

融合生成对抗网络与决策树的信号相位方案智能推荐方法

陈纲梅, 周勇, 祝佳祥, 魏鸿坤, 林涛
(深城交科技集团股份有限公司, 广东 深圳 518057)

摘要: 针对中国城市交叉口信号相位设计普遍依赖常规固定相位与基于专家经验的配置局限性, 突破传统单一算法的局限, 提出一种融合生成对抗网络(Generative Adversarial Networks, GAN)与可解释决策树的智能相位优化方法, 并构建了“数据扩增—特征映射—方案推荐”的全流程智能化框架。该方法创新性地将交叉口静态设施条件(车道渠化、几何布局等)与动态流量特征(转向比例、流量波动等)深度耦合, 采用基于 Gumbel-Softmax 改进技术的 GAN 模型解决交通样本稀缺问题, 将实际采集的 159 组交叉口样本高效扩增至 15 104 组有效训练数据; 进而基于分类与回归树模型算法构建承担“特征—相位”映射功能的决策树模型, 通过信息增益优化节点分裂策略, 实现多维度交通特征与相位方案的精准匹配。在北京市和桐乡市的 6 个不同类型交叉口的实证应用表明: 本算法使优化后交叉口的平均排队长度缩短 12.3%, 平均停车次数减少 11.5%。研究成果为城市道路交叉口动态信号相位优化提供了一种可工程化实践的解决方案。

关键词: 交通控制; 信号相位方案; 生成对抗网络(GAN); 决策树; AI与交通协同

An Intelligent Recommendation Method for Intersection Signal Phase Plans Based on the Integration of Generative Adversarial Networks and Decision Trees

Chen Gangmei, Zhou Yong, Zhu Jiaxiang, Wei Hongkun, Lin Tao

(Shenzhen Urban Transport Planning Center Co., Ltd., Shenzhen Guangdong 518057, China)

Abstract: To address the limitations of traditional signal design at urban intersections in China, which mainly relies on fixed phases and expert-based configurations, this paper proposes an intelligent phase optimization method that integrates Generative Adversarial Networks (GAN) with an interpretable decision tree, and develops a full-process intelligent framework encompassing data augmentation, feature mapping, and plan recommendation. The proposed method innovatively combines static intersection conditions, such as lane channelization and geometric layout, with dynamic traffic characteristics, including turning proportions and flow fluctuations. A GAN model based on an enhanced Gumbel-Softmax technique is adopted to address the problem of limited traffic samples. It expands 159 observed intersection samples into 15,104 effective training samples. Furthermore, a decision tree model using the classification and regression tree (CART) algorithm is constructed to perform "feature-phase" mapping. The node splitting strategy is optimized based on information gain, which enables accurate matching between multidimensional traffic characteristics and signal phase plans. Empirical applications at six different types of intersections in Beijing and Tongxiang show that the proposed method reduces the average queue length by 12.3% and the average number of stops by 11.5% after optimization. The results provide a practical and implementable solution for dynamic signal phase optimization at urban intersections.

Keywords: traffic control; signal phase plans; Generative Adversarial Networks (GAN); decision trees; AI-traffic integration

收稿日期: 2025-10-14

基金项目: 广东省重点领域研发计划项目“面向智能汽车的数字路网关键技术研究与应用示范”(2023B0909040001)、深圳市发展和改革委员会战略性新兴产业发展专项资金扶持计划“面向车路协同的智慧道路公共服务平台”(XMHT20230112001)

作者简介: 陈纲梅(1993—), 女, 广西梧州人, 硕士, 工程师, 研究方向为交通控制与管理, 电子邮箱 chengangmei@sutpc.com。

通信作者: 林涛(1975—), 男, 湖南长沙人, 博士, 正高级工程师, 董事长, 研究方向为智慧城市与交通大脑、低空交通系统, 电子邮箱918766856@qq.com。

引用格式: 陈纲梅, 周勇, 祝佳祥, 等. 融合生成对抗网络与决策树的信号相位方案智能推荐方法[J]. 城市交通, 2026, 24(2): 48-58.

Chen Gangmei, Zhou Yong, Zhu Jiexiang, et al. An intelligent recommendation method for intersection signal phase plans based on the integration of generative adversarial networks and decision trees[J]. Urban Transport of China, 2026, 24(2): 48-58.

0 引言

城市道路交叉口信号控制方案优化领域已积累丰富研究成果, 但现有研究存在明显局限。多数研究聚焦于信号配时方案优化, 例如: 构建以通行能力最大化或车均延误最小化为目标的数学模型^[1], 结合蚁群算法^[2]、遗传算法^[3]等智能搜索算法求解; 或通过多轮优化数学模型并用求解器分步求解^[4], 实现相位与配时的协同优化; 亦有研究利用花朵授粉算法(Flower Pollination Algorithm, FPA)搜索最优的相位、相序和配时方案^[5]。基于大数据的相位方案自动推荐算法研究极为匮乏, 且多局限于特殊场景(如短左转车道十字形交叉口^[6])或宏观路网优化(如多智能体深度强化学习信号控制算法^[7]), 模型泛化能力不足, 迁移至新路网时需重新调整超参数, 难以在实际工程中推广应用。

