

基于 LVC-TimeMixer 的浮法玻璃多类别缺陷预测方法

郑立召¹, 许世清¹, 张志勇², 刘世民^{1,2}, 王 辉¹, 窦丽姣¹, 郝晓辰¹

(1. 燕山大学, 河北 秦皇岛 066004; 2. 河北省浮法玻璃制造数智化技术创新中心, 河北 邢台 054100)

摘 要: 浮法玻璃熔化成形过程具有高温连续运行、多变量强耦合和缺陷响应长时滞等特点, 现有在线缺陷检测多属于事后识别, 难以及时支撑工艺前馈调节。针对多变量耦合及时滞不确定带来的多类别缺陷预测难题, 提出一种时滞感知变量耦合 TimeMixer 模型(Lag-aware Variable-Coupled TimeMixer, LVC-TimeMixer)。该模型以 TimeMixer 的多尺度分解与趋势波动混合结构为主干, 引入时滞感知编码器和变量分组耦合混合器: 前者利用 5、10、30、60、120 min 和 240 min 候选滞后尺度显式表征工艺扰动到缺陷响应的延迟关系, 后者按照温度、压力、流量、气氛和历史缺陷等工艺语义构建变量组内表征与组间耦合, 从而建立熔化成形工艺参数、历史缺陷序列与未来缺陷变化趋势之间的动态映射。基于某浮法玻璃生产线历史数据的验证结果表明, LVC-TimeMixer 在平均绝对误差(Mean absolute error, MAE)、均方根误差(Root mean square error, RMSE)、决定系数(Coefficient of determination, R^2)和 30 min 累计缺陷平均绝对误差(30-min cumulative MAE)方面表现最优, 对称平均绝对百分比误差(Symmetric mean absolute percentage error, sMAPE)和严重缺陷 F1 值(F1-score)虽非全部最优但接近优势水平; 消融实验进一步表明, 时滞感知编码与变量分组耦合具有协同增益。该方法可为浮法玻璃缺陷事前预警、工艺参数优化和智能质量控制提供数据驱动支撑。

关键词: 浮法玻璃; 缺陷预测; 时滞感知编码; 变量分组耦合; 时间序列预测

中图分类号: TP183 文献标志码: A 文章编号: 0454-5648(2026)10-3578-15

网络出版时间: 2026-09-03



浮法玻璃是建筑、汽车、电子显示和光伏等领域的重要基础材料, 其质量稳定性直接关系到后续深加工效率和终端应用性能^[1]。在浮法玻璃连续生产过程中, 气泡、结瘤、结石和点缺陷等质量问题会降低产品等级, 增加切裁损失与返工成本, 并对生产线稳定运行造成不利影响。当前工业现场通常配置在线缺陷检测设备, 用于在玻璃带检测端识别和统计缺陷^[2]。然而, 在线缺陷检测本质上属于事后检测手段, 当检测系统给出缺陷等级和数量时, 缺陷已在熔化、成形或退火过程中形成, 难以及时指导现场操作人员对熔窑热工制度、燃烧状态、液面和锡槽气氛进行前馈调节。除缺陷检测外, 条纹图像采集、识别与诊断也是表征浮法玻璃内在纹理和熔窑状态的重要手段, 能够从光学均匀性、液流路径和热历程等角度反映玻璃液流动规律及其潜在质量波动。因此, 利用历史工艺变量提前预测未来

缺陷变化趋势, 并与条纹图像诊断信息形成互补, 是实现浮法玻璃智能质量控制的重要方向。

从工艺机理看, 浮法玻璃熔化成形过程是典型的强非线性、强耦合、多工况连续热工过程^[3]。窑压、液面、流道温度、碛顶温度、澄清温度、残氧、天然气流量、助燃风量、池底温度以及锡槽保护气参数, 共同影响玻璃液的熔融、澄清、均化、冷却和成形状态^[4]。任一变量的局部波动往往不会单独作用于缺陷, 而是通过温度场、压力场、气氛场和玻璃液流场的耦合变化, 形成对缺陷生成的复合影响。同时, 玻璃液在熔窑和锡槽中的流动、停留和输送过程具有明显时滞, 工艺参数扰动往往需要经过数十分钟甚至更长时间后才能在检测端表现为缺陷等级变化。已有研究表明, 液流轨迹模拟与光学条纹检测可用于评价平板玻璃生产液流均化质量, 为基于条纹图像判断玻璃液流动状态提供了工艺依据^[5]。

收稿日期: 2026-05-15。 修订日期: 2026-06-21。

基金项目: 国家自然科学基金面上项目(52272029)。

第一作者: 郑立召(1993—), 男, 博士研究生。

通信作者: 许世清(1985—), 男, 博士, 副教授。

Received date: 2026-05-15. Revised date: 2026-06-21.

First author: ZHENG Lizhao (1993—), male, Doctoral candidate.

E-mail: zlbxk@stumail.ysu.edu.cn

Correspondent author: XU Shiqing (1985—), male, Ph.D., Associate Professor.

E-mail: ysuxsq@ysu.edu.cn

传统统计模型和浅层机器学习方法可用于部分平稳时序或单指标质量预测,但对浮法玻璃生产中的高维变量耦合、非平稳工况和长程依赖刻画不足^[6]。深度学习模型在工业软测量和时序预测中具有较强的非线性表达能力,其中长短期记忆网络(Long short-term memory, LSTM)、门控循环单元(Gated recurrent unit, GRU)和卷积神经网络(Convolutional neural network, CNN)能够捕捉短期时序依赖,但在长序列预测中存在梯度衰减和并行效率不足的问题^[7-9]; Transformer 及其改进模型通过注意力机制增强长程依赖建模能力,但在工业时间序列中也面临计算复杂度较高、时序结构归纳偏置不足和变量语义混合等问题^[10-11]。近年来, DLinear 通过趋势分解和线性映射提高长序列预测效率,但对非线性变量耦合表达有限^[12]; PatchTST 通过时间片建模增强局部模式提取,但变量间物理关联主要依赖数据驱动学习^[13]; iTransformer 将变量作为建模单元以增强多变量相关性表达,但缺少对工艺时滞的显式约束^[14]; TimeXer 强调外生变量融合,但仍未直接给出适用于浮法玻璃工艺链的滞后响应先验^[15]; TimeMixer 通过多尺度分解与混合刻画短期波动和长期趋势,适合作为多步预测的主干模型^[16]。WPMixer 利用小波或多分辨率分解与混合结构处理时间序列的多尺度特征,可作为频域/多尺度建模类基线,但其工艺变量语义分组和长时滞响应解释仍不充分^[17]。

基于某浮法玻璃生产线的真实工业数据,围绕未来一段时间内 4 类 10 等级缺陷的同步预测任务,提出时滞感知变量耦合 TimeMixer 模型(Lag-aware Variable-Coupled TimeMixer, LVC-TimeMixer)。选择优化 TimeMixer 而非重新构建全新主干,主要基于 2 点考虑:一方面,TimeMixer 的多尺度分解、Past-Decomposable-Mixing(PDM)和 Future-Multipredictor-Mixing(FMM)结构能够同时刻画连续生产中的短时

