

# Deep learning vs. signály a časové řady

Nové postupy umožňují používat metodu deep learning také v oboru analýzy jednorozměrných údajů, signálů a časových řad.

Metoda *deep learning* (popř. *Deep learning* či *Deep Learning*, učení do hloubky) je technika z oboru umělé inteligence, při níž je s použitím mnohovrstvých nelineárních výpočetních modelů získávána užitečná informace přímo z výchozích údajů. V klasifikačních úlohách dosahuje metoda deep learning velké přesnosti, kterou může předčít lidské schopnosti. Softwarový nástroj Matlab, vývojové prostředí pro vědeckotechnické výpočty, nabízí v oboru deep learning mnoho

Základem struktur modelů pro deep learning jsou tzv. hluboké neuronové sítě (*deep networks*). Tyto sítě se skládají z mnoha za sebou seřazených vrstev s různým významem. Nejjednodušší sítě mají okolo deseti vrstev, zatímco aktuální výkonné modely mohou obsahovat i stovky vrstev uspořádaných do sério-parallelních struktur.

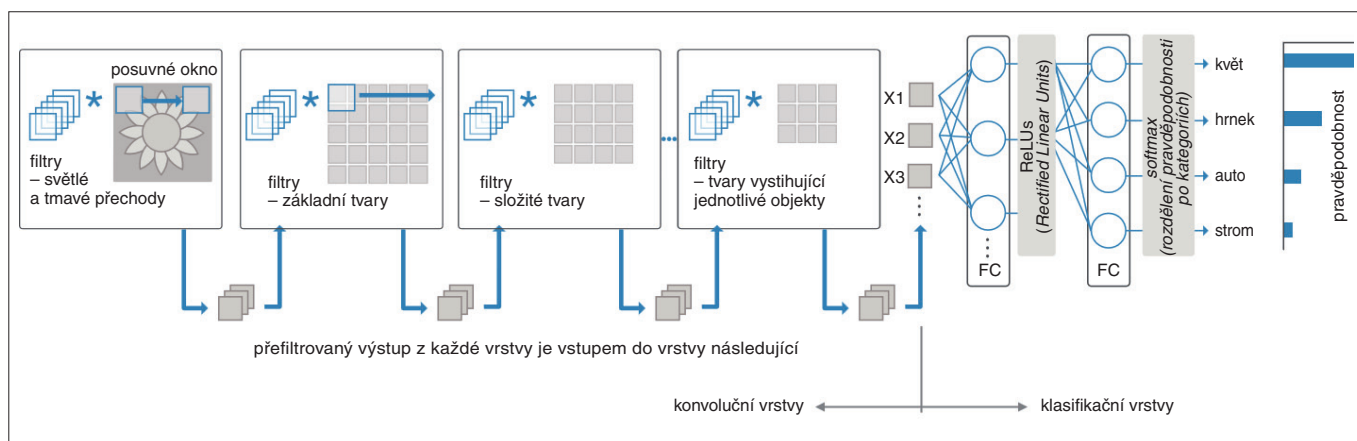
Technika deep learning nachází využití v mnoha směrech, zejména v úlohách:

- klasifikace obrazových údajů, rozpoznávání objektů na snímcích,
- lokalizace objektů na snímcích,
- sémantická segmentace snímků, rozdělení snímku na části podle významu,
- predikce a klasifikace signálů a časových řad.

ně co nejpřesnější, vyžadují ke svému naučení tisíce, či dokonce miliony vzorků. Naučení takového modelu může trvat i velmi dlouhou dobu.

## Učení metodou transfer learning

Naučení celé hluboké neuronové sítě z jejího výchozího nastavení je úloha náročná na čas i množství trénovacích údajů. Alternativním přístupem je využít předem naučenou (tzv. předučenu) síť, která již byla naučena pro jinou klasifikační nebo regresní úlohu a která ze vstupních údajů sama extrahuje charakteristické rysy. V tomto případě stačí síť „doučit“ pro novou úlohu.



Obr. 1. Princip fungování konvoluční neuronové sítě (CNN)

různých algoritmů a podporuje jejich použití při řešení reálných úloh.

