

基于 Q 学习算法结合下的 BSO 特征选择应用实例

文培安 边晓璐 李丹

四川大学锦城学院计算机与软件学院 四川 成都 611731

【摘要】第三次信息化浪潮的掀起宣告大数据时代的来临，面对海量数据，通常利用特征选择降低干扰度，建立精确度更高的模型用以处理数据或用于机器学习。本文提到一种将强化学习算法用于蜂群优化元神经网络算法（BSO）后得到的新特征选择算法（QBSO-FS）。并将其应用到不同形状建筑物的加热负荷度检测上，QBSO-FS 算法在保证检测准确率达 98% 的情况下减少了 5 个检测特征。同时在该数据集和另外的炎症诊断数据集及客户信誉评估数据集上也对 QBSO-FS 算法与贝叶斯算法和决策树算法进行比较，检测 QBSO-FS 算法性能，同样取得了比较满意的结果。

【关键词】QBSO-FS；强化学习 Q-learning；特征选择

1 BSO-FS 算法简介

1.1 特征选择（FS）

数据集中大多存在冗余特征，建立模型时若提取到大量噪声（冗余特征），对模型的性能几乎没有帮助，甚至可能降低模型性能。特征选择^[1]本质就是由评价标准的特定性来度量进而选择要素性质优良的特征子集。通过将原始特征中的不相关特征及冗余特征去除，将有效特征保留。

1.2 BSO 算法原理

蜂群优化（BSO）元神经网络通过模拟蜜蜂觅食行为^[2]。主要参数有 maxChance（在局部搜索区域中的机会数），Flip（一个经验参数、用来其额定搜索区域的解决方案集合）。算法主要有以下步骤：1. 设定蜂群规模、循环的最大量；2. 循环搜索，每只蜜蜂先进行当前自身的全局搜索，通过自适应环境判断当前循环的最优解，若邻域的解的适应度好于现在最优解则进行将最优解进行一次更新，否则继续搜索；3. 重复步骤 2，循环直到结果收敛或达到最大循环次数，停止算法。上述蜜蜂的搜索过程即为一个优化问题，蜜蜂在搜索过程中可能在一个位置经过两次或者在确定区域内进行无效率所搜，无法确保搜索空间的良好覆盖率及结果的最优性。在 BSO 用于特征选择上，引入解的编码、拟合度两个参数。解的编码是一个长度为 n 的二进制向量，其中 n 表示特征的原始个数，如果选择了相应的特征，则将其位置置为 1，否则置为 0。

2 QBSO-FS 算法及应用

2.1 Q-learning 算法

2.1.1 主要参数

Q-learning 算法属于强化学习^[3]一列，主要有三个重要参数：

Epsilon greedy：是用于决策上的策略，例如当 Q-Table 表对最优值进行百分之 90 的选择情况下，此时的 epsilon=0.9。

Alpha：学习率，决定误差当中有多少要被学习。

Gamma：对未来所产生的期望收益 reward 的衰减值，gamma 越接近 1，机器对未来的 reward 越敏感。

2.1.2 主要原理

目前 Q-learning 的应用较为广泛，在文献^[4]中被运用到高速铁路列车的节能优化上，文献^[5]中 Q-learning 算法被应用到网络时延的自动化控制中。

Q 即为 $Q(s, A)$ ，指在某一时刻的 state 状态下，采取一个 action 动作能产生的期望收益 reward，环境会将当前状态 state 和采取的行为 action 以及奖励用来构建一张表格 Q-Table 来储存 Q，建立完成以后再根据 Q 值选取能够获得最大收益的动作。Q-learning 融合了蒙特卡洛算法思想^[6]和动态规划能够进行 off-policy（智能体）学习，在求解过程中使用到贝尔曼方程使利益最大化。

贝尔曼方程：

$$Q(s, A) = (s, A) + \alpha * (R + \gamma * \text{Max}_{A'} Q(s', A') - Q(s, A))$$

Q-learning 方法决策如下：假设当前状态为 S1（写作业），我们有两个行为 A1（玩游戏）和 A2（继续写作业），根据自己的经验（Q-Table）假设选择 A2 动作（继续写）带来的收益也更大，那么此时再次选择 A2；

表 1 S1 状态表

	A1	A2
S1	-1	1

选择动作 A2 后更新至 S2 状态 (获得 1 分奖励) ,

表 2 S2 状态表

	A1	A2
S2	-2	2

重复以上步骤得到 S3、S4、S5 等下一时刻的状态。

Q-Table 表格决策方法如下: 依据上述的假设过程, 在 S2 状态下我们对比发现 $Q(s2, A2) > Q(s2, A1)$, 这是我们在 S2 状态下获得奖励的基础上加上衰减 γ 乘较大的 $Q(s2, A2)$ 所得的结果, 需要注意的是 S2 状态是我们模拟出来的状态, 但是奖励却如实存在, 因此我们将计算 $Q(s1, A2): R + \gamma * (\text{Max}Q(s2))$ 出来的值当作 $Q(s1, A2)$ 的现实值, 而在 S1 状态下 $Q(s1, A2)$ 为虚拟值, 则该情况下差距为现实值 - 虚拟值, 因此我们就可以计算出新的 $Q(s1, A2) = Q(s1, A2) + \alpha (\text{学习率}) * \text{差距}$; 若 $\gamma = 0.5, \alpha = 0.1$, 则能得出 S1 状态 - S2 状态 Q-Table 表的更新。

