

跨国经济增长决定因素的模型不确定性问题 ——基于机器学习的新框架*

刘岩[†]

谢天[‡]

武汉大学

上海财经大学

第一版：2019年3月15日

最新版：2019年11月25日

摘要：过去30年间，跨国经济增长实证研究提出了超过100个增长决定因素，而全球200余个国家（地区）的样本限制，意味着在总结跨国增长经验时，必须考虑模型不确定性问题：经济增长主要决定因素及其主要作用是什么？本文提出了一个基于机器学习的新分析框架，从小样本、变量排序、非线性性三个角度，说明具有特定特征的机器学习方法较传统方法可以更有效的处理模型不确定性问题。利用标准的跨国经济增长数据集，本文考察了10种常见机器学习方法的应用表现，并与传统方法进行了比较。结果显示，套袋法与随机森林法及两者的拓展均能够在小样本条件下对经济增长决定因素进行有效排序，灵活捕捉模型的非线性性，让模型不确定性问题化繁为简，得出清晰、稳健的结论。本文意图说明，基于机器学习的分析框架有助于提升跨国增长经验的整体归纳、理解，推动经济增长理论的进一步整合与进步。

关键词：跨国经济增长；机器学习；模型不确定性；变量排序；非线性性

一、引言

解释世界上不同国家与地区经济增长表现的差异，推断一个国家或地区未来的经济增长状况，寻求恰当的经济增长政策，一直以来都是经济学的核心问题。随着上世纪80年代末、90年代初，覆盖全球的跨国经济增长与国民经济核算数据库的建立与完善，经济学家得以对二战后长期发展的各类经济增长理论进行有效的实证检验，并提出进一步的理论改进意见或经济增长政策建议。以跨国回归分析为核心范式的经济增长研究纲领，迄今已经推进了近30年，取得了异常丰硕的研究成果，并且目前仍然是经济增长实证研究的最主要方法^④。

然而，随着跨国实证研究范围与深度的快速增长，学术界也很快意识到这一研究范式实际上存在着诸多不易克服的问题与缺陷，制约了跨国实证研究的进一步发展。在跨国增长回

* 本研究受到国家自然科学基金（项目编号：71661137003、71503191、71701175、91646206）资助。作者匿名审稿人的意见和建议；感谢操玮、李剑、倪禾、欧卫、潘越的点评，以及“机器学习在经济学和管理学中的应用”研讨会（2019，厦门大学）、浙江工商大学国际商学院报告会与会者的讨论。文责自负。

[†] 武汉大学经济发展研究中心、经管学院金融系，助理教授；联系电话：18062100728；电子邮箱：yanliu.ems@whu.edu.cn。

[‡] 通讯作者；上海财经大学商学院世界经济与贸易系，助理教授；联系电话：18659256281；电子邮箱：xietian001@hotmail.com。

^④ 最新的跨国回归分析代表为 Acemoglu et al. (2019) 等人在 JPE 的文章，用跨国面板数据分析民主化对经济增长的促进作用。尽管使用了最新的因果推断技术，但该文的基本模型仍然是跨国线性回归。

归范式中，一国人均实际产出 y_i 为被解释变量，再根据一定的理论引入一系列解释变量 \mathbf{x}_i （黑体表示列向量），建立回归方程

$$y_i = \mathbf{x}_i^T \boldsymbol{\beta} + \epsilon_i. \quad (*)$$

根据样本情况，上述截面回归可拓展为面板回归模型。每个经济增长理论，都对特定的解释变量的系数有一个理论推测，研究者进而通过系数的估计值来检验相应的理论推测。由于跨国增长回归通常呈现为上述约化（reduced form）线性回归的形式，因而此类模型所固有的问题，均会对增长理论的检验产生影响。

在 Brock and Durlauf（2001）的综述中，总结了主流的增长回归实证研究面临的 3 方面突出挑战：

1. 理论开放性——研究者可以任意添加解释变量到增长回归（*）中；
2. 参数异质性——不同国家各异的增长经验，可能难以通过（*）中一组各国同质的参数来解释；
3. 因果性——约化线性回归模型中，解释变量 \mathbf{x}_i 很容易存在与残差项 ϵ_i 的相关性，导致系数估计的内生性问题。

上述挑战 1 的实质，在于跨国样本的有限（全球只有 200 余个国家和地区）与可能选取的解释变量庞大数量这一基本事实。Durlauf et al.（2005）在 *Handbook of Growth Economics* 的综述章节中（p. 608 及 Appendix B），总结了 43 类共计 145 个文献中出现过的作为经济增长决定因素的解释变量^①，而不同的解释变量及其组合，又代表了不同的经济增长理论或者模型。一般而言，具体的跨国增长实证研究都不包括有所文献中考察过的解释变量，而是通过一个人为的先验变量选择过程，聚焦于少数几个解释变量。上述挑战 2 除了传统意义上的解释变量异质性之外，还提示了潜在经济增长决定因素 \mathbf{x} 与经济增长之间可能存在的非线性性^②。大量的实证文献，也反复验证了跨国增长数据样本中存在显著的非线性性与异质性（Durlauf 2009；Cohen-Cole et al. 2012）。对于挑战 3，在传统回归分析范式下，上述小样本与多变量问题（挑战 1）与非线性问题，都很容易导致跨国回归出现内生性问题^③。由于样本有限，每个跨国回归模型中不可能吸纳所有的潜在解释变量^④，但这些变量之间很容易存在相关性，因此每个特定的跨国回归总是可能出现遗漏变量问题，从而产生内生性。类似的，忽略解释变量可能具有的非线性效应，以及解释变量之间的交互效应，也同样会导致约化的线性回归模型出现遗漏变量导致的内生性问题。

Brock and Durlauf（2001）将上述挑战 1 与 2 并称为模型不确定性（model uncertainty）问题，包括变量排序与选取和变量边际作用设定——即函数形式设定——两方面不确定性。

^① Durlauf et al.（2005）将这些变量纳入统计范围的标准为，每个解释变量至少在一篇文献中对经济增长具有统计上显著的作用。

^② Brock and Durlauf 所指的参数异质性，是指一个解释变量对经济增长的边际作用随样本取值不同而发生变化的情形。下文中，我们用解释变量的非线性性来概括这一特征。具体而言，一组解释变量所具有的非线性性，并不局限于其中单个变量与经济增长之间的非线性性——体现在回归方程（*）中，则为该变量的高次项——还包括不同变量之间的任意形式交互作用。单个变量的高次项和多个变量间的交互项，都会令该变量的边际作用随着整组解释变量的取值不同而改变。

^③ 反向因果、缺失变量与测量误差这三个常见的回归模型内生性偏误，都广泛存在于跨国增长的回归分析中；见 Mankiw（1995）和 Durlauf et al.（2009）关于该领域中内生性问题的广泛讨论。

^④ 根据 Sala-i-Martin et al.（2004）的统计，跨国回归分析中解释变量的数量很少超过 20 个，平均而言少于 10 个。

上述讨论表明，模型不确定性是传统的跨国回归分析范式的一个根本性制约因素。过去十余年来，学术界不乏克服这一问题的尝试，最具代表性的是 Bayes 模型平均（Bayesian model averaging, BMA）方法^①。BMA 方法的基本思路，是给定一组潜在的回归变量，将不同变量组合定义为一个模型，然后考虑大量模型回归估计结果的平均。然而，BMA 方法的基础仍然是线性回归模型，因此并不能有效克服非线性性带来的挑战。而对于非线性性，传统研究范式的主要应对方法是借助于非参数（包括半参数）方法^②，但由于估计过程的复杂性，非参数方法又无法有效解决大量潜在解释变量带来的变量选择问题。

如果我们跳出传统线性增长回归模型 (*) 的局限，考虑更一般的生长决定因素模型，则可以从全新的角度来理解上述模型不确定问题，同时也便于我们引入基于机器学习的新框架来突破传统增长回归的研究困境。具体而言，我们可以将经济增长表现 y 与其决定因素之间的关系表示为一个函数^③：

$$y = f(\mathbf{x}; \epsilon). \quad (**)$$

上式中 \mathbf{x} 是一组研究者事前选定并对经济增长具有潜在作用的解释变量。我们将函数 $f(\cdot)$ 称为推测（prediction）函数^④，可以具有任意的形式，代表了研究者所能设想到 \mathbf{x} 对 y 的所有可能作用方式。误差项 ϵ 表示所有研究者未能掌握的其他可能影响因素。与传统跨国回归模型 (*) 相比，(**) 式不要求 \mathbf{x} 包括的变量数小于样本数，同时也允许 \mathbf{x} 对 y 的作用可以呈现任意形式。在传统计量分析框架及特定的样本条件下，我们有可能通过非参数方法来估计 $f(\cdot)$ 。但正如上面讨论已经指出，当样本有限而 \mathbf{x} 又包含很多变量时，传统的非参数估计存在难以克服的技术障碍；此外，非参数模型中变量排序问题带来的模型不确定性如何处理，目前仍是尚待解决的问题（Henderson et al. 2012）。

与传统计量分析框架不同，机器学习将 (**) 式看做是对数据特征进行函数拟合的问题：研究者的目标是从数据信息中，确定推测函数 $f(\cdot)$ 的拟合值 $\hat{f}(\cdot)$ 。机器学习提供了很多新的方法^⑤，可以统一、高效的处理高维度变量排序及非线性拟合问题。在本文中，我们具体考虑了 10 个监督学习算法：LASSO，回归树（regression tree, RT），套袋法（RT with bagging, BG），随机森林法（random forest, RF），神经网络法（neural network, NN），支持向量回归（support vector regression, SVR），弹性网络（elastic net, EN），最小二乘提升法（least square boosting, LSB），以及 M5P 的两个拓展版本（M5P-BG, M5P-RF）。其中，LASSO 与 EN 主要应用于线性回归形式的变量选择问题，而其他方法理论上可以灵活的刻画数据样本存在的非线性特征。RT、BG 与 RF 三种方法都是主流的处理小样本数据集的算法，其中 RT 是后两种方法的基础。与线性回归模型相比，RT 可以解决多变量与非线性性

^① 经典文献包括 Fernandez et al. (2001)，Sala-i-Martin et al. (2004)，以及 Durlauf et al. (2008) 等。

^② 经典文献包括 Liu and Stengos (1999)，Henderson et al. (2012) 等。

^③ 尽管我们将 \mathbf{x} 称为 y 的决定因素（determinants），但我们并非简单认为两者之间存在单向的因果决定关系，而是将 $f(\cdot)$ 看做现实世界中 \mathbf{x} 与 y 之间均衡决定关系的部分或全部。不过这一均衡决定关系未必只对应一个经济增长理论，而可以对应多个理论。

^④ 为了强调与一般时间序列模型中预测（forecasting）的区别，我们专门将 prediction 一词译为推测，以突出其理论、模型推定方面的涵义。经济学中 prediction 一词强调的是对变量间逻辑关系的判断，而 forecasting 仅指对变量未来取值的预先测算而已，并不需要这一测算有理论逻辑基础。

^⑤ 关于机器学习在社会科学中的应用与前景，Varian (2014)、Athey and Imbens (2017)、Mullainathan and Spiess (2017) 提供了全面的综述；中文综述可见陈硕与王宣艺 (2018)、黄乃静与于明哲 (2018)。Mitchell (1997)、Bishop (2006)、Hastie (2009)、Murphy (2012) 等教科书提供了更多的方法介绍。

两个问题，但其自身存在较强的过度拟合倾向。与此不同，BG 和 RF 两个方法，通过更有效的样本间交叉学习，可以有效克服 RT 的过度拟合问题，让拟合函数具有更强的稳健性。NN 的拟合灵活性很高，但在处理小样本预测问题时容易出现线性化过度拟合，从而忽略了样本的非线性特征。SVR 允许拟合函数的非线性性，但灵活性较低，不易充分捕捉数据中的异质性特征。LSB 通过反复使用 RT，可以获得极佳的样本内拟合效果，但缺乏稳健性。而 M5P-BG 与 M5P-RF 均可看做 BG 和 RF 的加强版，在继承后者的稳健性基础上，进一步提升了拟合效能。

为了全面说明机器学习在方法论上的对传统跨国实证分析中模型不确定性困境的突破意义，本文使用 Sala-i-Martin et al. (2004) 构建的一个标准跨国增长数据集，对上述 5 种机器学习方法的实证表现进行了系统对比，并进一步阐述了样本数据存在的非线性性对传统分析方法的制约。该截面数据集包括 88 个国家的 12 类共 67 个经济增长的解释变量^①。通过对比这几种方法在经济增长解释变量选择、增长表现解释效能以及增长现象非线性特征刻画等方面的差异，我们力图说明机器学习方法可以有效克服传统方法在应对模型不确定性方面的困境。通过对多维度的解释变量进行全面、一致的排序，并且灵活、全面捕捉经济增长经验中广泛存在的非线性性，以机器学习方法为基础的新分析框架能够提高我们对经济增长经验机理的整体认识，从中识别出经济增长的主要决定因素与其主要作用特征。

本文的贡献集中在方法论的层面。就我们掌握的研究现状而言，本文是第一篇系统探讨机器学习方法对跨国增长实证研究意义的文献。我们从机器学习——特别是本文重点考虑的套袋法与随机森林法及其拓展——的理论特性出发，系统论述了这一新的方法论对于突破传统跨国增长研究范式所面对的模型不确定性困境的原因与意义。在应用层面，本文也是首篇将常用的机器学习方法系统引入跨国增长实证研究的文献，突出了这些方法在处理多变量与非线性性方面的灵活性与有效性，并与传统方法进行了全方位的对比。从更宽泛的角度而言，本文意图阐述机器学习方法对解决其他社会科学领域存在的模型不确定性问题所具有的普适性意义^②。

需要特别指出的是，本文所提出的机器学习新框架，并不希冀其能够解决传统跨国回归模型中的内生性问题，并获得准确的因果推断。这个框架的主要目的，是致力于在小样本、多变量条件下，通过更全面、灵活的方法处理跨国增长研究中突出的模型不确定性问题，获得解释变量重要性排序及其主要作用特征——包括可能的非线性特征——全面、稳健的结论。我们相信这将为经济增长理论的进一步发展，提供典型事实的基础与参照^③。不过，考虑到因果推断问题的重要性，我们在结论部分的讨论中，就本文研究主题下机器学习与因果推断的关系进行了更进一步的分析与评述。

本文的结构安排如下：第二节中，我们对跨国增长实证研究的方法论进行简要的回顾，并对涉及机器学习的相关文献进行梳理；第三节中，我们对机器学习的一般特征，以及本文所应用的 5 个具体方法，进行较为细致的介绍，特别突出其对于克服模型不确定性问题的原

^① 这一数据集仍然是目前最常用的、包括变量最多的跨国增长数据集之一。

^② 在商业管理领域，参见 Liu and Xie (2019)、Lehrer and Xie (2019) 应用机器学习技术提升电影票房预测的准确性与稳健性。

^③ 通过与经济周期研究的对比，Durlauf (2009) 专门归纳了经济增长理论发展的不足，指出具体理论、模型以致“故事”的过度多样性，造成经济增长理论体系缺乏核心组织逻辑，阻碍了该领域的实质性进步。从实证角度看，正是解释变量的大量提出与全面、统一变量作用评价的缺失，造成了经济增长经验机制典型事实难以建立，从而无法为理论提供有效的实证参照。

理与直观解释；第四节中，我们汇报上述方法在 Sala-i-Martin et al. (2004) 跨国增长数据集上的应用；第五节包括简要的结论，以及本文研究主题下内生性问题的进一步评述与展望。

二、文献综述

跨国经济增长的实证研究，初期以 Solow 模型资本积累机制与经济增长收敛性为核心；接下来在 90 年代蓬勃发展的内生经济增长理论指引下，迅速拓展到教育与人力资本积累方面；在 2000 年前后，延伸到地理、制度、全球一体化等“深层次”决定因素中 (Spolaore and Wacziarg 2013, Johnson and Papageorgiou 2019)。一系列的研究成果，极大的丰富了学术界对经济增长浅层 (proximate) 与深层 (deep) 决定因素的理解。与这一发展脉络相对应，文献中考察过的经济增长解释变量也超过了 100 个，导致跨国样本限制与解释变量多维度之间的张力越发显著。

从方法论方面看，跨国增长实证最初均使用截面回归模型，如 Kormendi and Meguire (1985)、Barro (1991)、Barro and Sala-i-Martin (1992)、Barro and Lee (1994)。其潜在假设是模型设定的解释变量已经可以考虑各国经济增长差异的所有异质性特征，但显然这样的假设是过于严苛的。Islam (1995) 将跨国回归由截面拓展到面板模型，从而可以通过固定效应来捕捉国家层面不随时间改变的异质性因素。与此同时，Durlauf and Johnson (1995) 强调了样本分组的重要性，并具体说明了广泛存在的组间异质性，从而引领一系列后续文献分析跨国增长样本存在的门限效应，包括 Hansen (2000)、Canova (2004)、Masanjala and Papageorgiou (2004)、Kourtellos et al. (2007)、Minier (2007a、b) 及 Tan (2010) 等文章。针对广泛存在的非线性特征，一系列文献使用了非参数 (包括半参数) 方法，如 Liu and Stengos (1999)、Durlauf et al. (2001) 及 Henderson et al. (2012) 等文章。但这类非线性方法并未讨论变量选择问题带来的模型不确定性。

几乎从跨国增长回归研究的兴起之时，研究者对通过线性回归模型所得结果的稳健性就持谨慎态度。Levine and Renelt (1992) 应用极值界限 (extreme bound) 方法，指出当时大部分跨国回归系数均不显著。Sala-i-Martin (1997) 随后开始利用 Bayes 方法评估跨国回归系数的稳健性，并最终形成了以 Fernandez et al. (2001) 与 Sala-i-Martin et al. (2004) 为代表的 Bayes 模型平均法；后续研究还包括 Durlauf et al. (2008)、Ley and Steel (2009、2012)。但 BMA 方法几乎都只在线性回归框架下，讨论变量选择带来的模型不确定性问题，并未涉及非线性特征与变量选择并存的模型不确定性。

已有文献中，将机器学习方法应用到经济增长研究中的工作较少。Varian (2014) 在其述评文章中讨论了应用 LASSO 等方法进行跨国回归变量选择的可能性 (pp. 16-17)。Brock and Durlauf (1995) 使用了 RT 的方法，作为其分样本估计的稳健性说明；Johnson and Takeyama (2001) 利用 RT 方法来说明初始条件对经济增长的影响；Tan (2010) 使用了 RT 方法的一个变种来分析地理、制度等因素对经济增长俱乐部效应的影响。但这些文献均未从机器学习的角度来考察 RT 方法的特征^①，并将其与更一般的模型不确定性问题相联系。此外，这些文献无一例外没有考虑 RT 方法近期在机器学习领域的重要拓展，如 BG 与 RF 及其衍生的方法。

^① 这些文献在使用 RT 方法时，几乎都考虑分段线性回归作为推测函数，从而继承了线性回归模型对解释变量数目的限制，无法在跨国有限样本条件下考虑大量的回归变量。唯一的例外是 Tan (2010)；该文在分段线性预测之外，考虑了分段常数预测，这与机器学习文献中对 RT 的设定类似。但该文并未深入利用这一特点，从而克服多变量问题对传统分析的局限。

