

基于非负矩阵分解的药性与功效关联规则研究

游 聪¹ 钟远明¹ 胥 微¹ 卢 敏¹

YOU Cong ZHONG Yuanming XU Wei LU Min

摘 要

中医药物属性具有多维度和稀疏性特点,为更高效地挖掘药性与功效之间的关联规则,提出了一种基于非负矩阵分解(NMF)与FP-growth算法的组合方法。通过引入信息保留率,使用交叉验证法确定NMF降维的最小维度数,之后对原始稀疏矩阵进行投影和降维,以减少数据量,并应用多维FP-growth算法进行关联分析,从而获得中药药物属性的多维关联规则。实验结果表明,降维后的多维关联规则能够有效挖掘出治疗冠心病药物的药性与功效之间的多维关联,并且在计算效率上显著优于未降维的方法。

关键词

非负矩阵分解; FP-Growth 算法; 多维关联规则; 降维; 冠心病; 药性与功效

doi: 10.3969/j.issn.1672-9528.2024.11.001

0 引言

冠心病是由冠状动脉粥样硬化引起管腔狭窄,导致心肌缺血的心脏病,是全球范围内致死率第一的疾病^[1]。全国冠心病发病率和致死率逐年上升,已成为重大公共卫生问题之一^[2]。中医药在预防、治疗冠心病方面发挥了重要作用,传统治疗冠心病的组方,如血府逐瘀汤,以活血化瘀方法控制冠心病症状,通过抗血小板聚集、抗氧化等方面对冠心病进行全面干预^[3]。

为充分发挥传统中医药在冠心病治疗中的作用,探索经典治疗冠心病组方的用药规律和药性与功效已成为关键课题。历代中医书籍均强调“性效结合”与“药性互参”,中医在临床诊断患者症状时,需要综合考虑药物的药性与功效才能开出合适的药方对症治疗。挖掘组方中药物的药性与功效属性间的潜在关系,有助于分析治疗冠心病组方的组成结构,从而为个性化治疗提供数据支持。

目前关于中医药组方药物中药性与功效关系的研究方法主要有频数分析、关联分析^[4]和机器学习^[5]等。频数分析是一种基本的统计方法,常用于统计药物中各个药性和功效属性出现的频数,以及不同药性中功效的分布情况,在此基础上可进一步对高频属性进行关联分析或聚类分析,从而得出不同属性间的潜在关系。如张静雅等人^[6]利用频数分析对甘味药的药性表达与药物配伍中的应用进行研究并探讨。关联分析通过挖掘数据库中不同药性组合或药性组

合与功效之间的关联关系,为研究常用药物配伍提供数据支持;如Apriori算法和FP-growth算法是关联分析中的经典算法,金锐等人^[7]使用Apriori算法对《神农本草经》药物的气-味-效数据进行分析,揭示中药气-味-效之间的复杂关系,推动对四气五味功效关系机制的研究。为进一步提高挖掘效率,HAN等人^[8]提出的FP-growth算法通过条件模式树递归挖掘频繁项集,减少对数据库的扫描次数以提高挖掘效率,赵琦^[9]对数据库中的多维、多值数据进行合理剪枝排序方式构建FP-tree结构,可用于中医临床数据中多维度属性之间的关联分析。丁弋美等人^[10]使用疗效加权的FP-growth算法对干燥综合症的用药规律进行研究。随着中医药领域数据化的不断完善,为应对中药复杂的数据结构与物质基础,机器学习这种处理大型、复杂和不同数据的能力正是中医药现代化研究所需要的^[11]。邓乐等人^[12]研究了一种基于多层前馈神经网络的药性量化模型,利用中药学中的474味中药的药物-功效数据对模型进行训练,训练得到的BP药向量更能反映药物的属性特征,并且药向量在欧几里得距离方面能够体现中药功效差异。郭永坤等人^[13]使用神经网络构建中的中药方剂功效预测模型,利用神经网络的模糊性与拟合性,挖掘出中药组方药性与功效的联系。

面对中医药物复杂的数据结构与稀疏的药性-功效数据,本文利用非负矩阵分解(NMF)算法降低数据的维度,使用交叉验证法在保留中药潜在数据结构的同时得到最小降维数,采用FP-growth关联算法对四气-五味-归经药性与功效维度进行关联分析。结果显示,该方法能够有效挖掘出中医药治疗冠心病组方药物的药性组合之间的关系与药性组合与功效之间的关系,且挖掘效率显著高于不使用NMF算法的FP-growth算法。

