

Metody Deep Learning k segmentaci obrazu

Segmentace obrazu spočívá v jeho rozdělení na dvě či více částí za účelem získat užitečné informace o snímané scéně. Techniky založené na metodách známých jako *deep learning* (také *Deep Learning*; učení do hloubky) automaticky segmentují reálné snímky na části odpovídající konkrétnímu významu. Softwarový systém Matlab, jakožto vývojové prostředí pro vědeckotechnické výpočty, nabízí v oboru segmentace obrazu jak klasické metody, tak techniky využívající *deep learning*.

„Segmentace obrazu je metoda – nebo spíše skupina metod, založených na různých principech – digitálního zpracování obrazu, sloužící k automatickému rozdělení vlastního

náhlé nespojivosti v hodnotách parametrů pixelů. Skokové změny v hodnotách parametrů pixelů (změna jasu nebo barvy) obvykle naznačují okraj hledané oblasti. Jiné metody


- regionální metody založené na podobnosti pixelů v dané vlastnosti (parametru),
- metody založené na hranicích (detekce hran na snímku),
- pokročilejší metody, jako např. aktivní kontury či segmentace rozvodím.

Efektivní přístup k segmentaci obrazu obvykle vyžaduje kombinaci specializovaných funkcí a nástrojů v komplexnějším prostředí pro analýzu dat, vizualizaci a vývoj vlastních algoritmů.

Segmentace obrazu a Matlab

Softwarový systém Matlab je inženýrský nástroj a interaktivní prostředí pro vědecké a technické výpočty, analýzu dat, vizualizaci, vývoj algoritmů, modelování a simulace. Jde o nástroj určený jak pro pohodlnou interaktivní práci, tak pro vývoj širokého spektra aplikačních programů. O podpoře metody *deep learning* v prostředí Matlab přehledově pojednává [1].

V oboru segmentace obrazu Matlab poskytuje množství funkcí. Základní prahování lze provést použitím funkce *imbinarize*, která stanovuje úroveň prahu Otsuovou metodou, popř. lze provést i víceúrovňové prahování. K segmentaci na základě informací o barvě je možné využít jednoduché logické operace k určení oblastí s podobnou barvou nebo provést shlukovou analýzu (funkce *kmeans*). Pracovat lze v barevném prostoru RGB, L*a*b, HSV či YCrCb. Automaticky vyhledat podobné oblasti v obraze umožňuje také funkce *superpixels*. Hranice v obraze vyhledává funkce *edge* při použití Cannyho hrano-



Obr. 1. Ukázky metod segmentace obrazu: prahování (A), segmentace podle barev (B), segmentace rozvodím (C), segmentace podle textury (D)

obrazu na části (oblasti) se společnými vlastnostmi a obvykle nějakým smysluplným významem. Typickým účelem segmentace obrazu je identifikace popředí a určení oblastí v obraze odpovídajícím významnému prvku zachycené scény...“ (<http://cs.wikipedia.org>).

Rozdělení obrázku na oblasti je obvykle založeno na charakteristikách obrazových bodů – pixelů. Jedním ze způsobů, jak separovat oblasti v obraze, je např. vyhledat

rozdělují obraz na části na základě blízkých barevných hodnot nebo podobnosti textury.

Základní metody segmentace obrazu

Obraz lze segmentovat mnoha rozličnými způsoby. K především používaným metodám segmentace patří (obr. 1):

- metody založené na tzv. prahování (hodnocení jasu každého pixelu),

💡

📶

🤖

📊

🌐

MATLAB® & SIMULINK®

ROZBĚHNĚTE ÚSPĚŠNĚ
VÁŠ STARTUP

„Získejte za **výhodných podmínek** profesionální nástroj, který se stal celosvětovým standardem v oblasti technických výpočtů, modelování a simulací, generování kódu a certifikace.“

www.humusoft.cz/startups

HUMUSOFT®

Humusoft s.r.o.
Pobřežní 20, Praha 8

E-mail: info@humusoft.cz
Tel: +420 284 011 730

vého detektoru nebo Sobelova filtru. K segmentaci obrazu na základě textury je možné využít filtraci funkcemi *entropyfilt*, *stdfilt* nebo *rangefilt*.

