文章编号:1673-0291(2026)04-0178-13 **DOI**:10.11860/j.issn.1673-0291.20260020

快速路合流区风险势能谱聚类与异构协同牵制控制

饶江华,晏 松,王景升,史丹煜,李昭江
(中国人民公安大学 交通管理学院,北京 100038)

摘 要:针对快速路合流区网联自动驾驶车辆(Connected and Automated Vehicles,CAV)与人工驾驶车辆(Human-Driven Vehicles,HDV)混合交通流在对抗性扰动下的脆弱性与非线性特征问题,提出一种基于风险势能谱聚类(Risk Potential-Driven Spectral Clustering,SC-Risk)的异构协同牵制控制方法.首先,基于信息物理系统(Cyber-Physical Systems,CPS)视角与复合风险场理论,构建风险驱动的车辆群体动态网络模型,量化节点间的非对称风险耦合强度;然后,改进传统谱聚类算法,提出最大风险势能覆盖策略,通过特征空间映射辨识高传播风险的致因节点,将其作为牵制节点;最后,构建"决斗深度Q网络(Dueling Deep Q-Network,Dueling DQN)领航+协同自适应巡航控制(Cooperative Adaptive Cruise Control,CACC)跟随"的异构分层控制协议,牵制节点利用强化学习执行防御决策阻断风险源,跟随节点采用CACC维持队形稳定性.研究结果表明:该策略将车队同步率提升至0.877 3,速度震荡指数降至3.55;通过主动截断交通激波的逆向传播,使拥堵时空影响域面积缩减73.3%,延误指数从2.54降至1.21,实现了合流区混合交通流的主动风险防控与协同优化.

关键词:智能交通;快速路合流区;混合交通流;风险势能谱聚类;异构牵制控制
中图分类号:U491.2 **文献标志码**:A

Risk-potential-based spectral clustering and heterogeneous cooperative pinning control in expressway merging areas

Rao Jianghua, *Yan Song*, *Wang Jingsheng*, *Shi Danyu*, *Li Zhaojiang*
(School of Traffic Management, People's Public Security University of China, Beijing 100038, China)

Abstract: To address the vulnerability and nonlinear characteristics of mixed traffic flows comprising Connected and Automated Vehicles (CAV) and Human-Driven Vehicles (HDV) under adversarial disturbances in expressway merging areas, this study proposes a heterogeneous cooperative pinning control method based on Risk Potential-Driven Spectral Clustering (SC-Risk). First, from the perspective of Cyber-Physical Systems (CPS) and based on composite risk field theory, a risk-driven dynamic network model of vehicle groups is developed to quantify the asymmetric risk coupling strength between nodes. Second, the conventional spectral clustering algorithm is improved by introducing a maximum risk-potential coverage strategy, which identifies causal nodes with high-risk propagation potential as pinning nodes through feature-space mapping. Finally, a heterogeneous hierarchical control protocol

收稿日期:2026-01-26;**修回日期**:2026-04-27
基金项目:国家重点研发计划(2023YFB4302701);中国人民公安大学拔尖创新人才培养经费支持研究生科研创新项目(2026yjsky026)
Foundation items: National Key R&D Program of China (2023YFB4302701); Top-Notch Innovative Talent Training Fund (Graduate Research Innovation General Program) of the People's Public Security University of China (2026yjsky026)
第一作者:饶江华(2002—),男,江西抚州人,硕士生.研究方向为智能交通研究.**email**:1078170092@qq.com.
通信作者:晏松(1990—),男,云南曲靖人,讲师,博士.**email**:20216947@ppsuc.edu.cn.

引用格式:饶江华,晏松,王景升,等.快速路合流区风险势能谱聚类与异构协同牵制控制[J].北京交通大学学报,2026,50(4):178-190.
Rao Jianghua, Yan Song, Wang Jingsheng, et al. Risk-potential-based spectral clustering and heterogeneous cooperative pinning control in expressway merging areas[J]. Journal of Beijing Jiaotong University, 2026, 50(4): 178-190. (in Chinese)

combining Dueling Deep Q-Network (Dueling DQN)-based leading control with Cooperative Adaptive Cruise Control (CACC)-based following control is established. The pinning nodes employ reinforcement learning to make defensive decisions and contain risk sources, while the following nodes adopt CACC to maintain string stability. The results demonstrate that the proposed strategy increases the platoon synchronization rate to 0.877 3 and reduces the speed oscillation index to 3.55. By actively interrupting the upstream propagation of traffic shockwaves, it reduces the spatiotemporal impact area of congestion by 73.3% and decreases the delay index from 2.54 to 1.21. The proposed method therefore enables proactive risk prevention and cooperative optimization of mixed traffic flows in expressway merging areas.

Keywords: intelligent transportation; expressway merging area; mixed traffic flow; risk-potential-driven spectral clustering; heterogeneous pinning control

城市快速路合流区作为路网中的关键瓶颈节点,其交通流运行效率直接决定了整个路网的服务水平.随着智能交通系统的快速发展,网联自动驾驶车辆(Connected and Automated Vehicles,CAV)与人工驾驶车辆(Human-Driven Vehicles,HDV)长期共存的混合交通流已成为不可逆转的趋势[1-3].虽然CAV的引入有望通过精确的感知与控制能力提升道路容量,但在合流区这一存在剧烈强制性换道博弈的场景中,交通流呈现出明显的随机性与非线性特征[4].特别是当交通系统中存在恶意对抗性攻击(Adversarial Attacks)或极端驾驶行为干扰时,单一车辆的异常机动易引发“蝴蝶效应”,导致交通激波(Shockwave)逆向传播,进而诱发大范围拥堵甚至连环事故[5-6].因此,如何在混合交通流环境下,利用部分CAV的协同控制能力来主动阻断风险传播并平抑交通震荡,已成为当前学术界与工业界关注的焦点.

合流区因其特殊的拓扑结构,是车辆交互冲突的高发地.影响该区域混合交通流演化的因素具有多维异构特征:在空间拓扑方面,车辆交互受时空缝隙与碰撞时间(Time to Collision,TTC)的双重强制性约束;在群体构成方面,CAV与HDV共存的异质性驾驶风格显著加剧了微观交互的不确定性;在动态环境方面,突发交通事故或恶意对抗性攻击等极端扰动极易打破微观平衡.文献[7]通过无人机数据分析发现,合流区的车辆交互行为受时空缝隙与TTC的双重约束,且混合交通流中的异质性驾驶风格加剧了交互的不确定性.文献[8]在描述此类瓶颈处的拥堵演化时指出,传统的交通波理论往往难以量化微观行为对宏观流场的具体影响.因此,文献[9-10]引入了信息物理系统(Cyber-Physical Systems,CPS)视角,揭示了混合交通流本质上是一个动态耦合网络,车辆间的跟驰与通信构成了时变的物理拓扑,任何节点的扰动都可能通过该拓扑被放大或衰减.文献[11]进一步从韧性视角剖析了路网拥堵特性,强调提升关键节点对扰动的吸收能力是恢复路网功能的关键.

针对交通震荡的抑制问题,现有的控制策略主要分为基于规则的队列控制与基于学习的协同优化两类.文献[12]集中于协同自适应巡航控制(Cooperative Adaptive Cruise Control,CACC),试图通过缩短车间距来提升弦稳定性(String Stability).文献[13-14]结合复杂博弈场景分析表明,传统的CACC在面对强非线性扰动时往往表现出滞后性,难以应对多切入机制下的复杂博弈.文献[15]指出,基于深度强化学习(Deep Reinforcement Learning,DRL)的控制方法因其强大的非线性拟合能力而备受青睐.然而,大多数现有研究假设所有车辆均为合作代理,忽略了现实中可能存在的网络安全威胁.文献[16]针对自动驾驶系统的安全隐患展开评估,指出针对自动驾驶系统的对抗性攻击(如恶意急刹、虚假数据注入)已成为不可忽视的安全隐患,而现有的协同控制框架普遍缺乏对“恶意致因”的主动防御机制.

为了以最小的控制代价实现全局优化,牵制控制(Pinning Control)理论被引入交通系统,其核心思想是控制网络中的少量关键节点以引导系统趋同.文献[17]提出一种基于谱聚类的牵制控制策略,利用运动学特征将车流划分为子群并控制头车.现有策略多基于拓扑结构或运动学特征选取关键节点,却忽略了风险传播的物理机制.文献[18]探讨了交通事故时空影响的动态效应.文献[19]则结合事故数据分析揭示,风险的源头往往并非拓扑中心,而是具有高势能的“致因节点”.若无法精准识别并控制这些风险源,单纯的队形保持反而可能加速风险的级联扩散[20].此外,尽管复合风险场(Composite Risk Field,CRF)与结合对抗博弈的决斗深度Q网络(Du-

eling Deep Q-Network, Dueling DQN)模型在提升单车微观风险感知与防御决策方面具备基础优势，但如何将微观层面的单体防御能力转化为宏观车队的协同抗扰策略，特别是在面临对抗性攻击时，实现关键节点的有效识别与异构策略分配，仍是当前亟待解决的难题.

