机器学习方法与企业管理研究的融合：回顾与展望*

方 帅[1] 刘 知[2] 程雨涵[3] 李子璇[4]

（1.中国地质大学（北京）经济管理学院，北京 100083；
2.北京大学光华管理学院，北京 100871；
3.山东大学管理学院，山东 济南 250100；
4.中央财经大学金融学院，北京 102206）

内容提要：机器学习方法的引入对企业管理学者理解现象和构建理论带来的挑战与机遇并存。然而，目前学者们对于机器学习方法如何与既有研究范式相融合以赋能企业管理研究还缺乏系统和深入的理解。在对2000—2022年企业管理领域国内外顶尖期刊上发表的116篇文献进行梳理的基础上，本文识别了机器学习方法和企业管理研究相融合的四个阶段；介绍了有监督机器学习、无监督机器学习和强化学习三种技术在企业管理研究领域的应用中涉及的研究主题和存在的优劣势；阐释了机器学习为何适合及如何赋能理论构建和检验，进一步讨论了基于机器学习的溯因推理如何与传统的归纳推理及演绎推理协同互补，促进数据中稳健模式的识别，并利用混合方法推动理论的构建与检验。最后，本文以高管团队深层特征、战略管理、数字创新三个话题为例，展望了经典和前沿研究主题如何运用机器学习方法进行拓展和革新，并结合机器学习技术的进展预测如何进行跨学科借鉴。本文期待启发中国学者运用机器学习方法跨越研究范式，运用混合方法理解和解释现象，用突破性思维促进中国情境管理研究的理论创新，为中国企业管理实践提供理论支撑。

关键词：机器学习 企业管理 理论构建 范式跨越 混合方法

中图分类号：C93；F272 **文献标志码：**A **文章编号：**1002—5766（2025）03—0183—26

一、引 言

随着信息技术的高速发展，非结构化数据的价值越来越引起社会科学研究者的关注。相比于结构化数据，非结构化数据（比如文本、图像、视频等）体量更大，包含更多的信息，形式更加灵活、复杂。在企业管理领域，如何更好地挖掘和利用这些非结构化数据，赋能现象识别、构念测量、关系分析和理论构建与创新，需要与这类数据特质相匹配的新的分析方法。

然而，目前企业管理领域的大多数研究倾向于运用以回归为代表的传统计量经济学方法或以案例为代表的定性研究方法进行理论构建和检验。而这些传统方法在帮助学者们应对理论与实证

收稿日期：2024-03-20

*** 基金项目：**国家自然科学基金面上项目“高管团队深层特征探索研究：认知、关系、价值观”（72372001）；中央高校基本科研业务费资助项目“基于科学的创新企业违规的驱动因素和机制研究”（2-9-2023-042）；山东省泰山学者人才项目（tsqn202408061）。

作者简介：方帅，男，讲师，管理学博士，研究领域为人工智能在管理学中的应用、创新管理、企业治理等，电子邮箱：fangshuai@pku.edu.cn；刘知，女，副教授，博士生导师，管理学博士，研究领域为认知模式、领导者特征与行为、创造力与创新等，电子邮箱：lz@gsm.pku.edu.cn；程雨涵，男，助理教授，经济学博士，研究领域为人工智能在经济学中的应用、大型语言模型等，电子邮箱：chengyuhan@sdu.edu.cn；李子璇，女，研究助理，研究领域为机器学习与大语言模型，电子邮箱：lizix_x@163.com。通讯作者：刘知。

上的一些问题和挑战时呈现出了一定的局限性。例如，在现象解释方面，面对同一现象时，学者们有时会提供不同的甚至是竞争性的理论解释，究竟哪一个理论对现象有更强的解释力却无法得到较好的解答。即便在同一个理论视角下，针对解释变量和被解释变量之间的关系，学者们有时也会得到不一致的结论（正向、负向、无影响或非线性），结论的可靠性难以得到证实。在构念测量方面，由于传统企业管理研究中的某些构念难以量化，导致难以对理论上与该构念相联结的关系加以检验。在定性研究上，由于案例数量有限，所构建的理论外部效度较低，难以推广到其他情境中。

机器学习方法作为一种新的分析方法，以其独特的优势为弥补企业管理领域传统研究范式和方法的局限性提供了可能。例如，机器学习方法可以助力学者对海量的非结构化数据进行分析，揭示基于传统分析方法的不同研究所发现的自变量和因变量之间的不一致关系（如正向、负向、无关）中哪种关系更为可靠。机器学习方法还可以比较不同解释性模型对现象的解释能力，进而拓展解释模型背后所依赖的理论。另外，机器学习方法擅长从非结构化数据中提取有用信息帮助进行构念测量，同时也能采取更灵活的函数形式提升模型拟合效果，更精准地捕捉复杂概念间的理论关系，发现更稳健的规律和模式（刘景江等，2023）[1]。

但是，随着基于机器学习方法的管理研究快速涌现，学者们一方面对机器学习方法有了更多的了解和更广泛的应用，另一方面也产生了许多困惑与争论。核心议题之一即机器学习方法对企业管理理论构建的影响。有学者认为，机器学习方法的前景巨大，将使理论变得过时（Anderson，2008）[2]。其主要逻辑是，数据量的增加，加上前沿技术本身，可以让数据自动说话，从而摆脱了理论的束缚。科技领域的权威杂志 Wired 曾刊发题为“理论的终结：数据洪流使科学方法过时”的文章，宣称在机器学习的新时代，即使没有一致的模型、统一的理论，科学仍然可以取得进展（Anderson，2008）[2]。有些学者则对机器学习运用持更为谨慎的态度，提醒学者们认识到独立使用机器学习方法的局限性（Leavitt 等，2021）[3]。机器学习算法可以从数据中识别模式，但通常无法解释为什么该模式会发生，无法分辨这种模式能否以及如何推广到更广泛的情境中，也无法对数据之外的构念提出假设关系。鉴于机器学习方法的局限性，一些学者认为，机器学习方法无法颠覆传统的研究范式，而是与传统研究范式发挥协同作用（Leavitt 等，2021）[3]，推动企业管理学者走出孤岛并与不同的研究方法互动。

机器学习方法在国内管理研究中的应用还处于初期阶段。根据刘景江等（2023）[1]的检索，国内管理期刊上机器学习的研究约为国际管理期刊上的十分之一。洪永淼和汪寿阳（2021）[4]的研究是国内具有开创性、被引用较多的 1 篇文献，探讨了在大数据时代机器学习如何改变社会科学的实证研究方法。在此基础上，国内一些学者开始系统介绍与梳理机器学习方法在经济管理研究中的应用，但多集中于经济学、工商管理和财务会计领域（郭峰和陶旭辉，2023[5]；刘景江等，2023[1]；王芳等，2020[6]）。此外，这些文章更多地关注机器学习在技术层面的应用及其优势，例如，与传统方法相比，机器学习在匹配样本、断点回归、双重差分和工具变量等方面可以有力提升因果推断能力。然而，一项技术的先进性固然重要，但作为一个工具，如何推动研究领域的发展并赋能理论构建或更为重要。因此，要充分发挥机器学习方法的潜能，助力管理研究的发展，还需要对其有更为系统和深入的了解。具体而言，有以下几个关键问题：第一，机器学习有哪几种主要的方法或技术，其底层逻辑是什么，与演绎和归纳的逻辑范式有何关联？第二，机器学习方法目前主要应用于企业管理研究中的哪些领域和哪些主题？在不同领域和主题中的应用目的和赋能方式是怎样的？第三，机器学习和理论构建到底是什么关系？如果机器学习不是对理论的颠覆，与传统范式也不是竞争关系，那么机器学习方法如何才能助力企业管理学者进行理论构建？机器学习方法如何赋能演绎推理方法，如何赋能归纳推理方法，最终如何与这两种方法相结合以发挥混合方法的优势？第四，机器学习方法未来如何更好地应用到企业管理研究的经典和前沿研究主题中，从而促进对中国管理现象的了解和中国管理理论的发展？

鉴于此，本文对过往 20 多年间发表于国内外顶尖管理学期刊的文献进行了系统梳理和分析，发

现机器学习方法与企业管理领域文献的融合经历了四个阶段。国外学者的研究主题包括创新创业、员工离职、消费者行为等，利用机器学习进行变量测量、回归预测再到理论构建；而国内文献的研究主题主要集中在创新领域，且主要利用机器学习方法进行技术创新能力评价指标的构建，较少尝试利用机器学习方法赋能理论构建。在此基础上，本文聚焦于以下四个方面展开研究：第一，对机器学习不同方法的特征和逻辑进行论述。本文按照有监督机器学习、无监督机器学习和强化学习的分类，识别出这些方法在企业管理研究中的不同应用情境和应用目的，并分析每种方法的技术逻辑及其与传统的演绎推理和归纳推理逻辑的相似与关联，探讨机器学习方法如何为跨范式的混合方法应用提供技术支持（Leavitt 等，2021）[3]。第二，将分析的文献范围聚焦到“企业管理”领域。本文梳理了国内外期刊在这个领域中的关键研究主题，以及中外学者在不同主题上对机器学习方法的应用，以识别研究的特点、差异与空缺。第三，对机器学习方法如何赋能理论构建进行充分论证。本文提出机器学习方法是溯因推理的典型方法之一，能够弥补演绎推理方法和归纳推理方法；机器学习方法可以作为一种工具来测试和构建中程理论（midrange theory），并作为一种催化剂来扩大理论所能解释的范围；机器学习方法可以缓解不同范式之间的认知冲突，可以与其他方法相混合，提供跨越范式的技术路径和理论构建。第四，从研究主题和技术发展两个方面对机器学习方法如何助力企业管理领域的研究做出展望。以高管团队深层特征、企业战略管理研究和数字创新研究三个方面的研究主题为例，预测了机器学习技术如何推动企业管理经典和前沿研究课题的发展。此外，本文还提出，企业管理研究可以进一步借鉴机器学习方法在经济、金融领域的应用，将机器学习应用在企业管理研究的变量测量、回归预测、非线性降维、特征筛选和因果推断等方面。本文期望帮助中国学者更有效地将机器学习方法纳入理论构建中，通过不同学科的混合方法理解和解释现象，挑战和弥补既有的实证主义范式，用突破性思维促进中国情境管理研究的理论创新。

二、文献检索与分析

本部分对企业管理领域中涉及机器学习的研究进行检索和梳理，主要有两个目的：一是梳理机器学习与企业管理研究相融合的发展过程，即从时间的角度理解该方法如何逐步进入企业管理研究，以及各阶段的特征；二是在简要介绍机器学习主要技术类别的基础上，梳理不同技术在不同企业管理研究主题中的应用状况，即从研究主题的角度理解在哪些领域有较多或较少的应用、应用的方式和解答的主要问题有哪些。

1.文献检索策略

本文聚焦于“企业管理”领域文献。在我国的学科分类目录中，“企业管理”是二级学科，包括企业战略管理、市场营销、组织行为、人力资源管理、组织科学等方向。德克萨斯大学达拉斯分校（简称 UTD）列出的 24 本国际管理学顶级期刊覆盖了 6 个研究领域，其中工商管理领域（如 Academy of Management Journal）和营销领域（如 Journal of Consumer Research）包含的研究方向与国内二级学科“企业管理”基本一致。因此，本文的文献研究范围聚焦在“企业管理”领域，这与本文的研究目的也是匹配的。

对于英文文献，本文使用“主题”选项在 Web of Science 核心合集数据库进行检索，语种限定为英文，文献类型限定为“article”，时间窗口为 2000—2022 年。在企业管理类权威期刊上，使用 machine learning 等检索词进行检索①。为防止遗漏重要文献，本文还利用 google scholar 进行补充检

① 使用的检索词包括：machine learning，deep learning ，random forest ，neuron network，tree models，GBDT，lasso。检索的企业管理类权威期刊包括：Administrative Science Quarterly，Academy of Management Journal，Strategic Management Journal，Academy of Management Review，Organization Science，Journal of International Business Studies，Journal of Marketing，Journal of Marketing Research，Marketing Science，Management Science，Research Policy，Journal of Management Studies，Journal of Management，Entrepreneurship Theory and Practice，Journal of Business Venturing，Strategic Entrepreneurship Journal，Journal of Business Ethics 等。

索，挑选出代表性的经典文献和前沿文献。

对于中文文献，本文在中国知网上使用“主题词”选项进行检索以最大范围覆盖文献，时间窗口是2000—2022年。使用的主题检索词包括：机器学习、深度学习、随机森林、神经网络、树模型、集成学习、套索。检索范围包括《管理世界》《管理科学学报》《南开管理评论》等十三种权威期刊。

经过筛选和补充，本文获得符合要求的文献116篇，其中英文文献66篇，中文文献50篇。如图1所示，无论是中文文献还是英文文献，国内外一流期刊上发表的与机器学习相关的企业管理类文献数量随年度呈现出明显的上升趋势，尤其2019年之后的研究成果数量较过往年份明显增加。

