

# 基于GNN-PSO的医院人力资源管理数据需求分析研究

彭婧, 卢熙

(湖南省人民医院社会医学部, 湖南长沙 410001)

**摘要:** 本医院的人力资源管理是确保高效医疗服务的关键, 准确的需求预测对于人力资源规划至关重要。研究开发一种结合灰色神经网络与粒子群优化算法的新型预测模型, 目的是优化医院人力资源的预测准确性。通过对医院历史数据的分析, 模型对2023至2028年的人力资源需求进行了预测。结果表明, 改进的灰色神经网络-粒子群算法模型在2023年的预测误差为0.035, 到2028年进一步降至0.016。实验表明, 相比传统预测工具, 改进的模型能更精确地预测未来的人力资源管理数据需求, 从而为医院提供强有力的决策支持。

**关键词:** 灰色模型; GNN-PSO; 医院人力资源; 管理数据; 需求分析

中图分类号: TP183 文献标识码: A 文章编号: 1003-7241(2025)08-0146-05

## Research on Hospital Human Resource Management Data Demand Analysis Based on GNN-PSO

PENG Jing, LU Xi

(Department of Social Medicine, Hunan People's Hospital, Changsha 410001, China)

**Abstract:** Hospital human resource management is the key to ensure efficient medical services, and accurate demand forecasting is very important for human resource planning. A new forecasting model combining grey neural network and particle swarm optimization algorithm is developed to optimize the forecasting accuracy of hospital human resources. Through the analysis of historical hospital data, the model predicts the human resource demand from 2023 to 2028. The results show that the improved GNN-PSO model has a prediction error of 0.035 in 2023, which is further reduced to 0.016 in 2028. This finding suggests that the improved model can more accurately predict future human resource management data needs than traditional forecasting tools, thus providing hospitals with strong decision support.

**Keywords:** grey model; grey neural network-particle swarm optimization; hospital human resources; management data; demand analysis

## 0 引言

在当今医疗服务领域, 医院人力资源管理数据的合理配置是提高医疗服务效率和质量的关键。随着人口老龄化和医疗技术的进步, 对医疗专业人员的需求日益增长, 使得人力资源需求预测成为医院管理的重要组成部分。准确的预测可以帮助医院优化人力资源分配, 提前准备教育和培训资源, 确保患者接受及时和高质量的医疗服务<sup>[1-2]</sup>。然而, 传统的需求预测方法往往难以处理医疗数据的不确定性和复杂性, 特别是在面对大量历史数据时, 如何从中提炼出未来趋势, 是一个极具挑战性的问题<sup>[3-4]</sup>。黄珈頔等为解决挖掘人力资源管理数据的问题, 提出了基于神经网络的人力资源管理模型, 并设计了预测分析系统, 从而实现了人力资源数据的合理方案<sup>[5]</sup>。Nie W等为解决准确地预测数据和网络优化的问题, 提出了灰色模型, 并结合了神经网络模型, 从而实现预测有效

性和可行性<sup>[6]</sup>。综上所述, 许多研究对医疗数据进行了分析, 但是使用的都是单一的算法。此次研究的新颖性在于对灰色模型进行改进, 提出灰色神经网络与粒子群优化算法相结合, 构建了一个新型的预测模型。该模型采用灰色系统理论来捕捉数据中的潜在规律, 并通过神经网络学习这些规律, 以提高模型对未来趋势的预测能力。进一步地, 为提升网络参数和优化性能, 研究结合了粒子群优化 (particle swarm optimization, PSO) 算法。研究的意义在于为医院管理者提供了一个强有力的决策支持工具, 这一工具能够帮助他们在复杂的医疗环境中做出更加科学和精准的人力资源规划。

## 1 基于GNN-PSO的医院人力资源管理数据需求模型构建

### 1.1 基于GNN的人力资源管理数据需求分析模型

灰色模型 (grey model, GM) 理论以其对复杂现象整体规律性的识别而受到重视, 其核心观点是即便是在看

\*基金项目: 湖南省卫生健康委科研项目 (D202310005978)

