

基于 CBAM 注意力机制的智能交通信号控制

于贺婷, 刘思萌, 文峰

(沈阳理工大学 信息科学与工程学院, 沈阳 110159)

摘要: 针对智能交通系统存在的卷积神经网络特征提取能力弱和特征表达能力有待提升等问题, 在深度双 Q 网络(double deep Q network, Double DQN)模型基础上提出一种基于卷积注意力模块(convolutional block attention module, CBAM)的深度强化学习模型, 用于智能交通信号控制。在三维卷积神经网络中加入 CBAM 轻量注意力模块, 通过通道注意力和空间注意力两个模块结构更好地捕捉特征之间的相互依赖关系, 增强卷积神经网络的特征表示质量, 从而提升对拥堵路段重点特征的关注度以缓解交通拥堵问题。在城市交通仿真器 SUMO(simulation of urban mobility)上的实验结果表明, 相较其他常用算法, 本文算法提高了交通灯配时的效率和稳定性, 可为交通配时优化技术提供可靠依据。

关键词: 交通信号控制; 深度强化学习; 深度双 Q 网络; 卷积注意力模块

中图分类号: TP391.9 **文献标志码:** A **DOI:**10.3969/j.issn.1003-1251.2024.05.006

Intelligent Traffic Control Technology Based on CBAM Attention Mechanism

YU Heting, LIU Simeng, WEN Feng

(Shenyang Ligong University, Shenyang 110159, China)

Abstract: A deep reinforcement learning model is proposed based on the double deep Q network (Double DQN) model, using the convolutional block attention module (CBAM) to address issues such as weak feature extraction capabilities and limited feature expression in convolutional neural networks within intelligent transportation systems. By integrating the lightweight CBAM attention module into the 3D convolutional neural network, the model can better capture the interdependencies between features through the channel attention and spatial attention modules. This enhances the quality of feature representation in the convolutional neural network, thereby improving the focus on key features of congested road sections and alleviating traffic congestion. Experimental results conducted on the SUMO (simulation of urban mobility) urban traffic simulator demonstrate that the proposed algorithm improves the efficiency and stability of traffic signal timing compared to other commonly used algorithms, providing a reliable basis for traffic timing optimization technology.

Key words: traffic signal control; deep reinforcement learning; deep double Q network; convolutional block attention module

收稿日期: 2023-09-13

基金项目: 国家重点研发计划“社会治理与智慧社会科技支撑”重点专项(2022YFC3302502)

作者简介: 于贺婷(1997—), 女, 硕士研究生; 文峰(1977—), 通信作者, 男, 教授, 博士, 研究方向为大数据分析技术、机器学习、进化计算、智能交通等。

随着我国城市化进程不断深入,驾车出行成为人们的主流出行方式。目前有限的道路空间无法保证日益增多的车辆畅通无阻,这将导致城市交通陷入严重拥堵的困境。城市交通拥堵问题在居民日常生活中产生了较大的负面效应,已经作为一个关键的社会问题引起了我国政府和人民的高度关注。

近年来,智能交通系统^[1]的应用在一定程度上缓解了城市道路交通压力,人工智能算法与智能交通系统相结合的研究也逐渐完善,其中强化学习^[2]算法最为典型。在学习数据以及智能体和环境的互动过程中,强化学习注重权衡探索与利用的关系以形成最佳的决策方案。深度强化学习^[3]将深度学习的感知能力和强化学习的决策能力相结合,实现对复杂任务的高效控制,越来越多的深度强化学习算法应用于交通灯配时技术并取得了一定的成果^[4]。Chu等^[5]首次在自适应交通信号控制的背景下,提出了一种可扩展的多智能体深度强化学习算法。刘智敏等^[6]针对交叉口状态的动态改变,提出了一种优化的深度强化学习算法用于单一交叉口交通信号控制。深度强化学习算法仍有一定的局限性和不足,如模型参数增多带来信息过载的问题,即当模型的参数数量增加时,模型需要处理更多的信息,导致计算和存储成本增加、模型性能下降。

