

doi:10.19920/j.cnki.jmsc.2023.05.012

# 融合知识图谱与神经网络赋能数智化管理决策<sup>①</sup>

余艳<sup>1</sup>, 张文<sup>3</sup>, 熊飞宇<sup>4</sup>, 孟小峰<sup>1</sup>, 刘湘雯<sup>4</sup>, 陈华钧<sup>2\*</sup>

(1. 中国人民大学信息学院, 北京 100872; 2. 浙江大学计算机科学与技术学院, 杭州 310027;  
3. 浙江大学软件学院, 宁波 315048; 4. 阿里巴巴集团, 杭州 310052)

**摘要:** 知识图谱是感知智能通往认知智能的重要桥梁, 基于知识图谱的知识表示、融合、推理将对管理决策产生深远影响. 知识图谱能够有机集成符号表示和神经网络进行更有效的知识推理与决策. 本文提出一套基于知识图谱的神经符号集成推理框架及三个技术方法, 包括融合本体知识和生成模型的零样本决策、知识图谱嵌入表示学习增强结果异质性和可解释性、基于知识图谱的预训练模型增强面向下游任务的自动决策. 该“1+3”技术体系实现了“模型驱动+知识增强”, 在数智化管理决策中具有技术创新性. 该体系已在实际商务管理实践中落地与应用, 充分彰显场景创新性. 该体系也具备通用性, 可适用于多领域多情境的管理决策.

**关键词:** 知识图谱; 神经网络; 神经符号集成; 管理决策

**中图分类号:** TP3-05 **文献标识码:** A **文章编号:** 1007-9807(2023)05-0231-17

## 0 引言

以互联网、云计算、大数据与人工智能为代表的新兴技术的进步与迅速发展已成为我国数字经济的重要引擎. 我国“十四五”规划明确了“加快数字化发展, 建设数字中国”的发展纲要, 着重强调“数字化”与“智能化”, 提出要激活数据要素潜能, 充分发挥海量数据和丰富应用场景优势, 通过“用数赋智”, 推动数据赋能智慧企业乃至智慧产业. 因此, 融合数字化与智能化的“数智化”是我国当前技术变革的核心战略方向之一, 正在重新定义社会管理与国家战略决策、企业业务流程与管理决策、个人行为与决策的过程和方式<sup>[1-4]</sup>. 从“数”到“智”恰恰是管理决策的根本变革, 实现从“数据化”到“数智化”的新跃迁<sup>[5]</sup>. 在数智化过程中, 社会“像素”向更细粒度发展并极大提升了数字“成像”<sup>[6]</sup>, 数据要素成为生产力, 通过以直代曲、切分整合逐步逼近, 将以往决策“有限理性”

拓展到“极限理性”, 并以更快速、高效的方式在人与机器之间进行双向传输和理解, 机器智能与人类智慧的相互反馈机制得以增强<sup>[7, 8]</sup>. 这个无限丰富、细腻、复杂、动态的数智社会为企业的管理决策带来机遇, 同时也充满挑战.

特别地, 消费互联网、工业互联网所形成的万物互联使商务、政务、安全、健康、金融等领域的管理与决策不断涌现新模式、新方法. 从海量数据中获得知识与智慧, 基于分析与洞察, 发现新的管理逻辑和模式, 进而开展有效的管理决策, 是根本性研究主题. 围绕该主题的研究态势日益创新<sup>[9]</sup>. 传统的管理决策是线性、分阶段的, 其观察、解释、预测、决策等过程相互割裂, 不同阶段的决策主体往往依据独立的分析开展实践. 在数字时代, 管理决策以数据为中心, 决策主体呈现多元和交互, 各决策环节与要素相互关联反馈, 呈现非线性方式, 并向决策智能化方向发展<sup>[10, 11]</sup>. 大数据驱动的管

① 收稿日期: 2021-12-31; 修订日期: 2022-12-26.

基金项目: 国家自然科学基金资助项目(91846204; 72172155).

通讯作者: 陈华钧(1978—), 男, 湖北人, 博士, 教授, 博士生导师. Email: huajunsir@zju.edu.cn

理决策范式在信息情境、决策主体、理念假设和方法流程上都发生了深刻的变革<sup>[3]</sup>。以深度神经网络为代表的新机器学习模型进一步使能决策模式向智能化升级。然而,智能化的管理决策不仅仅是要通过大数据驱动的深度模型挖掘底层数据特征,也应将人们主观的认知、经验与知识融入到机器模型中,以此让大数据转化为人们“期望-确认”的决策价值。因此,既需要实现从数据中萃取知识来提升人的决策效率,也需要将知识融入大数据模型中来增强机器决策效率,以此构建一个“知识+模型”相互增强、相互补充的“数知融合、人机互益”的新型决策框架。

知识图谱(Knowledge Graph, KG)被视为人工智能由感知智能通往认知智能的基石之一<sup>[12]</sup>。在人工智能的认知理论中形成一个共识,即人的认知系统包含两个子系统:直觉系统主要负责快速、无意识、非语言的认知,即所谓感知层面的系统,感知智能是机器对语音、图像等进行感知的能力,例如对客体信号的自动捕捉与识别;逻辑分析系统是有意识的、带逻辑、负责规划和推理以及可以用语言表达的系统,具有解释数据、解释过程、解释现象的能力,能够对问题进行推理、规划、创作,进行正确的判断与决策。目前深度学习在感知智能方面具有优势,但在逻辑分析方面的能力依然有限,而知识图谱着重于加强逻辑推理与分析,可以弥补深度学习的短板<sup>[13, 14]</sup>。

知识图谱以最简单的三元组为知识表示基座,将以往以人工获取为主的“自上而下,逻辑优先”的获取方式转变为以大数据为基础的“上下结合,由简入繁”的获取新模式。更为重要的是,知识图谱能够有机融合专家知识与机器数据,是实现数据与知识深度融合,人与机器互为增益的有力技术手段。首先,知识图谱既有传统符号知识表示框架,也发展了基于数值向量的知识表示学习方法,这有利于将专家知识下沉,转化为更易于融入机器学习模型的数值化表示形式。其次,知识图谱天然有助于多模态数据的表示与融合,通过构建多模态知识图谱将主观认知获取的符号知识与机器感知采集的多模态数据相互链接,并在同一个表示空间进行融合处理,因而成为衔接感知

计算与认知计算的关键技术与方法。

此外,知识图谱的符号化表示也能极大提高深度模型的可解释性,促进人机交互,强化机器智能的可信任度,为机器决策与人工决策协同赋能,真正实现“人机互益”的智能管理与决策。人通过自然语言与机器互动,人的主观知识被传递给机器,并引导机器进行学习,人的主观知识也被深度融入到机器学习中,使得深度模型中蕴含更多的人类知识;机器反过来通过学习能力帮助人获取更多知识。

综上,数智时代的智能管理与决策,仅依靠数据驱动的算法智能是不够的,人类知识与智慧的博大精深也应纳入到智能决策框架与管理体系中。因此,本文提出基于知识图谱实现机器数据与专家知识的深度融合,并有机结合符号知识和神经网络,实现一种神经符号集成的推理框架(neural symbolic reasoning framework),为数智化管理与决策提供一种新的实现方法与技术路径。这一方法体系对管理决策的准则精细化、决策效果的精准化、决策结果的可解释性将发挥重要作用,具有技术创新性,同时该体系应用于商务管理,显示出其场景创新性。

## 1 知识图谱相关研究

知识图谱用于描述真实世界中的实体或概念及其之间的关系,是一种新的海量数据组织和领域知识管理方式<sup>[15]</sup>。知识图谱具有规模巨大、语义丰富、质量精良、结构友好等特性,可增强机器语言认知和机器学习能力,提升人工智能的可解释性。知识图谱相关技术发展至今,已具备体系化的构建方法、强大的语义理解能力和知识推理能力,并已经在语义搜索、智能问答、机器翻译、推荐系统等方面扮演着重要角色,在商务、金融、交通、医疗、安全等领域均有广泛应用,如图1。知识图谱赋能数智化管理决策源于其在知识表示、融合和推理三大环节上的技术突破,知识表示与融合激活数据的共享、流通和跨界关联,而知识推理则直接推动了从“数”到“智”的跃迁,通过模型激活数据的价值要素。

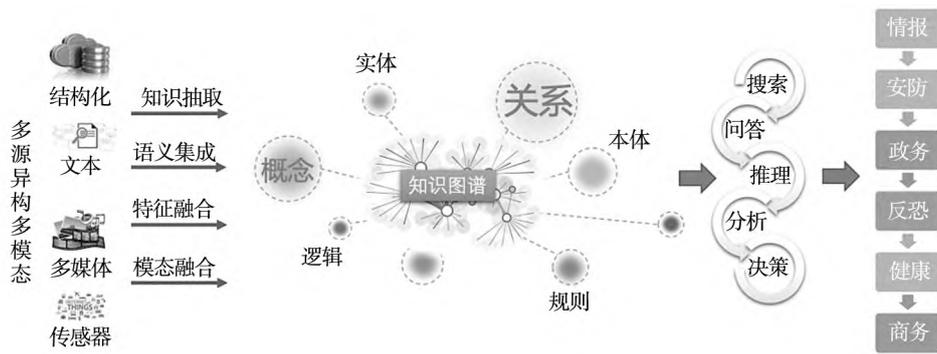


图1 知识图谱刻画实体与关系

Fig. 1 Knowledge graph for describing entities and relationships

知识表示是一种对知识的描述方式,利用信息技术将客观世界中的事物关系以及人的主观认知中的抽象概念转化为符合计算机处理模式的表示方式,主要分为符号表示和向量表示<sup>[16]</sup>.传统的知识表示多基于符号逻辑,例如一阶逻辑、霍恩逻辑、语义网络、框架逻辑等,主要用于刻画显式、离散的知识.针对随互联网发展涌现出的海量数据,知识表示则需要统一的描述框架以促进大规模知识的结构化表示,其中资源描述框架(RDF)通过<主语,谓语,宾语>三元组的形式表示知识图谱中头实体与尾实体之间的关系.向量化表示则基于深度学习的知识图谱表示学习,面向知识图谱中的实体和关系,将三元组的语义信息投射到稠密的低维向量空间,将原有符号化知识图谱转换为数值化表示形式,有利于计算复杂的语义关系和深度学习模型的集成<sup>[17]</sup>,这是知识图谱量化计算的基础<sup>[18]</sup>.

