

新质生产力下重点工业产品产量预测研究

——基于动态分层面板与可解释机器学习

周 雪

广西师范大学数学与统计学院, 广西 桂林

收稿日期: 2026年6月29日; 录用日期: 2026年7月21日; 发布日期: 2026年7月31日

摘 要

在高质量发展与新质生产力培育背景下, 重点工业产品月度产量变化能够反映技术扩散、产业链景气与结构替代。本文以国家统计局公开发布的规模以上工业生产资料为基础, 构造重点工业产品的产品-月份短面板, 并在原有滞后变量基础上补充增长产品占比、产品销售率、出口交货值增速、高技术制造业溢价等月度外部特征。研究采用动态固定效应、类别异质性检验、正则化回归和受约束集成学习相结合的建模路径, 重点比较不同产品类别的增长分化、预测误差结构和模型稳定性。研究表明, 新质生产力相关产品具有较高增长水平, 但部分产品同时表现出更强波动和更高预测风险; 短期预测中, 产品自身滞后增速仍是最稳定的基础信号, 外部景气变量主要用于刻画月度背景和修正模型偏差。本文的价值不在于简单堆叠算法, 而在于以产品层级数据、月度外部变量和误差分解共同支撑产业监测模型。

关键词

新质生产力, 工业产品产量, 短面板数据, 数据增强, 动态面板, Elastic Net, 梯度提升, 误差分解

Research on Forecasting the Output of Key Industrial Products under New-Quality Productive Forces

—Based on a Dynamic Hierarchical Panel and Interpretable Machine Learning Approach

Xue Zhou

School of Mathematics and Statistics, Guangxi Normal University, Guilin Guangxi

Received: June 29, 2026; accepted: July 21, 2026; published: July 31, 2026

Abstract

Under the background of high-quality development and the cultivation of new quality productive forces, monthly output fluctuations of key industrial products can reflect technological diffusion, industrial-chain dynamics and structural substitution. Based on public monthly industrial production statistics by the National Bureau of Statistics, this paper constructs a product-month short panel of key industrial products and enriches the feature space with external monthly indicators, including the breadth of products with positive growth, product sales ratio, export delivery growth and the high-tech manufacturing premium. A combined framework of dynamic fixed effects, category heterogeneity tests, regularized regression and constrained ensemble learning is used to examine growth differentiation, predictive errors and model robustness across product groups. The results indicate that products related to new-quality productive forces usually show stronger growth, while some of them also exhibit higher volatility and larger forecasting risk. For short-term prediction, product-specific lagged growth remains the most stable signal, whereas external monthly indicators help describe macro-industrial conditions and reduce interpretive ambiguity. The contribution of this paper lies in strengthening industrial monitoring with product-level data, external monthly variables and structured error decomposition rather than merely adding algorithms.

Keywords

New-Quality Productive Forces, Output of Industrial Products, Short Panel Data, Data Enhancement, Dynamic Panel, Elastic Net, Gradient Boosting, Error Decomposition

Copyright © 2026 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

1.1. 研究背景与问题提出

中国工业经济正在从数量扩张导向转向结构升级、技术扩散和效率提升导向。新质生产力强调以科技创新推动产业创新，具有高科技、高效能、高质量和符合新发展理念的特征[1]。传统宏观指标如规模以上工业增加值、制造业采购经理指数、固定资产投资、工业企业利润和出口交货值，仍能刻画工业运行的总量景气，但在产业升级速度加快阶段，单一总量指标容易掩盖产品之间的结构分化。新能源汽车、工业机器人、服务机器人、太阳能电池、集成电路和发电设备等产品的月度产量变化，与技术路线、设备更新、能源转型、出口需求和供应链重构密切相关。国家统计局在 2025 年 12 月工业生产资料中列示主要工业产品产量及同比增速，并披露产品销售率和出口交货值等指标[2]。这说明官方月度工业产品数据已经具备进行产品层级结构监测的公开基础。

本文关注的核心问题不是一般性地判断“工业是否平稳”，而是在月度样本较短、产品差异明显、预测结果需要解释的条件下，如何构建一套既有数据支撑又能用于后续月度更新的应用统计模型。若只做均值比较，难以回答产品产量增速是否存在可利用的动态规律；若只堆叠机器学习算法，又会弱化统计口径约束和经济解释。本文因此将研究对象设定为“产品 - 月份短面板”的可解释预测问题：在小时时间维度、多产品横截面和高解释需求并存的情境下，通过产品层数据、月度外部变量、动态面板和误差分解共同识别新质生产力相关产品与传统工业品之间的增长分化、动态惯性和预测风险。

1.2. 研究目标与边界

本文的研究目标包括三个层面。第一，在描述层面，刻画 2025 年 3 月至 12 月重点工业产品同比增速的类别差异，比较绿色能源装备、绿色交通装备、数字智能装备、能源化工、传统原材料和其他工业品的增长水平、波动程度和负增长占比。第二，在数据增强层面，将规模以上工业增加值、制造业增加值、高技术制造业增加值、增长产品占比、产品销售率和出口交货值增速转化为月度外部特征，用于补充单纯产品滞后项无法覆盖的共同冲击。第三，在预测层面，比较基准滞后模型、固定效应模型、正则化回归和集成学习模型的留出集表现，并通过滚动起点验证、产品块 Bootstrap 和类别误差贡献分解评估模型稳定性。

本文严格限定数据边界。由于国家统计局 1 月至 2 月工业生产月度数据通常采用累计口径发布，若将 1~2 月累计量机械拆分为单月观测，会破坏月度口径一致性。因此，本文样本期从 2025 年 3 月开始，至 2025 年 12 月结束。本文不虚构多年历史面板，也不把全国产品产量外推为省域或企业微观数据。这样的处理牺牲了时间长度，但提高了统计口径的可信度。为弥补时间维度不足，本文不再停留于理论模型扩写，而是补充月度外部数据和误差贡献分解，使模型深度更多来自数据维度和诊断维度的扩展。

