

## ROLE EXPERTA PŘI TVORBĚ SYSTÉMŮ PRO PODPORU ROZHODOVÁNÍ

Lenka Lhotská, Vladimír Krajča, Hana Schaabová, Martin Macaš, Václava Piorecká, Václav Gerla

### Anotace

Cílem příspěvku je ukázat výhody zapojení experta do tvorby znalostního obsahu systému pro podporu rozhodování nejen v klasickém pojetí formalizace znalostí experta do báze znalostí, ale i poněkud méně tradičním způsobem. Tento přístup se začal v nedávné době nazývat „human/expert-in-the-loop“. Základní myšlenkou je využít znalosti experta, které nemusejí být obsaženy v datech, jejichž analýzu chceme provádět, ale které mohou významně zlepšit kvalitu rozhodovacího procesu. Často je možné v rámci tohoto kroku integrovat znalosti více expertů. Pokud se takové přístupy využívají přímo v metodách strojového učení, označují se také jako aktivní učení. Na několika případových studiích z různých oblastí medicíny ukážeme, v jakých fázích procesu vývoje může expert vhodně do procesu zasáhnout.

První případová studie je věnována porovnání výsledků získaných pomocí znalostního systému, jehož báze znalostí byla vytvářena manuálně formalizací slovně popsaných znalostí, a pomocí metod strojového učení, konkrétně rozhodovacího stromu, naučeného na větším souboru dat. Následně byla báze znalostí porovnána s rozhodovacím stromem a doplněna o vybraná pravidla z tohoto stromu. Takto upravená báze znalostí poskytovala lepší rozhodnutí než původní. Další dvě případové studie jsou zaměřené na úlohu klasifikace v dlouhodobých záznamech biologických signálů, konkrétně elektroencefalografických a polysomnografických. U této úlohy je klíčové nalézt vhodný poměr mezi zobecněnými metodami, použitelnými na záznamy všech pacientů, a metodami nastavenými na konkrétního pacienta (jedna z možností personalizace). Motivací pro takové řešení je velká interpersonální variabilita, a u řady diagnóz i intrapersonální variabilita. Možnost interaktivního vstupu experta do procesu analýzy záznamů může přispět ke zvýšení kvality a konzistence hodnocení.

### Klíčová slova

*strojové učení, aktivní učení, expertní hodnocení, multidimenzionální data, kontext dat, EEG*

### 1 Úvod

V minulosti byla velká snaha vytvářet nástroje pro plně automatickou klasifikaci dat. Do značné míry jsou tyto systémy úspěšné v oblastech, kde vlastní klasifikace není závislá na dalších informacích, které nejsou obsaženy v datech, nebo kde není významná variabilita ve vstupních datech. Velkou odlišností lékařských úloh je interpersonální variabilita v patientských datech a v některých úlohách i dokonce intrapersonální variability. Pak plně automatické metody mají nižší úspěšnost a mohou dokonce selhat a klasifikovat chybně. Proto jsme se zaměřili na výzkum metod semiautomatické klasifikace, v nichž má nezastupitelnou roli člověk – expert. Jeho úlohou však není vytvořit na začátku plně ohodnocenou trénovací množinu, ale vhodným způsobem zasahovat v různých

fázích zpracování dat. Na několika případových studiích z různých oblastí medicíny tuto interakci ukážeme. První případová studie je věnována porovnání výsledků získaných pomocí znalostního systému, jehož báze znalostí byla vytvářena manuálně formalizací slovně popsaných znalostí, a pomocí metod strojového učení, konkrétně rozhodovacího stromu, naučeného na větším souboru dat. Následně byla báze znalostí porovnána s rozhodovacím stromem a doplněna o vybraná pravidla z tohoto stromu. Takto upravená báze znalostí poskytovala lepší rozhodnutí než původní. Další dvě případové studie jsou zaměřené na úlohu klasifikace v dlouhodobých záznamech biologických signálů, konkrétně elektroencefalografických a polysomnografických. Zde je klíčovou úlohou nalézt vhodný poměr mezi zobecněnými metodami, použitelnými na záznamy všech pacientů, a metodami nastavenými na konkrétního pacienta (jedna z možností personalizace).

