

颜伊庆, 李嘉豪, 黄思程, 等. 基于决策树的基元转化算法研究[J]. 广东工业大学学报, 2026, 43(4): 122-130. doi: 10.12052/gdutxb.250229.
Yan Yiqing, Li Jiahao, Huang Sicheng, et al. A basic-element transformation algorithm based on decision trees[J]. Journal of Guangdong University of Technology, 2026, 43(4): 122-130. doi: 10.12052/gdutxb.250229.

基于决策树的基元转化算法研究

颜伊庆, 李嘉豪, 黄思程, 李兴森

(广东工业大学 可拓学与创新方法研究所, 广东 广州 510006)

摘要: 当前主流深度学习模型因可解释性不足, 难以满足医疗、司法、金融等风险敏感领域对决策透明度与可控性的要求。针对现有监督学习方法侧重分类预测而忽略样本特征可转化性的问题, 本文引入可拓学理论, 提出一种基于决策树的基元转化算法。该算法首先明确分类问题与转化问题的本质差异, 建立转化问题的形式化数学模型; 其次定义转化距离以量化不同特征值之间的转化难度; 在此基础上, 设计可嵌入任意决策树模型的通用转化机制, 实现特征级转化路径的定量推导。实验结果表明, 该算法在个性化健康管理场景中能够有效挖掘正可拓域样本, 提升整体达标率, 验证了方法的有效性与可推广性。

关键词: 可拓学; 决策树; 基元转化算法; 转化距离; 转化成本

中图分类号: TP181

文献标志码: A

文章编号: 1007-7162(2026)04-0122-09

A Basic-element Transformation Algorithm Based on Decision Trees

Yan Yiqing, Li Jiahao, Huang Sicheng, Li Xingsen

(Institute of Extenics and Innovation Methods, Guangdong University of Technology, Guangzhou 510006, China)

Abstract: Current mainstream deep learning models, due to insufficient interpretability, struggle to meet the demands for decision transparency and controllability in risk-sensitive domains such as healthcare, justice, and finance. To address the limitation that existing supervised learning methods focus on classification prediction while neglecting the transformability of sample features, this research introduces Extenics theory and proposes a basic-element transformation algorithm based on decision trees. The algorithm first clarifies the essential differences between classification and transformation problems and establishes a formal mathematical model for the transformation problem. It then defines a transformation distance to quantify the difficulty of transforming between different feature values. On this basis, a general transformation mechanism is designed which can be embedded into arbitrary decision-tree models, enabling quantitative derivation of feature-level transformation paths. Experimental results demonstrate that the proposed algorithm can effectively mine samples in the positive extension domain and improve the overall compliance rate in personalized healthcare scenarios, verifying the effectiveness and generalizability of the method.

Key words: Extenics; decision tree; basic-element transformation algorithm; transformation distance; transformation cost

人工智能(Artificial Intelligence, AI)作为引领新一轮科技革命的核心技术,其研究范式可从两个维度加以审视:一是数据科学范式,侧重于从大规模数据中挖掘统计相关关系,以深度学习、大规模预训练

模型等为代表;二是机理科学范式,侧重于建模事物之间的因果关系与作用机理,以知识推理、因果推断、规则学习等为代表。近年来,随着计算能力的提升和大数据的广泛应用,深度学习等技术取得突破,

收稿日期: 2025-12-31 录用日期: 2026-04-10 网络首发日期: 2026-05-19

基金项目: 国家自然科学基金资助项目(72071049);广东省自然科学基金资助项目(2024A1515011324);广东省珠江人才计划(2024QN11X2333);广东工业大学青年百人项目(263114040)

作者简介: 颜伊庆(1990-),女,副教授,博士,主要研究方向为数据库、计算生物学、可拓智能, E-mail: yanlolo2012@gmail.com

通信作者: 李兴森(1968-),男,教授,博士,主要研究方向为可拓学与智能创新工程等, E-mail: lixs@gdut.edu.cn

推动AI在语音识别^[1]、图像处理^[2]、自然语言理解^[3]、智能决策^[4]等领域的广泛应用。

然而,数据科学范式的核心局限在于其所捕获的是变量间的统计相关关系而非因果关系。通过对当前人工智能应用领域的深入分析,本文发现其主要应用集中在相对风险不敏感的消费互联网场景中。这些应用场景具有以下特征:错误决策的后果相对可控,用户容忍度较高,以及存在人工干预和纠错的充分空间。例如,搜索引擎的推荐结果错误、内容推荐的偏差,或者电商平台的个性化展示不当,虽然可能影响用户体验,但不会造成不可逆转的重大损失^[5]。

展望未来十到二十年,人工智能技术必将向风险敏感性更高的关键领域渗透,这一趋势既是技术发展的必然结果,也是社会经济发展的客观需求:在医疗健康领域,人工智能辅助诊断、精准医疗、药物研发等应用将直接关系到患者的生命健康^[6-7];在司法领域,智能量刑辅助、证据分析、风险评估等应用将影响司法公正和社会稳定^[8];在金融科技领域,智能风控、量化投资、保险定价等应用将关系到金融体系的稳定性^[9];在工业生产领域,智能制造、质量控制、安全监测等应用将直接影响生产安全和产品质量。在这些风险敏感领域,决策错误的代价极高,往往涉及生命安全、财产损失或社会公平。这些场景要求系统不仅能做出准确预测,更需要提供因果层面的解释——即“为什么”做出特定决策,以及“如何”通过调整关键因素改变决策结果。这本质上是一个机理科学问题,要求从因果关系的角度建模决策过程。