1.3. 边际贡献

本文的边际贡献主要体现在四个方面。第一，将产品名称规范化、单位剥离、平衡面板检查、滞后变量重算和异常值处理纳入同一数据工程，减少由表格格式差异造成的伪异质性。第二，在产品滞后特征之外加入增长产品占比、产品销售率、出口交货值增速和高技术制造业溢价等月度变量，使模型能够同时利用产品自身惯性和工业景气背景。第三，将动态固定效应、类别异质性检验、Elastic Net 与受约束集成学习置于统一框架，使推断层回答“是否存在可预测的统计规律”，预测层回答“何种模型更适合短面板外推”。第四，通过时间顺序留出、滚动起点验证、产品块重抽样和类别误差贡献分解，避免只报告平均误差而忽视不同产品类别风险差异。

2. 文献综述与理论分析

2.1. 工业运行监测与产品层级统计

工业运行监测长期依赖工业增加值、PMI、用电量、货运量、价格指数和工业企业利润等总量或行业指标。这类指标宏观代表性强，但在结构升级阶段可能出现“总量平稳、结构分化”的情形。新兴装备类产品快速增长，而传统原材料产品低速增长甚至负增长，汇总后可能被相互抵消。产品层级统计的优势在于接近真实生产环节，可以把产业链景气落实到可观察的具体产品上。例如，新能源汽车产量反映整车制造、动力电池、汽车电子、充电基础设施和上游有色金属需求的共同变化；工业机器人产量反映制造业自动化投资和设备更新节奏；太阳能电池、风力发电量和发电设备则与能源结构转型、项目交付周期和电力投资相关。

国家统计局 2025 年统计公报和年度经济运行资料显示，装备制造业、高技术制造业和数字产品制造业保持较快增长，3D 打印设备、工业机器人、新能源汽车等产品增势突出[3] [4]。这类信息说明，“新质生产力”并非抽象概念，而可以通过装备制造、高技术制造、数字产品和关键产品产量等统计指标获得经验观察。本文的产品分类据此遵循“技术密集度、绿色转型属性、装备支撑功能与传统原材料属性”四项原则：新能源汽车归入绿色交通装备，太阳能电池和发电设备归入绿色能源装备，工业机器人和集成电路归入数字智能装备，钢材、水泥、生铁等归入传统原材料。需要说明的是，该分类用于研究解释和模型分组，并不等同于国家统计局的正式行业分类。

2.2. 短面板预测、正则化学习与非线性模型

短面板数据的基本特征是时间维度较短、横截面个体相对较多。若对每个产品单独建立时间序列模型，每个产品只有少量月份，参数估计不稳定；若把所有产品完全合并为一个总量模型，又会损失产品异质性。因此，短面板方法适合在利用产品共同信息的同时保留个体差异。固定效应模型能够控制产品不随时间变化的平均差异，动态项能够刻画自身惯性，类别交互项能够观察增长规律是否随产品类别变化[5] [6]。

在预测层面，正则化回归适合小样本、多变量、变量相关性强的场景。Ridge 通过 L2 惩罚降低共线性下的估计方差[7]，Lasso 通过 L1 惩罚实现变量筛选[8]，Elastic Net 结合 L1 和 L2 惩罚，适合产品虚拟变量、类别变量、滞后特征和宏观变量并存的特征矩阵[9]。随机森林能够捕捉非线性关系和变量交互[10]，梯度提升适合刻画逐步逼近的复杂函数关系[11]，但在短面板中容易过拟合，因此必须通过树深限制、最小叶节点约束和时间顺序验证控制复杂度。应用统计研究的关键不是展示算法数量，而是让模型复杂度与数据生成机制、样本边界和决策需求相匹配[12] [13]。从应用计量经济学视角看，机器学习模型还需服务于清晰的预测问题和解释边界[14] [15]。

2.3. 可解释预测与不确定性披露

真实产业监测场景中，单点预测往往不足以支持决策。若模型在绿色能源装备上误差较大，但在能源化工上误差较小，那么同样的 RMSE 均值背后对应不同的决策风险。时间序列预测还存在验证方式问题，普通随机交叉验证会把未来月份信息泄漏到训练集中，不适合用于月度监测[16]。滚动起点验证按照时间顺序扩展训练集并预测下一期，更接近真实使用过程[17]。由于单个产品在留出集内对应多期时序观测，聚类内部误差存在自相关，全部观测无法满足独立同分布假定；相比于朴素逐观测自助抽样(Naive Observation Bootstrap)，以产品为聚类单元的产品块 Bootstrap (Cluster Bootstrap)能够完整保留面板组内误差依赖关系。预测误差比较可参考 Diebold-Mariano 检验思路[18]，可解释性披露则有助于说明模型结论的适用边界[19]。本文因此把误差类别分解、不确定性区间和稳健性检验作为模型评价的组成部分。

3. 数据来源、样本构造与特征扩展

3.1. 数据来源

本文数据来自国家统计局官网发布的 2025 年 3 月至 12 月规模以上工业生产月度新闻稿及其“规模以上工业生产主要数据”表。国家统计局 2025 年 12 月、11 月、10 月、8 月和 7 月公开页面分别列示了相关产品表和产品销售率、出口交货值等背景指标[20]，工业司解读材料用于辅助说明月度工业运行背景[21]。数据字段包括主要工业产品当月绝对量、当月同比增速、累计绝对量和累计同比增速；同时合并月份层面的工业增加值、制造业、高技术制造业、汽车制造业、电子设备制造业、私营企业、产品销售率、出口交货值和工业生产者价格等背景指标。国家统计局对规模以上工业企业的统计范围通常指年主营业务收入达到统计制度规定标准的工业法人单位，因此本文结论仅适用于该公开统计口径下的规模以上工业主要产品，不外推为全部工业主体。

本文采用“网页正文整理 - 附件表格合并 - 产品口径统一 - 滞后变量重算 - 模型验证记录”的处理流程。研究者可按月份下载或复制国家统计局公开页面中的产品表，统一字段名称后合并。本文新增的数据处理重点不是机械扩大样本，而是在原有产品短面板基础上补充行业景气、产品扩散广度、销售率和出口背景变量，并把时间切分、误差区间和类别误差贡献纳入模型评价过程。样本结构见表 1。