知识融合是融合各个层面的知识,包括不同知识库的同一实体、多个不同的知识图谱、多源异构多模态的数据与知识等.其中,多模态是指数据类型包括图片、视频、文本、语音等多种形式,对多模态数据的处理和理解增强了知识图谱的多样性和丰富度,这有利于构建更细粒度的知识图谱<sup>[19]</sup>.知识融合通常包括本体匹配和对齐、实体对齐与消歧等.进一步,融合常识、专家知识知识图谱具有更强的推理能力和可解释性,数知融合可增强数据的跨界关联.

知识推理是知识图谱具有“智能”的直接表现,它针对知识图谱中已有事实或关系的不完备性,挖掘或推断出未知或隐含的关系,例如实体补

全、关系补全.在知识图谱推理中,逻辑规则充分利用了知识的符号性与精准性,让推理结果可理解、可解释;嵌入表示学习则将复杂的数据结构转化为向量化表示,让推理计算更加有效和直接;神经网络方法对非线性复杂关系推理具有更强的建模能力,在深度学习知识图谱结构特征和语义特征后有效进行知识图谱补全与关联推理<sup>[20]</sup>.

根据认知理论中双系统划分<sup>[13]</sup>,即认知系统包括符号系统和神经系统,符号系统擅长定义与表示专家经验、规则和知识,求解过程可解释性强,而神经系统擅长处理机器学习的问题,对数据噪音的容忍度大,两者各有优势<sup>[14]</sup>.基于此,本文将基于知识图谱的知识推理分为三大类型(如表1).

第一类是基于符号表示的推理,包括基于本体和基于规则的推理.基于本体推理主要利用本体层面的频繁模式、约束或路径进行推理,例如FaCT++<sup>[21]</sup>, HermiT<sup>[22]</sup>, Pallet<sup>[23]</sup>等模型.基于规则的推理则主要是在知识图谱上运用逻辑规则或统计学习特征进行推理,例如运用路径式规则<sup>[24, 25]</sup>、带常量的规则<sup>[26]</sup>、带否定逻辑的规则<sup>[27]</sup>、图结构的随机游走概率模型<sup>[28-30]</sup>等.

第二类是基于神经网络的推理,该推理是对知识图谱进行向量表示,充分利用神经网络模型深度学习图谱结构的特征和语义特征,进而有效预测图谱缺失关系.该推理形式包括通过翻译模型进行知识图谱嵌入(例如Trans系列<sup>[31]</sup>, HAKE<sup>[32]</sup>, CrossE<sup>[33]</sup>),基于本体表示学习的推理(例如OWL2Vec<sup>[34]</sup>, EL Embedding<sup>[35]</sup>, OntoZSL<sup>[36]</sup>),以及通过图神经网络进行链接预测的推理(例如R-GCN<sup>[37]</sup>, XTransE<sup>[38]</sup>等).

表1 基于知识图谱的知识推理相关研究总结

Table 1 A summary of related research on KG-based knowledge reasoning

类型	方法	代表性模型
基于符号表示的推理	基于本体的推理	FaCT + + <sup>[21]</sup> , HermiT <sup>[22]</sup> , Pallet <sup>[23]</sup>
	基于规则的推理	路径式规则 AMIE <sup>[24]</sup> , AMIE + <sup>[25]</sup> 带常量规则 AnyBurl <sup>[26]</sup> 带否定逻辑规则 RuDiK <sup>[27]</sup> 图结构规则 PRA <sup>[28]</sup> , SFE <sup>[29]</sup> , HiRi <sup>[30]</sup>
基于神经网络的推理	知识图谱嵌入	Trans 系列 <sup>[31]</sup> , HAKE <sup>[32]</sup> , CrossE <sup>[33]</sup>
	基于本体表示学习的推理	OWL2Vec <sup>[34]</sup> , EL Embedding <sup>[35]</sup> , OntoZSL <sup>[36]</sup>
	基于图神经网络的推理	R-GCN <sup>[37]</sup> , XTransE <sup>[38]</sup>
神经符号集成的推理	神经网络融合符号推理	Neural LP <sup>[39]</sup> , DRUM <sup>[40]</sup> , NTP <sup>[41]</sup> , GNTP <sup>[42]</sup> , CQD <sup>[43]</sup> , Query2Box <sup>[44]</sup>
	符号增强神经网络推理	KALE <sup>[45]</sup> , RUGE <sup>[46]</sup>
	神经符号互相迭代推理	IterE <sup>[47]</sup> , Rule-IC <sup>[48]</sup>

第三类是神经符号集成的推理,也是混合式推理.该推理过程充分利用符号系统和神经系统的优势,通过两者相互补充或迭代以增强推理的精细度和可解释性.神经系统赋能符号系统的推理,将神经系统学到的浅层知识表示更新到已有的符号系统中,反过来,符号系统也可对神经网络模型进行赋能,将规则和本体表示融入到神经网络建模中以提高模型的能力.神经符号集成的推理可进一步细分为神经网络融合符号推理(例如 Neural LP<sup>[39]</sup>, DRUM<sup>[40]</sup>, NTP<sup>[41]</sup>, GNTP<sup>[42]</sup>, CQD<sup>[43]</sup>, Query2Box<sup>[44]</sup>)、符号增强神经网络推理(例如 KALE<sup>[45]</sup>, RUGE<sup>[46]</sup>)、神经符号互相迭代推理(例如 IterE<sup>[47]</sup>, Rule-IC<sup>[48]</sup>).“神经+符号”的有机集成是当前知识图谱的前沿方向,本文把重点放在神经符号集成研究,并在电商场景中应用,例如建构模型 IterE<sup>[47]</sup>,旨在通过规则和表示学习嵌入之间的相互迭代进行商业知识图谱推理.

## 2 知识图谱赋能数智化管理决策框架

在数字经济背景下,商务活动呈现出高频实时、深度定制化、全周期沉浸式交互、跨组织数据整合、多主体决策等特点<sup>[2]</sup>.大数据涌现与人工智能技术发展深刻改变了商务管理与决策范式,决策准则由有限理性到无限理性、决策模式由静态到动态实时、决策主体从计算机辅助决策到人机协同决

策、决策流程从线性分阶段向非线性过程转变<sup>[3]</sup>.然而,单纯的数据驱动的管理决策日渐靠近“天花板”效应,这决定了在机器模型中融入知识成为问题解决的另一技术途径<sup>[12]</sup>,学者们开始提出“大知识”、“知识大图”等概念<sup>[49-51]</sup>.由此,本文提出基于“数知融合”的数智化管理决策方法,其本质在于集成数据和知识的优势,“数”是以大数据为基础,“智”则表现为模型驱动和知识增强,符号表示和神经系统系统交互迭代,以突破传统管理决策的挑战性问题(如少样本、零样本决策、异质性推荐等),实现决策过程过程的敏捷化、自动化.

陈国青等指出大数据管理决策中的三大根本问题是要回答“发生了什么”、“将发生什么”、“为什么发生”,这也是数智化管理决策范式下的基本问题<sup>[5]</sup>.知识图谱恰恰能为解决这些根本性问题提供新的技术路径.其中,知识表示为管理决策提供数据和知识基础,更好地刻画业务状态,提供全局视图,用以回答“发生了什么”;知识融合与推理是管理决策的关键,知识跨界融合更全面地建立多元主体联系和多元业务链路关系,对业务轨迹及其演化规律进行推理,进而对做出前瞻性预判,这有益于回答“将发生什么”和“为什么发生”.

本文认为知识图谱及相关技术为数智化管理与决策提供了新框架和新方法,该技术体系以“模型驱动+知识增强”为基础,以“人机互益”为指导,致力于有效解决管理决策中的根本性问题,促进并优化面向多领域的管理与决策.特别地,本

文提出以知识图谱为基础构建一套“符号神经集成系统”，通过结合符号表示和神经网络模型的知识表示、融合与推理，以解决多种决策问题，特别针对具有挑战性的少样本/零样本决策、面向下游任务的自动决策，以及决策过程中模型可解释性问题。该技术与方法体系可应用于商务管理各环节，包括商品推荐、品类规划、客户管理、平台质量管理与运营管理等。知识图谱赋能商务管理决策的框架体系如图 2 所示。

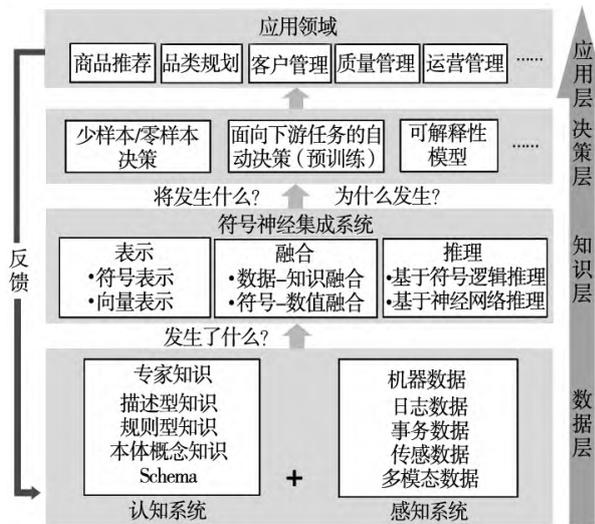


图 2 知识图谱赋能数智化管理决策

Fig. 2 KG empowering data-intelligence management decision

### 2.1 数知融合驱动管理决策准则精细化

随着人工智能技术逐步进入工程化、实用化阶段，管理决策思维与准则正从“有限理性”、“满意即可”过渡到“极限理性”、“最优选择”<sup>[7]</sup>，决策模型与方法也从基于小数据、小知识发展为基于大数据、大知识<sup>[5]</sup>。满意决策往往是人的有限理性和信息不充分、不对称条件下的次优选择<sup>[52]</sup>。将机器数据与专家知识进行融合实现“数知融合”，在海量数据基础上进行知识表示、融合与推理极大改善以往决策的约束条件，知识图谱所具备的强大信息处理能力及其所嵌入的智能算法有助于实现对数据、知识更为科学的分析与整合，优化管理者的决策环境，突破人的认知局限，提供基于场景精细化或跨领域关联式的推荐与决策以实施管理活动。

