



技术报告

基于 Informer 技术和 MindSpore 平台的 股票价格预测系统

参赛队名: 魔仙堡

队 长: 李明娟

邮 箱: 3151508285@qq.com

组员名单: 袁俊彬 王一琦

指导老师: 徐清振

参赛单位: 华南师范大学 人工智能学院

作品类别: 项目贡献赛道

作品链接: <https://www.gitlink.org.cn/limingjuan/Prediction-MindSpore>

摘要： 股票价格预测一直是金融领域的重要问题，对于投资者和金融机构来说具有重要的价值。然而，股票价格受多种因素影响，包括市场情绪、公司业绩、宏观经济等，因此具有挑战性。在本研究中，我们利用 MindSpore 框架构建了一个股票价格预测模型，该模型基于 Informer，能够捕获多种时间序列数据的关联性，并预测未来的股票价格趋势。我们使用了大量的历史股票价格数据和相关因素，通过训练和优化模型来提高预测准确性。本报告还包括了实验结果和性能评估，以验证模型的有效性和可行性。我们的研究为金融领域提供了一个强大的工具，用于更好地理解 and 预测股票市场的动态，帮助投资者和金融专业人士做出更明智的决策。

关键词： 股票价格预测、MindSpore、Informer

目录

1 设计方案	1
1.1 需求分析	1
1.2 国内外研究现状	1
1.3 设计目标	2
2 实现方案	2
2.1 数据获取	2
2.2 Transformer 模型	3
2.2.1 transformer 简介	3
2.2.2 transformer 架构	4
2.3 Informer 模型创新	5
2.4 Informer 原理	5
2.4.1 模型改进	5
2.4.2 Informer 架构	6
2.5 informer 模型的应用	7
2.5.1 股票价格预测	7
2.5.2 交易策略	7
2.5.3 训练	8
3 实验数据与结果	10
3.1 实验条件	10
3.2 实验数据集	10
3.3 模型评估	11
3.4 模型训练	11
3.5 实验结果与分析	13
3.5.1 模型训练结果	13
3.6 作品展示	15
4 特色创新	17
5 总结与展望	17
5.1 总结	17

5.2 展望.....	18
6 参考文献.....	19

1 设计方案

1.1 需求分析

如今，金融市场的波动性不断增加，对股票价格预测的准确性提出了更高的要求。在这一背景下，人工智能技术正在逐渐崭露头角，成为股票市场参与者的工具之一。股票市场需要及时、准确的决策来确保投资者和金融机构的安全。传统的股票价格预测方法依赖于统计分析和基本面分析，然而，这些方法在面对复杂、多变的市场情况时往往表现不佳。因此，人工智能技术在股票价格预测中的应用变得尤为重要。

1.2 国内外研究现状

研究表明，传统的股票价格预测方法仍然依赖于统计分析和基本面分析，但在面对复杂、多变的市场情况时，这些方法往往表现不佳。这导致了对更先进、更精确的预测方法的迫切需求，因此，人工智能技术在股票价格预测中的应用逐渐成为研究的热点和重要方向。国际上，许多研究团队和金融机构已经开始探索机器学习和深度学习技术在股票价格预测中的应用。例如，使用循环神经网络（RNN）和长短时记忆网络（LSTM）等深度学习模型，研究人员能够更好地捕捉时间序列数据中的模式和趋势，提高了预测的准确性。此外，卷积神经网络（CNN）等视觉处理技术也被应用于分析股票市场图表数据，以提供更全面的信息。国内研究方面，中国的学术界和企业也积极参与了股票价格预测的研究与应用。一些国内的科研机构和互联网公司正在开发基于大数据和自然语言处理（NLP）的模型，以分析新闻、社交媒体等文本数据对股票市场的影响。同时，利用强化学习技术来制定交易策略和风险管理策略也引起了广泛关注。国内外研究机构和从业者正在积极探索各种人工智能技术在股票价格预测中的应用，旨在提高市场决策的准确性、实时性和风险管理水平。这些研究为股票市场的未来发展提供了新的机会和挑战，也为投资者和金融专业人士提供了更多的工具和方法来应对不断变化的市场环境。

1.3 设计目标

本研究的设计目标是基于 Informer 模型进行股票价格预测应用研究。我们旨在获取大量历史股票价格数据和相关因素数据，通过 Informer 模型实现更准确的价格预测，捕捉时间序列数据的关联性。同时，我们追求实时性和高效性，建立实时数据处理系统，监测市场变化并进行实时预测，以协助投资者在快速变化的市场中做出明智决策。我们强调模型性能评估，包括历史数据回测和实盘测试，以验证实际应用价值。数据安全和隐私保护是关键，确保严格遵守法规和标准，保障数据的安全性。最终目标是提供可靠高效的股票价格预测应用，助力投资者理解市场、降低风险、支持明智决策。这一设计旨在为金融市场提供强大工具，更好地应对股票市场动态。