3.2. 产品口径规范化

官方网页表格并非天然适合直接建模。部分月份存在产品名称与单位混写的情况，例如同一产品可

能被写作“乙烯(万吨)”或“乙烯(万吨)”。若直接使用原始名称生成面板个体，模型会把同一产品拆成多个个体，导致固定效应、滞后变量和产品虚拟变量全部失真。本文的清洗流程包括：统一中英文括号、百分号和空格；识别并剥离产品名称末尾单位括号；把规范化产品名称作为唯一产品标识；按“产品-月份”排序后重算一阶滞后、二阶滞后、两期滚动均值和滞后差分；检查每个月是否均包含 36 种产品。规范化后样本恢复为 36 种产品、每种产品 10 个月的平衡短面板。

Table 1. Data sources and sample structure
表 1. 数据来源与样本结构

项目	内容
数据来源	国家统计局规模以上工业生产月度公开数据表
样本期间	2025 年 3 月至 2025 年 12 月
原始观测	360 条产品-月份记录
规范化产品数	36 种工业产品
建模样本	剔除二阶滞后缺失后为 288 条观测
训练集	2025 年 5 月至 10 月，共 216 条观测
主留出集	2025 年 11 月至 12 月，共 72 条观测
核心目标变量	产品月度产量同比增速

注：样本从 3 月开始，是为避免 1~2 月累计口径与 3 月以后单月口径混用。

3.3. 变量体系

本文被解释变量为产品 i 在月份 t 的产量同比增速 y_{it} 。选择同比增速而非产量绝对值，是因为不同产品单位差异显著，新能源汽车以万辆计，工业机器人以套计，发电量以亿千瓦时计，钢材和水泥以万吨计。同比增速在一定程度上消除了单位差异和季节项影响，更适合跨产品比较。核心动态特征包括一阶滞后同比增速 $y_{i,t-1}$ 、二阶滞后同比增速 $y_{i,t-2}$ 、两期滚动均值 $(y_{i,t-1} + y_{i,t-2})/2$ 和滞后差分 $y_{i,t-1} - y_{i,t-2}$ 。月份层面变量包括规模以上工业增加值、制造业、高技术制造业、汽车制造业、电子设备制造业和私营企业同比增速。产品属性变量包括产品类别和是否属于新质生产力相关产品。主要变量定义见表 2。

Table 2. Variable definitions and model entry methods
表 2. 变量定义与进入模型方式

变量类型	变量名称	含义	进入模型方式
被解释变量	yoy_growth	产品月度产量同比增速	主模型目标变量
动态特征	lag1_yoy	上一月同比增速	固定效应与预测模型
动态特征	lag2_yoy	前两月同比增速	预测模型
动态特征	rolling2_yoy	前两期同比增速均值	预测模型
动态特征	delta_lag	一阶滞后与二阶滞后差	固定效应与预测模型
宏观景气	hightech_yoy	月度行业增速变量	解释模型与预测模型
产品属性	category	产品类别	哑变量与交互项
稳健性目标	yoy_winsor	1%~99%缩尾同比增速	稳健性检验

3.4. 外部数据扩展与月度景气特征

为增强实证分析的信息含量，本文将模型深化重点放在数据扩展和诊断指标构造上，而不是仅增加

复杂公式。除产品月度产量同比增速外，本文进一步整理 2025 年 3 月至 12 月的工业增加值、制造业增加值、高技术制造业增加值、规模以上工业 623 种产品中同比增长的产品数量、产品销售率和出口交货值增速，构造增长产品占比、高技术制造业溢价和外需景气变量。这些变量位于月份层面，能够刻画所有产品共同面对的工业景气环境。月度景气变量见表 3。

表 3 显示，样本期内增长产品占比由 3 月的 65.0%回落至 11 月的 49.8%，12 月回升至 52.2%，说明产品增长并非始终呈均衡扩散状态，而是在年内经历了由宽口径增长向局部增长转换的过程。同期，高技术制造业增速始终高于全部规模以上工业增加值，高技术制造业溢价保持为正，说明技术密集部门仍构成工业结构升级的重要背景；出口交货值增速在样本期内由正转负再回升，提示单纯依赖产品滞后项难以解释所有月份波动。由此，本文把这些外部变量作为模型特征，而不是只在文献综述或政策背景中叙述。

Table 3. Monthly industrial cyclical variables and product diffusion breadth
表 3. 月度工业景气变量与产品扩散广度

月份	工业增加值 增速	制造业增速	高技术制造 业增速	增长产品占 比	产品销售率	出口交货值 增速
2025 年 3 月	7.7	7.9	10.7	65.0%	93.0	7.7
2025 年 4 月	6.1	6.6	10.0	54.7%	97.2	0.9
2025 年 5 月	5.8	6.2	8.6	52.3%	95.9	0.6
2025 年 6 月	6.8	7.4	9.7	60.8%	94.3	4.0
2025 年 7 月	5.7	6.2	9.3	53.8%	97.1	0.8
2025 年 8 月	5.2	5.7	9.3	51.2%	96.6	-0.4
2025 年 9 月	6.5	7.3	10.3	58.1%	96.7	3.8
2025 年 10 月	4.9	4.9	7.2	50.2%	96.4	-2.1
2025 年 11 月	4.8	4.6	8.4	49.8%	96.5	-0.1
2025 年 12 月	5.2	5.7	11.0	52.2%	98.2	3.2

注：增长产品占比 = 当月产量同比增长产品数/623；各增速单位均为%。数据根据国家统计局 2025 年 3 月至 12 月规模以上工业生产公开页面整理。

从数据结构看，外部变量增强了短面板的时间维度信息。增长产品占比反映工业产品扩散广度，产品销售率反映产销衔接，出口交货值增速反映外需扰动，高技术制造业溢价反映技术密集部门相对全部工业的增长优势。它们与产品自身滞后增速、类别变量和产品固定效应共同进入特征矩阵，使模型解释不再局限于“上一期增速决定下一期增速”的机械惯性。