1. 江西理工大学理学院 江西赣州 341000

[基金项目] 中国工程院战略研究与咨询“面向中医药的人工智能发展战略研究”(2023-HY-10)

1 非负矩阵分解 (NMF) 算法

NMF 是一种矩阵分解算法^[14], 广泛应用于数据挖掘、图像处理、文本分析等领域, 常用于降维、特征提取和数据表示等任务, NMF 能够在保留数据结构和信息的同时, 减少计算复杂度。中医药物的药性与功效数据呈现高维性、稀疏性等特点, 为提高药性与功效的挖掘效率, 使用 NMF 算法将高维稀疏数据投影到低维空间从而减少计算复杂度。

在中医药物属性分析中, 由于四气、五味、归经和功效维度中每个维度的取值较少, 导致药物属性矩阵通常呈现高维稀疏的特点。因此, 使用非负矩阵分解 (NMF) 的降维方法对每个维度进行降维, 可提高药物属性的关联分析效率。

1.1 非负矩阵分解算法

非负矩阵分解 (non-negative matrix factorization, NMF) 是一种在数据分析和降维中常用的方法, 它通过将一个给定的高维非负矩阵 V 分解为两个更小的非负矩阵 W 和 H 的乘积, 实现数据降维和特征提取。

给定一个非负矩阵 $V \in \mathbb{R}^{m \times n}$, NMF 试图找到两个矩阵 $W \in \mathbb{R}^{m \times k}$ 和 $H \in \mathbb{R}^{k \times n}$, 使得:

$$V \approx WH \quad (1)$$

NMF 可以被形式化为一个优化问题, 目标是最小化原始矩阵 V 与乘积 WH 之间的重构误差 $L(W, H)$:

$$L(W, H) = \min_{W, H \geq 0} \|V - WH\|_F^2 \quad (2)$$

$$H_{ij} \leftarrow H_{ij} \times \frac{(W^T V)_{ij}}{(W^T W H)_{ij}} \quad (3)$$

$$W_{ij} \leftarrow W_{ij} \times \frac{(V H^T)_{ij}}{(W H H^T)_{ij}} \quad (4)$$

式中: V 是原始数据矩阵, W 是基矩阵, H 是系数矩阵。矩阵 W 和 H 的更新过程通常采用乘法更新规则, 这是一种基于梯度下降的优化方法。通过乘法更新规则, 矩阵 W 和 H 的每个元素都会进行逐步调整, 使得误差 (即 $V - WH$) 逐渐减小, 最终使 WH 能够更近似原始矩阵 V 。

1.2 交叉验证法选择最小维度数

在 NMF 降维中, 选择合适的降维后维度数 k 是至关重要的。为了分析中医药治疗冠心病的药物属性数据中的潜在知识与规律, 本文引入了信息保存率 δ 作为评估标准, 采用了基于重构误差和相对误差的交叉验证方法来选择每个维度的最小维度数 k , 在降低数据维度的同时, 保持较好的数据保真度。

对于给定的初始维度数 k , NMF 分解后可以计算出重构矩阵 $\hat{V} = WH$ 。接着计算重构误差, 定义为原始矩阵与重构矩阵之间的均方误差 (mean squared error, MSE):

$$E(k) = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n (v_{ij} - \hat{v}_{ij})^2 \quad (5)$$

为了衡量不同维度数 k 下的相对误差, 首先计算初始维度数 (通常为 $k=1$) 时的重构误差 $E(1)$, 然后定义信息保存率 $\delta(k)$ 为:

$$\delta(k) = 1 - \frac{E(k)}{E(1)} \quad (6)$$

本文通过信息保存率 δ 选择满足以下条件的最小维度数 k^* 作为每个维度的最小维度数:

$$k^* = \min \{k | \delta(k) \geq \delta\} \quad (7)$$

即找到第一个使信息保存率大于或等于 δ 的维度 k , 这种方法确保在保证较低的重构误差与较高信息保存率的同时, 尽量减少数据维度, 从而优化后续的关联规则分析。

