

## 深度学习模型系列（一）基于扩散图神经网络的 CTA 策略初探

### 研究院 量化组

#### 研究员

##### 李逸资

☎ 0755-23887993

✉ liyizi@htfc.com

从业资格号: F03105861

投资咨询号: Z0021365

##### 高天越

☎ 0755-23887993

✉ gaotianyue@htfc.com

从业资格号: F3055799

投资咨询号: Z0016156

##### 李光庭

☎ 0755-23887993

✉ liguangting@htfc.com

从业资格号: F03108562

投资咨询号: Z0021506

#### 联系人

##### 黄煦然

☎ 0755-23887993

✉ huangxuran@htfc.com

从业资格号: F03130959

#### 投资咨询业务资格:

证监许可【2011】1289号

### 摘要

本文围绕图神经网络（GNN）在期货量化策略中的应用进行初步探讨，以扩散图神经网络为核心建模框架，对商品期货市场多品种、强关系、高异质性的特征进行结构化表达，并构建跨品种间的信息传播机制。研究基于主力合约行情数据，通过构建图结构输入、引入时间步多尺度嵌入层与注意力机制，实现对未来价格涨跌的分类预测任务。回测结果显示，该模型在 Top-K 多空策略中具备一定的阿尔法捕捉能力，验证了图结构在捕捉市场关联性中的建模优势

### 核心观点

- 期货市场的图结构建模需求强烈：与传统的截面因子截取方法相比，期货市场中存在显著的跨品种结构性联动，例如产业链上下游、跨期价差、资金流向等，适合借助图神经网络进行关联建模。
- 图神经网络具有天然的信息扩散与聚合优势。模型能够有效扩散并编码邻接图中的高阶依赖信息；同时引入的多头注意力机制增强了不同时间尺度与特征通道的建模能力。
- 实证验证具备阿尔法能力：以近几年主流商品合约数据为例，模型在 Top-K 多头、空头组合上显著优于传统截面策略，具备一定的超额收益获取能力，尤其在波动增强的阶段预测能力更为突出。
- 存在进一步优化空间：当前策略仍基于单步分类决策，未来可融合价格幅度回归目标、引入品种属性图谱、优化目标函数结构等方向进一步提升策略泛化能力与实际交易性能

## 目录

摘要 .....	1
核心观点 .....	1
研究背景与动机 .....	3
背景知识铺垫 .....	3
■ 什么是图结构.....	3
■ 什么是图神经网络.....	4
构建适用于期货市场的扩散图神经网络 .....	4
■ 基于信息熵驱动的图结构构建 .....	5
■ 特征编码模块.....	8
■ 信息传播模块.....	9
■ 表达融合与任务输出.....	10
实证研究设计 .....	12
■ 数据信息与预处理.....	12
■ 交易构建.....	12
结果回测 .....	13
总结 .....	15

## 图表

图 1: 以社交网络为例的图结构   单位: 无.....	4
图 2: 历史收益率关系图   单位: 无 .....	7
图 3: 简单图神经结构   单位: 无 .....	7
图 4: 完整扩散图神经网络生成图举例   单位: 无.....	7
图 5: 模型运作流程   单位: 无 .....	11
图 6: 扩散图神经网络与传统截面策略对比   单位: 无.....	13
图 7: 扩散图神经网络策略净值图   单位: 无.....	13
图 8: 月收益分布形态   单位: 无 .....	14
图 9: 分位数拟合图   单位: 无 .....	14
表 1: 扩散图神经网络策略指标   单位: 无.....	13

## 研究背景与动机

在当前高频变动的金融市场中，构建具备动态适应性的标的选择与择时策略，已成为量化交易领域的重要方向。尤其是在短周期策略、行业轮动与多因子增强模型日趋复杂化的背景下，传统基于回归或静态分类模型的方法逐渐暴露出其在结构建模与信息整合方面的天然局限。

首先，传统模型普遍基于对单个标的的时间序列的独立建模，忽视了期货之间由于行业联动、资本流向、风格切换等因素所构成的**动态耦合关系**。这种“单点视角”的建模方式在市场结构性剧烈变化时往往失效，导致预测结果稳定性差、偏差大。一方面，标的之间的价格联动不再仅由行业归属或市值大小决定，而是受到短期资金博弈、风格切换、政策扰动等**非线性因素**的影响；另一方面，标的内部的价格行为亦表现出明显的多层次结构，如不同时间尺度下的波动节奏、趋势惯性与逆转信号的交叠等。这种“跨资产+分层次”的动态交互构成了传统线性或静态分类模型难以建模的高维结构信息。

在此背景下，图神经网络（Graph Neural Network）因其对结构性依赖的天然适应性，成为建模金融市场复杂关系的有力工具。它**通过节点之间的信息传递机制，能够有效整合个体期货与其相邻期货之间的关联变化，从而实现对整体图结构的建模与局部特征的保留**。尤其是在多时间步、多维度输入的条件下，GNN能够以分层的方式解析不同特征层级的作用路径，避免信息“过平滑”或“过拟合”所带来的结构退化。