注意力机制的应用可以帮助模型从大量的输入信息中提取出对当前任务更有价值的信息,以减少对其他信息的关注,甚至会将不相关信息过滤掉,以此来解决信息过载问题,并提高任务处理的效率和准确性。Wang等^[7]使用卷积注意力模块(convolutional block attention module, CBAM),在通道和空间两个方面的双重注意力机制推动下,对检测特征进行选择优化,获得了良好的感知效果。本文针对现有算法存在的问题,在深度双Q网络模型(double deep Q network, Double DQN)基础上,提出一种基于CBAM的深度强化学习模型,用于智能交通信号控制。利用CBAM提高三维卷积神经网络对交通特征的提取能力,使神经网络重点关注某些特征通道,拥挤程度比较严重的交叉口得到更高的关注度,进而有效减少在交叉口处车辆平均等待时间和路网车辆等待数。

1 基于CBAM注意力机制的交通信号控制模型

1.1 交通路网的预处理

在卷积神经网络中,感受野指经过卷积运算

后输出层的每个像素点对应输入图上的区域大小。像素在图像中具有自然的顺序,这种空间顺序的规律性可以被传统的卷积神经网络所利用,道路在路网中的状态并不具有确定的空间位置关系。因此,本研究将感受野的移动路径按照自然的顺序进行设计,以此来获取特征,即将路网中道路状态转换为具有一定顺序和关联性的感受野,以充分挖掘道路状态之间的空间联系。

路网预处理过程如下。

1) 确定感受野的质心

为将交通路网的状态数据输入神经网络模型进行处理,本文将路网划分为多个感受野,使用K-means聚类算法^[8]确定路网中多个感受野的质心,即感受野的中心结点。首先采用随机选择策略在路网中标定K个结点,将其设为聚类的初始中心;然后计算每个交叉口与所有子聚类中心的欧氏距离,如某一交叉口结点距离某个聚类中心最近,则将该结点划分到这个聚类中心所在的簇,并重新计算该簇的质心;多次循环上述过程,如果新的质心与之前质心不是同一个,则将新质心更新为聚类中心,如果质心更新前后相同,则K-means聚类算法循环结束,感受野的质心计算完成。

2) 建立路网的感受野

根据确定的多个感受野质心,利用宽度优先搜索算法(BSF)^[9]遍历交通环境中的所有入边和出边车道,建立质心邻域,即感受野,如图1所示。构建多个具有重叠性质的感受野不只使感受野间存在特定的关联性,也确保了智能体对交通路网环境中全局时间特征和空间特征的感知。



图1 感受野的建立

Fig. 1 Establishment of receptive field

3) 感受野的规范化

规范化是为感受野的特征施加顺序,从而使特征以线性的顺序从无序空间映射到有序的特征矩阵向量空间,即将每个感受野规范化为可以输

入到卷积神经网络进行处理的密度矩阵。

4) 计算多个特征矩阵

分别计算入边和出边车道的车辆密度、入边和出边车道的平均速度四个特征矩阵,即交通路网环境的状态,作为深度强化学习模型的输入。

假设路网中有 q 条道路,共有 m 台车辆,每条车道长度为 l ,每辆车的长度为 h , t 时间间隔内通过某道路的车辆数为 n ,则车辆密度 d 的计算式为

$$d = \frac{m \times h}{q \times l} \quad (1)$$

车辆平均速度 v 的计算式为

$$v = \frac{n \times l}{t} \quad (2)$$

1.2 CBAM

CBAM 属于轻量级的注意力模块,是一种混合域注意力机制,可以自适应调整全局中各个特征的权重,使模型在节约参数和计算力的基础上,能够将更多的注意力用于交通路网中具有重要影响的特征和区域,即交通拥挤路段。相较于 SENet 注意力机制^[10] 只关注通道维度, CBAM 将注意力拓展为通道和空间两个维度,并在这两个维度上实行注意力机制,以获得更优的结果。在网络结构中, CBAM 将平均池化与最大池化相结合,可以弥补在只使用平均池化过程中缺失的信息。