三、模型不确定性的机器学习分析框架

1. 机器学习的基本逻辑

从被解释变量 y 是否已知的角度来看，机器学习方法可以被分为监督学习和非监督学习，前者中 y 是已知的，而后者中是未知的。经济学问题的特性决定了我们所研究的被解释变量往往是已知的，因此主要考虑监督学习方法。解释变量的常见类型包括类别型变量和数值型变量两种。针对本文研究的问题，我们仅考虑数值型监督学习方法。

数值型变量的监督学习算法，可视作在给定样本 $\mathcal{X} = \{y_i, \mathbf{x}_i\}_{i=1}^N$ 之下，对被解释变量 y 与解释变量 \mathbf{x} 间的（未知）推测函数关系 $y = f(\mathbf{x}; \boldsymbol{\epsilon})$ ，寻找最优拟合 $\hat{y} = \hat{f}(\mathbf{x})$ 的问题。其中，解释变量 \mathbf{x}_i 包括 K 个分量，可写为 $\mathbf{x}_i = (x_{1i}, \dots, x_{Ki})^\top$ 的分量形式，并且解释变量个数 K 可以接近或超过样本量 N 。不同的机器学习算法使用不同的最优近似标准，对应不同的近似函数 \hat{f} 构造方式。机器学习方法较少受到传统计量方法的模型设定限制，可以灵活捕捉数据本身的特性，处理变量不确定性与数据非线性性等。本文力图说明，机器学习方法的这些特性，正好可以用来处理经济增长的模型不确定性问题。

我们可以将推测函数拟合误差做进一步分解，从而便于系统对比不同机器学习方法的特征。具体而言，依照 Hastie et al. (2009, Ch. 7) 的方法，我们将样本点 \mathbf{x}_i 处的拟合误差做如下分解：

$$\begin{aligned} & \mathbb{E} \left[\left(f(\mathbf{x}_0; \boldsymbol{\epsilon}) - \hat{f}(\mathbf{x}_0) \right)^2 \middle| \mathbf{x} = \mathbf{x}_0 \right] \\ &= \mathbb{E} \left[\left(f(\mathbf{x}_0; \boldsymbol{\epsilon}) - f(\mathbf{x}_0; \mathbf{0}) \right)^2 \middle| \mathbf{x} = \mathbf{x}_0 \right] + \left(\mathbb{E} \hat{f}(\mathbf{x}_0) - f(\mathbf{x}_0; \mathbf{0}) \right)^2 + \mathbb{E} \left(\hat{f}(\mathbf{x}_0) - \mathbb{E} \hat{f}(\mathbf{x}_0) \right)^2 \\ &= \text{Residual error} + \text{Bias}^2 \left(\hat{f}(\mathbf{x}_0) \right) + \text{var} \left(\hat{f}(\mathbf{x}_0) \right) \end{aligned}$$

其中，残差误差是由于不可观测的残差项 $\boldsymbol{\epsilon}$ 引起，属于无法消除的因素；偏差（Bias）代表拟合推测值与样本真实值之间的差距；而方差（var）表示由于样本随机性造成了推测函数拟合值的不确定性。为了减小偏差，一般需要机器学习方法能够灵活捕捉数据的非线性性；而为了缩小方差，则需要机器学习方法具有较强的稳健性，能够适应样本数据集的变动。每个机器学习方法在进行推测函数拟合时，通常面对偏差与方差的权衡取舍问题：如果模型越复杂，通常而言拟合精度更高、偏差更小，但此时往往伴随了推测函数拟合不确定性增加、稳健性较差的问题。此外，小样本条件下，机器学习方法需要较强的变量排序与选择功能，能够从大量解释变量中识别出最有效的变量，进而在控制偏差的同时，有效削减方差。

2. 方法简介

本文考虑了 10 个常见的监督学习算法：LASSO，回归树（RT），套袋法（BG），随机森林（RF），神经网络（NN），支持向量回归（SVR），弹性网络（EN），最小二乘提升（LSB），M5P-BG，以及 M5P-RF。为了行文便利，本文将前 5 种算法划分为常规方法，进行重点分析；将后 5 种算法划分为进阶方法，主要作为常规方法的对比，突出本文结论。除此之外，我们还考虑了 3 种传统计量方法：Bayes 线性回归（Bayes linear regression, BLR），频率模型平均（frequentist model averaging, FMA），逐步回归（stepwise regression, SR）。为节约篇幅、突出主题，我们将这 3 种方法的介绍略去^①。

^① Qiu et al. (2019) 对相关方法做了详细的介绍。

2.1. 常规方法

A. LASSO

LASSO 方法与传统的线性回归模型最为接近，其近似推测函数同样是解释变量的线性函数 $\hat{y} = \mathbf{x}^\top \hat{\boldsymbol{\beta}}$ 。不同之处在于，传统线性回归确定回归系数 $\hat{\boldsymbol{\beta}}$ 是直接通过最小化残差平方和 $\min \sum_i (y_i - \mathbf{x}_i^\top \boldsymbol{\beta})^2$ 来实现；而 LASSO 方法在上述目标函数上，又增加了系数的绝对值之和（ L^1 范数）：

$$\min_{\boldsymbol{\beta}} \sum_{i=1, \dots, N} (y_i - \mathbf{x}_i^\top \boldsymbol{\beta})^2 + \lambda (|\beta_1| + \dots + |\beta_K|),$$

其中 K 为解释变量的数目， $\lambda > 0$ 为权重系数^①。LASSO 的最大特征在于目标函数中 $\boldsymbol{\beta}$ 的 L^1 范数会迫使重要性较低的变量系数取值为 0。因此，当备选解释变量较多时，LASSO 可以通过便捷的变量选择功能，减小拟合值的方差，提高推测函数的稳健性。但由于 LASSO 产生的近似方程仍然是解释变量的线性形式，因此当数据样本可能存在显著的非线性特征时，LASSO 的预测表现会受到很大限制。

B. 回归树

Breiman et al. (1984) 首先提出了分类和回归树 (Classification and Regression Tree, CART) 的概念，其中分类树主要适用于类别型变量问题，故不属于本文考虑的范围。回归树递归地将数据划分为不同的子样本，并将每个子样本下 y_i 的平均值作为最终推测值。在回归树中，结点 τ 包含 n_τ 个观测值。每个结点能进一步分为两个结点 τ_L 和 τ_R ，分别包含 n_L 和 n_R 个观测值。我们将结点内的 y_i 离差平方和定义为

$$\text{SSR}(\tau) = \sum_{i=1}^{n_\tau} (y_i - \bar{y}_\tau)^2,$$

其中 \bar{y}_τ 为平均值。在将结点 τ 的 n_τ 个样本拆分为 τ_L 和 τ_R 两部分时，拆分点的选择遵循最大化离差平方和（SSR）缩减值的原则^②：

$$\Delta = \text{SSR}(\tau) - \text{SSR}(\tau_L) - \text{SSR}(\tau_R), \quad (1)$$

结点 τ_L 或者 τ_R 可以视为新的结点并继续拆分过程。我们从树的顶部开始（完整样本）并将相同的方法应用于所有后续结点，直到触发预先设置好的结点拆分停止规则。拆分过程终止时的结点称为叶子结点。每个叶子结点 ℓ 都对应了一组子样本 \mathcal{X}_ℓ ，两两不相交且并集为全样本 \mathcal{X} 。最终的推测拟合值为变量 \mathbf{x} 所属子样本 \mathcal{X}_ℓ 中 y 的均值 \bar{y}_ℓ 。

Hastie et al. (2009) 提供的证据表明，回归树的推测值具有较低的偏差但是方差往往较大，原因在于回归树的不稳定性，即观测数据中的较小的变化可能导致差异很大的分割序列，并因此导致迥然不同推测值。文献中广泛使用了两种方法纠正这个问题：套袋回归树法和随机森林法。

^① 通过将样本随机划分为学习组与校验组并，进行多次交叉校验（cross validation），可以得到 LASSO 惩罚项系数的最优值 λ^* 。下文中所分析的 LASSO 推测函数，就是基于 λ^* 得到的。

^② 具体而言，拆分点的选择是按照如下步骤。首先，对每一个变量 x_k ，将结点 τ 所包括的样本取值 $\mathcal{X}(\tau, k) \equiv \{x_{ki}\}_{i \in \tau}$ 从小到大排序，然后依次考虑一系列样本分组 $\tau_S^j(k), \tau_B^j(k), j = 1, \dots, |\tau|$ ，其中 $\tau_S^j(k)$ 为 $\mathcal{X}(\tau, k)$ 中前 j 小取值 x_{ki} 所对应的指标集合， $\tau_B^j(k) = \tau \setminus \tau_S^j(k)$ 。其次，对所有分组，计算 $\Delta^j(\tau, k) = \text{SSR}(\tau) - \text{SSR}(\tau_S^j(k)) - \text{SSR}(\tau_B^j(k))$ 。最后，找到实现 $\max_{j,k} \Delta^j(\tau, k)$ 的分组 $\tau_S^{j^*}(k^*), \tau_B^{j^*}(k^*)$ ，进而将前者记为 τ_L ，后者记为 τ_R ，相应的 $\mathcal{X}(\tau, k^*)$ 中第 j 小的取值，记为该结点的拆分点。

C. 套袋法

Breiman (1996) 提出的用 Bootstrap 聚合 (Bootstrap aggregation, 简称为 BG) 方法, 通过构造随机生成的训练集来达到改进 RT 拟合值稳健性的目的。给定一个原始数据集 $\{y_i, \mathbf{x}_i\}$, 套袋法首先生成 B 个新的训练数据集 $\{y_i^b, \mathbf{x}_i^b\}$, $b = 1, \dots, B$, 其中每一组新训练集都包含有 N 个样本, 且每一个样本都是原始数据的“有放回”采样。因此某些观测值会有重复, 大样本下的 $\{y_i^b, \mathbf{x}_i^b\}$ 预计会有 $(1 - 1/e) \approx 63.2\%$ 的独特样本。我们将回归树法应用到每个训练数据集, 并构建一个 (不剪枝) 回归树。在套袋法中, 我们首先使用每棵回归树计算出一个推测值, 最终推测值是所有 B 个推测值的简单平均值。套袋法一方面继承了回归树的非线性特征, 能够保证较小的拟合偏差, 同时又通过 Bootstrap 缩减了拟合值的方差, 提高了推测函数的拟合稳健性。

D. 随机森林法

套袋法一个潜在的弱点在于, 生成每棵树的模拟样本都有相同的分布, 这容易导致各树之间的相关性较高, 从而削弱了 Bootstrap 方法降低拟合值方差的作用。针对这一问题, Breiman (2001) 进一步提出了随机森林法。随机森林法类似于套袋法, 两者都依靠对原始数据使用 Bootstrap 方法, 进而构建 B 个随机训练集。但随机森林法中, 在构建每棵树的每一个结点拆分时, 我们从 K 个解释变量中随机抽取 q 个 (不放回采样), 其中 q 的默认值为 $K/3$, 并仅在这 q 个变量中寻找拆分点。最终的推测值仍然是每棵树推测值的简单平均值, 不过由于每棵树构造过程中的随机性, B 棵树之间的相关性就得到了控制, 从而可能进一步增强推测函数拟合值的稳健性。

E. 神经网络法

神经网络法包括异常多的变种, 也是近年来流行的人工智能深度学习 (deep learning) 方法的基础。由于本文需要处理的推测问题较为简单, 因此我们仅考虑最基本的单层神经网络方法, 以及通用的转换函数设定。其工作流程如下: 首先, 根据确定好的中间神经元层结点数目 L , 将输入的 K 个解释变量组合为 L 个不同的线性组合 $\theta_\ell^\top \mathbf{x}$, $\ell = 1, \dots, L$; 接下来通过 sigmoid 函数将这些线性组合变量转换为中间变量 $z_\ell = \sigma(\theta_\ell^\top \mathbf{x})$ ^①; 最后, 再由 z_ℓ 的线性组合得到最终的推测值 $y = \phi^\top \mathbf{z}$ 。算法会根据样本 $\{y_i, \mathbf{x}_i\}$ 自动学习并确定相关参数, 从而得到推测函数。在后续分析中, 我们将 L 设为 10。

得益于以中间层神经元为数据转换中介, 神经网络法在构造推测函数上具有极大的灵活性; 并可以通过增加神经元层级数, 使其具有网络结构进而实现前后神经元之间的反馈特征, 进一步增强其推测适应能力。但在小样本之下, 这一算法特征也容易造成神经网络的过度拟合问题, 降低其推测稳健性^②。此外, 由于神经元结点同时考虑所有解释变量的作用, 神经网络方法本身不具有一个自然的变量选取结构。

2.2. 进阶方法

A. 支持向量回归

支持向量回归方法 (SVR) 将拟合函数设定为如下形式:

^① 其具体函数形式为 $\sigma(v) = 1/(1 + e^{-v})$ 。

^② 当样本量足够大且数据本身具有明确的空间或时间相关性时, 神经元起到的作用是提取原始数据在局部区域的总体特征, 如图像识别中神经元起到了局部抽象概括作用, 语音识别中起到词组识别的作用。

$$y_i = f(x_i) + e_i = \beta_0 + \sum_{m=1}^M \beta_m h_m(x_i) + e_i,$$

其中 $h_m(\cdot)$ 为一组基函数，由选定的核函数生成。系数向量 $\boldsymbol{\beta}$ 通过最小化如下拟合目标函数而得到：

$$H(\boldsymbol{\beta}) = \sum_{i=1}^N V_\epsilon(y_i - f(x_i)) + \frac{\lambda}{2} \|\boldsymbol{\beta}\|^2,$$

其中 $V_\epsilon(\cdot)$ 为 ϵ -不敏感误差度量；当 $|r| < \epsilon$ 时 $V_\epsilon(r) = 0$ ，当 $|r| \geq \epsilon$ 时 $V_\epsilon(r) = |r| - \epsilon$ 。我们对比了常用的核函数，最终选择了表现效果最好的 Gauss 核函数。

B. 弹性网络法

弹性网络法（EN）可以看做 LASSO 与岭回归（ridge regression）的结合，其预测函数仍然为线性形式 $\hat{y}_i = \mathbf{x}_i^\top \hat{\boldsymbol{\beta}}$ ，但系数的确定是通过最小化如下目标函数：

$$\min_{\boldsymbol{\beta}} \sum_i (y_i - \mathbf{x}_i^\top \boldsymbol{\beta})^2 + \lambda \left(\alpha \sum_k |\beta_k| + \frac{1-\alpha}{2} \sum_k \beta_k^2 \right),$$

即在 LASSO 的 L^1 惩罚项外增加了 L^2 惩罚项。考虑到对比的简明性，我们在后续分析中仅考虑 $\alpha = 0.5$ 这一基本设定。

C. 最小二乘提升法

最小二乘提升法（LSB）以 RT 为基础，通过迭代计算，对样本局部特征不断进行 RT 拟合。每一步迭代中，上一步拟合过程的残差项都自动获得更高的权重，因此进一步拟合过程中会更加偏向对应的样本变量，不断提高整体的拟合精度。最终输出的推测值是多次迭代拟合结果的平均值。尽管形式类似，但这与 BG 或 RF 中通过 Bootstrap 得到多次推测值求平均的方法有本质差异；LSB 的计算过程中，样本集都是固定不变的，其多次推测值来自迭代拟合，因此本质上是对固定样本特征的不断逼近，而这也导致 LSB 容易出现过度拟合问题^①。

D. M5P-BG 与 M5P-RF

M5P 是由 Wang and Witten（1997）在 Quinlan（1992）的 M5 算法基础上改进得到的，均可视作 RT 方法的拓展。M5P 与 RT 有两方面差异。第一，M5P 在进行样本切割时，目标不是 RT 之下的最小化两分支的残差平方和，而是最小化经过结点（子）样本量调整的样本标准差之和，即在每个结点拆分时，最大化下列目标函数

$$\max_{\tau_L, \tau_R} \sqrt{\text{var}(\tau)} - \frac{|\tau_L|}{|\tau|} \sqrt{\text{var}(\tau_L)} - \frac{|\tau_R|}{|\tau|} \sqrt{\text{var}(\tau_R)},$$

其中 $|\tau|$ 表示该结点之下子样本的样本量。第二，当 M5P 回归树生成以后，每个最终结点（子样本）处的推测值不再简单地定义为该子样本下 y_i 的均值，而是由该子样本下的 y_i 与 \mathbf{x}_i 的线性回归方程拟合得到。显然，对比 RT，M5P 的这一特征将提升算法的拟合精度。M5P-BG 和 M5P-RF 分别是基础的 M5P 算法与套代法和随机森林法下的结合。通过 Bootstrap 自助抽样，拟合函数的稳健性将得到大幅的提升。

^① 关于 LSB 以及更一般的提升法（Boosting）的详尽讨论，见 Hastie et al.（2009）及 Murphy（2012）。

2.3. 解释变量的排序与筛选

LASSO 方法在进行变量排序时，通常采用以下标准（如 Varian 2014）：随着权重系数 λ 的增大，LASSO 在计算系数向量 β 的取值时，会将越来越多的分量设为 0。在这一过程中，我们将系数最先达到 0 的变量，认定为最不重要，而系数越晚变为 0 的变量，其重要性越高。弹性网络方法下的变量排序 LASSO 一致。

对于回归树、套袋法、随机森林以及 M5P-BG、M5P-RF 五个方法，由于其推测函数的构建均是基于决策树，因此各分支结点对应的解释变量自然的具有一个重要性排序，越重要的变量，越靠近树的根部。由于一棵决策树中，同一个变量可能出现在多个结点，以及套袋法和随机森林法中同一个变量在各（随机）样本下所生成决策树中对应的位置可能不同，因此我们仍然需要一个量化的指标来衡量各变量的重要性。

对于回归树，我们计算每一个变量在所有拆分结点上对应的 Δ 值（式 1）的总和并除以结点的数量，以此来衡量变量的重要性（Breiman et al. 1984）。更高的值意味着所对应的预测因子更加重要。由于最小二乘提升法在每次迭代时，都是使用 RT 进行拟合，因此该方法下的变量排序方法就是 RT 下排序方法的自然扩展。

对于套袋法和随机森林法，每棵树都由各自随机抽取的样本生成，并且每一个自助法样本中都会有部分观测数据被排除。这部分被排除的样本（Out-of-Bag, OOB）可用于对回归树进行评估，并且由于没有参加树的构造，不存在过度拟合的风险。在此基础上，我们通过如下方法进行变量排序（Breiman 1996、2001）：首先计算第 b 棵树产生的推测函数在其 OOB 样本中的预测误差；第二，对所关心的变量 x_k ，在 OOB 样本中随机置换该变量观测值的顺序，并根据新生成的样本计算出新的预测误差；最后，比较两次预测误差的差值，定义为 Δ_k^b 。对于每一个变量 $k = 1, \dots, K$ ，我们计算出所有树 $b = 1, \dots, B$ 的平均值 $\bar{\Delta}_k$ ，并以 $\bar{\Delta}_k$ 的由大到小的排列顺序决定 K 个变量的重要性。如果解释变量 k 更加重要，那么通过置换其观测值顺序，这个解释变量会因失去正确的样本对应关系（特别是 x_{ki} 与 y_i 之间的对应关系），导致拟合精度更大的下降，即更高的 $\bar{\Delta}_k$ 。作为套袋法与随机森林法的拓展，M5P-BG 和 M5P-RF 的变量选择方法与上述方法一致。