以商务决策为例，商务大数据的基本特征来源广泛（包括在线数据源、线下数据源、企业内外

数据源等），种类多样（包括货品数据、媒体事件数据、供应链数据、零售数据、场景数据等），用户创造内容（例如购买评论、晒单等）高度动态变化。针对多源异构数据，数据融合与跨界关联是提升决策有效性、精准度的关键。跨界关联则是知识网络空间的外拓，强调企业内外数据的关联、不同模态数据的关联；而全局视图则强调对相关情境的整体画像及其动态演化的把控<sup>[5]</sup>。这种“全景式成像”能力的基础在于知识表示、数据融合与知识融合。

同时，智能决策的精细化还需要发挥专家主观经验性知识的价值。机器数据多来源于感知设备和机器日志等，虽然比较粗糙，但规模非常易于扩展，因而更有利于数据驱动的决策模型的学习与实现；专家知识多来源于人的主观总结和概念抽象，虽然获取困难，但知识的价值密度高，可直接应用于智能管理并支持更加精细化的决策准则。

知识图谱在一定程度上可以起到数知融合的桥梁作用<sup>[53]</sup>，将专家经验性知识与机器感知类数据在同一种表示框架中进行描述，并在同一张图中建立两者之间的连接。这种衔接一方面使得专家知识更直接地作用于机器数据，对机器数据产生约束，例如通过人工定义的本体 Schema 建立多来源的机器数据之间的语义关联；另一方面，包括描述型（know-what）和过程型（Know-how）在内的专家知识作为先验知识<sup>[54]</sup>，其融入可以直接作用于机器数据，以更好引导和指导机器模型的学习。同时，通过从多模态数据中不断抽取知识，可以进一步丰富专家知识库，并弥补专家知识在规模上的不足。

### 2.2 神经符号融合的知识图谱推理增强数智化决策深度

Tari 将知识推理定义为基于特定的规则和约束，从存在的知识获得新的知识<sup>[55]</sup>。戴汝维等提出“人-机结合的智能科学”<sup>[56]</sup>，张维等提出“混合智能管理系统”的理论与方法<sup>[11]</sup>，数智化将赋予综合集成、混合方法新的内涵和实现路径。由此可见，即便拥有海量数据，人类常识、业务规则、专家经验及其他隐知识等在推理中也不可或缺。虽

然传统的专家系统具有局限性,例如知识规模有限、开放度不够,使之不再适用于大数据环境,然而专家知识、隐知识、元知识等在管理决策中仍起到关键作用。在数值模型中注入大量累积的符号知识是突破机器学习瓶颈、让机器具有认知智能的重要思路。

符号知识对于机器智能的意义主要体现两方面。首先,利用知识图谱提升机器学习模型与专家先验知识的一致性。人在环中(human-in-the-loop)依然是发展人工智能技术的主要形式<sup>[57]</sup>,因为机器智能尚不足以自我发展出具有框架性质的元知识。机器需要人类,特别是领域专家赋予其认知世界、认知特定领域的基本概念框架,需要人类标注样本、反馈结果。其次,利用知识图谱可减少样本依赖,提升机器学习模型的健壮性。人类可以通过小样本进行有效学习,源于人类具有知识并能有效利用所积累的知识。利用知识图谱中的知识,尤其是本体概念图谱,通过约束构造、样本增强、事后检验、注意力构造等方法,可以减少对大规模样本的依赖<sup>[58]</sup>;通过语义关联、迁移学习,可以将旧标签、富样本上学习的有效模型赋予在新标签、贫样本<sup>[36]</sup>,这有益于提升电商平台的长尾商品推荐以及面向场景的异质推荐。

数智化管理与决策不仅体现在数据与知识在表示层面的融合,更重要是在推理层面的交织融合,即将基于符号逻辑的推理与基于嵌入表示、神经网络的推理有机集成。这种混合推理机制主要将规则转化为向量操作,应用于强学习能力的神经网络方法中,实现一个可微推理模型。融合神经符号的可微推理可增强数智化管理决策的深度,也能有效解决管理决策中特别强调的“关联+因果”诉求<sup>[5]</sup>。因此,本文认为通过知识图谱进行知识增强的推理机制是数智化管理决策从“数”向“智”升级的根本所在。

### 2.3 知识图谱增强数智化决策模型的可解释性

在数智化管理决策中,决策主体发生了深刻变革,决策主体不再是单一的组织或个人,而是人、组织与机器智能的结合<sup>[3]</sup>。用户可以转化成决策主体,形成价值共创。决策过程机器自动

决策与人工决策共存,甚至决策全过程智能化。一方面,多源数据的获取极大丰富了决策要素,使得智能化决策变为可能,提升决策准则的一致性,避免决策者个人的主观理解和解释偏差;另一方面,智能决策存在着不可解释的黑盒问题,这阻碍了人们对智能系统的理解和应用深化。当人们无法了解机器自动决策的结果,包括决策的原因、过程和逻辑,做为决策主体的人则难以信任和理解机器智能决策,进而可能导致响应行动措施的滞后或缺失。而符号知识是对人友好的,传统以符号推理为基础的决策系统都能依据符号表示给出结果的推理路径,因而可解释性更好。

可解释的人工智能是突破人机协同决策的重要途径。可解释性指使用解释作为人类和智能模型之间的接口,作为模型代理能够被人类所理解<sup>[59]</sup>。针对智能决策受益者,人工智能可解释性旨在给不同背景知识的用户,以简单清晰的方式,对智能决策过程的依据和原因进行解释,将黑盒人工智能决策转化为可解释的决策推断,使用户能够理解和相信决策<sup>[61]</sup>,且不同的解释机制效果有所不同<sup>[60]</sup>。知识图谱融合符号表示,提供可解释性,有益于形成“人机共益”,进而推动管理决策中人机交互与协同。

## 3 知识图谱与神经网络技术集成体系

“知识+模型”双轮驱动的数智化管理决策框架需要有机融合知识图谱与神经网络两方面的技术思想,两者优势互补。基于此,本文提出集成知识图谱和神经网络的技术方法体系,包括集成符号知识推理与神经网络推理以增强决策精度和深度,融合本体知识与生成模型以提升零样本决策和模型可解释性,以及利用知识图谱增强多模态数据融合,通过预训练模型以提升管理决策的敏捷性和智能化。

本文将此“1+3”框架的技术方法体系优势概要如表2所示,并在以下各小节分别加以详细描述和应用举例。

表2 “1+3”融合知识图谱与神经网络技术方法优势概要

Table 2 Advantages of the “1+3” knowledge graph and neural network integration techniques and methods

技术与方法	优势	应用实例
神经符号集成框架 (知识图谱 + 神经网络)	高质量规则学习, 减少计算代价 大规模机器学习, 缓解知识稀疏性 双向迭代, 提高决策的精细度、精准性	IterE <sup>[47]</sup>
本体知识与生成模型	突破数据稀疏性问题 增强少样本、零样本决策 提高面向长尾推荐、场景推荐效果	OntoZSL <sup>[36]</sup>
知识图谱嵌入表示	提升结果多样性、异质性 增强决策过程和结果可解释性	XTransE <sup>[38]</sup>
多模态知识图谱预训练	减少对数据及数据模态的依赖 提高预测稳健性、准确率 提升决策自动化、智能化	K3M <sup>[68]</sup>

### 3.1 基于知识图谱的神经符号集成推理

如前所述, 智能化管理与决策需要有机融合专家知识和机器数据. 由于专家知识多以离散的符号形式表示, 而机器数据则多以连续的数值向量形式表示, 这就需要将符号空间与向量空间进行有机集成. 如图3所示, 神经网络及表示学习方法在知识图谱中的应用使得可以将符号化的知识图谱(Symbolic KG)通过嵌入表示(embedding)技术投影到向量空间, 从而获得神经网络化的知识图谱(Neural KG)<sup>[38, 62]</sup>. 这种数值化或参数化的知识图谱更容易与原本位于向量空间的各种机器数据进行融合, 从而有利于实现专家知识与机器数据的深度融合.

在知识推理方面, 传统的符号推理引擎有很多, 例如可用于符号本体推理的RDFox<sup>[63]</sup>, 可用于符号规则推理的Drools<sup>[64]</sup>等. 这类推理引擎对符号知识的质量要求非常高, 受限于高质量符号知识的获取难题, 不易于大规模扩展. 一条新的推理引擎实现路径是将符号知识与神经网络进行融

合<sup>[33, 47]</sup>. 如图3所示, 符号化的规则或公理也可以通过嵌入表示实现神经网络化, 从而实现基于神经网络的符号推理. 神经网络是在连续的数值空间完成推理, 比起符号表示更易于表征那些隐藏的知识, 知识的利用度也更高. 同时, 神经网络对数据中的噪音容忍度也更高, 对知识的质量要求相对更低, 因而更易于大规模扩展.

进一步, 基于符号表示的推理和基于神经网络的推理可以相互集成, 并采用迭代方式进行互补<sup>[47]</sup>. 因此, 本文提出一套神经符号集成的决策系统, 其推理过程如图3所示.