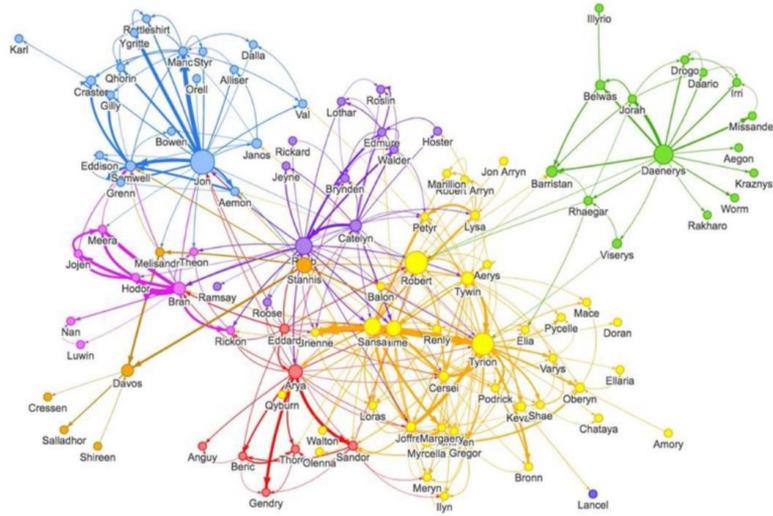
在本研究中，进一步引入了基于信息熵的边生成机制与广义图扩散方法，用于动态构建期货之间的连接关系和多阶传导路径。这一机制有效突破了传统图结构中“边固定、图静态”的建模假设，使得图结构可根据市场状态实时调整，反映出期货间联动强度与结构位置的动态变化。同时，通过图扩散与多头注意力的联合机制，本模型可以实现对局部模式与全局趋势的解耦提取，增强策略在实际应用中的鲁棒性与解释性。

## 背景知识铺垫

### ■ 什么是图结构

在数学和计算机科学中，图（Graph）是一种通用的数据结构，用于表达实体之间的关系。它由**节点（nodes）**和**边（edges）**组成。

图 1:以社交网络为例的图结构 | 单位: 无



数据来源: Wiki 华泰期货研究院

如图 1 所示，这是一个以社交网络为例的图结构。图中每一个彩色圆点代表一个“节点” (node)，通常表示图中的个体单位，比如一个人、一家公司或其他实体。节点之间的连线称为“边” (edge)，用于表达它们之间存在某种联系，例如交流、交易、合作或共同特征。其中部分边带有箭头，称为“有向边”，表示关系具有方向性 (如 A 影响 B)；而没有箭头的边则为“无向边”，表示关系是对等的 (如共同出现)。此外，图中节点的颜色可反映其所属群体或分层结构，节点的大小则通常与其连接数 (即在网络中的重要程度) 正相关。这种图结构可以直观展示出网络中信息的传播路径、聚集中心与边缘结构，是刻画复杂系统依赖关系的重要工具。

在期货市场中，这种图结构同样具有天然的类比价值：我们可以将每个期货品种或合约视作一个“节点”，而不同期货之间由于产业链上下游关系、价格联动性、资金共振、宏观变量驱动等形成的关联性则可被抽象为“边”。通过构建动态演化的期货图网络，模型可以捕捉品种之间潜在的结构性依赖关系，揭示某一品种的走势是否受到其他关键节点的影响。这种从“单一品种建模”向“多品种结构建模”的转变，为构建更具系统性、前瞻性的期货交易策略提供了全新路径

### ■ 什么是图神经网络

如果说将图结构和节点内容信息作为输入，那么图神经网络 (Graph Neural Network) 则是在这一结构上进行学习与预测的核心方法。与传统神经网络只能处理规则结构 (如表格或图像) 不同，图神经网络能够直接在图数据上进行计算，其核心思想是：让每个节点不仅依赖自身的历史特征进行预测，还可以“接收”并融合其相邻节点的信息，从而实现更丰富、更具结构意识的表达能力。这一过程通常通过“信息传递”机制实

现，即模型在多轮迭代中将邻居的特征逐步整合进节点自身的表示中，最终形成一个包含自身属性与图结构上下文的高阶嵌入表示。

以期货市场为例，在预测某一合约（如 PTA）的走势时，图神经网络模型不仅会考虑该品种自身的技术面和基本面因子，还能自动聚合其上游（如 PX）、下游（如涤纶）乃至宏观相关品种（如原油）的信息。如果这些关联节点近期出现趋势一致或波动共振，图神经网络能够借助图结构自适应地增强对该中心节点的信号感知能力。一般来讲图神经网络模型的构建一般包括三部分：**图的构建**（定义节点和边，及其特征）、**信息传递机制设计**（如图卷积、图注意力等）、**任务输出模块**（如分类、回归或排序）。通过这一框架，图神经网络可以在建模多个期货品种的联动关系时，兼顾局部影响与整体结构，从而有效提升策略模型的解释性、鲁棒性与预测准确性。