更关键的是, 现有研究未能实现 AI 算法与交通工程机理的有效融合。传统方法依赖人工经验与预设模型, 难以动态适配复杂多变的交通流特征; 而纯 AI 算法虽具备数据驱动的自适应能力, 却往往忽视车道渠化、信号控制设施限制等工程约束, 导致优化方案可行性不足。此外, 交通领域样本采集成本高、有效样本量有限的问题, 进一步制约了 AI 算法的训练效果与应用性能。

针对上述问题, 本文提出一种融合生成对抗网络(Generative Adversarial Networks, GAN)与可解释决策树(Decision Tree, DT)的智能相位优化方法。该方法通过 GAN 模型解决交通样本稀缺难题^[8-9], 利用 Gumbel-Softmax 改进技术突破传统 GAN 生成离散相位方案样本时的梯度传播障碍^[10-11]; 借助决策树模型建立交通特征与相位方案之间的可解释性映射, 既保留 AI 算法的数据驱动优势, 又融入交通工程的机理约束。这种“数据扩增(GAN)一逻辑推理(DT)”的双层架构, 不仅为信号相位方案智能化推荐提供了新的技术路径, 也构建了 AI 算法与交通

工程协同优化的新框架。

1 相位方案智能推荐算法

本文提出的相位方案智能推荐算法, 以“AI 算法适配交通场景、交通机理引导 AI 优化”为核心思路, 构建了包含样本信息预处理、基于 GAN 的样本扩增、相位方案推荐决策树 3 个部分的闭环智能化推荐模型。

1.1 样本信息预处理

样本预处理环节充分考虑交通工程的实际约束, 将交叉口特征划分为静态设施条件与动态流量特征, 为后续 AI 算法训练提供符合工程实际的高质量输入数据。

1.1.1 交叉口样本的特征条件向量

静态设施条件直接决定相位方案的设计边界, 包括交通渠化组织(交叉口类型、左转车道类型、右转组织类型、左转弯待转区设置)、信号控制设施(左转/右转机动车信号灯组类型、非机动车信号灯组类型)以及行人过街组织类型(一次过街、多次过街)。例如, 当交叉口设有短拓宽左转车道时, 直行与左转的放行顺序将受到限制, 需在特征中对此类约束进行单独标识; 在行人过街组织类型方面, 若采用行人二次(或多次)过街设计, 最短行人过街时间对相位时长的约束作用会被削弱, 从而为相位方案提供更大的选择空间。因此, 本文将行人过街组织类型划分为一次过街和多次过街两类。

动态流量特征反映交通流的运行需求, 各组车流对绿信比需求的差异在一定程度上决定相位方案的优选空间。本文选取交通流量比作为表征交通流特性的参考指标。两种交叉口类型的重点车流如图 1 所示, 其中交通流量比

$$y_i = \frac{q_i}{S_i} = \frac{q_i \cdot h_i}{3600}, \quad (1)$$

式中: y_i 为车流 m_i 的交通流量比; q_i 为车流 m_i 的实际交通量/(pcu·h⁻¹); S_i 为车流 m_i



图1 十字形和T形交叉口重点车流分布

Fig.1 Distribution of critical traffic flows at four-legged intersections and T-junctions

表1 交叉口样本特征条件及其取值说明

Tab.1 Characteristics of intersection samples and descriptions of their values

特征条件	取值说明
交叉口类型	十字形交叉口=0; T形交叉口=1
左转车道类型	是否存在某个进口道左转车道为短拓宽车道, 是=1, 否=0
右转组织类型	是否存在某个进口道右转车道已渠化, 是=1, 否=0
左转弯待转区设置情况	是否存在某个进口道左转车道已设置左转弯待转区, 是=1, 否=0
行人过街组织类型	是否存在某个进口道已设置行人二次或多次过街设施, 是=1, 否=0
左转机动车信号灯组类型	是否存在某个进口道左转信号控制灯组为“专用保护相位灯组”, 是=1, 否=0(T形交叉口仅考虑进口道C)
右转机动车信号灯组类型	是否存在某个进口道右转车道未渠化且右转信号控制灯组为“专用保护相位灯组”, 是=1, 否=0
非机动车信号灯组类型	是否存在某个进口道已设置右侧的非机动车道, 并配置专门的非机动车信号灯组, 是=1, 否=0
双向直行车流 DR ₁	1) 十字形交叉口: $DR_1 = y_1 - y_3 / \max(y_1, y_3)$, $DR_1 \in [0, 1]$; 2) T形交叉口: $DR_1' = (y_1 - y_3) / \max(y_1, y_3)$, $DR_1' \in [-1, 1]$
双向左转车流 DR ₂	1) 十字形交叉口: $DR_2 = y_2 - y_4 / \max(y_2, y_4)$, $DR_2 \in [0, 1]$; 2) T形交叉口: $DR_2' = 0$
对向直行左转冲突车流 DR ₃	1) 十字形交叉口: $DR_3 = \max[y_1 - y_4 / \max(y_1, y_4), y_2 - y_3 / \max(y_2, y_3)]$, $DR_3 \in [0, 1]$; 2) T形交叉口: $DR_3' = y_1 - y_4 / \max(y_1, y_4)$, $DR_3 \in [0, 1]$
进口A同向直行左转车流 DR ₄	1) 十字形交叉口: $DR_4 = (y_1 - y_2) / \max(y_1, y_2)$, $DR_4 \in [-1, 1]$; 2) T形交叉口: $DR_4' = 0$
进口C同向直行左转车流 DR ₅	1) 十字形交叉口: $DR_5 = (y_3 - y_4) / \max(y_3, y_4)$, $DR_5 \in [-1, 1]$; 2) T形交叉口: $DR_5' = 0$