扰动和长周期热惯性;另一方面,原始 TimeMixer 主要面向通用时间序列预测,通常将变量作为无差别通道输入,缺少对浮法玻璃“工艺扰动-缺陷响应”长时滞关系和温度、压力、流量、气氛等变量组间耦合关系的显式表达。因此,在保留 TimeMixer 多尺度预测优势的基础上,引入时滞感知编码器和变量分组耦合混合器,以增强模型对工业过程先验的利用。主要工作包括:1) 构建面向浮法玻璃熔化成形过程的多变量缺陷预测样本,将 31 维工艺变量与 40 维历史缺陷标签统一为监督学习序列;2) 提出 LVC-TimeMixer 模型,在 TimeMixer 多尺度混合框架中引入时滞感知编码器和变量分组耦合混合器;3) 与 DLinear、PatchTST、iTransformer、原始 TimeMixer 和 WPMixer 进行系统对比,并通过消融实验量化 2 个新增模块的独立贡献与协同作用。进一步地,该方法可与条纹图像智能识别诊断技术结合,从工艺参数、历史缺陷和内在纹理图像等多源信息中综合分析玻璃液流动状态、热历程演化与缺陷形成规律,为玻璃熔窑智能化诊断和工艺优化提供数据支撑。

1 浮法玻璃熔化成形过程与缺陷预测任务

1.1 熔化成形工艺机理分析

浮法玻璃生产过程具有典型的连续制造特征,其产品质量并非由单一工序或单一工艺参数决定,而是在原料投放、熔融反应、澄清均化、冷却调质、锡槽成形和退火冷却等连续工序中逐步形成。因此,浮法玻璃缺陷预测不能仅从检测端缺陷图像或单点质量指标出发,而需要结合熔化成形过程的工艺机理,分析关键变量对缺陷生成的潜在影响路径。

如图 1 所示,浮法玻璃生产过程可概括为配合料制备与投料、熔窑高温熔融、澄清均化、冷却调




图 1 浮法玻璃生产示意图

Fig. 1 Schematic diagram of float glass production process

节、锡槽拉制成形及退火等环节。经冷却部调节后，玻璃液进入锡槽并漂浮于锡液表面，在保护气氛和拉引制度作用下完成摊平、抛光和成形。该过程具有高温、连续、强惯性和强耦合特征，任一局部工艺波动均可能通过玻璃液流动和热状态演化向后传递，并在一定滞后时间后影响最终缺陷分布。

从缺陷形成机理看，气泡、结瘤、结石和点缺陷等典型缺陷与熔化成形过程中的热工制度、燃烧状态、气氛条件和液流稳定性密切相关。熔窑温度场直接影响配合料熔化充分性、玻璃液黏度和澄清效率；澄清部温度及玻璃液停留状态决定气泡排出能力；窑压、残氧和燃料供给状态影响燃烧充分性及窑内氧化还原环境；锡槽内氮氢保护气流量、槽

压及成形稳定性则与表面类缺陷和点缺陷具有较强的关联性^[18]。

基于上述工艺机理和建模需求，变量选择遵循工艺相关性、可测性和预测有效性相结合的原则，优先选取与熔化成形状态及缺陷形成过程密切相关的关键过程变量作为模型输入。如表 1 所示，31 维工艺变量覆盖熔窑热工状态、压力与液位状态、燃烧与气氛状态、锡槽保护气状态以及投料与控制设定等方面，历史缺陷组则由 4 类缺陷标签的历史序列构成。通过将熔化成形工艺变量与历史缺陷序列共同作为模型输入，以未来缺陷作为模型输出，建立工艺状态演化与未来缺陷变化之间的动态映射关系，实现对未来短时缺陷趋势的提前预测。

表 1 输入变量与输出标签说明

Table 1 Description of input variables and output labels

Variable category	Representative variables	Process characterization meaning	Defect type
Furnace thermal variables	Channel temperature, crown temperature 2, crown temperature 7, refining temperature, bottom temperature 1, bottom temperature 3, bottom temperature 9, main flue temperature	Characterizes melting adequacy, refining efficiency, and the thermal state of the glass melt	Bubble, Knot, Stone
Pressure and liquid-level variables	Furnace pressure, glass level, cooling-section pressure	Characterizes the stability of the furnace atmosphere, glass-melt flow, and forming stability	Bubble, PDefect
Combustion and atmosphere variables	Natural-gas inlet pressure, natural-gas flow rate, natural-gas inlet temperature, combustion-air pressure 1, combustion-air pressure 2, combustion-air flow rate, residual oxygen, natural-gas calorific value, front combustion-air temperature, rear combustion-air temperature	Characterizes combustion adequacy and the oxidation-reduction environment	Bubble, Knot, Stone
Protective gas variables	Nitrogen flow rate 1, nitrogen flow rate 2, hydrogen flow rate 1, hydrogen flow rate 2, bath pressure 1, bath pressure 2	Characterizes the tin-bath protective atmosphere and surface-forming environment	PDefect
Batch-feeding and control variables	Feeder frequency, fine-adjustment fan setting, combustion-air pressure valve 1 setting, combustion-air pressure valve 2 setting	Characterizes load changes and control-adjustment behavior	Multiple defect types

1.2 预测任务定义

设经过时间对齐与 1 min 重采样后的多变量时间序列为：

$$\mathbf{U} = \{\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_t\} \quad (1)$$

式中： $\mathbf{u}_t$ 表示第 t 分钟的综合输入向量，由工艺变量和历史缺陷标签拼接得到：

$$\mathbf{u}_t = [\mathbf{x}_t, \mathbf{y}_t] \quad (2)$$

式中： $\mathbf{x}_t \in \mathbb{R}^{31}$ 表示第 t 分钟的 31 维熔化成形工艺变量， $\mathbf{y}_t \in \mathbb{R}^{40}$ 表示第 t 分钟的 40 维缺陷等级标签。因此，综合输入向量维度为：

$$\mathbf{u}_t \in \mathbb{R}^{71} \quad (3)$$

给定历史输入窗口长度 $L = 360$ min，则模型输入可表示为：

$$\mathbf{U}_{t-L+1:t} = [\mathbf{u}_{t-L+1}, \mathbf{u}_{t-L+2}, \dots, \mathbf{u}_t] \in \mathbb{R}^{L \times 71} \quad (4)$$

预测目标为未来 $H = 30$ min 内的缺陷等级

序列：

$$\mathbf{Y}_{t+1:t+H} = [\mathbf{y}_{t+1}, \mathbf{y}_{t+2}, \dots, \mathbf{y}_{t+H}] \in \mathbb{R}^{H \times 40} \quad (5)$$

因此，本工作的预测任务可形式化表示为：

$$\hat{\mathbf{Y}}_{t+1:t+H} = f_{\theta}(\mathbf{U}_{t-L+1:t}) \quad (6)$$

式中： $f_{\theta}(\cdot)$ 表示待学习的预测模型， θ 为模型参数， $\hat{\mathbf{Y}}_{t+1:t+H}$ 为模型输出的未来一段时间内缺陷预测结果。

该任务本质上属于多变量输入、多步预测和多输出回归问题，其目标是在历史工艺状态和历史缺陷趋势的基础上，同步预测未来一段时间内 Bubble、Knot、Stone 和 PDefect 4 类缺陷的 40 维等级序列。

2 LVC-TimeMixer 浮法玻璃缺陷预测模型

2.1 模型总体框架

浮法玻璃缺陷预测面临长时滞、多变量强耦合

和多类别多等级同步预测等问题。工艺参数扰动通常不会立即反映在检测端缺陷标签中,而是需要经过玻璃液熔融、澄清、输送、成形和检测等过程后才逐步显现;同时,温度、压力、流量、气氛及历史缺陷状态之间存在复杂耦合关系,单一变量或单一时间尺度难以充分表征缺陷形成过程。因此,缺陷预测模型不仅需要具备多尺度时间依赖建模能力,还应能够显式刻画工艺扰动的滞后响应关系和多源变量之间的耦合关联。

