

Ensemble de Redes Neurais Profundas na Computação de Heurísticas para Algoritmos de Busca de Caminhos em Mapas Virtuais contendo Elevação e Inclinação

Claiton H. C. Neisse, Jairo F. Gez, Juliano L. Soares, Luis A. L. Silva

Curso de Graduação em Ciência da Computação
Universidade Federal de Santa Maria (UFSM) – Santa Maria, RS – Brasil

{chneisse, jfgez, jlsoares, luisalvaro}@inf.ufsm.br

Resumo. *Redes neurais profundas e algoritmos de busca de caminhos (pathfinding) têm sido investigados na área de Inteligência Artificial (IA). Apesar disso, essas áreas de pesquisa ainda requerem uma maior integração, principalmente visando a proposta de algoritmos de pathfinding que exploram informações de relevo nas computações de rotas com menores distâncias e custos topográficos. O objetivo da proposta de pesquisa apresentada neste artigo é investigar técnicas de ensemble de redes neurais profundas na construção de funções heurísticas utilizadas na otimização de algoritmos de pathfinding que exploram elevação e inclinação representadas em mapas virtuais de grandes dimensões.*

1. Introdução

Redes neurais profundas (Deep Neural Networks – DNN) [Goodfellow *et al.* 2016] têm sido exploradas com sucesso em diversas áreas de aplicação. Neste contexto, [Agostinelli *et al.* 2019], [Ariki e Narihira 2019], [Doebber 2019], [Jindal *et al.* 2017] [Li, *et al.* 2016], [Takahashi *et al.* 2019] e [Wang *et al.* 2019] investigam o emprego de DNN nas computações heurísticas requeridas para a resolução de problemas de busca. Em contraste, [Chagas 2019], [Chen *et al.* 2009] e [Ganganath *et al.* 2015] investigam heurísticas para algoritmos de busca de caminhos (*pathfinding*) que exploram informações de elevação e inclinação nas suas computações. O problema é que essas áreas de pesquisa da Inteligência Artificial (IA) ainda são pouco exploradas em conjunto, havendo a necessidade de investigar a construção de heurísticas baseadas em DNN para otimizar a busca de caminhos em terrenos virtuais com informações topográficas em diferentes problemas. Para atacar esse problema, este trabalho propõe o desenvolvimento de uma análise de técnicas de *ensemble* de DNN na resolução de problemas de *pathfinding* em mapas virtuais de grandes dimensões. O trabalho busca melhor compreender como usar DNN na construção de heurísticas para algoritmos de *pathfinding* que retornem caminhos com menores distâncias e custos topográficos.

2. Revisão da Literatura

DNN [Goodfellow *et al.* 2016] são algoritmos de aprendizagem de máquina formados por diversas camadas de unidades de processamento elementares. A topologia básica de um DNN é composta por camadas de entrada, intermediárias e de saída interagindo entre si, resultando num modelo matemático que possibilita a aprendizagem ou o reconhecimento de padrões em um conjunto de dados. O processo de aprendizagem consiste, essencialmente, na busca das características das unidades elementares, de maneira que a rede tenha a menor taxa de erro no conjunto de dados apresentado para

treinamento. Dentre outras arquiteturas de DNN, *ensemble* de DNN [Sagi e Rokach 2018] combinam as predições de um número finito de DNN, treinadas para a mesma finalidade, em uma única predição, potencialmente gerando um preditor com melhor generalização. Em contraste, algoritmos de *pathfinding* [Abd Algfoor *et al.* 2015] procuram o caminho mais curto ou de menor custo entre dois nodos, uma origem e um destino, em uma estrutura de representação do terreno em uso. A definição de mais curto ou de menor custo depende do problema abordado. Esses algoritmos podem funcionar com ou sem funções heurísticas compondo suas funções de custo. Uma heurística é uma função que estima o custo entre um nodo qualquer do mapa e um destino, sendo zero quando aplicada ao destino. Essa estimativa utiliza o conhecimento sobre o problema abordado para auxiliar o algoritmo na escolha do próximo nodo a ser analisado, indicando o quanto o nodo é promissor em relação a tarefa de chegar ao destino.