CBAM 包括通道注意力机制和空间注意力机制两部分内容,具体结构如图 2 所示。相关计算过程表示如下。

$$F' = M_c(F) \otimes F \quad (3)$$

$$F'' = M_s(F') \otimes F' \quad (4)$$

式中: F 表示输入的特征图; \otimes 为乘元素; F' 表示通过通道注意力获得的新特征,作为空间注意力的输入; F'' 表示经过空间注意力后得到的新特征; $M_c(\cdot)$ 表示经过池化后生成的一维通道注意力; $M_s(\cdot)$ 表示经过池化后生成的二维空间注意力。

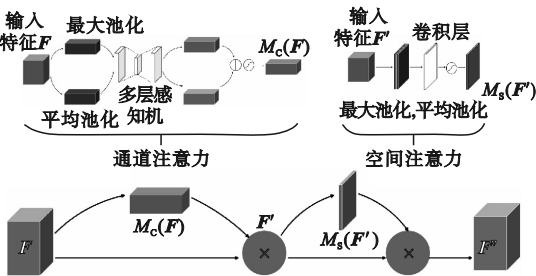


图2 CBAM 注意力机制结构

Fig.2 CBAM attention mechanism structure

为使神经网络重点关注有意义的特征,通道

注意力模块将特征传入全局平均池化层和全局最大池化层中,平均池化层可以提取所有的特征信息,最大池化层会保留权重最大的特征。将得到的两个特征分别送入多层感知机神经网络 (MLP),通过共享两层神经网络、ReLU 激活函数和 Sigmoid 激活函数的组合网络结构,将特征向量融合在一起,利用特定的计算方法产生最后的通道注意力特征。具体计算表达式为

$$M_c(F) = \sigma(\text{MLP}(\text{AverPool}(F)) + \text{MLP}(\text{MaxPool}(F))) \\ = \sigma(W_1(W_0(F_{\text{avg}}^C)) + W_1(W_0(F_{\text{max}}^C))) \quad (5)$$

式中: σ 为 Sigmoid 激活函数; MLP 表示多层感知机; AverPool(\cdot) 表示平均池化; MaxPool(\cdot) 表示最大池化; W_0 与 W_1 为感知机的权重系数; F_{avg}^C 代表经过平均池化层得到的特征图; F_{max}^C 代表经过全局最大池化层得到的特征图。

空间注意力模块使神经网络重点关注输入特征图中具有重要意义区域,该模块将经通道注意力模块处理后得到的特征分别进行沿通道维度的平均池化和最大池化,得到特征宽度和高度大小不变、通道特征均压缩为单一特征的两个通道描述,将这两个描述按通道进行拼接之后,通过一个卷积层的降维处理,并通过 Sigmoid 激活函数生成空间注意力特征,使得网络的关注点集中在关键区域。计算表达式为

$$M_s(F) = \sigma(f^{7 \times 7}([\text{AverPool}(F); \text{MaxPool}(F)])) \\ = \sigma(f^{7 \times 7}([F_{\text{avg}}^S; F_{\text{max}}^S])) \quad (6)$$

式中: $f^{7 \times 7}$ 表示 7×7 卷积; F_{avg}^S 及 F_{max}^S 分别表示沿通道方向经平均池化层和全局最大池化层得到的特征图。

1.3 三维卷积神经网络

本文采用三维卷积神经网络结构对路网环境的时间特征和空间特征进行准确提取和感知,该结构由输入层、特征提取层和输出层三部分组成,如图 3 所示。

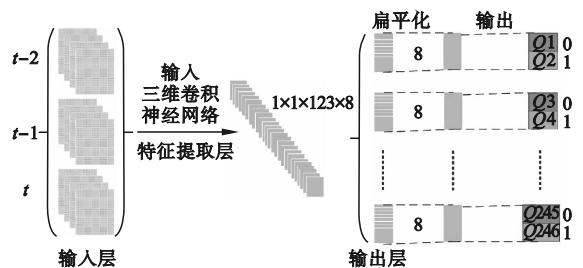


图3 三维卷积神经网络结构

Fig.3 3D convolutional neural network structure

输入层包含三个历史连续时间片段的多个三维特征矩阵,每个时间片段收集了入边和出边车道的车辆密度、入边和出边车道的车辆平均速度四个特征信息数据;特征提取层利用三维卷积神经网络感知状态特征,其结构由八层不同大小卷积核和不同步长的卷积模块以及 3 个 CBAM 模块构成,如图 4 所示。