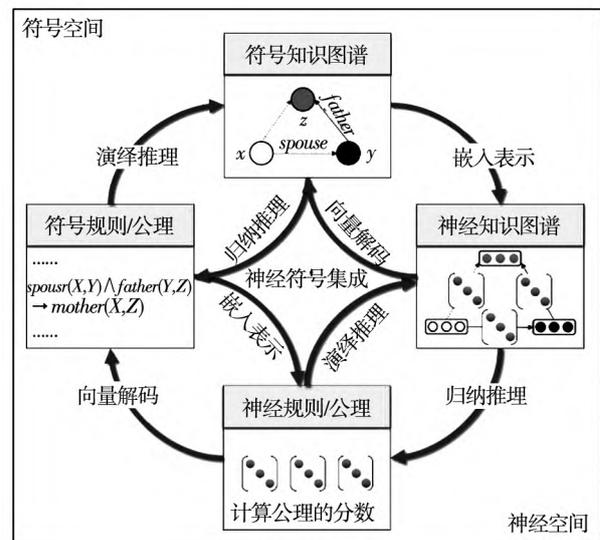


图3 基于知识图谱的神经符号集成提升决策推理的能力

Fig. 3 Neural symbolic integration enhancing the reasoning ability for decisions

给定符号知识图谱  $\mathcal{S}_s$  可以通过嵌入得到神经向量化表示  $\mathcal{S}_e$ , 表示为:  $\mathcal{S}_e = F_{kge}(\mathcal{S}_s)$ . 这里可以采用一系列知识图谱嵌入模型  $\mathcal{A}(\cdot)$ , 比如 TransE、DistMult、ComplEx 等.

通过对神经知识图谱的向量  $\mathcal{S}_e$  进行归纳推理, 通过向量空间的计算得到基于向量表示的规则/公理  $\mathcal{R}_e$ , 即  $\mathcal{R}_e = \mathcal{F}_{ind}(\mathcal{S}_e)$ , 并通过向量空间到符号空间的映射得到  $\mathcal{R}_e$  的符号化表示  $\mathcal{R}_s = \mathcal{F}_{Symb}(\mathcal{R}_e)$ .

这些符号规则/公理  $\mathcal{R}_s$  又可以通过演绎推理对初始的符号知识图谱  $\mathcal{S}_s$  进行补全和校准, 并不断进行迭代, 即  $\mathcal{S}_s \leftarrow \mathcal{F}_{ded}(\mathcal{R}_s, \mathcal{S}_s)$ . 在这个迭代过程中, 神经/符号的知识图谱  $\mathcal{S}_s/\mathcal{S}_e$  和规

则/公理  $\mathcal{R}_S/\mathcal{R}_E$ , 可以不断地通过归纳推理、演绎推理、嵌入表示和符号映射进行如下转换。

一是经过补全和校准的符号知识图谱  $\mathcal{S}_S$  可以通过再一轮的知识图谱嵌入模型  $\mathcal{F}_{kge}$  和归纳推理  $\mathcal{F}_{ind}(\cdot)$ , 得到新的神经规则/公理  $\mathcal{R}'_E$ , 即  $\mathcal{R}'_E = \mathcal{F}_{ind}(\mathcal{F}_{kge}(\mathcal{S}_S))$ , 并更新  $\mathcal{F}_E \leftarrow \mathcal{R}'_E$ ;

二是神经规则/公理  $\mathcal{R}_E$  亦可以通过符号映射和演绎推理  $\mathcal{F}_{ded}(\cdot)$ , 产生新的向量化三元组对神经三元组进行补全, 即  $\mathcal{S}'_S = \mathcal{F}_{ded}(\mathcal{F}_{Symb}(\mathcal{R}_E), \mathcal{S}_S)$ , 并更新  $\mathcal{S}_S \leftarrow \mathcal{S}'_S$ 。

实验证明:一方面,相比于传统的纯符号化的规则学习方法,从神经向量化知识图谱中通过归纳推理可以学到更多高质量规则,并且高效的向量计算有效地克服了规则学习搜索空间过大的问题;另一方面,通过利用学习到的规则对符号知识图谱进行演绎推理,可以起到数据增强的作用,并显著缓解图谱的稀疏性问题<sup>[47]</sup>,从而提升神经知识图谱的表示学习质量。最后,迭代学习的过程实现了符号知识图谱  $\mathcal{S}_S$  和神经向量化表示的知识图谱  $\mathcal{S}_E$  的不断融合和相互增强<sup>[47]</sup>。

### 3.2 融合本体知识和生成模型的零样本决策

在数智化管理决策过程中,兼顾“模型驱动 + 知识增强”两种决策模式的必要性还体现在缓解决策模型的样本依赖和提升模型可解释性等方面。数字商务管理面临更严峻的长尾问题<sup>[65]</sup>, 基于少样本、零样本做决策已成为管理挑战之一。因此,本文提出利用知识图谱,融合本体知识和生成模型,以突破低资源下的决策问题,例如零样本决策,即利用多样本学习的模型来解决没有任何样本的新问题。

OntoZSL (Ontology-enhanced Zero-shot Learning) 是一个融合本体知识和生成模型的算法,实现零样本决策的实例<sup>[36]</sup>。OntoZSL 可用于解决零样本分类问题,如图像分类、零样本知识图谱补全等。这一“知识 + 模型”的算法主要包含 4 个模块 (如图 4 所示)。

本体编码模块。该模块将本体知识映射到低维向量空间,以获取本体中每个概念的向量表示 (concept embedding), 基于此向量表示,可利用生

成模型为概念生成对应的训练样本。具体来说,本体中的结构三元组信息通过知识图谱表示学习算法如 TransE 进行编码,文本信息通过 TF-IDF 特征进行表示,结构表示和文本表示均将被映射到相同的向量空间,并使用相同的损失函数约束进行训练,最终得到包含了这两个层面的概念向量表示。

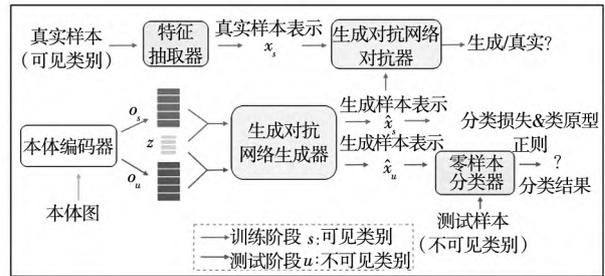


图 4 融合本体知识和生成模型实现零样本决策框架

Fig. 4 A framework of integrating ontology and generative models for zero-shot decisions

特征抽取器。用于抽取真实样本的特征表示,以引导生成模型生成符合真实特征分布的样本。考虑到不同任务中样本表示的不同,算法采用不同的特征抽取策略,如图像分类任务中,可使用 ResNet 抽取图像的特征;图片多标签分类任务中,可使用目标检测算法如 RCNN 等提取图像中目标的特征表示;知识图谱补全的任务中,可基于每个关系相关联的实体对得到关系的特征表示。

特征生成模块。基于本体编码模块中得到的概念向量表示,使用生成对抗网络 (Generative Adversarial Network, GAN) 生成概念对应的样本。生成模块包括一个生成器和一个对抗器。在生成器中,以一定分布的随机噪声和概念表示做输入,生成概念对应的样本;在对抗器中,用于判别真实样本和生成样本,以及一些附加的损失函数,使得生成的样本更具可辨性。

零样本分类器。经可见类别 (seen) 训练样本训练好的生成器,在给定不可见类别 (unseen) 及其向量表示的条件下,可为不可见类别生成其缺失的样本。基于这些生成的样本,模型将为每个不可见类获取对应的样本特征表示,用于预测其测试样本。

零样本分类问题是指给定一组有训练样本的

类别(seen 类),如图 5 中的篮球袜、篮球、篮球场等商品图片标签,要求模型只利用这些 seen 类的训练样本进行学习,并能够对新出现的没有任何样本的新类别(unseen 类)进行预测,如图中的新标签篮球鞋。

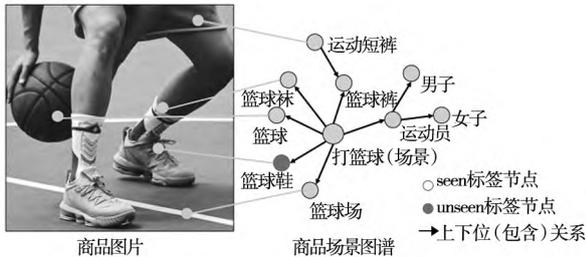


图 5 商品场景知识图谱增强实体语义关联

Fig. 5 Goods scene KG enhancing semantic association of items

利用符号知识增强类别间的语义关联,并利用知识图谱如商品场景知识图谱建立 seen 标签和 unseen 标签之间的联系,如层次关联。例如,篮球袜、篮球、篮球鞋等同属于“打篮球”这一场景。基于这些外部语义知识,可将模型在有训练样本的类别上学习到的特征迁移到训练样本缺失的类别上,从而有效解决零样本图像分类(标签)问题。

### 3.3 知识图谱表示学习提升结果异质性与可解释性

在数智化管理决策过程中,来自模型的可解释性预测有助于帮助人们理解模型代理的行为,从而推进管理决策中的人机交互与协同,实现“人机共益”。知识图谱作为一种知识组织方式,具有易于人理解的特性,基于知识图谱的可解释性预测将帮助管理者、工程师以及消费者理解决策过程,参与评估决策过程的合理性。