## 构建适用于期货市场的扩散图神经网络

### ■ 基于信息熵驱动的动态图结构构建

为了更精准地刻画期货品种之间在市场波动中不断演化的联动关系，在模型构建初期引入了一种**基于信息熵的边连接生成机制（Entropy-based Edge Generation）**，用于动态构建图神经网络的结构。相较于传统那种固定连接方式（例如仅用行业归属定义边），这种方法能根据市场的实际状态对节点之间的“连接关系”进行**实时更新**，从而更真实地反映出品种间的实际影响力和结构依赖。

具体而言，我们首先定义期货市场中每一只品种  $i$  在最近  $T$  天的收益率序列为：

$$R_i = \{r_i^{\{(t-T+1)\}}, \dots, r_i^{\{(t)\}}\}$$

其中

$$r_i^{\{(t)\}} = \frac{(P_i^{\{(t)\}} - P_i^{\{(t-1)\}})}{P_i^{\{(t-1)\}}}$$

$P_i^t$  表示品种  $i$  在时间  $t$  的收盘价。

我们选取任意两个期货品种  $i$  和  $j$ ，计算其条件熵（Conditional Entropy） $H(R_i | R_j)$ ，作为衡量二者信息耦合强度的指标。其定义如下：

$$H(R_i | R_j) = H(R_i, R_j) - H(R_j)$$

其中：

$H(R_i, R_j)$ 为联合熵， $H(R_j)$  为边缘熵。

如果两个品种之间具有高度的联动性，那么这个条件熵就会较低，说明品种j的行为对品种i的走势具有一定的解释力。

考虑到收益率是连续变量，计算熵的过程可通过核密度估计来进行。为了更简便地计算品种间的依赖关系，我们也可以用互信息（Mutual Information）来替代条件熵

它可以被表示为：

$$MI(R_i, R_j) = H(R_i) + H(R_j) - H(R_i, R_j)$$

为了使不同品种之间的对比更具可比性，我们将互信息进行标准化，得到一个“相似度矩阵”，用于衡量所有品种两两之间的关联强度：

$$S_{ij} = \frac{MI(R_i, R_j)}{\sqrt{[H(R_i) \times H(R_j)]}}$$

同时，为了控制图结构的复杂度，避免构造“全连接图”所带来的过度信息传播与模型退化风险，我们对初步相似度矩阵  $S$  进行稀疏处理，包括 Top-k 策略和阈值筛选法。最终，我们构建邻接矩阵  $A \in \mathbb{R}^{n \times n}$ ，其中：

$$A_{ij} = 1, \text{ 若品种 } i \text{ 和 } j \text{ 关联度足够高；否则 } A_{ij} = 0$$

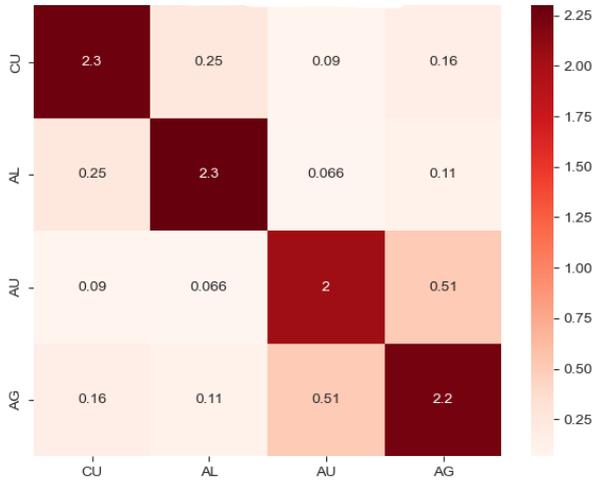
为增强稳定性并保留边权信息，我们将邻接矩阵进行对称归一化处理：

$$\hat{A} = D^{-\frac{1}{2}} \cdot A \cdot D^{-\frac{1}{2}}, \text{ 其中 } D \text{ 为度矩阵, } D_{ii} = \sum_j A_{ij}$$

我们在训练时引入了结构约束项（正则化项）来防止生成的图结构过于复杂或失真，最终，这一图结构模块作为整个模型的基础输入，为后续的图扩散计算、注意力机制和预测任务提供高质量的“市场结构视图”。通过这种机制，模型能够根据不同市场环境动态调整期货品种之间的结构联系，从而提高对趋势、波动乃至系统性风险的整体识别能力。

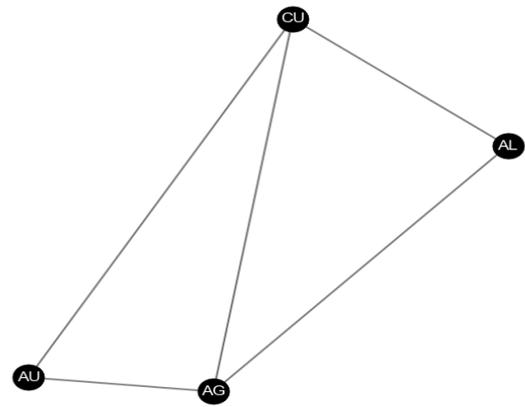
以铜，铝，黄金，白银这四个品种为例，首先我们构建这四个品种主力合约的收益序列。随后计算互信息得到如下的收益率关系图。