本文针对上述微观博弈与宏观协同的脱节问题，基于所构建的微观单车模型，提出一种基于风险势能谱聚类(Risk Potential-Driven Spectral Clustering, SC-Risk)的异构协同牵制控制架构.首先，构建风险驱动的动态网络模型，突破传统距离拓扑限制，基于复合风险场势能构建车辆交互网络.通过风险耦合权重刻画交通激波的逆向传播机理，以动态捕捉风险的级联路径；然后，提出SC-Risk关键节点识别算法.改进传统谱聚类算法，将风险势能引入特征空间，实现对高传播风险车辆子群的靶向划分与锁定，最后，设计异构分层牵制控制策略.构建“Dueling DQN领航+CACC跟随”的闭环协同架构.利用已训练的Dueling DQN智能体接管牵制节点，以主动阻断风险源，协同CACC跟随节点吸收残余震荡，实现从局部风险消解到全局交通流稳定的链路优化.

1 理论基础

实现宏观车队的协同牵制控制，其前提是系统内的单体智能车辆(Agent)必须具备对复杂物理环境的敏锐感知能力与在对抗博弈下的鲁棒决策能力.构建复合风险场模型作为环境感知的数学基准，并引入基于对抗博弈训练的Dueling DQN智能体作为牵制控制的底层执行机构.

1.1 复合风险场与节点势能量化

为克服传统基于距离(Distance-based)或TTC等离散指标在描述连续动态交通流时的局限性，引入复合风险场(Composite Risk Field, CRF)理论.该理论利用人工势场法，借鉴并改进了经典的行车安全场理论[21]，将交通空间中多源异构的危险因素映射为连续可微的标量势能场，为后续的网络拓扑建模提供物理量化依据.

为量化任意空间位置的综合风险，引入总风险势能$E_i(x,y,t)$，由车辆场、道路场及事件场线性叠加为

$$E_i(x,y,t)=w_{\text{vehicle}}\sum_{i\in M}E_{\text{vehicle},i}(x,y,t)+w_{\text{road}}E_{\text{road}}(x,y)+w_{\text{event}}E_{\text{event}}(x,y,t) \tag{1}$$

式中：$E_i(x,y,t)$为车辆i在时刻t的空间位置(x,y)处的总风险势能，i为车辆索引；x和y分别为空间位置坐标，m；t为时间，s；w_{vehicle}为车辆风险场权重系数；M为场景中相关车辆或节点的集合；$E_{\text{vehicle},i}(x,y,t)$为第$i$辆车在位置$(x,y)$、时刻$t$产生的车辆风险势能场；$w_{\text{road}}$为道路风险场权重系数；$E_{\text{road}}(x,y)$为位置$(x,y)$处的道路风险势能场；$w_{\text{event}}$为事件风险场权重系数；$E_{\text{event}}(x,y,t)$为位置$(x,y)$在$t$时刻的事件风险势能场.

针对高速运动的车辆实体，构建各向异性(Anisotropic)的广义高斯势能场.考虑到动能对碰撞破坏力的贡献，引入车辆等效质量与速度相关性，定义车辆i在空间点(x,y)产生的车辆风险势能场[22]为

$$E_{\text{vehicle},i}(x,y,t)=M_{\text{eq},i}(v_i)\cdot\exp\left(-\left[\left(\frac{x'}{\sigma_{\text{X}}(v_i)}\right)^2+\left(\frac{y'}{\sigma_{\text{Y}}(v_i)}\right)^2\right]^{\eta}\right) \tag{2}$$

式中：$M_{\text{eq},i}(v_i)$为第i辆车的等效作用质量，kg；v_i为第i辆车的速度，m/s；$\exp(\cdot)$为自然指数函数；x'和y'分别为车辆局部坐标系中的纵向坐标和横向坐标，m；$\sigma_{\text{X}}(v_i)$和$\sigma_{\text{Y}}(v_i)$分别为第i辆车风险场在局部纵向和横向的传播尺度参数，m；η为形状因子.

道路风险场$E_{\text{road}}(x,y)$由道路边界的强斥力场$E_{\text{boundary}}(d)$和车道标线的弱约束场E_{lane}组成，$E_{\text{boundary}}(d)$采用改进风险场模型中经典的指数函数形式[5]以实现边界的“虚拟护栏”效应，其表达式为

$$E_{\text{boundary}}(d)=A_{\text{road}}\cdot\exp\left(-\frac{d^2}{2\sigma_{\text{road}}^2}\right) \tag{3}$$

式中：$E_{\text{boundary}}(d)$为道路边界风险势能场；d为车辆到道路边缘的横向距离，m；A_{road}为道路边界风险场幅值系数；σ_{road}为道路边界风险场的扩散尺度参数，m.此外，针对突发事故或对抗智能体(Adversarial Agent, ADV)攻击源，构建事件风险场$E_{\text{event}}(x,y,t)$，其不仅具有高势能中心，还随时间t呈现动态扩散特征.

基于上述模型，车辆i在t时刻所承受的总风险势能$E_i(x,y,t)$可被精确计算.该指标将作为后续谱聚类算法的节点权重特征，用于识别高风险致因节点.

1.2 基于Dueling DQN的强鲁棒性换道模型

为了使被选中的牵制节点(Pinning Node)能够有效应对ADV的恶意干扰并引导车队脱困，必须赋予其超越规则(Rule-based)的高阶决策能力.建立采用Dueling DQN架构构建的微观换道决策模型.

不同于仅输入运动学参数的传统方法，将1.1

节计算的实时风险值直接映射至马尔可夫决策过程(Markov Decision Process,MDP)的状态空间S中.定义t时刻的状态向量$\boldsymbol{s}_t$为

$$\boldsymbol{s}_t=\left[v_{\text{ego}},a_{\text{ego}},y_{\text{ego}},v_{\text{lead}},\Delta x_{\text{lead}},v_{\text{lag}},\Delta x_{\text{lag}},\cdots,E_{\text{ego}}(t)\right]^{\mathrm{T}} \tag{4}$$

式中:$\boldsymbol{s}_t$为t时刻的强化学习状态向量,且$\boldsymbol{s}_t$为12维向量;v_{ego}为自车速度,m/s;a_{ego}为自车加速度,m/s^2;y_{ego}为自车横向位置,m;v_{lead}为前车速度,m/s;Δx_{lead}为自车与前车的纵向间距,m;v_{lag}为后车速度,m/s;Δx_{lag}为自车与后车的纵向间距,m;$E_{\text{ego}}(t)$为自车在t时刻的总风险势能;$(\cdot)^{\mathrm{T}}$为转置算子.

这种显式的风险输入使得智能体能够感知物理空间中不可见的"危险梯度".为了在合流区复杂的高维状态空间中评估动作价值,模型采用双流(Two-stream)网络结构.网络末端解耦为状态价值流$V(s,\theta_{\text{M}})$和动作优势流$A(s,a,\theta_{\text{N}})$,并通过聚合层输出动作价值函数为

$$Q(s,a,\theta)=V(s,\theta_{\text{M}})+A(s,a,\theta_{\text{N}})-\frac{1}{|N|}\sum_{a'\in N}A(s,a,\theta_{\text{N}}) \tag{5}$$

式中:$Q(s,a,\theta)$为动作价值函数;θ为Dueling DQN的总体网络参数;$V(s,\theta_{\text{M}})$为状态价值函数;s为状态;θ_{M}为状态价值分支的网络参数;$A(s,a,\theta_{\text{N}})$为动作优势函数;a为动作;θ_{N}为动作优势分支的网络参数;N为动作集合;$|N|$为动作集合N中动作的数量;a'为动作索引.

该架构的优势在于能够独立评估"状态本身的安全性"(由$V(s,\theta_{\text{M}})$决定)和"特定动作的必要性"(由$A(s,a,\theta_{\text{N}})$决定).例如,在极高风险的拥堵状态下,$V(s,\theta_{\text{M}})$均较低,模型将更倾向于选择优势值$A(s,a,\theta_{\text{N}})$相对较大的防御性动作(如减速让行).

为引导智能体习得"风险厌恶"策略,设计包含风险惩罚的综合奖励函数为

$$R_t=\lambda_1R_{\text{eff}}+\lambda_2R_{\text{comf}}(t)+\lambda_3R_{\text{rule}}(t)-\lambda_4E_{\text{ego}}(t+1) \tag{6}$$

式中:R_t为t时刻的即时奖励;λ_1、λ_2、λ_3、λ_4为各即时奖励项的权重系数;$R_{\text{eff}}(t)$为t时刻的效率奖励项;$R_{\text{comf}}(t)$为t时刻的舒适性奖励项;$R_{\text{rule}}(t)$为t时刻的规则约束奖励项;$E_{\text{ego}}(t+1)$为自车在$t+1$时刻的总风险势能,用于构造风险惩罚项.

1.3　基于PPO的对抗博弈模型与训练验证

为确保Dueling DQN控制器在面对极端攻击时仍具备鲁棒性,引入基于PPO(Proximal Policy Optimization)算法的对抗代理(Adversarial Agent,ADV),构建"Ego-Adversary"零和博弈训练框架.