2 FP-growth 算法

中药属性有四气、五味、归经和功效 4 个维度, 需要对这 4 个维度进行维度间的关联分析以获得准确的药性与功效关系。基于药物属性因素的分析, 构建药物多维属性架构并利用关联算法分析各个维度间的关联关系^[15], 图 1 为药物属性关联分析架构。




图 1 药物多维属性分层架构

FP-growth 算法是一种用于找出大量数据中潜在关系的关联算法, 该算法可用于挖掘中药数据多个特征之间的关联关系。使用 FP-growth 算法对中药信息数据库的药物、药性和功效的进行统计分析和关联分析。由于药物属性的多维、多值特点, 本文使用了 NMF 降维方法对其进行降维, 降维后通过比较每个维度的分量矩阵与其平均值, 将降维后的数据转换为布尔型数据。转换后的布尔型数据表示某一维度是否在某一属性上具有较高贡献:

$$R_{ij} = \begin{cases} 1, & \text{if } H_{ij} \geq \text{mean}(H_{ij}) \\ 0, & \text{others} \end{cases} \quad (8)$$

式中： R_{ij} 表示降维后的布尔型数据矩阵， H_{ij} 为 NMF 分解得到的系数矩阵， $\text{mean}(H_{ij})$ 为该矩阵的平均值。通过这种转换，数据被二值化，使得后续的频繁项集挖掘更加高效。对降维后的布尔型数据矩阵进行频繁项集挖掘和关联规则提取^[16]，规则形式为 $X \rightarrow Y$ ，其中 X 和 Y 分别表示前件和后件。关联规则通过支持度和置信度等指标来衡量规则的重要性，并设置提升度大于 1 的规则为强关联规则^[17]。

$$\text{support}(X \Rightarrow Y) = \frac{|X \cup Y|}{|D|} = P(X \cup Y) \quad (9)$$

$$\text{confidence}(X \Rightarrow Y) = \frac{\text{support}(X \cup Y)}{\text{support}(X)} = P(Y|X) \quad (10)$$

$$\text{lift}(X \Rightarrow Y) = \frac{\text{confidence}(X \Rightarrow Y)}{\text{support}(Y)} = \frac{P(Y|X)}{P(Y)} \quad (11)$$

生成的多维关联规则是基于降维后的数据，其表达的特征并不直观，为了确保规则的可读性与解释性，必须将降维后的规则映射回原始特征空间。通过这一映射过程，能够恢复规则与原始数据特征的对应关系，使得规则更易理解，并具备实际应用价值。对于给定的规则，映射过程为：

$$A_{\text{original}} = f(A, H_{ij}, \text{mean}(H_{ij})) \quad (12)$$

式中：映射函数 $f(\cdot)$ 根据贡献度阈值将降维后的维度映射回原始特征。

NMF-FP-growth 算法步骤如下：

- (1) 数据降维：通过 NMF 算法获取药物各个属性的低维数据矩阵。
- (2) 构建 FP 树：应用 FP-growth 算法，扫描两次药物属性数据库，构建频繁模式树（FP 树）来压缩数据库中的频繁项集信息。
- (3) 挖掘频繁项集：首先从 FP 树中提取与每个项相关的条件模式基，然后构建相应的条件 FP 树。重复这两个步骤，直至条件 FP 树中只剩下一个元素项为止，最终生成完整的频繁项集。
- (4) 筛选与映射：对生成的关联规则进行筛选，并将降维后的数据映射回原始药物属性数据中，以确保规则的可解释性和可读性。

3 NMF 算法降维与 FP-growth 算法关联分析

3.1 数据集

本文以冠心病为例，研究中医药治疗冠心病组方药物的药性与功效的关联规则，中药组方数据来源于《国家级名老中医冠心病验案良方》^[18]《当代名中医诊治冠心病临证经验集要》^[19]《冠心病良方大全》^[20] 中的完整医案组方或经验方

剂，共收集组方 389 首，涉及药物 260 味。并以 2020 版《中华人民共和国药典》^[21] 为标准对中药名称、药性、功效等信息进行规范处理，对异名同类的药物统一名称，如“白僵蚕”规范为“僵蚕”等。

