

基于深度强化学习的实时交通流量预测与优化

于骐嘉

辽宁科技大学, 中国·辽宁 鞍山 114051

摘要: 随着城市化进程的加速, 交通拥堵问题日益严重, 影响了人们的出行效率。为解决这一问题, 基于深度强化学习的实时交通流量预测与优化技术应运而生。论文探讨了如何利用深度学习和强化学习的结合, 实现对交通流量的精准预测和优化控制。通过构建基于深度强化学习的预测模型, 利用历史交通数据进行训练, 提高预测的准确性, 并据此优化交通信号控制、路网布局等, 有效缓解交通拥堵, 提升交通效率。实验结果表明, 该方法在实际交通管理中具有较高的实用性和普适性。

关键词: 深度强化学习; 交通流量预测; 交通优化; 强化学习; 智能交通系统

Real Time Traffic Flow Prediction and Optimization Based on Deep Reinforcement Learning

Qijia Yu

University of Science and Technology Liaoning, Anshan, Liaoning, 114051, China

Abstract: With the acceleration of urbanization, traffic congestion has become increasingly severe, affecting people's travel efficiency. To address this issue, real-time traffic flow prediction and optimization techniques based on deep reinforcement learning have emerged. The paper explores how to use the combination of deep learning and reinforcement learning to achieve accurate prediction and optimized control of traffic flow. By constructing a prediction model based on deep reinforcement learning and training it with historical traffic data, the accuracy of predictions can be improved. Based on this, traffic signal control and road network layout can be optimized to effectively alleviate traffic congestion and enhance traffic efficiency. The experimental results show that this method has high practicality and universality in practical traffic management.

Keywords: deep reinforcement learning; traffic flow prediction; traffic optimization; reinforcement learning; intelligent transportation system

0 前言

交通拥堵已成为现代城市面临的一项严峻挑战。随着城市化进程的加速和人口的不断增长, 城市交通需求急剧增加, 而道路、公共交通等基础设施的建设速度往往难以跟上这一需求增长的步伐。特别是在高峰时段, 交通拥堵现象尤为严重, 不仅影响了人们的日常出行效率, 增加了通勤时间, 还导致了能源消耗的增加和环境污染的加剧。此外, 交通拥堵还可能引发交通事故, 对公共安全构成威胁^[1]。

深度强化学习作为人工智能领域的一种重要技术, 结合了深度学习的特征提取能力和强化学习的决策优化能力, 为解决交通拥堵问题提供了新的思路。在交通流量预测方面, 深度强化学习模型可以利用历史交通数据, 捕捉交通流量的时空相关性和周期性特征, 实现对未来交通流量的精准预测。这不仅有助于提前规划交通管理措施, 还能为出行者提供准确的交通信息, 减少盲目出行和拥堵的发生^[2]。

在交通流量优化方面, 深度强化学习模型可以根据实时交通状况, 智能地调整交通信号控制策略、优化路网布局和交通流分配方案等。通过不断学习和优化, 这些模型能够逐步适应城市交通需求的变化, 提高交通系统的整体运行效率。此外, 深度强化学习模型还可以与自动驾驶、智能网联

汽车等先进技术相结合, 进一步推动智能交通系统的发展。

1 深度强化学习基础

1.1 深度学习概述: 神经网络、特征提取

深度学习是机器学习的一个分支, 它通过构建深层神经网络来模拟人脑的学习过程。神经网络由多个神经元(或称为节点)组成, 这些神经元通过加权连接形成复杂的网络结构。在深度学习中, 这些网络结构通常包括输入层、隐藏层和输出层。输入层负责接收原始数据, 隐藏层则通过非线性变换对数据进行特征提取和模式识别, 最后输出层将处理结果输出为最终的预测或分类结果^[3]。

特征提取是深度学习的核心任务之一。通过训练神经网络, 模型能够自动地从原始数据中提取出有用的特征信息, 这些特征信息对于后续的预测或分类任务至关重要。与传统的特征工程方法相比, 深度学习能够自动学习特征, 无需人工设计, 从而大大提高了模型的效率和准确性。

1.2 强化学习基础: 环境、智能体、状态、动作、奖励

强化学习是一种机器学习方法, 它通过与环境的交互来学习最优策略。在强化学习中, 有两个关键要素: 智能体

(Agent) 和环境 (Environment)。智能体是执行动作的主体, 而环境则是智能体交互的对象。

状态 (State) 是环境的一种表示, 它包含了智能体进行决策所需的所有信息。动作 (Action) 是智能体根据当前状态所做出的选择, 这些选择会影响环境的状态以及智能体所获得的奖励 (Reward)。奖励是环境对智能体动作的反馈, 它表示了智能体在执行某个动作后所获得的收益或惩罚^[4]。

