与冗余特征处理

在上述采用无线射频识别技术进行医疗数据的大数据采样和信息融合处理的基础上, 进行医疗数据表面重建算法的优化设计, 本文提出一种基于改进全卷积神经网络的医疗数据表面重建算法. 构建贯序自适应预测方法进行医疗数据的统计特征预测, 得到统计特征量的预测的迭代式为:

$$\xi_k^w(\omega) = t_k^w + \Phi^{-1}(\omega) \sigma_{k,t}^w, k \in R_w, w \in W \quad (15)$$

设置医疗数据特征构成的数据集 X , 采用多元回归分析方法提取医疗数据的相关性统计特征量, 回归分析模型用下式表述:

$$\eta_k^w(\omega) = t_k^w + \sigma_{k,t}^w / \sqrt{2\pi} (1 - \omega) \exp\left(-(\Phi^{-1}(\omega))^2 / 2\right) \quad (16)$$

在医疗数据的表面分布结构模型中, 采用稀疏点表达方法进行医疗数据的相似度特征分析, 得到医疗数据表面重建的调度集子序列为:

$$r_1(n) = r_2(n) \exp(-j\omega_0 T_p / 2), n = 0, 1, \dots, (N-3)/2 \quad (17)$$

$$r_2(n) = A \exp[j(\omega_0 n T + \theta)], n = 0, 1, \dots, (N-3)/2 \quad (18)$$

分别对 $r_1(n)$ 和 $r_2(n)$ 进行 $(N-1)/2$ 点傅里叶变换, 结合医疗数据的特征编码方法进行信息采样, 采用分组检测方法, 进行医疗数据的分集调度^[12], 得到医疗数据重建的迁移状态量:

$$R_1(k) = R_2(k) \exp(-j\omega_0 T_p / 2), k = 0, 1, \dots, (N-3)/2 \quad (19)$$

$$R_2(k) = A_k \exp(j\varphi_k), k = 0, 1, \dots, (N-3)/2 \quad (20)$$

其中, ω_0 为医疗数据的贯序自适应预测误差, T_p 为时间窗口函数, A_k 为医疗数据的特征分布幅值, φ_k 为扩展相

位. 针对医疗数据中的冗余特征采用匹配滤波检测器进行冗余滤波处理, 设置医疗数据的均值为 t_a , 方差为 ε_t^a , 医疗数据动态迁移最优的接收码元序列表示为:

$$t_a = E(T_a) = t_a^0 + \beta t_a^0 E((V_a)^n) E(1/(C_a)^n), a \in A \quad (21)$$

$$E((T_a)^2) = (t_a^0)^2 + 2\beta(t_a^0)^2 E((V_a)^n) E(1/(C_a)^n) + (\beta t_a^0)^2 E((V_a)^{2n}) E(1/(C_a)^{2n}), a \in A \quad (22)$$

$$\varepsilon_t^a = Var(T_a) = E((T_a)^2) - (E(T_a))^2, a \in A \quad (23)$$

构建贯序自适应预测器实现医疗数据的冗余特征预测, 在医疗数据的空间分布模型中, 对医疗数据进行自适应均衡控制^[13], 得到医疗数据分布的相位特性负载量为:

$$C_{T'}(f) Y_{T'}(f) = C_{T'}(f) \sum_n x(f - \frac{n}{T'}) e^{j2\pi(f - \frac{n}{T'})\tau_0} = C_{T'}(f) X(f) e^{j2\pi f \tau_0} \quad (24)$$

在医疗数据的信息管理系统中, 数据的空间负载分配为 Q^w 、 V_a 、 f_k^w , 采用匹配滤波检测器进行冗余滤波处理, 得到匹配滤波检测器模型为:

$$q^w = E(Q^w) = \sum_{k \in R_w} f_k^w, w \in W \quad (25)$$

$$v_a = E(V_a) = \sum_{w \in W} \sum_{k \in R_w} \delta_{ak}^w f_k^w, a \in A \quad (26)$$

$$f_k^w \geq 0, k \in R_w, w \in W \quad (27)$$

计算医疗数据检测的测度特征量为:

$$\|r\| = \sqrt{\sum_{i=0}^m r_i^2 \|v_{\sigma(i)}^*\|^2 + \|w\|^2} \geq \|r_m\| \|v_{\sigma(m)}^*\| \quad (28)$$

根据特征提取结果, 进行医疗数据的表面信息重构, 得到特征分布式提取的迭代方程为:

$$f_{ij}(n+1) = f_{ij}(n) + \mu_{MCMA} \frac{\partial J_{MCMA}(n)}{\partial f_{ij}(n)} \quad (29)$$

其中, μ_{MCMA} 代表初始数据采样频率, 根据上述算法和模型设计, 实现医疗数据的动态迁移控制和特征提取, 对提取的特征量进行提纯处理后进行卷积神经网络识别, 实现数据的表面重建.