收稿日期: 2024-04-06

似杂乱无章的数据中,也存在着可识别和可利用的内在模式。灰色系统的分析方法在于对数据进行有效的整理,以揭示其潜在的变化规律,这一过程涉及灰色序列的构造<sup>[7-8]</sup>。通过生成处理,灰色序列能够减弱随机性,更清晰地展示出数据的固有规律性。灰色预测模型利用有限且不完全的信息来构建数学模型,预测未来的发展。在灰色预测方法中,一阶单变量灰色预测模型(grey model first order one variable, GM(1,1))模型尤为突出,它是一种在需求分析预测中被广泛应用的方法,如图1所示。该模型本质上是一种基于一阶单变量微分法的动态预测工具。尽管它在形式上依赖单一因素,但实际上它能全面考虑多个因素,使之特别适用于分析时间序列数据。

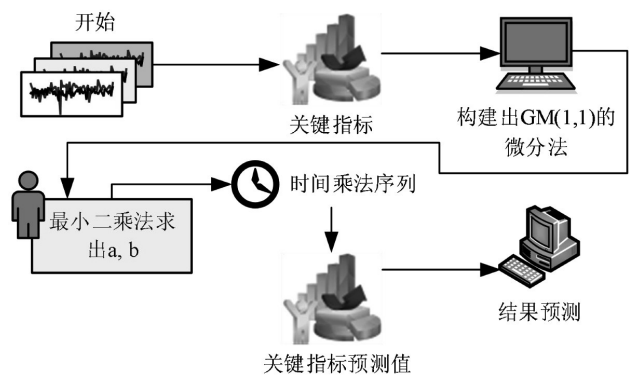


图1 GM模型流程

在应用GM(1,1)模型进行建模之前,通常需要对所收集的初始数据进行一系列预处理,这些处理过程中涉及的数据通常表示为式(1),为

$$\begin{cases} x^{(0)}(t) = (x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n)) \\ x^{(1)}(k) = (x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(n)) \\ x^{(1)}(k) = \sum_{t=1}^k x^{(0)}(t) \\ k = 1, 2, \dots, n \end{cases} \quad (1)$$

式中,  $x^{(0)}(t)$  代表初始的时间序列,  $x^{(1)}(k)$  代表  $x^{(0)}(t)$  执行一阶累加操作后生成新的序列。为了减少原始数据中的随机波动并凸显系统的内在规律,对这个累加后的数据序列  $x^{(1)}(k)$  应用一阶微分法进行深入分析,为

$$\frac{dx^{(1)}}{dt} + ax = b \quad (2)$$

式中,  $a$ 、 $b$  代表关键参数。 $a$  主要用于评估预测还原值的发展动态,而  $b$  则专注于分析原始数据的内部变化。接下来,采用使用最小二乘法计算  $a$  和  $b$  的具体数值,如式(3)所示,为

$$\begin{cases} x^{(1)}(k) = (x^{(0)}(1) - \frac{b}{a})e^{-a(k-1)} + \frac{b}{a}, k = 1, 2, \dots, n \\ \hat{x}^{(0)}(k) = (1 - e^a)(x^{(0)}(1) - \frac{b}{a})e^{-a(k-1)} \end{cases} \quad (3)$$

式中,当  $k$  的值不超过  $n$  时,反映的是 GM(1,1) 模型对数

据的拟合程度。相反,当  $k$  超出  $n$  的范围时,这个序列转变为对未来数据点的预测,基于 GM(1,1) 模型的推算。进一步地,研究引入了灰色神经网络(grey neural network, GNN)概念。这种网络结构是一种创新的方法,它结合了 GM 模型和先进的神经网络技术。通过这种融合,网络能够对数据进行更深层次的学习,从而不断优化其预测能力。这一过程的详细步骤和机制如图2所示<sup>[9-10]</sup>。