## Souhrnně o metodě deep learning

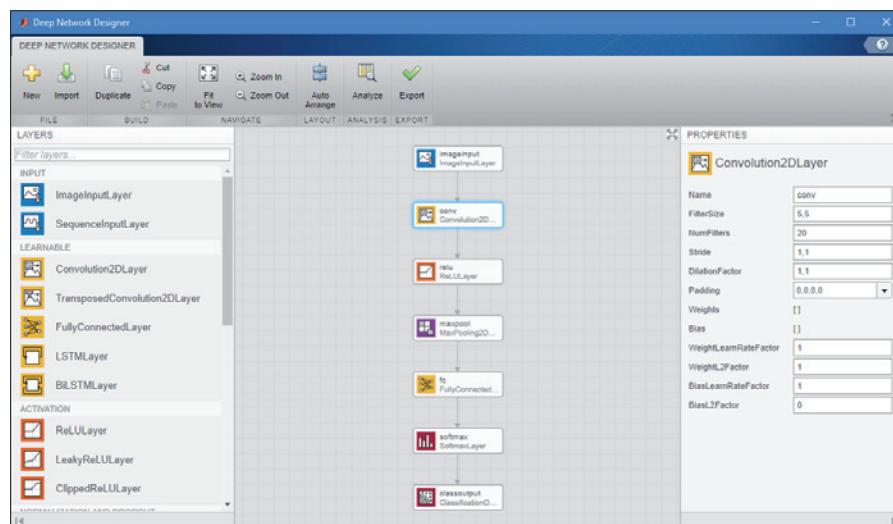
„Umělá inteligence (*Artificial Intelligence* – AI) je obor informatiky zabývající se tvorbou strojů vykazujících známky inteligentního chování. Definice pojmu *inteligentní chování* je stále předmětem diskuse, nejčastěji se jako etalon inteligence užívá lidský rozum“, viz <http://cs.wikipedia.org>.

Metoda deep learning spadá do podoboru umělé inteligence zvaného *strojové učení*. Cílem je řešit klasifikační úlohy, kdy je údajům přiřazena klasifikační kategorie (např. druh zvířete na obrázku), nebo úlohy regresní, kde je výstupem hodnota spojitě veličiny (např. odhadovaná cena nemovitosti). Jádrem algoritmů strojového učení jsou matematické modely, které jsou „učeny“ s využitím množiny označených údajů, u níž je předem známa správná hodnota výsledku. Naučený model je následně použit ke zpracování nové množiny údajů, u které se výsledek hledá.

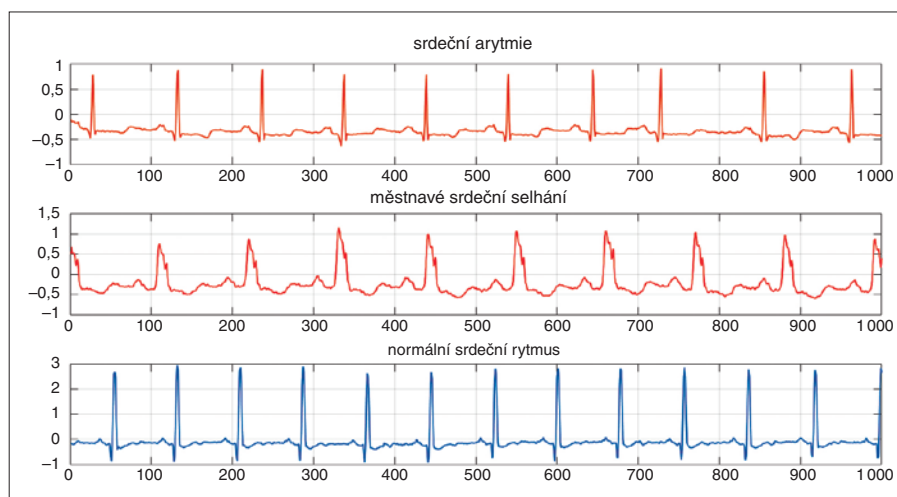
## Učení modelů deep learning

Přesnost modelu deep learning závisí z velké části na množství údajů použitých k jeho naučení. Mají-li modely být skuteč-

Vychází se ze skutečnosti, že počáteční vrstvy sítě extrahují z údajů základní obecné rysy, jež jsou pro většinu úloh společné. Tyto počáteční vrstvy lze tedy využít opakovaně. Doučit stačí pouze vrstvy blíže ke konci sítě,



Obr. 2. Nástroj Deep Network Designer



Obr. 3. Typické elektrokardiogramy srdeční činnosti (EKG)

keré již extrahují rysy specifické pro konkrétní úlohu. Tento přístup, označovaný jako *transfer learning*, je pohodlnou cestou použití metody deep learning s využitím omezeného množství údajů a relativně krátkou dobou do naučení. V současné době existuje mnoho volně dostupných předučných sítí, které je možné v praxi využít.