Z pokročilejších metod segmentace je v prostředí Matlab k dispozici segmentace rozvodím (funkce *watershed*), segmentace aktivními konturami (funkce *activecontour*) nebo oddělení popředí a pozadí (funkce *lazysnapping*).



Obr. 2. Sémantická segmentace obrazu metodami typu deep learning

Prostředí Matlab poskytuje též přípravnou grafickou aplikaci *Image Segmentation App*, ve které lze obrázky segmentovat s využitím palety připravených nástrojů.

Co základní metody nevyřeší

Segmentace na základě barev či kontur dokáže obrázky rozdělit tak, že jsou odděleny a ohraničeny jednotlivé objekty. Bez dalších doprovodných informací však nedokáže přiřadit objektům význam. Pokud např. víme, že hledáme červené auto na šedé vozovce, segmentovaná část snímku s převahou červené barvy bude velmi pravděpodobně námi hledané vozidlo.

Co však v případě, že taková apriorní informace není k dispozici nebo jde o složitou scénu s mnoha objekty?

Zde je možné sáhnout k sémantické segmentaci, využívající učení do hloubky – deep learning. Metodami typu deep learning lze rozdělit obrázek na oblasti odpovídající konkrétnímu významu. Ukázka sémantické segmentace obrázku, zde snímku horní části Václavského náměstí v Praze, je na obr. 2.

Sémantická segmentace přiřazuje ke každému pixelu v obrázku kategorie, jimiž jsou konkrétní typy objektů. Obrázek se tím rozdělí na oblasti s daným významem a je možné jej využít pro hlubší pochopení snímané scény. Na pozadí sémantické segmentace je využíván tzv. model deep learning, který v sobě nese veškeré nezbytné informace. Žádná další apriorní informace zde tudíž není k segmentaci třeba.

Co je deep learning

Deep learning je metoda strojového učení, kterou je, při použití mnohovrstvých neli-

neárních výpočetních modelů, získávána užitečná informace přímo z dat. V klasifikačních úlohách dosahují modely deep learning velké přesnosti, která může předčít lidské schopnosti. Modely jsou trénovány s využitím velkého množství označených dat a jejich struktura je založena na hlubokých neuronových sítích (*deep networks*). Využívají se zejména tzv. konvoluční neuronové sítě (*Convolutional Neural Network – CNN*), jejichž záklá-


CNN v prostředí Matlab

V prostředí Matlab se s CNN pracuje velmi pohodlně. Jsou zde připraveny funkce k vytváření jednotlivých vrstev sítě, jejich parametry může uživatel nastavovat. Poté vrstvy pospojuje, síť natrénuje a naučenou síť použije na nová data.

Typická klasifikační CNN se může skládat z vrstvy *ImageInput* pro vstup obrázků, jedné nebo několika za sebou zapojených skupin vrstev *Convolution2D* + *BatchNormalization* + *ReLU* + *MaxPooling2D* a navazujících klasifikačních vrstev *FullyConnected* + *Softmax* + *ClassificationOutput* (obr. 4).

Prostředí Matlab obsahuje funkce umožňující vytvářet více než dvacet typů vrstev a je zde k dispozici i šablona pro tvorbu vrstev nových, definovaných uživatelem.

Naučení celé konvoluční neuronové sítě z výchozího nastavení vyžaduje ohromné množství trénovacích dat. Alternativním přístupem k učení „od nuly“ je využití předučené sítě, která již sama extrahuje charakteristické rysy ze vstupních dat a kterou postačí „douchit“ pro konkrétní úlohu. Tento přístup, označovaný jako *transfer learning*, je poho-



Obr. 3. Princip fungování konvoluční neuronové sítě (CNN): ReLU – aktivací funkce (Rectified Linear Unit)

dem jsou vrstvy provádějící dvoudimenzionální (2D) konvoluci vstupních dat s naučenými filtry. Sítě CNN jsou vhodné zejména ke zpracování 2D dat, jako jsou obrázky.

Mezi jednotlivé konvoluční vrstvy jsou často jako doplněk vloženy vrstvy pro úpravu výstupů. Jestliže je síť určena ke klasifikaci obrázků, bývá zakončena vrstvami zajišťujícími přiřazení klasifikační třídy (hledaného objektu) ke vstupnímu obrázku (obr. 3).

dlnou cestou použití metody deep learning bez nutnosti použít velké množství údajů a bez dlouhé doby učení.