的饱和小时流率/(pcu·h⁻¹); h_i 为车流 m_i 的饱和车头时距/s。

通过比较各组关联车流交通流量比的差异(difference in traffic flow ratio, DR), 能够

有效刻画交叉口的实际交通流特性。在此基础上, 进一步定义双向直行车流 DR₁、双向左转车流 DR₂、对向直行左转冲突车流 DR₃ 等差异指标, 以量化不同方向车流的通行需求差异, 为相位方案的优化匹配提供动态决策依据。

各类型交叉口的特征条件及其取值如表1所示, 这些取值共同构成交叉口样本的特征条件向量。

1.1.2 相位方案类型

结合国内城市交叉口常见的相位设计形式, 本文划分出9种相位方案类型(见表2), 覆盖十字形交叉口与T形交叉口的主流应用场景。每种相位方案均严格遵循交通工程的安全原则, 例如右转专用保护相位需避免与冲突车流或行人过街同时放行, 确保推荐方案具备工程可行性。

1.2 基于GAN的交叉口样本扩增方法

针对实际交叉口案例样本稀缺, 以及交叉口特征条件或相位方案类型分布不均衡等问题, 本文设计了一种适配交通场景的GAN模型。该模型通过引入Gumbel-Softmax改进技术, 提升了离散相位方案样本的生成质量, 为后续决策树模型的训练提供了充足且高质量的数据集。

1.2.1 GAN建模与训练目标

设真实样本集的分布为 $P_{data}(x)$, 其中 x 为真实交叉口样本, 由其特征条件取值与相位方案类型构成的向量表示; 交叉口相位方案类型采用one-hot编码表示(如相位方案类型1对应[1, 0, 0, 0, 0, 0, 0, 0, 0], 相位方案类型2对应[0, 1, 0, 0, 0, 0, 0, 0, 0])。

1) 生成器(Generator): 通过输入随机先

验噪声生成新样本。生成器 $G(z; \theta_g)$ 接收随机噪声 $z \sim P_z(z)$ 作为输入，输出生成样本，其分布记为 $P_G(x; \theta_g)$ (θ_g 为生成器参数)。

2) 判别器(Discriminator): 对真实样本和生成样本进行分类。判别器 $D(x; \theta_d)$ 接收真实样本或生成样本作为输入，输出一个区间[0, 1]的标量，表示输入样本为真实样本的概率(θ_d 为判别器参数)。

3) 模型训练的价值函数如式(2)所示，训练目标是通过最小化生成器、最大化判别器的方式优化价值函数，两者形成对抗训练过程：

$$\min_{\theta_g} \max_{\theta_d} V(D, G) = E_{x \sim P_{data}(x)} [\log D(x)] + E_{z \sim P_z(z)} \langle \log \{1 - D[G(z)]\} \rangle \quad (2)$$

训练时采用交替迭代策略：先固定生成器，训练判别器 k 次(如 $k=5$)；再固定判别器，训练生成器 1 次。如此反复迭代，逐步优化判别器和生成器的参数。

1.2.2 交通场景下的GAN收敛性分析

1) 理论收敛条件。

① 分布一致性^[8]：当生成样本分布 P_G 与真实样本分布 P_{data} 完全一致时，判别器的最优输出为 $D_G^* = 0.5$ ，即样本来自 P_G 和 P_{data} 的概率均为 0.5。此时，式(2)收敛至 $-\ln 4 \approx -1.386$ ，表明生成样本已难以与真实样本区分。

② 梯度传播连续性：传统 GAN 生成离散样本时存在梯度中断问题，为此引入 Gumbel-Softmax 采样机制。具体而言，对生成器输出的相位类型向量添加标准 Gumbel 噪声，其采样公式为 $Gumbel(0, 1) = -\log[-\log(u_i)]$ ， $u_i \sim U(0, 1)$ ，再通过 Softmax 函数进行归一化处理。该方法既保证了梯度反向传播的连续性，又能使生成向量更接近 one-hot 编码的“独热性”（即向量中仅有一个分量接近 1，其余全接近 0，如 [0.1, 0.9, 0.1, ..., 0.1] 的置信度显著高于模糊向量 [0.3, 0.4, 0.5, ..., 0.3]），从而提升生成样本的物理意义合理性。