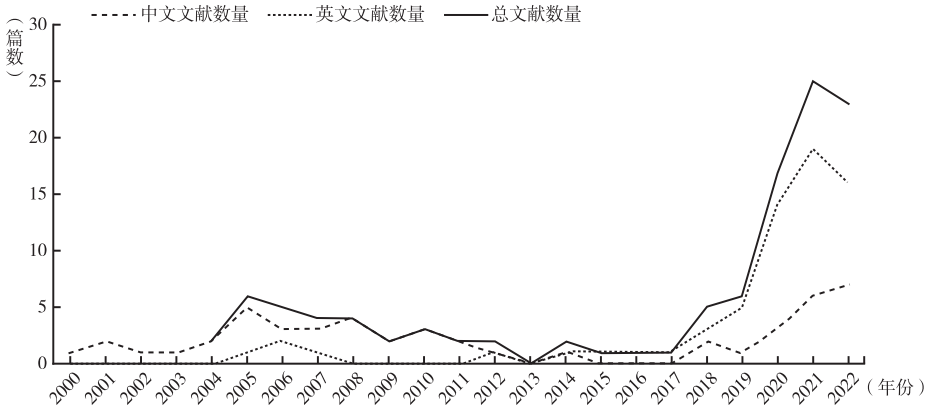

图1　2000—2022年应用机器学习的企业管理文献分布

2.企业管理研究应用机器学习的发展过程分析

按时间对搜索到的文献进行整理，可以发现机器学习技术在企业管理研究领域中的应用过程大致可分为四个阶段。本文描述了各个阶段的时间、背景、机器学习技术在企业管理研究中助力解决的核心问题和应用案例（如图2所示）。

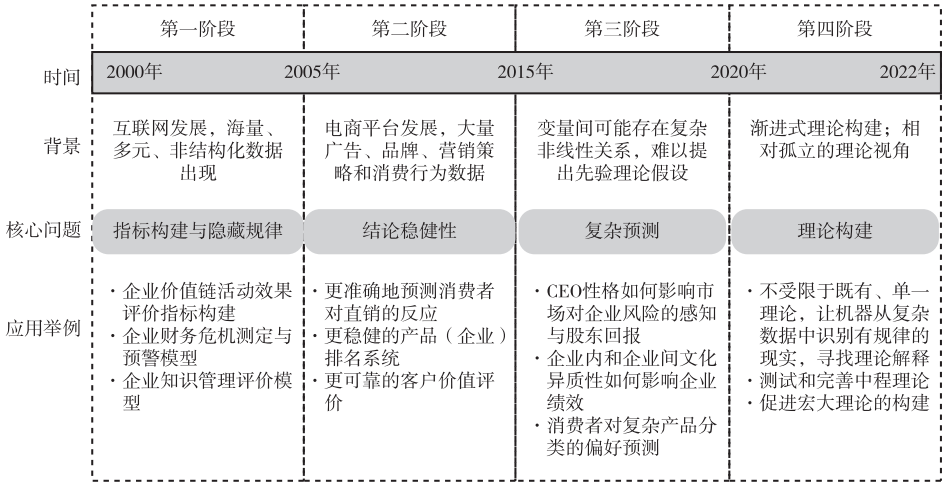

图2　企业管理研究应用机器学习的过程

第一阶段主要关注“企业管理研究中的指标构建与隐藏规律问题”（大约2000—2005年）。在进入“千禧年”后，随着数字基础设施的建设和社会网络需求的充分释放，产生了实时发生、体量大、类型多元化和信息密度低的大数据。如何从数据中找寻隐藏的规律进而构建相应的指标成为企业管理学者关注的新焦点。然而，受制于一系列苛刻的先验假设条件，传统的企业管

理研究方法在面对海量、复杂、高维、非结构化的数据时，较难发现其中隐藏的规律和模式。在这一背景下，学者们开始呼吁利用新技术弥补传统研究方法在大数据面前的短板。例如，魏一鸣等（2000）[7]在《南开管理评论》上呼吁将遗传算法、模糊逻辑、人工神经网络等方法应用到经济管理课题研究中。一些学者逐步将机器学习方法用于构建评价指标以评估企业价值链活动效果。例如，为了测量企业技术创新活动带来的经济效益大小，刘友金和徐江容（2001）[8]运用神经网络模型构建了企业技术创新效果评价指标体系，对企业技术创新能力进行了评价和预测。

第二阶段开始关注“企业管理研究中的结论稳健性问题”（大约 2005—2015 年）。随着电商平台的崛起，消费者的购买行为发生了较大的变化。学者们开始关注企业在电商平台上投放的广告效果、品牌管理、营销策略以及消费者的购买行为，尝试优化机器学习技术，比较不同机器学习技术的预测效果，选出适合特定研究情境（比如电商情境）的技术，以期得到更加稳定可靠的研究结论。比如，为了研究新兴市场的营销环境，Cui 和 Curry（2005）[9]探讨了支持向量机（supportive vector machine，指起源于计算机科学的一种半参数技术）对结果的预测能力。Cui 等（2006）[10]为了模拟消费者对直销的反应，提出了一种贝叶斯网络方法，发现其与神经网络、分类和回归树等方法相比，在预测准确性、程序透明度、结果可解释性和解释洞察力方面具有明显优势。Ghose 等（2012）[11]通过搜集消费者的文本数据，勾勒出消费者在产品属性上的异质性偏好，运用机器学习模型设计了一种更稳健的酒店排名系统。刘承水和乞建勋（2005）[12]基于客户生命周期理论构建了一种新的客户价值评价指标体系，并运用神经网络方法进行客户价值评价，提高了评价结果的准确性，解决了企业在客户关系管理中面临的客户价值序位评价问题。

第三阶段进一步关注“企业管理研究中的复杂预测问题”（大约 2015—2020 年）。企业管理领域的大部分实证研究范式是预先提出变量之间的因果关系，并运用传统的计量模型进行验证。不同于传统的解释性模型，以机器学习为基础的预测性模型不受限于先验的理论假设，也不受限于变量之间特定的函数形式。因此，由于机器学习方法的独特优势，学者们尝试将机器学习这一新兴工具引进到企业管理的实证研究中，以期为企业管理研究中的传统问题提供新的或更为全面的解答。一些学者运用有监督机器学习解决特征变量到结果变量的预测问题，以应对变量之间复杂的非线性和交互关系。例如，Harrison 等（2020）[13]探讨了 CEO 的性格特征如何影响市场对企业风险的感知，继而如何影响股东回报。也有一些学者将有监督机器学习应用于分类问题研究。例如，Huang 和 Luo（2016）[14]运用模糊支持向量机从数据中识别复杂的模式，并对产品类别进行区分和预测。另外，一些学者运用无监督机器学习方法从复杂、高维、非结构化的数据中生成难以观测的变量。例如，Corritore 等（2020）[15]运用主题建模的方法研究了企业内和企业间文化异质性如何影响企业绩效表现。

第四阶段主要关注“企业管理研究中的理论构建问题”（大约 2020—2022 年）。揭露现象的本质、发生的原因、过程机制、发生的情境条件等理论化过程，是企业管理领域学者的核心工作。在该阶段，学者们开始思考机器学习方法如何助力理论构建和理论检验。例如，Leavitt 等（2021）[3]开创性地提出，机器学习和理论构建不是竞争关系，机器学习方法有可能推动学者走出相互孤立的研究领域，不再局限于渐进式理论构建。机器学习方法不仅可以测试和完善中程理论，即针对特定情境下迫切需要解决的实际问题而发展的局部理论，也可以促进适用于不同情境和时间的宏大理论（grand theory）的构建。机器学习方法在企业管理的实证研究中，不受限于先验理论的限制，不预先提出假设，从复杂现实中归纳提取规律和模式，拓宽了学者的研究视角和思路，帮助学者比较不同理论对现实的解释力，从而为构建新的理论铺垫

基础。展望未来，学者们还将在机器学习方法如何赋能企业管理理论构建的问题上不断探索。

三、企业管理研究中机器学习技术的分类及应用

1.企业管理研究中主要的三种机器学习技术

根据过往文献对机器学习方法的应用，可以将机器学习技术的应用分为三大类：有监督机器学习、无监督机器学习和强化学习。如表1所示，本文详细列举了这三类方法所应用的研究主题和代表性中英文文献。在116篇文章中，大部分文献运用的是有监督机器学习方法（68.97%）和无监督机器学习方法（21.55%），强化学习方法（1.72%）在企业管理研究中的运用还在起步阶段。

（1）有监督机器学习。有监督的机器学习算法是在训练数据集上对已知的输入（解释变量）和输出（被解释变量）之间的关系进行训练，从而得出一个最优模型，并对新的数据集进行预测。用来训练的数据集是一个有标签的数据集，包含多个特征和一个标签（label），即多个解释变量和一个被解释变量。通过训练后的模型可以自己找到解释变量和被解释变量（标签）之间的关系，当面临一个新的数据集时，就可以运用解释变量预测未来标签（future label）。在企业管理研究中，运用到的有代表性的有监督机器学习技术主要包括梯度提升机（gradient boosting machine）、决策树（decision tree）、随机森林（random forest）、深度神经网络（deep-learning neural network）、模糊神经网络（fuzzy neural networks）等方法。

在企业管理领域，有监督机器学习算法在研究中的应用主要有三种用途：回归预测、样本分类和变量测量。首先，回归预测主要针对连续型变量问题，是指将解释变量作为输入来预测结果变量，识别出解释变量的相对重要性，也可比较不同解释模型对结果变量的解释力。相比于传统的计量模型，机器学习回归预测模型不预先假设残差的分布特点，也不假设变量之间的函数关系，不受变量之间多重共线性的影响，更擅长处理高维复杂的数据，能在样本外得到更好的拟合效果。例如，Tidhar和Eisenhardt（2020）[16]利用在线商城的产品信息构建了收益模型，对收益模型选择问题进行了预测。其次，样本分类主要针对离散型变量问题，是指根据预先设定的理论构念将不同的观测值进行分组，进而生成便于后续研究的分类变量。例如，Miric等（2023）[17]利用机器学习方法对非结构化的专利文本数据进行分类，并比较了有监督机器学习方法和传统的基于关键词词典方法的优劣，以及不同的有监督机器学习模型的优劣。最后，变量测量是指运用有监督机器学习方法从文本数据和图像数据中识别信息并将这些信息转换成数值形式，进而计算文本数据之间或图像数据之间的相似性。例如，通过CEO的发言文本，Harrison等（2020）[13]利用机器学习方法对CEO的个性进行了分类测量。

（2）无监督机器学习。与有监督学习相比，无监督机器学习更像是自学，是对无标记的训练数据集进行模式识别。无标记数据是指特征变量（即解释变量）已知，标签（即被解释变量）未知的数据集。例如主题建模，就是在没有任何先验理论构念存在的情况下，让机器自己识别文本数据或图片数据中蕴含的主要模式（Choi等，2021[18]；Choudhury等，2019[19]）。这种算法能够从无标记的样本中提炼出解释变量之间的内在关联，可以将高维、非结构化的数据降维至低维、解释性较强的数据。与有监督机器学习不同，无监督机器学习没有结果变量需要被预测，只有解释变量是已知的，其典型目标是从复杂的数据集中提取信息，有助于学者生成难以观测的变量。在企业管理研究中，运用到的有代表性的无监督机器学习技术主要包括K近邻聚类（k-nearest neighbor）、自组织映射神经网络（self-organizing map）、词嵌入（word2vec）、层次狄利克雷过程（hierarchical dirichlet process）、主题模型（topic model）等。

无监督机器学习在企业管理研究中主要用于解决变量难以测量的问题。例如，Bellstam 等（2021）[20]运用无监督机器学习方法处理大量分析师报告文本来测量企业创新。Choi 等（2021）[18]运用自然语言和主题建模技术从企业非结构化文本中测量了企业多元化程度，进而重新探讨了多元化和企业绩效的关系。

（3）强化学习。强化学习也不依赖有标签的数据集，而是从过去经历中进行学习，通过反复试验进行持续的自我训练。这种算法是基于惩罚和奖励机制进行的，当它作出正确的选择时会被奖励，做出错误的选择时则会被惩罚。整个机器学习的过程就是根据环境提供的信号判断行为策略的优劣，不断试错迭代出一个最优的行为策略。在企业管理研究中，强化学习技术包括基于价值的学习算法、多臂老虎机模型等。例如，Schwartz 等（2017）[21]使用多臂老虎机方法帮助广告公司判断哪种广告最为有效。

（4）机器学习技术的局限性。尽管机器学习在基于高维数据的预测、特征重要性识别等任务中表现优异，但也存在着可解释性不足、高度依赖数据质量和可用性等问题，具体表现如下。

第一，可解释性不足。机器学习模型的可解释性是指人们理解模型架构、模型学习过程以及模型决策依据等方面的难易程度。机器学习模型（特别是基于神经网络的深度学习模型）具有复杂的模型架构和大规模的参数，这一特性赋予了机器学习识别变量间复杂关系的能力，但同时也使模型的决策过程成为一个难以被观测和理解的“黑箱”。在管理学研究中，机器学习模型的可解释性是确保模型输出结果对管理实践具有指导意义的关键，然而机器学习的“黑箱”性质导致其输出的结果无法被有效解释和验证，例如机器学习模型无法解释求职者的浏览器选择为什么可以预测离职率和工作表现（Leavitt 等，2021）[3]，因此可解释性不足会在一定程度上制约机器学习决策结果在管理研究中的可信度和可靠性（Leavitt 等，2021）[3]。

第二，高度依赖数据质量和数据可得性。机器学习是纯粹的“数据驱动”方法，其基于训练数据来学习输入变量与输出变量之间的映射关系。这意味着机器学习的预测表现高度依赖训练数据的质量和可得性。然而，管理学研究常常遇到训练数据质量和数据可得性等问题，比如难以获取管理层个人价值观数据（方帅等，2024）[22]，这将削弱机器学习模型对输入和输出之间真实映射关系的拟合能力，从而制约了机器学习模型的样本外预测能力（Ying 等，2021[23]）。为了缓解这一问题，通过迁移学习方法可以提高机器学习模型在数据可用性和质量限制下的预测表现。