Prostředí Matlab nabízí k využití oblíbené předučené sítě, jako jsou AlexNet (síť naučená s 1,2 milionu obrázků, obsahuje 23 vrstev, klasifikuje objekty do 1 000 kategorií), VGG-16, VGG-19 (*Visual Geometry Group – VGG*) nebo GoogLeNet.

Vedle sítí se sériově řazenými vrstvami

(vrstvy následují jedna za druhou) je možné vytvářet i sítě rozvětvené. V prostředí Matlab lze konstruovat sítě s architekturou DAG (*Directed Acyclic Graph*). Rozvětvené sítě mohou zvětšit přesnost, usnadnit ladění a umožňují využít oblíbené předtrénované modely (GoogLeNet).

```
vrstvy = [imageInputLayer([28 28 1]);
convolution2dLayer(5,20);
batchNormalizationLayer();
reluLayer();
maxPooling2dLayer(2,'Stride',2);
fullyConnectedLayer(10);
softmaxLayer();
classificationLayer()];
nastaveni = trainingOptions('sgdm');
cnn = trainNetwork(trenovaciObrázky, vrstvy, nastaveni);
vysledek = classify(cnn, novyObrázek);
```

Obr. 4. Zápisi typické klasifikační CNN v prostředí Matlab

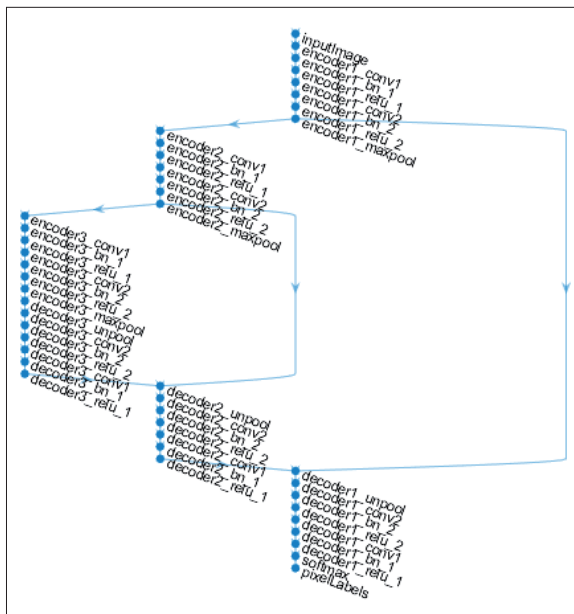
Sémantická segmentace v prostředí Matlab

V prostředí Matlab je k dispozici funkce `semanticseg(img,network)`, která provede sémantickou segmentaci daného obrázku při použití připravené hluboké neuronové sítě (výsledek takto provedené sémantické segmentace obrázku je ukázán na obr. 2).

Efektivní sémantickou segmentaci obrázků umožňuje speciální struktura hluboké neuronové sítě zvaná SegNet [1]. V prostředí Matlab lze síť SegNet vytvářet při použití funkce `segnetLayers`. Síť SegNet je síť typu DAG a obsahuje několik skupin vrstev (obr. 5). Každá skupina se skládá z vrstev *Convolution2D*, *BatchNormalization*, *ReLU* a *MaxPooling2D* nebo *MaxUnpooling2D*. Na vstupu sítě je vrstva *ImageInput* pro vstup obrázku a na výstupu sítě jsou vrstvy *Softmax* a *PixelClassification* pro přiřazení klasifikačních kategorií jednotlivým pixelům v obrázku.

Na vstup sítě přichází obrázek určený k segmentaci. Skupiny v první polovině sítě jsou označovány jako kodéry a slouží k extrakci významných rysů z obrázku, na základě kterých se určují jednotlivé segmenty. V druhé části sítě se nachází stejný počet skupin označovaných dekodéry, které

zpětně mapují segmenty vytvořené sítě na původní obrázek. Na výstupu sítě je segmentovaný obrázek se stejnou velikostí jako vstupní obrázek. Počet skupin kodérů a dekodérů si uživatel může zvolit. Na obr. 5 je zobraze-



Obr. 5. Síť SegNet se třemi skupinami kodérů/dekodérů

na struktura sítě SegNet se třemi skupinami kodérů/dekodérů.

