


VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



**FAKULTA ELEKTROTECHNIKY A
KOMUNIKAČNÍCH
TECHNOLOGIÍ**

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF BIOMEDICAL ENGINEERING

KLASIFIKACE MIKROSPÁNKU ANALÝZOU EEG

CLASSIFICATION OF MICROSLEEP BY MEANS OF ANALYSIS EEG SIGNAL

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Marina RONZHINA

VEDOUČÍ PRÁCE

SUPERVISOR

Ing. Vratislav ČMIEL

BRNO, 2009

ZDE VLOŽIT ORIGINAL ZADÁNÍ

LICENČNÍ SMLOUVA

POSKYTOVANÁ K VÝKONU PRÁVA UŽÍT ŠKOLNÍ DÍLO

uzavřená mezi smluvními stranami:

1. Pan/paní

Jméno a příjmení: Marina Ronzhina
Bytem: Nagovicina 12-10, Oktyabrsky, 427617
Narozen/a (datum a místo): 13. prosince 1986 v Oktyabrskem

(dále jen „autor“)

a

2. Vysoké učení technické v Brně

Fakulta elektrotechniky a komunikačních technologií
se sídlem Údolní 53, Brno, 602 00
jejímž jménem jedná na základě písemného pověření děkanem fakulty:
prof. Ing. Jiří Jan, CSc, předseda rady oboru Biomedicínské a ekologické inženýrství
(dále jen „nabyvatel“)

Čl. 1

Specifikace školního díla

1. Předmětem této smlouvy je vysokoškolská kvalifikační práce (VŠKP):

- disertační práce
 - diplomová práce
 - bakalářská práce
 - jiná práce, jejíž druh je specifikován jako
- (dále jen VŠKP nebo dílo)

Název VŠKP: Klasifikace mikrosprávku analýzou EEG

Vedoucí/ školitel VŠKP: Ing. Vratislav Čmiel

Ústav: Ústav biomedicínského inženýrství

Datum obhajoby VŠKP: _____

VŠKP odevzdal autor nabyvateli*:

- v tištěné formě – počet exemplářů: 2
- v elektronické formě – počet exemplářů: 2

2. Autor prohlašuje, že vytvořil samostatnou vlastní tvůrčí činností dílo shora popsané a specifikované. Autor dále prohlašuje, že při zpracovávání díla se sám nedostal do rozporu s autorským zákonem a předpisy souvisejícími a že je dílo dílem původním.

3. Dílo je chráněno jako dílo dle autorského zákona v platném znění.

4. Autor potvrzuje, že listinná a elektronická verze díla je identická.

* hodící se zaškrtněte

Článek 2

Udělení licenčního oprávnění

1. Autor touto smlouvou poskytuje nabyvateli oprávnění (licenci) k výkonu práva uvedené dílo nevýdělečně užít, archivovat a zpřístupnit ke studijním, výukovým a výzkumným účelům včetně pořizování výpisů, opisů a rozmnoženin.
2. Licence je poskytována celosvětově, pro celou dobu trvání autorských a majetkových práv k dílu.
3. Autor souhlasí se zveřejněním díla v databázi přístupné v mezinárodní síti
 - ihned po uzavření této smlouvy
 - 1 rok po uzavření této smlouvy
 - 3 roky po uzavření této smlouvy
 - 5 let po uzavření této smlouvy
 - 10 let po uzavření této smlouvy(z důvodu utajení v něm obsažených informací)
4. Nevýdělečné zveřejňování díla nabyvatelem v souladu s ustanovením § 47b zákona č. 111/ 1998 Sb., v platném znění, nevyžaduje licenci a nabyvatel je k němu povinen a oprávněn ze zákona.

Článek 3

Závěrečná ustanovení

1. Smlouva je sepsána ve třech vyhotoveních s platností originálu, přičemž po jednom vyhotovení obdrží autor a nabyvatel, další vyhotovení je vloženo do VŠKP.
2. Vztahy mezi smluvními stranami vzniklé a neupravené touto smlouvou se řídí autorským zákonem, občanským zákoníkem, vysokoškolským zákonem, zákonem o archivnictví, v platném znění a popř. dalšími právními předpisy.
3. Licenční smlouva byla uzavřena na základě svobodné a pravé vůle smluvních stran, s plným porozuměním jejímu textu i důsledkům, nikoliv v tísní a za nápadně nevýhodných podmínek.
4. Licenční smlouva nabývá platnosti a účinnosti dnem jejího podpisu oběma smluvními stranami.

V Brně dne: 29. května 2009

.....

Nabyvatel

.....

Autor

Abstrakt

Tato diplomová práce se zabývá detekcí mikrospánku na základě změn energetického spektra EEG signálu. Vstupními hodnotami pro klasifikaci jsou výsledky časově-frekvenční analýzy. Navržená metoda klasifikace využívá aparát fuzzy logiky. Jsou navrženy 4 klasifikátory, jejichž základem jsou fuzzy inferenční systémy lišící se bázi pravidel. Pro návrh funkce příslušnosti premis pravidel jsou použity výsledky fuzzy shlukování. První dva klasifikátory pro detekci mikrospánku využívají pouze alfa pásmo spektrogramu EEG signálu. Tedy umožňují detekci jen stavu relaxace. Třetí klasifikátor je na rozdíl od předcházejících doplněn pravidly pro delta pásmo, což dává možnost rozlišovat v spektru 3 stavy: mentace, relaxace a somnolence. Čtvrtý klasifikátor má rozhodovací mechanismus zahrnující celé pásmo signálu. Uvažovaný přístup ke klasifikaci mikrospánku je realizován a implementován prostřednictvím programového vybavení počítače. Je vytvořen uživatelský program s grafickým rozhraním.

Klíčová slova: klasifikace mikrospánku, EEG signál, časově-frekvenční analýza, fuzzy logika, shluková analýza, fuzzy inferenční systém

Abstract

This master thesis deals with detection of microsleep on the basis of the changes in power spectrum of EEG signal. The results of time-frequency analysis are input values for the classification. Proposed classification method uses fuzzy logic. Four classifiers were designed, which are based on a fuzzy inference systems, that are differ in rule base. The results of fuzzy clustering are used for the design of rule premises membership functions. The two classifiers microsleep detection use only alpha band of the EEG signal's spectrogram then allows the detection of the relaxation state of a person. Unlike to first and second classifiers, the third classifier is supplemented with rules for the delta band, which makes it possible to distinguish the 3 states: vigilance, relaxation and somnolence. The fourth classifier inference system includes the rules for the whole spectrum band. The method was implemented by computer. The program with a graphical user interface was created.

Keywords: classification of microsleep, EEG signal, time-frequency analysis, fuzzy logic, cluster analysis, fuzzy inference system

RONZHINA, M. *Klasifikace mikrosánku analýzou EEG: diplomová práce*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2009. 69 s. Vedoucí diplomové práce Ing. Vratislav Čmiel.

Prohlášení

Prohlašuji, že svou diplomovou práci na téma Klasifikace mikrospánku analýzou EEG jsem vypracovala samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušila autorská práva třetích osob, zejména jsem nezasáhla nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědomá následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení § 152 trestního zákona č. 140/1961 Sb.

V Brně dne 29. května 2009

.....
podpis autora

Poděkování

Děkuji vedoucímu diplomové práce Ing. Vratislavu Čmielovi za cenné rady při zpracování mé diplomové práce a organizaci měření encefalografických signálů. Také děkuji všem kamarádům zúčastněným na tomto měření.

V Brně dne 29. května 2009

.....
podpis autora

OBSAH

Seznam obrázků	10
Seznam tabulek	11
Úvod	12
1 Elektroencefalografické signály	13
1.1 Elektroencefalografie.....	13
1.1.1 Fyziologické základy EEG.....	13
1.1.2 Snímání EEG signálů.....	13
1.2 Vlastnosti signálů EEG.....	14
1.2.1 Atributy EEG signálů.....	15
1.2.2 Normální bdělá EEG.....	16
1.2.3 Normální pomalá aktivita.....	17
1.2.4 Normální spánková EEG	17
1.2.5 Spánková stadia	17
1.2.6 Aktivační metody	18
1.3 Artefakty	18
1.3.1 Artefakty z pacienta	18
1.3.2 Artefakty z EEG přístroje	19
1.3.3 Interferenční artefakty.....	19
2 Struktura použité metody	20
3 Časově-frekvenční analýza EEG signálů	23
4 Klasifikace na základě fuzzy usuzování	26
4.1 Teorie fuzzy množin	26
4.1.1 Fuzzy množiny	26
4.1.1.1 Základní pojmy.....	26
4.1.1.2 Základní vlastnosti fuzzy množin.....	27
4.1.1.3 Základní operace s fuzzy množinami.....	28
4.1.1.4 Funkce příslušnosti.....	29
4.1.2 Fuzzy inference	30
4.1.2.1 Báze fuzzy pravidel.....	30
4.1.2.2 Kompoziční pravidlo usuzování	30

4.1.2.3 Mamdaniho inference.....	31
4.1.2.4 Usuzování pro klasifikace.....	32
4.2 Fuzzy systémy	33
4.2.1 Struktura fuzzy systémů.....	33
4.2.2 Fuzzy shlukování.....	34
4.2.3 Syntéza fuzzy pravidel na základě výsledků fuzzy shlukování	37
4.3 Návrh klasifikátorů na základě fuzzy inferenčního systému	38
4.3.1 Výběr příznaků pro usuzování	38
4.3.2 Aproximace funkce příslušnosti	39
4.3.3 Tvorba báze fuzzy pravidel.....	43
4.3.4 Algoritmus zpracování výstupů FIS	47
5 Popis a struktura programu v prostředí MATLAB	52
6 Výsledky.....	59
Závěr	66
Seznam použité literatury	67
Použité zkratky	69

Seznam obrázků

Obr. 1 Mezinárodní systém rozmístění elektrod 10-20.....	14
Obr. 2 Ukázka signálu EEG a jeho spektra	15
Obr. 3 Volba rozmístění elektrod pro snímání EEG	20
Obr. 4 Simulovaný EEG signál	21
Obr. 5 Principiální blokové schéma metody	22
Obr. 6 Spektrogramy EEG signálu.....	24
Obr. 7 Spektrogram simulovaného signálu.....	25
Obr. 8 Metody defuzifikace: a) prvního maxima, b) průměrného maxima, c) těžiště.....	28
Obr. 9 Základní operace s fuzzy množinami	28
Obr. 10 Populární funkce příslušnosti.....	30
Obr. 11 Ilustrace Mamdaniho inference.....	32
Obr. 12 Schéma systému fuzzy usuzování	33
Obr. 13 Porovnání klasického a fuzzy shlukování	35
Obr. 14 Příklad fuzzy shluků: a) fuzzy shluk 1, b) fuzzy shluk 2	37
Obr. 15 Příklad výsledků fuzzy shlukování: a) 2 shluky, b) 3 shluky	39
Obr. 16 Aproximace funkce příslušnosti pro FIS1	40
Obr. 17 Aproximace funkce příslušnosti pro FIS2.....	40
Obr. 18 Ukázka aproximujících funkcí s vyznačenými parametry.....	42
Obr. 19 Aproximace funkce příslušnosti pro FIS3.....	43
Obr. 20 Funkce příslušnosti antecedentu a konsekventu pravidel FIS1	44
Obr. 21 Funkce příslušnosti antecedentu a konsekventu pravidel FIS2	45
Obr. 22 Funkce příslušnosti antecedentu a konsekventu pravidel FIS3	46
Obr. 23 Funkce příslušnosti antecedentu a konsekventu pravidel FIS4	47
Obr. 24 První etapa zpracování výstupu FIS (na příkladu FIS1).....	48
Obr. 25 Druhá etapa zpracování výstupu FIS (na příkladu FIS1)	49
Obr. 26 Závěrečná etapa zpracování výstupu FIS (na příkladu FIS1)	49
Obr. 27 První etapa zpracování výstupu FIS (na příkladu FIS4).....	50
Obr. 28 Druhá etapa zpracování výstupu FIS (na příkladu FIS4)	50
Obr. 29 Závěrečná etapa zpracování výstupu FIS (na příkladu FIS4)	51
Obr. 30 Okno zobrazení signálu a jeho spektra.....	52
Obr. 31 Okna programu: a) Výběr signálu (vlevo), b) Varovací okno Výběr signálu (vpravo).....	53
Obr. 32 Okno časově-frekvenční analýzy signálů.....	54
Obr. 33 Okna programu: a) Varovací okno PARAMETRY SPEKTROGRAMU (vlevo) b) ZOBRAZENÍ SPEKTROGRAMU (vpravo).....	54
Obr. 34 Okno shlukové analýzy.....	55
Obr. 35 Okno pro výběr klasifikátoru.....	55
Obr. 36 Okno KLASIFIKATOR.....	56
Obr. 37 Menu oken klasifikátorů.....	56
Obr. 38 Okna klasifikátoru: a) STRUKTURA FIS b) APROXIMACE FUNKCE PRISLUSNOSTI FIS	57
Obr. 39 Okna klasifikátoru: a) FUNKCE PRISLUSNOSTI FIS, b) VYSTUP FIS.....	57
Obr. 40 Okna klasifikátoru: a) ZPRACOVANI VYSTUPU FIS, b) VYSTUP KLASIFIKATORU	58
Obr. 41 Nález rozpadání alfa energií.....	59
Obr. 42 Srovnání výsledků klasifikaci	60
Obr. 43 Srovnání funkcí příslušnosti FIS1 a FIS2	61
Obr. 44 Výstup KLASIFIKATORU 3 pro simulovaný signál.....	62
Obr. 45 Výstup KLASIFIKATORU 4 pro simulovaný signál.....	62

Seznam tabulek

Tab. 1 <i>Závislost hodnoty energie spektrálních pásem na stavu člověka</i>	38
Tab. 2 <i>Kvantitativní hodnocení výsledků klasifikace</i>	64

Úvod

Co mají společného řidič automobilu, pilot a dispečer v elektrárně? Odpovědí je jednotvárná scéna, kterou pozorují na svém pracovišti. Přičemž člověk, pracující v podobné sféře, musí být schopen udržovat vysokou úroveň pozornosti, rychlosti a správnosti reakce během celého pracovního dnu, což je docela složité v podobných pracovních podmínkách.

Dlouhotrvající činnost unavuje a působí pokles pozornosti, což vede ke špatnému hodnocení informace, potřebné pro správné a spolehlivé vykonávání této činnosti. Extrémním případem je stav mikrospánku s otevřenými nebo zavřenými očima, kdy úroveň pozornosti je velice nízká. Pozdní reakce na vnější změnu může být příčinou nehod, které mají většinou tragické následky. Proto je detekce mikrospánku už několik let zájmem mnoha vědců.

V současné době existují perspektivní projekty vytvoření varovného systému pro řidiče, který by ho upozornil na nebezpečí v případě poklesu úrovně vigility [5], [14], [15]. Zajímavým je použití analýzy encefalografického signálu v metodě Biofeedback [3], [13].

Tato diplomová práce je zaměřená na využití analýzy encefalografického signálu pro účel detekce mikrospánku. Používaná data byla naměřena u 10 testovaných osob, přičemž získané záznamy obsahují reakci na podněty (řešení matematických úloh, otevření/zavření očí), zaměřených na vyvolání v signálech změn charakteristických pro přechod ze stavu bdělosti do stavu mikrospánku. Analýza spektru signálů v časově-frekvenční oblasti je popsána v kapitole 3. Výsledkem spektrální analýzy jsou spektrogramy, zobrazující vývoj spekter v čase. Dalším krokem je fuzzy shlukování hodnot spekter, výsledky kterého jsou dále použity pro návrh systému fuzzy usuzování. Posledním krokem je klasifikace výsledků spektrální analýzy klasifikátory, založenými na fuzzy rozhodování a následující zpracování výstupu systémů fuzzy usuzování. Návrh klasifikátorů je uveden v kapitole 4.

