

Nový přístup k detekci neočekávaných hodnot v biosignálech

Bc. Matouš Cejnek

Vedoucí práce: doc. Ing. Ivo Bukovský, Ph.D.

Abstrakt

Práce navazuje na původní vývoj adaptivní metodiky vyhodnocování komplexních dynamických systémů, zavedené na Ústavu přístrojové a řídicí techniky, ČVUT FS. Oproti známým metodám zde rozvíjený přístup je založen na okamžitém vyhodnocování každé nově naměřené hodnoty vzhledem ke konzistenci s dočasnou dynamikou systému a bez nutnosti použití historie signálu. V porovnání s původní vyvíjenou metodikou Adaptivního grafu je zde představovaná metoda zjednodušená a využívá vyhodnocení okamžité chyby predikce spolu s informací o chování systému, která je ukládána v adaptovatelných parametrech kognitivního prediktivního modelu. Potenciál této metody je demonstrován na umělém i reálném signálu EKG.

Klíčová slova

adaptivní detekce, časové řady, neočekávané stavy, lineární adaptivní prediktor, predikce

1. Úvod

Detekce neočekávaných dat v časových řadách je důležitá součást zpracování naměřených biosignálů, kterou se zabývalo už mnoho vědeckých prací a je stále atraktivním tématem. Schopnost odhalit v naměřeném biosignálu perturbace nebo neočekávané hodnoty je důležitou součástí analýz reálných dat. Perturbace v měřených datech může představovat jev, na který je potřeba co nejrychleji v reálném čase upozornit a případně i reagovat. U elektrokardiogramu (EKG) se může jednat například o počátek nebezpečné arytmie, která vyžaduje rychlý lékařský zásah. Z toho vyplývá, že je potřeba rozvíjet nejen algoritmy, jenž jsou schopny tyto jevy s naprostou přesností identifikovat, ale i v rámci možností tyto jevy predikovat s co nejvyšší přesností a co nejdříve předem. V tomto článku představuji nový přístup k detekci neočekávaných vzorků v časových řadách; dobře zavedeným termínem v odborné literatuře je výraz Novelty Detection, který budu nadále používat vzhledem k absenci vhodného českého ekvivalentu. Nový přístup který představuji vychází z metodiky adaptivního vyhodnocování časových řad pomocí Adaptivního grafu [1]–[3] (Bukovský 2007) a dále upravenou metodou [4] (Bukovský et al.), které jsou vyvíjeny na ČVUT ve spolupráci se zahraničními pracovišti (Japonsko, Kanada). Originální adaptivní metodika vyhodnocování časových řad byla představena v pracích [1]– [3], s rozšířením o multifraktální („multiscale“) analýzu v práci [4]. Tyto práce se zabývaly využitím nekonvenčních neuronových jednotek a Adaptivním grafem (Adaptation Plot). To je metoda, která využívá k detekci neočekávaných vzorků změnu adaptovatelných vah modelu a vizualizuje adaptaci neuronových jednotek na signál ve 2-D prostoru. Svoji práci navazuji na metodiku novelty detection představenou v článku [4], jako jednu z dalších možností jak je možné okamžitě detekovat perturbace v naměřených datech v každém novém vzorku zvlášť. Tento způsob je inovativní tím, že zjednodušeně (oproti [1]–[4]) využívá okamžitou chybu prediktivního modelu současně s informací uloženou v adaptivních přírůstcích adaptivního prediktivního modelu. To je zajímavý přístup, protože chyba predikce a adaptivní přírůstky vah neuronové jednotky spolu nejsou korelované [4], ale přitom obě společně udávají ucelenou informaci o konzistenci každého měřeného vzorku s dočasnou dynamikou systému. Tyto fakta jsou podle mě důvod,

proč tento a podobné modely detekce neočekávaných dat, mají význam být rozvíjeny a zkoumány.