Trabalhos descritos na literatura têm explorado informações topográficas de mapas virtuais na computação de algoritmos de *pathfinding*. [Chen *et al.* 2009] utilizam uma estrutura irregular para representar a superfície de um terreno, onde cada polígono possui um vetor normal ao plano que representa o terreno. A busca de caminhos considera o ângulo entre os vetores normais em polígonos adjacentes. [Ganganath *et al.* 2015] transformam um modelo digital de elevação em um grafo ponderado, onde cada vértice representa um ponto do terreno. A função heurística utilizada resulta em caminhos com um balanceamento entre o comprimento e o perfil de inclinação do caminho, buscando caminhos com menor custo energético para deslocamento de robôs. [Chagas 2019] descreve um algoritmo de *pathfinding* ajustado para a computação de informações topográficas de mapas virtuais. Para representar terrenos de grandes dimensões, os mapas são capturados em uma estrutura hierárquica de *quadtree*, onde os nodos folha possuem vetores normais que representam inclinações do terreno. Utilizando as informações capturadas nesses vetores, a função heurística usada pelos algoritmos de *pathfinding* é baseada em computações de custo inversamente proporcionais ao cosseno do ângulo entre faces adjacentes dos nodos do mapa virtual.

Outros trabalhos descritos na literatura têm investigado o uso de DNN no apoio a resolução de diferentes problemas de busca. [Agostinelli *et al.* 2019] propõem a utilização de técnicas de aprendizagem por reforço profundo em funções heurísticas para solução do cubo de Rubik. [Ariki e Narihira 2019] descrevem uma arquitetura convolucional de DNN para analisar um mapa de obstáculos e um destino, produzindo um mapa heurístico, onde cada ponto do mapa contém o custo heurístico até o destino. [Jindal *et al.* 2017] propõem uma arquitetura para predizer o tempo de viagem de táxi entre duas coordenadas geográficas, combinando a predição da distância entre origem e destino e o horário do dia que a viagem deve ser realizada. Um algoritmo semelhante ao A^* é proposto por [Li, *et al.* 2016]. Esse algoritmo utiliza uma DNN como heurística para predizer a dificuldade de buscar um caminho em um mapa. [Takahashi *et al.* 2019] exploram a aplicação de arquiteturas para segmentação de objetos e geração de imagens em heurísticas de problemas de *pathfinding*. [Wang *et al.* 2019] utilizam uma arquitetura recorrente na heurística do algoritmo A^* para gerar recomendações de rota personalizadas. [Doebber 2019] descreve a aplicação de uma arquitetura *feedforward* nas computações de *pathfinding* em mapas de labirintos bidimensionais. Em resumo, apesar desses trabalhos empregarem diferentes arquiteturas de DNN, nenhum deles investiga a construção de heurísticas utilizando *ensemble* de DNN. Mais ainda, eles não analisam como usar tais DNN na otimização da busca de caminhos em terrenos contendo informações topográficas.

3. Metodologia

Os experimentos devem ser desenvolvidos em diferentes mapas, a partir dos dados de elevação obtidos pelo satélite ALOS - *Advanced Land Observing Satellite*, conforme exemplos na Fig. 1. Os mapas devem apresentar uma variação de, respectivamente, 30, 50 e 70% em suas áreas com inclinações entre 5 e 45%, permitindo avaliar o impacto dessas diferentes inclinações nos algoritmos de busca de caminhos e arquiteturas de DNN propostos.




Figura 1. Exemplos de mapas contendo informações topográficas

A estrutura de representação dos mapas deve ser de *grid* regular com 100^2 nodos. Informações de elevação nestes mapas devem ser codificadas utilizando vetores normais, tal como proposto em [Chagas 2019]. Para a seleção dos mapas com os percentuais definidos de inclinações deve ser utilizado o sistema de informação geográfica QGIS, por meio da geração de mapas de declividade. Produzidos os mapas, o trabalho deve investigar arquiteturas de *ensemble* de DNN. Para isso, o conjunto de dados para treinamento da DNN deve ser construído. Menores caminhos devem ser computados entre os nodos da estrutura de representação dos mapas utilizando o algoritmo A^* , o qual deve ser adaptado para terrenos com informações topográficas. Para cada caminho computado devem ser armazenados: origem, destino, nodos avaliados durante a busca, comprimento e custo do caminho computado. Construído o conjunto de dados de treinamento gerado para os mapas usados, arquiteturas de *ensemble* de DNN devem ser treinadas em 70% dos dados.