Zpracování dat je realizováno v programovém prostředí MATLAB, které je velice vhodné pro dané účely. Konečným výstupem diplomové práce je uživatelský program, komunikující v grafickém prostředí. Program umožňuje automatickou detekci mikrospánku prostřednictvím navržené metody. Popis programu a uživatelského rozhraní je uveden v kapitole 5.

1 Elektroencefalografické signály

1.1 Elektroencefalografie

Elektroencefalografie (EEG) je metoda, při které se snímá elektrická aktivita mozku.

Bdělost a spánek se projevují v srdečním rytmu, pohybu očí, svalové aktivitě, změně kožní galvanické vodivosti, dechové aktivitě apod. Problémem je však zpomalenost reakce těchto aktivit na změny vigily. Proto se elektrokardiografie, elektrookulogram, elektromyogram téměř nepoužívají v běžné praxi. Naopak elektroencefalografie, pracující se signály mozku, našla uplatnění v neurologických a psychologických (hlavně dopravně psychologickém) vyšetřeních. Z analýzy záznamu EEG můžeme například posoudit, v jaké fázi spánkového cyklu se daná osoba nachází, zdali mozek zdravý, nebo zjistit a rozlišit různé druhy epilepsie.

1.1.1 Fyziologické základy EEG

EEG umožňuje analyzovat potenciálová pole mozkové elektrické aktivity tím, že zaznamenává zesílené rozdíly napětí mezi elektrodami umístěnými na skalpu (rutinní skalpová EEG), na kůře (elektrokortikografie) nebo v mozku (hloubková EEG).

Mozek se skládá z neuronů, glie a cév. Neurony jsou tvořeny somatem a výběžky (dendrity a axony). Z funkčního hlediska je dendrity možno pojímat jako jakési prodloužení somatu. Spolu s ním tvoří recepční část neuronu. Dendrity a somata jsou pokryty synapsami (desítky tisíc na jednom neuronu), na nichž se tvoří postsynaptické potenciály, které jsou prvotním zdrojem extracelulárního potenciálového pole. K neuronům zasahují výběžky glie, která na druhé straně přiléhá k cévám. Extracelulární prostor v mozku, tedy ten prostor, ve kterém dochází k proudům důležitým pro genezi EEG signálu, se tímto uspořádáním redukuje na velmi úzké prostory.

Nález určitého rytmu na EEG představuje záznam jakéhosi zprůměrněného, časově a prostorově sumovaného elektrického chování velkých populací neuronů. Individuální variabilita chování konkrétního neuronu ve vztahu k průměrnému chování neuronální populace je při složitosti anatomického a funkčního uspořádání mozkové kůry nízká. Protože extracelulární potenciálové pole jednotlivé buňky je velmi malé, a na skalpu by nebylo registrovatelné, je k tomu, aby elektrické děje nacházely svůj odraz v EEG signálech, třeba jeho sumace s obdobně časově a prostorově uspořádanými potenciálovými poli okolních buněk. [23]


1.1.2 Snímání EEG signálů

Rutinní skalpová EEG je bezpečná, široce dostupná, levná a pacienta nezatěžující vyšetřovací metoda, která se velmi dobře hodí ke sledování změn v čase.

Pro snímání EEG signálů se používají *povrchové* nebo *podkožní* elektrody. Povrchové elektrody jsou kruhového tvaru (ploché, někdy vypuklé), obvykle průměru 7 až 10 mm, zhotovené nejčastěji na bázi stříbra. K nim je připojen izolovaný flexibilní vodič, sloužící ke spojení elektrody se vstupem EEG přístroje. K jejich fixaci na skalp existuje několik technik. Jednotlivé elektrody jsou individuálně rozmístěny na povrchu lebky podle zvoleného plánu nebo je celý snímací systém elektrod fixován k pacientově hlavě pomocí gumových pásků nebo je zabudován v EEG čepice. Fixace kolodiem má výhodu v tom, že poskytuje velmi stabilní záznam s minimálními artefakty. Jinou metodou je použití vodivé pasty, která jednak

fixuje elektrodu, jednak zaručuje dobrý elektrický kontakt. Dalšími v současnosti používanými metodami fixace elektrod jsou pomocí pásů a elektrodových čepic. Skalповé elektrody snímají jemné rozdíly elektrických potenciálů (kolem 10mV) a vedou je ke zpracování do přístroje. Naměřené proudy jsou příliš nízké, proto se zesilují, aby je bylo možno lépe hodnotit. Naměřené a zesílené hodnoty elektrických potenciálů (vzestup a pokles hodnot) vytváří v záznamu vlny. Potenciály ve skutečnosti představují záznam velikostí rozdílů potenciálů mezi dvěma místy skalpu (mezi dvěma elektrodami).[22], [9]

Mezinárodní systém rozmístění elektrod 10-20 (viz Obr. 1) umožňuje pokrytí skalpu soustavou elektrod, zaručující symetrické rozmístění a reprodukovatelnost vyšetření u téhož pacienta i pacientů různých. Poloha elektrod je založena na soustavě linií vedených mezi kostěnými výstupky na hlavě. Tyto linie jsou při určování polohy elektrod děleny v 10% a 20% své délky. Jde o flexibilní systém umožňující přidání dalších elektrod a další rozdělení vzdáleností mezi elektrodami na intervaly 10%-tzv. systém 10-10. Standardní sestava elektrod v systému 10-20 zahrnuje 21 elektrod snímacích a 1 jednu zemnicí elektrodu. Systém 10-10 zahrnuje 75 elektrodových pozic. [17], [18]



Obr. 1 Mezinárodní systém rozmístění elektrod 10-20

1.2 Vlastnosti signálů EEG

Elektroencefalografie je pomocná vyšetřovací metoda. K tomu, aby mohl lékař popsat EEG signál, potřebuje čtyři informace: 1. pacientův věk, 2. stav jeho vědomí a behaviorální projevy během natáčení, 3. užívanou medikaci (eventuálně metabolickou situaci) a 4. podmínky natáčení včetně stimulů, kterých bylo použito, a možných zdrojů artefaktů.

Stav vědomí lze popsat jednoduše termíny jako „při vědomí“, „utlumený“, „soporózní“, „komatózní“. V grafu musí být poznamenány stimuly jako otevření a zavření očí, fotostimulace, hluboké dýchání nosem a ústy (hyperventilace), dotek, bolestivá stimulace, pohyb a eventuální možné zdroje artefaktů.

U neurologicky zdravých dospělých osob se dá nalézt několik typů EEG signálu v bdělosti i v různých stádiích spánku. Přitom variabilita bdělého signálu mezi různými vyšetřovanými bývá větší, než je tomu ve spánku.

EEG křivka je velmi zprostředkovaným odrazem elektrických dějů probíhajících v mozku.

Každá potenciálová změna mezi snímacími elektrodami, projevující se jako výchylka EEG stopy, se označuje jako vlna. Každou vlnu nebo sled vln popisujeme jako aktivitu.


1.2.1 Atributy EEG signálů

Pro popis EEG signálu důležité rozeznat v jednotlivých vzorcích jejich frekvenci, amplitudu, tvar, distribuci, šíření, symetrii, synchronii, rytmicitu, periodicitu, perzistenci a reaktivitu. Jde o vlastnosti (atributy) EEG vzorců. Popíšeme některé z nich.

Frekvence je počet vln, které se opakují za 1 s (vyjádřuje se v Hz). Frekvence EEG křivky je obvykle shrnována do frekvenčních pásem. Jako frekvenci delta se označuje frekvenci pod 3.5 Hz, jako theta 4-8 Hz, jako alfa 9-13 Hz a jako beta frekvenci nad 13 Hz.

Amplituda EEG vzorců se udává v mikrovoltech a značí vertikální rozměr vzorce. Přesné měření amplitudy jednotlivých vln v EEG signálu prakticky nemá význam, protože jejich výška závisí na mnoha faktorech, např. na vzdálenosti mezi elektrodami.

Na obrázku 2 je uveden příklad EEG signálu a jeho spektra. Je zřejmé, že dominující složkou je alfa aktivita.



Obr. 2 Ukázka signálu EEG a jeho spektra

Perzistenci popisujeme frekvenci, se kterou se daný EEG vzorec v delším úseku grafu objevuje. Některé vzorce se vyskytují občasně či intermitentně. Tuto frekvenci můžeme popsat indexem, což je podíl z celkové doby natáčení, během kterého se daný EEG vzorec objeví. Tak např. index 20% popíše fakt, že daný EEG vzorec se vyskytuje v 20% grafu.

Reaktivita označuje změnu, kterou je možno navodit v normálním či abnormním EEG vzorci zevními stimuly. Podněty užívané ke zkoumání reaktivity jsou na rozdíl od aktivačních

procedur zmíněných později spíše zaměřeny na objasnění přítomnosti nebo nepřítomnosti normální odpovědi na stimulaci. Dobře známými jsou vymizení alfa aktivity po otevření očí.

1.2.2 Normální bdělá EEG

Bdělé EEG dospělých zahrnuje normální vzorce.

Alpha aktivita je definována svou frekvencí 8 až 13 Hz, distribucí hlavně nad zadními oblastmi hlavy s maximem amplitudy okcipitálně či okcipitoparietálně a útlumem při otevření očí (tzv. alfa atenuační reakce či reakce zástavy, blokování či desynchronizace) se znovuobjevením při jejich opětovném zavření. Jde o aktivitu, která se nachází v EEG osob v relaxované bdělosti – při kolísající vigilitě a usínání mizí. Skalповá alfa aktivita představuje zprůměrněnou aktivitu několika generátorů, které se nacházejí nejen v okcipitálních, ale také temporálních a centrálních oblastech. Hlavním generátorem jsou však oblasti okcipitální.

Frekvence alfa aktivity může kolísat s kolísající vigilitou u stejné osoby v rozmezí až 1 Hz, také po otevření očí se může její frekvence přechodně až o 2 Hz zvýšit.

Stejně tak je normální, jestliže alfa aktivita není přítomná po celou dobu natáčení, nebo se vyskytuje pouze intermitentně, nejčastěji při hyperventilaci, či při probouzení ze spánku. To často vidíme u osob ve zvýšené psychické tenzi. Dokonce ani úplná absence alfa aktivity není abnormitou.

Amplituda alfa aktivity může být různá, za střední amplitudu je považováno 20-80 μV , přičemž amplituda má být nad oběma hemisférami symetrická či na straně pravé o třetinu vyšší. Amplituda alfa aktivity poněkud klesá s věkem, zřejmě v důsledku zvyšování impedance vmezeřených tkání, tedy ne v důsledku snížení výkonnosti jejích generátorů.

Alfa aktivita může být kromě otevření očí blokována i budivými podněty, pozorností, mentální činností či emoční tenzí a ospalostí. Stupeň útlumu alfa aktivity po otevření očí je velmi různý, a může kolísat od jejího úplného vymizení po celou dobu otevření očí až po krátce trvající mírné snížení amplitudy alfa aktivity. Abnormitou je, pokud alfa aktivita není vůbec blokována otevřením očí, či je-li blokována pouze jednostranně. V ospalosti se často objevuje vymizení alfa aktivity či tzv. paradoxní alfa rytmus, tedy alfa aktivita, která se objevuje po otevření očí. Tato aktivita se po několika sekundách většinou vytrácí, a znovu se objevuje po opětovném zavření očí.

Alfa aktivita představuje při hodnocení EEG jakousi *startovní čáru*. První otázkou je, zda je alfa aktivita přítomna. Jestliže není, pátráme po příčině, která může spočívat v tom, že pacient má otevřené očí, je ospalý nebo spí, má atypický graf s nepřítomností alfa aktivity či může jít o známku abnormity. Přítomnost a charakter alfa aktivity jsou také rozhodující pro hodnocení dalších vzorců.

Beta aktivitu definuje její frekvence, která je vyšší než 13 Hz. Obvyklé frekvenční rozpětí je 18-25 Hz, méně často 14-16 Hz a zřídka 35-40 Hz. Tato rychlá aktivita je ve skalповém EEG výrazně atenuována a její amplituda zde bývá téměř vždy nižší než 20 μV , většinou méně než 10 μV . Může se vyskytovat nad všemi oblastmi skalpu.

Nejčastější je nad oblastmi frontálními až frontocentrálními, tehdy ji často blokuje taktilní stimulace. Beta aktivity může ubývat v ospalosti a usínání, perzistuje však obvykle déle než aktivita alfa. Při usínání se může stát nápadnější, někdy jí dokonce může přibýt i fakticky. Její amplituda je většinou nižší, než je tomu u alfa aktivity. Zastoupení beta aktivity se zvyšuje s přibývajícím věkem. Také u žen je její zastoupení významně vyšší než u mužů. Zvýšené zastoupení beta aktivity můžeme pozorovat při medikamentózním ovlivnění (např. barbituráty).

1.2.3 Normální pomalá aktivita

U některých zdravých osob nacházíme frontocentrálně příměs theta vln 6-7 Hz ne vyšších než 15 μ V. Jejich amplituda se může zvětšovat při usínání. Tato aktivita se někdy objevuje u mladých osob při emocích. Jde o normální nález. U menšiny mladých dospělých zdravých osob (7-10%) lze nalézt určité množství pomalé aktivity, která je nad zadními oblastmi přimíšena k aktivitě alfa. Jde o vlny nepřesahující 120% amplitudy alfa aktivity, která je na ně často superponována. Častěji je zachycujeme u žen, dosti často jich ubývá během natáčení, obvykle reagují útlumem na otevření očí.

1.2.4 Normální spánková EEG

Normální vzorce zachycované ve spánku se liší od vzorců obvyklých v bdělosti.

Pomalé vlny theta a delta se ve spánku obvykle objevují v široké distribuci, bývají lépe prokreslené nad zadními oblastmi, rychlejší, nižší, více asynchronní a méně perzistující v povrchních stádiích non-REM spánku než ve stádiích hlubších.

1.2.5 Spánková stadia

Rozeznáváme 1.-4. stadium non-REM spánku a REM spánek. Na přechodu relaxované bdělosti ve spánek často dochází ke zvýraznění a mírnému zpomalení alfa aktivity, přičemž aktivita beta se nemění a přetrvává do 1. stadia non-REM spánku.

1. stadium non-REM spánku začíná vymizením alfa aktivity a objevením se pomalé aktivity 2-7 Hz. Tato směs vln různých frekvencí je u většiny osob nízká a nepravidelná, u některých však může být středně vysoká a rytmičtější. Takové pomalé vlny lze odlišit od abnormních pomalých vln právě tím, že přecházejí rozvoj hlubších spánkových stadií. V této fázi se mohou objevit několik sekund trvající artefakty z pomalých pohybů očí.

Ve 2.stadiu non-REM spánku perzistují pomalé vlny 2-7 Hz, které jsou častěji synchronní než v 1.stadiu.

Pro 3. stadium non-REM spánku je charakteristické, že 20-50% záznamu zaujímají delta vlny s frekvencí pod 2 Hz a s amplitudou nad 75 μ V.

Pro 4.stadium non-REM spánku je charakteristické, že více než 50% záznamu tvoří delta vlny s frekvencí pod 2 Hz a s amplitudou nad 75 μ V.

REM-spánek se na EEG projevuje nízkou nepravidelnou asynchronní aktivitou různých frekvencí, která připomíná 1.stadium non-REM spánku. V centrálních a frontálních oblastech se mohou vyskytovat skupiny vln podobné zubům pily a vlny alfa o 1-2 Hz pomalejší než v bdělosti. Charakteristické pro toto stadium spánku jsou rychlé oční pohyby, které jsou optimálně snímány elektrookulograficky v rámci spánkové polygrafie, kdy je možné též snímat snížení svalového tonu, zvýšení krevního tlaku a tepové frekvence a zrychlení a znepravidelnění dechu.

