

# 基于深宽网络模型的碳价预测

## ——基于LSTM-BLS的湖北碳排放权交易价格预测

王可欣

燕山大学理学院, 河北 秦皇岛

收稿日期: 2024年3月25日; 录用日期: 2024年4月15日; 发布日期: 2024年4月23日

### 摘要

近年来, 随着温室效应的愈发严重, 极端天气事件频发, 控制碳排放成为了当前全世界人们最为紧迫的共同任务。碳交易市场作为控制减碳的重要金融工具, 其健康发展依赖于稳定的碳价。准确地预测碳价不仅有助于投资者进行投资, 也有助于政策制定者制定合理的制度。本研究提出了一种结合长短期记忆网络(LSTM)和宽度学习(BLS)的LSTM-BLS预测模型, 以提高碳价预测的准确性和效率。通过对我国8个地方碳交易中发展时间较长, 交易量较多的湖北碳交易所的碳价数据进行实证分析, 发现引入宽度学习之后的模型预测效果优于基线模型和单一长短期记忆神经网络模型。研究结果为碳市场参与者提供了更可靠的预测工具。然而, 本研究也具有一定的局限性, 未来工作中将进一步考虑影响碳价的多因素数据, 不断对模型进行优化。

### 关键词

宽度学习, 碳价预测, 长短期记忆神经网络

# Based on the Deep and Broad Network Model for Carbon Price Forecasting

## —Prediction of Hubei Carbon Emission Rights Trading Price Based on LSTM-BLS

Kexin Wang

School of Science, Yanshan University, Qinhuangdao Hebei

Received: Mar. 25<sup>th</sup>, 2024; accepted: Apr. 15<sup>th</sup>, 2024; published: Apr. 23<sup>rd</sup>, 2024

### Abstract

In recent years, as the greenhouse effect has intensified, extreme weather events have become

文章引用: 王可欣. 基于深宽网络模型的碳价预测[J]. 统计学与应用, 2024, 13(2): 411-418.

DOI: 10.12677/sa.2024.132040

more frequent, making carbon emission control the most urgent common task for people worldwide. The carbon trading market, as an important financial instrument for reducing carbon emissions, relies on stable carbon prices for its healthy development. Accurate carbon price forecasting not only helps investors in their investment decisions but also assists policymakers in establishing reasonable systems. This study proposes an LSTM-BLS prediction model that combines Long Short-Term Memory Networks (LSTM) with Broad Learning System (BLS) to improve the accuracy and efficiency of carbon price forecasting. Through empirical analysis of the carbon price data from the Hubei Carbon Exchange, one of the eight local carbon trading markets in China with a longer development history and higher trading volume, we found that the model's predictive performance, after incorporating width learning, is superior to that of the baseline model and the single LSTM model. The research results provide carbon market participants with a more reliable forecasting tool. However, this study also has certain limitations, and future work will further consider multi-factor data that affects carbon prices, continuously optimizing the model.

## Keywords

Broad Learning System, Carbon Price Forecasting, Long Short-Term Memory Neural Network

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

我国作为世界上最大的二氧化碳排放国，曾在第 75 届联合国大会上承诺，到 2030 年达到碳排放峰值，到 2060 年实现碳中和。碳金融是实现减碳目标的重要且不可缺少的金融手段。碳排放权交易(简称碳交易)体系的建立，可以通过市场对碳排放进行调节，但由于我国碳交易市场起步较晚，有很多学者的研究是基于发展更为成熟的欧盟碳交易体系进行，并不完全适配我国碳交易市场的发展现状，因此需要对我国自己的碳交易市场进行研究。碳交易市场中碳排放权交易价格(简称碳价)的预测，是碳交易市场研究的重要部分。

