

基于多模态相似度模型的中文药品名称潜在混淆风险筛查与显示名优化^Δ

王 丰^{1*}, 王 琦¹, 范园园^{1,2}, 曾攀科¹, 董海燕^{1#} (1. 西安交通大学第一附属医院药学部, 西安 710061; 2. 西北妇女儿童医院药剂科, 西安 710061)

中图分类号 R952 文献标志码 A 文章编号 1001-0408(2026)19-2570-07
DOI 10.6039/j.issn.1001-0408.2026.19.15



摘要 **目的** 构建中文药品名称多模态相似度模型并设计优化显示名, 比较同一药品目录在不同场景中显示名的潜在混淆风险, 为药品显示名的管理提供量化依据。**方法** 从某三级甲等医院药品字典提取1 221个药品条目, 组成744 810对药对; 基于院内现用显示名(场景一)与标准显示名(场景二)候选混淆药对的混淆特征归纳出“五项规则”, 生成优化显示名(场景三)。构建融合拼音、字形、字符序列与渲染视觉特征的多模态相似度模型, 以同一阈值(总相似度 $S_{total} \geq 0.70$)筛选候选混淆药对, 开展混淆风险分级与转移、混淆特征标注、混淆网络聚类及残余簇分析, 并通过显示形态指标与规则消融考察优化显示名的命名机制, 通过相似度阈值与模型融合权重敏感性分析评价3种场景比较结果的稳健性。**结果** 3种场景候选混淆药对分别为156、269、83对(高风险及以上者分别为109、215、64对); 与场景一相比, 场景三候选混淆药对减少46.8%, 高风险及以上者减少41.3%; 显示形态分析显示, 场景三的平均墨量密度最低(0.057 3)、平均结构槽位数量最多(2.99个); 规则消融分析显示, 禁用厂家特征缩写提示规则后, 候选混淆药对数量增幅最大(增加74对), 而单独禁用结构化命名则净减少9对。残余簇主要涉及同成分不同规格或亚型药品, 以及同厂家、名称主干相似的系列品种。在0.60~0.80、步长0.025的阈值设置及11种不同权重配置(含基准值)下, 候选混淆药对数量均保持“场景三<场景一<场景二”的排序。**结论** 多模态相似度模型可用于中文药品显示名潜在混淆的量化筛查, 场景间的候选混淆药对数量排序在所设置参数范围内能保持稳定。基于“五项规则”的优化显示名能减少该院目录中的候选混淆药对、高风险及以上候选混淆药对的数量, 但其对实际辨识行为和临床用药安全的影响仍需进一步验证。

关键词 药品名称; 多模态相似度模型; 命名优化; 看似药品; 听似药品; 混淆风险; 语言学相似度; 视觉相似度

Potential confusion risk screening and display-name optimization for Chinese drug names based on a multimodal similarity model

WANG Feng¹, WANG Qi¹, FAN Yuanyuan^{1,2}, ZENG Panke¹, DONG Haiyan¹ (1. Dept. of Pharmacy, The First Affiliated Hospital of Xi'an Jiaotong University, Xi'an 710061, China; 2. Dept. of Pharmacy, Northwest Women's and Children's Hospital, Xi'an 710061, China)

ABSTRACT **OBJECTIVE** To construct a multimodal similarity model for Chinese drug names and design optimized display names, compare the potential confusion risk of display names of the same drug catalogue in different scenarios, so as to provide a quantitative basis for the management of drug display names. **METHODS** A total of 1 221 drug entries were extracted from the drug dictionary of a tertiary grade A hospital, forming 744 810 drug pairs. “Five rules” were summarized based on the confusion characteristics of candidate confusable drug pairs under the currently used in-hospital display names (Scenario 1) and standard display names (Scenario 2), to generate optimized display names (Scenario 3). A multimodal similarity model integrating Pinyin, glyph, character sequence and rendered visual features was constructed. The same threshold (total similarity $S_{total} \geq 0.70$) was adopted to screen candidate confusable drug pairs. Confusion risk grading and transition, confusion characteristic labeling, confusion network clustering and residual cluster analysis were carried out. The naming mechanism of optimized display names was investigated through display morphology indicators and rule ablation, and the robustness of the comparison results among the three scenarios was

evaluated through similarity threshold and fusion weight sensitivity analysis. **RESULTS** The numbers of candidate confusable drug pairs in the three scenarios were 156, 269 and 83 respectively, among which the number of pairs at high risk and above was 109, 215 and 64 respectively. Compared with Scenario 1, Scenario 3 reduced the number of candidate confusable drug pairs by 46.8%, and the number of those at

^Δ **基金项目** 国家卫生健康委医院管理研究所医院药学高质量发展研究项目(No.NIHAYSZX2537); 西安交通大学第一附属医院2024年度院基金项目(No.2024-RK-1)