Budí-li se dospělá osoba ze spánku, závisí obraz EEG tohoto děje na spánkovém stadiu. Buzení z 1.stadia nebývá provázeno jinou změnou než návratem původního alfa rytmu. Od 2. stadia non-REM spánku se při probouzení mohou objevovat vzorce, které jsou obvyklé a více vyjádřené u dětí. Pak se v EEG objeví krátký řetězec vln frekvence alfa ve frontocentrální oblasti. Navíc se mohou vyskytnout 1-2 frontální pomalé vlny o frekvenci 1.5-3 Hz. U mladých dospělých se může po probuzení objevit frontocentrálně skupina vln o frekvenci 4-5 Hz krátkého trvání. Spánkové cykly se skládají z charakteristického střídání

spánkových stadií. První spánkový cyklus většinou začíná 1. stadiem non-REM spánku a pokračuje přes stále hlubší stadia non-REM k REM spánku, na který opět navazuje povrchní non-REM spánek. Není nijak neobvyklé, že některá stadia v jednotlivých cyklech nejsou patrna. Během nočního spánku se u zdravých lidí opakuje asi 5-7 takových cyklů, přičemž první cyklus bývá nejkratší. Ostatní cykly trvají většinou 80-120 minut. REM spánek se obvykle objevuje na konci každého cyklu, takže první REM stadium lze očekávat 70-90 minut po začátku spánku. U mladých osob je podíl 1.stadia non-REM 5-10%, 2. stadia 30-50%, 3.a 4. stadia 20-40% a REM spánku 25%. [22]

Mnozí neurofyziology považují mikrosnánek za 1. stadium non-REM spánku.

1.2.6 Aktivační metody

Aktivační metody zahrnují jakoukoli proceduru používanou ke zvýraznění nebo vyvolání normální nebo abnormní aktivity. Aktivačními stimuly rozumíme různé sensorické modalities, elektrickou a farmakologickou stimulaci a změny v behaviorálním stavu nebo stavu vědomí. Rutinně se používá hluboké dýchání, fotostimulace a spánek (resp. spánková deprivace). Vedle běžné fotostimulace stroboskopem můžeme použít stimulace vizuálními vzorci, sledováním obrazů nebo televize, hrou počítačových her. Speciální stimuly představuje třeba úleková situace, čtení, psaní, psychické děje (počítání, představy atd). [16]

1.3 Artefakty

EEG artefaktem je každý EEG obraz, který není záznamem elektrické činnosti mozku. Nejčastěji se dělí podle původu na artefakty:

1. z pacienta,
2. z EEG zařízení,
3. z interference se zdroji elektrické energie.

Artefakty se obvykle jasně odlišují od EEG aktivity, mohou se objevovat v jedné nebo několika elektrodách. Objevují-li se v elektrodě jedné, vzbuzuje to samo o sobě podezření, protože taková EEG aktivita je vzácná. Jestliže se objevují ve více elektrodách, bývá jejich distribuce nelogická, nerespektující lokalizační pravidla EEG.

1.3.1 Artefakty z pacienta

Artefakty z pacienta představují elektroencefalografický záznam biologického signálu jiného než EEG. Řada z nich je záměrně zaznamenávána jinými elektrografickými metodikami (napr. oční pohyby bývají registrovány elektronystagmograficky, elektrické projevy srdeční činnosti elektrokardiograficky atd). Kombinace těchto metod s EEG je *polygrafie*, která nachází uplatnění hlavně při vyšetřování spánku a v intenzivní medicíně.

Artefakty oční: artefakty z mrkání a jiných pohybů očí jsou zachycovány hlavně frontálními elektrodami, ale mohou se šířit i do elektrod centrálních a temporálních. Jejich hlavním zdrojem je korneoretinální potenciál. Jeho velikost je 50-100 mV a můžeme si ho představit jako dipól s pozitivním pólem na rohovce a negativním na sítnici. Oční artefakty mohou mít různý tvar. Oční artefakty bývají symetrické. Kmitání (flutter) očních víček tvoří na EEG rytmickou aktivitu, obvykle o frekvenci 5-8 Hz. Oční artefakty jsou nejčastějším typem artefaktů z pacienta. Odstraňují je tím, že pacienta požádají, aby udržoval oči v klidu a zavřené.

Artefakty svalové: artefakty svalové jsou velmi časté. Jsou charakteristické svým krátkým trváním, ostrým tvarem a frontálním a temporálním maximem.

Artefakty z pohybu: pohybové artefakty v rutinních EEG jsou obvykle náhlé, nerepetitivní, vyskytují se ve většině nebo ve všech elektrodách v referenčním zapojení. Důležitou vlastností pohybových artefaktů je to, že pohyb hlavou postihuje všechny elektrody. Při reformátování grafu do bipolárního zapojení mají tedy pohybové artefakty tendenci se alespoň částečně vyrušit.

EKG artefakty: artefakty ze srdeční činnosti mají periodicitu danou frekvencí srdeční akce. Tato periodicitu je v případech, kdy není přítomna arytmie, pravidelná. Artefakty jsou zachycovány v jednom či ve více svodech, časté jsou ve svodech z uší. Někdy bývají důsledkem špatného elektrodového kontaktu. Nejnápadnější jsou u osob s krátkým krkem, zvláště u obézních hypertoniků. Artefakty vznikají i při činnosti kardiostimulátoru. EKG artefakty lze rozeznat podle jejich pravidelnosti a tvaru. Někdy mizí po úpravě elektrodového kontaktu, jindy je můžeme odstranit úpravou polohy nemocného tak, aby se hlava dostala dále od hrudníku. Ve sporných případech je nutné někdy současné natáčení EEG a EKG.

Pulzové artefakty: artefakty pulzové mají tvar periodických oblých či trojúhelníkovitých vln a nejčastější jsou frontálně a temporálně. Vznikají při umístění elektrody v blízkosti tepny, tedy většinou ve svodech z jedné elektrody. Také je jejich periodicitu shodná s frekvencí srdeční akce. Právě podle této periodicity a tvaru je můžeme během natáčení rozeznat a odstranit přemístěním elektrody. Od EKG artefaktů se odlišují tím, že na současně snímaném EKG předchází artefakt EKG artefakt pulzový.

Galvanické kožní artefakty: artefakty z pocení mají tvar velmi pomalých vln, nejčastěji lokalizovaných frontálně a temporálně. Někdy může být u osob s potivým zátylkem jejich distribuce největší nad zadními oblastmi. Vznikají změnami elektrodové impedance a kožního potenciálu při pocení.

Artefakty dentální: artefakty dentální vznikají zejména u osob se zubními výplněmi z rozdílných kovů. Často mohou být velmi matoucí.

Artefakty z pohybů jazyka a ostatních orofaryngeálních struktur: jazyk si lze představit jako dipól, jehož špička je negativnější než kořen. Artefakty z jeho pohybů jsou pomalé vlny široké distribuce, často se středočárovým maximem. Tyto artefakty vznikají při řeči, polykání a např. při pláči či škytání.

1.3.2 Artefakty z EEG přístroje

Artefakty elektrodové: artefakty elektrodové se objevují ve svodech z jedné elektrody. Některé mohou mít charakteristický tvar diametrálně odlišný od jakékoli EEG aktivity, řada však má tvar této aktivity podobný. Artefakty mohou vznikat i z kabelů a headboxu.

1.3.3 Interferenční artefakty

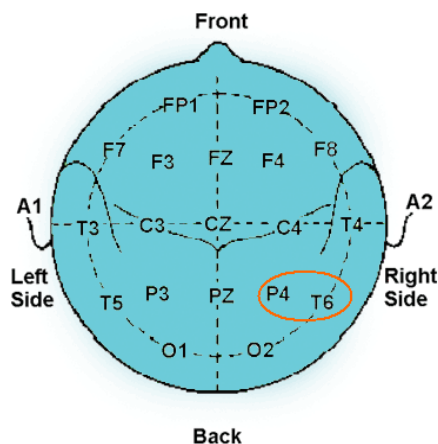
Interferenční artefakty vznikají záznamem elektrické interference z bližšího či vzdálenějšího okolí EEG přístroje. Mohou být generovány elektrostaticky bez ohledu na intenzitu proudu či elektromagneticky při vyšších intenzitách proudu. Dříve byl velmi častým interferenčním artefaktem artefakt od střídavého elektrického proudu s frekvencí 50 Hz. I nyní se s tímto artefaktem setkáváme často. Stále častěji ale můžeme narazit na artefakty s jinou frekvencí a morfologií, které vznikají např. při zvonění telefonu, zapnutí osvětlení, činností signalizačních systémů, ventilačních přístrojů, infúzních souprav aj. [22]

2 Struktura použité metody

Algoritmus klasifikace je založen na zpracování energie spektrálních složek EEG signálu.

Jako vstupní data jsou použity signály EEG, zaznamenané v laboratoři bioniky Ústavu biomedicínského a ekologického inženýrství VUT v Brně pomocí experimentálního laboratorního systému BIOPAC LAB (Biopac Systems, Inc., USA), který umožňuje snímání a zpracování signálů různými metodami vyšetření: elektromyografií (EMG), elektrokardiografií (EKG), elektroencefalografií (EEG), elektrookulografií (EOG).

Pro snímání EEG byly zvoleny 2 elektrody – P4 a T6 (viz Obr. 3), protože signály těchto elektrod obsahují menší množství pohybových, svalových a očních artefaktů, navíc tato krajina vykazuje dobré vyjádření alfa aktivity, která je důležitým markérem stavu bdělosti. Spolehlivý elektrický kontakt se skalpem zabezpečil speciální elektrodový gel.




Obr. 3 Volba rozmístění elektrod pro snímání EEG

Doba snímání každého signálu pohybuje mezi 12 a 18 minutami. Na začátku snímání pokusné osoby vždycky řešili matematickou úlohu (součet dvouciferných čísel), pak následovala reakce aktivace (otevření/zavření očí). Zbývající čas osoby leželi v klidu se zavřenými očima. Pro zpracování byly vybrány úseky signálu 21s každý, zaznamenávající přechod od stavu bdělosti do stavu relaxace až somnolence. Délka vybraných úseků je dána požadavky na následné kvantitativní hodnocení navržené metody klasifikace (v případě 21sekundových záznamů máme na výstupu sekvenci 80 vzorků každá).

Je velice těžké vyvolat mikrospánek u pokusných osob v podmínkách školní laboratoře. Měření probíhala v ranní hodiny od 9 do 11 hodin, což je doba, kdy se lidský organismus již probudil. Dá se předpokládat, že většinou mikrospánek je doprovázen zavřením očí. Pro simulaci stavu mikrospánku je proto využita reakce aktivace. Všechny signály pro analýzu mají v svém průběhu zachycené jeden nebo více přechodů ze stavu s otevřenými do stavu se zavřenými očima a to v různých časových okamžicích. Minimální doba, po kterou osoba měla zavřené oči je kolem 2s (model 2sekundového mikrospánku). K dispozici jsou celkem 30 signálů EEG deseti pokusných osob (mladí zdraví lidi), umožňující testování a kvantitativní hodnocení metody klasifikace.

Navíc v Matlabu byl simulován «ideální» elektroencefalografický signál, který je sumou 20 signálů frekvencí 1-20 Hz a měnící se v čase amplitudou (viz Obr.4).



Obr. 4 Simulovaný EEG signál

Signál simuluje situaci přechodu od stavu bdělosti (první 4 sekundy signálu) přes relaxaci (dalších 4s) k somnolenci (doba 8-12s) a návrat přes relaxaci (trvá 4s) do bdělosti (5s). Takový přechod se dá považovat za velmi podobný skutečnosti. Člověk je na začátku ve stavu bdělosti, řeší nějaké úlohy, čte, apod. Pak činnost, kterou vykonává, začíná unavovat, klesá pozornost. Dále následuje stav relaxace, po dobu kterého se člověk nachází v klidu, je uvolněn, oči jsou většinou zavřené (narůstá alfa energie). Pak osoba přechází do stavu somnolence, pro kterou jsou charakteristické rozpadající se až úplně mizející alfa a vysoká delta energie. Obecně můžeme pozorovat kmity energii alfa (alfa mizí, pak zase narůstá atd.). Tento proces se však za nějakou dobu ustali na vysokých hodnotách delta a teta energii. Návrat do stavu relaxace je doprovázen zpětným nárůstem aktivity alfa a mizením energii delta. Při mentaci je přítomnost pomalé delty vždycky patologická, rychlá delta se ale u některých osob vyskytuje. Proto máme na konci simulovaného signálu vysokou delta energii. Spektrogram simulovaného signálu je uveden v kapitole 3.

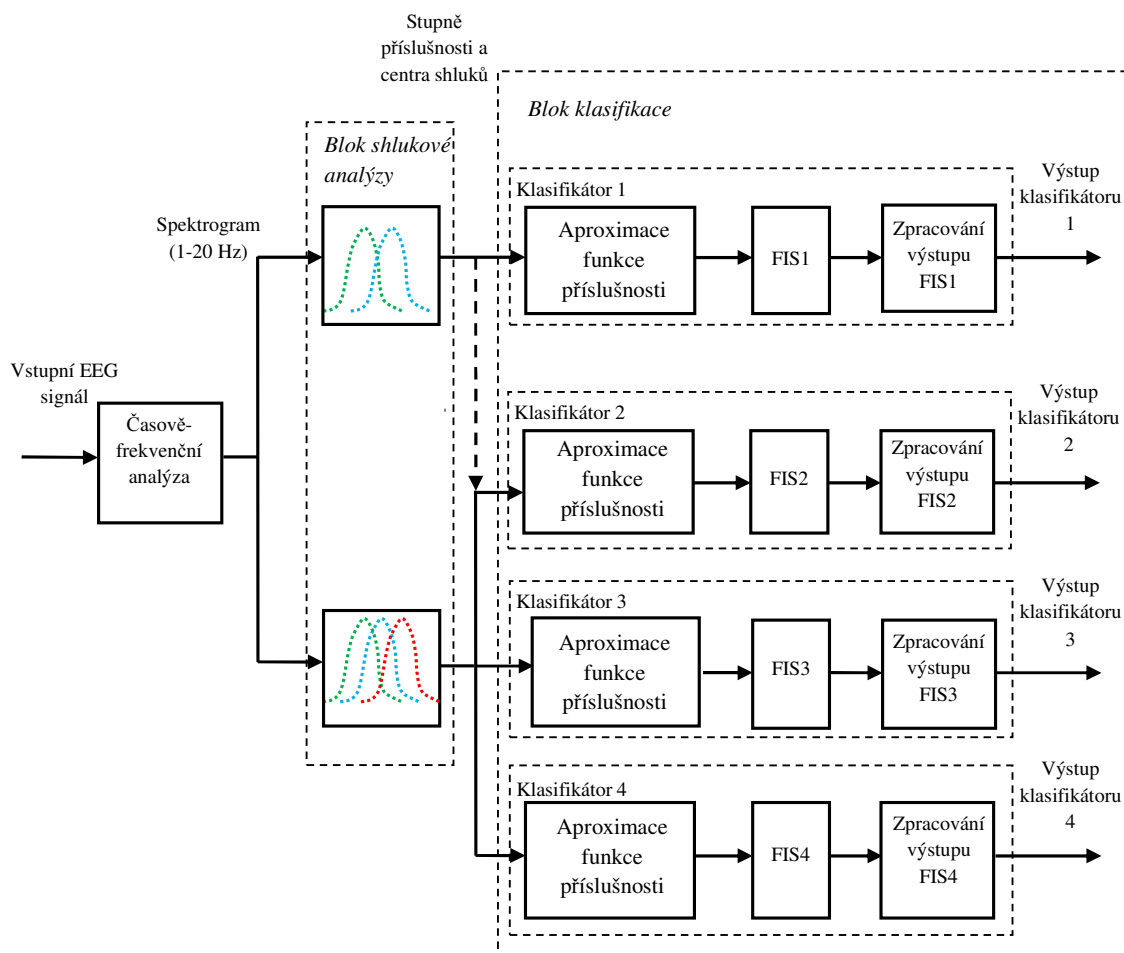
System BIOPAC LAB má ve svém vybavení filtr 0,5 – 30 Hz. K dalšímu zpracování se však používá pouze pásmo 1-20 Hz. Důvod použití pouze těchto kmitočtu je dán tím, že vyšší kmitočty oblasti beta obsahují velké množství nežádoucích složek (svalové artefakty). Navíc beta pásmo poskytuje malé množství informace a je z pohledu další analýzy nevýznamné.