2 实现方案

2.1 数据获取

本方案中我们主要使用纯数字数据，来源为 Tushare 大数据开放社区 (www.tushare.pro)，数据获取的核心流程为登录社区，注册 token，并使用相关接口 API(<https://tushare.pro/document/2>)调用所需股票数据即可。另外，除了直接在金融社区与平台调用接口，还可以使用相关脚本获取所需股票数据，例如 Python 的 beautifulsoup4。

名称	类型	描述
ts_code	str	股票代码
trade_date	str	交易日期
open	float	开盘价
high	float	最高价
low	float	最低价
close	float	收盘价
pre_close	float	昨收价（前复权）
change	float	涨跌额
pct_chg	float	涨跌幅（未复权）
vol	float	成交量（手）
amount	float	成交额（千元）

表 1 股票数据常见格式

2.2Transformer 模型

2.2.1 transformer 简介

Transformer 是一种深度学习模型架构，最初由 Vaswani 等人于 2017 年提出，并被广泛用于自然语言处理（NLP）和其他序列建模任务。它的设计革命性地改变了序列数据处理的方式，取代了传统的循环神经网络（RNN）和卷积神经网络（CNN）等传统结构。以下是 Transformer 模型的主要特点和组成部分：

1. 自注意力机制（Self-Attention）：Transformer 的核心是自注意力机制，它允许模型在处理序列数据时根据序列中的其他元素来动态地分配不同的权重。这使得模型能够同时关注序列中的所有位置，而不是像 RNN 那样逐步处理；2. 多头自注意力（Multi-Head Attention）：为了增强模型的表达能力，Transformer 引入了多个自注意力头，每个头学习不同的关注权重，然后将它们合并在一起，以更好地捕捉不同的序列关系；3. 位置编码（Positional Encoding）：由于 Transformer 不具备像 RNN 那样的固定位置处理能力，需要通过位置编码来注入序列元素的位置信息，以便模型能够理解元素的顺序；4. 编码器-解码器架构（Encoder-Decoder Architecture）：Transformer 常常被用于序列到序列的任务，如机器翻译。为此，它采用了编码器和解码器两个模块，编码器用于将输入序列编码成固定长度的表示，而解码器则将这个表示解码成目标序列；5. 残差连接和层归一化（Residual Connections and Layer Normalization）：Transformer 使用残差连接和层归一化来加速训练和提高模型稳定性；6. 位置感知前馈网络（Position-wise Feed-Forward Networks）：Transformer 中的前馈网络针对每个序列位置独立地进行计算，增加了模型的灵活性；7. 掩码注意力（Masked Attention）：在自注意力中，为了处理序列数据，解码器需要对之后的位置进行掩码，以避免未来信息的泄漏。

Transformer 模型的成功在 NLP 任务中取得了显著的突破，例如 BERT、GPT、T5 等模型都基于 Transformer 架构。此外，它还在计算机视觉、语音处理和其他领域的序列建模任务中取得了重大进展，成为深度学习中的重要里程碑之一。

2.2.2 transformer 架构

Transformer 架构是一种用于序列到序列 (Sequence-to-Sequence, Seq2Seq) 任务的深度学习模型架构, 最初由 Vaswani 等人在 2017 年提出。它革命性地改变了自然语言处理 (NLP) 和其他序列建模任务的方式, 取代了传统的循环神经网络 (RNN) 和卷积神经网络 (CNN) 等结构。以下是 Transformer 架构的主要组成部分:

1. 编码器 (Encoder) : 多层堆叠: Transformer 包含多个相同的编码器层, 每个层都独立执行一系列操作; 自注意力机制 (Self-Attention) : 编码器的核心是自注意力机制, 允许模型在处理序列时根据序列中的其他元素来分配不同的权重, 捕捉元素之间的关系; 前馈神经网络 (Feed-Forward Neural Network) : 每个自注意力子层之后都有一个前馈神经网络, 用于进一步处理信息; 残差连接和层归一化: 残差连接和层归一化有助于加速训练和提高模型稳定性。; 2. 解码器 (Decoder) : 多层堆叠: 与编码器类似, 解码器也由多个相同的解码器层组成; 自注意力机制: 解码器使用自注意力机制来捕捉输入序列和输出序列之间的依赖关系; 编码器-解码器注意力 (Encoder-Decoder Attention) : 解码器层还包括一个额外的注意力机制, 用于对编码器输出进行关注, 以获得更好的序列表示; 前馈神经网络: 解码器层也包括前馈神经网络; 残差连接和层归一化: 同样, 解码器层使用残差连接和层归一化; 3. 位置编码 (Positional Encoding) : 由于 Transformer 没有内置的关于位置的信息, 位置编码用于将序列中的位置信息注入模型, 以便模型理解元素的顺序; 4. 多头注意力机制 (Multi-Head Attention) : 为了增强模型的表达能力, Transformer 引入了多个自注意力头, 每个头学习不同的关注权重, 然后将它们合并在一起; 5. 掩码注意力 (Masked Attention) : 在自注意力中, 解码器需要对之后的位置进行掩码, 以避免未来信息的泄漏; 6. 输出层: 解码器的输出经过一个线性层, 通常与词汇表的大小相匹配, 用于生成最终的输出序列。

