



**Společná
Laboratoř spolehlivosti systémů
Katedra řídicí techniky a telematiky
Fakulta dopravní ČVUT Praha**
Konviktská 20, 11000 Praha 1
tel. 24221721/416 (fax), 417(sekr), 418, 413 (lab)
e-mail: mirko@fd.cvut.cz
Ústav informatiky AV ČR
18207 Praha 8, Pod vodárenskou věží 2
tel. 6606/2080, 821639 (fax)
e-mail: mirko@cs.cas.cz

Problémy spolehlivosti interakce řidiče (pilota) a dopravního systému

Výzkumná zpráva č. LSS 104/01

Autoři: Doc. Ing. Mirko Novák, DrSc.,
Prof. MUDr. Josef Faber, DrSc.,
Doc. Ing. Zdeněk Votruba, CSc.,
Ing. Tomáš Tichý
Ing. Petr Svoboda
Vladimír Tatarinov

Praha, srpen 2001

Souhrn:

V této výzkumné zprávě je charakterizována problematika spolehlivosti interakce lidského činitele, řidiče, pilota s dopravním prostředkem (systémem). Jsou zde uvedeny poznatky, získané při řešení výzkumného záměru MŠMT ČR č. VZ 2100024, grantu MŠMT č. ME 478 Neuroinformatika a grantu Mikrospánek MO ČR v průběhu uplynulého roku a diskutovány problémy spojené s řešením úlohy detekce, analýzy a predikce poklesu pozornosti a vzniku mikrospánků.

Předmětem zájmu jsou přitom zejména ty přístupy, které dávají naději na vývoj prostředků založeným na zpracování elektroencefalografických (EEG) signálů, kterými bude možno zajistit včasné varování před poklesem pozornosti a nástupem tzv. mikrospánku, případně též docílit vhodným tréninkem zvýšení odolnosti lidského subjektu vůči těmto vlivům.

Obsah:

Souhrn.....	str. 2
1. Úvod.....	str. 3
2. Problémy při měření a analýze EEG signálů.....	str. 4
3. Některé dosažené výsledky.....	str. 6
4. Závěr.....	str. 15
5. Literatura.....	str. 15

1. Úvod

Je známo, že poklesy pozornosti vedoucí často až k vzniku tzv. mikrospánků způsobují na celém světě každodenně mimořádně velké množství nehod způsobených špatným řízením, ovládáním nebo užíváním umělých, především technických systémů a že mnohdy vedou až ke skutečným katastrofám. Zejména se to týká systémů dopravních, pozemních leteckých i vodních, říčních i námořních, a to ať již jde o dopravní prostředky samé či o celé dopravní systémy. Americké statistiky ukazují v této souvislosti, že asi 10% všech nehod na dálnicích má svoji příčinu právě v mikrospánkách řidičů. Podobné údaje lze nalézt i o jiných způsobech dopravy. Nehody, ztráty i havarijní situace však mohou poklesy pozornosti způsobit i u jiných než dopravních systémů, např. u dispečinku výroby a rozvodu elektrické energie, plynu, vody, u zdravotnických systémů, ve finančnictví, u bezpečnostních systémů a v obraně. Je proto snahou nalézt prostředky, kterými lze toto nebezpečí účinně snížit.

Přitom je často velmi obtížné rozlišit, co bylo vlastní příčinou nehody, zejména, jak se to stává u dopravních prostředků, jestliže ji řidič či pilot nepřežije. Naše dopravní statistiky v tom směru však prakticky neexistují a ani zahraniční (ani americké) nejsou dostatečně přesné. Nicméně je známo několik případů, u kterých lze fatální pokles pozornosti řidiče považovat za jednoznačnou příčinu mimořádně závažné havárie. Mezi ně patří zejména případ požáru v rakouském silničním tunelu pod Taurami v r. 1999 nebo havárie italského autobusu v ústí tunelu Amberg počátkem srpna 2001. V těchto a řadě podobných případů došlo ke velmi značným škodám a ztrátám na lidských životech.

