

· AI+慢性病康复管理专题 · doi:10.3969/j.issn.1671-8348.2024.24.002

网络首发 [https://link.cnki.net/urlid/50.1097.R.20241129.2014.011\(2024-12-02\)](https://link.cnki.net/urlid/50.1097.R.20241129.2014.011(2024-12-02))

基于健康保险数据的医疗费用共病网络分析及深度学习预测*

曹毓文^{1,2},梅好^{1,2△},孙佳仪³,胡炯宇⁴,徐雅晴⁵

- [1. 中国人民大学应用统计科学研究中心,北京 100872;2. 中国人民大学统计学院,北京 100872;
3. 清华大学人文学院,北京 100084;4. 陆军军医大学第一附属医院内分泌科,重庆 400038;
5. 上海交通大学公共卫生学院,上海 200025]

[摘要] **目的** 通过分析相关医疗记录构建医疗费用共病网络,并结合疾病网络与长短期记忆神经网络构建深度学习预测模型,以提升个体医疗费用预测的准确度,同时为优化医疗政策、提升患者健康管理水平提供助力。**方法** 基于中国台湾健康保险研究数据库 2000—2013 年的医疗记录,分析 9 963 例患者的 584 万条就诊数据,构建包含 104 种常见疾病的医疗费用共病网络,分析网络结构并预测潜在共病,结合患者的性别、年龄、病史等信息输入构建深度学习模型个体医疗费用。**结果** 构建的医疗费用共病网络包含 104 个节点、3 390 条边和 6 个模块,是一个节点高度相连的网络,表示疾病间医疗费用具有高度相关性。构建的深度学习预测模型较传统回归模型及未充分考虑共病信息的深度学习模型相比,显著提高了预测精度。**结论** 构建的模型为理解疾病共病性提供了全新的理论视角,还为精准预测医疗费用、优化医疗资源配置以及实现个性化医疗服务提供了有效工具。

[关键词] 慢病管理;健康保险数据;疾病网络;深度学习;医疗费用预测

[中图法分类号] R112 **[文献标识码]** A **[文章编号]** 1671-8348(2024)24-3686-06

Comorbidity network analysis and deep learning prediction of medical expenses based on health insurance data*

CAO Yuwen^{1,2},MEI Hao^{1,2△},SUN Jiayi³,HU Jiongju⁴,XU Yaqing⁵

- (1. Scientific Research Center for Applied Statistics, Renmin University of China, Beijing 100872, China;2. School of Statistics, Renmin University of China, Beijing 100872, China;3. School of Humanities, Tsinghua University, Beijing 100084, China;4. Department of Endocrinology, First Affiliated Hospital of Army Military Medical University, Chongqing 400038, China;
5. School of Public Health, Shanghai Jiao Tong University, Shanghai 200025, China)

[Abstract] **Objective** To construct a comorbidity network for medical expenses by analyzing the relevant medical records, and to construct a deep learning prediction model by combining with the disease networks and long short-term memory neural networks in order to improve the accuracy of individual medical expense prediction and provide the assistance for optimizing the medical policies and enhancing the patient health management level. **Methods** Based on the medical records of Taiwan, China Health Insurance Research Database during 2000—2013, the data of 5.84 million visits from 9 963 patients were analyzed, and a comorbidity network of medical expenses for 104 common diseases was constructed. The network structure was analyzed and the potential comorbidity was predicted, and the deep learning model of individual medical cost was constructed by combining the input of patient's gender, age, medical history and other information. **Results** The constructed medical cost comorbidity network consists of 104 nodes, 3 390 edges and 6 modules, and is a highly connected network with nodes, indicating that the medical costs possesses the high correlation between diseases. The constructed deep learning prediction model significantly improves the prediction accuracy compared to the traditional regression models and deep learning models that do not fully consider the comorbidity information. **Conclusion** The constructed model provides a new theoretical perspective for understanding the comorbidity of diseases, as well as an effective tool for accurately predicting medical costs, optimizing medical resource allocation and achieving the personalized medical services.