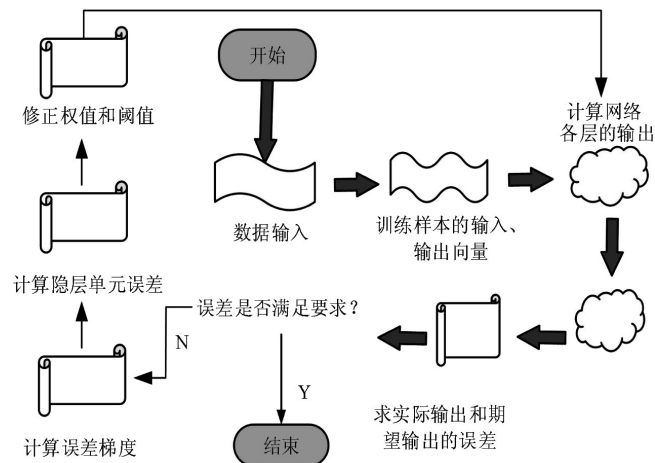


图2 GNN模型步骤和机制

首先,研究定义输入数据序列为  $X^{(0)}(t)$ , 其中  $t$  代表时间序列的索引,具体取值从1到  $N$ 。为了进一步处理这些数据,研究对  $X^{(0)}(t)$  执行了一次累加操作,这个步骤是为了生成一个新的数据序列,记作  $X^{(1)}(t)$ 。累加过程不仅平滑了初始数据,还为深入分析提供了更加连贯的数据结构。具体计算如式(4)所示,为

$$X^{(1)}(t) = (x^{(1)}(t)(1), x^{(1)}(t)(2), \dots, x^{(1)}(t)(n)) \quad (4)$$

接下来以式(4)中的数据为基础,来提升数据处理的细致度和准确性。通过这种方法,不仅可以更精确地分析数据的变化趋势,还能有效地揭示数据中隐藏的模式和关联。微分法如式(5)所示,为

$$\frac{dX_1^{(1)}(t)}{dt} + aX_1^{(1)}(t) = b_1X_2^{(1)}(t) + b_2X_3^{(1)}(t) + \dots + b_{n-1}X_n^{(1)}(t) \quad (5)$$

式中,  $X_2^{(1)}(t), \dots, X_n^{(1)}(t)$  代表第  $n$  个输入参数,  $X_1^{(1)}(t)$  代表输出参数。接下来研究求解相关的微分方程,以获得对数据的时间响应表达式,具体计算如式(6)所示,为

$$\begin{aligned} X_1^{*(1)}(t) &= (X_1^{(1)}(1) - \frac{b_1}{a}X_2^{(1)}(1) - \frac{b_2}{a}X_3^{(1)}(1) - \dots - \\ &\frac{b_{n-1}}{a}X_n^{(1)}(1))e^{-at} + \frac{b_1}{a}X_2^{(1)}(t) + \\ &\frac{b_2}{a}X_3^{(1)}(t) + \dots + \frac{b_{n-1}}{a}X_n^{(1)}(t) \end{aligned} \quad (6)$$

式中,  $X_1^{*(1)}(t)$  表示序列预测值。

为了更深入地理解和利用这个预测,对式(6)进行了一系列的转换和变形,这不仅增强了研究对数据的掌握,

而且为构建更加复杂和精确的模型打下了基础。这种转化过程最终导致了GNN模型的形成,其具体表达如式(7)所示,为

$$\begin{cases} X_1^{*(1)}(t) = ((X_1^{(1)}(1) - D) - X_1^{(1)}(1) \frac{1}{1 + e^{-at}} + \\ \quad 2D \frac{1}{1 + e^{-at}})(1 + e^{-at}) \\ D = \frac{b_1}{a} X_2^{(1)}(t) + \frac{b_2}{a} X_3^{(1)}(t) + \dots + \frac{b_{n-1}}{a} X_n^{(1)}(t) \end{cases} \quad (7)$$

由式(7)可以得出GNN的n-1个网络输入节点和1个输出节点。GNN模型的网络拓扑示意图详见图3。




图3 GNN模型的网络拓扑示意图

从图3可以看出,  $t$  代表时间序列, 而  $a$  和  $b$  表示参数。网络的输入包括  $X_2^{(1)}(t), \dots, X_n^{(1)}(t)$ , 这些是对原始时间序列进行不同程度处理后的结果。  $w_{ij}$  代表GNN的权重, 这些权值是网络学习和适应数据的关键因素。  $X_1^{*(1)}$  表示由GNN模型生成的输出, 而  $X_1^{(1)}(t)$  是GNN模型期望的输出值。此外,  $\chi_i$  代表GNN模型的误差, 它是衡量网络性能的重要指标。通过对这些参数和变量的精确控制和调整, 灰色神经网络能够有效地预测和分析时间序列数据, 同时最小化预测误差, 提高模型的整体效能。

