

融合数据分析与深度学习的电力用户行为模式识别与需求响应

黄钊坤 卞锦豪 黄一聪

西安市物联网应用实验室 陕西西安 710000

摘要: 本文聚焦融合数据分析与深度学习的电力用户行为模式识别与需求响应。首先阐述相关技术基础,接着介绍多源电力数据的融合与处理流程。构建基于深度学习的行为模式识别模型,制定基于识别结果的需求响应策略。通过实验,在不同数据集上评估模型性能,并与传统方法对比。结果表明,该方法能有效识别用户行为模式,制定合理需求响应策略,为电力系统优化运行提供支持。

关键词: 数据分析;深度学习;电力用户;行为模式识别;需求响应

1 研究背景与价值体现

在当今能源领域,电力系统正经历着深刻的变革。随着智能电网建设的不断推进以及分布式能源的广泛接入,电力系统的运行环境日益复杂。电力用户作为电力系统的重要组成部分,其行为模式对电力系统的供需平衡、安全稳定运行以及能源利用效率等方面都有着至关重要的影响。准确识别电力用户的行为模式,并基于此制定有效的需求响应策略,已成为提升电力系统运行质量、实现能源可持续发展的关键环节。

电力用户的行为模式涵盖了多个维度,包括用电时间分布、用电负荷特性、用电设备使用习惯等。这些行为模式并非一成不变,而是受到多种因素的综合影响,如季节变化、天气状况、用户生活习惯、电价政策等。例如,在夏季高温天气下,居民用户的空调使用频率大幅增加,导致用电负荷显著上升;而在工作日与休息日,商业用户的用电模式也会存在明显差异。准确把握这些复杂多变的行行为模式,有助于电力部门更好地进行电力调度和规划,提高电力供应的可靠性和经济性。

需求响应作为电力系统管理的重要手段,旨在通过激励措施引导电力用户在用电高峰时段减少用电,在用电低谷时段增加用电,从而实现电力供需的动态平衡。传统的需求响应策略往往基于简单的统计方法或经验规则,难以充分考虑电力用户行为的多样性和复杂性,导致策略的有效性和针对性不足。随着大数据时代的到来,电力系统中积累了海量的用户用电数据,这些数据蕴含着丰富的用户行为信息。如何从这些海量数据中挖掘出有价值的信息,准确识别用户的

行为模式,成为制定科学合理需求响应策略的关键。

数据分析技术为处理和分析电力用户用电数据提供了有力工具。通过对用电数据进行预处理、特征提取等操作,可以提取出能够反映用户行为模式的关键特征。然而,传统的数据分析方法在处理复杂、高维的电力数据时,往往面临着特征提取困难、模型泛化能力不足等问题。深度学习作为人工智能领域的热门技术,具有强大的特征学习和模式识别能力。它能够自动从原始数据中学习到低层次的特征表示,有效捕捉数据中的复杂模式和关系。将数据分析技术与深度学习相结合,充分发挥两者的优势,为电力用户行为模式识别与需求响应提供了新的思路和方法。

2 相关技术基础

2.1 数据分析技术

在电力用户行为模式识别中,数据分析技术是不可或缺的基础环节。其核心目的在于从海量的用户用电数据中,挖掘出有价值的信息,为后续的行为模式识别提供有力支持。数据预处理是数据分析的首要步骤,它包括数据清洗、数据集成、数据变换和数据归一化等操作。数据清洗旨在去除原始数据中的噪声、异常值和缺失值,以提高数据的质量和可靠性。数据集成则是将来自不同数据源的数据进行整合,形成一个统一的数据集,便于后续的分析 and 处理。数据变换通过对数据进行归一化、标准化等操作,消除不同特征之间的量纲差异,使数据更适合于后续的模型训练。数据归一化则进一步确保数据在相同的尺度范围内,避免某些特征因数值范围过大而对模型训练产生不利影响。

特征提取是数据分析技术的关键环节,它直接影响到后

续模型训练的效果和准确性。在电力用户行为模式识别中,常用的特征提取方法包括时域特征、频域特征和统计特征等。时域特征主要反映用电数据在时间维度上的变化规律,如用电量的均值、方差、最大值、最小值等。频域特征则通过傅里叶变换等方法,将时域信号转换为频域信号,从而提取出用电数据的频率成分和能量分布等信息。统计特征则是对用电数据进行统计分析,提取出如偏度、峰度等能够反映数据分布形态的特征。这些特征提取方法能够从不同角度刻画电力用户的行为模式,为后续的深度学习模型提供丰富的输入信息。

