



SALÃO DE INICIAÇÃO CIENTÍFICA XXVIII SIC

paz no plural



Evento	Salão UFRGS 2016: SIC - XXVIII SALÃO DE INICIAÇÃO CIENTÍFICA DA UFRGS
Ano	2016
Local	Campus do Vale - UFRGS
Título	Confiabilidade e Criticalidade de GPUs Embarcadas para Aplicações Automotivas
Autor	LUCAS FERNANDO WEIGEL
Orientador	PHILIPPE OLIVIER ALEXANDRE NAVAUX

Título: Confiabilidade e Criticalidade de GPUs Embarcadas para Aplicações Automotivas

Autor: Lucas Fernando Weigel

Orientador: Philippe Olivier Alexandre Navaux

UFRGS

A indústria automotiva não vem economizando esforços para o desenvolvimento de carros autônomos, com sistemas capazes de detectar veículos e pedestres e parar autonomamente. Torna-se então imprescindível a avaliação da confiabilidade de tais sistemas. O trabalho desenvolvido consiste em uma avaliação pioneira da confiabilidade do HOG (*Histogram of Oriented Gradients*), um algoritmo muito utilizado para a detecção de pedestres. Através de um experimento no Laboratório Nacional de Los Alamos (LANL), avaliam-se os erros induzidos pela radiação nesse algoritmo, utilizando um feixe de nêutrons controlado. Também é feita uma injeção de falhas a fim de identificar as partes mais críticas do algoritmo e propor soluções para aumentar a confiabilidade do algoritmo.

O experimento consistiu em dois dispositivos APU, da AMD, e quatro dispositivos K1, da Nvidia, rodando repetidamente o algoritmo enquanto expostas ao feixe de nêutrons. A opção por GPUs embarcadas foi eficiência e velocidade. Toda vez que um erro devido à exposição foi detectado (isto é, uma divergência entre o resultado obtido e o resultado esperado, aquele obtido através da execução normal sem exposição), o resultado errôneo foi salvo para ser analisado.

Para quantificar e qualificar os erros obtidos, foram utilizadas quatro métricas: o número de BBs (Binding Boxes) resultante, que são retângulos marcados pelo detector que representam os pedestres; o Centro de Massa, que avalia a distribuição das BBs no frame; a Precision, que representa a probabilidade de uma BB marcada pelo detector representar de fato um pedestre; e o Recall, que representa a probabilidade que um pedestre foi de fato marcado com uma BB pelo detector.

Na APU, 24% dos erros observados mantiveram o número de BBs marcadas correto. Na K1, esse número foi de 45%. Considerando apenas esses casos, o ponto representando o Centro de Massa das BBs nunca ficou mais do que 1% deslocado. Além disso, nenhum desses resultados obteve uma Precision ou um Recall menores que 98%. Dessa forma, é seguro afirmar que, se o número de BBs permaneceu correto, a detecção pode ser considerada correta.

Nos casos onde o número de BBs foi diferente do esperado, os resultados observados são mais críticos. Na APU, apenas 60% desses resultados mantiveram valores seguros de Precision e Recall superiores a 98%. Nessa arquitetura, foram observados resultados bastante críticos, com valores atingindo 10% ou até 0%. Tais resultados muito provavelmente ocasionariam acidentes. Na K1, 40% dos resultados mantiveram valores superiores a 98%, e observa-se valores de Precision de até 80%, indicando possíveis detecções que não correspondem a pedestres de fato, e Recall de até 90%, indicando possíveis pedestres não detectados.

Através da injeção de falhas, percebeu-se que as partes mais críticas do algoritmo são as últimas e mais computacionalmente intensivas: *Orientation*, *Block Normalization* e *Classifier*. Nesse último, uma SVM (*Support Vector Machine*) é utilizada para identificar os pedestres. Uma matriz com os parâmetros para a correta identificação é carregada no pré-processamento e armazenada em memória. Toda vez que um erro foi injetado nessa matriz, observou-se um resultado errôneo, visto que o algoritmo usou de parâmetros errados para a detecção. Como essa matriz é eventualmente armazenada em cache devido ao uso contínuo, ela torna-se sujeita à erros. Sugere-se duplicação dessa matriz, mesmo em cache, ou então mantê-la em memória principal, tipicamente mais protegida e menos sujeita à erros.

Como trabalhos futuros, têm-se a ideia de uma implementação por *deep learning* e redes neurais, treinada para detectar os erros provenientes da radiação e evitar possíveis acidentes.