

基于预测状态表示模型和稀疏分布记忆的多观测系统预测*

汪庆森^{1,2}, 鞠时光¹

(1. 江苏大学 计算机科学与通信工程学院, 江苏 镇江 212013; 2. 苏州大学 计算机科学与技术学院, 江苏 苏州, 215006)

摘要: 提出了一种新型的 PSR 建模方法, 该方法建立针对复杂多观测系统的近似预测模型 S-PSR, 将系统中的检验和经历依据归属关系进行归类划分, 利用稀疏分布记忆(SDM)存储结构进行模型当前状态保存和状态更新, 实现了对多观测系统复杂数据的处理。实验表明, 该近似模型相比其他模型具有更好的预测准确性。

关键词: 多观测系统; 预测状态表示; 稀疏分布记忆; 系统模型

中图分类号: TP29

文献标志码: A

文章编号: 1001-3695(2012)08-2988-03

doi:10.3969/j.issn.1001-3695.2012.08.048

Prediction of multi-observation system based on predictive state representation and sparse distribute memory

WANG Qing-miao^{1,2}, JU Shi-guang¹

(1. School of Computer Science & Communication Engineering, Jiangsu University, Zhenjiang Jiangsu 212013, China; 2. School of Computer Science & Technology, Soochow University, Suzhou Jiangsu 215006, China)

Abstract: this paper proposed a new model creation method for PSR. The method constructed the approximate prediction model for complex multi-observations system-S-PSR. The new model divided the tests and the histories for classification based on relation. Furthermore the model finished the state saving and updating by using SDM and realized the process of complex data on multi-observation system. The result shows that the proposal model is better than other model in prediction error.

Key words: multi-observation system; predictive state representation(PSR); sparse distribution memory(SDM); system modeling

预测状态表示(PSR)模型可用于表示局部可观测随机动态系统, PSR 利用一个对将来事件的预测集合来表示系统状态^[1]。当前对 PSR 的研究主要集中在利用模型来表示一个完整的系统。当所要表示的系统比较简单、观测值和动作数量有限时, PSR 可以很好地描述系统状态。但是现实中存在大量的系统, 它们有复杂的系统结构, 拥有大量的观测值和动作, 即使在同一时刻也可能同时有多个观测值存在, 同时由于数据采样问题, 所获得数据也存在一定的偏差, 这使得利用模型准确表示系统状态变得非常困难^[2]。

为了表示复杂的大规模系统, 人们提出了许多可行的方法。Talvitie 等人^[3]利用局部模型来代替整体模型表示系统状态, 每个局部模型对应一组感兴趣的预测信息, 局部模型的并集用于表示整体模型。该方法可以简化对复杂系统的学习, 但同时生成的系统模型也存在表示不完整的问题。Dinculescu 等人^[4]提出了一个统一框架来实现对复杂系统的简化, 通过对框架内映射函数的变换, 可提供对多种类型 PSR 的支持, 但是该方法没有具体讨论对多观测情况的处理。Wolfe 等人^[5]提出一个近似 PSR 模型, 它将同时刻的多观测值信息分解为一个多维向量值, 然后对每一维观测值分别进行预测, 通过计算其联合概率得到系统完整的预测信息。然而该模型需要很

强的条件假设, 这在现实环境中很难实现。

根据复杂多观测系统的特点, 本文提出了一种新型 PSR 建模思想, 将多观测系统中的检验(test)和经历(history)信息映射为对应的向量, 根据向量的分布情况确定系统各检验和经历类别归属关系, 生成一个近似预测模型 S-PSR, 再利用稀疏分布记忆(SDM)^[6]作为新模型状态保存和更新的存储结构。SDM 具有处理高维数据的能力, 同时 SDM 的大容量存储也适合保存复杂系统的大规模状态信息。

1 稀疏分布记忆

SDM 建立的初始目的是为了记忆长期经历信息。SDM 具有很强的联想容错能力, 能够对输入向量进行去噪处理并得到相对应的输出向量。和其他的记忆结构不同, SDM 不需要通过迭代过程收敛到某个目标值, 它更类似于一个前馈神经网络, 因此 SDM 也常常被应用到预测领域。

