

에너지 최적화를 위한 생성형 AI 강화학습 자율주행 알고리즘

조예령, 노지민, 이상미, 김중헌*

{joyena0909, emilyjroh, sangmi, *joongheon}@korea.ac.kr

Generative AI Reinforcement Learning-based Autonomous Driving Algorithm for Energy Optimization

Yeryeong Cho, Emily Jimin Roh, Sangmi Lee, and Joongheon Kim*

Korea University

요약

본 논문은 자율주행차량의 에너지 최적화를 위해 생성형 AI (Generative AI, GAI)와 강화학습(Reinforcement Learning, RL)의 융합 기술에 대한 최신 연구 동향을 분석한다. 전통적 제어 기법은 동역학 모델 의존으로 환경 변화에 취약하며, RL은 실제 주행 데이터 요구와 안전성 제약으로 한계를 지닌다는 점을 개선하기 위해 GAI는 다양한 가상 샘플을 생성하고 오류를 보완함으로써 RL의 효율성과 안정성을 개선 가능하다. 관련 최신 연구 동향과 알고리즘의 개념에 대해 설명하며, 실제 플랫폼 검증 등의 향후 연구 방향을 제시하여 지속가능한 자율주행 에너지 관리 전략의 발전 가능성을 시사한다.

I. 서론

최근 자율주행 차량의 상용화가 가속화되면서 주행 안전성과 편의성뿐만 아니라 에너지 효율 최적화가 중요한 연구 과제로 부상했다. 전통적인 제어 기반 방법은 차량 동역학 모델에 의존해 에너지 소비를 최소화하지만, 환경 변화에 유연하게 대응하기에는 한계가 존재한다 [1]. 특히 배터리 용량의 한계는 주행 거리와 직결되므로, 에너지 최적화 전략은 운영 비용 절감과 주행 가능 구역 확대 측면에서 핵심 요소로 주목받고 있다 [2]. 기존 연구는 강화학습(Reinforcement Learning, RL)을 통해 도로 환경과 교통 흐름을 인지하고 최적화된 주행 정책을 학습해왔으나, 실제 도로 환경에서의 학습 데이터의 수집 비용과 안전성 보장 문제로 인해 한계가 존재한다. 이러한 한계를 개선하기 위해 생성형 AI (Generative AI, GAI)는 데이터 분포를 학습해 다채로운 가상 데이터를 생성할 수 있어, 강화학습의 학습 데이터를 생성하고 탐색(Exploration)의 다양성을 확보하는 데 유리하다 [3]. 따라서 본 논문에서는 에너지 최적화 관점에서 RL과 GAI의 융합 필요성을 고찰하고, 관련 연구 동향을 분석한다. 또한, 현재 연구의 한계와 발전 가능성을 제시함으로써 향후 연구 방향을 제안한다.

II. 생성형 AI 기반 강화학습 알고리즘 개념

GAI 기반 RL 알고리즘은 RL의 정책 학습 과정에 대해 GAI와 융합하는 것을 의미한다. 제일 범용적이며 직관적인 방법은 가상 데이터 생성으로 GAI는 에이전트와 환경 간 실제 데이터로부터 상태 - 행동 - 보상 - 다음 상태(State - Action - Reward - Next State) 쌍의 분포를 학습하며, 이를 기반으로 새로운 전이 샘플을 생성하는 방법이다 [4]. 이러한 데이터는 RL 에이전트의 학습 데이터에 추가되어 학습 데이터의 다양성을 높임으로써 샘플의 효율성을 극대화할 수 있다. 그림 1에서 볼 수 있듯이 환경을 기반으로 GAI에 데이터를 제공하며, 이를 기반으로 학습 데이터의 생성이 가능하다. 두 번째로, GAI는 실제 경험 데이터와 유사한 분포를 가질 수 있도록 손실 함수에 추가되어 에이전트가 학습하는 과정에서 오류로 인해 환경의 중요한




그림 1 생성형 AI 기반 RL 알고리즘 구조

특성을 놓치지 않도록 보정하는 역할을 한다 [5]. 이처럼 GAI 기반 RL 알고리즘은 데이터 수집에 대한 부담을 완화하고, 탐색 다양성을 확보할 수 있도록 도와주는 역할을 한다. 결과적으로, 전통적인 RL 알고리즘의 한계인 데이터 효율성 저하, 낮은 안정성 등 다양한 측면에서 상호보완이 가능하다.