为应对这一需求,学术界从机理科学视角提出了多种可解释智能方法。在可解释人工智能(Explainable Artificial Intelligence, XAI)方向,局部可解释性模型诊断解释(Local Interpretable Model-Agnostic Explanations, LIME^[10])、夏普利加性解释(Shapley Additive Explanations, SHAP^[11])等方法通过局部近似或特征归因为黑盒模型提供事后解释;在因果推断方向,基于结构因果模型(Structural Causal Model, SCM)的方法试图从数据中识别变量间的因果效应^[12];在规则学习方向,决策树、规则集等方法直接生成可读的if-then规则,具有天然的可解释性^[13-14]。然而,上述方法仍存在共同的局限:它们主要关注“分类”或“解释”,即判断样本属于哪一类或解释为何属于该类,而忽略了一个同样重要的机理问题——样本特征的可转化性,即在因果机制约束下,不满足目标条件的样本能否通过特征调整实现状态

转化,以及如何以最小代价完成转化。

可拓学作为一门研究事物拓展可能性的学科,量化地描述事物“是”与“非”的相互转化及量变与质变过程,为事物动态转化提供了理论依据。其核心工具——可拓集合与可拓变换,能够建模对象在不同条件下的状态转化关系,这正是上述因果转化问题的理论基础。已有研究尝试引入特征转化的概念,通过结合特征转化系数与信息增益率构造综合增益指标,从而扩展决策树模型对正可拓域的覆盖^[15]。然而,该方法对转化系数的定义仍比较初步,未考虑同一特征不同特征值之间转换难度的差异,也未考虑转化成本。本文将在此基础上进一步区分分类与转化问题的本质差异,建立形式化的转化问题数学模型,引入转化距离概念,并提出可适配任意决策树模型的通用机制,为正可拓域的有效建模与利用提供理论支撑与实践框架。

1 基础知识

1.1 可拓集合理论

可拓学是用形式化的模型研究事物拓展的可能性和开拓创新的规律与方法,并用于解决矛盾问题的科学^[16]。可拓集合理论作为可拓学中可拓论的重要组成部分,量化地描述事物“是”与“非”的相互转化及量变与质变过程,是传统集合论的一种开拓和突破^[17]。

在传统数学中,经典集描述事物的确定性分类。其元素与集合之间的关系是非黑即白:要么属于,要么不属于。它使用特征函数0和1这两个值来表示一个对象属于或不属于特定集合。在模糊数学中,模糊集是对经典集的推广,用于描述不确定、模糊或边界不清晰的分类^[18]。在模糊集中,元素属于集合的程度是连续的,即有“部分属于”的可能。它使用隶属函数 $[0, 1]$ 中的值来描述事物属于某个集合的程度,如隶属函数等于0.5表示属于该集合的可能性或程度是50%。

而可拓集用于刻画事物分类的动态可转化性,其核心在于通过关联函数 $k(x) \in (-\infty, +\infty)$ 表示对象在当前状态及其可拓状态下对某集合的隶属程度^[19-22]。正可拓域包含那些原本不具有某性质,但在可拓变换后可转化为具备该性质的元素。例如,在产品质量分类中,传统上将工件划分为合格品与不合格品。但若引入电镀这一工艺,不满足尺寸要求的工件中部分可通过返工达到合格标准,此类工件应视为可返工品,而其余则为真正的不合格品。为此,本文将进一步提出一种可解释的正可拓域挖掘方法,

以扩展潜在可转化样本,提高目标特性样本的数量,从而提升系统整体达标率。

1.2 决策树算法

决策树是一种基于树状结构的机器学习算法,广泛应用于分类和回归任务中^[23-25]。作为一种监督学习方法,决策树通过构建一个类似于流程图的树状模型来进行决策推理,其中每个内部节点代表对某个特征属性的测试,每个分支代表测试结果的输出,而每个叶节点则代表最终的决策结果或预测值。决策树算法的核心思想是采用“分而治之”的策略,通过递归地选择最优特征对数据集进行划分,使得每次划分后的子集在目标变量上具有更好的纯度。这种自顶向下的贪心策略能够将复杂的决策问题分解为一系列简单的判断问题,从而实现对未知样本的有效分类或预测。

2 基元转化算法

2.1 问题定义与建模

针对研究对象,本文建立类基元模型 $\{B_i\} = \{(O, C, V)\}$,其中 O 表示研究对象, $C = [c_0, c_1, c_2, \dots, c_m]^T$ 表示 $m+1$ 个特征维度, $V = [v_0, v_1, v_2, \dots, v_m]^T$ 表示对应特征的量值域。通过数据采集,获得 N 个样本的数据集 $\mathcal{D}$ 并将其表示为 $\{B_i\}$ 的基元形式,其中第 i 个基元 $B_i = (O_i, C, V_i)$,量值向量为 $V_i = [v_{i,0}, v_{i,1}, v_{i,2}, \dots, v_{i,m}]^T$ 表示第 i 个基元在各特征维度上的量值。对此,本文建立基元集 S

$$S = \{B_i | B_i = (O_i, C, V), O_i \in U, C \in \mathcal{L}(C), V \in V(C)\}$$

设 c_0 为基元 B 的评价特征,其量值为 $v_{i,0}$, $\mathcal{V}(c_0)$ 为其量值域。记 $\mathbb{R}$ 为实数域,建立关联函数 $K(B_i) = k(v_{i,0})$ 。对给定变换 $T = (T_S, T_k, T_B)$,称

$$\tilde{E}(B_i)(T) = \left\{ (B_i, Y, Y') \left| \begin{array}{l} B_i \in S, Y = K(B_i) = k(v_{i,0}) \in \mathbb{R} \\ T_{B_i} B_i \in T_S S, Y' = T_k K(T_{B_i} B_i) = T_k k(v'_{i,0}) \in \mathbb{R} \\ v'_{i,0} = c_0(T_{B_i} B_i) \end{array} \right. \right\}$$