图 2：历史收益率关系图 | 单位：无



数据来源：华泰期货研究院

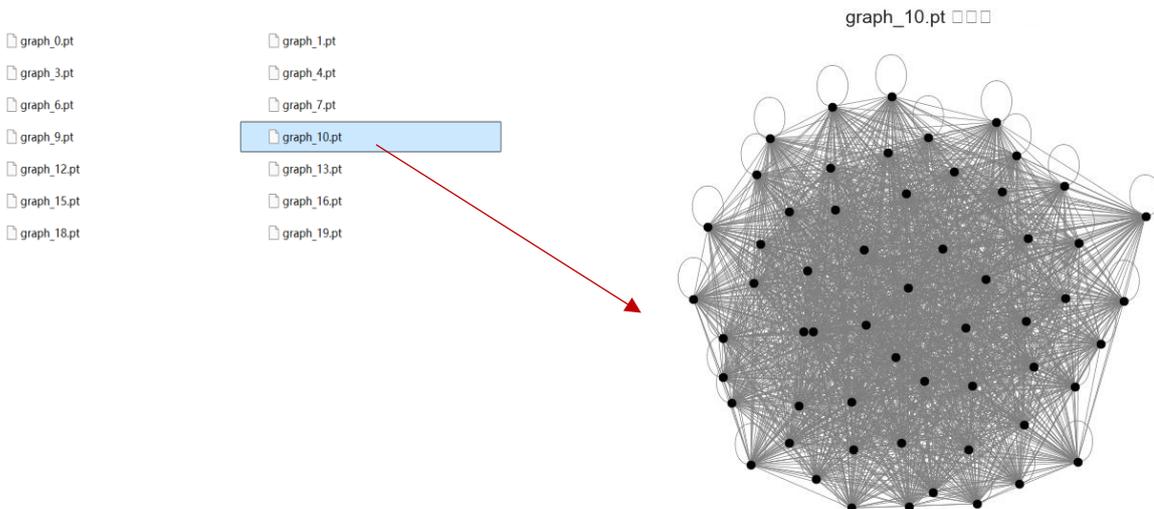
图 3：简单图神经结构 | 单位：无



数据来源：华泰期货研究院

在图 2 中，我们利用互信息（Mutual Information）这一衡量信息关联强度的指标，计算了典型品种（如铜 CU、铝 AL、黄金 AU、白银 AG）之间过去收益率序列的联合分布结构。热力图展示了品种之间的信息共享程度，数值越高表明两者在历史收益率层面具有更强的动态耦合关系。基于上述互信息强度，我们在图 3 中进一步应用 Top-k 稀疏策略，仅保留每个品种最显著的若干个信息连接边，从而构建了一个稀疏而稳定的图神经结构。这种结构相比传统按行业归属设边的方式更加贴近真实市场状态，能够动态反映商品间在波动性、趋势性乃至系统性风险传导方面的结构依赖性。最终，该图结构可作为图神经网络的输入，使模型在训练过程中持续感知并利用品种间演化的网络关系，从而增强对未来走势与信号的识别能力。

图 4：完整扩散图神经网络生成图举例 | 单位：无



数据来源：华泰期货研究院

图 4 展示的是基于互信息生成的期货市场**完整关联图**的例子，通过对期货品种在指定时间窗口内的价格数据进行分析构建。我们以训练集的 graph\_10.pt 为例。图中**每个节点代表一个期货合约**，节点特征是该合约在过去 21 天的数据。随后，我们计算了一个相似度阵，该矩阵反映了合约间的价格关联性，基于“信号能量”和“信息熵”的计算方法，能够量化合约之间的相互影响强度。将这个关联矩阵转化为图形化结构，**节点间的连线代表合约间的关联程度**，**连线越强则表明这两个合约的价格波动越相似**。

这种关联图可以帮助我们识别市场中哪些合约之间存在较强的价格同步性，哪些合约之间的联系较弱。基于这样的图结构，图神经网络模型能够沿着图的边进行信息传播，利用历史价格数据和合约间的相关性来预测未来的市场走势。具体来说，通过模型的训练，系统能够识别出期货合约间的潜在影响关系，从而对未来的涨跌趋势进行预测。这种基于图的建模方法，可以有效提高期货市场预测的准确性，尤其是在趋势分析和多合约联动效应的捕捉上。