### Rozpoznávání obrazu

K rozpoznávání objektů na snímcích se využívají tzv. konvoluční neuronové sítě (*Convolutional Neural Network – CNN*), jejichž jádrem jsou konvoluční vrstvy. Výpočetní algoritmus CNN je založen na konvoluci mezi vstupními údaji a filtry, které reprezentují hledané charakteristické rysy (obr. 1). Síť CNN využívá dvourozměrné (2D) konvoluční vrstvy, a je tedy vhodná pro zpracování 2D souborů údajů, jako jsou obrázky. Mezi konvoluční vrstvy bývají

vají vsazeny vrstvy pro úpravu dílčích výstupů, např. normalizaci, sdružování (*pooling*) apod. Za sadu konvolučních vrstev jsou napojeny vrstvy klasifikační nebo regresní, jejichž výstupem je pravděpodobnost přiřazení klasifikačních tříd (objektů) ke vstupnímu obrázku nebo predikovaná hodnota.

### Metoda deep learning a Matlab

Software Matlab je inženýrský nástroj a interaktivní prostředí pro vědecké a technické výpočty, analýzu dat, vizualizaci, vývoj algoritmů, modelování a simulace. Se sítími CNN se v prostředí Matlab pracuje velmi pohodlně. Jsou zde připraveny funkce pro vytvoření více než dvaceti různých typů vrstev, jejichž parametry může uživatel sám nastavovat. Poté uživatel vrstvy pospojuje, síť natrénuje a využije ke klasifikaci či predikci hodnot s novými údaji.

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*. Příslušný zápis v programovém kódu je následující:

```
vrstvy = [imageInputLayer(velikost_obr);
convolution2dLayer(velikost_filtru,pocet);
batchNormalizationLayer;
reluLayer;
maxPooling2dLayer(okno,'Stride',krok);
fullyConnectedLayer(pocet_trid);
softmaxLayer;
classificationLayer];
volby = trainingOptions(,sgdm');
cnn = trainNetwork(obrazky,vrstvy,volby);
vysledek = classify(cnn,novy_obrazek);
vysledek = classify(cnn,novy_obrazek);
```

K práci s CNN lze s výhodou využívat výpočty v grafických procesorech (GPU). Prostředí Matlab nabízí ke stažení a využívání oblíbené předučné sítě, jako např. *AlexNet*, *GoogLeNet* nebo *ResNet*.

Síť CNN je možné vytvářet a editovat též v grafickém nástroji *Deep Network Designer* (obr. 2).

### Signály a časové řady

Jak využít potenciál a výkonnost konvolučních neuronových sítí při práci s jednorozměrnými signály a časovými řadami? Jednou z možností je převést s použitím časově-frekvenční transformace signály na „obrázky“. Výsledkem transformace je obrázek změn rozložení frekvencí v signálu v čase. Může jít o spektrogram, který využívá Fourierovu transformaci, nebo scalogram, který využívá vlnkovou (*wavelet*) transformaci. Konvoluční neuronová síť je poté použita ke zpracování transformova-

# MATLAB® & SIMULINK®

„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](http://www.humusoft.cz/startups)

ROZBĚHNĚTE ÚSPĚŠNĚ  
VÁŠ STARTUP

Humusoft s.r.o.  
Pobřežní 20, Praha 8

E-mail: [info@humusoft.cz](mailto:info@humusoft.cz)  
Tel: +420 284 011 730

ných údajů stejným způsobem, jako by pracovala s běžnými obrázky.


### Ukázka použití CNN: klasifikace EKG

Příkladem použití metody deep learning k práci s jednorozměrnými (1D) signály je klasifikace elektrokardiogramů (EKG). Dále použité údaje jsou veřejně dostupné na webových stránkách Physionet (<https://physionet.org/>). Na obr. 3 jsou signály srdečního rytmu ze tří situací: srdeční arytmie, městnavé srdeční selhání a normální srdeční rytmus. Cílem bylo naučit hlubokou neuronovou síť tyto tři situace rozpoznat.

Aby bylo možné využít sílu konvolučních neuronových sítí, byly úseky záznamů srdečního rytmu převedeny s využitím spojité vlnkové transformace na scalogramy (obr. 4).

Ke klasifikaci byla využita předučena síť AlexNet složená z 25 vrstev. Síť AlexNet je natrénována na 1,2 milionu obrázků a rozpoznává 1 000 druhů objektů (druhy zvířat, kancelářské předměty atd.). K rozpoznání srdečního ryt-

mu byla téměř celá síť ponechána v originální podobě, pouze poslední klasifikační vrstvy byly nahrazeny novými, „čistými“ vrstvami. Síť byla poté doučena na údajích reprezentovaných ve 130 scalogramech elektrokardiogramů zahrnujících tři sledované kategorie srdečního rytmu. Fungování naučené sítě



Obr. 4. Scalogram elektrokardiogramu se záznamem srdeční arytmie

bylo ověřeno s použitím validační sady údajů, když síť dosáhla úspěšnosti větší než 93 %.