图 4 特征提取层结构

Fig. 4 Feature extraction layer structure

输出层将特征提取层的 123 个 $1 \times 1 \times 8$ 卷积经过全连接层及扁平化处理,得到交通路网经过训练后的 123 组 Q 值(代表动作为 0 或 1),对应 123 组交通灯的最佳动作决策,即输出用于设置仿真器中交叉路口的信号相位。0 表示相位一,即南北方向的交通灯为绿灯、东西方向的交通灯为红灯;1 表示相位二,即东西方向的交通灯为绿灯、南北方向的交通灯为红灯。

1.4 基于 CBAM 注意力机制的深度强化学习模型

强化学习在控制系统中表现良好,深度神经网络已成功用于提高强化学习对复杂任务的学习能力。本文使用 Double DQN 算法^[11],将卷积神经网络模型和强化学习的 Q-learning 算法相结合,弥补强化学习在解决智能交通信号控制问题时带来的学习空间过大、学习速率缓慢、算法收敛困难等缺陷,提出一种基于 CBAM 的深度强化学习模型。将混合域注意力机制 CBAM 加入到三维卷积神经网络中,通过自适应学习,使神经网络重点关注某些特征通道,拥挤程度比较严重的交叉口得到更高的关注度,从而更有效地优化交通信号的配时。

本文模型结构由策略网络模块、目标网络模块、经验池及环境四部分组成,四个模块协同组成基于 CBAM 注意力机制的智能交通信号控制模型,其结构如图 5 所示,图中 CNN 表示卷积神经网络。模型主要运行过程如下。

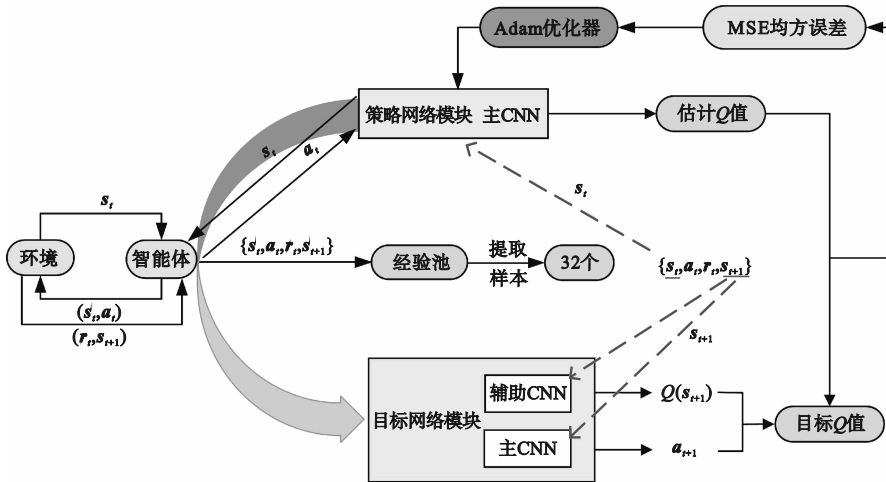


图 5 基于 CBAM 注意力机制的交通信号控制模型

Fig. 5 Traffic signal control model based on CBAM attention mechanism

1) 动作决策过程

深度强化学习模型接收智能体预处理后的路网状态,并利用贪婪策略的探索-利用机制对路

网状态数据信息进行处理。在预训练阶段,策略网络随机输出动作,在正式训练过程中,智能体将状态输入策略网络中进行感知,经过训练得到动

作,最后向智能体返回最佳的动作决策,完成交通信号配时。在每个时间步,将当前时刻(t)的状态 s_t 、动作 a_t 、奖励值 r_t 、下一时刻($t+1$)的路网状态 s_{t+1} 存入经验池中。