4. 研究设计与模型设定

4.1. 动态固定效应模型

本文首先估计动态短面板固定效应模型，以检验产品同比增速是否存在短期惯性。模型设定为：

$$y_{it} = \alpha_i + \beta_1 y_{i,t-1} + \beta_2 \Delta y_{i,t-1} + \gamma' M_t + \varepsilon_{it} \tag{1}$$

其中， α_i 为产品固定效应， $y_{i,t-1}$ 为一阶滞后同比增速， $\Delta y_{i,t-1} = y_{i,t-1} - y_{i,t-2}$ ， M_t 为月份层面的工业景气变量。由于同一产品在不同月份的误差可能相关，标准误按产品聚类。本文时间维度较短，不机械使用复杂动态面板 GMM；固定效应模型的作用是提供统计解释，而非严格因果识别。

4.2. 数据增强型动态特征模型

在固定效应模型基础上, 本文进一步引入月份层面的外部特征向量 z_t , 包括增长产品占比、产品销售率、出口交货值增速、高技术制造业溢价以及制造业相对全部工业的增速差。数据增强型动态模型设定为:

$$y_{it} = \alpha_i + \rho y_{i,t-1} + \delta \Delta y_{i,t-1} + \eta' z_t + \kappa' (z_t \times q_i) + x_{it}' \beta + u_{it} \quad (2)$$

其中, z_t 为月度外部特征向量, q_i 表示产品是否属于新质生产力相关类别, $z_t \times q_i$ 用于刻画外部景气变化对新兴产品和传统产品的差异影响。该设定的重点不是引入难以支撑的复杂层级结构, 而是把已经整理出的月度外部数据直接纳入预测特征, 使模型深度来自可观察变量和误差诊断。

此外, 为避免只比较总体 RMSE 而忽视类别风险, 本文使用类别误差贡献率刻画不同产品块对总预测损失的贡献:

$$RC_c = \frac{\text{RMSE}_c^2 \times n_c}{\sum_g \text{RMSE}_g^2 \times n_g} \times 100\% \quad (3)$$

其中, RMSE_c 为类别 c 在留出集上的预测误差, n_c 为该类别留出集观测数。该指标把模型误差转换为类别层面的风险权重, 可用于识别哪些产品组决定了总体预测表现。

4.3. 正则化回归与集成学习

预测层面构造统一特征矩阵 X 。数值特征包括滞后增速、滚动均值、差分项、产量绝对值对数、月份趋势和宏观景气变量; 类别特征包括产品类别和规范化产品名称。线性模型中, 数值变量标准化, 类别变量独立编码。Elastic Net 目标函数为:

$$\min_{\beta} \left\{ \frac{1}{2n} y - X\beta_2^2 + \lambda \left[\frac{1-a}{2} \beta_2^2 + a\beta_1 \right] \right\} \quad (4)$$

其中, λ 控制惩罚强度, a 控制 L1 与 L2 惩罚混合比例。当产品虚拟变量和宏观变量共同进入模型时, Elastic Net 能够同时压缩不稳定系数并剔除弱贡献特征。随机森林和梯度提升作为非线性对照, 用于检验特征之间是否存在可预测的非线性或交互结构。为防止短面板中过拟合, 本文限制树深度和叶节点样本数, 并将其与 Naive 基准和正则化模型放在相同时间顺序验证下比较。

4.4. 验证设计与评价指标

主验证方案以 2025 年 5 月至 10 月为训练集, 以 2025 年 11 月至 12 月为留出集。评价指标包括 RMSE、MAE、 R^2 和 Bias。为增强模型比较的统计含义, 本文同时保留三类诊断思路: 一是按时间顺序的滚动起点验证, 检验模型在逐月更新场景中的稳定性; 二是产品块 Bootstrap, 估计留出集误差区间; 三是基于预测损失差异的 Diebold-Mariano 检验思路, 用于判断模型误差差异是否具有统计含义。考虑到主留出集较小, 本文不机械解释单一 p 值, 而将其作为误差比较的补充依据。评价指标定义如下:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2}, \text{MAE} = \frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j|. \quad (5)$$

$$R^2 = 1 - \frac{\sum_{j=1}^n (y_j - \hat{y}_j)^2}{\sum_{j=1}^n (y_j - \bar{y})^2}, \text{Bias} = \frac{1}{n} \sum_{j=1}^n (\hat{y}_j - y_j). \quad (6)$$

进一步采用滚动起点验证: 依次使用 5 月至 $h-1$ 月训练模型, 并预测 h 月, $h = 8, 9, 10, 11, 12$ 。对

于最优模型留出集 RMSE，采用产品块 Bootstrap，即每次以产品为单位重抽样，使同一产品在 11 月和 12 月的误差共同进入或退出样本。稳健性检验包括改变训练截止月份、对目标变量进行 1%~99%缩尾，以及比较不同模型在高波动类别上的误差分布。

5. 实证结果

5.1. 类别增长结构

描述性统计显示，产品类别之间存在明显增长分化。绿色能源装备平均同比增速为 11.54%，绿色交通装备为 11.37%，数字智能装备为 5.36%，而传统原材料为-1.23%。从分布位置看，绿色能源装备和绿色交通装备的中位数分别为 7.27%和 10.40%，传统原材料的中位数为-0.25%；从下尾风险看，传统原材料负增长观测占比达到 50.0%，明显高于能源化工的 13.3%和绿色交通装备的 7.5%。这说明样本期内的工业产品增长不是整体平移，而是呈现“新兴装备高增长、传统材料承压、能源化工相对平稳”的结构特征。类别统计结果见表 4。

Table 4. Descriptive statistics of YoY growth by different product categories

表 4. 不同产品类别的同比增速描述统计

类别	产品数	观测数	均值	中位数	标准差	P10	P90	负增长占比
绿色能源装备	8	80	11.54	7.27	20.80	-5.51	28.29	20.0%
绿色交通装备	4	40	11.37	10.40	9.78	2.25	20.54	7.5%
数字智能装备	6	60	5.36	3.60	13.47	-9.56	18.53	38.3%
其他工业品	2	20	5.30	2.85	9.27	-3.61	18.41	35.0%
能源化工	9	90	4.47	4.75	3.62	-0.63	9.00	13.3%
传统原材料	7	70	-1.23	-0.25	5.61	-8.75	4.72	50.0%




