

基于深度学习与 D-S 理论的 多模态数据特征融合算法

张 燕

(新疆师范大学 计算机科学技术学院, 乌鲁木齐 830017)

摘要: 针对传统多模态数据特征融合算法存在融合效果较差的问题, 提出一种基于深度学习与 D-S(Dempster-Shafer)理论的多模态数据特征融合算法. 首先, 在深度学习框架内, 采用受限 Boltzmann 机(RBM)对多模态数据进行训练, 根据数据的特性和任务需求, 构建 RBM 模型结构进行多模态数据特征选择. 其次, 根据选取的特征选择计算同类模态数据之间的距离, 确定信任函数, 并设定阈值以删除异常数据, 实现同类模态数据初步融合. 最后, 通过计算异类模态数据与不同等级特征之间的距离, 确定异类数据的信任函数, 结合 D-S 理论实现多模态数据特征融合. 实验结果表明, 该算法的纯度最高达 1.0, 标准化互信息最高达 0.3, 表明该算法可以获取精准的多模态数据特征融合结果.

关键词: 深度学习; D-S 理论; 多模态数据特征; 融合

中图分类号: TP274 **文献标志码:** A **文章编号:** 1671-5489(2025)03-0855-06

Multimodal Data Feature Fusion Algorithm Based on Deep Learning and D-S Theory

ZHANG Yan

(College of Computer Science and Technology, Xinjiang Normal University, Urumqi 830017, China)

Abstract: Aiming at the problem of poor fusion performance in traditional multimodal data feature fusion algorithms, the author proposed a multimodal data feature fusion algorithm based on deep learning and D-S theory. Firstly, within the framework of deep learning, a restricted Boltzmann machine (RBM) was used to train multimodal data. Based on the characteristics of the data and task requirements, an RBM model structure was constructed for multimodal data feature selection. Secondly, based on the selected features, the author calculated the distance between similar modal data, determined the trust function, and set a threshold to remove abnormal data, achieving preliminary fusion of similar modal data. Finally, by calculating the distance between heterogeneous modal data and features of different levels, the author determined the trust function of heterogeneous data, and combined with D-S theory, multimodal data feature fusion was achieved. The experimental results show that the purity of the proposed algorithm can reach up to 1.0, and the standardized mutual information can reach up to 0.3, indicating that the proposed algorithm can obtain accurate multimodal data feature fusion results.

收稿日期: 2024-04-17.

作者简介: 张 燕(1978—), 女, 汉族, 博士, 副教授, 从事计算机应用及智能算法的研究, E-mail: zhangyan00hx1@163.com.

基金项目: 国家自然科学基金(批准号: 41561100)、新疆师范大学自治区“十四五”重点学科招标项目(批准号: 23XJKD0202)和新疆师范大学校级教学研究与改革项目(批准号: SDJG202214).

Keywords: deep learning; D-S theory; multimodal data feature; fuse

随着信息技术的迅猛发展,多模态数据在各领域的应用日益广泛.多模态数据主要是来自不同传感器或不同来源的多种类型数据,例如文本和图像等.这些数据具有各自独特的信息描述方式和特点,可以更全面地描述并反映现实世界的复杂性和多样性.因此,如何有效融合多模态数据特征^[1-2],提取有利用价值的信息成为当前该领域的研究热点.目前,多模态数据特征面临诸多挑战,如噪声干扰和环境因素等.近年来,关于数据融合^[3-4]的相关研究已取得了许多成果,例如:莫慧凌等^[5]通过张量 Tucker 分解理论组建高阶张量,将其用于捕获数据的高维特征,进而实现了多源异构数据融合,但该算法未考虑多源异构数据存在的稀疏性问题,会导致 Tucker 分解效果不佳,影响最终的融合结果;马宇红等^[6]对数据集的流形距离核矩阵进行计算,组建 Laplace 矩阵,通过矩阵构建全新的数据集,引入量子聚类算法对数据集进行聚类,获取原始数据类标签,最终实现数据融合,但该算法的计算复杂度和计算成本较高,在实际应用中会影响融合结果;Liu 等^[7]先根据不同的衡量标准确定各证据之间的特征区域,然后根据证据与平均证据两者之间的差异性,分别计算各证据对应的权重系数,最终采用加权因子对初始证据进行贴切,同时通过 Dempster 组合原理完成数据融合,但该算法未考虑信息冗余问题对融合结果的影响;Liu 等^[8]通过多个传感器进行数据采集和整合处理,最终实现数据融合,但该算法未考虑适应性问题,在复杂环境下获取的融合效果并不理想.