## 2. 研究现状分析

碳排放权交易市场是利用市场机制控制和减少温室气体排放的政策工具[1]。碳排放权交易通过显性碳定价原则，也称“污染者付费”原则，将排放的负外部效应内部成本化，为处理经济发展与减排关系难题提供了一种解决方案。当前国际上发展最成熟，影响力最大的是欧盟排放交易体系，因此有很多的研究是基于欧盟的碳价数据进行的。2011 年 10 月，我国正式批准了包括北京、天津、重庆、上海、湖北、广东和深圳在内的七省市率先开展碳排放权交易市场试点，并于 2021 年 7 月正式启动全国碳市场。随着我国碳市场的不断完善，也需要针对我国本土的碳交易体系进行研究分析，从而可以更加科学稳妥的发展，早日实现减排目标。

目前针对碳价预测，有很多学者从多方面进行研究。传统的统计学方法主要包括自回归差分移动平均模型(ARIMA)、广义自回归条件异方差模型(GARCH)、自回归模型(AR)、线性回归方法等，在使用传统的统计模型方面。Heia 和 Haraldur [2]首先引入了多元线性回归模型来对碳价进行预测，Byun 和 Cho 则提出了基于不同 GARCH 类型的预测模型来预测碳期货的波动率[3]。随着研究的不断深入，Sanin 等提出了在 ARMAX-GARCH 模型中引入时变跳跃概率[4]，随后进行实证并取得了较好的预测结果。然而，由于碳价具有非平稳非线性的特点，在利用传统统计学模型进行预测之前，需要先对碳价数据进行处理

使得其平稳后才可以进行预测。考虑引入基于人工智能的预测方法。其中，常见的用于碳价预测的单一模型主要包括人工神经网络(ANN)模型[5]、最小二乘支持向量回归(LSSVR) [6]等。但常常由于价格序列的噪声大，波动幅度强，导致单一模型的预测性能并不是很准确。所以目前更多的碳价模型是集成模型，Zhu [7]提出了基于 EMD 算法来分解数据并利用 ANN 来预测的模型，有效地提高了碳价的预测精度。随后，高杨和李健[8]构建了基于 EMD-PSO-SVM 算法的误差矫正模型，发现该模型对欧盟碳价和欧盟的减排量价格都具有较高的预测精度。2022 年，魏宇等[9]运行多种模型进行对比，在经典预测模型、动态模型选择和动态模型平均方法中发现，动态模型选择的结果更加准确。随后 2023 年，朱亮亮等[10]也对 ARIMA 模型、多项式回归算法和 LSTM 模型进行对比，最终效果最好的模型是 PCC-LSTM 模型。

LSTM 模型对于时间序列的处理能力很优秀，可以捕捉到非线性关系以及序列中的长期依赖性，而金融数据又是典型非线性的时间序列数据，并且金融市场的很多趋势都会跨越较长时间，因此可以推断 LSTM 模型可以很大程度上提高对金融数据的预测，例如丁文娟[11]分别利用 ARIMA 模型与 LSTM 模型分别对一只股票数据进行预测，得出针对于股票的预测精度而言，LSTM 模型的结果优于 ARIMA 模型。但 LSTM 模型又存在一些不可避免的缺点，例如 LSTM 模型的内部比较复杂，极易发生过拟合的现象；金融数据包括大量噪声，LSTM 模型也可能学习到这些噪声，从而影响预测的准确率；模型的结构特点也容易造成局部最优化的缺点。而宽度学习 BLS 的提出也为序列预测提供了新的思路，BLS 具有不用进行大量计算，直接计算权重，泛化能力强的特点，CHEN 等[12]也在理论层面证明了该方法在涉及时序数据的预测上有很好的函数逼近能力，并通过具体实验得到与现在的几种算法相比，BLS 模型在回归方面更加优越。

综上所述，本文利用 BLS 模型高效的优点，结合 LSTM 在金融数据上优秀的表现能力，构建基于 LSTM-BLS 模型的碳价预测模型。通过将 LSTM 模块的输出特征承接 BLS 模型，以防止出现梯度爆炸，局部最优等问题，从而建立更加高效准确的碳价预测模型。