### ■ 特征编码模块

在图神经网络中，每个节点（即一个期货品种）均包含多个来源的特征信息，这些特征可分为三大类：技术面因子（如收益率、波动率、动量）、基本面因子（如持仓变化、交易额）、以及另类因子。我们用  $X_{i(t)} \in \mathbb{R}^F$  表示品种  $i$  在时间  $t$  的  $F$  维原始特征向量，整体输入张量可表示为：

$$X \in \mathbb{R}^{N \times T \times F}$$

其中， $N$  表示期货品种数量， $T$  表示时间步长， $F$  为特征维度。为提升模型的收敛速度与稳定性，所有特征在输入前均经过归一化处理

接着，我们为模型引入一个共享的线性嵌入层，将原始特征映射至统一维度  $d$  的隐藏空间：

$$\tilde{X}_{i(t)} = W_{emb} \cdot X_{i(t)} + b$$

其中  $W_{emb} \in \mathbb{R}^{d \times F}$  为嵌入权重，

$b \in \mathbb{R}^d$  为偏置项。

此步骤有助于消除不同特征维度之间的尺度差异，并为后续的图扩散与注意力计算提供统一表示。为了进一步建模节点在图结构中的**相对位置**，我们引入了位置编码机制。该机制旨在为每个节点引入结构位置信息，实现方式是基于图的拉普拉斯特征分解：

$$L = D - A, \quad L = U\Lambda U^T$$

其中  $L$  是图拉普拉斯矩阵,

$U \in \mathbb{R}^{N \times N}$  为特征向量矩阵,

$\Lambda$  为特征值对角矩阵。我们取前  $k$  个特征向量构建节点的位置编码  $PE \in \mathbb{R}^{N \times k}$ , 再与特征嵌入相加:

$$H_{i(t)} = \tilde{X}_{i(t)} + PE_i$$

最终, 嵌入后的  $H \in \mathbb{R}^{N \times T \times d}$  被送入图扩散模块与注意力机制模块进行特征聚合与模式提取。该特征编码方式融合了时序变化信息与图结构的位置信息, 使得模型不仅能捕捉单节点自身的行为特征, 也能感知其在产业链图谱中的上下游路径关系, 对于提升建模准确性与结构鲁棒性具有重要意义。

### ■ 信息传播模块

在图神经网络中, 信息的传递机制是连接图结构与节点特征之间的核心桥梁。传统方法如图卷积网络 (GCN) 或图注意力网络 (GAT) 通常只处理一阶或少量邻居节点, 难以捕捉金融市场中跨品种、跨链条的非局部联动效应。为解决这一问题, 本研究引入了更具灵活性的广义图扩散机制 (Generalized Graph Diffusion, GGD), 以建模多阶信息的传播路径。

设节点输入特征为  $H \in \mathbb{R}^{N \times d}$ , 邻接矩阵为  $A$ , 经归一化处理后得到扩散核  $\hat{A}$ 。GGD 机制将不同阶的扩散表示建模为:

$$Z^{(k)} = \hat{A}^k \cdot H, \quad k = 1, 2, \dots, K$$

其中  $Z^{(k)}$  表示从  $k$  跳邻居中传递过来的特征信息。

通过对多个阶数  $k$  的扩散进行聚合, 可以综合捕捉局部与全局的结构信息。为了提升学习能力, GGD 机制引入了可学习的衰减权重  $\alpha_k$ , 使模型能够自动调整每一阶扩散的重要性:

$$Z = \sum_{k=1} \alpha^k \cdot Z^{(k)} = \sum_{k=1} \alpha^k \cdot \hat{A}^k \cdot H$$

其中  $\alpha_k$  是可学习的参数，满足  $\sum \alpha_k = 1$ ，确保信息权重在不同扩散阶之间分布合理。

我们在扩散模块之后引入了**多头注意力机制 (Multi-head Attention)**，该机制可以从不同角度“解读”扩散后的特征，并通过注意力得分聚焦于更具代表性的信号通道。

设扩散后特征为  $Z \in \mathbb{R}^{N \times d}$ ，我们使用  $h$  个注意力头进行并行变换，每个头执行如下计算：

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d}}\right) \cdot V$$

$$Q = ZW_Q^{\{(h)\}}, \quad K = ZW_K^{\{(h)\}}, \quad V = ZW_V^{\{(h)\}}$$

最终所有注意力头的输出被拼接并通过线性映射生成融合表示：

$$Z_{out} = Concat(Head_1, \dots, Head_h) \cdot W_O$$

这一组合模块的优势在于：图扩散提供了跨层级的结构语义，而注意力机制则负责从中挑选出“对预测最有用的信息通道”，两者协同作用，特别适用于期货市场中存在复杂因果路径与非对称冲击传导的场景。

### ■ 表达融合与任务输出

在图扩散与注意力模块之后，**每个节点（即期货品种）**在所有时间步上生成的结构嵌入向量将被拼接为一个统一表示，用于最终的预测输出。设节点  $i$  的扩散嵌入为  $Z_i \in \mathbb{R}^{\{\tau \times d\}}$ ，我们将其展平为一维向量：

$$z_i = Flatten(Z_i) \in \mathbb{R}^{\{\tau \cdot d\}}$$

随后，该表示被送入一个由**多层感知机 (Multi-layer Perceptron, MLP)**构成的解码器，以完成对目标变量的预测任务。MLP 通常由若干层线性变换 + 激活函数 + Dropout 组成，在本研究中其输出可为：

- **分类任务**（如预测次日涨跌方向）：输出概率分布  $[p_0, p_1]$ ，采用 Softmax 激活；
- **回归任务**（如预测波动率或打分值）：输出实数，采用线性激活。

