

基于IPSO-LSTM模型的能源消费碳排放

田露佳 王志强*

青岛理工大学

DOI:10.12238/eep.v7i4.2039

[摘要] 提高能源消费碳排放的预测精度,为制定更为精确的碳排放管理策略提供理论支持。首先,收集并整理能源消费及碳排放等相关数据,进行数据处理和特征提取。其次,利用IPSO算法对LSTM模型的参数进行优化,构建IPSO-LSTM预测模型。最后,对IPSO-LSTM模型进行训练和验证。

[关键词] 能源消费; 碳排放; 改进粒子群

中图分类号: F206 文献标识码: A

Carbon emissions of energy consumption based on IPSO-LSTM model

Lujia Tian Zhiqiang Wang*

Qingdao University of Technology

[Abstract] Improving the prediction accuracy of carbon emissions from energy consumption provides theoretical support for developing more accurate carbon emission management strategies. Firstly, relevant data such as energy consumption and carbon emissions are collected and sorted out for data processing and feature extraction. Secondly, IPSO algorithm is used to optimize the parameters of LSTM model, and IPSO-LSTM prediction model is constructed. Finally, the IPSO-LSTM model is trained and verified.

[Key words] energy consumption; Carbon emissions; Improved particle swarm

引言

随着全球气候变化问题的日益严重,减少碳排放、实现可持续发展已成为全球共识。能源消费作为碳排放的主要来源之一,其碳排放的预测与管理对于实现低碳发展具有重要意义。本研究旨在利用IPSO-LSTM模型,提高能源消费碳排放的预测精度,为制定更为精确的碳排放管理策略提供理论支持。

目前,国内外学者在能源消费排放预测方面已进行了大量研究。国外研究主要集中在碳排放预测模型的构建与优化,如灰色预测模型、神经网络模型等。国内研究则更多地关注碳排放与经济增长^[1]、能源结构^[2]等因素的关系,以及政府调控^[3]对碳排放的影响。在研究过程中我们发现LSTM模型在处理时间序列数据上具有明显优势,但在优化方面存在明显不足,容易陷入局部最优解。IPSO算法作为一种高效的优化算法,具有全局搜索能力强,收敛速度快等特点,与LSTM模型结合有望提高预测精度,深化对碳排放影响因素的理解。

1 基于IPSO-LSTM模型的能源消费碳排放

1.1 IPSO-LSTM模型概述

IPSO-LSTM模型是一种结合了粒子群优化算法(Particle Swarm Optimization,简称PSO)和长短期记忆网络(Long Short-Term Memory,简称LSTM)的模型,主要用于预测。该模型通过粒子群优化算法的迭代过程,可以自适应地搜索最佳的权

重和偏置组合,以提高预测的准确性和稳定性。具体来说,首先进行数据预处理,包括数据的加载、分割和归一化处理。然后,构建IPSO-LSTM模型,该模型由多个LSTM层组成,每个LSTM层的输出作为下一层的输入。在每个LSTM层后面,紧跟着一个全连接层,用于将LSTM层的输出映射到指定的输出维度。在IPSO-LSTM模型中,粒子群优化算法被嵌入到模型中,用于优化LSTM网络的权重和偏置。

这种模型可以学习到更为复杂的交通流数据的时空特性,并且相比于传统的基于统计分析的模型,具有更高的预测精度和稳定性。同时,粒子群优化算法的使用也可以避免传统优化算法容易陷入局部最优解的问题,从而提高全局搜索能力。

1.2 IPSO优化算法与LSTM模型原理

IPSO是一种基于粒子群优化算法的改进版本,用于寻找最优解。在IPSO中,每个解被视为一个粒子,并在搜索空间中以一定的速度飞行,通过迭代找到最优解。

LSTM(Long Short Term Memory)是一种递归神经网络(RNN)的变体,由Hochreiter等^[4]于1997年提出的,专门设计用于处理具有时间依赖性的序列数据。LSTM通过引入记忆单元来解决传统RNN在处理长时间依赖时出现的梯度消失或爆炸问题。LSTM能够学习并记忆序列中的长期依赖关系,使得它能有效地处理各种时间序列预测任务^[5]。