Spektrální složení EEG signálu s ohledem na jejich nestacionární charakter je vhodné zkoumat v časově-frekvenční oblasti aplikaci krátkodobé Fourierové transformaci. Výsledkem zpracování je spektrogram (rozvoj spektra v čase), hodnoty kterého jsou uloženy do matice a použité pro další analýzu. Navržená metoda využívá možnosti fuzzy logiky, která je velmi vhodná při práci s «vágními» daty, což charakteristiky mozkových signálů jsou. Jádrem algoritmu je systém fuzzy usuzování, jehož inferenční mechanismus je založen na

bázi fuzzy pravidel. Protože předem nevíme o distribuci vstupních dat, používáme pro návrh funkci příslušnosti (podle kterých je prováděn převod konkrétních vstupních hodnot na fuzzy hodnoty) premis pravidel fuzzy shlukování. Výstup fuzzy systému není «rovnoměrný», obsahuje «kmitání» výstupních hodnot. Proto třeba použít algoritmus zpracování výsledků fuzzy inferenčního systému, který minimalizuje krátkodobé oscilaci.

Na konci pak máme grafické zobrazení distribuci elementů jednotlivých skupin, prezentujících buď stav mikrosněpku (relaxace/somnolence) anebo aktivní bdělosti (mentace), v souladu s časovým průběhem vstupního signálu a vývojem spektra. Na základě této informaci můžeme vyhodnotit výsledky klasifikaci.

Na obrázku 5 je blokové schéma grafický znázorňující jednotlivé etapy algoritmu.



Obr. 5 Principiální blokové schéma metody

3 Časově-frekvenční analýza EEG signálů

Existuje několik možností zpracování EEG signálů, např. časová analýza průběhů EEG, nebo ve frekvenční, či časově frekvenční oblasti – *Waweletova transformace*, *Matching pursuits transformací* [12]. Vzhledem k tomu, že je vhodné analyzovat EEG ve frekvenční oblasti, ale je potřeba zachytit projevy mikrosprávku v čase, ukázala se pro práci nejvhodnější časově-frekvenční oblast. Jako metoda zpracování byla vybrána jednodušší z hlediska implementace:

Časově-frekvenční analýza EEG signálu pomocí krátkodobé Fourierove transformace (angl. STFT – Short-time Fourier transform).

Časově-frekvenční analýza spočívá ve zjišťování spekter signálů z jeho krátkých segmentů (což je vhodné pro analýzu signálu EEG, který má nestacionární charakter) a formuluje spektrum jako dvojrozměrnou funkci, závislou nejen na frekvenci, ale i na pozici v čase. Ačkoli integrální Fourierova transformace v čisté (teoretické) podobě pracuje se signály nekonečné délky, praktická analýza vždy vychází jen z konečných úseků signálu, vymezených použitým oknem. Pokud tedy okno má vhodnou délku N a je formulováno jako klouzavé na časové ose, může tento přístup být použit pro časově-frekvenční analýzu. Pozorovací interval je určen kompromisem mezi požadavkem na dostatečnou rozlišovací schopnost ve frekvenční oblasti (rozlišitelná diference frekvencí je nepřímo úměrná délce okna) a současnou snahou o velké rozlišení také v čase (minimální rozlišitelný časový rozdíl je délce okna úměrný). Aplikací vztahu:

$$S_i(k) = \frac{1}{N} |F_{w_i}(k)|^2, \quad (1)$$

na takto stanovené úseky signálu vznikají zmíněná krátkodobá výkonová spektra časových úseků délky N . $F_{w_i}(\omega)$ je spektrum jednotlivého úseku signálu $f_{w_i}(n)$, $n = \overline{0, N-1}$, obecně získaný použitím *diskrétní Fourierove transformaci* (angl. DFT, Discrete Fourier Transform):

$$DFT\{f_{w_i}(n)\} = \left\{ F_{w_i}(k) = \sum_{n=0}^{N-1} f_{w_i}(n) W^{kn} \right\}, \quad W = e^{-j\frac{2\pi}{N}} \quad (2)$$

Hodnoty krátkodobého spektra odpovídají celému časovému úseku okna a nelze již rozlišit, zda uvnitř tohoto intervalu došlo k nějakému vývoji – tím je v zásadě určena časová rozlišovací schopnost. Na druhé straně, délka signálového okna určuje také frekvenční rozlišovací schopnost, která je zhruba N -tým dílem z rozsahu $\langle -\omega_{vz/2}, \omega_{vz/2} \rangle$ ($\omega_{vz/2}$ – vzorkovací kmitočet), a je tudíž konstantní v celém rozsahu zpracovávaných frekvencí. [7]

Pro sledování vývoje frekvenčního obsahu v rámci úseku signálu lze použít dělení posloupnosti signálových vzorků a z celkového úseku signálu o M vzorcích, který je pro analýzu k dispozici, tak získat M/N spekter. Přitom dosahujeme frekvenční rozlišovací schopnosti, odpovídající délce okna NT (T -vzorkovací perioda), a tento časový úsek znamená současně také nejmenší rozlišitelný rozdíl v čase. Poněkud lze časovou rozlišovací schopnost zvýšit tím, že dílčí okna mají zvolený přesah, např. o polovinu své délky. Pak dostaneme podél časové osy přiměřeně více spekter a lze lépe sledovat případný rychlý vývoj zejména na straně vysokých kmitočtů. Takový soubor spekter, tzv. *spektrogram*, může být názorně zobrazen jako dvourozměrný obraz, v němž jedna souřadnice odpovídá frekvenci, druhá času a barva nebo úroveň jasu resp. šedi odpovídá amplitudě odpovídajících koeficientů spekter.

Postup základního zpracování signálu EEG – tedy bude následující:

- 1) rozdělení signálu na segmenty o délce N – tyto segmenty se často překrývají pro zlepšení časového rozlišení,
- 2) stanovení výkonového spektra z každého segmentu (1)-(2),
- 3) uložení jednotlivých spekter do matice – spektra tvoří sloupce matice,
- 4) zobrazení matice a její další analýza. [11].

Pro toto zpracování signálu je třeba zvolit dva základní parametry: délku okna, ze kterého je každý bod spektrálního rozkladu počítán, a délku překrytí sousedních oken. Řada experimentů měla za následek kompromisní hodnoty: *délka okna* = 200 vzorků a *překrytí* = 75% délky okna. Vzorkovací kmitočet se rovná $Fvz = 200$ vzorků/s, tedy délka okna reprezentuje 1s záznamu EEG, překrytí – 0,75s. To znamená, že jsou zaručeny rozlišení v čase 0,25s. a ve frekvenční ose 1 Hz, což je postačující pro řešení našeho problému.

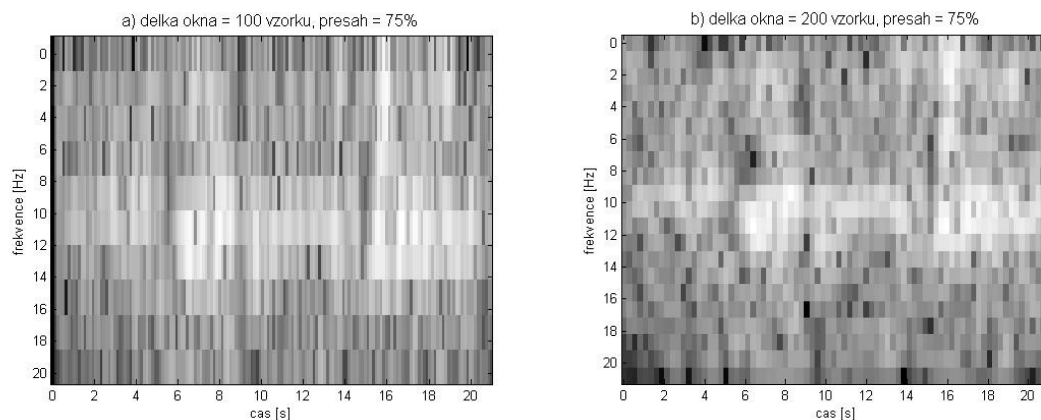
Takto získaná spektrální hustota je posléze rozdělena do jednotlivých spektrálních pásem *teta*, *delta*, *alfa* a *beta*.

Pro analýzu se obecně používá jen část signálu, odpovídající aktivitám delta až beta (kmitočty 0.5-20 Hz). Proto prvním krokem zpracování má být vymezení hodnot energie spektra na daných frekvencích.

Pro zpracování jednotlivých aktivit lze použít digitální pásmové filtry. V práci je pro daný účel využito výhod obrazové vlastnosti časově-frekvenční oblasti, kdy jednotlivá pásma tvoří submatice v obraze. Vymezení vhodného frekvenčního pásma současně odstraňuje problém s artefaktem od střídavého elektrického proudu s frekvencí 50 Hz.


Dalším krokem je výpočet energetického spektra signálu. Přičemž postup programování odpovídá teorii uvedené výše. Takovým způsobem jsou získány *spektrogramy* reprezentující vývoj spektra v čase. Použití aktivačních metod se v záznamu projevuje nárůstem/poklesem energie na určitých spektrálních složkách.

Na následujícím obrázku je ukázka vlivu vstupních parametrů na rozlišení získaných spektrogramů: při výběru menší délky okna dostáváme lepší rozlišení v čase ale zároveň horší ve frekvenční ose, což v případě analýzy spektra je nepřijatelné (viz Obr.6).



Obr. 6 Spektrogramy EEG signálu

Na obrázku 7 je spektrogram simulovaného EEG signálu. Energie alfa (9-13 Hz) a delta (0.5-4 Hz) pásem na určitých časových intervalech je mnohem vyšší energií ostatních pásem.



Obr. 7 Spektrogram simulovaného signálu

4 Klasifikace na základě fuzzy usuzování

*Pokud matematika popisuje realitu, není přesná. A pokud je přesná, nepopisuje realitu.
(Albert Einstein)*

4.1 Teorie fuzzy množin

4.1.1 Fuzzy množiny

Teorie fuzzy množin byla představená v r. 1960 prof. Lotfi Zadehem, jako prostředek pro modelování neurčitostí v přirozeném jazyku. To je logika představující základ myšlení, které je skoro přibližné jako přesné. Důležitost fuzzy logiky vyplývá z faktu, že většina způsobů lidského myšlení a především myšlení zdravého rozumu je přirozeně přibližná.

Slovo **fuzzy** znamená *neostrý, matný, mlhavý, neurčitý, nejasný, vágní*. Odpovídá tomu i to, čím se fuzzy teorie zabývá: snaží se pokrýt realitu v její nepřesnosti a neurčitosti. Často se fuzzy logika nesprávně spojuje s pravděpodobností. U pravděpodobnosti zjišťujeme, jestli jev může nastat a s jakou pravděpodobností, kdežto u fuzzy logiky víme, že jev existuje a zjišťujeme jeho stupeň příslušnosti v určité množině (pravdivost výroku).

Uplatnění fuzzy modelování je účelné ve všech případech, kdy se řeší problém spojený s neurčitostí, s nepřesností, případně je problém silně ovlivněn subjektivním přístupem řešitele. Musíme tedy pracovat s neurčitými daty a používání přesných popisů by nás vedlo k idealizování skutečností reálného světa a tedy k odklonu od reality.

Striktní popis vede k popisu skutečnosti pouze pomocí dvouprvkové množiny $\{0,1\}$. Pokud problém nelze jednoznačně určit, rozkládá se na menší podproblémy, ale za cenu místa a opět lze použít jen dvouprvkovou množinu. V případech, kdy je již nemožné nebo neúnosné takto problém rozdělit, dopouštíme se jisté chyby a tím je dán odklon od reality.

S tím souvisí i princip inkompability, který vyslovil v roce 1973 L. A. Zadech: „S rostoucí složitostí systému klesá naše schopnost formulovat přesné a významné vlastnosti o jeho chování, až je dosažena hranice, za kterou je přesnost a relevantnost prakticky vzájemně se vylučující jevy.“

S vágními pojmy se setkáváme v běžném životě. V přirozeném jazyce, kterým se lidé dorozumívají, je vágních pojmů spousta: velmi starý člověk, nízká rychlost apod. [20], [25]

4.1.1.1 Základní pojmy

Univerzální množina (též **univerzum**) je množina všech prvků, které souvisejí s daným problémem. Univerzální množina bývá označována, jako U . Univerzální množina je tedy nadmnožinou všech množin, které v rámci daného problému uvažujeme.

Fuzzy množinou A se rozumí dvojice (U, μ_A) , kde U je univerzum a $\mu_A : U \rightarrow [0, 1]$ je funkce popisující příslušnost prvků z U do fuzzy množiny A . Tuto příslušnost označíme $\mu_A(x)$.

Fuzzy množina je zobecněním «klasické» množiny, neboť pro příslušnost u «klasické» množiny A platí $\mu_A : U \rightarrow \{0, 1\}$ a $x \in A \Leftrightarrow \mu_A(x)=1$ a $x \notin A \Leftrightarrow \mu_A(x)=0$.

Čím vyšší stupeň příslušnosti, tím více element universální množiny odpovídá vlastnostem fuzzy množiny.

Funkcí příslušnosti je funkce, pomocí které můžeme pro libovolný element univerza vypočítat stupeň příslušnosti fuzzy množině. Funkce μ_A je funkce příslušnosti fuzzy množiny A. Každému prvku $x \in X$ přiřazuje prvek $\mu_A(x) \in \langle 0; 1 \rangle$, který se nazývá stupněm příslušnosti prvku x do fuzzy množiny A.

Je-li $\mu_A(x) = 0$, pak x nepatří do fuzzy množiny A.

Je-li $\mu_A(x) = 1$, pak x patří do fuzzy množiny A.

Je-li $0 < \mu_A(x) < 1$, pak x částečně patří do fuzzy množiny A.

Formální zápis fuzzy množiny je pak:

$$A = (\mu_A(x_i)/x_i), \text{ pro } \forall x_i. \quad (3)$$

Příklad zápisu fuzzy množiny:

Nechť máme $U = \{x_1, x_2, x_3, x_4, x_5\}$, A – fuzzy množina, pro kterou platí:

$$\mu_A(x_1) = 0,3; \mu_A(x_2) = 0; \mu_A(x_3) = 1; \mu_A(x_4) = 0,5; \mu_A(x_5) = 0,9.$$

Pak A můžeme zapsat jako:

$$A = \{0,3/x_1; 0/x_2; 1/x_3; 0,5/x_4; 0,9/x_5\} \text{ nebo}$$

$$A = \{0,3/x_1 + 0/x_2 + 1/x_3 + 0,5/x_4 + 0,9/x_5\} \text{ nebo}$$

$$A = \begin{array}{c|c|c|c|c} x_1 & x_2 & x_3 & x_4 & x_5 \\ \hline 0,3 & 0 & 1 & 0,5 & 0,9 \end{array}$$

Lingvistická proměnná je taková proměnná, jejíž hodnota může být vyjádřena slovem nebo slovním spojením přirozeného jazyku.

Term množina je množství všech možných hodnot lingvistické proměnné.

Term je libovolný element term množiny, udává se fuzzy množinou pomocí funkce příslušnosti. Nechť proměnná «hodnota energie spektra» může nabývat hodnot «nízká», «střední», «vysoká». Pak lingvistickou proměnnou je «hodnota energetického spektra», termy – «nízká», «střední» a «vysoká», který představují term množinu. [4], [21]

4.1.1.2 Základní vlastnosti fuzzy množin

Výška fuzzy množiny je nejmenší horní hranice fuzzy množiny A.