O algoritmo A^* considera o custo de um nodo (n) como sendo a distância real entre a origem e o nodo que está sendo analisado, representado pela função $g(n)$, onde n é o nodo sendo avaliado. Esse custo é acrescido por uma estimativa do custo até o destino, dada pela função heurística h , passando a ser $g(n) + h(n)$. Para considerar informações topográficas nessas computações, é acrescentando um fator inversamente proporcional ao cosseno da inclinação do nodo, onde o custo computado é diretamente proporcional a inclinação. Neste trabalho, DNN devem substituir tais heurísticas $h(n)$ nos algoritmos de *pathfinding* testados.

Ao final, os 30% restantes do conjunto de dados inicial devem ser utilizados para analisar estatisticamente o comportamento do algoritmo de busca implementado, utilizando as métricas: tempo de treinamento da DNN, tempo de execução do algoritmo de *pathfinding*, acurácia das DNN treinadas, a quantidade de nodos avaliados durante a busca de caminhos e custo/distância dos caminhos computados.

4. Considerações Finais

Algoritmos de *pathfinding* podem se beneficiar da capacidade das DNN, as quais podem ser exploradas na otimização das computações heurísticas requeridas por esses

algoritmos. A proposta descrita neste artigo visa testar e comparar arquiteturas de *ensemble* de DNN nas computações de caminhos em mapas virtuais com grandes dimensões. O objetivo é explorar essas arquiteturas de DNN na computação de heurísticas para algoritmos de *pathfinding* que consideram informações de elevação e inclinação. A partir dos experimentos que estão sendo desenvolvidos, e das análises estatísticas dos resultados, espera-se determinar formas de como construir *ensembles* de DNN que melhor aproximem as computações heurísticas dos algoritmos de *pathfinding* testados.

Referências

- Abd Algfoor, Z., Sunar, M. S. e Kolivand, H. (2015) "A comprehensive study on pathfinding techniques for robotics and video games," Int. Journal of Computer Games Technology.
- Agostinelli, F., McAleer, S., Shmakov, A. e Baldi, P. (2019) "Solving the Rubik's cube with deep reinforcement learning and search", Nature Machine Intelligence, vol. 1, pp. 356-363.
- Ariki, Y. e Narihira, T. (2019) "Fully Convolutional Search Heuristic Learning for Rapid Path Planners", arXiv preprint arXiv:1908.03343.
- Doebber, D. M. (2019) "Uso de redes neurais profundas para o aprendizado de funções heurísticas para algoritmos de busca de caminhos." Trabalho de Conclusão do Curso de Ciência da Computação. Santa Maria: Universidade Federal de Santa Maria.
- Chagas, C. (2019) "Algoritmos de busca de caminhos voltados para informações de altura e inclinação representadas em mapas de navegação", Trabalho de Conclusão de Curso em Ciência da Computação. Santa Maria: Universidade Federal de Santa Maria.
- Chen, S., Shi, G., Liu, Y. (2009) "Fast path searching in real time 3D game", WRI Global Congress on Intelligent Systems: IEEE. 3: 189-194 p.
- Ganganath, N., Cheng, C.-T., Chi, K. T. (2015) "A constraint-aware heuristic path planner for finding energy-efficient paths on uneven terrains", IEEE transactions on industrial informatics, v. 11, n. 3, p. 601-611.
- Goodfellow, I., Bengio, Y. e Courville, A. (2016) Deep learning, MIT press.
- Jindal, I., Chen, X., Nokleby, M. e Ye, J. (2017) "A unified neural network approach for estimating travel time and distance for a taxi trip", arXiv preprint arXiv:1710.04350.
- Li, G., Wang, G., Wang, Q., Fei, F., Lü, S. e Guo, D. (2016) "ANN: a heuristic search algorithm based on artificial neural networks", presented at the The 2016 International Conference on Intelligent Information Processing.
- Sagi, O. e Rokach, L. (2018), "Ensemble learning: A survey", Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery. 8. e1249. 10.1002/widm.1249.
- Takahashi, T., Sun, H., Tian, D. e Wang, Y. (2019) "Learning Heuristic Functions for Mobile Robot Path Planning Using Deep Neural Networks", presented at the Int. Conf. on Automated Planning and Scheduling.
- Wang, J., Wu, N., Zhao, W. X., Peng, F. e Lin, X. (2019) "Empowering A* Search Algorithms with Neural Networks for Personalized Route Recommendation", presented at the The 25th ACM SIGKDD Int. Conf. on Knowledge Discovery & Data Mining.