表1 综合能源平衡表

项目	Item	2018	2019	2020	2021
可供消费的能源总量	Total Energy for Consumption	40580.5	41390.0	43649.0	45935.1
一次能源生产量	Primary Energy Output	13735.6	13499.5	13213.4	13030.9
外省(区、市)调入量	Allocation from Other Provinces	31537.2	36082.7	31945.4	34226.9
进口量	Imports	13118.8	14622.4	16554.2	14571.6
本省(区、市)调出量(-)	Allocation to Other Provinces(-)	-16853.7	-22325.9	-18377.8	-14938.5
出口量(-)	Exports(-)	-253.1	-49.1	-2.6	-94.3
年初年末库存差额	Stock Changes in the Year	-704.3	-439.7	316.5	-862.0
能源消费总量	Total Energy Consumption	40580.5	41390.0	43649.0	45935.1
在总量中:	Consumption by sector				
1. 农林牧渔业	1_Agriculture, Forestry, Animal Husbandry and Fishery	550.1	599.7	574.6	583.1
2. 工业	2. Industry	31146.2	31293.7	33627.4	35353.4
3. 建筑业	3. Construction	437.3	481.4	500.6	535.3
4. 交通运输、仓储和邮政业	4. Transport, Storage and Post	2188.3	2381.8	2037.9	2181.8
5. 批发、零售业和住宿、餐饮业	5. Wholesale and Retail Trade, Hotels and Catering Services	928.2	986.7	978.3	1073.3
6. 其他行业	6. Other Sectors	1353.6	1454.4	1491.2	1613.1
7. 生活消费	7. Household Consumption	3976.7	4192.4	4439.1	4595.1
在总量中:	Consumption by Usage				
(一) 终端消费	(I) End-use Consumption	38243.9	40359.4	42981.6	45156.0
#工业	Industry	28809.5	30263.1	32960.0	34574.3
(二) 加工转换损失量	(II) Losses During the Process of Energy Conversion	2336.6	1030.6	667.4	779.1
炼焦	Coking	395.1	3.0	341.0	327.0
炼油	Petroleum Refining	2508.4	1622.5	923.3	1018.6

LSTM整体结构的中文示意图如下,这个结构中两个重要参数分别是“记忆细胞”c和“隐藏状态”h,一般来说我们称为长期记忆, h为短期记忆。

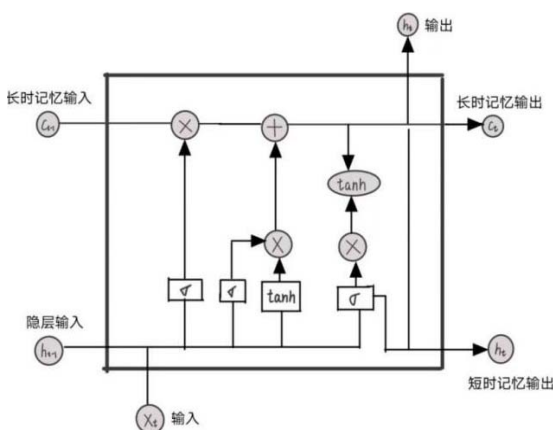


图1 LSTM模型构架

1.3能源消费碳排放数据

要预测未来的碳排放情况,首先需要历史碳排放进行分析。通过对历史能源消费数据的分析,可以预测未来一定时期内

能源消费总量的变化趋势。在此基础上,可以进一步探讨能源结构调整和节能减排的必要性。从历史数据上看,碳排放量呈现逐年上升的趋势。这主要是由于人口增长、经济发展和城市化进程的加速。因此,未来的碳排放量仍将保持一定的增长趋势。本文选取了山东省的能源数据作为研究对象,为模型的训练和预测提供了基础数据。主要数据来源为国家统计局地方统计网站山东省统计局。