神经网络法并不具有一个自然的变量选择结构，所有解释变量通过中间层神经元都进入到最终预测目标中。因此，该方法下的变量选择标准具有一定的任意性。注意到我们考虑的单层神经网络方法中，解释变量到各个神经元需经过一次线性组合（忽略转换函数 σ ），而从各个神经元到最终推测值，又需要经过一次线性组合，因此一个简便的变量重要性测度方法，就是将一个变量在两次线性变换中所涉及的系数（标准化后）相乘并求和。具体而言，我们使用如下公式计算一个变量的重要性： $w_k = \sum_{\ell=1, \dots, L} \omega_{k\ell} \cdot \varpi_{\ell}$ ，其中 $\varpi_{\ell} = |\phi_{\ell}| / \sum_m |\phi_m|$ 为 ϕ 中各系数标准化得到，而 $\omega_{k\ell} = |\theta_{k\ell}| / \sum_m |\theta_{m\ell}|$ 为 θ_{ℓ} 中各系数标准化得到。

与神经网络类似，支持向量回归也不具有自然的变量选择结构。我们仿照 Wang and Witten（1997）的思路衡量每个变量对于推测函数的重要性。具体方法如下：通过 Bootstrap 构造自助抽样样本，在每组样本中打乱除去变量 x_k 之外的其他变量顺序，并用已得到的拟合函数计算该样本下的 R^2 ；这一 R^2 与未打乱顺序样本的 R^2 的差距，就体现了该组样本下变量 x_k 的重要性。最后，将自助抽样得到的各组样本下变量 x_k 对应的 R^2 差距取平均，即可衡量该变量的重要性。

值得强调的是，LASSO、回归树、套袋法与随机森林及其衍生算法（EN, LSB, M5P-BG 与 M5P-RF）的变量排序具有全局一致性：即便将一部分解释变量剔除计算过程，每个

方法对剩下变量的排序，仍然与使用所有解释变量进行计算所得排序结果保持一致^①。神经网络与支持向量回归在变量排序方面并不具有这个特性，原因在于其拟合过程不具有递归结构，所有变量同时参与推测函数全体参数的计算。这一问题对 Bayes 回归、频率主义模型平均和逐步回归同样适用。

在小样本之下，推测函数拟合方法的变量排序与筛选功能有额外意义。变量多样本少，模型自由度高，很容易出现过度拟合问题。此时，如果能够在拟合过程中识别出少数关键变量，并将拟合信息集中在这些变量之上，则有助于削减推测函数拟合值的方差，实现更稳健的拟合效果。

2.4. 方法小结

以回归树为基础的套袋法与随机森林，其算法特征最符合处理模型不确定性问题的内在需求，既能灵活捕捉样本的非线性性从而减少偏差，又通过 Bootstrap 减少推测函数拟合值的方差；相应的，M5P-BG 和 M5P-RF 分别是套袋法与随机森林法的拓展，并进一步提高了拟合精度。同时，这一类算法均具有自然的变量排序功能。最小二乘提升是回归树的直接拓展，但容易出现拟合值方差较大的问题。LASSO 及 EN 具有很好的变量排序与选择功能，但仅考虑线性模型。神经网络方法理论上具有很好的推测函数拟合灵活性，但缺少变量排序性质。SVR 方法可以处理非线性性，但拟合灵活性相对较低。

3. 推测函数关键特征的度量

推测函数的拟合值 \hat{f} 通常是一个高维度的非线性函数，为了尽可能直观、全面的理解该推测函数的特性，我们需要采取一定的方法，对各个解释变量在 \hat{f} 所起作用进行一个分解、测算。这一分解有 3 方面目标：i. 测算单个变量的样本内解释效力；ii. 测算多个变量组合的联合解释效力；iii. 分解推测函数的线性趋势与非线性性。由于这部分内容技术性较强，我们在正文中直接给出相关公式，将更详细的推导与讨论放到附录 A 中展开说明。

对单个变量解释效力的测算，我们采取一个“减法”思维，从样本推测值 $\hat{f}(\mathbf{x}_i)$ 中减去变量 x_{ki} 的作用，再求和度量总的解释效能损失程度，从而获得单变量 x_k 的解释效力。我们使用如下公式测算单变量解释力度的水平值（average explained prediction variation）：

$$AEPV(\hat{f}; k) = \frac{1}{N} \sum_{i=1}^N \left(\hat{f}(\mathbf{x}_i) - \frac{1}{N} \sum_{j=1}^N \hat{f}(x_{1i}, \dots, x_{k-1,i}, x_{kj}, x_{k+1,i}, \dots, x_{ki}) \right)^2. \quad (1)$$

其中 $\frac{1}{N} \sum_{j=1}^N \hat{f}(x_{1i}, \dots, x_{k-1,i}, x_{kj}, x_{k+1,i}, \dots)$ 剔除了变量 x_k 在样本点 i 处对推测值 $\hat{f}(\mathbf{x}_i)$ 的贡献，故两者之差反映了 x_k 在该点样本值对预测的贡献。进一步定义所有变量联合的解释力度（average prediction variation）：

$$APV(\hat{f}) = \frac{1}{N} \sum_{i=1}^N \left(\hat{f}(\mathbf{x}_i) - \frac{1}{N} \sum_{j=1}^N \hat{f}(\mathbf{x}_j) \right)^2, \quad (2)$$

则可计算单个变量的百分比解释力度（fraction of EPV）：

^① 这几个算法进行拟合时，每一步都会优先识别出对样本特征推测能力最强或者最弱的变量，并在下一步计算中保留或者去除这个变量，计算过程具有递归结构，因此对变量的排序具有全局性质。

$$FEPV(\hat{f}; k) = \frac{AEPV(\hat{f}; k)}{APV(\hat{f})}. \quad (3)$$

类似的，我们还可以定义两个变量的联合解释力度：

$$AEPV(\hat{f}; k, m) = \frac{1}{N} \sum_{i=1}^N \left(\hat{f}(x_i) - \frac{1}{N} \sum_{j=1}^N \hat{f}(\dots, x_{kj}, \dots, x_{mj}, \dots) \right)^2, \quad (4)$$

并减去 x_k, x_m 两个变量各自的单独解释力度，得到其交互作用解释力度 (interactive EPV)：

$$IEPV(\hat{f}; k, m) = AEPV(\hat{f}; k, m) - AEPV(\hat{f}; k) - AEPV(\hat{f}; m), \quad (5)$$

并计算交互作用的百分比解释力度：

$$FIEPV(\hat{f}, k) = \frac{IEPV(\hat{f}; k, m)}{APV(\hat{f})}. \quad (6)$$

最后，我们将 $\Delta \hat{y}_{[k]i} \equiv \hat{f}(x_i) - \frac{1}{N} \sum_j \hat{f}(\dots, x_{kj}, \dots)$ 视作变量样本值 x_{ki} 对推测值 $\hat{y}_i = \hat{f}(x_i)$ 的贡献，并通过下述辅助回归

$$\Delta \hat{y}_{[k]i} = \alpha + \beta_k x_{ki} + \xi_i, \quad i = 1, \dots, N, \quad (7)$$

来刻画变量 x_k 对推测值的贡献中，线性趋势项与非线性项各自的贡献。上述回归的 R^2 捕捉了线性趋势的解释贡献，对应的 $1 - R^2$ 则测算了变量非线性特征的贡献。

四、实证分析

为了具体说明机器学习方法在经济增长跨国实证分析中的优势，我们使用跨国增长研究领域的标准数据，系统对比上述 10 种广泛使用的数值型监督学习算法及传统分析方法的实证表现，以此说明机器学习方法可以有效突破传统方法范式所面对的困境。具体而言，我们详细讨论 5 种常规方法的实证表现，将 5 种进阶方法的实证表现作为对比，以此简化实证分析并突出研究重点。

1. 数据样本

我们的数据样本是 Sala-i-Martin et al. (2004) AER 文章所采用的样本^①，包括 88 个国家的人均实际 GDP 增速（被解释变量）与 67 个潜在解释变量^②。这一数据集也是后续 BMA 方法文献所使用的标准数据集，如 Ley and Steel (2009) 等。表 1 包括了所有变量的代码及释义，详细说明及来源请见 Sala-i-Martin et al. (2004)。注意，表中第一个变量 GR6096 是被解释变量。

表 1：样本变量

变量代码	释义	分组	变量代码	释义	分组
GR6096	1960-96 年人均 GDP 增速	Na	LIFE060	1960 年预期寿命	2
ABSLATIT	纬度绝对值	4	LT100CR	通航水域土地占比	7
AIRDIST	距大城市的空中距离	7	MALFAL66	60 年代疟疾虚拟变量	4

^① AER 官网页面：<http://www.aeaweb.org/articles?id=10.1257/0002828042002570>。

^② Sala-i-Martin et al. (2004) 详细解释了选择这 67 个变量作为潜在解释变量的原因。除去最大化样本范围之外，另一个变量选择标准是尽可能选择“状态变量”，即那些仅反映 1960 年代经济状况而不受后来经济增长影响的变量，这样可以确保样本尽量不受反向因果偏误的影响；不过仍有少部分变量不满足这标准，如 PI6090，即 1960-1990 年均通胀率。

<u>AVELF</u>	民族语言分化	Na	<u>MINING</u>	采矿业的 GDP 比例	11
BRIT	英国殖民地虚拟变量	10	<u>MUSLIM00</u>	穆斯林比例	6
<u>BUDDHA</u>	佛教徒比例	6	NEWSTATE	独立时间	10
CATH00	天主教徒比例	6	OIL	石油生产国虚拟变量	11
CIV72	公民自由	8	OPENDEC1	1965-74 开放度	3
COLONY	殖民地虚拟变量	10	ORTH00	东正教比例	6
CONFUC	儒教比例	6	OTHFRAC	外语人口比例	na
DENS60	人口密度 1960	7	P60	1960 小学教育	1
DENS65C	60 年代沿海人口密度	7	PI6090	1960-90 通胀率	3
DENS65I	60 年代内陆人口密度	7	SQPI6090	1960-90 通胀率平方	3
DPOP6090	1960-90 人口增长率	1	PRIGHTS	政治权利	8
EAST	东亚虚拟变量	5	POP1560	15 岁以下人口比例	2
ECORG	资本主义	8	POP60	1960 年人口	7
ENGFRAC	英语人口	na	POP6560	65 岁以上人口比例	2
EUROPE	欧洲虚拟变量	5	PRIEXP70	1970 年初级产品出口	11
FERTLDC1	60 年代的生育率	2	PROT00	新教徒比例	6
GDE1	国防开支	3	RERD	实际汇率扭曲	3
GDPCH60L	60 年人均 GDP (log)	1	REVCOU	革命和政变	9
GEEREC1	60 年代公共教育支出占比	1	SAFRICA	非洲虚拟变量	5
GGCFD3	公共投资份额	3	SCOUT	经济外向性	3
GOVNOM1	60 年代政府名义支出占比	3	SIZE60	经济规模	7
GOVSH61	60 年代政府实际支出占比	3	SOCIALIST	社会主义虚拟变量	8
<u>GVR61</u>	60 年代政府消费占比	3	<u>SPAIN</u>	西班牙殖民地虚拟变量	10
H60	1960 高等教育水平	1	TOT1DEC1	60 年代的贸易增长	12
HERF00	信教程度	6	TOTIND	贸易条件排名	12
HINDU00	印度教徒比例	6	TROPICAR	热带地区面积占比	4
IPRICE1	投资品价格	3	TROPPOP	热带地区人口占比	4
<u>LAAM</u>	拉丁美洲虚拟变量	5	WARTIME	1960-90 战争花费比例	9
LANDAREA	土地面积	7	WARTORN	1960-90 战争虚拟变量	9
LANDLOCK	内陆国家虚拟变量	7	<u>YRSOPEN</u>	1950-94 年开放年数	3
LHPCP	油气储量 1993	11	ZTROPICS	热带气候虚拟变量	4

注：数据来源为 Sala-i-Martin et al. (2004)；分组代码见表 2，部分变量无分组，记为 na；加粗变量为 Sala-i-Martin et al. 识别出的前十显著变量，加下划线变量表示非前十但显著的变量

同时，为了能够更充分的讨论后续的实证结果及其经济意义，我们借鉴 Ciccone and Jarocinski (2010) 的分类方法，将上述 67 个解释变量，依据其理论归属，分为 12 组。具体分组及编号见表 2^①。

表 2：变量分组及编号

编号	分组名称	编号	分组名称	编号	分组名称
1	新古典增长理论	5	地区异质性	9	战争及冲突
2	人口结构	6	宗教	10	殖民地历史
3	宏观政策	7	区位及贸易	11	自然资源
4	自然地理特征	8	制度	12	贸易条件

^① Ciccone and Jarocinski (2010) 的“理论”变量分组中，忽略了 3 个变量：民族语言分划 (AVELF)，英语人口 (ENGFRAC)，外语人口比例 (OTHFRAC)。由于这 3 个变量在后续实证分析中并没有表现出很强的预测解释力，因此我们也没有对其进行补充分组。

2. 程序与计算

本文所使用的程序都为 MATLAB 自带的程序包。套袋法、随机森林、神经网络因为使用了 Bootstrap 法对原有样本进行了再抽样，因此具有一定的随机性。为了控制随机性，我们将所有程序的 Bootstrap 数量设置为 $B = 10,000$ ，以保证结果的稳健性^①。表 3 报告了 5 中基础机器学习算法所对应的程序命令、计算变量排序的时间成本^②、是否有随机性、以及 Bootstrap 数量。

表 3: 计算程序基本信息

算法	MATLAB 命令	随机性	Bootstrap 数量	计算时间*
LASSO	lasso	否		约 30 秒
回归树	fitrtree	否		约 30 秒
套袋树	TreeBagger	是	10,000	约 1800 秒
随机森林	TreeBagger	是	10,000	约 1000 秒
神经网络	feedforwardnet	是	10,000	约 1500 秒
支持向量回归	fitrsvm	否		约 30 秒
弹性网络	lasso	否		约 30 秒
最小二乘提升法	fitensemble	否		约 30 秒
M5P-BG	m5pparamsensemble	是	10,000	约 1800 秒
M5P-RF	m5pparamsensemble	是	10,000	约 1500 秒

注：计算时间为使用 i7 8700K 芯片配合 32G DDR4 内存所得出的时间；程序经过并行优化，调用 6 个逻辑核心；因为硬件条件差异该项指标会有较大变化

3. 实证结果

3.1. 变量排序

我们首先汇报 5 种基础机器学习方法的变量排序与选择结果，结果见表 4。为简洁起见，我们只列出了按照第三节 2.2 中介绍的重要性测度排序前 10 位的变量。作为对比，我们同时列出了 Sala-i-Martin et al. (2004) 使用 BMA 方法得到的前 10 位显著解释变量。BMA 方法中，变量显著性的通用衡量指标是后验纳入 (posterior inclusion) 概率；Sala-i-Martin et al. (2004) 一共发现 18 个变量具有显著性^③。

表 4: 常规方法变量排序结果

	LASSO	回归树	套袋法	随机森林	神经网络	BMA
1	<u>YRSOPEN</u>	<u>MALFAL66</u>	<u>MALFAL66</u>	<u>BUDDHA</u>	<u>IPRICE1</u>	<u>EAST</u>
2	<u>EAST</u>	<u>BUDDHA</u>	<u>BUDDHA</u>	<u>MALFAL66</u>	<u>MINING</u>	<u>P60</u>
3	TROPPOP	ABSLATIT	EAST	EAST	EAST	IPRICE1
4	<u>P60</u>	LANDAREA	ABSLATIT	<u>LIFE060</u>	<u>CONFUC</u>	<u>GDPCH60L</u>
5	<u>MALFAL66</u>	GDE1	<u>P60</u>	<u>P60</u>	<u>P60</u>	<u>TROPICAR</u>
6	<u>CONFUC</u>	<u>GVR61</u>	<u>LIFE060</u>	ABSLATIT	OPENDEC1	<u>DENS65C</u>
7	RERD	<u>IPRICE1</u>	<u>YRSOPEN</u>	<u>YRSOPEN</u>	<u>DENS65C</u>	<u>MALFAL66</u>
8	<u>IPRICE1</u>	AIRDIST	<u>CONFUC</u>	<u>TROPICAR</u>	POP60	<u>LIFE060</u>
9	<u>BUDDHA</u>	SIZE60	AIRDIST	<u>CONFUC</u>	HINDU00	<u>CONFUC</u>

^① 我们尝试了 5000 到 100,000 的 Bootstrap 抽样次数，发现 3 个相应算法的变量选择与推测函数拟合在 10,000 次 Bootstrap 抽样下已经基本稳定。

^② 图表中所汇报的时间成本仅指计算变量排序 (即表 3) 所用的时间。测算推测函数非线性 (图 2、图 3、以及附录) 时，因为需要对所有变量及其两两组合，在所有样本点上反复进行推测函数的赋值，而每次赋值都需要重新运行一遍整个算法，因此累计计算成本很高。当 Bootstrap 抽样次数取 10,000 时，全套分析程序在 6 核并行设定下，运行一遍约需 4 周。

^③ Sala-i-Martin et al. (2004) 将变量显著性定义为后验纳入概率超过先验纳入概率，亦即数据样本的信息提高了该变量的纳入概率。其文章中具体选用的先验纳入概率为 10.4%。故这 18 个显著变量的后验纳入概率均大于等于 10.4%。

10	<u>GVR61</u>	POP6560	TROPICAR	H60	DENS60	SAFRICA
注：代码涵义见表 1；加黑表示该变量出现在 BMA 选取的前十显著变量；下划线表示该变量是 BMA 选取的非前十但显著的变量						

为了说明机器学习方法变量选择的效能，我们在表 4 中，将标准的 BMA 方法变量选取结果作为对比基础。第 2 到 6 列中，我们将机器学习方法选择出来的前十个重要变量中，与 BMA 前十变量重复的变量均加黑标识；此外，如果该变量是 BMA 方法选取的前十之外的显著变量，我们以下划线标识。在对比结果之前，我们再次指出，BMA 方法从设计上能够有效处理变量选择带来的模型不确定性，识别出不同模型设定下反复出现、具有显著预测效应的变量，但其基础是线性模型，无法应对样本的非线性特征。

