

常见病和疑难病的疾病诊断相关分组权重划分研究*

陈 吟¹ 郝一炜² 刘晓宇³ 姚润徽⁴ 李 昂¹ 侯亚冰⁵ 董爱然⁶ 郭默宁^{1△}

【摘要】目的 探索基于疾病诊断相关分组权重的疑难和常见疾病范围划分,为绩效评价和分级诊疗推进效果评估提供数据支撑。**方法** 采用 CN-DRG 分组方案对 2022 年 3188340 份病案首页数据分为 738 组并以病组为单位进行 k 中心点聚类。模拟 4 个聚类模型并通过指标对模型解释力度确定最优模型后,划分常见病和疑难病的 RW 截点。**结果** 经过模型测算确定纳入最优聚类模型的指标为平均住院日、进入重症监护室比例、呼吸机使用比例和例均费用四个指标。内科治疗常见病和疑难病的 RW 截点为 0.97;外科治疗常见病和疑难病的 RW 截点为 2.13。**结论** 本研究首次通过资源消耗、疾病治疗界定了疑难病和常见病的疾病诊断相关分组权重范围。研究结果为医院功能定位落实、临床专科能力评估等提供高诊治难度疾病测算工具。

【关键词】 相对权重 诊治难度 疾病诊断相关分组 K 中心点聚类

【中图分类号】 R195.1 **【文献标识码】** A **DOI** 10.11783/j.issn.1002-3674.2025.01.003

Study on the Relative Weight Divisions of Diagnosis-related Groups for both Common and Complex Diseases

Chen Yin, Hao Yiwei, Liu Xiaoyu, et al (Beijing Municipal Health Big Data and Policy Research Center, Beijing 101117)

【Abstract】Objective To examine the classification of difficult and common diseases based on the weight of diagnosis related groups and to provide data support for performance evaluation and effect evaluation of the hierarchy medical system. **Methods** The CN-DRG grouping scheme was utilized to categorize the data from 3188340 medical records into 738 groups in 2022. The disease group performed k-medoids clustering. our clustering models were simulated, and the optimal model was determined by evaluating the explanatory power of each model using specific indicators. Subsequently, the relative weight ranges of DRG for common and difficult diseases were established. **Results** The optimal clustering model was identified using four indicators: the average length of stay, the proportion of patients admitted to intensive care units, the proportion of patients using ventilators, and the average cost per patient. The relative weight for common and difficult diseases was 0.97 for medical treatment, while for surgical treatment, it was 2.13. **Conclusion** This study is the first to define the weight ranges of diagnosis-related groups for common and difficult diseases by analyzing resource consumption and treatment outcomes. The findings provide a valuable measurement tool for hospital functional positioning and the evaluation of clinical specialty capabilities.

【Key words】 Relative weight; Treatment difficulty; Diagnosis-related groups; K-medoids

疾病诊断相关分组 (diagnosis related groups, DRG) 相对权重 (relative weight, RW) 是每个病组平均费用与全部病组平均费用的相对比值,反映不同疾病和治疗方式资源消耗差异。病情越复杂,通常治疗成本越高^[1]。通过计算区域 RW 进而计算病例组合指数 (case mix index, CMI),可以评价区域或医院的平均技术水平。

2015 年,《国务院办公厅关于推进分级诊疗制度建设的指导意见》(国办发[2015]70 号)提出明确各级各类医疗机构诊疗服务功能定位,城市三级医院主要提供急危重症和疑难复杂疾病的诊疗服务,城市二

级医院主要接收三级医院转诊的急性病恢复期患者、术后恢复期患者及危重症稳定期患者。从卫生管理角度来看,在划分急危重症、疑难复杂和相对简单常见疾病,确定不同等级医院诊疗服务范围后,才能以数据为支撑评估分级诊疗落实情况。而疑难复杂疾病和常见疾病,目前并没有统一标准。尽管公立医院高质量发展^[2]和临床专科能力评价^[3]将 RW 作为考核指标体现收治情况,但对疑难病和常见病 RW 应界定在什么范围,尚未有数据验证。综上所述,本研究利用病案首页数据,从 RW 出发,通过权重值界定疾病诊疗难度,为考评医疗机构收治病种结构、分级诊疗推动情况评价提供参考。