### 2 Metody

Pro výše zmíněné typy úloh se s výhodou využívají různé metody a algoritmy umělé inteligence. Nejčastějšími jsou expertní systémy, strojové učení a výpočetní inteligence. V našich případových studiích jsme využili expertní systém s pravidlovou reprezentací znalostí a několik metod strojového učení a výpočetní inteligence (rozhodovací stromy, neuronové sítě, genetické algoritmy a simulované žhání).

V první případové studii byl využit námi vyvinutý expertní systém FEL-Expert [1] a algoritmus C4.5 pro tvorbu rozhodovacího stromu [2]. Systém FEL-Expert využívá pro reprezentaci znalostí formu pravidel. Pravidla jsou vytvářena na základě slovního vyjádření znalostí experta. Rozhodovací strom je generován z dat trénovací množiny. Jeho výhodou je explicitní vyjádření ve formě grafové struktury, kterou lze snadno převést do pravidel, podobných těm pro expertní systém.

Další dvě popisované studie z oblasti zpracování dlouhodobých záznamů EEG využívají více na sebe navazujících metod [3], [4]. Metodami předzpracování signálů (filtrace, segmentace) a extrakcí příznaků se zde podrobně zabývat nebudeme. V obou studiích byla využita kombinace metod učení bez učitele a učení s učitelem. Jako metoda učení bez učitele byla zvolena shluková analýza, s jejíž pomocí byly na základě zvolených příznaků získány shluky podobných segmentů. Již v této fázi může expert zkontrolovat, zda ve shlucích nejsou segmenty, které by mohly patřit do jiných shluků. Pokud takové nalezneme, může manuálně shluky opravit. Tak vznikne trénovací množina. Dalším krokem je naučení algoritmu na vytvořené trénovací množině. Trénovací množinu můžeme ještě upravit a zredukovat. Vytvoříme tzv. etalony pro každý shluk, resp. klasifikační třídu. Tyto etalony potom reprezentují jednotlivé třídy. Při tvorbě etalonů opět do procesu vstupuje interaktivně expert.

psychické zátěži. Expertní systém s touto bází znalostí dosáhl úspěšnost 70 procent u diagnózy neuroticismu a 68 procent pro rizikové osoby podle Bortnerovy stupnice. Celková úspěšnost expertního systému byla 60 procent.

Vzhledem k tomu, že úspěšnost této báze znalostí nebyla vysoká, jsme vyvinuli další bázi znalostí s využitím algoritmu strojového učení. Vstupy byly průměrné hodnoty srdeční frekvence, elektromyografických potenciálů, kožního odporu a krevního tlaku (systolický a diastolický), doplněné o anamnestické údaje. Cílové hypotézy byly diagnóza neuroticismu a rizikové chování. Úspěšnost této báze znalostí je 93,8 procenta u diagnózy neuroticismu a 82,79 procenta pro druhu rizikového chování podle Bortnerovy stupnice. Celková úspěšnost expertního systému s touto bází znalostí báze je 81 procent.

Získaná vstupní data pokusných subjektů jsme využili jako vstup pro klasifikační algoritmus. Zvolili jsme algoritmus pro tvorbu rozhodovacího stromu C4.5. Úspěšnost vytvořeného rozhodovacího stromu byla 79 procent. Výsledky získané jednotlivými metodami se výrazně neliší. Odlišnosti jsou způsobeny rozdíly ve znalostech a zpracování dat. Výhodou strojového učení je, že rozhodovací strom je generován pomocí

### 3 Případové studie

Případové studie, které jsme zvolili pro ilustraci role experta v procesu tvorby systému pro podporu rozhodování, vznikaly postupně za účasti členů řešitelského týmu. Každá studie má poněkud jiný charakter a pracuje s jinými konkrétními algoritmy. Nejvíce se odlišuje první studie, ve které mají vstupní data charakter diskretních numerických hodnot a slovních popisů. Zbývající studie pracují s dlouhodobými signálovými daty, která musejí být pro účely klasifikace ještě předzpracována a rozdělena do kratších segmentů. Z nich se následně teprve vypočítávají numerické příznaky, sloužící jako vstupní data pro klasifikační algoritmy.