从该表结果可见，回归树选取的前十变量中，只有 4 个是 BMA 显著变量。这反映了回归树方法过度拟合数据的倾向，使其在有限样本下容易关注预测效果并不特别稳健的变量。套袋法在设计时有意增强模型解释效能的稳健性，表 4 的结果也显示出这一点，一共识别出 8 个 BMA 显著变量，且其中有 6 个都是 BMA 前十显著的。随机森林与套袋法接近，理论上在数据呈现高截面相关性时有更强的稳健性，使其选取的解释变量能在更多的情况下显示出良好的解释能力；但当截面相关性有限时，解释效能未必一定超过套袋法。表 4 的结果清晰的显示了这一点，选取的前十变量中有 8 个都是 BMA 显著变量，且 6 个是 BMA 前十显著变量。表 4 中 LASSO 的结果同样在意料之中。与其他 3 个机器学习方法相比，LASSO 是为一个以线性推测函数为基础的，最接近 BMA 的基础设定；同时系数绝对值之和的增加，大幅提高了其变量选取的稳健性。与随机森林方法表现类似，LASSO 选取的前十变量中有 8 个是 BMA 显著变量，其中 5 个是 BMA 前十显著变量。与这 4 个方法相对比，神经网络方法结果有较大区别，所选择的前十变量中，6 个是 BMA 显著变量，其中 5 个是前十显著。如第三节中所述，神经网络方法的特征是深入挖掘样本间横向或纵向的固定关联特性，从而获取优良的解释能力。但是在跨国经济增长的样本中，样本本身具有的横向固定相关性有限，因此其数据挖掘的能力无法凸显出来。

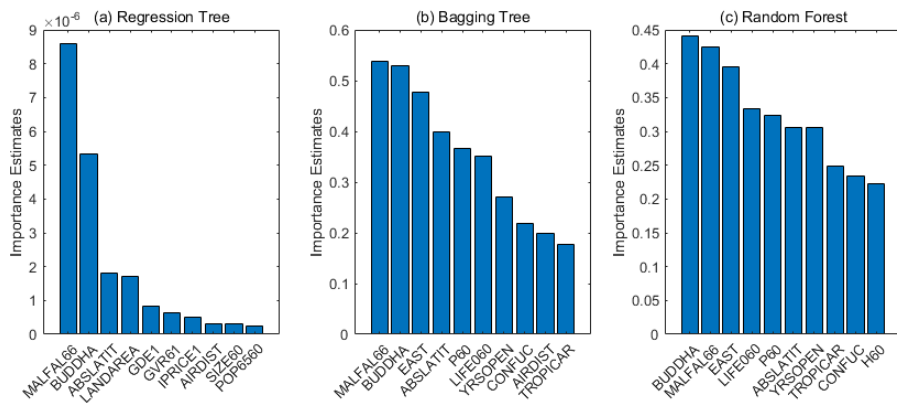


图 1：回归树、套袋法与随机森林法的前十变量选取结果

图 1 进一步绘制了回归树、套袋法与随机森林 3 种方法选择前十变量时各自的量化标准，即第三节 2.2 中描述的重要性指标。由图可见，回归树倾向于对不同变量给出差异明显的重要性判断。与此不同，套袋法与随机森林法对各自前十大解释变量的重要性评估较为一致，且后者较前者更为均衡。这反映出套袋法与随机森林法通过 Bootstrap 进行模拟交叉验证后，其产生的近似推测函数稳定性更高，变量选择过程不会由于微弱的样本变动导致结果的大幅改变。

作为 5 个常规方法的对比与参照，表 5 汇报了 5 种机器学习进阶方法与 3 种传统计量方法的变量排序结果。从中可以看出，EN、M5P-BG 和 M5P-RF 总体表现最佳。EN 法选取的 9 个变量都是 Sala-i-Martin et al. (2004) 应用 BMA 方法获得的显著变量，而 M5P-BG 与 M5P-RF 分别选择了 7 个和 8 个显著变量，其中分别有 5 个和 6 个前十显著变量。与此不同，SVR、LSB 两个机器学习方法仅选取出 1 个与 3 个显著变量，说明其变量排序与稳健性方面有较大的欠缺。传统计量方法上，BLR 与 FMA 均只选择出 1 个显著变量，甚至远差于最基础的逐步回归法，后者排序选择出了 8 个显著变量，其中有 6 个是前十显著的。但正如前文中已经说明过的，逐步回归法变量选择不具有全局一致性。

表 5: 进阶方法与传统计量方法变量排序结果

	M5P-BG	M5P-RF	SVR	EN	LSB	BLR	FMA	SR
1	SQPI6090	<u>BUDDHA</u>	SQPI6090	EAST	MALFAL66	DPOP6090	ORTH00	EAST
2	<u>BUDDHA</u>	MALFAL66	PI6090	P60	<u>BUDDHA</u>	POP6560	DENS65I	MALFAL66
3	MALFAL66	EAST	SAFRICA	<u>YRSOPEN</u>	LANDAREA	GEEREC1	HINDU00	<u>SPAIN</u>
4	EAST	LIFE060	PRIGHTS	CONFUC	ABSLATIT	GDE1	<u>BUDDHA</u>	P60
5	ABSLATIT	P60	ECORG	RERD	POP6560	H60	SQPI6090	GDPCH60L
6	P60	ABSLATIT	NEWSTATE	IPRICE1	IPRICE1	TOT1DEC1	SOCIALIST	IPRICE1
7	LIFE060	<u>YRSOPEN</u>	LANDAREA	<u>BUDDHA</u>	DPOP6090	GGCFD3	PROT00	OTHFRAC
8	<u>YRSOPEN</u>	H60	PROT00	<u>GVR61</u>	PRIGHTS	POP1560	EUROPE	LIFE060
9	CONFUC	TROPICAR	POP1560	DENS65C	OPENDEC1	GOVNOM1	ENGFRAC	<u>MINING</u>
10	AIRDIST	CONFUC	ZTROPICS	TROPICAR	AIRDIST	<u>GVR61</u>	POP60	GGCFD3

注: 粗体与下划线标注涵义与表 4 相同

3.2. 推测函数有效性

为了评估机器学习方法给出的拟合函数推测能力的有效性，我们系统对比不同方法推测值对应的 R^2 。具体而言，给定样本数据 $\{y_i, \mathbf{x}_i\}_{i=1, \dots, N}$ 以及一个机器学习方法所得的近似推测函数 \hat{f} ，我们首先计算相应的样本内中心 R^2 ：

$$R^2 = 1 - \frac{\sum_i (y_i - \hat{f}(\mathbf{x}_i))^2}{\sum_i (y_i - \bar{y})^2},$$

其中 \bar{y} 为样本均值。注意，由于回归树及其衍生的套袋法与随机森林，近似函数（预测树）的构造过程中，均是以样本估计 SSR 为判断基础，因此本质上均是最小化 L^2 -风险的预测方程。相应的，这些方法计算出的 R^2 应当在 0 和 1 之间。与此不同，LASSO 考虑的不是纯粹的 L^2 -风险，因此其产生的预测方程 \hat{f} 可能导致 R^2 小于 0。注意，对于 LASSO 之外的 4 个机器学习方法，其产生的近似推测函数 \hat{f} 均可能会呈现出高度非线性的特征。

注意上述中心 R^2 反映的是对数据样本整体的拟合情况，从模型不确定性问题角度看，主要着眼于样本中的非线性特征。为了更加突出模型不确定性的另一个来源——变量选择问题——我们暂时将非线性特征搁置，利用 5 个机器学习方法所挑选出的 5 组前十解释变量，在线性回归框架下，考察其样本内预测功效。这样做的一个好处，在于我们可以有效对比回归树、套袋法、随机森林与 LASSO 四个方法在线性约束下的解释能力，避免 LASSO 方法本身 R^2 评价的不适用性。此外，我们还可以对比包括所有 67 个变量的全样本线性回归模型的预测表现，从而更全面的考察机器学习方法的有效性。

表 6 汇报了按照上述两种方式所进行的模型预测效力评估。其中上半部分报告了使用各个机器学习方法产生的原始（非线性）近似推测函数的 R^2 表现以及预测残差绝对值的平

均值 (mean absolute error)。总体而言, 除 LASSO 之外的 4 种方法, 均能较好的捕捉 88 个国家样本数据的总体特征, 其中心 R^2 没有明显差别。GUM 所代表的包含 67 个解释变量的线性回归模型产生了高于机器学习方法的中心 R^2 , 但这仅只是由于解释变量数目接近样本量本身这一事实。如果将参数个数考虑进来, GUM 调整 R^2 自然大幅下降。

表 6: 常规方法推测函数有效性评估

	LASSO	回归树	套袋法	随机森林	神经网络	GUM
拟合推测函数样本内解释力						
MAE	0.0336	0.0047	0.0047	0.0050	0.0047	
中心 R^2	-2.3774	0.8696	0.8820	0.8674	0.8886	
排序前十解释变量样本内线性推测解释力						
中心 R^2	0.5449	0.6215	0.5659	0.5719	0.2141	0.9135
调整 R^2	0.4858	0.5723	0.5095	0.5163	0.1121	0.6236

注: GUM 表示一般无约束线性预测模型, 此处指包含全部 67 个变量的线性回归模型

表 6 下半部分的结果将预测模型约束到线性范围内, 并且只考虑 5 个机器学习方法各自挑选的前十大变量。如此我们可以暂时忽略样本非线性, 而只聚焦变量选择不确定性问题。此时中心 R^2 已经呈现出明显差别。回归树因为过度拟合数据局部特征, 而忽略了数据整体的线性趋势特征, 造成其中心 R^2 相比无约束非线性情况大幅下降。套袋法与随机森林法由于更加稳健的预测特征, 能够较好的捕捉数据的线性趋势特征, 因此对应的中心 R^2 表现优越。LASSO 由于模型本身的线性特征, 其约束预测效果也具有优势。比较 5 个方法在受约束线性预测时的调整 R^2 , 可以完全消除参数数目的影响, 并且可以直接与 GUM 的调整 R^2 进行对比。结果显示, 套袋法所选变量呈现出最好的线性解释能力, 甚至大幅超过基准模型为线性的 LASSO 方法。同时, 考虑到参数个数后, 套袋法、随机森林与 LASSO 所选变量的线性解释能力, 均高于或接近包含所有 67 个解释变量的 GUM, 进一步说明了机器学习方法较传统线性模型在克服变量不确定性问题时的明显优势。

表 7 进一步报告了 5 种进阶方法与 3 种传统计量方法所得到的推测函数的有效性, 以及各方法所选取前十变量的线性趋势解释力。仅考察全样本拟合推测函数的解释力 (即中心 R^2), 能够看到拟合效果最好的是最小二乘提升法。这与我们前面对该方法特征的讨论一致: 在逐步迭代中, LSB 不断改进对上一步残差值的拟合效果, 最终得到的样本内拟合结果自然较高。但这一特征其实造成了 LSB 的过度拟合倾向, 这从其变量选择结果及前十解释变量的样本内拟合效果就可看出。其余 4 种机器学习方法中, M5P-BG 与 M5P-RF 的样本内解释力保持在较高水平, 而 SVR 与 EN 方法的样本内解释力明显较弱。这说明两种方法在解释变量作用受限时 (过多的解释变量会导致额外的惩罚), 对于数据非线性特征的捕捉均存在较大的局限。三种传统计量方法较好的样本解释力并不意外, 因为在小样本条件下, 充足的解释变量确保了线性推测函数对样本的拟合精度。

表 7: 进阶方法与传统计量方法推测函数有效性评估

	M5P-BG	M5P-RF	SVR	EN	LSB	BLR	FMA	SR	GUM
拟合推测函数样本内解释力									
MAE	0.0047	0.0051	0.0057	0.0081	0.0024	0.0060	0.0051	0.0066	
中心 R^2	0.8779	0.8617	0.7031	0.6942	0.9749	0.8270	0.8764	0.7952	
排序前十解释变量样本内线性推测解释力									
中心 R^2	0.6678	0.7084	0.4168	0.7270	0.5717	0.3311	0.3222	0.7847	0.9135
调整 R^2	0.6247	0.6706	0.3410	0.6915	0.5160	0.2442	0.2342	0.7568	0.6236

注: 同表 6

与表 5 的讨论类似，我们可以进一步聚焦到各方法所选取的前十解释变量在样本内的线性拟合精度。这反映了各方法对数据的线性趋势特征捕捉能力及推测稳健性。从结果可以立即看到，全样本拟合精度最高的 LSB 方法，并不能很好的捕捉数据的总体趋势特征。相反，EN 方法由于推测函数的线性性，因此限制在前十解释变量时，并未明显丧失去样本内拟合水平；同时，上下两个 R^2 的对比也说明 EN 方法最终所得到的推测函数，几乎就只用了其前十解释变量。具有类似特征的，还有 SR 方法。与 LSB 明显不同，M5P-BG 与 M5P-RF 对样本的线性趋势捕捉能力仍然很强，甚至接近 EN 方法。这再次说明了通过 Bootstrap 提升回归树推测函数拟合稳健性在小样本下能够有效克服模型不确定性问题。同时，得益于结点推测值拟合效能的提高，M5P-BG 与 M5P-RF 不论在整体的推测函数解释力还是在前十变量线性推测解释力方面，都要优于基本的 BG 与 RF 方法。最后我们注意到，SVR、BLR 与 FMA 三个方法下，前十变量样本内线性推测拟合效能均大幅下降。这与这三个方法的变量排序与选择结果是一致的。

3.3. 推测函数特征分解

上述变量排序和拟合效果的分析，已经说明特定的机器学习方法，在处理小样本条件下跨国增长模型不确定性问题时具有很强的优势。为了进一步理解机器学习方法的特性，我们利用第三节中论述的推测函数关键特征分解、测度方法，对 5 种常规机器学习方法所得的推测函数进行分析，并特别突出各方法所选取前十变量的关键特征。限于篇幅，我们略去对 5 个进阶方法所得近似推测函数的分解、测度。

第一，我们讨论 5 种机器学习方法所产生的 5 个推测函数中，单个解释变量的解释力度。正文中，我们仅考虑各个方法选取的前十解释变量的解释力度，结果见表 8^①。表中 FEPV 一列，报告了每个方法下前十变量所具有的解释力度，以百分比表示，测算方法见上一节 (3) 式。变量代码下出现下划线的，说明该变量位列该方法 67 个变量解释力度排序前十。显然，除了神经网络法之外，其他 4 种方法所选取的前十解释变量，基本上同时也是解释力度排名前十的变量。各个方法选取的前十解释变量所具有的单一变量平均解释力度相差较大，从回归树方法的最高值 4.73%，到神经网络法的最低值 0.33%，说明各种方法的推测函数对变量间的交互作用捕捉程度不尽相同^②。套袋法与随机森林法下，前十解释变量的平均解释力度分别为 0.85% 与 0.47%，但联系到表 5 中这两个方法前十变量的良好解释效能，这说明套袋法与随机森林法通过充分捕捉变量间的交互解释效能，大幅提高了各自前十变量的总体预测解释力。

与表 1 中各个变量所属理论分组类别相对照可见，LASSO、回归树、套袋法与随机森林法所识别出的主要预测解释变量，集中在自然地理环境、宗教、人口结构、区位和贸易等方面，更多的反映经济增长的深层次根源（Spolaore and Wacziarg 2013）。归属于新古典增长理论类别的变量，主要为 P60，即 60 年代的小学教育程度。特别的，1960 年的人均 GDP（GDPCH60L）不但没有进入各方法选取的前十解释变量行列，甚至都不属于各方法下具有

^① 67 个变量的完整结果见附录 B 表 B2。

^② 五种方法下，67 个变量的累计单一变量解释力度也呈现较大差异：LASSO 为 27.81%，回归树最高为 48.51%，套袋法为 9.44%，随机森林法最低为 5.77%，神经网络法为 17.59%。根据第三节第 4 小节的测算框架，不能由单一变量解释的预测变动，均归因于变量间的多重交互作用。这说明，各个方法的预测结果中，归为多重交互效应的部分存在较大差异。

前十解释力度的变量序列^①。这说明新古典增长模型的主要理论预测，即经济增长的绝对收敛或者俱乐部收敛，在样本数据中很难获得支持。

表 8：常规方法前十解释变量特征测度

LASSO	FEPV	NL	回归树	FEPV	NL	套袋法	FEPV	NL
YRSOPEN	0.88	0.00	MALFAL66	14.63	72.65	MALFAL66	2.10	29.15
EAST	2.31	0.00	BUDDHA	12.68	24.68	BUDDHA	1.91	23.48
TROPPOP	0.00	0.00	ABSLATIT	7.19	99.93	EAST	1.32	4.53
P60	4.38	0.00	LANDAREA	4.02	99.61	ABSLATIT	0.56	44.12
MALFAL66	0.35	0.00	GDE1	2.98	93.88	P60	0.86	29.42
CONFUC	1.78	0.00	GVR61	0.97	95.97	LIFE060	0.89	47.02
RERD	0.57	0.00	IPRICE1	1.68	98.52	YRSOPEN	0.17	23.77
IPRICE1	2.03	0.00	AIRDIST	1.26	71.61	CONFUC	0.13	28.86
BUDDHA	0.88	0.00	SIZE60	1.03	85.36	AIRDIST	0.06	47.19
GVR61	0.29	0.00	POP6560	0.88	97.64	TROPICAR	0.03	25.32
随机森林			神经网络					
BUDDHA	0.95	24.74	IPRICE1	0.34	2.84			
MALFAL66	1.02	26.89	MINING	0.12	8.51			
EAST	0.65	4.10	EAST	1.73	1.10			
LIFE060	0.70	46.98	CONFUC	0.11	0.16			
P60	0.60	25.06	P60	1.09	1.23			
ABSLATIT	0.24	42.92	OPENDEC1	0.05	4.15			
YRSOPEN	0.28	21.87	DENS65C	0.06	1.13			
TROPICAR	0.07	25.64	POP60	0.02	1.19			
CONFUC	0.13	28.07	HINDU00	0.00	50.93			
H60	0.12	84.49	DENS60	0.10	13.46			

注：表中数字单位为百分比；FEPV 由 (3) 式定义，NL 表示非线性性测度，由 (7) 式辅助回归进行测算

第二，表 8 中 NL 的一列，报告了各个变量在相应推测函数中非线性特征，单位同为百分比，测度方法为 100% 减去 (7) 式辅助回归所得的 R^2 。除去 LASSO 方法总是线性推测函数，故非线性性总为 0 之外，其他 4 个方法均呈现出一定的非线性特征。其中回归树的非线性性最高，平均而言其前十解释变量的预测效果中 84% 来自非线性变动。与之相比，套袋法与随机森林法通过使用 Bootstrap 抽样方法，平滑了回归树方法频繁出现的局部非线性拟合，因此变量的平均非线性程度有明显下降。比较令人意外的是神经网络法产生的推测函数并未显示出突出的非线性特征，变量的平均非线性性仅 20% 有余^②。在下一小节中，我们选择套袋法和随机森林法，用图示方法进一步说明推测函数的非线性性。

第三，我们用热力图的形式报告 5 种机器学习方法下，前十变量的两两交互作用对推测值的贡献。具体结果见图 2。其中，每个方法所得结果单独以子图（热力图）形式呈现。每个热力图的上三角区域空白，两两变量组合在下三角区域已经出现过。热力图矩阵中，每个方块的颜色代表两两变量组合交互预测解释力（FIEPV，见(6)式定义），颜色越深表示解释

^① 详见附录 B 表 B1。GDPCH60L 仅在神经网络方法下进入解释力前十行列，在回归树方法中位列 12，在其他 3 种方法中均在解释力度前 20 之外。

^② 尽管神经网络方法中神经元层的 sigmoid 转换函数可以灵活拟合各类非线性函数，但是在跨国经济增长的样本数据下，神经网络学习的结果倾向于平均使用各个变量，导致总体推测函数更接近一个无约束（无变量选择）的线性预测形式。这一点在附录图 B3 中有更明确的呈现。

