

A Comprehensive Perspective on Economic Forecasting: Methods, Construction, and Application

Chenxi Lai

SILC Business School, Shanghai University, Shanghai, 200000, China

Email: laichenxi@shu.edu.cn

Abstract

Economic forecasting, leveraging mathematical and statistical methods, seeks to predict economic trends and deepen scientific insights into development. It primarily employs quantitative methods over qualitative ones. Economic forecasting is pivotal in contemporary society, confronting a myriad of challenges and opportunities that collectively define the intricate nature and imperative of economic predictions. This paper endeavors to furnish a compendium of insights for the practice of economic forecasting by delineating the development and practical applications of exemplary models within the realms of time series models, mixed frequency models, and machine learning models.

Keywords: Economic Forecasting; Time Series Models; Mixed Frequency Models; Machine Learning Models

经济预测的综合视角：方法、构建与应用

赖晨夕

上海大学，上海 200000

摘要：经济预测是运用数学和统计方法分析未来经济趋势的重要学科，旨在提高对经济发展的科学认识。目前，经济预测方法主要分为定性预测和定量预测，实际应用中以定量预测为主。经济预测在现代社会中扮演着至关重要的角色，然而当前经济预测领域面临着一系列挑战和机遇，这些挑战和机遇共同塑造了经济预测的复杂性和必要性。本文将通过概述时间序列模型、混频模型以及机器学习模型中一些典型模型的构建过程以及具体的应用场景，旨在为经济预测实践提供参考。

关键词：经济预测；时间序列模型；混频模型；机器学习模型

引言

经济预测作为一个重要的研究领域，具有广泛的学术价值和实际应用价值。近年来，随着经济形势的复杂化和不确定性增加，经济预测受到了国内外众多研究机构的广泛关注。本文将在接下来的部分中，首先阐述经济预测的定义和主要目标；重点对经济预测研究任务涉及的关键领域进行详细介绍，并分析模型的选择标准与适用场景；最后，展望经济预测技术的发展趋势及其可能带来的创新和挑战。

1 经济预测定义及研究目标

经济预测是预测的一个分支，是指通过收集和分析经济数据与信息，运用科学方法研究经济现象的历史、现状及规律，从而做出对当前经济活动的定性和定量分析，并预测未来的经济走势⁰。

经济预测按时间维度可分为短期（一年内，关注季节性和周期性变化）、中期（一至五年，侧重产业结构和政策变动）和长期（五年以上，分析人口、技术、资源配置）。按范围维度，则分为宏观经济预测

(全国经济总量)、行业预测(特定行业趋势)和地区预测(地方经济发展趋势)。

经济预测的主要目标是通过科学的分析和推断,对未来经济活动的演变规律和趋势进行预测。宏观预测关注国家或地区的经济健康、稳定性、就业、财政政策、货币政策、国际竞争力和居民消费储蓄,而微观预测则侧重企业经营状况、市场地位、投资项目收益风险、内部管理和消费者行为^[2]。

2 经济预测研究任务

经济预测研究任务可以分为几个关键领域:数据收集与处理、模型构建、结果验证。本节将对每个任务进行详细分析和介绍。

2.1 数据收集与处理

在进行经济预测时,数据来源多种多样,涵盖了传统经济指标、金融市场数据、社会统计信息以及现代大数据技术和混频数据等多个领域。宏观经济数据通常由国家统计局或国际组织发布,金融交易所和市场监测机构能够提供关于市场预期和资金流动信息等金融市场数据,社会统计数据通常来源于人口普查局和社会调查机构,这些都官方权威数据收集来源。而随着大数据技术的发展,经济预测还可以广泛利用互联网、社交媒体和传感器等渠道,实时获取大量及时反映市场动态的高频数据,为短期预测提供更精准的信息。

数据进行预处理是为了确保所使用的数据准确、完整且具有可操作性。数据清洗的首要任务是去除重复、错误和缺失的数据,减低分析结果的偏差以及模型的误导。在处理来自不同来源或格式的数据时,需要统一数据的格式和单位,即进行数据转换,可以通过归一化、标准化等方法对数据进行处理。此外,数据清理还包括去除异常值或填补缺失值,以确保数据的一致性和完整性,为后续分析打下坚实的基础。