为 S 上的一个单评价特征基元可拓集。依据关联函数和可拓函数,基元可拓集 $\tilde{E}(B_i)(T)$ 划分为正可拓域、负可拓域、正稳定域、负稳定域和拓界。其中,正可拓域 $\tilde{E}_+(B_i)(T)$ 的定义如下,

$$\tilde{E}_+(B_i)(T) = \left\{ (B_i, Y, Y') \left| \begin{array}{l} B_i \in S, Y = K(B_i) \leq 0 \\ T_{B_i} B_i \in T_S S, Y' = T_k K(T_{B_i} B_i) > 0 \end{array} \right. \right\}$$

本文将对其展开研究,挖掘通过元素变换实现基元从负域或零界到正域的转化方法。任一负域或零界基元 $B_i = (O_i, C, V_i)$,其 $Y = k(v_{i,0}) \leq 0$,寻求一个可拓变换 T_B ,变换后的基元 $B'_i = (O_i, C, V'_i)$ 属于正域,使得 $Y' = k(v'_{i,0}) > 0$ 。由于原始样本已经给定,其特征取值 V_i 为固定的观测结果,因而无法直接在真实对象上验证某一可拓变换 T 是否能够将负域或零界基元转化至正域。基于此,本文假设所有样本服从独立同分布(i.i.d.),来自相同的联合概率分布。通过决策树算法学习数据集中非评价特征与评价特征之间的映射关系 f ,并将学习得到的映射模型 f 视为对原有样本空间的计算近似,用以在特征空间中评估变换效果。具体而言,对任一负域或零界基元 B_i ,本文对其特征向量对应的量值施加变换,得到 $V'_i = T(V_i)$,并利用模型预测变换后的评价量 $f(V'_i)$,若 $k(v'_{i,0}) > 0$,则可认为变换 T 在模型意义上是成功的,即能够使原本处于负域或零界的基元在变换后进入正域。通过数据驱动的函数逼近模型间接判断可拓变换的有效性,从而在无需修改原始样本的前提下模拟基元的可拓性。

在设计变换 T 时,重点考虑以下两个方面:(1)基元的可转化性:指某些对象关于某特征的量值在特定条件下能够被修改或调节。例如,温度、设备参数和市场价格等特征的量值具有多态性、可塑性或受环境与人为因素调控的能力,因此具备较高的可转化性。而诸如出生地、基因序列等固有属性则通常稳定且难以更改,其量值的转化空间受限。(2)基元的转化成本:指将某特征的量值从当前状态转变为期望状态所需的代价,包括物理、经济、生理或计算资源的消耗。高成本基元的转化应被谨慎考虑,以确保整体变换在可行性与优化目标之间取得平衡。本文引入转化距离。设第 i 个特征的原始量值为 x_i ,目标量值为 x_i^* ,定义转化距离 $d_i(x_i, x_i^*)$ 为衡量从 x_i 到 x_i^* 之间转化跨度的非负实值函数。该函数应满足以下基本性质:

(P1)非负性: $d_i(x_i, x_i^*) \geq 0$;

(P2)同一性: $d_i(x_i, x_i^*) = 0$ 当且仅当 $x_i = x_i^*$;

(P3)单调性:在有序特征上, $|x_i - x_i^*|$ 越大,则 d_i 越大。

转化距离不强制要求满足对称性。在许多实际场景中,正向转化与逆向转化的难度并不相同。例如在医学领域,降低身体质量指数(Body Mass Index, BMI)通常比升高BMI困难;在工业领域,提高加工精度比降低精度代价更高,此时采用非对称的转化距离更加合理。在上述公理框架下,转化距离的具体计算方式可根据特征的数据类型和领域语义灵活选择如欧氏距离、曼哈顿距离等。

下面,将对可转化性和转化成本进行具体刻画。对于任一负域基元 B_i ,设其特征量值 V_i 经可拓变换后由负域转化为正域,其对应的目标值记为 V_i^{target} 。对于该基元的第 j 个特征 c_j ,其原始量值记为 $v_{i,j}$,经变换后转化为正域的目标量值记为 $v_{i,j}^{\text{target}}$,定义可转化度函数 $\mathcal{T}_{i,j}$ 来刻画从 $v_{i,j}$ 到 $v_{i,j}^{\text{target}}$ 的可转化性。

$$\mathcal{T}_{i,j}(v_{i,j}, v_{i,j}^{\text{target}}) = \exp\left(-\frac{d(v_{i,j} - v_{i,j}^{\text{target}})}{\sigma_j}\right) \quad (1)$$

其中, $d(v_{i,j} - v_{i,j}^{\text{target}})$ 表示两者之间的转化距离, σ_j 表示特征 c_j 的量值的转化难度系数, σ_j 值越大,表示越容易转化。转化距离刻画的是特征量值之间的转化跨度,即“要变化多少”;转化难度刻画的是该特征自身的转化难易程度,即“变化的阻力有多大”。两者共同决定可转化性的大小。对于同样的转化跨度,在易于调节的特征上,可转化性衰减较慢;而在难以改变的特征上,即使较小的转化跨度也会导致可转化性大幅下降。由式(1)可知, $\mathcal{T}_{i,j}(v_{i,j}, v_{i,j}^{\text{target}}) \in (0, 1]$;特别地,当 $v_{i,j}$ 与目标值 $v_{i,j}^{\text{target}}$ 相等时,值等于1;当两者之间的转化距离越大时,可转化性越低。