Figure 1. Mean and volatility of YOY growth by different product categories

图 1. 不同产品类别同比增速均值与波动

从表 4 和图 1 可以看出，类别差异不仅体现在均值高低上，也体现在波动和负增长占比上。绿色能源装备与绿色交通装备平均增速接近，但前者标准差为 20.80，明显高于后者的 9.78，说明绿色能源装备的增长更依赖项目交付、装机节奏和订单批次；传统原材料均值为负且负增长占比最高，反映其在样本期内更多受到需求周期和产能结构调整影响。因此，本节图表不宜只作为数据展示，而应与“高增长伴随高波动、传统品类承压更明显”的分析结论共同呈现。

Table 5. Top ten products by average YoY growth
表 5. 平均同比增速排名前十的产品

产品	类别	均值	标准差	最小值	最大值
发电机组(发电设备)	绿色能源装备	42.12	40.42	8.70	124.20
工业机器人	数字智能装备	26.15	12.18	14.40	51.50
新能源汽车	绿色交通装备	23.51	10.27	8.70	40.60
太阳能发电量	绿色能源装备	16.44	7.30	5.93	28.70
太阳能电池(光伏电池)	绿色能源装备	11.93	16.06	-9.70	33.40
集成电路(亿块)	数字智能装备	11.08	5.25	3.20	17.70
金属切削机床	其他工业品	10.74	10.28	-8.60	23.00
乙烯	能源化工	8.32	3.44	3.00	14.40
汽车	绿色交通装备	8.04	4.82	-2.80	13.70
核能发电量	绿色能源装备	8.01	6.20	1.60	23.00

表 5 进一步表明，平均增速排名前十的产品集中在绿色能源装备、绿色交通装备和数字智能装备三类，其中发电机组、工业机器人和新能源汽车的增长表现尤为突出。发电机组平均增速达到 42.12%，但标准差也达到 40.42，最大值与最小值之间差距较大，说明其增长受项目交付和设备投资节奏影响较强；工业机器人和新能源汽车的均值较高且最小值仍为正，显示其增长连续性相对更好。由此可见，新质生产力相关产品的结构优势需要与波动风险同步解释，后续模型比较也应关注预测误差在不同类别间的差异。

5.2. 动态固定效应与异质性检验

固定效应模型显示，上一期同比增速系数为 0.309，在 1%水平显著。这意味着在控制产品固定差异和月份景气变量后，产品增速仍存在显著短期惯性，即上一月表现较好的产品在下一月仍倾向于保持较高增速。滞后增速差分系数为 0.051，但未达到常规显著水平，说明“增速水平”比“增速变化方向”更能解释短期产量波动。高技术制造业、汽车制造业和电子设备制造业变量不显著，可能源于时间维度较短、月份层面变量高度相关，以及产品自身滞后已经吸收了主要短期变化。具体估计结果见表 6。

Table 6. Estimates of product fixed-effects model
表 6. 产品固定效应模型估计结果

变量	系数	聚类稳健标准误	t 值	p 值
上一期同比增速	0.309***	0.078	3.954	0.000
滞后增速差分	0.051	0.058	0.881	0.378
高技术制造业增速	-0.859	1.456	-0.590	0.555
汽车制造业增速	-0.048	0.226	-0.212	0.832
电子设备制造业增速	0.858	1.533	0.560	0.576

注：表中显著性标记含义为：***表示在 1%显著性水平下显著(p < 0.01)。

类别异质性模型进一步显示，绿色能源装备与一阶滞后项的交互系数为-0.389，并在 5%水平显著。若以基准类别的一阶滞后系数 0.708 作为参照，绿色能源装备的实际滞后惯性约为 0.319，明显低于基准类别。这一结果说明绿色能源装备虽然平均增长较快，但其增长延续性弱于部分传统或稳态产品，可能与项目交付、装机节奏、订单批次和政策节奏等因素有关。对产业监测而言，高增长不等于高可预测性；新兴产品越依赖项目和技术扩散，其短期误差越需要单独诊断。交互项结果见表 7。

Table 7. Heterogeneous moderation of growth inertia by product category
表 7. 产品类别对增长惯性的异质性调节

变量	系数	标准误	t 值	p 值
基准类别一阶滞后	0.708***	0.176	4.026	0.000
其他工业品 × 滞后	−0.051	0.248	−0.205	0.838
数字智能装备 × 滞后	−0.099	0.171	−0.581	0.562
绿色交通装备 × 滞后	−0.041	0.212	−0.195	0.845
绿色能源装备 × 滞后	−0.389**	0.163	−2.379	0.018
能源化工 × 滞后	−0.133	0.259	−0.513	0.608

注：表中显著性标记含义为：***表示在 1%显著性水平下显著($p < 0.01$)，**表示在 5%显著性水平下显著($p < 0.05$)。

5.3. 留出集预测比较

留出集预测结果显示，Elastic Net 取得最优综合表现，RMSE 为 6.567，MAE 为 4.622， R^2 为 0.371；梯度提升和随机森林分别以 6.578 和 6.631 的 RMSE 紧随其后。与 Naive 一阶滞后基准相比，Elastic Net 的 RMSE 下降约 10.6%，MAE 下降约 5.3%，说明加入产品类别、产品虚拟变量和月度外部变量后，模型确实获得了超越简单惯性外推的信息增益。Ridge、动态固定效应 OLS 和 Huber 稳健回归表现弱于 Elastic Net，表明在产品虚拟变量、宏观变量和滞后变量共同进入特征矩阵时，单纯 L2 压缩或稳健损失不足以解决弱特征和共线性问题。模型比较结果见表 8 和图 2。

Table 8. Holdout set predictive performance comparison
表 8. 留出集模型预测性能比较

模型	RMSE	MAE	R^2	Bias
ElasticNetCV	6.567	4.622	0.371	2.165
GradientBoosting	6.578	4.519	0.369	2.448
RandomForest	6.631	4.654	0.359	1.993
Naive_lag1	7.343	4.882	0.214	1.361
RidgeCV	8.067	5.875	0.051	2.244
Dynamic_FE_OLS	8.215	5.981	0.016	2.241
Huber_Robust	8.373	5.989	−0.022	3.357