### 3. 模型结构

#### 3.1. 宽度学习

宽度学习(Broad Learning System, BLS)是澳门大学陈俊龙教授在 2018 年基于随机向量函数链神经网络(Random Vector Functional-Link Neural Network, RVFLNN)提出的一种灵活结构网络[13]。BLS 有很好的泛化能力，并且如果需要加入新的数据，也有很快的进行扩展，不需要重新训练模型。其网络结构如图 1 所示。

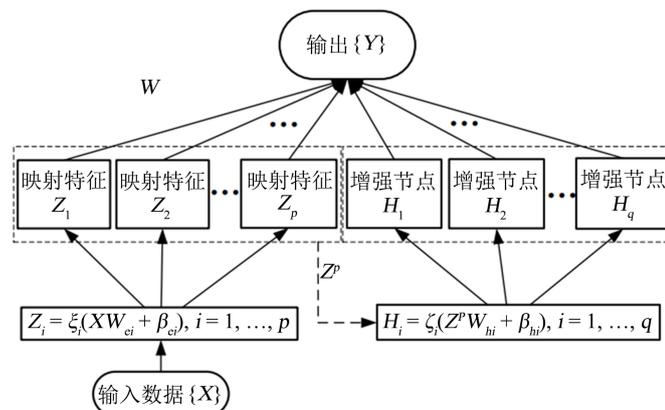


Figure 1. Broad learning system network structure diagram  
图 1. 宽度学习网络结构

假设数据集  $X$ , 包含  $N$  个样本, 每个样本有  $M$  个维度,  $Y$  是属于  $R^{N \times Q}$  的输出矩阵,  $Q$  是输出的维度。利用公式(1), 特征映射为  $\varphi_i, i=1,2,\dots,n$ , 得到特征层的各个特征节点  $Z_i$  可以表示为:

$$Z_i = \varphi(XW_{ei} + \beta_{ei}), i=1,2,\dots,n \tag{1}$$

式中,  $W_{ei}$  和  $\beta_{ei}$  分别为随机生成的稀疏化链接权重和偏置;  $n$  为特征层特征节点的组数。 $Z^n \equiv [Z_1, Z_2, \dots, Z_n]$  表示所有特征节点  $Z_i$ 。随后把所有特征节点  $Z^n$  作为增强层的输入, 经过非线性激活函数  $\xi(\bullet)$ , 得到增强层的各个增强节点  $E_j$  可以表示为:

$$E_j = \xi(Z_n W_{hj} + \beta_{hj}), j=1,2,\dots,m \tag{2}$$

式中,  $W_{hj}$  和  $\beta_{hj}$  分别为随机权重和偏置。BLS 的增强层节点可以表示为  $E^n \equiv [E_1, E_2, \dots, E_m]$ 。结合特征节点和增强节点, BLS 的公式可以表示为:

$$Y = [Z_1, \dots, Z_n | E_1, \dots, E_m]W = [Z_n | E_m]W = HW \tag{3}$$

式中,  $W$  为 BLS 模型的输出权重, 可由加权岭回归的求解方法得到:

$$W = (\lambda I + H^T H)^{-1} H^T Y \tag{4}$$

其中,  $\lambda$  为正则化系数,  $I$  为单位矩阵。

### 3.2. 长短期记忆网络

长短期记忆网络(Long Short-Term Memory, LSTM)是循环神经网络(Recurrent Neural Network, RNN)的一种特殊情况, 是 1997 年由 Hochreiter 和 Schmidhuber 首次提出。LSTM 模型在处理时间序列数据方面由明显的优势, 其和 RNN 模型中不同的组成部分可以减少 RNN 在处理长序列数据时产生的梯度爆炸或梯度消失的问题。所有的 LSTM 都具有一种重复神经网络模式的链式形式, 重复的结构模式都是一个结构, 可以如图 2 所示。