2 Popis navržené metodiky

Navržená metodika detekce využívá adaptivního prediktivního modelu. Je zajímavé, že metodika detekce funguje velmi slibně i při použití statického lineárního adaptivního modelu na nelineárních datech s klasickým gradientovým algoritmem adaptace (Gradient Descent, vzorec (1)). Pro demonstraci schopností metody jsem tudíž zvolil lineární prediktor, kdy na počátku simulace vektor adaptovatelných vah modelu \mathbf{w} obsahuje náhodná čísla, a jejich adaptace pro výpočet každého dalšího vzorku probíhá dle rovnice (1),

$$\mathbf{w}(k+1) = \mathbf{w}(k) + (\eta(k) \times e(k) \times \mathbf{x}(k)^T) \quad (1)$$

a kde vektor $\mathbf{x}(k)$ je vektor vstupů

$$\mathbf{x}(k) = [1 \quad y_r(k) \quad y_r(k-1) \quad \dots \quad y_r(k-10)]^T \quad (2)$$

a kde y_r jsou měřené hodnoty signálu (časové řady). Jako vstup pro predikci vzorku jsem použil deset předchozích vzorků. Vektor dat jsem před samotnou predikcí standardizoval podle vzorce (3) pro dosažení lepší stability adaptačního algoritmu (2).

$$yr = \frac{yr - \text{mean}(yr)}{3 \cdot \text{std}(yr)} \quad (3)$$

Pro další zlepšení stability modelu jsem použil adaptaci rychlosti učení μ známou v odborné literatuře jako „Normalized Least Squares“ [5]. Tato adaptace probíhá dle vzorce (4) před výpočtem každého dalšího vzorku. Jak je ze vzorce (4), patrné rychlost učení se zmenšuje oproti přednastavené hodnotě μ v závislosti na vstupu $\mathbf{x}(k)$ v každém okamžiku k následovně

$$\eta = \frac{\mu}{1 + \mathbf{x}(k)^T \times \mathbf{x}(k)}, \quad (4)$$

kde η je skutečně použitá rychlost učení ve vzorci (1). Jako výpočet detekce neočekávanosti (*ND* ... novelty detection) každého nového vzorku v každém čase k jsem použil součin absolutních hodnot chyby e a přírůstku i -té váhy neuronu Δw_i s adaptací Gradient Descent podle vzorce

$$ND(k) = \max \{ |e(k) \cdot \Delta w_i(k)| ; i=0..10 \} . \quad (5)$$

Vzorec (5) tudíž představuje hlavní princip detekce neočekávanosti každého vzorku dat vzhledem k dočasné dynamice systému. Vyhodnocuje současně chybu predikce a očekávanost vzorku prediktivním modelem (tj. velikostí maximálního adaptačního přírůstku vah). Vzorec (5) je hlavní teoretický výsledek této práce. V následující sekci je ukázána funkčnost metody na umělém i reálném signálu EKG (vzorkování 256 Hz).