[Key words] chronic disease management; health insurance data; disease network; deep learning; medical expenses prediction

随着中国经济的快速发展,人们的生活方式发生了巨大变化。饮食结构、运动习惯等因素的改变使慢性疾病越来越常见^[1]。根据世界卫生组织 2020 年全球慢性疾病调查报告,中国的死亡人口中,因慢性疾病导致死亡的比例为 89%^[2]。慢性疾病通常需要长期的治疗和管理,对医疗资源的需求更大。因此,慢性疾病管理和预防是维护健康、减轻医疗负担的关键措施之一。而预测医疗费用在慢病管理中的重要性不容忽视,因为它直接反映了疾病的严重程度对个人、家庭和医疗系统造成的负担。通过准确预测医疗费用,医疗机构和政府可以更好地规划资源、提供更有效的医疗服务;医疗保险机构可以更精准地厘定保险费用、研发更完善的健康保险产品;患者和家庭可以做出更明智的决策,包括购买医疗保险、调整生活方式以预防疾病等。总之,预测医疗费用不仅有助于个体健康管理,也是医疗体系优化的重要一环。

已有研究指出,多病共存与医疗费用的增加密切相关^[3]。然而国内对于共病模式的研究大多为描述性分析^[4],大多数医疗费用预测并未使用患者共病的信息,而少数使用共病信息(如 Charlson 共病指数、Elixhauser 共病指数等)的研究也往往不在全疾病的范围^[5-6]。在预测模型方面,早期的研究人员在预测医疗费用时主要使用经典回归模型^[7-8]。然而,医疗数据往往呈现数据量大、有复杂相关性的特征,因此机器学习和深度学习在处理复杂数据和解决非线性问题方面的优势使得医疗领域的许多研究人员开始利用人工智能技术来挖掘医疗数据中的潜在信息,构建更准确、更可靠的预测模型^[9-11]。

本研究基于中国台湾健康保险研究数据库中 2000—2013 年 584 万条就诊数据中每位患者的主副疾病构建医疗费用共病网络,并使用该网络测度潜在共病,填补了现有研究在使用全疾病范围内的共病信息预测费用方面的空白。本研究构建了结合长短期记忆(LSTM)的全连接神经网络,使用人口学信息、就诊信息、历史疾病信息、可能共病信息预测 2013 年个体层面的全疾病医疗费用。

1 资料与方法

1.1 一般资料

本研究采用中国台湾的健康保险研究数据库。该数据库建立于 2002 年,至今已覆盖了 99.99% 的中国台湾人口,能够提供较为精确、长期跟踪的医疗保健数据,一定程度上能够为亚洲人群的疾病研究提供参考^[12-13]。本研究采用 2000—2013 年 9 963 例患者共 5 849 402 条病例,每条病例包含年份、患者编码、患者性别、就诊年龄、就诊费用和国际疾病分类(ICD)编码等信息。本研究采用由美国卫生保健研究与质量局制定的临床分类软件(CCS)分组方案进一步将 ICD 编码聚类成临床上更有意义的疾病分类^[14]。

1.2 方法

1.2.1 数据预处理

在数据预处理阶段,本研究首先剔除主疾病缺失的病例数据。其次依据文献^[15]对于常见疾病的规范定义,剔除以下疾病编码为主疾病的病例数据:(1)外因损伤及其他(ICD-9-CM 编码中 E 和 V 开头编码);(2)妊娠、分娩及分娩后并发症(ICD-9-CM 编码中 630-679);(3)症状、体征和不明情况(ICD-9-CM 编码中 760-999)。其次,在剔除医疗费用记录为 0 的病例数据之后,依照以下原则对每条病例数据进行对应的费用分配:若该就诊记录只存在主疾病编码记录,则该疾病的医疗费用为该记录的医疗总费用;若该就诊记录存在一条或多条副疾病编码记录,则主疾病医疗费用占总费用的 60%,一个或多个副疾病医疗费用平分剩余 40% 的总费用。经处理后,最终筛选出 3 341 768 条病例数据,共纳入 9 930 例患者,200 个疾病分类。数据预处理流程图见图 1。为保证推断和预测的准确性,本研究聚焦于在 14 年记录中超过 3% 的人口患病率的常见疾病共 104 个。