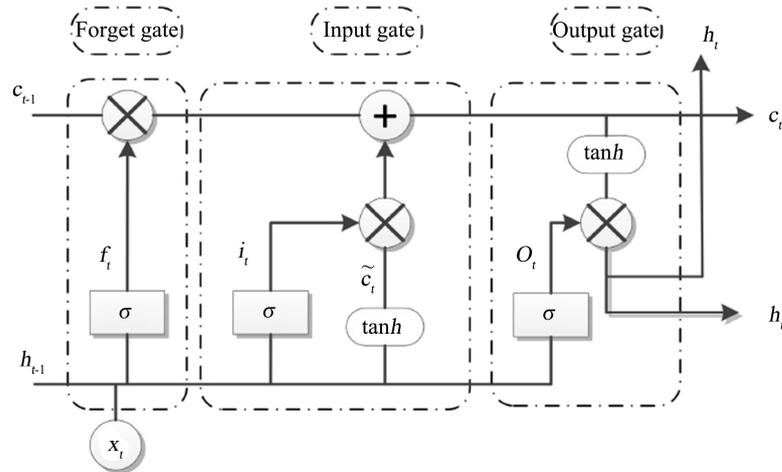


Figure 2. Long short-term memory structural principle  
图 2. LSTM 模型结构原理

其中,  $X_t$  是输入的数据向量,  $i_t$  是时间为  $t$  时的输入状态,  $f_t$  为时间为  $t$  时的单元遗忘状态,  $o_t$  为时间为  $t$  时的输出状态,  $h_{t-1}$  和  $c_{t-1}$  是时间为  $t-1$  时的隐藏状态和单元状态。LSTM 模型是通过引入 tanh 和 sigma 为激活函数  $\sigma$  的公式加入非线性特征。具体流程计算公式为:

$$f_t = \sigma(W_f \cdot [h_{t-1}, X_t] + b_f) \quad (5)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, X_t] + b_i) \quad (6)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (7)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (8)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, X_t] + b_o) \quad (9)$$

$$h_t = o_t * \tanh(C_t) \quad (10)$$

其中,  $W_f$ 、 $W_i$ 、 $W_o$ 、 $W_c$  分别为遗忘门、输入门、输出门以及记忆单元的权重矩阵,  $b_f$ 、 $b_i$ 、 $b_o$ 、 $b_c$  分别代表遗忘门、输入门、输出门以及记忆单元的输出值, 其中符号 \* 是指 Hadamard 积。LSTM 模型的关键在于其单元状态, 用来对数据进行存储和筛选。

### 3.3. LSTM-BLS 模型

融合 LSTM 模型和 BLS 模型的优势, 提出 LSTM-BLS 相结合的数据预测模型, 将预处理后的数据输入 LSTM 模块提取输入数据的特征, 将输出的数据作为 BLS 模型的输入数据进行输入, 再次提取数据的特征, 同时自动生成特征节点和增强节点, 输出最终的预测结果。

## 4. 模型实证检测

### 4.1. 数据准备

我国全国性的碳交易市场于 2021 年 7 月开始, 数据量较少, 考虑选取发展时间更长, 数据量更多的湖北碳市场, 时间选取为 2014 年 4 月 28 日至 2023 年 9 月 1 日, 共计 2209 个数据, 选择前 80% 时间序列数据为训练集, 后 20% 的序列数据为测试集。由于交易市场仅在交易日开放, 存在部分时间缺失问题, 本文在数据预处理阶段剔除空缺数据, 构建更加可靠的序列数据并利用公式(11)对数据进行归一化处理, 公式为:

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (11)$$

其中,  $x_{max}$  和  $x_{min}$  分别代表数据中的最大值和最小值。在归一化处理之后, 考虑使用窗口滑动法对序列数据进行处理, 窗口滑动法可以提取序列的局部特征, 这对于捕捉时间序列中的短期依赖关系和模式非常有用。

