

一种新的学习记忆模型的研究

吴小景^{1,2} 石振国¹ 程显毅¹

(南通大学计算机科学与技术学院 江苏 南通 226019)¹ (南通大学电子信息学院 江苏 南通 226019)²

摘要 基于传统的认知心理学的 AS 模型,提出了一种新的学习记忆模型。该模型基于 AS 的记忆原理,结合大脑皮层的记忆机制来细化记忆的过程,进而提出针对该模型的学习记忆算法。实验结果表明,该算法的性能良好,其机制符合人脑思维,实用、有效且可行。

关键词 学习,记忆模型,预测

中图法分类号 TP181 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2018.05.038

Study on New Model for Learning Memory

WU Xiao-jing^{1,2} SHI Zhen-guo¹ CHENG Xian-yi¹

(College of Computer Science and Technology, Nantong University, Nantong, Jiangsu 226019, China)¹

(College of Electronic and Information, Nantong University, Nantong, Jiangsu 226019, China)²

Abstract In the traditional cognitive psychology, a new memory model was proposed on the basis of AS model. This method uses the memory principle of AS model and the mnemonic mechanism of cerebral cortex to detail the process of memory. And then a new memory algorithm on the basis of the model was proposed. Experiments show that the algorithms are practical, effective and feasible, and the mechanism of the algorithm is close to the human thoughts.

Keywords Learning, Memory model, Prediction

自 19 世纪末以来,学术界和工业界对人脑的记忆机制进行了大量的研究,提出了许多相关的记忆模型。Atkinson 等^[1]于 1968 年提出的 Atkinson-Shiffrin 模型是描述记忆结构的心理学模型,随后研究人员将其衍生为三阶段记忆模型,本文将此模型及其衍生模型均称为 AS 模型。如图 1 所示,AS 模型由瞬时记忆、短时记忆和长时记忆 3 个阶段^[2]组成。在该模型中,瞬时记忆阶段记录的信息量大且精准,但持续的时间短,较多信息会被遗忘^[3];短时记忆阶段是指将在瞬时记忆过程中被遗忘的信息重新组合成信息块的过程,持续时间短,信息块的组合过程是指根据信息之间的相似性和关联性而进行信息的选择过程,遗忘部分信息可以提高记忆的容量和效率^[4];长时记忆阶段则是对短时记忆处理后的信息进行进一步的整合,将有意义的信息进行长时间的存储,以便识别和记忆新的信息^[5]。




图 1 记忆的 AS 模型

Fig. 1 AS model of memory

近年来,基于上述记忆模型的各种衍生或拓展的模型在各个领域都有一定的应用^[6-11],文献[8]将 AS 模型引入到粒

子滤波器的更新替代模板中,提出了一种基于记忆的粒子滤波器;文献[9]提出了一种基于 AS 模型的聚类算法;文献[10]提出了一个带有学习和遗忘的视觉 AS 模型,并将其用于视觉记忆冗余信息的删除,但 AS 模型对记忆过程并没有进行深入的分析,即 AS 模型的记忆形成机制不清晰,这限制了 AS 模型的进一步拓展。

本文在 AS 模型的基础上结合大脑皮层的工作原理^[12],探讨了记忆形成的过程,构造了一种深入记忆的学习记忆模型,并基于此模型提出了一种新的学习记忆算法,通过实验证明了该算法实用、有效且可行。

本文第 1 节介绍了新的学习记忆模型;第 2 节给出了基于大脑皮层工作原理的学习记忆算法;第 3 节通过实验验证了本文算法的可行性;最后总结全文并展望未来。

1 学习记忆模型

学习记忆模型是基于记忆机制和大脑皮层原理所构建的模型(见图 2),该模型由下层、中层、顶层 3 层记忆空间组成,其中包含学习记忆过程和识别预测过程。该模型为一个树形的存储结构,其 3 层结构对应 3 个不同的信息处理模块,且随着层次的上升,其对应的信息单元^[10]数减少。其中,下层为信息接收层,对信息进行初步特征提取;中层接收下层信息特征并学习记忆;顶层则进一步学习记忆中层的信息特征,从而

到稿日期:2017-10-01 返修日期:2017-12-11

吴小景(1990—),男,硕士,主要研究方向为机器学习,E-mail:hy_wuxiaojing@163.com;石振国(1963—),男,博士,副教授,CCF 会员,主要研究方向为人工智能、机器学习,E-mail:chinaemail@sohu.com(通信作者);程显毅(1956—),男,博士,教授,主要研究方向为数据挖掘、模式识别。