力越大；方块中的数字代表解释力数值，单位为百分比。注意，每个子图所用的色温尺度均不相同。

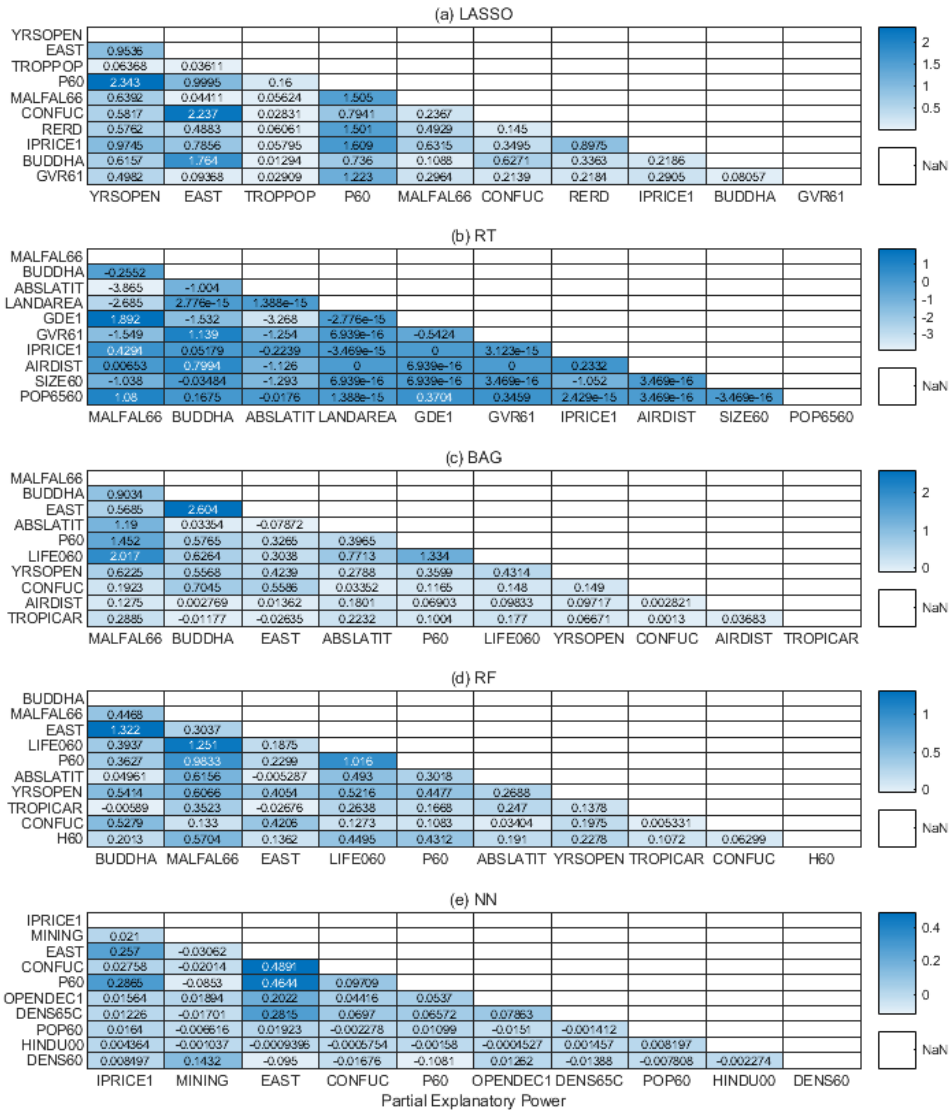


图 2：变量交互作用解释力

从图 2 的整体特征来看，可以发现神经网络方法下，变量间的双重交互作用大小比较一致，且幅度均较为有限；而回归树方法下，存在比较突出的正、负向双重交互作用。与此不同，LASSO、套袋法与随机森林法下，双重交互作用均为正向，且两两变量组合件交互作用差异较大。从幅度上看，套袋法与 LASSO 均存在交互作用大于 2% 的情况，联系表 6 给出的单一变量解释力度，可见交互作用对推测值的贡献可以非常显著。

观察套袋法、随机森林法与 LASSO 三种方法，一个突出的特征是显著的双重交互作用更容易出现在同类别或相近类别变量之间。如儒家文化 (CONFUC)、佛教比例 (BUDDHA) 与东亚地区 (EAST) 三者之间，就呈现出显著的两两正向交互作用。类似的，疟疾流行程度 (MALFAL60) 与预期寿命 (LIFE60) 之间，也存在很强的正向交互作用。这些特征说明，在经济增长的深层次决定因素中，不同类别深层次因素或同类别不同因素之间的交互作用，

对经济增长具有重要的预测意义。同时，这也说明拘泥于单纯线性模型的跨国实证研究，会容易忽略掉深层次决定因素间通过交互效应带来的重要影响。

3.4. 非线性特征图示

最后，我们着重说明机器学习方法在应对数据中可能存在的非线性特征时的显著优势。鉴于前述分析结果已经说明套袋法与随机森林两个方法的优良表现，我们在本节中仅就这两个方法所得推测函数图示汇报其非线性特征。

图 3 和图 4 分别对套袋法和随机森林法所选取的前十解释变量，绘制 $\hat{y} = \hat{f}(x_k, \mathbf{x}_{K \setminus k})$ 关于变量 x_k 的函数图像，其中 $\mathbf{x}_{K \setminus k}$ 表示所有 K 个变量中除去 k 外的 $K - 1$ 的变量。显然，推测值 \hat{y} 不仅依赖于 x_k 的取值，也依赖于 $\mathbf{x}_{K \setminus k}$ 的取值。为了反映 \hat{y} 与 x_k 之间的全样本特征，我们考虑 3 种 $\mathbf{x}_{K \setminus k}$ 的取值：所有 $K - 1$ 个变量固定在各自样本 25%、50% 和 75% 分位点。

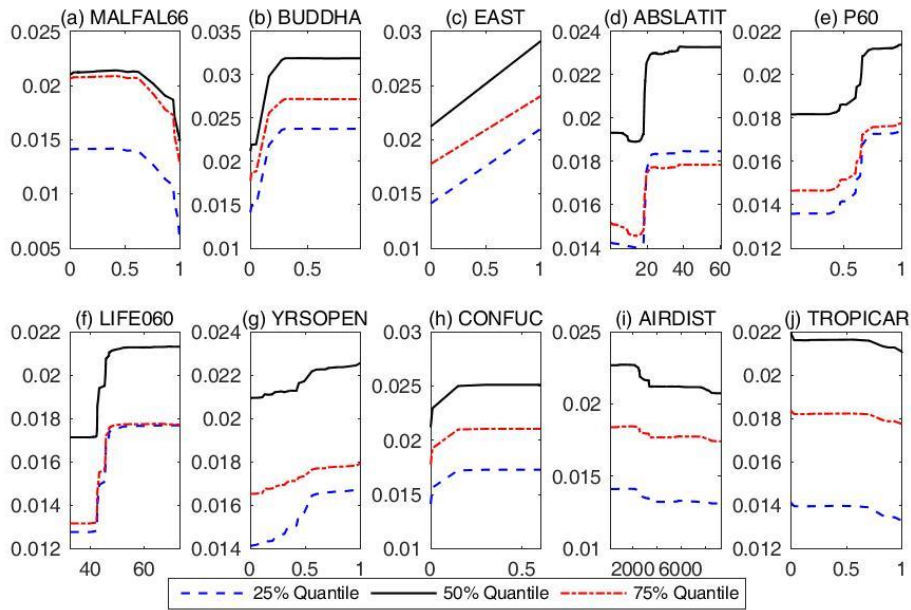


图 3：套袋法推测函数拟合值非线性特征

比较图 3 和图 4，我们首先注意到，对两图中同时出现的变量 x_k ，如 MALFAL66、BUDDHA，推测值（平均经济增长率） \hat{y} 与 x_k 之间的函数关系均高度相似。由于随机森林法所构造的回归树之间相关性天然弱于套袋法，因此两者最终所产生推测函数的一致性进一步互相印证了其稳健性，同时也说明数据样本中存在如图所反映的稳健特征。

两幅图中的纵坐标均为经济增长速度的水平值，因此相应解释变量对经济增长的边际作用反映在图中推测拟合值的整体走势与局部非线性变化上。两图中，除 EAST 为东亚经济虚拟变量取值 0/1 之外，其他变量均为连续取值。对虚拟变量而言，其推测函数拟合值一定为直线，因为所有样本仅在 0/1 处取值。因此，对推测函数非线性性的讨论，仅集中在连续取值变量上。

以图 3 中子图 (a) 为例，解释变量 MALFAL66 为 1960 年代疟疾流行程度。从图中拟合线明显可见，其对经济增长的作用，仅在水平上升到一定程度（0.6 以上）才开始显现，在此之前疟疾流行程度并不影响经济增长。类似的情况还出现在子图 (d) 1960 年代小学教育普及水平与子图 (f) 1960 年代人均预期寿命等解释变量中。对照图 3 和 4，也可以观察到，部分解释变量呈现出较为一致的增长预测作用，非线性程度较低。如经济开放程度

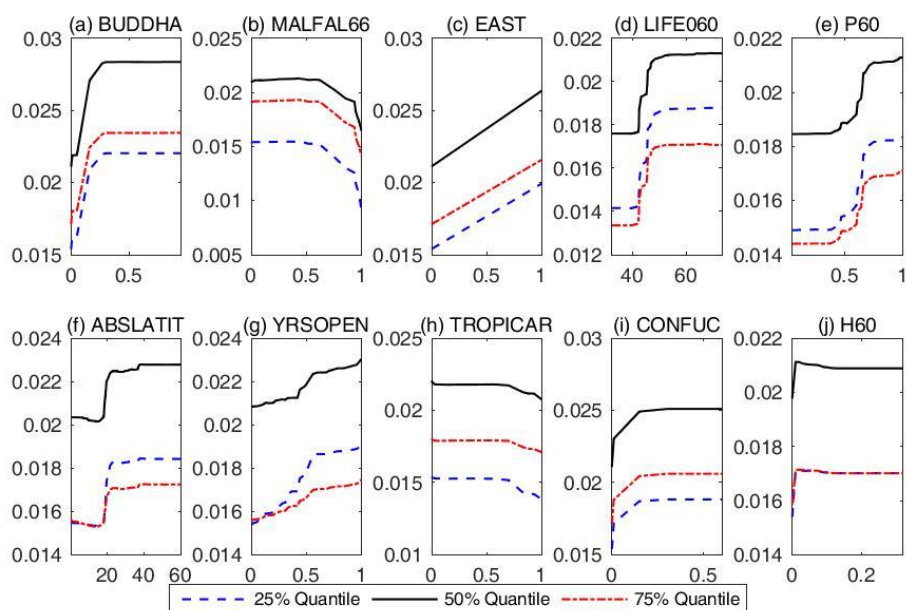


图 4：随机森林法推测函数拟合值非线性特征

（YRSOPEN），不论在何种方法与何种样本区间下，总体的线性趋势是其解释效能的主要部分。限于篇幅，我们不对各个变量的具体非线性特征进行展开分析，而只是再次指出，如果天然的将推测函数限定为线性形式，则会遗漏客观的样本非线性特征信息^①。

五、结论与讨论

经过近 30 年的发展，跨国实证研究中主流的回归分析范式，日益显示出方法论困境。由于样本有限性带来的模型不确定性问题，对传统跨国实证分析方法所得结论的归纳、总结与进一步发展形成了显著的制约。针对这一困境，本文提出可以充分利用新近的机器学习方法，有效缓解或克服传统分析方法存在的局限。本文系统阐述了机器学习方法的三个优势：适应小样本问题；处理变量排序、选择问题；克服样本非线性问题。利用 Sala-i-Martin et al.（2004）标准的跨国经济增长数据集，我们对 LASSO、回归树、套袋法、随机森林及神经网络法等 5 种常规数值型监督学习方法进行了实证测试，以说明其相对传统分析方法的优劣。同时，我们还考虑了支持向量回归、弹性网络、最小二乘提升、M5P-BG 与 M5P-RF5 种进阶方法，并使用贝叶斯回归、频率模型平均与逐步回归 3 种传统的计量方法作为对照。研究结果显示，套袋法与随机森林法及其拓展版本 M5P-BG 与 M5P-RF 在跨国经济增长及类似实证问题中具有突出的适用性、有效性、稳健性。通过机器学习方法提供的更强大数据特征提取功能，我们可以更好的处理跨国增长问题中的模型不确定性问题，从而获得更全面、稳健的经济增长经验典型事实，为未来经济增长理论的发展奠定更好的实证基础。

在结束全文前，我们就机器学习方法在经济增长研究中的应用前景，提供几点讨论与展望。由于在数据特征识别、提取方面所展现出的强大功能，机器学习方法近年来在越来越多的学科中得到广泛应用、取得良好效果，经济学也不例外。就经济增长的实证研究而言，机

^① 另外一种图示考察推测函数拟合值非线性性的方式，是对 (7) 式定义的 $\Delta\hat{y}_{[k]}$ 绘制其关于 x_k 的函数图像。这一表示方法能够直接与表 8 的结果相对照。限于篇幅，我们将 5 种常规方法所得推测函数对应的图示全部列入附录中。对套袋法与随机森林法而言，两种方法所绘制的前十变量函数图像非线性趋势均非常一致。

机器学习方法的应用才刚刚开始。如本文所述，机器学习方法对处理经济增长实证领域的模型不确定性问题有着很好的表现，但就目前初步的应用而言，这个新的框架是有其自身局限的。

首先，机器学习方法可以有效解决小样本、多变量条件下的增长函数推测问题，从而在一定程度上削减了由于遗漏变量所带来的内生性影响，但机器学习方法本身并不能轻而易举的解决跨国经济增长实证研究中广泛存在的内生性问题。不过，正如 Durlauf et al. (2009, sec. 24.6) 关于经济增长计量问题的综述中所指出的，虽然目前没有一个计量经济学的技术方法可以完全消除跨国增长回归的内生性问题，但我们并不应当就此全然抛弃跨国增长回归提供的丰富信息^①，这些约化回归中的相关性结论，对于指导增长理论的发展，判断基本理论推断是否符合现实方面具有很大的作用。同理，对机器学习方法的初步应用而言，通过更好的处理模型不确定性问题，得到更全面、文件的解释变量及其边际作用的经验规律，同样对经济增长理论的后续发展有着重要的意义。

其次，从模型不确定性的角度来看，目前在对经济增长的主要决定因素及其主要作用尚存诸多争论的情况下，我们甚至不应当寄期望于机器学习方法来解决内生性问题。人工智能领域图灵奖得主 Judea Pearl 在其关于因果推断的最新著作 (Pearl and Mackenzie 2018) 中反复指出，变量间因果性的建立不可能仅靠数据挖掘得到，而必须依靠含有相应变量间逻辑关系的因果性理论或模型。具体在经济增长领域，这就要求在识别每个具体解释变量的因果性时，需要有一个明确的理论或模型做支撑^②。因此，当研究的对象本身就是经济增长理论或模型的不确定性时，讨论某个变量的因果性问题本身在逻辑上就有一定的不一致性。

最后，将机器学习方法应用于因果推断，是当前一个研究前沿^③。不过，目前这一方面的工作，均集中在通过测算 0-1 型处置变量 (treatment variable) 带来的因果效应 (causal effect) 实现因果推断这一框架中。但在跨国经济增长的数据范围中，相关解释变量自身几乎都不满足处置变量的要求，因此难以应用最近的机器学习因果推断方法。

当然，我们相信随着机器学习方法的不断进步与推广，未来将会诞生可以直接应用于类似经济增长这类复杂因果关系问题类型的新方法。希望本文的研究内容和结果，可以激发更多研究者思考、探索机器学习在经济增长领域的广阔应用前景。

^① 在给 William Easterly 的书评中，Wacziarg (2002, fn. 26) 有如下非常贴切的评述：“At the same time, the comment that ‘this regressor is endogenous’ is both the easiest to make and the most common comment at academic seminars. I have heard pretty convoluted and unlikely stories for why causality could be reversed in specific cases. While establishing the direction of causality is a noble goal, concerns about reverse causality are sometimes taken too far. As mentioned earlier, simple correlations can also go a long way towards constraining our priors on the world.”

^② 事实上，即便是约化回归模型中常见的工具变量回归，关于工具变量的合理性论证也无法脱离一个具体的经济理论作为基础。

^③ 见 Athey and Imbens (2016)、Wagner and Athey (2018)、Chernozhukov et al. (2018) 等利用机器学习方法来解决处置效应 (treatment effect) 异质性问题，从而获得更准确因果推断的系列工作。

参考文献

- [1] Acemoglu D, Naidu S, Restrepo P, et al. Democracy Does Cause Growth[J]. *Journal of Political Economy*. 2019, 127(1): 47-100.
- [2] Athey S, Imbens G. Recursive Partitioning for Heterogeneous Causal Effects[J]. *Proceedings of the National Academy of Sciences*. 2016, 113(27): 7353-7360.
- [3] Athey S, Imbens G W. The State of Applied Econometrics: Causality and Policy Evaluation[J]. *Journal of Economic Perspectives*. 2017, 31(2): 3-32.
- [4] Barro R J. Economic Growth in a Cross Section of Countries[J]. *Quarterly Journal of Economics*. 1991, 106(2): 407-443.
- [5] Barro R J, Lee J W. Sources of Economic Growth[J]. *Carnegie-Rochester Conference Series on Public Policy*. 1994, 40: 1-46.
- [6] Barro R J, Sala-I-Martin X. Convergence[J]. *Journal of Political Economy*. 1992, 100(2): 223-251.
- [7] Bishop C M. *Pattern Recognition and Machine Learning*[M]. New York, NY: Springer, 2006.
- [8] Breiman L. Bagging Predictors[J]. *Machine Learning*. 1996, 24(2): 123-140.
- [9] Breiman L. Random Forests[J]. *Machine Learning*. 2001, 45(1): 5-32.
- [10] Breiman L, Friedman J, Olshen R A, et al. *Classification and Regression Trees*[M]. Boca Raton: Chapman and Hall/CRC, 1984.
- [11] Brock W A, Durlauf S N. What Have We Learned from a Decade of Empirical Research on Growth? Growth Empirics and Reality[J]. *World Bank Economic Review*. 2001, 15(2): 229-272.
- [12] Canova F. Testing for Convergence Clubs in Income Per Capita: A Predictive Density Approach[J]. *International Economic Review*. 2004, 45(1): 49-77.
- [13] Chernozhukov V, Chetverikov D, Demirer M, et al. Double/Debiased Machine Learning for Treatment and Structural Parameters[J]. *Econometrics Journal*. 2018, 21(1): C1-C68.
- [14] Ciccone A, Jarociński M. Determinants of Economic Growth: Will Data Tell?[J]. *American Economic Journal: Macroeconomics*. 2010, 2(4): 222-246.
- [15] Cohen-Cole E B, Durlauf S N, Rondina G. Nonlinearities in Growth: From Evidence to Policy[J]. *Journal of Macroeconomics*. 2012, 34(1): 42-58.
- [16] Durlauf S N. The Rise and Fall of Cross-Country Growth Regressions[J]. *History of Political Economy*. 2009, 41(Suppl_1): 315-333.
- [17] Durlauf S N, Johnson P A. Multiple Regimes and Cross-country Growth Behaviour[J]. *Journal of Applied Econometrics*. 1995, 10(4): 365-384.
- [18] Durlauf S N, Johnson P A, Temple J R W. *Growth Econometrics*[M]. Aghion P, Durlauf S N, Elsevier, 2005: 1A, 555-677.
- [19] Durlauf S N, Johnson P A, Temple J R W. *The Methods of Growth Econometrics*[M]. Mills T C, Patterson K, Palgrave Macmillan UK, 2009, 1119-1179.
- [20] Durlauf S N, Kourtellos A, Minkin A. The Local Solow Growth Model[J]. *European Economic Review*. 2001, 45(4): 928-940.
- [21] Durlauf S N, Kourtellos A, Tan C M. Are Any Growth Theories Robust?[J]. *Economic Journal*. 2008, 118(527): 329-346.
- [22] Easterly W, Kremer M, Pritchett L, et al. Good Policy or Good Luck?[J]. *Journal of Monetary Economics*. 1993, 32(3): 459-483.