Výzkumy posledních let prováděné v oblasti spolehlivosti interakce člověk – systém a poklesu pozornosti lidského činitele při obsluze či užívání umělého systému ukázaly (viz např. [1,2,3,4,5]), že:

- a) jedním z nejúčinnějších prostředků pro detekci, analýzu a predikci očekávaného vývoje stavu bdělosti a pozornosti lidského činitele, operujícího jakýmkoliv umělým, zejména technickým systémem je rozbor elektromagnetického pole, vyzařovaného celým rozsáhlým souborem nervových drah v mozku, zejména pak drah mezi cortexem a thalamem;
- b) pro podobný účel existují i jiné biologické signály, které lze považovat alespoň z části za signifikantní – tj. za tzv. markery. Mezi

ně patří zejména frekvence mžikání očních víček, vibrace rukou na ovládacích systému, elektrický odpor a teplota pokožky, výraz obličeje;

- c) většinu těchto markerů je však nutno považovat za markery sekundární, podpůrné, protože indikace sledovaného jevu z nich jednak není dostatečně specifická, jednak se mohou projevat s jistým, někdy i velmi značným zpožděním.
- d) analýzu elektromagnetického pole vyzařovaného mozkiem je možno provádět buď na základě jeho magnetické či elektrické složky. Výsledky jsou více-méně rovnocenné, nicméně měření magnetické složky je mnohem obtížnější.

Na základě toho jsme se při výzkumu výše zmíněné problematiky soustředili především na detekci a analýzu tzv. elektroencefalografických signálů (dále jen signály EEG).

2. Problémy při měření a analýze EEG signálů

EEG signály se promítají na celý povrch hlavy a mají amplitudu několik, maximálně několik desítek μV . Dominantní složky jejich pseudo-spekter (pojem spektra v přesném matematickém významu je zde poněkud problematický, neboť tyto signály mají kvazi-periodický a kvazi-stacionární charakter, proto jsme použili termín pseudo-spektra) leží v pásmu asi 0,5 až 30 Hz.

Z celé řady problémů, s nimiž je nutno se vyrovnat při detekci a analýze těchto signálů, prováděné za účelem klasifikace a predikce vývoje stavu pozornosti lidského činitele považujeme za potřebné upozornit zejména na tyto:

- Měření EEG signálů se sice v medicínské praxi provádí již dlouho, samo je však poměrně obtížné, protože je třeba snímat elektrické potenciály o poměrně velmi malé amplitudě v oblasti velmi nízkých kmitočtů a vyrovnat se přitom s proměnlivým elektrickým odporem mezi pokožkou a elektrodou. Tense mění s fyzickým a psychickým stavem probanda (měřeného lidského subjektu), s parametry vnějšího prostředí i s časem.
- Dále je třeba na hlavě nalézt taková místa, kde je měření dostatečně málo ovlivňováno rušivými signály (v medicínské terminologii tzv.

artefakty), produkovanými zejména pohyby obličejových a hlavových svalů i pohyby očí. Lze soudit, že pro účely detekce, analýzy a případné predikce poklesů pozornosti a nástupu mikrosnávků k tomu budou vhodné zejména partie hlavy za ušima. Tam lze též očekávat menší potíže s vlasovou pokrývkou hlavy.

- Zásadním problémem však zůstává vyřešení techniky snímání tak, aby měření bylo možno konat po dostatečně dlouhou dobu i za provozu v pohybujiícím se dopravním prostředku. Podstata tohoto problému není v případných rušivých signálech technického charakteru – dosavadní zkušenosti z měření v jedoucím autě ukázaly, že toto lze poměrně dobře překonat. Rovněž vyvinutá převozná elektronická zařízení se ukázala přijatelně spolehlivá a použitelná.

Hlavní část problému tkví v tom, že dosud je nutno používat kontaktních elektrod, jejichž spolehlivá instalace na hlavu pokusné osoby, tzv. probanda je zdoluhavá, pracná a elektrody pochopitelně probanda obtěžují. Ideálním řešením by tedy bylo bezkontaktní snímání. Dosavadní diskuse s odborníky z oblasti fyziky (viz např. [6]) však vedou k pocitu, že takové řešení, ať již orientované na elektrickou či na magnetickou složku mozem vyzařovaného elektromagnetického pole, je někde na hranici současných možností, zejména, mělo-li by se jednat o mobilní a cenově dostupné řešení. Pokud je tento pocit správný, bude třeba se vyrovnat s potřebou vytvořit lehké a po dostatečně dlouhou dobu (alespoň nepřetržitě několik hodin) použitelné kontaktní elektrody, které by byly na hlavu probanda snadno instalovatelné (např. v podobě speciálních brýlí, sluchátek, čelenky či u vojenských pilotů doplněním standardní přilby), probanda by příliš neobtěžovaly a z nichž by snímané signály byly do palubního záznamového a analytického zařízení přenášeny bezdrátově (půjde o vzdálenost 1 až 1,5 m). Tento přenos ovšem bude muset být dostatečně spolehlivý.