2) 参数更新过程

在正式训练阶段,每经过4个时间步更新一次策略网络模块和目标网络模块的权重参数。先从经验池中随机抽取一定数量的样本,将当前时刻的状态值 s_t 输入策略网络中得到估计 Q 值,再将下一时刻的状态 s_{t+1} 输入目标网络中训练得到 Q 值以及预测的下一时刻动作 a_{t+1} 。目标 Q 值计算表达式为

$$Q^*(s_{t+1}, a_{t+1}) = r_t + \gamma \max_a Q(s_{t+1}, a_{t+1}; w^-) \quad (7)$$

式中: $Q^*(s_{t+1}, a_{t+1})$ 表示目标 Q 值; γ 为折扣因子; w^- 代表目标网络的参数权重; $Q(s_{t+1}, a_{t+1}; w^-)$ 表示经过参数权重为 w^- 的目标网络训练得到的 Q 值。

将得到的估计 Q 值和目标 Q 值计算均方误差(MSE),并通过 Adam 优化器来更新策略网络的参数,在一定时间间隔后,策略网络将参数传递给目标网络。值得注意的是,两个网络具有相同的结构,均为带有 CBAM 的深度神经网络结构。

2 仿真实验过程及结果分析

本文使用 SUMO(simulation of urban mobility)交通仿真平台^[12]进行实验。SUMO 是一个开源、微观、多模态交通仿真模拟软件,可以模拟包含大量车辆和特定交通需求的道路网络,其中车辆、道路和交叉口均有明确的模型。车辆模型包括车辆的 ID、长度、宽度等属性;道路模型包括道路 ID、车道长度、车道数量等属性;道路交叉口包括交叉口 ID、有无信号灯控制、交叉口的物理坐标等属性。本文路网状态、反馈值和评价参数均由 SUMO 提供数据并经过计算得到。

本文仿真实验采用如下两个评价指标。

1) 路网中车辆平均等待时间:对每辆车计时,自车辆进入交叉路口的入边车道开始,直至车辆离开出边车道计时结束,计算所有车辆的通过时长,并取平均值,即为车辆平均等待时间。

2) 路网车辆等待数:当路网中产生拥堵时,路网中车辆数目将会增多,统计在设定的固定绿灯时长内交通路网整体聚集的车辆总数量,即为路

网车辆等待数。

2.1 实验参数及实验过程

本文实验在 Windows Server 2016 Standard 下进行仿真,CPU 为 Intel(R)Xeon(R)CPU E5-2640 v3 @ 2.60 GHz,总体深度强化学习模型基于 Tensorflow 框架实现。设定参数如下:衰减率为 0.99,Adam 优化器学习率为 0.001,经验池的容量为 500,每次从经验池采样的样本数量为 32,绿灯时长为 10 s,多通道的时间片段数量为 3,每个时间片段有 4 个矩阵,分别记录不同时刻入边、出边道路的车辆密度和车辆平均速度,时间片段间隔为 4 s。实验共训练 20 000 时间步:预训练阶段为 5 000 步,正式训练阶段为 15 000 步。仿真实验路网的感受野数量为 25,每个感受野大小为 5×5 ,路网设 160 个交叉路口,其中 123 个路口有交通灯,共 11 个出车对,每个出车对设置固定的出车起点和终点,每个出车对起点处以 6.67 s^{-1} 的固定频率发出一辆车。SUMO 仿真器通过模拟实际交通网络并设置相关参数实现交通仿真,反映真实的交通拥堵状态。

本文提出的深度强化学习模型每个时间步从 160 个结点的仿真路网环境收集 7 500 个实时状态特征,通过深度强化学习模型感知并输出 123 个动作相位,每次更新模型权重的总参数量为 111 384 B,计算 3 936 个奖励值、7 872 个 Q 值。在上述硬件实验条件下,每个时间步模型感知状态并输出最优动作仅需 0.03 s。

2.2 损失函数

损失函数为预测值与目标值之间的差值,本文使用均方误差损失,将策略网络模块的输出值作为预测值,目标网络模块的输出值作为目标值。本实验正式训练中每 4 个时间步记录一次损失函数,结果如图 6 所示。由图 6 可知,随着时间步递增,损失函数值逐渐减小并趋于稳定,表明模型收敛。