TimeMixer 通过多尺度下采样、趋势-波动分解、Past-Decomposable-Mixing(PDM)和 Future-Multipredictor-Mixing(FMM)等结构,能够同时提取时间序列中的短期波动和长期趋势信息,适合处理具有多尺度变化特征的工业时间序列。然而,原始 TimeMixer 主要面向通用时间序列预测任务,通常将各输入变量作为并列通道进行建模,对工业过程中特有的长时滞响应关系和变量组间耦合结构缺乏显式约束。对于浮法玻璃缺陷预测而言,若直接采用原始 TimeMixer,模型需要在高维长序列中自行学习“工艺扰动-缺陷响应”的延迟对应关系以及多类工艺变量之间的耦合传递规律,容易造成工艺先验利用不足的问题。

为解决上述问题,本工作在 TimeMixer 多尺度时间序列建模框架基础上提出 LVC-TimeMixer。该模

型保留 TimeMixer 对多尺度时间变化的建模优势,并在其输入特征进入多尺度混合主干之前引入两个面向工业过程的结构增强模块:时滞感知编码器(Lag-Aware Encoder)和变量分组耦合混合器(Variable-Coupled Mixer)。其中,时滞感知编码器用于构造不同滞后尺度下的历史状态表示,使模型能够显式捕捉工艺扰动与缺陷响应之间的延迟关系;变量分组耦合混合器则按照温度、压力、流量、气氛和历史缺陷等工艺语义对输入变量进行分组表征,并通过跨组融合刻画不同变量组之间的耦合关联。

如图 2 所示,LVC-TimeMixer 的整体流程包括输入序列构造、时滞感知编码、变量分组耦合混合、TimeMixer 多尺度混合主干和多步缺陷预测输出。首先,将 31 维熔化成形工艺变量与 40 维历史缺陷标签拼接为多变量输入序列,以同时表征工艺驱动信息和缺陷自身历史趋势;其次,时滞感知编码器围绕多个候选滞后尺度提取历史影响特征,增强模型对缺陷长时滞响应的表达能力;再次,变量分组耦合混合器依据工艺语义对变量进行分组,并在组内表征和跨组融合的基础上形成变量耦合表示;随后,通过多尺度分解与跨尺度混合提取短期扰动和长期趋势信息;最后,模型输出未来一段时间点内 Bubble、Knot、Stone 和 PDefect 4 类缺陷的预测序列。




图 2 LVC-TimeMixer 模型结构
Fig. 2 Structure of the LVC-TimeMixer model

与原始 TimeMixer 相比,LVC-TimeMixer 的改进重点不在于改变其多尺度趋势-波动建模范式,而是在输入端引入面向工业过程的时滞先验和变量耦合先验。时滞感知编码器用于缓解缺陷响应滞后不确定造成的有效信息稀释问题;变量分组耦合混合器用于增强模型对温度、压力、流量、气氛和历史缺陷等多类变量协同变化关系的建模能力。

2.2 时滞感知编码器

浮法玻璃缺陷形成具有显著的过程滞后性。熔窑温度场、窑压、液面、燃烧气氛及保护气状态的变化,通常需要经过玻璃液熔融、澄清、流动、成形和检测等环节后,才会在缺陷检测端表现为 Bubble、Knot、Stone 和 PDefect 等缺陷数量或等级的变化。因此,缺陷预测并非典型的即时响应问题,

而是具有明显滞后映射关系的工业多变量时间序列预测问题。

为增强模型对长时滞依赖的显式表征能力,本工作在 TimeMixer 主干之前引入时滞感知编码器。设经过时间对齐和重采样后的输入序列为

$$\mathbf{U}_{t-L+1:t} = [\mathbf{u}_{t-L+1}, \mathbf{u}_{t-L+2}, \dots, \mathbf{u}_t] \in \mathbb{R}^{L \times C} \quad (7)$$

式中: L 为历史输入窗口长度, C 为输入变量维度。第 t 分钟的综合输入向量由工艺变量和历史缺陷标签拼接得到:

$$\mathbf{u}_t = [\mathbf{x}_t, \mathbf{y}_t] \quad (8)$$

$$\mathbf{x}_t \in \mathbb{R}^{31}, \mathbf{y}_t \in \mathbb{R}^{40}, C = 71 \quad (9)$$

式中: $\mathbf{x}_t$ 表示第 t 分钟的工艺变量, $\mathbf{y}_t$ 表示第 t 分钟的历史缺陷标签。本工作设置历史窗口长度 $L = 360$ min, 预测窗口长度 $P = 30$ min。为避免符号混淆, 本工作统一采用 P 表示预测窗口长度, 采用 τ 表示滞后尺度, 采用 d_h 表示隐空间维度。

考虑浮法玻璃缺陷响应可能分布于不同滞后尺度, 构造离散滞后集合。该集合并非纯粹的超参数罗列, 而是结合现场工艺响应经验进行设置: 5 min 和 10 min 主要用于捕捉检测统计窗口及短时控制扰动带来的快速变化; 30 min 和 60 min 对应燃烧状态调整、澄清区气泡排出和温度场局部波动向检测端传递的中等时滞; 120 min 和 240 min 则用于表征玻璃液流动及长周期热惯性引起的慢响应:

$$\mathcal{D}_{lag} = \{5, 10, 30, 60, 120, 240\} \text{ min} \quad (10)$$

对于任意滞后尺度 $\tau \in \mathcal{D}_{lag}$, 在历史窗口内对每一个时间索引 $i = t - L + 1, \dots, t$ 抽取对应的滞后表示:

$$\mathbf{z}_i^{(\tau)} = \phi_\tau(\mathbf{U}_{t-L+1:t}; i) \quad (11)$$

式中: $\phi_\tau(\cdot)$ 表示以滞后时间 τ 为中心的特征抽取算子, 可由滞后点值、局部窗口均值、局部波动幅度或变化率共同构成。例如:

$$\begin{aligned} \phi_\tau(\mathbf{U}_{t-L+1:t}; i) = \\ \text{Concat}[\mathbf{U}_{i-\tau}, \text{Mean}(\mathbf{U}_{i-\tau-r:i-\tau+r}), \text{Std}(\mathbf{U}_{i-\tau-r:i-\tau+r}), \Delta \mathbf{U}_{i-\tau}] \end{aligned} \quad (12)$$

式中: r 为局部统计窗口半径, $\Delta \mathbf{U}_{i-\tau}$ 表示滞后位置附近的变化率特征。对于历史窗口边界之外的索引, 可采用有效样本截断或边界填充方式处理。由此可得到滞后尺度 τ 下的序列表示:

$$\mathbf{Z}_{t-L+1:t}^{(\tau)} = [\mathbf{z}_{t-L+1}^{(\tau)}, \mathbf{z}_{t-L+2}^{(\tau)}, \dots, \mathbf{z}_t^{(\tau)}] \quad (13)$$

将不同滞后尺度的序列表示进行拼接, 可得到

多时滞特征集合:

$$\begin{aligned} \mathbf{Z}_{t-L+1:t}^{lag} = \\ \text{Concat}[\mathbf{Z}_{t-L+1:t}^{(5)}, \mathbf{Z}_{t-L+1:t}^{(10)}, \mathbf{Z}_{t-L+1:t}^{(30)}, \mathbf{Z}_{t-L+1:t}^{(60)}, \mathbf{Z}_{t-L+1:t}^{(120)}, \mathbf{Z}_{t-L+1:t}^{(240)}] \end{aligned} \quad (14)$$

为进一步提取不同滞后尺度之间的局部相关性, 本工作采用空洞卷积对多时滞特征进行编码:

$$\mathbf{F}_{t-L+1:t}^{lag} = \text{Conv}_{dilated}(\mathbf{Z}_{t-L+1:t}^{lag}) \quad (15)$$