- Další problém představuje sám charakter snímaných signálů. Jak jsme již uvedli, ty jsou kvazi-periodické a kvazi-stacionární. Konvenční metody spektrální analýzy lze na ně uplatnit tedy pouze za předpokladu, že neočekáváme přesný a reprezentativní výsledek.

Standardní metody Fourierovy spektrální analýzy jsou v neurologii sice používány pro rozbor naměřených časových řad již velmi dlouho, a lékařští experti z jejich výsledků dokážou získat řadu cenných poznatků, ty však jsou dosahovány převážně zásluhou jejich zkušeností, invence a talentu. Jednotlivá takto získaná pseudo-spektra jsou ve skutečnosti navzájem těžko porovnatelná a lékařští experti často přitom ani nevědí (resp. nemohou vědět, neboť firmy vyrábějící EEG analyzátoři to vesměs neuvádějí) na základě jaké metody spektrální analýzy jejich přístroj pracuje.

Nicméně i tak se podařilo získat základní obecný náhled na souvislost vývoje některých charakteristických komponent takových pseudo-spekter a jednoho z hlavních markerů poklesu pozornosti a nástupu mikrospánku, za nějž lze považovat reakční dobu.

3. Některé dosažené výsledky


V průběhu r. 2000 a první poloviny r. 2001 byla provedena řada měření časových řad EEG signálů různých probandů a byla analyzována jejich pseudo-spektra a to zejména se zřetelem jejich souvztažnostem k současně měřeným reakčním dobám těchto probandů.

Ze získaných poznatků lze soudit, že pro identifikaci poklesů pozornosti probanda a nebezpečí nástupu mikrospánku jsou dominantní zejména frekvenční pásma jejich pseudo-spekter, označovaná v medicínské terminologii jako δ a α .

Na obr. 1 je naznačen principiální vztah mezi komponentami α a δ pseudo-spektra EEG signálu, změřeného na hlavě probanda a jeho reakčním časem RT.

Přitom byla úroveň pozornosti klasifikována takto:

reakční doba RT od 200 ms do 400 ms...vigilance, tj. plná pozornost,
reakční doba RT od 400 ms do 600 ms... relaxace, tj. uvolnění s nastupující únavou,
reakční doba RT od 600 ms do 800 ms... somnolence, tj. ospalost
reakční doba nad 800 ms...hypnagogium, tj. usínání, přípaně mikrospánek.



Obr. 1: Závislost mezi reakčním časem probanda a komponentami α a δ pseudo-spektra jeho EEG signálů.

Hranice jednotlivých těchto fází poklesu pozornosti jsou ovšem empirické a diskutabilní. Reakční doba byla přitom měřena elektronicky jako rozdíl časů mezi začátkem stimulačního signálu a časů, v nich na ně proband reagoval stisknutím páky, na níž měl položenou pravou ruku. Stimulační signály byly přitom generovány v náhodných okamžicích. Pro jiné uspořádání experimentu by byly naměřené hodnoty patrně poněkud jiné, celkový charakter by však zůstal. I u zdravých a odpočínutých jedinců se na počátku měření podařilo dosáhnout reakční doby pod 200 msec jen zcela výjimečně. S postupujícím časem měření (seance pro jednoho probanda trvala obvykle asi 45 minut) se počal projevovat nástup únavy a hodnoty RT se prodlužovaly, většinou 3 až 4 krát. Po prodloužení hodnot RT nad 800 až 1000 msec proband usínal (hodnota TR by se prodloužila mnohonásobně až do jeho probuzení). U odpočínutých, mladých a zdravých probandů může však čas, potřebný k dosažení tohoto stavu být velmi dlouhý.

