

# 基于GRU-GCN模型的碳排放权价格预测及影响因素分析研究

白鑫怡<sup>1\*</sup>, 崔 骥<sup>2</sup>

<sup>1</sup>南京信息工程大学数学与统计学院, 江苏 南京

<sup>2</sup>苏州博纳讯动软件有限公司, 江苏 苏州

收稿日期: 2024年1月4日; 录用日期: 2024年1月24日; 发布日期: 2024年4月29日

## 摘 要

中国作为世界第一大碳排放国, 先后成立了深圳、北京、上海等8个碳排放权交易试点, 相较于国际上成熟的碳市场, 中国的碳排放权交易市场尚处在探索阶段, 研究全国碳市场交易价格的波动特征, 有助于企业规避交易价格风险、制定绿色创新及节能减排的战略, 也对政府完善碳排放权交易市场机制、建设全国碳交易市场具有一定意义, 本文以上海交易所为例, 探究不同因素对碳排放权交易价格的影响程度, 并且使用StemGNN模型, 即基于GRU和GCN具有联合捕获序列间相关性和时间依赖性功能的新型预测模型对碳排放权交易价格进行预测, 以期为我国碳交易市场的参与者及政府相关管理部门提供更加科学、精准的决策工具。

## 关键词

碳排放权交易, 深度学习, GRU, GCN

# Research on Carbon Emission Rights Price Prediction and Influencing Factors Analysis Based on GRU-GCN Model

Xinyi Bai<sup>1\*</sup>, Ji Cui<sup>2</sup>

<sup>1</sup>School of Mathematics and Statistics, Nanjing University of Information Science and Technology, Nanjing Jiangsu

<sup>2</sup>Suzhou Beyondcent Software Co., Ltd., Suzhou Jiangsu

Received: Jan. 4<sup>th</sup>, 2024; accepted: Jan. 24<sup>th</sup>, 2024; published: Apr. 29<sup>th</sup>, 2024

\*通讯作者。

文章引用: 白鑫怡, 崔骥. 基于 GRU-GCN 模型的碳排放权价格预测及影响因素分析研究[J]. 运筹与模糊学, 2024, 14(2): 1156-1169. DOI: 10.12677/orf.2024.142214

## Abstract

As the world's largest carbon emitter, China has established eight carbon emission trading pilot projects, including Shenzhen, Beijing, and Shanghai. Compared to mature international carbon markets, China's carbon emission trading market is still in the exploratory stage. Studying the fluctuation characteristics of national carbon market trading prices can help enterprises avoid trading price risks, formulate strategies for green innovation, energy conservation and emission reduction, and also improve the government's carbon emission trading market mechanism. The construction of a national carbon trading market has certain significance. This article takes the Shanghai Stock Exchange as an example to explore the degree of influence of different factors on carbon emission trading prices, and uses the StemGNN model, which is a new prediction model based on GRU and GCN with joint capture of inter sequence correlation and time dependence functions, to predict carbon emission trading prices. In order to provide more scientific and accurate decision-making tools for participants in China's carbon trading market and relevant government management departments.

## Keywords

Carbon Emission Trading, Deep Learning, GRU, GCN

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

2020年9月,国家主席习近平在第七十五届联合国大会上郑重宣誓:中国将提高国家自主贡献力度,采取更加有力的政策和措施,二氧化碳排放力争于2030年前达到碳达峰,努力争取2060年前实现碳中和[1]。

欧盟的碳交易体系[2] (EUETS)市场机制较为成熟且运行时间长,当下国内外对欧盟碳交易体系的研究成果也相对丰富,众多学者对碳交易价格的影响因素展开了深入地分析和研究。例如 Deeney 基于事件分析法对欧洲议会的决议对于碳交易价格波动的影响进行了研究[3], Aatola 对欧盟 ETS 市场进行探究并发现碳交易价格与电力价格及能源价格存在着强相关性[4], Tan 针对碳交易价格进行了基于分位数回归的探究,阐释了能源、经济因素的依赖性和相应的影响路径,其研究发现在碳金融市场发展前期,能源价格对碳金融市场冲击影响较大[5];而在碳金融市场发展后期,股票市场因素、工业发展趋势的影响力则会逐渐提升。

在国内现有的文献中,郭文军选用了标准普尔 500 指数、法兰克福 DAX 指数与沪深 300 指数等为代表指标[6],探讨了影响深圳碳交易价格的各种因素,并分别从国内、国外的经济因素方面对深圳碳交易价格的影响展开了深入的研究,发现欧洲、中国的经济状况对深圳的碳交易定价具有积极的作用,美国的经济状况对深圳的碳交易价格产生了负面影响[7]。陈欣运用上海综合指数和制造业 PMI 为代表的宏观经济指标,研究了我国七个试点城市的碳交易价格,并通过实证分析得出,宏观经济对其具有明显的作用[8]。祝越在对深圳地区的碳交易定价进行研究时,选择了以原油、煤炭为代表的能源价格,并对其进行了实证研究,最终得出煤炭价格对碳价有着负面作用,而原油价格对碳价有着积极影响的结论[9]。张