Transformer 架构的创新在于它的并行计算能力、对长距离依赖性的建模、可扩展性以及对各种序列建模任务的通用性。它已经成功应用于机器翻译、文本生成、问答系统、语音识别、图像生成等多个领域, 并成为了深度学习中的一项重要技术。




图 1 Transformer 模型架构图

2.3 Informer 模型创新

Informer 是一种基于 Transformer 模型改进的长时间序列预测 (Long Sequence Time-Series Forecasting, LSTF) 模型，专门用于处理具有长期依赖关系和不规则间隔的时间序列数据，即具有提取长距离依赖耦合的能力。与 Transformer 一样，Informer 也是典型的编码器解码器模型结构，通过使用自注意力机制和卷积层来捕捉时间序列数据中的时序特征和上下文信息。Informer 模型是改进于 Transformer 的，更适用于长时间序列预测，

2.4 Informer 原理

2.4.1 模型改进

本方案模型有以下几点改进：

- 1、多尺度时间注意力：Informer 引入了多尺度时间注意力机制，使模型能够在不同时间尺度上对时间序列进行建模。传统的 Transformer 模型只使用固定尺度的自注意力机制，而 Informer 通过使用不同的时间尺度，可以捕捉到不同尺度的时间依赖关系，提高对时间序列中不同尺度模式的建模能力；
- 2、卷积层：为了增强模型对局部特征的感知能力，Informer 模型引入了卷积层。卷积层能够有效地捕捉时间序列数据中的局部模式和趋势，使模型能够更好地理解和建模时间序列中的局部特征；
- 3、Masking 机制：由于时间序列数据具有不规则的时间间隔，Informer 模型引入了 Masking 机制，通过随机掩码部分输入序列，使模型能够更好地捕捉时间序列中的局部特征；

隔，Informer 模型使用了掩码机制，如三角形因果掩码和概率掩码，以便在训练和推理过程中对未来信息进行屏蔽。这样可以避免模型在预测未来时间步时使用未知的未来信息，从而提高预测准确性；4、数据嵌入和位置编码：Informer 模型在输入端使用了数据嵌入 (Token Embedding) 和位置编码 (Positional Encoding)。数据嵌入将时间序列数据转换为嵌入向量表示，而位置编码则提供了每个时间步的位置信息。这样可以使时间序列数据适应 Transformer 模型的输入格式，并捕捉时间序列数据的时序特征；5、预测输出：Informer 模型使用线性投影层将解码器的输出映射到预测输出空间。这样可以将模型的输出转换为时间序列的预测结果，便于与实际值进行比较和评估。

所以，由于 Informer 在传统 Transformer 模型上引入了多尺度时间注意力和概率自注意力机制、掩码机制、数据嵌入和位置编码等优化策略，使 Informer 能够更好地捕捉时间序列数据中的时序特征和上下文信息，在股价预测及其各种应用场景中都有着更优秀的表现。

2.4.2 Informer 架构

近年来的研究表明，Transformer 具有提高预测能力的潜力。然而，Transformer 存在几个严重的问题，使其不能直接适用于长期时序预测问题，例如二次时间复杂度、高内存使用量和编码器-解码器体系结构固有的局限性。为了解决这些问题，这篇文章中设计了一种基于 Transformer 的长期时序预测模型，即 Informer 模型。




图 2 Informer 模型架构图

2.5informer 模型的应用

2.5.1 股票价格预测

股票价格预测是通过分析历史数据来预测未来股票价格趋势的金融任务。这有助于投资决策、风险管理和资产配置。这是一个复杂的任务，因为它受到多种因素的影响，包括经济指标、公司绩效和市场情感。预测通常使用技术分析、基本面分析和机器学习模型等方法。尽管有挑战性，但股票价格预测在金融领域中具有重要意义。

2.5.2 交易策略

在量化交易中，交易策略是指根据预测的股价走势和其他相关因素制定的用于买入和卖出股票的规则与时机等策略。常见的交易策略如表所示。

交易策略	简介
高频交易策略	利用短期价格波动进行高频买卖，通过捕捉股价微小变动来获取买卖价差收益。
长期投资策略	基于基本面分析，选择那些具有长期发展潜力的公司，通过持有股票并等待其股价稳定增长后出售来获取收益。
组合投资策略	权衡不同股票特征、风险等因素，在整个股票市场内构建投资组合，通过分散投资风险来获得超额收益。
事件驱动策略	基于公司公告、财务数据发布、行业新闻等事件来进行相应的买入或卖出操作。

表 2 常见量化交易策略

在本方案中，量化交易策略如上图所示，可详细表述为：通过过去 time_step（本方案以 60 为例）天内的股价数据，对股票连续两日的价格做出预测，并根据股票的涨跌趋势选择购入/继续持有或者卖出/继续等待。即当第 n 天时(收盘前)，对第 n+1 天和第 n+2 天的股票收盘价做出预测，若发现第 n+2 天的价格高于第 n+1 天，则说明下一交易日(第 n+1 天)股价会涨；进一步判断目前的股票持有情况，若目前未持有股票，则可使用第 n 天收盘价购入股票，若目前已持有股票，则继续持有即可。同理，若发现第 n+2 天的价格低于第 n+1 天，则说明下一交易