### 4.2. 实验设置

实验的参数设置, 针对 LSTM 模块, 考虑 2209 个数据量不算庞大, 本研究选择了较小的参数, 其中参数含义分别为: Layers (层数)是指 LSTM 模型中堆叠的 LSTM 层的数量, 每一层都包括一定数量的神经元; Number of neurons (神经元数目)每一层中的神经元数据, 神经元是 LSTM 的基本单元; batch size (批量大小)是指每次模型参数更新前, 一次训练所需的样本数; Epoch (迭代次数)是指数据集完整送入网络几次; Activation (激活函数), 针对 LSTM 常用 tanh 和 sigmoid 作为激活函数; Loss (损失函数)用于量化预测值和真实值之间的误差, 对于回归问题, 常用 MSE 作为损失函数; Optimizer (优化器)则是决定了如何对权重进行更新以达到最优效果, Adan 是通用选择。随后, 将 Dense 层链接 LSTM 模型和 BLS 模型, 其中 BLS 模型参数中的 N1 表示每个窗口的特征映射层的节点数, 它决定了每个窗口生成的特征数量; N2 表示窗口的数量, 每个窗口都会生成一组特征; N3 表示增强层的节点数, 用于进一步提取特征; s

表示收缩参数，用于控制增强层输出的范围；c 表示正则化参数，用于控制输出权重的平滑度。经过多次调整参数信息，最终得到最优参数，如表 1 的参数信息。

**Table 1.** Parameter data

**表 1.** 参数数据

Method	Parameter	values
LSTM	Number of neurons	{64, 32, 16}
	Dropout	0.2
	Batch size	128
	Epoch	200
	Activation	tanh
	Loss	mse
	Optimizer	Adam
Dense	Number of neurons	10
	layer	2
BLS	N1	10
	N2	7
	N3	80
	s	0.8
	c	1e-6

本文选取 3 个指标进行模型效果对比，分别为 MAE，RMSE，R<sup>2</sup>\_score，其公式分别为：

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |\tilde{y}(i) - \tilde{y}| \quad (12)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\tilde{y}(i) - y(i))^2} \quad (13)$$

$$\text{R}^2\_score = 1 - \frac{\sum_{i=1}^n (y(i) - \tilde{y}(i))^2}{\sum_{i=1}^n (y(i) - \bar{y})^2} \quad (14)$$

其中， $y(i)$ 、 $\tilde{y}(i)$  以及  $\bar{y}$  分别表示实际值、预测值和平均值。

### 4.3. 结果分析

通过 python 编程实现 LSTM-BLS 模型的结果，并给出与基线模型：ARIMA 和 SVM 模型以及单一 LSTM 模型的预测结果对比，见表 2。可以看出，基线模型相比 LSTM-BLS 模型在具体数据的表现上存在明显差距。SVM 模型在处理金融数据这类较复杂的数据时存在一定缺陷，LSTM 模型对于金融序列数据处理能力较好，但存在一定的梯度问题，ARIMA 模型对于处理平稳数据具有优势，但由于碳价数据具有非平稳非线性的特点，需要经过差分后进行处理，对碳价的预测准确率也比不上本文提出的模型。

**Table 2.** Comparison of results between the LSTM-BLS model and baseline models  
**表 2.** LSTM-BLS 模型与基线模型结果数据对比

	MAE	RMSE	R <sup>2</sup> _score
ARIMA	0.9668	0.9832	-0.0019
SVM	0.9926	0.9963	-0.0263
LSTM	0.0237	0.0269	0.0569
LSTM-BLS	0.0080	0.0081	0.5999

## 5. 结束语

关于碳价的预测一直是研究我国碳交易市场的重要组成部分，碳价受诸多因素影响，尤其受到政策制定的影响，但碳价的走势也影响市场制度制定者的决定。随着我国碳交易市场的不断发展，2024年1月5日，国务院发布了《碳排放权交易管理暂行条例》，自2024年5月1日起施行。这个条例的目的是为了规范碳排放权交易及相关活动，加强对温室气体排放的控制，并促进经济社会绿色低碳发展。促进低碳发展，早日达成减碳目标，都离不开碳市场的发展。对于普通投资者而言，碳价也是最为直观信息体现。因此，如何高效准确地预测碳价也是我们一直以来不断研究的领域。本文将宽度学习与深度学习针对时序数据表现良好的循环神经网络模型相结合，提出了融合 LSTM 和 BLS 的碳价预测模型。通过实例对比，发现 BLS 模型可以有效地解决 LSTM 会在预测中出现的拟合效果差等问题，从而提高整体模型的预测准确率。同时，BLS 具有高效的优点，仅 BLS 模型的预测运行时间不到 0.01 秒，同时 BLS 模块对于运行环境的要求相较于其他复杂的神经网络更加宽松，针对数据量不大的碳价数据，正常的笔记本电脑即可进行实现。因此，LSTM-BLS 模型同时具备准确率高和运行速度快的优点。