#### 3.1 Případová studie 1 – Kombinace expertního systému a strojového učení

V první studii byla cílem identifikace jednotlivých osob na základě naměřených fyziologických veličin v klidu a při psychické zátěži (srdeční frekvence, systolický a diastolický krevní tlak, elektromyografické potenciály a kožní odpor) a dat z anamnestického dotazníku (káva, alkohol, spotřeba cigaret, aktuální zdravotní problémy, užívané léky a pohybová aktivita). Výzkum byl proveden s osobami trpícími neuroticismem nebo s rizikovým chováním a osobami, které nemají žádný z těchto příznaků. Klasifikace byla provedena pomocí expertního systému, strojového učení a s využitím kombinace expertního systému a strojového učení.

V případě klasifikace s využitím expertního systému jsme vyvinuli dvě báze znalostí. První z nich používá jako vstupní informace reakci srdeční frekvence, svalové aktivity, kožní galvanické reakce, systolického a diastolického krevního tlaku v klidu a při

pouze naměřených dat a dat z anamnestického dotazníku. Není nutné mít k dispozici odborné znalosti. Nicméně tyto znalosti jsou nutné pro tvorbu báze znalostí. Použitý typ expertního systému je plně založen na odborných znalostech a teoretických **3.2 Případová studie 2 – interaktivní úprava trénovací množiny**

Cílem popisované práce bylo vyvinout systém pro automatizovanou klasifikaci speciálních typů záznamů EEG, jako jsou komatické stavy, spánkové EEG nebo novorozenecké EEG [6]. EEG je analyzováno jak v časové, tak ve frekvenční oblasti. Pro segmentaci byla použita kombinace neadaptivní a adaptivní segmentace. Metody byly testovány na reálném spánkovém EEG. Jádrem vyvinutého systému je trénovací množina, obsahující 319 segmentů klasifikovaných do 10 tříd. Byla použita pro klasifikaci dvouhodinového záznamu spánkového EEG pomocí algoritmu nejbližšího souseda (k-NN) a neuronové sítě s radiální bázovou funkcí (RBF). Je dobře známo, že kvalita učení u metod učení s učitelem do značné míry závisí na trénovací množině. Proto jsme se v naší práci soustředili na přípravu trénovací množiny, kdy byly netradičním způsobem využity znalosti experta.

Jednotlivé fragmenty byly získány ze spánkového EEG, které je velmi podobné komatickému EEG. Základní kroky je možné popsat následovně:

1. Uložili jsme celkem 453 osmisesekundových intervalů 18-elektrodeového spánkového EEG, u kterých byla klasifikace do stupňů 1 až 10 (poskytnutá prof. MUDr. Milošem Matouškem).
2. Protože vytvořená trénovací množina vykazovala nepříjemnou krosvalidační chybu, bylo nutné modifikovat trénovací množinu do akceptovatelné podoby.
3. Segmenty nevhodné pro další zpracování, např. ty, které obsahují artefakty, byly vyloučeny z trénovací množiny. Počet segmentů se snížil na 436.
4. Jádro trénovací množiny bylo vygenerováno pomocí shlukové analýzy. Do jádra byly zahrnuty pouze ty segmenty, jejichž klasifikace pomocí shlukové analýzy souhlasila s původní klasifikací profesora Matouška. Při opakovaném shlukování jsme hledali takovou metriku prostoru příznaků, která by vyústila ve shodnou klasifikaci pro co nejvyšší počet segmentů. Jádro trénovací množiny vygenerované tímto způsobem obsahuje 184 segmentů.
5. Pomocí klasifikace nejbližšího souseda a současné vizuální kontroly výsledků byly některé dříve vyřazené segmenty znovu přidány do trénovací množiny, ale často byla jejich klasifikace změněna o 1 až 2 stupně. Výsledná trénovací množina má 349 segmentů.
6. Pro výpočet krosvalidační chyby byla použita RBF neuronová síť. Data byla náhodně rozdělena v poměru 1:1 do trénovací a testovací množiny. RBF síť se naučila na trénovací množině a chyba byla vypočtena s využitím testovacích dat. Tato procedura byla opakována několikrát pro různá náhodná rozdělení trénovací a testovací množiny. Výsledná chyba byla vypočtena jako průměrná chyba těchto rozdělení. Opakovaně nesprávně klasifikované segmenty ve druhé fázi výpočtu byly vyřazeny z výsledné trénovací množiny.
7. Výsledná trénovací množina obsahuje 319 segmentů klasifikovaných do stupňů komatu 1 až 10. Průměrná krosvalidační chyba vypočtená s využitím RBF neuronové sítě nepřekročila 3%.