日(第 $n+1$ 天)股价会跌；进一步判断目前的持有情况，若目前未持有股票，则继续保持空仓不购入股票，若目前已持有股票，则使用第 n 天收盘价卖出股票。由此，可以实现股票涨价时手中持有股票持续增值，股价下跌时立即反应及时止损，从而实现高收入。




图 3 数据重整流程图

为保证操作一致性，避免由于买卖股票数量差距导致的总盈亏差异，每次买卖都执行至当前可执行的最大操作以充分展现策略效果。此外，必须在当日股票收盘前完成对未来两日股票收盘价的预测，否则将无法完全覆盖第 $n+1$ 天的股票价格变动数值。因为股票市场上采取的是逐笔连续撮合交易的方式，即只有等到了出现与交易者买卖数量相同、价格相同、意愿相反的对手方时，交易者才能按照心中预期进行股票买卖，这样的结果是较长时间的等待或者不得不选择折溢价买卖。为保证可以按照确定价格买卖一次性买卖全部股票，利用收盘前最后的集合竞价时期是最好的选择。

2.5.3 训练

对于深度模型，训练 (train) 一般是指通过使用训练数据来调整模型的参数，使其能够学习输入和输出之间关系的过程。在训练过程中，模型会反复进行前向传播和反向传播来计算预测值与实际值之间的误差，并根据误差来更新模型的参数。训练的目标是使模型能够在训练数据上达到较低的误差（损失函数值），并具有较好的泛化能力，即在未见过的数据上表现良好。

而在训练过程中，不同（超）参数组合、不同模型、不同损失函数、不同优化器的选择都会使训练效果存在差异。对于本论文的 Informer 方案，核心超参数如表 3.4 所示。选用的损失函数为均方误差（MSE）损失，如公式 3.5 所示。而

优化器选择为 Adam 优化器，其对梯度的一阶矩估计（梯度的均值）和二阶矩估计（梯度的未中心化的方差）进行综合考虑，计算出更新步长。

结合 Informer 模型的架构，本方案训练核心流程即分为三步。1) 为有效利用计算资源，将数据 Batch 化并输入构建好的模型，2) 判断是否停止训练（迭代次数 < 50 ？），3) 若迭代次数 < 50 ，进行前向传播得到预测值并计算 MSE，再利用 Adam 优化器进行梯度下降与参数更新。反之，停止训练并保存模型(参数)。

3 实验数据与结果

3.1 实验条件

模型的训练与测试都在同一设备进行，实验设配置为：操作系统为 Windows 10，CPU 为 Intel® i3 - 8100，GPU 为 NVIDIA GTX 1660 SUPER，内存为 16GB，开发环境为 MindSpore 3.10、Cuda 10. 1、Cudnn 7. 6。使用 Adam 优化器对网络进行优化，使用固定步长衰减进行学习率的调整，实验中的学习率设为 0.001，step_size 取为 2，gamma 取 0.95，批处理大小设为 16，衰减系数设为 0.0005，动量设为 0.9。深度学习框架采用 MindSpore，编程语言为 Python 3.7 版本，同时使用了 NumPy、Pandas、Matplotlib 等库和依赖。

3.2 实验数据集

本实验使用的数据主要来源于 Tushare 大数据开放社 (www.tushare.pro)，这是一个提供金融市场数据的在线数据平台，包含了股票、指数、交易数据等大规模金融数据。此外，还使用了社交媒体数据以及国内外公开的金融数据。在数据预处理阶段，进行了数据清洗，以处理可能存在的缺失值和异常值。此外，从原始数据中提取了相关特征，如价格、成交量、新闻情感分析等，并将数据集划分为训练集、验证集和测试集。损失函数使用均方误差 (MSE)，训练迭代次数为 100 个迭代轮次。采用学习率衰减策略来逐渐减小学习率，以提高训练的稳定性。实验评估指标包括均方根误差 (RMSE)、平均绝对误差 (MAE) 等，用于评估模型对股票价格的预测性能。数据集划分为 70% 的训练集、15% 的验证集和 15% 的测试集，以支持模型的训练和评估。为确保实验的可重复性，固定了随机种子，并采取了相同的随机初始化策略。数据获取通过 Tushare 大数据开放社获取了历史股票价格数据，社交媒体数据通过 Web 抓取，国内外公开的金融数据由相应的数据提供商提供。这些详细的实验条件信息将有助于其他研究人员理解和重现本研究，确保实验结果的可信度和可复现性。