云在针对除重庆外的六个试点的碳交易价格进行分析时, 选取日均气温与历史平均气温的偏离值作为气候环境因素的代表指标, 进而分析该差值对碳交易价格的影响, 并得出气温偏差对碳交易价格有着显著的负向影响的研究结论[10]。陈欣对我国七个试点的碳交易价格影响因素进行探究时, 采用了日均气温与历史平均气温偏差值的绝对值作为气候环境因素的代表指标, 进而分析其对碳交易价格的影响, 最终发现气温变化对碳交易价格的影响并不显著。同时张玉娟[11]、王煦楠[12]、欧阳屹欣[13]等从理论分析角度阐述了政策因素对于碳价的影响, 研究结果显示, 政策和制度信息对碳价格无明显影响。

在以往碳排放交易价格的研究中, 研究者们大多使用经济计量模型或使用简单的机器学习模型来对碳排放交易价格进行预测, 例如高杨和李健在对 CER 期货的价格进行预测时采用了 EMD-PSO-SVM 模型, 研究结果显示该预测模型能够解决误差序列随机性等问题和缺陷, 并且该模型的预测结果准确率也较高[14]。王娜使用大数据对深圳市的碳交易价格进行了预测[15]。张晨和杨仙子以深圳市碳交易试点为例子, 构建了多频率组合碳价预测模型, 结果发现该模型相较于 NVA、WNN、SVM、GARCH 等单模型, 预测效果更好[16]。石雪涛等[17]为预测欧盟碳配额期货价格, 构建了 PSO-PSR-LSSVR 模型, 结果显示 PSO-PSR-LSSVR 模型的拟合精度要高于普通模型。Li 和 Lu 在对我国碳交易市场展开分析研究时运用了 EMD-GARCH 模型, 并对碳交易价格进行预测分析, 最终发现 EMD-GARCH 模型的拟合精度较高, 模型表现较为优秀[18]。

从上述文献综述可以看出, 目前在碳价预测方面已有一些研究成果, 但仍有待完善之处: 一方面, 已有研究主要通过历史碳价数据构建计量经济模型或智能机器学习模型, 进而对当期碳价进行预测, 对能源市场、金融市场、国际碳市场、自然环境等对碳价有较大影响的关键因素考虑不足; 另一方面, 现有 LSTM 等智能机器学习方法对碳价预测的精度通常比自回归求移动平均模型等计量经济方法高, 但还有待进一步提升。因此本文将能源市场、金融市场、国际碳市场等对碳价有影响的因素均考虑在内, 并使用 CFS 进行特征筛选并将 StemGNN 应用于预测碳排放权交易以期对碳排放权交易价格预测提出新思路。

## 2. 方法介绍

### 2.1. 相关性特征选择

基于相关性的特征选择(CFS)是由 Hall 提出的一种经典的过滤式特征选择算法, 该方法通过启发式评估函数对特征子集进行评估, 进而选择出特征变量预测能力强、特征之间相关性低的特征子集相关系数计算公式和启发式评估函数如下:

$$r_{xy} = \frac{\left| \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}) \right|}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}}$$

$$Merit_s = \frac{k \bar{r}_{xy}}{\sqrt{k + k(k-1) \bar{r}_{xx}}}$$

式中  $r_{xy}$  为  $x, y$  的 Pearson 相关系数,  $\bar{X}, \bar{Y}$  分别为  $X, Y$  的平均数,  $Merit_s$  为包含  $k$  个特征的特征子集  $S$  的启发式 merit 值,  $k$  表示所选特征子集中包含特征变量的个数,  $\bar{r}_{xy}$  为特征自变量与特征因变量之间相关系数的平均值, 其中  $x \in S$ ,  $\bar{r}_{xx}$  为特征自变量与特征自变量平均相关性。

CFS 算法实现流程是先计算多维时间序列的相关系数矩阵, 再使用序列前向选择即 SFS 搜索策略对变量子集进行搜索, 经过启发式评估函数评估得到最优的特征子集。特征子集的搜索首先从空集  $S$  开始,

首先计算单个特征变量的 Merit 值, 选择 Merit 值最大的变量  $x_i$  进入  $S$  然后选择除  $x_i$  之外 Merit 值最大的变量  $x_j$  进入  $S$ , 若  $x_i$  和  $x_j$  之间的 Merit 值小于原 Merit 值, 则将子集  $S$  中的变量  $x_i$  剔除掉接着考虑除  $x_i$  和  $x_j$  之外的其他变量, 循环迭代, 直到所有变量被筛选完成, 此时得到 Merit 值最大的特征子集  $S^*$  即为最优子集。CFS 特征变量筛选原理图如图 1 所示。