强化学习的目标是找到一种策略 (Policy), 使得智能体在遵循该策略时能够获得最大的累积奖励。这通常通过迭代地更新策略来实现, 直到策略收敛到最优解。

1.3 深度强化学习: 结合深度学习与强化学习的优势

深度强化学习是将深度学习与强化学习相结合的一种技术。它利用深度学习的特征提取能力来自动学习环境的表示, 并利用强化学习的策略优化能力来找到最优策略。这种结合使得深度强化学习在处理复杂、高维的状态空间时具有显著的优势^[5-6]。

具体来说, 深度强化学习通过构建深度神经网络来近似策略或价值函数, 从而解决了传统强化学习在处理大规模状态空间时面临的计算难题。同时, 深度神经网络还能够自动地从原始数据中提取有用的特征信息, 这使得深度强化学习在处理复杂的视觉、听觉等感知任务时表现出色。

2 基于深度强化学习的交通流量预测模型

2.1 数据预处理: 清洗、切分、标准化

在构建基于深度强化学习的交通流量预测模型之前, 数据预处理是一个至关重要的步骤。原始交通数据通常包含噪声、缺失值和异常值, 这些数据如果不经过适当的处理, 可能会严重影响模型的预测性能。

数据清洗: 需要对原始数据进行清洗, 以去除其中的噪声和异常值。这包括识别并删除无效数据、填充缺失值、平滑噪声数据等步骤。例如, 可以使用插值法或均值填充法来处理缺失值, 使用阈值法或箱线图法来识别并去除异常值^[7-8]。

数据切分: 需要将数据切分为训练集、验证集和测试集。训练集用于训练模型, 验证集用于调整模型的超参数, 测试集则用于评估模型的最终性能。合理的数据切分可以确保模型在不同数据集上的泛化能力。

数据标准化: 需要对数据进行标准化处理, 以消除不同特征之间的量纲差异。标准化通常包括将数据转换为均值为 0、方差为 1 的正态分布, 或者将数据缩放到一个特定的范围 (如 0 到 1 之间)。这有助于模型更快地收敛, 并提高预测的准确性和稳定性。

2.2 模型构建: 基于 RNN 和 CNN 的预测模型

在深度强化学习中, 循环神经网络 (RNN) 和卷积神经网络 (CNN) 是两种常用的模型架构, 它们在处理时间序列数据和空间特征方面表现出色。

基于 RNN 的预测模型: RNN 是一种特别适合处理时

间序列数据的神经网络架构。它通过在时间轴上展开, 能够捕捉数据中的时间依赖关系。在交通流量预测中, 可以利用 RNN 来捕捉交通流量的时间序列特征, 如周期性、趋势性和自相关性。为了进一步提高预测性能, 还可以引入长短期记忆网络 (LSTM) 或门控循环单元 (GRU) 等变体, 以克服 RNN 在处理长序列数据时容易出现的梯度消失或梯度爆炸问题^[9]。

基于 CNN 的预测模型: CNN 则擅长处理具有空间特征的数据。在交通流量预测中, 可以利用 CNN 来捕捉交通流量的空间分布特征, 如不同路段之间的交通流量相关性。通过将交通流量数据转换为图像形式 (如热力图), 并使用 CNN 进行卷积操作, 可以提取出有用的空间特征, 进而实现更准确的预测。

结合 RNN 和 CNN 的优点, 可以构建混合模型来同时捕捉交通流量的时间序列特征和空间特征。这种混合模型通常具有更高的预测性能和更强的泛化能力^[10]。

2.3 实验验证: 使用实际城市交通数据评估模型性能

为了验证基于深度强化学习的交通流量预测模型的性能, 需要使用实际城市交通数据进行实验验证。实验验证的过程通常包括以下几个步骤:

数据收集: 收集来自城市交通监测系统的实际交通流量数据, 包括不同路段、不同时间段的交通流量、速度、密度等信息。

模型训练: 使用预处理后的数据对模型进行训练, 调整模型的参数和超参数以最小化预测误差。

性能评估: 使用测试集数据对训练好的模型进行性能评估, 常用的评估指标包括均方误差 (MSE)、平均绝对误差 (MAE)、均方根误差 (RMSE) 等。同时, 还可以绘制预测结果与实际结果的对比图, 以直观地展示模型的预测性能。