2.2 模型构建

基于经济预测中不同的应用场景,分别从时间序列模型、混频模型以及机器学习模型来介绍基础模型的构建方式和步骤。

2.2.1 时间序列模型

时间序列模型专门用于分析按时间顺序排列的数据,从而探寻数据随时间变化的规律并进行预测^[3]。时间序列模型具有很强的时间依赖性,考虑了数据点之间的时间顺序和依赖性,即一个时间点的数据可能会影响后续时间点的数据。这些数据中还可能存在一定的趋势、季节性、周期性以及随机性。最基础的时间序列模型是自回归模型(Autoregressive model, AR)(见公式1)和移动平均模型(moving average model, MA)(见公式2)。

$$X_t = c + \sum_{i=1}^p \varphi_i X_{t-i} + \varepsilon_t \quad (1)$$

其中, c 是常数项, φ_i 是自相关系数, ε_t 是随机误差项。

$$X_t = \mu + \varepsilon_t + \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (2)$$

其中, X_t 是时点 t 的观测值, $\varepsilon_t, \varepsilon_{t-1}, \dots, \varepsilon_{t-q}$ 是白噪声误差项, θ_i 是 MA 模型参数。

ARMA 模型巧妙地融合了 AR 和 MA 两种模型,专门用于描述那些既包含自回归特性又包含滑动平均特性的时间序列,它能够精确捕捉时间序列中的线性趋势和随机噪声。而自回归积分滑动平均模型(ARIMA)则是 ARMA 模型的扩展,通过引入差分操作来处理非平稳时间序列,适合于进行长期预测。在 ARIMA 模型的基础上,如果进一步加入季节性差分和季节性项,就可以形成季节性自回归积分滑动平均模型(SARIMA)。长记忆模型(ARFIMA)则是基于 ARIMA 模型的进一步发展,适用于预测具有长期记忆效应的数据^[4]。向量自回归模型(VAR)是 AR 模型的扩展,适用于多变量时间序列的预测,能够捕捉多个经济变量之间的动态相互作用。自回归条件异方差模型(ARCH)和广义自回归条件异方差模型(GARCH)

则是基于自回归模型的变体，专门用于金融市场中波动性的预测。图 1 是总结上述时间序列模型之间的相关转化过程。

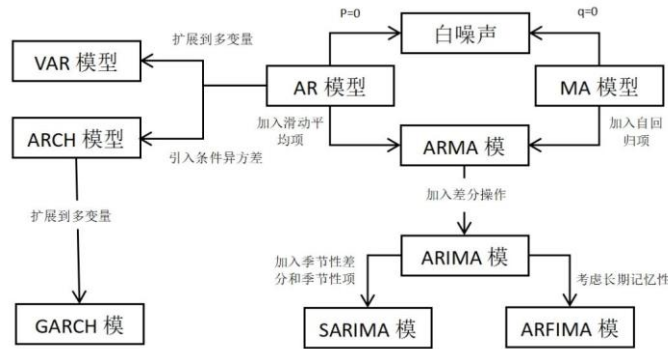


图 1 时间序列模型转换过程

时间序列建模过程通常包括多个关键步骤。首先是数据预处理，接下来判断平稳性，以确定是否需要差分处理。平稳后就可以开始模型结构识别，确定最适合的模型类型，通常选择使得 AIC（赤池信息准则）值最小的参数组合来优化模型。之后进行模型检验，包括检验模型的拟合效果以及残差序列是否为白噪声序列。如果模型通过检验，就可以进行模型预测，使用建立好的模型来预测未来的短期序列值。在实际应用中，根据数据的特征，建模流程会有所不同。对于单变量时间序列，可以选择 ARIMA、ARFIMA 或 SARIMA 模型；对于多变量时间序列，则可以选择 VAR 模型；而对于金融市场中的波动性预测，则可选择 ARCH 或 GARCH 模型。图 2 为时间序列建模提供了一个通用框架，能够适应多种不同的时间序列分析和预测任务。