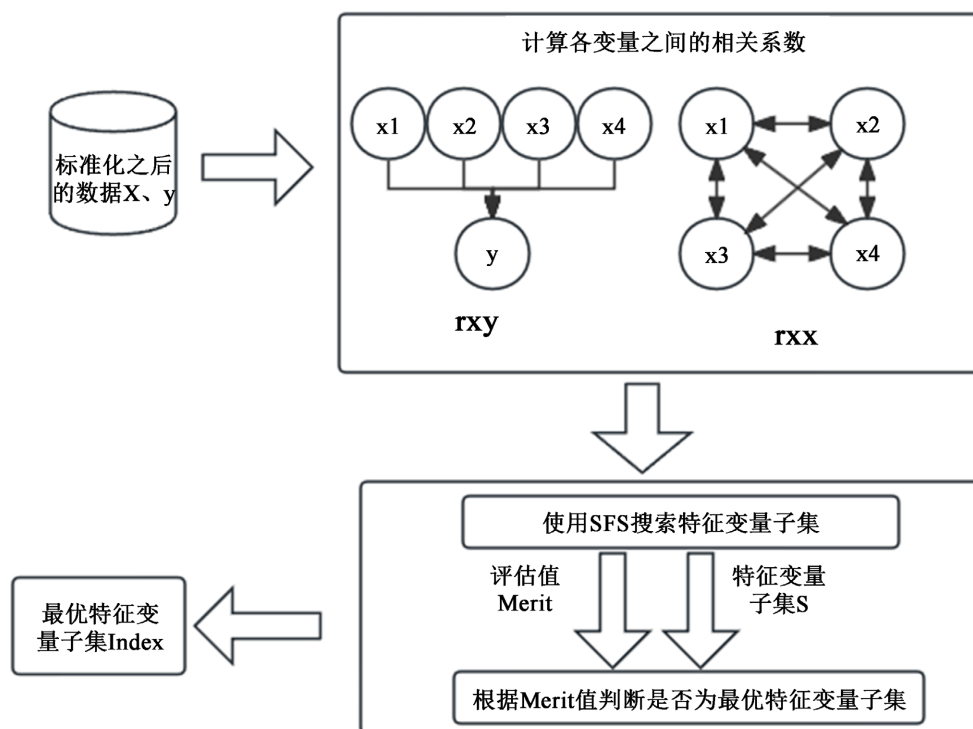


Figure 1. Schematic diagram of principle based on correlation feature filtering  
图 1. 基于相关性特征筛选的原理示意图

## 2.2. 门控循环神经网络

GRU 也称门控循环单元结构, 是传统 RNN 的变体, GRU 模型同 LSTM 一样能够有效捕捉长序列之间的语义关联, 可以有效缓解 RNN 模型中梯度消失或爆炸现象。同时 GRU 模型的结构和计算要比 LSTM 更简单, GRU 模型将 LSTM 模型中的遗忘门和输入门使用更新门来替代, 进一步降低了神经网络的计算复杂度、参数量和计算时间。GRU 网络结构如图 2 所示:

GRU 网络模型前向传播公式如下:

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z)$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r)$$

$$\tilde{h}_t = \tanh(W \cdot [r_t \cdot h_{t-1}, x_t] + b_h)$$

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \tilde{h}_t$$

其中,  $z_t$  为更新门, 用来控制  $t-1$  时刻的状态信息和  $t$  时刻的输入信息有多少被保留到当前状态, 其值越大表明保留信息越多;  $r_t$  为重置门, 用来决定遗忘  $t-1$  时刻的信息程度, 其值越小表明  $t-1$  时刻的状态信息带入的越少;  $\tilde{h}_t$  为  $t$  时刻候选集的状态;  $x_t$  为  $t$  时刻的输入向量;  $h_{t-1}$  为  $t-1$  时刻隐藏单元的输出信息;

$h_t$  为  $t$  时刻的输出信息;  $W$  为各类门的权重矩阵;  $b$  为各类门的偏置项;  $\sigma$  为 sigmoid 激活函数;  $\tanh$  为双曲正切激活函数。