同时, 为避免所有滞后尺度被等权利用, 引入门控机制自适应调节不同滞后特征对当前预测任务的贡献:

$$\mathbf{G}_{t-L+1:t}^{lag} = \sigma(\mathbf{W}_g \mathbf{Z}_{t-L+1:t}^{lag} + \mathbf{b}_g) \quad (16)$$

$$\mathbf{H}_{t-L+1:t}^{lag} = \mathbf{G}_{t-L+1:t}^{lag} \odot \tanh(\mathbf{F}_{t-L+1:t}^{lag}) + (1 - \mathbf{G}_{t-L+1:t}^{lag}) \odot \mathbf{Z}_{t-L+1:t}^{lag} \quad (17)$$

式中: $\mathbf{W}_g$ 为滞后特征门控层的可学习权重矩阵, $\mathbf{b}_g$ 为门控偏置向量, $\sigma(\cdot)$ 为 Sigmoid 激活函数, $\odot$ 表示逐元素乘法, $\mathbf{G}_{t-L+1:t}^{lag}$ 为滞后门控权重, $\mathbf{H}_{t-L+1:t}^{lag}$ 为时滞感知编码后的序列表示。该结构使模型能够在不同工况下动态选择更有效的滞后尺度, 从而提升对“工艺扰动-缺陷响应”延迟关系的建模能力。

从建模机理看, 时滞感知编码器相当于向模型引入时间延迟归纳偏置。该归纳偏置并不预设唯一固定滞后时间, 而是通过多尺度滞后集合和门控选择机制, 使模型在候选滞后范围内自适应学习不同变量对未来缺陷的作用时段, 更符合浮法玻璃复杂热工过程中非固定时滞的实际特征。

2.3 变量分组耦合混合器

浮法玻璃熔化成形过程中的工艺变量具有明确的物理语义和过程属性。温度变量主要反映熔窑热工制度和玻璃液热状态, 压力变量反映窑内与锡槽气氛稳定性, 流量变量反映燃料、助燃风和保护气供应状态, 气氛变量反映燃烧充分性和氧化还原环境, 历史缺陷变量则表征检测端质量状态的短期演化趋势。若直接将所有变量作为无差别通道输入模型, 虽然能够利用深度网络自动学习变量关系, 但会弱化工艺变量之间的结构先验, 降低模型对复杂耦合过程的表达效率。

为此, LVC-TimeMixer 引入变量分组耦合混合器。具体地, 先依据表 1 将 31 维工艺变量归入温度、压力、流量和气氛等工艺语义组, 再将 40 维历史缺陷标签作为历史缺陷组输入, 使模型同时获得过程状态和质量状态两类信息。投料频率、微调风机设定和助燃风压力阀设定等控制变量不再作为孤立类

别处理, 而是根据其作用对象并入对应的流量、压力或燃烧气氛相关变量组。由此可得到:

$$\mathcal{G} = \{\mathcal{G}_{\text{temp}}, \mathcal{G}_{\text{press}}, \mathcal{G}_{\text{flow}}, \mathcal{G}_{\text{atm}}, \mathcal{G}_{\text{defect}}\} \quad (18)$$

式中: $\mathcal{G}_{\text{temp}}$ 、 $\mathcal{G}_{\text{press}}$ 、 $\mathcal{G}_{\text{flow}}$ 、 $\mathcal{G}_{\text{atm}}$ 和 $\mathcal{G}_{\text{defect}}$ 分别表示温度组、压力组、流量组、气氛组和历史缺陷组。

对于第 m 个变量组, 其输入表示记为 $\mathbf{H}_m^{\text{lag}}$, 其中 $m=1, 2, \dots, K$, K 为变量组数量。首先, 通过组内映射函数提取组内局部表示:

$$\mathbf{E}_m = \psi_m(\mathbf{H}_m^{\text{lag}}) \quad (19)$$

式中: $\psi_m(\cdot)$ 可由线性层、轻量 MLP 或一维卷积实现。该步骤用于对同一工艺语义下的变量进行局部聚合, 使温度、压力、流量等变量组形成相对独立的隐空间表达。

在获得组内表示后, 进一步构建跨组耦合关系。考虑到不同变量组之间并非独立作用, 而是通过燃烧、传热、气氛稳定和玻璃液流动形成耦合传播, 本工作采用可学习的组间耦合权重描述不同工艺组之间的信息交互:

$$\alpha_{mn} = \text{Softmax} \left[\frac{(\mathbf{W}_q \mathbf{E}_m)(\mathbf{W}_k \mathbf{E}_n)^T}{\sqrt{d_h}} \right] \quad (20)$$

$$\tilde{\mathbf{E}}_m = \mathbf{E}_m + \sum_{n=1}^K \alpha_{mn} \mathbf{W}_v \mathbf{E}_n \quad (21)$$

式中: $\mathbf{W}_q$ 和 $\mathbf{W}_k$ 分别为注意力机制中的 Query 和 Key 映射矩阵, $\mathbf{E}$ 为变量组经过组内特征映射后的嵌入表示, α_{mn} 表示第 n 个变量组对第 m 个变量组的影响权重, K 为变量组数量, d_h 为隐空间维度。最终将各变量组的融合表示拼接, 得到变量耦合后的整体表征:

$$\mathbf{H}_{t-L+1:t}^{\text{vc}} = \text{Concat}(\tilde{\mathbf{E}}_1, \tilde{\mathbf{E}}_2, \dots, \tilde{\mathbf{E}}_K) \quad (22)$$

该模块的作用在于将工业变量由无结构通道集合转化为具有工艺语义约束的变量组交互系统。与直接对全部变量进行混合相比, 变量分组耦合混合器能够同时保留组内变量的一致性和组间变量的协同性, 更符合浮法玻璃熔化成形过程中温度、压力、燃烧、气氛与缺陷之间的耦合传播机制。

此外, 组间耦合权重可作为模型解释性分析的辅助依据。例如, 在换火或燃烧状态调整过程中, 燃烧/气氛组对温度组及缺陷组的耦合权重可能增强; 在改板、拉引制度变化或锡槽保护气波动时, 压力组、流量组与历史缺陷组之间的权重变化可用于分析表面类缺陷或点缺陷的风险来源。受限于当前数据标注, 本工作主要通过总体预测性能和消融

实验验证该模块的有效性, 后续工程部署中可进一步结合换火、改板和异常工况标签开展组间权重的动态解释。

2.4 TimeMixer 多尺度混合主干与预测输出

经过时滞感知编码器和变量分组耦合混合器处理后, 输入序列被转化为同时包含滞后响应信息和变量组耦合关系的隐含表示:

$$\mathbf{H}_{t-L+1:t}^{\text{vc}} \in \mathbb{R}^{L \times d_h} \quad (23)$$

式中: L 表示历史输入窗口长度, d_h 表示隐空间维度。需要说明的是, LVC-TimeMixer 的主要结构改进集中于前端的时滞感知编码和变量分组耦合建模, 后续时间序列建模部分仍沿用 TimeMixer 的多尺度混合主干。该处理方式既保留了 TimeMixer 对短期波动与长期趋势的分解建模能力, 又使主干网络输入具有更明确的工业过程先验。

在多尺度建模阶段, 模型首先对 $\mathbf{H}_{t-L+1:t}^{\text{vc}}$ 进行不同尺度的下采样, 构造多尺度序列表示:

$$\mathbf{H}^{(s)} = \text{Down}_s(\mathbf{H}_{t-L+1:t}^{\text{vc}}) \quad s \in \mathcal{S} \quad (24)$$

式中: $\mathcal{S} = \{1, 2, 4, 8, 16\}$, 表示下采样尺度集合, $\text{Down}_s(\cdot)$ 表示尺度因子为 s 的下采样操作。较小尺度保留原始序列中的局部扰动信息, 较大尺度则压缩历史窗口并突出长周期工况趋势。