基于知识图谱,本文作者开发了可解释的预测模型 XTransE<sup>[38]</sup>,主要包含一个知识图谱表示学习的嵌入表示模块和一个生成预测解释的解释生成器。在嵌入表示模块,给定一个表示商品  $e_i$  属于场景  $e_L$  的三元组  $(e_i, r_b, e_L)$ ,设计基于嵌入表示的得分函数,通过聚合邻居三元组和注意力机制以赋予模型可解释性。对于每个邻居三元组  $(e_j, r, e)$ ,计算一个注意力值  $a_{e_j(r,e)}$  用于聚合邻居  $e$  的信息,该注意力值越大说明邻居三元组

$(e_j, r, e)$ 对当前的预测越重要。训练过程中,通过最小化正负样本对的基于间隔的损失函数得到最优的参数组合。在解释生成器中,给定一个模型预测结果  $(e_i, r_b, e_L)$ ,对模型的注意力值进行排序,并选出注意力值最高的几个邻居作为模型预测结果的解释。

该方法被应用于真实的商务场景中,将场景知识图谱嵌入推荐算法中,完成基于场景的商品搜索与推荐,提升了商品推荐的多样性。如图 6 所示,传统的商品搜索推荐结果较为同质化,而基于场景知识图谱嵌入表示学习的推荐使结果具有异质性,呈现跨品类商品组合。

传统搜索结果		基于场景的检索：做音乐	
	品牌: LAVA GUITAR 型号: 源5.23 面板材质: 其他 卷弦器: 封闭旋钮 箱体材质分类: 面单 1 001元-3 000元		品牌: LAVA GUITAR 型号: 源5.23 面板材质: 其他 卷弦器: 封闭旋钮 箱体材质分类: 面单 1 001元-3 000元
	品牌: LAVA GUITAR 型号: LAVA ME 3 8.18 面板材质: 碳纤维 卷弦器: 其他 箱体材质分类: 其他 3 001元-10 000元		品牌: Kepma 型号: K-6 面板材质: 锌合金 弹压技术: 钢制弹簧 用途: 变调 40元
	品牌: Yamaha/雅马哈 型号: F600 面板材质: 枫木 箱体材质分类: 合板 适用对象: 初学入门 501元-1 000元		品牌: ENO/伊诺 型号: ET-33 调音项目: G、B、V、U、 12平均律/尤克里里/吉他/贝 斯/提琴 24.8元
	品牌: Kepma 型号: EDC/EAC 面板材质: 云杉木 卷弦器: 封闭旋钮 箱体材质分类: 合板 501元-1 000元		品牌: KORG 型号: TM60 续航: 130小时 适用乐器: 十二平均律乐器/ 管乐/提琴/吉他/钢琴 208元

图 6 两种搜索方法结果对比

Fig. 6 Results comparison of two search methods

进一步,表 3 展示了三类不同样本的预测解释,包括预测正确和经人工评估解释与预测结果是否一致,以及预测错误但解释一致的例子。

表 3 XTransE 的解释样例

Table 3 Examples of explanations enabled by XTransE

类别	预测正确 解释一致	预测正确 解释不一致	预测错误 解释一致
数据标签	做音乐	做甜点	潜水
模型预测	做音乐	做甜点	蛙泳
解释 1	拥有属性“类别”	拥有属性“颜色”	标题含“Speedo”
解释 2	标题含“CD”	拥有属性“商品 ID”	标题含“运动”
解释 3	类别是“音乐”	标题含“品牌”	拥有属性“颜色”
解释 4	类别是“CD/DVD”	标题含“车”	品牌是“Speedo”
解释 5	拥有属性“流派”	标题含“水晶”	类别是“运动”

不难发现,表 3 第 1 列证明通过模型的注意

力值生成的解释有助于帮助人们理解和判断模型预测结果的合理性.表3第2列表明尽管存在机器模型预测正确但与人工解释不一致的情况,模型给出解释可能激发人工更多可解释性思路.表3第3列虽为机器模型预测与标签不一致,但模型给出的正确解释可用以纠正数据标记不全的问题,例如,模型预测目标商品适合蛙泳,解释中的品牌 Speedo 是一个著名的游泳装备品牌,尽管与数据标签“潜水”不一致,但预测适合“蛙泳”亦为合理,这可增补数据标签用以提升未来的模型预测准确率.

总之, XTransE 不仅提高了商品搜索推荐结果的多样性,且彰显了模型可解释性,用以帮助人们评估模型决策过程的合理性,即使人机存在不一致的解释,人机也可在交互中相互增进知识.

### 3.4 基于多模态知识图谱的预训练模型增强下游任务的自动化决策

知识存在于文本、图片、视频等多模态的数据中,知识图谱激活数据要素有两种途经.一种途经是为从原始数据中抽取、表示和推理知识,用于面向实时业务需求的分析,例如融合本体知识和生成模型的零样本决策、基于知识图谱表示学习的异质性推荐等问题.另一种途经则是利用数据中存在的基本信息对隐藏的知识进行预训练,形成面向下游任务的预训练模型,下游任务通过嵌入计算得到必要的知识,减少繁琐的数据选择和模型设计,使得面向下游任务的决策自动化、智能化.

预训练的核心思想是“预训练+微调”,首先利用大规模知识图谱训练出一个知识模型,然后针对下游任务,设计相应的目标函数,基于较少的监督数据进行微调,即可得到较好的结果<sup>[19]</sup>.知识图谱用于预训练,有利于提升模型预测效果和可解释性,这也是知识图谱与深度学习模型融合的一种新范式<sup>[66, 67]</sup>.本文认为基于知识图谱和神经网络不仅激活了数据要素,也激活了模型要素,预训练模型简化了面向下游任务的决策,让决策过程更敏捷.

本文提出了一套融入知识图谱的多模态预训

练方法 K3M<sup>[68]</sup>,该方法在真实商务场景中已得到实际应用.如图7所示,该模型的基本思想是:在模态编码层对各模态的独立信息进行编码,在模态交互层对模态间的相互作用进行建模,其中知识图谱也作为一种模态数据与文本、图片等模态数据进行交互学习,在模态任务层对预训练模型进行监督.

具体来说,模态编码层是对不同模态进行信息编码,针对图像、文本以及知识图谱,采用基于 Transformer 的编码器提取图像、文本、三元组形式的初始特征.模态交互层包含两个交互过程:一个是文本与图像之间的模态交互,通过叠加一个 Co-attention Transformer 层,得到图像和文本模态的初始特征学习对应的交互特征;二是知识图谱分别与文本、图像的交互,该过程首先以图像和文本模式的交互结果  $c$  和给定实体(如某个商品)的某个三元组为输入为输入,计算两种模态与每条三元组的交互关系,再对给定实体的所有三元组的交互结果进行聚合以得出最终融合该实体的最终向量表示.这个最终的向量表示包含了有关该实体(如某个商品)的图片、文本、结构化图谱三方面的信息.模态任务层,作为预训练模型的监督信号,图像模态、文本模态和知识图谱的预训练任务分别采用掩码对象模型、掩码语言模型和链接预测模型对模型训练过程进行约束,通过三个模型的损失函数得到 K3M 模型的损失之和.

该模型的有效性在真实商务场景下得到验证,在商品类目预测、同款商品识别和多模态问答三个下游任务上, K3M 都取得了最佳性能.相较于没有知识图谱增强的基线模型,随着模态缺失率和模态噪音率的提升, K3M 表现出明显的鲁棒性.当文本模态缺失率从 20% 增加至 100% 时,不引入知识图谱的基线模型准确率平均下降了 10.2% ~ 40.2%, 而 K3M 模型的准确率仅平均下降了 1.8% ~ 5.7%<sup>[68]</sup>.这些实测结果验证了知识图谱对于增强多模态处理能力的价值,使预训练模型能在面向下游任务时能进行更稳健、可靠地自动决策.因此,基于知识图谱嵌入的预训练模型为面向海量数据的敏捷化智能决策提供了知识基

础和模型基础,再次彰显“模型驱动 + 知识增强” 技术体系的有效性和有用性.

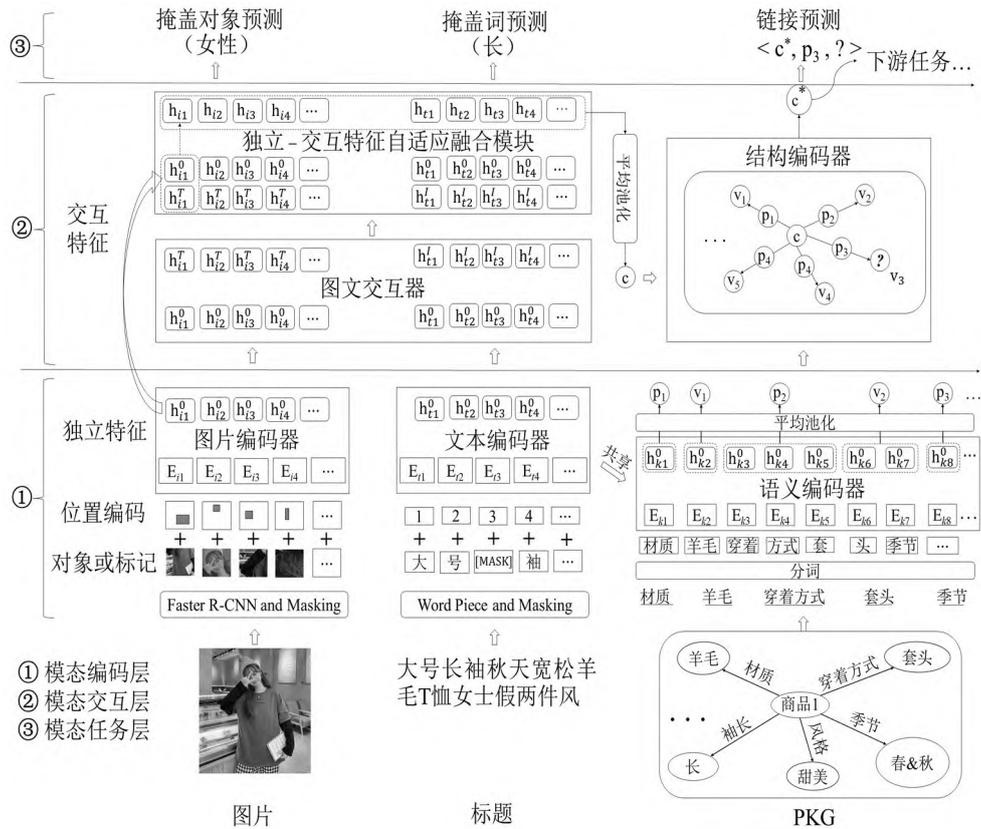


图7 知识图谱增强多模态预训练模型框架

Fig. 7 An enhanced multimodal pretraining framework via KG

### 4 应用场景举例：基于商业知识图谱的数智化决策

在电商领域,构建商品域的整体知识体系非常重要,海量商务数据促使了多类型知识图谱的形成与涌现。“全景化”知识图谱是平台实现智能化商品搜索、商品域问答、商品知识推理等功能的重要基础.例如,阿里巴巴集团作为服务全球的电商平台,构建了千亿级数字商业知识图谱,即一个规模巨大的商业域知识体系,以支持其生态体系中数十亿商品的流通.其业务数据来源包括其自身建立的新零售平台提供的各种内部数据源,并整合了舆情、百科、国家行业标准、竞品平台等多种外部数据源,形成了海量的知识图谱网络.至2021年,该商品知识图谱沉淀了近52.2亿个商品相关实体,三元组数量级达到2000亿,其中