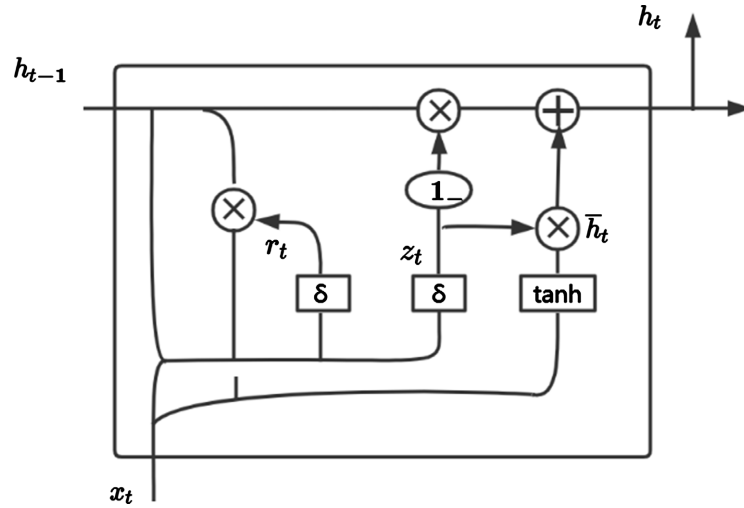


Figure 2. Structure diagram of GRU neural network  
图 2. GRU 神经网络结构图

### 2.3. 基于谱的图卷积神经网络

图卷积网络将卷积运算从传统数据推广到图数据。其核心思想是学习一个函数映射  $f(\cdot)$ , 通过该映射图中的节点  $v_i$  可以聚合它自己的特征  $x_i$  与它的邻居特征  $x_j$  ( $j \in N(v_i)$ ) 来生成节点  $v_i$  的新表示。图卷积网络是许多复杂图神经网络模型的基础, 包括基于自动编码器的模型、生成模型和时空网络等。GCN 方法又可以分为两大类, 基于谱(Spectral-Based)和基于空间(Spatial-Based)。基于谱的方法从图信号处理的角度引入滤波器来定义图卷积, 其中图卷积操作被解释为从图信号中去掉噪声。

图傅里叶变换(GFT)是频谱图卷积的基本算子。它将输入图投影到正交空间, 其中基由归一化图拉普拉斯算子的特征向量构成。归一化图拉普拉斯算子可以计算为:  $L = I_N - D^{-\frac{1}{2}}WD^{-\frac{1}{2}}$ , 其中  $I_N \in R^{N \times N}$  是单位矩阵,  $D$  是  $D_{ii} = \sum_j W_{ij}$  的对角度矩阵。然后, 我们对拉普拉斯矩阵进行特征值分解, 形成  $L = U\Lambda U^T$ , 其中  $U \in R^{N \times N}$  是特征向量矩阵,  $\Lambda$  是特征值对角矩阵。给定多元时间序列  $X \in R^{N \times T}$ , GFT 和 IGFT 的算子分别定义为  $GF(X) = U^T X = \hat{X}$  和  $GF^{-1}(\hat{X}) = U\hat{X}$ 。图卷积算子实现为特征值矩阵  $\Lambda$  的函数  $g\Theta(\Lambda)$ , 参数为  $\Theta$ 。整体时间复杂度为  $O(N^3)$ 。

### 2.4. 评价指标

为对模型预测结果作出直观评价, 本文选取了 3 种误差指标: MAE(平均绝对误差)、RMSE(均方根误差)以及 MAPE(平均绝对百分比误差)。研究对象的数量等级会对 MAE 和 RMSE 的绝对数值产生影响, 而 MAPE 作为百分比误差规避了这种差异。Pao 等根据 MAPE 的大小把预测效果分为: 高精度预测(MAPE < 10%)、良好预测(10% ≤ MAPE < 20%)、合理预测(20% ≤ MAPE < 50%)和不准确预测(MAPE ≥ 50%) 4 类。误差指标的计算方法如下:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|$$



$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

RMSE 为均方根误差, 其范围为  $[0, \infty)$ , 当预测值与真实值完全吻合时等于 0, 即为完美模型; 误差越大则 RMSE 的值越大。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}$$

其中  $\hat{y}_i$  表示碳价的预测值,  $y_i$  表示碳价的实际值,  $N$  表示数据集的个数。显然如果得到的这三个指标的数值越小, 则代表模型的预测精度越高。

### 3. 模型架构

图神经在时间序列预测方面尚未被广泛使用, 且现有的解决方案都没有在谱域中联合捕获时间模式和多变量依赖关系。

StemGNN 基于 GRU 和 GCN 提出了具有联合捕获序列间相关性和时间依赖性功能的新型碳排放权交易价格预测模型, 结合了图傅里叶变换(GFT)和离散傅里叶变换(DFT)。通过 GFT 和 DFT 后, 谱表示具有清晰的模式, 可以通过卷积和顺序学习模块进行有效预测, 整体网络结构如图 3 所示。