第三，易出现过拟合问题。机器学习模型的复杂性、数据质量及可得性不足等因素均会使模型更容易捕捉到训练数据中的特例和噪声，导致模型在新数据集上的预测表现不佳（Leavitt 等，2021）[3]。为了缓解这一问题，通过交叉验证、正则化等方法可以有效降低过拟合风险，提升模型的泛化能力。

综上可见，与其他技术或方法一样，机器学习也有其不可避免的局限性。因此，在管理学研究中应用机器学习的优势时，也应该充分认识到这些问题对结论解释和理论构建等的影响（刘景江等，2023[1]；Leavitt 等，2021[3]）。

如图 3 所示，本文直观地展示了企业管理研究应用机器学习技术的研究主题、主要技术分类、各项技术在管理研究中的用途和机器学习的局限性。

2. 企业管理研究运用机器学习探讨的主题

基于文献检索，本文总结了国内外学者应用机器学习技术探讨了哪些主题，以及机器学习技术如何帮助回答这些主题下的研究问题。如表 1 所示，以有监督机器学习和无监督机器学习为主的技术已被广泛应用于多元化的企业管理研究主题中，包括创业管理、创新管理、高管特质、客户关系管理、消费者行为、品牌管理、营销战略等。接下来本文以典型的、应用较为集中的几个研究

主题为例，分析学者们是如何运用机器学习技术来探讨研究问题的，以及国内外运用机器学习技术的研究目的和研究主题的差异。

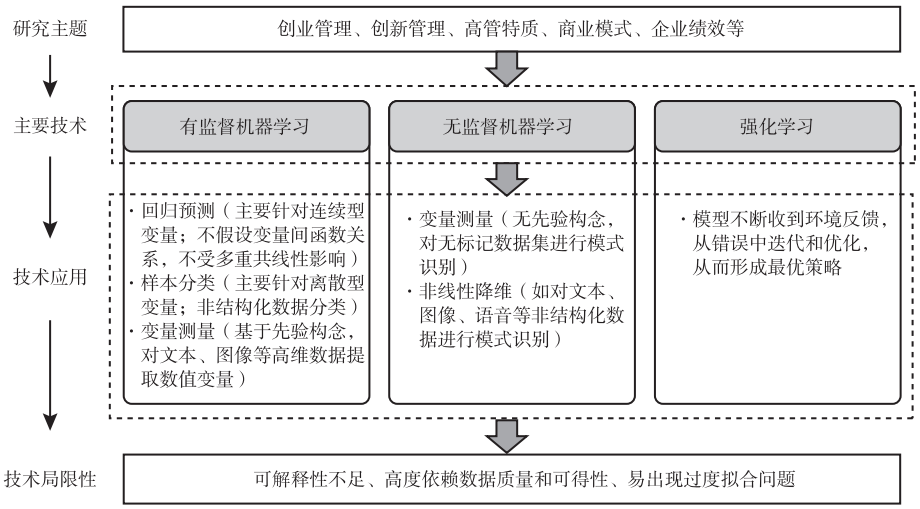

图3　企业管理研究对机器学习技术的应用概览

在创业管理主题上，学者们运用机器学习方法探讨了合法性以及创业失败的问题。比如，Vossen和Ihl（2020）[24]使用无监督机器学习方法来测量产品叙事与产品附带的文化意义之间的语义关系，研究结果显示，通过语义将产品叙事锚定在游戏产品类别特有的文化意义上，有助于减少缺乏合法性带来的损失。Williamson等（2022）[25]用有监督的机器学习方法对初创企业的论坛帖子进行分类，识别出创业者失望情绪的归因，探讨了这种归因和抑郁之间的关系。他们发现，相较于做出外部归因、不稳定归因和具体失望归因（例如，公司绩效）的发帖人，具有内部归因、稳定归因和全局失望归因（例如，不符合创业规范）的发帖人，平均而言患抑郁症的可能性较高。

在创新管理主题上，学者们运用机器学习方法探讨了创新来源和创新测量的问题。在知识推动的创新上，Furman和Teodoridis（2020）[26]利用无监督机器学习方法研究了一项自动化研究任务技术的引入如何影响研究人员知识产出的速度和类型。他们发现，微软Kinect系统的引入增加了创意的产生，并促使研究人员在不同领域运用更为多样化的路径进行创新。在消费者生成的创新上，Von Hippel和Kaulartz（2021）[27]利用机器学习方法筛选了网络上公开的用户生成内容，归纳出26种消费者开发的创新。也有一些学者聚焦于创新的测量，例如，Bellstam等（2021）[20]基于标准普尔500公司的分析师报告文本，运用机器学习方法重新测量了创新。该测量方式不仅适用于有专利和研发投入的企业，也适用于无专利和研发投入的企业。对于没有专利的企业，该方法识别了采用新技术和创新业务实践的创新型企业。对于有专利的企业，基于文本的创新测量指标与专利的质量呈现正向的强相关关系。

在高管特征主题上，学者们运用有监督机器学习探索了CEO人格特点、CEO沟通风格、CEO情感及其对企业绩效的影响。首先，在高管人格特点上，Harrison等（2019）[28]对首席执行官的大五人格特质进行了测量，使用词嵌入方法（word2vec）从3，573位CEO的文本语料库中提取语言特征，使用产生的词向量建立回归模型，使用梯度提升机（gradient boosting machine）对这些模型进行了训练。进一步，胡楠等（2021）[29]采用机器学习技术构建了管理者短视主义指标，进而对研发支出的影响进行了实证检验。其次，在CEO沟通风格上，Choudhury等（2019）[19]利用先进的卷积神经网络算法对面部图像进行有监督的编码，识别出五种沟通风格，即“兴奋型”“严厉型”

“戏剧型”“喋喋不休型”和“忧郁型”。第三，在高管情感上，基于情感人工智能方法，Momtaz（2021）[30]运用公开的CEO照片中获取的面部肌肉收缩-松弛模式编码面部表情，识别出七种情感，即快乐、悲伤、惊讶、恐惧、愤怒、厌恶和轻视，并进一步将情感归类成正向和负向情感。为了回答究竟哪一种维度的高管特征更能预测企业绩效的问题，陆瑶等（2020）[31]研究了中国上市公司CEO和董事长的多维度特征对企业绩效的预测能力，发现高管年龄和持股比例对企业绩效的预测能力最强。方帅等（2024）[22]探讨了高管的深层次特征（价值观特征）对企业创新的影响，发现董事长和总经理在不确定性规避价值观与制度性集体主义价值观两个维度上对企业创新的影响是不同的。

值得一提的是，国内外文献运用机器学习技术研究企业管理领域的问题时，其探讨的主题和目的存在差别。国外文献中，应用了机器学习的研究主题和研究目的较丰富，有的使用机器学习方法从海量文本数据中提取关键信息进行变量测量，有的使用机器学习方法比较不同维度的解释变量对结果变量的预测能力，有的则是在机器学习识别的隐藏模式中发现理论方向、推动理论的构建。国内文献的研究主题则主要集中在创新领域，较少涉及其他研究主题。可能是由于我国近年来强调科技创新是高质量发展的新引擎，探索具有中国特色的自主创新发展道路，因此创新领域的研究较多，对机器学习方法的应用也集中出现在该领域。在机器学习的技术和应用上，国内文献主要是借助机器学习模型构建指标体系以评价技术创新能力、创新效果等，较少将机器学习方法应用到实证研究中进行理论检验或构建。比如，我国一些学者基于神经网络模型构建指标体系对企业技术创新能力进行了评价（刘友金和徐江容，2001）[8]。

表1　　企业管理领域运用机器学习的研究主题、方法类型和国内外代表文献

研究主题	使用的机器学习算法	英文代表文献	中文代表文献
创业管理	有监督机器学习	Williamson等（2022）[25]、Hyytinen等（2023）[32]	
	无监督机器学习	Vossen和Ihl（2020）[24]、Guzman和Li（2023）[33]	
创新管理	有监督机器学习	Von Hippel和Kaulartz（2021）[27]	刘友金和徐江容（2001）[8]、张方华（2006）[34]
	无监督机器学习	Furman和Teodoridis（2020）[26]、Bellstam等（2021）[20]	
高管特质	有监督机器学习	Harrison等（2019）[28]、Momtaz（2021）[30]	陆瑶等（2020）[31]、胡楠等（2021）[29]
	无监督机器学习	Choudhury等（2019）[19]	
商业模式	有监督机器学习	Tidhar和Eisenhardt（2020）[16]、Sen和Puranam（2022）[35]	
	无监督机器学习	Hollenbeck（2018）[36]、Dotzel和Shankar（2019）[37]	
企业/员工绩效	有监督机器学习	Li（2015）[38]、Choudhury等（2021）[39]	郭岚和张祥建（2007）[40]、胡健等（2009）[41]
	无监督机器学习	Choi等（2021）[18]	肖泽磊等（2008）[42]、肖泽磊等（2009）[43]
企业治理状况	有监督机器学习	Xu等（2023）[44]	

续表 1

研究主题	使用的机器学习算法	英文代表文献	中文代表文献
广告效果	有监督机器学习	Danaher 等（2020）[45]	
	强化学习	Schwartz 等（2017）[21]	
品牌管理	有监督机器学习	Hartmann 等（2021）[46]	
	无监督机器学习	Liu 等（2020）[47]、Dzyabura 和 Peres（2021）[48]	
消费者行为	有监督机器学习	Ghose 等（2012）[11]、Huang 和 Luo（2016）[14]	钱明辉和徐志轩（2019）[49]、刘逸等（2021）[50]
	无监督机器学习	Zhang 和 Luo（2023）[51]、Zhang 等（2023）[52]	
客户关系管理	有监督机器学习	Ascarza（2018）[53]、Padilla 和 Ascarza（2021）[54]	刘承水和乞建勋（2005）[12]、叶强等（2004）[55]
	无监督机器学习		罗彬等（2011）[56]、史达等（2020）[57]
营销策略	有监督机器学习	Homburg 等（2020）[58]、Ellickson 等（2023）[59]	
	无监督机器学习		高曦含和王锐（2021）[60]
企业资本分配	有监督机器学习	Nauhaus 等（2021）[61]、Blohm 等（2022）[62]	
员工离职	无监督机器学习	Choudhury 等（2021）[63]	

资料来源：作者整理

四、机器学习对理论构建的作用

前面两部分梳理和总结了机器学习在企业管理研究中的应用历程、应用的研究领域与主题、以及用到的具体方法和目的。尽管机器学习方法在企业管理研究上已经展示出其技术上的特点与优势，但一种方法或技术对研究更大的价值应该取决于其是否能推动理论的构建与发展。下面将结合机器学习的方法特点，分析其为推动理论构建的可能方式，尤其是与中程理论的结合，以及其所代表的研究范式如何与其他范式相互补充共同推进理论构建。

1.机器学习赋能理论构建的方式

理论构建涉及到现象本身是什么、为什么发生、在什么情境下发生等问题。在尝试解释现象“为什么”发生之前，至少要了解该现象的大致轮廓。也就是说，需要先揭示出实证规律（Helfat，2007）[64]。一系列揭示实证规律的证据可以提供对世界更广泛和更一般化的理解，这些实证规律被称为“程式化事实”（stylized facts）（Helfat，2007）[64]。例如，在战略组织领域，基于程式化事实构建理论尤为重要。该领域常常借用社会学、经济学等领域的理论视角解释现象。在面对同一现象时，不同理论视角的解释所关注的要素不同，经济学研究可能更关注经济因素，社会学研究可能更关注社会因素。不同理论视角的研究可能对相同现象提供不同的、甚至是竞争性的理论解释。这些相互冲突或竞争的解释本质上可以激发进一步的研究，但需要坚实的事实来支撑这些分析，以防止构建完全错误或者无关紧要的理论。

从事实和数据中进行理论构建的一个关键要素是“程式化事实”或者数据中的稳健模式

(Choudhury 等,2021)[63]。机器学习算法恰恰提供了理论构建所必需的这种事实。Shrestha 等(2021)[65]对机器学习方法如何赋能理论构建做了开创性探索,将运用机器学习方法进行理论构建的过程分为四个步骤。第一,样本拆分,即将样本随机分为两个子样本。一个子样本叫作可见或训练数据,通过其来训练和识别重要的预测变量或预测变量与结果变量之间的关系模式。另一个子样本叫作不可见或备用数据,通过其对预测变量或关系模式的准确度进行验证。第二,模式识别,即通过反复训练、验证和迭代,识别稳健的规律和模式。第三,理论解释,即基于机器学习发现的规律或模式,从不同视角寻找该模式的多种理论解释,选择并构建一个可以解释主要发现的理论。第四,理论检验,即从构建的理论出发,推导出新的假设,并在后续研究中对这一新产生的理论解释加以检验。从这一过程中可以看出,在通过机器学习算法构建理论的过程中,首先要进行模式检测或者"程式化事实"的识别,再进行理论归纳。

然而,研究人员尚未认识到机器学习技术从数据中构建理论的价值,这可能是因为过往文献认为机器学习算法只产生预测,但无法被有效解释。机器学习技术是一种算法支持的归纳方法,可识别出数据中隐藏的模式和规律(Shrestha 等,2021)[65]。这些模式可作为归纳理论化的关键要素。正如 Shrestha 等(2021)[65]所说,理论构建过程分为模式检测和模式解释,其中模式检测主要是由算法驱动,并借助机器学习技术完成。