2.3 对比实验

为证明本文基于 CBAM 的智能交通控制模型的稳定性,将本文模型(用 Double DQN + CBAM 表示)与基于交通路网状态感知的深度强化学习模型(用 Double DQN 表示)^[13]以及基于 SENet 的交通信号控制模型(用 Double DQN + SENet 表示)^[14]进行训练,并在相同的实验参数下完成对比实验,每 100 s 记录一次,结果如图 7 和图 8 所示,具体实验数据如表 1 所示。




图 6 损失函数

Fig. 6 Loss function

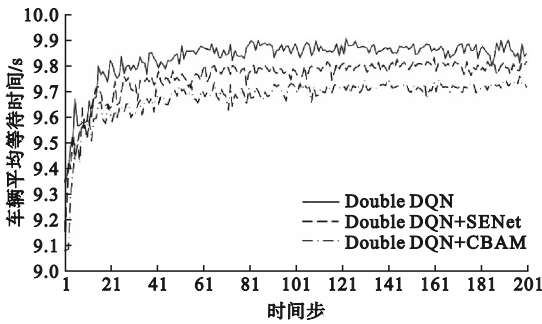


图 7 不同模型的车辆平均等待时间

Fig. 7 Average waiting time of vehicles of different models




图 8 不同模型的路网车辆等待数

Fig. 8 Number of vehicles in the road network of different models

表 1 不同模型对比实验结果

Table 1 Comparison of experimental results of different models

模型	车辆平均等待时间/s	路网车辆等待数/辆
Double DQN	9.830	2 202
Double DQN + SENet	9.756	1 928
Double DQN + CBAM	9.678	1 700

由图 7 和图 8 可见:随着训练时间步的增多,三个模型的两个指标均逐渐增大并趋于稳定;本文基于 CBAM 的智能交通控制模型的车辆平均等待时间和路网车辆等待数低于其他两种模型。由表 1 可知:随着仿真实验中路网环境与智能体的不断交互,交通路网情况逐渐复杂,本文方法对缓解交通拥挤情况的效果良好。与基于 Double DQN 的交通路网感知模型相比较,车辆平均等待时间减少了 0.152 s,即 1.55%,路网车辆等待数减少了约 502 辆,即 22.8%;与基于 SENet 注意力机制的交通信号控制模型相比较,路网车辆等待数平均减少了约 228 辆,即 11.8%,车辆平均等待时间减少了 0.078 s,即 0.8%。

3 结论

为提高卷积神经网络对交通环境中特征的提取能力,并使其对拥挤程度比较严重的交叉路口有更高的关注度,提出了一种基于混合域注意力机制 CBAM 的智能交通信号控制方法。对比实验结果表明,本文方法在减少车辆平均等待时间和路网车辆等待数方面的效果较好,模型的训练效果和实施性能比较突出,可以实现交通信号灯的实时优化。本文结果可为智能城市交通系统的相关研究提供参考,也证实了深度强化学习和智能交通系统在大型交通路网中的实用性和稳定性。

参考文献 (References):

[1] 艾峰. 城市智能交通系统的发展现状与趋势[J]. 智能城市, 2021, 7(20): 140 - 141.
 AI F. Development status and trend of urban intelligent transportation system [J]. Intelligent City, 2021, 7 (20) : 140 - 141. (in Chinese)

[2] EL-TANTAWY S, ABDULHAI B, ABDELGAWAD H. Multi-agent reinforcement learning for integrated network of adaptive traffic signal controllers (MARLIN-ATSC): methodology and large-scale application on downtown Toronto [J]. IEEE Transactions on Intelligent Transportation Systems, 2013, 14 (3) : 1140 - 1150.