3.2 最小维度数

本文采用交叉验证方法选择最小降维维度 k^* ，确保所选的 k^* 具有良好的泛化能力。在中医药治疗冠心病组方的降维过程中，设置信息保留率为 90% ($\delta=0.9$)，以 NMF 降维方法确定了四气、五味、归经和功效的最小降维数，减少维度的同时保留了关键的信息与数据结构，提升了关联分析的准确性，如图 2 所示。




图 2 最小维度数

在降维处理中，四气和五味维度分别从 5 维降至 4 维、7 维降至 5 维，降幅较小，表明这些属性的原始维度已较低，因而仅需小幅度降维即可保留足够信息与结构。相比之下，归经维度从 12 维降至 8 维，功效维度则从 204 维降至 53 维，显示了归经和功效数据的稀疏性，在保留 90% 信息的前提下，能够显著降维，从而有效简化数据的复杂性，同时确保信息和结构的完整性。

3.3 非负矩阵分解算法降维

本文研究的药物属性数据类型为符号型数据，不同符号表示不同的药物属性类别，因此使用独热编码将原始数据转换为布尔型数据矩阵再进行分析，如图 3 所示。

符号型数据格式					布尔型数据格式											
	归经	四气	五味	功效	心	脾	寒	平	甘	苦	养血	活血	清心			
药物1	心	寒	甘	清心	1	...	0	1	...	0	1	...	0	0	0	...
药物2	心、肝	寒	苦	活血	1	...	0	1	...	0	0	...	1	0	1	...
药物3	脾、脾	平	甘	养血	0	...	1	0	...	1	1	...	0	1	0	...

图 3 符号型 - 布尔型数据关系映射

以归经维度的数据为例使用 NMF 算法进行降维，该数据包括 12 个特征指标，分别是三焦 x_1 、大肠 x_2 、小肠 x_3 、心 x_4 、心包 x_5 、肝 x_6 、肺 x_7 、肾 x_8 、胃 x_9 、胆 x_{10} 、脾 x_{11} 和膀胱 x_{12} ，如表 1 所示。

表 1 归经维度数据

编号	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_{10}	x_{11}	x_{12}
1	0	0	0	0	0	1	1	1	0	0	0	0
2	0	0	0	1	0	0	1	1	1	0	1	0
3	0	0	0	0	0	1	0	1	0	0	0	0
4	0	0	0	0	0	1	0	0	0	0	0	0
5	0	0	0	0	0	1	0	1	0	0	0	0

由表 1 可知，归经维度中每味药物仅有 2、3 个值，数据过于稀疏，因此使用非负矩阵分解算法进行降维。通过最小维度实验已知，归经维度在保留 90% 的信息下，最小维度数为 8 维，原数据矩阵经过 NMF 算法分解后得到 W 和 H 矩阵，其中 W 是新特征值 y_j 与原数据特征值 x_i 关系的系数矩阵。 W 系数矩阵如表 2 所示。

表 2 W 系数矩阵

	y_1	y_2	y_3	y_4	y_5	y_6	y_7	y_8
x_1	0.481	0.061	0	0	0	0	0.069	0.160
x_2	0	0	0.008	0	0	0	0	4.627
x_3	0.107	0	0	0	0.093	0	0.082	0.177
x_4	0.005	0	0	9.315	0	0.002	0	0
x_5	0	0.097	0	0	0	0	2.642	0
x_6	0	20.682	0	0	0	0	0.153	0
x_7	0.086	0	0.037	0	14.430	0	0	0
x_8	0	0	0	0	0	9.742	0	0
x_9	0	0	10.996	0	0	0	0	0
x_{10}	0.014	0	0.007	0.124	0.025	0	3.923	0.194
x_{11}	28.372	0	0.001	0	0.002	0.002	0	0
x_{12}	0	0.465	0	0.129	0.898	0	0	0.413

由表 2 可知，降维后的新特征值为 y_1 、 y_2 、 y_3 、 y_4 、 y_5 、 y_6 、 y_7 、 y_8 。新特征值与原特征值的计算关系为：

$$y_1 = 0.481x_1 + 0.107x_3 + 0.005x_4 + 0.086x_7 + 0.014x_{10} + 28.372x_{11}$$

(13)