Schema 或本体层实体类型数达到62种,关系类型数达35种,规则数则达370.1万<sup>[69]</sup>,这也为基于知识图谱的预训练提供了规模化的前提条件.该千亿级数字商业知识图谱日均调用200亿次,每秒20余万次,为电商平台上的商家节省上亿元运营成本,并创造了可观的收入,展现出强大的经济效益.

全景商业知识图谱表示、融合与推理将推动平台运营方的商品标准化、选品决策智能化、质量控制精细化,提升全网商品治理能力与效率.进一步,在全景式知识图谱融合基础上进行问题/场景导向的分析与推理也将大大提升面向消费端和供应端的商务管理决策效率.针对商品消费端,利用知识图谱可以为各种差异化的消费场景与动态需求变化进行精准化匹配与推荐.传统的导购已经无法满足消费升级下的购物需求,消费者的诉求越来越来呈现跨类目、跨品类、快速变化的趋势,结合场景与商品知识图谱的推理可以重构货品组

织方式,形成智能导购链路、智能问答服务.针对商品供应端,知识图谱融合与推理将助力卖家进行智能品类规划、智能商品发布和标准化商品单元(SPU:Standard Product Unit)发布.平台亦可基于全景式知识图谱对渠道商进行赋能,例如,内外部知识图谱融合与推理可以推动在线平台与线下实体零售店的通力合作,多语言知识图谱融合与推理将极大提升渠道运营者在国际市场铺货.

本文面向真实业务中以“模型驱动+知识增强”为根本设计原则,基于神经符号集成系统,实施了融合知识图谱嵌入和规则学习的推理方法<sup>[33]</sup>,在数知融合基础上进行知识图谱模型预训练,从而赋能平台各主体进行高效实时的商务决策与管理,加强决策智能化、敏捷化并具有可解释性,如图8所示.

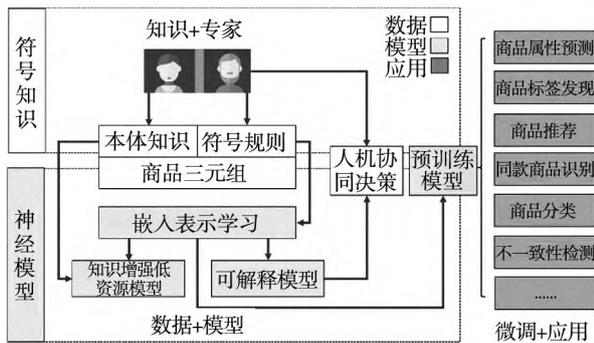


图8 融合知识图谱与神经网络提升商务决策

Fig.8 Integrating knowledge graph and neural network for leveraging business decisions

一方面通过“模型驱动”,对海量商品实体和关系进行向量表示学习,快速推理和计算缺失关系,以补充缺失的知识或推断新关联关系,如品牌补全、场景推荐、商品-场景挂载等等<sup>[70]</sup>.在智能导购和商品推荐应用中,基于知识图谱的推理可以从大量的场景、用户和商品实体中预测缺失的“场景-商品-用户”关联关系,例如,OntoZSL<sup>[36]</sup>不仅可以解决零样本决策问题也可以提升面向场景-用户的商品推荐,例如,预测“打篮球”场景与多个有年龄属性、性别属性约束的运动类商品之间的关联关系.XTransE<sup>[38]</sup>,即可解释的知识图谱表示学习技术,已应用于挖掘和补充电商平台场景挂载规则,并进一步基于规则的通用性、可复

用性,快速将国内电商场景学习的知识迁移到跨境电商平台,帮助跨境电商平台快速构建和沉淀场景树,从而支持跨境业务的快速部署.此外,基于商业知识图谱的表示学习和推理也可用于不一致性知识检测,以提升知识质量.例如,在商品智能管控中,检测关于同款商品知识描述之间的冲突,用以识别虚假营销,提升平台质量管理能力.

另一方面通过“知识增强”,商业知识图谱实体类型多导致训练语料获取成本高、业务形态多等挑战,规则学习做为一种具备可解释性的白盒化算法可最大化发挥专家知识的效用,事半功倍.比如,专家产生或审核的一万条规则的价值远高于专家审核一万条语料去产生少量规则<sup>[69]</sup>.头部电商平台通常都有很多经验丰富的行业运营专家,一是将他们的运营经验或行业常识沉淀为规则,优化算法;二是通过将黑盒化的深度学习白盒化,翻译成规则,让运营专家参与到整个数据和算法的建设中.因此,在实践中可以基于商业知识图谱的向量表示快速学习和挖掘新的业务规则,然后将这些新的业务规则交付给业务运营专家进行评估,合格的新规则将被应用于推理计算获取新的三元组<sup>[38, 62]</sup>.数据和知识相互增强,数据才真正可沉淀、可运营、可维护,发挥海量数据与专家知识融合与协同价值.

针对管理决策对结果可解释性的需求,本文将可解释的知识图谱推理框架运用到电商场景中,采用规则嵌入来生成对推理结果的解释.从“人-机”智能交互决策中,人们对机器的决策往往寻求可解释性<sup>[57]</sup>.这同样发生在电商场景中,即要求在基于机器学习与推理结果的同时要对结果的原因提供解释,供专家对业务正确性进行验证.例如,基于向量表示模型推理出某个商品适用于某特定场景或特定人群的同时需要提供判断的依据,解释为什么<sup>[38]</sup>;在商品同款智能判定中,模型在得出推理结果的同时还要找出这些等价的属性及其权重<sup>[62]</sup>,并进一步对推理结果可解释性进行了评估,发现提供解释后人工判断三元组正误的效率有明显提升,且准确度未受显著影响<sup>[38]</sup>.

针对电商平台的自动化决策需求,本文提出

在已构建的大规模商品知识图谱基础上,以“预训练+微调”的模式开发预训练模型,将预训练好的知识图谱模型作为知识增强的使能者.预训练知识图谱模型是通过向量空间计算为其他任务提供知识服务.在实践中已实现在千亿级商品知识图谱上对模型进行预训练,使预训练模型具有为三元组查询和关系查询提供知识信息的能力,然后将其用于基于向量表示的知识增强任务模型中,在微调阶段,根据具体任务和数据集特性进行调整,同时进行特定的微调训练,进而得到符合特定任务需求且有良好效果的模型.知识图谱预训练既能避免繁琐的数据选择和模型设计,又能克服商品知识图谱的不完整性,方便、有效地为下游任务自动提供知识,从而提升商务决策效果,让决策更敏捷.在实际电商场景中,基于知识图谱预训练可以展开智能化的商品分类、同款商品识别、商品推荐、商品标签发现、商品属性预测等<sup>[69]</sup>,极大提升了电商平台的整体运营效率.

## 5 结束语

数智化管理决策的关键在于数据与知识融合,知识与模型交互.本文提出以“模型驱动+知识增强”为设计原则,针对大规模商业知识图谱进行表示、融合与推理,提出知识图谱赋能数智化

管理决策的逻辑框架,形成一套神经符号集成推理框架与技术体系.基于该框架,本文提出的框架体系在多方面进行了技术创新,包括提出融合本体知识与生成模型用于破解零样本决策、利用知识图谱表示学习提升决策结果异质性和可解释性、通过“预训练+微调”方法增强下游任务的自动化决策.神经符号集成体系最大化了机器的感知智能和人类知识的认知智能,符号系统和神经系统的有机双向迭代过程不仅是“人机互动”,更重要的是实现了“人机互益”,使管理决策更精细、精准、敏捷、智能.与此同时,将神经符号集成框架下的技术创新落地应用于拥有海量数据的电商平台管理中,大幅提升了该平台在商品管理、质量管理、运营管理等多场景的管理决策效率与效果,取得了真实、卓越的商务价值,创造出面向价值导向的场景创新.

总之,本文提出的融合知识图谱与神经网络的框架和技术体系赋能数智化商务管理与决策,充分彰显了其技术创新性与场景创新性.数知融合、人机互益、人机协同是数智化发展的必然要求与趋势,研究团队将基于知识图谱的神经符号集成推理框架,持续进行技术与方法创新以提升管理决策效果,并期望将相关技术体系应用到其他领域和场景,例如政务管理、安全管理、健康管理等,从而涌现出更多的价值导向的场景创新.