* 基金项目:首都卫生发展科研专项(首发 2021-1G-3051;首发 2024-2-3052)

1. 北京市卫生健康大数据与政策研究中心(北京市医院管理研究所)(101117)

2. 首都医科大学附属北京地坛医院

3. 首都经济贸易大学统计学院

4. 清华大学未央书院

5. 首都医科大学燕京医学院

6. 首都医科大学宣武医院

△通信作者:郭默宁,E-mail:guomoning@wjw.beijing.gov.cn

资料和方法

1. 资料来源

数据来源于北京市出院病人调查表(京卫信 A1-5-1 表),该表由北京市卫生健康大数据与政策研究中心按照《北京市卫生健康统计调查制度》,每月通过北京市卫生综合统计信息平台法定收集,内容涵盖北京地区住院病例基本信息、诊疗信息和

费用信息。

2. 研究设计

(1) 疾病诊治难度的概念和内涵

诊治难度指的是诊断、治疗某一疾病所需的技术水平,以及相对应的医疗资源消耗水平^[4-5]。从临床角度来看,高诊治难度代表了治疗患者与其提供护理服务的困难,体现了包括疾病严重程度、死亡风险、疾病转归、干预需求和开展治疗消耗的资源强度。从行政管理角度来看,诊治难度体现的是对满足患者需求所需耗费的成本或资源。诊治难度越高,表明治疗患者需要越多资源,从而提供服务的成本更高。综合两方面考虑,高诊治难度代表的是救治疑难和危重疾病的能力,以及更高的资源消耗。

(2) 疾病诊治难度与 RW 的关系

DRG 以出院患者信息为依据,综合考虑患者的主要诊断和主要治疗方式并结合个体体征,通过“病例组合”的方式将临床过程相近和(或)资源消耗相当的病例分类组合成为若干个组别,组与组之间制定不同

的权重反映各组特征,从而让不同强度和复杂程度的医疗服务之间有了客观对比依据^[1,6]。RW 一定程度上体现了疾病复杂程度和资源消耗强度,但真实世界数据存在治疗难度高但资源消耗很低的病例。例如,晚期癌症患者病情非常严重且预后不良,但除了基本护理外,需要的医疗资源很少。对于病例组合复杂性的所有不同方面,没有一种度量方法能够同样有效。基于此,国际经验是在 DRG 分组基础上结合疾病治疗的其他特征去界定疾病诊治难度,如美国 3M 公司在 MS-DRG 基础上,将疾病严重程度和死亡风险纳入 DRG 系统,并根据患者的复杂性进行校正,以比较资源利用、并发症发生率和住院时间差异^[7-8]。

(3) 疾病诊治难度 RW 范围界定的模型思路

图 1 展示了疾病诊治难度 RW 范围界定的研究思路。总体分为三个步骤,一是内科、外科和急症类病组的区分,二是疑难病和常见病的分类,三是疑难病和常见病 RW 的划分,最后统计常见疾病、急症类和疑难疾病 RW 范围。