ADV代理的目标是在物理约束范围内最大化自车车辆(Ego)的碰撞风险.其策略网络$\varphi_{\theta_{\text{adv}}}$通过优化目标函数来生成最具威胁的攻击动作序列(如急刹、侧向挤压)

$$L^{\text{CLIP}}(\theta_{\text{adv}})=\hat{E}_t\Big[\min\left(r_t(\theta_{\text{adv}})\hat{A}_t,\text{clip}\left(r_t(\theta_{\text{adv}}),1-\varepsilon,1+\varepsilon\right)\hat{A}_t\right)\Big] \tag{7}$$

式中:$L^{\text{CLIP}}(\theta_{\text{adv}})$为对抗代理的PPO剪切目标函数;$\theta_{\text{adv}}$为对抗代理策略网络的参数;$\hat{E}_t[\cdot]$为基于采样$t$时刻的经验期望算子;$\min(\cdot)$为取最小值算子;$r_t(\theta_{\text{adv}})$为$t$时刻的新旧策略概率比;$\hat{A}_t$为$t$时刻的优势函数估计值;clip(·)为剪切函数;$\varepsilon$为剪切阈值参数.

PPO的截断机制(Clip)保证了攻击策略的更新步长在合理范围内,避免了训练坍塌.采用交替进化(Alternating Evolution)策略对Ego和ADV进行多轮次对抗训练.在每个决策时间t,Ego根据当前状态空间特征,通过Dueling DQN网络评估动作价值并输出最优防御动作A_{best};同时,ADV智能体通过PPO策略网络及局部优势函数值$\hat{A}_t$的引导,生成最具威胁的攻击动作$\hat{A}_{\text{best}}$.实验结果表明,该训练机制显著提升了决策模型的边界适应能力.训练情况如图1所示.由图1可知:在经过3回合对抗迭代后,Dueling DQN智能体在高强度攻击下的碰撞率(Collision Rate)从初始的28.5%降至4.2%,表现出较好的防御性驾驶特征;在面对未见过的混合攻击场景(如同时发生前车急刹与侧向切入)时,基于风险场的Dueling DQN模型依然保持了92%的换道成功率,显著优于未引入风险场的基准模型的76%.

通过构建复合风险场模型、设计Dueling DQN决策网络以及开展基于PPO的对抗博弈训练,构建了一套具备全域风险感知与极限工况鲁棒性的微观决策模型.经过对抗博弈的Dueling DQN智能体,将作为异构协同控制架构中的牵制点.模型的理论基础流程如图2所示,展示了复合风险场量化、Dueling DQN换道决策网络以及PPO对抗博弈训练的整体结构连接关系.

由图2可知:该理论框架构筑了从物理场感知到强化学习决策的完整闭环;左侧的复合风险场将多源交通要素量化为连续势能,直接映射为自车决策模型的风险状态输入;同时,依托SUMO仿真环境,自车(Dueling DQN)与对抗智能体(PPO)展开动态的零和博弈训练.这种风险驱动与对抗演进的

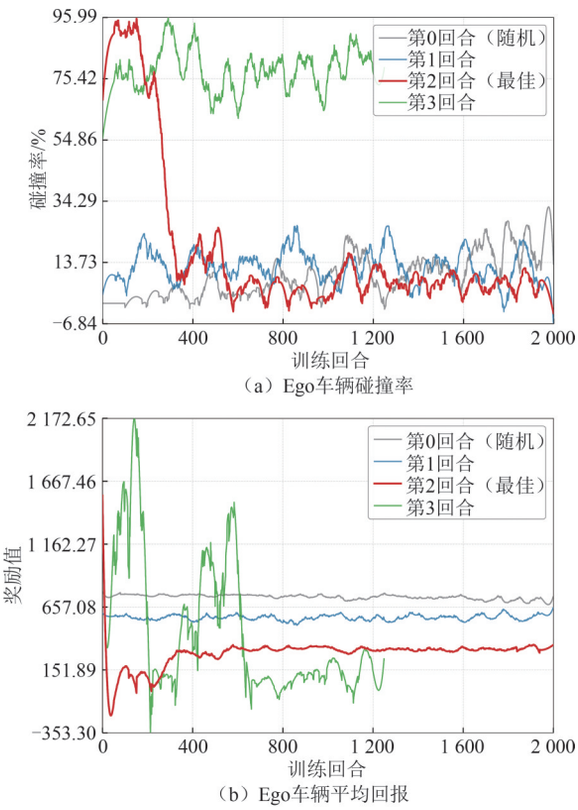


图 1　Ego 车辆训练情况

Fig.1　Training performance of the ego vehicle

深度融合，使系统不仅能精准捕获全域的危险梯度，更在面临极限工况与恶意扰动时展现出极强的鲁棒防御能力.

2　基于风险势能谱聚类的牵制控制方法

2.1　风险驱动的混合交通流动态网络建模

本文提出风险势能谱聚类算法（Risk Potential-Driven Spectral Clustering，SC-Risk），用于在混合交通流动态网络中精准识别高风险传播的致因节点，以此为基础构建异构协同牵制控制体系.该算法将复合风险场势能引入谱聚类的拓扑权重与特征空间构建，突破传统方法仅依赖运动学特征的局限，实现风险源头的靶向锁定.本节将依次阐述风险驱动的动态网络建模、SC-Risk 节点识别方法，以及分层异构牵制控制协议的设计.

在智能网联环境下，车辆群体不仅存在物理空间上的跟驰与换道耦合，更通过 V2X 通信构成了紧密的信息物理网络.为了从系统层面刻画风险传播的级联机理，研究将 t 时刻的车辆群体抽象为动态加权有向图为

$$\boldsymbol{G}(t)=\{\nu,\varepsilon(t),\boldsymbol{W}(t)\} \tag{8}$$

式中：$\boldsymbol{G}(t)$ 为 t 时刻的动态加权有向图；节点集 ν 涵盖了路段内所有异构车辆；$\varepsilon(t)$ 为 t 时刻的边集合；$\boldsymbol{W}(t)$ 为 t 时刻的邻接矩阵.

与传统研究仅基于欧氏距离或通信半径构建拓扑不同，混合交通流中节点间的耦合强度本质上取决于“风险传播的梯度”.基于所构建的复合风险场模型，定义邻接矩阵 $\boldsymbol{W}(t)$ 的元素 $a_{ij}(t)$ 为风险耦合

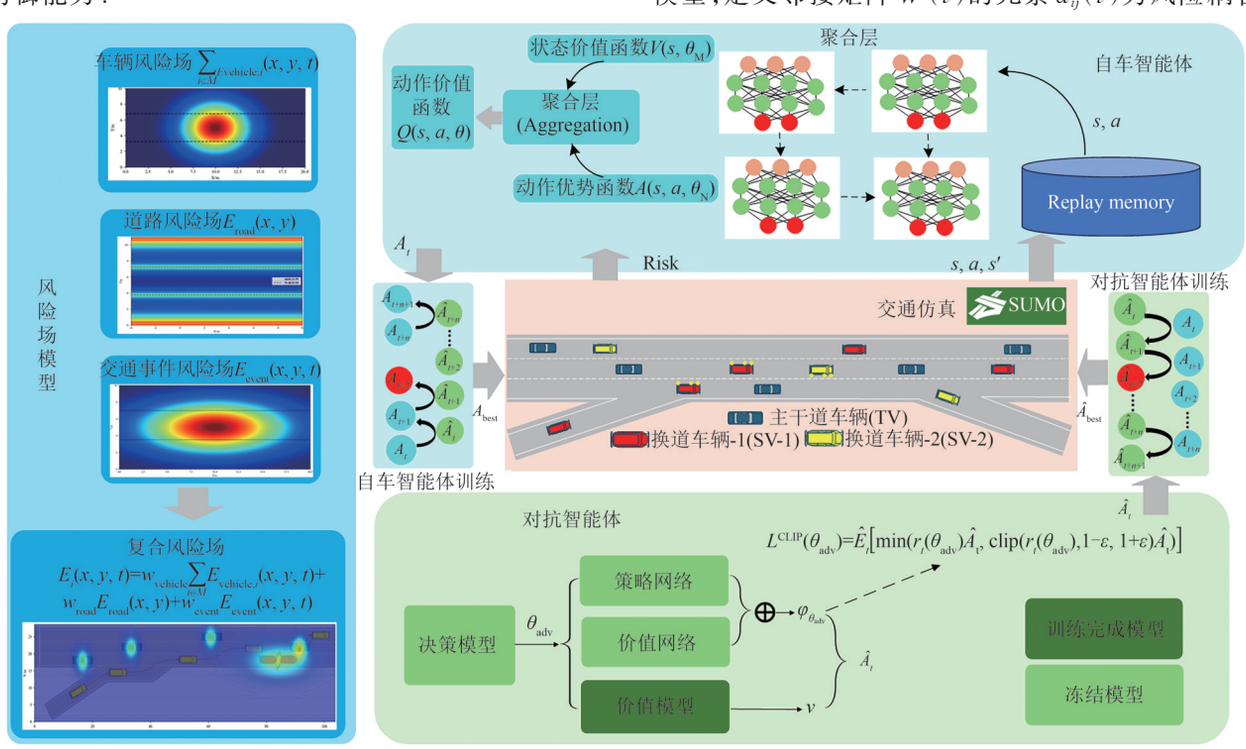


图 2　理论基础框架流程图

Fig.2　Flowchart of the theoretical framework

权重.该权重不仅需刻画车辆在纵向位置与速度状态上的运动学相似性,更需引入风险势能差函数$\Psi(\cdot)$以打破传统拉普拉斯矩阵的对称性,其关系式为

$$a_{ij}(t)=\exp\left(-\frac{\|\boldsymbol{f}_i(t)-\boldsymbol{f}_j(t)\|_2^2}{2\sigma_f^2}\right)\cdot\left[1+\chi\Psi\left(\frac{E_j(t)-E_i(t)}{E_{\max}(t)}\right)\right] \tag{9}$$

式中:$a_{ij}(t)$为t时刻节点i指向节点j的风险耦合权重;$\boldsymbol{f}_i(t)$和$\boldsymbol{f}_j(t)$分别为时刻t节点i和节点j的聚类特征向量;$\|\cdot\|$为欧氏范数;σ_f为特征相似核的尺度参数;χ为风险敏感系数;$\Psi(\cdot)$为风险势能差映射函数;$E_i(t)$和$E_j(t)$为节点i和节点j在t时刻的总风险势能;$E_{\max}(t)$为t时刻网络中节点风险势能的最大值.