Normální se nazývá fuzzy množina s výškou 1.

α – řezem fuzzy množiny A se nazývá podmnožina U, jejíž elementy mají stupně příslušnosti, větší nebo rovnající α .

Fuzzifikace - převod číselné hodnoty vstupní proměnné na pravdivostní hodnoty vstupních proměnných (termů).

Defuzzifikace je proces, v němž nějaké fuzzy množině přiřazujeme ostrou hodnotu, která ji v jistém smyslu nejlépe reprezentuje.

Nejčastěji používané metody defuzzifikace (viz Obr.8):

1. **Metoda těžiště** (angl. COA, center of area).

$$\text{Spojitý případ: } z_0 = \int_{\Omega} z C(z) dz / \int_{\Omega} C(z) dz; \quad (4)$$

Diskrétní případ:
$$z_0 = \sum_{i=1}^n \alpha_i z_i / \sum_{i=1}^n \alpha_i \quad (5)$$

2. *Metoda prvního maxima* (angl.FOM, first-of-maxima).


Určitá hodnota výstupní proměnné je minimální hodnota, při které se dosahuje maximum výsledné fuzzy množiny:

$$z_0 = \min\{z | C(z) = \max_u C(u)\} \quad (6)$$

3. *Metoda průměrného maxima* (angl.MOM, mean-of-maxima).

$$z_0 = \int_G z dz / \int_G dz \quad (7)$$

kde G – podmnožina elementů, maximalizujících C . [20]



Obr. 8 Metody defuzzifikace: a) prvního maxima, b) průměrného maxima, c) těžiště

4.1.1.3 Základní operace s fuzzy množinami

Základní operace nad fuzzy množinami (A, B jsou fuzzy množiny):

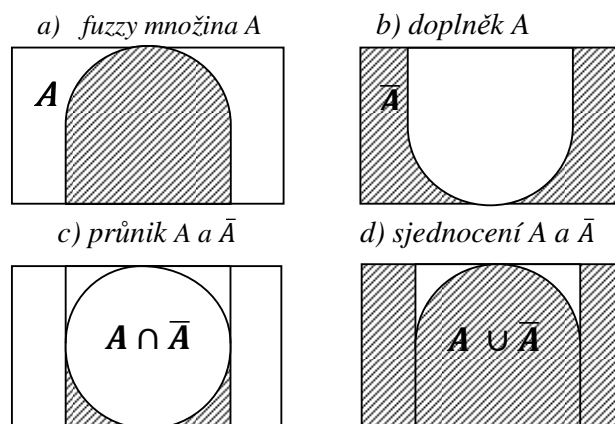
sjednocení A a B: $A \cup B: \mu_{A \cup B} = \max\{\mu_A(x); \mu_B(x)\}$, pro $\forall x \in X$, (8)

průnik A a B: $A \cap B: \mu_{A \cap B} = \min\{\mu_A(x); \mu_B(x)\}$ pro $\forall x \in X$, (9)

doplňek A: $\bar{A}: \mu_{\bar{A}} = 1 - \mu_A(x)$ pro $\forall x \in X$, (10)

implikace: $\mu_{A \Rightarrow B}(u) = \max(1 - \mu_A(u), \mu_B(u))$. (11)

neplatí zákon protikladu a vyloučení třetího ($\bar{\bar{A}} \cup A \neq X, \bar{\bar{A}} \cap A \neq \emptyset$) (viz Obr.9) [2].



Obr. 9 Základní operace s fuzzy množinami

4.1.1.4 Funkce příslušnosti

Praktické použití teorie fuzzy množin předpokládá existence funkcí příslušnosti, kterými popsané lingvistické termy. Úloha návrhu funkcí příslušnosti kladená následovně. Máme 2 množiny: množinu termů $L=\{l_1, l_2, \dots, l_m\}$ a univerzum $U= \{u_1, u_2, \dots, u_n\}$. Fuzzy množina l^* pro určení lingvistického termu l_j na univerzu U vypadá takto:

$$l_j^* = \left(\frac{\mu_{l_j}(u_1)}{u_1}, \frac{\mu_{l_j}(u_2)}{u_2}, \dots, \frac{\mu_{l_j}(u_n)}{u_n} \right), \quad j = \overline{1, m}. \quad (12)$$

Je nutné najít stupně příslušnosti elementů U elementům množiny L , tj. najít $\mu_{l_j}(u_i)$ pro všechny $j = \overline{1, m}$ a $i = \overline{1, n}$. [20]

Existuje několik možností návrhu funkcí příslušnosti. První vychází ze statistického zpracování úsudků skupiny expertů. Druhý je založen na porovnání po dvou, provedeném jedním expertem. Další možností je návrh funkcí příslušnosti na základě výsledků nějakého aplikovaného algoritmu zpracování dat, jakým může být např. shluková analýza. Podrobnější popis poslední metody bude uveden dále.

Je velmi vhodné definovat funkci příslušnosti v parametrické podobě. V tomto případě úloha návrhu funkcí příslušnosti omezuje se na určení jejich parametrů. Nejčastěji používané jsou trojúhelníková, lichoběžníková, Gaussova a sigmoidní funkce [6]. Definice těchto funkcí v parametrické podobě a ukázky průběhu jsou uvedeny na další stránce.

Trojúhelníková funkce:

$$\mu(u) = \begin{cases} 0, & u \leq a \text{ nebo } u \geq c \\ (u - a)/(b - a), & a < u \leq b \\ (c - u)/(c - b), & b < u < c \end{cases} \quad (13)$$


Lichoběžníková funkce:

$$\mu(u) = \begin{cases} 0, & u \leq a \\ \frac{u - a}{b - a}, & a \leq u \leq b \\ 1, & b \leq u \leq c \\ \frac{d - u}{d - c}, & c \leq u \leq d \\ 0, & u \geq d \end{cases} \quad (14)$$

Sigmoidní funkce: $\mu(u) = 1/(1 + \exp(-a(u - c)))$ (15)

Gaussova funkce: $\mu(u) = \exp(-(u - b)^2/2c^2)$. (16)

Ukázka implementaci těchto funkcí v Matlabu je na obrázku 10.



Obr. 10 Populární funkce příslušnosti

4.1.2 Fuzzy inference

4.1.2.1 Báze fuzzy pravidel

Klasické modely systémů jsou postaveny na základě vztahu mezi vstupem a výstupem systému. Fuzzy modely toto klasické pojetí transformují do skupiny pravidel.

Bázi pravidel je možno vytvořit buď na základě empirických znalostí anebo na základě obecně platných metapravidel.

Lingvisticky popsaná báze pravidel je vyjádřena jako skupina pravidel:

IF (antecedent pravidla) – **THEN** (konsekvent pravidla)

s neurčitými tvrzeními.

Například lingvistický model popisu závislosti spektrálních hodnot na psychofyziologickém stavu člověka:

IF HODNOTA SPEKTRA ALFA malá **THEN** STAV je MENTACE ,

IF HODNOTA SPEKTRA ALFA střední **THEN** STAV je MENTACE,

IF HODNOTA SPEKTRA ALFA velká **THEN** STAV je RELAXACE.

4.1.2.2 Kompoziční pravidlo usuzování

Je-li známá fuzzy relace R mezi x a y , pak při neurčité hodnotě vstupní proměnné $x=A$ fuzzy hodnota výstupní proměnné y bude:

$$y = A \circ R, \quad (17)$$

kde « \circ » - kompozice max-min:

Kompozice max-min fuzzy relací A a B , definovaných na $X \times Z$ a $Z \times Y$, se nazývá fuzzy relace $G=A \circ B$ na $X \times Y$ s funkcí příslušnosti:

$$\mu_G(x, y) = \sup_{z \in Z} \min(\mu_A(x, z), \mu_B(z, y)), \quad (x, y) \in X \times Y, (x, z) \in X \times Z, (z, y) \in Z \times Y.$$

Tato operace se provádí jako obecný součin matic, v němž součin po částech nahrazen operací minima, sčítání – operací maxima.

Kompoziční pravidlo je základem různých algoritmů fuzzy usuzování. [20]

4.1.2.3 Mamdaniho inference

Nechť znalostní báze se skládá pro jednoduchost jen ze dvou pravidel:

P1: je-li x je A_1 a y je B_1 , pak z je C_1 ,

P2: je-li x je A_2 a y je B_2 , pak z je C_2 ,

kde x a y jsou názvy vstupních proměnných, z je název proměnné výstupní, $A_1, A_2, B_1, B_2, C_1, C_2$ – dané funkce příslušnosti, přičemž určitou hodnotu z_0 musíme najít na základě známé informací a určitých hodnot x_0 a y_0 .

Matematicky tento algoritmus můžeme pospat následovně.

1. Neurčitost: hledáme stupně pravdivosti pro premisy každého pravidla: $A_1(x_0), A_2(x_0), B_1(y_0), B_2(y_0)$.
2. Neurčitý výstup: hledáme úrovní «odříznuti» pro premisy každého pravidla (použitím operaci MINIMUM):

$$\alpha_1 = A_1(x_0) \wedge B_1(y_0), \quad (18)$$

$$\alpha_2 = A_2(x_0) \wedge B_2(y_0), \quad (19)$$

kde « \wedge » slouží jako označení pro operaci logického minima (min).

Pak hledáme «oříznuté» funkce příslušnosti

$$C'_1(z) = (\alpha_1 \wedge C_1(z)), \quad (20)$$


$$C'_2(z) = (\alpha_2 \wedge C_2(z)). \quad (21)$$

3. Kompozice: pomocí operace MAXIMUM (max, pak « \vee ») sjednotíme nalezené «oříznuté» funkce, tím dostaneme výslednou fuzzy podmnožinu pro proměnnou výstupu s funkcí příslušnosti

$$\mu_{\Sigma}(z) = C(z) = C'_1(z) \vee C'_2(z) = (\alpha_1 \wedge C_1(z)) \vee (\alpha_2 \wedge C_2(z)). \quad (22)$$

4. Defazifikace (nalezení z_0) pomocí například centroidní metodou. [20]

Grafická ilustrace Mamdaniho inferenci je na obrázku 11 na další stránce.



Obr. 11 Ilustrace Mamdaniho inference

4.1.2.4 Usuzování pro klasifikace

Úloha klasifikaci spočívá v zařazení objektu, popsaného vektorem příznaků $X=(x_1, x_2, \dots, x_n)$, do jedné z předem definovaných tříd $\{d_1, d_2, \dots, d_m\}$. Klasifikace odpovídá zobrazení typu:

$$X = (x_1, x_2, \dots, x_n) \rightarrow y \in \{d_1, d_2, \dots, d_m\}. \quad (23)$$

Pro klasifikaci je nutná fuzzy báze pravidel typu:

- IF $x_1 = a_{1,j1}$ AND $x_2 = a_{2,j1}$ AND ... AND $x_n = a_{n,j1}$
 OR $x_1 = a_{1,j2}$ AND $x_2 = a_{2,j2}$ AND ... AND $x_n = a_{n,j2}$
 ...,
 OR $x_1 = a_{1,jkj}$ AND $x_2 = a_{2,jkj}$ AND ... AND $x_n = a_{n,jkj}$
 THEN $y = d_j, j = \overline{1, m}$,

kde $a_{j, jp}$ – fuzzy term, pomocí kterého je hodnocená proměnná x_i v pravidle číslo jp , $p = \overline{1, k_j}$; k_j – počet pravidel, definujících třídu d_j .

Stupně příslušnosti objektu $X^*=(x_1^*, x_2^*, \dots, x_n^*)$ třídám d_j spočítáme takto:

$$\mu_{d_j}(X^*) = \max_{p=1..k_j} \min_{i=1..n}(\mu_{jp}(x_i^*)), j=\overline{1, m}, \quad (24)$$

kde $\mu_{jp}(x_i^*)$ – funkce příslušnosti vstupu x_i fuzzy termu $a_{i, jp}$. [19]

Jako řešení se vybírá třída s maximálním stupněm příslušnosti.

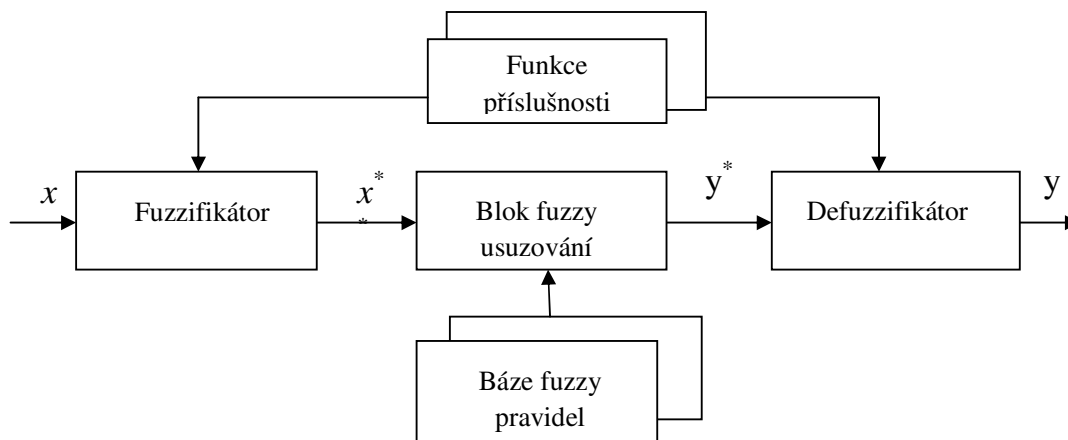
4.2 Fuzzy systémy

4.2.1 Struktura fuzzy systémů

Struktura systému fuzzy usuzování (angl. FIS, Fuzzy Inference System) obsahuje moduly:

- *fuzzifikátor* (převod vstupního vektoru faktorů (X) do vektoru fuzzy množin (X^*), nutných pro fuzzy usuzování),
- *báze fuzzy pravidel* (obsahuje informaci o závislosti $Y=f(X)$ v podobě lingvistických pravidel <IF - THEN>),
- *funkci příslušnosti* (používají se pro definici lingvistických termů ve formě fuzzy množin),
- *blok fuzzy logického usuzování* (určení na základě bázi pravidel hodnot výstupní proměnné v podobě fuzzy množiny Y^* , odpovídající neurčitým hodnotám vstupních proměnných X^*),
- *defuzzifikátor* (převod výstupní fuzzy množiny Y^* do ostré hodnoty Y). [21]

Na obrázku 12 je znázorněná schéma FIS, podle které budeme postupovat při návrhu klasifikátorů, jejichž jádro je tvořené fuzzy systémy usuzování.



Obr. 12 Schéma systému fuzzy usuzování

4.2.2 Fuzzy shlukování

V běžném životě i technické praxi se často setkáváme s problémem, že máme k dispozici data, která mají popisovat nějaký děj, strukturu, uspořádání nebo jinou část reálného světa a potřebujeme vhodným způsobem tyto data vyhodnotit. Navíc, data mohou být nepřesná, nebo vyjádřena vágními pojmy.

Popis reálného světa se k člověku dostává zprostředkovaně přes jeho smysly nebo přes hodnoty z měřicích přístrojů, proto může být tento popis nepřesný, neboť smysly jsou nedokonalé a měřicí přístroje mají konečnou přesnost měření. Některé objekty dokonce nelze z jejich podstaty přesně změřit a musíme tedy přejít k vágnějšímu popisu. Např. je-li objektem člověk a chceme popsat jeho charakteristické vlastnosti, musíme k popisu použít vágnějších pojmů používaných v přirozeném jazyce. Pokud již máme objekt popsán více či méně nepřesnými (vágními) pojmy, pak naším úkolem je z takto získaných dat odvodit požadovanou informaci.