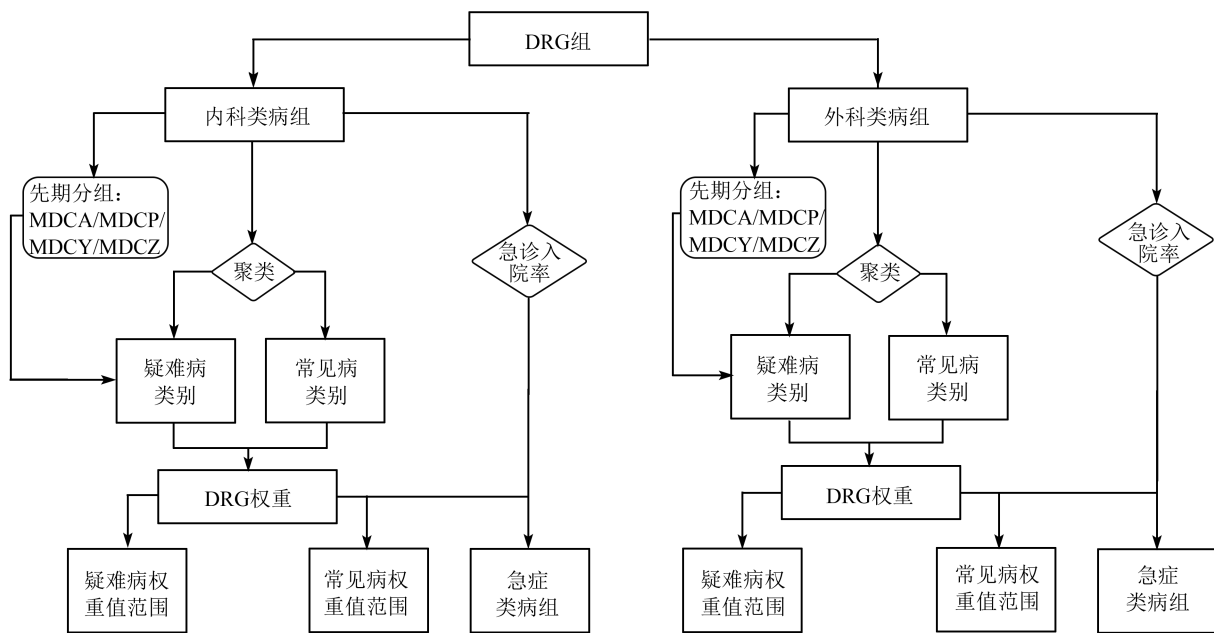


图 1 基于 RW 的疾病诊治难度分类框架

① 内科和外科单建模型

内科和外科的诊疗思路和治疗方式不同因而存在资源消耗差异,相应治疗难度不完全具有可比性。RW 侧重于从资源消耗角度给不同治疗方式的所有 DRG 组确定相对数值,但若考虑诊治难度,需要将内科和外科予以区分。本研究首先根据手术、操作和药物治疗三类方式来划分外科和内科的 DRG 组,并分别构建模型划分以外科和内科治疗为主的疑难病和常见病类别。每个 DRG 组代码有 4 位,其中第二位代表治疗方式。将 DRG 代码第二位在 A 至 Q(手术和操作治疗)的病组定义为外科组,R 至 Z(药物治疗)定义为内科组。

② 在 DRG 分组逻辑体系下优先确定疑难组

DRG 通常根据主要诊断将病例分入到不同的系统和解剖部位(major diagnosis category, MDC),在此之前,会将需要开展移植手术、疾病累及多个部位的病例,根据主要诊断和手术操作治疗方法优先入组(先期分组)。鉴于这些组别已预判为治疗复杂、花费较高的病组,因此本研究直接将其划分为疑难疾病类,包括先期分组(MDCA)、新生儿及其他围产期新生儿疾病(MACP)、HIV 感染疾病及相关操作(MDCY)和多发严重创伤(MDCZ)。

③ 对急症病组的考虑

危急类疾病特点体现在就近就医、抢救。按照我

国医院的公益性属性,二、三级医院须有能够对危急症病人的不同抢救能力,而急诊科室是医院急诊诊疗的首诊场所,急诊收治住院患者通常代表诊治的时效,同时在通过急诊初步处理后仍需住院进一步治疗,体现了除难度之外的救治时效性。因此,本研究通过病组急诊入院率,在疑难病和常见病之外设置急症组类别,将其作为交叉组别,该类别的 DRG 组无论 RW 高低,均属于二级和三级医院所需收治疾病。急诊入院率定义为某一病组急诊入院人次占该病组全部入院人次。急诊入院需求和疾病复杂情况及年龄相关^[9]。在综合分析了每个病组平均年龄和是否伴有合并症并发症情况(见表 1“细分组分类”)这两个指标后,将急症病组范围界定在急诊入院率 $\geq 48.34\%$ 。基于该划分标准,共将除先期分组外的 76 个病组确定为急症病组。

