面向新质生产力的未来技术预见模型探究

陈　劲　张可人　杨　硕　朱子钦*

摘要:全球科技创新和产业变革持续加速,新质生产力成为引领未来经济发展的关键动力。然而,新质生产力的未来技术预见单靠专家前瞻洞见存在有限理性、经验主义等痼疾,仅凭人工智能模型又存在幻觉、缺乏领域知识等问题。因此,本文提出一种融合机器智能与人类智慧的未来技术预见模型,将图神经网络方法视为机器层面的广义溯因推理路径,通过结构化学习重构"技术—产业—资金"间的复杂因果关联,同时引入专家排序评估与潜力判断,形成基于主观洞见的认知增强机制,实现了溯因推理和归纳演绎的有机结合。本文进一步选取七大关键产业领域,基于未来技术预见模型分析了新质生产力的未来技术趋势。研究发现,未来技术预见模型有效弥补了单一方法中存在的推理演绎不足或过拟合等缺陷,在复杂技术和产业估值预测中显著提升了效率和精度。七大关键产业领域的未来技术趋势矩阵呈现出动态演化与跨领域协同特征,各领域的未来技术发展展现出从单点突破向系统集成、从效率提升向范式革新的整体演进规律。本文的决策框架能够为技术趋势和产业机会的预测提供科学决策路径和量化评估工具,促进新质生产力的加快发展和现代化产业体系的建设。

关键词:新质生产力　未来技术预见　人机混合智能　溯因推理　图神经网络

中图分类号:F124.3　**文献标识码:**A　**文章编号:**1000-3894(2025)09-0005-24

一、引　　言

2024年1月,习近平总书记在中共中央政治局第十一次集体学习时强调,科技创新能够催生新产业、新模式、新动能,是发展新质生产力的核心要素。相较于传统生产力,新质生产力摆脱了对高耗生产资料、资本扩张及廉价劳动力的依赖,转向以创新为主导、以质优为核心,并通过全要素生产率的大幅跃升推动高质量发展。这一理念与中国当前从高速增长向高质量发展阶段迈进的历史进程高度契合,为中国式现代化的实践提供与时俱进的理论支撑。习近平总书记明确指出,"高质量发展需要新的生产力理论来指导,而新质生产力已经在实践中形成并展示出对高质量发展的强劲推动力、支撑力"。因此,科学预见和系统谋划新质生产力实现路径,探索其在主要产业领域的未来技术趋势,成为当前推动科技创新与产业创新深度融合的紧迫需求。面向新质

* 陈劲,教授,清华大学经济管理学院、清华大学技术创新研究中心,电子邮箱:chenjin@sem.tsinghua.edu.cn;张可人,博士研究生,清华大学经济管理学院,电子邮箱:zkr23@mails.tsinghua.edu.cn;杨硕(通讯作者),讲师,北京科技大学马克思主义学院,电子邮箱:yangshuo@sem.tsinghua.edu.cn;朱子钦,助理研究员,清华大学经济管理学院,电子邮箱:zhuzq@sem.tsinghua.edu.cn。本文获得国家重点研发计划重点专项(2022YFF0903200)和国家自然科学基金项目(72304163)的资助。感谢匿名审稿专家的宝贵意见,文责自负。

生产力进行未来技术的科学预见能够有效洞察技术和产业演变方向,抢占科技竞争和未来发展的制高点,助力中国打破美国的科技围堵,实现高水平科技自立自强和科技强国建设的宏伟目标。

面向新质生产力的未来技术是以创新为核心,聚焦人工智能、量子计算、生物制造、先进材料等战略性前沿领域,通过多技术群协同演进与系统性融合,推动生产要素向数字化、智能化、绿色化方向深度重构的技术体系。这类技术的催生高度依赖于原创性颠覆性创新,其发展具有难预测性、高突变性和高风险性等特点。作为新质生产力的核心驱动力,未来技术通过非线性演化不断突破既有生产范式,构成了生产力跃升的爆发点,但也给未来预见带来了巨大挑战(陈劲和朱子钦,2021)。当前技术预测主要分为两种路径,第一种是以信息技术为基础的机器智能路径,包括主题词提取、聚类、知识图谱、文献计量及交叉影响分析等方法(Kim 和 Bae,2017;Daim 等,2006;宋跃刚和宋长青,2024)。这一路径虽然具备高效处理庞大数据集并提供深入、全面以及实时分析的能力,却过分依赖于历史数据,缺乏非线性、不连续的推理演绎能力,在提供前瞻性技术洞察和创新思考方面存在明显的不足(Zhu 等,2019)。第二种是以专家意见为基础的主观洞见路径,包括头脑风暴(Gallupe 等,1991)、技术路线图(Phaal 等,2004)、情景分析(Postma 和 Liebl,2005)和德尔菲法(Okoli 和 Pawlowski,2004)等方法。主观洞见虽然为理解未来技术和市场发展提供了宝贵的视角,但过分依赖于专家经验,存在着主观性强、权变性弱与适应性不足的问题,难以应对快速变化的技术环境和全局市场需求。针对上述两种预测路径的局限性,本文提出一种融合机器智能与人类智慧的未来技术预见模型(Jarrahi, 2018),以期实现专家建议和人工智能的优势互补。

未来技术预见模型在方法论上实现了人机双重推理路径的协同融合:在机器智能层面,该模型以图神经网络(Graph Neural Network,GNN)为核心,将"技术—产业—资金"异质图作为结构化知识载体,通过节点表示历史数据中的因果关联路径。这一过程虽未显示因果图谱,但其在功能上具备由观测结构反推出因果关系的能力,可视为机器层面的广义溯因推理路径,在结构建模中实现对未来趋势的解释性生成(罗仁地和姚洲,2023)①。在人类智慧层面,该模型引入专家群体对关键技术的排序评估与潜力判断,构建基于认知经验的主观溯因推理机制。该机制通过"基于专家经验的排序度量损失"函数嵌入模型训练过程,使专家判断以标签形式参与模型更新,从而补全机器智能对突变性、跨领域跃迁等复杂场景的认知盲区。两类推理路径协同驱动,共同构建了具备结构感知能力与知识注入能力的未来技术预见框架,在多维数据与专家经验的双重支持下,提升了该模型在复杂技术趋势预测中的泛化性、解释性与前瞻性。与传统仅依赖于归纳或演绎推理的技术预测方法不同,本文的模型实现了归纳、演绎与溯因推理的系统融合,在理论层面突破了既有范式,在实践层面提供了更具适应性的未来预见工具。具体而言,大语言模型、知识图谱和图神经网络为代表的人工智能算法能够增强人类信息获取和处理能力,为人类智慧向深远触及提供强大辅助;而人拥有机器难以模拟的想象力和创造力,人类智慧可以基于自身感知和社会经验进行未来技术预见和产业变革洞察(Billinger 等,2021)。融合专家主观洞见与机器智能的未来技术预见模型的主要流程包括:(1)机器智能部分:通过构建"技术—产业—资金"异质图,整合多源异构数据,并在多任务学习框架下完成技术与产业潜力的初步评估。(2)主观洞见部分:

① 本文的溯因推理是广义层面的,即在构建技术发展和产业变迁因果链的基础上,机器智能能够实现类溯因操作,而狭义层面的溯因推理强调"形成解释性假说的直觉飞跃",仍严重依赖于人类认知。

基于第一轮评估结果,邀请近千位战略科学家、产业专家和青年学者进行深度分析与反馈,形成科技评论库。(3)人机协同优化:结合“基于专家经验的排序度量损失”优化算法,将主观反馈嵌入模型,利用大小模型协同机制挖掘深层次语义信息,并通过多轮迭代实现技术趋势矩阵的最终输出。

本文的主要创新点包括:(1)深度融合机器智能与主观洞见:提出了人机混合智能决策机制,结合异质图与多任务学习,有效弥补了单一方法中存在的推理演绎不足或过拟合等缺陷,实现对新质生产力未来技术发展的多维表征和预测。(2)科技评论库的构建:整合近千位战略科学家、产业专家和青年学者的意见,形成涵盖多视角、多维度的科技评论数据库,填补机器智能无法认知突变性、跨领域跃迁等复杂场景的盲点。(3)优化模型框架:创新性地结合深度对比学习、时序知识图谱与动态平衡策略,优化有监督与无监督学习的协同效果,提升预测精确度和可靠性。(4)技术与产业潜力的量化评估:通过构建“技术—产业—资金”间的复杂关系网络,全面捕捉技术与产业之间的关联,为新质生产力的未来技术预见提供科学依据。(5)新质生产力的未来技术预见:基于未来技术预见模型形成了七大关键领域未来0~5年、5~10年、10~20年和20年以上的新质生产力技术趋势矩阵,科学预见新质生产力的未来技术发展进路。

二、文献回顾与综述

(一)新质生产力的文献回顾

“新质生产力”概念一经提出,便引发了学术界的高度关注和积极响应。现有文献主要聚焦于三个方面:一是内涵界定与逻辑机理分析。陈劲(2024)认为发展新质生产力的“本质”在于强化科技创新,“介质”在于激活数字科技,“品质”方向为绿色发展。尹西明等(2025)则指出新质生产力是创新起主导作用、科技创新为内核的先进生产力,并遵循实践、发展和理论等内在发展逻辑。周文和许凌云(2024)基于政治经济学视角,从“新”和“质”两个方面把握新质生产力内涵特征。此外,部分学者以传统生产力的特质为参照,对新质生产力的概念、内涵及作用机理展开深入探讨(胡莹和刘铿,2024;苏世彬和蔡丽敏,2025)。二是指标测度与区域差异分析。陈钰芬等(2025)基于“投入—过程—产出”视角,从投入质量、生产活力和产出效能等维度构建新质生产力评价指标体系,考察中国整体及各省份发展差异情况。任保平等(2024)从智能化、绿色化、创新化、人本化、产业发展与安全、制度环境等方面构建了中国制造业新质化发展水平评价体系。董庆前(2024)构建了包括劳动者、劳动资料、劳动对象和优化组合跃升四个维度的新质生产力评估体系,考察新质生产力发展水平的动态演进及空间收敛情况。三是影响因素与结果效应分析。韩文龙等(2024)在测度中国新质生产力水平基础上,进一步考察新质生产力对中国经济增长的影响机制。马银琦等(2024)考察高等教育资源配置对新质生产力发展的促进作用及空间溢出效应。任宇新等(2024)分析了金融集聚、产学研合作与新质生产力之间的互动关系。还有学者从企业层面实证考察新质生产力与企业ESG发展(宋佳等,2024)、企业内部薪酬差距(肖有智等,2024)、企业数实技术融合(张沥幻和张金昌,2024)和企业基础研究(刁海璨,2025)等因素之间的作用关系。

虽然前述研究对新质生产力的逻辑机理、测度评价和影响效果等进行了广泛探索,但局限于考察新质生产力的历史演变,缺乏从前瞻预见视角探究新质生产力的未来前景。陆岷峰(2025)基于趋势预测视角,主观分析了在近期、中期和长期等阶段数据要素对新质生产力发展的促进作用。孙贵祥和任苏灵(2024)利用变权组合预测模型预测了中国2023~2027年新质生产力发展水平。上述