模型优化: 根据性能评估的结果, 对模型进行进一步的优化和改进, 以提高预测的准确性和稳定性。这包括调整模型架构、增加数据量、引入新的特征等。

通过实验验证, 可以评估基于深度强化学习的交通流量预测模型的性能, 并为其在实际交通管理中的应用提供有力的支持。

3 基于深度强化学习的交通流量优化策略

3.1 交通信号控制优化: 调整红绿灯时长

交通信号控制是城市交通管理的重要手段之一, 通过合理设置红绿灯时长, 可以有效缓解交通拥堵, 提高道路通行能力。基于深度强化学习的交通信号控制优化策略, 旨在通过智能算法动态调整红绿灯时长, 以适应不同时段、不同路段的交通流量变化。

具体而言, 该策略首先利用深度学习模型对城市交通流量数据进行预处理和分析, 提取出交通流量的时空特征和

周期性规律。然后,将这些特征作为强化学习智能体的输入状态,通过与环境(即城市交通网络)的交互,学习出最优的信号控制策略。智能体的动作即为调整红绿灯时长的决策,而奖励函数则根据交通流畅度、车辆等待时间、排队长度等指标进行定义,以反映信号控制策略的效果。

在训练过程中,智能体不断尝试不同的信号控制策略,并根据奖励反馈进行调整,直到收敛到最优策略。该策略不仅能够适应实时交通流量的变化,还能在高峰期、节假日等特殊时段自动调整信号时长,有效缓解交通拥堵。

3.2 路网规划与优化: 改变车道规划, 优化交通流分配

路网规划与优化是城市交通管理的另一项重要任务。通过改变车道规划、增设公交专用道、调整交叉口布局等手段,可以优化交通流分配,提高道路使用效率。基于深度强化学习的路网规划与优化策略,旨在通过智能算法对路网结构进行动态调整,以适应城市交通流量的变化。

该策略首先利用深度学习模型对城市交通流量数据进行空间分析和模式识别,提取出交通拥堵的热点区域和瓶颈路段。然后,将这些信息作为强化学习智能体的输入状态,通过模拟不同路网规划方案下的交通流变化,学习出最优的路网规划策略。智能体的动作即为改变车道规划、增设公交专用道等决策,而奖励函数则根据道路通行能力、交通流畅度、车辆行驶时间等指标进行定义。

通过训练智能体,可以自动找到最优的路网规划方案,并在实际交通管理中进行应用。该策略不仅能够提高道路使用效率,还能减少交通拥堵和交通事故的发生,提升城市交通的整体运行水平。

3.3 出行决策辅助: 为用户提供个性化出行方案

基于深度强化学习的出行决策辅助策略,旨在为用户提供个性化的出行方案,以缓解城市交通拥堵,提高出行效率。该策略通过分析用户的出行需求、交通流量数据以及实时路况信息,利用深度学习模型对用户行为模式进行预测和分类,并结合强化学习算法为用户推荐最优的出行路径和时间。

具体而言,该策略首先利用深度学习模型对用户的历史出行数据进行挖掘和分析,提取出用户的出行习惯、偏好和目的地等信息。然后,将这些信息以及实时交通流量数据和路况信息作为强化学习智能体的输入状态,通过模拟不同出行方案下的交通流变化和用户行为反应,学习出最优的出行决策策略。智能体的动作即为推荐不同的出行路径和时间等决策,而奖励函数则根据用户的满意度、出行时间、交通费用等指标进行定义。

通过训练智能体,可以为用户推荐符合其需求和偏好的个性化出行方案,并在实际出行过程中进行实时调整和优化。该策略不仅能够提高用户的出行效率和满意度,还能在

一定程度上缓解城市交通拥堵问题,提升城市交通的整体运行效率。

4 模型验证

4.1 实验设计

实验设计旨在全面验证交通流量预测模型的有效性。实验过程精心规划为三个阶段:训练阶段、测试阶段和性能评估阶段。在训练阶段,模型通过大规模历史交通数据学习识别各种影响因素与交通流量之间的关系。测试阶段则利用独立的测试数据集,确保评估结果的客观性和公正性。最后,在性能评估阶段,采用多个评估指标对模型进行全面评价。