Pseudo-spektrum bylo v této sérii měření získáno pomocí Gaborovské filtrace s polynomiální filtrační funkcí 50-tého stupně. Komponenta α zabírá přitom frekvenční rozsah cca 4 až 14 Hz, komponenta δ rozsah asi 0,5 až 4 Hz. Proband byl při měření v klidu a byl stimulován akustickým signálem – souvislým poměrně

slabým tónem. Taková měření byla provedena dosud ovšem pouze pro asi 10 probandů různého věku a profese a proto je nutno výsledkem uvedený v obr. 1 považovat dosud za předběžný. Lze však očekávat, že:

- Pro většinu probandů budou mít takové diagramy podobný charakter, avšak v detailech se budou pro jednotlivce lišit.
- Pokud dospělý proband neprodělá vážné onemocnění nebo úraz mozku, nervového ústrojí či uvažovaných čidel, zůstane pro něj takový diagram po dlouhou dobu (pravděpodobně po většinu života) téměř neměnný.
- Obdobné diagramy, sestavené pro případ stimulování probanda vizuálními signály, blízkými reálným situacím budou mít podobný charakter.

Zevrubná analýza podobných záležitosti bude zřejmě východiskem k seriózní detekci a klasifikaci stavu somnolence, resp. hypnagogia, bude jí však nutno založit na provedení mnohem většího počtu měření různých probandů a za různých podmínek (odpočínutí, unavení, resp. nevyspalí, případně též stresovaní).

Nelze vyloučit, že v takto vytvořené databázi měření bude pak možno vhodnými metodami pro vytěžování poznatků z dat (datamining), např. metodami třídy GUHA nalézt jisté typické skupiny probandů, reagujících podobným způsobem. To by pak mohlo do jisté míry zjednodušit řešení problému individuality těchto závislostí. Zatím je však nutno předpokládat, že pro každého operátora či uživatele umělého systému bude nutno provést základní proměření výchozích závislostí jeho EEG signálů na stupni jeho únavy zvlášť.

Při analýze výše uvedených dosavadních výsledků musíme mít na zřeteli již vzpomenutou skutečnost, že byly získány z pseudo-spekter naměřených kvazi-periodických a kvazi-stacionárních časových řad, která sama z principu zahrnují značný faktor neurčitosti. Díky velké zkušenosti a erudici expertů je sice možno z jejich rozboru vyvodit zmíněné nadějně výsledky, při širším použití uvedené metodiky by to však bylo jen sotva možné.

Vyvstává tedy naléhavá potřeba nalézt vhodné charakteristické veličiny (markery) – to nemusí být nutně jen spektra – použitelné pro exaktnější a automatizovatelnou reprezentaci kvazi-periodických a kvazi-stacionárních řad a vyvinout k tomu potřebné analytické metody.

Lze soudit, že jedním z možných východisek pro řešení tohoto problému by mohla být práce s

- diferenciálními rovnicemi Hillového typu, či

- aproximace vhodných úseků časových průběhů (např. Zolotarevovými funkcemi),
nebo tzv.
- parametrické metody, vycházející z rozboru polohy nul a pólů vhodných aproximujících funkcí (např. získaných ARMA, MA či AR modely v časové oblasti) transformovaných do frekvenční oblasti (např. po Z-transformaci). Předběžné výsledky v tomto směru dosažené v [4] lze označit za nadějně.

Další možností je

- analýza stavových trajektorií, získaných např. metodou delay-time imbedding. Také v této oblasti jsou v [4] ukázány velmi zajímavé výsledky, které však bude nutno ověřit na větším počtu případů.

Velmi významnou problematikou pak je vývoj potřebných klasifikátorů a prediktorů, které budou schopny v reálném čase rozpoznat, že příslušný proband se dostává do stavu, kdy jeho pozornost výrazně klesá a jeho reakční doba se podstatně prodlužuje. Zde zřejmě naleznou uplatnění především umělé neuronové sítě, pravděpodobně zejména s aktivačními funkcemi výkonných prvků s radiální bází (RBF).

Dosavadní předběžné výsledky, dosažené V. Tatarinovem, z nichž část je ukázána v následujících tabulkách (viz obr. 2 až 6) naznačují, že by bylo možno očekávat spolehlivost klasifikace somnolentních stavů (stavů, kdy se reakční doba již velmi výrazně prodlužuje) na úrovni 85 až 90%. Při této sérii experimentů bylo též cílem zjistit, jaké je frekvenční pásmo snímaných EEG signálů je vhodné uvažovat.