针对上述方法存在的不足,本文提出一种基于深度学习与 D-S(Dempster-Shafer)理论的多模态数据特征融合算法.本文将深度学习中的受限 Boltzmann 机(RBM)与 D-S 理论相结合,利用深度学习框架对多模态数据进行训练和特征提取,同时引入 D-S 理论的不确定性处理方法,更准确地融合多模态数据特征.实验结果表明,该算法的纯度(PUR)和标准化互信息(NMI)均高于其他融合算法.其中,纯度最高达 1.0,说明其在完成融合处理后可以更好地保留原始多模态数据的类别信息,便于后续进行分类和识别等相关任务.而 NMI 最高达 0.3,说明经过融合处理后的多模态数据特征和原始特征具有较高的一致性,可以有效保留原始数据中的结构信息.因此,本文算法实用性较好.

1 多模态数据特征融合算法设计

1.1 基于深度学习的多模态数据特征选择

为获取更理想的多模态数据特征融合结果,本文采用深度学习对多模态数据特征进行选择. Boltzmann 机(BM)的主要优势是可以训练 BM 参数,该过程涉及利用目标分布的现有样本进行近似建模,从而逐渐勾勒出未知分布的轮廓.在 BM 中,神经元占重要地位,其被清晰地分为两大类:可见神经元和隐神经元. RBM 是 BM 的一个特殊变种,其独特之处是相同神经元之间不存在内部连接,这种设计使 RBM 的结构更简洁高效,如图 1 所示.

由图 1 可见, RBM 主要由 D 个二进制可见神经元组成,其中 b 和 a 分别表示不同的变量, D 和

F 分别为两者中包含的可见神经元和隐神经元数量.联合 b 和 a 的定义可获取能量函数:

$$E(b, a) = - \sum_{i=1}^D \sum_{j=1}^F W_{ij} b_i a_j - \sum_{i=1}^D c_i b_i - \sum_{j=1}^F d_j b_j, \quad (1)$$

其中 W_{ij} 表示权重, b_i 和 b_j 分别表示第 i 、第 j 个可见神经元的二进制状态, a_j 表示第 j 个隐神经元的二进制状态, c_i 表示第 i 个可见神经元的 biase 取值, d_j 表示第 j 个隐神经元的 biase 取值. 式(1)的能量函数主要由可变量和隐变量对应的联合分布 $P(b, a)$ 组成,可表示为以下形式:

$$P(b, a) = \frac{1}{Z} \exp\{-E(b, a)\}, \quad (2)$$




图 1 RBM 结构

Fig. 1 RBM structure

其中 $Z = \sum_b \sum_a \exp\{-E(b,a)\}$ 表示配分函数.

对全部的 (b,a) 进行求和, 并将 RBM 的条件分布表示为

$$\begin{cases} p(a_j = 1 | b) = g\left(\sum_{i=1}^D W_{ij} \frac{b_i}{\sigma_i} + c_i\right), \\ p(b_j = 1 | a) = N(c_i + \sigma_i W_{ij} b_j + \sigma_i^2), \end{cases} \quad (3)$$

其中 g 表示 Logistic 函数, N 表示神经元数量, σ_i 表示方差.

结合上述分析, 通过基于 RBM 的生成式属性进行多模态数据特征选择. 其中, 多模态数据特征选择主要包括以下步骤.

1) 训练程序初始化处理. 在训练 RBM 的过程中, 首先向模型输入训练数据; 然后对训练数据执行计算, 确定所有隐神经元的值; 最后使用 Gibbs 采样方法重新构造输入信号, 以逼近模型的真实分布. 同时, 计算重构信号与原始输入数据之间的差异, 利用其完成 RBM 调节:

$$\frac{1}{N} \sum_{n=1}^N \frac{\partial \log(P(b_n))}{\partial W_{ij}} = E_{\text{data}}(b_i a_j) - E_{\text{model}}(b_i a_j), \quad (4)$$

其中 $E_{\text{data}}(b_i a_j)$ 表示 $b_i a_j$ 关于数据分布的期望值, $E_{\text{model}}(b_i a_j)$ 表示节点二进制分布为 1 的频率, $P(b_n)$ 表示条件概率, ∂ 表示调节参数.