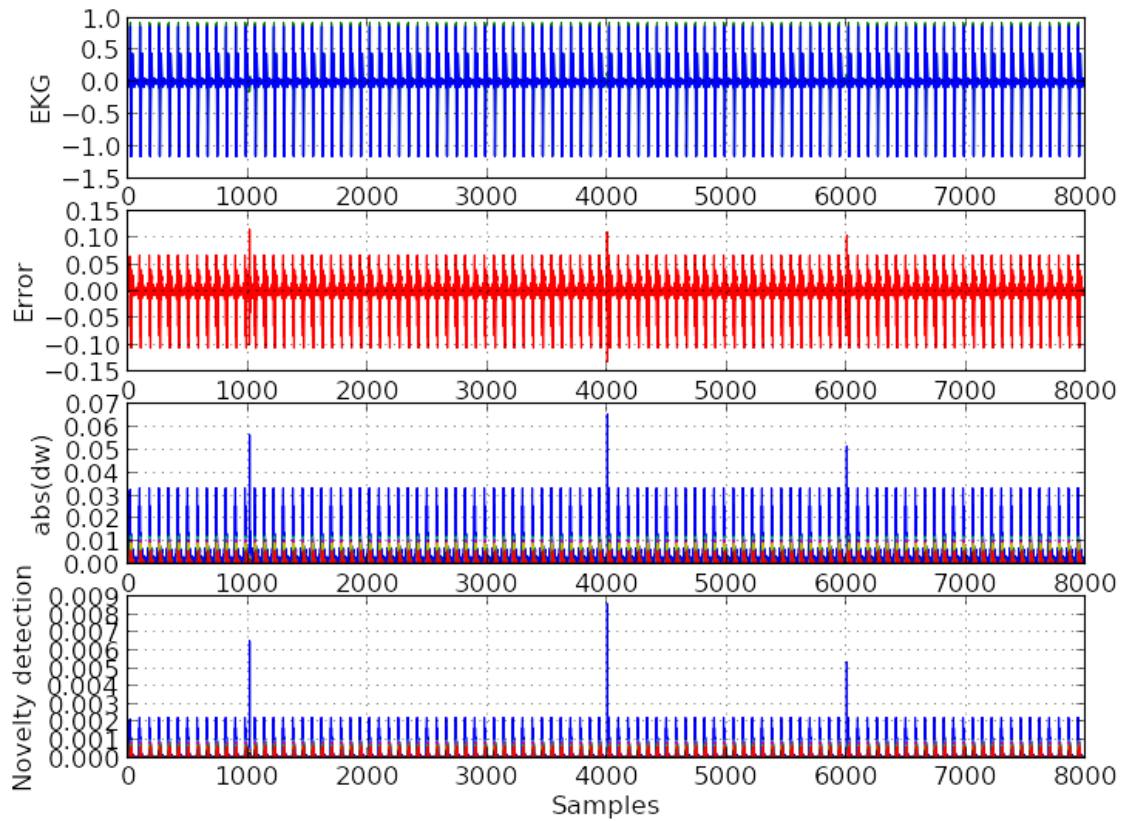
3 Experimentální analýza

Pro demonstrace mé výše popsané metody jsem použil vlastní počítačové simulace vytvořené v programovacím jazyce Python 2.7 [6]. Pro numerické algoritmy jsem použil knihovnu Numpy [7]. Simulace jsem prováděl na běžném kancelářském počítači. Běh simulace s tímto vybavením byl rychlejší než by trvalo měření reálného EKG, což je dobře pro online implementaci.


3.1 Umělé EKG

V následujících kapitolách představím využití této nové metody na uměle vytvořeném EKG bez šumu a pak s přidaným šumem a pak na reálném signálu EKG (256 Hz). Šum jsem do signálu přidal, abych ukázal schopnost novelty detection i při menší přesnosti predikce. Význam testování mé metody na umělém signálu, spočívá v možnosti vyzkoušet, jak dobře

mnou použitá technika detekce perturbovaných dat funguje, pokud signál neobsahuje žádné komplikované jevy. Uměle vytvořená časová řada EKG, použitá v mém článku, byla vytvořena mnohonásobným zkopírováním jedné periody naměřeného reálného EKG. Představuje tedy ideální periodický signál.



Obr. 1. Novelty detection na uměle vytvořeném EKG bez šumu (details viz. Obr. 2)




Obr. 2. Detail predikce v oblasti perturbace na umělém EKG bez šumu (modrá – signál s perturbací=0.03, zelená – predikovaný signál), viz. Obr. 1.