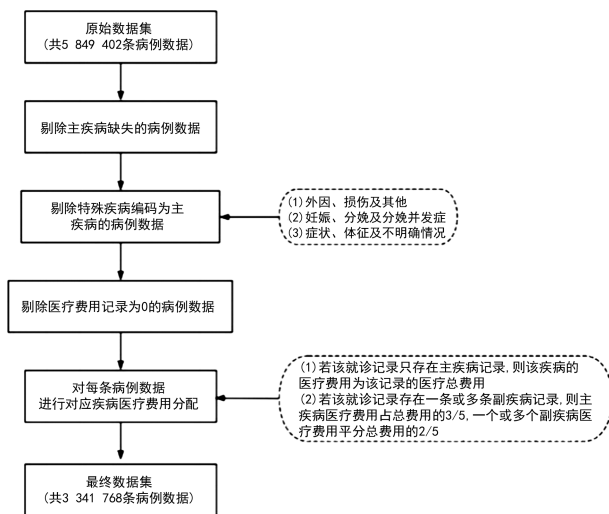


图 1 数据预处理流程图

1.2.2 医疗费用共病网络

人类疾病网络是通过分析和展示各种疾病之间的相互关系和关联来揭示其复杂性的工具。它通常基于大规模的医疗数据和生物信息学数据,通过对疾病共同特征的分析,来研究疾病间复杂的作用关系。本研究的目标是基于并存疾病间医疗费用的相关性构造共病网络,网络中的一个节点表示一个疾病,两个节点有边相连表示其对应的医疗费用具有统计相关性,也就是说两个共病之间的医疗费用有互相影响的作用。本研究借鉴 MEI 等^[16]提出的图模型方法构建医疗费用共病网络。

考虑医疗费用数据的偏态性,本研究对其非零部分进行对数转换处理,使其服从正态分布。同时,本研究改进了 MEI 等^[16]中网络邻接矩阵的计算方法,使其能够度量疾病间医疗费用相关性的大小程度,并进一步利用动态树切割聚类的方法构建疾病网络模

块。网络模块由紧密互联的节点组成的,同一模块内的疾病医疗费用方面具有密切相关性,而来自不同模块的疾病之间的连接则相对较弱。模块分析可以为疾病特征和分类提供重要的见解^[17-18]。

1.2.3 医疗费用预测模型

本研究预测对象为个体每次就诊时的医疗费用,采用人口学信息、疾病信息等作为预测变量。其中,就诊疾病信息分为两类,一类是患者就诊时疾病信息,另一类是患者历史及潜在共病信息。其中潜在共病信息通过上文中构造的医疗费用共病网络推断得出。本研究构建的神经网络分为左右两部分,其中右半部分的输入(第二类疾病信息)通过 LSTM 结构、两个全连接层并经过 Dropout 与左半部分的输入(人口学信息、第一类疾病信息)通过两个全连接层后的输出拼接起来,紧接着经过全连接层、Dropout 得到最终预测结果。见图 2。

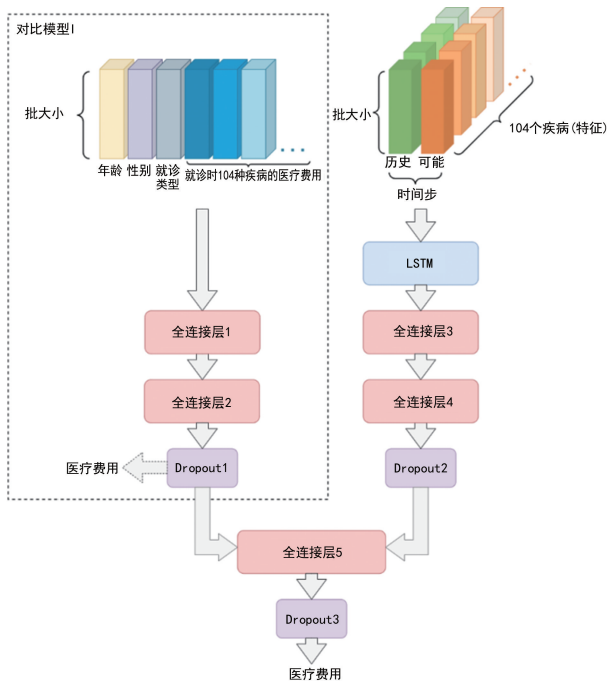


图 2 神经网络结构图

在预测变量构造部分,本研究考虑了患者的性别、年龄、就诊类别、每次就诊时的主副疾病编码,患者的历史疾病和潜在共病。此外,由于不同疾病医疗费用的平均水平各有不同,而实际就诊费用与其息息相关,本研究计算了在 2000—2013 年每个常见疾病的平均医疗费用。预测变量的构造见表 1。