对于第 j 个特征 c_j ,定义其转化成本为 $L_{i,j}$:

$$L_{i,j}(v_{i,j}, v_{i,j}^{\text{target}}) = \beta_j \cdot d(v_{i,j} - v_{i,j}^{\text{target}}) + \lambda_j \quad (2)$$

其中, $\beta_j > 0$ 是特征 c_j 的基础成本系数, $\lambda_j \geq 0$ 是特征 c_j 的固定转化成本。因此,对于基元 B_i ,本文的目标是寻找最优变换 T^* ,使得变换后的基元 B_i' 能够预测为属于正域。对此,定义总转化成本如下:

$$L_i = \min_{v_{i,j}^{\text{target}}} \sum_{j=1}^m \omega_j \cdot L_{i,j}(v_{i,j}, v_{i,j}^{\text{target}}) \quad (3)$$

其中, $\omega_j > 0$ 是特征 c_j 的权重系数,反映不同特征在优化中的重要性,可通过等权法、基于特征重要性的数据驱动方法或者领域专家打分等方法确定。本文的目标是最小化损失函数,实现总转化成本的最小化。

变换 T 必须满足以下约束:(1)可行性约束:可转化函数的值大于最小可转化性阈值 $\tau_{\min}$,该值可以通过领域约束法、分位数法或交叉验证法等方式确定。(2)边界约束:即特征值在可行域内,其中 $\underline{v}_j$ 和 $\bar{v}_j$ 分别是第 j 个特征的下界和上界。(3)预测一致性约束:负域基元 B_i 的非评价特征进行变换后,通过传导变换使得评价特征改变,变换后基元 B_i' 的评价特征的关联函数值大于0,确保变换的有效性。即

$$\mathcal{T}_{i,j}(v_{i,j}, v_{i,j}^{\text{target}}) \geq \tau_{\min}, \quad \forall j = 1, \dots, m \quad (4)$$

$$v_{i,j}^{\text{target}} \in [\underline{v}_j, \bar{v}_j], \quad \forall j = 1, \dots, m \quad (5)$$

$$K(B_i') = k(f(V_i^{\text{target}})) > 0, \quad \text{其中 } V_i^{\text{target}} = T(V_i) \quad (6)$$

2.2 基元转化算法的一般流程

针对成本函数(3),本文采用基于决策树的基元转化方法进行求解。具体流程如下(见图1):




图1 基元转化算法框架图

Fig.1 Framework of the basic-element transformation algorithm

(1) 通过构建基元模型,对原始数据进行结构化处理与特征提取,识别特征的量值与目标结果之间的关联模式,从而生成训练基元样本集。

(2) 利用决策树算法对样本数据建模,得到一个可解释的分类模型。该模型以特征划分规则为基础,将样本空间划分为多个叶节点区域。

(3) 对叶节点进行筛选,仅保留同时满足以下约束的节点:特征可转化性约束(式(4))、边界约束(式(5))以及预测一致性约束(式(6))。

(4) 对于负域的样本,本文计算其与所有满足约束的叶节点之间的转化距离。该距离刻画了样本经最小调整后落入目标区域所需的代价。

(5) 基于转化距离,计算每个候选叶节点对应的转化成本。将损失最小的叶节点所对应的基元的变换作为该样本的最优转化方案。

3 案例分析

本文以高血压风险人群向正常人群转化的可行性策略及其算法实现路径为例,评估基元转化算法的有效性。在实验部分,首先选取一个包含24名个体的小规模样本数据集,对所提出的转化算法进行详细演示与分析,重点展示算法的运行流程和关键决策机制。随后,进一步在一个包含4 240名个体的公开大规模数据集上开展实验验证,评估算法在更大样

本条件下的有效性、稳定性及可扩展性,从而验证该方法在实际应用场景中的可行性。

3.1 小样本案例演示

本文采用阜新市矿业集团总医院2010年开展的一项针对辽宁省阜新农村人群的高血压及其危险因素的基线调查的24名个体的小样本集(见表1),用于特征转化方法的案例分析。每条样本记录包含个体的6项关键健康特征及其对应的高血压诊断结果。

表 1 24人样本的高血压及特征量值记录
Table 1 Records of hypertension and characteristic measurements in a sample of 24 people