### 1.2 改进GNN-PSO的人力资源管理数据需求分析模型

在GNN模型时, 网络参数的选择至关重要, 因为这些参数直接影响着模型预测的准确性。为了优化这些参数, 研究采用了粒子群算法 (particle swarm optimization, PSO), 得到改进的GNN-PSO模型。PSO算法是一种模仿生物群体行为的智能优化算法, 特别适用于解决复杂的优化问题。PSO算法的核心思想在于, 它在多维搜索空间中模拟粒子群体的行为。每个粒子不仅具有自身的位置和速度属性, 还能与其他粒子以及群体中的最优粒子

交换信息。通过这种信息的共享和交互, 每个粒子能够调整自己的飞行轨迹, 从而逐渐靠近群体中的最优解。在每次迭代过程中, 粒子通过评估自身的适应度来确定下一步的位置, 旨在找到解空间中的全局最优解。这一过程通常以群体或食物源的位置作为目标。在GNN-PSO模型的实施过程中, 首先使用GM模型对原始数据进行累加处理, 同时设定粒子群优化算法的相关参数, 如种群规模、最大迭代次数等<sup>[11-12]</sup>。其次, 研究运用PSO算法对GNN模型的结构参数  $a$ 、 $b$ , 进行精确调整和优化。此过程包括生成初始种群  $X_i$ , 并利用适应度函数  $f$  来评估每个粒子的适应度。适应度函数  $f$  的具体计算如式(8)所示, 为


$$f = \frac{1}{n} \sum_{i=1}^n \sum_{k=1}^m |y_{ik} - t_{ik}| \quad (8)$$

式中,  $n$  代表测量数据的个数, 而  $m$  则代表输出节点的数目。在这个设置下,  $y_{ik}$  被定义为预测值, 而  $t_{ik}$  则是实际观测值。基于这些定义, 研究的目标是确定最佳的模型参数。这一过程涉及寻找具有最小适应度值  $f_{\min}$  的个体  $X_{\min}$ , 其中  $X_{\min}$  代表着最优解,  $f_{\min}$  则是与之相对应的最佳适应度值。随后的步骤包括更新粒子的速度和位置, 并相应地计算新的适应度值。这一过程导致了新的最小适应度值  $f'_{\min}$  的生成, 以及与之对应的最优个体  $X'_{\min}$ 。关键在于比较  $f_{\min}$  与  $f'_{\min}$ , 若  $f_{\min}$  大于  $f'_{\min}$ , 研究便保留  $X'_{\min}$  作为新的最优解并继续迭代; 反之, 如果  $f_{\min}$  小于  $f'_{\min}$ , 研究则舍弃  $X_{\min}$  并持续迭代。这一循环持续进行, 直到达到预设的最大迭代次数。最终, 研究获得的最优解是具有最小适应度  $f_{\min}$  的个体  $X_{\min}$ , 从而确保了模型的最佳性能。


## 2 GNN-PSO的医院人力资源管理数据需求结果与分析

### 2.1 GNN-PSO模型的适应度训练测试结果分析

此次研究设置了一些参数, 包括14个输入神经元和1个输出神经元, 以及5个隐含神经元。基于这种配置, 网络总共包含75个权值 (计算方式为14乘以5加上5乘以1) 和6个阈值。为了有效地将PSO算法应用于GNN模型, 首先需要对PSO算法的关键参数进行精确设置。这些参数的配置算法后续的优化性能产生显著影响。具体而言, 需要初始化的PSO算法参数包括: 粒子的维数设为80, 这是GNN模型的权值和阈值之和。粒子群的种群规模定为30, 惯性权重设置为0.8, 而最大迭代次数则为300。此外, 为了评估和验证模型的准确性, 研究采用了误差直方图检验标准。这种标准通过对目标值与预测值之间误差的分布进行分析, 来衡量模型的精度。如果误差集中在接近0的区域, 这表明模型的误差较小, 预测精度较高。相关的结果展示在图4中。