III. 에너지 최적화를 위한 GAI RL 기반 자율주행 알고리즘

GAI와는 실제 주행 데이터의 분포를 학습하여 새로운 상태 - 행동 쌍을 생성할 수 있는 모델로, 대표적으로 변분 오토인코더(VAE)와 생성적 적대 신경망(GAN), 확산 모델(Diffusion Model) 등이 존재한다. 특히 에너지 최적화 관점에서는 GAI가 생성한 부드러운 가감속 궤적을 활용해 저에너지 행동 후보군을 사전에 구성함으로써, 정책 탐색 과정에서 비효율적 행동 시나리오를 효과적으로 회피할 수 있다 [6]. 안전성 제약 강화학습(Safe RL)과 결합은 에너지 효율과 주행 안전성 간 균형을 가능하게 한다. GAI로 생성된 행동 후보군 중 위험도가 낮은 궤적만을 필터링하거나, CMDP(Constrained Markov Decision Process) 프레임워크 내에서 에너지 소비 한계를 제약 조건으로 설정함으로써, 에이전트가 안전 제약을 만족하면서도 에너지를 절감할 수 있도록 한다 [7]. 이때 GAI는 위험 상황이 과소 표현되지

않도록 보장하여, 실제 주행에서의 안전성 저하를 방지한다. 이외에도 GAI는 모델 기반 RL과도 유기적으로 결합하여 MuZero와 유사한 구조에서는 환경 동역학 모델에 GAI를 결합해 예측 불확실성이 큰 영역을 보완하며, 에너지 소비 예측 신경망과 연결되어 예측 데이터를 생성한다 [8]. 이를 통해 실제 주행 환경과 유사한 조건에서 초기 정책을 안전하게 학습시키고, 반복적인 실제 시도로 인한 위험을 최소화할 수 있다. 한편, 디지털 트윈(Digital Twin) 기반 시뮬레이션과의 연계도 활발히 연구되고 있다 [9]. 실제 차량·도로·교통 흐름 정보를 실시간으로 피드백 받는 디지털 트윈 환경에 GAI를 통합하면, 에너지 소비 예측 모델의 정확도를 높이고, 정책 학습 과정에서 동적 환경 변화를 반영할 수 있다 [10]. 특히 심층 강화학습 정책 네트워크를 디지털 트윈에 배치해 실험을 반복하면, 실차 테스트 없이도 에너지 최적화 성능을 검증하여 현실로의 실제 적용에 용이할 수 있다 [11]. 이렇게 다양한 융합 알고리즘을 통해 에너지 최적화를 위한 차량 제어 알고리즘의 초석을 마련하고 있다.

IV. 결론

본 논문에서는 GAI 기반 RL 알고리즘의 개념과 자율주행 제어 분야에서의 적용 기술 동향을 정리하였다. 전통적 제어 기반 기법이 동역학 모델 의존성으로 인해 환경 변화에 유연하게 대응하기 어려운 반면, RL은 환경에 적응적 학습이 가능하나 샘플 효율성과 안전성 문제가 제약 요인으로 작용한다. 이에 GAI는 실제 주행 데이터로부터 가상 전이 샘플을 생성하여 리플레이 버퍼를 풍부히 하고, 다양한 탐색 경로를 제공함으로써 RL의 데이터 효율성과 탐색 안정성을 동시에 개선 가능성을 다양한 연구 사례를 통해 제시하였다. 향후 연구에서는 첫째, GAI 생성 경험의 품질 평가 지표를 정립하여 가상 전이의 신뢰도를 수치화하여 신뢰성을 높이는 연구가 필수적이다. 둘째, 에너지 최적화를 위한 다중 목표 RL 프레임워크에서 GAI의 사용자 정의 보상 설계 기법을 개발하여 다중 제약을 동시에 만족하는 정책을 학습할 수 있는 알고리즘 연구가 필요하며, 마지막으로 실제 차량 플랫폼에 적용 가능한 경량 GAI-RL 통합 파이프라인 구축으로 나아가야 할 것이다. 이와 같이 GAI-RL의 시너지 효과를 극대화하기 위한 다양한 연구는 자율주행 차량의 에너지 효율성을 향상시키고 향후 실제 적용에 필요한 핵심 열쇠가 될 것이다.

ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원-대학ICT연구센터(ITRC)의 지원을 받아 수행된 연구임(IITP-2025-RS-2024-00436887). 본 논문의 교신 저자는 김중현임.

참 고 문 헌

- [1] A. Rocha, A. Ganesan, D. Yang and N. Murgovski, "Energy-Optimal Trajectory Planning for Electric Vehicles using Model Predictive Control," in *Proc. European Control Conference (ECC)*, Stockholm, Sweden, June 2024, pp. 1346-1351.
- [2] B. R. Kiran et al., "Deep Reinforcement Learning for Autonomous Driving: A Survey," *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, no. 6, pp. 4909-4926, June 2022.
- [3] Jonathan Ho, Ajay Jain, and Pieter Abbeel, "Denoising diffusion

- probabilistic models", in *Proc. International Conference on Neural Information Processing Systems (NIPS)*, NY, USA, December 2020, pp. 6840 - 6851.
- [4] Haofei Lu, Dongqi Han, Yifei Shen, Dongsheng Li, "What Makes a Good Diffusion Planner for Decision Making?", in *Proc. International Conference on Learning Representations*, Singapore, April 2025.
- [5] K. Joo and S. S. Woo, "TVDR: Imitation learning with Variational inference and Distributional Reinforcement learning to find Optimal Driving Strategy," in *Proc. IEEE International Conference on Machine Learning and Applications (ICMLA)*, Pasadena, CA, USA, 2021, pp. 256-262
- [6] Shufeng Wang, Zhengli Wang, Xinkai Wang, Qingwei Liang, Lingyi Meng, "Intelligent vehicle driving decision-making model based on variational AutoEncoder network and deep reinforcement learning", *Expert Systems with Applications*, vol. 268, April 2025, pp. 126319.
- [7] K. Joo and S. S. Woo, "TVDR: Imitation learning with Variational inference and Distributional Reinforcement learning to find Optimal Driving Strategy," in *Proc. IEEE International Conference on Machine Learning and Applications (ICMLA)*, Pasadena, CA, USA, December 2021, pp. 256-262.
- [8] Mohammed Alshiekh, Roderick Bloem, Rüdiger Ehlers, Bettina Könighofer, Scott Niekum, and Ufuk Topcu, "Safe reinforcement learning via shielding", in *Proc. AAAI Conference on Artificial Intelligence*, Louisiana, USA, February 2018, pp. 2669-2678.
- [9] Y. Tao, J. Wu, X. Lin, S. Mumtaz and S. Cherkaoui, "Digital Twin and DRL-Driven Semantic Dissemination for 6G Autonomous Driving Service," in *Proc. IEEE Global Communications Conference (GLOBECOM)*, Kuala Lumpur, Malaysia, 2023, pp. 2075-2080.
- [10] J. Wang, Y. Li, S. Zhou, Y. Zhang, X. Xiong and W. Zhai, "Traceability and Performance Optimization: Application of Generative AI, Digital Twin, and DRL in the Recycling Process of WEEE," *IEEE Internet of Things Magazine*, vol. 7, no. 3, pp. 22-28, May 2024.
- [11] Z. Hu, S. Lou, Y. Xing, X. Wang, D. Cao and C. Lv, "Review and Perspectives on Driver Digital Twin and Its Enabling Technologies for Intelligent Vehicles," *IEEE Transactions on Intelligent Vehicles*, vol. 7, no. 3, pp. 417-440, September 2022.