生成器的网络架构如图 2 所示。该网络通过多层感知机与批量归一化层的组合，实现对交叉口多维度特征(如进口道数量、流量分布等)的精准建模。

2) 训练稳定性保障。

① 轻量化网络结构：生成器与判别器

均采用 2 层全连接架构，避免复杂网络导致的训练震荡；采用 Full-batch 训练方式，一次性输入全部样本计算梯度，确保模型能够充分学习样本分布特征。

② 双重收敛验证指标。

动态平衡指标：若训练过程中式(2)的估计值趋于稳定，且判别器 D 对生成器 G 所生成样本判断为“真实样本”的概率均值接近 0.5，则认为模型训练收敛，达到动态平衡。

分布一致性指标：采用最大平均差异(Maximum Mean Discrepancy, MMD)量化真实样本与生成样本的分布差异，训练过程中计算真实样本集 X_{data} 与生成样本集 Y_G 的 MMD 值。若 MMD 值逐渐趋近于 0，且继续训练无明显下降，则表明生成样本分布与真实样本分布高度吻合。其中 MMD 值采用高

表 2 交叉口信号相位方案类型

Tab.2 Types of intersection signal phase plans

类型编号	交叉口类型	相位图
1		包含迟启情况
2		
3	十字形	
4		
5		或
6		包含迟启情况
7		
8	T形	
9		包含迟启情况




图 2 生成器的网络架构

Fig.2 Network architecture of the generator

斯核函数 $k(x, y) = e^{-\|x-y\|^2}$ 进行计算, 计算方法为:

$$MMD = \frac{2}{N(N-1)} \sum_{i \neq j} k(x_i, x_j) - \frac{4}{N(N-1)} \sum_{i \neq j} k(x_i, y_j) + \frac{2}{N(N-1)} \sum_{i \neq j} k(y_i, y_j) \quad (3)$$

式中: $k(x_i, y_j)$ 为高斯核函数; x 为真实样本集 X_{data} 中的样本向量; y 为生成样本集 Y_G 中的样本向量; N 为样本数量, $i, j = 1, 2, \dots, N$ 。

1.3 相位方案推荐决策树

决策树模型承担“特征-相位”映射的核心任务, 通过融入交通工程机理, 赋予AI算法可解释的输出能力, 从而有效解决纯AI模型的“黑箱”问题。

1.3.1 决策树生成

上文已标定交叉口的两类关键特征信息: 一是静态条件(如进口道数量、转向限制等), 采用0-1二元变量表示, 这类特征直接限制相位方案的可选范围; 二是交通流动

态特性(如高峰小时交通量、转向比例等), 采用连续型变量表示, 这类特征决定不同相位方案的优劣, 但不构成选择限制。为构建二叉分类决策树, 需针对连续型动态特征寻找最优切分点, 将其转化为离散化的取值范围, 为后续规则生成奠定基础。

1) 最优特征选择。

决策树的学习过程通过递归选择最优特征实现数据分割, 使子数据集的分类效果最优化。本文选用ID3算法, 以信息增益作为特征选择的核心准则——信息增益越大, 表明该特征对降低分类不确定性的贡献越显著。具体计算方式如下:

设交叉口训练样本集为 D (样本容量为 $|D|$, 即训练样本个数), 包含 K 种相位方案类型 $C_k (1, 2, \dots, K)$, 其中相位类型 C_k 的样本个数为 $|C_k|$; 对于离散型特征条件 A , 其有2种不同取值(0或1), 可将 D 划分为2个子集 D_1 和 D_2 (D_i 的样本个数为 $|D_i|$, 子集 D_i 中相位类型 C_k 的样本集为 D_{ik} , D_{ik} 的样本个数为 $|D_{ik}|$)。信息增益计算方法为:

$$g(D, A) = H(D) - H(D|A) \quad (4)$$

$$H(D) = - \sum_{k=1}^K \frac{|C_k|}{|D|} \log_2 \frac{|C_k|}{|D|} \quad (5)$$

$$H(D|A) = \sum_{i=1}^n \frac{|D_i|}{|D|} H(D_i) = - \sum_{i=1}^n \frac{|D_i|}{|D|} \sum_{k=1}^K \frac{|D_{ik}|}{|D_i|} \log_2 \frac{|D_{ik}|}{|D_i|} \quad (6)$$

式中: $g(D, A)$ 为特征条件 A 对样本集 D 的信息增益; $H(D)$ 为样本集 D 的经验熵, 反映对 D 中样本进行相位方案分类的不确定性; $H(D|A)$ 为特征条件 A 对 D 的条件经验熵, 反映在条件约束下的分类不确定性。 $H(D)$ 与 $H(D|A)$ 的差值即为信息增益。

2) 确定最优切分点。

对于连续型取值的交叉口动态特征, 本文参考分类与回归树(Classification and Regression Tree, CART)模型对连续变量的切分思路, 结合ID3算法的经验熵指标, 采用启发式切分方法确定最优切分点。设第 j 个连续变量为 $x^{(j)}$, 以其在样本集 R 中的某个取值 s 作为切分点, 可将样本集分割成两个子集: $R_1(j, s) = \{x | x^{(j)} \leq s\}$, $R_2(j, s) = \{x | x^{(j)} > s\}$, 然后遍历 R 中所有样本 $x^{(j)}$ 的可能取值, 寻找 $x^{(j)}$ 的最优切分