Uživatel si také může zvolit, zda vytvoří „čistou“ síť SegNet, kterou naučí od základu, nebo využije předtrénovanou síť, založenou na síti VGG-16 nebo VGG-19.

Trénování sítě pro sémantickou segmentaci vyžaduje velké množství označených obrázků, kde jsou jednotlivým oblastem přiřazeny kategorie. V prostředí Matlab je k dispozici grafická aplikace Image Labeler, která manuálně označování snímků částečně automatizuje a tím celý proces urychluje.

Využití sémantické segmentace v praxi

V současné době jsou typickými oblastmi využití sémantické segmentace tyto obory:

- autonomní řízení vozidel,
- průmyslové inspekční systémy,
- klasifikace satelitních snímků,
- analýza snímků v lékařství.

S dalším nárůstem výpočetní síly lze předpokládat, že se sémantická segmentace nejen bude dále používat stále častěji ve velkých analytických systémech, ale pronikne též do světa vestavných zařízení, zejména v oboru autonomní dopravy.

Literatura:

- [1] Deep Learning v prostředí Matlab. *Automa*. Děčín: Automa – ČAT, 2017, (5), 12–14. ISSN 1210-9592.
- [2] BADRINARAYANAN, Vijay – Alex KENDALL a Roberto CIPOLLA. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. arXiv preprint. arXiv:1511.00561, 2015.

Jaroslav Jirkovský,
Humusoft s. r. o.

Automatizace nevyčerpatelné a udržitelné energetiky

Článek podává informaci o semináři energetického cyklu E2017, který organizuje již mnoho let společnost EGÚ Praha Engineering, a. s. Seminář se konal 14. června 2017 a jeho hlavním tématem byly velké systémové energetické zdroje v České republice.

Důvodem pro uspořádání tematického semináře byla skutečnost, že v odborných energetických časopisech se o elektroenergetice píše, jako by už v nejbližších letech měly obnovitelné zdroje OZE téměř zcela nahradit klasické elektrárny. Přitom „stávající“ klasické (kondenzační) elektrárny budou v provozu minimálně do roku 2050 a jaderné minimálně do roku 2100.

Předpokladem a podmínkou efektivního provozu velkých energetických bloků je vysoká úroveň automatizace energetických procesů. V souvislosti s vyčerpatelností a udržitelností české energetiky je zmíněn tzv. Krajíčkův zákon, z něhož vyplývá, že by Česká republika měla budovat

dvojnásobnou elektrickou přenosovou soustavu, nikoliv ji kapacitně utlumovat. Důvod pro výstavbu a rozvoj je jednoznačný: potřeba zvládnout na konci tohoto století všechny výkonové rázy a přetoky elektřiny vzniklé z nevyčerpatelných zdrojů (solární a větrná energie). V závěru je upozorněno na absolutní nedostatek propagace českého jaderného i nejaderného energetického průmyslu a nedostatek informací o možnostech výstavby jaderných bloků v ČR s maximální účastí českých průmyslových podniků. V této souvislosti jsou specifikovány přínosy výstavby nových velkých klasických i jaderných elektráren pro konkurenceschopnost českého průmyslu.

Dostupné zdroje energie pro lidstvo

Krajíčkův zákon, formulovaný na konci 60. let minulého století českým geografem Liborem Krajíčkem [1], nepoužívá současnou terminologii „obnovitelné“ a „neobnovitelné“ zdroje, ale dělí je na „vyčerpatelné“ a „nevyčerpatelné“. Mezi nevyčerpatelné patří slunce, gravitace, zemský klimatický systém [2], geotermální energie a slapové síly. Vyčerpatelné zdroje teprve pak dělí na „obnovitelné“ (rostlinná biomasa) a „neobnovitelné“ (fosilní zdroje uhlí a uran).

Podle Krajíčka by Československo (podobně to dnes platí pro země střední Evropy včetně ČR) mělo budovat dvojnásobnou elektrickou přenosovou soustavu – možná v některých místech trojnásobnou –, aby na konci století zvládlo všechny rázy a přetoky elektřiny získané z nevyčerpatelných zdrojů,