3.3 模型评估

采用的模型评估指标主要包括：调和均值和平均精确度。平均精确度与调和均值是同时考虑精确率和召回率的量化指标，它们的数值越大，识别效果越好。

3.4 模型训练

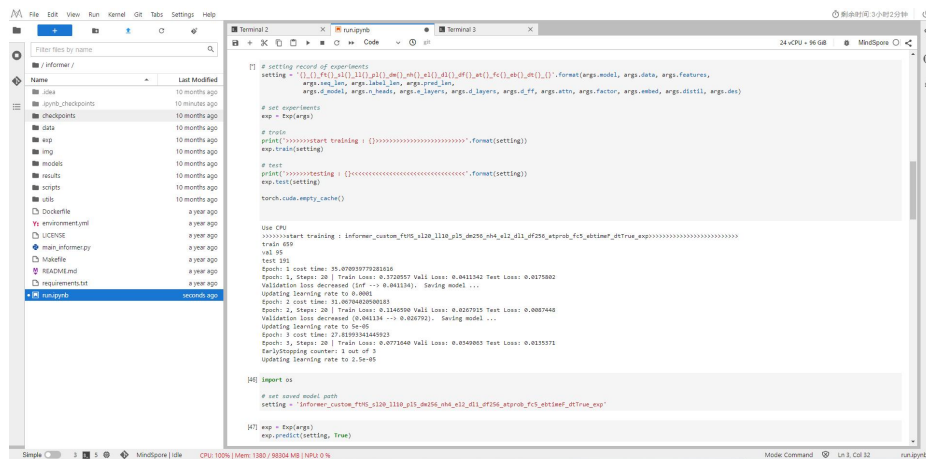


图 4 应用 MindSpore 框架的训练过程

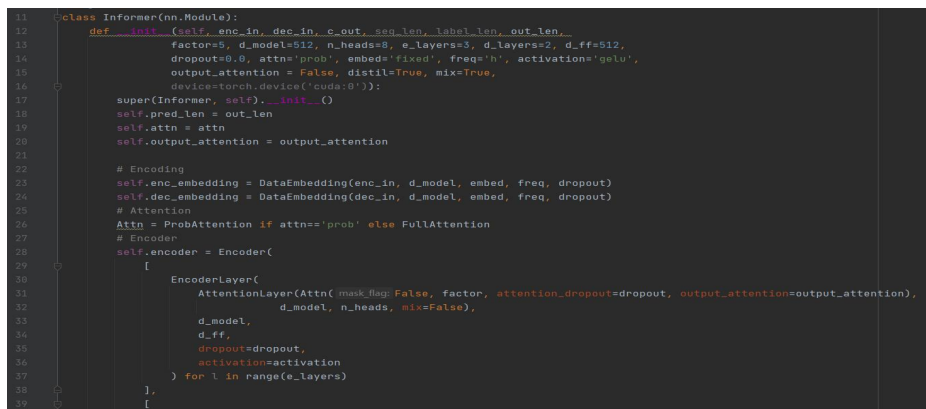


图 5 模型实现代码

图 6 模型实现代码

图 7 应用 MindSpore 框架的训练日志

3.5 实验结果与分析

3.5.1 模型训练结果

```
>>>>>start training : informer_custom_ftMS_sl20_ll10_pl5_dm256_nh4_el2_dl1_df256_atprob_fc5_ebtimeF_dtTr
train 659
val 95
test 191
Epoch: 1 cost time: 1.8236503601074219
Epoch: 1, Steps: 20 | Train Loss: 0.4227553 Vali Loss: 0.0319062 Test Loss: 0.0245216
Validation loss decreased (inf --> 0.031906). Saving model ...
Updating learning rate to 0.0001
Epoch: 2 cost time: 1.803605556488037
Epoch: 2, Steps: 20 | Train Loss: 0.1243612 Vali Loss: 0.0671695 Test Loss: 0.0823020
EarlyStopping counter: 1 out of 3
Updating learning rate to 5e-05
Epoch: 3 cost time: 1.8560359477996826
Epoch: 3, Steps: 20 | Train Loss: 0.0910275 Vali Loss: 0.0242387 Test Loss: 0.0311569
Validation loss decreased (0.031906 --> 0.024239). Saving model ...
Updating learning rate to 2.5e-05
Epoch: 4 cost time: 2.1183347702026367
Epoch: 4, Steps: 20 | Train Loss: 0.0757393 Vali Loss: 0.0215489 Test Loss: 0.0264782
Validation loss decreased (0.024239 --> 0.021549). Saving model ...
Updating learning rate to 1.25e-05
Epoch: 5 cost time: 2.111354351043701
Epoch: 5, Steps: 20 | Train Loss: 0.0707515 Vali Loss: 0.0184724 Test Loss: 0.0211690
Validation loss decreased (0.021549 --> 0.018472). Saving model ...
Updating learning rate to 6.25e-06
Epoch: 6 cost time: 1.6446027755737305
Epoch: 6, Steps: 20 | Train Loss: 0.0734530 Vali Loss: 0.0180806 Test Loss: 0.0200154
Validation loss decreased (0.018472 --> 0.0180806). Saving model ...
Updating learning rate to 3.125e-06
Epoch: 7 cost time: 1.7283775806427002
Epoch: 7, Steps: 20 | Train Loss: 0.0701941 Vali Loss: 0.0202722 Test Loss: 0.0219292
EarlyStopping counter: 2 out of 3
Updating learning rate to 1.5625e-06
Epoch: 8 cost time: 1.8929383754730225
Epoch: 8, Steps: 20 | Train Loss: 0.0698262 Vali Loss: 0.0195256 Test Loss: 0.0222712
EarlyStopping counter: 3 out of 3
Early stopping
>>>>>testing : informer_custom_ftMS_sl20_ll10_pl5_dm256_nh4_el2_dl1_df256_atprob_fc5_ebtimeF_dtTrue_exp
test 191
test shape: (5, 32, 5, 1) (5, 32, 5, 1)
test shape: (160, 5, 1) (160, 5, 1)
mse:0.021161550655961037, mae:0.1239549070596695
```