一个 SDM 可以划分成物理地址单元和存储单元两个部分。每个物理地址单元都对应一个存储单元, 其单元长度和输入向量的长度相同。当给定一个地址向量 $\mathbf{a}$ 和相应的数据向量 $\mathbf{r}$ 作为 SDM 的输入时, SDM 将计算地址向量 $\mathbf{a}$ 与每个物理地址单元的距离 d_i , 对于每个 $d_i \leq \delta$ (δ 为阈值) 的物理地址单元

收稿日期: 2012-01-29; 修回日期: 2012-03-05 基金项目: 国家自然科学基金资助项目(60773049)

作者简介: 汪庆森(1977-), 男, 浙江绍兴人, 博士研究生, 主要研究方向为模式识别、系统建模(qmwang@suda.edu.cn); 鞠时光(1955-), 男, 江苏南通人, 教授, 博导, 主要研究方向为信息安全、模式识别、空间数据库管理。

元,将数据向量 r 使用 add 操作存储到所对应的各个存储单元中。SDM 的学习模式也非常简单,对于给定一个地址向量 a ,为了获取其所对应的输出向量 s ,需要激活那些满足 $d_i \leq \delta$ 的物理地址单元所对应的存储单元,将其累加获得相应的输出向量 s 。

2 观测值选择

多观测系统在同一时刻存在多个观测值,本文将观测值变量符号定义为 O_j^i 。其中, j 表示预测所处的第 j 个时刻, i 表示所处时刻下的第 i 个观测值。假设在同一时刻 j 下存在 k 个观测值变量 $O_j^i (\tau \in [1, k])$,则可定义一个选择函数 $g^{[7]}$,表示从同一时刻的 k 个观测值变量中选取对未来预测产生影响的观测值变量,而忽略其他无关观测变量,从而降低计算的复杂度。

定义1 设存在选择函数 g :

$$g(O^i) = \begin{cases} 1 & \text{如果 } i \text{ 是与预测相关的观测} \\ 0 & \text{如果 } i \text{ 是与预测无关的观测} \end{cases}$$

假设原检验 $t = a_1 o_1^T \cdots a_k o_k^T$,将函数 g 作用于该动作—观测值序列,则有

$$g(t) = a_1 g(o_1^T) \cdots a_k g(o_k^T)$$

假定利用函数 g 选择的观测值个数为 m ,且同一时刻下的各观测值是条件独立的,令 $t' = g(t)$,则在给定经历 h 下的预测为

$$p(t'/h) = \prod_{i=1}^m p(a_i o_i^i \cdots a_k o_k^i/h)$$

3 基于 SDM 结构的 S-PSR 模型

利用函数映射关系,使系统的检验对应于统一的向量空间。依据其在向量空间中的分布状况,将属于同一空间区域内的检验归为一类,从而生成一个简化的 S-PSR 模型。利用 SDM 实现对经历的归类处理,当新的经历 h 输入时,通过比较其和 SDM 位置地址的相近度得到相关位置地址,从而计算出其对应的预测期望值。利用 SDM 还可实现模型预测向量随经历的变化而同步更新。

3.1 检验的归类学习

首先给出检验观测值量化和预测的相关定义。

定义2 设有探测函数 d ,有 $d: O^* \rightarrow V, V$ 表示为 k 维向量的集合。

定义3 对于给定经历和探测函数 d ,其检验的探测预测表示为给定经历条件下 $d(t)$ 的预测期望: $p_d(t/h) = p(t/h)d(o(t))$ 。

其中: $o(t)$ 表示在检验 t 中的观测值序列。特别当 h 为空时,令 $p_d(ao) = \theta_{ao}$ 。 θ_{ao} 表示单步观测值的预测期望。

由于条件期望值 $p_d(t/h)$ 对于相同观测目标具有相等的期望值,所以考虑利用 $p_d(t/h)$ 来代替原 S-PSR 矩阵中的 $p(t/h)$ 。如果矩阵中的两个检验 t_1, t_2 分别对于任意经历 h_1, h_2 都有相同的 $p_d(t/h)$ 值,则表示这两个检验属于同一类检验^[8]。

将所有检验的集合 T 依据其 $p_d(t/h)$ 的情况划分成若干个聚类集合 T' ,则对于每个聚类 $T_i \in T'$,有

$$\forall t_1, t_2 \in T_i, \forall h \in H, \|p_d(t_1/h) - p_d(t_2/h)\| \leq \delta$$