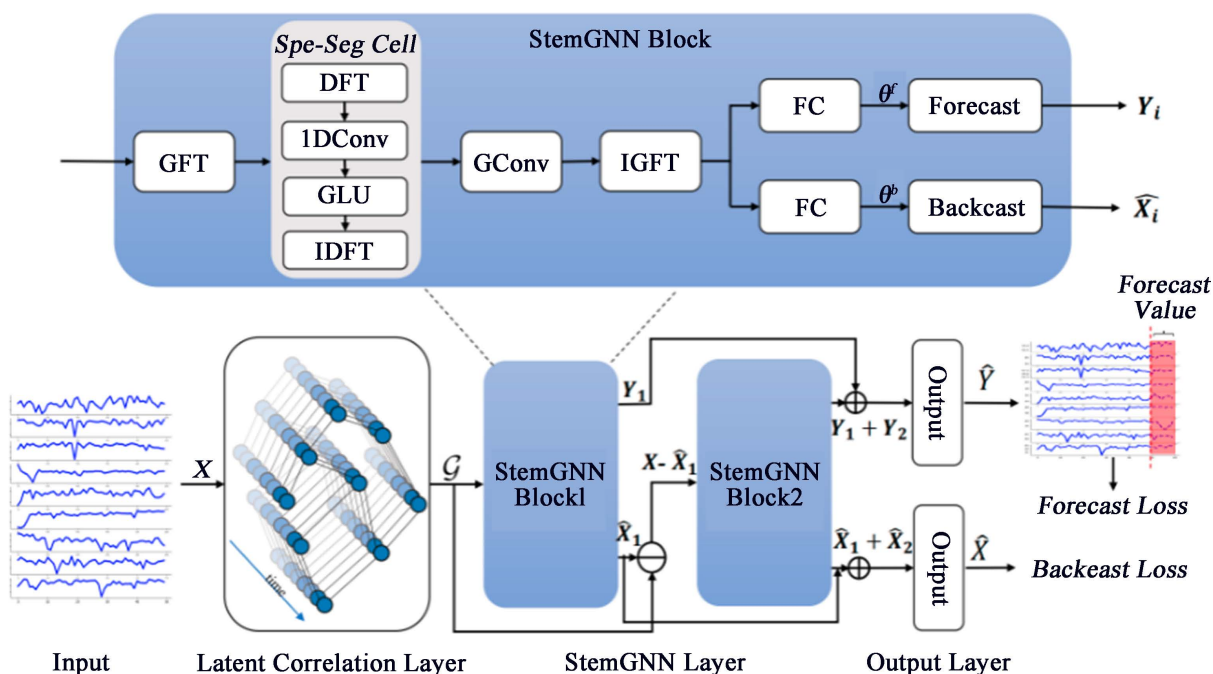


Figure 3. Overall network architecture diagram

图 3. 整体网络架构图

在对多变量时间序列进行建模时, 基于 GNN 的方法需要图结构。因此利用自注意力机制自动学习多个时间序列之间的潜在相关性。

首先, 输入  $X \in R^{N \times T}$  被送入一个门控循环单元(GRU)层, 该层依次计算每个时间戳  $t$  对应的隐藏状态。然后, 使用最后一个隐藏状态  $R$  作为整个时间序列的表示, 并通过自注意力机制计算权重矩阵  $W$ , 如下所示:

$$Q = RW^Q, K = RW^K, W = \text{Soft max} \left( \frac{QK^T}{\sqrt{d}} \right)$$

其中  $Q$  和  $K$  表示 query 和 key 的表示, 可以分别通过注意力机制中具有可学习参数  $W^Q$  和  $W^K$  的线性投影来计算;  $d$  是  $Q$  和  $K$  的隐藏维度大小。输出矩阵  $W \in R^{N \times N}$  作为图  $G$  的邻接权重矩阵。Self-attention 的整体时间复杂度  $O(N^2d)$ 。

图  $G = (X, W)$  作为两个残差 StemGNN 块组成的 StemGNN 层的输入。StemGNN 块的设计目的是在频谱域联合多变量时间序列内的结构和时间依赖性进行建模。首先, 图傅里叶变换(GFT)算子将图  $G$  转换为谱矩阵表示, 其中每个节点的单变量时间序列变为线性独立。然后, 离散傅里叶变换(DFT)算子将每个单变量时间序列分量变换到频域。在频域中, 分量被输入一维卷积和 GLU 子层以捕获特征模式, 然后通过逆 DFT 转换回时域。最后, 在谱矩阵表示上应用图卷积并执行逆 GFT。

在 StemGNN 层之后, 添加了一个由 GLU 和全连接(FC)子层组成的输出层。网络中有两种输出。预测输出  $Y_t$  被训练以生成对未来值的最佳估计, 而回溯输出  $\hat{X}_t$  以自动编码方式使用以增强多元时间序列的表示能力。最终的损失函数可以表示为预测损失和回溯损失的组合:

$$L(\hat{X}, X; \Delta_\theta) = \sum_{t=0}^T \|\hat{X}_t - X_t\|_2^2 + \sum_{t=K}^T \sum_{i=1}^K \|B_{t-1}(X) - X_{t-i}\|_2^2$$

