

Data z mobilních robotů

Michal Dvořák

Abstrakt— Tento článek se zabývá paralelní rekonstrukcí tvarů pomocí Kohenenových map. Naměřená data pocházejí z laserového senzoru používaného v mobilní robotice. Při rozkladu dat na shluky byla použita metoda PCA (Principal Component Analysis).


I. ZADÁNÍ

Zadáním této práce je rozložení množiny naměřených dat na jednotlivé shluky a ty pak aproximovat pomocí Kohenenových map.

II. ÚVOD

Mobilní roboty mohou pro svoji orientaci využít laserový senzor (dálkoměr), který umožňuje identifikovat okolí robota. Výstupem takového měření jsou pak souřadnice bodů od kterých se odrazil laserový paprsek. Na obr. 1 jsou vstupní data pořízená laserovým scannerem na chodbě ve druhém patře na katedře kybernetiky. Obsahují 13006 bodů s rastrem 10 cm.

Problém je však v tom, že dat je velmi mnoho a je obtížné je využít pro účely robota. Cílem je tedy z naměřených dat rekonstruovat prostředí kolem robota s minimální datovou reprezentací. Při praktické implementaci je také důležité, aby algoritmus pracoval v reálném čase.



Obr. 1. Vstupní naměřená data

Jedno z možných řešení je rekonstrukce prostředí pomocí Kohenenovy samo - organizující se mapy (SOM). SOM je jednovrstvá neuronová síť provádějící shlukovou analýzu. Její učení je založeno na uspořádání neuronů tak, aby reprezentovaly předložená data co nejlépe ve smyslu nějakého kritéria. Vhodným kritériem může být například minimalizace euklidovské vzdálenosti.

Aplikace SOMu najednou na všechna data je jednak časově velmi náročná a nelze s ní dosáhnout kvalitní reprezentace dat. Je tedy třeba nejdříve naměřená data rozdělit do shluků

pro které se navrhnu jednotlivé SOM mapy. Tyto mapy se nakonec spojí do jednotné reprezentace. Pro rozdělování do shluků byl použit algoritmus k -means. Tento algoritmus rozděluje vstupní množinu na předem nastavený počet shluků a je založen na minimalizaci euklidovské vzdálenosti.

Při aplikaci k -means na naše data však dochází k tomu, že některé shluky přecházejí z jedné stěny na druhou. V rohových oblastech pak shluk může obsahovat až 3 stěny. Pro dobrou reprezentaci SOM mapou však potřebujeme spíše rovinné shluky což k -means algoritmus samozřejmě nemůže zajistit. Proto byla při rozkladu dat použita také metoda PCA (Principal Component Analysis), která umožňuje detekovat zda jsou shluky rovinné či nikoliv.


Metoda PCA vlastně umožňuje testovat, zda k dané množině dat existuje nízko-dimenzionální reprezentace, což v našem případě představuje rovinu oproti obecnému 3D shluku. Nechť shluk $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_m]$ obsahuje m n -rozměrných vektorů se střední hodnotou

$$\mu = \frac{1}{m} \sum_{i=1}^m \mathbf{x}_i.$$

Význačné směry ve shluku \mathbf{X} nalezneme pomocí vlastních vektorů matice

$$\mathbf{S} = \sum_{i=1}^m (\mathbf{x}_i - \mu)(\mathbf{x}_i - \mu)^T.$$

Provedeme SVD rozklad matice \mathbf{S} na $\mathbf{S} = \mathbf{V}\mathbf{\Lambda}\mathbf{V}^T$, kde \mathbf{V} je matice vlastních vektorů a matice $\mathbf{\Lambda}$ je diagonální matice příslušných vlastních čísel. Vlastní vektory příslušející relativně velkým vlastním číslům odpovídají význačným ortogonálním směrům v datech \mathbf{X} .



Obr. 2. Detekce roviny metodou PCA

Je-li jedno vlastní číslo výrazně menší než ostatní, můžeme tak usoudit, že data lze dobře reprezentovat daty nižší dimenze. V našem případě rovinou.

III. CÍL PRÁCE


Cílem této práce je pokusit se rozložit data na shluky, které budou mít rovinný charakter a reprezentovat je SOM mapou.