两篇文章虽然从预测这一特殊视角探究了新质生产力的未来发展,但采用的主观预测或实证模型单一方法往往存在过拟合、数据扰动大等预测精度低的缺陷,导致预测结果偏差较大。有鉴于此,本文将采用融合“主观洞见+机器智能”的未来技术预见模型对新质生产力发展的技术趋势进行科学预见。

(二)机器智能与主观洞见的相关研究

机器智能方法整合了统计模型以及数学建模等量化手段,通过分析大量历史数据,以量化方式预测技术的未来发展趋势(陆伟等,2020;Kim和Bae,2017;Zhang等,2016;Altuntas等,2015;熊焰等,2023)。主观洞见方法主要依靠专家的经验和直觉,包括通过整合技术绘制发展趋势的技术路线图(Phaal等,2004;Robinson等,2013)、通过构建未来场景来理解不确定性的情景分析(Postma和Liebl,2005)、利用专家多轮匿名问卷投票形成共识的德尔菲法(Okoli和Pawlowski,2004)等,以专家主观判断为参考依据开展技术与产业预测。在决策活动与预见分析中,不论是机器智能还是主观洞见方法,都可以利用大语言模型、知识图谱和深度学习等机器智能技术降本增效(Vaswani等,2017)。

机器智能的优势在于其能够处理和分析大规模数据集,识别复杂的模式和趋势,提供快速、客观的分析结果(Clough和Wu,2022)。这种方法能够在短时间内完成人类难以手动处理的大量数据计算,为决策提供基于数据的支持。然而,机器智能过分依赖于历史数据和现有模式,难以有效处理未知情境下的非线性和不连续变化,同时缺乏对人类情感、文化背景和伦理道德因素的感知,而这些往往在决策过程中扮演重要角色。相比而言,主观洞见的优势在于融合了人类的直觉、经验和创造力,能够在复杂、不确定的情境中提供深刻的洞察和创新的解决方案。人类决策者能够基于经验快速做出判断,理解复杂的人际关系和文化背景,考虑伦理道德因素,这些是机器目前无法完全复制的(Balasubramanian等,2022)。但主观洞见易受个人偏见的影响,普遍缺乏客观性和可重复性,且在处理大数据时效率、精度较低。总体而言,机器智能和主观洞见分别具备上述若干优势,在决策分析中必须重视将两者优势相结合,在未知的复杂场景中提供更为全面、科学的技术和产业预见分析。

(三)未来技术预见模型的起源与发展

本文提出的未来技术预见模型本质上是一种人机混合智能决策系统,通过融合机器智能与人类智慧进行未来技术和产业潜力的科学预见。人机结合这一概念最早可追溯至20世纪50年代,Fitts首次提出人机功能分配的概念,即根据人和机器的长处将系统中任务进行合理分派的过程(Fitts,1951)。人机功能分配的理念一经提出便广泛应用于工业与自动化领域,尤其是在核电监控、载人航天、空中交通管制等复杂系统的设计上(汤志荔等,2010)。此后,学界开展了一系列关于“人—机”相结合的研究。Licklider(1960)构想了“人机共生”(Man-computer Symbiosis)理念,认为未来人类大脑将与计算机紧密融合,形成一种互相依赖的共生关系。Lenat和Feigenbaum(1991)提出人机协同预测的概念(Man-machine Synergy Prediction),认为智能计算机和人类智能之间存在一种协同合作关系,各自执行所擅长的任务。路甬祥和陈鹰(1994)立足于机械科学立场提出“人机一体化”(Humachine)系统思想,强调人类与机器优势互补、平等协作以实现更高效益。此外,钱学森等(1990)提出的人机综合集成法是基于经验知识和专家判断的定性研究和参数模型的定量分析相结合的集成方法。刘伟(2017)提出了人机智能融合理念,强调人机智能融合系统是未来智能科学的演变进路。吴冠霖等(2023)认为将人的意向性与机的形式化相结合的人机智能融合系统,能够破解机器智能在军事作战决策领域中的障碍,提升实际军事作战决策

水平。

上述研究均为人机混合智能决策系统提供了重要的参考价值,总结这些研究可发现相似点,即从系统设计规划至系统实现及运行的整个生命周期过程中应充分考虑人类智慧与人工智能的交互关系。然而,既有研究主要聚焦于静态的任务分派机制(汤志荔等,2010)、单向的辅助决策模式(Lenat 和 Feigenbaum,1991)或特定领域的功能互补框架(吴冠霖等,2023),在动态协同机制与复杂系统预见层面仍存在明显的研究空白。相较于传统人机系统研究的单向度功能整合,本文创新性地构建了"双向融合—动态演化"的智能增强回路。一方面,通过深度学习算法实现多源异构数据的融合挖掘,形成技术演化规律的量化表征;另一方面,借助人类智慧涌现机制,将专家的隐性知识转化为可量化的决策参数,突破了"人机共生"构想中单纯相互依赖的局限性。这种"数据驱动+知识引导"的双引擎架构,既超越了人机综合集成法中定性与定量分析的简单叠加范式,又显著拓展了"人机一体化"系统在动态适应性方面的理论边界。

此外,大多学者聚焦于理论框架构建上,提出的人机混合决策机制往往停留在"人类监督+机器执行"的表层交互层面,而鲜有学者基于人机混合智能理念对新质生产力的未来技术进行科学预见。有鉴于此,本研究提出一种融合专家主观洞见与机器智能的未来技术预见模型,通过图神经网络来动态关联技术与产业,以探究关键产业领域的新质生产力未来技术趋势,有效填补理论构想与实践应用的鸿沟。本模型优势在于既具备机器智能的大规模数据处理和模式识别能力,又能够借助人类的创造力、直觉和经验进行深层次的洞察和判断。需要注意的是,人机混合智能决策系统不是简单的"人脑+智能",其本质是强调人工与机器处理方向不同,人负责依据过往经验进行科学决策,智能负责进行海量数据处理,建立一种良性循环、互补互赖的"融合生态"(吴冠霖等,2023)。这种融合在弥补各自不足、提高决策的准确性和效率的同时,还能够在预测和解决复杂问题时提供更为全面和深刻的理解。通过人机交互和协作优化决策过程,使之更加灵活和适应性强,在面对新质生产力发展的高不确定性和复杂性时,提供更为有效的决策支持。

三、未来技术预见模型

(一)未来技术预见模型的框架设计

为了系统刻画技术、产业与资金之间的动态关联,并提升面向新质生产力的未来技术预见的准确性与解释力,本文设计了一种融合机器智能与专家主观洞见的混合智能预测模型。该模型基于图神经网络,构建涵盖"技术—产业—资金"三类实体节点及其关系的异质图,通过结构学习动态挖掘节点间的高阶关联路径,完成对技术演化趋势的结构化建模。该模型在推理机制上融合了广义溯因推理与归纳演绎策略:前者通过异质图中的因果路径学习,实现对历史演化逻辑的反推建构;后者通过深度学习模型提取跨模态特征,实现趋势预测与模式识别。同时,该模型引入专家认知路径,以"基于专家经验的排序度量损失"函数为桥梁,将战略科学家、产业专家与青年学者的排序判断转化为可学习标签,补强该模型在非线性跃迁与不确定性场景下的认知能力。算法上,该模型采用融合无监督深度对比学习与有监督多任务预测的混合式学习框架,兼顾表示学习的结构一致性与预测任务的准确性。最终形成一个集结构建模、知识注入与趋势预测于一体的混合智能决策系统,为未来技术演进与产业变革提供可解释、可量化的系统性支持。如图1所示。

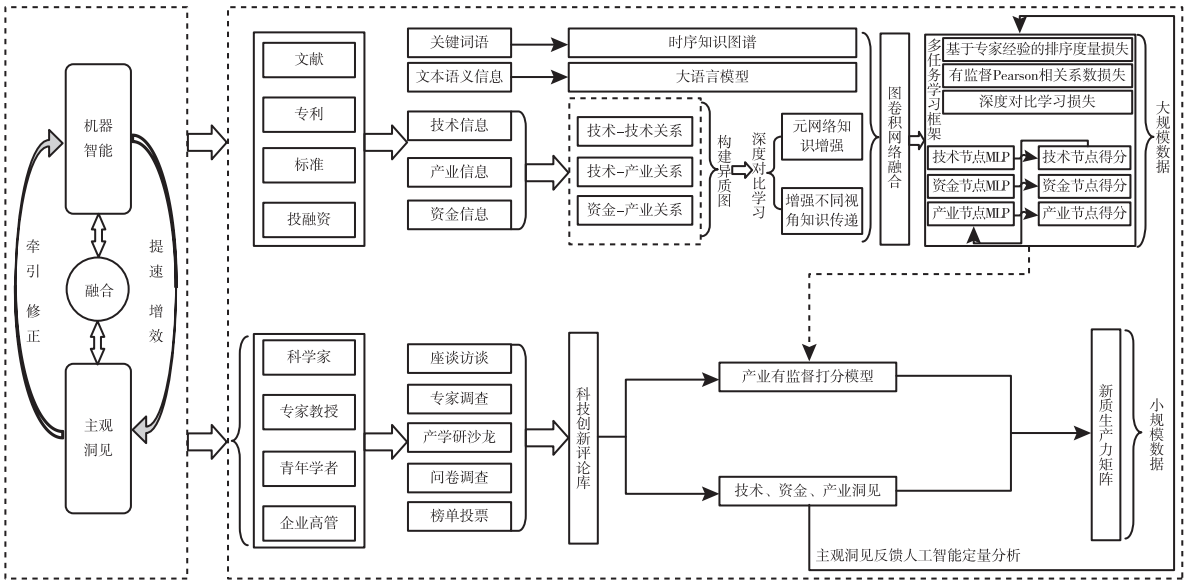

图1 未来技术预见智能大脑框架

第一,本文构建了一个异质图,包含“技术”“产业”和“资金”三个节点类型以及相应的关系边(Zhang等,2019;Wang等,2019)。为了准确表征技术和产业的复杂交互,本研究引入了专利、文献和投融资数据,构建了一个多源异构数据集。通过专利数据,提取了技术节点的基本信息(如专利号、技术领域、申请时间、引用、被引用和摘要等),并通过关键词和技术领域的分析,构建了技术节点的属性。产业节点在本研究中代表了特定行业或产业领域,它们不仅在技术发展过程中起到承载和推动作用,还与技术、资金等节点之间建立了多维关系。每个产业节点的属性包括了产业的历史表现(如公司数量、增长率等),以及与技术节点和资金节点的关联度。投融资数据则揭示了资金与产业之间的关系,通过投资事件与产业节点的连接,反映了资本对技术与产业的支持。这一异质图为模型的机器智能部分提供了丰富的语义信息和关系数据,旨在通过图神经网络来学习技术与产业之间的动态关联。