2) 多模态数据特征消除阶段. 采用随机森林技术对多模态数据进行降维处理, 将原始数据中不相关的特征直接删除, 获取特征消除处理后的多模态数据特征 $p(r_k)$, 上述过程表示为

$$p(r_k) = \frac{1}{\sqrt{2\pi}} \sum_{i=-\infty}^{r_k} \frac{\exp\{x - \beta_g\}}{2\sigma_i^2}, \quad (5)$$

其中 r_k 表示多模态数据特征相关性, x 表示多模态数据特征, β_g 为准则函数.

3) 多模态数据特征选择阶段. 采用完成特征消除处理后的多模态数据特征对 RBM 进行训练, 当 RBM 完成初始化训练后, 通过其计算输入特征的重建误差 e_i :

$$e_i = \frac{1}{D} \sum_{i=1}^D \bar{e}_i, \quad (6)$$

其中 \bar{e}_i 表示重建误差均值.

首先, 将重建误差作为判定依据, 采用选择的特征, 对 RBM 进行深入训练, 使其性能达到最佳. 其次, 利用这些特征进一步训练 RBM, 使其能充分吸收并利用这些特征中的信息, 再将训练好的 RBM 的学习参数用于初始化多层神经网络. 最后, 通过后向传播方法对多层神经网络进行训练, 完成特征选择. 上述操作过程, 不仅实现了特征的有效选择, 且确保了多层神经网络在处理多模态数据时能发挥更好的性能.

1.2 基于 D-S 理论的多模态数据特征融合

通过多模态数据特征选择可有效筛选出与目标任务最相关的特征, 有效提升多模态数据特征融合性能, 达到最佳的特征融合效果^[9]. 下面采用 D-S 理论优先对同类数据进行融合, 然后将异类数据进行融合, 最终根据决策标准判定融合后的结果.

在 D-S 理论中, 样本空间即为辨识框架, 用 Θ 表示, Θ 由一系列对象 θ_i 组成, 可表示为

$$\Theta = \{\theta_1, \theta_2, \dots, \theta_n\}. \quad (7)$$

在辨识框架 Θ 下, 对于事件 H , 根据相关定义可利用基本概率赋值函数 mass 计算获取事件 H 的信任函数 $\text{Bel}(H)$ 和似然函数 $\text{Pl}(H)$, 两者之间的关系如图 2 所示.




图 2 D-S 理论区间标识示意图

Fig. 2 Schematic diagram of D-S theoretical interval labeling

D-S 理论在处理不确定问题时性能卓越, 但一旦遭遇证据间的激烈冲突, 融合结果通常会陷入悖论漩涡. 为避免这种情况, 必须从下列多个维度进行深入剖析, 以寻找切实可行的解决方案:

- 1) 改变证据融合规格;
- 2) 得到改变证据后再改变 mass 值.

采用 D-S 理论优先对同类数据进行融合处理, 然后再对异类数据进行融合决策, 最终获取多模态数据特征融合结果. 多模态数据特征融合流程如图 3 所示.