该结构可灵活适配多种金融策略场景，包括日内趋势预测，多空组合打分等

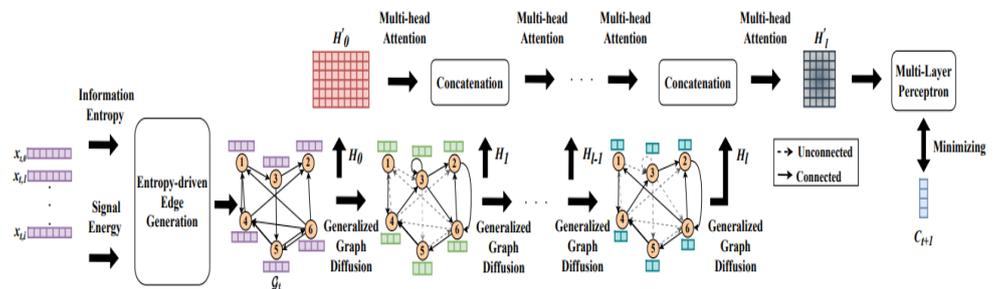
为了提高模型的稳健性与推广能力，我们采用了“联合损失函数”作为优化目标，包括交叉熵损失，邻接矩阵正则项等。

最终目标函数形式为：

$$Loss_{total} = Loss_{CE} + \lambda \cdot R_G$$

其中  $Loss_{CE}$  为交叉熵， $R_G$  为图结构正则项， $\lambda$  为调节系数。

图 5：模型运作流程 | 单位：无



数据来源：华泰期货研究院

图 2 系统展示了应用的模型在期货市场建模中的完整流程，其核心在于从“图结构构建”到“图信息扩散”再到“预测输出”的全链条建模。首先，模型以期货品种间的收益率时间序列为基础，基于条件熵与信号能量等指标动态生成边连接结构，构建出随时间变化的图网络，用以反映市场中各品种之间的联动强度。随后，在图扩散阶段，模型通过多层广义图扩散机制将节点特征在不同阶数的邻居间传播，从而捕捉跨层级、非局部的结构依赖。同时，为提升对关键路径的建模能力，引入多头注意力机制对每一层扩散特征进行加权整合，以突出重要节点之间的交互关系。最终，将所有时间步和扩散层级下的结构嵌入进行拼接，并输入多层感知机解码器，输出对下一个时间步涨跌信号的预测结果，并以交叉熵损失联合结构正则进行优化训练。整体架构实现了从数据驱动图结构生成、结构感知特征提取，到可解释性强的预测输出一体化建模，适用于期货市场中复杂的联动关系与动态演化结构的建模需求。

## 实证研究设计

### ■ 数据信息与预处理

在本研究中，所有实验所用数据均来源于国内商品期货市场的主力合约日线行情数据，涵盖了包括黑色、有色、化工、农产品等多个板块的主流交易品种。我们根据模型训练、验证与测试阶段的需求，分别设定了：

- 训练集（2021年1月4日至2022年12月31日）
- 验证集（2023年1月4日至2024年6月30日）
- 测试集（2023年7月1日至2025年5月9日）

在每一个阶段内，模型将自动筛选出在对应时间窗口内存在完整数据记录的所有品种，以确保样本结构的稳定性与研究结果的代表性。每个商品期货品种的数据均以独立文件形式存储，采用了包括开高低收价、持仓量、成交量等共15个特征，涵盖了市场交易中最核心的结构性与流动性特征。

在数据预处理环节，我们对所有品种的历史行情进行了统一格式化与特征工程处理。首先，通过字段规范化操作将所有特征数值标准化为相同量纲区间，以消除不同品种间由于价格区间差异所造成的模型学习偏差；其次，结合主力合约跳转信息完成了跨合约的连续拼接处理，确保时间序列的一致性与可学习性。我们构建了基于收盘价差异的二分类标签体系。具体而言，以时间  $t$  表示当前预测目标交易日，则其标签定义如下：

- 若该品种在  $T-1$  日的收盘价高于  $T-2$  日的收盘价，则标记为 1，代表“上涨”
- 若  $T-1$  日的收盘价低于  $T-2$  日的收盘价，则标记为 0，代表“下跌”

该标签构造方式充分考虑了信息可得性与无未来函数原则，确保模型预测仅基于  $t-2$  及更早时间点的信息，避免了样本标签信息泄露所带来的过拟合问题。

### ■ 交易构建

在本研究中，我们在完成上述模型的训练与验证后，进一步将模型应用于实盘回测框架，设计并实现了一套日频滚动多空信号生成机制。该机制旨在检验模型对未来走势方向的预测能力，并量化其在实际交易中的策略表现。

具体而言，回测采用 21 天滚动预测窗口的日频交易方式。在每一个测试集交易日  $T$ ，模型以过去 21 个交易日的多维特征作为输入，推理得到每个商品合约在  $T+1$  日的上涨概率分布，即通过 Softmax 输出的概率向量中的第二维（上涨类标签）作为排序依