Figure 2. RMSE comparison of holdout set models, Nov.-Dec. 2025
图 2. 2025 年 11~12 月留出集模型 RMSE 比较

5.4. 滚动验证与不确定性区间

滚动起点验证显示，梯度提升平均 RMSE 为 7.174，略低于 Ridge 的 7.279、动态固定效应 OLS 的

7.384 和 Naive 基准的 7.384。与单次留出不同，滚动验证将训练窗口沿时间向后移动，更接近月度更新场景，也能检验模型在不同月份冲击下的稳定性。梯度提升的 CV RMSE 标准差为 1.642，低于 Naive 基准的 2.057，说明其误差波动相对可控；但其优势幅度并不大，表明短面板条件下不能把非线性模型的局部优势解释为普遍优越。结合留出集结果，本文将 Elastic Net 作为可解释主模型，将梯度提升作为非线性辅助预警模型。滚动验证结果见表 9 和图 3。

Table 9. Rolling-origin cross-validation results
表 9. 滚动起点交叉验证结果

模型	CV RMSE 均值	CV RMSE 标准差	CV MAE 均值	CV R ² 均值
GradientBoosting	7.174	1.642	4.864	0.369
RidgeCV	7.279	1.497	5.078	0.355
Dynamic_FE_OLS	7.384	1.340	5.138	0.335
Naive_lag1	7.384	2.057	5.012	0.323




Figure 3. Mean and standard deviation of RMSE in rolling-origin validation
图 3. 滚动起点验证的 RMSE 均值与标准差

产品块 Bootstrap 结果表明，Elastic Net 留出集 RMSE 的 95%置信区间约为[5.054, 8.019]。该区间并不狭窄，说明短面板月度数据的模型评价存在不可忽略的不确定性，也说明 6.567 这一点估计不能被理解为稳定不变的预测精度。对真实产业监测而言，不确定性披露与点预测同等重要；尤其是当模型用于识别异常产品或高波动类别时，区间信息比单个 RMSE 值更能反映风险边界。区间估计结果见表 10 和图 4。

Table 10. Product-block Bootstrap confidence interval of the best model
表 10. 最优模型产品块 Bootstrap 置信区间

模型	RMSE 2.5%分位数	RMSE 中位数	RMSE 97.5%分位数
ElasticNetCV	5.054	6.512	8.019




Figure 4. Product-block Bootstrap interval for Elastic Net holdout set RMSE
图 4. Elastic Net 留出集 RMSE 的产品块 Bootstrap 区间

5.5. 误差结构与可解释性

类别误差诊断显示，能源化工类别 RMSE 最低，为 2.258；绿色能源装备 RMSE 最高，为 9.025，数字智能装备为 8.504。这与描述性统计中绿色能源装备和数字智能装备高波动的特征一致。进一步按 $RMSE^2 \times$ 观测数计算误差贡献，绿色能源装备约占总平方预测损失的 42.0%，数字智能装备约占 27.9%，二者合计接近七成；能源化工虽然观测数较多，但误差贡献仅约 3.0%。这说明总体 RMSE 主要由高波动新兴装备产品决定，产业监测不能只报告平均增速，还应把误差来源落实到具体类别。类别诊断结果见表 11 和图 5。

Table 11. Category-level diagnostic errors in the holdout set
表 11. 留出集误差的类别诊断

类别	RMSE	MAE	Bias	观测数
能源化工	2.258	1.772	1.097	18
传统原材料	4.753	3.643	3.451	14
其他工业品	6.327	4.864	3.971	4
绿色交通装备	6.763	5.779	4.495	8
数字智能装备	8.504	7.179	3.045	12
绿色能源装备	9.025	6.129	-0.034	16




Figure 5. Category differences in Elastic Net holdout set errors
图 5. Elastic Net 留出集误差的类别差异




Figure 6. Ranking of feature contributions of the interpretable main model
图 6. 可解释主模型的特征贡献排序

特征贡献结果表明，一阶滞后同比增速仍占据主导地位，是否属于新质生产力相关产品、私营企业增速、汽车制造业增速、高技术制造业增速和电子设备制造业增速也保留一定贡献。结合新增月度变量可以看出，外部变量的作用不是替代产品自身惯性，而是解释同一月份内多个产品共同受到的景气冲击。换言之，模型的主要预测信息来自产品自身历史状态，月度工业景气变量则提供背景校正；二者结合后，预测结果既能反映短期惯性，也能识别某些月份由外需、产销衔接或高技术制造业景气变化带来的共同偏离。特征排序见图 6。

5.6. 数据增强后的综合解释

综合表 3、表 8 和表 11 可以看出，数据增强后的模型并不是简单追求更低误差，而是在“产品自身惯性 - 月份共同冲击 - 类别误差来源”之间建立了更清晰的解释链条。增长产品占比反映当月工业增长的扩散广度，产品销售率反映生产与销售衔接程度，出口交货值增速反映外需方向；这些变量与滞后增速共同进入模型后，可以解释为什么同样属于高增长产品，有些月份预测较稳定，有些月份误差却明显放大。

从实证结果看，数据增强并未改变短面板预测的基本事实：一阶滞后仍是最强信号，外部变量主要发挥背景校正和误差分解作用。Elastic Net 相对于 Naive 基准的误差下降表明新增特征具有边际信息，但 Bootstrap 区间和类别误差贡献又提示这种改进存在边界。因而，本文的实证重点不是宣称某一算法绝对最优，而是说明在有限月度样本中，只有把外部景气数据、产品类别差异和误差贡献同时纳入，模型结论才更接近真实产业监测需求。

进一步看，模型误差的类别集中性具有明确的统计含义。绿色能源装备和数字智能装备在留出集中合计只占 38.9% 的观测，但按 $RMSE^2 \times$ 观测数计算却贡献约 69.9% 的平方预测损失；相反，能源化工观测数占 25.0%，误差贡献约 3.0%。这说明总体预测误差并非均匀分布，而是集中在高波动、高技术扩散和项目交付特征更强的产品块上。若只报告总体 RMSE，容易掩盖模型在不同产业环节上的适用边界。