借助机器学习技术完成的模式检测在理论构建中具备以下优点(Shrestha 等,2021)[65]。一方面,由机器学习算法完成的模式检测具有高度的跨主体可靠性,同时也适用于不同的研究样本。不同研究者使用的算法得到的结果高度相似。如果研究结论只是例外,只能在少数情况下发生,那么这种结论不会产生深远的影响,不会拓展知识的边界。然而,机器学习算法配备了正则化和交叉验证等程序,减轻了过拟合问题的发生,有助于研究结论在其他子样本中进行可重复的验证,有助于构建在样本外进行预测的具有一定普适性的理论。另一方面,机器学习算法进行的模式检测不受研究者理解的约束。构建的理论要兼顾预测准确性和可解释性。管理理论学者运用的模型往往是线性的,这主要是因为线性关系的优势在于可解释性。而机器学习算法不再受限于先前学者的理解,可以调整算法,在预测准确性和可解释性之间进行权衡。

综上可见,机器学习方法与目前企业管理领域的理论构建,既没有造成威胁,也不是竞争关系,而是可以对理论构建发挥补充与协同作用,为理论构建助力和赋能。一方面,机器学习方法可以促使一个领域的学者走出自己熟悉的研究领域,突破习惯的理论视角,与其他领域产生链接,促进了新理论的产生(Leavitt 等,2021)[3]。另一方面,机器学习方法还可以作为一种工具来测试和修建中程理论,即在特定情境下针对当下需要解决的实际问题而提出的局部理论;还能作为一种催化剂来扩大理论所能解释的范围(Leavitt 等,2021)[3]。

2.机器学习助力中程理论构建

中程理论是介于日常研究中较小但必要的操作性假设和包罗万象的、自成体系的、全盘系统化的统一理论之间的理论(Bourgeois,1979)[66]。较小但必要的操作性假设是对细节的详细描述,但缺乏更一般性的概括。统一理论又被称宏大理论(grand theory),超越了具体时空条件限制,但难以解释所观察到的具体现象(Leavitt 等,2021)[3]。介于两者之间的中程理论主要具备下面两个特性:一是与实际观察的资料密切相关,用于指导经验研究,可以通过经验研究进行检验;二是涉及有限的社会现象,通常包括几组有限的假定,并且可以通过逻辑推导从这些假定中得出能够经受实证检验的具体假设。比如,牛顿提出的物理学理论是属于大理论的范畴;组织科学的理论(比如组织学习理论)基本属于中程理论;实证研究经过演绎推理提出的假设属于较小的操作性假设(Bourgeois,1979)[66]。

中程理论的构建和检验面临的一些局限性需要新技术来解决。不同于物理科学等学科构建大理论，企业管理领域的研究常常是聚焦于企业行为（包括企业员工行为）的规律和特点，专注于构建中程理论（Bourgeois，1979）[66]。组织科学之所以重点发展中程理论，原因是涉及行为科学的研究领域尚未产生高度跨学科共识的构念。若忽略中程理论的构建，直接构建宏大理论，会带来一个严重的结果：大理论过于抽象，与实际观察之间的距离较远，无法比较不同的经验研究，甚至无法带来后续的经验研究（Bourgeois，1979）[66]。纵然中程理论在企业管理领域得到了较高的重视，然而几十年以来企业管理领域专注对中程理论的构建和发展，带来了以下问题：一是极端专业化和标准化使中程理论根深蒂固，不同理论之间缺乏交流，相互割裂，加剧了构念的冗余；二是一些理论的提出并未经过后续的实证检验，这些理论的准确性和完备性有待验证（Leavitt 等，2021）[3]。

机器学习技术的运用帮助中程理论缓解了局限性，拓展了理论的解释范围。Leavitt 等（2021）[3]认为机器学习有较大潜力解决中程理论构建和检验中遇到的问题。一是在理论检验中存在构念身份谬误（construct identity fallacy），即不同的理论对构念的命名是不一致的。在不同理论对涉及的构念进行命名时，对不同的现象却给予了相同的名字，对相同的现象却给予了不同名字。比如，学者们在研究高管团队成员之间的差异时，运用了不同的构念，比如多样性（diversity）、群体断裂带（group faultlines）、异质性（heterogeneity）等。这对构念效度的检验、理论的发展脉络、理论的比较、元分析等造成了障碍。一些学者开发了自然语言模型来处理构念身份谬误问题，有助于在文献梳理和元分析中更有效地整合文献、对相关理论进行梳理和检验（Larsen 和 Bong，2016）[67]。二是机器学习模型可以评估理论的准确性和完备性。在准确性上，机器学习方法可以处理高维、丰富的数据（比如图像和语言），精确地识别复杂构念之间的理论化关系，这些关系可能在过往的传统研究由于测量的困难并未得到检验（Leavitt 等，2021）[3]。比如，Choudhury 等（2019）[19]通过有监督机器学习对 CEO 在视频中的面部表情进行了编码，构建了 5 种沟通风格，并尝试揭开沟通风格与企业战略行为（比如并购）的关系。可见，机器学习方法通过测量 CEO 沟通风格，捕捉了高管个人身上难以观察的深层特质（比如性格、价值观和人格特质），从实证上进一步检验了高阶理论的准确性。在完备性上，机器学习方法可建立一个最佳可预测水平的基准（Leavitt 等，2021）[3]。通过比较解释性理论模型与机器学习模型的方差，可以知晓在现象或问题的解释上理论还存在多大的提升空间。比如，为了探讨不同特质和情境对领导有效性的预测效果，Spisak 等（2019）[68]比较了机器学习模型和基于理论的线性模型，研究结果表明，当维度增加时，机器学习模型的预测准确性更高，特质和情境的直接效应预测了领导有效性，而弥补了传统的理论模型得出的结论“特质和情境的交互作用预测了领导有效性”。可见，机器学习方法提供了一种工具，使学者们思考已有理论对现象的解释力的局限性，并尝试提升理论的改进空间。

3.机器学习与演绎推理和归纳推理的互补协同

演绎推理和归纳推理在因果解释、假设（命题）和理论构建中是最常用的两种范式。演绎推理的过程是从一般理论演绎到具体预测，归纳推理的过程是从具体案例归纳到一般理论。Behfar 和 Okhuysen（2018）[69]提出溯因推理的过程，则是从具体现象到针对该类现象所形成的特定解释。作为辅助溯因推理的技术方法之一，机器学习有助于解释局部现象，发展和完善适用于特定情境的中程理论。

（1）机器学习与演绎推理的互补协同。演绎推理的研究范式常常是基于先验的理论进行逻辑推理，提出假设，然后利用计量方法进行检验。假设研究者在进行任何实证研究之前要求先有理论，这样可能会错过现实世界中发生的重要而有趣的问题，而这恰恰是研究者要关注的，尤其是在

企业管理领域(Helfat,2007)[64]。与其总是用实证研究来测试理论,研究者更应该利用实证研究探讨现实世界中观察到的现象从而构建理论(Helfat,2007)[64]。

与演绎推理研究总是验证事先被合理化的解释不同,溯因推理(比如利用机器学习技术)则是基于事实证据推导出解释(Lockett等,2014)[70]。溯因推理的基础逻辑是实用主义。实用主义是理论构建中较实用的一种哲学方法(Behfar和Okhuysen,2018)[69]。它强调与经验现象深度互动,将理论解释与观察到的现象紧密匹配。基于实用主义的溯因推理丰富了演绎推理的验证过程。演绎推理的逻辑关注的是原因所产生的结果,溯因推理的逻辑关注的是导致结果产生的原因(Behfar和Okhuysen,2018)[69]。两者在理论构建中的功能不同。正是由于这种不同,机器学习方法可以在以下两个方面弥补演绎推理的研究过程。

一是机器学习方法有助于发现数据模式和规律,帮助发展额外的解释,有助于构建新的假设。在一个演绎推理研究的主分析完成之后,学者在事后分析阶段可能会提出额外的解释,提出新的视角,甚至提出其他未回答的重要问题,这就为第二个演绎推理的研究项目铺垫了基础(Behfar和Okhuysen,2018[69]; Choudhury,2021[63])。如此,运用机器学习的溯因推理通过连接解释和检验之间的关系以补充不同演绎推理研究的逻辑,使第二个演绎推理研究建立在第一个演绎推理研究的基础上。Behfar和Okhuysen(2018)[69]提出机器学习的溯因推理法在过往演绎推理研究基础上提出的新问题和合理的新假设,为后续研究提供了动力,巧妙地连接了一系列演化推理研究。

二是机器学习方法有时可挑战和替代演绎推理研究中的解释逻辑(Behfar和Okhuysen,2018)[69]。不同的演绎推理研究往往基于不同的先验理论视角,提出不同的影响因素和作用机制,因此对同一发现的结论和解读可能是不一致或矛盾的。机器学习方法可以综合比较不同演绎推理研究的预测能力,发现预测能力较强的演绎推理研究、理论视角和影响因素,有助于引导研究者建立对现象解释能力更强的理论,从而推动该研究领域的理论发展。另外,有时演绎推理的结论与现实情况会出现不一致,此时"异常"就产生了。机器学习方法提供了一种替代的认识论基础,可以通过与数据的紧密互动来探索、发现和发展与"异常"相关的解释,甚至挑战已经确立的实证主义规范,提供一种新的替代规范(Behfar和Okhuysen,2018)[69]。尤其是在关注"新兴、偶发和局部特定"现象的中程理论上,机器学习对现象的识别能力帮助确定和完善中程理论的范围,并帮助中程理论兼顾一般性和特定性(Behfar和Okhuysen,2018)[69]。

(2)机器学习与归纳推理的互补协同。一些学者(Behfar和Okhuysen,2018)[69]认为机器学习方法可以识别数据中隐藏的模式和规律,从而促进了基于算法的归纳推理。也有一些学者(Folger和Stein,2017)[71]认为,以机器学习为代表的溯因推理逻辑与以案例为代表的归纳推理逻辑密切相关,甚至在一些情况下将二者等而视之。

一些经典文献在如何将机器学习和案例研究进行有益结合上做出了突破性工作,比如Tidhar和Eisenhardt(2020)[16]比较了机器学习方法和归纳推理的异同,并探讨了两者的互补作用。他们提出,机器学习和归纳推理分别通过算法和案例找到规律模式,两者都没有先验的假设,两者的目标是一致的,都采取措施来防止过拟合和过度复杂的问题。具体而言,两者的目标都是构建稳健的、准确的、可推广的理论。在防止过拟合问题上,机器学习方法采取交叉验证,案例研究方法采取逻辑复制。在防止过度复杂问题上,机器学习方法采取正则化技巧,案例研究方法采取构念抽象。

以案例研究为代表的归纳推理提供了理论构念和机制,并为机器学习提供了基础(Tidhar和Eisenhardt,2020)[16]。归纳推理的研究范式是从具体事件中总结发生机制、过程规律以及变量之间的关系,并将其升华到一般理论。归纳推理擅长解决"how"的问题,能够从具体案例中获取细致详

细的信息，剖析事件本身发生的过程。此外，归纳推理也能揭示定量研究可能忽略的有趣或意外现象（Helfat，2007）[64]。例如，案例研究通过系统分析少数案例来识别理论模式。案例研究可以揭示经验基础的理论模式，并通过提供理论指导来改进机器学习，从而缩小搜索空间和提升模型性能（Tidhar 和 Eisenhardt，2020）[16]。可见，案例研究通过有意义的理论构建和机制揭示增强了模型的可解释性，成为大规模数据收集和分析的基础（Helfat，2007）[64]。

但是，归纳推理面临着无法进行大规模分析、无法提供精确的效应大小等局限性。尤其是基于案例研究进行归纳推理所得出的结论往往局限于当前案例，难以推广到其他情境中，外部效度较低。此外，案例研究还极大地依赖学者的主观感知、知识背景、抽象思维和概念化的能力。不同学者从同一个案例中可能归纳出不同的理论模型。

机器学习方法则可以缓解归纳推理的这些局限性。一是通过探索数据，机器学习方法揭示了趋势、规律和模式，为案例的理论抽样提供了路线图（Tidhar 和 Eisenhardt，2020）[16]。二是机器学习具有大规模验证和精确性的优势。作为一种模式识别技术，机器学习方法主要通过两种方式为案例理论构建增加精度：一方面，大规模的模式验证和模式的详细解释；另一方面，精确识别效应大小、等终路径（equifinal paths，即达到同样目的的不同方法路径）、非线性特征和配置特点。当案例研究完成之后，研究者可以利用机器学习方法对大规模数据进行收集和分析，以检测案例研究的发现是否适用于更大范围的样本，兼顾了内部效度和外部效度。

4.混合方法助力理论构建的模型

将基于机器学习方法的溯因研究与传统的演绎研究或归纳研究相混合，可提供更丰富的认识论框架；将不同方法得到的结果整合在一起，有助于在大型定量数据集上进行理论构建（Behfar 和 Okhuysen，2018）[69]。混合方法通常在解决实际问题或异常情况时非常有用。例如，Tidhar 和 Eisenhardt（2020）[16]结合机器学习和定性案例研究方法，开发了关于 iOS 应用最佳收入模型的新理论。使用混合方法的常见挑战是范式之间可能存在冲突，比如个案和规律性方法之间的冲突，机器学习能够为混合方法研究中跨越范式提供有用的技术支持（Behfar 和 Okhuysen，2018）[69]。

根据机器学习的技术逻辑，机器学习主要通过两种方法连接演绎研究和归纳研究。有监督机器学习连接了以传统计量分析为代表的演绎研究，无监督机器学习连接了以案例研究为代表的归纳研究（Leavitt 等，2021）[3]。一是有监督机器学习具备与演绎推理类似的目标，都是利用重复观察的模式来建立已知构念或变量之间的关系。有监督机器学习按照一定原则优化和演绎，寻求模型的最优拟合，对意外结果具有较低的容忍度，预先建立类别，并指定结果指令，这与演绎研究的逻辑是类似的（Leavitt 等，2021）[3]。二是无监督机器学习在理论和所选模型的主题之间进行迭代的过程与归纳推理研究是类似的。Hannigan 等（2019）[72]详细描述了研究者如何从机器学习方法的算法输出中创建出理论构念的过程，即把原始主题作为描述性编码，然后提炼成一阶概念，进一步抽象为二阶主题，并最终迭代开发了聚合维度，这个过程与案例研究过程是一脉相承的。具体来说，以主题建模为例，无监督机器学习以词向量和主题向量为基准，围绕关键词进行主题聚类以捕捉理论构念。主题建模的内在灵活性有助于开发更好的度量标准，并引出新颖的概念、流程和机制（Hannigan 等，2019）[72]。