* **第一作者** 主管药师。研究方向: 医院药学、药学信息化。电话: 029-85324174。E-mail: wangfeng7927@126.com

通信作者 主任药师, 博士。研究方向: 医院药学、临床药学。电话: 029-85323508。E-mail: donghy@mail.xjtu.edu.cn

high risk or above decreased by 41.3%. Display morphology analysis showed that Scenario 3 had the lowest average ink density (0.057 3) and the largest average number of structural slots (2.99). Rule ablation analysis showed that after disabling the rule of manufacturer characteristic abbreviation prompts, the number of candidate confusable drug pairs increased the most (+74 pairs), while disabling structured naming alone resulted in a net decrease of 9 pairs. The residual clusters mainly involved drugs with the same active ingredient but different specifications or subtypes, as well as series products from the same manufacturer with similar main name stems. Under the threshold setting of 0.60 to 0.80 with a step size of 0.025 and 11 different weight configurations (including the baseline value), the number of candidate confusable drug pairs always maintained the ranking of Scenario 3 < Scenario 1 < Scenario 2. **CONCLUSIONS** The multimodal similarity model can be used for quantitative screening of potential confusion of Chinese drug display names, and the ranking of the number of candidate confusable drug pairs among scenarios remains stable within the set parameter range. The optimized display names based on the “five rules” can reduce the number of candidate confusable drug pairs, and the number of those at high risk or above in the hospital’s drug catalogue, but their impact on actual identification behavior and clinical medication safety still needs further verification.

KEYWORDS drug names; multimodal similarity model; naming optimization; look-alike medicine; sound-alike medicine; confusion risk; linguistic similarity; visual similarity

2017年世界卫生组织发起“无伤害用药”(Medication without Harm)全球患者安全挑战,将可避免的药物相关伤害列为重点关注问题^[1]。在可避免的药物相关伤害中,用药错误的关键诱因——药品名称混淆,是医院药学管理与信息系统安全设计的核心问题之一^[2]。药品名称是医生检索药品、药师调剂发药的核心依据,也是患者用药交代的关键信息,一旦出现错认,将直接影响医师开方、药师调剂和患者使用等环节。

对于英文外观相似或读音相似的药品(look-alike/sound-alike medicines,即“看似/听似药品”),常见干预措施为差异字母大写法(Tall Man lettering,即将两个易混药名中的差异字母大写或加粗)、字体强化、颜色区分和警示列表等^[3-5]。这些措施主要针对线性字母序列中的局部字符差异^[6],不直接用于筛查混淆药名。中文药品名称兼具语音、形体和结构信息,存在大量同音字、近音字、形近字和部件近似字,同一药品在不同信息系统或显示场景中,可能由通用名、酸根、剂型、规格、商品名和厂家等字段组合成不同的显示名^[7-8]。因此,中文药品名称的混淆往往是语音、字形、结构、界面显示等多种因素共同作用的结果,上述针对英文药品名称的干预措施难以直接套用,亚洲其他发展中国家同样也报告了类似问题^[9]。现有中文药品名称相似度检测多采用编辑距离、语音编码等技术路线^[10-11],或基于英文药品正字相似性开发自动检测算法^[12],但这些方法对中文语境下形、音、结构协同多模态的相似性识别能力不足,同时缺少从显示名规范化角度开展的系统治理研究。

在上述背景下,本研究将“多模态相似度筛查”与“显示名优化”纳入同一分析框架,以某三级甲等综合医院的药品字典为基础,在同一药品目录上构建院内现用显示名、标准显示名与优化显示名3种场景;同时,构建融合拼音、字形、序列及视觉特征的多模态相似度模型,比较3种场景显示名的混淆风险。本研究旨在为医院易混淆药品规范化治理及用药安全防控提供量化依据与实践参考。

1 资料与方法

1.1 资料收集与预处理

从某三级甲等综合医院的医院信息系统(hospital information system, HIS)药品字典中提取药品编码、院内显示名与规格、注册通用名与规格、生产厂家和商品名。经剔除重复条目、统一字符全半角格式、删除多余空格,最终保留具备完整名称与规格信息的药品1 221种。药品目录中任意两个条目进行无序组合称为“药对”,本研究纳入的1 221种药品共组成744 810对药对。

1.2 药品显示名的多模态相似度模型构建

已有研究表明,药名混淆风险由字形与语音多维相似度共同驱动,且多种度量的加权组合优于任意单一度量^[13-14];美国FDA的POCA系统即采用字形与语音通道加权合成的0~1标准化得分^[14-15]。据此,本研究将总相似度设为语言学相似度与视觉相似度的加权组合,构建用于量化中文药品显示名两两相似程度的多模态相似度模型:根据药品显示名的拼音、字形、字符序列和渲染图像的相似度,计算每个药对的总相似度 S_{total} 。对任意药对, S_{total} 由语言学相似度 S_{ling} 与视觉相似度 S_{vis} 两大通道加权构成: $S_{total}=0.6 \cdot S_{ling}+0.4 \cdot S_{vis}$ 。各通道权重为本研究预设(后文的分支通道权重同为预设)。