2.2 医疗数据分类及表面重建

根据医疗数据特征构成的数据分布集, 求解医疗数据的稀疏表矩阵 W 的最优解^[14,15], 即:

$$W_{opt} = \arg \min_W \lambda \|X - DW\|_F^2 \text{ s.t. } \|w_i\|_0 \leq k \quad \forall i \quad (30)$$

对提纯后的医疗数据采用相空间重构技术实现医疗数据重构, 相空间重构轨迹为:

$$\begin{cases} \min_{\alpha} \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l y_i y_j \alpha_i \alpha_j K(x_i, x_j) - \sum_{j=1}^l \alpha_j \\ \text{s.t.} \begin{cases} \sum_{j=1}^l y_j \alpha_j = 0 \\ 0 \leq \alpha_j \leq u(x_j) C, \\ j = 1, 2, \dots, l \end{cases} \end{cases} \quad (31)$$

在重构的医疗数据分布相空间中, 采用主成分尺度分解方法, 得到医疗数据的关联规则集为:

$$D_{opt} = \lambda X V^{-1} W^T (W V^{-1} W^T)^{-1} \quad (32)$$

考虑不同数据的类间分类性^[16], 采用改进的全卷积神经网络进行数据分类, 得到改进全卷积神经网络模型如图2所示.




图2 改进全卷积神经网络模型

在图2所示的神经网络模型中, 医疗数据的谱特征分类输出为:

$$B_{(i+1)} = \lambda_i B_{(i)} + \beta_{i+1}^{-1} x_{i+1} w_{i+1}^T \quad (33)$$

$$C_{(i+1)}^{-1} = \lambda_i C_{(i)}^{-1} + \beta_{i+1}^{-1} w_{i+1} w_{i+1}^T \quad (34)$$

在神经网络的隐含层, 引入自适应加权学习因子, 得到医疗数据表面重建的隶属度迭代更新公式为:

$$C_{(i+1)} = \lambda_i^{-1} C_{(i)} - \beta_{i+1}^{-1} \alpha u u^T \quad (35)$$

$$D_{(i+1)} = D_{(i)} + \beta_{i+1}^{-1} \alpha z_{i+1} u^T \quad (36)$$

其中, 卷积神经网络学习的迭代步长为 λ_i . 通过对比医疗数据簇分布模型, 计算医疗数据特征的主成分尺度, 得到统计分布函数为:

$$S_{v_i} = \{k(v_1, 1), \dots, k(v_1, i), \dots, k(v_1, K)\}, K \leq M, j \in M \quad (37)$$

根据边缘样本点的检测结果, 进行医疗数据的全

卷积神经网络学习,得到深度学习的表达式为:

$$x(t)e^{j\pi t^2 \cot \alpha} = \sum_{n=-N}^N x\left(\frac{n}{2\Delta x}\right) e^{\frac{j\pi(\cot \alpha)n^2}{(2\Delta x)^2}} \operatorname{sinc}\left[2\Delta x\left(t - \frac{n}{2\Delta x}\right)\right] \quad (38)$$

其中, $N = (\Delta x)^2$, 表示医疗数据的统计特征量,采用多关联数据回归分析方法,构建医疗数据表面重建的递归图,输出为:

$$m_k = \Phi^k(\omega)|_{\omega=0} = E[x^k] = \int_{-\infty}^{+\infty} x^k f(x) dx \quad (39)$$

式中, $d = E(x) = \eta$, 在医疗数据三维分布表面重建的稀疏散乱点分布范围内,采用网格顶点的形变位移重构方法,得到统计特征量:

$$\mu_k = E[x^k] = \begin{cases} 0, & k \text{ 为奇数} \\ 1 \cdot 3 \cdot \dots \cdot (k-1)\sigma^2, & k \text{ 为偶数} \end{cases} \quad (40)$$

在医疗数据表面网格模型的匹配点上^[17],结合负载均衡控制方法,得到整个数据表面重建网格模型统计特征量为:

$$G(U|\mu_k, \sum_k) = (2\pi)^{-d/2} \left| \sum_k \right|^{-1/2} \times \exp\left[-\frac{1}{2}(U - u_k)^T \sum_k^{-1} (U - u_k)\right] \quad (41)$$