第二,在模型的设计上,本文采用溯因推理和归纳演绎相结合的策略。溯因推理是从历史数据和技术趋势出发,构建技术发展和产业变迁的因果链;而归纳演绎则利用机器学习方法自动发现数据中潜在的规律和模式,以支持未来技术的预见。这种结合为人机协同提供了有效的理论框架,确保了技术预见任务在面对复杂变量时既能依赖于历史经验,又能通过数据驱动的方式生成新的预测。在融合专家意见方面,本文分为两个步骤:第一步,将专家意见转化为标签并输入模型进行训练;第二步,邀请专家和青年学者对机器学习结果进行微调,借助“基于专家经验的排序度量损失”损失函数来优化模型结果,确保了专家的主观洞见能够有效地指导机器学习过程,这一过程大幅提升了模型的精度和泛化能力。

第三,为了提升模型的精度和适应性,本文设计了混合式学习框架,其中结合了无监督学习和有监督学习的优势。在无监督学习方面,深度对比学习能够通过自我探索和学习数据的内在结构,从未标注的数据中提取有效的特征;而有监督学习则能够通过多任务学习框架,精确地从标注数据中进行目标预测,从而确保模型在各种任务中的可靠性和准确性。

第四,基于人机协同的设计理念,本文邀请了近千名战略科学家和青年学者参与历史技术成果

的评价,通过调整“基于专家经验的排序度量损失”损失函数,确保了专家的主观洞见能够有效地指导机器学习过程。通过专家与AI的结合,模型不仅能够充分利用专家的领域知识,还能借助AI的计算能力实现更高效的决策。

(二)数据来源说明

本文的数据来源分为客观专利数据和主观评议数据两个部分。在客观专利数据部分,本研究选用IncoPat全球专利数据库作为核心数据源。作为国内外广泛使用的专业知识产权信息服务平台,IncoPat覆盖全球100余个国家和地区的专利数据资源,其权威性已获得国内外学界和业界的普遍认可。为确保数据完整性,本研究将初始数据采集时段设定为1985~2024年。但鉴于专利申请公开存在18~24个月的法定延迟周期,2023~2024年数据存在严重缺失,因此本文最终确定有效分析时段为1985~2022年。为便于读取和处理,原始数据按照年度进行拆分,总计包含超过4800万条专利的申请和授权记录①。此外,部分实验数据来源于国家知识产权局(CNIPA)、CIRD地级市专利数据和CnOpenData平台,这些数据与IncoPat数据在结构上具有较强的一致性,显著增强了研究结果的稳健性与适应性。

在构建中文专利文本数据集时,为平衡信息密度与文本长度,本文选取了“标题”“摘要”“背景技术”“第一独立权利要求”以及“IPC 主分类号”五个字段作为主要内容。其中,“摘要”通常涵盖第一独立权利要求的核心要素,能有效反映专利的核心技术特征。摘要的篇幅限制有利于控制输入文本长度,更契合深度学习模型对规范化数据的需求。有鉴于此,采用“摘要”替代“第一独立权利要求”进行中文专利分类模型的训练,可在保证技术特征完整性的同时提升训练效率。

在主观评议数据部分,本文邀请了清华大学机械工程、电子工程等7个理工科院系的522位硕博研究生作为青年学者样本,通过累计开展213场前沿技术研讨交流会,系统采集青年科研群体对未来技术路线的原始判断。同时组织青年学者与18位两院院士、32位专家教授、26位行业领军企业家开展深度访谈与主题沙龙,记录了专家群体和青年学者对未来技术方向的前瞻判断,最终形成涵盖代际观点碰撞、产学研视角融合的多维度未来技术预见数据集。主观评议群体的描述性统计如表1所示。

(三)实体节点构建与潜力评估

在构建了融合机器智能与人类智慧的未来技术预见模型后,本文进一步通过异质图来刻画技术、产业和资金之间的复杂关系,并整合多维度的数据以增强模型的预测能力。为了确保模型能够有效捕捉这些复杂的交互关系,本文构建了一个包含专利、论文和投融资数据的综合知识库,其中投融资数据包括上市企业年报数据、未上市独角兽公司和专精特新等公开数据。通过多源数据的结合,可以为技术、产业和资金之间的相互作用提供丰富的背景信息,帮助进一步提升技术预见的精准性和深度。

① 本研究所用的专利数据字段涵盖了专利的基本信息、技术内容、申请人及其工商背景,以及引用情况等多维度属性。主要字段包括专利唯一标识(ipzlid)、申请年份、申请日、标题、摘要、申请人、公开公告号及日期、申请号、专利类型、公开国别、首项权利要求、独立权利要求、文献页数、IPC主分类号、完整IPC分类、洛迦诺分类号、当前专利权人、申请人类型与国家地区、申请人地址、工商注册地址、公司类型、成立时间、统一社会信用代码、工商注册号、上市代码、企业状态、发明人、专利引用与被引情况(含自引与他引)、优先权信息(号与日期)、授权公告号与授权日期以及地理位置属性(省、市、县及其代码)等。

表1 主观评议群体的描述性统计 单位:人

分类统计	类型	数量	分类统计	类型	数量	分类统计	类型	数量
评议群体	两院院士	18	来源机构	高等院校	550	工作类型	教学科研	558
	专家教授	32		科研机构	20		智库研究	8
	产业专家	26		企业	28		技术研发	16
	硕士研究生	74	专业	电子电气	74		创意设计	5
	博士研究生	448		智能制造	82		技术顾问	5
年龄	25岁以下	469		生命医药	75		工业研发	6
	26~35岁	53		人工智能	81	工作年限	1年以下	502
	36~45岁	50		新能源	75		1~5年	20
	45岁以上	26		新材料	68		6~10年	18
学历	硕士	482		数理基科	73		10~15年	26
	博士	116		建筑土木	70		15年以上	32

1.技术节点构建与潜力评估

本研究基于专利数据构建技术节点,首先从4800万个专利数据中筛选出200万项专利作为研究样本,通过GPT-4o模型从专利摘要中智能化提取出669个潜在技术节点,再经过人工研判最终筛选出450个具有代表性的技术节点。此外,从专利节点中收集了过去五年内相对于当年技术节点的专利增长率,以及专家主观洞见的技术潜力标签,作为技术节点的核心特征。为了量化技术节点间的相对关系,本文采用了大规模预训练语言模型(如SciBERT)对技术节点名称进行嵌入(Embedding),并计算各技术节点之间的距离,只选择欧氏距离大于0.8的节点进行相连,从而构建了一个技术之间的关系图(见图2)。技术节点的属性包括过去五年内相关专利的增长率、这些专利的被引用率增长率等动态指标,体现了技术的历史发展与演变趋势。这些节点属性为评估技术在未来五年内的潜力提供了基础。值得注意的是,技术节点之间的交互不仅表现在相同技术领域内的相似性,还包括跨领域技术之间的潜在关联。例如,不同技术领域之间可能因为共享的关键技术或应用场景而形成相互联系,从而推动技术创新的跨领域融合。

2.产业节点的构建与潜力评估

产业节点的构建紧密联系于技术节点的分布与发展。为了将技术与产业之间的联系有效建立,本文首先通过大模型为每个技术关键词预设了相对独立的产业类别,并将技术节点连接到这些产业节点上。每个产业节点的属性包括该产业相关公司数量在过去五年的增长率,反映了产业的历史增长情况。产业的未来潜力通过五年后的相对增长率以及专家的排序来加以评估。专家排序根据当前技术的应用前景、市场需求和技术成熟度等多维度因素进行预测,进而为每个产业节点分配一个潜力评分。此外,产业节点之间也存在相互交互,尤其是那些在技术创新、市场需求、资源共享等方面相互依赖的产业。例如,某些高科技产业可能与传统制造业有着紧密的联系,它们在技术进步和市场变化中相互推动、共同发展。

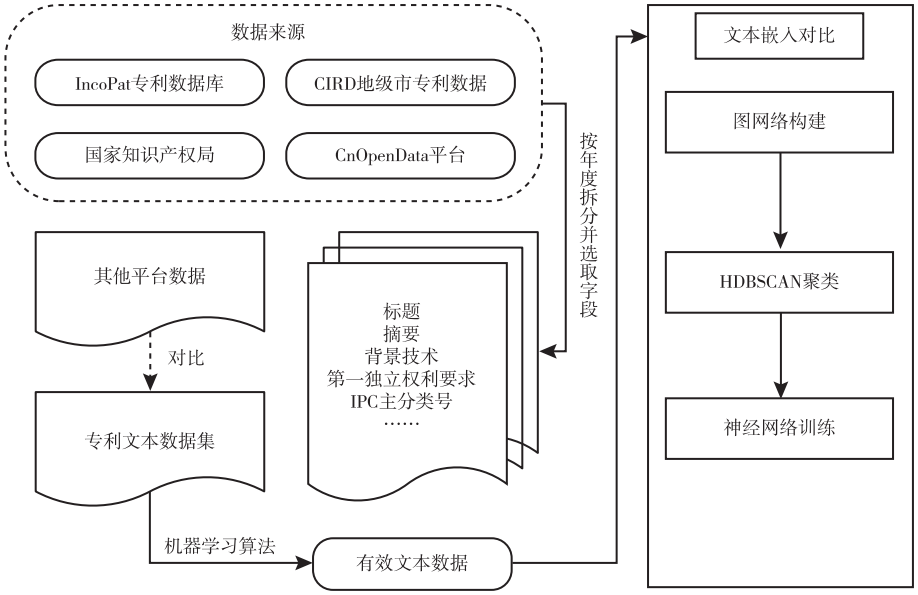

图2　技术节点构建路线示意图

3.投融资节点的构建与分析

投融资节点的构建旨在追踪资金流动对技术和产业发展的影响。为此,本文设定了过去十年内每年的投融资节点,代表每年对不同产业节点的资金投入情况。每个投融资节点与产业节点之间通过边的权重表示投资金额,反映了资金流向的强度与规模。通过分析投融资节点与产业节点之间的边权重关系,可以追踪资金流动的趋势,揭示资本对技术进步和产业发展的推动作用。此外,投融资节点之间也存在相互作用,资金不仅影响单一产业,还可能跨产业促进技术合作和资源共享,从而推动多个产业的协同发展。

表2展示了本文模型所使用的实体和关系数据统计,数据主要来源于专利、投融资和产业相关信息。实体数据包括技术、产业和投资节点,其中技术节点通过专利数量和专利被引数量的增长率来衡量技术的创新性与影响力,产业节点基于相关公司数量来反映产业的规模和发展,投融资节点则根据资金投入总额来捕捉资本对产业的支持。关系数据则涉及技术与技术之间的相似度(通过欧氏距离衡量)、产业与技术之间的依赖度,以及资金与产业之间的投资金额,这些关系帮助揭示了技术、产业与资金的动态相互作用。通过整合这些多源数据,模型能够更准确地预测技术和产业的未来发展趋势。