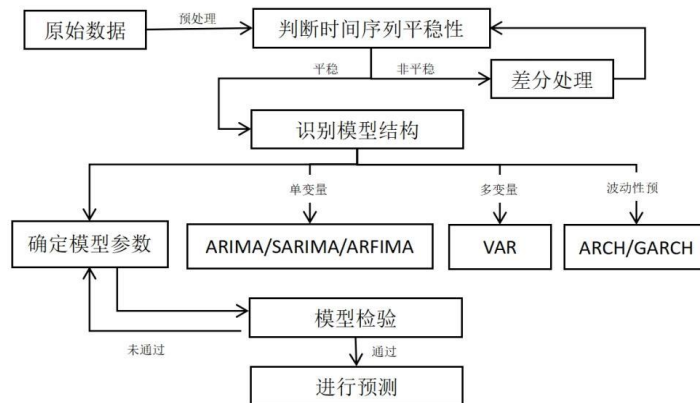


图 2 时间序列模型建模框架

2.2.2 混频模型

混频模型（Mixed Data Sampling Model, MIDAS）是一种用于处理不同频率数据的计量经济学模型，其特点就是结合高频率和低频率的数据，以预测低频率的经济变量。MIDAS 模型主要借助参数控制的滞后权重多项式函数对高频滞后数据进行有权重的加总并构建模型，再通过数值优化和非线性的方法估计混频数据模型中的最优参数^[5]。MIDAS 模型基本形式如公式 3 所示：

$$Y_t = \alpha + \sum_{k=0}^q \beta_k f_k(L) X_{t-k} + \epsilon_t \quad (3)$$

其中， Y_t 是低频的因变量， X_{t-k} 是高频自变量在时间 $t-k$ 时的值， β_k 是回归系数， α 为截距项， ϵ_t 为误差项， $f_k(L)$ 为核函数，用于加权高频数据点，通常形式是一个加权函数。常见的核函数如下：

(1) Almon 函数，如公式 4 所示，其中 λ_i 为待估计参数。

$$f_k(L) = \frac{1-L}{1+\sum_{i=1}^p \lambda_i L^i} \quad (4)$$

(2) Beta 函数，如公式 5 所示，其中 α 和 β 是核函数的参数。

$$f_k(L) = \frac{(1-L)^\alpha}{(1-L^\beta)^\alpha} (\%) \quad (5)$$

(3) 指数函数，如公式 6 所示，其中 λ 是参数，控制加权衰减速率。

$$f_k(L) = e^{-\lambda L} \quad (6)$$

MIDAS 模型的建模流程如图 3 所示，重点是需要定义模型结构并选择合适的核函数（如 Almon、Beta 或指数核函数）与滞后期数，核函数决定了高频数据对低频因变量的加权方式。然后，使用加权最小二乘法（WLS）或最大似然估计（MLE）对模型进行参数估计，确保加权高频数据的合理性。模型完成后，进行残差分析、稳定性检验及拟合优度评价，以确保模型的预测精度与可靠性。最后，通过样本内外预测验证模型的预测能力。

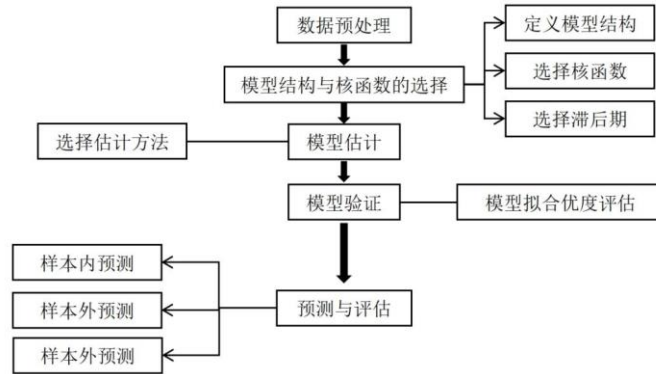


图 3 混频模型建模框架

(1) 半监督学习：

半监督学习结合了监督学习和无监督学习，通常在标注数据稀缺时使用。它用少量标注数据和大量未标注数据来训练模型。常见的半监督学习方法包括标签传播（Label Propagation）等。