④ 聚类模型的指标选择

如前所述,疾病诊治难度从救治能力和资源消耗上体现。其中,救治能力代表对疑难危重患者的救治情况,包括重症监护和使用呼吸机情况,以及体现疾病转归的死亡率。资源消耗从患者单次住院的费用以及占用床位时长予以体现。在结合国际经验和专家咨询后,本研究最初纳入体现上述两方面的 11 个指标进行

模型计算(见表 1),并通过对指标进行排列组合后,筛选出能够计算疑难病和常见病 RW 的最小数据集。

通过构建基于不同指标的 4 个聚类分析模型,对结果进行比较后,确定常见病和疑难病划分最终模型。如表 1 所示,模型 1 考虑了住院效率、费用、体现疾病严重程度相关指标、DRG 细分组分类、疾病转归情况以及该疾病的死亡风险分级。死亡风险等级是通过利用各 DRG 病例的住院死亡率对不同 DRG 进行死亡风险分级并计算死亡风险评分,基于死亡风险评分将 DRG 组分为“低风险组”、“中低风险组”、“中高风险组”和“高风险组”。

考虑死亡率和死亡风险等级相关性较强($r_s = 0.46, P < 0.001$),且细分组分类是根据 DRG 代码定义将 DRG 组的病例合并症和并发症情况细分为类,而是否有合并症或并发症和 RW 也存在较强相关性($r_s = 0.48, P < 0.001$),可通过权重值体现,因此模型 2 到模型 4 在经过相关性验证后,排除了细分组分类和死亡率。

从指标进行聚类的解释力度出发,模型 3 和模型 4 进一步精简了指标,以聚类解释度作为确定最终模型判断指标。

表 1 K-medoids 聚类分析模型纳入变量

序号	模型 1	模型 2	模型 3	模型 4	指标类型
1	平均住院日	平均住院日	平均住院日	平均住院日	连续变量
2	例均费用	例均费用	例均费用	例均费用	连续变量
3	例均药品费用	例均药品费用	例均药品费用	/	连续变量
4	例均耗材费用	例均耗材费用	例均耗材费用	/	连续变量
5	用血比例	用血比例	/	/	连续变量
6	进入重症监护室比例	进入重症监护室比例	进入重症监护室比例	进入重症监护室比例	连续变量
7	呼吸机使用比例	呼吸机使用比例	呼吸机使用比例	呼吸机使用比例	连续变量
8	抗菌药物使用比例	抗菌药物使用比例	/	/	连续变量
9	细分组分类	/	/	/	分类变量:0=未细分;1=伴不伴合并症与并发症; 2=伴一般合并症与并发症;3=严重合并症
10	死亡率	/	/	/	连续变量
11	死亡风险等级	死亡风险等级	死亡风险等级	/	分类变量:1=低风险;2=中低风险; 3=中高风险;4=高风险

3. 统计学方法

(1) 聚类模型数据分组和纳入、排除标准

利用绩效版疾病诊断相关分组方案规则^[10],将 2022 年 1—12 月 3188340 份北京市出院病人数据分为 738 组,其中,内科病组 424 组,外科病组 314 组。排除未入组病例 9476 例(占 0.30%)。按照③和④的思路,在聚类分析时,只纳入非急症类别、非先期分组病组,共纳入内科病组 357 组、外科病组 267 组,占全部病组的 85%。