从产品层面看，平均增速排名靠前的产品并不具有相同的预测属性。发电机组平均增速最高，但标准差也最高，属于典型的高均值、高波动产品；工业机器人和新能源汽车在样本期内最小值仍保持正增长，更接近连续扩张型产品；太阳能电池虽然位于前十，但最小值为负，说明其月度波动更容易受到产能释放、出口订单和价格变化的共同影响。上述差异使得同一“新质生产力相关产品”标签下仍需要保留产品层级诊断。

从月份层面看，增长产品占比、产品销售率和出口交货值增速共同提供了对短期误差的背景解释。当增长产品占比下降时，说明工业增长由普遍扩散转向局部支撑，此时依靠上一期增速进行外推更容易高估部分产品；当出口交货值增速转弱时，受外需影响较大的装备和电子产品更可能出现预测偏离；当产品销售率处于高位时，生产端与销售端衔接较好，部分库存型扰动对产量的影响可能相对缓和。

因此，本文实证部分的模型深度主要体现在三个数据层次：一是产品层级的滞后增速和固定差异，二是类别层级的增长分化与误差贡献，三是月份层级的工业景气和外需背景。三类信息共同进入模型后，预测结论不再只是“哪个算法误差最低”，而可以进一步解释误差来自何处、哪些产品更需要预警、哪些月份需要谨慎解释。

6. 稳健性检验与应用讨论

6.1. 不同训练窗口与缩尾目标

稳健性检验首先改变训练截止月份。当训练至 9 月并预测 10 月至 12 月时，梯度提升在原始同比增速目标上的 RMSE 为 7.101，略优于 Naive 基准的 7.170；当训练至 10 月并预测 11 月至 12 月时，梯度提

升 RMSE 为 6.578，也优于 Naive 基准。其次，对目标变量进行 1%~99%缩尾后，梯度提升在两个时间切分中仍保持较优 RMSE，说明模型改进并非完全由少数极端观测驱动。由于 Elastic Net 在主留出集上表现最佳，而梯度提升在滚动和缩尾检验中更稳，本文将二者解释为互补关系：Elastic Net 适合作为可解释主模型，梯度提升适合作为辅助预警模型。不同切分结果见表 12。

Table 12. Robustness tests under different training windows and winsorized targets
表 12. 不同训练窗口与缩尾目标下的稳健性检验

目标变量	模型	RMSE	MAE	R ²	Bias
训练截止月：2025 年 9 月，预测 10 月至 12 月					
缩尾同比增速	GradientBoosting	7.027	5.129	0.366	2.629
缩尾同比增速	Naive_lag1	7.116	5.036	0.350	1.464
缩尾同比增速	RidgeCV	8.476	6.046	0.078	1.118
原始同比增速	GradientBoosting	7.101	5.158	0.366	2.680
原始同比增速	Naive_lag1	7.170	5.084	0.354	1.513
原始同比增速	RidgeCV	8.479	6.077	0.097	1.149
训练截止月：2025 年 10 月，预测 11 月至 12 月					
缩尾同比增速	GradientBoosting	6.613	4.565	0.360	2.629
缩尾同比增速	Naive_lag1	7.330	4.874	0.214	1.353
缩尾同比增速	RidgeCV	8.034	5.843	0.056	2.248
原始同比增速	GradientBoosting	6.578	4.519	0.369	2.448
原始同比增速	Naive_lag1	7.343	4.882	0.214	1.361
原始同比增速	RidgeCV	8.067	5.875	0.051	2.244

6.2. 产业监测应用价值

本文框架可以转化为月度产业监测仪表盘。每当国家统计局发布新的工业产品产量数据后，研究者可自动完成网页数据整理、产品名称规范化、滞后特征更新、月度外部变量合并、模型再估计、留出误差检查和异常偏离清单输出。对于政府部门和行业组织，模型可用于识别新兴产业增长是否由少数高波动产品驱动；对于企业，模型可作为排产、采购、库存和供应链风险预警的辅助信号；对于金融机构和咨询机构，产品层级高频信号可用于构建产业景气监测指标。

更重要的是，本文说明了规范的应用统计研究不应仅依赖复杂算法，而应把数据口径、验证方案、误差结构和可解释性作为同等重要的研究对象。若数据来源和处理规则无法说明，模型再复杂也无法支撑结论；若验证方式泄露未来信息，RMSE 再低也不具备真实外推意义；若不报告类别误差和不确定性，产业监测就容易把高增长误读为稳定趋势。

6.3. 局限与改进方向

本文仍存在局限。第一，样本期仅覆盖 2025 年 3 月至 12 月，时间维度较短，无法充分识别长期季节性、产业周期和政策冲击，因此本文定位为产品层级短期监测研究，而非长期因果识别研究。第二，数据为全国层面公开产品产量，无法刻画地区和企业异质性。第三，产品类别由研究者根据产业属性划分，具有分析意义，但不是国家统计局官方固定分类。第四，宏观解释变量仍较少，价格、出口、投资、库存、利润和上游原材料价格尚未形成完整产业链解释体系。

未来研究可以在数据条件允许的前提下扩展三类工作：其一，整理多年同口径月度产品产量，构造可估计季节效应的长面板；其二，合并价格、利润、出口、投资、库存和上游原材料价格，建立产业链解释变量体系；其三，在较长样本基础上实际估计贝叶斯动态层级模型、状态空间模型或动态因子模型，把共同趋势、类别冲击、产品个体波动和观测噪声分解开来。只有当数据长度和变量体系支持更高模型复杂度时，高阶模型的优势才可能充分体现。

进一步改进建议：目前模型主要引入同期的外部变量。从经济逻辑上看，宏观景气或行业政策对具体产品产量的影响通常存在一定的传导时滞。后续可在特征工程阶段系统引入外部变量的滞后项，如滞后 1~2 个月，并利用 Elastic Net 等模型的特征筛选能力确定较优滞后结构。这种处理既更符合经济直观，有助于缓解同期性问题，也能够更充分刻画宏观冲击向微观产品产量传导的动态过程。