随后, TimeMixer 主干对每一尺度下的序列进行趋势项与波动项分解:

$$\mathbf{T}^{(s)} = \text{AvgPool}[\mathbf{H}^{(s)}] \quad (25)$$

$$\mathbf{R}^{(s)} = \mathbf{H}^{(s)} - \mathbf{T}^{(s)} \quad (26)$$

式中: $\mathbf{T}^{(s)}$ 表示尺度 s 下的趋势项, 主要表征工况缓慢漂移和长期演化; $\mathbf{R}^{(s)}$ 表示对应的波动项, 主要表征短期扰动和局部异常。该分解与浮法玻璃生产过程中短时控制扰动和长周期热惯性并存的特征相一致。

在 Past-Decomposable-Mixing(PDM)模块中, 不同尺度下的趋势项与波动项进行跨尺度混合, 形成多尺度历史表征:

$$\mathbf{M}^{(s)} = \text{PDM}[\mathbf{T}^{(s)}, \mathbf{R}^{(s)}] \quad s \in \mathcal{S} \quad (27)$$

式中: $\mathbf{M}^{(s)}$ 表示尺度 s 下经过多尺度混合后的历史表示。PDM 模块使模型能够同时利用高分辨率序列中的局部波动信息和低分辨率序列中的长期趋势信息, 从而降低单一时间尺度建模对缺陷演化规律刻画不足的问题。

最后, Future-Multipredictor-Mixing(FMM)模块对不同尺度的历史表示进行未来多步预测融合, 得

到未来 P 个时间步的缺陷预测序列:

$$\hat{\mathbf{Y}}_{t+1:t+P} = \text{FMM}\left(\{\mathbf{M}^{(s)}\}_{s \in S}\right) \quad (28)$$

$$\hat{\mathbf{Y}}_{t+1:t+P} \in \mathbb{R}^{P \times 40} \quad (29)$$

式中: P 为预测窗口长度, 本工作设置 $P = 30$ min; 40 表示 Bubble、Knot、Stone 和 Pdefect 4 类缺陷的输出维度。由此, LVC-TimeMixer 的整体预测映射可表示为:

$$\hat{\mathbf{Y}}_{t+1:t+P} = f_{\theta}(\mathbf{U}_{t-L+1:t}) \quad (30)$$

式中: $f_{\theta}(\cdot)$ 表示由时滞感知编码器、变量分组耦合混合器和 TimeMixer 多尺度混合主干共同组成的预测模型, θ 为模型参数。

该模型在结构上形成了工艺时滞建模、变量耦合表征、多尺度趋势波动混合、多步缺陷输出的完整预测流程。通过上述设计, LVC-TimeMixer 能够在保持 TimeMixer 原有多尺度建模能力的基础上, 更充分地利用浮法玻璃生产过程中的时滞与变量耦合先验, 从而提升未来短时缺陷趋势预测的稳定性和准确性。

3 结果与讨论

3.1 数据集与实验设置

本工作实验数据来源于某浮法玻璃生产线熔化成形工序的历史生产记录, 字段包括 31 维工艺过程变量以及 40 维缺陷等级标签。工艺变量覆盖温度、压力、流量、气氛、燃烧和控制设定等关键过程信息, 缺陷标签包括 Bubble、Knot、Stone 和 PDefect 4 类缺陷的 10 个等级。

原始数据采样间隔为 10 s, 考虑到工业现场数据存在异步采集、重复记录、局部缺失和高频噪声等问题, 实验前对数据进行统一预处理。首先, 按照时间戳对原始数据排序, 并将其重采样为 1 min 时间粒度, 以统一不同变量的时间基准。对于工艺变量, 采用窗口均值聚合以降低瞬时噪声影响; 对于缺陷标签, 采用窗口内数量统计以保留缺陷发生强度。对于短时缺失的工艺变量, 采用前向填充和线性插值相结合的方法进行处理。

在样本构造方面, 采用滑动窗口方式生成监督学习样本。历史输入窗口长度设置为 360 min, 预测窗口长度设置为 30 min, 即利用过去 360 min 的工艺变量和历史缺陷序列预测未来 30 min 内的 40 维缺陷标签。训练集、验证集和测试集按照时间顺序划分, 避免随机划分造成未来信息泄露, 从而保证

模型评估结果能够反映真实工业应用中的时间外推能力。

为保证模型对比的公平性, 所有模型均采用相同的数据划分、输入窗口、预测窗口和评价指标。对比模型包括 DLinear、PatchTST、iTransformer、TimeMixer、WPMixer 以及本工作提出的 LVC-TimeMixer。

3.2 评价指标

为全面评价模型在缺陷数量预测、趋势拟合、累计风险估计和严重缺陷预警方面的性能, 选取平均绝对误差(Mean absolute error, MAE)、均方根误差(Root mean square error, RMSE)、对称平均绝对百分比误差(Symmetric mean absolute percentage error, sMAPE)、决定系数(Coefficient of determination, R^2)、30 min 累计缺陷 MAE(Cum30-MAE)和严重缺陷 F1 值作为评价指标。按照与工程应用目标的关联程度, MAE、RMSE 和 R^2 用于优先评价缺陷数量预测精度、峰值误差控制和趋势拟合能力; Cum30-MAE 用于评价 30 min 窗口内累计风险估计能力; sMAPE 作为相对误差指标, 用于补充分析不同量级缺陷下的预测偏差; 对于严重缺陷预警, 将等级 7~10 的缺陷定义为高风险缺陷, 并计算 Precision、Recall 和 F1 值, 以衡量模型对严重缺陷的识别能力。

$$\text{CumMAE}_{30} = \frac{1}{N} \sum_{n=1}^N \left| \sum_{h=1}^{30} y_{n,h} - \sum_{h=1}^{30} \hat{y}_{n,h} \right| \quad (31)$$

$$P = \frac{TP}{TP + FP}, R = \frac{TP}{TP + FN} \quad (32)$$

$$F1 = \frac{2PR}{P + R} \quad (33)$$

式中: N 为测试样本数, n 为样本序号, h 为预测步序号, 30 为预测窗口长度, $y_{n,h}$ 和 $\hat{y}_{n,h}$ 分别表示第 n 个样本在第 h 个预测步的真实值和预测值, P 为精确率(Precision), R 为召回率(Recall), F1 为二者的调和平均值。

3.3 总体预测性能对比

为验证 LVC-TimeMixer 在浮法玻璃多类别缺陷短时预测任务中的有效性, 本工作选取 DLinear、PatchTST、iTransformer、原始 TimeMixer 和 WPMixer 作为对比模型。不同模型在测试集上的总体预测结果如表 2 所示。

由表 2 可知, LVC-TimeMixer 在 MAE、RMSE、 R^2 和 30 min 累计缺陷 MAE 上均取得最优结果, 但在 sMAPE 和严重缺陷 F1 指标上接近最优, 说明时滞感知编码和变量耦合建模能够提升模型对缺陷变

化趋势的拟合能力, 但其在极端严重缺陷识别方面仍有进一步提升空间。

3.4 LVC-TimeMixer 预测稳定性分析

为进一步评价模型在不同预测步长下的稳定

性, 统计了 5、10、15、20 min 和 30 min 预测范围内的累计缺陷预测结果, 并从误差变化、趋势解释能力和相对改进幅度 3 个方面进行分析, 结果见表 3、图 3 和图 4。

表 2 不同模型总体预测性能对比

Table 2 Comparison of overall prediction performance of different models

Model	MAE	RMSE	sMAPE	R^2	30-min Cumulative MAE	Severe-Defect F1
DLinear	10.722	46.639	70.282	-11.767	5 433.20	0.853
PatchTST	11.857	38.190	70.731	0.020	5 383.05	0.855
iTransformer	11.251	37.117	66.715	0.583	5 702.81	0.873
LVC-TimeMixer	10.525	30.368	69.817	0.616	5 194.10	0.842
TimeMixer	14.031	41.179	75.408	0.423	6 672.30	0.797
WPMixer	14.660	48.542	74.130	-6.663	9 142.76	0.850