点, 具体求解:

$$\operatorname{argmin}_s [H(R_1) + H(R_2)] \quad (7)$$

式中: $H(R_i)$ 为子集 R_i 的经验熵。

3) 决策树的生成算法流程。

基于上述逻辑, 相位方案推荐决策树的生成算法流程如下(特别设计多方案推荐机制): 每个叶结点标记各类相位方案的样本数量占比, 作为推荐置信度, 为设计者提供备选方案。

- ① 输入训练数据集 D (包含特征集 B);
- ② 若 D 中样本相位类型均为同一类 C_k , 则决策树 T 为单结点树, 标记为 C_k 并输出 T ;
- ③ 若 $B = \phi$, 则 T 为单结点树, 标记 D 中各类相位方案及其样本数量占比并输出 T ;
- ④ 否则, 按照式(4)~(7)计算各特征条件对 D 的信息增益, 选择信息增益最大的特征 A_g ;
- ⑤ 若 A_g 的信息增益等于0, 则置 T 为

单结点树, 标记 D 中各类相位方案及其样本数量占比并输出 T ;

⑥ 否则, 按 A_g 的每个取值(如为连续变量, 则指基于切分点的取值范围) $a_i (i=1, 2)$ 将 D 分割为两个非空子集 D_1 和 D_2 , 构建两个子结点, 由结点及其子结点构成树 T , 并输出 T ;

⑦ 对第 $i (i=1, 2)$ 个子结点, 以 D_i 为训练集, 以 $B - \{A_g\}$ 为特征集, 递归执行步骤①~⑥, 得到子树 T_i 并输出。

1.3.2 决策树剪枝与增强型可解释性设计

1) 剪枝策略。

为避免决策树因过度拟合训练数据导致泛化能力下降, 需通过剪枝过程实现模型复杂度与拟合效果的平衡, 其核心是极小化损失函数。定义损失函数为:

$$\begin{aligned} C_\alpha(T) &= \sum_{t=1}^{|T|} N_t H_t(T) + \alpha |T| \\ &= - \sum_{t=1}^{|T|} \sum_{k=1}^K N_{tk} \log_2 \frac{N_{tk}}{N_t} + \alpha |T|, \quad (8) \\ &= C(T) + \alpha(T) \end{aligned}$$

式中: $C_\alpha(T)$ 为整体损失函数; $C(T)$ 为模型对训练样本集的拟合程度; N_t 为树 T 的叶结点 t 包含的交叉口样本数量/个; $H_t(T)$ 为叶结点 t 上的经验熵; $\alpha \geq 0$ 为正则化参数, 用于权衡模型拟合程度与复杂度之间的关系; $|T|$ 为树 T 的叶结点数量/个, 代表模型复杂度; N_{tk} 为叶结点 t 中相位方案类型为 C_k 的样本数量, $k=1, 2, \dots, K$ 。

决策树的剪枝过程具体步骤如下:

① 输入算法生成的原始决策树 T 和参数 α ;

② 计算每个结点的经验熵;

③ 从树的叶结点开始向上递归回缩。设一对叶结点回缩至该父结点之前与之后的整体树分别为 T_A 和 T_B , 其对应的损失函数分别为 $C_\alpha(T_A)$ 和 $C_\alpha(T_B)$ 。若 $C_\alpha(T_B) \leq C_\alpha(T_A)$, 则进行剪枝(即将该父结点变为新的叶结点, 并更新该叶结点的分类标记);

④ 重复步骤③, 直至所有叶结点均不满足剪枝条件, 得到损失函数最小的子树 T_α 。

2) 增强型可解释性设计。

① 规则可视化: 将决策树的分支逻辑转化为“if-then”工程化规则, 例如“若交叉口类型为十字形(特征 $1=0$)、左转信号控制灯组为专用保护相位(特征 $6=1$)、 $DR_3 < 0.49$,

则推荐相位方案 6(置信度 80.95%)”, 便于工程师理解与应用。

② 置信度标注: 每个叶结点不仅输出推荐相位方案, 还标注各类方案的置信度, 例如“相位方案 8(置信度 95.45%)、相位方案 9(置信度 4.55%)”, 为工程师提供多方案选择空间, 兼顾 AI 推荐的精准性与工程决策的灵活性。

1.3.3 交叉验证推荐最优子树

应用不同参数 α 进行剪枝会得到不同的子树。为确定最优决策树, 需利用测试样本集对各子树进行交叉验证。具体流程为:

1) 子树序列生成: 记逐渐增大 α 值进行剪枝所获得的不同子树构成的序列为 T_0, T_1, \dots, T_n 。利用各子树对相同测试集中的交叉口样本进行相位方案推荐, 并计算各子树的测试评价指标, 用于后续对比。

2) 评价指标计算: 采用受试者工作特征(Receiver Operating Characteristic, ROC)曲线评价不同子树的测试效果, 通过计算其曲线下面积(Area Under the Curve, AUC)进行对比。本算法所生成的决策树为多分类二叉决策树, 故采用微平均法(micro-averaging)计算 ROC-AUC, 具体步骤如下:

① 将测试集样本的相位方案类型进行 one-hot 编码, 得到一个维度为 $m \times n$ 的标签矩阵 L (其中 m 为样本数量, n 为相位方案类型数), 矩阵 L 中的元素取值为 0 或 1;

② 利用子树 T_α 对测试集样本进行相位方案推荐。根据上述设定的生成算法, T_α 在相应的叶结点为每个测试交叉口样本推荐一种或多种相位方案, 并输出各方案的置信度, 由此得到维度为 $m \times n$ 的测试结果矩阵 P , 该矩阵每行数值为 T_α 对每个测试样本推荐的各类相位方案的置信度;

③ 将矩阵 L 和 P 分别按行展开, 得到两个长度均为 $m \times n$ 的列向量(二者元素一一对应), 从而将多分类问题转化为二分类问题, 进而依据二分类 ROC 计算方法求得每个子树 T_α 的 ROC-AUC 值。

3) 最优子树选择: 选择 ROC-AUC 值最大的子树作为最终的相位方案推荐模型。

2 案例应用

2.1 样本数据与实验设计

本研究采集了北京、桐乡、潮州等城市




图3 实际交叉口样本信号相位方案类型分布

Fig.3 Distribution of signal phase plan types in observed intersection samples

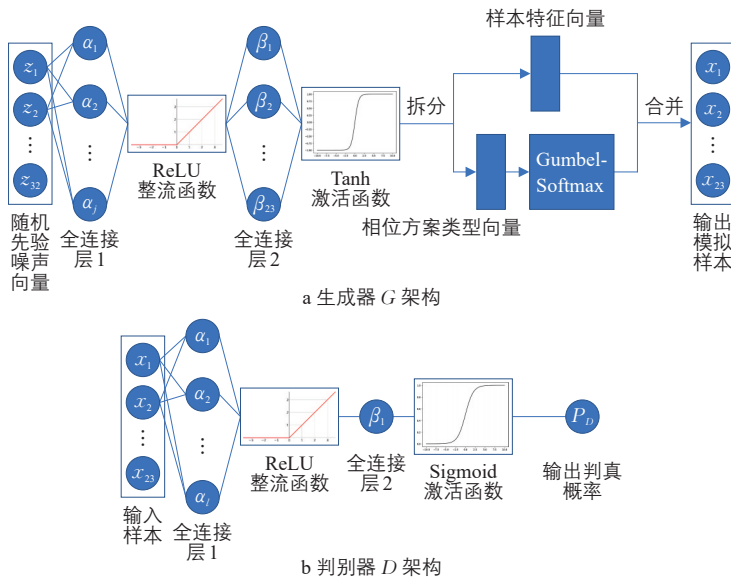


图4 GAN网络架构示意

Fig.4 Schematic diagram of the GAN architecture




图5 V, P_{D-G} 和 MMD 曲线

Fig.5 Curves of V, P_{D-G} and MMD

共计 159 组交叉口样本，其中十字形交叉口 121 组、T 形交叉口 38 组，覆盖表 2 所列的全部 9 种相位设置方案类型，其分布情况如图 3 所示。根据每组交叉口样本的特征条件，按照表 1 进行取值，形成每个样本的特征向量 $\{p_1, p_2, \dots, p_{13}\}$ ；样本的 9 种相位方案类型则构成输出空间。实验采用固定测试集与多组训练集，通过控制变量法验证算法性能。

2.2 GAN 模型扩样应用

2.2.1 GAN 网络架构设计与实现

首先对每个交叉口相位方案类型进行 one-hot 编码，得到相位方案类型向量 $\{q_1, q_2, \dots, q_9\}$ ， $q_i = 0$ 或 1，并将其与特征向量 $\{p_1, p_2, \dots, p_{13}\}$ 组合，形成 22 维样本信息向量 $S = \{p_1, p_2, \dots, p_{13}, q_1, q_2, \dots, q_9\}$ 。

基于 PyTorch 框架搭建的 GAN 模型采用轻量化网络架构，在保证生成精度的同时提升训练效率，其核心组件设计如下：

1) 生成器 G 包含两个全连接层，如图 4a 所示。32 维随机先验噪声首先经全连接层 1 展开为 128 维张量，经 ReLU 激活后输入至全连接层 2，输出 22 维张量。该张量经 Tanh 激活函数激活后，对其中的相位方案类型分量通过 Gumbel-Softmax 层进行处理，最后输出表示完整样本信息的张量。

2) 判别器 D 同样包含两个全连接层，如图 4b 所示。其接收真实交叉口样本或生成器生成的样本张量，经全连接层 1 展开为 64 维张量，经 ReLU 激活后输入至全连接层 2，输出 1 维数值，最后经 Sigmoid 激活函数处理后输出样本为真实样本的概率。