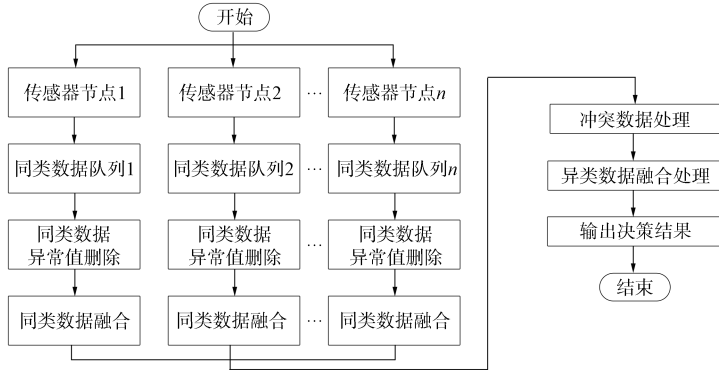


图 3 多模态数据特征融合流程

Fig. 3 Flow chart of multimodal data feature fusion

采用基于欧氏距离的异常值剔除方法, 剔除多模态数据中的异常值. 核心思想为: 同类数据间, 若距离紧密, 则相似度极高, 数据的真实性也更值得信赖; 反之, 若距离疏远, 则数据间的真实性大幅度降低. 因此, 需精准计算每对数据间的距离, 并求平均值, 以此作为衡量标准. 同时设定阈值, 一旦数据超出该范围, 即将其从多模态数据中剔除.

将传感器的数量表示为 n , 采集到的同类数据表示为 u_i , 则 u_i 和除 u_i 外的其他同类数据 u_j 之间的距离 $d(u_i)$ 为

$$d(u_i) = \left[\frac{1}{n-1} \sum_{j=1}^n (u_i - u_j)^2 \right]^{1/2}. \quad (8)$$

利用式(8)计算完距离后, 即可组建距离矩阵:

$$Dd(d_{ij}) = \begin{pmatrix} d_{11} & \cdots & d_{1j} & \cdots & d_{1n} \\ \vdots & & \vdots & & \vdots \\ d_{i1} & \cdots & d_{ij} & \cdots & d_{in} \\ \vdots & & \vdots & & \vdots \\ d_{m1} & \cdots & d_{mj} & \cdots & d_{mn} \end{pmatrix}. \quad (9)$$

距离 $Dd(d_{ij})$ 反映了该数据与其他数据之间的相似程度, $Dd(d_{ij})$ 中元素取值越小, 数据之间的距离越短, 它们之间的相似度更显著. 同时, 还需对相似度进行归一化处理, 使同类数据之间的相似度对比更鲜明, 进而提升了数据的真实性和可靠性. 利用多模态数据的归一化相似度 $DG(u_i)$ 即可得到同类数据的信任函数:

$$DSUP(u_i) = 1 - DG(u_i). \quad (10)$$

对完成筛选处理后的多模态数据进行平均计算, 得到 \bar{u}_i , 再计算 \bar{u}_i 到各相应等级 T_i 的距离:

$$D(\bar{u}_i) = \sum_{i=1}^n \left(\frac{1}{T_{i\max} - T_{i\min}} \left(\bar{u}_i - \frac{\Delta T_i}{2} \right)^2 \right)^{1/2}, \quad (11)$$

其中 $T_{i\max}$ 和 $T_{i\min}$ 分别表示不同类数据等级特征值的最大和最小值, $\frac{\Delta T_i}{2}$ 表示等级区间中间值. 得到 $D(\bar{u}_i)$ 后, 即可经过计算获取异类数据的信任函数:

$$MSUP(u_i) = \frac{1}{D(\bar{u}_i)}. \quad (12)$$

完成上述计算后, 对信任函数 $MSUP(u_i)$ 进行归一化处理作为 D-S 理论的 mass 函数, 同时通过

D-S 理论进行最后融合, 获取多模态数据特征融合结果:

$$m(H_i) = \frac{\text{MSUP}(u_i)}{\sum_{i=1}^n \text{MSUP}(u_i)}. \tag{13}$$

2 实验及结果分析

2.1 实验环境

为验证本文基于深度学习与 D-S 理论的多模态数据特征融合算法的有效性, 采用 MATLAB 平台进行实验分析, 实验参数如下: 网络范围为 150 m × 150 m, 最大仿真轮数为 3 000, 包头长度为 150 bit, 节点数量为 200 个, 数据包长度为 2 500 bit, 分簇消息长度为 150 bit, 节点初始能量为 0.5 J, 可信度系数为 0.98, 融合权重为 0.75, 正则化参数为 0.70, 学习率为 0.1, 损失函数值为 0.01.