式中, $G(U|\mu_k, \sum_k)$ 表示为第 i 个顶点的采样频谱特征量, U 表示初始采样点云数据, u_k 表示网格模型顶点分布序列。

综上分析,在改进的全卷积神经网络分类器中进行分类识别,实现医疗数据的表面重建和自动识别。

3 仿真实验与结果分析

为了测试基于改进全卷积神经网络的医疗数据表面重建算法在进行医疗数据表面重建中的应用性能,以医疗数据冗余特征处理效果、分类精度以及重建误差、重建耗时做为实验指标,进行仿真实验。

3.1 实验参数设置

实验以某三级甲等医院公开性医疗数据为数据基础,采用 Visual Studio 2016 软件平台实现医疗数据提取,并运用 Matlab 仿真软件进行数据模拟分析。具体实验参数为:数据采样的离散点为 2000,训练点数为 200,全卷积神经网络的训练次数为 15,数据采样的时间间隔为 2.5 s,相空间重构的延迟为 12,嵌入维数为 4,根据上述实验参数,对传统方法和本文方法进行对

比实验分析。

3.2 医疗数据冗余特征处理效果对比

由 2.1 小节可知,在对医疗数据进行重建之前,需要对医疗数据中的冗余特征进行滤波处理,以此来提升数据重建的效果与效率。以 2.1 节中的冗余数据处理结果作为依据,对传统方法与本文方法的医疗数据冗余特征处理效果进行对比分析。根据冗余度对处理效果进行评判,冗余度数值越低,代表处理效果越好,图 3 为不同方法的处理结果。




图3 不同方法的医疗数据冗余特征处理效果

分析图 3 可知,运用文献[4]方法对医疗数据中的冗余特征进行处理时,随着实验时间的变化,冗余度起伏较大,缺乏稳定性,整体处理效果处于较低水平;运用文献[5]方法对医疗数据中的冗余特征进行处理时,在开始阶段时,冗余度较高,随着时间的增长,冗余度虽然有所降低,但冗余度总体过高,说明该方法也不能实现对冗余数据的有效处理;而运用本文方法进行处理时,采用匹配滤波检测器进行冗余滤波处理,并根据匹配滤波检测器模型,实现对医疗数据特征量的提纯处理,根据图 3 可知,本文方法处理效果数值始终处于 0-1 之间,说明本文方法具有有效性。

3.3 医疗数据分类精度对比

在医疗数据特征提取与处理的基础上,利用全卷积神经网络分类器对数据进行分类处理,以便于更好的完成医疗数据重建。以稀疏散乱的医疗数据分类精度为实验指标,以式(33)和式(34)的分类计算为依据,对本文方法与文献[4,5]方法进行对比,结果如图 4 所示。

分析图 4 得知,采用本文方法进行医疗数据分类时,构建了改进全卷积神经网络模型,利用该模型对医

疗数据进行分类处理,分类精度可高达90%以上,而文献[4]和文献[5]方法的最高分类精度不超过80%,由此可见,本文所提方法的性能较好,对稀疏散乱数据的分类效果好。




图4 医疗数据分类精度

3.4 医疗数据重建误差对比

医疗数据的准确性关乎患者的健康问题,因此重建结果十分重要,重建误差过大会对医疗诊断以及治疗产生负面影响。为进一步验证本文方法的实用性能,对不同方法的重建误差进行测试,得到对比结果如图5所示。




图5 不同方法医疗数据表面重建误差对比

分析图5得知,文献[4]方法和文献[5]方法的表面重建误差较高,而不论样本数据为何值,本文方法的表面重建误差始终低于两种传统方法,这是由于运用本文方法对医疗数据的特征进行提取时,考虑到冗余数据的影响,并采用匹配滤波检测器对冗余数据进行滤波处理,使得本文方法的表面重建误差较低,对医疗数

据的重构和特征识别能力较强。

3.5 医疗数据重建耗时对比

选取重建耗时为实验指标,对本文方法与文献[4]、文献[5]方法进行对比,结果如表1所示。

表1 医疗数据重建耗时对比

实验次数 (次)	文献[4]方法 (s)	文献[5]方法 (s)	本文方法 (s)
10	20	32	13
20	22	41	15
30	31	40	11
40	44	32	10
50	30	38	14
60	55	50	11
70	52	54	13
平均值	36	41	12