2.2.2 模型训练与收敛验证

针对交叉口样本量有限的特点，采用 Full-batch 训练方式(一次性输入全部样本计算梯度)，确保模型充分学习样本分布特征。记录训练过程中模型的价值函数 V 、判别器 D 对生成器 G 所生成样本判别为真实样本的概率 P_{D-G} ，以及生成样本与训练样本之间的最大平均差异值(MMD)，结果如图 5 所示。可以看出，当模型迭代训练接近 3 万次时， V 逐渐趋于稳定， P_{D-G} 稳定在 0.5 左右，且 MMD 值逐渐降低并稳定在 0.2 以下。各项指标均满足收敛条件，因此停止训练并保存生成器参数。

2.2.3 生成样本的分布情况

利用已完成训练的生成器生成 15 900 个虚拟样本(为原始 159 个样本的 100 倍)。经有效性筛选后,得到有效样本 15 104 个,有效率为 95%。其中剔除了 796 个相位类型与交叉口静态条件相矛盾的无效样本。

从生成的相位方案类型分布来看(见图 6),生成样本与真实样本的类型占比高度吻合,为后续决策树的训练提供了类别分布均衡且样本量丰富的数据集。

2.3 决策树模型应用

为验证 GAN 生成样本对决策树性能的提升作用,本研究设计了多组对比实验,通过系统的样本划分、模型训练与指标评估,确定了最优训练策略,并输出最终的决策树模型。

2.3.1 样本划分与实验设计

针对真实样本集 S_c 中交叉口特征条件与相位方案类型分布不均衡的问题,从 GAN 模型生成的有效交叉口样本中随机选取 450 个样本(每类相位方案各选取 50 个),组成 GAN 样本集 S_g ,与 S_c 共同构成训练数据池。为量化生成样本的增益效果,采用以下实验设计:

1) 测试集固定化:从 S_c 与 S_g 中随机各抽取 20% 样本,组成固定的测试样本集 S_{test} (共 121 个样本),该测试集覆盖上述 9 类相位方案,以消除测试数据分布差异对结果的干扰;

2) 训练集比例化:将 S_c 与 S_g 中剩余的 80% 样本共同作为训练集 S_{train} ,通过调整 S_g 样本在 S_{train} 中的占比(0%~100%),构建多组训练数据;

3) 模型统一化:对每组 S_{train} 采用相同参数训练决策树并进行最优剪枝,利用剪枝后的最优子树对测试集 S_{test} 中的交叉口进行相位方案推荐测试,分别计算其 ROC-AUC 值,结果如图 7 所示。

2.3.2 实验结果与分析

图 7 直观呈现了不同样本组合下的模型性能,其中绿色区域表示 AUC 值较大,红色区域表示 AUC 值较小,灰色部分因对应样本组合的占比过小而暂不考虑。结果表明:

1) 单一样本训练的局限性:仅使用 S_c (不含生成样本)或仅使用 S_g (不含真实样本)

训练的决策树,其 AUC 值均低于 0.75,表明无论仅使用稀缺的真实样本,还是仅使用生成的虚拟样本,均会导致模型泛化能力不足;

2) 融合样本的协同增益:当训练集 S_{train} 同时包含全部 S_c 和 S_g 样本时,AUC 值较单一样本训练提升 15%~25%,验证了 GAN 样本扩增与决策树推理的协同效应。最终选择 AUC 最大的子树作为最优模型,实现了“数据质量提升—模型性能优化”的正向循环。

2.3.3 最优决策树模型输出

基于上述实验结论,使用全部 S_c 和 S_g 样本训练决策树,经剪枝后得到最优子树,如图 8 所示。该树的叶结点不仅标记了推荐




图 6 实际样本与生成样本信号相位方案类型分布对比

Fig.6 Comparison of signal phase plan type distributions between observed and generated samples




图 7 不同抽取比例决策树 ROC-AUC 值对比

Fig.7 Comparison of ROC-AUC values of decision trees under different sampling ratios

方向的交通运行效益显著提升。具体表现为：平均排队长度总体缩短12.3%，平均停车次数总体减少11.5%，验证了本算法的工程实践价值。

3 结束语

本文的核心创新点在于实现AI算法与交通工程实践的深度融合，即算法设计并非简单的技术套用，而是紧密结合交通系统的物理约束与运行规律，从而实现从“黑箱”预测到“白箱”决策的跨越。主要创新点如下：

1) 融合创新架构。突破传统单一算法的局限性，提出“GAN样本扩增-决策树推理”双层架构，有效解决交通样本稀缺与AI模型可解释性不足的难题，实现数据驱动与机理约束的有机统一。

2) 理论突破。通过将交通物理约束(如通行能力、排队长度)融入GAN的收敛性条件，确保生成数据符合交通系统的基本规律；论证了GAN在交通场景下的收敛条件，量化了决策树的特征重要性，为AI算法在交通领域的应用提供理论支撑。

3) 工程价值。该模型可广泛适用于十字形交叉口与T形交叉口，实证结果表明算法可显著提升交叉口运行效益，具备工程化推广潜力，为城市交通信号控制的智能化升级提供新路径。此外，其样本扩充机制与决策逻辑可延展至复杂路网，为多交叉口协同控制提供思路，为智能交通信号优化提供实用范式与理论基础。

参考文献：

References:

[1] 魏丽英, 丁黎容, 艾子妍, 等. 面向相位动态优化的交叉口智能控制方法[J]. 北京交通大学学报, 2023, 47(5): 136-147.
Wei Liying, Ding Canrong, Ai Ziyang, et al. Intelligent control method of signalized intersection based on dynamic phase optimization[J]. Journal of Beijing Jiaotong University, 2023, 47(5): 136-147.