2.2 实验指标

采用纯度(PUR)和标准化互信息(NMI)作为实验指标. 纯度计算公式为

$$\text{PUR} = \frac{1}{N} \sum_{i=1}^k \max_j |C_i \cap L_j|, \tag{14}$$

其中 N 表示样本总数, k 表示融合后簇的数量, C_i 表示第 i 个簇中的样本集合, L_j 表示第 j 个真实类别的样本集合. 纯度越高, 表明融合后的特征能更好地区分不同类别的数据, 保留了原始数据的类别信息, 使得对数据进行分类、识别或其他任务时具有更可靠的性能和效果. 标准化互信息计算公式为

$$\text{NMI}(C, L) = \frac{2 \times I(C, L)}{H(C) + H(L)}, \tag{15}$$

其中 C 表示融合结果, L 表示真实标签, $I(C, L)$ 表示 C 与 L 的互信息, $H(C)$ 和 $H(L)$ 分别表示 C 和 L 的熵. 高标准化互信息表明融合后的特征与原始特征之间具有较高的相关性, 保留了原始数据中的结构信息, 使融合后的特征更能表示原始数据的基本特征和结构, 有利于在后续分析、识别和应用任务中取得更好的效果.

2.3 实验结果

采用本文算法对多模态数据特征进行融合处理, 实验结果如图 4 所示. 由图 4 可见, 在一定的持续时间内, 本文算法获取的融合结果和真实值基本吻合, 说明该算法融合效果较好.

为进一步验证本文算法的性能, 将其与文献[5]算法和文献[6]算法的纯度和标准化互信息进行对比, 实验结果如图 5 所示. 由图 5 可见, 本文算法的 PUR 和 NMI 均高于其他融合算法. 本文算法的纯度最高达 1.0, 说明其在完成融合处理后可更好地保留原始多模态数据的类别信息, 便于后续进行分类和识别等相关任务. 本文算法的 NMI 最高达到 0.3, 说明经过融合处理后的多模态数据特征和原始特征具有较高的一致性, 可有效保留原始数据中的结构信息. 因此, 本文算法更适用于解决多模态数据特征融合问题.

综上所述, 针对传统多模态数据特征融合算法存在的不足, 本文提出了一种基于深度学习与 D-S 理论的多模态数据特征融合算法. 实验测试结果表明, 本文算法可有效降低融合误差, 提升纯度和标准化互信息, 获取更精准的多模态数据特征融合结果.




图 4 本文算法的多模态数据特征融合效果
Fig. 4 Multimodal data feature fusion effect of proposed algorithm