同理可求得 y_2 、 y_3 等新特征值，在表达式中， y_1 主要受 x_{11} 影响， y_2 主要受 x_6 影响， y_7 主要受 x_5 和 x_{10} 影响等。在保留原始数据矩阵中足够信息的前提下，每个新的特征值都与相应的影响较大的因素密切相关。这表明，非负矩阵分解能够有效对高维数据进行降维，这不仅降低了各变量之间的相关性，还验证了原始数据指标与降维后数据指标之间的关联关系。

3.4 多维关联规则

设置支持度 $\geq 5\%$ ，置信度 $\geq 80\%$ ，分析四气、五味、归经、功效维度间的关联规则，研究结果见表 3 和表 4。由表 3 和表 4 可知，药性组合有温苦 - 心肾、温辛 - 胃肺、平淡甘 - 脾肺胃、温辛肝、温辛肺、温淡甘脾、寒苦心肝。不同的药性组合有着不同的功效，如温性辛味的药物归肝经则有着活血

止痛的功效，归肺经则有着化痰的功效，可适用于治疗气滞血瘀、气虚血瘀或者痰瘀互阻证型的冠心病；寒性苦味的药物一般归心经或肝经，同样有着活血化瘀、通经止痛的功效，除此之外，还可能有凉血清心的功能，可用于痰阻热蕴、痰瘀互阻、气滞血瘀证型的冠心病；平性药物有淡味和甘味一般归脾、肺、胃经，这是由于平性甘味的药物药性平和、作用缓和，可用于阴阳调和，且能调和脾胃、补益气血。由这些关联结果可知，本文提出的算法能够有效挖掘出多维关联规则，且符合中医药性理论。

表 3 药性维度间的关联规则

序号	前项	后项	支持度	置信度	提升度
1	温、苦	心、肾	5.76%	86.84%	1.86
2	平、淡、甘	肺	12.27%	90.75%	1.99
3	平、淡、甘	胃	5.26%	89.16%	1.95
4	平、淡、甘	脾	11.60%	86.93%	2.85
5	温、辛	胃、肺	5.41%	98.41%	3.37
6	寒、苦	肝	7.88%	83.64%	2.85
7	寒、苦	心	7.47%	94.83%	4.20

表 4 药性与功效维度间的关联规则

序号	前项	后项	支持度	置信度	提升度
1	温、辛、肝	活血、止痛	6.16%	97.70%	2.19
2	寒、苦、心、肝	活血、止痛	7.33%	95.09%	12.07
3	寒、苦、心	活血、化瘀、通经、止痛	5.76%	97.06%	13.14
4	温、淡、甘、脾	利水渗湿	6.08%	97.66%	2.14
5	温、辛、肺	化痰	5.73%	99.49%	3.41
6	温、辛、肝	止痛	7.24%	90.22%	3.13
7	寒、苦、肝	止痛	11.13%	99.48%	2.08
8	寒、苦、心、肝	凉血、化瘀、止痛、活血、消痈、清心、通经、除烦、活血	5.76%	86.84%	11.62

3.5 挖掘效率对比

综合使用非负矩阵分解 NMF 算法与关联规则 FP-growth 算法，本文设置 100 次实验比较降维前与降维后关联分析的挖掘效率，效率结果如图 4、表 5 所示。




图 4 降维前后关联分析效率图

表 5 降维前后关联分析时间平均值

算法	关联分析平均时间 /s
FP-growth 算法	1.90
NMF+FP-growth 算法	1.17(0.03+1.14)

由表 5 可见,使用 NMF+FP-growth 算法进行多维药性与功效的关联规则挖掘时,仅需 0.03 s 即可完成关联规则的发现,而 1.14 s 则用于将关联规则映射回原始数据,以提高其可读性。本文提出的方法在提高关联规则挖掘效率方面具有显著优势。

4 结语

本文针对中医药治疗冠心病组方药物的药性与功效之间的关系,开展了多维关联分析研究。由于药物属性数据库中的数据具有高维稀疏的特点,本文提出了一种基于非负矩阵分解(NMF)和 FP-growth 算法的组合方法。首先,使用 NMF 对四气、五味、归经和功效四个维度的数据进行降维,以减少中药属性数据的维度并降低稀疏性。在 NMF 算法的应用过程中,考虑到中药属性中存在潜在的信息与结构,引入了信息保留率,并根据该保留率确定了每个维度的最小降维数,以确保在降维过程中最大限度地保留这些信息。随后,使用 FP-growth 算法对降维后的数据进行频繁项集挖掘和关联规则提取,并将这些规则映射回原始特征。相比于传统的 NMF 和 FP-growth 算法,本文的方法通过数据驱动的方式,根据重构误差动态选择最小维度数,从而提供了更大的灵活性和准确性,在揭示药物数据中药性与功效之间的潜在关系方面,能够有效降低数据维度并提高挖掘效率。

