

LANDMARK EXTRACTION USING SELF-ORGANIZING MAP

Viktor Žáček

Master Degree Programme (2), FEEC BUT

E-mail: xzacek01@stud.feec.vutbr.cz

Supervised by: Václav Jirsík

E-mail: jirsik@feec.vutbr.cz

Abstract: This paper deals with extraction of landmarks, from laser scanner data. The landmarks are used for localization of a robot in environment. The idea of algorithm is to automatically choose landmarks, selecting as landmarks places that differs from the usual surroundings of the robot. Landmarks extraction is done by self-organizing map also known as Kohonen neural network. The main goal is to obtain a simple method of landmarks extraction, that can be used regardless of the characteristics of the environment.

Keywords: Self-organizing map, Landmark extraction, Kohonen neural network

1 ÚVOD

Extrakce orientačních bodů je významnou součástí problematiky současné lokalizace a mapování, SLAM. Problematika SLAM se zabývá lokalizací robota v neznámém prostředí. Robot ve svém okolí vyhledá výrazné body, které označí za orientační. Robot se pomocí těchto orientačních bodů orientuje na základě změny své polohy vůči těmto bodům [2]. Snímání okolí robota je v dnešní době obvykle zajišťováno laserovým skenerem.

Algoritmů pro získání orientačních bodů je celá řada, mnohé z nich jsou však buď velmi složité, nebo jsou využitelné pouze ve specifických prostředích (vnitřek budov). Mnou navržená metoda je založená na faktu, že za orientační bod je možno považovat cokoli, co se nějakým způsobem výrazně odlišuje od svého okolí. Pro extrakci je využita samo-organizační mapa. Jedná se o neuronovou síť používající učení bez učitele. V následujícím textu budou popsány jednotlivé části algoritmu.

2 SAMO-ORGANIZAČNÍ MAPA

Samo-organizační mapa je dvojrvtvá plně propojená neuronová síť s topologicky uspořádanou výstupní vrstvou. Charakteristickými rysy této neuronové sítě jsou učení bez učitele a funkce sousedství. Funkce sousedství zajišťuje rovnoměrné pokrytí vstupního prostoru a uspořádanost vstupně-výstupního mapování.

Algoritmus učení je následující: Po předložení trénovacího vzoru x , se vypočte Eukleidovská vzdálenost D , pro každý neuron j , dle rovnice:

$$D(j) = \sum_{i=1}^n (w_{ij} - x_i)^2. \quad (1)$$

Kde w jsou váhy neuronu a n je dimenze vstupních dat. Neuron, který má Eukleidovskou vzdálenost nejmenší, se stává vítězným neuronem j^* . Tento neuron změní své váhy tak, aby se více přiblížily k tréninkovému vzoru. Spolu s ním změní své váhy taktéž všechny neurony, které spadají do jeho okolí. Změna vah je dána rovnicí [1]:


$$w_j(t+1) = w_j(t) + \Theta(j^*)\mu(t)[x(t) - w_j(t)]. \quad (2)$$

Kde μ je parametr učení a $\Theta(j^*)$ je funkce sousedství. Funkce sousedství závisí na vzdálenosti neuronu j od vítězného neuronu j^* , je definována poloměrem okolí $\rho(t)$. Parametry μ a ρ se s rostoucím počtem iterací snižují.

V aktivním režimu sítě je aktivní vždy jen jeden výstupní neuron, a to ten jehož váhy jsou nejbližší datům na vstupu sítě (viz rovnice 1).

3 UČENÍ SAMO-ORGANIZAČNÍ MAPY

Algoritmus pracuje s daty získanými pomocí laserového skeneru. Pro účely lokalizace byla ze 3D skenů vyříznuta pouze jedna 2D rovina. Jako vstup do neuronové sítě slouží okno o velikosti n , body v tomto okně jsou popsány vzájemným úhlem. Tento popis zajišťuje invariantnost vůči posunutí a natočení. Pro odstranění rozptylu bodů způsobeného nepřesností měření je vhodné data vyhladit průměrujícím filtrem.



Obrázek 1: Okno o délce $n = 5$.

Samo-organizační mapa má na vstupu $n - 2$ neuronů. Jako trénovací data slouží vzorové skeny prostředí, v němž očekáváme, že se robot bude pohybovat. Okno je posunováno přes všechny body a tato data vstupují do neuronové sítě.