综上，机器学习突破了传统范式之间的边界，缓解了不同范式之间的认知冲突。运用混合方法进行理论构建（如图 4 所示），可以为企业管理理论做出贡献，弥补成熟理论的局限，促进新兴领域的理论涌现。

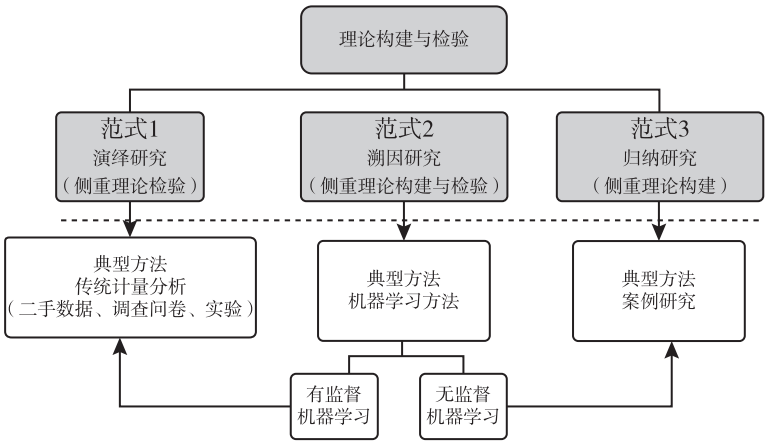

图4 混合方法助力理论构建的模型

5.机器学习推动理论构建:以高管团队研究为例

本文以企业管理领域的“高管团队”研究主题为例，分析其应用机器学习的目的、过程和结果，直观地展示机器学习如何赋能企业管理领域的理论构建和检验。

关于高管特征和企业绩效之间关系的探讨始于Hambrick和Mason（1984）[73]的开创性文章，其核心观点是，高管特征影响企业的战略选择，进而影响企业绩效。后续一系列的实证研究对高管特征如何影响企业战略行为和企业绩效展开了讨论，主要可分为三个流派：一是关注了企业关键人物（比如CEO）的个人特征，二是关注了高管团队的整体特征，三是关注了企业关键人物与其他高管成员的特征差异及其带来的交互作用。

关于企业关键人物的个人特征研究，学者们关注了CEO的可观测特征对企业战略管理的影响（Chen等，2016）[74]，比如CEO的职业背景、年龄、性别、国际化经历影响多元化战略、创新战略以及战略变革。关于高管团队的整体特征，学者们关注了高管团队的整体结构和在某些特征上的平均水平对企业绩效的影响（Cannella等，2008）[75]，比如团队规模、任期、团队多样性、职业背景等。关于企业关键人物与其他高管成员的特征差异，学者们关注了CEO与其他高管成员之间的交互对企业战略决策影响（Buyl等，2011）[76]，比如任期交互对国际化的影响，职业背景交互对企业绩效的影响。

三个流派的高管研究关注的是可观测的特征带来的影响，对更细微的心理学构念缺乏深入研究。这些构念，比如高管认知特征、高管性格、高管情感，扮演的微观机制的重要性不容忽视。一些学者尝试运用问卷的方式研究CEO大五人格对企业战略和绩效的影响（Herrmann和Nadkarni，2014）[77]。采用问卷方式的问题在于：一方面是样本规模太小，另一方面是高管不太愿意接受学术界的深入调研，往往很难有后续的系列研究。也有一些学者开始尝试内容分析方法，运用词汇计数软件识别关键词来测量性格特点（Chatterjee和Hambrick，2007）[78]，然而这种方法依赖于测量的表面效度，其是否能有效地测量构念往往是未知的。

一些交叉学科的文献进一步拓展了对机器学习算法的应用，Harrison等（2019）[28]就是将机器学习算法引入到CEO人格特质研究中的经典案例，填补了高管领域中利用文本和对话中的语言线索识别性格特质的空白。首先，他们从标普1500指数公司选取子样本，并使用CEO讲话的文本记录训练模型，估计CEO的大五人格特质分数，并与此前使用心理学测量工具得出的人格特质分数进行比较；其次，他们将此工具应用于更大规模的样本中，以测量超过3000位CEO的大五人格特质；最后，他们通过探讨CEO的大五人格特质对企业战略变革的影响，对机器学习方法提供的测量方法进行预测试。

可见，针对CEO的大五人格，机器学习方法不仅提供了有效的测量方法，还使得学者可以开启一系列研究，来探讨CEO身上不可观测的深层特质对企业结果的影响。这不仅弥补了大部分研究只探讨CEO可观测特质的缺憾，更为构建高管对企业结果的影响机制的新理论提供了可能，还为不同理论的整合奠定了基础，比如通过引入组织行为学中的微观理论到高阶理论中，可拓展高阶理论对现象的解释边界。

五、未来展望

这一部分主要从企业管理领域的研究主题和机器学习技术的进展两方面对企业管理研究和机器学习技术的融合进行展望。在研究主题上，本文将讨论企业管理领域的经典和前沿研究主题如何运用机器学习方法进行拓展和革新，以高管团队深层特征、企业战略管理、数字创新三个话题为例，展望机器学习如何助力企业管理领域中的开拓性研究。在技术上，本文将阐述机器学习技术在经济和金融领域的最新进展，并讨论企业管理研究领域在变量测量、回归预测、非线性降维、特征筛选和因果推断等方面，如何进行跨学科的借鉴，以充分发挥机器学习的技术优势，赋能理论与实证发展。

1.企业管理领域的经典和前沿研究主题对机器学习的应用展望

中国经济目前处于转型升级关键阶段，这个阶段涉及新兴产业的培育、高端制造业的发展、从投资驱动向消费驱动的转变、现代服务业和制造业的融合发展等。各类主体的活动产生了大量非结构化的、高维的数据。这些源于中国经济与企业活动的数据为中国企业管理理论的构建提供了肥沃的土壤。然而，理论构建和检验首先需要具备可靠的构念度量标准。在企业管理研究中，建立构念的度量标准一直是一个困难的任务。学者们常常怀疑代理变量是否能够准确测量到真实的目标构念。过往采用档案数据的学者常常采用可量化的数据（比如财务数据）作为代理变量，但是度量标准与目标构念之间的关联较松散。缺乏足够的数据和方法阻碍了研究人员进行外部效度较高、时间跨度较大的大规模实证研究。机器学习方法为学者们提供了从复杂数据提取有价值信息的机会，克服了数据和传统方法带来的局限，为研究中国情境下企业管理问题提供了工具。接下来将主要聚焦企业管理研究的三个主题：高管团队深层特征、企业战略管理和数字创新，探讨如何借助机器学习方法推动构念度量和理论构建。

（1）企业高管团队深层特征研究对机器学习的应用展望。以高阶理论为代表的研究指出，企业高管的自身特征影响其决策过程，从而影响企业战略选择和行动结果。一些学者关注了高管的人口学特征对企业战略的影响（You等，2020）[79]，比如年龄、教育水平、性别等。这些人口学特征是浅层次特征，而一个人的行为选择往往受更深层次特征（比如个性、价值观等特征）的影响。因此，近年来对高管的研究越来越关注深层次特征对企业战略决策过程及结果的影响，例如难以通过人口学特征推测的、难以直接测量的人格特质（如短视主义、自恋、控制焦点、大五人格等）和价值观。机器学习方法主要在多模态数据库的构建和分析上赋能企业高管团队深层特征的研究，主要体现在高管个体的人格特质、文化价值观和中国文化背景下特有的高管特质上。

第一，高管个体的人格特质对企业战略的影响。例如，有学者利用机器方法测量了高管人员的短视主义特质，发现短视主义的高管人员会减少研发支出（胡楠等，2021）[29]。还有学者将心理学理论与变量引入到组织科学和战略管理等领域的研究中。例如，Harrison等（2020）[13]基于机器学习识别了高管人员的大五人格特质，发现某些特质会影响企业在股票市场上的表现。学者在未来研究中可继续挖掘机器学习在内容分析上的功能，通过迭代学习训练算法构建反映构念的词集，测量在理论上与具体情境更为相关的人格特质与心理变量。为了提升机器学习算法测量高管人格特征的内容效度，未来也可以比较机器学习的测量与问卷调查之间的差异，确保不同工具方

法的测量达到较高聚合效度，解决了单个方法的局限性。

第二，高管文化价值观对企业战略的影响。从企业内部视角出发，有学者依据GLOBE文化价值观、施瓦兹世界价值观及其他模型，研究了高管的深层次价值观如何影响企业创新战略。例如，方帅等（2024）[22]利用机器学习方法研究了中国企业“一把手”董事长和“二把手”总经理在九个维度文化价值观上的差异与企业创新绩效的关系，并识别出了对企业创新绩效影响最大的两个维度。从外部利益相关者视角来看，企业高层管理人员的价值观等深层次特征难以直接观察，外部利益相关者往往根据高管的语言或行动对任职企业的价值观做出判断。企业高管会主动进行印象管理，获取重要利益相关者的支持。未来研究可以考虑利用自然语言处理技术捕获企业关键人物对外部治理主体的印象管理策略，进而测量企业关键人物的价值观。进一步，可以运用有监督机器学习比较不同印象管理策略对企业战略绩效的预测能力，挑选出预测能力最强的印象管理策略，并尝试分析其影响机制。

第三，中国文化下所特有的企业高管特征对企业战略的影响。一个人的人格、认知与价值观等受其所处社会文化的深刻影响。中国文化具有整体“大一统”、局部区域“多元化”的特征（赵向阳等，2015）[80]，儒释道文化对中国企业家也有着深刻的影响（徐细雄和李万利，2019）[81]。因此，中国企业高层管理人员的个性和价值观特征可能展现出西方研究模型无法覆盖的维度。机器学习方法有助于建立中国企业高层管理人员的语料库和视频库，利用非线性特征降维方法探索多模态数据，提炼出中国企业高层管理人员的人格、认知和价值观维度，与西方模型进行对比，进而分析中国情境下企业高层管理人员的深层次特征如何影响企业战略和绩效、如何影响外部利益相关者对企业战略的反应等。

（2）企业战略管理研究对机器学习的应用展望。企业战略管理领域关注较多的有多元化战略和创新战略。一是多元化战略研究可以借助机器学习技术进行测量。中国企业在“走出去”的过程中往往选择多元化战略以促进企业绩效，其中有些企业开拓的市场在“一带一路”沿线，有一些企业的目标锚定在西方市场，还有些企业在全球市场开展多元化业务。这几种情境下的多元化战略面对的海外市场环境不同，尤其是在中美贸易战情境下，因此多元战略的内涵、形式和对企业绩效的促进作用和机制亦不相同。过往研究中对多元化战略有不同的测量方法。一些学者用同行业多元化程度来测量多元化战略（Zahavi和Lavie，2013）[82]，一些学者用跨行业多元化程度来测量多元化战略（Hashai，2015）[83]，也有一些学者以国外销售额在总销售额中的占比来测量多元化战略（Wiersema和Bowen，2011）[84]。然而，这些研究在多元化战略和绩效的关系上并未得到一致的结论（Choi等，2021）[18]，这与多元化在测量上的不一致和不完全密切相关。多元化战略的传统测量过度依赖财务披露信息，会造成一些问题。例如，若一个企业的财务报告只披露单一业务的财务数据，或者一些跨越多个行业的企业在年度报告中只报告地区的营收数据，这就给测量多元化战略造成了重大障碍（Miller，2006）[85]。尤其是，企业对共建“一带一路”国家和地区与西方国家实施的多元化战略如何进行区分，运用传统方法难以测量。在中国情境下，学者可以利用自然语言处理技术对企业年报文本中涉及的多元化业务信息进行分析，构建更稳健的多元化战略测量指标。

二是创新战略研究可以借助机器学习技术进行创新性质的区分。企业创新结果的一个重要衡量指标是其专利成果。中国目前的专利制度还未做到完全有效地保护企业专利成果。一些从事实质性创新活动的企业在专利活动获利之前往往不会以专利的形式对创新活动进行披露。然而，实际上，过去几十年，中国企业专利申请数量却呈现了爆发式增长趋势。一些学者将这种趋势归因于制度因素。研究表明，专利补贴制度促进了企业专利的申请（Li，2012）[86]。事实上，这些专利中很大一部分并不是真正的技术创新，而只是象征性创新，本质上是企业的一种政治策略。在转型经济体中，如何区分企业从事的创新活动是实质性创新还是象征性创新是一个有意义的研究

问题。过往创新战略研究的另一个特点是，对创新活动的测量局限于专利，然而创新这一种活动无法捕捉创新活动丰富的内涵和外延。创新不仅体现在专利上，还包括实质的产品创新、新的生产工艺和程序、新的市场、新的组织形式、新的创新体系、新的商业模式、新的管理手段等。未来可以采用机器学习方法从外部治理视角来重新审视企业的创新性质（实质性创新 vs.象征性创新）、创新类型（专利 vs.其他创新形式）。例如，可以基于分析师报告建立大型语料库文本数据库，利用无监督机器学习中的主题建模工具对创新进行重新度量，对创新进行分类，对不同性质的创新进行区分，进而探讨不同种类创新的驱动因素和过程机制。

