

Vyhodnocení hyperspektrálních snímků pomocí neuronových sítí

Ing. Jiří Čech <jiri.cech@tul.cz>

Speciální Hyperspektrální kamery dokáží zaznamenat scénu v desítkách až stovkách úzkých spektrálních pásmech, a tím získat pro každý bod scény jeho spektrální charakteristiku. Na základě ní, lze pomocí předem naučené neuronové sítě, rozpoznat materiál, který je v daném místě obsažený. Rozpoznávání materiálů je omezené detekčním spektrálním pásmem kamery a vyžaduje naměření a ohodnocení velkého množství učicích dat. Výsledná síť lze posléze integrovat přímo do výpočetního modulu kamery.


Klíčová slova: Hyperspektrální snímky, Neuronové sítě, Konvoluční neuronové sítě, detekce materiálu

Úvod

Úkolem projektu je vyhodnocování snímků z vyvíjené hyperspektrální kamery, která umožňuje detekci nebezpečných látek zaznamenáním spektrální charakteristiky v dlouhovlnné infračervené oblasti. Vyhodnocovací metody založené na porovnávání charakteristik dvou vzorků [1] neposkytují dostatečnou přesnost a vyžadují přesnou kalibraci a stabilitu vlastností kamery [2]. Využití neuronových sítí dosahuje výrazně přesnějších výsledků i při méně kvalitních vstupních snímcích [3], ale pro jejich aplikaci je potřeba vytvoření rozsáhlé databáze vzorových dat, na kterých se daná síť natrénuje.


Metodika

Pro záznam scény využíváme světlocitlivé senzory, které převádějí dopadající záření na elektrickou hodnotu a tím vytváří monochromatický snímek scény. Přidáním masky barevných filtrů před senzor vytvoříme multispektrální kameru (Obrázek 1), která v několika bodech zaznamená spektrální charakteristiku daného místa v obraze. Nejznámější z nich je kombinace modrého, zeleného a červeného filtru, pomocí kterých jsme schopni detekovat barvy obdobně jako lidské oko.




Obrázek 1: Multispektrální snímek

Hyperspektrální kamery vylepšují metodu záznamu spektrální charakteristiky na desítky až stovky bodů, viz Obrázek 2.



Obrázek 2: Hyperspektrální snímek

Nevýhodou je, že v důsledku dělení spektrální charakteristiky na více bodů, klesá jejich energie, a proto jsou kladeny vyšší nároky na kvalitu senzoru, který musí být citlivější. Naměřená data následně projdou náročnou korekcí [2][4], aby nebyla zatížena vlastnostmi kamery, viz Obrázek 3.



Obrázek 3: Spektrální charakteristika obrazového bodu: a) naměřená, b) po korekci, c) skutečná

Naměřené průběhy je pak možné porovnávat se vzorovými průběhy a podle míry schody je rozpoznat [1][4]. Kvalita rozpoznání bohužel není příliš vysoká, a proto využíváme neuronových sítí, které dosahují kvalitnějších výsledků. Jako vstup jim stačí surová naměřená data daného bodu a jeho blízkého okolí [3].

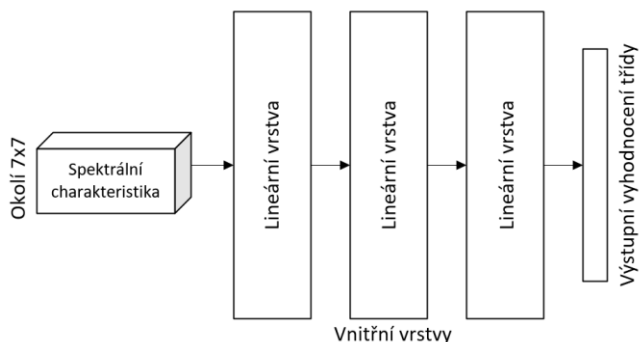
Výsledky a diskuze

Experimentálně byla naměřena kalibrační sada čítající deset různých materiálů. Pro porovnání každé naměřené spektrální charakteristiky „x“ s referenčními „y“, byla aplikována metoda Euklidovské vzdálenosti (1).

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1)$$


Pro zpřesnění vyhodnocení byla rozpoznávaná charakteristika daného prostorového bodu rozšířená o jeho okolí v rozsahu 3×3, 5×5 a 7×7 bodů.

Vyhodnocení bylo provedeno pomocí hlubokých neuronových sítí (NN), které se skládají z kaskády vrstev vzájemně propojených neuronů, viz Obrázek 4. Každý neuron sčítá hodnoty neuronů předchozí vrstvy násobené natrénovanými váhami.



Obrázek 4: Struktura hluboké neuronové sítě

Úspěšnost vyhodnocení deseti tisíc vzorků od každého materiálu pomocí jednotlivých metod znázorňuje Obrázek 5. Metoda pomocí měření Euklidovské vzdálenosti dosáhla 85 % a zahrnutí okolí nevedlo k jejímu zlepšení. Oproti tomu neuronové sítě dosáhli 92 % a při rozšíření vstupu o jeho okolí se úspěšnost zlepšila na 98 %.



Obrázek 5: Graf úspěšnosti vyhodnocení jednotlivých metod

Závěr

Podařilo se nasnímat hyperspektrální kamerou sadu vzorků, které byly vyhodnoceny pomocí několika metod. Nejlepších výsledků dosáhla neuronová síť vyhodnocující daný bod a jeho okolí s úspěšností 98 %. Dále bych se chtěl zaměřit na redukci výpočetních nároků neuronové sítě a její integraci do výpočetního modulu kamery.

Poděkování

Tato práce byla podpořena z projektu Studentské grantové soutěže (SGS) na Technické univerzitě v Liberci v roce 2019.

Reference

- [1] J. M. Bioucas-Dias, A. Plaza, G. Camps-Valls, P. Scheunders, N. Nasrabadi and J. Chanussot, "Hyperspectral Remote Sensing Data Analysis and Future Challenges", IEEE Geoscience and Remote Sensing Magazine, vol. 1, no. 2, pp. 6-36, June 2013.
- [2] R. Olbrycht, B. Więcek and G. De Mey, "New approach to thermal drift and gain non-uniformity correction in microbolometer detectors", Thermal Investigations of ICs and Systems (THERMINIC), Paris, 2011, pp. 1-4
- [3] X. Yang, Y. Ye, X. Li, R. Y. K. Lau, X. Zhang and X. Huang, "Hyperspectral Image Classification With Deep Learning Models", IEEE Transactions on Geoscience and Remote Sensing, vol. 56, no. 9, pp. 5408-5423, Sept. 2018.
- [4] F. Zhu, Y. Wang, S. Xiang, B. Fan and Ch. Pan, „Structured Sparse Method for Hyperspectral Unmixing“, ISPRS Journal of Photogrammetry and Remote Sensing, arXiv e-prints, 2014, arXiv: 1403.4682.