对于 pro_prc,本研究仅考虑与某一疾病有关的前五大最有可能的共病的概率。因此具体来看,神经网络左半部分的输入特征为 sex、age、source、cur_prc,即形状为(batch_size,107)的向量,右半部分的输入特征为堆叠成形状(batch_size,2,104)的 his_prc、pro_prc,其中的 LSTM 结构常用于处理时间序列的多维数据,符合本研究同时利用历史疾病与可能共病的预期。

表 1 自变量描述

类型	变量名	变量解释
患者人口学信息	sex	患者性别
	age	患者年龄
就诊信息	source	就诊类别,分为门诊部(OPD)与住院部(IPD)
	cur_prc	本次就诊记录中主副疾病的平均医疗费用
其他信息	his_prc	患者每个疾病的历史医疗费用
	pro_prc	患者潜在共病的平均医疗费用

1.3 统计学处理

在数据预处理与模型训练阶段,使用 Python 进行数据清洗及医疗费用预测模型的构建,从而实现预测精度的提升。为了探索疾病之间的复杂关系,采用 R 软件,利用其在统计建模和网络分析方面的强大功能,建立了医疗费用的共病网络。

2 结果

2.1 医疗费用共病网络结果

本研究基于 9 930 例患者 14 年内 104 种常见疾病的患病状况和医疗费用建立疾病网络。该网络包含 104 个节点和 3 390 条边,是一个节点高度相连的网络,表示疾病间医疗费用具有高度相关性。图中每个节点代表一个 CCS 疾病,节点的标签是对应的 CCS 疾病编码,两个节点有边相连表示其对应的疾病费用有统计学相关性。节点大小与节点连通度成正比,节点的颜色与聚类模块相一致,见图 3。

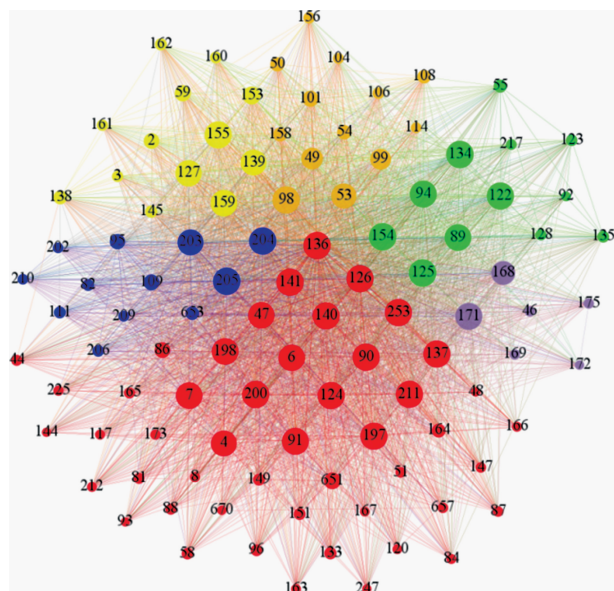


图 3 医疗费用共病网络可视化图

2.1.1 高连通度疾病分析

连通度衡量一个节点与其他节点之间的连接程度。通常,较高的连通度表明节点在网络中的整体影响力更大。这些节点可能对应着关键疾病或重要病理过程,因此,在疾病的早期预警、精准诊断以及医疗

资源的有效分配中应当被重视。表 2 展示了连通度排名前十位的疾病及其对应的连通度。从表中可以看出,高连通度疾病主要集中于以下几类:一是发病率高且常见的疾病(如高血压、急性支气管炎等),二是具有中心作用的疾病(例如,原发性高血压不仅是心血管疾病的重要危险因素,还可能诱发或加重肾病、糖尿病等一系列慢性疾病),三是对全身具有广泛影响的疾病(如结缔组织疾病和脊柱疾病等)。这些特征共同体现了高连通度疾病在疾病网络中的关键地位,为疾病间的交互机制研究和临床干预策略提供了重要参考。