Jedním z nejdůležitějších aspektů systémů pro klasifikaci EEG je spolehlivá analýza záznamů EEG, která umožňuje identifikaci významných hodnot na měřeném signálu. Tato analýza je nezbytnou podmínkou pro správnou klasifikaci. Je nutné zdůraznit, že

nejen výběr metody předzpracování je velmi důležitým krokem v dolování dat, zejména v oblasti spojitých signálů, ale také pečlivé generování trénovací množiny. V takových složitých úlohách, jakou je klasifikace záznamů EEG, může zkušenost experta, který např. modifikuje trénovací množinu vygenerovanou shlukovou analýzou, významně přispět k úspěšnější klasifikaci.

### 3.3 Případová studie 3 – interaktivní úprava trénovací množiny

Základním cílem této studie bylo navrhnout takový nástroj, který se bude co nejvíce blížit způsobu práce lékaře při hodnocení dlouhodobého vícekanálového záznamu EEG [4]. Jde o semiautomatickou analýzu EEG grafoelementů s využitím neuronové sítě jako klasifikátoru. Byl použit vícevrstvý perceptron, který je inicializovaný pomocí simulovaného žhání a jehož váhy jsou optimalizovány pomocí genetického algoritmu. Neuronová síť se příznaky naučí ze souboru etalonů (prototypů), které jsou vytvořeny pomocí nového semiautomatického procesu, jenž kombinuje shlukovou analýzu (konkrétně algoritmus K-means) s následnou manuální verifikací/doplněním/editací etalonů expertem. Pro tuto činnost má expert k dispozici zobrazení segmentů v časové oblasti s barevným odlišením jejich příslušnosti do shluků.

Celá analýza záznamů vícekanálového EEG se skládá z vícekanálové adaptivní segmentace, následuje extrakcí příznaků ze segmentů, poloautomatický proces extrakce etalonů a klasifikace pomocí neuronové sítě. Výsledkem je barevně odlišené zobrazení segmentů dle příslušnosti do tříd v původním záznamu EEG a časových profilech (viz Obr. 1).

Semiautomatická extrakce etalonů je novinkou ve zpracování EEG. Značně přispívá k efektivitě celého procesu. Expert nemusí všechny etalony vytvářet manuálně. Semi-automatický přístup nabízí rychlejší tvorbu etalonů. Proto může být použit v individualizovaném módu pro každého pacienta. To přispívá k eliminaci negativního dopadu interpersonální variability, která často snižuje úspěšnost klasifikace příliš zobecněného klasifikátoru. Obrázek 2 ilustruje použití interaktivního módu při tvorbě etalonů. U vybraného segmentu se zobrazí všechny jeho vypočítané příznaky.

### 4 Závěr

Ukázali jsme, že expert může být do procesu tvorby systému pro podporu rozhodování zapojen v různých fázích a různým způsobem. Některé z těchto postupů se ad hoc využívaly i v minulosti, ale v poslední době dostávají ucelený systematický rámec. Využívají se při vytváření metod pracujících s kontextovou informací, s variabilními daty, případně s informacemi, které nejsou součástí vstupních dat. Expert tak může vhodně eliminovat problémy způsobené přílišnou variabilitou v datech či neočekávanými artefakty, které mohou být v automatickém režimu mylně vyhodnoceny jako užitečná data. Příkladem jsou léky, které pacient užívá. Expert tuto informaci má, tudíž dokáže rozhodnout, zda je segment artefakt, či specifický grafoelement, jehož tvar je změněn působením léku. Dále expert vidí širší kontext zaznamenaných dat, včetně prostorových a časových sou-

vislostí, které stávající metody klasifikace také nedokáží vyhodnotit.