参考文献:

[1] 罗昱,何妙侠,陶立阳,等.动脉粥样硬化及其相关危险因素的研究进展[J].中国综合临床,2015(9):859-862.

[2] 《中国心血管健康与疾病报告》2021(冠心病部分内容)[J].心肺血管病杂志,2022,41(12):1205-1211.

[3] 苏世家,于瑞丽,赵琳,等.防治冠心病中药经典方剂及其作用机制研究进展[J].辽宁中医药大学学报,2021,23(8):146-150.

[4] 于林童,曲文白,余新波,等.数据挖掘方法在名老中医用药规律研究中的应用现状[J].中医杂志,2017,58(10):886-888+900.

[5] 王志杰,樊薛津,王豫骞,等.机器学习方法在中医药研究中的应用进展[J].药物评价研究,2024,47(8):1906-1913.

[6] 张静雅,曹煌,龚苏晓,等.中药甘味的药性表达及在临证配伍中的应用[J].中草药,2016,47(4):533-539.

[7] 金锐,林茜,张冰,等.基于 Apriori 算法的中药气-味-

效三维数据关联规则挖掘研究[J].结合医学学报(英文版),2011,9(7):794-803.

[8] HAN J W, PEI J, YIN Y W, et al. Mining frequent patterns without candidate generation: a frequent-pattern tree approach[J]. Data mining and knowledge discovery, 2004, 8(1): 53-87.

[9] 赵琦.基于 Fp-Growth 的多维关联规则算法研究[D].哈尔滨:哈尔滨理工大学,2023.

[10] 丁弋美,侯佳奇,薛鸾.基于疗效加权 FP-Growth 算法的干燥综合征组方用药挖掘分析[J].世界科学技术-中医药现代化,2023,25(1):324-330.

[11] HANDELMAN G S, KOK H K, CHANDRA R V, et al. eD-ocor: machine learning and the future of medicine[J]. Journal of Internal Medicine, 2018, 284(6):603-619.

[12] 邓乐,丁长松,黄辛迪,等.基于多层前馈神经网络的中药药性量化研究[J].中草药,2020,51(16):4277-4283.

[13] 郭永坤,章新友,刘莉萍,等.基于神经网络的中药方剂功效预测系统研究[J].时珍国医国药,2019,30(2):493-495.

[14] LEE D D, SEUNG H S. Learning the parts of objects by non-negative matrix factorization[J]. Nature, 1999, 401(6755): 788-791.

[15] 李海磊,王晗,孔令富,等.一种基于数据两方垂直分布的多维关联规则挖掘算法[J].计算机应用与软件,2014,31(1): 18-21+80.

[16] 陈兴蜀,张帅,童浩,等.基于布尔矩阵和 MapReduce 的 FP-Growth 算法[J].华南理工大学学报(自然科学版),2014,42(1): 135-141.

[17] 章志刚,吉根林.一种基于 FP-Growth 的频繁项目集并行挖掘算法[J].计算机工程与应用,2014,50(2):103-106.

[18] 徐江雁,王亮.国家级名老中医冠心病验案良方[M].郑州:中原农民出版社,2010.

[19] 毛静远,张伯礼.当代名中医诊治冠心病临证经验集要[M].北京:中国中医药出版社,2017.

[20] 毛以林,吴彬才.冠心病良方大全[M].山西:山西科学技术出版社,2016.

[21] 国家药典委员会.中华人民共和国药典(一部)[M].北京:中国医药科技出版社,2022.

【作者简介】

游聪(2000—),男,江西宜春人,硕士研究生,研究方向:智能中医。

卢敏(1964—),通信作者(email: lumin641122@126.com),男,江西于都人,硕士,教授,硕士生导师,研究方向:深度学习和智能计算。

(收稿日期: 2024-08-11)