- [23] Fernandez C, Ley E, Steel M F J. Model Uncertainty in Cross-country Growth Regressions[J]. *Journal of Applied Econometrics*. 2001, 16(5): 563-576.
- [24] Hastie T, Tibshirani R, Friedman J. *The Elements of Statistical Learning: Prediction, Inference and Data Mining*[M]. 2 ed. New York: Springer-Verlag, 2009.
- [25] Henderson D J, Papageorgiou C, Parmeter C F. Growth Empirics without Parameters[J]. *Economic Journal*. 2012, 122(559): 125-154.
- [26] Johnson P A, Papageorgiou C. What Remains of Cross-Country Convergence?[J]. *Journal of Economic Literature*. 2019, forthcoming.
- [27] Johnson P A, Takeyama L N. Initial Conditions and Economic Growth in the US States[J]. *European Economic Review*. 2001, 45(4): 919-927.
- [28] Kormendi R C, Meguire P G. Macroeconomic Determinants of Growth: Cross-country Evidence[J]. *Journal of Monetary Economics*. 1985, 16(2): 141-163.
- [29] Kourtellos A, Tan C M, Zhang X. Is the Relationship between Aid and Economic Growth Nonlinear?[J]. *Journal of Macroeconomics*. 2007, 29(3): 515-540.
- [30] Lehrer S F, Xie T. *The Bigger Picture: Combining Econometrics with Analytics Improve Forecasts of Movie Success*[Z]. 2018.
- [31] Levine R, Renelt D. A Sensitivity Analysis of Cross-Country Growth Regressions[J]. *American Economic Review*. 1992, 82(4): 942-963.
- [32] Ley E, Steel M F J. On the Effect of Prior Assumptions in Bayesian Model Averaging with Applications to Growth Regression[J]. *Journal of Applied Econometrics*. 2009, 24(4): 651-674.
- [33] Ley E, Steel M F J. Mixtures of g -priors for Bayesian Model Averaging with Economic Applications[J]. *Journal of Econometrics*. 2012, 171(2): 251-266.
- [34] Liu Y, Xie T. Machine Learning Versus Econometrics: Prediction of Box Office[J]. *Applied Economics Letters*. 2019, 26(2): 124-130.
- [35] Liu Z, Stengos T. Non-linearities in Cross-country Growth Regressions: A Semiparametric Approach[J]. *Journal of Applied Econometrics*. 1999, 14(5): 527-538.
- [36] Mankiw N G. Growth of Nations[J]. *Brookings Papers on Economic Activity*. 1995, 1995(1): 275-326.
- [37] Masanjala W H, Papageorgiou C. The Solow Model with CES Technology: Nonlinearities and Parameter Heterogeneity[J]. *Journal of Applied Econometrics*. 2004, 19(2): 171-201.
- [38] Minier J. Nonlinearities and Robustness in Growth Regressions[J]. *American Economic Review*. 2007, 97(2): 388-392.
- [39] Minier J. Institutions and Parameter Heterogeneity[J]. *Journal of Macroeconomics*. 2007, 29(3): 595-611.
- [40] Mitchell T M. *Machine Learning*[M]. McGraw-Hill, 1997.
- [41] Mullainathan S, Spiess J. Machine Learning: An Applied Econometric Approach[J]. *Journal of Economic Perspectives*. 2017, 31(2): 87-106.
- [42] Murphy K P. *Machine Learning: A Probabilistic Perspective*[M]. Cambridge, Massachusetts: The MIT Press, 2012.
- [43] Pearl J, Mackenzie D. *The Book of Why: The New Science of Cause and Effect*[M]. Basic Books, 2018.
- [44] Qiu Y, Ren Y, Xie T. Weighing Asset Pricing Factors: A Least Squares Model Averaging

- Approach[J]. *Quantitative Finance*. 2019, 19(10): 1673-1687.
- [45] Quinlan J R. Learning with Continuous Classes[C]. *Proceedings of the 5th Australian Joint Conference on Artificial Intelligence (AI '92)*, 1992, 343-348.
- [46] Sala-I-Martin X, Doppelhofer G, Miller R I. Determinants of Long-Term Growth: A Bayesian Averaging of Classical Estimates (BACE) Approach[J]. *American Economic Review*. 2004, 94(4): 813-835.
- [47] Spolaore E, Wacziarg R. How Deep Are the Roots of Economic Development?[J]. *Journal of Economic Literature*. 2013, 51(2): 325-369.
- [48] Tan C M. No One True Path: Uncovering the Interplay between Geography, Institutions, and Fractionalization in Economic Development[J]. *Journal of Applied Econometrics*. 2010, 25(7): 1100-1127.
- [49] Tibshirani R. Regression Shrinkage and Selection Via the Lasso[J]. *Journal of the Royal Statistical Society: Series B (Methodological)*. 1996, 58(1): 267-288.
- [50] Varian H R. Big Data: New Tricks for Econometrics[J]. *Journal of Economic Perspectives*. 2014, 28(2): 3-28.
- [51] Wacziarg R. Review of Easterly's *The Elusive Quest for Growth*[J]. *Journal of Economic Literature*. 2002, 40(3): 907-918.
- [52] Wager S, Athey S. Estimation and Inference of Heterogeneous Treatment Effects using Random Forests[J]. *Journal of the American Statistical Association*. 2018, 113(523): 1228-1242.
- [53] Wang Y, Witten I H. Inducing Model Trees for Continuous Classes[C]. *Proceedings of the 9th European Conference on Machine Learning Poster Papers*, 1997, 128-137.
- [54] 陈硕, 王宣艺. 机器学习在社会科中的应用: 回顾与展望[Z]. 复旦大学, 2018.
- [55] 黄乃静, 于明哲. 机器学习对经济学研究的影响研究进展[J]. *经济学动态*. 2018(07): 115-129.

附 录

A. 测算框架的详细说明

A.1. 单个变量解释效力的测算

给定推测函数 \hat{f} ，我们希望衡量某个具体的解释变量 x_{ki} 的样本变动，最终带来了多少样本内推测值 \hat{y}_i 的变动，从而得到该变量对推测值内样本内变动的贡献份额。这里的难点，在于如何将 x_{ki} 样本变动的同时，其他变量 $x_{ji}, j \neq k$ 样本变动带来的推测值 \hat{y}_i 变动，纳入考虑。在通常的“加法”思维下，我们希望固定住其他变量，只让 x_{ki} 变化并观察推测值 $\hat{f}(\dots, x_{ki}, \dots)$ 出现了多少变化。但这样一来，我们所衡量的 x_{ki} 对推测值变动的贡献，本质上都是“条件”评估——测算结果取决于其他变量被固定住的取值水平；与此同时，给定其他变量样本取值的多样性，并没有任何一组特定的取值具有明显的“合理性”。这样一来，上述条件评估本身又变成一个高维度的对象，从而失去了对单一变量解释力贡献测度的简明性。与此相反，我们可以采取一个“减法”思维，直接获得一个“无条件”测度。具体而言，我们定义推测函数 \hat{f} 关于变量 x_k 的平均可解释预测变动（average explained prediction variation）如下：

$$AEPV(\hat{f}; k) = \frac{1}{N} \sum_{i=1}^N \left(\hat{f}(x_i) - \frac{1}{N} \sum_{j=1}^N \hat{f}(x_{1i}, \dots, x_{k-1,i}, x_{kj}, x_{k+1,i}, \dots, x_{ki}) \right)^2. \quad (A8)$$

上式中的第 i 个求和项解释如下：首先，给定样本点 x_i 及其对应的推测值 $\hat{f}(x_i) = \hat{f}(x_{1i}, \dots, x_{ki}, \dots, x_{ki})$ ，固定 x_k 之外的变量样本取值不变，但让 x_k 取遍样本取值 $\{x_{k1}, \dots, x_{kN}\}$ 并计算对应推测值的平均，则这一平均推测值反映了除 x_k 之外所有其余变量对该样本点处推测值的贡献，同时仅保留 x_k 自身在整个样本取值范围内预测贡献的平均说明；其次， $\hat{f}(x_i)$ 与该预测均值的离差，刻画了该样本点处， x_k 取对应样本值 x_{ki} 时，推测值的改进程度，从而反映了变量 x_k 在该样本点对于推测值的贡献大小；最后，将所有样本点处的离差取平方求和再取平均，即得到变量 x_k 在所有样本点处，对样本内推测值变动的总体平均解释度。下面第 A.4 小节，我们会进一步用线性推测函数的例子，说明上述公式的意义。

我们可以进一步定义平均预测变动（average prediction variation）如下：

$$APV(\hat{f}) = \frac{1}{N} \sum_{i=1}^N \left(\hat{f}(x_i) - \frac{1}{N} \sum_{j=1}^N \hat{f}(x_j) \right)^2, \quad (A9)$$

换言之， $APV(\hat{f})$ 就是样本内推测值的方差。在此基础上，我们定义推测函数 \hat{f} 关于变量 x_k 的可解释预测变动占比（fraction of EPV）：

$$FEPV(\hat{f}; k) = \frac{AEPV(\hat{f}; k)}{APV(\hat{f})}. \quad (A10)$$

这一占比变量，简洁的反映了 x_k 对推测函数 \hat{f} 样本内预测的贡献比例。

A.2. 两个变量联合解释效力的测算

有了单变量情形作为铺垫，我们下面讨论两个变量的情形。首先，沿用 $AEPV(\hat{f}; \cdot)$ 的记号，我们定义两个变量 x_k, x_m 的联合可解释预测变动如下：

$$AEPV(\hat{f}; k, m) = \frac{1}{N} \sum_{i=1}^N \left(\hat{f}(x_i) - \frac{1}{N} \sum_{j=1}^N \hat{f}(\dots, x_{kj}, \dots, x_{mj}, \dots) \right)^2, \quad (A11)$$

上式求和项中 $\hat{f}(\dots, x_{kj}, \dots, x_{mj}, \dots)$ 的省略号表示除 x_k, x_m 外所有其他变量均为样本点 i 处的取值。这里定义的 $AEPV(\hat{f}; k, m)$ 包括了 x_k, x_m 两个变量各自对推测值的独立贡献，以及两个变量对推测值的交互贡献。为测量这后一部分预测贡献，我们可以进一步定义交互可解释预测变动（interactive EPV）：

$$IEPV(\hat{f}; k, m) = AEPV(\hat{f}; k, m) - AEPV(\hat{f}; k) - AEPV(\hat{f}; m). \quad (A12)$$

同样，我们将在第 A.4 节中用线性推测函数为例，进一步说明 $AEPV(\hat{f}; k, m)$ 及 $IEPV(\hat{f}; k, m)$ 的涵义。与单变量情形类似，可以计算上述两个特征量与 $AEPV(\hat{f})$ 的比例，用来简洁测度两个变量的联合解释贡献占比与交互解释贡献占比：

$$FEPV(\hat{f}; k, m) = \frac{AEPV(\hat{f}; k, m)}{APV(\hat{f})}, \quad FIEPV(\hat{f}; k, m) = \frac{IEPV(\hat{f}; k, m)}{APV(\hat{f})}. \quad (A13)$$

A.3. 推测函数非线性性的度量

正如前文所述，机器学习方法较传统计量方法——特别是以线性回归为基础的线性预测方法——的一个突出优势是可以灵活的捕捉、处理数据样本中存在的非线性性。但如何刻画机器学习方法所生成推测函数的非线性性，却并没有一套现成的技术。不过，我们下面马上会说明，在上述变量解释力测算框架下，我们可以很自然的度量推测函数的非线性性。

参照 A.1 小节，我们可以将 $\Delta \hat{y}_{[k]i} \equiv \hat{f}(x_i) - \frac{1}{N} \sum_j \hat{f}(\dots, x_{kj}, \dots)$ 视作变量样本值 x_{ki} 对推测值 \hat{y}_i 的预测贡献。若以 $\Delta \hat{y}_{[k]i}$ 为分析对象，并将其视作仅与 x_k 有关，那么我们可以进一步将 x_k 对目标变量的预测效果——即 $\Delta \hat{y}_{[k]i}$ 体现的部分——分解为线性趋势项与非线性项两个部分。为此，我们只需要用 $\Delta \hat{y}_{[k]i}$ 对 x_k 进行如下的辅助性线性回归：

$$\Delta \hat{y}_{[k]i} = \alpha + \beta_k x_{ki} + \xi_i, \quad i = 1, \dots, N, \quad (A14)$$

进而可以将回归所得的线性部分 $\alpha + \beta_k x_{ki}$ 解释为 x_k 预测贡献中的线性趋势项，残差项 ξ_{ki} 则可视作相应的非线性部分。同时，该回归的 R^2 自然可以解释为 x_k 解释能力中线性趋势部分的比例，而 $1 - R^2$ 则表示非线性变动部分的比例。

类似的，我们还可以衡量多个变量的联合非线性性。以两个变量为例说明，我们仅需定义 $\Delta \hat{y}_{[km]i} \equiv \hat{f}(x_i) - \frac{1}{N} \sum_j \hat{f}(\dots, x_{kj}, \dots, x_{mj}, \dots)$ ，并通过 2-元辅助回归

$$\Delta \hat{y}_{[km]i} = \alpha + \beta_k x_{ki} + \beta_m x_{mi} + \xi_i, \quad i = 1, \dots, N$$

进行分析即可。

A.4. 测算框架的直观说明：三个示例

我们首先考察线性推测函数的例子。假设推测函数由如下形式：

$$\hat{f}(x_i) = \boldsymbol{\beta}^\top x_i = \beta_1 x_{1i} + \dots + \beta_k x_{ki}.$$

直接计算可知， $\Delta \hat{y}_{[k]i} = \hat{f}(x_i) - \frac{1}{N} \sum_j \hat{f}(\dots, x_{kj}, \dots) = \beta_k x_{ki} - \beta_k \bar{x}_k$ ，其中 \bar{x}_k 表示样本均值。因此，(1)式定义的 $AEPV(\hat{f}; k) = \frac{\beta_k^2}{N} \sum_i (x_{ki} - \bar{x}_k)^2$ ，即线性回归中变量 x_k 的可解释样本方差（explained sample variance）。类似的，两个变量 x_k, x_m 联合时， $AEPV(\hat{f}; k, m) =$

$\frac{1}{N} \sum_i (\beta_k(x_{ki} - \bar{x}_k) + \beta_m(x_{mi} - \bar{x}_m))^2$; 此时存在两个变量交互作用对预测的贡献, 相应的 $IEPV(\hat{f}; k, m) = \frac{2\beta_k\beta_m}{N} \sum_i (x_{ki} - \bar{x}_k)(x_{mi} - \bar{x}_m)$ 。此外, 由于 $\Delta\hat{y}_{[k]i}$ 此时是线性依赖于 x_{ki} , 故非线性性分解所用的辅助回归 (7) 可实现完美拟合, $R^2 = 1$; 同时 $\Delta\hat{y}_{[k]i} = \beta_k x_{ki} - \beta_k \bar{x}_k$ 也说明辅助回归方程 (7) 中包括常数项的必要性。

接下来, 我们考虑一般的可加性推测函数:

$$\hat{f}(\mathbf{x}_i) = g_1(x_{1i}) + \cdots + g_K(x_{Ki}),$$

上式中各个 $g_k(\cdot)$ 均假设为非线性函数。直接计算可知, $\Delta\hat{y}_{[k]i} = g_k(x_{ki}) - \bar{g}_k$, 其中 \bar{g}_k 表示 $g_k(x_{ki})$ 的样本均值。此时, 单变量或双变量下 AEPV 和 IEPV 的表达式与线性推测函数时类似, 不再赘述。但此时 $\Delta\hat{y}_{[k]i}$ 不再是线性的依赖于 x_{ki} , 因此辅助回归 (7) 将通过 $R^2 < 1$ 捕捉到 $g_k(\cdot)$ 反映的非线性特征。

最后, 我们考虑一个含有交叉项的 (拟) 线性预测模型:

$$\hat{f}(\mathbf{x}_i) = \beta_1 x_{1i} + \beta_2 x_{2i} + \lambda x_{1i} x_{2i} + \beta_3 x_{3i} + \cdots + \beta_K x_{Ki}.$$

此时, 对应的

$$\begin{aligned} \Delta\hat{y}_{[1]i} &= (x_{1i} - \bar{x}_1)(\beta_1 + \lambda x_{2i}), \\ \Delta\hat{y}_{[2]i} &= (x_{2i} - \bar{x}_2)(\beta_2 + \lambda x_{1i}), \\ \Delta\hat{y}_{[12]i} &= \beta_1(x_{1i} - \bar{x}_1) + \beta_2(x_{2i} - \bar{x}_2) + \lambda(x_{1i}x_{2i} - \bar{x}_1\bar{x}_2) \\ &= (x_{1i} - \bar{x}_1)(\beta_1 + \lambda x_{2i}) + (x_{2i} - \bar{x}_2)(\beta_2 + \lambda x_{1i}) \\ &\quad + \lambda(\bar{x}_1 x_{2i} + x_{1i} \bar{x}_2 - x_{1i} x_{2i} - \bar{x}_1 \bar{x}_2), \end{aligned}$$

其中 $\bar{x}_1 \bar{x}_2$ 表示 $x_{1i} x_{2i}$ 的样本均值。由此可算得

$$\begin{aligned} IEPV(\hat{f}; 1, 2) &= AEPV(\hat{f}; 1, 2) - AEPV(\hat{f}; 1) - AEPV(\hat{f}; 2) \\ &= \frac{\lambda^2}{N} \sum_i (\bar{x}_1 x_{2i} + x_{1i} \bar{x}_2 - x_{1i} x_{2i} - \bar{x}_1 \bar{x}_2)^2 \\ &\quad + \frac{2\lambda}{N} \sum_i (x_{1i} - \bar{x}_1)(\beta_1 + \lambda x_{2i}) (\bar{x}_1 x_{2i} + x_{1i} \bar{x}_2 - x_{1i} x_{2i} - \bar{x}_1 \bar{x}_2) \\ &\quad + \frac{2\lambda}{N} \sum_i (x_{2i} - \bar{x}_2)(\beta_2 + \lambda x_{1i}) (\bar{x}_1 x_{2i} + x_{1i} \bar{x}_2 - x_{1i} x_{2i} - \bar{x}_1 \bar{x}_2) \\ &\quad + \frac{2}{N} \sum_i (x_{1i} - \bar{x}_1)(\beta_1 + \lambda x_{2i})(x_{2i} - \bar{x}_2)(\beta_2 + \lambda x_{1i}). \end{aligned}$$