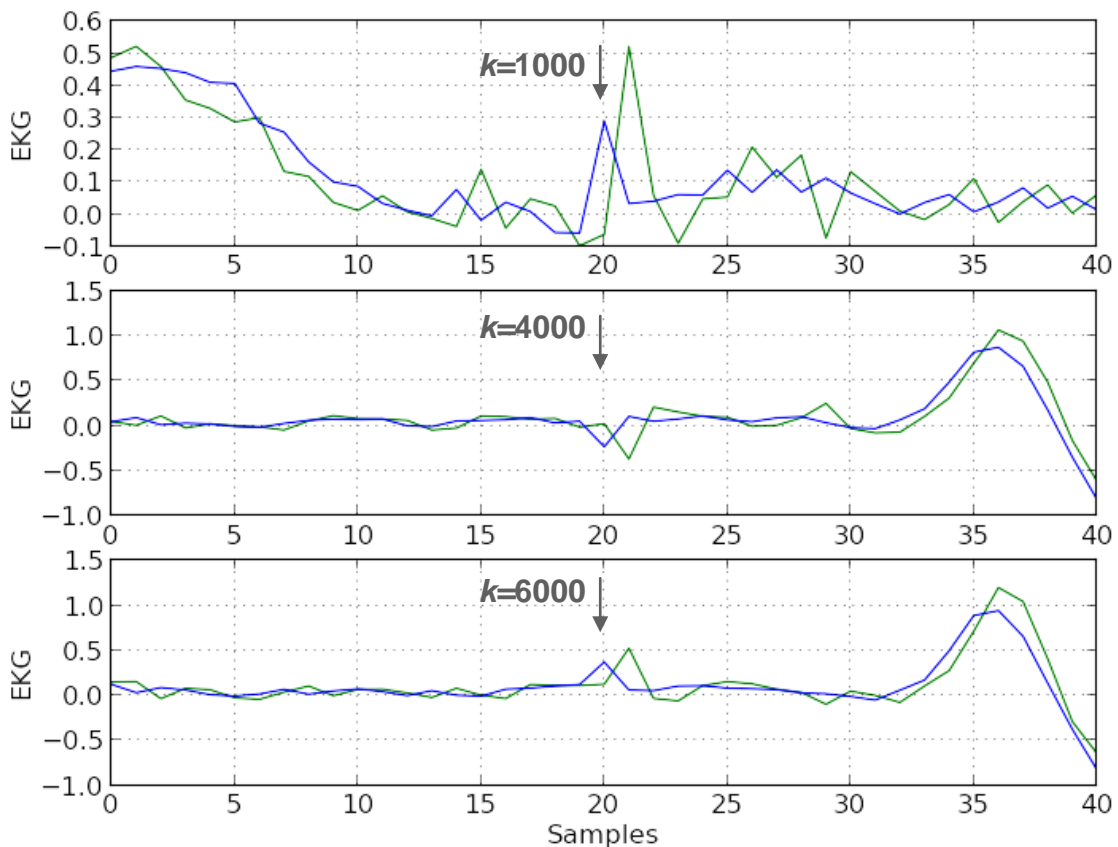
Délku dat pro naučení neuronu jsem zvolil prvních 2000 vzorků (viz. Obr.1). Pro dostatečné naučení s touto délkou učebních dat stačilo sto epoch. Na obrázku 2. jsou zobrazeny detaily všech jednotlivých perturbací vložených do umělého EKG bez šumu. Velikost vložené perturbace je 0.03. Jak je vidět na Obr.2, tyto perturbace jsou ve srovnání s amplitudou signálu nepatrné. Neuron na ně reaguje okamžitou snahou se přeučit a v daném místě velmi vzroste chyba predikce i adaptace vah (Obr.1). Návrat k původní přesnosti trvá modelu přibližně 20 dalších vzorků. Na Obr.1 je dále možné pozorovat chyby predikce ve specifických místech periody signálu. Tyto chyby jsou způsobeny omezenými možnostmi jednoduchého a lineárního modelu. Jak bylo možné vidět na Obr.1., tyto chyby nedetekuje novelty detection jako nová data. Na Obr.3. jsou vykresleny grafy simulace pro uměle vytvořené EKG obohacené o šum. Do dat jsem opět vložil tři náhodné perturbace. Jsou umístěny na stejných místech jako v signálu bez šumu. Šum jsem vytvořil pomocí generátoru pseudonáhodných čísel, kterým jsem vygeneroval vektor náhodných čísel v rozsahu 0 až 0,1. Způsob, jakým jsem tento šum do dat přidal, je vyjádřen ve vzorci (5).

$$yr(k)=yr(k)+rand, \text{ kde } rand \in \langle 0, 0.1 \rangle \text{ a } k=1000,4000,6000 \quad (5)$$

Na Obr.3 zobrazujícím vstupní a simulovaný signál, je vidět nepatrný rozdíl v oblasti maxima amplitud. Pro model je zašuměný signál mnohem náročnější na naučení. V grafech chyby a absolutní hodnoty přírůstků adaptovatelných vah (Obr. 3), můžeme pozorovat, že hodnoty už tolik nezávisí na periodicitě signálu. U grafu chyby na Obr. 3 už ani perturbace nejsou tak dobře vidět, jako v grafu chyby predikce dat bez šumu na Obr. 2. V grafu absolutní chyby adaptovatelných vah je lokace perturbací stále dobře rozpoznatelná. Na grafu novelty detection (Obr. 3), jsou lokace perturbací vidět ještě lépe, je zde odfiltrována velká část periodických chyb modelu, které z pohledu detekce neočekávaných dat nemají žádný význam.