表2　　实体和关系数据统计　　单位:个

分类统计	类型	数量	属性
实体数据	技术	450	专利数量增长率,专利被引增长率
	产业	116	公司数量
	投资	10	投资总额

（续）

分类统计	类型	数量	属性
关系数据	技术—技术	2037	欧氏距离
	产业—技术	596	技术依赖度
	资金—产业	1160	投资金额

（四）图卷积神经网络构建

为了有效捕捉图中节点的特征以及节点间的复杂关系，本研究采用的图卷积神经网络（Graph Convolutional Network，GCN）通过邻居聚合或消息传递机制更新每个节点的特征表示，从而逐步捕捉更多的结构信息①。每个节点的特征不仅由其本身的属性决定，还会受到与其相邻节点的影响，这种机制帮助模型逐渐学习节点间的关系和依赖性。本文的异质图包含了三类节点："技术""产业""资金"，以及它们之间的复杂关系边。本文通过专利数据和技术关键词构建技术节点，产业节点通过产业规模和市场增长率来表征，而资金节点则通过投融资数据与产业节点建立连接。在GCN的训练过程中，这些节点的特征信息会通过图卷积层传递和更新。

节点特征聚合：在图卷积层中，每个节点的特征通过与邻居节点的特征进行聚合更新。对于技术节点，特征更新基于相邻技术节点的关系和属性；对于产业节点，特征则依赖于相邻产业节点及其资金支持信息。通过这种方式，节点的表示能力逐步增强，能够更全面地反映节点之间的关联性。

图卷积层的多层堆叠：图卷积操作是逐层堆叠的，随着GCN层数的增加，节点的特征表示将逐渐丰富。每一层GCN整合更多来自邻居节点的信息，使得模型能够捕捉到技术、产业和资金之间更复杂的关联模式。

节点关系的多维建模：通过这种图卷积神经网络，技术节点、产业节点和资金节点的多维关系得到了有效建模。例如，技术节点通过专利和技术领域关键词与产业节点建立联系，而资金节点则通过投资事件与产业节点相连接，反映资本对产业和技术发展的推动作用。这种建模方式帮助模型更精准地捕捉到技术、产业与资金之间的相互作用。

图3展示了本文模型的数据流过程。首先，在数据准备阶段，模型收集并处理了包括技术数据（如专利信息）、产业数据（如公司数量和行业增长情况）以及投融资数据（如投资金额等）在内的多种数据类型，并提取了关键特征如年度增长率和专利被引率等。其次，在图谱构建阶段，模型将这些数据转化为一个异质图，包含技术、产业和资金三类节点，节点之间的关系通过边来表示，比如技术与产业之间的依赖关系，以及资金与产业之间的投资流动关系。在图卷积神经网络阶段，模型通过多层GCN聚合节点特征，每一层GCN会根据邻居节点的信息逐步更新节点的特征表示，随着层数的增加，节点之间的复杂关系得到更深入的捕捉。最后，基于节点间的动态关系和更新后的特征表示，模型进行技术、产业和资金节点的预测，具体包括技术节点的潜力预测、产业节点的规模增长预测以及资金节点的增长率预测。

① 图卷积神经网络（GCN）是图神经网络（GNN）的一种具体实现形式。图神经网络泛指所有基于图结构数据设计的深度学习模型，而图卷积神经网络特指通过卷积操作聚合邻域节点信息的GNN分支，其核心是利用谱域或空域卷积提取图拓扑特征。

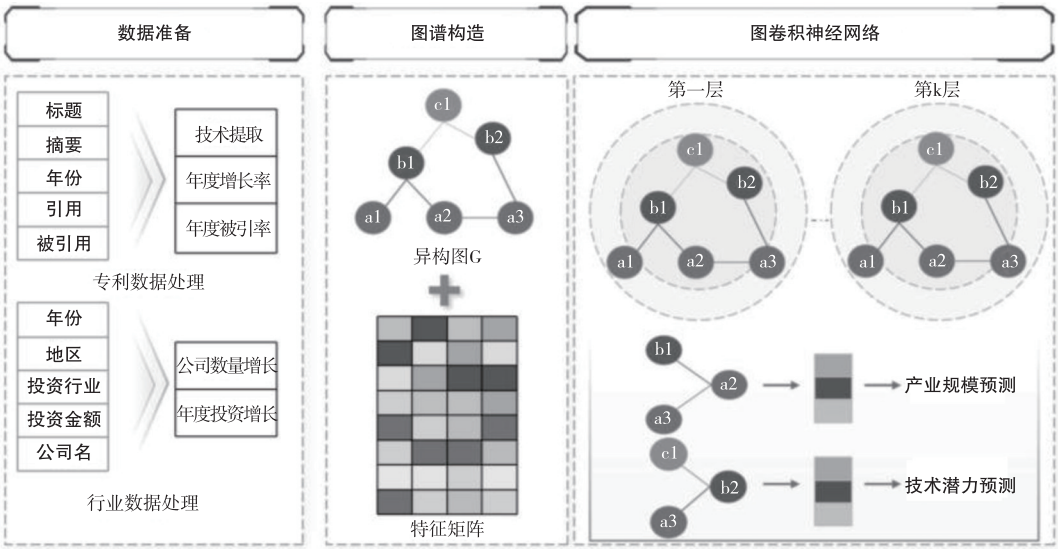

图3　图卷积神经网络数据流过程

(五)基于异质图的深度对比学习

在整合三个类型实体的基础上,本文引入了无监督的深度对比学习方法。通过设计正样本对和负样本对,模型将正样本对中的节点表示拉近,而将负样本对中的节点表示推远,从而有效强化实体间复杂相互作用的特征表示。这一方法不仅提高了特征学习的效率和有效性,还增强了模型对复杂数据结构的理解与泛化能力。如图4所示,技术链平面包括专利和论文描述的技术集合,产业链平面包括产业集合,资金链平面包括相关产业的投融资事件。

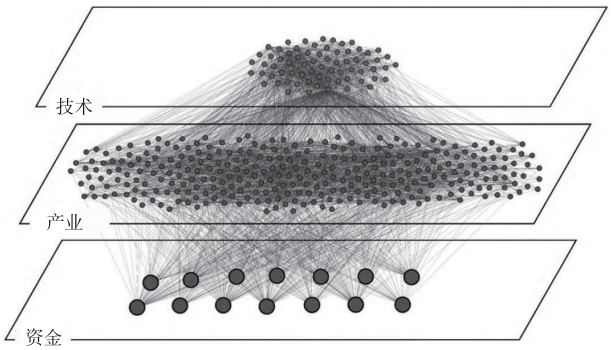

图4　"技术—产业—资金"三元异质图

通过设计合适的损失函数,模型能够有效地学习节点之间的相似性和区别性特征。这一过程能够显著提升节点特征的学习能力,并为多任务学习提供更加丰富和准确的输入。在技术和产业的回归任务中,如何应用对比学习以优化特征学习是至关重要的。对比学习的核心思想是通过将相似的节点对拉近,将不相似的节点对推远,从而学习节点的语义相似性和差异性。

在具体应用中,本文通过BERT模型对节点的原始名称进行编码,计算节点间的距离来评估相似性,然后通过专家调整来优化节点表示。通过这种无监督学习的方法,能够计算对比学习的损

失，从而有效训练模型。具体地，正样本对中的节点表示被拉近，而负样本对中的节点表示被推远，强化了节点间复杂相互作用的特征表示能力。这种方法不仅提高了特征学习的效率和有效性，还增强了模型对复杂数据结构的理解和泛化能力。损失函数的具体表达式如下：

$$L = -\sum_{(v_i, v_j)\in P} \log \frac{\exp\left[sim(z_i, z_j)/\tau\right]}{\sum_{k\in N_i} \exp\left[sim(z_i, z_k)/\tau\right]} \tag{1}$$

其中，v_i和v_j代表图中的一对相似节点；P代表正样本对的集合；z_i和z_j分别是v_i和v_j的嵌入向量；$sim(\cdot)$是相似度函数；τ是温度参数，控制相似度分布的平滑程度；N_i是v_i的负样本集合，即与v_i不相似的节点集合。通过深度对比学习，本文能够优化节点特征表示，提高模型在技术和产业节点的回归任务中的性能，同时提升其对复杂关系和多维数据的处理能力。

（六）构建多任务学习框架

为了提升模型在新质生产力预测任务中的精确度与可靠性，并增强其处理复杂数据结构的能力，本文设计了一个多任务学习（Multi-task Learning，MTL）框架，将多个损失函数结合使用，以优化模型在技术和产业节点预测中的表现。具体而言，本文整合了深度对比学习损失、基于专家经验的排序度量学习损失、有监督Pearson相关系数损失以及其他相关损失函数。每个损失函数的作用在于通过不同的方式优化模型的预测能力，并确保模型在各个任务中达到最佳的平衡。

1.深度对比学习损失

深度对比学习通过对比正负样本对来强化模型对不同技术领域的识别能力。具体而言，目标是通过将相似的节点对拉近，将不相似的节点对推远，以此提升模型学习节点语义相似性和差异性的能力。该损失函数表达式为：

$$L_{contrast} = FastAPLoss(X, Y) \tag{2}$$

其中，X和Y分别表示样本的嵌入向量和类别标签。

2.基于专家经验的排序度量学习损失

排序度量学习通过利用专家经验中的排序信息，优化模型预测结果的排序准确性。该损失函数表达式为：

$$L_{rank} = -\frac{1}{N}\sum_{(i,j)} \log\left(\frac{1}{1+e^{-P_{ij}}}\right) S_{ij} + (1 - S_{ij})\log\left(1 - \frac{1}{1+e^{-P_{ij}}}\right) \tag{3}$$

其中，对于N个成对样本集合，每对样本包含样本i和j，其真实标签差异表示为S_{ij}，如果i的排名高于j，则$S_{ij} = 1$；反之，$S_{ij} = 0$。对样本x的预测得分是$f(x)$，模型预测的分数差异为$P_{ij} = f(x_i) - f(x_j)$。

3.有监督Pearson相关系数损失

为了确保模型预测值与实际标签值之间的线性关系，本文引入了有监督的Pearson相关系数损失。该损失函数最大化模型预测值与实际值之间的相关性，确保预测结果与真实标签之间的关系更加精准。该损失函数表达式为：

$$L_{pearson} = 1 - \frac{\sum_i (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_i (x_i - \bar{x})^2 \sum_i (y_i - \bar{y})^2}} \tag{4}$$

其中，x_i表示模型的预测得分，y_i表示对应的实际技术指标，$\bar{x}$和$\bar{y}$分别表示x_i和y_i的均值。

在以上损失函数的基础上，本文结合了有监督与无监督的多任务学习策略。该策略通过引入任务相关的不确定度作为权重调整的依据，实现了对损失权重的自适应分配，其目的是在多个任务

之间实现最佳平衡。具体的多任务损失函数表达式为:

$$L = \sum_{i=1}^{N}\left\{\exp\left(-\alpha_i\right)L_i + \log\left[1 + \exp\left(\alpha_i\right)\right]\right\} \tag{5}$$