Jednou z metod, jak získat požadovanou informaci, je nad danými daty (objekty) provést *shlukování*. Shlukování má za úkol *roztřídit množinu objektů do menších celků podle vhodných charakteristických rysů*. To je proces seskupování dat do tříd (shluků) s velkou podobností v jednom shluku a s velkou nepodobností mezi shluky (k ostatním shlukům).

Vhodné metody číselného vyjádření vlastností, jimiž jsou zkoumané objekty vyznačovány, metody kvantitativního vyjádření podobností takto zakódovaných objektů a konečně metody seskupování podobných objektů do “shluků” zahrnujeme pod název *shluková analýza* nebo zkráceně *shlukování*.

Významnou etapou v rozvoji shlukové analýzy je uplatnění fuzzy množin ve shlukovacím procesu. Tyto metody se nazývají *fuzzy shlukovací metody* nebo zkráceně *fuzzy shlukování*. Nejznámější a nejpoužívanější je fuzzy shlukování definované J.C. Bezdekem. [24], [26]

Klasické metody shlukování dělí výchozí množinu objektů X na několik disjunktních podmnožin. Přičemž libovolný objekt z X patří jen do jednoho shluku ze všech možných. Fuzzy metody shlukování umožňují objektu současně patřit do několika shluků, anebo do všech shluků, ale s různým stupněm příslušnosti. Fuzzy shlukování bývá ve většině případů «přirozenější» než klasické, např. pro objekty, které se nacházejí na hranici shluků. Tuto zvláštnost fuzzy shlukování se dá ukázat na «motýlku» - velice známém v teorii shlukování příkladu. [10]

«Motýlek» se skládá z 15 objektů (viz Obr.13, *a*). Při aplikaci algoritmu klasického shlukování (viz Obr.13, *b* a *c*) dostáváme 2 shluky ze sedmi a osmi objektů. Na obrázku jsou objekty prvního shluku označeny čtverci, druhého – kružnicemi. Symetrický «motýlek» se při klasickém shlukování dělí na dva nesymetrické shluky. Při fuzzy shlukování (viz Obr.13, *d*) problematický osmý objekt, ležící ve středu «motýlku», patří současně do dvou symetrických shluků se stejným stupněm příslušnosti. Na obrázku je velikost markerů úměrná stupňům příslušnosti objektu shluku. Červenou barvou jsou označena centra shluků.



Obr. 13 Porovnání klasického a fuzzy shlukování

Metody shlukování se dá klasifikovat ještě podle toho, jestli je předem známý počet shluků nebo ne. V posledním případě se počet shluků určuje na základě distribuce vstupních dat v průběhu provádění algoritmu.

Populární shlukovací metodou je shlukování pomocí K-středu.

Fuzzy shlukování s použitím algoritmu K-středů.

Princip této metody je založen na nalezení nejbližšího prototypu pro každý vstupní vzorek a zahrnuje náročné výpočty vzdáleností.

Shlukování byl obecně studovaný problém v různých sférách domén aplikací včetně dolování dat. Různé algoritmy byly popsány v literatuře. Shlukovací algoritmy rozdělují datový soubor do množiny k shluků. Každý shluk je představovaný buď středem vážnosti shluku (jako v k -středu) nebo jedním z objektů shluku umístěného blízko jeho středu. Shlukovací algoritmus pomocí k -středu ukázal, že je efektivním pro mnoho praktických aplikací.

Fuzzy shluky můžeme popsat následující matici fuzzy rozkladu:

$F=[\mu_{ki}]$, $\mu_{ki} \in [0, 1]$, $k = \overline{1, M}$, $i = \overline{1, c}$, ve které k -ý řádek obsahuje stupně příslušnosti objektu $X_k = (x_{k1}, x_{k2}, \dots, x_{kn})$ shlukům A_1, A_2, \dots, A_c . Matice fuzzy rozkladu se liší od klasické matice tím, že při fuzzy třídění stupeň příslušnosti objektu do shluku nabývá hodnot z množiny $\{0, 1\}$. Matice rozkladu by měla splňovat podmínky:

$$\sum_{i=1, c} \mu_{ki} = 1, \quad k = \overline{1, M} \quad (25)$$

$$0 < \sum_{k=1, M} \mu_{ki} < M, \quad i = \overline{1, c} . \quad (26)$$

Fuzzy třídění umožňuje řešit problém objektů, ležících na hranice mezi shluky – takovým objektům bude přiřazena stejná stupeň příslušnosti, např. 0,5.

Pro odhad kvality fuzzy shlukování se používá kritérium rozptylu:

$$\sum_{i=\overline{1,c}} \sum_{k=\overline{1,M}} (\mu_{ki})^m \|V_i - X_k\|^2, \quad (27)$$

kde

$$V_i = \sum_{k=\overline{1,M}} (\mu_{ki})^m X_k / \sum_{k=\overline{1,M}} (\mu_{ki})^m \quad (28)$$

- jsou centra fuzzy shluků, $m \in (1, \infty)$ je exponenciální váha.

Nejvíce známou a používanou metodou minimizaci kritéria je algoritmus fuzzy k-středů (angl. FCM, fuzzy c-means). Tento algoritmus vyhledává lokální optimum.

Algoritmus fuzzy k-středů:

1. Nastavení parametrů algoritmu: c – počet shluků, m – exponenciální váha, ε – parametr ukončení algoritmu.
2. Náhodná generace matice fuzzy rozkladu F , splňující podmínky (25)-(26).
3. Vypočet center shluků podle vztahu:

$$V_i = \sum_{k=\overline{1,M}} (\mu_{ki})^m X_k / \sum_{k=\overline{1,M}} (\mu_{ki})^m, i = \overline{1,c}. \quad (29)$$

4. Vypočet vzdálenosti mezi objekty $z X$ a centry shluků:

$$D_{ki} = \sqrt{\|X_k - V_i\|^2}, \quad k = \overline{1,M}, i = \overline{1,c}. \quad (30)$$

5. Přepočet elementů matice F pro všechna $k = \overline{1,M}, i = \overline{1,c}$:

Je-li $D_{ki} > 0$ pak :

$$\mu_{ki} = 1 / \left(D_{ik}^2 \sum_{j=\overline{1,c}} \frac{1}{D_{jk}^2} \right)^{1/(m-1)} \quad (31)$$

$$\text{Je-li } D_{ki} = 0 \text{ pak } \mu_{ki} = \begin{cases} 1, & j = i \\ 0, & j \neq i \end{cases}, j = \overline{1,c}. \quad (32)$$

6. Ověření podmínky: $\|F - F^*\|^2 < \varepsilon$, kde F^* je matice předchozí iterace algoritmu. Když je podmínka splněná, přechod do dalšího kroku, jinak – krok 3.

7. Konec.

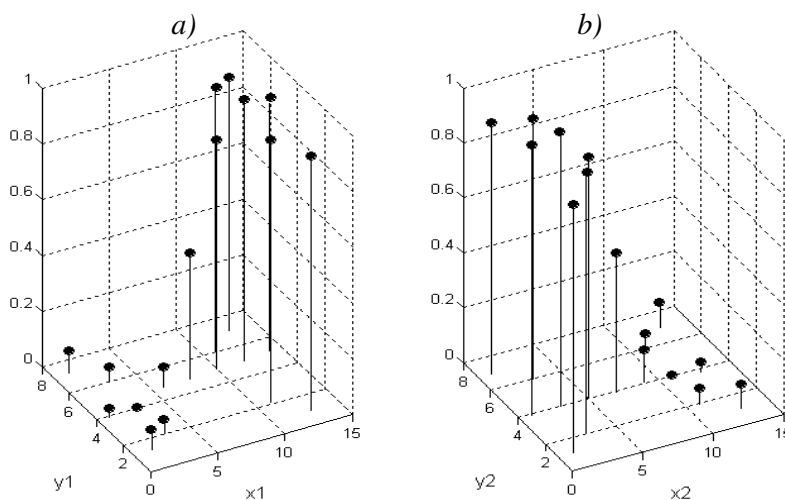
Tedy k -střed je iterativní technika, která začíná s počátečními shluky (např. náhodně generovanými), a během následujících iterací vylepšuje kvalitu těchto shluků. Tento proces je zastaven, když je dosaženo ukončovacího kritéria, např. členství ve shluku je již 1 anebo je splněná podmínka v kroku 6. [19], [8]

V algoritmu k -středů je nejdůležitějším parametrem počet shluků c . Správná definice počtu shluků je bez nějaké apriorní informace o struktuře dat pro reálné úlohy těžké

realizovatelná. Existují různé metody výběrů počtu shluků. Jedna z nich je metoda založená na využití výsledků shlukové analýzy, která bude probána v dalším oddílu.

Exponenciální váha (m) v algoritmu udává stupeň neurčitosti získávaných shluků. Čím více váha, tím fuzzy shlukování rozmazanější. Při $m \rightarrow \infty$ elementy matice F mívají k $1/c$, tedy všechny elementy budou patřit do všech shluků se stejnou mírou. Exponenciální váha umožňuje při tvorbě souřadnic center shluků zvětšit vliv objektů s velkými stupněmi příslušnosti a zmenšit vliv objektů s malými. Dnes neexistuje teoretický opodstatněných pravidel výběrů hodnoty exponenciální váhy. Obecně se pracuje s hodnotou $m=2$.

Na obrázku 14 je ilustrována aplikace shlukové analýzy na případ «motýlku» z předchozí podkapitoly.



Obr. 14 Příklad fuzzy shluků: a) fuzzy shluk 1, b) fuzzy shluk 2

4.2.3 Syntéza fuzzy pravidel na základě výsledků fuzzy shlukování

Na základě výsledků fuzzy klasterizace je možné definovat pravidla pro fuzzy systém. Necht' objekty shlukování mají dva příznaky ($n=2$). Tedy výsledky shlukování si můžeme představit v podobě třírozměrné plochy. Pro návrh takové plochy třeba odložit na x-ové ose y-ové osách hodnoty příznaků, na ose z - stupeň příslušnosti objektu fuzzy shluku. Počet ploch se rovná počtu shluků (n). Pak každému shluku můžeme přiřadit jedno fuzzy pravidlo. [19]

Podle výsledků fuzzy shlukování se dá syntézovat fuzzy pravidla různých báze pravidel: Mamdani, Sugeno aj.

Funkce příslušnosti termů v pravidle dostáváme projekci stupně příslušnosti příslušného shluku (řádků matice F) na osy vstupních proměnných. Pak získané množiny stupni příslušnosti se aproximují vhodnými parametrickými funkcemi příslušnosti (viz kapitola 4.3.2, 4.3.3).

4.3 Návrh klasifikátorů na základě fuzzy inferenčního systému

4.3.1 Výběr příznaků pro usuzování

Klasifikovat mikrosnání znamená najít v signálu EEG úseky, mající charakteristické pro daný stav vlastnosti. Metoda navržená v této práci se opírá na časově-frekvenční analýzu signálů EEG, proto budeme hledat řešení na základě změn energetického spektra signálu.

Teoretické znalosti závislosti energie spektra v určitých pásmech na psychofyziologickém stavu člověka jsou shrnuty v tabulce [13], [22], [23]. Mentace je stav bdělosti: člověk má otevřená oči, řeší nějakou matematickou úlohu, čte apod. Relaxace je klidový stav se zavřenými očima, kdy člověk uvolněn. Somnolence (usínání) se dá popsat jako stav s klesající pozorností, se sníženou úrovní hodnocení informací apod.

Při natáčení EEG signálu měřené osoby prováděli různé činnosti, důsledkem čeho je přítomnost v signálech charakteristických «značek» užitečných při klasifikaci.

	Mentace	Relaxace	Somnolence
<i>Delta</i> (1-2 Hz)	V	N	V
<i>Delta</i> (3-4 Hz)	N	N	V
<i>Teta</i> (5-8 Hz)	N	N	V
<i>Alfa</i> (9-13 Hz)	N a S	V	N
<i>Beta</i> (14-20Hz)	V	N	N

Pozn.: V-velká, N-nízká, S-střední energie v odpovídajícím pásmu

Tab. 1 Závislost hodnoty energie spektrálních pásem na stavu člověka

Je vidět, že hodnota spektra alfa pásma je dobrým markérem stavu Relaxace.

Dále je zřejmé, že na základě změn jenom v pásmu alfa není možné rozlišit stavy Mentace a Somnolence. Pro tento účel je vhodné použít buď analýzu beta, teta pásma anebo úzkopásmovou analýzu delta pásma.

Protože pracujeme s «vágními» daty použijeme pro usuzování aparát fuzzy logiky.

Postupovat budeme podle schématu popsaného v kapitole 2.

Úlohu detekovat stav Relaxace řeší první klasifikátor, využívající výsledky fuzzy shlukování hodnot energie spektra v pásmu alfa na 2 shluky. Navržený FIS umožňuje rozlišit 2 stavy: Relaxace a Není relaxace. A to s toho důvodu, že zbývající stavy (Mentace a Somnolence) mohou mít stejný úroveň energie alfa.

První klasifikátor ale může být vylepšen tím, že místo shlukování na 2 shluky budeme uvažovat shlukování na 3. Protože v daném případě budeme mít rozdělení energie alfa na 3 skupiny (velká, nízká a vysoká energie) máme možnost zavedením vhodných pravidel v FIS předejít přiřazení zbytečného počtu vstupních vzorků k «skupině» Relaxace (střední hodnoty alfa patří do skupiny Mentace – viz Tabulka 1).

Jak již bylo řečeno, mentace a somnolence nemůžou být detekovány jen na základě analýzy alfa-pásma (viz Tabulka 1), ale potřebují vyhodnocení změn buď v pásmu teta anebo


delta. Přičemž bráno v úvahu by mělo být jen pásmo delta vyšších frekvencí, poněvadž zejména tyto frekvence mohou obsahovat užitečnou informaci. Tato myšlenka je realizována ve třetím klasifikátoru, který využívá rozdělení alfa pásma na 3 a delta – na 2 množiny. Klasifikátor by měl na výstupu udávat informaci o přítomnosti v signálu EEG úseků všech třech možných stavů: mentace, relaxace a somnolence. Teoreticky by měl tento klasifikátor co nejdříve odpovídat požadavkům na klasifikaci mikrosnání. Čtvrtý klasifikátor využívá pro usuzování celý kmitočtový rozsah vstupních dat (tedy pásma delta až beta), také rozlišující tři stavy. Výstup třetího klasifikátoru by se ale neměl moc lišit od čtvrtého, neboť základní charakteristické změny při mikrosnání jsou zejména v pásmech alfa a delta.