Proband „Freedom“ - klasifikátor na bázi umělé neuronové sítě typu: LVQ 1 - 20 neuronů - 2 třídy - učení: 100 epoch	dm = 2 hm = 15 úspěšnost = 0.8529	dm = 3 hm = 21 úspěšnost = 0.8397

dm = 1 hm = 12 úspěšnost = 0.7456	dm = 2 hm = 18 úspěšnost = 0.8397	dm = 4 hm = 12 úspěšnost = 0.8574
dm = 1 hm = 15 úspěšnost = 0.7265	dm = 2 hm = 21 úspěšnost = 0.8926	dm = 4 hm = 15 úspěšnost = 0.8706
dm = 1 hm = 18 úspěšnost = 0.6882	dm = 3 hm = 12 úspěšnost = 0.8824	dm = 4 hm = 18 úspěšnost = 0.8500
dm = 1 hm = 21 úspěšnost = 0.7794	dm = 3 hm = 15 úspěšnost = 0.8750	dm = 4 hm = 21 úspěšnost = 0.8574
dm = 2 hm = 12 úspěšnost = 0.8676	dm = 3 hm = 18 úspěšnost = 0.8382	

Obr. 2.: Výsledky aplikace neuronového klasifikátoru LVQ 1 na záznamy EEG signálů, naměřené na hlavě probanda „Freedom“ pro různé šířky uvažovaného frekvenčního pásma.

Zde i v dalších obrázcích 3 až 5 značí:

dm...dolní mez uvažovaného frekvenčního pásma v Hz,

hm...horní mez uvažovaného frekvenčního pásma v Hz,

úspěšnost...spolehlivost klasifikace stavu somnolence.

Červeně jsou označeny experimenty, při nichž byla spolehlivost klasifikace tohoto stavu nad 85%, tučně pak nejvyšší dosažená hodnota.

V tabulce na následujícím obr. 3 je uveden příklad výsledků klasifikace jednoho vzorku dat:

Proband „Freedom II“ , frekvenční pásmo 3-12Hz

výsledek	2	2	2	2	2	1	1	2	1	2	1	2	1
správně	2	2	2	2	2	1	1	2	1	2	1	2	1
výsledek	2	2	2	1	1	1	2	2	2	2	1	1	1
správně	1	2	2	1	1	1	2	2	2	1	1	1	1
výsledek	2	2	2	1	2	1	2	2	1	1	2	1	2
správně	2	2	2	1	2	1	1	2	1	1	1	1	2

výsledek	2	2	2	1	2	1	1	2	2	2	1	2	1			
správně	1	2	1	1	1	1	1	2	2	1	1	2	1			
výsledek	2	2	2	1	1	2	1	1	2	2	2	2	1	2	2	2
správně	2	2	1	1	1	2	1	1	2	2	1	2	1	2	2	2

Obr. 3: Příklad klasifikace jednoho vzorku dat z tabulky na obr. 2. Zde značí:
1 vigilita
2 somnolence

Na obr. 4, 5 a 6 jsou obdobné výsledky získané pro další probandy pomocí klasifikátorů na bázi umělé neuronové sítě a aktivačními funkcemi o radiálních bázích.

Proband “Freedom” - klasifikátor na bázi umělé neuronové sítě s aktivačními funkcemi RBF 110 neuronů - testováno metodou bootstrap 1/e vzorků nahrazeno, 10 krát převzorkováno - vstupní vektor FFT z 3s úseků - 185 vzorků po 3 sekundách	dm = 3 hm = 18 úspěšnost = 0.8500	dm = 2 hm = 18 úspěšnost = 0.8515
	dm = 3 hm = 21 úspěšnost = 0.8676	dm = 2 hm = 21 úspěšnost = 0.8574
	dm = 4 hm = 12 úspěšnost = 0.8868	dm = 3 hm = 12 úspěšnost = 0.8588
	dm = 4 hm = 15 úspěšnost = 0.8912	dm = 3 hm = 15 úspěšnost = 0.8574
	dm = 4 hm = 18 úspěšnost = 0.8882	dm = 3 hm = 18 úspěšnost = 0.8588
	dm = 4 hm = 21 úspěšnost = 0.8618	dm = 3 hm = 21 úspěšnost = 0.8691
	dm = 1 hm = 12 úspěšnost = 0.7353	dm = 3 hm = 12 úspěšnost = 0.8824
	dm = 1 hm = 15 úspěšnost = 0.7735	dm = 4 hm = 12 úspěšnost = 0.8824
	dm = 1 hm = 21 úspěšnost = 0.7588	dm = 4 hm = 15 úspěšnost = 0.8779
	dm = 2 hm = 12 úspěšnost = 0.8647	