其中,L_i是第i个子任务的损失值,α_i是对应的不确定度参数,$N = 5$是本文的子任务总数。

(七)机器智能融合主观洞见

通过科技评论库中的投票数据和预见分析,本文将主观洞见获得的认知以“基于专家经验的排序度量学习损失”的形式反馈给机器智能部分,使之获得更加准确的初始得分,经过几轮专家意见迭代后,模型在准确性和泛化能力方面都有所提高。在模型训练后,本文针对若干重点领域输出了技术和产业排名,邀请专家和青年学者基于以上重点产业领域分析未来0~5年、5~10年、10~20年和20年以上的技术趋势,形成新质生产力发展的未来技术趋势矩阵。这一过程有效融合了机器智能与专家知识,提高了预测结果的科学性和前瞻性。

四、模型效果评估

(一)消融实验与可靠性分析

本文进一步通过消融实验分析了各个模型组件的重要性,尤其是基于聚类、技术链和产业链的对比学习损失和基于异构图的元对比学习损失(见表3)。这些实验通过计算均方根误差(Root Mean Squared Error,RMSE)来评估去除特定模型组件后的性能影响。消融实验的结果如图5所示,移除任何一个关键组件都会导致性能的统计显著下降,其中基于技术链的对比学习损失去除后性能下降最为显著。这一发现强调了这些组件在增强模型预测精度和捕捉数据深层特征中的关键作用,并指出在实际应用中维持这些组件的重要性。同时,图6展示了对应的实验训练过程。

表3　消融实验分析

节点类型	完整方法	去除基于聚类先验的对比学习损失	去除基于技术链传统指标先验的对比学习损失	去除基于产业链传统指标先验的对比学习损失	去除基于异构图的元对比学习损失
技术	0.113	0.105	0.101	0.096	0.092
产业	0.132	0.126	0.125	0.120	0.120

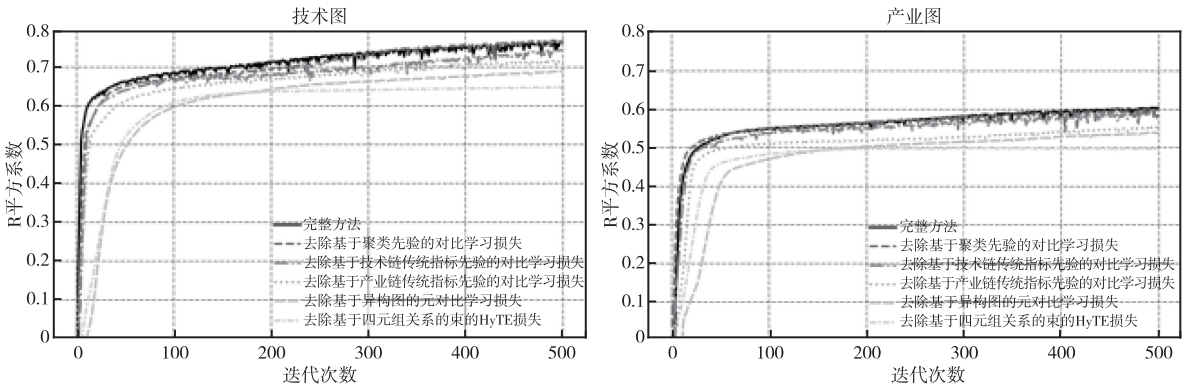

图5　消融实验分析

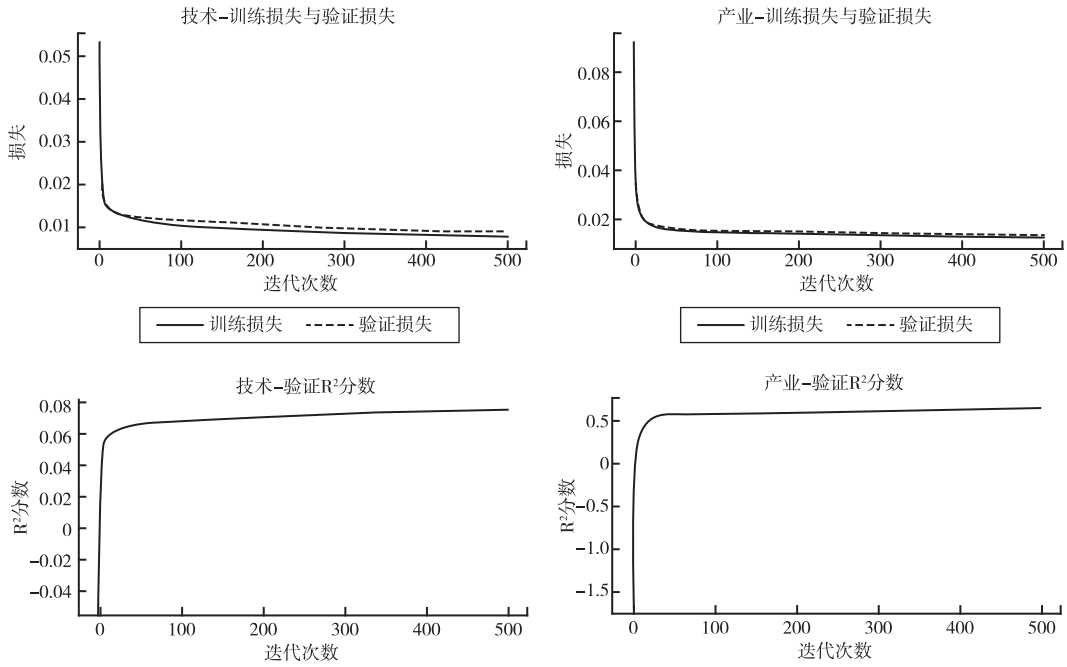

图6　实验训练过程

在验证模型的科学性和预测的可靠性方面，图7详细展示了技术、产业和资金三种主要节点的预测效果。这些结果通过散点图和最佳拟合线展示，显示了模型在捕捉各节点特定动态的能力。技术节点的高决定系数（R^2=0.765）表明模型能够准确捕捉技术变化的主要趋势。而产业节点和资金节点虽然决定系数较低，分别为0.604和0.393，但这些结果仍有助于理解模型在这些领域的应用潜力和限制，特别是在资金流动不稳定和受外部经济因素影响较大的情境中。

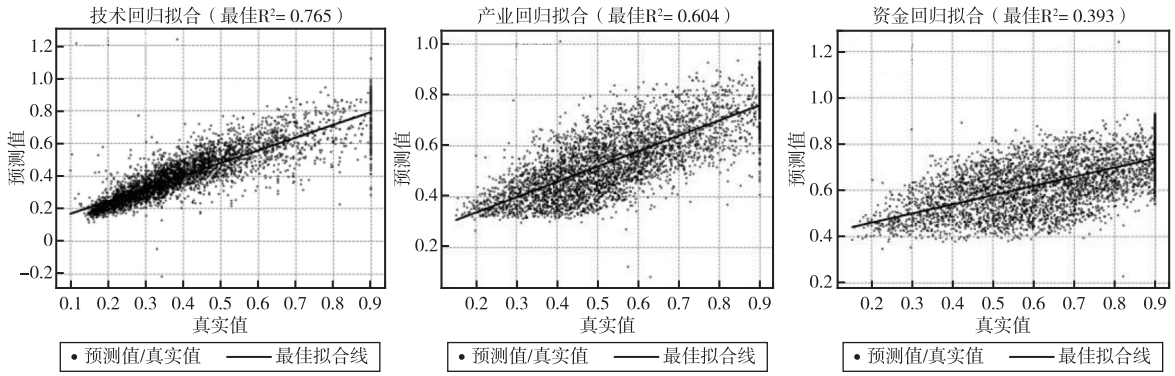

图7　三种主要节点预测效果展示

此外，图8展示了含专家洞见残差的模型和不含专家洞见的模型的预测对比结果，本文发现后者在统计指标上表现更优（R^2约提高至0.770，MSE约降至0.008），但前者在处理复杂数据结构时显示出独特的鲁棒性和可解释性。残差分布图揭示了两种模型预测准确性上的差异，为进一步优化

模型提供了方向。这种图形化的结果解析不仅增强了研究结果的透明度,也便于专业和非专业读者更好地理解模型的性能及其在实际应用中的潜在价值。

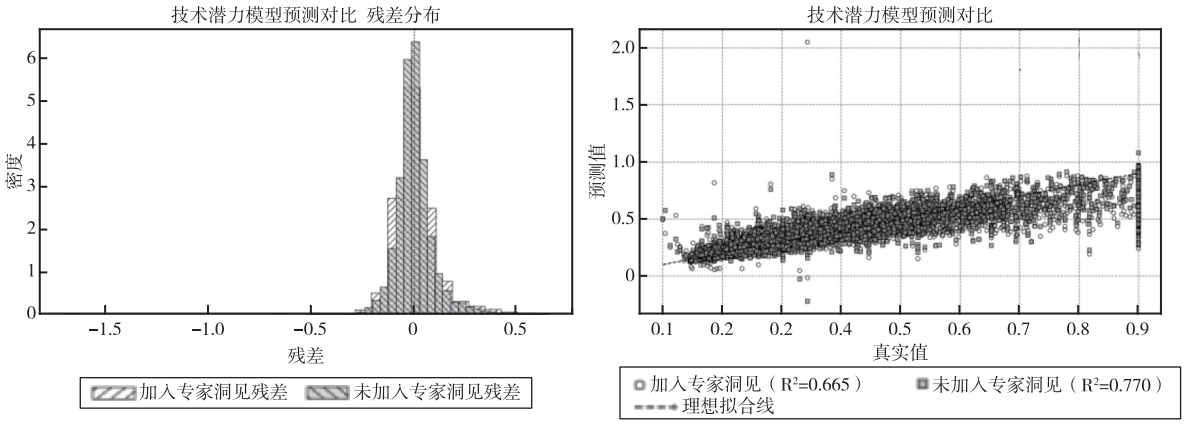

图8　技术潜力模型预测对比

(二)基于机器定量的技术潜力预测

本文利用历史数据对模型进行训练,以预测不同技术的发展潜力。首先,本文收集各技术领域相关的历史数据,包括专利、研究论文数量、市场需求等指标,并对这些数据进行预处理以适配模型需求。使用2000年以前的数据训练一个深度学习模型,该模型可能包括多层神经网络,能够处理时间序列数据,捕捉技术发展的动态特征。模型训练完成后,使用2000年的数据测试模型的预测能力,然后逐步使用2004年、2008年、2012年、2016年和2020年等更近年份的数据进行验证,每次预测后更新模型输入,以便更精确地模拟技术的实际发展路径。如图9所示,每条曲线代表模型对特定技术领域发展潜力的预测输出。其中,计算机视觉技术的预测潜力呈现出显著增长态势,反映了深度学习等技术的快速发展和广泛应用;遗传算法在前期快速