(2) K 中心点聚类

K 中心点(K-medoids)聚类是一种基于划分的聚

类算法,是以数据的中心点为中心对数据进行划分,得到初始的簇后,将全部数据分配到对应簇中,并计算新的中心点,对新簇进行分类,在历遍所有中心点后结束分类。K-medoids 聚类最常见的算法之一是围绕中心点的划分(partitioning around medoids, PAM)。利用 R 4.3.2 和 Rstudio 调取程序包 cluster 的 PAM 算法开展聚类分析。

(3) RW 值计算方式

由于医疗机构间存在客观差异,RW 在计算后通常还会经过一定调整,并由临床、管理、经济等领域的专家共同审议评定,以满足其反映各医疗机构诊疗水

平、资源消耗程度以及用于医保报销等方面的需要。目前医疗收入结构中药品耗材占比较大,影响 RW 对医疗服务价值的表达^[11],国家卫生健康委 DRG 质控中心

在应用 RW 开展考核时,先将住院过程中发生的各项明细费用归类为医疗服务费、检查检验费、药品耗材费三大类后计算 RW,具体归类见文章[12],计算公式为:

$$RW = \frac{\text{该 DRG 组例均医疗服务费用} \times 60\% + \text{该 DRG 组例均检查检验费用} \times 20\% + \text{该 DRG 组例均药品耗材费用} \times 20\%}{\text{全部 DRG 组例均费用} \times 60\% + \text{全部 DRG 组例均检查检验费用} \times 20\% + \text{全部 DRG 组例均药品耗材费用} \times 20\%}$$

结果

1. 聚类分析模型结果

由表 2 可知,内科组和外科组 4 个模型最佳聚类数都为 2 类,加入不同的聚类变量,模型解释度存在差异,两治疗类别的最佳聚类均为模型 4。在模型 4 下,内科组变量对聚类解释度为 93.91%,外科组为 91.54%,均高于其他模型。从区分度来看,如图 2 所示,模型 4 较好将内科和外科 DRG 病组聚为两类。

表 2 模型聚类效果

	最佳聚类数	聚类变量解释比例/%	类别 1 组数/组	类别 2 组数/组
内科				
模型 1	2	50.57	225	132
模型 2	2	58.65	214	143
模型 3	2	70.95	182	175
模型 4	2	93.91	234	123
外科				
模型 1	2	63.44	186	81
模型 2	2	74.89	229	38
模型 3	2	82.88	169	98
模型 4	2	91.54	178	89

2. 最优聚类模型指标数据分析

表 3 展示了模型 4 最小数据集各指标特征。从内科组看,类别 1 平均住院日为 6.13 天,例均费用为 9230.92 元,进入重症监护室比例和呼吸机使用比例分别为 1.06% 和 0.16%,明显低于类别 2 (8.28% 和 2.79%)。从外科组看,类别 1 平均住院日为 6.88 天,例均费用为 25420.40 元,进入重症监护室比例和呼吸机使用比例分别为 2.84% 和 1.15%,明显低于类别 2 (33.21% 和 23.53%)。综上分析,将类别 1 设置为常见疾病类,类别 2 设置为疑难疾病类。