这一数学构造的物理意义在于高风险车辆(如失控ADV)对周围邻居的耦合影响被显著放大,而其受到的反向约束则相对较弱.这种非对称的强耦合连接,刻画了交通激波逆向传播的动力学机制,为后续识别风险源头提供了坚实的拓扑学依据.

在构建风险加权网络后,问题的核心转化为如何从复杂的网络缠结中解耦出具有独立动力学特征的子系统.谱聚类(Spectral Clustering)方法本质上是通过寻找图拉普拉斯矩阵的特征向量空间,来揭示系统的"弱耦合界面".

为构造谱聚类所需的度矩阵,将t时刻的度矩阵表示为

$$\boldsymbol{D}(t)=\mathrm{diag}(d_1,d_2,\cdots,d_F) \tag{10}$$

式中:$\boldsymbol{D}(t)$为t时刻的度矩阵;$\mathrm{diag}(\cdot)$为对角矩阵生成算子;$d_1,d_2,\cdots,d_F$为各节点的加权度,即$d_i=\sum_{j=1}^{M}a_{ij}(t)$,$d_i$为节点$i$的加权度.

为刻画风险耦合网络的谱结构,定义标准化拉普拉斯矩阵为

$$\boldsymbol{L}_{\mathrm{sym}}(t)=\boldsymbol{I}-\boldsymbol{D}(t)^{-1/2}\boldsymbol{W}(t)\boldsymbol{D}(t)^{-1/2} \tag{11}$$

式中:$\boldsymbol{L}_{\mathrm{sym}}(t)$为$t$时刻的标准化拉普拉斯矩阵;$\boldsymbol{I}$为单位矩阵.

根据代数图论,$\boldsymbol{L}_{\mathrm{sym}}(t)$的特征值谱决定了网络的聚类特性.特别是Fiedler值λ_2及其对应的高阶特征向量,表征了将网络分割为若干子群所需的"切图代价"(Cut Cost).通过对前k个特征向量构成的特征空间进行K-means聚类,可将车辆群体划分为k个风险-运动同质子群$C=\{C_1,C_2,\cdots,C_k\}$.这一划分保证了子群内部车辆具有高度的风险同质性与运动同步性,而在子群之间则表现为弱耦合特征,从而为分而治之的控制策略提供了拓扑基础.

在每个识别出的风险子群C_k内部,为了有效抑制风险的级联扩散,需选取最具控制价值的节点实施牵制.传统的最大度中心性策略往往忽略了节点的致因属性,因此,提出最大风险势能覆盖策略来确定牵制节点集.选取兼具高风险势能与高传播影响力的节点p_k为

$$p_k=\arg\max_{i\in C_k}\left(\alpha\cdot E_i(x,y,t)+\beta\cdot\sum_{j\in C_k}a_{ij}(t)\right) \tag{12}$$

式中:p_k为第k个聚类簇中选取的牵制节点;$\arg\max(\cdot)$为使目标函数取得最大值时对应自变量的选择算子;C_k为第k个聚类簇对应的节点集合;α为风险势能项的权重系数;β为风险耦合的权重系数.

选出的牵制节点p_k具有双重属性,它既是子群中风险势能最高的,又是风险传播链上的核心枢纽(出度加权和最大).通过锁定并控制这一节点,系统能够以最小的代价切断风险在子群内部的倍增效应,实现最佳的控制效果.

2.2　异构车队牵制控制方法

确定牵制节点后,系统进入异构协同控制阶段.研究将混合交通流视为一个具有k个外部控制输入的复杂网络系统,并将其动力学行为描述为两类截然不同的控制协议.对于系统中的任意车辆i,其纵向动力学方程可统一描述为

$$\dot{v}_i(t)=f_{\text{car-following}}(v_i,\Delta x_{ir},\Delta v_{ir})+\delta(i\in P)\cdot u_i(t)+\xi_i(t) \tag{13}$$

式中:$\dot{v}_i(t)$为车辆i在t时刻的纵向加速度,m/s^2;$f_{\text{car-following}}(\cdot)$为车辆固有的跟驰非线性项;$\Delta x_{ir}$为车辆$i$与其关联车辆$r$之间的纵向间距,m;$\Delta v_{ir}$为车辆$i$与关联车辆$r$之间的相对速度,m/s;$\delta(i\in P)$为指示函数,当$i\in P$时取1,否则取0;$P$为牵制节点集合;$u_i(t)$为施加于第$i$个牵制节点在$t$时刻的外部控制输入,m/s^2;$\xi_i(t)$为第$i$辆车在$t$时刻所受的外部扰动,m/s^{2}m/s^2;$r$为与车辆$i$发生跟驰耦合的关联车辆.

第一层为跟随层(Followers).对于未被选中的普通节点(包含HV和非牵制CAV),其外部控制输入$u_i(t)=0$.这些车辆仅遵循CACC或IDM动力学,利用车辆间的耦合作用维持队形稳定性.在控制回路中,它们充当了"阻尼器"的角色,负责吸收由前车传递的残余震荡,并通过紧密的跟驰行为维持交通流的层流结构.

第二层为牵制层(Pinning Nodes).对于牵制节点,系统施加主动控制输入$u_i(t)$.不同于传统控制理论中基于误差反馈的线性控制律,引入1.3节训练好

的Dueling DQN智能体作为非线性控制器，$u_i(t)$为

$$u_i(t)=\varphi_\theta\left(E_i(t)\,|\,E_{\text{field}}\right) \tag{14}$$

式中：$\varphi_\theta(\cdot)$为参数θ的控制策略函数；$E_i(t)$为t时刻节点i的局部风险势能；E_{field}为局部环境风险场表征量.

该控制器利用强化学习在复杂博弈中的寻优能力，根据局部风险场势能$s_i(t)$输出防御性动作（如提前减速或避让换道）.从控制稳定性视角分析，SC-Risk算法保证了网络拓扑始终维持较高的代数连通度，使得拉普拉斯矩阵的最小非零特征值满足$\lambda_{\min}>0$.根据Lyapunov稳定性理论，只要牵制节点的控制增益足够大且Dueling DQN策略能够保证局部收敛，整个异构网络的速度误差向量为

$$\boldsymbol{e}(t)=\boldsymbol{v}(t)-v_{\text{ref}}\boldsymbol{\mu} \tag{15}$$

式中：$\boldsymbol{e}(t)$为t时刻的速度误差向量；$\boldsymbol{v}(t)$为t时刻全体车辆的速度向量；v_{ref}为参考速度，m/s；$\boldsymbol{\mu}$为元素全为1的列向量.

将渐近收敛至零，即$\lim\limits_{t\to\infty}\|\boldsymbol{e}(t)\|=0$.这不仅为“部分控制影响全局”的可行性提供了理论支撑，也为后续实验中观测到的“冲击波截断”与“风险消散”现象提供了动力学机理解释，基于风险势能谱聚类的牵制控制原理如图3所示.

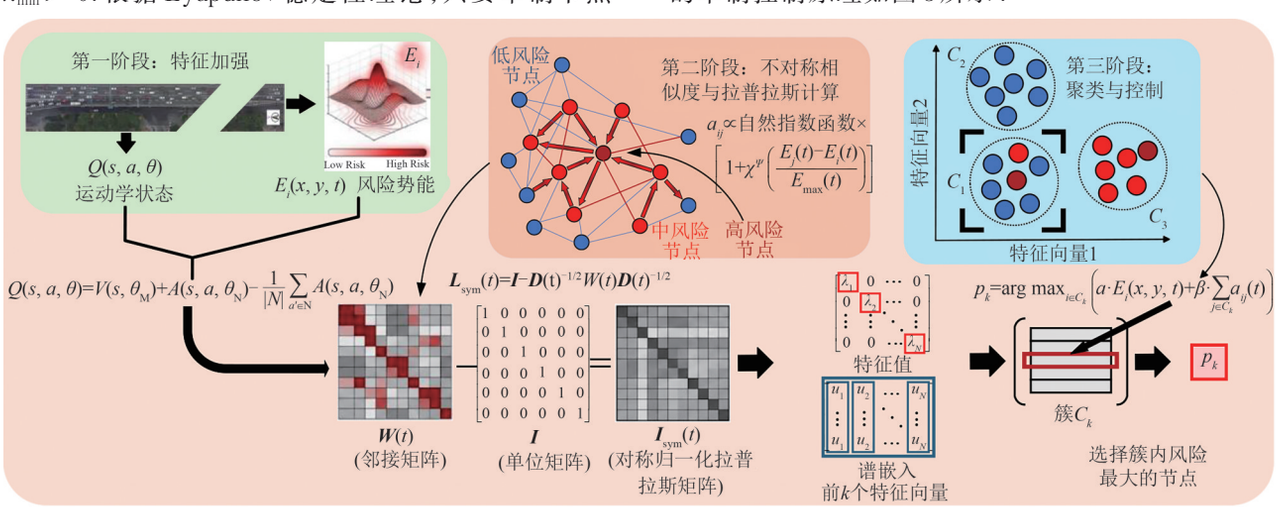


图3　基于风险势能谱聚类的牵制控制原理图

Fig.3　Schematic diagram of pinning control based on risk-potential-driven spectral clustering