S_{ling} 由拼音、字形和字符序列3个分支通道加权构成: $S_{ling}=0.4 \cdot S_{pinyin}+0.3 \cdot S_{glyph}+0.3 \cdot S_{sequence}$ 。各分支通道计算逻辑如下——(1)拼音相似度 S_{pinyin} :融合全拼字符串的归一化编辑距离相似度(权重0.25)^[2,16]、声母/韵母/声调匹配得分(权重0.45)、拼音首字母的Jaccard相似系数(权重0.15)^[17]及Soundex式语音编码一致性(权重0.15)^[18]。(2)字形相似度 S_{glyph} :综合汉字四角编码匹配率、偏旁部首一致性、笔画数差异比及结构类型(独体/左右/上下/包围)一致性,整数计分制权重分别为8、6、2、10,并按权重和归一化得到等效权重约为0.31、0.23、0.08、0.38。(3)字符序列相似度 $S_{sequence}$ ^[20]:为模拟阅读扫视中的首因-近因效应,采用边缘位置加权字符序列比对,

对名称首尾字符差异施加更高惩罚权重,权重自两端向中间按二次函数递减(首尾2.0、中间1.0)。为保证无序药对评分的对称性,该通道取正、反两个方向得分的均值,即对任意药对 $A-B$,有 $S_{\text{sequence}}(A,B)=S_{\text{sequence}}(B,A)$ 。

S_{vis} 计算方法:把药品显示名文本渲染为 128×32 像素的灰度图,以灰度值128为阈值进行二值化,通过水平滑动窗口寻找最佳重叠位,以交并比(intersection over union, IoU;指两幅图像的前景像素交集与并集的像素数之比)^[21]度量轮廓重合度,并引入墨量密度差校正。计算公式为 $S_{\text{vis}}=\text{IoU}_{\text{best}}\cdot(1-\lambda\cdot|D_a-D_b|)$,其中, IoU_{best} 为水平滑动搜索中两幅名称二值图像的前景像素集合IoU的最大值; D_a 与 D_b 分别为两幅名称图像的墨量密度,即前景像素占画布总像素的比例; λ 为密度惩罚系数,本研究取0.5。

1.3 基于“五项规则”的优化显示名设计及相似度计算

院内现用显示名(场景一)使用的是HIS界面药品现用显示名及规格,仅有主成分,无剂型等其他结构化信息(例如:氯吡格雷)。标准显示名(场景二)使用的是国家药品注册的标准通用名(例如:硫酸氢氯吡格雷片)。针对“1.1”项下的744 810对药对,本研究采用“1.2”项下构建的多模态相似度模型对场景一和场景二的显示名进行计算,将 $S_{\text{total}}\geq 0.70$ 的药对定义为“候选混淆药对”(阈值设置参照美国FDA药名相似度评审的POCA系统分级标准^[15,22])。结果显示,院内现用显示名(场景一)仅含有主要成分,部分关键区分信息缺失,区分信息常分散在商品名、厂家、规格和装置等字段;标准通用名(场景二)虽然规范,但重复出现的酸根、剂型和结构后缀增加了名称的字符组成方式与排列相似性。

基于上述混淆特征,本研究归纳形成了“五项规则”,即在保留标准通用名及后台法定字段的前提下,将核心成分、酸根、剂型、商品名或厂家、装置或亚型、规格信息拆分为相对独立的语义单元,形成包含5个项目的优化显示名结构——“【商品名】核心成分(酸根)·剂型[标签]”,例如:【波立维】氯吡格雷(硫酸氢)·片。具体规则如下——(1)结构化命名:对显示名主体进行结构重排,通用名主体保留核心成分、酸根和剂型,其中核心成分置于主体位置,酸根以括号标示,剂型统一后置,使各语义成分出现在相对固定的位置。(2)商品名前置:对药品信息中已有的真实商品名使用“【】”括注并前置,用于区分不同厂家的相同产品。(3)厂家特征缩写提示:当药品无商品名时,从生产厂家字段提取具有稳定对应关系的厂家特征缩写,去除厂家名称中的“股份有限公司”“有限责任公司”“有限公司”“集团”“制药厂”“药业”“制药”等通用后缀及末尾行政区划字,保留不超过4个核心汉字,以括号连接在显示名主体之后,用于辅助区分同通用名、同规格但生产厂家不同的品种;已有商品名的品种不再叠加厂家缩写。(4)标签上浮:将儿童装、成人

装、容量或浓度、笔芯、预填充笔及数字或罗马数字亚型等信息从规格自由文本移至主显示名,以方括号标示。(5)剂量分层:对于核心成分、酸根和剂型上完全一致的药对,将可换算为相同计量单位的规格进行比较,剂量统一换算为mg、体积统一换算为mL。计量单位相同的同一分组内最大规格值与最小规格值之比 ≥ 2.0 时,将最小规格标注为[低剂量]、最大规格值标注为[高剂量];分组内存在3个及以上不同规格值时其余规格标注[中剂量]。其中,比值2.0是本研究设定的管理阈值,表示组内规格至少相差1倍,并非临床剂量分界。无法可靠换算或计量单位不一致的规格不参与分层。