人员	性别	年龄	是否经常运动	BMI	饮酒频次	每日蔬菜量	血压
1	男	[50, 60)	否	高	较多	经常	正常
2	男	[30, 40)	是	正常	从不	一般	正常
3	男	[20, 30)	否	正常	偶尔	一般	正常
4	男	[40, 50)	否	较高	偶尔	经常	高血压
5	男	[20, 30)	否	正常	经常	很少	高血压
6	男	[20, 30)	否	正常	从不	一般	正常
7	男	[30, 40)	否	正常	偶尔	一般	正常
8	女	[40, 50)	否	较高	较多	很少	高血压
9	男	[30, 40)	否	较高	从不	一般	正常
10	男	[30, 40)	否	正常	偶尔	一般	正常
11	男	[50, 60)	是	高	经常	一般	高血压
12	男	[20, 30)	是	正常	从不	一般	正常
13	女	[50, 60)	否	较高	较多	一般	高血压
14	女	[30, 40)	否	高	经常	一般	高血压
15	女	[50, 60)	否	高	经常	很少	高血压
16	女	[30, 40)	是	高	偶尔	很少	正常
17	女	[20, 30)	否	较高	偶尔	经常	正常
18	女	[20, 30)	是	正常	从不	经常	正常
19	女	[30, 40)	否	正常	偶尔	一般	正常
20	女	[30, 40)	否	正常	经常	一般	高血压
21	男	[30, 40)	否	正常	偶尔	一般	正常
22	男	[20, 30)	否	较高	偶尔	经常	正常
23	男	[40, 50)	否	高	经常	一般	高血压
24	女	[30, 40)	否	正常	偶尔	经常	正常

本文可以建立人员的类基元 $\{B_i\}$ 如下:

$\{B_i\} =$

{人员},

血压,

{正常, 高血压}

性别,

{男, 女}

年龄,

{[0, 10), [10, 20), ..., [110, 120)}

是否经常运动,

{是, 否}

BMI,

{正常, 较高, 高}

饮酒频次,

{从不, 偶尔, 经常, 较多}

每日蔬菜量,

{很少, 一般, 经常}

每一个人员对应一个基元,例如,人员23的基元 B_{23} 表示如下:

$$B_{23} = \begin{bmatrix} O_{23}, & \text{血压,} & \text{高血压} \\ & \text{性别,} & \text{男} \\ & \text{年龄,} & [40, 50) \\ & \text{是否经常运动,} & \text{否} \\ & \text{BMI,} & \text{高} \\ & \text{饮酒频次,} & \text{经常} \\ & \text{每日蔬菜量,} & \text{一般} \end{bmatrix}$$

以 c_0 血压作为评价特征,建立离散型的关联函数 $k(x)$,任一基元的血压如果是正常的,该基元的关联函数等于1,属于正域;如果是高血压的,该基元的关联函数等于-1,属于负域。本案例将为负域基元寻求转化到正域的最优转化路径。

$$k(x) = \begin{cases} 1, & x = \text{正常} \\ -1, & x = \text{高血压} \end{cases}$$

然后,本文通过决策树的方法,找到评价特征 c_0 与非评价特征 $c_1, c_2, \dots, c_6$ 之间的映射关系。为适应决策树等机器学习模型对数值型特征的要求,本文对原始数据中的多个分类变量进行了预处理,具体包括以下内容:(1) 性别(gender): 将“男”映射为0,“女”映射为1;(2) 年龄(age): 从原始年龄区间中提取区间起始值,作为年龄的近似代表值,如用30来近似表示区间[30,40);(3) 是否经常运动(exercise): 将“否”映射为0,“是”映射为1;(4) 体重指数(BMI): 将“正常”“较高”“高”分别映射为0、1、2,反映体重水平的递增趋势;(5) 饮酒频次(drink): 将“从不”“偶尔”“经常”“较多”分别映射为0、1、2、3,以表达饮酒行为的递进程度;(6) 蔬菜摄入频率(vegetable): 将“很少”“一般”“经常”分别映射为0、1、2,量化蔬菜摄入水平。下文中,本文将用 $\tilde{v}$ 表示预处理后的特征量值。

随后,本文采用sklearn.tree库中的DecisionTree Classifier 对预处理后的数据进行分类建模,得到评价特征与非评价特征之间的映射关系:

$$v_0 = \begin{cases} \text{正常,} & \{(\tilde{v}_5 \leq 1.5) \wedge (\tilde{v}_2 \leq 35)\} \vee \{(\tilde{v}_5 > 1.5) \wedge (\tilde{v}_6 > 1.5)\} \\ \text{高血压,} & \{(\tilde{v}_5 \leq 1.5) \wedge (\tilde{v}_2 > 35)\} \vee \{(\tilde{v}_5 > 1.5) \wedge (\tilde{v}_6 \leq 1.5)\} \end{cases}$$

结果如图2所示。决策树模型表明,饮酒频次、年龄和每日蔬菜摄入量是影响高血压发生的关键特征。本文重点分析负域的高血压基元的分布特征:(1) 在饮酒频次为“从不”或“偶尔”的人群中,高血压的患病风险较低。具体而言,该组共15个样本,其中14人未患高血压,仅有1人在年龄超过35岁时出现高血压;(2) 在饮酒频次为“经常”或“较多”的人群中,高血压风险显著升高。该组共9个样本,其中8人患高血压,但在“经常”摄入蔬菜的子群中,仍有1人未患高血压,表明蔬菜摄入可能对风险具有一定缓解作用。




图2 农村人群的高血压特征分类

Fig.2 Classification of hypertension characteristics in rural population

为了更直观且简洁地表示各特征的量值转化关系,在后续分析中本文采用基于绝对值的距离函数来定义特征的可转化度函数。同时,依据领域知识,设定转化难度系数 $\sigma = \{0, 0, 4, 2, 3, 5\}$,成本系数 $\beta = 1$, $\lambda = 0$,阈值为 $\tau_{\min} = 0.5$ 。然后,识别对应于正域的叶节点,具体如下:

叶节点1: 性别: 任意; 年龄: ≤ 35 ; 是否经常运动: 任意; BMI: 任意; 饮酒频次: 从不或偶尔; 每日蔬菜量: 任意;