分析表1得知,在数据重建耗时方面,文献[4]方法的平均耗时约为本文方法的3倍,文献[5]方法的平均耗时约为本文方法的3.5倍,由此可以显著看出,本文方法能够快速地完成医疗数据重建,说明该方法能够提高对医疗数据的检测和统计分析能力。这是因为本文采用多关联数据回归分析方法,构建了医疗数据表面重建的递归图,以此为基础完成了数据重建,大大降低了耗时。

4 结语

由于采用传统方法对医疗数据进行重建和识别时,重建误差较大,因此提出一种基于改进全卷积神经网络的医疗数据表面重建算法。采用无线RFID和ZigBee组网技术,进行医疗数据采样的网络节点分布式设计,采用密集型模糊迭代方法,进行医疗数据的融合处理,采用卷积神经网络学习算法进行医疗数据动态迁移均衡调度,对提纯后的医疗数据采用相空间重构技术实现医疗数据重构,对重构数据采用改进全卷积神经网络分类器进行分类识别,实现医疗数据的表面重建和自动识别。研究得知,本文方法能有效实现对医疗数据的表面重建,具有较强的实用性,能够为相关研究提供一定的参考价值。

参考文献

- 李昆仑,关立伟,郭昌隆.基于聚类和改进共生演算法的任务调度策略.计算机应用,2018,38(3):707-714.[doi:10.11772/j.issn.1001-9081.2017092311]
- 文政颖,李运娣.语义指向性特征聚类的图像检索算法研究.计算机技术与发展,2017,27(4):83-88.

- 3 邓海音, 苏慧. 医院自助医疗系统在数字化门诊中的应用探讨. 中国医学装备, 2018, 15(8): 90–93. [doi: 10.3969/J.ISSN.1672-8270.2018.08.025]
- 4 周鹏, 李景富. 一种有效的多类医疗数据挖掘算法研究. 科技通报, 2017, 33(5): 174–179.
- 5 张挺, 刘金华. 一种新的空间数据不确定性重建方法. 电子学报, 2018, 46(3): 641–645. [doi: 10.3969/j.issn.0372-2112.2018.03.019]
- 6 陈虹云, 王杰华, 胡兆鹏, 等. 面向医疗数据发布的动态更新隐私保护算法. 计算机科学, 2019, 46(1): 206–211. [doi: 10.11896/j.issn.1002-137X.2019.01.032]
- 7 阮彤, 邱加辉, 张知行, 等. 医疗数据治理——构建高质量医疗大数据智能分析数据基础. 大数据, 2019, 5(1): 12–24.
- 8 Lohit S, Kulkarni K, Kerviche R, *et al.* Convolutional neural networks for noniterative reconstruction of compressively sensed images. *IEEE Transactions on Computational Imaging*, 2018, 4(3): 326–340. [doi: 10.1109/TCI.6745852]
- 9 吕恒勇, 李心蕊, 朱宏亮, 等. 医疗设备档案数据挖掘研究. 生物医学工程研究, 2018, 37(4): 523–526.
- 10 丁可. 便携式医疗设备通信异常数据检测仿真. 计算机仿真, 2018, 35(12): 313–316. [doi: 10.3969/j.issn.1006-9348.2018.12.072]
- 11 赵国超, 张志强, 张学农. 医疗数据服务云的多维视图与应用模式. 中国数字医学, 2018, 13(12): 40–43. [doi: 10.3969/j.issn.1673-7571.2018.12.014]
- 12 Tan C, Lv SH, Dong F, *et al.* Image reconstruction based on convolutional neural network for electrical resistance tomography. *IEEE Sensors Journal*, 2019, 19(1): 196–204. [doi: 10.1109/JSEN.2018.2876411]
- 13 李兰英, 孔银, 陈德运. 一种新的卷积神经网络的ECT图像重建算法. 哈尔滨理工大学学报, 2017, 22(4): 28–33.
- 14 孙毅堂, 宋慧慧, 张开华, 等. 基于极深卷积神经网络的人脸超分辨率重建算法. 计算机应用, 2018, 38(4): 1141–1145.
- 15 李素梅, 雷国庆, 范如. 基于卷积神经网络的深度图超分辨率重建. 光学学报, 2017, 37(12): 1210002.
- 16 Zhang C, Qiao K, Wang LY, *et al.* Constraint-free natural image reconstruction from fMRI signals based on convolutional neural network. *Frontiers in Human Neuroscience*, 2018, 12: 242. [doi: 10.3389/fnhum.2018.00242]
- 17 Schlemper J, Caballero J, Hajnal JV, *et al.* A deep cascade of convolutional neural networks for dynamic MR image reconstruction. *IEEE Transactions on Medical Imaging*, 2018, 37(2): 491–503. [doi: 10.1109/TMI.42]