## 参考文献:

- [1]冯芷艳,郭迅华,曾大军,等.大数据背景下商务管理研究若干前沿课题[J].管理科学学报,2013,16(1):1-9.  
Feng Zhiyan, Guo Xunhua, Zeng Dajun, et al. On the research frontiers of business management in the context of big data [J]. Journal of Management Sciences in China, 2013, 16(1): 1-9. (in Chinese)
- [2]徐宗本,冯芷艳,郭迅华,等.大数据驱动的管理与决策前沿课题[J].管理世界,2014,30(11):158-163.  
Xu Zongben, Feng Zhiyan, Guo Xunhua, et al. On the research frontiers of big data-driven management and decisions[J]. Management World, 2014, 30(11): 158-163. (in Chinese)
- [3]陈国青,曾大军,卫强,等.大数据环境下的决策范式转变与使能创新[J].管理世界,2020,36(2):95-105.  
Chen Guoqing, Zeng Dajun, Wei Qiang, et al. Transitions of decision-making paradigms and enabled innovations in the context of big data[J]. Management World, 2020, 36(2): 95-105. (in Chinese)
- [4]黄丽华,朱海林,刘伟华,等.企业数字化转型和管理:研究框架与展望[J].管理科学学报,2021,24(8):26-35.  
Huang Lihua, Zhu Hailin, Liu Weihua, et al. The firms' digital transformation and management: Toward a research frame-

- work and future directions[J]. *Journal of Management Sciences in China*, 2021, 24(8): 26–35.
- [5] 陈国青, 任明, 卫强, 等. 数智赋能: 信息系统研究的新跃迁[J]. *管理世界*, 2022, 38(1): 180–196.  
Chen Guoqing, Ren Ming, Wei Qiang, et al. Data-intelligence empowerment: A new leap of information system research [J]. *Management World*, 2022, 38(1): 180–196. (in Chinese)
- [6] 陈国青, 吴刚, 顾远东, 等. 管理决策情境下大数据驱动的研究和应用挑战——范式转变与研究方向[J]. *管理科学学报*, 2018, 21(7): 1–10.  
Chen Guoqing, Wu Gang, Gu Yuandong, et al. The challenges for big data driven research and applications in the context of managerial decision-making: Paradigm shift and research directions[J]. *Journal of Management Sciences in China*, 2018, 21(7): 1–10. (in Chinese)
- [7] 徐鹏, 徐向艺. 人工智能时代企业管理变革的逻辑与分析框架[J]. *管理世界*, 2020, 36(1): 122–129+238.  
Xu Peng, Xu Xiangyi. Change logic and analysis framework of enterprise management in the era of artificial intelligence[J]. *Management World*, 2020, 36(1): 122–129+238. (in Chinese)
- [8] 王国成. 数字化如何影响决策行为[J]. *经济与管理*, 2021, 35(5): 26–34.  
Wang Guocheng. How does digitization affect decision-making behavior[J]. *Economy and Management*, 2021, 35(5): 26–34. (in Chinese)
- [9] 伍之昂, 赵新元, 黄宾, 等. 基于文献计量的大数据管理决策研究热点分析[J]. *管理科学学报*, 2021, 24(6): 117–126.  
Wu Zhiang, Zhao Xinyuan, Huang Bin, et al. Status and trends in big-data-driven managerial decision-making on bibliometric[J]. *Journal of Management Sciences in China*, 2021, 24(6): 117–126. (in Chinese)
- [10] 曾大军, 李一军, 唐立新, 等. 决策智能理论与方法研究[J]. *管理科学学报*, 2021, 24(8): 18–25.  
Zeng Dajun, Li Yijun, Tang Lixin, et al. Decision intelligence research: Theory and methods[J]. *Journal of Management Sciences in China*, 2021, 24(8): 18–25. (in Chinese)
- [11] 张维, 曾大军, 李一军, 等. 混合智能管理系统理论与方法研究[J]. *管理科学学报*, 2021, 24(8): 10–17.  
Zhang Wei, Zeng Dajun, Li Yijun, et al. Hybrid intelligence management system research: Theory and methods[J]. *Journal of Management Sciences in China*, 2021, 24(8): 10–17. (in Chinese)
- [12] 张钹, 朱军, 苏航. 迈向第三代人工智能[J]. *中国科学: 信息科学*, 2020, 50(9): 1281–1302.  
Zhang Bo, Zhu Jun, Su Hang. Toward the third generation of artificial intelligence[J]. *Scientia Sinica: Informationis*, 2020, 50(9): 1281–1302. (in Chinese)
- [13] Bengio Y, Lecun Y, Hinton G. Deep learning for AI[J]. *Communications of the ACM*, 2021, 64(7): 58–65.
- [14] Chen H, Deng S, Zhang W, et al. Neural symbolic reasoning with knowledge graphs: Knowledge extraction, relational reasoning, and inconsistency checking[J]. *Fundamental Research*, 2021, 1(5): 565–573.
- [15] 陈华钧. 知识图谱导论[M]. 北京: 电子工业出版社, 2021.  
Chen Huajun. Introduction to Knowledge Graph[M]. Beijing: Publishing House of Electronics Industry, 2021. (in Chinese)
- [16] Sowa J F. Knowledge Representation: Logical, Philosophical and Computational Foundations[M]. Pacific Grove: Brooks/Cole Publishing Co., 2000.
- [17] 刘知远, 孙茂松, 林衍凯, 等. 知识表示学习研究进展[J]. *计算机研究与发展*, 2016, 53(2): 247–261.  
Liu Zhiyuan, Sun Maosong, Lin Yankai, et al. Knowledge representation learning: A review[J]. *Journal of Computer Research and Development*, 2016, 53(2): 247–261. (in Chinese)
- [18] 张祎, 孟小峰. InterTris: 三元交互的领域知识图谱表示学习[J]. *计算机学报*, 2021, 44(8): 1535–1548.  
Zhang Yi, Meng Xiaofeng. InterTris: Specific domain knowledge graph representation learning by interaction among triple elements[J]. *Chinese Journal of Computers*, 2021, 44(8): 1535–1548. (in Chinese)
- [19] 王萌, 王昊奋, 李博涵, 等. 新一代知识图谱关键技术综述[J]. *计算机研究与发展*, 2022, 59(9): 1947–1965.  
Wang Meng, Wang Haofen, Li Bohan, et al. Survey of key technologies of new generation knowledge graph[J]. *Journal of Computer Research and Development*, 2022, 59(9): 1947–1965. (in Chinese)

- [20]王 硕, 杜志娟, 孟小峰. 大规模知识图谱补全技术的研究进展[J]. 中国科学: 信息科学, 2020, 50(4): 551–575.  
Wang Shuo, Du Zhijuan, Meng Xiaofeng. Research progress of large-scale knowledge graph completion technology[J]. Scientia Sinica: Informationis, 2020, 50(4): 551–575. (in Chinese)
- [21]Tsarkov D, Horrocks I. FaCT++ description logic reasoner: System description[C]. International Joint Conference on Automated Reasoning(IJCAR), 2006: 292–297.
- [22]Glimm B, Horrocks I, Motik B, et al. HermiT: An OWL 2 reasoner[J]. Journal of Automated Reasoning, 2014, 53(3): 245–269.
- [23]Sirin E, Parsia B, Grau B C, et al. Pellet: A practical OWL-DL reasoner[J]. Journal of Web Semantics, 2007, 5(2): 51–53.
- [24]Galárraga L, Teflioudi C, Hose K, et al. AMIE: Association rule mining under incomplete evidence in ontological knowledge bases[C]. The 22<sup>nd</sup> International Conference on World Wide Web(WWW), 2013: 413–422.
- [25]Galárraga L, Teflioudi C, Hose K, et al. Fast rule mining in ontological knowledge bases with AMIE[J]. VLDB Journal, 2015, 24(6): 707–730.
- [26]Meilicke C, Chekol M W, Ruffinelli D, et al. Anytime bottom-up rule learning for knowledge graph completion[C]. The 28<sup>th</sup> International Joint Conference on Artificial Intelligence(IJCAI), 2019: 3137–3143.
- [27]Ortona S, Meduri V V, Papotti P. RuDiK: Rule discovery in knowledge bases[C]. The VLDB Endowment, 2018, 11(12): 1946–1949.
- [28]Lao N, Mitchell T M, Cohen W W. Random walk inference and learning in a large scale knowledge base[C]. 2011 Conference on Empirical Methods in Natural Language Processing(EMNLP), 2011: 21–31.
- [29]Gardner M, Mitchell T M. Efficient and expressive knowledge base completion using subgraph feature extraction[C]. 2015 Conference on Empirical Methods in Natural Language Processing(EMNLP), 2015: 1488–1498.
- [30]Liu Q, Jiang L Y, Han M H, et al. Hierarchical random walk inference in knowledge graphs[C]. The 39<sup>th</sup> International ACM SIGIR Conference on Research and Development in Information Retrieval(SIGIR), 2016: 445–454.
- [31]Bordes A, Usunier N, Garcia-Duran A, et al. Translating embeddings for modeling multi-relational data[C]. Neural Information Processing Systems(NIPS), 2013: 2787–2795.
- [32]Zhang Z Q, Cai J Y, Zhang Y D, et al. Learning hierarchy-aware knowledge graph embeddings for link prediction[C]. The 34<sup>th</sup> Association for the Advancement of Artificial Intelligence(AAAI), 2020: 3065–3072.
- [33]Zhang W, Paudel B, Zhang W, et al. Interaction embeddings for prediction and explanation in knowledge graphs[C]. The 12<sup>th</sup> ACM International Conference on Web Search and Data Mining(WSDM), 2019: 96–104.
- [34]Chen J Y, Hu P, Jimenez-Ruiz E, et al. OWL2Vec<sup>+</sup>: Embedding of OWL ontologies[J]. Machine Learning, 2021, 110(7): 1813–1845.
- [35]Kulmanov M, Wang L W, Yuan Y, et al. EL embeddings: Geometric construction of models for the description logic EL++[C]. The 28<sup>th</sup> International Joint Conference on Artificial Intelligence(IJCAI), 2019: 6103–6109.
- [36]Geng Y X, Chen J Y, Chen Z, et al. OntoZSL: Ontology-enhanced zero-shot learning[C]. The 30<sup>th</sup> World Wide Web Conference(WWW), 2021: 3325–3336.
- [37]Schlichtkrull M, Kipf T N, Bloem P, et al. Modeling relational data with graph convolutional networks[C]. 2018 European Semantic Web Conference(ESWC), 2018: 593–607.
- [38]Zhang W, Deng S, Wang H, et al. XTransE: Explainable knowledge graph embedding for link prediction with lifestyles in e-commerce[C]. The 9<sup>th</sup> Joint International Semantic Technology Conference(JIST), 2019: 78–87.
- [39]Yang F, Yang Z L, Cohen W W. Differentiable learning of logical rules for knowledge base reasoning[C]. The 31<sup>st</sup> Annual Conference on Neural Information Processing Systems(NIPS), 2017.
- [40]Sadeghian A, Armandpour M, Ding P, et al. DRUM: End-To-End differentiable rule mining on knowledge graphs[C]. The 33<sup>rd</sup> Conference on Neural Information Processing Systems(NIPS), 2019: 15321–15331.
- [41]Rocktaschel T, Riedel S. End-to-End differentiable proving[C]. The 31<sup>st</sup> Annual Conference on Neural Information Pro-