Obr. 3. Novelty detection na uměle vytvořeném EKG se šumem (detaily viz. Obr.4)



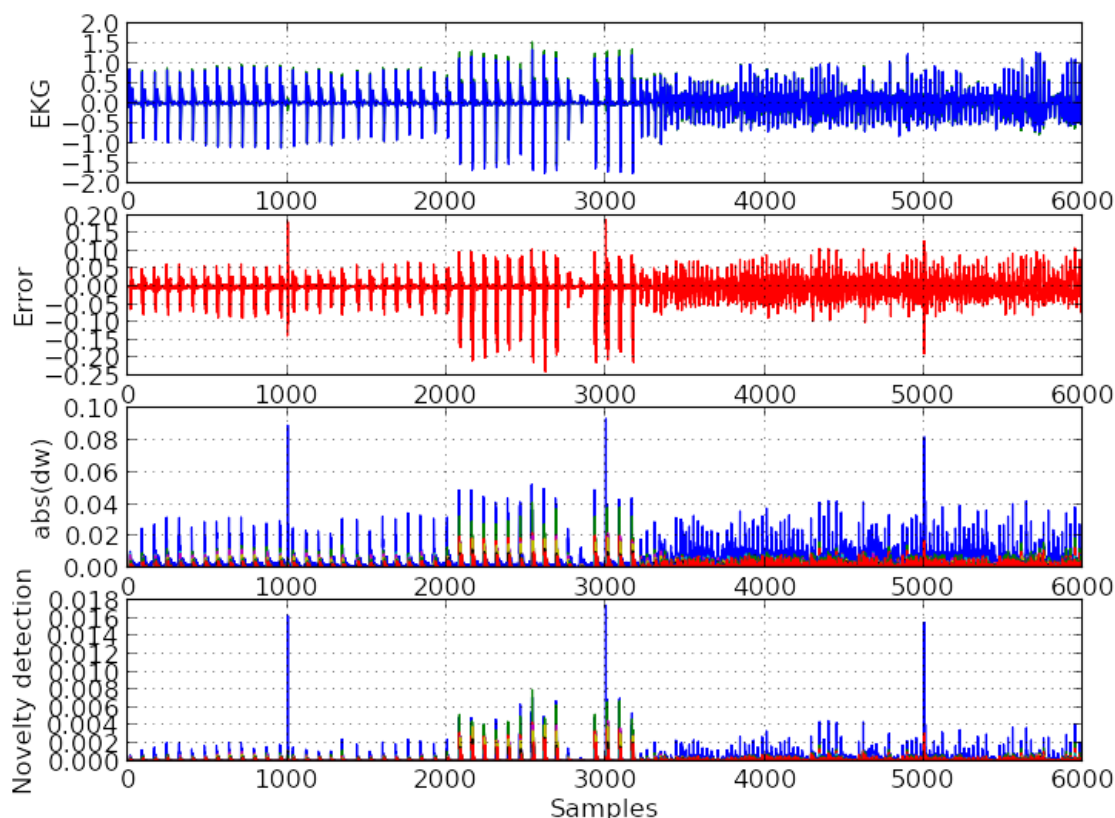
Obr. 4. Detail predikce v oblasti perturbace na uměle vytvořeném EKG se šumem (modrá – signál, zelená – predikovaný signál); metoda funguje pro detekci perturbací při přítomnosti šumu (viz. Obr 3)

Na Obr. 4. jsou zobrazeny detaily tří perturbací vložených do umělého signálu doplněného o šum. Jak je z detailů vidět, chyba predikce při zašuměném signálu místy dosahuje vysokých hodnot i mimo oblast vložených perturbací. Adaptivní model opět okamžitě reaguje na vloženou perturbaci a snaží se přeučit. Doba návratu přesnosti k normálu po setkání modelu s perturbací se zde těžko odhaduje, jelikož chyba predikce je velmi silně závislá na šumu.