根据“1.2”项下构建的多模态相似度模型,计算场景三(优化显示名)的相似度,筛选混淆药对,并与场景一、二的结果相比较。

1.4 3种场景候选混淆药对的潜在混淆风险等级分布与转移分析

按“1.3”项下 $S_{\text{total}}\geq 0.70$ 的候选阈值设定,对3种场景下达到候选阈值的混淆药对进行混淆风险分级: $0.70\leq S_{\text{total}}<0.75$ 为中风险, $0.75\leq S_{\text{total}}<0.90$ 为高风险, $S_{\text{total}}\geq 0.90$ 为极高风险。统计各场景下各风险等级的混淆药对数量及占比,并在不同场景候选集的并集上统计各药对的等级变化,构建场景间转移矩阵。

1.5 3种场景候选混淆药对的多标签混淆特征比较

对3种场景下每个候选混淆药对进行多标签混淆特征标注(同一药对可标注多项特征)。混淆特征共有8类:(1)一品多规混淆;(2)核心成分相似混淆;(3)拼音首字母相似混淆;(4)规格相近混淆;(5)剂型相似混淆;(6)同音/近音强干扰混淆;(7)部分匹配混淆;(8)综合性混淆,即同时标注3类及以上者。统计各场景下各混淆特征的药对数量及占比。上述标签参考易混淆药品识别及药品名称形似、音似研究^[2,13-14],结合本研究药品目录特点制定。

1.6 3种场景的混淆网络聚类及场景三的残余簇分析

在完成潜在混淆风险分级与混淆特征标注的基础上,分别以3种场景的候选混淆药对构建加权无向网络并进行社区聚类,用于识别经显示名优化后仍聚集成簇、难以通过名称手段进一步区分的残余大簇,为货位隔离、条码核对与重点警示等非名称干预措施提供目标。网络中的节点为药品目录条目、边为达到候选阈值的药对(边权为 S_{total})。采用Louvain社区发现算法(由NetworkX实现,分辨率为1.0,随机种子为42)识别连接相对紧密的药品社区(即候选混淆网络中连接紧密的药品子群);若社区内药品两两间存在较多达到候选阈值的相似关系,则提示彼此易混淆。统计社区数量、药品种类、最大社区规模和规模分布;选取场景三中社区规模最大的前5个社区作为代表性残余大簇。

1.7 优化显示名的命名机制验证

1.7.1 显示形态指标计算

计算3种场景下全部显示名的平均墨量密度、名称长度和结构槽位数量,检验优化显示名“关键信息结构化分散以提高可辨性”的设计目标是否实现。其中,墨量密度为显示名渲染至128×32像素二值图像后前景像素占画布总像素的比例,取场景内全部显示名的均值;名称长度按显示名字符数统计,报告均值、中位数与极值;结构槽位数量按显示名中成对括号信息段,如“()”“()”“【】”“[]”“[]”等的个数加1(计入名称主体段)统计,取场景内均值。

1.7.2 规则消融分析

为考察各规则对候选混淆药对数量的边际影响,本研究依次禁用“五项规则”中的任意一项(规则消融),重新生成场景三和优化显示名,按“1.2”项下模型重新计算全部药对的 S_{total} ,统计候选混淆药对、高风险及以上候选混淆药对的数量,并与完整“五项规则”所得结果作对比,以评估各规则在其余规则保留条件下的边际影响。

1.8 多模态相似度模型敏感性分析

1.8.1 相似度阈值敏感性分析

设定 S_{total} 阈值在0.60~0.80区间内,以0.025为步长取值,重新筛选候选混淆药对,检验3种场景候选混淆药对数量排序对相似度阈值选择的敏感性。

1.8.2 模型融合权重敏感性分析

相似度模型采用的多通道融合权重为固定预设值,为考察该取值对识别结果稳定性的影响,本研究开展了融合权重敏感性分析。测试前,先记录每个药对在4个相似度通道(即拼音、字形、字符序列3个语言学相似度分支通道及视觉相似度通道,分别对应 S_{pinyin} 、 S_{glyph} 、 $S_{sequence}$ 与 S_{vis})下的原始未取整相似度评分,据此计算 S_{total} 。然后,调整权重参数后重新测算:先调整语言学相似度通道与视觉相似度通道的融合权重,按0.50/0.50、0.55/0.45、0.60/0.40(基线)、0.65/0.35、0.70/0.30共5档梯度取值;再调整语言学相似度通道内部的拼音、字形、字符序列权重,以0.40/0.30/0.30为基准,单项权重增减0.10后,剩余2项权重按比例归一化调整。共设置11组差异化权重组合,逐一统计每组权重组合下模型识别出的候选混淆药对数量($S_{total} \geq 0.70$)和高风险及以上者($S_{total} \geq 0.75$)。

1.9 统计学方法

采用描述性统计报告各场景候选混淆药对数量、潜在混淆风险等级构成与混淆特征标注结果。

2 结果

2.1 3种场景的候选混淆药对及其主要指标

在场景一、二、三中(均纳入1 221种药品及组成的744 810对无序药对),候选混淆药对数量分别为156、269、83对,高风险及以上候选混淆药对数量分别为109、

215、64对。与院内现用显示名场景(场景一)相比,优化显示名场景(场景三)的候选混淆药对减少46.8%,高风险及以上候选混淆药对减少41.3%;标准显示名场景(场景二)的候选混淆药对、高风险及以上候选混淆药对的数量均高于院内现用显示名场景。