2.2 深度学习模型

深度学习模型是近年来人工智能领域的重要突破,它通过构建深度神经网络,能够自动从原始数据中学习到低层次的特征表示,有效捕捉数据中的复杂模式和关系。在电力用户行为模式识别中,常用的深度学习模型包括卷积神经网络(CNN)、循环神经网络(RNN)和长短时记忆网络(LSTM)等。

卷积神经网络是一种具有局部连接和权重共享特性的深度学习模型,它在图像处理 and 特征提取方面表现出色。在电力用户行为模式识别中,CNN可以用于提取用电数据的局部特征和空间结构信息。通过卷积层和池化层的交替堆叠,CNN能够逐层抽象出用电数据的高层次特征表示,为后续的分类和识别任务提供有力支持。

循环神经网络是一种专门用于处理序列数据的深度学习模型,它能够捕捉序列数据中的时间依赖关系。在电力用户行为模式识别中,用户的用电行为往往具有一定的时间序列特性,如日用电曲线、周用电模式等。RNN通过引入循环连接,使得网络能够记忆历史信息,并根据当前输入和历史信息预测未来的用电行为。然而,传统的RNN在处理长序列数据时存在梯度消失和梯度爆炸等问题。为了解决这些问题,长短时记忆网络(LSTM)被提出。LSTM通过引入门控机制,能够有效地捕捉长期依赖关系,并在处理长序列数据时表现出更好的性能。在电力用户行为模式识别中,LSTM可以用于建模用户的长期用电行为模式,为需求响应策略的制定提供重要依据。

3 数据融合与处理

在电力用户行为模式识别中,数据融合与处理是至关重要的一环。随着智能电网的快速发展,电力系统中积累了

海量的用户用电数据,这些数据来源于不同的设备和系统,具有多源、异构、海量等特点。如何有效地融合和处理这些数据,提取出有价值的信息,是电力用户行为模式识别的关键。

数据融合是指将来自不同数据源的数据进行整合,形成一个统一的数据集。在电力用户行为模式识别中,常见的数据源包括智能电表数据、气象数据、用户信息数据等。智能电表数据记录了用户的用电量、用电时间等详细信息,是分析用户行为模式的基础数据。气象数据则反映了外部环境对用户用电行为的影响,如温度、湿度等气象因素与用户的空调使用、采暖需求等密切相关。用户信息数据则包括用户的年龄、职业、收入等基本信息,这些信息有助于理解用户的用电习惯和需求。通过数据融合,可以将这些不同来源的数据进行关联和整合,形成一个更全面、更丰富的数据集,为后续的分析 and 处理提供有力支持。

数据融合后,需要进行一系列的数据处理操作,以确保数据的质量和可用性。数据清洗是数据处理的首要步骤,它旨在去除原始数据中的噪声、异常值和缺失值。在电力用户用电数据中,由于设备故障、通信中断等原因,可能会出现数据缺失或异常的情况。数据清洗可以通过插值、平滑等方法,对这些缺失或异常数据进行处理,以提高数据的质量和可靠性。

数据标准化是数据处理的重要环节,它旨在消除不同特征之间的量纲差异,使数据更适合于后续的模型训练。在电力用户行为模式识别中,不同的特征可能具有不同的量纲和取值范围,如用电量的单位为千瓦时,而温度的单位为摄氏度。这些量纲差异可能会对模型训练产生不利影响。数据标准化可以通过对数据进行归一化、标准化等操作,将数据映射到相同的尺度范围内,从而消除量纲差异,提高模型的训练效果和准确性。

特征选择是数据处理的另一个关键环节,它旨在从原始特征中选择出对模型训练最有用的特征。在电力用户行为模式识别中,原始特征可能包含大量的冗余信息和噪声,这些信息可能会对模型训练产生干扰。特征选择可以通过统计方法、机器学习方法等,评估每个特征对模型训练的贡献度,选择出贡献度较高的特征,从而降低模型的复杂度,提高模型的训练效率和准确性。