其中: δ 为一个实数,表示预测期望的差异度。

对于给定经历 h 的聚类 T_i 的预测,有

$$p_d(T_i/h) = \frac{1}{|T_i|} \sum_{t \in T_i} p_d(t/h)$$

在实际运用中,对于聚类 T_i 的预测,选取一个检验 t'_i , $t'_i \in T_i$,利用 $p_d(t'_i/h)$ 来近似表示聚类 T_i 的预测。所以得到在给定经历 h 情况下 S-PSR 模型检验预测向量为

$$p_d(T'/h) = [p_d(t'_1/h), p_d(t'_2/h), \dots, p_d(t'_k/h)]$$

3.2 基于 SDM 的预测向量保存和更新

假设函数 d 已知,对于给定的任意经历 h , S-PSR 模型都希望获得其所对应的 $p_d(T'/h)$ 的值。由于经历 h 和检验 t 一样都是一个动作—观测值对序列,所以 h 也可以利用函数 d 将经历转换为向量空间中的一个向量 $d(h)$ ^[9]。

利用 SDM 有效处理高维数据和强大的容错能力,可用 S-PSR 模型的预测向量来获得和更新。这里将 $d(h)$ 作为 SDM 的输入,而将 $p_d(T'/h)$ 作为输出信息。假定 SDM 的位置 L 已经给定,则对于输入 $d(h) = \langle d_1(h), \dots, d_k(h) \rangle$,需要与 $l = \langle l_1, \dots, l_k \rangle$ 比较彼此的相近度 s 为

$$s(d(h), l) = \min_{i=1, \dots, k} s_i(d_i(h), l_i)$$

$$s_i(d_i(h), l_i) = \begin{cases} 1 - \frac{|d_i(h) - l_i|}{\alpha_i} & |d_i(h) - l_i| \leq \alpha_i \\ 0 & \text{其他} \end{cases}$$

其中: $l = \langle l_1, \dots, l_k \rangle$ 表示 SDM 中的位置地址, α_i 表示在各维度上的激活半径。利用相近度计算方法,可得到 SDM 中被 $d(h)$ 激活的位置地址 $L_{d(h)}$ 。

当有训练样本 $\langle d(h), p_d(T'/h) \rangle$ 输入时,首先获得被 $d(h)$ 激活的位置地址 $L_{d(h)}$ 。令 w_m 为位置地址所对应的存储值,则利用梯度下降法可实现对 w_m 的更新为

$$w_m = w_m + \alpha \frac{s^m}{\sum_{n \in L_{d(h)}} s^n} [p_d(T'/h) - \tilde{p}_d(T'/h)] \quad \forall m \in L_{f(h)}$$

其中: $\alpha \in (0, 1)$ 为学习率, $\tilde{p}_d(T'/h)$ 为 $d(h)$ 在 SDM 的预测值,可用归一化表示为

$$\tilde{p}_d(T'/h) = \frac{\sum_{n \in L_{d(h)}} s^n w_m}{\sum_{n \in L_{d(h)}} s^n}$$

当 S-PSR 模型预测向量的条件经历由 $h \rightarrow hao$ 时,则在 SDM 中的各 w_m 也相应地更新为

$$w_m = w_m + \alpha [\varphi \tilde{p}_d(T'/h) + \theta_{ao} - \tilde{p}_d(T'/h)] \quad \forall m \in L$$

其中: $\varphi \in (0, 1)$ 表示预测期望信息的折扣率。

4 仿真实验和结果分析

本文选用模拟现实交通仿真系统来作为模型的适用领域进行实验测试。数据来源于下一代交通仿真项目 (NG-SIM)^[10,11],该项目数据来自旧金山区域内一个六车道大约 500 m 长距离上的交通信息。这是一个很大的数据集,常常被用来进行各种交通方面的分析。

实验选取在该区域中行驶的一辆汽车作为参照物,观测值信息分别来自于车前、车后和车两侧的车辆路况信息,包括其他车辆所处位置以及车辆的各方向速度情况,这些信息同步进行采样分析。观测采样范围包括车前 100 m、车后 50 m 以及两侧各 15 m 的区域。车辆速度用一个二维向量表示,包括水平速度和垂直速度信息。

本文选用 S-PSR 模型和 N 阶马尔可夫模型进行预测结果比较, $1 \leq N \leq 4$, 令 $\alpha = 0.8, \varphi = 0.2, \delta = 0.001$,使用预测的单步检验均方误差作为误差判定方法。实验使用 NGSIM I80 数据库从 7:00 ~ 7:15 的交通数据作为训练数据, 8:00 ~ 8:15 的交