(2) 强化学习：

强化学习是一种让计算机通过“试错”来学习如何做决策的方法。就像一个智能体在一个环境中不断尝试不同的行动，每次行动后，它都会得到一个奖励或者惩罚。根据这些反馈，智能体会逐步改进自己的决策，最终找到一种最有效的行动方式，目的是让自己获得最多的奖励。强化学习通过马尔可夫决策过程（MDP）来建模，目标是最大化长期奖励，如公式 8 所示：

$$Q(S_t, a_t) = r_t + \gamma \max_{a_{t+1}} Q(S_{t+1}, a_{t+1}) \quad (8)$$

其中， $Q(S_{t+1}, a_{t+1})$ 是状态-动作函数， r 是在时刻 t 获得的奖励， γ 是折扣因子。

(3) 深度学习：

深度学习是机器学习的一个重要分支，主要通过构建多层神经网络（如卷积神经网络 CNN、循环神经网络 RNN）来自动提取特征并进行模式识别。与传统的机器学习方法不同，深度学习能够通过多层次的结构逐步提炼数据中的关键特征，因此在处理大规模数据集时特别有效。深度神经网络的输出可以表示为公式 9：

$$y = f(W_n f(W_{n-1} \cdots f(W_1 X))) \quad (9)$$

其中， X 是输入， W_1, W_2, \cdots, W_n 是神经网络的权重矩阵， f 是激活函数，可以选择 ReLU、Sigmoid 等。

2.3 结果验证

通过模型的验证，可以量化模型预测的准确性，从而对模型的实际解决问题能力进行评估，因此模型的验证方法也可以作为比较不同模型或算法的工具。以下是常见的模型验证方法：

2.3.1 交叉验证

交叉验证主要用于评估模型的泛化能力，即模型对未知数据的预测能力。它通过将数据集分成多个部分，然后在这些部分上循环地进行训练和验证来实现。这种方法可以减少模型评估的方差，提高模型性能估计的稳定性。常见的交叉验证方法有如下几种：

(1) k-fold 交叉验证：

k-fold 交叉验证表示为公式 10，原理是将数据集 D 分成 k 个互斥的子集 D_1, D_2, \dots, D_k ，每个子集大小为 n/k （假设 n 是数据集的总样本数，且 n 能被 k 整除）。对于每个 i ($i=1, 2, \dots, k$)，使用 D/D_i 作为训练集， D_i 作为测试集，训练模型并计算测试集上的误差，然后取平均值作为最终的交叉验证误差。其中， $Error(D_i)$ 是在第 i 个测试集 D_i 上的误差。

$$CV_{k-fold} = \frac{1}{k} \sum_{i=1}^k Error(D_i) \quad (11)$$

(2) 留一法 (LOOCV)：

留一法的原理是对于每个样本 X_i ($i=1,2,\dots,n$)，将 X_i 作为测试集，其余 $n-1$ 个样本作为训练集，使用 $D/\{X_i\}$ 作为训练集， $\{X_i\}$ 作为测试集，训练模型并计算测试集上的误差，同样取平均值作为最终的交叉验证误差。如公式 11 所示， $Error\{X_i\}$ 是在第 i 个测试集 $\{X_i\}$ 上的误差。

$$CV_{LOOCV} = \frac{1}{n} \sum_{i=1}^n Error(x_i) \quad (12)$$

(3) 留 p-out 交叉验证：

该方法从数据集 D 中随机选择 p 个样本作为测试集，其余 $n-p$ 个样本作为训练集，使用 D/T 作为训练集， T 作为测试集，训练模型并计算测试集上的误差，其中 T 是包含 p 个样本的测试集。重复上述过程多次，每次选择不同的 p 个样本作为测试集，然后计算所有测试集上的误差的平均值，见公式 12。

$$CV_{LPO} = \frac{1}{\binom{n}{p}} \sum_{T \in \binom{D}{p}} Error(T) \quad (13)$$

(4) 分层 k 折交叉验证：

该方法和 k-fold 交叉验证原理大致相同，都是将样本分成 k 份，轮流用其中一份测试，其余训练。与 k-fold 不同的是，分层 k 折保持每份中各类样本比例相同。

2.3.2 误差分析

误差分析主要用于评估模型预测的准确性，通过计算预测值与实际值之间的差异来实现。常用的误差指标包括衡量预测值与实际值之间差异的平方的平均值的均方误差 (MSE) 和衡量预测值与实际值之间差异的绝对值的平均值的平均绝对误差 (MAE)。