2.2 3种场景候选混淆药对的潜在混淆风险等级分布与转移

3种场景候选混淆药对的潜在混淆风险等级分布见表1。场景一、二、三的中风险及高风险候选混淆药对占比分别为60.3%(94/156)、52.4%(141/269)和83.1%(69/83),极高风险候选混淆药对占比分别为39.7%(62/156)、47.6%(128/269)和16.9%(14/83)。与场景一相比,场景三的极高风险候选混淆药对由62对(39.7%)降至14对(16.9%);中风险及高风险占比合计由60.3%升至83.1%,该占比上升是极高风险候选混淆药对大量退出后风险构成变化的结果,并非风险整体上移。进一步在场景一与场景三候选混淆药对的并集(186对)上构建风险等级转移矩阵(图1A)与风险等级流动图(图1B)。结果显示,场景三的潜在混淆风险相对于场景一呈系统性降级:场景一原有的94对中风险及高风险候选混淆药对中,84对(89.4%)在场景三未达候选阈值;在62对极高风险候选混淆药对中,仅13对(21.0%)在场景三仍为极高风险。两场景下均达到候选阈值且分级一致的药对仅18对(占并集的9.7%),其中极高风险者13对、高风险者3对、中风险者2对,提示分级一致的药对集中于显示名高度近似的极高风险药对。

表1 3种场景候选混淆药对的潜在混淆风险等级分布 [药对数(占比/%)]

潜在混淆风险等级	场景一	场景二	场景三
中风险($0.70 \leq S_{total} < 0.75$)	47(30.1)	54(20.1)	19(22.9)
高风险($0.75 \leq S_{total} < 0.90$)	47(30.1)	87(32.3)	50(60.2)
极高风险($S_{total} \geq 0.90$)	62(39.7)	128(47.6)	14(16.9)
合计	156(100)	269(100)	83(100)

2.3 3种场景候选混淆药对的混淆特征比较

3种场景候选混淆药对的8类混淆特征标注结果见表2。与场景一相比,场景三的拼音首字母相似混淆、部分匹配混淆特征的药对数量及占比均下降;一品多规混淆、核心成分相似混淆、规格相近混淆、剂型相似混淆和综合性混淆特征的占比因分母减小(156对减少至83对)而升高,但绝对数量在下降;同音/近音强干扰混淆特征在场景一、三均未出现,在场景二出现6对。需要说明的是,由于同一药对可能标注多项混淆特征,各项特征的占比之和超过100%。

2.4 3种场景的混淆网络聚类及场景三的残余大簇

混淆网络聚类分析显示,3种场景的药品社区数量分别为90、120、60个,涉及药品分别为207、303、132种,最大社区的规模(药品数量)分别为7、9、5种,完整社区规模分布见表3。以场景三规模最大的前5个社区作为




图1 场景一与场景三候选混淆药对风险等级转移矩阵及风险等级流动图

表2 3种场景候选混淆药对的混淆特征比较[药对数(占比/%)]

混淆特征	场景一	场景二	场景三
一品多规混淆	40(25.6)	77(28.6)	24(28.9)
核心成分相似混淆	97(62.2)	173(64.3)	64(77.1)
拼音首字母相似混淆	80(51.3)	141(52.4)	34(41.0)
规格相近混淆	48(30.8)	106(39.4)	26(31.3)
剂型相似混淆	121(77.6)	262(97.4)	81(97.6)
同音/近音干扰混淆	0(0)	6(2.2)	0(0)
部分匹配混淆	33(21.2)	37(13.8)	15(18.1)
综合性混淆	86(55.1)	172(63.9)	64(77.1)

代表性残余大簇:最大簇为粉尘螨滴剂的5个规格(蛋白质量浓度分别为1、10、100、333、1 000 μg/mL),名称主干完全相同,剂量分层标注后仍无法分开;其余4个簇各含3种药品,分别为门冬胰岛素30/50笔芯簇(诺和锐50笔芯、锐舒霖30笔芯、锐舒霖50笔芯)、司来帕格片不同规格簇(0.2、0.6、0.8 mg)、同厂家金嗓系列胶囊簇(金嗓清音、金嗓利咽、金嗓开音,生产厂家均为西安碑林)和同厂家地黄丸类簇(杞菊地黄、桂附地黄、六味地黄丸,生产厂家均为兰州佛慈)。以上残余大簇主要包括同成分、不同规格或亚型的药品,以及同厂家、名称主干相似的系列品种,显示名优化对其区分能力有限。

2.5 优化显示名机制分析结果

2.5.1 显示形态指标分析结果

3种场景显示名的平均墨量密度分别为0.149 2、0.170 8、0.057 3,平均名称长度分别为9.51、7.30、18.13

表3 3种场景的Louvain社区发现法聚类结果

场景	社区数量/个	涉及药品数量/种	最大社区规模/种	社区规模(社区数量)
场景一	90	207	7	2种(72个)、3种(14个)、4种(1个)、5种(2个)、7种(1个)
场景二	120	303	9	2种(88个)、3种(16个)、4种(7个)、5种(6个)、6种(2个)、9种(1个)
场景三	60	132	5	2种(50个)、3种(9个)、5种(1个)

