

## Semantic SuperPoint: Um Descritor Semântico Profundo

Gabriel Soares Gama

Nícolas dos Santos Rosa, Valdir Grassi Junior

Universidade de São Paulo

gabriel\_gama@usp.br, nicolas.rosa@usp.br, vgrassi@usp.br

**Palavras-chave:** Visão Computacional, Odometria Visual, Robótica

### Objetivos

Diversos métodos de SLAM se beneficiam do uso de informação semântica. A maioria adiciona informação semântica de alto nível, como detecção de objetos e segmentação semântica, aos métodos fotométricos. Esta pesquisa propõe que informação semântica também pode ser utilizada nos métodos de extração de *features* através do treinamento de um extrator de *features* profundo com segmentação semântica. Assim, seria uma maneira mais robusta em comparação a utilização de apenas informações de alto nível, já que seria aprendida intrinsecamente pelo descritor e não seria dependente da qualidade final.

### Métodos e Procedimentos

Nesta pesquisa foi utilizado o modelo SuperPoint (Sp) [1] como base. A arquitetura do modelo Sp é um *encoder* compartilhado seguido de dois *decoders*, um para a extração de KeyPoints e outro para o descritor. Para adicionar informação semântica, foi utilizada a técnica de aprendizado multitarefa, adicionando uma *semantic head* para realizar segmentação semântica. O modelo proposto, Semantic SuperPoint (SSp), pode ser visto na Figura 1. Para balancear a otimização dos objetivos foram utilizados três métodos. A soma uniforme, balanceamento das funções de perda considerando a incerteza [2] e o método *central dir + tensor* [3] que calcula um gradiente para melhorar todas as tarefas.

Para treinar o modelo, foi selecionado o *dataset* MS-COCO 2017 [4] e o HPatches [5] para a avaliação, de acordo com as métricas de

detector e descritor descritas no artigo do Sp [1]. Como foram utilizadas diversas métricas, se fez necessário criar um critério de avaliação. Então, foi considerado o *matching score* (MS) como a principal, já que representa a porcentagem de *inliers*. Logo, avalia tanto o detector quanto o descritor, além de ser a mais relacionada com tarefas de SLAM.

Além disso, os modelos foram utilizados como extratores de *features* no ORB-SLAM2 [6] e foram avaliados de acordo com a métrica *absolute position error* (APE) obtida ao gerar por SLAM as trajetórias no *dataset* do Kitti [7]. Vale notar que, ao adicionar o *decoder* extra, o custo de treinamento aumenta, mas o de inferência é mantido, pois a predição da segmentação semântica não é necessária após o treinamento.




Figura 1: Semantic SuperPoint

### Resultados

Na Tabela 1, têm-se os resultados de métodos de extração de *features*, tanto clássicos quanto

profundos. Foram utilizadas as abreviações *uni* para a função de perda uniforme, *unc* para a incerteza e *ct* para o método *central dir + tensor*.

Extrator de features	Estimação Homográfica			Métricas do detector	Métricas do descriptor				
	$\epsilon = 1$	$\epsilon = 3$	$\epsilon = 5$			Rep.	MLE	NN mAP	M.S.
ORB	.150	.395	.538	<b>.641</b>	1.157	.735	.266		
SIFT	.424	.676	.759	.495	<b>.833</b>	.694	.313		
LIFT	.284	.598	.717	.449	1.102	.664	.315		
Sp + uni (referência)	<b>.476</b>	.748	<b>.817</b>	.599	1.017	<b>.864</b>	.519		
Sp + unc	.460	.745	.812	.599	1.010	<b>.864</b>	.520		
Sp + ct	<b>.493</b>	.753	.812	.602	1.001	.862	.519		
SSp + uni (nossa)	.398	.710	.797	.584	1.052	.843	.506		
SSp + unc (nossa)	.450	.745	.816	.598	1.005	<b>.864</b>	<b>.522</b>		
SSp + ct (nossa)	.466	<b>.762</b>	.805	.598	0.999	.858	.519		