叶节点2: 性别: 任意; 年龄: 任意; 是否经常运动: 任意; BMI: 任意; 饮酒频次: 经常或较多; 每日蔬菜量: 经常。

以人员23(B_{23})为例, $K(B_{23}) < 0$,本文希望找到变换,使得变换后的 B'_{23} 的 $K(B'_{23}) > 0$ 。首先,本文考虑其通向叶节点1的路径,其第1维非评价特征(年龄)的原始值为 $v_{23,1} = 40$,目标值为 $v_{23,1}^{\text{target}} = 35$,可转化度函数 $\mathcal{T}_{23,1}$ 为

$$\mathcal{T}_{23,1}(v_{23,1}, v_{23,1}^{\text{target}}) = \exp\left(-\frac{|40-35|}{0}\right) \rightarrow 0 < \tau_{\min} \quad (7)$$

因此,无法通过年龄特征实现转化, B_{23} 无法通过叶节点1转化到正域。

然后本文以其通向叶节点2的路径为例,分析其在“每日蔬菜量”维度上的转化函数值与转化成本。第6维特征(即蔬菜)原始值为 $v_{23,6} = 1$,目标状态为 $v_{23,6}^{\text{target}} = 2$ 。其特征可转化度函数定义如下:

$$\mathcal{T}_{23,6}(v_{23,6}, v_{23,6}^{\text{target}}) = \exp\left(-\frac{|2-1|}{5}\right) = 0.81 > \tau_{\min} \quad (8)$$

因此,样本在蔬菜维度具备从当前状态向叶节点2转化的可行性。进一步地,蔬菜量维度的转化成本计算如下 $L_{23,6}(v_{23,6}, v_{23,6}^{\text{target}}) = 1 \times |2-1| + 0 = 1$ 。因此, B_{23}

可以通过将蔬菜量从“一般”增加到“经常”,进而通过传导变换,使得 B'_{23} 落入正域 $K(B'_{23}) > 0$,实现从高血压风险人群向正常人群的转化。在存在多个可行的转化路径时,可分别计算各路径在所有特征维度上的转化成本总和,并选择成本最小的路径作为推荐的健康干预方案。

3.2 大规模数据验证

更进一步地,本文在Kaggle提供的开源高血压数据集(Hypertension Risk Model Dataset)上对所提出的方法进行了验证。该数据集包含4 240个样本,以及12个特征:性别(gender),年龄(age),当前是否吸烟(currentSmoker),每日吸烟支数(cigsPerDay),是否服用降压药(BPMeds),是否患有糖尿病(diabetes),总胆固醇(totChol),收缩压(sysBP),舒张压(diaBP),体质指数(BMI),心率(heartRate),血糖(glucose)。本文对此建立类基元 $\{B_i\}$ 如下:

$$\{B_i\} = \begin{bmatrix} \{\text{人员}\}, & \text{血压}, & \{\text{正常, 高血压}\} \\ & \text{性别}, & \{\text{男, 女}\} \\ & \text{年龄}, & [32, 70] \\ & \text{是否吸烟}, & \{\text{是, 否}\} \\ & \text{每日吸烟支数}, & [0, 70] \\ & \text{是否服用降压药}, & \{\text{是, 否}\} \\ & \text{是否患有糖尿病}, & \{\text{是, 否}\} \\ & \text{总胆固醇}, & [100, 700] \\ & \text{收缩压}, & [80, 300] \\ & \text{舒张压}, & [45, 145] \\ & \text{体脂数}, & [15, 57] \\ & \text{心率}, & [40, 145] \\ & \text{血糖}, & [40, 400] \end{bmatrix}$$

每一个人员对应一个基元,例如人员2836的基元 B_{2836} 表示如下:

$$B_{2836} = \begin{bmatrix} O_{2836}, & \text{血压}, & \text{高血压} \\ & \text{性别}, & \text{男} \\ & \text{年龄}, & 50 \\ & \text{是否吸烟}, & \text{否} \\ & \text{每日吸烟支数}, & 0 \\ & \text{是否服用降压药}, & \text{否} \\ & \text{是否患有糖尿病}, & \text{否} \\ & \text{总胆固醇}, & 230 \\ & \text{收缩压}, & 126 \\ & \text{舒张压}, & 93 \\ & \text{体脂数}, & 25.36 \\ & \text{心率}, & 80 \\ & \text{血糖}, & 84 \end{bmatrix}$$

以 c_0 血压作为评价特征,建立离散型的关联函数 $k(x)$,其建模过程与第3.1节一致,此处不再赘述。

对于该数据集,本文首先进行了数据预处理,删除存在缺失值的489条样本记录。随后调用corr() 函数开展特征相关性分析,结果表明,特征 c_1 (是否吸烟)与 c_4 (每日吸烟支数),以及特征 c_6 (是否患有糖尿病)与 c_{12} (血糖水平)之间存在显著相关性。为了避免冗余信息对模型训练造成影响,本文仅保留了数值信息更为丰富的特征 c_4 和 c_{12} 。在此基础上,本文进一步剔除了异常值,并使用imblearn.over_sampling对高血压样本进行了过采样,以缓解类别不平衡问题。在数据预处理完成后,本文基于sklearn.tree库中的

DecisionTreeClassifier构建分类模型。实验结果表明,该模型在测试集上的接收者操作特征曲线下方面积达到90.7%,具体结果如表2和图3所示。

表 2 Kaggle高血压风险数据的决策树分类结果
Table 2 Decision tree classification results of kaggle hypertension risk data