通数据作为测试数据进行学习,假设在训练和测试中参照汽车匀速运行,动作选择基本保持不变。为了方便预测结果的比较,选取对车辆加速度的似然估计预测作为模型计算的实验结果。因为在已知当前时刻车辆位置和速度的情况下,利用对加速度的预测,可以很容易获得下一时刻车辆位置和速度的预测。图1显示了S-PSR模型和1~4阶马尔可夫模型的预测成功率对照情况。从图1可以看出,S-PSR模型拥有最好的预测成功率,1~3阶马尔可夫模型的预测成功率大体相当,4阶马尔可夫模型由于经历长度为4的测试数据的不完备性,导致预测成功率较低。

同时,马尔可夫模型学习依赖EM方法收敛到一个局部最优解,这个最优解很大程度上取决于初始参数的设定。初始参数的随机选择会给预测带来很大的偏差和错误率。而S-PSR模型参数学习来源于可观测值,随着样本的增加,S-PSR模型的预测趋向于平稳状态。图2的实验表明,S-PSR模型较2阶马尔可夫模型有更好的预测准确性和收敛性。




图1 平均预测成功率比较




图2 不同初始参数模型收敛性比较

5 结束语

本文针对多观测系统的特点提出了一种简化近似预测模型S-PSR,利用检验的预测期望值和SDM结构中的相近度作为模型归类的判定标准,并利用SDM的高存储能力实现系统状态的维护。同时由于S-PSR初始参数来源于实际数据的特点,在模拟现实交通仿真系统中的应用表明,S-PSR相对于其他参数设定模型具有很好的预测有效性和收敛性。

参考文献:

[1] SINGH S, JAMES M R, RUDARY M R. Predictive state representations: a new theory for modeling dynamical systems[C]//Proc of the

20th Conference on Uncertainty in Artificial Intelligence. Banff: AUAI Press, 2004: 512-519.

- [2] BOWLING M, McCracken P, JAMES M, *et al.* Learning predictive state representations using non-blind policies[C]//Proc of the 23rd International Conference on Machine Learning. New York: ACM, 2006: 129-136.
- [3] TALVITIE E, SINGH S. Simple local models for complex dynamical systems[C]//Proc of the 22nd Annual Conference on Neural Information Processing Systems. Vancouver: AUAI Press, 2008: 8-11.
- [4] DINULESCU M, PRECUP D. Approximate predictive representations of partially observable systems[C]//Proc of the 27th International Conference on Machine Learning. New York: ACM, 2010: 859-902.
- [5] WOLFE B, JAMES M R, SINGH S. Learning predictive state representations in dynamical systems without reset[C]//Proc of the 22nd International Conference on Machine Learning. New York: ACM, 2005: 980-987.
- [6] MENG Hong-ying, APIAH K, HUNTER A, *et al.* A modified sparse distributed memory model for extracting clean patterns from noisy inputs[C]//Proc of IEEE International Joint Conference on Neural Networks. Atlanta: IEEE Press, 2009: 2084-2089.
- [7] WOLFE B, JAMES M R, SINGH S. Approximate predictive state representations[C]//Proc of the 7th International Joint Conference on Autonomous Agents and Multiagent Systems. Estoril: AAAI Press, 2008: 363-370.
- [8] BOOTS B, SIDDIQI S M, GORDON G J. Closing the learning-planning loop with predictive state representations[J]. *The International Journal Robotics*, 2011, 30(7): 954-966.
- [9] WINGATE D, SINGH S. On discovery and learning of models with predictive state representations of state for agents with continuous actions and observations[C]//Proc of the 6th International Joint Conference on Autonomous Agents and Multiagent Systems. New York: ACM, 2007: 187.
- [10] TALVITIE E, SINGH S. Maintaining predictions over time without a model[C]//Proc of the 21st International Joint Conference on Artificial Intelligence. Pasadena: AAAI Press, 2009: 1249-1254.
- [11] POUPART P, VLASSIS N. Model-based Bayesian reinforcement learning in partially observable domains[C]//Proc of the 10th International Symposium on Artificial Intelligence and Mathematics. Fort Lauderdale: AUAI Press, 2008: 1035-1042.