(a) 适应度函数曲线



(b) 误差直方图

图4 适应度和误差直方图

由图4(a)可以看出,在初始迭代阶段的误差降低趋势。在这一阶段,研究观察到模型总体误差的显著减少。当迭代次数达到5至10次时,误差降低的速度开始放缓,曲线斜率趋向于0。这表明,PSO算法在这个阶段已经趋近于收敛。可以发现,如果继续对单一个体进行优化,不仅可能导致时间和资源的浪费,而且模型的性能改善可能非常有限。这一发现指示研究可能已经接近或达到了某个最优解。这一过程反映了研究在对GNN模型的权值和阈值进行优化调整的努力。另一方面,图4(b)展示了经过PSO-BP算法训练的研究所提模型的误差直方图。可以看出,在测试集上的预测结果与实际结果之间的偏差大多集中在49.5左右。这一观察结果进一步证明了模型预测结果的精确性和模型本身的高度精准度。研究所使用的数据源自本省的卫生计生年鉴,选取了2008年至2022年的医院人力资源管理历史数据。基于这些数据,研究对2023年至2028年的人力资源趋势进行预测。图5呈现了2008年至2022年间医院人力资源管理数据的趋势。

## 2.2 GNN-PSO模型的医院人力资源管理数据需求分析

为评估改进后的GNN-PSO模型的性能,研究设计了一项比较分析,涉及四种不同的预测模型。这四种模型包括反向传播神经网络模型、GM模型、GNN模型以及经过粒子群优化的改进GNN-PSO模型,分别表示1到4类

型。研究将1到4模型对2023年的数据需求预测结果如图6所示。从图6中可以观察到,GNN模型和GNN-PSO模型在预测精度上均优于反向神经网络模型和GM模型。具体来看,GNN模型在预测2023年医院人力资源管理数据需求时的相对误差仅为0.035,而采用粒子群优化策略的改进GNN模型将误差进一步降低至0.016。这一结果不仅凸显了GNN模型在处理此类预测任务时的有效性,更凸显了PSO算法在优化模型参数中的重要作用,为实现更高预测精度提供了强有力的支持。通过这项对比分析,可以清楚地看出,改进的GNN-PSO模型通过精细调整网络权重和阈值,有效地捕捉了数据中的复杂模式,提高了模型的预测能力。研究模型在医院人力资源管理数据的策略制定和规划中,具有显著的应用价值,有助于准确预测未来的人力资源需求,为决策者提供可靠的数据支持。




图5 2008年至2022年医院人力资源数据的趋势




图6 四种模型对2023年的数据需求预测结果

接下来进行详细的比较和评估GNN网络模型与改进后的GNN-PSO模型在预测医院人力资源管理数据方面的性能,研究将这两个模型对2023至2028年的管理数据进行了分析,结果详见图7。

图7中数据显示,GNN模型在整个预测期内系统性地给出了偏高的预测值,2028年预测值为112万人。相比之下,改进后的GNN-PSO模型虽然倾向于给出较低的预测值,但其预测精度却相对更高。从2008年起医院人力资源管理数据需求的变化轨迹,可以发现该省医院的人力资源管理数据需求呈现出稳定的线性增长趋势。特别是在2008年至2023年间,这一增长趋势更为显著。在对

未来几年的预测时,GNN模型的预测值与实际增长趋势之间的差异变得越来越大,尤其是在预测年份较远的2028年,这种偏差尤为明显。相比之下,改进GNN-PSO模型虽然在某些年份给出了略低于实际需求的预测值,但整体上更加贴近实际数据,显示出更为精准的预测能力。这表明,当研究考虑长期预测时,改进GNN-PSO模型提供了更为稳健和可靠的结果,显著减少了预测误差,从而为医院人力资源的规划和数据管理提供了有力的数据支撑。因此可以得出结论,改进后的GNN-PSO模型在医院人力资源数据需求预测中,无论是短期还是长期,改进后的GNN-PSO模型是更优的选择。

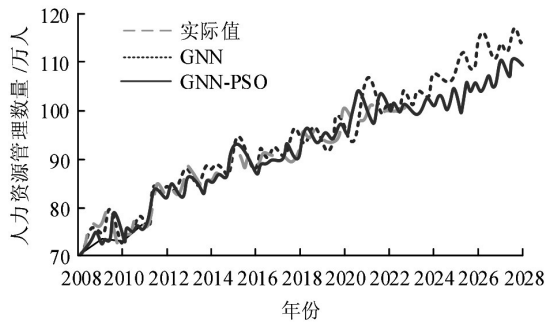


图7 模型对2023至2028年的数据管理需求分析

### 3 结束语

研究旨在探究医院人力资源管理数据需求的准确预测,以支持更加精准的人力资源规划。采用了GNN模型并结合了PSO算法,以期通过优化网络结构,提升数据需求分析预测的准确性。结果显示,在迭代的初期阶段,模型的总体误差显著降低,而当迭代次数在5至10之间时,误差减少速度放缓,表明PSO算法接近收敛。证实了模型的高精确度,其中大多数预测偏差集中在49.5%左右。对比分析表明,改进的GNN-PSO模型相比其他模型,如反向传播神经网络和传统GM模型,具有更高的预测精度。在对未来六年的预测中,改进模型预测的2023年需求量误差为0.035,而到了2028年,预测精度进一步提升,误差降至0.016。此外,长期趋势分析表明,尽管标准GNN