图 8 模型训练结果图

```
EarlyStopping counter: 1 out of 3
Updating learning rate to 3.125e-06
Epoch: 7 cost time: 1.7283775806427002
Epoch: 7, Steps: 20 | Train Loss: 0.0701941 Vali Loss: 0.0202722 Test Loss: 0.0219292
EarlyStopping counter: 2 out of 3
Updating learning rate to 1.5625e-06
Epoch: 8 cost time: 1.8929383754730225
Epoch: 8, Steps: 20 | Train Loss: 0.0698262 Vali Loss: 0.0195256 Test Loss: 0.0222712
EarlyStopping counter: 3 out of 3
Early stopping
>>>>>testing : informer_custom_ftMS_sl20_ll10_pl5_dm256_nh4_el2_dl1_df256_atprob_fc5_ebtimeF_dtTrue_exp
test 191
test shape: (5, 32, 5, 1) (5, 32, 5, 1)
test shape: (160, 5, 1) (160, 5, 1)
mse:0.021161550655961037, mae:0.1239549070596695
```

图 9 模型训练结果图




图 10 直接调用后 5 天的收盘价走势，预测所有数据后面的未知数据




图 11 从测试集上随机选出几条预测结果以及 ground truth 进行可视化 (1)




图 12 从测试集上随机选出几条预测结果以及 ground truth 进行可视化 (2)




图 13 测试集上的预测结果进行可视化

3.6 作品展示




图 14 预测未来走势界面

The figure shows the '模型市场' (Model Market) interface. It features a sidebar with navigation options: 首页 (Home), 股价预测 (Stock Price Prediction), 房子按揭 (Mortgage), 模型选择 (Model Selection), and 我的模型 (My Models). The main content area is titled '模型市场'.

Model details:

- 模型名称: 输入数据
- 模型类型: 选择模型
- 按钮: 添加模型

编号	模型名称	模型类型	准确率	内存	作者	更新时间
01	ARIMA	统计模型	82%	200MB	ming	2023-9-13
02	CNN	预测模型	86%	268MB	lin	2023-9-13
03	RNN	预测模型	89%	328MB	qi	2023-9-13
04	GRU	预测模型	90%	338MB	lin	2023-9-13
05	TCN	预测模型	92%	358MB	ming	2023-9-13
06	LSTM	预测模型	91%	288MB	ming	2023-9-13
07	Bi-LSTM	预测模型	92%	368MB	lin	2023-9-13
08	Transformer	预测模型	91%	368MB	lin	2023-9-13
09	Informer	预测模型	94%	368MB	lin	2023-9-13

Page navigation: < 1 2 3 4 5 10 >

图 15 模型市场界面

基于AI的股票挖掘及股价预测系统

首页

股价预测

股票挖掘

模型选择

我的模型

我的模型

当前状态: 部署中

应用类型: 选择模型

添加

编号	模型名称	模型大小	模型类别	准确率	训练时间	部署	是否公开	作者	状态	操作
01	ARIMA	56MB	时间序列	78%	2023-09-14	200MB	是	liminglian	正在使用	修改 删除
02	RNN	80MB	预测模型	82%	2023-09-14	288MB	是	yuajunbin	未使用	修改 删除
03	CNN	86MB	预测模型	83%	2023-09-14	288MB	是	wangqi	未使用	修改 删除
04	LSTM	80MB	预测模型	86%	2023-09-14	288MB	是	liminglian	正在使用	修改 删除
05	Transformer	289MB	预测模型	88%	2023-09-14	328MB	是	yuajunbin	未使用	修改 删除
06	Informer	300MB	预测模型	91%	2023-09-14	368MB	是	wangqi	未使用	修改 删除

<

1

3

4

5

...

10

>

显示数据

图 16 我的模型界面

16

4 特色创新

股价预测是金融领域中的一个关键任务，它对投资者、金融机构和市场监管机构都具有重要意义。传统的股价预测方法主要依赖于统计分析和基本面分析，这些方法在处理复杂、多变的市場情况时常常表现不佳。然而，随着人工智能技术的发展，越来越多的研究和应用开始将机器学习和深度学习技术应用于股价预测领域。国内外的研究现状表明，传统的股价预测方法仍然依赖于统计分析和基本面分析，但在面对复杂、多变的市場情况时，这些方法往往表现不佳。这导致了对更先进、更精确的预测方法的迫切需求，因此，人工智能技术在股价预测中的应用逐渐成为研究的热点和重要方向。

本文使用了 Informer 模型进行股票价格预测应用研究，本研究提出的原 Informer 方案在不同方面均存在一定局限，故从数据与模型两大部分讨论了原方案的不足，并提出了优化架构的思考。也针对其中的一些思考基于原方案的代码进行了改进，并通过消融实验对比验证了优化效果，还进行了实验结果的展示与可视化的尝试，为读者提供了更直观的理解和评估。也为进一步提高股价预测效果和量化交易应用提供了一定的参考和指导。