### Alternativa: síť LSTM

Alternativou k použití konvolučních neuronových sítí jsou sítě LSTM (*Long Short-Term Memory*), které jsou přímo navrženy pro práci s jednorozměrnými signály a časo-

vými řadami. Hlavní složkou těchto sítí jsou tzv. vrstvy LSTM, přičemž vrstva LSTM je rekurentní neuronová síť (*Recurrent Neural Network – RNN*), schopná naučit se dlouhodobé závislosti v signálech, tj. závislosti ze vzdálených časových kroků. Síť LSTM lze využít ke stejným účelům jako síť konvoluční (CNN), tedy k řešení klasifikačních a regresních úloh.

Typická klasifikační síť LSTM v prostředí Matlab může být vytvořena sestavením vhodných vrstev a dále trénována a volána příkazy *trainNetwork*, *classify* a *predict*, stejně jako síť konvoluční, takto:

```
vrstvy = [sequenceInputLayer(kanaly);
          lstmLayer(delka_vnitri_pameti);
          fullyConnectedLayer(pocet_trid);
          softmaxLayer;
          classificationLayer];;
```

### Závěr

Časově-frekvenční transformace signálů ve spojení s „obrázkovými“ konvolučními neuronovými sítěmi (CNN) a využití sítí LSTM zavádí metodu deep learning do oblasti jednorozměrných údajů, signálů a časových řad. Uplatnění nachází jak v technických oborech, tak i např. v lékařství, biologii a finančnictví.

Jaroslav Jirkovský,  
Humusoft, s. r. o.

### ► Průmysl 4.0 a smart manufacturing – ATS Knowledge Day

Společnost ATS aplikované technické systémy uspořádala ve dnech 31. října a 1. listopadu 2018 třetí ročník ATS Knowledge Day, věnovaný chytrým továrnám a průmyslu 4.0. Podělila se o zkušenosti se zaváděním výrobních informačních systémů MES v průmyslových podnicích a představila softwarová řešení, která vyvíjejí inženýři ATS pro chytré továrny.

Jednotlivé prezentace představily některé z aktuálních projektů, na kterých se podílí odborníci ATS z Nového Jičína, Olomouce nebo Loun v rámci jak vlastních projektů, tak projektů nadnárodní skupiny. Byly představeny především projekty z oblastí strojírenství, automobilního průmyslu a potravinářství.

Velkou diskusi otevřela přednáška o projektu měření kvality usazení dveří v auto-

mobilu, což jednoznačně ukazuje na aktuálnost tohoto tématu u výrobců automobilů. K zajímavým informacím patřilo sdělení, že v současnosti již mnoho automobilek vyžaduje protokol o kvalitě jednotlivých dílů ještě před vlastní dodávkou např. dveří na sklad. Z těchto protokolů se mimo jiné vytváří digitální dvojče konkrétního kusu, kde je možné vysledovat působení odchylek jednotlivých částí vozu na celkový dopad a konstrukční tolerance. Takto lze přesunout posuzování výsledné kvality již do předvýrobní fáze a včas eliminovat negativní důsledky sčítání odchylek od požadavků.

I další příspěvek se věnoval oboru výroby automobilů. Zde se ATS pochlubilo dodávkou několika pracovních stanic významnému výrobcí automobilových reflektorů z regionu. Nešlo pouze o řízení výrobní linky z PC stanic pomocí softwaru LabView, ale o ukázkou, jak je možné řešit výrobní linku s velkými požadavky na flexibilitu (např. časté změny výrobních parametrů) a na měření a kontrolu každého vyrobeného kusu nebo jak funguje

ukládání velkého množství dat, ze kterých lze zpracovávat podrobné reporty.

Závěrečná odborná přednáška byla věnována implementaci systému třídy MES ve velké potravinářské firmě s mnoha pobočkami v zemích západní Evropy. Kromě relativně běžných informací o implementaci systému Simatic IT posluchače zaujala zkušenost uživatele, který všechny servery z většiny provozů v různých zemích provozuje jako virtuální v centrále v Londýně. Tento přístup vede k výraznému zvýšení kvality servisu a provozu informačních systémů, naproti tomu vyžaduje velmi kvalitní přenosové cesty mezi centrálou a jednotlivými podniky.

I díky diskusím se čas věnovaný tomuto odbornému semináři protáhl. Nikdo ovšem nelitoval, protože obsáhle diskuse hovoří o zájmu, který uvedené prezentace vyvolaly, o vhodném výběru témat a o schopnostech společnosti ATS projekty ve spolupráci nejen řešit a realizovat, ale také podle přání jednotlivých uživatelů vyvíjet.

Radim Adam