其中第一项表示预测损失, 第二项表示回溯损失。对于每个时间戳  $t$ ,  $\{X_{t-K}, \dots, X_{t-1}\}$  是滑动窗口内的输入值,  $X_t$  是要预测的真实值,  $\hat{X}_t$  是时间戳  $t$  的预测值,  $B_{t-K}(X), \dots, B_{t-1}(X)$  是来自回溯模块的重构值。 $B$  表示产生回溯输出的整个网络,  $\Delta_\theta$  表示网络中的所有参数。

在推理阶段, 采用滚动策略进行多步预测。首先, 通过将  $\{X_{t-K}, \dots, X_{t-1}\}$  作为输入来预测  $\hat{X}_t$ 。然后, 输入将变为  $\{X_{t-K+1}, \dots, X_t\}$  用于预测下一个时间戳  $\hat{X}_{t+1}$ 。通过连续应用这种滚动策略, 可以获得下一个  $H$  个时间戳的预测值。

## 4. 实验分析

### 4.1. 参数设置

本文软件环境为 python3.8, 每个图卷积层的通道大小设置为 64, 1D 卷积的内核大小为 3。采用 RMSprop 作为优化器, 并且将训练时期的窗口大小设置为 50。学习速率初始化为 0.001, 每 5 个 epoch 后以 0.7 的速率衰减。

### 4.2. 数据来源

上海碳排放交易所目前已经成为全国规模和业务量最大的碳排放交易所之一, 并且目前正在牵头组建全国碳排放权交易所。因此, 本文选取其自 2019 年 7 月 17 日至 2023 年 4 月 13 日共 595 条交易数据进行实证分析。将数据按照 8:1:1 的比例划分为训练集、验证集以及测试集, 在训练集上对模型进行学习, 在验证集上用于调整超参数, 在训练集上验证模型的预测精度。对数据进行描述性统计如图 4~图 6 所示。

### 4.3. 影响因素变量选取

本文以上海市碳排放权交易试点为例, 对碳排放价格进行预测。关于解释变量本文根据查阅国内外相关的参考文献, 选取了初步认为对碳交易价格影响较大的几个因素, 同时考虑到数据的可获得性, 本

文选取中证 500 工业指数、沪深 300 指数、美元汇率、欧元汇率、温度、空气质量指数、原油期货、天然气期货、动力煤期货作为解释变量，变量的具体情况参见表 1。




Figure 4. Training set data trading price trend chart

图 4. 训练集数据交易价格走势图




Figure 5. Validation set data trading price trend chart

图 5. 验证集数据交易价格走势图

下面将从经济因素、能源价格、气候因素三个角度对采用的解释变量进行说明。

宏观经济的发展影响着社会的总供给与总需求，供需关系决定了社会的生产状况，生产状况越繁荣，则社会总体碳排放量越高，从而影响碳排放权价格。因此从经济因素角度出发，本文采用中证 500 工业指数、沪深 300 指数、美元汇率以及欧元汇率分为代表指标，分别用  $x_1$ 、 $x_2$ 、 $x_3$ 、 $x_4$  表示。经济发展水平会对社会的需求和消费产生直接影响，碳金融体系的运行离不开市场经济，由此国内外经济的变化情况会对碳价的波动产生重要影响。

在夏季或是冬季人们空调或暖气的使用率大大增加，导致全社会的用电需求量增加，从而引起发电






Figure 6. Test set data trading price trend chart  
图 6. 测试集数据交易价格走势图

Table 1. Specific situation of variables  
表 1. 变量具体情况

	变量	变量含义	类别	数据来源
被解释变量	$y$	碳价	碳交易价格	中国碳交易平台
解释变量	$x_1$	中证 500 工业指数	经济因素	英为财经网
解释变量	$x_2$	沪深 300 指数	经济因素	英为财经网
解释变量	$x_3$	美元汇率	经济因素	英为财经网
解释变量	$x_4$	欧元汇率	经济因素	英为财经网
解释变量	$x_5$	温度	气候因素	中国天气网
解释变量	$x_6$	空气质量指数	气候因素	中国空气质量在线监测分析平台
解释变量	$x_7$	原油期货	能源价格	英为财经网
解释变量	$x_8$	天然气期货	能源价格	英为财经网
解释变量	$x_9$	动力煤期货	能源价格	英为财经网

企业的碳排放量增加, 从而影响碳排放权的价格。空气质量指数主要对 CO<sub>2</sub>、PM 2.5、PM 10、CO、O<sub>3</sub> 等污染物进行检测, 进而反映了空气中主要污染物的含量。AQI 的值越高, 则意味着空气污染越严重, 因此政府分配给各企业的碳配额就会越少, 碳价会因此升高。因此从气候环境的角度出发, 本文选取空气质量指数及温度作为代表指标, 分别用  $x_5$ 、 $x_6$  表示。