IV. EXPERIMENTY

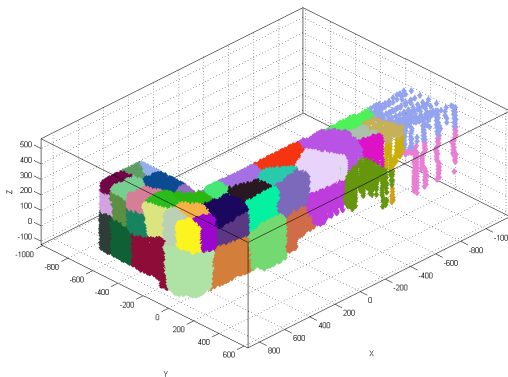
Celá práce byla vytvořena v programu MATLAB s využitím SOM toolboxu. Nejprve byla data rozložena na 30 shluků pomocí k -means algoritmu (obr.3). Dále byly provedeny experimenty s metodou PCA. Pro každý shluk byl proveden SVD rozklad a určen koeficient

$$\varepsilon = \frac{\max(|\lambda_i|)}{\min(|\lambda_i|)}.$$

Pro shluky s $\varepsilon \leq 5$ byl proveden rozklad daného shluku na další dva a tři podshluky. Podle maximálního součtu kritéria ε jednotlivých podshluků byl potom původní shluk nahrazen 2-podshlukem nebo 3-podshlukem. Cílem bylo nahradit shluk obsahující dvě stěny 2-podshlukem a shluk obsahující tři stěny 3-podshlukem. Tato metoda se však příliš neosvědčila, protože při rozkladu shluku na podshluky není zaručeno, že podshluky budou nutně rovinné. Což plyne z podstaty k -means algoritmu.



Obr. 3. Rozklad dat na 30 shluků




Obr. 4. Rozklad dat na shluky pomocí metody PCA - 57 shluků


Nakonec byl algoritmus upraven tak, že když je $\varepsilon \leq 5$ tak se vždy vypočte 2-podshluk a jejich koeficienty ε . Jeli opět kritérium příliš špatné ($\varepsilon \leq 20$) vypočtou se další dva podshluky. V nejhorším případě se tedy vytvoří s daného shluku 2

podshluky, z nichž každý obsahuje opět 2 podshluky a původní shluk je tedy nahrazen podshluky čtyřmi. Výsledek je na obr. 4. Celkem byla data rozložena na 57 shluků. Je patrné že velké rovinné shluky zůstaly zachovány a problematické shluky se rozdělily na dva či čtyři podshluky což bylo požadováno.

Další krokem byla reprezentace shluků 3D SOM mapou. Nejprve byl algoritmus učení odzkoušen na jednom rovinném shluku. Výsledek funkce som_make je vidět na obr.5. Protože se mapa neroztáhla až do okrajů shluku byla upravena finální trénovací fáze učícího algoritmu. Poloměr okolí ve finální učící fázi radius_fin byl zmenšen z hodnoty 1 na hodnotu 0.01. Jak je vidět na obr.6 změna tohoto parametru výsledek výrazně zlepšila. Použitá obdelníková verze vykazovala nepatrně lepší pokrytí než hexagonální uspořádání mapy.




Obr. 5. SOM mapa s parametrem radius_fin = 1



Obr. 6. SOM mapa s parametrem radius_fin = 0.01

Nakonec byly SOM mapou pokryty všechny shluky získané rozkladem dat pomocí PCA metody. Výsledek je zobrazen na obr.7.



Obr. 7. Reprezentace všech shluků pomocí SOM map

V. DISKUSE

Použití metody PCA při rozkladu dat na shluky umožňuje vytvoření shluků rozdílné velikosti díky detekci rovin ve shlucích. Shluky, které tvoří rovinu zůstanou zachovány a problematické shluky ležící v rozích stěn jsou rozděleny na další podshluky, což je pro následující aplikaci SOM mapy vhodné. Nevýhodou může být o něco větší časová náročnost při výpočtu SVD rozkladu a nutnost nastavovat prahové koeficienty, které rozhodnou, zda se nové podshluky vytvoří či nikoliv.

Dalším krokem k vytvoření celé reprezentace dat je seřadování jednotlivých map do celku. To však již nebylo cílem této práce.

VI. ZÁVĚR

Bylo zjištěno, že použití metody PCA při rozkladu vstupních dat na shluky umožňuje lépe rozložit oblasti v okolí rohů stěn a potom lépe aplikovat SOM mapu. Všechny takto vzniklé shluky byly nakonec aproximovány SOM mapou. Při učení SOM mapy byl upraven koeficient poloměru přitahování mřížky pro lepší roztažení mapy přes celý shluk.