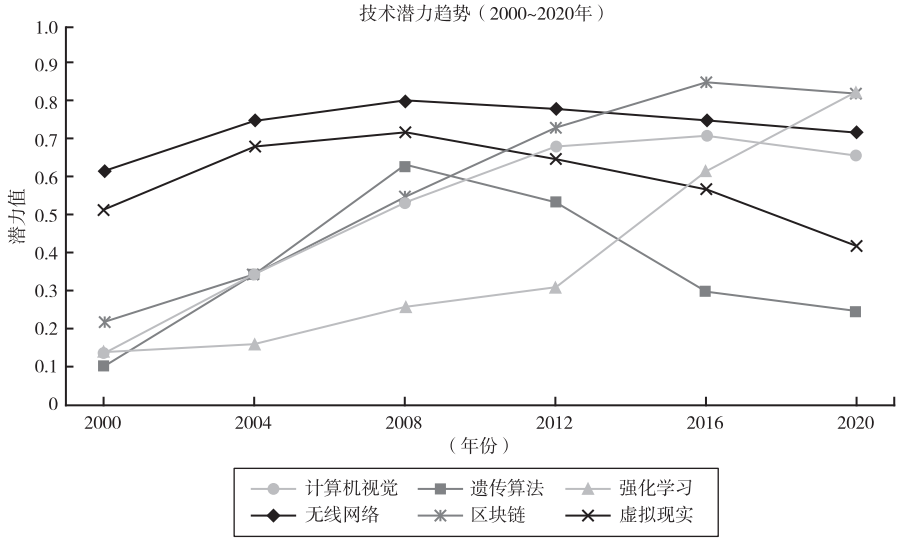

图9　典型技术潜力趋势分析

增长体现了遗传算法技术的迅猛发展，尤其是在移动互联网和物联网领域；强化学习的预测输出显示，其在2000~2012年发展较为缓慢，可能是因为这一领域技术创新和商业应用相对较少。

（三）专家评分与模型预测融合效果分析

为验证融合专家主观洞见和机器智能的未来技术预见模型在技术潜力预测中的有效性，本文利用雷达图对高潜力技术和低潜力技术分别进行了系统对比分析，如图10所示。这些图展示了真实得分、专家评分、模型预测评分以及模型专家混合评分的结果在不同技术维度上的表现，旨在评估模型的预测能力，并揭示未来技术预见模型人机混合系统的核心优势。

图10展示了信息与通信技术（ICT）领域中最高潜力技术的对比结果，包括边缘计算、量子计算和人工智能/机器学习（AI/ML）等代表性技术。从结果来看，模型专家混合评分在技术预测方面展示出卓越性能。除人工智能/机器学习（AI/ML）技术外，本混合评分机制在所有技术领域的评估得分与基准评估结果（真实得分）更为吻合，尤其是在量子计算、物联网（IOT）和网络安全等技术中，精准捕捉了技术潜力的关键特征。在人工智能/机器学习（AI/ML）技术中，模型专家混合评分在接近真实得分方面仅次于专家评分。这表明人机混合评分有效平衡了机器学习模型计算的精确性与专家知识的深刻洞察，在技术预测领域表现出更为接近真实状态的优异性能。证实了未来技术预见模型能够充分发挥人工智能的计算优势，同时弥补其在复杂社会经济环境中的短板。

图10同时展示了最低潜力技术的评估结果，包括公用交换电话网（PSTN）、调制解调器（Modem）、数字视频光盘（DVD）等传统技术。对于这些低潜力技术，模型专家混合评分预测同样表现出较高的贴合度，尤其是在PSTNN和DVD等技术领域，模型评分接近真实得分，展现出其在不同技术层次上的适应能力。相比之下，专家评分和模型预测评分在某些传统技术，如局域网（LAN）和调制解调器（Modem）上表现出较高的偏离倾向。通过融合模型和专家评分，未来技术预见模型成功平衡了预测的精准性和专家洞察的前瞻性，使得最终得分与真实得分的匹配程度显著提升。

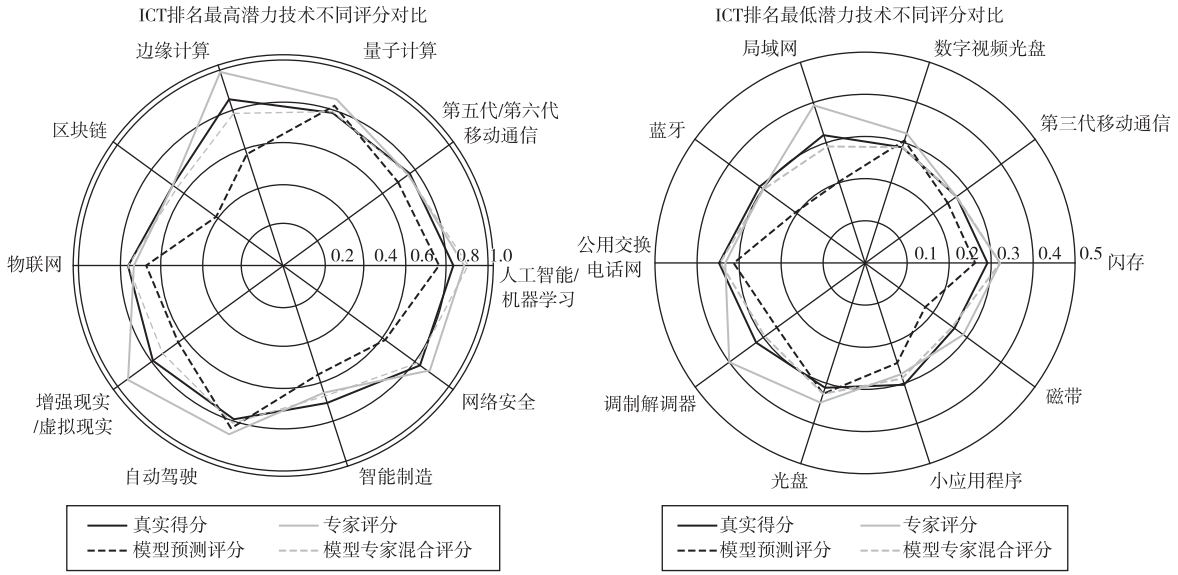

图10 ICT排名最高和最低潜力技术不同评价对比

(四)技术潜力预测效果的统计评估

为增强人机混合决策实验的说服力,本文进一步引入TOP-50命中率作为统计指标,对不同预测组在技术潜力判断中的表现进行量化评估。具体而言,本文选取数字科技、生命健康、新材料、高端制造、新能源、空间科技、电子信息七大关键产业领域,从每个产业领域中筛选出的200项核心技术,分别提取人工智能模型(AI组)、专家评分(专家组)与人机混合模型(混合组)输出的技术潜力TOP-50列表,并将其与实际表现突出的技术(真实得分前50项)进行比对,统计各组在TOP-50范围内的命中数与命中率。表4为各组在七大技术领域的TOP-50命中率统计结果。

表4　七大技术领域的TOP-50命中率统计

领域	AI组命中率	专家组命中率	混合组命中率
数字科技	62%(31/50)	72%(36/50)	84%(42/50)
生命健康	60%	68%	82%
新材料	58%	70%	80%
高端制造	55%	65%	78%
新能源	60%	67%	81%
空间科技	63%	69%	83%
电子信息	59%	66%	85%

统计结果显示,混合组在多数领域中表现出最优的预测能力。例如,在数字科技领域,混合组TOP-50命中42项,命中率为84%;相比之下,AI组与专家组命中(率)分别为31项(62%)与36项(72%)。在生命健康、新材料和电子信息等多个领域,混合组的命中率均稳定在80%以上,明显优于AI组与专家组的单一预测结果(见图11)。该结果表明,面对技术路径复杂、数据异构性高的未来技术预见任务时,人机结合模式通过“结构建模+认知注入”的协同机制,有效克服了机器模型对历史路径的惯性依赖与专家评分在知识迁移上的局限性,从而实现更具稳定性与准确性的潜力判断。TOP-50命中率的引入也从量化精度的维度强化了本文研究模型的实证优势,为人机融合模型在技术趋势预测场景下的可靠性与可推广性提供了强有力支持。

上述分析清晰地展现了人机混合智能的核心优势:人工智能技术(如大语言模型和神经网络)通过精准的数据挖掘与特征提取,能够高效地识别技术潜力特征,同时,人类专家基于其独特的创造性思维和对社会经济规律的深刻理解,为潜力评估注入了不可替代的经验洞察。两者的深度融合,不仅克服了各自的局限性,还能够显著提升技术和产业耦合发展的决策能力。

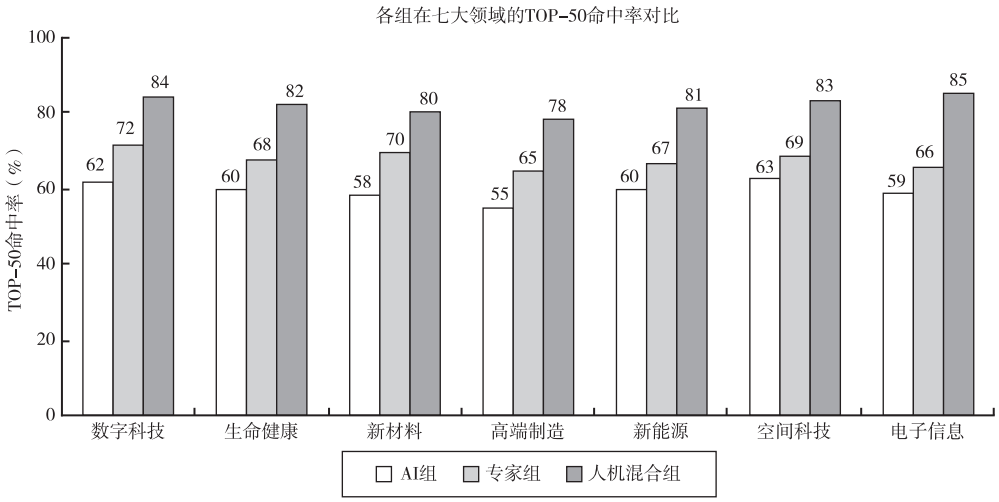

图11　各组在七大领域的TOP-50命中率对比

五、新质生产力未来技术预见示例

本文以生命健康、数字科技、新能源、新材料、空间科技、高端制造和电子信息七大赛道为例，基于未来技术预见模型分析了面向新质生产力的未来技术在不同生命周期阶段的演化趋势。每个赛道从科学引文索引（Web of Science）和德温特专利库中下载了引用量最高的20万个专利和20万篇论文的主要信息。同时，通过企名片、产业通、万得和Crunchbase下载了2014~2024年上市企业年报数据和未上市的独角兽、专精特新企业的投融资数据。本研究团队租用16台A100（80G）服务器作为算力平台，分领域构建了异质图，每个异质图在分析的时候等距离采用1∶10的采样比，运行10次取平均值，单次运行时间为20小时。在机器智能部分进行模型训练后，将第一轮技术和产业得分汇总，按照排名筛选了每个领域20个产业和相关的200个技术，依托清华大学的未来产业协会，每个领域组织25~30位相关方向博士生进行校对和修正，记录了增删意见并通过度量学习损失反馈给算法。为节省算力，第二轮算法运行不再进行异质图层面的训练，只进行MLP层面的优化，在结合了第一轮反馈意见之后，输出第二轮技术和产业得分，筛选该领域5~10个产业及相关技术。组织青年博士生针对清单上的技术和产业预约该领域战略科学家、产业专家和青年学者的开放交流时间或餐叙，交流并记录意见领袖们对这些技术的看法。结合第二轮反馈意见，再次运行算法并重新输出技术和产业评估得分，筛选每个领域5个最有潜力的产业，每个产业筛选10个最有潜力的技术。针对该清单，本文依托未来产业协会及科技评论编辑部，组织和举办院士交流沙龙30余次、产学研沙龙50余次和未来产业天才预见沙龙100余次，并结合了“青年最关注的改变未来十大变革”超9000位研究生的投票统计数据，最终形成了新质生产力发展的未来技术趋势矩阵，篇幅所限，具体结果见附表1①。