4 基于深度学习的行为模式识别

在电力用户行为模式识别中,深度学习技术展现出强大

的特征提取与模式分类能力。通过构建深度神经网络模型,能够自动学习用户用电数据的复杂特征,并实现精准的行为模式识别。

模型构建是深度学习应用的核心环节。针对电力用户用电数据的时序特性,常采用循环神经网络(RNN)及其变体长短时记忆网络(LSTM)作为基础模型。LSTM网络通过引入门控机制,能够有效捕捉用电数据中的长期依赖关系,适用于处理具有时间序列特性的用电行为数据。在模型结构设计上,通常采用多层LSTM网络堆叠的方式,以逐层提取用电数据的高层次特征。同时,为了增强模型的泛化能力,还会在模型中引入Dropout层和批量归一化层,以防止过拟合现象的发生。

在模型训练过程中,优化算法的选择对模型性能具有重要影响。常用的优化算法包括随机梯度下降(SGD)、Adam等。其中,Adam算法结合了动量法和自适应学习率的优点,能够自动调整学习率,加速模型收敛。通过合理设置学习率、批量大小等超参数,可以进一步优化模型训练过程,提高模型的识别准确率。

行为模式分类是深度学习模型的最终目标。在模型训练完成后,可以通过将新的用电数据输入模型,得到用户的行为模式分类结果。常用的分类方法包括Softmax分类、支持向量机(SVM)分类等。其中,Softmax分类器能够将模型的输出转换为概率分布,直观地反映用户属于不同行为模式的概率。

为了验证深度学习模型在电力用户行为模式识别中的有效性,进行了大量的实验验证。实验结果表明,基于深度学习的行为模式识别方法相比传统方法具有更高的识别准确率和更强的泛化能力。该方法还能够自动学习用电数据的复杂特征,减少人工特征提取的工作量,提高识别效率。

5 需求响应策略制定

基于深度学习模型输出的用户行为模式分类结果,可构建分层需求响应机制。针对不同行为特征的用户群体,设计差异化响应策略。对于具备明显峰谷用电特性的工业用户,可实施动态电价激励机制,通过分时电价引导其在负荷低谷期增加生产。针对居民用户,结合其用电设备使用习惯,开发智能家居控制系统,在高峰时段自动调节空调温度设定值或延迟高能耗设备运行时间。

6 实验与结果分析

实验采用某地区2000户智能电表采集的年度用电数据,数据采集间隔15分钟。实验环境配置为Intel i7-11800H处理器、32GB内存,基于TensorFlow 2.8框架构建模型。将数据集按7:2:1比例划分为训练集、验证集和测试集。对比实验选取支持向量机(SVM)、随机森林(RF)两种传统方法,以及LSTM、GRU两种深度学习模型。评估指标采用分类准确率(Accuracy)、F1值及响应策略执行后的峰谷差缩减率。

实验结果表明,本文提出的LSTM-Attention混合模型在测试集上达到92.7%的分类准确率,较传统方法提升8-12个百分点。在需求响应模拟环节,执行优化策略后系统日峰谷差降低18.3%,显著优于固定阈值触发策略的12.6%降幅。特别在居民用户场景中,模型成功识别出76%具有可调节潜力的空调负荷,通过智能控制实现单户日均移峰量2.1kWh。

7 结论与展望

本文构建了数据驱动的电力用户行为分析框架,通过深度学习技术实现用电模式精准识别,并基于识别结果制定动态需求响应策略。实验验证了所提方法在提升需求响应效能方面的有效性。未来工作将聚焦三方面:一是拓展多能互补场景下的用户行为建模;二是研究联邦学习框架下的跨区域数据协同;三是开发具备自适应能力的实时响应控制系统。

参考文献:

- [1] 方茂益,孙志杰,周国鹏,谢枫,王鹏伍,周辛南. 基于FCM配电侧典型电力日负荷曲线分类研究[J]. 华北电力技术,2016(11):15-19.
- [2] 苏适,李康平,严玉廷,陆海,汪新康,刘力铭,王飞,董凌. 基于密度空间聚类和引力搜索算法的居民负荷用电模式分类模型[J]. 电力自动化设备,2018,38(1):129-136.
- [3] 朱祥和. 考虑气象因素的短期负荷预测模型研究[J]. 数学的实践与认识,2018,48(3):131-143.
- [4] 陈俊艺,丁坚勇,田世明,卜凡鹏,朱炳翔,黄事成,周凯. 基于改进快速密度峰值算法的电力负荷曲线聚类分析[J]. 电力系统保护与控制,2018,46(20):85-93.
- [5] 魏震波,关翔友,刘梁豪. 电网社区结构发现方法及其应用综述[J]. 电网技术,2020,44(7):2600-2609.

作者简介:黄钊坤(2002—),男,汉族,陕西省商洛市,本科生,研究方向为计算机应用。