



# Simpósio de Integração Acadêmica

“Bicentenário da Independência: 200 anos de ciência, tecnologia e inovação no Brasil e 96 anos de contribuição da UFV”

SIA UFV 2022



## Minimizando interrupções na conexão de redes utilizando aprendizado por reforço orientado a aproximação de funções

**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, Aprendizado por reforço

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

### Introdução

A computação em névoa é um novo paradigma de redes de computadores e sistemas distribuídos. Ela é aplicada, por exemplo, à internet das coisas (IoT – Internet of Things), uma vez que emprega recursos computacionais na borda da rede, ou seja, ela traz os serviços da computação em nuvem para mais próximo dos usuários finais, conservando a largura de banda e reduzindo a latência de comunicação. Porém, como o acesso a recursos computacionais presentes na névoa é dependente da localização física, a potencial mobilidade observada em dispositivos na borda torna proibitiva a disponibilidade de recursos compartilhados de forma contínua.

### Objetivos

Esse projeto tem como objetivo criar um agente que realiza decisões de forma inteligente sobre a distribuição dos recursos móveis entre os domínios da névoa, ou seja, sobre qual domínio se conectar. Permitindo a implementação desses agentes treinados sem conhecer as malhas rodoviárias e o padrão de movimentação dos veículos previamente. De modo que tal agente minimize as interrupções na conexão e trocas frequentes entre domínios da névoa em redes veiculares, a fim de maximizar a disponibilidade de recursos.

### Material e Métodos

Esse trabalho visa atingir seu objetivo por meio do emprego de aproximação de função com técnicas tabulares e algoritmos de aprendizado por reforço. No aprendizado por reforço o agente aprende a alcançar um objetivo através da tentativa e erro. Para isso, o mesmo recebe recompensas ou penalidades pelas ações que executa, buscando maximizar os ganhos totais. No modelo proposto, as funções utilizadas foram: (1) função de distância entre o veículo e os pontos de acesso (AP–Access Point) dando acesso a cada névoa, que objetiva evitar desconexões causadas por longas distâncias; (2) função que analisa se o veículo permaneceu conectado ao mesmo AP ou se decidiu conectar-se a outro (handover), com o intuito de impedir migrações frequentes e desnecessárias entre domínios de névoas distintas; e (3) função de aproximação, que determina a variação da distância entre veículo e AP, permitindo dar preferência para APs que estão mais próximos nas etapas seguintes.

O agente foi implementado em duas versões (abordagens 3 e 4) e comparado com duas abordagens simples, mas utilizadas em cenários reais (abordagens 1 e 2). Na primeira, o veículo sempre se conecta no AP com melhor sinal e se mantém conectado até a desconexão por perda do sinal, quando busca novamente pelo AP com melhor sinal.

Em uma segunda abordagem, o veículo sempre muda para o AP com melhor sinal, mesmo que o conectado atualmente ainda tenha um sinal bom. Na terceira, o veículo se conecta ao AP com melhor sinal antes de desconectar-se. Enquanto na quarta abordagem, antes de desconectar-se, o veículo se conecta no AP de melhor sinal nas etapas seguintes.

### Resultados e Discussão

Tabela 1: Quantidade de desconexões em média em 1000000 movimentos

	3 APs	4 APs	5 APs	6 APs
Abordagem 1	0	0	0	0
Abordagem 2	48577	45886	55164	64210
Abordagem 3	13567	36344	44568	56740
Abordagem 4	13954	36129	44423	56629

Tabela 2: Quantidade de handovers que o agente escolheu realizar em 1000000 passos

	3 APs	4 APs	5 APs	6 APs
Abordagem 1	15732	30758	35905	64188
Abordagem 2	0	0	0	0
Abordagem 3	7249	7926	7567	7358
Abordagem 4	7095	7856	7623	7442

As tabelas 1 e 2 mostram a quantidade de desconexões e handovers realizados em média pelo agente nas malhas rodoviárias, com um número de APs e raios de alcances diferentes, aplicando as quatro abordagens.

Note que as abordagens 3 e 4 chegaram em quantias de desconexões e handovers balanceadas comparado com as outras duas abordagens, mostrando que o aprendizado por reforço conseguiu modelar um agente que chegou em uma política ideal. Isso ocorre, pois o agente visa se manter conectado em um mesmo AP o maior tempo possível, porém sem que o sinal fique ruim, isto é, ele se conecta em outro ponto de acesso antes que a distância fique muito grande, logo não ocorre handovers desnecessários. Além disso, é possível observar que a abordagem 4 é um pouco mais vantajosa que a abordagem 3, portanto o emprego da função três que leva em conta a direção do veículo fez diferença.

### Conclusões

Os experimentos numéricos ilustram que a metodologia proposta é adequada, uma vez que houve a minimização na quantidade de migrações desnecessárias entre névoas distintas e no número de desconexões, diminuindo as interrupções na conexão. Consequentemente, concluímos que o modelo proposto cumpre o objetivo de ampliar a disponibilidade de recursos em redes veiculares na névoa.

### Bibliografia

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.

Sutton RS, Barto AG. Reinforcement learning: An introduction. MIT press; 2018 Nov 13.

### Apoio Financeiro