4.2 数据描述

为构建准确的交通流量预测模型,我们收集并整理了多种数据类型。这包括来自多个城市不同路段的每小时车流量和车速数据,与交通数据时间和地点相对应的天气数据(如温度、湿度、降水量、风速等),以及可能影响交通流量的公共假期和大型活动等事件信息。数据收集时间范围覆盖过去三年,确保了数据的多样性和全面性。

4.3 数据处理与特征提取

数据处理与特征提取是模型训练前的关键步骤。首先进行数据清洗,去除异常值和缺失数据,并采用插值方法填补缺失值。随后进行数据标准化,使用 Z-score 标准化方法将数据转换为具有零均值和单位方差的形式,以提高模型的收敛速度和预测准确性。最后,基于时间序列分析提取滞后特征、移动平均、时间窗口聚合等特征,为模型训练提供丰富的输入信息。

4.4 评估指标

为全面评估模型的性能,我们采用了多个评估指标。其中,预测准确率是衡量模型预测准确性的重要指标;均方误差(MSE)则用于量化模型预测值与真实值之间的差异。这些评估指标共同构成了对模型性能的全面评价。

4.5 结果分析

通过对模型在不同城市、路段类型和天气条件下的预测结果进行分析,我们得出了以下结论:

在晴朗天气条件下,模型的预测准确率普遍较高,表明模型在晴朗天气时预测交通流量的能力更强。然而,在雨雪等恶劣天气条件下,模型的预测准确率有所下降,这可能是由于恶劣天气对交通流量的影响更为复杂和多变。

主干道的 MSE 普遍低于支路,表明模型在主干道上的预测更为准确。这可能是由于主干道交通流量大、数据丰富,使得模型能够学习到更多有用的特征和信息。同时,不同天气条件下的 MSE 波动也反映了模型在不同环境因素下的适应性。在恶劣天气条件下, MSE 的波动可能更为显著,表明模型在这些条件下的预测难度更大(见图 1)。

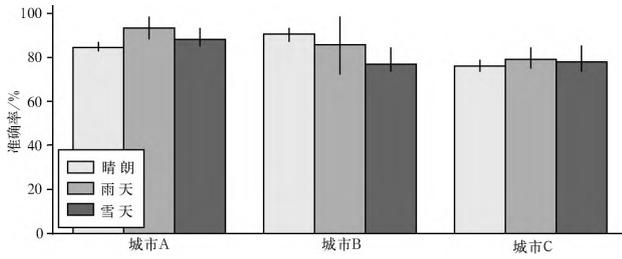


图 1 不同城市和天气条件下的预测准确率

综上所述，通过对模型在不同场景下的预测结果进行分析，我们验证了模型的有效性和适用性，并发现了模型在不同条件下的表现差异。这些分析结果将为后续模型优化和改进提供有价值的参考。

参考文献：

[1] 姜文翰,姜志侠,孙雪莲.一种修正学习率的梯度下降算法[J].长春理工大学学报(自然科学版),2023(6):23-25.
 [2] 陈琨,王安志.卷积神经网络的正则化方法综述[J].计算机应用研究,2024(4):56-75.

[3] 李晓宇,周梅,王金虎,等.基于点密度与卡尔曼滤波的路面标识线提取方法[J].中国科学院大学学报,2023(6):123-140.
 [4] 任丽丽,吴江玲,郭旭亮,等.无信号环形交叉口机非冲突机器学习预测方法[J].科学技术与工程,2023(31):223-225.
 [5] 王文杰,石竞琛,姜念祖,等.主成分分析在模式识别领域中的研究进展[J].白城师范学院学报,2023(5):73-77.
 [6] 白云,颜华,魏元焜.基于PCA降维和迭代正则化的温度场重建[J].自动化与仪表,2023(9):53-55.
 [7] 朱骏宇.基于卷积神经网络的图像识别的技术分析[J].长江信息通信,2023(8):334-350.
 [8] 崔素萍,卜崇阳.深度学习下交通拥堵路段信息自动识别仿真[J].计算机仿真,2023(7):213-215.
 [9] 方华珍,刘立,肖小凤,等.混合示教长短时记忆网络的车辆轨迹预测研究[J].交通运输系统工程与信息,2023(4):223-226.
 [10] 朱承元,张澈,管建华.基于改进支持向量机的空域交通态势识别方法[J].交通信息与安全,2023(2):123-125.

作者简介: 于骐嘉, 中国辽宁人, 从事大数据工程研究。