



# Simpósio de Integração Acadêmica

## “Ciências Básicas para o Desenvolvimento Sustentável”

SIA UFV 2023



## Maximizando a conectividade em redes veiculares através de handover inteligente entre domínios da névoa

**Autor:** Natascha Siqueira Martinez Palhares - Departamento de Informática - Universidade Federal de Viçosa - [natascha.palhares@ufv.br](mailto:natascha.palhares@ufv.br)

**Orientador:** Vitor Barbosa Carlos de Souza - Departamento de Informática - Universidade Federal de Viçosa - [vitor.souza@ufv.br](mailto:vitor.souza@ufv.br)

**Palavras-chave:** Redes veiculares, Computação em névoa, Redes neurais

**Modalidade:** Pesquisa | **Área de Conhecimento:** Ciências Exatas e Tecnológicas | **Área temática:** Ciência da Computação

### Introdução

A proliferação de dispositivos na borda da rede gera muitos dados, exigindo comunicação em tempo real e aplicativos de alta largura de banda. A computação em névoa coloca recursos próximos aos dispositivos, reduzindo latência e custos, mas a mobilidade dos dispositivos pode causar problemas de acesso. Essa tecnologia distribui serviços entre dispositivos e data centers, sendo usada na internet das coisas, controle de tráfego e redes veiculares para análise instantânea de dados e suporte a veículos autônomos.

### Objetivos

O objetivo deste projeto é desenvolver uma estratégia avançada para alocar recursos móveis de forma inteligente em redes veiculares na computação em névoa. Isso envolve a utilização de uma Deep Q-Network sem conhecimento prévio das malhas rodoviárias e dos movimentos dos veículos. O objetivo principal é minimizar as interrupções na conexão e reduzir as trocas frequentes entre os domínios de névoa, garantindo a disponibilidade contínua de recursos para melhorar a eficiência e a segurança das operações dos veículos.

### Material e Método

A metodologia utilizada neste trabalho visa reduzir handovers e desconexões desnecessárias entre domínios de névoa em redes veiculares. Isso é feito através da combinação de uma Deep Q-Network (DQN), que é uma rede neural profunda, com o método Q-Learning. A DQN é escolhida devido à sua capacidade de aprender em ambientes complexos sem conhecimento prévio dos estados e da eliminação da necessidade de criar tabelas-Q para armazenar todas as ações possíveis. O Q-Learning é um método de aprendizado por reforço usado para encontrar a política ótima em ambientes de Processo de Decisão de Markov desconhecidos. Ele atualiza iterativamente uma tabela chamada Q-table para representar a utilidade esperada de ações em estados específicos. A DQN, por outro lado, utiliza redes neurais profundas para aproximar a função Q, permitindo lidar com problemas complexos e espaços de estado e ação grandes. Para melhorar o aprendizado, são empregadas técnicas como Experience Replay e Target Q-Network.

O treinamento do DQN é realizado em uma rede rodoviária com 12 Pontos de Acesso (APs), e as recompensas e penalidades são usadas para guiar o aprendizado. Três situações são consideradas: recompensa positiva para conexão estável, recompensa negativa para handovers e penalidade mais severa para desconexões. Os estados são compostos pelo SNR entre o veículo e os APs na área de alcance, juntamente com informações sobre a AP atualmente conectada. A rede neural do DQN gera saídas para todas as ações possíveis em cada estado, permitindo a escolha da AP com a maior probabilidade de conexão.

### Resultados e Discussão

Tabela 1 - Média dos resultados das quatro rotas

	Conexões	Handovers	Desconexões	Recompensas
Heurística gulosa	47,8	6	5,25	-11
Modelo 1	48,8	8	2,25	18,3
Modelo 2	50	6,25	2,75	16,3
Modelo 3	49,5	6,25	3,25	10,8
Modelo 4	49,5	7,75	1,75	24,3
Modelo 5	48	7,75	3,25	7,75

Foram testados cinco modelos de DQNs com diferentes configurações em relação ao tamanho da rota e à taxa de exploração. O Modelo 4 se destacou, alcançando a recompensa média mais alta e reduzindo significativamente as desconexões e handovers, especialmente as desconexões. Isso ocorreu porque o veículo se conectou a outro AP antes que o sinal ficasse muito fraco, evitando desconexões desnecessárias. A análise comparativa mostrou que a heurística gulosa teve um desempenho inferior em relação a todos os modelos de DQN, especialmente no número de desconexões e recompensas totais. Isso sugere que, em ambientes veiculares dinâmicos sujeitos a mudanças na rede, as abordagens baseadas em DQN são mais eficazes. No geral, o uso de DQNs resultou em uma redução de 50,5% no número de desconexões, com um aumento de 20% no número de handovers em média em relação à heurística.

### Conclusões

Os experimentos demonstraram que a metodologia proposta reduziu a necessidade de migrações entre domínios de névoa, especialmente nas desconexões críticas. Isso resultou em menos interrupções na conexão, indicando que o modelo atingiu seu objetivo de melhorar a disponibilidade de recursos em redes veiculares na névoa.

### Bibliografia

DOSHI, Ketan. Reinforcement Learning Explained Visually (Part 5): Deep Q Networks, step-by-step. In: Towards Data Science, 19 de dezembro de 2020.

F. Bonomi, R. Milito, J. Zhu, and S. Addepalli, “Fog computing and its role in the internet of things,” in Proceedings of the first edition of the MCC workshop on Mobile cloud computing, pp. 13–16, ACM, 2012.

### Apoio Financeiro