从七大领域的未来技术趋势矩阵来看，新质生产力的未来技术发展在整个生命周期过程中呈现显著的技术演化路径与跨领域协同特征。在数字科技领域，技术演进呈现从架构优化向量子融合的阶梯式发展：未来五年无服务器架构将主导SaaS与云计算，边缘智能设备实现AI应用推广；5~

① 本文附录详见《数量经济技术经济研究》杂志网站，下同。

10年量子计算能力开始云服务化,工业物联网通过数字孪生实现系统优化;20年后将完成云计算与量子计算的全维度融合,构建人脑深度协同的操作系统。新材料领域凸显功能迭代与生态适应双重导向,水凝胶技术从生物医疗向环境感知系统演进,第三代半导体材料经历效率提升、商用拓展直至全光谱应用,可降解高分子材料最终实现零环境影响闭环。在新能源领域,氢能与氨能从分布式系统向全球网络升级,光伏技术从建筑一体化迈向空间能源采集,可控核聚变技术经历小型化实验后最终成为主导能源。电子信息领域的未来技术演进遵循"仿生—集成—量子"路径,类脑芯片从低功耗设计向全脑仿真突破,光计算技术逐步融合量子特性形成超级计算平台。高端制造领域的技术呈现"精密化—智能化—自主化"发展趋势,精密加工技术突破原子级精度,机器人实现从具身智能到超智能自主系统的跨越,增材制造未来将具备环境响应能力。空间科技领域展现"专用—通用—泛在"演进逻辑,大模型技术向通用人工智能升级,量子计算从算法验证发展到量子互联网构建,隐私计算最终实现全球安全数据网络。生命健康领域形成"治疗—预防—增强"技术矩阵,基因治疗从疾病根治扩展到人类进化调控,合成生物学实现从微生物改造到生态重建的突破,再生医学完成从组织修复到生命延续的质变。各领域技术发展既保持专业纵深又形成跨域融合,在"数字—物理—生物"三元空间构建起技术创新网络,展现出从单点突破向系统集成、从效率提升向范式革新的整体演进规律。

面向新质生产力的未来技术趋势矩阵的构建充分体现了未来技术预见模型的优势,通过结合专家的主观洞见与机器智能的计算能力,有效弥补了单一决策方法的局限性,显著提升了新质生产力未来技术预见的效率和精度。具体而言,矩阵的生成过程不仅依赖于传统的专家预测和经验分析,还通过机器学习和人工智能技术对大量数据进行深入分析,克服了人类专家在面对复杂技术演化和产业趋势时的有限理性和经验主义偏差。此过程实现了溯因推理和归纳演绎的有机结合,使得技术趋势的预测不仅具备了较强的理论基础,还能充分考虑到行业发展的动态变化和技术创新的复杂性。

通过这一决策系统,矩阵能够系统化地识别并量化各项技术在不同生命周期阶段的演化特征,同时结合行业需求、投资动向及技术潜力,提供了对新质生产力未来技术趋势的全面预测。矩阵还进一步细分了不同时间段(0~5年、5~10年、10~20年、20年以上)内各项技术的演进趋势,帮助政策制定者和行业决策者识别潜在的技术机遇和发展方向。相比于单一的专家主观决策或人工智能模型,本文的决策框架通过融合人类智慧和机器计算,不仅提高了预测精度,也有效避免了过拟合和推理演绎不足的问题。该矩阵为新质生产力的发展提供了清晰的战略路径,为技术趋势的识别、产业机会的发现以及未来产业体系的构建提供了科学依据,推动了技术与产业融合的可持续发展。

六、结论与政策建议

本文针对新质生产力未来预见这一议题,基于人机协同预测理念提出了一种融合机器智能与人类智慧的未来技术预见模型,为应对科技创新和产业变革面临的高不确定性、非线性和不连续性挑战,提供了一种全新的未来技术预见模式。本文首先构建了"技术—产业—资金"异质图,并运用图神经网络、深度对比学习等前沿技术构建出全面的机器智能框架。其次,运用该智能决策框架,从海量多源异构数据中挖掘深层洞见,结合科技评论库中汇集的战略科学家与产业专家的判断,展示出人机混合智能决策系统的强大力量。再次,进一步以生命健康、数字科技、新能源、新材料、空间科技、高端制造和电子信息七大关键产业领域为例,运用未来技术预见模型分析新质生产力发展

未来0~5年、5~10年、10~20年和20年以上的技术趋势。最后,本文主要研究发现:一是融合专家主观洞见与机器智能的未来技术预见模型,有效弥补了单一方法中存在的推理演绎不足或过拟合等缺陷,在持续进步能力、泛化性能、准确率等方面均表现良好,在复杂技术和产业估值预测中能够显著提升效率和精度。二是针对七大关键产业领域形成的新质生产力未来技术趋势矩阵,在整个生命周期过程中呈现出动态演化与跨领域协同特征,各领域的未来技术发展展现出从单点突破向系统集成、从效率提升向范式革新的整体演进规律。三是研究最终形成的新质生产力技术趋势矩阵,不仅为新质生产力未来技术发展预测提供了科学依据,也为有效提升技术创新和产业创新耦合发展的决策能力探索了新路径。

结合前文研究结论,为持续优化未来技术预见模型,加快培育和发展新质生产力,本文提出了以下政策建议。第一,应采取"数据治理—智能研发—平台支撑"的系统化策略,优化未来技术预见模型的机器智能体系。在数据治理层面,突破多源异构数据融合技术瓶颈,通过强化通用型信息融合算法研发,建立"政产学研用"协同机制,构建分布式联邦学习框架与动态知识图谱,实现跨领域数据的语义对齐与价值挖掘,为未来技术预见模型提供高质量数据支撑;在智能研发层面,实施"前沿探索—应用突破"双轨战略,一方面,超前布局神经科学、全脑仿真等未来科技前沿领域,为提升未来技术预见能力提供强大的前沿科技支撑;另一方面,重点攻关人机交互领域的技术难题,特别是对机器"直觉"技术的突破,通过赋予机器智能直觉推动其在非完备信息环境下进行联想学习、跨领域学习,推动机器智能突破对突变性、跨领域跃迁等复杂场景的认知盲区。在平台支撑层面,通过创建国家级技术预见平台,整合重点产业全链条数据资源,构建覆盖关键技术节点的动态追踪系统,确保技术发展路径清晰可追踪,为国家战略规划和产业升级提供精准支撑。

第二,应实施"分层协同—动态演化"的专家洞见体系优化方案,以更好适配机器智能体系。在专家洞见体系构建层面,应由国家主导建立三级梯度专家库:战略型专家智库聚焦宏观趋势研判,技术型专家团队深耕细分领域前沿突破,应用型产业顾问对接市场需求转化,形成覆盖"基础研究—技术开发—产业应用"创新链的知识网络。同时,应构建人机混合智能决策沙箱系统,采用生成对抗网络技术模拟多元技术演化路径,结合专家德尔菲法和强化学习算法进行策略博弈推演,建立基于贡献度评估的专家知识更新机制。最终形成"知识沉淀—智能增强—决策验证"的闭环优化体系,依托数字化平台实现专家贡献的可信存证与价值流转,确保未来技术预见模型的决策逻辑兼具专业深度与演化适应性。

第三,应构建"研发—标准—生态"三位一体的推进体系,以提升未来技术预见模型的战略价值。一是建立政府主导的智能决策系统专项基金,通过"揭榜挂帅"机制引导产学研协同攻关,重点支持针对不同产业领域的定制化人机混合智能决策系统的研发,以确保人机混合智能决策系统的实用性和创新性。二是支持建设人机交互技术标准和规范,确保不同系统和设备之间的兼容性和互操作性,为实现更加通用的人机交互奠定基础。同时,中国应寻求提升技术标准的制定话语权,积极主导下一代人机交互标准的制定,通过建立"一带一路"未来技术预见联盟,输出中国未来技术预见模型与方法论,以"中国方案"引领全球未来技术标准演进方向。

参 考 文 献

[1]陈劲.加快形成促进新质生产力发展的科技创新能力[J].今日科技,2024,(4):3.

[2]陈劲,朱子钦.全球未来产业的发展态势及对中国的启示[J].新经济导刊,2021,(3):4~9.

[3]陈钰芬,杨双双,胡思慧.新质生产力评价指标体系构建及测度分析——基于"投入—过程—产出"视角[J].科研管理,2025,(2): 1~11.

[4]刁海璨.企业基础研究与新质生产力培育[J].数量经济技术经济研究,2025,(3):91~110.

[5]董庆前.中国新质生产力发展水平测度、时空演变及收敛性研究[J].中国软科学,2024,(8):178~188.

[6]韩文龙,张瑞生,赵峰.新质生产力水平测算与中国经济增长新动能[J].数量经济技术经济研究,2024,(6):5~25.

[7]胡莹,刘铿.新质生产力推动经济高质量发展的内在机制研究——基于马克思生产力理论的视角[J].经济学家,2024,(5):5~14.

[8]刘伟.人机智能融合:人工智能发展的未来方向[J].人民论坛·学术前沿,2017,(20):32~38.

[9]陆岷峰.数据市场化赋能新质生产力:理论逻辑、实施模式与发展趋势[J].新疆社会科学,2025,(1):11~20+187.

[10]陆伟,李鹏程,张国标,程齐凯.学术文本词汇功能识别——基于BERT向量化表示的关键词自动分类研究[J].情报学报,2020,(12):1320~1329.

[11]路甬祥,陈鹰.人机一体化系统与技术立论[J].机械工程学报,1994,(6):1~9.

[12]罗仁地,姚洲.人工智能要考虑到溯因推理[J].长江学术,2023,(4):109~113.

[13]马银琦,许志通,张天雪.高等教育资源配置何以成为推动新质生产力发展的引擎——基于2012~2021年省级面板数据的实证分析[J].中国高教研究,2024,(8):23~31.