模型倾向于过高估计人力资源需求,改进的GNN-PSO模型则提供了更接近实际的预测值,尤其是在更远的预测年份,这种趋势更为明显。综上所述,改进的GNN-PSO模型因其在预测医院人力资源管理数据需求方面的高精度和稳健性。

### 参考文献:

[1] 李勇,高辉,周灿丰,等.基于数据增广灰色神经网络的ACFM裂纹角度预测[J].科学技术与工程,2023,23(15):6425-6433.  
 [2] 刘双.基于GM(1,1)模型和NAR神经网络的城市热水供热能力预测[J].现代信息科技,2022,6(10):170-176.  
 [3] 林宗英.基于粒子群优化算法的工业机器人定位抓取控制系统设计[J].计算机测量与控制,2023,31(10):128-133.  
 [4] 王飞.基于改进CNN卷积神经网络的音乐识别模型构建[J].自动化技术与应用,2024,43(2):127-131.  
 [5] 黄珈颖.基于神经网络的人力资源管理和预测模型研究[J].微型电脑应用,2022,38(4):152-155.  
 [6] NIE W, AO O, DUAN H. A novel grey prediction model with a feedforward neural network based on a carbon emission dynamic evolution system and its application[J]. Environmental Science and Pollution Research, 2023, 30(8): 20704-20720.  
 [7] 朱嘉豪,郑巍,杨丰玉,等.基于蚁群算法优化反向传播神经网络的软件质量预测[J].计算机应用,2023,43(11):3568-3573.  
 [8] 李义勇,时建平,张灵杰.基于粒子群算法的SVM飞机空调系统状态评估[J].计算机测量与控制,2022,30(11):257-264.  
 [9] 燕紫君,熊英,吴明芬.灰色DGM(2,1)与BP神经网络的组合预测模型研究[J].信息技术与信息化,2023,1(6):72-75.  
 [10] 杨子琳,陈家清.基于随机波动模型的医疗器材需求预测仿真[J].计算机仿真,2023,40(6):528-532.  
 [11] 刘佳宁.基于互联网智能人单合一技术的任务画像算法模型[J].自动化技术与应用,2023,42(10):88-90,124.  
 [12] 王江荣.基于卡尔曼滤波和粒子群优化算法的灰色神经网络预测模型[J].电气自动化,2022,1(1):24-26.

作者简介:彭婧(1988—),女,硕士,高级经济师,研究方向:人力资源。

(上接第8页)

twin integration[J]. IEEE Trans, 2023, 19(4): 3421-3432.  
 [51] DAI S, LIU Y, WANG Y, et al. Tianmouc: A heterogeneous neuromorphic vision chip for edge perception[C]//IEEE ISSCC, San Francisco: [s. n.], 2024: 1-3.  
 [52] ZENG A, LIU X, DU Z, et al. GLM-130B: An open bilingual pre-trained model with 130B parameters[J]. NeurIPS, 2022(35): 1081-1095.  
 [53] 曾津,刘轩,杜政,等. GLM-130B: 开源双语预训练模型[J]. 神经信息处理系统进展, 2022(35): 1081-1095.  
 [54] SMITH J, CHEN L, RODRIGUEZ A, et al. VISAR: A uni-

fied visual-inertial-SLiAM architecture for real-time autonomous navigation in dynamic environments[J]. RA-L, 2023, 8(4): 3987-3994.  
 [55] HKGAI CORE TEAM. PanGu- $\Sigma$ : scaling billion-parameter foundation models for Hong Kong's multilingual ecosystem[J]. SIGMOD, 2024, 2(1): 1-25.

作者简介:邓迅(1982—),男,本科,工程师,研究方向:智能传感器,AI应用。