形成最终的记忆模式。所提模型的基本思想是:在输入信息中寻找共有的模式并不断学习和记忆这些模式,同时根据记忆的模式预测下一步的输入信息。




图 2 记忆学习模型

Fig. 2 Memory learning model

1.1 学习记忆的基本概念

在所提模型中,内部学习记忆的机制是根据大脑皮层的记忆理论设定的,即每层记忆空间的学习记忆规则是一致的^[12],构成每层记忆空间的内部信息单元^[10]是相同的。此信息单元模拟生物学上的人脑神经元,由文献^[12]可知,神经元是由细胞体和树突区域两部分组成,因此定义相关信息如下。

定义 1 定义记忆细胞 T ,即信息单元,其有 3 种输出状态:1)非激励状态 NS;2)由下层特征输入激活的记忆学习状态 LS;3)由邻近记忆细胞的激励而触发的预测状态 CS。其中,记忆细胞输出的状态 LS 模拟神经元动作电位的短脉冲,预测状态 CS 则模拟神经元中平缓的动作电位。

定义 2 定义 T 的树突集 S , S 分为近体树突(接近细胞核的树突) S_i 和末端树突 S_d ,近体树突接收自下而上的输入,而末端树突则接收邻近 T 的激励。两者接收的输入或激励后的状态构成突触 S_{yn} 。

$$S_i = \{S_i, i=1,2,\dots,m\} \tag{1}$$

$$S_d = \{S_d, i=1,2,\dots,n\} \tag{2}$$

定义 3 定义记忆细胞集 T_s ,用于接收输入信息的特征子集,是 k 个 T 构成的集合(见图 3),每层所划分的区域代表一个 T_s ,其中每个 T_s 包含多个 T ,即图 3 中小框里所表示的椭圆以及 T 相关的功能模块,即一个或多个 T_s 可表示输入信息形成的学习记忆模式。

$$T_s = \{T_i, i=1,2,\dots,q\} \tag{3}$$




图 3 记忆单元图

Fig. 3 Memory unit diagram

1.2 学习记忆的原理

由定义 3 可知,一个学习记忆模式在模型中是由一个或多个 T_s 表示的,即每个 T_s 对应输入中的唯一的一个特征子集,不同的输入模式会形成激励程度不同的 T_s 。

在学习记忆模型的形成过程中,首先是模型的激励机制,用于初步处理输入的特征,接着对激励后的 T_s 产生一个抑制

作用,抑制作用类似三阶段记忆模型中的遗忘原则,亦类似生物神经元的抑制作用。 T_s 通过抑制作用可形成一个离散稀疏的学习记忆模式,其抑制作用有一定的范围和力度,由 T_s 的状态决定。这种抑制作用可以有效控制 T_s 的激励程度,当输入的特征很多或者输入的模式变化不大且存在较多该种情况时,在抑制作用下整个表示的学习记忆模式仍然可以维持在一个稳定的状态。

在学习记忆模式形成后,当有后续输入时,查找 T_s (处于学习记忆状态)中是否有处于 CS 状态的 T ,如果没有,则激活 T_s 中全部 T 的 LS 状态,最终活跃 T 的集合就是当前输入在先前的输入环境下的学习记忆模式;如果有,则找到处于 CS 状态的 T 并激活其 LS 状态,以形成激励程度不同的 T_s ,从而再次形成新的学习记忆模式。查找流程如下:对于 T_s 中的每个 T 的 S_d ,统计连接到活跃 T 的 S_{yn} 数量,如果该数量超过阈值,那么标记该 S_d 为活跃树突,对应的活跃 S_d 的细胞则被置为 CS 状态。其中,已经被输入激活的 T 无法被置为 CS 状态,没有活跃 S 并且没有因输入而活跃的细胞则维持 NS 状态。

最后是模型的预测机制,以当前的输入和已经构成的特征学习模式为基础进行预测,当输入的模式随着时间发生变化时,不同状态下的 T 会按一定的顺序变得活跃。当其中一个 T 处于激励状态时,该 T 随即与周围的 T 建立连接并传递激励,周围的 T 接收到激励时进入预测状态,进而将这样一种机制推行到 T_s 上,当一个 T_s 有输入的特征激励时,以相同的机制使得周围的 T_s 进入预测状态。最后处于活跃状态的多个 T_s 将组合成上一层输入的特征,激励上一层的 T_s ,从而形成上一层新的学习记忆模式。

2 学习记忆算法描述

根据 1.2 节所阐述的原理,本文提出了一种学习记忆算法,该算法主要分为学习记忆过程和预测匹配过程。

2.1 学习记忆过程

学习记忆过程主要形成学习记忆模式,具体步骤如下。

Step1 输入从空间 $columns$ 中选取的一个随机子集 $C(c_1, c_2, c_3, \dots, c_k)$,并设定节点(即记忆细胞集 T_s)的初始状态及其 T 的 S_i 连通值集合的随机初始化值。