表 2 高连通度疾病

CCS 编码	疾病名称	连通度
136	肠道感染	40
126	其他上呼吸道感染	32
211	结缔组织疾病	14
205	脊柱疾病;椎间盘疾病;其他背部问题	13
90	失明及视力缺陷	13
125	急性支气管炎	12
253	手术操作或医疗护理并发症	12
124	肺炎(不包括由结核或性传播疾病引起的肺炎)	11
134	其他上呼吸道疾病	11
98	原发性高血压	9

2.1.2 疾病模块分析

根据动态树切割聚类算法,本研究构建的医疗费用共病网络结果被划分为 6 个模块。每个模块内的疾病由一组紧密相关的疾病构成,这种相关性可能反映了它们在病理机制、共病模式或临床表现上的内在联系。如图 3 所示,一类疾病(红色)主要包括肿瘤及其相关并发症,是节点最多、影响力最大的模块;二类疾病(橙色)主要包括糖尿病、心血管疾病、肾病等慢性疾病,病程较长,需要长期的治疗和管理;三类疾病(黄色)多与感染和炎症相关,可能导致全身性的症状或并发症;四类疾病(绿色)主要包括水电解质紊乱、眼睛及耳朵相关疾病等;五类疾病(蓝色)主要包括神经系统疾病、骨关节疾病和结缔组织疾病等;六类疾病(紫色)主要包括生殖系统疾病。

同一模块的疾病可能共享相似的病因、发病机制或共同的高危因素,也可能在患者群体中具有较高的共病概率。由于这些疾病在临床上常常相伴出现,因此在临床诊疗中应注重联合诊断和综合治疗,以提高诊疗效率并改善患者预后。同时,这些模块还可以为医疗资源分配提供科学依据,例如在医疗设备采购、药物供应和患者管理中,可以针对同一模块的疾病进行一体化规划。此外,在公共健康政策制定中,这些模块的疾病应被同时纳入考虑,例如针对同一模块内疾病的综合防控措施,可以更有效地降低整体疾病负担。这种基于模块化分析的策略,不仅能够优化医疗和健康管理资源,还为个性化医疗和精准健康干预提供了理论支持。

2.2 预测模型结果

在训练预测医疗费用的神经网络时,以 8 : 2 的比例随机划分训练集和测试集,对训练集的自变量与因变量进行标准化并在测试集上应用相同的标准化处理。损失函数为机器学习中常用于回归问题的损失函数均方误差 MSE,其公式为:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad \text{①}$$

其中, y_i 为测试集样本的真实值, \hat{y}_i 为测试集样本的预测值, n 为样本数, MSE 越小意味着预测值与真实值越接近,则预测效果越好。另外选取具有自适应学习率的特性的 Adam 作为优化器,有助于快速收敛。在确定每层神经元个数时,本研究选择网格搜索,以找到模型性能最佳的超参数组合。

在第一种对比方法中,仅考虑神经网络左半部分的结构,即图 2 的“对比模型 I”部分,输入仅为患者性别、年龄、就诊类别、就诊记录的主副疾病的平均费用,以此证明本研究主模型中考虑历史疾病、可能共病的优越性。在第二种对比方法中,保留本研究主模型的神经网络结构,但在计算可能共病时使用 KAL-GOTRA 等^[19]的研究中构建共病网络邻接矩阵的方法,即 Ochiai 系数,以此证明本研究在医疗费用共病网络构建时同时纳入疾病本身与其费用的优越性。第三种对比方法为简单回归模型,输入与主模型的输入相同。主模型与对比模型 I、II 的神经元个数选取和所有模型在测试集上的 MSE,见表 3。

表 3 主模型与对比模型 MSE 结果

模型	全连接层 1	全连接层 2	LSTM	全连接层 3	全连接层 4	Drop-out1,2	全连接层 5	Drop-out3	MSE
主模型	80	10	20	50	50	0.5	30	0.5	0.81
对比模型 I	80	10							1.13
对比模型 II	80	10	20	50	50	0.5	30	0.5	0.91
对比模型 III									0.89

从结果看出,仅使用人口学信息和当前就诊信息

的对比模型 I 其预测效果最差(MSE 最大),而在纳

入历史疾病信息、可能共病信息的主模型、对比模型Ⅱ和对比模型Ⅲ中,主模型预测效果最好,主模型和对比模型Ⅲ效果优于对比模型Ⅱ,说明在预测医疗费用的背景下,本研究在构建医疗费用共病网络时同时考虑疾病是否存在以及医疗费用信息要优于传统共病网络邻接矩阵构建的方法。