Budoucí práce budou zaměřeny na výzkum dalších možností interakce experta se systémem, návrh nových vizualizací vybraných etalonů ve vztahu k původním shlukům a optimalizaci výběru příznaků s využitím znalosti experta o původu dat.

### Poděkování

Práce byla podporována projektem GA ČR č. 17-20480S „Časový kontext v úloze analýzy dlouhodobého nestacionárního vícerozměrného signálu“.

### Literatura

- [1.] Lhotská, L., Mařík, V., Vlček, T.: *Medical Applications of Enhanced Rule-Based Expert Systems. International Journal of Medical Informatics*. 2001, vol. 63, no. 1–2, p. 61–75. ISSN 1386-5056.
- [2.] Quinlan, J. R. *C4.5: Programs for Machine Learning*. Morgan Kaufmann Publishers, 1993
- [3.] Gerla, V. *Automated Analysis of Long-Term EEG Signals*. Prague: 2012. PhD thesis. Czech Technical University in Prague
- [4.] Schaabová, H. et al. *Application of Artificial Neural Networks for Analyses of EEG Record with Semi-Automated Etalons Extraction: A Pilot Study*. In: *Engineering Applications of Neural Networks (EANN) 2016*, Aberdeen, 2016-09-02/2016-09-05. Cham: Springer International Publishing, 2016. p. 94–107.
- [5.] Šorf, M., Lhotská, L., Janků, L., Eck, V.: *Application of AI Approaches to Personality Type Classification*. In: *Proceedings of the IASTED Inter. Conference MIC*. Calgary: IASTED, 2001, pp. 403–408. ISBN 0-88986-316-4.
- [6.] Rieger, J., Lhotská, L., Krajča, V., Matoušek, M.: *Application of Quantitative Methods of Signal Processing to Automatic Classification of Long-Term EEG Records*. In *Biological and Medical Data Analysis*. Berlin: Springer, 2004, p. 333–343. ISBN 3-540-23964-2.

### Kontakty

#### Lenka Lhotská

ČVUT FBMI a ČVUT CIIRC  
Zikova 4, 166 36 Praha 6  
tel.: 224354199  
e-mail: [lhotska@cvut.cz](mailto:lhotska@cvut.cz)  
<http://ciirc.cvut.cz>

#### Vladimír Krajča

ČVUT FBMI  
Sítná 3105, 272 01 Kladno  
tel.: 224359896  
e-mail: [vladimir.krajca@fbmi.cvut.cz](mailto:vladimir.krajca@fbmi.cvut.cz)  
<http://www.fbmi.cvut.cz>

#### Hana Schaabová

ČVUT FBMI, Sítná 3105, 272 01 Kladno  
tel.: 224359896  
e-mail: [hana.schaabova@fbmi.cvut.cz](mailto:hana.schaabova@fbmi.cvut.cz)  
<http://www.fbmi.cvut.cz>

#### Martin Macaš

ČVUT CIIRC, Zikova 4, 166 36 Praha 6  
tel.: 224354199  
e-mail: [mmacas@seznam.cz](mailto:mmacas@seznam.cz)  
<http://ciirc.cvut.cz>

#### Václava Piorecká

ČVUT FBMI, Sítná 3105, 272 01 Kladno  
tel.: 224359896  
e-mail: [vaclava.piorecka@fbmi.cvut.cz](mailto:vaclava.piorecka@fbmi.cvut.cz)  
<http://www.fbmi.cvut.cz>  
a Národní ústav duševního zdraví

#### Václav Gerla

ČVUT CIIRC, Zikova 4, 166 36 Praha 6  
tel.: 224354199  
e-mail: [vaclav.gerla@cvut.cz](mailto:vaclav.gerla@cvut.cz)  
<http://ciirc.cvut.cz>