4.3.2 Aproximace funkce příslušnosti

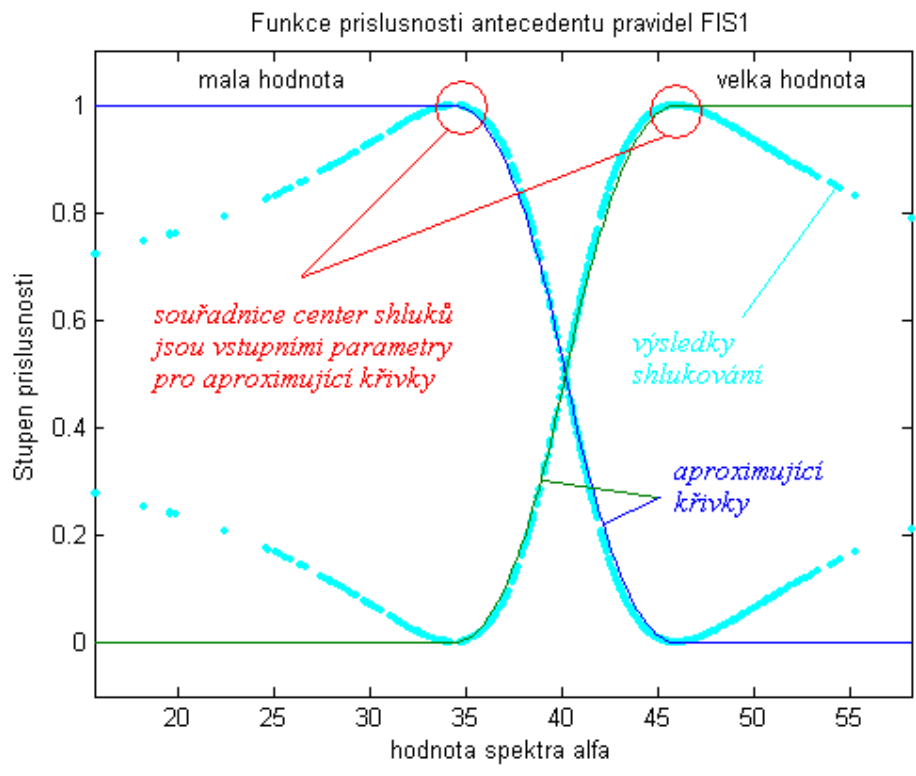
Hlavní otázkou při návrhu FIS je jakou použít *funkci příslušnosti* pro převod určité vstupní hodnoty do neurčité (fuzzy) podoby (fuzzifikace). Odpovědět na tuto otázku můžeme v případě, když máme přehled o typu rozložení daných, «prahových» hodnotách, které určí, do jakého okamžiku hodnota může být považována za malou/velkou. V případě signálu EEG obecně takové hodnoty k dispozici nemáme (práh pro signál jedné osoby může, ale nemusí se rovnat prahové hodnotě jiné osoby). V tomto rozhodování může pomoci fuzzy logika, a sice neurčité shlukování.

Vstupem pro shlukování jsou hodnoty jednotlivých úseků spektrogramu (delta až beta), uložené do matic. Shlukování se provádí pomocí c-means algoritmu. Pro různé klasifikátory se používá shlukování na 2 nebo 3 shluky. Exponenciální váha se rovná 2, prahová hodnota zlepšení výsledků, při které se algoritmus zastaví je 10^{-5} .

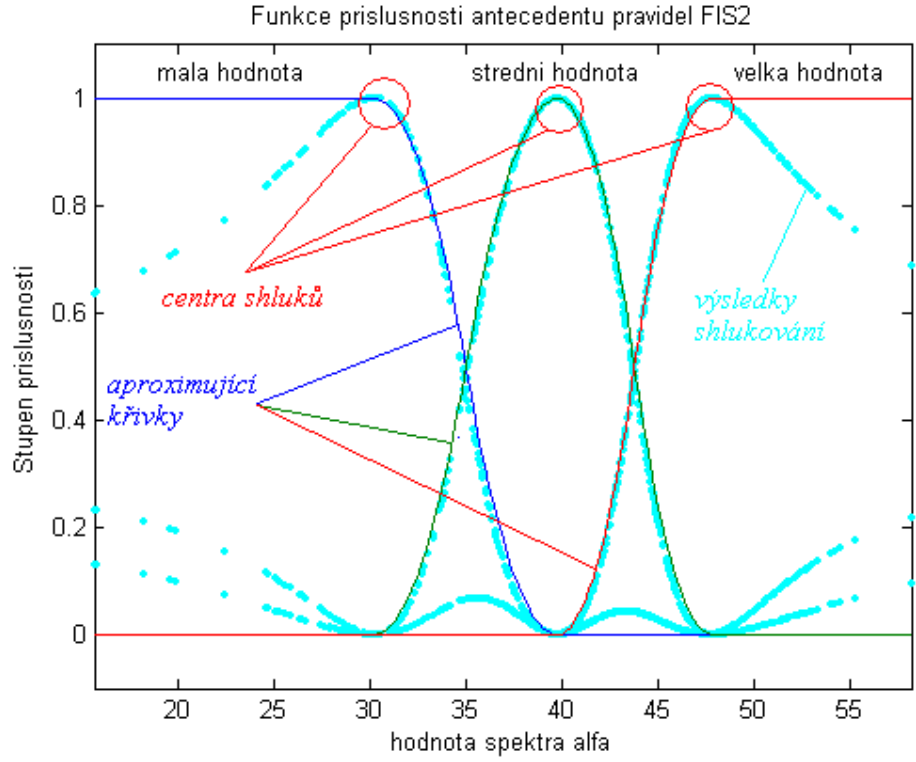
Výstupem shlukové analýzy jsou hodnoty funkce příslušnosti a centra shluků (příklad výstupů shlukování je na obrázku 15). Koordináty center shluků se dá použít pro aproximaci funkce příslušnosti «klasickými» funkcemi (viz Obr.16, Obr.17). Sice aproximace není stoprocentně přesná, ale je postačující pro použití v FIS. Tyto funkce mají výhodu v tom, že odpovídají podmínkám, potřebným pro její použití v praxi (viz dále).



Obr. 15 Příklad výsledků fuzzy shlukování: a) 2 shluky, b) 3 shluky



Obr. 16 Aproximace funkce příslušnosti pro FIS1



Obr. 17 Aproximace funkce příslušnosti pro FIS2

MATLAB je velice vhodný pro práci s fuzzy množinami. Velká výhoda spočívá ve vložení balíku programů zabývajícím se fuzzy problematikou – Fuzzy Logic Toolbox. Tento balík obsahuje Fuzzy Interface Systém, umožňující návrh FIS.

V praxi používané fuzzy množiny by měly být normální a konvexní. Fuzzy množina A se nazývá normální, jestliže $\text{Ker}(A) \neq \emptyset$, kde $\text{Ker}(A)$ je jádro fuzzy množiny definované: $\text{Ker}(A) = \{x \in U; \mu_A(x) = 1\}$. Fuzzy množina $A = (U, \mu_A)$ se nazývá konvexní, jestliže U je lineární prostor a pro každé dva prvky $x, y \in U$ a pro každé $\lambda \in [0, 1]$ platí: $\mu_A(\lambda x + (1 - \lambda)y) \geq \mu_A(x) \wedge \mu_A(y)$. [20]

Fuzzy množiny definované vztahy (33-36) jsou normální a konvexní. Dále splňují požadavek částečné spojitosti funkce příslušnosti. Pomocí těchto funkcí jsou aproximovány funkce příslušnosti antecedentů pravidel inferenčního mechanismu FIS.

Definice Z-funkce:

$$\mu(x) = \begin{cases} 1, & x \leq a \\ 1 - 2 \left(\frac{x-a}{b-a} \right)^2, & a \leq x \leq \frac{a+b}{2} \\ 2 \left(\frac{b-x}{b-a} \right)^2, & \frac{a+b}{2} \leq x \leq b \\ 0, & x \geq b \end{cases} \quad (33)$$

Definice S-funkce:

$$\mu(x) = \begin{cases} 0, & x \leq a \\ 2 \left(\frac{x-a}{b-a} \right)^2, & a \leq x \leq \frac{a+b}{2} \\ 1 - 2 \left(\frac{x-b}{b-a} \right)^2, & \frac{a+b}{2} \leq x \leq b \\ 1, & x \geq b \end{cases} \quad (34)$$

Definice trojúhelníkové funkce:

$$\mu(x) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ \frac{c-x}{c-b}, & b \leq x \leq c \\ 0, & x \geq c \end{cases} \quad (35)$$

Definice funkce aproximující Gaussovou:

$$\mu(x) = \begin{cases} 0, & x \leq a \\ 2 \left(\frac{x-a}{b-a} \right)^2, & a \leq x \leq \frac{a+b}{2} \\ 1 - 2 \left(\frac{x-b}{b-a} \right)^2, & \frac{a+b}{2} \leq x \leq b \\ 1 - 2 \left(\frac{x-b}{c-b} \right)^2, & b \leq x \leq \frac{b+c}{2} \\ 2 \left(\frac{c-x}{c-b} \right)^2, & \frac{b+c}{2} \leq x \leq c \\ 0, & x \geq c. \end{cases} \quad (36)$$

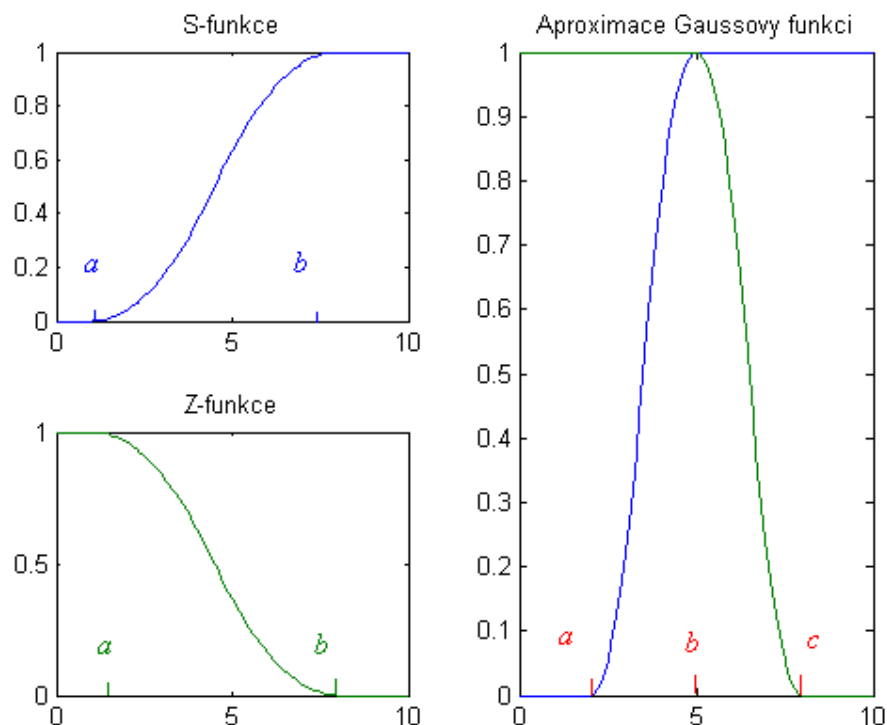
U Gaussove funkci je složité odhadnout hodnotu parametru b (středně kvadratická odchylka), vhodnějším je navrhnout funkci stejného tvaru jako «sumu» S- a Z-funkcí (36) s použitím již známých parametrů (viz Obr.18).

Pro aproximaci funkce příslušnosti musíme dosadit výstupní hodnoty algoritmu shlukování (centra shluků) do příslušných vzorků:

Z-funkce: a = hodnota centra 1, b = hodnota centra shluku 2 .

S-funkce: a = hodnota centra 1, b = hodnota centra shluku 2.

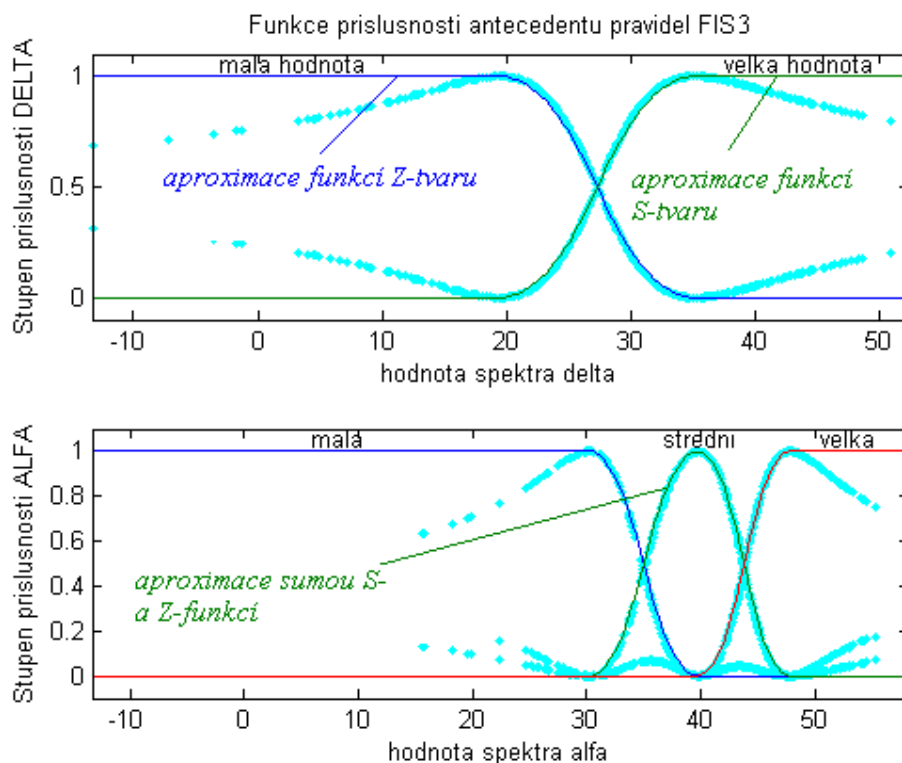
Kombinace Z- a S-funkcí (aproximace Gaussove křivky): a = hodnota centra 1, b = hodnota centra shluku 2, c = hodnota centra shluku 3.



Obr. 18 Ukázka aproximujících funkcí s vyznačenými parametry

Na obrázku 19 je příklad aproximace funkce příslušnosti premis pravidel inferenčního systému třetího klasifikátoru.

Trojúhelníkovou funkci využijeme při tvorbě funkce příslušnosti konsekventů pravidel FIS (viz 4.3.3).



Obr. 19 Aproximace funkce příslušnosti pro FIS3

4.3.3 Tvorba báze fuzzy pravidel

Součástí každého klasifikátoru je fuzzy inferenční systém, základem kterého je fuzzy báze pravidel.

Pravidla popisují vztah mezi vstupními a výstupními proměnnými vyjádřenými pomocí funkcí příslušnosti. Jde vlastně o rozložení problému na množství rozhodnutí.

Existují podmínky, které by měla splňovat správně tvořená báze pravidel:

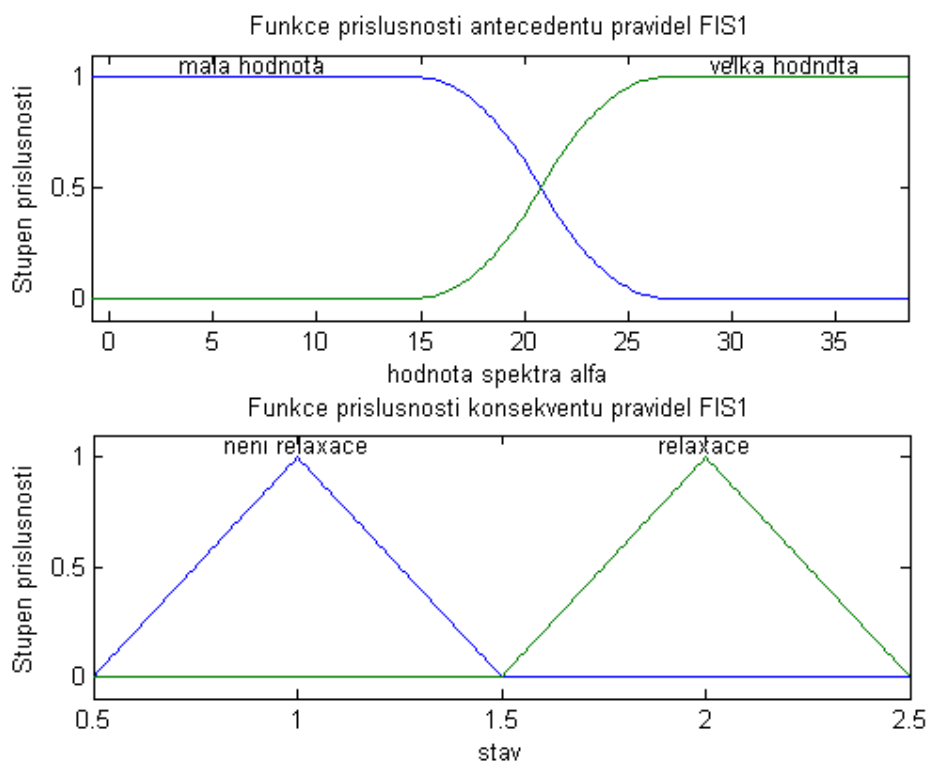
- báze by měla obsahovat alespoň jedno pravidlo pro každý term výstupní proměnné;
- pro libovolný term vstupní proměnné by mělo existovat alespoň jedno pravidlo, v němž tento term bude sloužit antecedentem;
- pro libovolný vektor vstupních proměnných musí existovat alespoň jedno pravidlo, míra splnění kterého je větší jak 0. Jinými slovy pravidla by měly pokrývat celý datový prostor.