[14]钱学森,于景元,戴汝为.一个科学新领域——开放的复杂巨系统及其方法论[J].自然杂志,1990,(1):3~10+64.

[15]任保平,程至瑜,宗景辉.新质生产力形成中制造业新质化发展水平测度与时空演进[J].数量经济技术经济研究,2024,(12):5~24.

[16]任宇新,吴艳,伍喆.金融集聚、产学研合作与新质生产力[J].财经理论与实践,2024,(3):27~34.

[17]宋佳,张金昌,潘艺.ESG发展对企业新质生产力影响的研究——来自中国A股上市企业的经验证据[J].当代经济管理,2024,(6):1~11.

[18]宋跃刚,宋长青.新一代人工智能助推新质生产力形成和发展:运行机理与实践路径[J].中国经济学,2024,(2):1~25+286~287.

[19]苏世彬,蔡丽敏.因地制宜发展新质生产力:基于新质生产力指标体系构建及量化视角[J].中国经济学,2025,(1):1~25+240~241.

[20]孙贵祥,任苏灵.新质生产力内涵特点及发展状况研究——基于熵权法和变权组合预测[J].统计与管理,2024,(9):4~14.

[21]汤志荔,张安,曹璐,刘跃峰.复杂人机智能系统功能分配方法综述[J].人类工效学,2010,(1):68~71.

[22]吴冠霖,包卫东,牛莅原,曹江,王吉.从"可解释"到"可接受":一种作战决策背景下的人机智能融合新视角[J].指挥与控制学报,2023,(1):33~44.

[23]肖有智,张晓兰,刘欣.新质生产力与企业内部薪酬差距——基于共享发展视角[J].经济评论,2024,(3):75~91.

[24]熊焰,张凌恺,陈旭,江瑶.基于"突变—演化"模型的颠覆性技术识别方法及应用[J].情报杂志,2023,(12):119~126+152.

[25]尹西明,苏雅欣,陈泰伦,陈劲,余江.场景驱动:产业智能化加速新质生产力发展的逻辑与路径研究[J].中

国科学院院刊,2025,40(6):1070~1081.

[26]张沥幻,张金昌.数实技术融合、企业转型升级与新质生产力——基于A股制造业企业的实证检验[J].科技进步与对策,2024,(20):1~12.

[27]周文,许凌云.再论新质生产力:认识误区、形成条件与实现路径[J].改革,2024,(3):26~37.

[28] Balasubramanian N., Ye Y., Xu M., 2022, *Substituting Human Decision-making with Machine Learning: Implications for Organizational Learning* [J], Academy of Management Review, 47(3),448~465.

[29]Billinger S., Srikanth K., Stieglitz N., Schumacher T.R., 2021, *Exploration and Exploitation in Complex Search Tasks: How Feedback Influences Whether and Where Human Agents Search* [J], Strategic Management Journal, 42(2), 361~385.

[30] Clough D.R., Wu A., 2022, *Artificial Intelligence, Data-driven Learning, and the Decentralized Structure of Platform Ecosystems* [J], Academy of Management Review, 47(1), 184~189.

[31]Daim T.U., Rueda G., Martin H., Gerdsri P., 2006, *Forecasting Emerging Technologies: Use of Bibliometrics and Patent Analysis* [J], Technological Forecasting and Social Change, 73(8), 981~1012.

[32] Fitts P.M., 1951, *Human Engineering for an Effective Air Navigation and Traffic Control System* [M], Washington, DC: National Research Council.

[33] Gallupe R.B., Bastianutti L.M., Cooper W.H., 1991, *Unblocking Brainstorms* [J], Journal of Applied Psychology, 76(1), 137~142.

[34]Hu X., Rousseau R., Chen J., 2012, *A New Approach for Measuring the Value of Patents based on Structural Indicators for Ego Patent Citation Networks* [J], Journal of the American Society for Information Science and Technology, 63(9), 1834~1842.

[35] Jarrahi M.H., 2018, *Artificial Intelligence and the Future of Work: Human-ai Symbiosis in Organizational Decision Making* [J], Business Horizons, 61(4), 577~586.

[36] Kim G., Bae J., 2017, *A Novel Approach to Forecast Promising Technology through Patent Analysis* [J], Technological Forecasting and Social Change, 117, 228~237.

[37]Lenat D.B., Feigenbaum E.A., 1991, *On the Thresholds of Knowledge* [J], Artificial Intelligence, 47(1~3), 185~250.

[38]Licklider J.C.R., 1960, *Man-computer Symbiosis* [J], IRE Transactions on Human Factors in Electronics, 1(1), 4~11.

[39]Okoli C., Pawlowski S.D., 2004, *The Delphi Method as A Research Tool: An Example, Design Considerations and Applications* [J], Information & Management, 42(1), 15~29.

[40]Phaal R., Farrukh C.J., Probert D.R., 2004, *Technology Roadmapping-a Planning Framework for Evolution and Revolution* [J], Technological Forecasting and Social Change, 71(1~2), 5~26.

[41] Postma T.J., Liebl F., 2005, *How to Improve Scenario Analysis as A Strategic Management Tool?* [J], Technological Forecasting and Social Change, 72(2), 161~173.

[42]Robinson D.K., Huang L., Guo Y., Porter A.L., 2013, *Forecasting Innovation Pathways (FIP) for New and Emerging Science and Technologies* [J], *Technological Forecasting and Social Change*, 80(2), 267~285.

[43]Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A.N., Kaiser L., Polosukhin I., 2017, *Attention is All You Need* [C], arXiv, 1706.03762.

[44]Wang X., Ji H., Shi C., Wang B., Cui P., Yu P., Ye Y., 2019, *Heterogeneous Graph Attention Network* [C], arXiv, 1903.07293.

[45]Zhang C., Song D., Huang C., Swami A., Chawla N.V., 2019, *Heterogeneous Graph Neural Network* [C], Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, 793~803.

[46]Zhang Y., Zhang G., Chen H., Porter A.L., Zhu D., Lu J., 2016, *Topic Analysis and Forecasting for Science, Technology and Innovation: Methodology with A Case Study Focusing on Big Data Research* [J], Technological Forecasting and Social Change, 105, 179~191.

[47]Zhu X., Zhang G., Sun B., 2019, *A Comprehensive Literature Review of the Demand Forecasting Methods of Emergency Resources from the Perspective of Artificial Intelligence* [J], Natural Hazards, 97(1), 65~82.

Research on Future Technology Prediction Model for New Quality Productivity

CHEN Jin[1,2] ZHANG Keren[1] YANG Shuo[3] ZHU Ziqin[1]

(1.School of Economics and Management, Tsinghua University;
2.Research Center for Technological Innovation, Tsinghua University;
3.School of Marxism, University of Science and Technology Beijing)

Summary: Under the accelerated background of global scientific and technological innovation and industrial change, new quality productivity (NQP) is a key driving force for future economic development. NQP is an advanced form of productive forces led by scientific and technological innovation, which aims at fostering new industries, new models, and new driving forces. Compared with traditional productive forces, NQP has diverted from its reliance on high-consumption production materials, capital expansion, and cheap labor. It has shifted to being innovation-driven, quality-centered, and promoting high-quality development through a significant increase in total factor productivity. This concept is highly consistent with China's current historical process of advancing from high-speed growth to high-quality development, providing theoretical support that keeps pace with the times for the practice of Chinese-style modernization. Therefore, scientifically predicting and systematically planning the realization path of NQP and exploring its future technological trends in major industrial fields are urgent demands for promoting the deep integration of scientific and technological innovation and industrial innovation.

Future technologies for NQP are a technological system centered on innovation, focusing on strategic frontier fields such as artificial intelligence, quantum computing, biomanufacturing, and advanced materials. Through the collaborative evolution and systematic integration of multiple technology clusters, it promotes the in-depth reconstruction of production factors toward digitalization, intelligence, and greenness. The emergence of such technologies is highly dependent on original and disruptive innovations. Their development is characterized by unpredictability, high volatility, and high risk, posing a huge challenge to future foresight. The current technological prediction mainly falls into two paths. The first one is machine intelligence based on information technology. Although this method can efficiently process large datasets and provide in-depth, comprehensive, and real-time analysis, it overly relies on historical data and lacks nonlinear and discontinuous reasoning and deduction capabilities. It has obvious deficiencies in providing forward-looking technological insights and innovative thinking. The second type is subjective insights based on expert opinions. Although subjective insights provide valuable perspectives for understanding future technological and market developments, they overly rely on expert experience, which leads to problems such as strong subjectivity, weak weighting, and insufficient adaptability,

making it difficult to cope with the rapidly changing technological environment and overall market demands. In view of the limitations of the above two prediction methods, this study proposes a future technology prediction model that integrates machine intelligence and subjective insight to cope with the high uncertainty and complexity of future industries. The graph neural network method is regarded as the generalized abductive reasoning path at the machine level. The complex causal relationships among "technology-industry-capital" are reconstructed through structured learning. Further, expert ranking evaluation and potential judgment are introduced to form a cognitive enhancement mechanism based on subjective insights, thereby achieving the organic combination of abductive reasoning and inductive deduction.

The future technology prediction model is a human-machine hybrid intelligent decision-making system that deeply integrates machine intelligence and subjective insights. By constructing a multi-source data network covering heterogeneous graphs of "technology-industry-capital," and combining heterogeneous graph convolutional neural to dynamically mine the complex correlations among nodes, this model adopts a collaborative strategy of abductive reasoning and inductive deduction and supports the prediction of future technologies by analyzing historical causal chains and discovering machine learning patterns. A hybrid learning framework is designed to integrate unsupervised deep contrastive learning and supervised multi-task prediction, and the "ranking metric loss based on expert experience" function is introduced to transform the subjective insights of multi-level expert teams, such as strategic scientists, industry experts, and young scholars, into computable knowledge labels. Ultimately, a prediction system that integrates dynamic correlation modeling, multi-modal data fusion, and human-machine collaborative decision-making is formed, providing precise quantitative support for technological evolution and industrial transformation.

This study further selected seven major industrial fields to analyze the future technological trends of NQP. It finds that the future technology prediction model effectively compensates for deficiencies, such as insufficient reasoning and deduction or overfitting existing in a single method, and significantly improves the efficiency and accuracy in the valuation prediction of complex technologies and industries. The future technological trend matrix of NQP formed for the seven key areas indicates dynamic evolution and cross-domain collaboration characteristics throughout the entire life cycle. The future technological development in each area demonstrates an overall evolution pattern from single-point breakthroughs to system integration and from efficiency improvement to paradigm innovation. The decision-making framework in this study can fully explore the potential of NQP, provide scientific decision-making paths and quantitative evaluation tools for predicting technological trends and industrial opportunities, and promote the accelerated development of NQP and the construction of a modern industrial system.

Keywords: New Quality Productivity; Future Technology Prediction; Human-computer Hybrid Intelligence; Abductive Reasoning; Graph Neural Network

JEL Classification: C53; E11

（责任编辑：张容嘉；数据编辑：知　鱼；校对：石银凤）