能源价格与碳交易价格密切相关。煤、石油、天然气等能源价格的变动会引起企业对所使用的能源类型、所占比例以及消费总量的变化。一方面, 碳交易价格上涨时, 企业为了减少成本会减少对碳排放权的购买和使用。另一方面, 企业也可以通过改变生产方式、提高能源利用率或使用清洁能源的方式介绍对化石能源的使用, 导致二氧化碳排放量降低, 从而影响碳排放权的价格。本文选取原油期货、天然气期货以及动力煤期货这几个指标作为能源价格角度的主要因素, 分别用  $x_7$ 、 $x_8$ 、 $x_9$  表示。

对各影响因素进行描述性统计, 结果如表 2 所示。

**Table 2.** Descriptive statistical results of each factor  
**表 2.** 各因素描述性统计结果

	最小值	最大值	均值	标准偏差
上海碳排放权配额:成交均价	28.60	63.00	47.23	8.74
温度	-3.89	35.42	19.01	8.59
原油价格	-37.63	123.70	68.99	23.86
沪深 300 指数	3508.70	5597.33	4385.22	500.19
中证 500 指数	4658.39	7648.75	6218.56	671.22
美元汇率	6.31	7.32	6.75	0.28
欧元汇率	6.74	8.29	7.50	0.39
空气质量指数	10.17	167.79	48.07	22.46
天然气	1.55	9.65	4.16	2.16
动力煤期货	468.40	1700.00	769.81	194.28

因相关因素数目过多, 因此本文中只展现部分使用相关性函数的前向搜索计算过程如下(表 3):

**Table 3.** Partial results based on CFS feature screening  
**表 3.** 基于 CFS 特征筛选部分结果

Feature set	$k$	$\bar{r}_{xy}$	$\bar{r}_{xx}$	Merit
[]	0	N/A	N/A	0.0
[温度]	1	0.030	1.000	0.030
[温度, 原油价格]	2	0.386	-0.029	0.554
[温度, 原油价格, 沪深 300 指数]	3	0.136	-0.067	0.253
[温度, 原油价格, 沪深 300 指数, 中证 500 指数]	4	0.045	0.190	0.072
[温度, 原油价格, 沪深 300 指数, 中证 500 指数, 美元汇率]	5	0.069	-0.169	0.271
[温度, 原油价格, 沪深 300 指数, 中证 500 指数, 美元汇率, 欧元汇率]	6	-0.070	-0.213	0.67
[温度, 原油价格, 沪深 300 指数, 中证 500 指数, 美元汇率, 欧元汇率, 空气质量指数]	7	-0.074	-0.240	0.295
[温度, 原油价格, 沪深 300 指数, 中证 500 指数, 美元汇率, 欧元汇率, 天然气价格]	7	0.043	-0.169	0.962
[温度, 原油价格, 沪深 300 指数, 中证 500 指数, 美元汇率, 欧元汇率, 天然气价格, 动力煤价格]	8	0.072	-0.020	0.275
[温度, 原油价格, 沪深 300 指数, 中证 500 指数, 美元汇率, 欧元汇率, 空气质量指数, 天然气价格]	8	0.025	-0.221	0.096
[温度, 原油价格, 沪深 300 指数, 中证 500 指数, 美元汇率, 欧元汇率, 空气质量指数, 天然气价格, 动力煤价格]	9	0.053	-0.093	0.314

经过 CFS 特征筛选之后, 根据 Merit 值最大即为最优子集的原理, 筛选出最终的最优子集中包含温

度, 原油价格, 沪深 300 指数, 中证 500 指数, 美元汇率, 欧元汇率, 天然气价格等因素。

从而可以得知根据 CFS 原理, 碳排放权交易价格与温度、原油价格、沪深 300 指数、中证 500 指数、美元汇率、欧元汇率以及天然气价格等因素有关, 而动力煤价格以及空气质量指数这两个因素对于碳排放权价格的影响较弱。各影响因素的相关性矩阵热力图如图 7 所示。




Figure 7. Correlation heatmap of various influencing factors  
图 7. 各影响因素的相关性热力图

#### 4.4. 实验结果与分析

本文将 LSTM 网络、GRU 网络作为对比网络模型, 从而说明 StemGNN 在预测碳排放权交易价格方面的有效性。将筛选出的影响因素作为输入分别传入 LSTM、GRU、StemGNN 网络中, 得到的预测结果如表 4 所示。

Table 4. Prediction accuracy results of each model  
表 4. 各模型预测精度结果

模型	MAE	RMSE	MAPE (%)
LSTM	0.32	0.54	31
GRU	0.17	0.58	11.9
StemGNN	0.10	0.23	10.58

由表 4 可知, StemGNN 网络在各评价指标中都取得了良好表现, 总体效果均优于其他对比模型。StemGNN 网络相比于 LSTM 和 GRU 网络模型具有联合捕获序列间相关性和时间依赖性功能, 因此具有