在实际应用中,精准预测个体层面的医疗费用具有多方面的重要意义。以高血压为例,这是一种常见的慢性病,常伴随多种共病,如糖尿病、心血管疾病和肾病等。精准预测高血压患者的医疗费用,可以在优化个体化健康管理、支持医保政策制定、辅助医疗资源

配置、推动健康政策制定、提高患者经济负担管理等方面发挥重要作用。以测试集中高血压为主副疾病的患者为例,图 4 分别展现了不同性别、不同年龄段、高血压为主或副疾病的医疗费用预测值的分布。如图所示,女性和男性相比,高血压患者的全因医疗费用均值和中位数相近,但有极端高花费的女性人数更多;<60 岁和 ≥60 岁相比高血压患者的全因医疗费用均值和中位数相近,但有极端高花费的老年人数更多;就诊时副疾病包括高血压的人群比主疾病为高血压的人群平均医疗费用更高,有极端高花费的人数也更多。




图 4 高血压患者子人群医疗费用预测分布

3 讨 论

本研究通过对中国台湾健康保险研究数据库 2000—2013 年的医疗就诊记录进行深入分析,从一个全新的角度审视了疾病之间的相互作用及其对医疗费用分布模式的影响。所构建的疾病医疗费用共病网络不仅揭示了疾病之间的潜在关联,还可以帮助医疗管理者识别资源配置的重点领域。其中,高连通度疾病应当被重点关注,因为这些疾病通常处于疾病网络的核心位置,与多种其他疾病存在强关联,可能成为共病管理和医疗资源分配的关键节点^[15-18]。同一模块的疾病由于在网络中表现为密切相关的群体,可能反映共同的病理机制或易感性,因此在临床诊疗、健康管理和资源分配中应当被同时考虑。

此外,本研究将医疗费用共病网络信息纳入长短期记忆深度学习模型,用于预测个体医疗费用,显著提升了预测精度。本研究使用的医保数据覆盖了 99.99% 的中国台湾人口,与单个或几个医院相比数据范围更加全面,但缺乏临床诊疗及检验检查相关信息,这是医保数据的缺陷。本研究结果展示基于有限信息,通过疾病网络分析潜在共病从结果来看是合理的,文中深度学习模型的变量纳入患者潜在共病的概率时预测表现更好。该疾病网络量化疾病间医疗费用的相关性,与文献^[17-18]中的人类疾病网络结果有所不同,提供了新的疾病间互相作用及聚类的观测视角。因此,基于有限的医保数据信息,本研究模型对

比各基线方法有效提高了预测精准度。本研究重在网络构建和预测方法的提出,如果未来能获得更加详细的临床数据,本研究中所提出的深度学习模型也可以很容易地进行扩展,通过在个体特征部分纳入更多的临床特征作为输入变量来进一步提升预测精度。

本研究中提出的图模型计算成本在 5 min 内,神经网络模型对于一组超参数组合训练成本在 10 min 以内。同时,以上模型不需要进行实时更新,在训练结束后可以保存模型参数直接用于之后新的个体数据的预测,每条数据在几秒内即可完成估计。对于图模型和神经网络的更新,可以在样本量翻倍、人群分布发生重大变化或者在全社会范围内出现大型公共卫生突发情况进行周期性的更新。因此,使用本研究提出的方法进行医疗费用预测计算成本及实际应用转换难度较低。

本研究的成果不仅为理解疾病共存性提供了新的理论视角,也为精准预测医疗费用以优化医疗资源配置和实现个性化医疗服务提供了有效的工具。本研究的方法路径可以在未来用于探究其他数据分布类型的临床结局信息,如术后并发症、住院时长、死亡等,或综合分析多个结局之间疾病网络的关系,为预测提供更多支持。