3.2 Reálné EKG

Následně jsem tuto metodu otestoval na skutečně naměřeném EKG. Jako naměřený signál pro můj výzkum použil signál EKG naměřený interním kardiodefibrilátorem s frekvencí 256 Hz (zprostředkovaný v rámci spolupráce s Tohoku University v Japonsku). Tento signál jsem zvolil proto, že obsahuje spontánně začínající arytmií. Tyto data jsou velice vzácná. Pro demonstrace v následujících kapitolách použiji úsek dat obsahující sinusový rytmus i arytmií. V pozdější části bude ukázáno, že technika funguje v oblasti sinusového rytmu i v úseku arytmiie. Pro představení mé metody jsem vybral úsek dat, kde se nachází jak část vzorků představující zdravé EKG, tak úsek přechází do ventrikulární arytmiie. Jako model predikce jsem zvolil lineární neuron, stejný jako pro predikci umělého EKG. Počet vzorků pro učení je 1000. Pro dostatečné naučení neuronu s tímto rozsahem okna dat pro detekci perturbací stačí méně než 500 epoch pro dosažení optimálních výsledků. Větší množství epoch už nezvyšuje přesnost významným způsobem. Jak je vidět na Obr. 5., z naměřených dat je dobře rozeznat, která část dat představuje zdravé EKG a která data s arytmií. Už větší úsek dat před začátkem arytmiie (přibližně 1000 vzorků) je možné pozorovat, že signál se trochu mění. Tvar periody

vypadá stejně, ale měřítko amplitudy se začíná měnit. V prvním grafu na téže obrázku je také možné pozorovat, že změřený signál je prakticky totožný se signálem predikovaným. Vložené perturbace nejsou v tomto grafu viditelné. Perturbace jsem umístil do vzorků v diskretním čase 1000, 3000, 5000. Na grafu chyby je možné poměrně slušně rozpoznat perturbace. V grafu absolutních hodnot adaptovatelných vah už je lokace perturbací rozpoznatelná jednoznačně. V grafu novelty detection, jsou tyto perturbace výrazné ještě více. A navíc je potlačeno zobrazení periodických chyb v oblasti zdravého EKG i signálu s arytmií. Za pozornost stojí fakt, že potlačení periodické chyby v oblasti přechodu ze zdravého EKG do arytmie, není tak markantní, jako v ostatních částech dat. Při pohledu na Obr. 6. můžeme vidět detail vložených perturbací do skutečného EKG. Můžeme zde pozorovat, že naměřený signál je poměrně dost čistý, prakticky neobsahuje šum, který by byl viditelný při tomto měřítku, ale na druhou stranu je signál dynamicky značně komplikovaný. Z pohledu na detail (Obr. 6.) se model predikce zdá být poměrně přesný, ale v některých místech se stále objevuje nepatrná nepřesnost. Tyto pro model obtížné místa jsou zejména minima a maxima period naměřeného signálu. Vložené perturbace jsou nepatrné velikosti (0,04 – přibližně 2% z amplitudy průměrné periody zdravého EKG). Adaptivní model na ně přesto reaguje okamžitou snahou o přeučení. Návrat k předchozí přesnosti modelu po setkání s perturbací trvá přibližně 5 až 10 následujících vzorků.



Obr. 5. Detekce perturbace dat (Novelty detection) na reálném naměřeném EKG



Obř. 6. Detail predikce v oblasti perturbace na naměřeném EKG (modřá – signál, zelená – výřtup neuronové jednotky); adaptivní metoda dokáže detekovat velmi malé perturbace reálného EKG v $k=5000$, 3000 , 1000

4. Závěr

Jak jsem demonřtroval v předchozích kapitolách, potenciál novelty detection pro biomedicínské signály jako například EKG je značný. I když jsem úmyslně zvolil velice jednoduchý model predikce, který není schopný naučit se pořádně predikovat naměřené EKG, detekce neočekávaných vzorků, tak jak jsem jí použil já, dokáže rozeznat rozdíl mezi chybou predikce způsobenou omezeností modelu a chybou predikce způsobenou neočekávanými daty. Tento způsob se také ukázal použitelný na uměle vytvořeném signálu obsahující značný řum, kde model samozřejmě není schopný se řum naučit, ale dokáže ho rozeznat od nového jevu v naměřených datech. I na uměle vytvořených datech bez řumu je vidět, že novelty detection spolehlivě rozezná chybu predikce modelu od nových dat, i při velmi malé perturbaci signálu. Důvod proč tato nová metoda pracuje takto dobře, spočívá ve využití součinu chyby predikce modelu a zároveň detekce maximálního přířrůstku adaptovatelných vah modelu (5). Chyba predikce modelu nese informaci o velikosti nepřesnosti, zatímco změna adaptovatelných vah vypovídá o tom, jak moc se model pokusil adaptovat na nová data. Novelty detection tedy detekuje stavy, ve kterých měl model velkou chybu a přitom se snažil přeučit, aby tuto chybu neopakoval. V případě chyby, která je způsobena častými jevy, jež jsou mimo schopnost modelu se naučit, novelty detection neoznačí vzorek vysokou hodnotou, jelikož model měl pouze malou snahu o změnu adaptovatelné váhy.