表 3 状态改变 Q-Table 值更新表

原始 $Q(s1, A2)$	更新后 $Q(s1, A2)$
1	1.1

值得注意的是, 在此过程中, $\text{Max}Q(s2)$ 只是估算了 S2 的状态, S2 自身没有行为, 所以在 S2 的状态下进行决策需要等 Q-Table 表中值更新完毕以后再进行选择动作, 重复步骤。

Q-learning 算法流程图如图 1 所示:

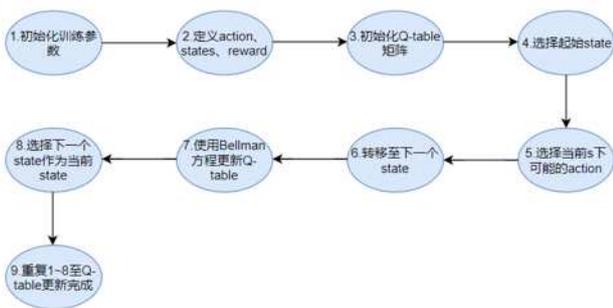


图 1 算法流程图

2.2 QBSO-FS

本文引入的 QBSO-FS 算法是将 Q-learning 算法用于跟 BSO-FS 算法进行结合, 替代 BSO 算法中蜜蜂的自适应搜索过程。Q 学习算法中的一个动作的进行就类同于从当前特征子集中添加或删除一个特征, Q 学习算法在替代蜜蜂进行局部搜索过程中将当前状态的现实值与下一个状态的最大估计值通过贝尔曼方程运算, 并将结果作为选择这一个动作产生的的奖励权重, 更新 Q 矩阵,

进而通过 Q 矩阵中奖励权重得到最大奖励的最优路径, 得到最佳的解决方案。

3 QBSO-FS 应用分析

3.1 数据集描述

该数据集由 Angeliki Xifara(土木/结构工程师)创建, 使用 Ecotect 中模拟的 12 中不同的建筑形状进行能源分析, 建筑物在玻璃面积、屋顶面积以及其他参数方面有所不同, 根据不同特征获得 768 中建筑形状以及于其对应的 8 个特征, 旨在预测不同形状建筑物真实有效地加热负荷度。8 个属性列分别是 x_1 相对紧凑度、 x_2 表面积、 x_3 壁面积、 x_4 屋顶面积、 x_5 总高度、 x_6 方向、 x_7 玻璃面积、 x_8 玻璃面积分布, 目标变量为加热负荷度。

3.2 结果分析

QBSO-FS 算法参数值对算法性能有相当大的影响。在本文的引用中通过手动调整来找到最佳的值, 使其分类准确率和运行时间都达到最佳。表 3 展示了在实例中我们所使用的参数值。

表 4 参数值

	Parameter	Value
BSO	Flip	5
	maxChance	3
	nBees	10
	maxIterations	10
	LsIterations	10
Q-Learning	α	0.9
	γ	0.1
	e	0.1

QBSO-FS 算法应用在该数据下的结果显示, QB-SO-FS 只选用了壁面积、屋顶面积和玻璃面积 3 个属性列, 数据集分类的准确率达到 98%。经过 QBSO-FS 算法有效减少 5 个冗余特征, 能帮助检测人员更直接清楚地对建筑物加热负荷程度有一个基本判断, 减少检测时间, 从而减少人员成本花销。

4 QBSO-FS 的性能检测及模型评估

4.1 与 Bayes、ID3 算法比较

为简单验证 QBSO-FS 算法泛化能力和进一步评估其性能, 我们将 QBSO-FS 算法应用到较小的膀胱炎症诊断数据集和较大的用户信誉度评估数据集两个数据集上, 数据集特征由表 4 展示。

表 5 数据集特征

名称	膀胱炎症诊断	用户信誉度评估
属性列数	6	17
数据量	120	1002

在 3 个数据集上我们应用了 QBSO-FS, Bayes 和 ID3 算法, 得到结果如表 5 及图 2 所示。

表 6 不同算法结果对比

	Bayes	ID3	QBSO-FS
膀胱炎症诊断准确率	87.5%	100%	100%
建筑物加热负荷度准确率	85.71%	98.7%	98.05%
用户信誉度评估准确率	73.63%	77.61%	78.02%
三个数据集上分别选用特征数	6、8、17	6、8、17	4、3、5