Tabela 1: Resultados no HPatches

Considerando o MS, o modelo SSp teve um resultado melhor, com um pequeno aumento de **+0.2%** em comparação com o Sp + unc. Para a estimação homográfica, teve um melhor resultado que o Sp + unc no caso  $\epsilon = 5$ , enquanto balanceava as métricas do detector. Para a avaliação no ORB-SLAM2, as sequências foram executadas 10 vezes e na Tabela 2 as médias dos erros ATE de cada trajetória são exibidas para cada modelo, junto ao valor-p obtido pelo teste Kruskal-Wallis.

Sequência	Sp	SSp	Valor-p
00	6.77	<b>6.65</b>	0.71
01	286.71	<b>209.99</b>	0.13
02	22.46	<b>22.31</b>	0.82
03	<b>1.32</b>	1.63	0.00
04	<b>0.84</b>	0.90	0.94
05	<b>5.80</b>	6.31	0.82
06	11.95	<b>11.83</b>	0.41
07	3.39	<b>2.12</b>	1.00
08	31.32	<b>26.70</b>	0.00
09	35.94	<b>31.79</b>	0.00
10	5.51	<b>4.95</b>	0.02

Tabela 2: Resultados no kitti

Analisando os erros em cada trajetória, o modelo SSp obteve um resultado melhor em 8 situações, sendo pelo menos 3 relevantes, enquanto o modelo Sp só possui um resultado melhor que seja relevante.

Portanto, adicionar informação semântica melhora métodos de extração de *features* profundos.

## Conclusões

Percebe-se então que adicionar informação semântica em uma arquitetura baseada em um *encoder* compartilhado em combinação com métodos de aprendizado de multitarefa, melhora o desempenho de métodos de extração *features*

profundos e, nesse caso, sem adicionar custo computacional na inferência.

Trabalhos futuros podem ajustar a intensidade do processo de *data augmentation* e a complexidade do *dataset* de treinamento para balancear a capacidade de generalização e aprendizado semântico. O modelo também pode ser treinado por outro método de aprendizado que não dependa do processo intensivo de *data augmentation*.

Além disso, caso tenha obtido uma predição semântica de qualidade satisfatória, é possível utilizar a informação de alto nível para aplicar os métodos de SLAM semântico.

## Referências Bibliográficas

- [1] DeTone, D., Malisiewicz, T., & Rabinovich, A. (2018). Superpoint: Self-supervised interest point detection and description. In Proceedings of the IEEE conference on computer vision and pattern recognition workshops (pp. 224-236).
- [2] Kendall, A., Gal, Y., & Cipolla, R. (2018). Multi-task learning using uncertainty to weigh losses for scene geometry and semantics. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 7482-7491).
- [3] Nakamura, A. T. M., Wolf, D. F., & Grassi Jr, V. (2022). Leveraging convergence behavior to balance conflicting tasks in multi-task learning. arXiv preprint arXiv:2204.06698.
- [4] Lin, T. Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., ... & Zitnick, C. L. (2014, September). Microsoft coco: Common objects in context. In European conference on computer vision (pp. 740-755). Springer, Cham.
- [5] Balntas, V., Lenc, K., Vedaldi, A., & Mikolajczyk, K. (2017). HPatches: A benchmark and evaluation of handcrafted and learned local descriptors. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 5173-5182).
- [6] Raul Mur-Artal and Juan D. Tardos. ORB-SLAM2: An open-source SLAM system for monocular, stereo, and RGB-d cameras. IEEE Transactions on Robotics, 33(5):1255–1262, oct 2017.
- [7] Geiger, A., Lenz, P., Stiller, C., & Urtasun, R. (2013). Vision meets robotics: The kitti dataset. The International Journal of Robotics Research, 32(11), 1231-1237.