表 3 不同预测步长下 LVC-TimeMixer 与对比模型结果

Table 3 Results of LVC-TimeMixer and comparison models under different prediction horizons

Prediction Horizon/min	LVC 30-min Cumulative MAE	LVC R^2	Second-Best Model	Second-Best MAE	Reduction Relative to Second Best	Reduction Relative to Original TimeMixer
5	642.92	0.925	PatchTST	717.22	10.36%	37.95%
10	1 351.44	0.912	PatchTST	1 468.78	7.99%	34.89%
15	2 174.41	0.890	PatchTST	2 311.97	5.95%	31.09%
20	3 092.56	0.867	PatchTST	3 242.55	4.63%	27.36%
30	5 194.10	0.813	PatchTST	5 383.05	3.51%	22.15%




图 3 不同预测步长下预测指标变化

Fig. 3 Variation of prediction metrics under different prediction horizons




图4 不同预测步长下 LVC-TimeMixer 相对各对比模型的改进率

Fig. 4 Improvement rate of LVC-TimeMixer relative to comparative models under different prediction horizons

由表 3 和图 3 可知, 随着预测步长由 5 min 延长至 30 min, 各模型的 MAE 和 MSE 整体呈上升趋势, R^2 则逐渐下降, 说明多步预测中误差累积和趋势不确定性增强是普遍现象。相比其他模型, LVC-TimeMixer 在不同预测步长下均保持最低 MAE, 并且 R^2 始终维持在较高水平, 表明该模型在短期和中期预测范围内均具有较好的误差控制能力和趋势保持能力。尤其在 30 min 预测范围内, LVC-TimeMixer 仍能保持较优的累计缺陷预测效果, 说明其对未来缺陷总量变化具有较强的稳定估计能力。

图 4 进一步给出了 LVC-TimeMixer 相对各对比模型的改进率。可以看出, LVC-TimeMixer 在 5、

10、15、20 min 和 30 min 预测范围内均取得正向改进, 其中相较于原始 TimeMixer 的误差降低较为明显, 说明时滞感知编码与变量分组耦合机制能够有效弥补原始 TimeMixer 对工艺长时滞和变量耦合关系显式建模不足的问题。

综合来看, LVC-TimeMixer 在预测步长增加时仍能保持较稳定的误差水平和趋势解释能力, 说明其对浮法玻璃缺陷演化中的短期扰动、长期趋势和滞后响应关系具有较好的适应性。

3.5 不同缺陷类型预测性能分析

为考察模型在不同缺陷类别上的适用性, 进一步统计 Bubble、Knot、Stone 和 PDefect 4 类缺陷的预测误差。由表 4 和图 5 可知, 不同模型在 4 类缺

陷上的表现存在差异,说明 Bubble、Knot、Stone 和 PDefect 的时序变化规律及其受工艺变量影响的方式并不完全相同。其中,DLinear在 Bubble和 Stone 上取得最优结果,表明这 2 类缺陷在测试区间内具有较明显的连续趋势特征;iTransformer 在 Knot 上表现较好,说明变量间相关性对该类缺陷预测具有重要作用;PatchTST 在 PDefect 上更具优势,反映局部时间片模式对表面类缺陷变化较为敏感。LVC-TimeMixer 虽未在所有单类缺陷上均取得最

优,但其 4 类缺陷 MAE 均接近最优模型。

表 4 4 类缺陷上的最优模型与 LVC-TimeMixer 表现
Table 4 Performance of the optimal model and LVC-TimeMixer on four types of defects

Defect Type	Optimal Model	Optimal MAE	LVC-TimeMixer MAE
Bubble	DLinear	19.875	20.103
Knot	iTransformer	4.100	4.378
Stone	DLinear	10.548	10.605
PDefect	PatchTST	6.500	7.012




图 5 4 类缺陷预测曲线对比

Fig. 5 Comparison of prediction curves for four types of defects

3.6 预测曲线与分布一致性分析

为进一步检验模型在真实时间顺序测试中的跟踪能力,本工作在完成训练和验证集参数选择后,固定各模型参数,在同一测试集上按时间顺序进行滚动预测。每个测试样本均以前 360 min 工艺变量和历史缺陷标签作为输入,输出未来 30 min 内 40 维缺陷等级序列。测试阶段不随机抽样、不打乱时间顺序,所有模型使用完全相同的测试窗口、预测步长和后处理方式,以避免时间序列泄漏并保证模型间比较的公平性。

统计时,首先在每个测试窗口内对 Bubble、Knot、Stone 和 PDefect 4 类、10 个等级的预测标签和真实标签进行汇总,得到窗口级总缺陷序列;随

后按测试时间顺序拼接各窗口结果,绘制测试段总缺陷预测曲线(图 6)。同时选取测试集第一个滚动窗口,比较未来 30 min 内真实缺陷变化与模型预测变化,以观察模型在单次在线预测中的短时跟踪能力(图 7)。最后,将测试集中所有窗口、预测步和输出维度的预测值与真实值配对,绘制预测值-真实值散点分布,并以 1:1 参考线评价预测分布偏移程度(图 8)。

由图 6~图 8 可见,LVC-TimeMixer、iTransformer 和 PatchTST 的预测曲线整体更接近真实曲线,能够较好跟随缺陷总量的上升、下降及局部峰值变化;WPMixer 和原始 TimeMixer 在部分时段存在系统性偏移。结合表 2 中 RMSE 和 30 min 累计 MAE 结果




图6 测试段总缺陷预测曲线对比

Fig. 6 Comparison of total defect prediction curves in the test segment




图7 第一个测试窗口内未来 30 min 总缺陷预测曲线

Fig. 7 Total defect prediction curves for the next 30 min within the first test window




图8 预测值与真实值分布散点图

Fig. 8 Scatter plot of predicted values versus true values distribution

可知, LVC-TimeMixer 不仅平均误差较低, 而且对局部峰值误差和窗口累计风险的控制更好。散点分布结果也显示, LVC-TimeMixer 的点云整体更集中于 1:1 参考线附近, 说明其预测分布与真实分布具有较好一致性。

3.7 消融实验

为验证时滞感知编码器和变量分组耦合混合器的独立贡献及协同作用, 在与 3.1 节相同的数据划

分、输入窗口、预测窗口、训练流程和评价指标下构建 4 组消融模型: TimeMixer 为不引入新增模块的基线模型; TimeMixer-Lag 仅在 TimeMixer 输入端加入时滞感知编码器; TimeMixer-VC 仅加入变量分组耦合混合器; LVC-TimeMixer 同时引入时滞感知编码器和变量分组耦合混合器。4 组模型除上述结构差异外均保持相同的训练/验证/测试划分和预测任务设置, 以保证消融结果的对比性。

表5 消融实验总体指标

Table 5 Overall metrics of ablation experiments

Model	MAE	RMSE	sMAPE	R^2	30-min Cumulative MAE	Severe-Defect F1
TimeMixer	14.031	41.179	75.408	0.423	6 672.302	0.797
TimeMixer-Lag	13.360	37.800	74.480	0.514	6 228.000	0.812
TimeMixer-VC	14.780	43.500	76.620	0.357	6 965.000	0.804
LVC-TimeMixer	10.525	30.368	69.817	0.616	5 194.098	0.842