dm = 2 hm = 15 úspěšnost = 0.8574	dm = 1 hm = 18 úspěšnost = 0.7456	dm = 4 hm = 18 úspěšnost = 0.8676
dm = 2 hm = 18 úspěšnost = 0.8662	dm = 1 hm = 21 úspěšnost = 0.7735	dm = 4 hm = 21 úspěšnost = 0.8662
dm = 2 hm = 21 úspěšnost = 0.8471	dm = 2 hm = 12 úspěšnost = 0.8515	
dm = 3 hm = 12 úspěšnost = 0.8515	dm = 2 hm = 15 úspěšnost = 0.8706	
dm = 3 hm = 15 úspěšnost = 0.8515		

Obr. 4: Klasifikace stavu vigility a somnolence probanda „Freedom“ pomocí umělé neuronové sítě s aktivačními funkcemi o radiálních bázích. Symboly mají stejný význam jako v obr. 2.

Proband „MiJa“, samp. 10, 2 stavy - klasifikátor na bázi umělé neuronové sítě s aktivačními funkcemi RBF 110 neuronů - 423 vzorků po 3 sekundách	dm = 4 hm = 12 úspěšnost = 0.9297	dm = 3 hm = 12 úspěšnost = 0.8955
	dm = 4 hm = 15 úspěšnost = 0.8903	dm = 3 hm = 15 úspěšnost = 0.8542
	dm = 4 hm = 18 úspěšnost = 0.8865	dm = 3 hm = 18 úspěšnost = 0.8529
	dm = 4 hm = 21 úspěšnost = 0.8852	dm = 3 hm = 21 úspěšnost = 0.8458
	dm = 1 hm = 12 úspěšnost = 0.7439	dm = 1 hm = 12 úspěšnost = 0.7323
dm = 1 hm = 15 úspěšnost = 0.7181		
dm = 1 hm = 18 úspěšnost = 0.7155		

dm = 1 hm = 21 úspěšnost = 0.7032	dm = 1 hm = 15 úspěšnost = 0.7071	dm = 4 hm = 15 úspěšnost = 0.8800
dm = 2 hm = 12 úspěšnost = 0.8490	dm = 1 hm = 18 úspěšnost = 0.7077	dm = 4 hm = 18 úspěšnost = 0.8826
dm = 2 hm = 15 úspěšnost = 0.8258	dm = 1 hm = 21 úspěšnost = 0.7019	dm = 4 hm = 21 úspěšnost = 0.8897
dm = 2 hm = 18 úspěšnost = 0.8135	dm = 2 hm = 12 úspěšnost = 0.8400	
dm = 2 hm = 21 úspěšnost = 0.8200	dm = 2 hm = 15 úspěšnost = 0.8239	
dm = 3 hm = 12 úspěšnost = 0.8916	dm = 2 hm = 18 úspěšnost = 0.8155	
dm = 3 hm = 15 úspěšnost = 0.8368	dm = 2 hm = 21 úspěšnost = 0.8329	
dm = 3 hm = 18 úspěšnost = 0.8374		
dm = 3 hm = 21 úspěšnost = 0.8471		

Obr. 5: Klasifikace stavu vigily a somnolence probanda „MiJa“ pomocí umělé neuronové sítě s aktivačními funkcemi o radiálních bázích. Symboly mají stejný význam jako v obr. 2.