2.3.3 灵敏度分析

灵敏度分析用于评估模型对参数变化的敏感程度，即改变模型中的某个参数，观察模型输出的变化情况。在灵敏度分析中，主要采用数值方法、解析方法和统计方法三种技术。

数值方法中，如有限差分法通过函数在相邻点的值之差来近似导数，蒙特卡洛模拟通过随机抽样来估计模型输出对输入参数变化的响应，适用于参数间存在相互作用或难以用解析形式表达的复杂系统。解析方法基于模型的数学表达式，通过计算偏导数或灵敏度方程来评估参数的影响。通常包括参数灵敏度分析和全局灵敏度分析。敏感度分析还可以利用统计模型来评估参数变化对模型输出的影响，识别对输出最为敏感的参数。比如回归分析则评估一个或多个自变量对因变量的影响，通过建立回归模型量化参数对输出的影响，并预测不同参数值下模型的行为。

3 适用场景与模型选择

在经济数据分析与预测中，模型选择对预测准确性、解释性和稳健性至关重要。根据数据特性和预测目标，合理选择模型是提升效果的关键。

经济数据通常具有复杂的动态特征，如季节性波动、长期趋势和周期性变化，因此需要根据数据特征进行模型选择^[7]。时间序列模型（如 ARIMA、VAR）适用于捕捉数据的动态关系和长期趋势。对于不同频率的数据，混频数据模型（如 MIDAS）能更好地整合高频与低频数据，提升预测精度。对于多变量数据，VAR 模型适合处理变量间的相互影响。金融市场预测中，ARCH/GARCH 模型可捕捉波动性，适合市场波动预测。

此外，机器学习与深度学习模型逐渐在经济预测中得到应用。决策树、随机森林和 XGBoost 等模型适合处理非线性关系，而神经网络、LSTM 等深度学习模型则特别适用于复杂的时间序列预测。然而，复杂模型虽然提高了准确性，但可能缺乏透明性和可解释性，选择时需要平衡准确性和可解释性之间的关系。

模型的选择还需考虑数据的质量与可用性。深度学习模型需要大量高质量数据，而传统模型则在数据较少或噪声较大的情况下也能提供较好的预测。因此，合理选择模型时，要综合考虑数据特性、计算资源和过拟合风险。

4 结语

尽管经济预测在现代经济管理中至关重要，但仍面临诸多挑战。经济社会的复杂性和不确定性使得精准预测变得困难，尤其是超预期事件对预测的冲击，也增加了预测难度。此外，经济预测中存在“俄狄浦斯效应”，进一步影响预测准确性^[8]。然而，随着大数据、人工智能和机器学习等技术的进步，经济预测正迎来新机遇。这些技术为处理海量经济数据提供了强大工具，显著提高了预测的准确性和效率。

未来，随着计算能力和技术的快速发展，经济预测将不断创新，推动不同模型的结合应用，并广泛采用基于大数据和人工智能的预测模型，以应对日益复杂的数据环境。同时，跨学科合作，尤其是与心理学和工学的结合，将有助于更好地理解人类行为对经济活动的影响，从而使经济预测变得更加精确和可靠。

参考文献

- [1] 付蓉. 经济管理中常用预测模型的应用及比较分析[J]. 现代营销(学苑版), 2010, (09): 59-60
- [2] 杨明. 预测经济走势的指标与方法: 基于文献综述的视角[J]. 西部金融, 2021, (03): 32-38. DOI: 10.16395/j.cnki.61-1462/f.2021.03.008
- [3] 何晓群. 现代统计分析方法与应用[M]. 中国人民大学出版社, 1998
- [4] 李超楠. 几种山东省 GDP 的预测方法及其比较[D]. 山东大学, 2018
- [5] Clements, M. P., & Galvão, A. B. "Macroeconomic forecasting with mixed-frequency data: Forecasting output growth in the United States." *Journal of Business & Economic Statistics*, 2008, 26(4): 546-554
- [6] 刘涛雄, 尹德才. 大数据在农业经济问题研究中的应用展望[J]. 农业经济问题, 2024, (08): 4-12. DOI: 10.13246/j.cnki.iae.2024.08.005
- [7] 鞠雨宏, 张焕伟. 经济预测方法综述与选择[C]// 吉林省财政科学研究所. 财金观察 (2020 年第 1 辑). 吉林省财政科学研究所; 吉林省股权基金投资有限公司, 2020: 10. DOI: 10.26914/c.cnkihy.2020.014494
- [8] 徐高. 经济预测的意义何在? [J]. 金融博览, 2024, (10): 54-56

【作者简介】



赖晨夕（1998-），女，汉族，硕士，金融计量，上海大学。Email: laichenxi@shu.edu.cn