由表 5 可知, 仅加入时滞感知编码器后, TimeMixer-Lag 相较 TimeMixer 的 MAE、RMSE、sMAPE 和 30 min 累计缺陷 MAE 分别提升至 13.360、37.800、74.480 和 6 228.000, R^2 由 0.423 提高至 0.514, 严重缺陷 F1 由 0.797 提高至 0.812, 说明显式滞后建模能够改善缺陷响应延迟造成的预测偏差。仅加入变量分组耦合混合器时, TimeMixer-VC 的严重缺陷 F1 由 0.797 提高至 0.804, 但 MAE、RMSE 和累计缺陷误差未同步改善, 表明变量耦合先验若缺少时滞对齐, 可能会放大不同工艺组之间的非同步扰动。同时引入 2 个模块后, LVC-TimeMixer 相较 TimeMixer 的 MAE、RMSE、sMAPE 和 30 min 累计缺陷 MAE 分别提升至 10.525、30.368、69.817 和 5 194.098, R^2 提高至 0.616, 严重缺陷 F1 提高 0.045。

图 9 表明, 随着预测步长增加, 各模型误差均逐渐增大、 R^2 逐渐下降, 但 LVC-TimeMixer 始终保持最低误差和最高 R^2 。图 10 展示了各消融模型在测试段总缺陷变化趋势上均能一定程度跟随真实曲线, 但预测稳定性和峰值跟踪能力存在明显差异: 原始 TimeMixer 在部分时段与真实值存在偏移, TimeMixer-Lag 引入时滞感知编码后, 预测曲线整体更接近真实曲线, 说明滞后信息对缺陷演化趋势具有较强约束作用; TimeMixer-VC 在缺少时滞对齐

的情况下, 部分区间预测值偏高, 表明单独引入变量耦合可能受到不同工艺变量非同步扰动的影响。相比之下, LVC-TimeMixer 的预测曲线与真实曲线吻合度最高, 尤其在缺陷总量上升、局部波动及峰值变化阶段均表现出较好的跟踪能力。这说明时滞感知编码器首先完成工艺扰动与缺陷响应的对齐, 变量分组耦合混合器再在相对对齐的隐空间中学习温度、压力、流量、气氛与历史缺陷之间的耦合传播关系, 两者具有明显的协同作用。

3.8 工程应用与局限性讨论

为评估模型在线部署可行性, 本工作基于搭载定制 2×24 GB VRAM NVIDIA GeForce RTX 4090 图形处理器计算硬件, 进一步统计 LVC-TimeMixer 在测试阶段的单窗口推理耗时。本任务以长度 360 min、单步 31 维工艺变量时序与同步历史缺陷序列构成输入样本, 实现未来 30 min 缺陷的滚动预测; 在上述硬件环境下, 模型单次推理平均耗时为 11.6 ms, 最大耗时为 21.3 ms, 推理延迟显著低于工业现场 1 min 级滚动预警时效阈值, 满足在线实时预警的算力约束, 可作为现场滚动预警信号。

从工程应用角度看, 当模型预测 Bubble 类缺陷上升时, 可优先提示操作人员复核澄清温度、燃烧状态、窑压和残氧等变量; 当 PDefect 类缺陷风险升高时, 可结合锡槽保护气流量、槽压和成形稳定




图 9 不同预测步长下各消融模型预测指标变化

Fig. 9 Variation of prediction metrics of ablation models under different prediction horizons




图 10 测试段各消融模型总缺陷预测曲线对比

Fig. 10 Comparison of total-defect prediction curves of ablation models in the test segment

性进行排查。此外，条纹图像诊断可作为缺陷预测模型的重要补充信息来源，后续可通过图像处理或深度视觉模型提取条纹强度、条纹密度、纹理方向、灰度统计量及高维图像特征，并依据图像采集时间戳与工艺变量和历史缺陷序列进行对齐。对齐后的条纹图像特征可作为独立的图像诊断变量组输入变量分组耦合混合器，与温度组、压力组、流量组、气氛组和历史缺陷组共同参与组内表征和组间耦合建模，为分析玻璃液流动状态、热历程演化和缺陷生成风险提供更完整的数据支撑。受限于本工作数据集尚未包含严格同步的条纹图像序列，未开展图像-时序多源融合实验，该方向将在后续工作中进一步验证。

4 结论

针对浮法玻璃熔化成形过程中多类别缺陷的短时预测问题，本工作提出了 LVC-TimeMixer 模型。该模型在 TimeMixer 多尺度趋势—波动建模框架基础上，引入时滞感知编码器和变量分组耦合混合器，用于刻画工艺扰动与缺陷响应之间的非固定滞后关系，以及温度、压力、流量、气氛和历史缺陷等变量组之间的耦合关系。基于真实工业数据的实验结果表明，LVC-TimeMixer 在 MAE、RMSE、 R^2 和 30 min 累计缺陷 MAE 方面表现最优；消融实验进一步验证了时滞感知编码与变量分组耦合的协同增益。研究结果表明，该方法能够为浮法玻璃缺陷滚动预警、熔窑工况优化和智能质量控制提供数据驱动支撑，后续可进一步结合极端工况样本、同步条纹图像数据和现场在线部署验证，拓展其在异常工况识别、多源信息融合和闭环工艺优化中的应用能力。

(第二十八届中国科协年会学术论文)

参考文献:

- [1] LIU Z Y. Research status on the structure, performance, and defects of float glass[J]. Adv Engineering&PrecisionManufacturing, 2026, 2(1): 1–7.
- [2] QI F L, TAN X, ZHANG Z Z, et al. Glass makes blurs: Learning the visual blurriness for glass surface detection[J]. IEEE Trans Ind Inf, 2024, 20(4): 6631–6641.
- [3] 金明芳, 何峰, 谢峻林, 等. 700 t/d 浮法玻璃熔窑中玻璃液流动特性与澄清过程研究[J]. 过程工程学报, 2024, 24(4): 425–434. JIN Mingfang, HE Feng, XIE Junlin, et al. Chin J Process Eng, 2024, 24(4): 425–434.
- [4] 彭开香, 秦昕, 王佳浩, 等. 一种面向多工序复杂制造过程的质量软测量方法[J]. 工程科学与技术, 2024, 56(6): 3–14. PENG Kaixiang, QIN Xin, WANG Jiahao, et al. Adv Eng Sci, 2024, 56(6): 3–14.
- [5] 许世清, 陈天麟, 刘林林, 等. 人工智能在平板玻璃生产领域的研究进展与展望: 技术融合与产业变革[J]. 硅酸盐学报, 2025, 53(10): 2912–2928. XU Shiqing, CHEN Tianlin, LIU Linlin, et al. J Chin Ceram Soc, 2025, 53(10): 2912–2928.
- [6] CHEN T Q, GUESTRIN C. XGBoost: A scalable tree boosting system[C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco California USA. ACM, 2016: 785–794.
- [7] BECK M, PÖPPEL K, SPANRING M, et al. xLSTM: Extended long short-term memory[C]//Advances in Neural Information Processing Systems 37. Vancouver, BC, Canada. Neural Information Processing Systems Foundation, Inc. (NeurIPS), 2024: 107547–107603.
- [8] JHIN S Y, KIM S, PARK N. Addressing prediction delays in time series forecasting: A continuous GRU approach with derivative regularization[C]//Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. ACM, 2024: 1234–1245.
- [9] LI Z X, PENG K X, CHEN J H, et al. CNN-LSTM-CVA based quality monitoring of waviness for float glass manufacturing process[C]//2023 35th Chinese Control and Decision Conference (CCDC). Yichang, China. IEEE, 2023: 76–81.
- [10] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Advances in Neural Information Processing Systems. 2017, 30: 5998–6008.
- [11] ZHOU H Y, ZHANG S H, PENG J Q, et al. Informer: Beyond efficient transformer for long sequence time-series forecasting[J]. Proc AAAI Conf Artif Intell, 2021, 35(12): 11106–11115.
- [12] LIN L, SHANG X N. Time series forecasting of train axle fatigue crack acoustic emission signals by integrating multi-head attention mechanism into DLinear model[J]. Appl Acoust, 2025, 240: 110922.
- [13] QU Z J, MENG Y, HOU X X, et al. Integrated energy short-term multivariate load forecasting based on PatchTST secondary decoupling reconstruction for progressive layered extraction multi-task learning network[J]. Expert Syst Appl, 2025, 269: 126446.
- [14] LIU Y, HU T, ZHANG H, et al. iTransformer: Inverted transformers are effective for time series forecasting[C]//Int Conf Learn Represent. 2024: 11116–11140.
- [15] TANG W, CHEN J, CHEN D, et al. Predicting EV battery state of health using long short term degradation feature extraction and FEA TimeMixer[J]. Sci Rep, 2025, 15: 2200.