但是，本文仅考虑了基于碳价的历史数据进行预测，并未考虑引入其他影响碳价因素的数据，例如原油价格、欧盟碳价、天然气价格、全球范围内的政策等因素，同时，由于我国是先在地方进行试点，所以关于各个试点和全国碳价之间的联系也应该考虑在内。在后续工作中，会考虑多因素的深宽网络模型结果的碳价预测，从而提供更准确的预测数据。

## 参考文献

- [1] 《第四次气候变化国家评估报告》编写委员会. 第四次气候变化国家评估报告特别报告: 国家碳市场评估报告 [M]. 北京: 商务印书馆, 2013.
- [2] Heiea, N.G. and Haraldur, O.H. (2011) Predicting the Price of EU ETS Carbon Credits. *Procedia Systems Engineering*, **1**, 481-489. <https://doi.org/10.1016/j.sepro.2011.08.070>
- [3] Byun, S.J. and Cho, H.J. (2013) Forecasting Carbon Futures Volatility Using GARCH Models with Energy Volatilities. *Energy Economics*, **40**, 207-221. <https://doi.org/10.1016/j.eneco.2013.06.017>
- [4] Sanin, M.E., Violante, F. and Mansanet, B.M. (2015) Understanding Volatility Dynamics in the EU-ETS Market. *Energy Policy*, **82**, 321-331. <https://doi.org/10.1016/j.enpol.2015.02.024>
- [5] Feng, Z.H., Zou, L.L. and Wei, Y.M. (2011) Carbon Price Volatility: Evidence from EU ETS. *Applied Energy*, **88**, 590-598. <https://doi.org/10.1016/j.apenergy.2010.06.017>
- [6] Zhu, B.Z., Shi, X.T., Chevallier, J., et al (2016) An Adaptive Multiscale Ensemble Learning Paradigm for Nonstationary and Nonlinear Energy Price Time Series Forecasting. *Romanian Journal of Economic Forecasting*, **35**, 633-651. <https://doi.org/10.1002/for.2395>
- [7] Zhu, B.Z. (2012) A Novel Multiscale Ensemble Carbon Price Prediction Model Integrating Empirical Mode Decomposition, Genetic Algorithm and Artificial Neural Network. *Energies*, **5**, 355-370. <https://doi.org/10.3390/en5020355>
- [8] 高杨, 李健. 基于 EMD-PSO-SVM 误差修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): 163-170.

- [9] 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——来自湖北碳市场的经验证据[J]. 系统工程, 2022, 40(4): 1-17.
- [10] 朱亮亮, 肖楚鹏, 余梦, 等. 基于 PCC-LSTM 模型的全国碳排放权交易价格预测[J]. 环境保护科学, 2023, 49(5): 1-14.
- [11] 丁文娟. 基于股票预测的 ARIMA 模型、LSTM 模型比较[J]. 工业控制计算机, 2021, 34(7): 109-112, 116.
- [12] Chen, C.L.P., Liu, Z. and Feng, S. (2019) Universal Approximation Capability of Broad Learning System and Its Structural Variations. *IEEE Transactions on Neural Networks and Learning Systems*, **30**, 1191-1204.  
<https://doi.org/10.1109/TNNLS.2018.2866622>
- [13] Chen, C.L.P. and Liu, Z. (2018) Broad Learning System: An Effective and Efficient Incremental Learning System without the Need for Deep Architecture. *IEEE Transactions on Neural Networks & Learning Systems*, **29**, 10-24.  
<https://doi.org/10.1109/TNNLS.2017.2716952>