- cessing Systems(NIPS), 2017: 3788 – 3800.
- [42] Minervini P, Bosnjak M, Rocktäschel T, et al. Differentiable reasoning on large knowledge bases and natural language [C]. The 34<sup>th</sup> Association for the Advancement of Artificial Intelligence(AAAI), 2020: 5182 – 5190.
- [43] Arakelyan E, Daza D, Minervini P, et al. Complex query answering with neural link predictors[C]. International Conference on Learning Representations(ICLR), 2021.
- [44] Ren H, Hu W, Leskovec J. Query2box: Reasoning over knowledge graphs in vector space using box embeddings[C]. International Conference on Learning Representations(ICLR), 2020.
- [45] Guo S, Wang Q, Wang L, et al. Jointly embedding knowledge graphs and logical rules[C]. 2016 Conference on Empirical Methods in Natural Language Processing(EMNLP), 2016: 1488 – 1498.
- [46] Guo S, Wang Q, Wang L, et al. Knowledge graph embedding with iterative guidance from soft rules[C]. The 32<sup>th</sup> Association for the Advancement of Artificial Intelligence(AAAI), 2018: 4816 – 4823.
- [47] Zhang W, Paudel B, Wang L, et al. Iteratively learning embeddings and rules for knowledge graph reasoning[C]. The 28<sup>th</sup> World Wide Web Conference(WWW), 2019: 2366 – 2377.
- [48] Lin Q K, Liu J, Pan Y D, et al. Rule-enhanced iterative complementation for knowledge graph[J]. Information Science, 2021, 575: 66 – 79.
- [49] Lu R, Jin X, Zhang S. A study on big knowledge and its engineering issues[J]. IEEE Transactions on Knowledge and Data Engineering, 2018, 31(9): 1630 – 1644.
- [50] 洪亮, 马费成. 面向大数据管理决策的知识关联分析与知识大图构建[J]. 管理世界, 2022, 38(1): 207 – 219.  
Hong Liang, Ma Feicheng. Knowledge association analysis and big knowledge graph construction for big data management and decision making[J]. Management World, 2022, 38(1): 207 – 219. (in Chinese)
- [51] 洪亮, 欧阳晓凤. 金融股权知识大图的关联发现与风险分析[J]. 管理科学学报, 2022, 25(4): 44 – 66.  
Hong Liang, Ouyang Xiaofeng. Knowledge association discovery and risk analysis based on financial equity knowledge graph [J]. Journal of Management Sciences in China, 2022, 25(4): 44 – 66. (in Chinese)
- [52] Yu Y, Liu B Q, Hao J X, et al. Complicating or simplifying? Investigating the mixed impacts of online product information on consumers' purchase decisions[J]. Internet Research, 2020, 30(1): 263 – 287.
- [53] Gutierrez C, Sequeda J F. Knowledge graphs[J]. Communications of the ACM, 2021, 64(3): 96 – 104.
- [54] Lebovitz S, Levine N, Lifshitz-Assaf H. Is AI ground truth really true? The dangers of training and evaluating AI tools based on experts' know-what[J]. MIS Quarterly, 2021, 45(3): 1501 – 1526.
- [55] Tari L. Knowledge Inference[M]. New York: Springer-Verlag, 2013.
- [56] 戴汝为, 李耀东, 李秋丹. 社会智能与综合集成系统[M]. 北京: 人民邮电出版社, 2013.  
Dai Ruwei, Li Yaodong, Li Qiudan. Social Intelligence and Metasynthetic System[M]. Beijing: Posts & Telecom Press, 2013. (in Chinese)
- [57] Monarch R. Human-in-the-loop Machine Learning: Active Learning and Annotation for Human-centered AI[M]. Shelter Island: Manning Publications Co, 2021.
- [58] Chen J, Geng Y, Chen Z, et al. Knowledge-aware zero-shot learning: Survey and perspective[C]. The 30<sup>th</sup> International Joint Conference on Artificial Intelligence(IJCAI), 2021: 4366 – 4373.
- [59] Guidotti R, Monreale A, Ruggieri S, et al. A survey of methods for explaining black box models[J]. ACM Computing Surveys, 2018, 51(5): 142.
- [60] Fernandez-Loria C, Provost F, Han X T. Explaining data-driven decisions made by AI systems: The counterfactual approach[J]. MIS Quarterly, 2022, 46(3): 1635 – 1660.
- [61] 孔祥维, 唐鑫泽, 王子明. 人工智能决策可解释性的研究综述[J]. 系统工程理论与实践, 2021, 41(2): 523 – 546.  
Kong Xiangwei, Tang Xinze, Wang Ziming. A survey of explainable artificial intelligence decision[J]. Systems Engineering-Theory & Practice, 2021, 41(2): 523 – 546. (in Chinese)
- [62] Kang J, Zhang W, Kong H, et al. Learning rule embeddings over knowledge graphs: A case study from e-commerce entity

- alignment[C]. Companion Proceedings of the Web Conference, 2020: 854 – 855.
- [63] Nenov Y, Piro R, Motik B, et al. RDFox: A highly-scalable RDF store[C]. International Semantic Web Conference (ISWC), 2015: 3 – 20.
- [64] Proctor M. Drools: A rule engine for complex event processing[C]. Applications of Graph Transformations with Industrial Relevance(ACTIVE), 2011: 2.
- [65] Oestreicher-Singer G, Sundararajan A. Recommendation networks and the long tail of electronic commerce[J]. MIS Quarterly, 2012: 36(1), 65 – 83.
- [66] Zhang N, Deng S, Cheng X, et al. Drop redundant, shrink irrelevant: Selective knowledge injection for language model pretraining[C]. The 30<sup>th</sup> International Joint Conference on Artificial Intelligence(IJCAI), 2021: 4007 – 4014.
- [67] Liu W, Zhou P, Zhao Z, et al. K-BERT: Enabling language representation with knowledge graph[C]. The 34<sup>th</sup> Association for the Advancement of Artificial Intelligence(AAAI), 2020: 2901 – 2908.
- [68] Zhu Y, Tou H, Zhang W, et al. Knowledge perceived multi-modal pretraining in e-commerce[C]. The 29<sup>th</sup> ACM International Conference on Multimedia(ACM MM), 2021: 2744 – 2752.
- [69] 张 伟, 陈华钧, 张亦驰. 工业级知识图谱: 方法与实践[M]. 北京: 电子工业出版社, 2021.  
Zhang Wei, Chen Huajun, Zhang Yichi. Industrial Knowledge Graph: Methods and Practices[M]. Beijing: Publishing House of Electronics Industry, 2021. (in Chinese)
- [70] Zhang W, Wong C M, Ye G, et al. Billion-scale pre-trained e-commerce product knowledge graph model[C]. The 37<sup>th</sup> International Conference on Data Engineering(ICDE), 2021: 2476 – 2487.

## Fusion of knowledge graph and neural network to empower data-intelligence for management decisions

*YU Yan*<sup>1</sup>, *ZHANG Wen*<sup>3</sup>, *XIONG Fei-yu*<sup>4</sup>, *MENG Xiao-feng*<sup>1</sup>, *LIU Xiang-wen*<sup>4</sup>,  
*CHEN Hua-jun*<sup>2\*</sup>

1. School of Information, Renmin University of China, Beijing 100872, China;
2. College of Computer Science and Technology, Zhejiang University, Hangzhou 310027, China;
3. School of Software Technology, Zhejiang University, Ningbo 315048, China;
4. Alibaba Group, Hangzhou 310052, China

**Abstract:** Knowledge graph(KG) is an important bridge of linking sensor intelligence to cognitive intelligence. Utilizing KG for knowledge representation, fusion and reasoning will exert great impacts on management decisions. KG helps the organic fusion of symbolic representation and neural network for more effective knowledge reasoning and decision-making. This paper develops a neural symbolic integration framework, which includes three groups of technologies and methodologies, i. e., the integration of ontology and generative models for zero-shot decisions, the KG embedding representation learning for heterogeneous and explainable results, and the KG pretraining models for decision-making automations of down-side tasks. The proposed “1 + 3” technical framework embodies “model driven + knowledge enhanced” and can leverage the data-intelligence for management decisions, demonstrating the technological innovativeness. These methods and techniques have been applied in real e-commerce practices, implying the contextual innovations. The whole framework also entails the generalizability and can be applied to enhance general management decisions in various domains and contexts.

**Key words:** knowledge graph; neural network; neural symbolic integration; management decision