Velkou výhodou tohoto způsobu detekce perturbací v signálu, je jeho malá časová náročnost. Jelikož se jedná pouze o vynásobení hodnot, které byly spočítány už pro predikci dat, nepředstavuje novelty detection prakticky žádné zpomalení výpočtu. Tento fakt je velkou výhodou obzvláště při zpracování signálu v reálném čase, což může být u signálu typu EKG případně jiných biomedicínských signálů klíčová vlastnost.

Navíc, jak vidět z výsledků získaných aplikováním novelty detection na skutečné EKG (Obr.5), tato technika detekce neočekávaných dat poměrně výrazně odlišila normální EKG od signálu, kde začíná arytmie. Tyto odlišnosti je možno pozorovat na signálu dříve, než je počátek arytmie evidentní z naměřeného signálu, nebo chyby predikce. První vzorky poukazující, že něco s daty není v pořádku, se objevují přibližně 1000 vzorků před začátkem arytmie samotné. Tento nebo podobný model by při vhodné optimalizaci bylo možné používat k detekci srdeční arytmie a je předmětem dalšího výzkumu.

Seznam symbolů

μ	uživatelé nastavená rychlost učení
η	adaptovaná rychlost učení
k	diskrétní čas
ND	koeficient neočekávanosti (Novelty Detection)
\mathbf{w}	vektor adaptivních vah modelu
w_i	i-tá váha (skalár)
e	chyba
\mathbf{x}	vektor vstupů modelu
\mathbf{y}_r	vektor vstupních dat
\mathbf{rand}	vektor náhodných čísel
k	diskrétní index času při konstantním vzorkováním

Poděkování

Vývoj metodiky je podporován grantem SGS12/177/OHK2/3T/12SGS12/177/OHK2/3T/12, *Nekonvenční a kognitivní metody zpracování signálů dynamických systémů*. Za poskytnutá fyziologická data EKG a cenné konzultace děkujeme kolegům z pracoviště Yoshizawa/Homma Lab., Tohoku University, Japonsko.

Seznam použité literatury

- [1] Bukovsky, I. : *Modeling of Complex Dynamic Systems by Nonconventional Artificial Neural Architectures and Adaptive Approach to Evaluation of Chaotic Time Series*, Ph.D. THESIS, Faculty of Mechanical Engineering, Czech Technical University in Prague (defended September 7, 2007).
- [2] Bukovsky, I., Bila, J.: “Adaptive Evaluation of Complex Time Series using Nonconventional Neural Units“, ICCI 2008, The 7th IEEE International Conference on COGNITIVE INFORMATICS, California , USA, 2008, ISBN 9781424425389.
- [3] Bukovsky, I., Bila. J: “Adaptive Evaluation of Complex Dynamic Systems using Low-Dimensional Neural Architectures”, in *Advances in Cognitive Informatics and Cognitive Computing, Series: Studies in Computational Intelligence*, Vol. 323/2010, eds. D. Zhang, Y. Wang, W. Kinsner, Springer-Verlag Berlin Heidelberg, 2010, ISBN: 978-3-642-16082-0, pp.33-57.
- [4] Bukovsky, I., Kinsner, W., Bila, J.: „Multiscale Analysis Approach for Novelty Detection in Adaptation Plot“, *3rd Sensor Signal Processing for Defence 2012 (SSPD 2012)*, Imperial College London, UK, September 24-27, 2012.
- [5] B. Widrow and S. D. Stearns, *Adaptive Signal Processing*. Englewood Cliffs, NJ: Prentice-Hall, 1985.
- [6] van Rossum, G., Drake, F. L. (eds): *Python Reference Manual*, PythonLabs, Virginia, USA, 2001. Available at <http://www.python.org>
- [7] Ascher, D., Dubios, P., F., Hinsen, K., Hugunin, J., Oliphant, T.: *Numerical Python*, Lawrence Livermore National Laboratory, Livermore, California, USA, 2001.