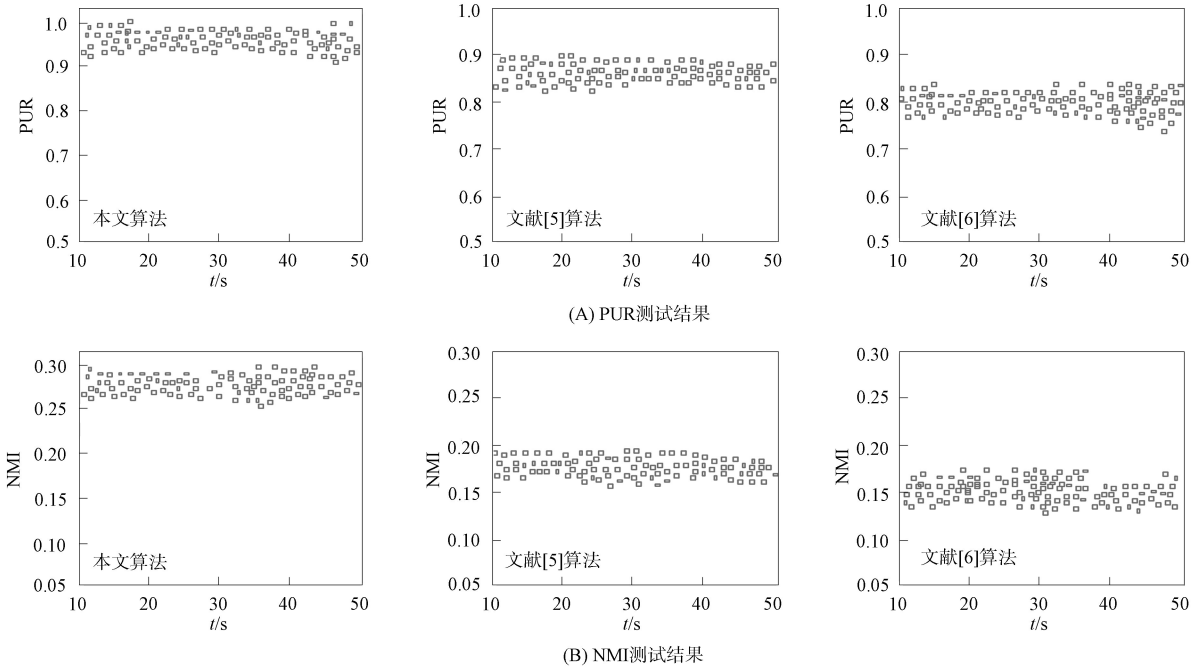


图 5 不同融合算法的 PUR 和 NMI 测试对比结果

Fig. 5 Comparison results of PUR and NMI test for different fusion algorithms

参 考 文 献

[1] 张良培, 何江, 杨倩倩, 等. 数据驱动的多源遥感信息融合研究进展 [J]. 测绘学报, 2022, 51(7): 1317-1337. (ZHANG L P, HE J, YANG Q Q, et al. Data-Driven Multi-source Remote Sensing Data Fusion: Progress and Challenges [J]. Acta Geodaetica et Cartographica Sinica, 2022, 51(7): 1317-1337.)

[2] 邓晨, 陈功, 王文正, 等. 基于不确定度和气动模型的气动数据融合算法 [J]. 空气动力学学报, 2022, 40(4): 117-123. (DENG C, CHEN G, WANG W Z, et al. Aerodynamic Data Fusion Algorithms Based on Aerodynamic Model and Uncertainly [J]. Acta Aerodynamica Sinica, 2022, 40(4): 117-123.)

[3] 戴海发, 卞鸿巍, 杜红松, 等. 基于自适应因子图优化的导航系统信息融合方法 [J]. 中国惯性技术学报, 2023, 31(1): 45-52. (DAI H F, BIAN H W, DU H S, et al. Information Fusion Method of Navigation System Based on Adaptive Factor Graph Optimization [J]. Journal of Chinese Inertial Technology, 2023, 31(1): 45-52.)

[4] 胡楚阳, 柳先辉, 赵卫东. 基于规则链的网络协同制造数据融合方法研究 [J]. 计算机科学, 2022, 49(增刊 2): 219-225. (HU C Y, LIU X H, ZHAO W D. Data Fusion Method of Network Collaborative Manufacturing Based on Rule Chain [J]. Computer Science, 2022, 49(Suppl 2): 219-225.)

[5] 莫慧凌, 郑海峰, 高敏, 等. 基于联邦学习的多源异构数据融合算法 [J]. 计算机研究与发展, 2022, 59(2): 478-487. (MO H L, ZHENG H F, GAO M, et al. Multi-source Heterogeneous Data Fusion Based on Federated Learning [J]. Journal of Computer Research and Development, 2022, 59(2): 478-487.)

[6] 马宇红, 李兴义, 薛生倩, 等. 一种基于流形距离核的谱聚类 and 量子聚类融合算法 [J]. 西北师范大学学报(自然科学版), 2023, 59(2): 37-46. (MA Y H, LI X Y, XUE S Q, et al. A Fusion Algorithm of Spectral Clustering and Quantum Clustering Based on Manifold Distance Kernel [J]. Journal of Northwest Normal University (Natural Science), 2023, 59(2): 37-46.)

[7] LIU Y, ZHANG Y. A Weighted Evidence Combination Method for Multisensor Data Fusion [J]. Journal of Internet Technology, 2022, 23(3): 553-560.

[8] LIU Z, XIAO G, LIU H, et al. Multi-sensor Measurement and Data Fusion [J]. IEEE Instrumentation & Measurement Magazine, 2022, 25(1): 28-36.

[9] 卢艳军, 张前, 张晓东, 等. 基于气流传感器的位置信息融合方法 [J]. 探测与控制学报, 2022, 44(3): 51-56. (LU Y J, ZHANG Q, ZHANG X D, et al. Location Information Fusion Method Based on Extended Kalman Filter [J]. Journal of Detection & Control, 2022, 44(3): 51-56.)

(责任编辑: 韩 啸)