- [16] WANG Y X, WU H X, DONG J X, et al. TimeXer: Empowering transformers for time series forecasting with exogenous variables[C]// Advances in Neural Information Processing Systems 37. Vancouver, BC, Canada. Neural Information Processing Systems Foundation, Inc. (NeurIPS), 2024: 469–498.
- [17] MURAD M M N, AKTUKMAK M, YILMAZ Y. WPMixer: Efficient multi-resolution mixing for long-term time series forecasting[J]. Proc AAAI Conf Artif Intell, 2025, 39(18): 19581–19588.
- [18] 陈淑勇, 李从云, 王照猛, 等. 浮法工艺玻璃带成形过程的模拟分析[J]. 硅酸盐学报, 2021, 49(2): 340–346.
- CHEN Shuyong, LI Congyun, WANG Zhaomeng, et al. J Chin Ceram

Soc, 2021, 49(2): 340–346.

作者贡献声明:

郑立召: 论文构思、设计研究方法和实验方案、撰写初稿
 许世清: 监督指导、审阅与修订
 张志勇: 项目管理、提供资源
 刘世民: 监督指导、审阅与修订
 王 辉: 软件使用、绘制图表
 窦丽姣: 调查研究, 数据管理
 郝晓辰: 提供资源、审阅与修订

A Multi-Class Defect Prediction Method for Float Glass Based on LVC-TimeMixer

ZHENG Lizhao¹, XU Shiqing¹, ZHANG Zhiyong², LIU Shimin^{1,2}, WANG Hui¹, DOU Lijiao¹, HAO Xiaochen¹
 (1. Yanshan University, Qinhuangdao 066004, Hebei, China; 2. Hebei Technology Innovation Center for Digital and Intelligent Float Glass Manufacturing, Xingtai 054100, Hebei, China)

Extended Abstract

Introduction Float glass is a fundamental material for architecture, automotive applications, electronic displays and photovoltaics, and its quality stability directly affects downstream processing efficiency and end-use performance. In continuous float glass production, defects such as bubbles, knots, stones and point defects reduce product grade, increase cutting losses and rework costs, and disturb stable operation. Existing online defect inspection systems usually identify defects after they have already formed, so they cannot provide sufficient support for feed-forward adjustment of furnace thermal conditions, combustion state, glass level or tin-bath atmosphere. The melting and forming process is a highly nonlinear, strongly coupled, and long-lag industrial thermal process. Process disturbances are transmitted through the temperature field, pressure field, atmosphere field and glass flow field, and their influence may appear at the inspection end only after tens of minutes or longer. Therefore, this study focuses on short-term prediction of four types of defects with 10 levels in float glass and proposes a lag-aware variable-coupled TimeMixer model, named LVC-TimeMixer, to establish a dynamic mapping from historical process states and defect sequences to future defect trends.

Methods Historical records from a float glass production line were used to construct the prediction dataset. The input data consisted of 31 process variables covering furnace thermal state, pressure and liquid level, combustion and atmosphere, tin-bath protective gas, feeding and control settings, together with 40 historical defect labels corresponding to Bubble, Knot, Stone and PDefect at ten levels. The raw 10 s records were sorted by timestamp and resampled to a 1 min interval. Window averaging was applied to process variables to suppress high-frequency noise, while defect labels were aggregated by counts in each window; short missing values were treated using forward filling and linear interpolation. Supervised samples were generated by a sliding-window strategy, with a 360 min historical input window and a 30 min prediction horizon. On the basis of the original TimeMixer framework, LVC-TimeMixer introduces a lag-aware encoder and a variable-coupled mixer before the multiscale mixing backbone. The lag-aware encoder explicitly extracts delayed representations under candidate lag scales of 5, 10, 30, 60, 120 min and 240 min and uses a gating mechanism to adaptively select effective lag information. The variable-coupled mixer groups variables according to process semantics, including temperature, pressure, flow, atmosphere and historical defects, and then learns intra-group representations and inter-group coupling relationships. The encoded representation is subsequently fed into the TimeMixer backbone, where multiscale decomposition, Past-Decomposable-Mixing and Future-Multipredictor-Mixing are used to predict the multi-step defect sequence.

Results and discussion The proposed model was compared with DLinear, PatchTST, iTransformer, the original TimeMixer and WPMixer under the same data split, input window, prediction horizon and evaluation metrics. The results show that LVC-TimeMixer achieved the best overall performance in MAE, RMSE, R^2 and 30 min cumulative defect MAE, with corresponding values of 10.525, 30.368, 0.616 and 5 194.10, respectively. Although its sMAPE and severe-defect F1 were not the best among all models, they remained close to the leading level, indicating that the proposed lag-aware and variable-coupled structures improve trend fitting and cumulative risk estimation while maintaining competitive severe-defect warning capability. At prediction horizons of 5, 10, 15, 20 min and 30 min, LVC-TimeMixer consistently maintained the lowest MAE and a relatively high R^2 , demonstrating stable short- and medium-term prediction capabilities.

For different defect categories, the optimal model varied because Bubble, Knot, Stone and PDefect have different temporal patterns and process response mechanisms. LVC-TimeMixer did not achieve the best MAE for every single defect type, but its errors for all four defect categories were close to those of the corresponding optimal models, and its overall defect prediction and 30 min cumulative risk estimation were superior. Rolling prediction curves and predicted-vs.-true scatter distributions further indicate that

LVC-TimeMixer can better track the rise, fall and local peaks of total defects on chronological test data. Ablation experiments confirm that the lag-aware encoder improves prediction by aligning process disturbances with delayed defect responses, whereas the variable-coupled mixer used alone may be limited when lag alignment is absent. When both modules were introduced simultaneously, the MAE and 30 min cumulative defect MAE were further reduced by 21.22% and 16.60%, respectively, compared with TimeMixer-Lag, proving the synergistic effect between lag-aware encoding and variable-group coupling. Engineering evaluation showed that the average and maximum inference times for a single prediction window were 11.6 ms and 21.3 ms, respectively, on a computing platform equipped with custom 2×24 GB VRAM NVIDIA GeForce RTX 4090 GPUs, which is far below the 1 min rolling warning threshold in industrial applications.

Conclusions In this study, an LVC-TimeMixer model was proposed for short-term multiclass defect prediction in the float glass melting-forming process. By embedding a lag-aware encoder and a variable-coupled mixer into the TimeMixer multiscale trend-fluctuation modeling framework, the model explicitly describes both the delayed relationship between process disturbances and defect responses and the coupling relationship among temperature, pressure, flow, atmosphere and historical defect variables. The comparative experiments, prediction-curve analysis and ablation study demonstrate that the proposed model improves overall prediction accuracy, cumulative risk estimation and prediction stability. The model can provide data-driven support for rolling defect early warning, furnace operating-condition optimization and intelligent quality control in float glass production. However, further research is still required to improve generalization under extreme operating conditions, to verify long-term real-time deployment, and to integrate synchronized stripe-image diagnosis or other multi-source visual information.

Keywords float glass; defect prediction; lag-aware encoding; variable group coupling; time series forecasting