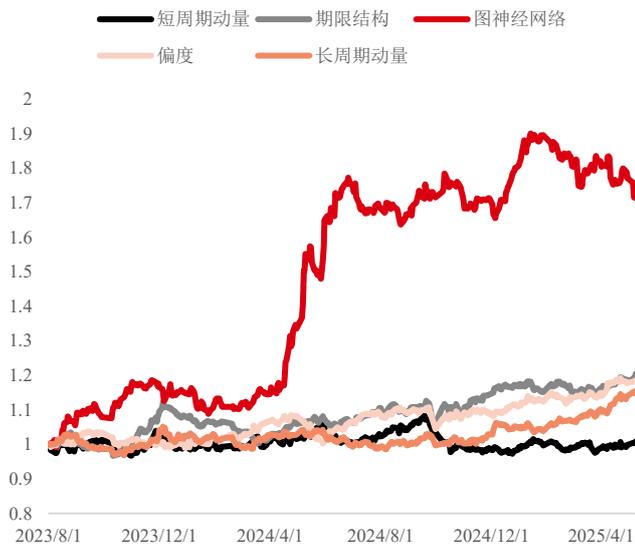
据。随后，系统基于该上涨概率  $P_{up}$  对所有可交易商品进行截面横截面排名，执行如下两类交易指令：

- **多头组合 (Long Portfolio)**：选择上涨概率排名前五的商品合约，赋予正向信号 (signal = +1)，构建等权多头组合；
- **空头组合 (Short Portfolio)**：选择上涨概率排名倒数五位的合约，赋予反向信号 (signal = -1)，构建等权空头组合。

上述多空信号在模型推理阶段逐日生成，便于后续与回测。至此，我们实现了从图结构建模、特征聚合、图扩散与注意力融合到交易信号输出的完整闭环。

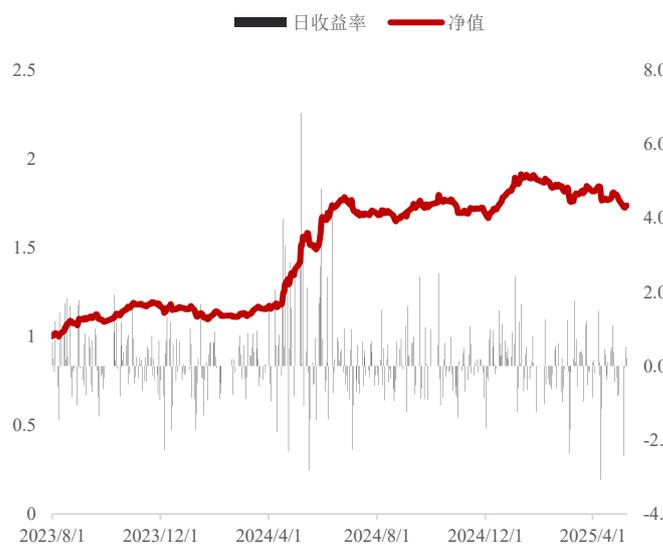
## 结果回测

图 6: 扩散图神经网络与传统截面策略对比 | 单位：无



数据来源：华泰期货研究院

图 7: 扩散图神经网络策略净值图 | 单位：无



数据来源：华泰期货研究院

表 1: 扩散图神经网络策略指标 | 单位：无

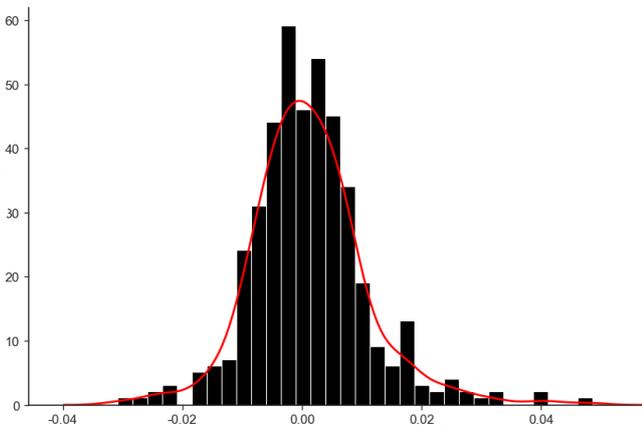
策略区间	年化收益率	年化波动率	Sortino 比率	最大回撤	夏普比率	信息比率
2023.08.01- 2025.05.09	38.45%	16.15%	4.53	-9.81%	2.38	1.92

数据来源：Wind 华泰期货研究院

从净值走势来看，策略自 2023 年 8 月起运行至 2025 年 5 月期间整体呈现稳健上行趋势，尤其在 2024 年中后期进入主升段，净值曲线斜率显著上扬，表现出较强的趋势捕捉与持仓执行能力，且表现大幅领先传统的截面策略。期间虽经历多轮市场波动，但最大回撤始终控制在 10% 以内。从日度收益率分布来看，波动幅度受控，极端负收益稀少，净值回撤后的恢复速度较快。尽管策略整体表现稳健，但需注意的，自 2025 年初以来，净值曲线进入平台震荡区间，收益增长趋于平缓，策略边际收益有所收窄。从走势上看，策略在该阶段的斜率明显下降，叠加日度收益率重心下移，进入区间波动的状态。