Step2 输入 C ,计算得到 C' ,计算方法如下:

当输入为底层时:

$$C' [i] = \exp(- \| T_i - C \|^2 / \sigma^2) \tag{4}$$

当输入为中间层时:

$$C' [i] = \prod_{j=1}^k C_j \cdot [T_i [j]] \tag{5}$$

其中, σ^2 为节点形成速率的控制参数。

Step3 通过抑制作用参数 $DActivity$ 选择得到离散特征集,即学习记忆序列 $C' \rightarrow C_s$;

$$C_s [i] = \sum_{i=1}^q C' [i] \cdot DActivity [i, j] \tag{6}$$

其中, $\sum_{i=1}^q C' [i] = 1$, $DActivity [i, j]$ 为 T 结合 S_i 所构建的矩阵,即 $DActivity [i, j] = P(S_c | T_j)$ 。

Step4 更新参数 $DActivity$,其过程如下:

$$DActivity[i, j] = \begin{cases} P(S_i), & S_i \in T_j \\ 0, & \text{其他} \end{cases} \quad (7)$$

其中, $P(S_i)$ 表示 S_i 对应的 T 所激活的概率。

$$DActivity^{new}[i, j] = \frac{DActivity[i, j]}{\sum_{k=1}^m DActivity[k, j]} \quad (8)$$

Step5 输入下个子集, 返回 Step2, 直到输入结束。

2.2 预测匹配过程

该过程以 T 为预测单元, 即通过计算 T_i 中 T 的当前状态来决定预测匹配的基础, 具体步骤如下。

Step1 初始化集合 S_d , 赋予较小随机数并进行归一化处理。

Step2 自下而上地输入 C , 计算 C 中的 c_i 和所有输出节点的欧氏距离 d , 并选择与 C_i 距离最小的节点, 即 $c_i - S_d = \min\{d_i\}$, T_i 即为最佳匹配节点。

Step3 调整 S_d 的权值, 其方法如下:

$$\Delta S_d = \sigma(c_i - S_d) \quad (9)$$

Step4 对应的节点为预测匹配结果 p , 返回学习记忆过程的 Step2。

预测即为对已有记忆和输入的综合判断, 以便进一步学习记忆, 从而得到一个良好的预测结果。

3 实验及结果分析

3.1 实验数据的设定

为了评估本文提出的学习记忆算法, 本文采用 UCI 标准评测数据集, 并选取 10 个数据集进行实验, 针对每个数据集, 随机选取 70% 的数据作为训练集, 选取其他 30% 的数据作为测试集, 实验所用数据集的信息如表 1 所列。

表 1 实验所用数据集的信息

Table 1 Dataset information used in experiment

数据集	样本数	特征数	类别数
Balance	625	4	3
Parkinson	197	23	2
ILPD	583	10	2
Vertebral_c	310	6	3
Soy_a	307	34	19
Ionosphere	351	35	2
Statlog_heart	270	13	2
Audiology	228	69	24
Breast_cancer	699	32	2
Backup	683	35	19

3.2 比较分析

本文对 BP 算法、BFGS 算法、RPROP 算法与所提算法的预测精度进行对比。其中, BP 算法是一种有导师学习的多层神经网络算法, 在实际中被广泛应用; 而 BFGS 算法是一种拟牛顿算法, 利用 Hessian 矩阵来进行优化计算; RPROP 算法是一种局部自适应学习率的前馈网络算法, 具有良好的鲁棒性。

算法流程设定训练的节点数为 100, 其对比分析结果如表 2 所列。从整体角度分析, 本文算法在平均预测精度方面比 RPROP 高 3.06%, 比 BFRS 高 4.4%, 比 BP 高 5.56%。从单一数据集角度分析, 除了 Audiology 和 Backup 这两个数据样本的预测表现略低于 RPROP 算法和 BFRS 算法, 在其他数据样本测试中, 本文算法均能提高其预测精度。通过比

较分析可知, 本文算法在预测方面表现良好, 表明其细化记忆的模型构建机制具有一定的实用性。

表 2 实验统计结果

Table 2 Experimental statistical results

(单位: %)