字,平均结构槽位数量分别为2.05、1.03、2.99个。由此可知,优化显示名虽然更长,但渲染后墨量密度最低、留白更多,关键区分信息分散到固定槽位,与设计目标一致。

2.5.2 规则消融分析结果

以完整“五项规则”的场景三结果为基准,依次禁用“五项规则”中的任意一项后重新评分。结果(表4)显示,禁用规则3(厂家特征缩写提示)后候选混淆药对数量增幅最大(增加74对),其后依次为禁用规则2(商品名前置)后增加29对、禁用规则4(标签上浮)后增加16对、禁用规则5(剂量分层)后增加7对。“五项规则”全部禁用时(等同于场景二标准显示名),候选混淆药对为269对,表明候选混淆药对的减少主要由规则2~5提供的区分信息贡献。值得注意的是,单独禁用规则1(结构化命名)后,候选混淆药对净减少9对,为退出与新增药对双向变动的净结果(退出药对以中风险层级为主,同成分与跨成分药对并存),提示结构化命名的统一格式会整体增加显示名间的相似度,但规则1为规则2~5的区分信息提供了统一的承载槽位,因此“五项规则”须作为整体使用。

表4 场景三优化显示名的优化规则消融结果(对)

禁用规则	候选混淆药对数量	候选混淆药对数量差值	高风险及以上候选混淆药对数量	高风险及以上候选混淆药对数量差值
未禁用(完整五项规则)	83	0(基准)	64	0(基准)
全部禁用(等同于场景二)	269	+186	215	+151
禁用规则1(结构化命名)	74	-9	61	-3
禁用规则2(商品名前置)	112	+29	77	+13
禁用规则3(厂家特征缩写提示)	157	+74	118	+54
禁用规则4(标签上浮)	99	+16	71	+7
禁用规则5(剂量分层)	90	+7	66	+2

2.6 多模态相似度模型敏感性分析结果

2.6.1 相似度阈值敏感性分析结果

S_{total} 筛选阈值在0.60~0.80范围内且以0.025为步长变化时,3种场景候选混淆药对数量排序始终为场景三<场景一<场景二。阈值为0.60、0.70、0.80时,场景一、二、三候选混淆药对数量分别为340、682、161对,156、269、83对和88、172、52对。这表明场景间该候选数量排序在所设置阈值范围内能保持稳定。

2.6.2 模型融合权重敏感性分析结果

融合权重敏感性分析结果见表5。在11组权重配置(含基准值)下,3种场景的候选混淆药对数量分别为151~161、264~277、80~85对(基准值分别为156、269、83对),高风险及以上者分别为107~114、213~217、61~65对(基准值分别为109、215、64对)。相对于各场

景自身基准值,候选混淆药对数量的最大绝对差值为8对,出现在字形分支权重增加0.10时的场景二,候选数量由269对增至277对,增幅为3.0%;相对变化幅度最大为3.6%,出现在字形分支权重减少0.10时的场景三,候选数量由83对降至80对。全部11种权重配置下,候选混淆药对数量和高风险及以上者均保持“场景三<场景一<场景二”的排序,表明3种场景结果排序在本研究考察的权重范围内保持稳定。

表5 模型融合权重敏感性分析结果

权重配置	权重(语言学/视觉)	分支权重(拼音/字形/字符序列)	候选混淆药对数量 (场景一/二/三)/对	高风险及以上候选混淆药 对数量(场景一/二/三)/对
基准配置	0.60/0.40	0.40/0.30/0.30	156/269/83	109/215/64
融合层调整	0.50/0.50	0.40/0.30/0.30	157/264/81	111/213/63
融合层调整	0.55/0.45	0.40/0.30/0.30	156/268/83	111/213/64
融合层调整	0.65/0.35	0.40/0.30/0.30	160/272/84	109/217/64
融合层调整	0.70/0.30	0.40/0.30/0.30	161/276/84	109/216/63
拼音分支-0.10	0.60/0.40	0.30/0.35/0.35	154/269/83	110/213/64
拼音分支+0.10	0.60/0.40	0.50/0.25/0.25	155/271/82	110/216/64
字形分支-0.10	0.60/0.40	0.457 1/0.200 0/0.342 9	153/267/80	108/213/61
字形分支+0.10	0.60/0.40	0.342 9/0.400 0/0.257 1	159/277/85	114/214/65
字符序列分支-0.10	0.60/0.40	0.45 71/0.342 9/0.200 0	157/275/84	114/215/65
字符序列分支+0.10	0.60/0.40	0.342 9/0.257 1/0.400 0	151/269/82	107/213/62