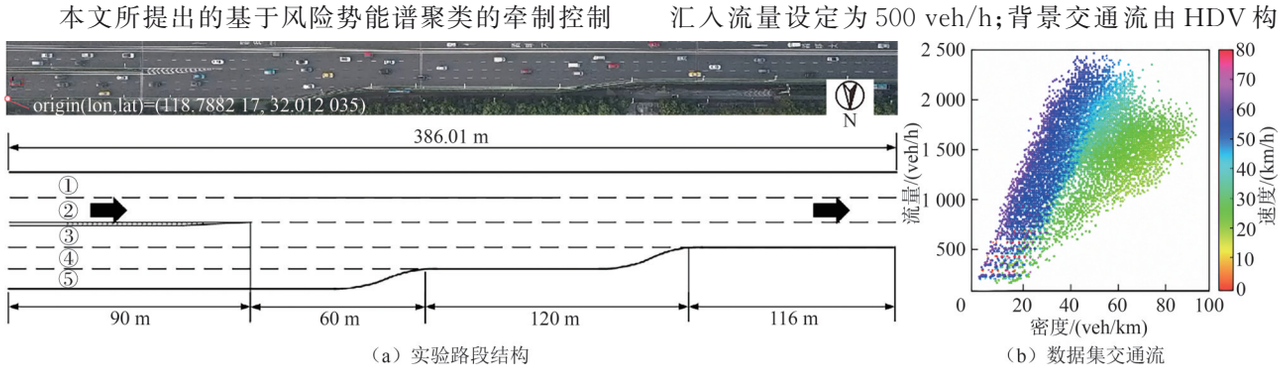
图3中：包含风险驱动的动态网络建模、SC-Risk关键节点识别算法以及异构分层牵制控制策略的实施过程.由图3可知，系统通过提取节点风险特征进行谱聚类筛选，最终成功构建了“Dueling DQN领航＋CACC跟随”的闭环协同控制网络.

3　仿真与分析

3.1　实验设置

本文所提出的基于风险势能谱聚类的牵制控制策略严格以车辆运行轨迹为决策依据.选用东南EAV数据集[28]中的SQM-W-2轨迹数据，以验证该策略的可行性与有效性.快速路合流区换道场景如图4所示.图4中，研究路段长度386.01 m，东西走向，其中东端为单向五车道，西端为单向三车道.

为确保仿真的真实性与可重复性，对交通流输入与仿真约束条件进行如下设定：①在交通数据流输入方面.主线初始流量设定为2 000 veh/h，匝道汇入流量设定为500 veh/h；背景交通流由HDV构



（a）实验路段结构　　（b）数据集交通流

图4　快速路合流区换道场景

Fig.4　Lane-changing scenario in expressway merging areas

成,其微观驾驶行为受智能驾驶员模型(Intelligent Driver Model,IDM)与换道模型(Minimizing Overall Braking Induced by Lane changes,MOBIL)驱动.②在仿真临界与约束条件方面.结合相关道路设计规范,设定主干线全局速度约束边界为100 km/h,匝道速度约束为40 km/h;为符合真实车辆的机械性能边界,车辆运动学约束设定为最大加速度2.0 m/s^2,最大舒适减速度−3.0 m/s^2,极限紧急制动减速度−4.5 m/s^2.③全局仿真物理步长统一设置为0.2 s,以保证底层运动学状态更新的连续性.

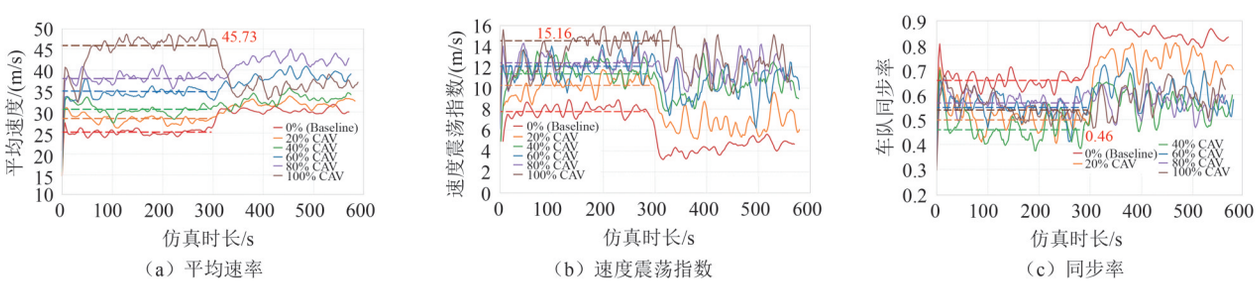
在SUMO仿真中,通过引入基于PPO的对抗车辆产生交通扰动并发生碰撞,发生碰撞后的车辆停在原处600 s以观测事故后交通流的变化,并于每0.2 s记录区域内所有车辆的位置、速度、加速度等信息.

3.2　模型对比

在ADV持续攻击导致交通流出现拥堵瓶颈的场景下,分别设置单智能体控制、传统车队控制和异构分层控制3组方案,对比不同CAV渗透率下的平均速率(Average Speed,AS)、同步率、速度震荡指数(Speed Oscillation Index,SOI)等指标.

实验设定在ADV持续攻击导致交通流出现拥堵瓶颈的场景下进行.为全面分析CAV渗透率对控制效能的影响,实验设置0%(基准组)、20%、40%、60%、80%、100%共6个CAV渗透率梯度;在每个渗透率工况下,按设定比例从主线与匝道的入流车辆中,随机将HDV替换为CAV,并通过随机种子控制保证CAV在路段空间内均匀分布,避免车辆集中投放造成的结果偏差;每组渗透率实验均采用多随机种子重复仿真,取指标统计均值以消除随机因素干扰.依据控制手段的不同,构建3个对比组:组别1车流中所有CAV均采用Dueling DQN控制算法,模拟全员具备高自主性但缺乏显式协同约束的“单智体集群”模式;组别2车流中所有CAV均保持CACC协同自适应巡航控制,模拟追求极致弦稳定性但缺乏主动博弈能力的“传统车队”模式;组别3采用所提出的谱聚类筛选机制,将关键牵制节点切换为Dueling DQN控制,其他跟随节点维持CACC控制,构建“智体领航-车队跟随”的异构模式.相关模型对比结果如图5~图7所示.

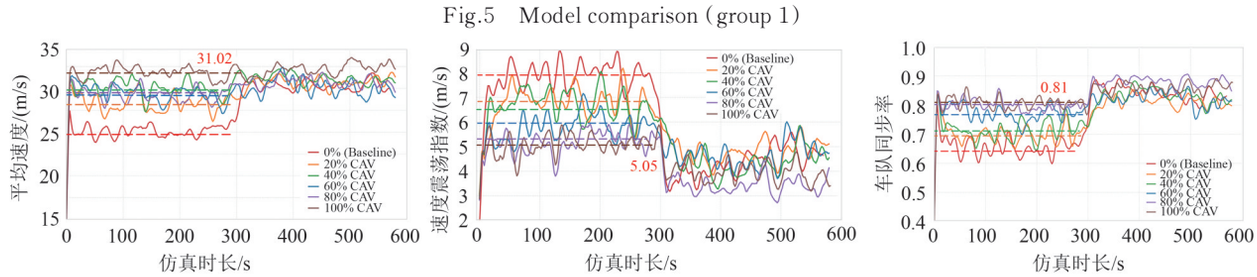
由图5~图7可知:① 组别1虽然在平均通行速度指标上表现优异,且随着渗透率的提升,车队的整体推进能力显著增强,但由于Dueling DQN奖励函数倾向于最大化自车的行驶效率与安全性,在缺乏全局协同约束的情况下,这种决策逻辑导致CAV表现出无序性,破坏了交通流的层流结构,导致速度震荡指数居高不下,车队同步率(Synchronization Rate,SR)甚至低于基准水平.这表明,单纯堆砌智能体的数量并不能涌现出群体智能,反而可能因个体间的非合作博弈加剧交通流的熵增.② 组别2展现了较好的队形保持能力与低震荡特性.这得益于CACC算法严格的间距控制策略,车辆能够像刚性链条一样稳定运行,有效抑制了后向激波的放大.然而,在面对ADV制造的强行变道或恶意停车等



（a）平均速率　（b）速度震荡指数　（c）同步率

图5　模型对比(组别1)