B. 推测函数关键特征度量

B.1. 单一变量预测解释力度结果

表 B1: 常规方法单一变量解释力度排序

LASSO		RT		BG		RF		NN	
P60	0.04	MALFAL66	0.15	MALFAL66	0.02	MALFAL66	0.01	EAST	0.02
EAST	0.02	BUDDHA	0.13	BUDDHA	0.02	BUDDHA	0.01	SAFRICA	0.01
IPRICE1	0.02	ABSLATIT	0.07	EAST	0.01	LIFE060	0.01	P60	0.01
CONFUC	0.02	LANDAREA	0.04	LIFE060	0.01	EAST	0.01	YRSOPEN	0.01
TROPICAR	0.01	GDE1	0.03	P60	0.01	P60	0.01	BRIT	0.01
BUDDHA	0.01	IPRICE1	0.02	ABSLATIT	0.01	YRSOPEN	0.00	MALFAL66	0.01
YRSOPEN	0.01	AIRDIST	0.01	YRSOPEN	0.00	ABSLATIT	0.00	COLONY	0.00
MINING	0.01	SIZE60	0.01	CONFUC	0.00	CONFUC	0.00	CIV72	0.00
GDPCH60L	0.01	GVR61	0.01	DENS60	0.00	H60	0.00	LIFE060	0.00
RERD	0.01	POP6560	0.01	IPRICE1	0.00	DENS60	0.00	PROT00	0.00
SPAIN	0.00	RERD	0.01	AIRDIST	0.00	DENS65C	0.00	TROPICAR	0.00
DENS65C	0.00	GDPCH60L	0.00	TROPPOP	0.00	TROPPOP	0.00	OTHFRAC	0.00
MALFAL66	0.00	DENS60	0.00	RERD	0.00	RERD	0.00	SPAIN	0.00
GVR61	0.00	CATH00	0.00	LANDAREA	0.00	IPRICE1	0.00	IPRICE1	0.00
MUSLIM00	0.00	AVELF	0.00	DENS65C	0.00	TROPICAR	0.00	GDPCH60L	0.00
OTHFRAC	0.00	BRIT	0.00	TOTIND	0.00	SAFRICA	0.00	AVELF	0.00
REVCOU	0.00	CIV72	0.00	POP6560	0.00	TOTIND	0.00	RERD	0.00
GGCFD3	0.00	COLONY	0.00	H60	0.00	FERTLDC1	0.00	TROPPOP	0.00
AVELF	0.00	CONFUC	0.00	TROPICAR	0.00	AIRDIST	0.00	CATH00	0.00
SAFRICA	0.00	DENS65C	0.00	GDPCH60L	0.00	ZTROPICS	0.00	LAAM	0.00
GOVNOM1	0.00	DENS65I	0.00	DENS65I	0.00	GDPCH60L	0.00	MINING	0.00
HINDU00	0.00	DPOP6090	0.00	ZTROPICS	0.00	DENS65I	0.00	NEWSTATE	0.00
CIV72	0.00	EAST	0.00	OPENDEC1	0.00	LANDAREA	0.00	BUDDHA	0.00
OPENDEC1	0.00	ECORG	0.00	LHCPC	0.00	AVELF	0.00	PRIEXP70	0.00
TROPPOP	0.00	ENGFRAC	0.00	FERTLDC1	0.00	PRIGHTS	0.00	CONFUC	0.00
PRIEXP70	0.00	EUROPE	0.00	HERF00	0.00	POP6560	0.00	SOCIALIST	0.00
POP60	0.00	FERTLDC1	0.00	GDE1	0.00	CATH00	0.00	DENS60	0.00
SCOUT	0.00	GEEREC1	0.00	SIZE60	0.00	GDE1	0.00	WARTORN	0.00
PROT00	0.00	GGCFD3	0.00	PRIGHTS	0.00	PRIEXP70	0.00	POP1560	0.00
GEEREC1	0.00	GOVNOM1	0.00	SPAIN	0.00	SPAIN	0.00	PRIGHTS	0.00
ABSLATIT	0.00	GOVSH61	0.00	SAFRICA	0.00	LHCPC	0.00	REVCOU	0.00
AIRDIST	0.00	H60	0.00	GGCFD3	0.00	LAAM	0.00	GGCFD3	0.00
BRIT	0.00	HERF00	0.00	PROT00	0.00	HERF00	0.00	GOVNOM1	0.00
CATH00	0.00	HINDU00	0.00	CATH00	0.00	GEEREC1	0.00	SCOUT	0.00
COLONY	0.00	LAAM	0.00	GEEREC1	0.00	PROT00	0.00	LT100CR	0.00
DENS60	0.00	LANDLOCK	0.00	LT100CR	0.00	OPENDEC1	0.00	GVR61	0.00
DENS65I	0.00	LHCPC	0.00	GOVSH61	0.00	SIZE60	0.00	LHCPC	0.00
DPOP6090	0.00	LIFE060	0.00	REVCOU	0.00	GOVSH61	0.00	GOVSH61	0.00
ECORG	0.00	LT100CR	0.00	AVELF	0.00	GVR61	0.00	LANDLOCK	0.00
ENGFRAC	0.00	MINING	0.00	PRIEXP70	0.00	LT100CR	0.00	DENS65C	0.00
EUROPE	0.00	MUSLIM00	0.00	CIV72	0.00	GGCFD3	0.00	OPENDEC1	0.00
FERTLDC1	0.00	NEWSTATE	0.00	LAAM	0.00	REVCOU	0.00	ECORG	0.00
GDE1	0.00	OIL	0.00	DPOP6090	0.00	DPOP6090	0.00	OIL	0.00
GOVSH61	0.00	OPENDEC1	0.00	GOVNOM1	0.00	CIV72	0.00	DPOP6090	0.00

H60	0.00	ORTH00	0.00	POP1560	0.00	POP1560	0.00	SIZE60	0.00
HERF00	0.00	OTHFRAC	0.00	PI6090	0.00	GOVNOM1	0.00	ZTROPICS	0.00
LAAM	0.00	P60	0.00	ENGFRAC	0.00	MUSLIM00	0.00	TOT1DEC1	0.00
LANDAREA	0.00	PI6090	0.00	GVR61	0.00	POP60	0.00	FERTLDC1	0.00
LANDLOCK	0.00	SQPI6090	0.00	MUSLIM00	0.00	PI6090	0.00	ENGFRAC	0.00
LHCPC	0.00	PRIGHTS	0.00	POP60	0.00	SQPI6090	0.00	TOTIND	0.00
LIFE060	0.00	POP1560	0.00	TOT1DEC1	0.00	TOT1DEC1	0.00	H60	0.00
LT100CR	0.00	POP60	0.00	MINING	0.00	MINING	0.00	GDE1	0.00
NEWSTATE	0.00	PRIEXP70	0.00	OTHFRAC	0.00	COLONY	0.00	POP60	0.00
OIL	0.00	PROT00	0.00	ECORG	0.00	ENGFRAC	0.00	GEEREC1	0.00
ORTH00	0.00	REVCOU	0.00	WARTIME	0.00	OTHFRAC	0.00	PI6090	0.00
PI6090	0.00	SAFRICA	0.00	NEWSTATE	0.00	HINDU00	0.00	AIRDIST	0.00
SQPI6090	0.00	SCOUT	0.00	HINDU00	0.00	WARTIME	0.00	EUROPE	0.00
PRIGHTS	0.00	SOCIALIST	0.00	COLONY	0.00	ECORG	0.00	LANDAREA	0.00
POP1560	0.00	SPAIN	0.00	SCOUT	0.00	NEWSTATE	0.00	HERF00	0.00
POP6560	0.00	TOT1DEC1	0.00	WARTORN	0.00	WARTORN	0.00	MUSLIM00	0.00
SIZE60	0.00	TOTIND	0.00	BRIT	0.00	SCOUT	0.00	POP6560	0.00
SOCIALIST	0.00	TROPICAR	0.00	LANDLOCK	0.00	BRIT	0.00	WARTIME	0.00
TOT1DEC1	0.00	TROPPOP	0.00	EUROPE	0.00	LANDLOCK	0.00	ABSLATIT	0.00
TOTIND	0.00	WARTIME	0.00	ORTH00	0.00	EUROPE	0.00	HINDU00	0.00
WARTIME	0.00	WARTORN	0.00	SOCIALIST	0.00	SOCIALIST	0.00	SQPI6090	0.00
WARTORN	0.00	YRSOPEN	0.00	OIL	0.00	ORTH00	0.00	DENS65I	0.00
ZTROPICS	0.00	ZTROPICS	0.00	SQPI6090	0.00	OIL	0.00	ORTH00	0.00

注：每种方法对应变量按照解释力度从大到小排序；每个变量右侧数字为百分比解释力度，单位为百分比

B.2. 单一变量预测非线性性测度结果

表 B2：常规方法单一变量预测非线性性排序

LASSO		RT		BG		RF		NN	
IPRICE1	0.00	BUDDHA	24.68	EAST	4.53	EAST	4.10	CONFUC	0.16
P60	0.00	AIRDIST	71.61	SPAIN	6.71	SPAIN	7.14	GDPCH60L	0.50
GDPCH60L	0.00	MALFAL66	72.65	ENGFRAC	9.93	ENGFRAC	10.78	H60	1.02
YRSOPEN	0.00	GDPCH60L	84.08	SAFRICA	10.44	SAFRICA	11.17	EAST	1.10
RERD	0.00	EAST	84.75	TROPPOP	19.76	LAAM	15.28	DENS65C	1.13
MINING	0.00	SIZE60	85.36	LAAM	19.78	TROPPOP	16.99	POP60	1.19
GVR61	0.00	CONFUC	85.47	BUDDHA	23.48	YRSOPEN	21.87	SAFRICA	1.22
DENS65C	0.00	DENS65C	88.79	YRSOPEN	23.77	BUDDHA	24.74	P60	1.23
TROPICAR	0.00	ENGFRAC	90.68	TROPICAR	25.32	RERD	24.99	PROT00	1.52
EAST	0.00	SCOUT	93.78	COLONY	25.72	P60	25.06	LIFE060	1.61
CONFUC	0.00	GDE1	93.88	RERD	27.45	TROPICAR	25.64	RERD	1.67
BUDDHA	0.00	DENS60	94.40	CONFUC	28.86	MALFAL66	26.89	ORTH00	1.69
AVELF	0.00	CATH00	94.57	MALFAL66	29.15	CONFUC	28.07	POP1560	1.70
GGCFD3	0.00	PROT00	95.00	P60	29.42	COLONY	28.36	YRSOPEN	1.89
OTHFRAC	0.00	DENS65I	95.60	SOCIALIST	30.11	PRIEXP70	32.22	CIV72	1.91
MUSLIM00	0.00	GVR61	95.97	EUROPE	39.96	NEWSTATE	33.03	BUDDHA	2.06
MALFAL66	0.00	RERD	95.97	NEWSTATE	43.40	SOCIALIST	34.10	SIZE60	2.44
SPAIN	0.00	EUROPE	96.22	ABSLATIT	44.12	AVELF	37.38	TROPICAR	2.66
REVCOU	0.00	TOT1DEC1	96.32	CIV72	44.46	REVCOU	42.09	IPRICE1	2.84
GOVNOM1	0.00	COLONY	96.87	REVCOU	45.70	GVR61	42.36	AVELF	2.85
OPENDEC1	0.00	MINING	97.06	LIFE060	47.02	CIV72	42.70	COLONY	3.00

CIV72	0.00	LAAM	97.26	AIRDIST	47.19	ABSLATIT	42.92	SPAIN	3.54
PRIEXP70	0.00	ZTROPICS	97.27	AVELF	48.58	PROT00	44.06	REVCOU	3.60
POP60	0.00	OPENDEC1	97.54	PRIEXP70	49.39	LIFE060	46.98	OPENDEC1	4.15
HINDU00	0.00	H60	97.63	ZTROPICS	50.25	ZTROPICS	49.20	GOVNOM1	4.38
SAFRICA	0.00	POP6560	97.64	HINDU00	50.31	AIRDIST	49.71	MALFAL66	4.55
TROPPOP	0.00	SPAIN	97.67	ECORG	52.97	ECORG	52.12	PRIEXP70	5.26
SCOUT	0.00	OIL	97.90	PROT00	53.67	DENS65C	58.32	TOTIND	6.05
PROT00	0.00	LHCPC	97.90	PRIGHTS	57.90	DPOP6090	58.88	CATH00	6.06
GEEREC1	0.00	TOTIND	98.08	DPOP6090	57.99	PRIGHTS	60.39	GOVSH61	6.58
ZTROPICS	95.45	HINDU00	98.20	MUSLIM00	65.77	GOVSH61	62.23	DPOP6090	6.61
BRIT	96.77	PRIGHTS	98.20	SCOUT	66.85	IPRICE1	62.84	LAAM	6.88
SIZE60	97.55	PRIEXP70	98.35	GDPCH60L	68.56	OTHFRAC	63.51	GVR61	7.46
GOVSH61	97.60	HERF00	98.50	GDE1	68.93	MUSLIM00	64.73	TROPPOP	7.70
WARTORN	97.92	POP1560	98.51	IPRICE1	69.48	GDE1	65.59	OTHFRAC	8.49
OIL	97.93	IPRICE1	98.52	GOVSH61	71.02	TOT1DEC1	67.83	MINING	8.51
PI6090	98.09	NEWSTATE	98.58	GVR61	71.27	OPENDEC1	67.94	FERTLDC1	10.91
DPOP6090	98.46	POP60	98.71	DENS65C	71.31	FERTLDC1	69.45	ENGFRAC	12.07
SOCIALIST	98.56	TROPICAR	98.80	SIZE60	71.72	HINDU00	70.45	DENS65I	12.75
ECORG	98.89	PI6090	98.90	DENS60	73.41	TOTIND	72.66	TOT1DEC1	13.13
DENS65I	99.03	ORTH00	98.97	OPENDEC1	74.21	GGCFD3	72.88	DENS60	13.46
SQPI6090	99.16	GEEREC1	99.09	FERTLDC1	75.33	OIL	75.97	BRIT	13.70
DENS60	99.28	GGCFD3	99.40	GGCFD3	79.82	GDPCH60L	79.69	GGCFD3	15.29
LHCPC	99.30	LT100CR	99.40	TOT1DEC1	80.09	DENS60	79.72	ECORG	16.27
POP6560	99.31	AVELF	99.40	TOTIND	80.26	H60	84.49	NEWSTATE	19.05
ABSLATIT	99.34	WARTORN	99.47	OTHFRAC	82.18	ORTH00	85.24	PI6090	19.80
ORTH00	99.39	TROPPOP	99.47	MINING	83.82	EUROPE	88.07	LHCPC	20.29
PRIGHTS	99.49	YRSOPEN	99.55	H60	86.64	SQPI6090	88.39	LT100CR	20.46
POP1560	99.53	CIV72	99.58	WARTIME	88.78	PI6090	88.54	EUROPE	24.36
COLONY	99.55	DPOP6090	99.58	PI6090	89.06	GEEREC1	89.76	SOCIALIST	24.90
LIFE060	99.62	LANDAREA	99.61	POP6560	91.08	SCOUT	90.90	GEEREC1	28.34
GDE1	99.71	WARTIME	99.64	BRIT	91.68	DENS65I	91.59	PRIGHTS	29.72
EUROPE	99.73	LIFE060	99.65	WARTORN	92.03	LT100CR	91.92	WARTORN	33.79
HERF00	99.75	GOVSH61	99.72	DENS65I	92.22	HERF00	93.18	ZTROPICS	35.35
TOT1DEC1	99.81	GOVNOM1	99.75	ORTH00	94.48	CATH00	94.30	AIRDIST	36.71
ENGFRAC	99.81	LANDLOCK	99.82	LANDLOCK	94.98	LANDAREA	94.83	WARTIME	38.37
H60	99.86	SQPI6090	99.83	LANDAREA	96.96	BRIT	95.28	SQPI6090	39.28
NEWSTATE	99.87	ECORG	99.92	HERF00	97.01	WARTORN	95.44	GDE1	39.35
LAAM	99.93	ABSLATIT	99.93	GEEREC1	97.57	MINING	95.44	LANDAREA	43.41
WARTIME	99.95	OTHFRAC	99.94	POP1560	98.31	POP60	96.58	ABSLATIT	50.92
LANDLOCK	99.98	P60	99.95	POP60	99.10	POP1560	99.13	HINDU00	50.93
FERTLDC1	99.98	SAFRICA	99.96	CATH00	99.46	POP6560	99.17	LANDLOCK	53.22
AIRDIST	99.98	SOCIALIST	99.99	LT100CR	99.56	SIZE60	99.56	SCOUT	65.56
LT100CR	99.98	BRIT	99.99	OIL	99.93	WARTIME	99.60	OIL	86.66
LANDAREA	99.99	REVCOU	100.00	LHCPC	99.95	LHCPC	99.93	MUSLIM00	88.85
TOTIND	99.99	MUSLIM00	100.00	SQPI6090	99.97	GOVNOM1	99.98	POP6560	89.61
CATH00	100.00	FERTLDC1	100.00	GOVNOM1	99.98	LANDLOCK	100.00	HERF00	98.74