[3] 杨思明, 单征, 丁煜, 等. 深度强化学习研究综述 [J]. 计算机工程, 2021, 47 (12) : 19 - 29.
 YANG S M, SHAN Z, DING Y, et al. Survey of research on deep reinforcement learning [J]. Computer Engineering, 2021, 47 (12) : 19 - 29. (in Chinese)

[4] LIANG X Y, DU X S, WANG G L, et al. A deep reinforcement learning network for traffic light cycle control [J]. IEEE Transactions on Vehicular Technology, 2019, 68 (2) : 1243 - 1253.

[5] CHU T S, WANG J E, CODECA L, et al. Multi-agent deep reinforcement learning for large-scale traffic signal control

- [J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(3): 1086 - 1095.
- [6] 刘智敏, 叶宝林, 朱耀东, 等. 基于深度强化学习的交通信号控制方法[J]. 浙江大学学报(工学版), 2022, 56(6): 1249 - 1256.
- LIU Z M, YE B L, ZHU Y D, et al. Traffic signal control method based on deep reinforcement learning[J]. Journal of Zhejiang University (Engineering Science), 2022, 56(6): 1249 - 1256. (in Chinese)
- [7] WANG S H, FERNANDES S L, ZHU Z, et al. AVNC: attention-based VGG-style network for COVID-19 diagnosis by CBAM[J]. IEEE Sensors Journal, 2022, 22(18): 17431 - 17438.
- [8] 郭永坤, 章新友, 刘莉萍, 等. 优化初始聚类中心的 K-means 聚类算法[J]. 计算机工程与应用, 2020, 56(15): 172 - 178.
- GUO Y K, ZHANG X Y, LIU L P, et al. K-means clustering algorithm of optimizing initial clustering center[J]. Computer Engineering and Applications, 2020, 56(15): 172 - 178. (in Chinese)
- [9] TRIPATHY H K, MISHRA S, THAKKAR H K, et al. CARE: a collision-aware mobile robot navigation in grid environment using improved breadth first search[J]. Computers & Electrical Engineering, 2021, 94: 107327.
- [10] 张力. 基于注意力机制的短时交通流预测方法研究[D]. 湖州: 湖州师范学院, 2022.
- [11] 汪晨曦, 赵学艳, 郭新. 基于权重值的竞争深度双 Q 网络算法[J]. 南京信息工程大学学报(自然科学版), 2021, 13(5): 564 - 570.
- WANG C X, ZHAO X Y, GUO X. Weighted dueling double deep Q-network[J]. Journal of Nanjing University of Information Science & Technology (Natural Science Edition), 2021, 13(5): 564 - 570. (in Chinese)
- [12] 崔居福, 胡本旭, 夏辉, 等. SUMO 平台上多种车辆跟驰模型的仿真对比分析[J]. 重庆大学学报, 2021, 44(7): 43 - 54, 98.
- CUI J F, HU B X, XIA H, et al. Comparative analysis of simulation of multi-car-following models under SUMO platform[J]. Journal of Chongqing University, 2021, 44(7): 43 - 54, 98. (in Chinese)
- [13] 胡小光, 胡晓杰. 基于交通路网状态感知的交通信号配时优化技术[J]. 河南科技, 2021, 40(16): 18 - 21.
- HU X G, HU X J. Traffic signal timing optimization based on traffic network state perception[J]. Henan Science and Technology, 2021, 40(16): 18 - 21. (in Chinese)
- [14] 黄思萌, 王梅, 杨晨. 基于注意力机制的交通信号控制技术[J]. 信息技术与信息化, 2023(3): 93 - 96.
- HUANG S M, WANG M, YANG C. Traffic signal control technology based on attention mechanism[J]. Information Technology and Informatization, 2023(3): 93 - 96. (in Chinese)

(责任编辑: 宋颖韬)

(上接第 33 页)