类别	精确率	召回率	F_1 分数
正常	0.91	0.90	0.91
高血压	0.91	0.91	0.91




图 3 Kaggle高血压风险数据的特征分类
Fig.3 Feature classification of kaggle hypertension risk data

下面将重点分析负域的高血压人群向正常人群转化的策略。首先,识别正域对应的叶节点:

叶节点1: 性别: 任意; 年龄: 任意; 当前是否吸烟: 任意; 每日吸烟支数: 任意; 是否服用降压药: 否; 是否患有糖尿病: 任意; 总胆固醇: 任意; 收缩压: ≤ 139.75 ; 舒张压: ≤ 89.75 ; 体质指数: 任意; 心率: 任意; 血糖: 任意。

叶节点2: 性别: 任意; 年龄: 任意; 当前是否吸烟: 任意; 每日吸烟支数: 任意; 是否服用降压药: 任意; 是否患有糖尿病: 任意; 总胆固醇: 任意; 收缩压: ≤ 139.75 ; 舒张压: $[89.75,96.5]$; 体质指数: ≤ 21.72 ; 心率: 任意; 血糖: 任意。

叶节点3: 性别: 任意; 年龄: 任意; 当前是否吸烟: 任意; 每日吸烟支数: 任意; 是否服用降压药: 任意; 是否患有糖尿病: 任意; 总胆固醇: 任意; 收缩压: $(139.75,148.25]$; 舒张压: 任意; 体质指数: 任意; 心率: ≤ 52.5 ; 血糖: 任意。

叶节点4: 性别: 任意; 年龄: ≤ 35.5 ; 当前是否吸烟: 任意; 每日吸烟支数: 任意; 是否服用降压药: 任意; 是否患有糖尿病: 任意; 总胆固醇: 任意; 收缩压: > 148.25 ; 舒张压: 任意; 体质指数: 任意; 心率: 任意; 血糖: 任意。

依据领域知识,转化难度系数为 $\sigma = \{1,0,10,10,5,3,6,6,7,8,9,5\}$, 成本参数为 $\beta = 1, \lambda = 0$, 阈值为

$\tau_{\min} = 0.5$ 。本文分别计算了各个节点的可转化度与转化成本,结果如表3所示。由于叶节点3(心率难以降低)和叶节点4(年龄不可逆)的可转化性小于阈值,其对应的转化路径被判定为不可行。相对的,个体 B_{2836} 可以通过叶节点1降低舒张压,经传导变换得到 B'_{2836} ;也可以通过叶节点2降低 BMI,得到 B''_{2836} 。此时,两种转化后的状态均落入正域,即满足 $K(B'_{2836}) > 0$ 与 $K(B''_{2836}) > 0$ 。进一步对比转化成本可知,通过降低舒张压实现的转化路径代价更低,因此更有利于个体以较小成本完成从高血压高风险状态向正常状态的转化。

表 3 Kaggle高血压风险数据的转化结果

Table 3 Transformation results of kaggle hypertension risk data

指标	叶节点1	叶节点2	叶节点3	叶节点4
可转化性	0.628	0.634	0.044	0
转化成本	3.25	3.64		

4 结论与展望

当前主流的监督学习方法侧重于分类预测与特征归因解释,但在风险敏感领域中,决策者不仅需要知道“样本属于哪一类”以及“为什么属于该类”,更需要回答“如何通过可行的特征调整使不达标样本转化为达标样本”这一核心问题。针对这一尚未被充分研究的“转化问题”,本文融合可拓学理论与决策树模型,提出了一种基于决策树的基元转化算法。在理论层面,本文明确区分了分类问题与转化问题的本质差异,通过定义满足非负性、同一性和单调性的转化距离公理化框架,并引入可转化度函数与转化成本函数,建立了以可转化性约束、边界约束和预测一致性约束为核心的形式化约束优化模型,将转化方案的求解从定性分析提升为定量推导。在算法层面,本文提出了可嵌入任意决策树模型的通用转化机制,利用决策树叶节点结构天然定义正域的特征条件区域,通过遍历所有满足约束的正域叶节点计算负域样本的特征级转化路径,并基于成本最小化原则筛选最优方案,使得转化路径的每一步调整都具有清晰的逻辑依据与领域可解释性。在实证层面,通过小样本案例演示(24人高血压数据)与大规模数据验证(4 240人Kaggle公开数据集)两个层次的实验,系统验证了算法的有效性——算法能够准确识别正可拓域样本,有效排除不可行的转化路径(如年龄不可逆、心率难以大幅降低),并为高风险个体生成具有医学合理性的个性化干预建议,整体达标率得到显著提升。

本文的研究为基于可拓学的特征转化问题奠定了初步的理论与方法基础,但仍存在若干值得深入探索的方向。首先,在与相关方法的融合方面,反事实解释关注“如何最小程度地改变输入以改变预测结果”,与本文的转化问题在形式上具有相似性,但其基于黑盒模型的事后扰动搜索不显式考虑转化的现实可行性与领域约束,未来将系统比较两类方法的适用性,并探索将反事实解释中的高效搜索策略引入基元转化算法以提升高维空间中的求解效率;同时,本文当前采用决策树学习的映射关系作为因果机制的近似,后续拟引入结构因果模型与干预演算,将转化算法建立在更严格的因果推断基础之上,以区分相关性驱动的“虚假转化路径”与因果性支撑的“有效转化路径”。其次,在方法论扩展方面,当前算法以单一成本最小化为目标,未来将扩展为同时考虑转化成本、转化风险、转化时效性的多目标优化框架,并引入动态规划或强化学习方法建模多步骤贯转化策略,以更贴合现实干预过程中特征值变化的时序依赖性与路径依赖性。最后,在应用推广方面,本文以高血压风险管理为典型案例进行了验证,后续将在金融风控、工业质量控制、教育评估等多个风险敏感领域开展应用研究,进一步验证算法的通用性与可推广性。

参考文献:

[1] BENGIO Y, GOODFELLOW I, COURVILLE A. Deep learning[M]. Cambridge, MA, USA: MIT Press, 2017.