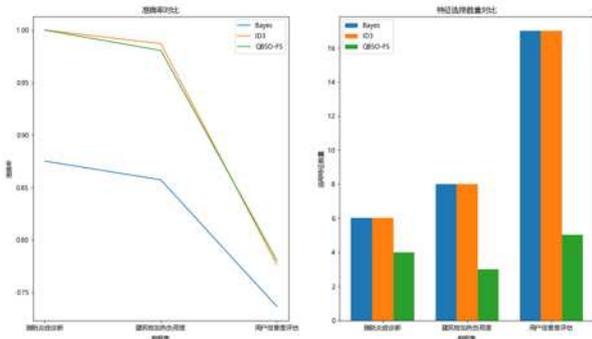


图 2 不同算法结果对比

结果显示在实例中任一数据集上 QBSO-FS 算法都能够有效的发现冗余特征并不做选择, 同时得到与其他算法相当的准确度, Bayes 算法在实例中的数据集上表现差于 ID3 算法和 QBSO-FS 算法, 需要说明的是我们并未对 Bayes 算法进行调参优化, 不能否定该算法的性能。在建筑物加热负荷度数据集上 ID3 算法的准确率略高于 QBSO-FS 算法, 但从整理来看 QBSO-FS 算法是优于 Bayes 算法和 ID3 算法。3 个算法在膀胱炎症数据集上表现都不错且 QBSO-FS 算法在该数据集上发现的冗余特征明显少于另外两个数据集, 膀胱炎症数据集是由医学专家整理用于判断患者是否患病, 数据具有高度准确性这一点不难解释上述问题。

4.2 浅析模型存在不足

在运行过程中我们发现 QBSO-FS 算法在执行 Q-learning 寻找最优解过程中会花费大量时间, 导致算法整体运行时间低于 ID3 算法和 Bayes 算法, 我们认为问题产生主要原因可能是因为执行 Q-learning 算法所需要的 Q-Table 表在通常状态下都是很大的, 查找和储存都需要消耗大量的时间和空间。在分析过程中我们还发现 Q-learning 算法还可能存在过高估计的问题, 因为 Q-learning 在更新 Q 函数的时候使用的是下一时刻最优值对应的 action 并用贝尔曼方程计算来当作这一时刻

的现实值, 这样就会可能导致“过高”地估计采样过的 action, 而对于没有采样到的 action, 便不会被选择为最优的 action。

4.3 未来可能应用方向

在本文叙述中, QBSO-FS 算法在建筑物加热负荷度检测、膀胱炎症诊断、用户信誉度评估上都能减少冗余特征, 加快检测效率。在医疗行业, 患者病情诊断上, 可以以 QBSO-FS 提供的有效特征来进行相应的医学检测, 避免患者小病大查的恐医情绪; 在产品检验中, 同样以 QBSO-FS 所提供的特征来进行检测, 跳过不必要步骤, 大大减少成本投入。

5 结语

本文对提到的 QBSO-FS 算法中 Q 强化学习算法进行了较为细致的讲解, 旨在理解替代蜂群优化元神经网络算法 (BSO) 中蜜蜂的自适应局部搜索过程。在实例运用中不难看出 QBSO-FS 算法具有明显的减少特征选择数量的优点, 在实际应用中能减少检测时间, 但 QBSO-FS 算法的泛化能力还需要进一步的验证, 在未来工作上本文将对所提到可能存在的问题进行进一步分析, 并执行更深入的调参优化, 将其运用到更大的数据集上。

【参考文献】

- [1]Blum, A.L., Langley, P.: Selection of relevant features and examples in machine learning. *Artif. Intell.* 97(1 - 2), 245 - 271 (1997)
- [2]Sadeg, S., Hamdad, L., Benatchba, K., Habbas, Z.: BSO-FS: bee swarm optimization for feature selection in classification. In: Rojas, I., Joya, G., Catala, A. (eds.) *IWANN 2015. LNCS*, vol. 9094, pp. 387 - 399. Springer, Cham (2015).
- [3]Wauters, T., Verbeeck, K., De Causmaecker, P., Berghe, G.V.: Boosting metaheuristic search using reinforcement learning. In: Talbi, E.G. (ed.) *Hybrid Metaheuristics. SCL*, pp. 433 - 452. Springer, Heidelberg (2013)
- [4]张森, 张琦, 张梓轩. 基于 Q 学习算法的高速铁路列车节能优化研究 [J]. *铁道运输与经济*, 2019, 41(12):111-117.
- [5]荆荣丽, 葛书荣, 王鹏, 宁玉文. 基于强化学习的网络时延自动化控制数学建模研究 [J]. *自动化与仪器仪表*, 2020(03):57-59.
- [6]陆颖刚, 陈泉静, 黄邦华, 张海波. 基于蒙特卡洛模型的出租车上车点设置 [J]. *台州学院学报*, 2020, 42(03):17-22.