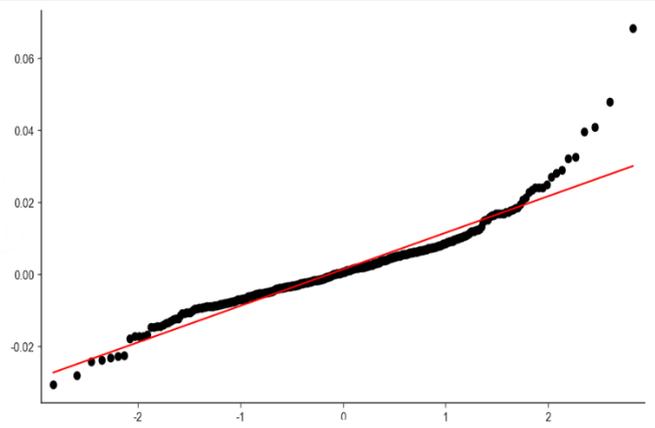
在核心绩效指标上，该策略年化收益率 38.45%、年化波动率 16.15%，对应夏普比率 2.38、整体收益-风险配比优秀。其中夏普和信息比率均显著高于 1，表明策略具备稳定的超额收益生成能力，并能有效分辨信号质量避免噪声干扰。Sortino 比率高达 4.53，进一步验证下行波动控制表现优异，回撤浅、回升快，兼顾进攻性与风险管理特征。

图 8：月收益分布形态 | 单位：%



数据来源：华泰期货研究院

图 9：分位数拟合图 | 单位：无



数据来源：华泰期货研究院

图 8 和图 9 分别展示了该策略在月度频率下的收益分布形态与正态性拟合结果，为理解策略潜在的风险-收益特征提供了直观依据。从图 8 来看，策略收益大致符合正态分布形态，但分布曲线右尾略厚，表明策略在多数时间段保持稳定、温和的收益波动，但在少数行情演绎顺畅的月份存在较大概率获取超额收益，从而拉高了整体收益的期望水平。左尾相对较轻，极端负收益样本出现频次较低，说明该策略在风险可控的前提下，具备较好的防御属性和尾部回撤管理能力。

进一步从图 9 可观察到，在分布尾部尤其是右尾区域，实际分位点显著偏离理论正态线，形成了典型的“右偏+厚尾”特征。这一统计特征通常代表收益的非对称性，即策略

表现并非单纯依赖长期均值回归，而是在少数市场趋势显著的窗口期内捕捉确定性机会，实现显著正向突破。

## 总结

本研究通过将扩散图神经网络引入商品期货市场，初步验证了基于动态结构建模与信息扩散机制的策略在捕捉跨品种联动、提升预测精度方面的可行性与有效性。实证结果表明，借助图结构动态生成、信息熵约束与多阶扩散特征融合，模型能够在复杂市场环境下持续挖掘具备前瞻性的多空交易信号，策略整体表现出稳健的收益-风险特征，具备一定的实盘应用价值。

但同时需要指出，本文工作仍处于早期探索阶段，整体策略框架、特征设计与交易实现存在较大优化空间。未来研究方向可考虑引入更为丰富的异构信息图谱、拓展至连续价格预测与交易动态调整任务、以及提升模型的实时自适应能力，进一步完善策略体系与落地效果。我们相信，随着图神经网络技术与金融数据建模手段的不断演进，基于结构信息感知的量化策略有望在复杂市场环境中展现更强的稳健性与前瞻性。

## 免责声明

本报告基于本公司认为可靠的、已公开的信息编制，但本公司对该等信息的准确性及完整性不作任何保证。本报告所载的意见、结论及预测仅反映报告发布当日的观点和判断。在不同时期，本公司可能会发出与本报告所载意见、评估及预测不一致的研究报告。本公司不保证本报告所含信息保持在最新状态。本公司对本报告所含信息可在不发出通知的情形下做出修改，投资者应当自行关注相应的更新或修改。

本公司力求报告内容客观、公正，但本报告所载的观点、结论和建议仅供参考，投资者并不能依靠本报告以取代行使独立判断。对投资者依据或者使用本报告所造成的一切后果，本公司及作者均不承担任何法律责任。

本报告版权仅为本公司所有。未经本公司书面许可，任何机构或个人不得以翻版、复制、发表、引用或再次分发他人等任何形式侵犯本公司版权。如征得本公司同意进行引用、刊发的，需在允许的范围内使用，并注明出处为“华泰期货研究院”，且不得对本报告进行任何有悖原意的引用、删节和修改。本公司保留追究相关责任的权利。所有本报告中使用的商标、服务标记及标记均为本公司的商标、服务标记及标记。

华泰期货有限公司版权所有并保留一切权利。

## 公司总部

广州市天河区临江大道1号之一2101-2106单元 | 邮编：510000

电话：400-6280-888

网址：www.htfc.com