5 总结与展望

5.1 总结

本项目旨在利用 MindSpore 框架和 Informer 模型，实现对股票价格的预测任务。通过对历史股票数据的分析和建模，我们取得了以下重要成果和发现：数据收集和准备：我们成功地获取了来自 Tushare 大数据开放社、社交媒体以及国内外公开金融数据等多个数据源的股票相关数据。这些数据的综合利用为我们提供了丰富的信息基础，有助于更好地进行预测分析；Informer 模型选择：在本项目中，我们选择了 Informer 模型作为主要的预测工具。Informer 是一种基于 Transformer 的深度学习模型，特别适用于时间序列预测任务。其能够有效捕捉时间序列数据中的长期和短期依赖关系，提高了预测的准确性；模型训练和调优：我们使用 MindSpore 框架来搭建和训练 Informer 模型。在训练过程中，我们通过

对损失函数和性能指标的监控，进行了模型的调优和参数调整。这有助于提高模型的泛化能力和预测准确性；预测结果分析：我们对 Informer 模型进行了全面的测试和验证，以评估其在不同股票数据集上的性能。通过对比实际股价和模型预测结果，我们发现 Informer 模型能够在一定程度上捕捉到股票价格的趋势和波动，为投资决策提供了有价值的参考。

通过这个项目，我们展示了 MindSpore 框架和 Informer 模型在股票价格预测任务中的潜力。这个项目为金融领域的实际应用提供了有益的经验 and 启示，也为未来的研究和应用奠定了坚实的基础。

5.2 展望

尽管我们在本项目中已经取得了一定的成果，但股票价格预测领域仍然有许多挑战 and 机会等待我们进一步探索和发展。以下是一些未来展望和可能的研究方向：模型改进与优化：未来，我们将致力于进一步改进和优化 Informer 模型，以提高其在股票价格预测任务中的性能。这包括尝试不同的网络架构、调整超参数、引入更多的特征工程等方法，以提高模型的预测准确性；多源数据整合：股票市场受到多种因素的影响，包括宏观经济指标、公司业绩、社交媒体情感等。未来的研究可以考虑整合更多不同来源的数据，以更全面地理解市场动态，从而提高预测模型的可信度；实时预测与交易策略：对于投资者而言，实时性非常重要。未来的研究可以集中在实时股票价格预测和交易策略的开发上，以帮助投资者更好地把握市场机会；解释性与可解释性：为了提高模型的可信度和可接受性，我们将研究如何增加模型的解释性和可解释性。风险管理：股票市场存在着各种风险，包括市场风险、操作风险等。未来的研究可以关注如何利用预测模型来进行风险管理和资产配置，以降低投资风险；应用领域扩展：股票价格预测模型不仅仅适用于投资决策，还可以应用于金融监管、资产管理、信贷评估等多个金融领域。未来我们将探索更多的应用领域，以发挥模型的广泛价值。

总之，股票价格预测领域充满了潜力和挑战。通过不断的研究和创新，我们有望改进预测模型，提高金融决策的准确性，为投资者和金融专业人士提供更多有用的工具和方法，以应对不断变化的市场环境。这个领域的发展将在未来为金融市场带来更多的机会和改进。

6 参考文献

- [1] 韩莹,张栋,孙凯强等.结合长短时记忆网络和宽度学习的股票预测新模型研究[J].运筹与管理,2023,32(08):187-192.
- [2] 张倩玉, 严冬梅, 韩佳彤. 结合深度学习和分解算法的股票价格预测研究[J]. Journal of Computer Engineering & Applications, 2021, 57(5).
- [3] Lu W, Li J, Wang J, et al. A CNN-BiLSTM-AM method for stock price prediction[J]. Neural Computing and Applications, 2021, 33: 4741-4753.
- [4] 胡玲燕, 朱家明. 基于逐步回归和 BP 神经网络对股票价格预测的对比分析[J]. 辽宁工业大学学报: 自然科学版, 2019, 39(3): 201-205.
- [5] Obthong M, Tantisantiwong N, Jeamwatthanachai W, et al. A survey on machine learning for stock price prediction: Algorithms and techniques[J]. 2020.
- [6] Wu S, Liu Y, Zou Z, et al. S_L_LSTM: stock price prediction based on multiple data sources and sentiment analysis[J]. Connection Science, 2022, 34(1): 44-62.
- [7] Mehtab S, Sen J, Dutta A. Stock price prediction using machine learning and LSTM-based deep learning models[C]//Machine Learning and Metaheuristics Algorithms, and Applications: Second Symposium, SoMMA 2020, Chennai, India, October 14 – 17, 2020, Revised Selected Papers 2. Springer Singapore, 2021: 88-106.
- [8] Ren S, Wang X, Zhou X, et al. A novel hybrid model for stock price forecasting integrating Encoder Forest and Informer[J]. Expert Systems with Applications, 2023, 234: 121080.
- [9] Lu Y, Zhang H, Guo Q. Stock and market index prediction using Informer network[J]. arXiv preprint arXiv:2305.14382, 2023.
- [10] Lei M, Pan X, Gao S, et al. Portfolio management algorithm based on long-term prediction of assets[C]//Proceedings of the 5th International Conference on Big Data Technologies. 2022: 145-153.
- [11] Zeng A, Chen M, Zhang L, et al. Are transformers effective for time series forecasting?[C]//Proceedings of the AAAI conference on artificial intelligence. 2023, 37(9): 11121-11128.