注：每种方法对应变量按照非线性性从小到大排序；变量右侧数字表示其非线性性程度，单位为百分比，依照正文 (7) 式的辅助回归进行测算

B.3. 前十变量预测非线性性图示

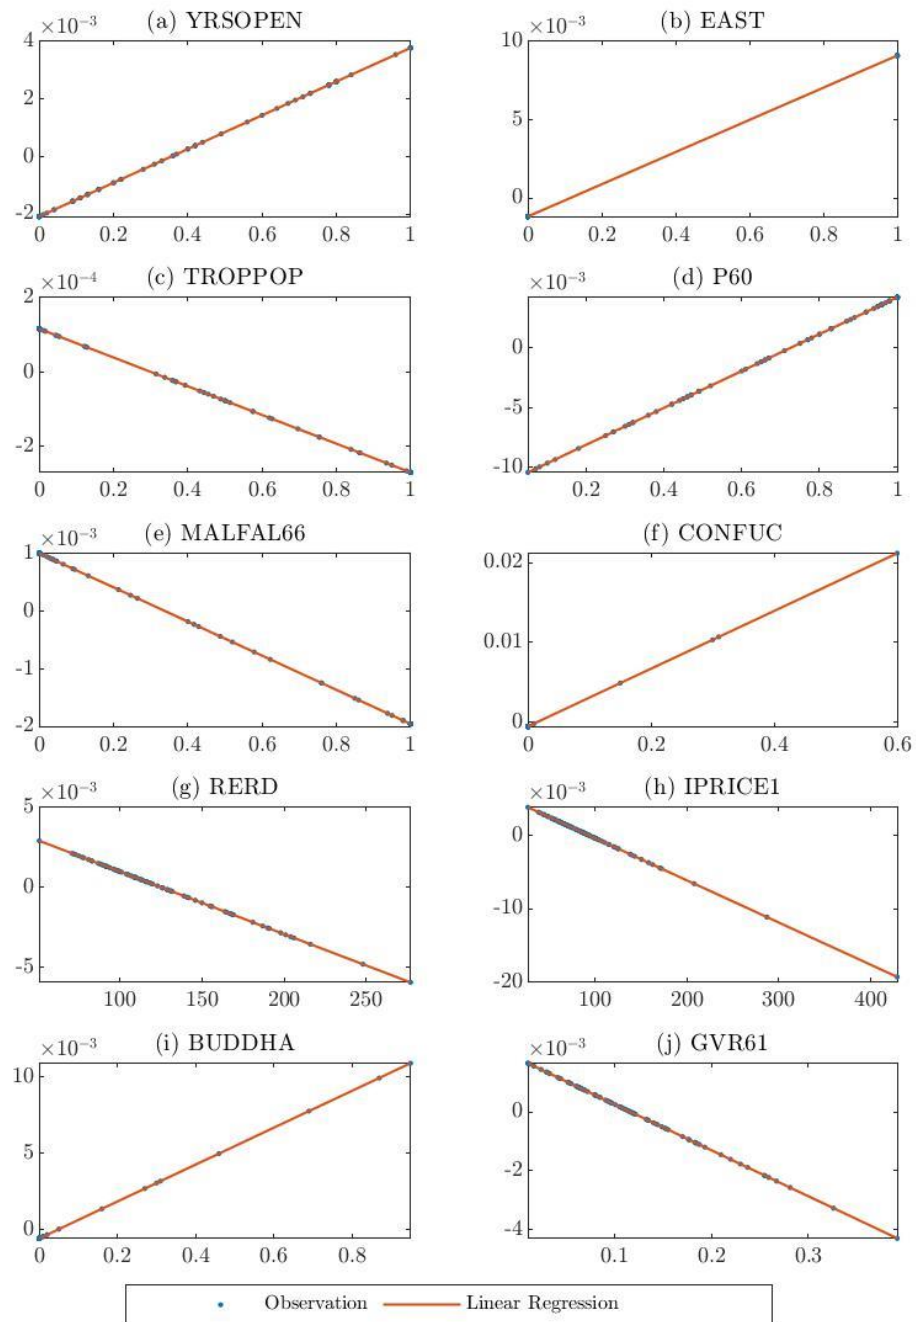


图 B1: LASSO 方法下变量预测非线性性及趋势特征

注: 图中蓝色圆点代表该样本点处的变量 k 对推测值的贡献 $\Delta \hat{y}_{[k]}$

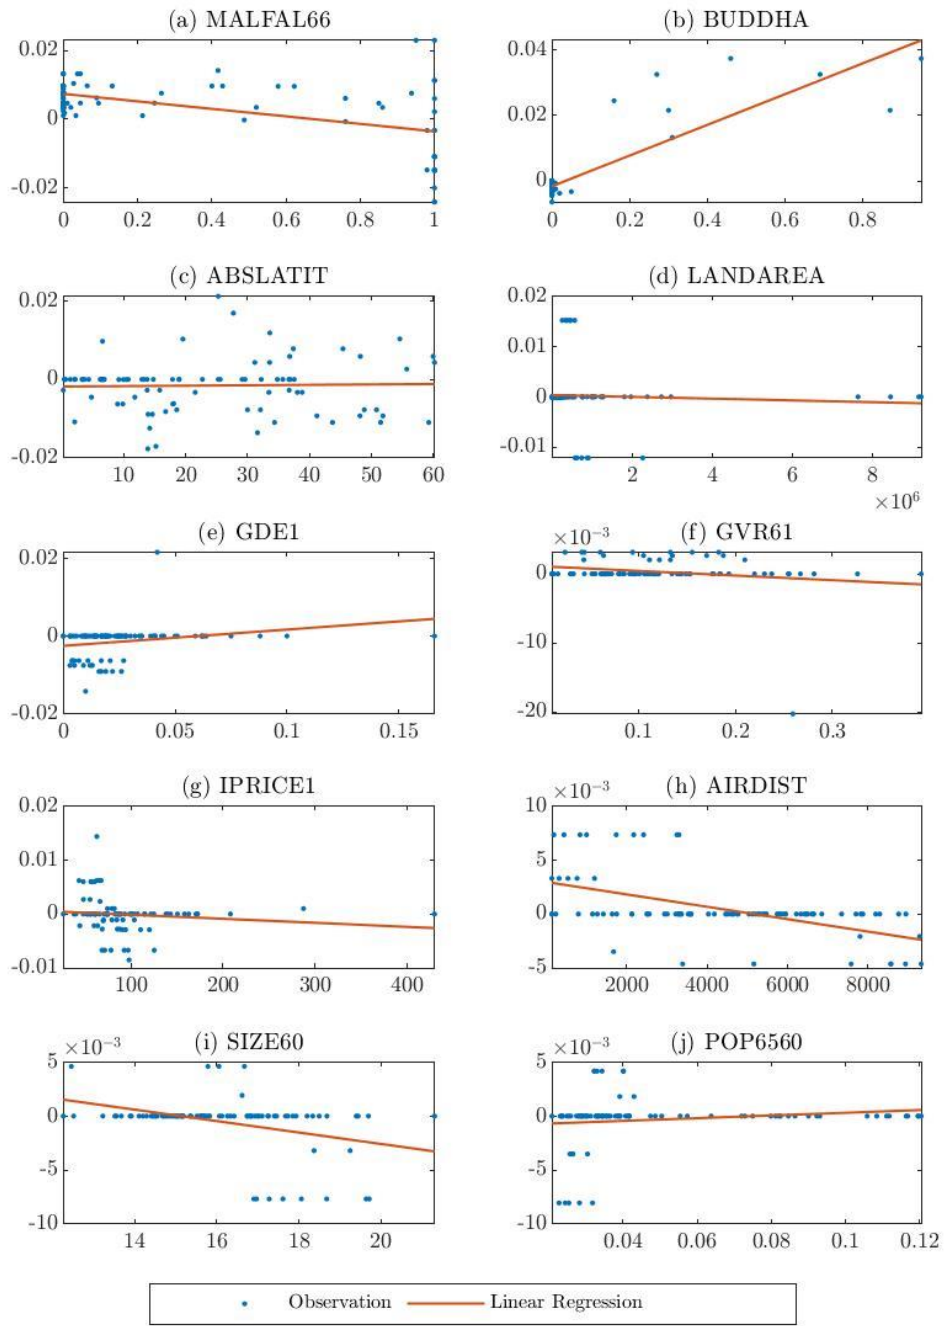


图 B2: 回归树方法下变量预测非线性性及趋势特征

注: 图中蓝色圆点代表该样本点处的变量 k 对推测值的贡献 $\Delta\hat{y}_{[k]}$

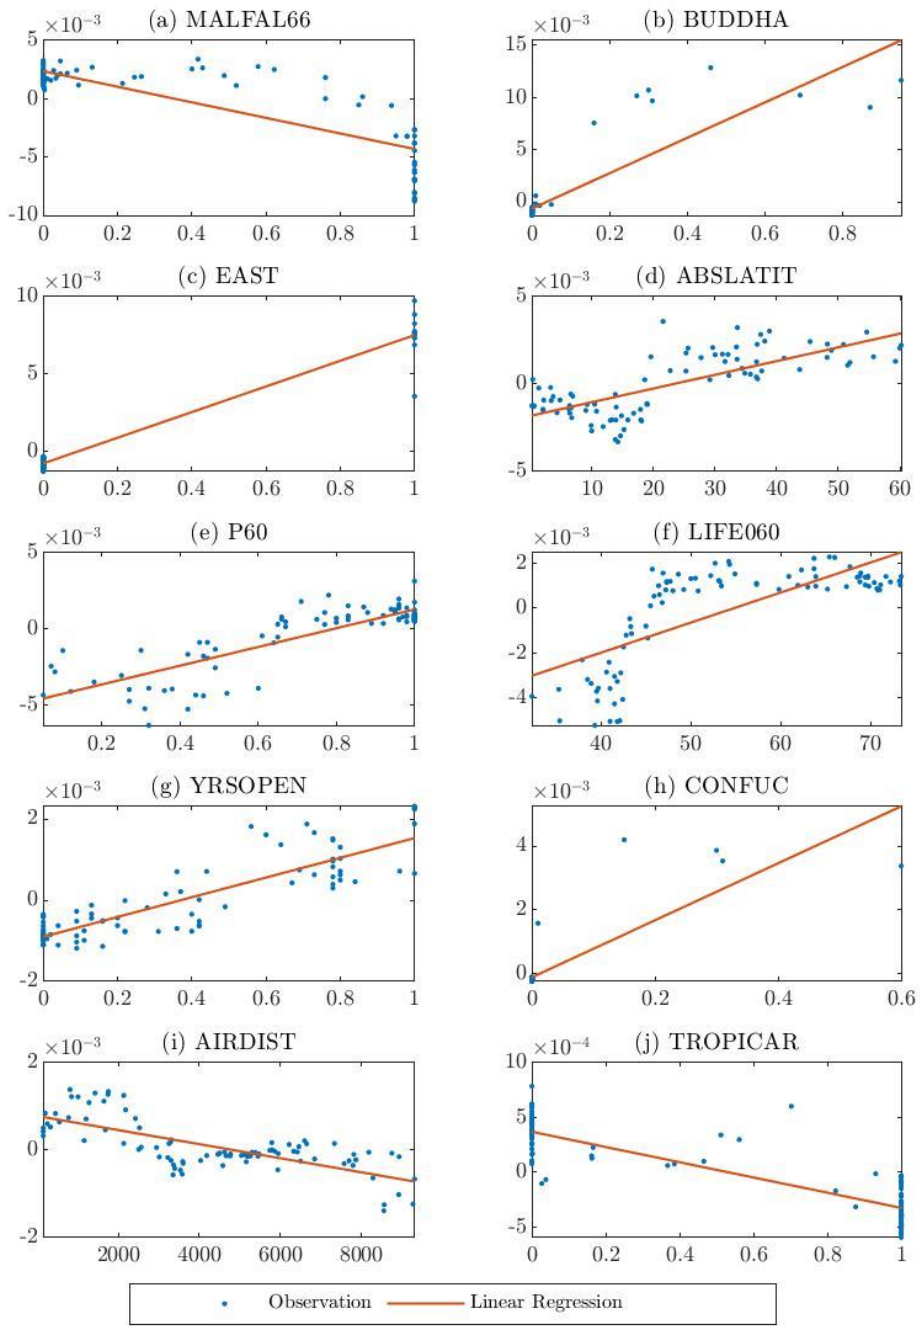


图 B3: 套袋法方法下变量预测非线性性及趋势特征

注: 图中蓝色圆点代表该样本点处的变量 k 对推测值的贡献 $\Delta\hat{y}_{[k]}$

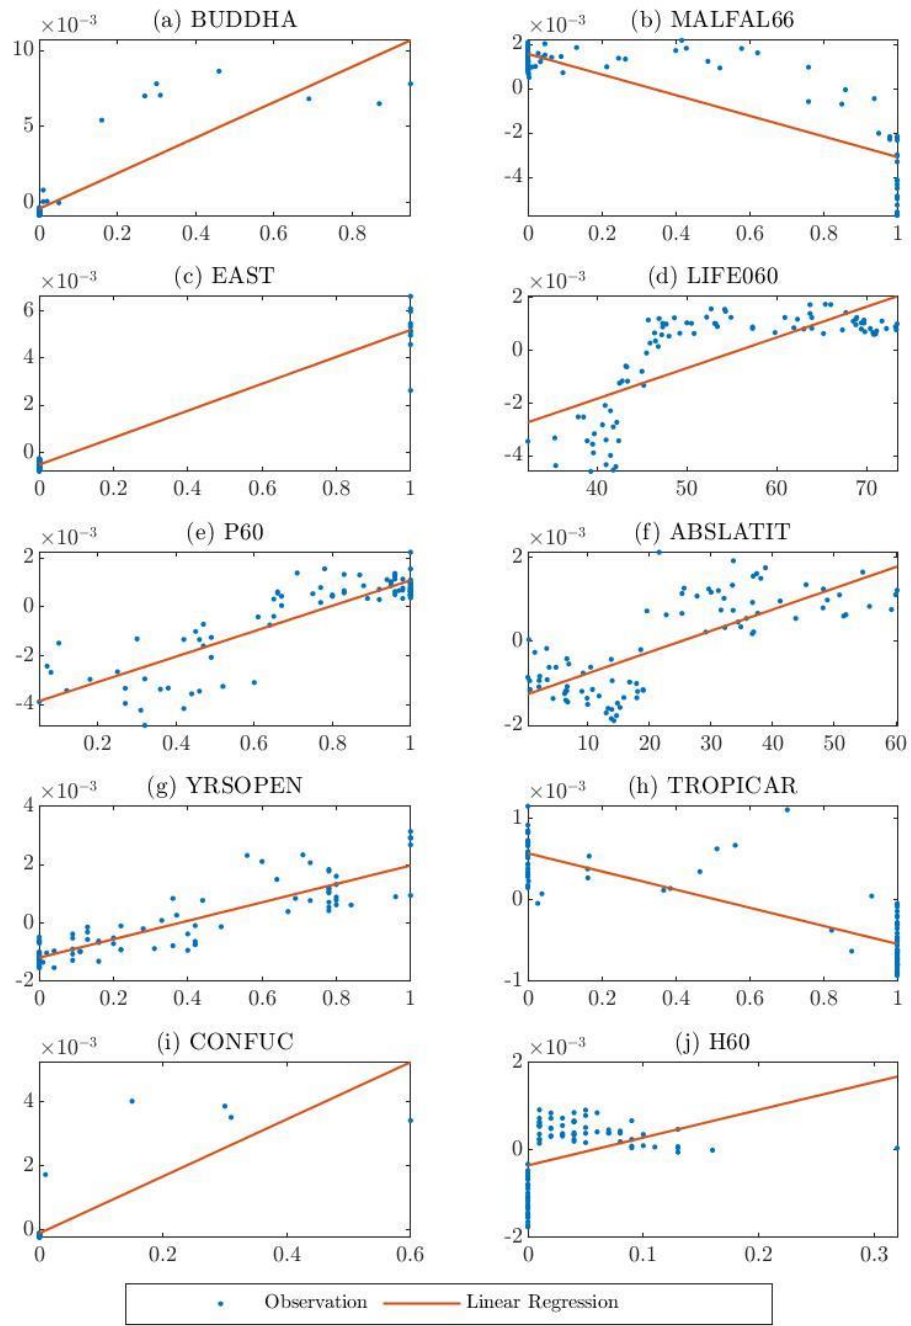


图 B4: 随机森林方法下变量预测非线性性及趋势特征

注: 图中蓝色圆点代表该样本点处的变量 k 对推测值的贡献 $\Delta\hat{y}_{[k]}$

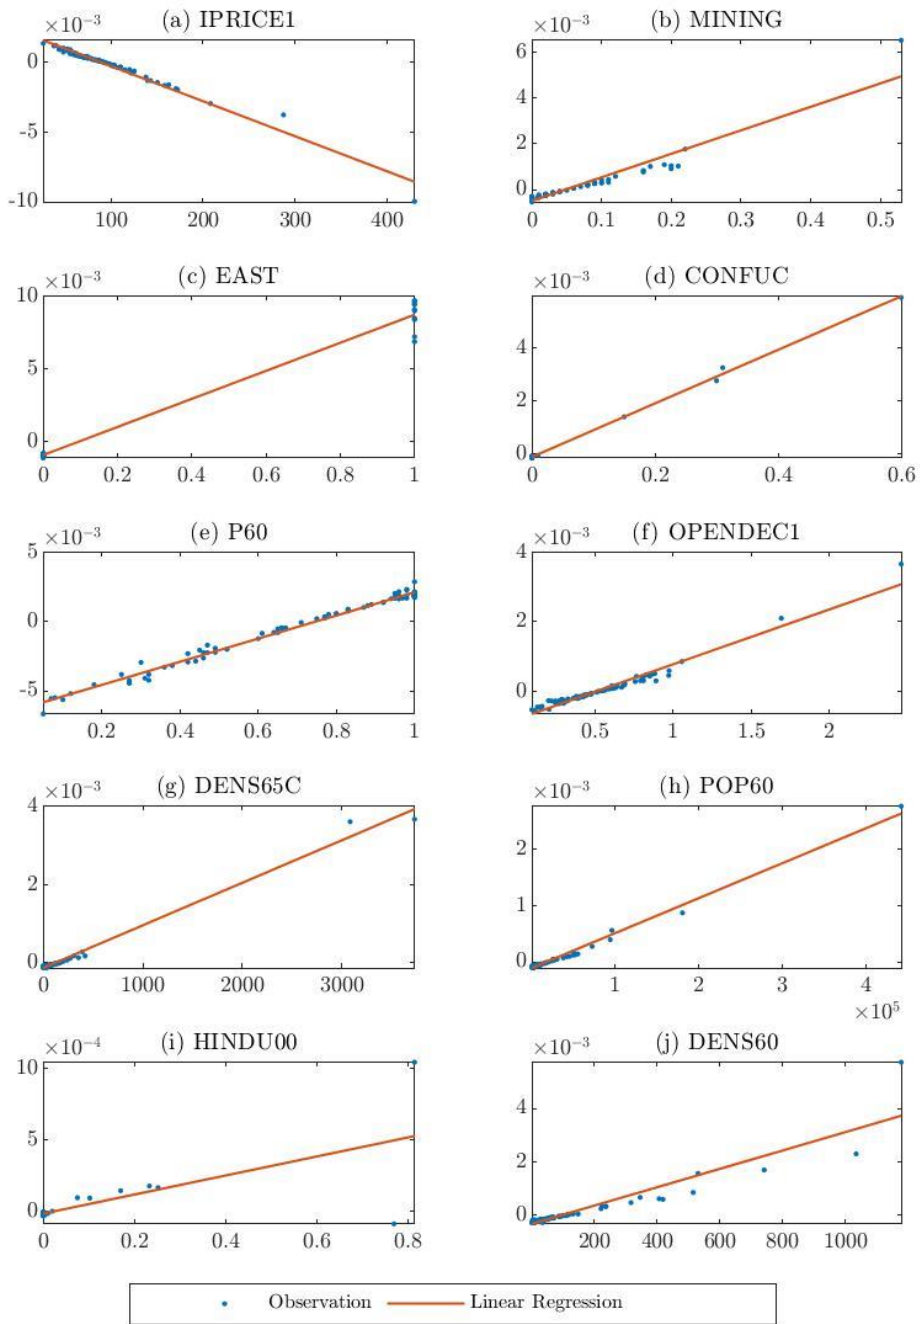


图 B5: 神经网络方法下变量预测非线性性及趋势特征

注: 图中蓝色圆点代表该样本点处的变量 k 对推测值的贡献 $\Delta\hat{y}_{[k]}$