[2] 梁子君. 基于交通流组合相位控制逻辑的信号优化控制研究[D]. 西安: 长安大学, 2018.
Liang Zijun. Research on signal optimization control based on the control logic of overlap-

表4 案例交叉口信号相位配时方案

Tab.4 Signal timing for intersections in case study

s

交叉口	相位周期	相位方案	相位配时方案				
后厂村路— 上地西路	140	原相位方案					
		推荐相位方案	40	35	40	25	25
信息路— 农大南路	120	原相位方案					
		推荐相位方案	56	36	28 ¹⁾	28	28
上地三街— 信息路	140	原相位方案					
		推荐相位方案	43	37	38	22	22
世纪大道— 中山路	120	原相位方案					
		推荐相位方案	43	28	29	20	20
世纪大道— 校场路	130	原相位方案					
		推荐相位方案	23	30	25	28	24
庆丰路— 校场路	140	原相位方案					
		推荐相位方案	42	26	42	30	30
		原相位方案					
		推荐相位方案	26	19	23	42	30

1) 南、北进口行人需要最短相位时长为28 s。

ping phase of the traffic flow[D]. Xi'an: Chang'an University, 2018.

[3] 刘伟, 肖文彬, 王奥博. 信号交叉口控制相位的流线动态优化组合方法[J]. 交通运输系统工程与信息, 2015, 15(2): 68-75.
Liu Wei, Xiao Wenbin, Wang Aobo. Optimization-based methods for dynamic schemes of movement in control phases at signalized intersections[J]. Journal of Transportation Systems Engineering and Information Technology, 2015, 15(2): 68-75.

[4] Lu Kai, Lin Guanrong, Xu Jianmin, et al. Simultaneous optimization model of signal phase design and timing at intersection[C]. International Conference on Transportation and Development 2018: Traffic and Freight Opera-




图9 应用推荐相位方案前后交叉口的交通运行数据对比

Fig.9 Comparison of traffic operational data before and after applying the recommended signal phase plans

(上接第47页)

[9] 殷炬元, 黎淘宁, 孙剑. 网联环境下基于可选相位优化框架的公交信号优先[J]. 同济大学学报(自然科学版), 2023, 51(3): 395-404. Yin Juyuan, Li Taoning, Sun Jian. Transit signal priority based on optional phase optimization framework in connected vehicle environment[J]. Journal of Tongji University (Natural Science), 2023, 51(3): 395-404.

[10] Long Meng, Zou Xiexin, Zhou Yue, et al. Deep reinforcement learning for transit signal priority in a connected environment[J]. Transportation Research Part C: Emerging Technologies, 2022, 142: 103814.

[11] Yu Jiajie, Laharotte P A, Han Yu, et al. Decentralized signal control for multi-modal

tions and Rail and Public Transit, American Society of Civil Engineers, 2018: 65-74.

[5] Korkmaz E, Akgüngör A P. Optimizing of phase plan, sequence and signal timing based on flower pollination algorithm for signalized intersections[J]. Soft Computing, 2021, 25(6): 4243-4259.

[6] Yao Ronghan, Zhou Hongmei, Ge Yingen. Optimizing signal phase plan, green splits and lane length for isolated signalized intersections [J]. Transport, 2018, 33(2): 520-535.

[7] Chu Tianshu, Wang Jie, Codecà L, et al. Multi-agent deep reinforcement learning for large-scale traffic signal control[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(3): 1086-1095.

[8] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets[J]. Advances in Neural Information Processing Systems, 2014, 27: 2672-2680.

[9] Camino R, Hammerschmidt C, State R. Generating Multi-Categorical Samples with Generative Adversarial Networks[J/OL]. arXiv, 2018. DOI:10.48550/arXiv.1807.01202.

[10] Jang E, Gu S, Poole B. Categorical Reparameterization with Gumbel-Softmax[J/OL]. arXiv, 2016. DOI:10.48550/arXiv.1611.01144.

[11] Kusner M J, Hernández-Lobato, José Miguel. GANS for Sequences of Discrete Elements with the Gumbel- softmax Distribution[J/OL]. arXiv, 2016. DOI:10.48550/arXiv.1611.04051.

traffic network: a deep reinforcement learning approach[J]. Transportation Research Part C: Emerging Technologies, 2023, 154: 104281.

[12] Panwai S, Dia H. Comparative evaluation of microscopic car-following behavior[J]. IEEE Transactions on Intelligent Transportation Systems, 2005, 6(3): 314-325.

[13] Jiang Xiancai, Shang Qingpeng. A dynamic CAV-dedicated lane allocation method with the joint optimization of signal timing parameters and smooth trajectory in a mixed traffic environment[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(6): 6436-6449.