参考文献

[1] 王辉,王楠,柳光斌,等. 慢性疾病防治研究进展

- [J]. 中国城乡企业卫生, 2021, 36(9): 30-32.
- [2] 刘永民. 从国家调控视角看慢性疾病管理全面实施的困境与对策分析[J]. 中国医药科学, 2020, 10(22): 221-223.
- [3] MARTHIAS T, ANINDYA K, NG N, et al. Impact of non-communicable disease multimorbidity on health service use, catastrophic health expenditure and productivity loss in Indonesia: a population-based panel data analysis study [J]. *BMJ Open*, 2021, 11(2): e041870.
- [4] 孙至佳, 樊俊宁, 余灿清, 等. 中国 10 个地区成年人共病流行特征分析[J]. 中华流行病学杂志, 2021, 42(5): 755-762.
- [5] FARLEY J F, HARLEY C R, DEVINE J W. A comparison of comorbidity measurements to predict healthcare expenditures[J]. *Am J Manag Care*, 2006, 12(2): 110-119.
- [6] LUO L, YU X, YONG Z, et al. Design comorbidity portfolios to improve treatment cost prediction of asthma using machine learning[J]. *IEEE J Biomed Health Inform*, 2021, 25(6): 2237-2247.
- [7] ZHAO Y, ASH A S, ELLIS R P, et al. Predicting pharmacy costs and other medical costs using diagnoses and drug claims[J]. *Med Care*, 2005, 43(1): 34-43.
- [8] BERTSIMAS D, BJARNADÓTTIR M V, KANE M A, et al. Algorithmic prediction of health-care costs[J]. *Operat Res*, 2008, 56(6): 1382-1392.
- [9] 石菊, 王小倩, 王熙. 微观医疗费用预测模型: 从线性回归到机器学习[J]. 经济学(季刊), 2023, 23(6): 2247-2263.
- [10] MORID M A, SHENG O R L, KAWAMOTO K, et al. Healthcare cost prediction: Leveraging fine-grain temporal patterns[J]. *J Biomed Inform*, 2019, 91: 103113.
- [11] ZENG X, LIN S, LIU C. Multi-view deep learning framework for predicting patient expenditure in healthcare[J]. *IEEE Open J Comput Society*, 2021, 2: 62-71.
- [12] HSIEH C Y, SU C C, SHAO S C, et al. Taiwan's national health insurance research database: past and future[J]. *Clin Epidemiol*, 2019, 11: 349-358.
- [13] LIN L Y, WARREN-GASH C, SMEETH L, et al. Data resource profile: the National Health Insurance Research Database (NHIRD) [J]. *Epidemiol Health*, 2018, 40: e2018062.
- [14] WEI W Q, BASTARACHE L A, CARROLL R J, et al. Evaluating phecodes, clinical classification software, and ICD-9-CM codes for phenotype-wide association studies in the electronic health record [J]. *PLoS One*, 2017, 12(7): e0175508.
- [15] JIANG Y, MA S, SHIA B C, et al. An epidemiological human disease network derived from disease co-occurrence in Taiwan[J]. *Sci Rep*, 2018, 8(1): 1-12.
- [16] MEI H, JIA R, QIAO G, et al. Human disease clinical treatment network for the elderly: the analysis of medicare inpatient length of stay data[J]. *Stat Med*, 2021, 40(8): 2083-2099.
- [17] HIDALGO C A, BLUMM N, BARABÁSI A L, et al. A dynamic network approach for the study of human phenotypes[J]. *PLoS Comput Biol*, 2009, 5(4): e1000353.
- [18] GOH K I, CUSICK M E, VALLE D, et al. The human disease network[J]. *Proceed Natl Acad Sci U S A*, 2007, 104(21): 8685-8690.
- [19] KALGOTRA P, SHARDA R. When will I get out of the hospital? Modeling length of stay using comorbidity networks[J]. *J Manag Inform Syst*, 2021, 38(4): 1150-1184.

(收稿日期: 2024-03-28 修回日期: 2024-09-11)

(编辑: 管佩钰)

(上接第 3685 页)

- [39] MEHELI S, SINHA C, KADABA M. Understanding people with chronic pain who use a cognitive behavioral therapy-based artificial intelligence mental health app (Wysa): mixed methods retrospective observational study[J]. *JMIR Hum Factors*, 2022, 9(2): e35671.
- [40] ANAN T, KAJIKI S, OKA H, et al. Effects of

an artificial intelligence-assisted health program on workers with neck/shoulder pain/stiffness and low back pain: randomized controlled trial [J]. *JMIR Mhealth Uhealth*, 2021, 9(9): e27535.

(收稿日期: 2024-03-28 修回日期: 2024-09-12)

(编辑: 姚雪)