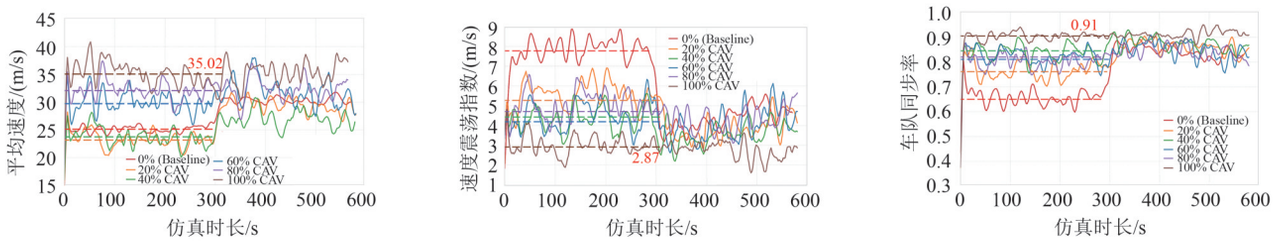
Fig.5　Model comparison (group 1)



（a）平均速率　（b）速度震荡指数　（c）同步率

图6　模型对比(组别2)

Fig.6　Model comparison (group 2)



（a）平均速率 （b）速度震荡指数 （c）同步率

图 7 模型对比(组别 3)

Fig.7 Model comparison (group 3)

极端扰动时,由于CACC缺乏对环境风险的主动认知与博弈能力,CACC车辆只能被动地执行减速跟随,无法像智能体那样利用侧向空间进行规避或通过激进操作打破僵局.因此,组别2虽然稳定,但在拥堵消散效率与恢复时间(Recovery Time)上表现最差,难以应对具有对抗性质的交通瓶颈.③ 组别3中,被选为牵制节点的Dueling DQN车辆利用其强鲁棒性的深度强化学习策略,果断执行变道或加速机动,为后方车流创造通行的时空窗口.与此同时,后方的CACC车辆紧密而平滑地跟随牵制节点,将前车剧烈机动产生的高频扰动过滤为低频的柔性波动.④ 进一步剖析可知,SC-Risk机制的鲁棒性与抗扰动能力并非稳态指标间的被动妥协,而是源于对交通激波的动态阻断.在时域维度,复合风险场先于宏观速度突变提前约3.5 s捕获扰动势能,为系统提供了超前的主动防御余量;在空域维度,牵制节点利用Dueling DQN的博弈能力吸收ADV制造的高频硬冲击,而跟随节点利用CACC的跟驰特性平抑残余的低频柔性波动.这种机制不仅在微观上维持了车队的弦稳定性,更在宏观上避免了局部扰动向全局瘫痪的级联演化,从而在对抗性瓶颈场景中展现出较高的系统韧性.

3.3 控制方法对比

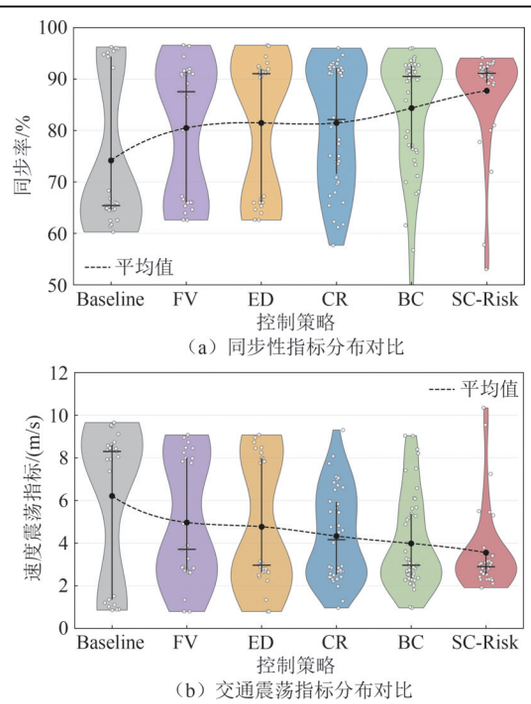
为了全面评估牵制节点选取策略对异构车队协同控制效能的影响,选取均匀分布(Even Distribution,ED)[32]、控制秩(Control Rank,CR)[33]、靠前车辆(Former Vehicles,FV)[35]和介数中心性(Betweenness Centrality,BC)[36]4种关键节点识别方法作为对照,控制方法效能对比如表1所示,表1记录了基准组及5种控制策略在交通震荡与同步率上的均值和方差;各类控制方法的同步性指标和交通震荡指标分布对比如图8所示.

由表1和图8可知:FV与ED等规则类策略虽然相比基准组在一定程度上改善了交通流稳定性,将同步率提升至0.81左右,但未考虑ADV攻击发生的具体时空位置;基于复杂网络理论的BC与CR策略表现出更优的控制潜力,其中BC策略的同步率达到0.843 5,速度震荡指数也降至3.98;SC-Risk策略以最小的控制代价实现了最优效果,其速度震荡指数降至最低的3.55,车队同步率达到0.877 3,较无控制基准组提升18.3%.

表 1 控制方法效能对比

Tab. 1 Comparison of control method effectiveness

控制策略	速度震荡指数		同步率	
	均值	方差	均值	方差
Baseline	6.210 711	3.617 978	0.741 760	0.147 033
FV	4.966 530	2.954 545	0.804 830	0.132 141
ED	4.766 578	3.056 434	0.814 707	0.137 529
CR	4.327 852	2.123 721	0.814 684	0.117 859
BC	3.982 041	2.198 726	0.843 516	0.114 045
SC-Risk	3.551 982	1.944 319	0.877 292	0.093 837



（a）同步性指标分布对比

（b）交通震荡指标分布对比

图 8 控制方法指标分布

Fig.8 Distribution of performance metrics across control methods

3.4 风险消解实验

在快速路合流区设置事故前风险消解场景,背

景交通流由 HDV 组成,采用 IDM+MOBIL 模型,引入高强度 ADV 代理作为扰动源,在匝道汇入点执行恶意急刹或侧向挤压行为;系统根据 SC-Risk 识别结果切换牵制节点控制策略,考察风险波形成与拥堵扩散过程,各组别风险消解状态如图 9 所示.

由图 9 可知:① 在基准组时空图中,仿真时间 $t=15$ s 左右,ADV 车辆在位置 $x=0$ m 处发动攻击,导致后方车流速度急剧下降;图中呈现出一条显著的深红色拥堵带(速度 <5 m/s),并以大约 -15 km/h 的波速向时空上游(纵向位置增加的方向)迅速传播,形成了典型的交通激波现象;结合对比 Risk-SSG 与 Speed-SSG 的前置突变点发现,风险指标平均比速度指标前置突变点提前 3.5 s 发出预警.② 在控制组时空图中,原有的红色拥堵带被显著"截断"和"稀释",交通流迅速恢复至自由流状态;同时,控制组成功将高风险区域局限在狭小范围内未发生级联扩散,总风险值下降了 28.76%,拥堵时空影响域(Time-Space Impact Region, TSIR)面积下降了 73.3%,成功将一次潜在的交通事故降维为一次轻微的交通扰动,有效验证了"风险阻断"机理.

3.5　对照实验

采用 SC-Risk 识别与异构协同控制策略,分别在事故前风险积聚期和事故后拥堵扩散期统计延误指数、区域吞吐量和同步率,评估交通流韧性变化,事故前对照实验如图 10 所示.由图 10 可知:在 ADV 发起攻击但尚未引发实质性拥堵的阶段(Pre-accident Phase),基准组(Baseline)的交通流呈现出剧烈的震荡特征;而引入 SC-Risk 策略的控制组表现出较好的风险阻断效应,提升了交通流的抗干扰阈值.

在 ADV 攻击导致瓶颈形成的阶段(Post-accident Phase),事故后对照实验如图 11 所示,宏观交通流效能对比如表 2 所示.由图 11 和表 2 可知:基准组拥堵带呈现发散状的漏斗效应,后向激波以约 -15 km/h 的速度迅速向上游传播;控制组冲击波在接触牵制节点群时即发生形态突变,成功截断了能量传递链条,TSIR 面积从基准组的 4 500 m·s 降至 1 200 m·s;控制组的延误指数维持在 1.2 的低位,路段吞吐量在扰动期间仅下降 12%,宏观收益显著优于基准组;得益于拥堵的快速消散,控制组的延误指数维持在 1.2 的低位,而基准组则攀升至 2.5 以上;在区域通行效率方面,SC-Risk 策略通过加速车流的层流恢复,使得路段吞吐量在扰动期间仅下降 12%,远优于基准组 40% 的跌幅.