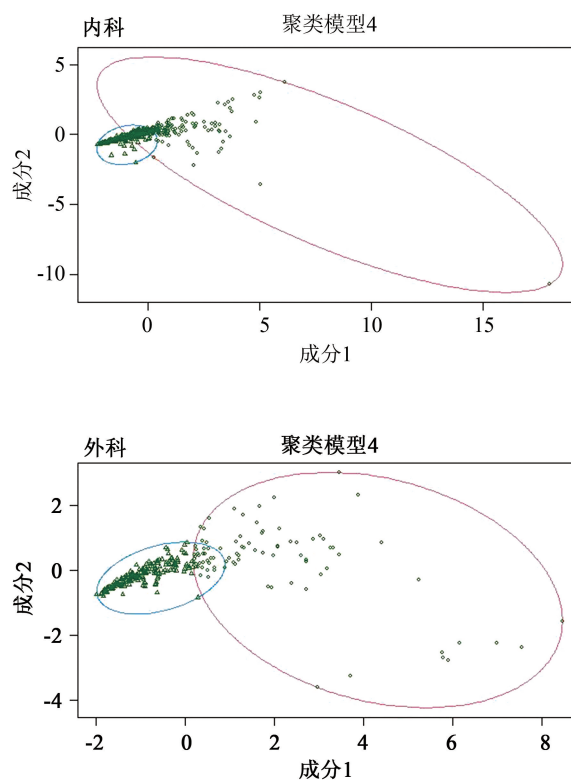


图 2 内科(上)和外科(下)聚类图

3. 基于聚类结果的常见病疑难病 RW 范围

基于内科和外科聚类结果,结合前述先期分组和急症类病组的 RW,获得表 4 和图 3 的结果。内科治疗中,常见疾病类、急症类和疑难疾病类的病组数分别为 239 组、31 组和 154 组。95% 的内科类常见病组 RW 集中在 0.21~0.97 之间,急症类病组 RW 为 0.3~2.54,疑难病病组则集中在 0.97~2.61 之间。95% 的外科类病组常见病病组 RW 集中在 0.26~2.13 之间,急症类病组集中在 0.6~6.06,疑难病病组 RW 则分布在 2.13~10.88 之间。

表 3 模型 4 聚类结果

指标	内科 $\bar{x}(sd)$		外科 $\bar{x}(sd)$	
	常见病	疑难病	常见病	疑难病
平均住院日(天)	6.13(2.16)	12.40(5.10)	6.88(3.05)	15.58(4.38)
例均费用(元)	9230.92(3690.73)	24119.92(10340.58)	25420.40(16831.67)	88680.56(51314.34)
进入重症监护室比例(%)	1.06(1.58)	8.28(10.48)	2.84(3.95)	33.21(26.58)
呼吸机使用比例(%)	0.16(0.58)	2.79(5.45)	1.15(1.75)	23.53(27.85)

表 4 内科和外科各类别病组分布情况

类别	病例数/n (%)	组数	RW($\bar{x}\pm sd$)	RW(0.25%~97.5%)
内科				
常见疾病类	531151(57.82)	239	0.59±0.22	0.21~0.97
急症类	25514(2.78)	31	1.09±0.65	0.3~2.54
疑难疾病类	361998(39.40)	154	1.48±0.68	0.98~2.63
外科				
常见疾病类	1622470(88.22)	203	1.01±0.53	0.26~2.13
急症类	52447(2.85)	20	1.91±1.81	0.6~6.06
疑难疾病类	164279(8.93)	91	4.21±3.06	2.13~10.88