较好的预测性能。图 8~图 10 分别为 LSTM 网络、GRU 网络模型以及 StemGNN 在上海碳排放权交易价格上的预测结果。其中, 横坐标代表预测天数, 单位为天, 纵轴为碳排放权交易价格, 单位为元。由图 10 可以看出, StemGNN 模型的预测值与实际真实值之间的拟合效果较好, 其预测性能明显高于其他对比模型的预测性能。




Figure 8. LSTM network prediction results

图 8. LSTM 网络预测结果




Figure 9. GRU network prediction results

图 9. GRU 网络预测结果




Figure 10. StemGNN network prediction results

图 10. StemGNN 网络预测结果

## 5. 结语

本文使用 StemGNN 模型, 即基于 GRU 和 GCN 提出了具有联合捕获序列间相关性和时间依赖性功能的新型预测模型对碳排放权交易价格进行预测, 并且采用了平均绝对百分比误差(MAPE)、平均绝对误差(MAE)、均方根误差(RMSE)作为预测模型拟合精度的衡量指标。通过测试分析, 我们可以得出 StemGNN 模型的预测值与实际真实值之间的拟合效果较好, 其预测性能明显高于其他对比模型的预测性能。因此, StemGNN 模型具备较好的预测能力, 相较于普通 LSTM、GRU 模型更加准确, 能够用于碳排放权交易价格的预测。并且以该模型为参考, 也可以对全国其他省的碳交易价格进行预测分析, 对碳金融市场的碳价预测具有一定的借鉴意义和参考价值。

## 基金项目

国家自然科学基金(2081112000701)。

## 参考文献

- [1] 曾诗鸿, 狐咪咪. 清洁发展机制研究综论[J]. 中国人口·资源与环境, 2013, 23(S2): 296-299.
- [2] 肖星宏, 万春林, 邓翔, 周璇. 欧盟碳排放交易体系及其对我国的启示[J]. 价格理论与实践, 2015(4): 101-103.
- [3] Deeney, P., Cummins, M., Dowling, M., et al. (2016) Influences from the European Parliament on EU Emissions Prices. *Energy Policy*, **88**, 561-572. <https://doi.org/10.1016/j.enpol.2015.06.026>
- [4] Aatola, P., Ollikainen, M. and Toppinen, A. (2013) Price Determination in the EU ETS Market: Theory and Econometric Analysis with Market Fundamentals. *Energy Economics*, **36**, 380-395. <https://doi.org/10.1016/j.eneco.2012.09.009>
- [5] Tan, X.P. and Wang, X.Y. (2017) Dependence Changes between the Carbon Price and Its Fundamentals: A Quantile Regression Approach. *Applied Energy*, **190**, 306-325. <https://doi.org/10.1016/j.apenergy.2016.12.116>
- [6] 林伯强, 蒋竺均. 中国二氧化碳的环境库兹涅茨曲线预测及影响因素分析[J]. 管理世界, 2009(4): 27-36.
- [7] 郭文军. 中国区域碳排放权价格影响因素的研究——基于自适应 Lasso 方法[J]. 中国人口·资源与环境, 2015(s1): 305-310.

- 
- [8] 陈欣. 中国碳交易市场价格研究——定价基础、影响因素及定价效率[D]: [博士学位论文]. 西安: 陕西师范大学, 2016.
- [9] 祝越. 我国碳排放权市场价格影响因素及其波动特征研究[D]: [硕士学位论文]. 杭州: 浙江财经大学, 2016.
- [10] 张云. 中国碳金融交易价格机制研究[D]: [博士学位论文]. 长春: 吉林大学, 2015.
- [11] 张玉娟. 基于随机波动模型的碳价格波动性研究[D]: [硕士学位论文]. 芜湖: 安徽工程大学, 2013.
- [12] 王煦楠. 碳排放权价格影响因素分析[D]: [硕士学位论文]. 长春: 吉林大学, 2016.
- [13] 欧阳屹欣. 碳排放权交易价格的影响因素分析[J]. 时代金融, 2017(9): 284-285.
- [14] Zhou, J.G. and Chen, D.F. (2021) Carbon Price Forecasting Based on Improved CEEMDAN and Extreme Learning Machine Optimized by Sparrow Search Algorithm. *Sustainability*, **13**, 4896-4896. <https://doi.org/10.3390/su13094896>
- [15] 魏宇, 张佳豪, 陈晓丹. 基于 DMS 和 DMA 的我国碳排放权交易价格预测方法研究——来自湖北碳市场的经验证据[J]. 系统工程, 2022, 40(4): 1-16.
- [16] 王娜. 基于大数据的碳价预测[J]. 统计研究, 2016, 33(11): 56-62.
- [17] 高杨, 李健. 基于 EMD-PSO-SVM 误差校正模型的国际碳金融市场价格预测[J]. 中国人口资源与环境, 2014, 24(6): 163-163.
- [18] 张晨, 杨仙子. 基于多频组合模型的中国区域碳市场价格预测[J]. 系统工程理论与实践, 2016, 36(12): 3017-3025.