（3）数字创新研究对机器学习的应用展望。中国拥有世界上最多的互联网用户，近些年中国的数字技术和数字市场发展迅猛。一些平台企业（如阿里巴巴和腾讯）在数字基础技术和数字应用市场有了明显的突破，同时越来越多的传统企业也在积极进行数字化转型。这些情境为机器学习的应用提供了多种可能。

首先，数字创新研究可以借助机器学习技术厘清其内涵和外延。目前学术界对数字创新的定义侧重点不同，一些学者强调创新结果（Lee 和 Berente，2012）[87]，一些学者强调创新过程（Nambisan 等，2017）[88]，还有些学者强调创新过程中的数字技术（Fichman 等，2014）[89]。在此基础上，刘洋等（2020）[90]采取了更宽泛的视角，同时强调数字技术、创新过程和创新结果，将数字创新定义为“在创新过程中采用信息、计算、沟通和连接技术的组合，包括带来新的产品、生产过程改进、组织模式变革以及商业模式的创建和改变等”。可见，数字创新的定义在内涵和外延上并未形成一致的看法。机器学习技术可以利用企业的数字化资料文本进行分析，探索数字化创新包括哪些主题，同时利用机器学习的聚类分析技术区分不同企业的数字化创新类型以识别不同企业数字创新的重点。进一步，企业管理学者可以将基于机器学习技术从实践中抽取出来的数字创新内涵与不同文献中的定义进行对比，挑选出对实践解释力更大的定义。

其次，针对中国情境下数字平台组织所面临的利益分配冲突和治理制度重建等问题，可以借助机器学习技术进行机制设计。在某些领域中，个别平台企业一家独大，垄断了用户市场，产生了一系列问题。为了解决这些问题，有必要对数字创新的整个过程及其关键步骤进行研究。刘洋等（2020）[90]尝试从数字创新启动、数字创新开发、数字创新应用三个阶段来阐述数字创新的产生过程。然而，Nambisan 等（2017）[88]认为不同于传统的创新过程，数字创新是一个动态交互的过程，很难清晰界定每个步骤的节点。传统的创新涉及到的创意产生、研究开发、商业化等过程具有清晰的边界，是一种线性关系（Desouza 等，2009）[91]。然而数字创新过程是持续迭代的过程，创新主体很难界定，创新过程和创新产出的关系也比较复杂，很难界定开始点和结束点，是一种非线性关系（Nambisan 等，2017）[88]。而机器学习方法尤其擅长处理这种非线性关系，有助于识别平台领导者与其他利益相关者的互动模式，找出最优的利益分配模式，确保平台生态系统朝着最优方向进行演化。例如，Tidhar 和 Eisenhardt（2020）[16]运用机器学习方法提出了在线商城里不同种类产品最优收益模型。

最后，我国传统企业数字化转型成败的研究，可以借助机器学习技术进行成因识别。一些学者分析了数字化转型过程的影响因素，强调了企业资源（Mithas 等，2013）[92]、企业能力（Kohli 和 Melville，2019）[93]、企业文化（Vial，2021）[94]、情境交融（Melville，2010）[95]等因素的重要性。还有学者在结合交叉学科知识的基础上运用了机器学习，例如，武常岐等（2022）[96]综合了企业战略管理视角和经济学视角，运用机器学习方法探讨了企业在数字化转型过程中竞争战略的选择对企业全要素生产率的影响。究竟哪些因素在传统企业的数字化转型中发挥着更重要的作用？机器学习方法可以比较不同因素在数字化转型中的相对重要性，筛选出关键因素，进而构建传统企业数字化转型的理论框架，指导传统企业的数字化转型实践。

2.机器学习技术的进展:跨学科机器学习技术的借鉴

(1)变量测量和回归预测。人工智能的兴起不仅给管理学带来了机遇,而且给经济金融领域研究提供了强有力的工具。由于经济金融领域往往具有海量、复杂、多维和非结构化的数据,因此为机器学习的应用提供了天然应用情境。无论是在股票市场、衍生品市场,还是在债券市场、投资市场,机器学习的应用已经获得了一定程度的发展。这些应用可概括为两大类:变量测量和回归预测。

在变量测量上,经济金融学领域逐步从大规模的非结构化数据提取信息,到利用社交媒体的言论进行公众的情感分析,或者利用卫星图像监测农产品供应链的运营状况。以情绪量化测量为例,Jing等(2021)[97]等使用机器学习对投资者情绪进行了量化分类,其分类效果优于普通的分类模型;Sohangir等(2018)[98]尝试使用机器学习方法分析了社交网络大数据,发现机器学习方法可以进行金融情感分析,有助于了解公众对某一金融产品或事件的情感反应。

在回归预测上,机器学习方法对结果变量预测具备较高的准确性。现实中的数据常常是复杂的、非线性的,不满足传统的计量经济学假设(如数据的正态性和线性关系)。机器学习在这方面具备明显的优势,善于从大规模数据中识别和提取潜在的模式,发现非线性关系,甚至处理数据中的缺失和噪声。在股票市场研究中,学者抓住机器学习方法在金融时间序列数据上的强大能力对回报收益等进行了预测,发现机器学习具备较高的预测精度(Gu等,2020)[99]。在衍生品市场研究中,学者利用机器学习方法处理了期权市场的数据,对期权定价、期权收益预测等问题进行了分析,发现机器学习方法更加灵活和准确(Bali等,2023)[100]。在投资市场研究中,机器学习方法也被运用以提高预测准确性,比如Edmans 等(2012)[101]运用机器学习方法优化共同基金流量的预测模型,为投资者和政策制定者提供了更精准的建议。

企业管理领域可以借鉴经济金融领域对语料库的处理技术和变量测量等功能。近年来,大数据高阶文本构成的语料库成了企业管理领域研究的数据来源。企业管理学者常常利用预设字典进行内容分析,将预设的字符与语料库可能的单词进行匹配(Hannigan等,2019)[72]。这可能会导致匹配不准确问题,比如由于语言的排列组合和歧义可能导致匹配效果不佳。机器学习模型可以补充、甚至取代预设字典,通过迭代学习训练算法来构建内部单词列表(Hannigan等,2019)[72]。可见,机器学习方法的发展和引入为企业管理研究从各类数据源中构建变量打开了大门,有效避免了该领域长期依赖基于自我报告的问卷方法和回顾性偏见所带来的影响。在未来运用机器学习对语料库进行概念化时,尤其处理中文语料库时,学者们要注意中文与西方语言有不同的语言表达和写作系统,要对文本数据进行预处理,以确保算法能够精确识别文本。

(2)非线性降维与特征筛选。机器学习在经济金融领域研究中(比如资产定价和投资组合管理)中的另一项重要应用是进行特征降维和特征筛选。有效的特征降维和筛选有助于减小不相关特征变量或者噪声过大的特征变量对预测过程的影响,提高运算效率和预测准确性。

特征降维包括线性降维和非线性降维。以主成分分析方法为代表的线性特征降维在各类经济金融预测上都有广泛的应用。但是,线性降维在面对大量潜在因子时容易产生过拟合问题。非线性特征降维有效地避免了此类问题的发生。一些学者将非线性特征降维方法应用到银行信用率、通货膨胀率等研究问题上,发现非线性降维的降维能力和效果远远比线性降维要好(Hauzenberger等,2023)[102]。

同样,机器学习也是特征筛选的有效工具。Freyberger等(2020)[103]提出了一种自适应群lasso的非参数方法来选择特征,增加了模型对异常值的稳健性,并允许更灵活的函数形式。进一步,Cai等(2018)[104]讨论了几种常用的特征选择评估方法,并讨论了广泛应用于机器学习问题(如分类和聚类)的监督、无监督和半监督特征选择方法。后续学者利用神经网络等模型对影响资产定价的

特征进行了筛选（Bryzgalova 等，2023）[105]。

企业管理领域的学者在未来可以借鉴经济金融领域的特征降维和特征筛选技术进行理论构建。有些学者可能认为机器学习算法只产生预测，低估了机器学习技术从数据中构建理论的价值。现实数据可能包括多维度的主题，主题之间可能相互关联、相互重叠，如何进行降维以提取简洁的、可解释的理论构念成为关键。机器学习可以从丰富、复杂、非结构化数据中进行降维处理，识别出数据中潜在的结构，生成新的构念。机器学习方法还有助于开发更好的度量标准，通过迭代的过程输出相关的概念及其基础机制。另外，在特征筛选上，机器学习方法可以比较不同解释变量对结果变量的相对重要程度。利用传统计量方法分析问题的企业管理学者预先提出理论演绎和具体假设，但不同学者可能对哪些变量更能解释结果变量有不同的理论解释和研究视角。机器学习方法可以比较不同学者提出的理论模型对结果变量的解释力，挑选出最能预测结果变量的解释变量，再去构建对现象解释力更强的理论，对未来运用传统计量方法进一步验证理论奠定了基础。

（3）因果推断。近些年，管理学国际顶尖期刊对因果推断的要求越来越高。企业管理学者逐步开始借鉴经济金融领域的因果推断方法。在经济金融领域，学者们关注的经济金融问题往往嵌入到系统之中（如利率、股票价格、通货膨胀率），众多变量是相互关联的。如何识别变量之间的因果关系对于制定货币政策、投资策略和风险管理至关重要。传统的因果推断方法通常基于统计学模型，如回归分析或实验设计，以确定变量之间的因果联系。然而，这些方法通常面临数据非随机化、未观察到的潜在变量和复杂的模型结构等挑战，这些挑战使得因果关系的准确推断变得非常困难。

机器学习技术的崛起为经济金融领域的因果推断带来了希望。机器学习算法能够处理大规模、高维度的数据，提供更复杂的模型，同时也更具灵活性。它们可以处理非线性关系，发现隐藏的模式，并在没有实验设计的情况下进行因果推断。例如，基于机器学习的因果推断方法可以识别金融市场中不同变量之间的复杂因果路径，从而揭示它们之间的影响关系。这些方法可以自动处理大量金融数据，识别潜在因果关系，进一步改进风险管理策略和预测模型。Chernozhukov 等（2017）[106]开发了一种基于机器学习的双重/去偏方法，该方法通过内曼正交得分和交叉拟合技术，使研究者能够有效地从观测数据中估计平均处理效果，即使在干扰参数由机器学习方法估计的情况下也是如此。Belloni 等（2017）[107]采用现代机器学习方法来解决经济计量学中的结构方程模型问题，建议使用各种机器学习方法来学习模型中的非参数或高维分量，并结合机器学习预测能力和经典统计推断方法提出了一个整合框架，尤其是通过诚实推断来提高估计结果的可靠性。论文中提到的方法，如正交或双重稳健的矩条件，可以帮助研究者解释机器学习模型如何识别和控制处理效应。Farrell 等（2021）[108]探讨了深度神经网络在半参数统计推断中的应用，不仅为深度前馈神经网络建立了新的收敛速率，还为使用深度学习进行因果推断提供了理论支撑。这些方法提供了强大的工具来处理高维数据，在金融和经济模型中捕捉复杂的非线性关系，有助于提升因果效应估计的准确性。

机器学习技术与传统因果推断技术地融合在经济金融学领域的重要应用，有助于启发企业管理学者在未来的研究中提高因果推断质量。近年来，因果识别成为了企业管理实证研究的焦点。然而，目前企业管理学者在应用机器学习方法对结果变量进行预测时对因果论断不够充分（Tidhar 和 Eisenhardt，2020）[16]。有学者提出，机器学习在大数据时代为因果识别提供了新机遇。例如，郭峰和陶旭辉（2023）[5]分析了机器学习方法对因果识别的价值，比如在识别和控制混淆因素（confounding factors）、构建对照组、识别异质性因果效应、检验因果关系的外部有效性上。借鉴经济金融学领域的因果识别方法，未来企业管理学者可以结合机器学习方法和传统的因果识别方法

(比如双重差分法、倾向匹配法、合成控制法、断点回归法、随机实验法等),为变量之间的因果关系识别提供更稳健的结果,为理论构建和检验提供更丰富的工具箱。

六、结 语

机器学习方法在技术和理论构建中的优势得到了企业管理领域学者的关注。然而,机器学习方法在企业管理领域的应用还不够成熟,尤其是国内企业管理研究领域对机器学习方法的应用仍处于初级探索阶段。学者们对机器学习方法和企业管理研究的融合过程、研究主题、研究技术、理论构建、与传统研究范式的异同及互补等的理解和认知尚不够系统和深入,对企业管理领域未来如何运用机器学习方法还需要更细致的科学分析和综合研判。

本文对过去20多年间发表于国内外管理学顶级学术期刊的116篇文献进行系统梳理,发现企业管理领域学者根据研究中遇到的问题对机器学习的应用逐步经历了四个阶段的发展,并呈现出如下特点。首先,在研究主题上,国外文献的研究主题比较丰富,不仅利用机器学习进行变量测量和回归预测,也开始尝试运用机器学习进行理论构建和检验;国内文献的研究主题比较集中,主要是构建技术创新能力评价指标,在利用机器学习方法进行理论构建方面还有所欠缺。其次,在机器学习技术上,国外企业管理学者倾向于运用有监督机器学习技术进行回归预测、样本分类和变量测量,运用无监督机器学习技术进行数据降维、聚类分析、变量测量,较少运用强化学习技术;国内学者则更多集中在有监督机器学习技术本身的应用上。最后,在理论构建上,国外企业管理学者开始思考机器学习方法如何助力理论构建,认为机器学习算法可以从复杂数据中提炼出规律和模式,从而为新理论的构建铺垫基础;国内学者主要将机器学习用作测量与分析的工具,对其与理论构建的关系还处于了解与探索阶段。

基于对国内外文献的这些比较分析可以发现,机器学习方法在助力企业管理领域的理论构建和检验上具有巨大的潜能,二者不是竞争关系或从属关系,而是可以赋能理论的构建和检验。机器学习方法有助于完成理论构建的关键一步,即揭示“程式化事实”(stylized facts)或者数据中的稳健模式,不断测试和完善中程理论,并作为一种催化剂扩大理论解释的范围。具体而言,机器学习方法可以识别复杂构念之间的理论化关系,检验那些由于构念测量困难而未得到检验的理论。同时,机器学习方法能够帮助缓解构念身份谬误问题,从而为不同理论之间的对话和整合提供了可能。机器学习方法可建立最佳可预测水平的基准,比较解释性模型的解释力,从而发现解释性模型依赖理论在现象解释上还存在多大的提升空间。在理论构建范式上,以机器学习方法为基础的溯因推理范式可以与传统的演绎推理和归纳推理范式形成协同互补,还有助于缓解不同范式之间的认知冲突,因此本文提出了构建混合方法以进行理论构建。

机器学习方法在未来中国企业管理研究中的运用极具潜力。一方面,本文以高管团队深层特征、企业战略管理和数字创新三个话题为例,分析机器学习在构念测量和理论构建中可能发挥的作用;另一方面,根据机器学习技术的进展,本文认为企业管理学者可以借鉴经济金融领域的前沿机器学习技术。本文期待启发中国学者利用前沿方法开展中国情境下的问题研究,探索中国企业管理实践的一般规律,揭示中外企业管理中关键要素与运行机制的异同,为中国企业管理实践提供理论支撑。

参考文献

[1]刘景江,郑畅然,洪永淼.机器学习如何赋能管理学研究?——国内外前沿综述和未来展望[J].北京:管理世界,2023,(9):191-216.