3 讨论

3.1 3种场景显示名的目录内比较

本研究在某三级甲等医院同一药品目录上比较了3种场景的药品显示名混淆情况。院内现用显示名、标准显示名和优化显示名场景的候选混淆药对分别为156、269、83对,高风险及以上者分别为109、215、64对。与院内现用显示名相比,优化显示名场景的候选混淆药对总数减少46.8%,高风险及以上者减少41.3%,极高风险者由62对降至14对。场景二的候选混淆药对、高风险及以上候选混淆药对的数量均高于场景一,提示在核心成分名称基础上补入酸根、剂型等语块后,名称的字符组成和长度更趋一致,标准显示名易混淆风险增加。

风险转移分析显示,场景一的中风险及高风险候选混淆药对中约有89%在场景三未达候选阈值,两场景分级一致的比例仅为9.7%,场景三中风险及高风险候选混淆药对占比上升,是极高风险者减少带来更多带来的构成变化,并非风险整体上移。从显示形态看,优化显示名的平均墨量密度最低,名称更长但留白更多,关键区分信息落入固定槽位,与结构化分散的设计目标一致。混淆特征方面,与场景一相比,场景三的一品多规混淆、拼音首字母相似混淆和部分匹配混淆特征标签数量下降,剂型相似混淆特征标签仍覆盖97.6%的候选混淆药对。上述结果来自药品名称和结构化属性的仿真研究,反映的是名称层面潜在混淆风险的变化,不能直接推断真实临床差错率下降。

混淆网络聚类分析方面,3种场景的社区数量分别为90、120、60个,最大社区规模分别为7、9、5种。场景三规格最大的社区(最大簇)为粉尘螨滴剂的5个规格,

其名称主干完全相同,剂量分层标注后仍无法分开;其余残余大簇放包括门冬胰岛素30/50笔芯簇(3种)、司来帕格片不同规格簇(3种)、同厂家金嗓系列胶囊簇(3种)和同厂家地黄丸类簇(3种)。其主要包括同成分、不同规格或亚型的药品,以及同厂家、名称主干相似的品种。对此类药品,名称显示调整之外仍需配合货位隔离、条码核对与重点警示。

3.2 多模态相似度模型的筛查特点与应用定位

中文药品名称同时携带语音、字形、结构和显示形态信息,仅靠字符增删替换类度量难以覆盖全部混淆路径^[14-16]。本研究将拼音、字形、字符序列和渲染视觉特征纳入同一评分框架,并采用相同目录、相同模型和相同阈值的对照设计,使场景间差异仅由显示名不同引起。融合权重敏感性分析显示,在11种不同权重配置(含基准值)下,3种场景候选混淆药对数量排序均为场景三<场景一<场景二,候选混淆药对数量相对于各场景自身基准值的变化幅度均不超过3.6%。当 S_{total} 筛选阈值在0.60~0.80范围内、以0.025为步长变化时,上述排序同样保持不变,证明了3种场景结果比较在所设置参数范围内的稳健性。规则消融分析结果显示,禁用规则3(厂家特征缩写提示)后候选混淆药对数量增幅最大,禁用规则2、4、5后增幅次之,而单独禁用规则1(结构化命名)后候选混淆药对反而减少9对,提示统一结构若不与区分信息配合,会增加跨成分药对的序列相似度,故“五项规则”须组合使用。

从应用角度看,优化显示名适合作为标准通用名之外的前端安全显示层,并不是替代药品法定名称,系统后台和非人机交互场景仍应完整显示标准通用名、标准规格,以保证数据的规范性和可追溯性;前端交互显示则可按使用场景组合显示商品名、装置、亚型和剂量层级等信息。新增药品可在进入院内药品目录前与现有品种进行全量相似度比对,由药学部门复核高风险候选混淆药对。对存量药品,可优先处理高警示药品、治疗窗较窄的药品、高频使用品种及残余大簇。显示名调整还应与检索别名、界面高亮、货位管理和条码核对等措施配合^[23-24],避免将用药安全责任集中于单一显示策略。

3.3 本研究的局限性

本研究数据来源于单一医疗机构,药品目录结构和院内命名习惯具有机构特异性;因缺乏真实差错事件和外部专家标注的“金标准”,所得分析结果反映的是名称层面的潜在混淆风险筛查结果,不能等同于临床差错发生率;药品使用频次、治疗窗、给药途径和差错后果严重程度尚未纳入风险评价;聚类结果受候选阈值、边权和Louvain算法参数的影响,社区数量变化需结合社区规模分布解释;剂量跨度2.0倍为本研究设置的目录管理阈值,其适用性需结合具体药品和临床场景验证。后续

将进一步开展多中心外部验证,并在模拟界面中开展药品辨识实验,记录反应时间与眼动指标,以评价不同显示名规则对实际辨识行为的影响。

综上所述,本研究构建了融合拼音、字形、字符序列与渲染视觉特征的多模态相似度模型,用于中文药品显示名潜在混淆药对的量化筛查。在所设置的阈值和权重下,3种场景候选混淆药对数量的排序保持一致;基于“五项规则”设计的优化显示名在本院药品目录中减少了候选混淆药对和高风险及以上候选混淆药对的数量。上述结果为显示名优化提供了模型层面的量化依据,其对实际辨识行为和临床用药安全的影响仍需进一步验证。