7. 结论与政策建议

本文基于国家统计局 2025 年 3 月至 12 月规模以上工业生产月度公开数据，构造 36 种重点工业产品的产品 - 月份短面板，围绕新质生产力相关产品产量波动开展数据增强预测研究。研究发现：第一，产品增长结构明显分化，绿色能源装备和绿色交通装备平均增速较高，但绿色能源装备波动更强，传统原材料平均增速为负且负增长观测占比较高。第二，产品同比增速存在显著短期惯性，上一期同比增速在固定效应模型中显著，并在预测模型中成为最重要特征。第三，加入月度外部变量后，Elastic Net 在留出集上较 Naive 基准取得更低误差，梯度提升在滚动起点验证和稳健性检验中表现较稳，说明短面板官方统计场景下，正则化模型和受约束非线性模型比无约束线性模型更适合。第四，绿色能源装备和数字智能装备合计贡献了主要平方预测损失，提示新质生产力相关产品监测必须同时报告增长水平、波动程度和预测不确定性。

据此，本文提出三点建议。第一，产业统计分析应更多使用产品层级高频数据，而不只依赖行业总量指标。第二，公开数据建模应把口径清洗、分类依据、外部变量合并和时间顺序验证放在与模型选择同等重要的位置。第三，对新质生产力相关产品的监测应从“单月高增长”转向“增长水平、波动区间、误差来源和异常预警”并重。总体而言，公开统计数据经过规范化处理和适当建模后，能够支持具有现实意义和可更新价值的应用统计研究。

参考文献

- [1] 培育和发展新质生产力 激发高质量发展新动能[EB/OL]. 2024-07-05. https://www.ndrc.gov.cn/wsdwhfz/202407/t20240705_1391512.html, 2026-06-18.
- [2] 2025 年 12 月份规模以上工业增加值增长 5.2% [EB/OL]. 2026-01-19. https://www.stats.gov.cn/sj/zxfb/202601/t20260119_1962329.html, 2026-06-18.
- [3] 中华人民共和国 2025 年国民经济和社会发展统计公报[EB/OL]. 2026-02-28. https://www.stats.gov.cn/zwfwck/sjfb/202602/t20260228_1962662.html, 2026-06-18.
- [4] 2025 年经济发展向新向优预期目标圆满实现[EB/OL]. 2026-01-19. https://www.stats.gov.cn/sj/zxfb/202601/t20260119_1962330.html, 2026-06-18.
- [5] Wooldridge, J.M. (2010) *Econometric Analysis of Cross Section and Panel Data*. 2nd Edition, MIT Press.
- [6] Arellano, M. (2003) *Panel Data Econometrics*. Oxford University Press. <https://doi.org/10.1093/0199245282.001.0001>
- [7] Hoerl, A.E. and Kennard, R.W. (1970) Ridge Regression: Applications to Nonorthogonal Problems. *Technometrics*, **12**, 69-82. <https://doi.org/10.1080/00401706.1970.10488635>
- [8] Tibshirani, R. (1996) Regression Shrinkage and Selection via the Lasso. *Journal of the Royal Statistical Society: Series B*, **58**, 267-288. <https://doi.org/10.1111/j.2517-6161.1996.tb02080.x>
- [9] Zou, H. and Hastie, T. (2005) Regularization and Variable Selection via the Elastic Net. *Journal of the Royal Statistical Society Series B: Statistical Methodology*, **67**, 301-320. <https://doi.org/10.1111/j.1467-9868.2005.00503.x>

-
- [10] Breiman, L. (2001) Random Forests. *Machine Learning*, **45**, 5-32. <https://doi.org/10.1023/a:1010933404324>
 - [11] Friedman, J.H. (2001) Greedy Function Approximation: A Gradient Boosting Machine. *The Annals of Statistics*, **29**, 1189-1232. <https://doi.org/10.1214/aos/1013203451>
 - [12] Hastie, T., Tibshirani, R. and Friedman, J. (2009) The Elements of Statistical Learning. 2nd Edition, Springer. <https://doi.org/10.1007/978-0-387-84858-7>
 - [13] James, G., Witten, D., Hastie, T., *et al.* (2021) An Introduction to Statistical Learning. 2nd Edition, Springer. <https://doi.org/10.32614/CRAN.package.ISLR2>
 - [14] Varian, H.R. (2014) Big Data: New Tricks for Econometrics. *Journal of Economic Perspectives*, **28**, 3-28. <https://doi.org/10.1257/jep.28.2.3>
 - [15] Mullainathan, S. and Spiess, J. (2017) Machine Learning: An Applied Econometric Approach. *Journal of Economic Perspectives*, **31**, 87-106. <https://doi.org/10.1257/jep.31.2.87>
 - [16] Hyndman, R.J. and Athanasopoulos, G. (2021) Forecasting: Principles and Practice. 3rd Edition, OTexts. <https://otexts.com/fpp3/>
 - [17] Bergmeir, C. and Benítez, J.M. (2012) On the Use of Cross-Validation for Time Series Predictor Evaluation. *Information Sciences*, **191**, 192-213. <https://doi.org/10.1016/j.ins.2011.12.028>
 - [18] Diebold, F.X. and Mariano, R.S. (1995) Comparing Predictive Accuracy. *Journal of Business & Economic Statistics*, **13**, 253-263. <https://doi.org/10.1080/07350015.1995.10524599>
 - [19] Molnar, C. (2022) Interpretable Machine Learning. 2nd Edition, Christoph Molnar. <https://christophm.github.io/interpretable-ml-book/>
 - [20] 2025 年 11 月份规模以上工业增加值增长 4.8% [EB/OL]. 2025-12-15. https://www.stats.gov.cn/sj/zxfb/202512/t20251215_1962074.html, 2026-06-18.
 - [21] 国家统计局工业司首席统计师孙晓解读 11 月份工业生产数据[EB/OL]. 2025-12-15. https://www.stats.gov.cn/sj/sjtd/202512/t20251215_1962085.html, 2026-06-18.