- [12] Zeng A, Chen M, Zhang L, et al. Are transformers effective for time series forecasting?[C]//Proceedings of the AAAI conference on artificial intelligence. 2023, 37(9): 11121–11128.
- [13] Zhou H, Zhang S, Peng J, et al. Informer: Beyond efficient transformer for long sequence time-series forecasting[C]//Proceedings of the AAAI conference on artificial intelligence. 2021, 35(12): 11106–11115.
- [14] Bilokon P, Qiu Y. Transformers versus LSTMs for electronic trading[J]. arXiv preprint arXiv:2309.11400, 2023.
- [15] 胡玲燕, 朱家明. 基于逐步回归和 BP 神经网络对股票价格预测的对比分析[J]. 辽宁工业大学学报: 自然科学版, 2019, 39(3): 201–205.
- [16] Zhou W, Pan Y, Wu Z. Stock price prediction under multi-frequency model-based on attention state-frequency memory network[C]//Proceedings of the 4th International Conference on Information Technology and Computer Communications. 2022: 117–124.
- [17] Jin C, Li Y. Cryptocurrency Price Prediction Using Frequency Decomposition and Deep Learning[J]. Fractal and Fractional, 2023, 7(10): 708.
- [18] 黄超斌, 程希明. 基于 LSTM 神经网络的股票价格预测研究[J]. 北京信息科技大学学报 (自然科学版), 2021, 36(1): 79–83.
- [19] Kim S, Chae D K. Look Ahead: Improving the Accuracy of Time-Series Forecasting by Previewing Future Time Features[C]//Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval. 2023: 2134–2138.
- [20] Huang X, Jiang A. Wind Power Generation Forecast Based on Multi-Step Informer Network[J]. Energies, 2022, 15(18): 6642.
- [21] Cui Y, Xie J, Zheng K. Historical inertia: A neglected but powerful baseline for long sequence time-series forecasting[C]//Proceedings of the 30th ACM international conference on information & knowledge management. 2021: 2965–2969.
- [22] Shen L, Wang Y. TCCT: Tightly-coupled convolutional transformer on time series forecasting[J]. Neurocomputing, 2022, 480: 131–145.
- [23] 李辉, 化金金, 邹波蓉. 基于 RF-LSTM 组合模型的股票价格预测[J]. 河南

理工大学学报 (自然科学版), 2022, 41(1): 136-142.

[24] Cholakov R, Kolev T. Transformers predicting the future. Applying attention in next-frame and time series forecasting[J]. arXiv preprint arXiv:2108.08224, 2021.

[25] 赵庆国, 孔祥月, 刘莉明, 等. 短期股票价格预测的时序权重均值模型构建[J]. 沈阳航空航天大学学报, 2020, 37(4): 81-89.

[26] Prata M, Masi G, Berti L, et al. LOB-Based Deep Learning Models for Stock Price Trend Prediction: A Benchmark Study[J]. arXiv preprint arXiv:2308.01915, 2023.

[27] Yao X, Yang X. Forecasting crude oil futures using an ensemble model including investor sentiment and attention[J]. Kybernetes, 2023.

[28] Gao J, Hu W, Chen Y. Client: Cross-variable Linear Integrated Enhanced Transformer for Multivariate Long-Term Time Series Forecasting[J]. arXiv preprint arXiv:2305.18838, 2023.

[29] Qi X, Xu Z, Wang F. Temporal Fusion Point-Interval Forecasting: A Comprehensive Approach for Financial Time Series Prediction[J]. Available at SSRN 4585057.

[30] 罗露. 基于 ARIMA 模型的股票价格预测分析[J]. Advances in Applied Mathematics, 2022, 11: 9096.

[31] Chen J, Shi X, Zhang H, et al. Mutual adaptation: learning from prototype for time series prediction[J]. IEEE Transactions on Artificial Intelligence, 2023.

[32] Hou M, Xu C, Li Z, et al. Multi-Granularity Residual Learning with Confidence Estimation for Time Series Prediction[C]//Proceedings of the ACM Web Conference 2022. 2022: 112-121.

[33] 杨梦梦, 王星惠, 赵兴. 基于动态因子增强模型平均方法的股票价格预测[J]. 2022.

[34] Tao Z, Wu W, Wang J. Series decomposition Transformer with period-correlation for stock market index prediction[J]. Expert Systems with Applications, 2023: 121424.

[35] Al-qaness M A A, Ewees A A, Elaziz M A, et al. Wind power forecasting using optimized dendritic neural model based on seagull optimization algorithm and aquila optimizer[J]. Energies, 2022, 15(24): 9261.