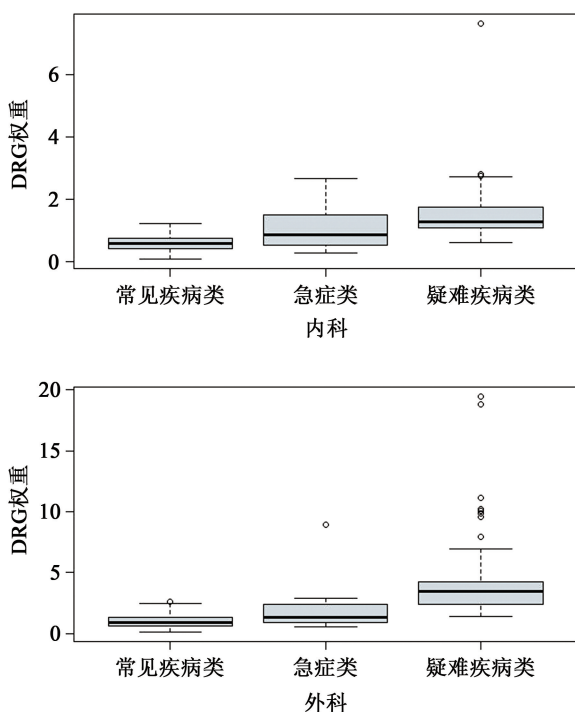


图 3 内科和外科各类别病组 RW 箱式图

讨论

1. RW 范围划分疑难病和常见病契合实际

本研究利用 DRG 分组思想和权重,在疾病诊治难度的内涵概念下,在真实世界数据模型构建的基础上,推算出常见病和疑难病的 RW 值划点,并且截点能较好区分疾病诊治难度和资源消耗差异,在 RW 截点划分下内、外科常见病与疑难病病组比例在 1.5 倍至 2.5 倍之间,符合医疗服务的诊疗特点。外科类常见病和疑难病的 RW 值与现行的临床专科能力评估指标体系体现技术能力的 $RW \geq 2$ (或 3)^[3] 保持一致,印证了本研究基于模型推算出的 RW 值范围契合实际情况,符合研究假设与预期。

2. RW 范围推算模型的优势与可能存在的问题

本研究采用聚类分析方法来区分疾病组诊治难度水平,且在 DRG 分组内涵基础上又结合了反映疾病

难度的治疗方式等相关指标,在方法上具有创新性。同时,聚类分析属于无监督学习,仅是通过算法对数据进行了划分,而划分是否合理且符合实际,在聚类上未能体现,而本研究一是在专家研讨和对现状分析的基础上优先判别了无法纯靠模型获得判别的病组后才进行聚类;二是在聚类结果上,进一步结合 RW,通过分析两类疾病 RW 值分布的连续性 & 聚类性,最终制定了最优截点。该模型充分发挥定性和定量分析方法的

优势。DRG 分组方案需要随着疾病诊断编码升级、临床技术发展不断优化,优化的分组方案在病组的设置上存在一定差异,通过不同分组方案测算出来的常见病和疑难病权重范围可能存在一定差异。

3. 常见病和疑难病的 RW 范围应用和未来研究方向

作为一套医疗管理工具,基于 DRG 计算的相关指标在我国医院管理考核医院中逐渐得到体现和重视。通过真实世界的临床诊疗数据计算得到的权重值对反映疾病在临床过程中的难度具有其发挥“一把尺”测量的优势和科学性,随着党和国家对医疗服务体系完善提出更高的要求、公立医院高质量发展的目标导向、分级诊疗制度的深入实施,如何体现改革实施后医院临床专科能力的提高,如何测量二级和三级医院功能定位落实情况,RW 则能在此方面发挥一定作用,例如:按照分级诊疗制度要求,三级医院要急危重症和疑难复杂疾病,可以通过 RW 划分出的疑难病,来对比分析医院收治该类疾病的变化情况,评判分级诊疗制度落实情况。在临床专科层面,可结合各临床专科的诊疗特点、医疗服务特色,有针对性划定各临床专科高诊治难度的病组范围,尤其是系统评估国家、地方重点建设的临床专科在疑难、危重疾病的能力建设。

此外,通过分析患有常见病和疑难病人群的就医流动情况,反映区域医疗资源供给和需求的匹配状况,找出医疗服务能力薄弱和资源配置不足之处,为优化区域资源布局提供规划依据。

