

Simulando padrões de acesso a memória com Wasserstein-GAN

Arnon Bruno Ventrilho dos Santos, Francis Birck Moreira, Marco Antonio Zanata Alves

Departamento de Informática – Universidade Federal do Paraná (UF)
Curitiba – PR – Brazil

abvsantos@inf.ufpr.br, mazalves@inf.ufpr.br

Resumo. Neste trabalho exploramos a possibilidade de simular traços de padrões de acesso a memória utilizando o mecanismo de redes neurais adversárias denominado Wasserstein-GAN (WGAN). A experimentação demonstrou que os padrões de footprint, diferença média entre endereços e reutilização de memória obtidos artificialmente são diferentes daqueles verificados a partir dos padrões reais. Este resultado sugere que o mecanismo de produção de traços artificiais não foi capaz de simular acessos com padrões realistas.

1. Introdução

Dentro do contexto da arquitetura de Von-Neumann, aplicações realizam operações e interação com a memória de um computador digital. Esse processo de interação com a memória produz padrões que são explorados nas estratégias de prefetching, que visam disponibilizar um determinado dado da memória dinâmica para uma memória cache e de menor latência, com o objetivo de aumentar a eficiência computacional. Estratégias de aprendizado de máquina ainda são pouco exploradas no contexto de arquitetura de computadores, embora possam ser utilizadas para descoberta de novas formas de acesso à memória, eventualmente produzindo melhorias [1]. Com este trabalho explora-se a criação de traços de memória sintéticos utilizando redes neurais adversárias do tipo WGAN. Estes traços sintéticos são produzidos com base em traços reais e seus padrões são comparados, com o objetivo de medir a qualidade dos traços sintéticos. A expectativa com esse experimento é verificar a capacidade de um mecanismo caixa-preta em produzir novos padrões de acesso à memória que, eventualmente, produzam maior qualidade para o *prefetching*.

2. Wasserstein GAN

WGAN é uma derivação das redes neurais adversárias (GANs) originais [2]. Sua criação visa resolver a instabilidade do treinamento de GANs aplicando algumas mudanças à estrutura original. A principal adaptação é a utilização de uma nova rede adversária denominada “Crítico”, que ao invés vez de emitir a probabilidade de uma determinada amostra ser real ou falsa (como faz o “Discriminador” na GAN original), emite um sinal indicando o quão realista é a amostra sintética. Foi demonstrado experimentalmente que as amostras sintéticas produzidas utilizando essa estratégia apresentam maior similaridade às amostras reais [3].

3. Metodologia

Para este experimento, treinou-se a WGAN utilizando traços de memórias reais. Esses traços estão contidos em um único arquivo texto que, por conta do seu tamanho, foi dividido em partes menores para viabilizar o treinamento das redes neurais contidas na WGAN. Essas redes neurais são do tipo densas fully-connected, onde cada neurônio é conectado aos demais neurônios da camada seguinte. Cada rede possui 3 camadas escondidas, cada uma com 16 neurônios, o que mostrou-se eficiente para obtenção de dados sintéticos de natureza tabular [4].

A WGAN foi então treinada durante 100 ciclos (épocas) em cada uma das 30 partes, o que significa que a WGAN teve a oportunidade de aprender os padrões de cada parte 100 vezes e, a partir disso, produzir um novo conjunto de padrões sintéticos do mesmo tamanho. Após o final do treinamento, todas as partes foram unificadas de maneira a apresentarem um único arquivo de traços sintéticos. Por fim, analisamos os resultados comparando os traços sintéticos aos reais, medindo os padrões de footprint, diferença média entre endereços, e reutilização de memória.

3. Resultados

O arquivo contendo os traços reais possui aproximadamente 700 milhões de endereços de memória, e o mesmo número de traços sintéticos foi obtido utilizando a metodologia citada acima. Monitorando o custo (loss) em cada uma das partes durante o treinamento, verificou-se que nenhuma das partes apresentou custo de amostras sintéticas superior ao dos traços reais, o que sugere que os traços sintéticos foram identificados como realistas pelos “Crítico” da WGAN. No entanto, os resultados abaixo demonstram que há diferenças significativas entre os conjuntos reais e sintéticos. Isto sugere que essa metodologia não foi capaz de simular padrões de memória realistas.

	Traços Reais	Traços Sintéticos
<i>Footprint</i>	7.086.651	20.444.317
Distância Média	44,308	11,677
Reutilização	123.558	10.568

4. Referencias

- [1] Hashemi, Milad, et al. "Learning memory access patterns." International Conference on Machine Learning. PMLR, 2018.
- [2] Goodfellow, Ian, et al. "Generative adversarial nets." Advances in neural information processing systems 27 (2014)
- [3] Arjovsky, Martin, Soumith Chintala, and Léon Bottou. "Wasserstein generative adversarial networks." International conference on machine learning. PMLR, 2017
- [4] Santos, Arnon, and Deborah Ribeiro Carvalho. "Generating synthetic 2019-nCoV samples with WGAN to increase the precision of an Ensemble Classifier." Iberoamerican Journal of Applied Computing 10.2 (2020).