- [4] 李永建, 栗浩森, 耿惠, 等. 钕铁硼永磁材料在过热失磁条件下的磁滞损耗测试与分析[J]. 中国电力, 2020, 53(10): 50 - 57.
- LI Y J, LI H S, GENG H, et al. Measurement and analysis of hysteresis loss of Nd-Fe-B permanent magnet under superheated loss of magnetism[J]. Electric Power, 2020, 53(10): 50 - 57. (in Chinese)
- [5] 姜佳宁. 表贴式高速永磁同步电机失磁故障特性及磁体选区渗重稀土研究[D]. 哈尔滨: 哈尔滨理工大学, 2023.
- [6] 付兴贺, 江政龙, 吕鸿飞, 等. 电励磁同步电机无刷励磁与转矩密度提升技术发展综述[J]. 电工技术学报, 2022, 37(7): 1689 - 1702.
- FU X H, JIANG Z L, LÜ H F, et al. Review of the brushless excitation and torque density improvement in wound field synchronous motors[J]. Transactions of China Electrotechnical Society, 2022, 37(7): 1689 - 1702. (in Chinese)
- [7] 张博文, 莫英东, 王晗钰, 等. 基于 GRU-CNN 的双馈风力发电机电刷滑环电弧故障诊断[J]. 农业装备与车辆工程, 2023, 61(8): 45 - 50.
- ZHANG B W, MO Y D, WANG H Y, et al. Fault diagnosis of doubly-fed induction generator brush ring based on GRU-CNN[J]. Agricultural Equipment & Vehicle Engineering, 2023, 61(8): 45 - 50. (in Chinese)
- [8] 蒋晓东, 石征锦. 磁阻转子定子电励磁无刷同步电机电磁特性分析[J]. 微特电机, 2022, 50(7): 14 - 18.
- JIANG X D, SHI Z J. Electromagnetic characteristics analysis of stator electrically excited brushless synchronous motor with reluctance rotor[J]. Small & Special Electrical Machines, 2022, 50(7): 14 - 18. (in Chinese)
- [9] 蒋晓东, 王秀平. 笼条对磁阻转子电励磁同步电机性能影响[J]. 电机与控制应用, 2023, 50(2): 7 - 12.
- JIANG X D, WANG X P. Effect of cage bar on performance of electrically excited synchronous motor with reluctance rotor[J]. Electric Machines & Control Application, 2023, 50(2): 7 - 12. (in Chinese)
- [10] ZHANG F G, JIA G L, ZHAO Y W, et al. Simulation and experimental analysis of a brushless electrically excited synchronous machine with a hybrid rotor[J]. IEEE Transactions on Magnetics, 2015, 51(12): 1 - 7.
- [11] JIA G L, ZHANG F G, ZHAO Y W, et al. Magnetic field modulation mechanism and characteristic simulation of electrically excited brushless synchronous machine[C]// 2014 IEEE Conference and Expo Transportation Electrification Asia-Pacific (ITEC Asia-Pacific). Beijing: IEEE, 2014: 1 - 6.
- [12] 胡堃, 邓先明, 何凤有. 新结构无刷电励磁同步电机设计与分析[J]. 电机与控制学报, 2014, 18(1): 86 - 91.
- HU K, DENG X M, HE F Y. Design and analysis of novel structural brushless electrically excited synchronous motor[J]. Electric Machines and Control, 2014, 18(1): 86 - 91. (in Chinese)
- [13] 张凤阁, 贾广隆, 郑阳, 等. 无刷电励磁同步电机不同转子结构的对比分析[J]. 电工技术学报, 2016, 31(7): 40 - 49.
- ZHANG F G, JIA G L, ZHENG Y, et al. Comparison of brushless electrically excited synchronous machine with different rotor structures[J]. Transactions of China Electrotechnical Society, 2016, 31(7): 40 - 49. (in Chinese)
- [14] 诸自强, 周严鉴. 定子电励磁同步电机的新进展[J]. 电气工程学报, 2015, 10(4): 11 - 25.
- ZHU Z Q, ZHOU Y J. Recent development in stator wound field synchronous machines[J]. Journal of Electrical Engineering, 2015, 10(4): 11 - 25. (in Chinese)
- [15] 郑阳. 无刷电励磁同步电机损耗分析与温度场计算[D]. 沈阳: 沈阳工业大学, 2016.
- [16] 王凤翔, 张凤阁. 磁场调制式无刷双馈交流电机[M]. 长春: 吉林大学出版社, 2004.

(责任编辑: 和晓军)