2 IPSO-LSTM模型构建

2.1模型构建与训练

2.1.1数据预处理。(1)数据清洗:去除重复数据;处理缺失值(插值、删除或均值填充);异常值检测与处理。(2)数据变换。标准化或归一化数据;对时间序列数据进行差分或平滑处理特征工程,提取有意义的特征。(3)数据划分。将数据划分为训练集、验证集和测试集。

2.1.2模型结构设计。(1)确定模型结构。根据任务需要选择合适的LSTM架构;考虑是否需要堆叠多个LSTM层考虑是否加入其他组件。(2)设计超参数。确定LSTM层的单元数量。设定批次大小(batch size);设定训练轮次(epochs)。(3)参数初始化。使用合适的权重初始化方法,如随机正态分布、He初始化等;偏

置通常初始化为0或较小的正值

2.1.3训练过程设置。(1)损失函数选择:根据任务类型选择合适的损失函数,如均方误差(MSE)。(2)优化器选择:选择合适的优化器。(3)学习效率设置:设置合适的学习效率,根据训练情况调整。

2.1.4模型训练与优化。(1)训练模型。使用训练集和验证集进行模型训练;记录训练过程中的损失和准确率等指标。(2)模型优化。根据训练过程中的性能指标调整超参数;使用验证集进行模型选择,防止过拟合。

2.2模型评估与讨论

在训练过程中,可以使用交叉验证^[6]等方法评估模型性能,根据评估结果调整模型结构和参数。评估模型的最终性能,比较模型与其他基准模型的性能。将训练好的模型应用于测试集,得到能源消费碳排放的预测结果。通过对比实际值与预测值,观察模型的实际应用效果与其可行性。同时,我们对模型的预测结果进行误差分析和相关性分析,进一步验证模型的可靠性。

虽然IPSO-LSTM模型在能源消费碳排放预测中取得了良好的效果,但仍存在一些不足之处。未来我们将进一步优化模型结构和参数设置,以提高模型的预测精度和稳定性。同时,我们还将考虑更多的影响因素作为模型的输入,以更全面地反映能源消费碳排放的变化规律。

3 结论与展望

根据预测数据,未来一段时间内,可再生能源的发展速度将加快,在能源结构中的比重将逐渐提升。结果表明,优化能源结构,提高能源利用率,促进经济转型升级以及实施严格的碳排放政策,都是降低能源消费碳排放的有效途径。基于IPSO-LSTM模

型的能源消费碳排放预测方法可以提高预测精度,为能源管理政策制定提供一定科学依据。但该方法仍需要进一步完善和优化,如提高模型的泛化能力,调整优化算法的参数等。未来,随着全球气候变化问题的日益严峻和能源结构的不断调整,能源消费碳排放将成为研究热点。可以进一步研究其他优化算法与神经网络模型的结合方式,以提高能源消费碳排放预测的准确性和可靠性,也可进一步关注可再生能源的发展潜力、碳排放权交易市场以及国际合作在应对气候变化中的作用等方面。

[大创项目]

基于机器学习的建筑物物化阶段碳排放预测研究;编号:S202310429216。

[参考文献]

[1]王运豪,杨皓翔,官国宇.碳排放、能源消费与经济增长——基于中国省级面板数据的中介效应模型[J/OL].数理统计与管理,1-15[2024-03-18].<https://doi.org/10.13860/j.cnki.sltj.20231128-001>.

[2]安红宇.电力行业能源消费结构调整与碳排放减少策略研究[J].现代工业经济和信息化,2023,13(12):186-188+193.

[3]金英君,刘晓峰,王义源.政府调控碳排放路径研究——基于金融效率的视角[J].中国软科学,2021,(05):135-144.

[4]HOCHREITER S,SCHMIDHUBER R.Long short term memory [J].Neural Computation,1997,9(8):1735-1780.

[5]赵一鸣,吉月辉,刘俊杰.基于EMD-IPSO-LSTM模型的短期电力负荷预测[J].国外电子测量技术,2023,42(01):132-137.

[6]范永东.模型选择中的交叉验证方法综述[D].山西大学,2013.