数据集	BP	BFRS	RPROP	本文算法
Balance	75.25	77.20	76.41	83.62
Parkinson	78.34	79.83	84.52	87.53
ILPD	76.09	76.45	79.64	83.50
Vertebral_c	77.69	79.89	78.04	80.10
Soy_a	78.30	78.46	79.69	80.68
Ionosphere	73.45	74.37	77.56	80.86
Statlog_heart	72.50	73.72	77.40	81.43
Audiology	79.80	79.98	80.32	79.80
Breast_cancer	72.78	74.68	73.24	80.56
Backup	79.48	80.69	81.85	81.25
平均值	76.37	77.53	78.87	81.93

本文进一步对抑制参数 $DActivity$ 进行相应的实验验证分析, 设置不同的节点个数, 在 Soy_a 数据集上进行预测分析, 其结果如表 3 所列。

表 3 参数 $DActivity$ 的分析结果

Table 3 Analysis results of parameter $DActivity$

训练节点数	$DActivity$ 对应矩阵	预测精度 / %
10	34×20	71.73
50	130×52	78.56
100	301×117	85.76
250	834×265	94.62
500	2034×643	95.78
750	3421×1123	97.43
1500	7589×3076	98.65

由实验结果可知, 整体上随着节点数量的增加, 预测精度随之提高, 说明节点的数量对预测精度有着重要的作用, 但当节点数量为 500 乃至更大时, 预测精度的提升趋于平缓。

结束语 本文结合 AS 模型和大脑皮层的工作原理, 提出了一种细化记忆过程的学习记忆算法, 该算法能有效提高预测的精度, 实验结果表明本文算法实用、有效且可行。同时, 本文还在细化记忆过程方面拓展了 AS 模型。但所提算法在学习记忆模型的其他构建环节中还存在不足, 如在记忆空间有效利用、记忆空间层次衔接等方面。因此下一步的工作是完善本文的学习记忆模型, 以提出预测精度更高的算法。

参 考 文 献

- [1] ATKINSON R C, SHIFFRIN R M. Human Memory: A Proposed System and Its Control Processes [C] // Psychology of Learning & Motivation, 1968; 89-195.
- [2] HARRY M. Real learning a bridge to cognitive neuroscience [M]. Lanham: Scarecrow Education, 2003; 87-106.
- [3] WANG Y X, WANG Y. Cognitive Models of the Brain [C] // Proc of the 1st IEEE International Conference on Cognitive Informatics. Calgary, Canada, 2002; 259-269.
- [4] ZHANG S J, BAN X J, CHEN Y, et al. Memory-based cognitive model of artificial fish [J]. Computer Engineering, 2007, 33(19): 33-35. (in Chinese)
张淑军, 班晓娟, 陈勇, 等. 基于记忆的人工鱼认知模型 [J] 计算机工程, 2007, 33(19): 33-35.

- [5] HUANG G Q,ZHAO Y. Approach to intrusion detection model based on biological memory principles[J]. Journal of Computer Applications,2009,29(5):1279-1284.
- [6] FRATE F D,PACIFICI F,SCHIAVON G,et al. Use of neural-networks for automatic classification from high-resolution images[J]. IEEE Transactions on Geoscience & Remote Sensing, 2007,45(4):800-809.
- [7] WANG Y X,WANG Y. Cognitive Informatics Models of the Brain[J]. IEEE Trans on Systems, Man and Cybernetics, 2006,36(2):203-207.
- [8] ZHANG G W,LIAO W H,LIU C Y,et al. Memorizing-Forgetting Featured Knowledge Management and Optimizing Model [J]. Journal of Nanjing University of Aeronautics & Astronautics,2008,40(2):265-270. (in Chinese)
张格伟,廖文和,刘长毅,等. 知识的记忆-遗忘模型及其在知识管理中的应用[J]. 南京航空航天大学学报,2008,40(2):265-270.
- [9] QI Y J,WANG Y J. Robust Object Tracking by Particle Filter Based on Human Memory Model[J]. Pattern Recognition and Artificial Intelligence,2012,25(5):810-816. (in Chinese)
齐玉娟,王延江. 基于人类记忆模型的粒子滤波鲁棒目标跟踪算法[J]. 模式识别与人工智能,2012,25(5):810-816.
- [10] CHEN R,PENG L. Moving target detection based on visual memory model and clustering [J]. Computer Engineering and Applications,2015,51(13):172-175. (in Chinese)
陈容,彭力. 基于视觉记忆模型聚类的运动目标检测[J]. 计算机工程与应用,2015,51(13):172-175.
- [11] GUO C L,ZHANG L M. A Visual Memory Model with Amnesic Function and Its Application in Attention Selection [J]. Pattern Recognition and Artificial Intelligence, 2008, 21(3):381-387. (in Chinese)
过晨雷,张立明. 带有遗忘的视觉记忆模型及其在注意力选择上的应用[J]. 模式识别与人工智能,2008,21(3):381-387.
- [12] WILLSHAW D,HALLAM J,GINGELL S,et al. Theory of the Neocortex as a Self-Organizing Neural Network [J]. Neural Computation,1997,9(4):911-936.