<p>Proband „Holik“ - klasifikátor na bázi umělé neuronové sítě s aktivačními funkcemi RBF 110 neuronů - 127 vzorků po 3 sec</p>	<p>dm = 3 hm = 21 úspěšnost = 0.9261</p>	<p>dm = 2 hm = 21 úspěšnost = 0.8630</p>
	<p>dm = 4 hm = 12 úspěšnost = 0.8935</p>	<p>dm = 3 hm = 12 úspěšnost = 0.9022</p>
	<p>dm = 4 hm = 15 úspěšnost = 0.8761</p>	<p>dm = 3 hm = 15 úspěšnost = 0.8913</p>
	<p>dm = 4 hm = 18 úspěšnost = 0.8913</p>	<p>dm = 3 hm = 18 úspěšnost = 0.8935</p>
	<p>dm = 4 hm = 21 úspěšnost = 0.8739</p>	<p>dm = 3 hm = 21 úspěšnost = 0.8891</p>
	<p>dm = 1 hm = 15 úspěšnost = 0.8022</p>	<p>dm = 4 hm = 12 úspěšnost = 0.9000</p>
	<p>dm = 1 hm = 18 úspěšnost = 0.7696</p>	<p>dm = 4 hm = 15 úspěšnost = 0.8978</p>
	<p>dm = 1 hm = 21 úspěšnost = 0.8022</p>	<p>dm = 4 hm = 18 úspěšnost = 0.8761</p>
	<p>dm = 2 hm = 12 úspěšnost = 0.8848</p>	<p>dm = 4 hm = 21 úspěšnost = 0.8826</p>
	<p>dm = 2 hm = 15 úspěšnost = 0.9043</p>	
	<p>dm = 2 hm = 18 úspěšnost = 0.8609</p>	<p>dm = 2 hm = 15 úspěšnost = 0.9022</p>
	<p>dm = 3 hm = 12 úspěšnost = 0.9109</p>	<p>dm = 2 hm = 18 úspěšnost = 0.8891</p>
	<p>dm = 3 hm = 15 úspěšnost = 0.8848</p>	
	<p>dm = 3 hm = 18 úspěšnost = 0.8870</p>	

Obr. 6: Klasifikace stavu vigily a somnolence probanda „Holik“ pomocí umělé neuronové sítě s aktivačními funkcemi o radiálních bázích. Symboly mají stejný význam jako v obr. 2.

Uvedené výsledky bude nutno ještě dále vyhodnotit.

Z výsledků uvedených v tabulkách na obr. 2, 4, 5 a 6 je možno soudit, že dosažené hodnoty úspěšnosti klasifikace by mohly být postačující pro reálné aplikace. Pro potvrzení však bude třeba provést podobná vyhodnocení pro mnohem větší počet probandů. Další měření bude též třeba uskutečnit při vizuální stimulaci probandů, která je zřejmě bližší stavu při činnosti operátora dopravního prostředku v praxi.

Nutno je přitom také mít na zřeteli, že klasifikátory a prediktory vycházející z analýzy EEG signálů budou pravděpodobně silně individuální, tj. že je asi bude nutno upravovat pro každou osobu zvlášť. Naštěstí však se přitom též zdá, že pro jednu a tutéž osobu zůstanou po velmi dlouhou dobu jejího života neměnné.

4. Závěr

Detekce a analýza EEG signálů za účelem klasifikace stavu bdělosti a pozornosti lidských operátorů (řidičů, pilotů, dispečerů) nebo též uživatelů umělých systémů, zejména technických a zvláště pak dopravních přináší celou řadu závažných problémů technických i teoretických.

Z nich jsme zde uvedli stručně 5, které za současného stavu našich znalostí v této oblasti považujeme za nejzávažnější. U některých naznačují získané poznatky nadějně cesty k jejich řešení.

Tyto poznatky však bude třeba podepřít dostatečným množstvím srovnatelných měření na vhodně rozprostřeném vzorku pokusných osob. To je zřejmě náročný a značně dlouhodobý úkol, který přesahuje možnosti jedné laboratoře.

5. Literatura

- [1]...Novák M., Faber J., Tichý T.: Analysis of Human Operator Attention Decrease (Analýza poklesu pozornosti řidičů), konference AUTOS, ČVUT, Praha 2001

- [2]...Novák M.: Artificial Systems Operation – Problems in Safety and Reliability
(Funkce umělých systémů – problémy v oblasti bezpečnosti a spolehlivosti),
Multiconference CSCC, MCP, MCME, Crete, Rethymno, July 9, 2001
- [3]...Tichý T.: Výběr signifikantních parametrů poklesu pozornosti řidičů,
diplomová práce, ČVUT, Praha, Fakulta dopravní, 2000
- [4]... Svoboda P.: Metody analýzy EEG aktivity,
diplomová práce, ČVUT, Praha, fakulta elektrotechnická, 17.5. 2001
- [5]...Vysoký P.: Central fatigue identification of human operator (Identifikace únavy
operátora),
Neural Network World, vol. 11, No. 5.
- [6]...Tichý R., Janů Z.: Studie proveditelnosti bezkontaktního snímání signálů
EEG/EMG pro aplikace v dopravě
Výzkumná zpráva Společné laboratoře FZÚ AV ČR a MFF UK, Praha, 2000