为验证底层物理场数学建模的严密性与工程鲁棒性,针对复合风险场的核心参数——风险敏感系

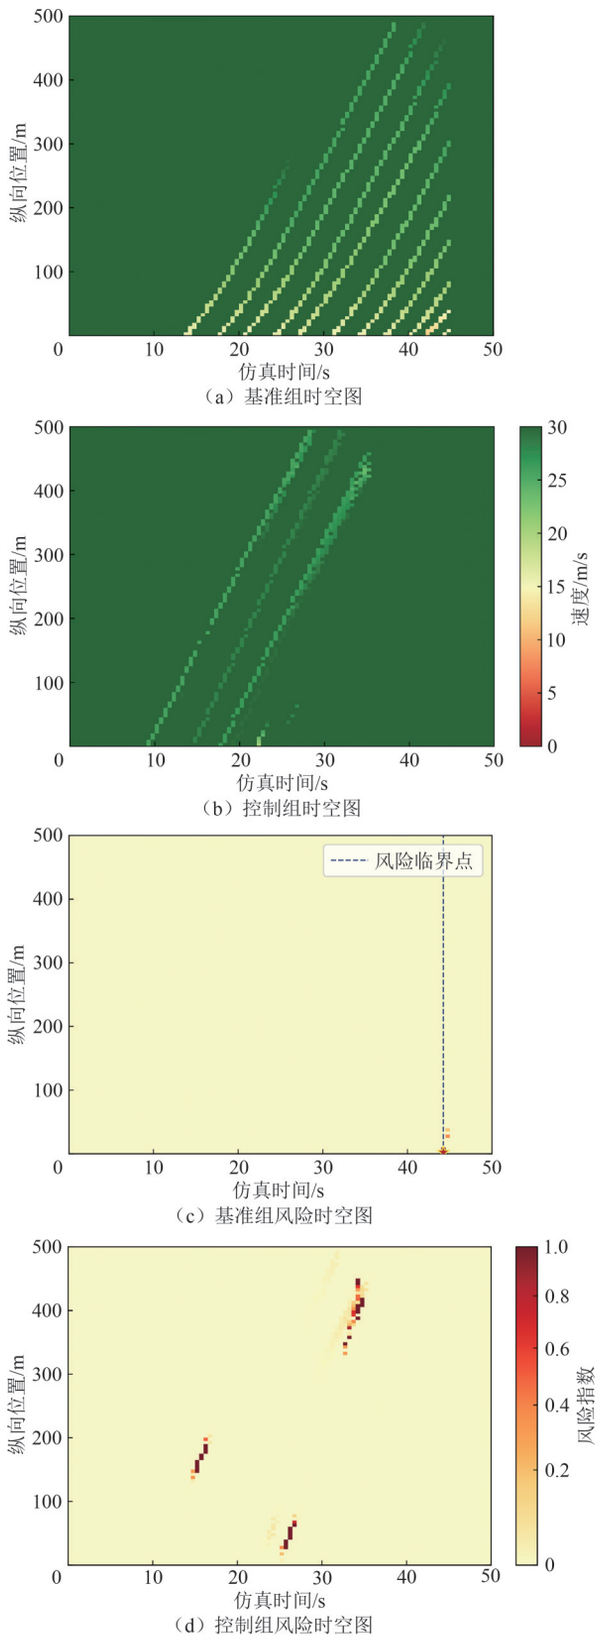
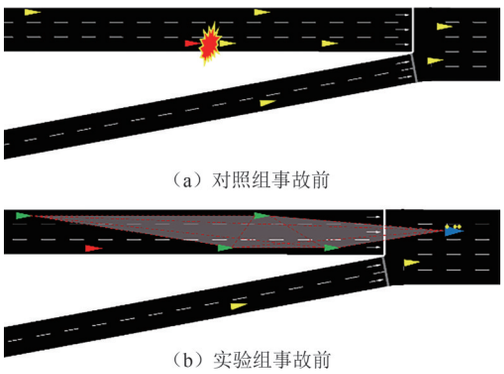


图 9　风险消解图

Fig.9　Risk mitigation diagram

数 χ 进行了多随机种子的敏感性测试.风险敏感系数的系统效能敏感性分析如图 12 所示.由图 12 可知:① 当 χ 在基准值 $\pm20\%$ 范围内摄动时,谱聚类

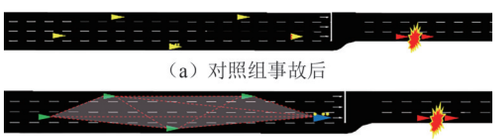


（a）对照组事故前

（b）实验组事故前

图 10 事故前对照实验

Fig.10 Pre-accident comparative experiment



（a）对照组事故后

（b）实验组事故后

图 11 事故后对照实验

Fig.11 Post-accident comparative experiment

表 2 宏观交通流效能对比

Tab.2 Comparison of macroscopic traffic flow performance

指标	AS/(m/s)	TDI	SOI	SR	TSIR面积/(m·s)
基准组	25.2	2.54	10.42	0.482 8	4 500
控制组	28.6	1.21	5.85	0.705 5	1 200

划分的子群数量保持相对稳定，且系统延误指数均值维持在1.35以下的低位，展现出较好的参数鲁棒性与协同效应涌现.② 当参数发生极端偏移时，控制效能出现符合物理机制的降级.若$\chi<0.5$，风险势能场退化，网络拓扑钝化导致牵制节点无法有效剥离高风险源，交通延误指数（Traffic Delay Index，TDI）提高至1.87且方差变大；若$\chi>1.5$，网络对微小风险过度敏感，导致连通图被过度碎片化，宏观车队协同解体，TDI同样显著增加.该量化测试从动力学边界上充分证实了参数标定域的合理性.

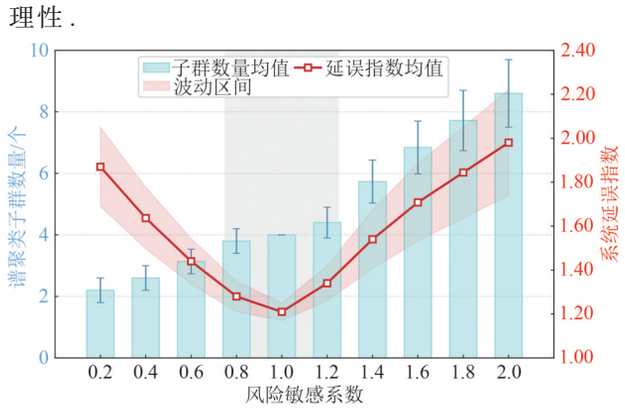


图 12 风险敏感系数的系统效能敏感性分析

Fig.12 Sensitivity analysis of system performance with respect to the risk sensitivity coefficient

4 结论

本文深入探讨了城市快速路合流区混合交通流在对抗性扰动下的脆弱性问题，提出并验证了一套基于风险势能谱聚类与异构分层牵制控制的控制方案，主要研究结论归纳如下：

1）风险势能谱聚类策略能精准锁定并靶向阻断风险传播源头，克服了传统位置或静态拓扑策略在应对动态风险时的局限性，SC-Risk机制先于宏观速度突变发出预警，在特征空间映射中精准锁定高传播风险的“致因节点”并实施靶向阻断，在各类不确定性对抗扰动下稳定提供了高自适应性的鲁棒防御策略.

2）异构协同牵制控制显著提升了交通流的稳定性和韧性，车队同步率提高至0.877 3，拥堵时空影响域面积缩减73.3%，在维持高通行效率与保障宏观运行安全之间实现了更优的平衡.

3）“Dueling DQN领航＋CACC跟随”模式有效解决了非合作博弈与被动滞后问题，高自主性的牵制节点通过强化学习敏锐感知物理空间中不可见的“危险梯度”，果断执行规避机动以消解硬冲击；跟随节点则利用CACC的紧密跟驰特性过滤残余的高频震荡，维持了车队的弦稳定性，在提升系统安全性的同时具备较高的经济与减碳环保效益.

针对当前研究在通信时延、多瓶颈耦合及全局环境风险（如极端天气）方面的局限性，未来工作将致力于构建基于非理想通信条件的鲁棒协同框架，探索分布式路网博弈机制及宏观韧性评估理论，并计划通过实车在环测试校准模型参数，以验证策略在真实物理世界中的有效性.

参考文献（References）：

[1] 冯汝怡，李志斌，吴启范，等.航拍视频车辆检测目标关联与时空轨迹匹配[J].交通信息与安全，2021，39(2)：61－69.
Feng Ruoyu，Li Zhibin，Wu Qifeng，et al. Target association and spatio-temporal trajectory matching of vehicle detection in aerial video[J]. Journal of Transport Information and Safety，2021，39(2)：61－69.（in Chinese）

[2] 黄帅，孙棣华，赵敏.T-CPS下考虑人驾车行为影响的混行车辆协同控制[J].控制与决策，2024，39(5)：1424－1432.
Huang Shuai，Sun Dihua，Zhao Min. Cooperative control of mixed vehicles considering influence of human-driven vehicles behavior under T-CPS[J]. Control and Decision，2024，39(5)：1424－1432.（in Chinese）

[3] Suriyarachchi N, Baras J S. Shock wave mitigation in multi-lane highways using vehicle-to-vehicle communication[C]//2021 IEEE 94th Vehicular Technology Conference (VTC2021-Fall). Norman, 2021: 1－7.

[4] 潘登, 郑应平. 路径约束条件下车辆行为的时空演化模型[J]. 物理学报, 2015, 64(7): 078902.
Pan Deng, Zheng Yingping. Spatiotemporal evolution model of vehicle behavior under path constraints[J]. Acta Physica Sinica, 2015, 64(7): 078902. (in Chinese)

[5] Tian Y, Pei H X, Yang J X, et al. An improved model of driving risk field for connected and automated vehicles[C]//2021 IEEE International Intelligent Transportation Systems Conference (ITSC). Indianapolis, 2021: 285－291.