Po ukončení učení je určen nejvhodnější neuron pro extrakci orientačních bodů. Ten je vybrán na základě aktivační mapy sítě. Ta je získána tak, že je síť aktivována postupně všemi trénovacími daty, přičemž se každému neuronu počítá počet aktivací. Neuron, který byl aktivován nejméně, ale byl aktivován alespoň třikrát pro každý sken, je zvolen jako neuron pro extrakci orientačních bodů.

4 EXTRAKCE ORIENTAČNÍCH BODŮ

Pro extrakci orientačních bodů posíláme na vstup samo-organizační mapy okna z neznámého prostředí. Pokud je aktivován neuron zvolený pro extrakci, je dané okno považováno za orientační bod. Následně je nutno zkontrolovat, zda už robot někdy stejný orientační bod nevidoval. To se provede srovnáním nového orientačního bodu s již dříve uloženými body v databázi. Pokud je míra shody nižší než nastavený práh, je okno uloženo jako nový orientační bod. Spolu s oknem jsou uloženy souřadnice prvního bodu a úhel přímky mezi prvním a druhým bodem okna vůči ose x v souřadném systému robota.

5 NASTAVENÍ ALGORITMU

Výsledky algoritmu závisí na správném nastavení všech parametrů neuronové sítě.

Stěžejní je volba velikosti okna n , pro malou velikost okna je algoritmus výpočetně nenáročný, ale kvalita orientačních bodů je malá. Orientační značky složené jen z několika bodů skenu jsou snadno zaměnitelné a jejich znovupozorovatelnost je malá. S rostoucí velikostí okna jsou získány lepší orientační body, ale výpočetní náročnost roste. Vhodný rozsah parametru n je 5-15.

Dalším podstatným parametrem je rozměr výstupní vrstvy mapy. S více neurony na výstupu je vstupní prostor rozdělen na více shluků. Protože však příliš jemné dělení vstupního prostoru není žádoucí, ukázala se jako ideální velikost výstupní vrstvy 4×4 neurony.

Algoritmus učení samo-organizační mapy iteruje velmi rychle. Byla použita ostrá funkce sousedství $\Theta(j)$ s lineárně se snižujícím poloměrem ρ v čase:

$$\rho = \rho_0 - \frac{n}{j}. \quad (3)$$

Kde ρ_0 je počáteční poloměr okolí, ρ je okolí současné, n je počet proběhlých iterací a j je krok poloměru okolí. Vhodné hodnoty parametrů pro mapu 4×4 jsou $\rho_0 = 2$, $j=2-5$.


Funkce parametru učení μ je exponenciální:

$$\mu = \mu_0 e^{-kn}. \quad (4)$$

Kde μ_0 je počáteční parametr učení, μ je aktuální parametr učení, n je počet proběhlých iterací a k je koeficient snižování parametru učení v čase. Vhodné hodnoty parametrů jsou $\mu_0 = 0.8, k = 0.1$.

Ukončovací podmínkou učení samo-organizační mapy je počet iterací N , pro uvedené hodnoty parametrů je vhodnou hodnotou $N = 15$.

Na obrázku 2 vidíme možný výsledek algoritmu, zelené kružnice označují efektivní část skenu (body příliš blízko skeneru jsou zarušené dvojitým odrazem laseru a body příliš vzdálené jsou velmi řídké).



Obrázek 2: Extrahované orientační body ze skenu.

6 ZÁVĚR

Byla navržena metoda extrakce orientačních bodů z laserových skenů pomocí samo-organizační mapy. Metoda je výpočetně velmi jednoduchá. Po naučení mapy odpovídajícími daty ji lze použít pro jakékoliv prostředí. Výsledky algoritmu jsou dané správným nastavením jednotlivých parametrů mapy. Nevýhodou metody je nedeterminismus metody, tedy že algoritmus pokaždé dává jiný výsledek. Algoritmus byl otestován na 35 skenech z interiéru budovy a na 74 venkovních skenech. Skeny byli pořízeny 3D skenerem HDL-64E S2.

REFERENCE

- [1] Volná, E.: Neuronové sítě 1. Ostravská univerzita v Ostravě, 2008.
- [2] Durrant-Whyte, H.; Bailey, T.: Simultaneous Localisation and Mapping (SLAM): Part I The Essential Algorithms. IEEE ROBOTICS AND AUTOMATION MAGAZINE, ročník 2, 2006: str. 2006.