[2]Anderson,C.The End of Theory:The Data Deluge Makes the Scientific Method Obsolete [J/OL].Wired Magazine,2008,https://

www.wired.com/2008/06/pb-theory/.

[3]Leavitt, K., K.Schabram, P.Hariharan, and C.M.Barnes.Ghost in the Machine: On Organizational Theory in the Age of Machine Learning[J].Academy of Management Review, 2021, 46, (4): 750-777.

[4]洪永淼，汪寿阳.大数据如何改变经济学研究范式?[J].北京：管理世界，2021，(10)：40-55，72，56.

[5]郭峰，陶旭辉.机器学习与社会科学中的因果关系：一个文献综述[J].北京：经济学(季刊)，2023，(1)：1-17.

[6]王芳，王宣艺，陈硕.经济学研究中的机器学习：回顾与展望[J].北京：数量经济技术经济研究，2020，(4)：146-164.

[7]魏一鸣，范英，徐伟宣.工业工程的过去、现在与未来[J].天津：南开管理评论，2000，(2)：19-21，30.

[8]刘友金，徐江容.基于bp网络的企业技术创新效果评价模型[J].北京：科学学研究，2001，(1)：78-83.

[9]Cui, D., and D.Curry.Prediction in Marketing Using the Support Vector Machine[J].Marketing Science, 2005, 24, (4): 595-615.

[10] Cui, G., M. L. Wong, and H. -K. Lui. Machine Learning for Direct Marketing Response Models: Bayesian Networks with Evolutionary Programming[J].Management Science, 2006, 52, (4): 597-612.

[11] Ghose, A., P.G.Ipeirotis, and B.Li.Designing Ranking Systems for Hotels on Travel Search Engines by Mining User-Generated and Crowdsourced Content[J].Marketing Science, 2012, 31, (3): 493-520.

[12]刘承水，乞建勋.基于价值的客户序位评价应用研究[J].哈尔滨：管理科学，2005，(6)：37-42.

[13] Harrison, J.S., G.R.Thurgood, S.Boivie, and M.D.Pfarrer.Perception Is Reality: How Ceos' Observed Personality Influences Market Perceptions of Firm Risk and Shareholder Returns[J].Academy of Management Journal, 2020, 63, (4): 1166-1195.

[14] Huang, D., and L.Luo.Consumer Preference Elicitation of Complex Products Using Fuzzy Support Vector Machine Active Learning[J].Marketing Science, 2016, 35, (3): 445-464.

[15] Corritore, M., A.Goldberg, and S.B.Srivastava.Duality in Diversity: How Intrapersonal and Interpersonal Cultural Heterogeneity Relate to Firm Performance[J].Administrative Science Quarterly, 2020, 65, (2): 359-394.

[16]Tidhar, R., and K.M.Eisenhardt.Get Rich or Die Trying Finding Revenue Model Fit Using Machine Learning and Multiple Cases [J].Strategic Management Journal, 2020, 41, (7): 1245-1273.

[17] Miric, M., N.Jia, and K.G.Huang.Using Supervised Machine Learning for Large-Scale Classification in Management Research: The Case for Identifying Artificial Intelligence Patents[J].Strategic Management Journal, 2023, 44, (2): 491-519.

[18] Choi, J., A. Menon, and H. Tabakovic. Using Machine Learning to Revisit the Diversification-Performance Relationship [J]. Strategic Management Journal, 2021, 42, (9): 1632-1661.

[19] Choudhury, P., D.Wang, N.A.Carlson, and T.Khanna.Machine Learning Approaches to Facial and Text Analysis: Discovering Ceo Oral Communication Styles[J].Strategic Management Journal, 2019, 40, (11): 1705-1732.

[20] Bellstam, G., S.Bhagat, and J.A.Cookson.A Text-Based Analysis of Corporate Innovation[J].Management Science, 2021, 67, (7): 4004-4031.

[21] Schwartz, E. M., E. T. Bradlow, and P. S. Fader. Customer Acquisition Via Display Advertising Using Multi-Armed Bandit Experiments[J].Marketing Science, 2017, 36, (4): 500-522.

[22]方帅，程雨涵，刘知，张建君.企业"一把手"和"二把手"的价值观差异与企业创新：基于机器学习的经验证据[J].北京：中国软科学，2024，(S1)：203-222.

[23] Ying, L., L.Yan-Bo, F.Jiu-Lun, W.Fu-Ping, G.Yan-Chao, and T.Qi.Survey on Image Classification Technology Based on Small Sample Learning[J].Acta Automatica Sinica, 2021, 47, (2): 297-315.

[24] Vossen, A., and C. Ihl. More Than Words! How Narrative Anchoring and Enrichment Help to Balance Differentiation and Conformity of Entrepreneurial Products[J].Journal of Business Venturing, 2020, 35, (6), 106050.

[25] Williamson, A.J., A. Drencheva, and M. Battisti. Entrepreneurial Disappointment: Let Down and Breaking Down, a Machine-Learning Study[J].Entrepreneurship Theory and Practice, 2022, 46, (6): 1500-1533.

[26] Furman, J.L., and F.Teodoridis. Automation, Research Technology, and Researchers' Trajectories: Evidence from Computer Science and Electrical Engineering[J].Organization Science, 2020, 31, (2): 330-354.

[27] Von Hippel, E., and S.Kaulartz. Next-Generation Consumer Innovation Search: Identifying Early-Stage Need-Solution Pairs on the Web[J].Research Policy, 2021, 50, (8), 104056.

[28] Harrison, J.S., G.R.Thurgood, S.Boivie, and M.D.Pfarrer. Measuring Ceo Personality: Developing, Validating, and Testing a Linguistic Tool[J].Strategic Management Journal, 2019, 40, (8): 1316-1330.

[29]胡楠，薛付婧，王昊楠.管理者短视主义影响企业长期投资吗？——基于文本分析和机器学习[J].北京：管理世界，2021，(5)：139-156，111，119-121.

[30]Momtaz, P.P.Ceo Emotions and Firm Valuation in Initial Coin Offerings: An Artificial Emotional Intelligence Approach[J]. Strategic Management Journal,2021,42,(3):558-578.

[31]陆瑶,张叶青,黎波,赵浩宇.高管个人特征与公司业绩——基于机器学习的经验证据[J].天津:管理科学学报,2020,(2):120-140.

[32]Hyytinen,A.,P.Rouvinen,M.Pajarinen,and J.Virtanen.Ex Ante Predictability of Rapid Growth:A Design Science Approach[J]. Entrepreneurship Theory and Practice,2023,47,(6):2465-2493.

[33]Guzman,J.,and A.Li.Measuring Founding Strategy[J].Management Science,2023,69,(1):101-118.

[34]张方华.资源获取与技术创新绩效关系的实证研究[J].北京:科学学研究,2006,(4):635-640.

[35]Sen,P.,and P.Puranam.Do Alliance Portfolios Encourage or Impede New Business Practice Adoption? Theory and Evidence from the Private Equity Industry[J].Strategic Management Journal,2022,43,(11):2279-2312.

[36]Hollenbeck,B.Online Reputation Mechanisms and the Decreasing Value of Chain Affiliation[J].Journal of Marketing Research, 2018,55,(5):636-654.

[37]Dotzel,T.,and V.Shankar.The Relative Effects of Business-to-Business (Vs.Business-to-Consumer) Service Innovations on Firm Value and Firm Risk:An Empirical Analysis[J].Journal of Marketing,2019,83,(5):133-152.

[38]Li,M.Moving Beyond the Linear Regression Model:Advantages of the Quantile Regression Model[J].Journal of Management, 2015,41,(1):71-98.

[39]Choudhury,P.,C.Foroughi,and B.Larson.Work-from-Anywhere:The Productivity Effects of Geographic Flexibility[J].Strategic Management Journal,2021,42,(4):655-683.

[40]郭岚,张祥建.基于bp神经网络的企业核心竞争力评价[J].北京:科学学研究,2007,(1):132-137.

[41]胡健,李向阳,孙金花.中小企业环境绩效评价理论与方法研究[J].北京:科研管理,2009,(2):150-156,165.

[42]肖泽磊,李帮义,项喜章,刘虹.中国风险企业内生核心竞争力构建及其实证研究[J].天津:南开管理评论,2008,(4):20-24.

[43]肖泽磊,项喜章,刘虹.中国知识型企业内生核心竞争力实证研究[J].天津:科学学与科学技术管理,2009,(1):143-147.

[44]Xu,X.,F.Xiong,and Z.An.Using Machine Learning to Predict Corporate Fraud:Evidence Based on the Gone Framework[J]. Journal of Business Ethics,2023,186,(1):137-158.

[45]Danaher,P.J.,T.S.Danaher,M.S.Smith,and R.Loaiza-Maya.Advertising Effectiveness for Multiple Retailer-Brands in a Multimedia and Multichannel Environment[J].Journal of Marketing Research,2020,57,(3):445-467.

[46]Hartmann,J.,M.Heitmann,C.Schamp,and O.Netzer.The Power of Brand Selfies[J].Journal of Marketing Research,2021,58, (6):1159-1177.

[47]Liu,L.,D.Dzyabura,and N.Mizik.Visual Listening In:Extracting Brand Image Portrayed on Social Media[J].Marketing Science, 2020,39,(4):669-686.

[48]Dzyabura,D.,and R.Peres.Visual Elicitation of Brand Perception[J].Journal of Marketing,2021,85,(4):44-66.

[49]钱明辉,徐志轩.基于机器学习的消费者品牌决策偏好动态识别与效果验证研究[J].天津:南开管理评论,2019,(3):66-76.

[50]刘逸,孟令坤,保继刚,赵创钿.人工计算模型与机器学习模型的情感捕捉效度比较研究——以旅游评论数据为例[J].天津:南开管理评论,2021,(5):63-74.

[51]Zhang,M.,and L.Luo.Can Consumer-Posted Photos Serve as a Leading Indicator of Restaurant Survival? Evidence from Yelp [J].Management Science,2023,69,(1):25-50.

[52]Zhang,Z.,K.Yang,J.Z.Zhang,and R.W.Palmatier.Uncovering Synergy and Dysergy in Consumer Reviews:A Machine Learning Approach[J].Management Science,2023,69,(4):2339-2360.

[53]Ascarza,E.Retention Futility:Targeting High-Risk Customers Might Be Ineffective[J].Journal of Marketing Research,2018,55, (1):80-98.

[54]Padilla,N.,and E.Ascarza.Overcoming the Cold Start Problem of Customer Relationship Management Using a Probabilistic Machine Learning Approach[J].Journal of Marketing Research,2021,58,(5):981-1006.

[55]叶强,邹鹏,尚维.基于多分类器融合的客户细分研究[J].哈尔滨:管理科学,2004,(2):64-67.

[56]罗彬,邵培基,罗尽尧,刘独玉,夏国恩.基于粗糙集理论-神经网络-蜂群算法集成的客户流失研究[J].武汉:管理学报, 2011,(2):265-272.

[57]史达,王乐乐,衣博文.在线评论有用性的深度数据挖掘——基于tripadvisor的酒店评论数据[J].天津:南开管理评论,

2020,(5):64-75.

[58]Homburg, C., M.Theel, and S.Hohenberg.Marketing Excellence: Nature, Measurement, and Investor Valuations[J].Journal of Marketing,2020,84,(4):1-22.

[59]Ellickson, P.B., W.Kar, and J.C.Reeder Iii.Estimating Marketing Component Effects: Double Machine Learning from Targeted Digital Promotions[J].Marketing Science,2023,42,(4):704-728.

[60]高曦含,王锐.品效之争:疫情后企业营销战略导向选择对绩效的影响[J].哈尔滨:管理科学,2021,(5):16-28.