(上接第 200 页)

结束语 针对 K 近邻相似图构造过程中 K 近邻搜索的效率瓶颈问题,本文提出了一种基于堆的 K 近邻搜索方法;另外,K 邻域易带入噪声边,本文根据邻域共存信息选择每个点的局部邻域来代替原来固定大小的 k 近邻邻域,提高了相似图的可靠性和稳定性,经过阈值截断的相似图更稀疏,加快了谱聚类特征向量分解的速度。

相似图不仅能够用于谱聚类,还能用于 LLE^[18-19] 等提出的相似矩阵算法。此外,本文的邻域选择方法在流形数据^[20]上能够较大幅度地保留局部特征,因此下一步工作就是将该算法应用于图像检索等领域。

参 考 文 献

- [1] JAIN A K. Data Clustering:50 Years Beyond K-means[C]// European Conference on Machine Learning and Knowledge Discovery in Databases. Springer-Verlag,2008:651-666.
- [2] NG A Y,JORDAN M I,WEISS Y. On Spectral Clustering: Analysis and an Algorithm[J]//Proc Nips,2001,14:849-856.
- [3] SHI J,MALIK J. Normalized cuts and image segmentation[J]. IEEE Trans. Pattern Anal. Mach. Intell,2000,22(8):888-905.
- [4] BACH F R,JORDAN M I. Learning spectral clustering, with application to speech separation[J]. Journal of Machine Learning Research,2006,7(2):2006.
- [5] OZERTEM U,ERDOGMUS D,JENSSEN R. Mean shift spectral clustering[J]. Pattern Recognition,2008,41(6):1924-1938.
- [6] MA C,WU T,DUAN M Y. Research on clustering algorithm based on degree of membership of K nearest neighbor [J]. Computer Engineering and Applications,2016,52(10):55-58. (in Chinese)
马闯,吴涛,段梦雅. 基于 K 近邻隶属度的聚类算法研究[J]. 计算机工程与应用,2016,52(10):55-58.
- [7] LU H,FU Z,SHU X. Non-negative and sparse spectral clustering[J]. Pattern Recognition,2014,47(1):418-426.
- [8] YANG X,BAI X,LATECKI L J,et al. Improving Shape Retrieval by Learning Graph Transduction[C]// European Conference on Computer Vision. Marseille, France, DBLP,2008:788-801.
- [9] PAVAN M,PELILLO M. Dominant Sets and Pairwise Clustering[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence,2007,29(1):167-72.
- [10] LI L,LV J,YI Z. A non-negative representation learning algorithm for selecting neighbors[J]. Machine Learning,2016,102(2):133-153.
- [11] LUXBURG U. A tutorial on spectral clustering[J]. Statistics and Computing,2007,17(4):395-416.
- [12] CHUANG Y Y. Affinity aggregation for spectral clustering[C]// IEEE Conference on Computer Vision and Pattern Recognition. IEEE,2012:773-780.
- [13] ZELNIK-MANOR L. Self-tuning spectral clustering[J]. Advances in Neural Information Processing Systems,2004,17:1601-1608.
- [14] CHANG H,YEUNG D Y. Robust path-based spectral clustering[J]. Pattern Recognition,2008,41(1):191-203.
- [15] ZHANG X,LI J,YU H. Local density adaptive similarity measurement for spectral clustering[J]. Pattern Recognition Letters,2011,32(2):352-358.
- [16] ASUNCION A,NEWMAN D J. UCI Machine Learning Repository[EB/OL]. <http://archive.ics.uci.edu/ml>.
- [17] The MNIST database of handwritten digits[OL]. [2015-03-01]. <http://yann.lecun.com/exdb/mnist>.
- [18] ANANDKUMAR A,FOSTER D P,HSU D,et al. A Spectral Algorithm for Latent Dirichlet Allocation [J]. Algorithmica, 2015,72(1):193-214.
- [19] HETTIARACHCHI R,PETERS J F. Multi-manifold LLE learning in pattern recognition [J]. Pattern Recognition, 2015, 48(9):2947-2960.
- [20] GU L L,PENG L M. Clustering algorithm based on K nearest neighbor of relative density and manifold[J]. Computer Science, 2016,43(12):213-217. (in Chinese)
古凌岚,彭利民. 基于相对密度和流形上 k 近邻的聚类算法[J]. 计算机科学,2016,43(12):213-217.