参 考 文 献

- [1] 邓小虹,北京市 DRGs 系统的研究与应用[M]. 北京:北京大学医学出版社,2008:18.
- [2] 国家卫生健康委办公厅. 关于印发公立医院高质量发展评价指标(试行)的通知(国卫办医发[2022]9号)[EB/OL]. (2022-07-31) [2024-07-24]. <http://www.nhc.gov.cn/zyygi/s3594q/202207/3324136282364655baa64f6e84fe0792.shtml>.
- [3] 国家卫生健康委办公厅. 国家临床专科能力评估办法(试行)(国卫办医政函[2024]65号)[EB/OL]. (2024-02-29)[2024-07-24]. https://www.gov.cn/zhengce/zhengceku/202403/content_6939209.htm.
- [4] 方金鸣,陶红兵. 基于博弈理论的 DRG 支付对三级医院疾病诊治难度的影响分析[J]. 中国卫生质量管理,2023,30(7):24-29.
- [5] 段磊,张翔,张研. 按病种分类的疾病诊疗难度测度及应用研究[J]. 中国卫生政策研究,2024,17(2):17-22.
- [6] 郭默宁,刘勇,张乐辉. 医院疾病诊断相关分组(DRG)实施实务[M]. 北京:人民卫生出版社,2023:1.
- [7] 3M. 3M™ All Patient Refined Diagnosis Related Groups (APR DRG) Methodology Overview [EB/OL]. (2023—09) [2025-05-22]. https://www.3m.com/3M/en_US/health-information-systems-us/drive-value-based-care/patient-classification-methodologies/apr-drgs/.
- [8] Elgwairi E, Yang S, Nugent K. Association of the All-Patient Refined Diagnosis-Related Groups Severity of Illness and Risk of Mortality Classification with Outcomes[J]. South Med J. 2021,14(10):668-674.
- [9] Roland M, Dusheiko M, Gravelle H, et al. Follow up of people aged 65 and over with a history of emergency admissions: analysis of routine admission data[J]. BMJ, 2005,330(7486):289-292.
- [10] 北京市卫生健康大数据与政策研究中心(北京市医院管理研究所). 北京地区住院医疗服务绩效评价平台[EB/OL]. [2014-12-17]. <https://wstj.phic.org.cn/apex/f?p=701:19:1782241049303>.
- [11] 卢铭,杜圣普,简伟研,等. 用资源消耗会计方法调整诊断相关组权重[J]. 中华医院管理杂志,2011,27(11):839-842.
- [12] 仇叶龙,郭默宁,陈吟,等. 医院绩效评价视角下的北京地区 DRG 权重算法优化研究[J]. 中华医院管理杂志,2024,40(7):563-567.
- (责任编辑:张悦)
-
- (上接第 11 页)
- [14] Zhao XM. Bayesian Information Criterion (BIC) [M]. Berlin: Springer, 2013.
- [15] 张宏东. EM 算法及其应用[D]. 济南:山东大学,2014.
- [16] 岳佳,王士同. 高斯混合模型聚类中 EM 算法及初始化的研究[J]. 微计算机信息,2006,22(11-3):1-4.
- [17] Beriman L. Random forests[J]. Machine Learning, 2001, 45(1):5-32.
- [18] Fan S, Zhao Z, Yu H, et al. Applying probability calibration to ensemble methods to predict 2-year mortality in patients with DLBCL [J]. BMC Medical Informatics and Decision Making, 2021, 21(1):1-12.
- [19] Vardhana SA, Sauter CS, Matasar MJ, et al. Outcomes of primary refractory diffuse large B-cell lymphoma(DLBCL) treated with salvage chemotherapy and intention to transplant in the rituximab era [J]. British Journal of Haematology, 2017, 176(4):591-599.
- [20] Fernández A, García S, Galar M, et al. Learning from Imbalanced Data Sets [M]. Boston:Springer Nature, 2018.
- [21] Chawla NV, Bowyer KW, Hall LO, et al. SMOTE: Synthetic minority over-sampling technique[J]. Journal of Artificial Intelligence Research, 2002, 16(6):321-357.
- [22] Han H, Wang WY, Mao BH. Borderline-SMOTE: A new over-sampling method in imbalanced data sets learning [J]. Springer-Verlag Berlin Heidelberg, 2005, LNCS3644:878-887.
- [23] Last F, Douzas G, Bacao F. Oversampling for Imbalanced Learning based on K-means and SMOTE[EB/OL]. (2017-12-12)[2021-07-21]. <http://arxiv.org/pdf/1711.00837>.
- [24] Stauffer C, Grimson WEL. Adaptive background mixture models for real-time tracking [J]. IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 1999, 2:246-252.
- [25] 郑建华, 李小敏, 刘双印, 等. 融合级联上采样与下采样的改进随机森林不平衡数据分类算法[J]. 计算机科学, 2021, 48(7):145-154.
- (责任编辑:张悦)