[61]Nauhaus, S., J.Luger, and S.Raisch.Strategic Decision Making in the Digital Age: Expert Sentiment and Corporate Capital Allocation[J].Journal of Management Studies,2021,58,(7):1933-1961.

[62]Blohm, I., T.Antretter, C.Sirén, D.Grichnik, and J.Wincent.It'sa Peoples Game, Isn't It?! A Comparison between the Investment Returns of Business Angels and Machine Learning Algorithms[J].Entrepreneurship Theory and Practice,2022,46,(4):1054-1091.

[63]Choudhury, P., R.T.Allen, and M.G.Endres.Machine Learning for Pattern Discovery in Management Research[J].Strategic Management Journal,2021,42,(1):30-57.

[64]Helfat, C.E.Stylized Facts, Empirical Research and Theory Development in Management[J].Strategic Organization, 2007, 5, (2):185-192.

[65]Shrestha, Y.R., V.F.He, P.Puranam, and G.Von Krogh.Algorithm Supported Induction for Building Theory: How Can We Use Prediction Models to Theorize?[J].Organization Science,2021,32,(3):856-880.

[66]Bourgeois Iii, L.J.Toward a Method of Middle-Range Theorizing[J].Academy of Management Review,1979,4,(3):443-447.

[67]Larsen, K.R., and C.H.Bong.A Tool for Addressing Construct Identity in Literature Reviews and Meta-Analyses[J].MIS Quarterly,2016,40,(3):529-552.

[68]Spisak, B.R., P.A.Van Der Laken, and B.M.Doornenbal.Finding the Right Fuel for the Analytical Engine: Expanding the Leader Trait Paradigm through Machine Learning?[J].The Leadership Quarterly,2019,30,(4):417-426.

[69]Behfar, K., and G.A.Okhuysen.Perspective—Discovery within Validation Logic: Deliberately Surfacing, Complementing, and Substituting Abductive Reasoning in Hypothetico-Deductive Inquiry[J].Organization Science,2018,29,(2):323-340.

[70]Lockett, A., A.Mcwilliams, and D.D.Van Fleet.Reordering Our Priorities by Putting Phenomena before Design: Escaping the Straitjacket of Null Hypothesis Significance Testing[J].British Journal of Management,2014,25,(4):863-873.

[71]Folger, R., and C.Stein.Abduction 101: Reasoning Processes to Aid Discovery[J].Human Resource Management Review,2017,27,(2):306-315.

[72]Hannigan, T.R., R.F.Haans, K.Vakili, H.Tchalian, V.L.Glaser, M.S.Wang, S.Kaplan, and P.D.Jennings.Topic Modeling in Management Research: Rendering New Theory from Textual Data[J].Academy of Management Annals,2019,13,(2):586-632.

[73]Hambrick, D.C., and P.A.Mason.Upper Echelons: The Organization as a Reflection of Its Top Managers[J].Academy of Management Review,1984,9,(2):193-206.

[74]Chen, G., C.Crossland, and S.Huang.Female Board Representation and Corporate Acquisition Intensity[J].Strategic Management Journal,2016,37,(2):303-313.

[75]Cannella Jr, A.A., J.-H.Park, and H.-U.Lee.Top Management Team Functional Background Diversity and Firm Performance: Examining the Roles of Team Member Colocation and Environmental Uncertainty[J].Academy of Management Journal, 2008, 51, (4): 768-784.

[76]Buyl, T., C.Boone, W.Hendriks, and P.Matthyssens.Top Management Team Functional Diversity and Firm Performance: The Moderating Role of Ceo Characteristics[J].Journal of Management Studies,2011,48,(1):151-177.

[77]Herrmann, P., and S.Nadkarni.Managing Strategic Change: The Duality of Ceo Personality[J].Strategic Management Journal, 2014,35,(9):1318-1342.

[78]Chatterjee, A., and D.C.Hambrick.It's All About Me: Narcissistic Chief Executive Officers and Their Effects on Company Strategy and Performance[J].Administrative Science Quarterly,2007,52,(3):351-386.

[79]You, Y., S.Srinivasan, K.Pauwels, and A.Joshi.How Ceo/Cmo Characteristics Affect Innovation and Stock Returns: Findings and Future Directions[J].Journal of the Academy of Marketing Science,2020,48:1229-1253.

[80]赵向阳,李海,孙川.中国区域文化地图:"大一统"抑或"多元化"?[J].北京:管理世界,2015,(2):101-119,187-188.

[81]徐细雄,李万利.儒家传统与企业创新:文化的力量[J].北京:金融研究,2019,(9):112-130.

[82]Zahavi, T., and D.Lavie.Intra-Industry Diversification and Firm Performance[J].Strategic Management Journal, 2013, 34, (8):

978-998.

[83]Hashai, N.Within-Industry Diversification and Firm Performance—an S-Shaped Hypothesis[J].Strategic Management Journal, 2015,36,(9):1378-1400.

[84]Wiersema, M.F., and H.P.Bowen.The Relationship between International Diversification and Firm Performance: Why It Remains a Puzzle[J].Global Strategy Journal,2011,1,(1-2):152-170.

[85]Miller, D.J.Technological Diversity, Related Diversification, and Firm Performance[J].Strategic Management Journal, 2006, 27, (7):601-619.

[86]Li, X.Behind the Recent Surge of Chinese Patenting: An Institutional View[J].Research Policy, 2012, 41, (1):236-249.

[87]Lee, J., and N.Berente.Digital Innovation and the Division of Innovative Labor: Digital Controls in the Automotive Industry[J]. Organization Science, 2012, 23, (5):1428-1447.

[88]Nambisan, S., K.Lyytinen, A.Majchrzak, and M.Song.Digital Innovation Management[J].MIS Quarterly, 2017, 41, (1):223-238.

[89]Fichman, R.G., B.L.Dos Santos, and Z.Zheng.Digital Innovation as a Fundamental and Powerful Concept in the Information Systems Curriculum[J].MIS Quarterly, 2014, 38, (2):329-343.

[90]刘洋,董久钰,魏江.数字创新管理:理论框架与未来研究[J].北京:管理世界,2020,(7):198-217,219.

[91]Desouza, K.C., C.Dombrowski, Y.Awazu, P.Baloh, S.Papagari, S.Jha, and J.Y.Kim.Crafting Organizational Innovation Processes [J].Innovation, 2009, 11, (1):6-33.

[92]Mithas, S., A.Tafti, and W.Mitchell.How a Firm's Competitive Environment and Digital Strategic Posture Influence Digital Business Strategy[J].MIS Quarterly, 2013, 37, (2):511-536.

[93]Kohli, R., and N.P.Melville.Digital Innovation: A Review and Synthesis[J].Information Systems Journal, 2019, 29, (1):200-223.

[94]Vial, G.Understanding Digital Transformation: A Review and a Research Agenda[J].Journal of Strategic Information Systems, 2019, 28, (2):118-144.

[95]Melville, N.P.Information Systems Innovation for Environmental Sustainability[J].MIS Quarterly, 2010, 34, (1):1-21.

[96]武常岐,张昆贤,周欣雨,周梓洵.数字化转型、竞争战略选择与企业高质量发展——基于机器学习与文本分析的证据[J].北京:经济管理,2022,(4):5-22.

[97]Jing, N., Z.Wu, and H.Wang.A Hybrid Model Integrating Deep Learning with Investor Sentiment Analysis for Stock Price Prediction[J].Expert Systems with Applications, 2021, 178, 115019.

[98]Sohangir, S., D.Wang, A.Pomeranets, and T.M.Khoshgoftaar.Big Data: Deep Learning for Financial Sentiment Analysis[J]. Journal of Big Data, 2018, 5, (1):1-25.

[99]Gu, S., B.Kelly, and D.Xiu.Empirical Asset Pricing Via Machine Learning[J].The Review of Financial Studies, 2020, 33, (5): 2223-2273.

[100]Bali, T.G., H.Beckmeyer, M.Moerke, and F.Weigert.Option Return Predictability with Machine Learning and Big Data[J].The Review of Financial Studies, 2023, 36, (9):3548-3602.

[101]Edmans, A., I.Goldstein, and W.Jiang.The Real Effects of Financial Markets: The Impact of Prices on Takeovers[J].The Journal of Finance, 2012, 67, (3):933-971.

[102]Hauzenberger, N., F.Huber, and K.Klieber.Real-Time Inflation Forecasting Using Non-Linear Dimension Reduction Techniques [J].International Journal of Forecasting, 2023, 39, (2):901-921.

[103]Freyberger, J., A.Neuhierl, and M.Weber.Dissecting Characteristics Nonparametrically[J].The Review of Financial Studies, 2020, 33, (5):2326-2377.

[104]Cai, J., J.Luo, S.Wang, and S.Yang.Feature Selection in Machine Learning: A New Perspective[J].Neurocomputing, 2018, 300: 70-79.

[105]Bryzgalova, S., J.Huang, and C.Julliard.Bayesian Solutions for the Factor Zoo: We Just Ran Two Quadrillion Models[J].The Journal of Finance, 2023, 78, (1):487-557.

[106]Chernozhukov, V., D.Chetverikov, M.Demirer, E.Duflo, C.Hansen, and W.Newey.Double/Debiased/Neyman Machine Learning of Treatment Effects[J].American Economic Review, 2017, 107, (5):261-265.

[107]Belloni, A., V.Chernozhukov, I.Fernandez-Val, and C.Hansen.Program Evaluation and Causal Inference with High-Dimensional Data[J].Econometrica, 2017, 85, (1):233-298.

[108]Farrell, M.H., T.Liang, and S.Misra.Deep Neural Networks for Estimation and Inference[J].Econometrica, 2021, 89, (1):181-213.

Integration of Machine Learning Methods and Enterprise Management Research:Retrospect and Prospect

FANG Shuai[1], LIU Zhi[2], CHENG Yu-han[3], LI Zi-xuan[4]

(1.School of Economics and Management, China University of Geosciences Beijing, Beijing, 100083, China;
2.Guanghua School of Management, Peking University, Beijing, 100871, China;
3.School of Management, Shandong University, Shandong, Jinan, 250100, China;
4.School of Finance, Central University of Finance and Economics, Beijing, 102206, China)

Abstract: The introduction of machine learning methods presents both significant challenges and opportunities for enterprise management scholars in understanding phenomena and building theories. However, scholars currently lack a systematic and in-depth understanding of how machine learning methods can be integrated with existing research paradigms to empower enterprise management research. There is still insufficient understanding regarding the integration process of machine learning methods with enterprise management research, research themes, research techniques, theory building, and bridging with traditional research paradigms. More detailed scientific analysis and comprehensive judgment are needed to explore how machine learning methods can be applied in the field of enterprise management in the future.

This paper systematically reviews 116 articles published in top domestic and international management academic journals over the past two decades. It finds that scholars in the field of enterprise management have gradually experienced four stages of development in their use of machine learning based on the challenges encountered in research, and several characteristics emerge. First, regarding research themes, foreign literature covers a broader range, using machine learning not only for variable measurement and regression prediction but also for theoretical construction and testing. In contrast, domestic literature tends to focus more narrowly, mainly on constructing evaluation indicators for technological innovation capability, with less focus on theoretical construction using machine learning methods. Secondly, regarding machine learning techniques, foreign enterprise management scholars prefer supervised machine learning techniques for regression prediction, sample classification, and variable measurement, and unsupervised machine learning for data dimensionality reduction, cluster analysis, and variable measurement, with less use of reinforcement learning techniques. Domestic scholars, however, are more concentrated on applying supervised machine learning techniques. Thirdly, regarding theory building, foreign scholars have begun to consider how machine learning methods can aid in theory construction, believing that machine learning algorithms can extract patterns and rules from complex data, thereby laying the foundation for new theory development. Domestic scholars mainly use machine learning as a tool for measurement and analysis, and their understanding of its relationship with theory construction is still in the exploration stage.

Based on this comparative analysis of domestic and international literature, it is clear that machine learning methods have great potential to aid in the theory construction and testing in the field of enterprise management. They do not represent a competitive or subordinate relationship but can empower theory building and testing. Machine learning methods help complete a key step in theory construction: revealing "stylized facts" or robust patterns in data, continuously testing and refining mid-range theories, and acting as a catalyst to expand the scope of theoretical explanations. Specifically, machine learning methods can identify theoretical relationships between complex constructs, test theories that have not been examined due to difficulties in construct measurement, and help alleviate the issue of construct identity fallacy, thus enabling dialogue and integration between different theories. Machine learning methods can also establish benchmarks for the best predictive level, compare the explanatory power of explanatory models, and highlight the areas where those models still have room for improvement in explaining phenomena.

In the paradigm of theory building, the abductive reasoning paradigm based on machine learning can complement traditional deductive and inductive reasoning paradigms, helping to alleviate cognitive conflicts between different paradigms. Therefore, this paper proposes the construction of a mixed-method approach for theory building.

Finally, this paper looks ahead to the future application of machine learning methods in enterprise management research in China. On one hand, taking the topics of top management team deep characteristics, corporate strategic management, and digital innovation as examples, this paper analyzes the potential role that machine learning can play in concept measurement and theory construction. On the other hand, it envisions how enterprise management scholars can learn from cutting-edge machine learning techniques in economics and finance.

This paper hopes to inspire Chinese scholars to use advanced methods to conduct research on issues within the Chinese context, explore general laws in Chinese enterprise management practices, and reveal similarities and differences in key elements and operational mechanisms between Chinese and foreign enterprises, thereby providing theoretical support for Chinese enterprise management practices.

Key Words: machine learning; enterprise management; theory construction; paradigm crossing; mixed methods
JEL Classification: M00, M10
DOI: 10.19616/j.cnki.bmj.2025.03.010

(责任编辑:刘建丽)