利益冲突 本文所有作者声明不存在利益冲突

参考文献

- [1] Donaldson L J, Kelley E T, Dhingra-Kumar N, et al. Medication without harm: WHO's third global patient safety challenge[J]. *Lancet*, 2017, 389(10080): 1680-1681.
- [2] 陈杨, 淡重辉, 何瑶, 等. 基于莱文斯坦距离的易混淆药品目录自动生成算法及软件实现[J]. *中国药房*, 2024, 35(15): 1899-1904.
- [3] Simas da Rocha B, Garcia Moraes C, Miyake Okumura L, et al. Interventions to reduce problems related to the readability and comprehensibility of drug packages and labels: a systematic review[J]. *J Patient Saf*, 2021, 17(8): e1494-e1506.
- [4] Bryan R, Aronson J K, Williams A J, et al. A systematic literature review of LASA error interventions[J]. *Br J Clin Pharmacol*, 2021, 87(2): 336-351.
- [5] Chen C Y, Chen Y L, Scholl J, et al. Ability of machine-learning based clinical decision support system to reduce alert fatigue, wrong-drug errors, and alert users about look alike, sound alike medication[J]. *Comput Methods Programs Biomed*, 2024, 243: 107869.
- [6] Larmen -Beld K H M, Alting E K, Taxis K. A systematic literature review on strategies to avoid look-alike errors of labels[J]. *Eur J Clin Pharmacol*, 2018, 74(8): 985-993.
- [7] 周怡, 尤启冬. 中国化学药品通用名称的构建及监管[J]. *药学与临床研究*, 2025, 33(1): 1-3.
- [8] 陈家润, 沈波, 沈小莉, 等. 广东省医疗机构制剂化学药品通用名称命名存在问题及对策[J]. *中国药事*, 2022, 36(10): 1117-1121.
- [9] Neelakantan M, Sharma P, Kulkarni A. Look-alike, sound-alike (LASA) drugs in India[J]. *Lancet Reg Health South-east Asia*, 2024, 26: 100425.
- [10] Lv L S, Yao Y, Zhang M W, et al. Impact of implementing the lean management on internal errors at an outpatient hospital pharmacy in China[J]. *Patient Prefer Adherence*, 2025, 19: 139-147.
- [11] Ting H W, Chung S L, Chen C F, et al. A drug identification model developed using deep learning technologies: experience of a medical center in Taiwan[J]. *BMC Health Serv Res*, 2020, 20(1): 312.
- [12] Rash-Foanio C, Galanter W, Bryson M, et al. Automated detection of look-alike/sound-alike medication errors[J]. *Am J Health Syst Pharm*, 2017, 74(7): 521-527.
- [13] Lambert B L, Lin S J, Chang K Y, et al. Similarity as a risk factor in drug-name confusion errors: the look-alike (orthographic) and sound-alike (phonetic) model[J]. *Med Care*, 1999, 37(12): 1214-1225.
- [14] Kondrak G, Dorr B. Automatic identification of confusable drug names[J]. *Artif Intell Med*, 2006, 36(1): 29-42.
- [15] Emmerton L, Curtain C, Swaminathan G, et al. Development and exploratory analysis of software to detect look-alike, sound-alike medicine names[J]. *Int J Med Inform*, 2020, 137: 104119.
- [16] Levenshtein V I. Binary codes capable of correcting deletions, insertions, and reversals[J]. *Sov Phys Dokl*, 1966, 10(8): 707-710.
- [17] Jaccard P.  tude comparative de la distribution florale dans une portion des Alpes et du Jura[J]. *Bull Soc Vaudoise Sci Nat*, 1901, 37: 547-579.
- [18] Zobel J, Dart P. Phonetic string matching: lessons from information retrieval[C]//Frei H P, Harman D, Sch uble P, et al. Proceedings of the 19th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 1996: 166-172.
- [19] Qiao Z H, Zhou H Q, Liu Y M, et al. DISC: plug-and-play decoding intervention with similarity of characters for Chinese spelling check[C]//Che W X, Nabende J, Shutova E, et al. Proceedings of the 63rd Annual Meeting of the Association for Computational Linguistics: Volume 1: Long Papers. Vienna: Association for Computational Linguistics, 2025: 28312-28324.
- [20] Murdock B B. The serial position effect of free recall[J]. *J Exp Psychol*, 1962, 64(5): 482-488.
- [21] Rezatofighi H, Tsoi N, Gwak J Y, et al. Generalized intersection over union: a metric and a loss for bounding box regression[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2019: 658-666.
- [22] US Food and Drug Administration. Best practices in developing proprietary names for human prescription drug products: guidance for industry[R]. Silver Spring (MD): US Department of Health and Human Services, Food and Drug Administration, 2020.
- [23] 王琦, 曾攀科, 宋昊昕, 等. 基于数智驱动的中药房调剂取药流程优化研究[J]. *中国药房*, 2026, 37(5): 660-664.
- [24] 王琦, 曾攀科, 冯靖婷, 等. 基于数智追溯技术重构门诊药房药品库间转移验收流程[J]. *医药导报*, 2026, 45(2): 325-330.

(收稿日期: 2026-05-19 修回日期: 2026-09-20)

(本文责编: 段思怡)