[6] 蔺庆海, 何兆成, 谢俊, 等. 基于AVI数据与深度强化学习的城市快速路匝道协调控制方法[J]. 中国公路学报, 2023, 36(10): 224－237.
Lin Qinghai, He Zhaocheng, Xie Jun, et al. Urban expressway coordinated ramp metering approach using automatic vehicle identification data and deep reinforcement learning[J]. China Journal of Highway and Transport, 2023, 36(10): 224－237. (in Chinese)

[7] Zhang F, Wang C, Wang J. Vehicle interaction patterns at on-ramp merging area of urban expressway[J]. China Journal of Highway and Transport, 2022, 35(9): 66－79.

[8] Treiber M, Kesting A. Traffic Flow Dynamics: Data, Models and Simulation[M]. Berlin: Springer, 2013.

[9] 孙棣华, 刘忠诚, 赵敏, 等. 动态物理拓扑下基于CPS的混合交通牵制控制[J]. 控制与决策, 2023, 38(3): 729－737.
Sun Dihua, Liu Zhongcheng, Zhao Min, et al. CPS-based mixed traffic pinning control considering dynamic physical topology[J]. Control and Decision, 2023, 38(3): 729－737. (in Chinese)

[10] 黄帅, 孙棣华, 赵敏. 多切入机制下基于信息物理系统的混合车群协同控制[J]. 控制与决策, 2024, 39(1): 17－25.
Huang Shuai, Sun Dihua, Zhao Min. CPS-based mixed vehicle group cooperative control with multiple cut-in maneuvers[J]. Control and Decision, 2024, 39(1): 17－25. (in Chinese)

[11] 徐鹏程, 路庆昌, 李静, 等. 韧性视角下高速公路网络拥堵特性分析[J]. 中国公路学报, 2024, 37(10): 196－208.
Xu Pengcheng, Lu Qingchang, Li Jing, et al. Analyzing congestion characteristic of expressway network from perspective of resilience[J]. China Journal of Highway and Transport, 2024, 37(10): 196－208. (in Chinese)

[12] Öncü S, Ploeg J, Van de Wouw N, et al. Cooperative adaptive cruise control: Network-aware stability analysis[J]. IEEE Transactions on Intelligent Transportation Systems, 2014, 15(4): 1527－1537.

[13] Han Y, Hegyi A, Zhang L, et al. A new reinforcement learning-based variable speed limit control approach to improve traffic efficiency against freeway jam waves[J]. Transportation Research Part C: Emerging Technologies, 2022, 144: 103900.

[14] 赵杭, 赵敏, 孙棣华, 等. 面向快速路交通瓶颈的混合交通群体节流控制策略[J]. 交通运输工程学报, 2022, 22(3): 162－173.
Zhao Hang, Zhao Min, Sun Dihua, et al. Mixed traffic group throttling control strategy for traffic bottleneck of expressway[J]. Journal of Traffic and Transportation Engineering, 2022, 22(3): 162－173. (in Chinese)

[15] Wu C, Kreidieh A, Vinitsky E, et al. Emergent behaviors in mixed-autonomy traffic[C]//Conference on Robot Learning. Mountaion view, 2017: 398－407.

[16] Girdhar M, Hong J, Moore J. Cybersecurity of autonomous vehicles: a systematic literature review of adversarial attacks and defense models[J]. IEEE Open Journal of Vehicular Technology, 2023, 4: 417－437.

[17] 王灿, 赵妍, 李林恒, 等. 智能网联环境下基于谱聚类的车辆群体牵制控制策略[J]. 中国公路学报, 2024, 37(11): 235－248.
Wang Can, Zhao Yan, Li Linheng, et al. Spectral clustering-based pinning control strategy for vehicle platoons in connected and automated environments[J]. China Journal of Highway and Transport, 2024, 37(11): 235－248. (in Chinese)

[18] 杨洋, 胡嫣然, 袁振洲, 等. 高速公路交通事故时空影响动态效应的传播分析[J]. 华南理工大学学报(自然科学版), 2023, 51(1): 123－133.
Yang Yang, Hu Yanran, Yuan Zhenzhou, et al. Analysis on propagation of spatio-temporal dynamic effects towards freeway traffic crash[J]. Journal of South China University of Technology (Natural Science Edition), 2023, 51(1): 123－133. (in Chinese)

[19] 沈静. 高速公路事故风险实时预测及事后时空影响分析[D]. 南京: 东南大学, 2017: 43－57.
Shen Jing. Real-time prediction of highway accident risk and analysis of post-accident spatiotemporal impact[D]. Nanjing: Southeast University, 2017: 43－57. (in Chinese)

[20] Cao D, Wu J, Dong X, et al. Quantification of the impact of traffic incidents on speed reduction: A causal inference based approach[J]. Accident Analysis & Prevention, 2021, 157: 106163.

[21] 王建强, 吴剑, 李洋. 基于人-车-路协同的行车风险场概念、原理及建模[J]. 中国公路学报, 2016, 29(1): 105－114.
Wang Jianqiang, Wu Jian, Li Yang. Concept, principle

and modeling of driving risk field based on driver-vehicle-road interaction[J]. China Journal of Highway and Transport, 2016, 29(1): 105－114. (in Chinese)

[22] Rong Z H, Li X, Lu W L. Pinning a complex network through the betweenness centrality strategy[C]//2009 IEEE International Symposium on Circuits and Systems. Taipei, 2009: 1689－1692.

[23] 熊晓夏, 陈龙, 梁军, 等. 基于贝叶斯网络模型的道路交通事故链生成与演化研究[J]. 公路交通科技, 2018, 35(5): 99－107.
Xiong Xiaoxia, Chen Long, Liang Jun, et al. Study on generation and evolution of road traffic accident chain based on Bayesian network model[J]. Journal of Highway and Transportation Research and Development, 2018, 35(5): 99－107. (in Chinese)

[24] 曹堉, 王成, 杨岳铭, 等. 基于贝叶斯网络的城市道路交通拥堵多原因自动实时识别[J]. 公路交通科技, 2020, 37(11): 89－97.
Cao Yu, Wang Cheng, Yang Yueming, et al. Multi-cause automatic real-time recognition of urban road traffic congestion based on Bayesian network[J]. Journal of Highway and Transportation Research and Development, 2020, 37(11): 89－97. (in Chinese)

[25] Rong Z, Li X, Wang X. Roles of heterogeneities in spreading dynamics on complex networks[J]. Physical Review E, 2007, 76(2): 027101.

[26] Yu X, Guo G. A general variable time headway policy in platoon control[J]. Acta Automatica Sinica, 2019, 45(7): 1335－1343.

[27] Li Y F, Tang C C, Li K Z, et al. Consensus-based cooperative control for multi-platoon under the connected vehicles environment[J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 20(6): 2220－2229.

[28] 孙棣华, 李永福, 刘卫宁, 等. 交通信息物理系统及其关键技术研究综述[J]. 中国公路学报, 2013, 26(1): 144－155.
Sun Dihua, Li Yongfu, Liu Weining, et al. Research summary on transportation cyber physical systems and the challenging technologies[J]. China Journal of Highway and Transport, 2013, 26(1): 144－155. (in Chinese)

[29] Tian J F, Jiang R, Li G Y, et al. Cellular automaton model simulating spatiotemporal patterns, phase transitions and evolution concavity in traffic flow[EB/OL]. (2025-07-15)[2026-01-26]. https://arxiv.org/abs/1507.04054.

[30] Mogelmose A, Trivedi M M, Moeslund T B. Vision－based traffic sign detection and analysis for intelligent driver assistance systems: Perspectives and survey[J]. IEEE Transactions on Intelligent Transportation Systems, 2012, 13(4): 1484－1497.

[31] Liu Z C, Sun D H, Zhao M, et al. Pinning control strategy and stability analysis of mixed platoon: A cyber-physical perspective[J]. Physica A: Statistical Mechanics and Its Applications, 2022, 594: 127049.

[32] Liu Z C, Sun D H, Zhao M, et al. CPS-based pinning approach for mixed traffic considering human driver differences[J]. Transportation Research Part C: Emerging Technologies, 2022, 140: 103674.

[33] Yao J, Jia Q, Shen L J. Pinning control of a new car-following model with the consideration of preceding and following cars[C]//2015 IEEE Conference on Control Applications (CCA). Sydney, 2015: 816－821.

[34] Feng R Y, Zhu H H, Sze N N, et al. Ubiquitous Traffic Eyes: trajectory dataset focus on multiple traffic states and state transition on urban expressways[J]. Transportation Letters, 2026, 18(2): 446－462.

[35] Wakasa T, Nagatani Y, Sawada K, et al. Switched pinning control for vehicle platoons via mixed logical dynamical modeling[C]//2020 IEEE/SICE International Symposium on System Integration (SII). Honolulu, 2020: 449－454.

[36] Jia Z, Li X, Rong Z H. Pinning complex dynamical networks with local betweenness centrality information[C]//Proceedings of the 30th Chinese Control Conference. Yantai, 2011: 5969－5974.

[37] Lee Y G, Park M J, Kwon O M. Betweenness-centrality-based-pinning control approach to nonlinear multi-agent systems[J]. IEEE Transactions on Circuits and Systems Ⅱ: Express Briefs, 2024, 71(3): 1216－1220.

[38] Wang J Q, Wu J, Li Y. The driving safety field based on driver-vehicle-road interactions[J]. IEEE Transactions on Intelligent Transportation Systems, 2015, 16(4): 2203－2214.