[2] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521(7553): 436-444.

[3] DEVLIN J, CHANG M W, LEE K, *et al*. Bert: pre-training of deep bidirectional transformers for language understanding[C]//Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics. Minneapolis, Minnesota: Human Language Technologies, 2019: 4171-4186.

[4] VASWANI A, SHAZEER N, PARMAR N, *et al*. Attention is all you need[J]. *Advances in Neural Information Processing Systems*, 2017, 30: 5998-6008.

[5] 王凡. 生成式人工智能在电商中的伦理风险与治理机制研究[J]. *电子商务评论*, 2025, 14(7): 28-35.
WANG F. Research on the ethical risks and governance mechanisms of generative artificial intelligence in e-commerce[J]. *E-Commerce Letters*, 2025, 14(7): 28-35.

[6] GUNNING D, AHA D. DARPA's explainable artificial intelligence (XAI) program[J]. *AI Magazine*, 2019, 40(2): 44-58.

[7] ARRIETA A B, DÍAZ-RODRÍGUEZ N, DEL SER J, *et al*.

- Explainable artificial intelligence (XAI): concepts, taxonomies, opportunities and challenges toward responsible AI[J]. *Information Fusion*, 2020, 58: 82-115.
- [8] WALTERS R, NOVAK M. Cyber security, artificial intelligence, data protection & the law[M]. Berlin: Springer, 2021.
- [9] BUSSMANN N, GIUDICI P, MARINELLI D, *et al.* Explainable AI in fintech risk management[J]. *Frontiers in Artificial Intelligence*, 2020, 3: 26.
- [10] RIBEIRO M T, SINGH S, GUESTRIN C. “Why should I trust you?” explaining the predictions of any classifier[C]// *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York: ACM, 2016: 1135-1144.
- [11] LUNDBERG S M, LEE S I. A unified approach to interpreting model predictions[J]. *Advances in Neural Information Processing Systems*, 2017, 30: 4765-4774.
- [12] PEARL J. Causality[M]. Cambridge: Cambridge University Press, 2009.
- [13] BREIMAN L, FRIEDMAN J, OLSHEN R A, *et al.* Classification and regression trees[M]. New York: Chapman and Hall/CRC, 2017.
- [14] LETHAM B, RUDIN C, MCCORMICK T H, *et al.* Interpretable classifiers using rules and bayesian analysis: Building a better stroke prediction model[J]. *The Annals of Applied Statistics*, 2015, 9(3): 1350-1371.
- [15] LI X, SUN J, LI J, *et al.* A transformation tree based on extension set theory[J]. *Annals of Data Science*, 2025: 1-17.
- [16] 蔡文. 可拓集合和不相容问题[J]. *科学探索学报*, 1983, 3(1): 83-97.
CAI W. Extension set and non-compatible problems[J]. *Journal of Science Exploration*, 1983, 3(1): 83-97.
- [17] 杨春燕, 蔡文, 汤龙. 可拓学[M]. 2版. 北京: 科学出版社, 2024.
- [18] ZADEH L A. Fuzzy sets[J]. *Information and Control*, 1965, 8(3): 338-353.
- [19] 蔡文, 杨春燕, 陈文伟等. 可拓集与可拓数据挖掘[M]. 北京: 科学出版社, 2008. 06.
- [20] 田英杰, 刘大莲, 李兴森. 面向标签可变性的可拓分类方法[J]. *广东工业大学学报*, 2025, 42(4): 1-7.
TIAN Y J, LIU D L, LI X S. Extension classification method for label variability[J]. *Journal of Guangdong University of Technology*, 2025, 42(4): 1-7.
- [21] 李兴森, 许立波, 刘海涛, 等. 因素空间与可拓学的互补性分析及问题处理融合模型[J]. *智能系统学报*, 2022, 17(5): 990-998.
LI X S, XUN L B, LIU H T, *et al.* A complementary analysis of factor space and extenics and a fusion model for solving problems[J]. *CAAI Transactions on Intelligent Systems*, 2022, 17(5): 990-998.
- [22] 董翠玲, 杨春燕. 转换桥方法的改进及其应用[J]. *广东工业大学学报*, 2023, 40(5): 15-20.
DONG C L, YANG C Y. Improvement of the transforming bridge method and its application[J]. *Journal of Guangdong University of Technology*, 2023, 40(5): 15-20.
- [23] ARIK S Ö, PFISTER T. Tabnet: attentive interpretable tabular learning[C]// *Proceedings of the AAAI Conference on Artificial Intelligence*. Palo Alto: AAAI Press, 2021: 6679-6687.
- [24] CHEN T, GUESTRIN C. Xgboost: a scalable tree boosting system[C]// *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York: ACM Press, 2016: 785-794.
- [25] KE G, MENG Q, FINLEY T, *et al.* Lightgbm: a highly efficient gradient boosting decision tree[J]. *Advances in Neural Information Processing Systems*, 2017, 30: 3146-3154.

(责任编辑: 王威娜 英文审核: 熊荣斌)