Báze pravidel FIS *prvního klasifikátoru* má nejjednodušší tvar: 2 antecedenty a 2 konsekventy:

Je-li hodnota energie spektru v pásmu alfa MALÁ, pak stav je NENÍ RELAXACE;

Je-li hodnota energie spektru v pásmu alfa VELKÁ, pak stav je RELAXACE.

Příčemž rozdělení hodnot má lineární charakter. Na obrázků 20 jsou funkce příslušnosti antecedentů a konsekventů pravidel.



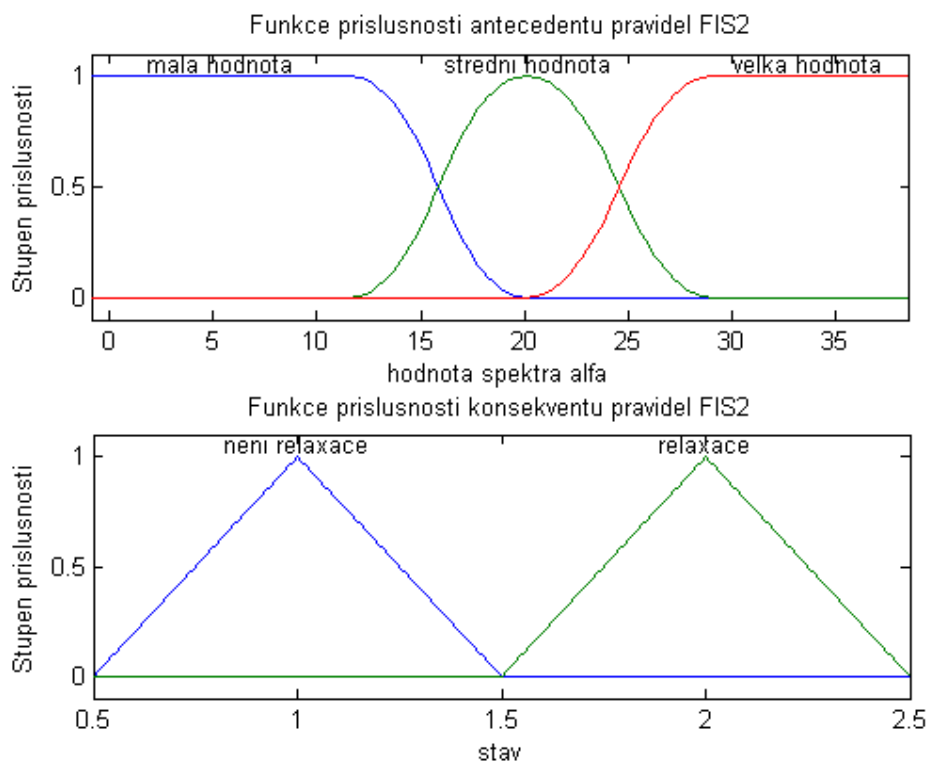
Obr. 20 Funkce příslušnosti antecedentu a konsekventu pravidel FIS1

Vidíme, že FIS přiřadí hodnotu energie spektra 5 termu Malá hodnota, 30 – Velká hodnota, 20 – se stupni příslušnosti kolem 0,4 k množině Velká hodnota a 0,7 – Malá hodnota. Pak podle pravidel a funkcí příslušnosti pro konsekventy pravidel provede usuzování o stavu člověka pomocí Mamdaniho inferenci, defuzzifikuje získanou hodnotu příslušnosti na základě centroidní metody defuzzifikace. Takovým způsobem se provede usuzování pro celkový vektor vstupních hodnot. Na stejném principu fungují další klasifikátory.

Báze pravidel **druhého klasifikátoru** (znázornění funkcí příslušnosti antecedentů a konsekventů pravidel je na obrázku 21) je tvořená následujícími pravidly:

- Je-li hodnota energie spektru v pásmu alfa MALÁ, pak stav je NENÍ RELAXACE;
- Je-li hodnota energie spektru v pásmu alfa STŘEDNÍ, pak stav je NENÍ RELAXACE;
- Je-li hodnota energie spektru v pásmu alfa VELKÁ, pak stav je RELAXACE.

Tím, že dělíme hodnoty spektra pásma alfa na 3 třídy, posouváme «prahové» hodnoty, říkající o tom, jak velká je analyzována hodnota (srovnej Obr.20 a Obr.21). Tento fakt působí zlepšení výsledků klasifikace, protože hodnota, kterou první klasifikátor přiřadí k termu Velká hodnota, druhý klasifikátor možná zařadí do množiny Střední hodnota. Takto se zvýší efektivita detekce Relaxace (tento stav je pro nás modelem mikrosněžku) (viz Tabulka1).

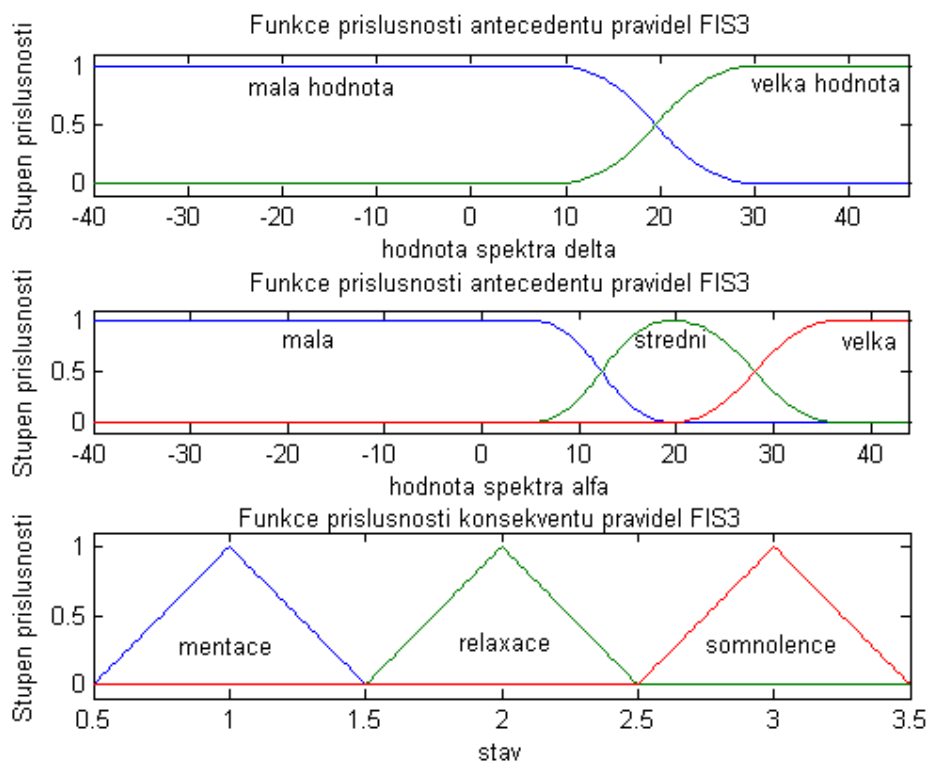


Obr. 21 Funkce příslušnosti antecedentu a konsekventu pravidel FIS2

Báze pravidel *třetího klasifikátoru* (funkce příslušnosti jsou na obrázku 22):

- Je-li hodnota energie spektra v pásmu alfa **VELKÁ**, pak stav je **RELAXACE**;
- Je-li hodnota delta **VELKÁ** a zároveň hodnota alfa je **MALÁ** pak stav je **SOMNOLENCE**;
- Je-li hodnota energie spektra v pásmu alfa **STŘEDNÍ**, pak stav je **MENTACE**;
- Je-li hodnota delta **MALÁ** a zároveň hodnota alfa je **MALÁ** pak stav je **MENTACE**.

Třetí klasifikátor analyzuje informaci o hodnotách pásem alfa a delta, proto má větší možností klasifikaci: usuzování o přítomnosti v záznamech charakteristik, odpovídajících stavům Mentace, Relaxace a Somnolence. V tomto případě za model mikrosněpánku je vhodné přijmout právě Somnolenci, která má projevy více podobné projevům mikrosněpánku (ospalost, nevnímání apod.).



Obr. 22 Funkce příslušnosti antecedentu a konsekventu pravidel FIS3

Čtvrtý klasifikátor má za úkol detekovat také tři stavy: mutace, relaxace a somnolence. Ale na rozdíl od třetího bere v úvahu všechna pásma, kromě pomalé delty. Pravidla, podle kterých se provádí usuzování:

Je-li delta MALÁ & teta je MALÁ & alfa je MALÁ & beta je VELKÁ,

pak stav je MENTACE;

Je-li delta MALÁ & teta je MALÁ & alfa je STŘEDNÍ & beta je VELKÁ,

pak stav je MENTACE;


Je-li alfa VELKÁ, pak stav je RELAXACE;

Je-li delta VELKÁ & teta je VELKÁ & alfa je MALÁ,

pak stav je SOMNOLENCE.

V pravidlech je pomocí symbolu «&» označována operace logické AND.

Funkce příslušnosti FIS4 jsou zobrazené na obrázku 23 na další stránce.



Obr. 23 Funkce příslušnosti antecedentu a konsekventu pravidel FIS4

4.3.4 Algoritmus zpracování výstupů FIS

Fuzzy inferenční systém definuje nad hodnotou vstupní proměnné soubor vstupních logických proměnných – vstupních termů a převádí číselnou hodnotu vstupní proměnné na pravdivostní hodnoty termů (fuzzifikace). Pak jádro systému transformuje pravdivostní hodnoty svých vstupních proměnných na pravdivosti jedné nebo více výstupních logických proměnných (výstupních termů). Každý z výstupních fuzzy termů může mít nenulovou pravdivost, takže jejich soubor dává víceznačnou (nebo dokonce rozporuplnou) výpověď o potřebné hodnotě výstupní jazykové proměnné (podobně jako závěry a doporučení skupiny expertů nebo politiků). Pak je hledané jednoznačné řešení pro vyřešení rozhraní mezi logickou a číselnou částí systému (defuzzifikace).

Tedy máme na výstupu FIS ostré hodnoty. Úloha klasifikace požaduje víceméně «rovnoměrnou» distribuci výstupních hodnot. Výsledek FIS ale může obsahovat krátkodobé «oscilaci» výstupních hodnot.

Proto třeba použít algoritmus zpracování výsledků fuzzy inferenčního systému, který eliminuje nežádoucí kmitání.

Tento algoritmus se dá popsat schématem:

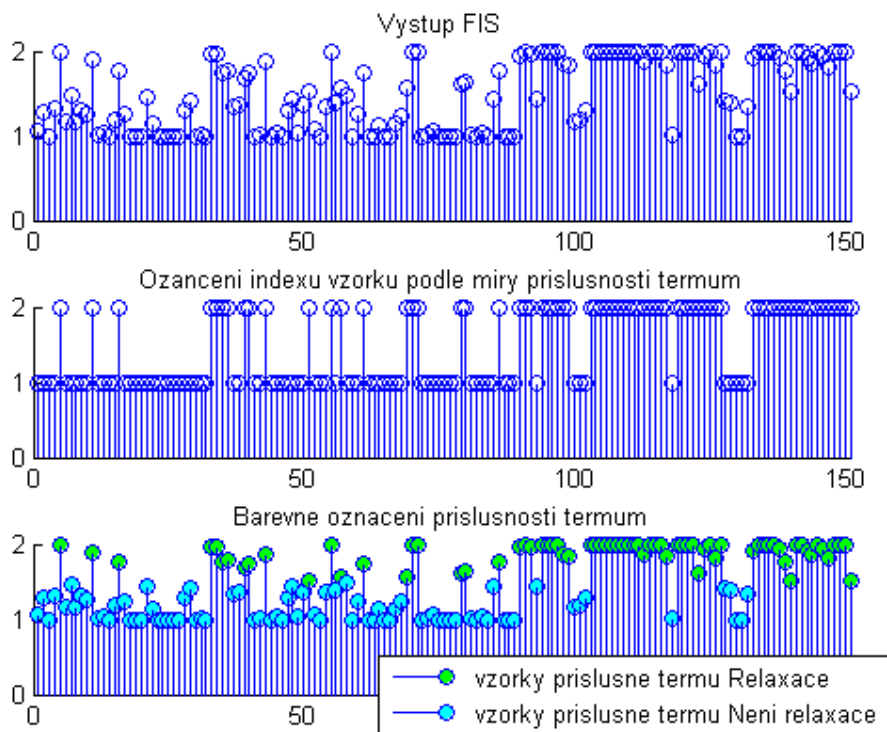
1. přiřazení indexům vzorků vstupní posloupnosti (které jsou výstupními hodnotami fuzzy inferenčního systému) hodnot 1, 2 nebo 3 (tři hodnoty přidělujeme jen v případě čtvrtého klasifikátoru) v závislosti na míře příslušnosti výstupním termům FIS (viz 4.3.3) (viz Obr.24, Obr.27);
2. hledáme v takto stanovené posloupnosti sekvenci jdoucích za sebou indexů, které mají stupeň příslušnosti ke stejnému termu po dobu delší jak 4 indexy, což

odpovídá situace, kdy se člověk nachází v jednom stavu (např. relaxace) déle jak 1s., zbývající označíme za «oscilaci» (viz Obr. 25, Obr. 28);

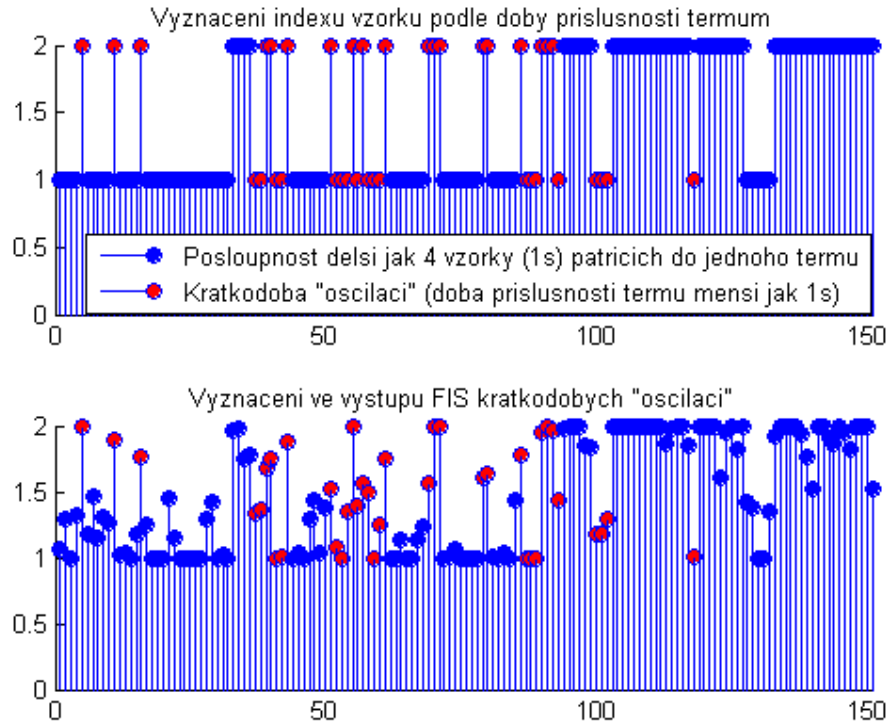
3. hledáme indexy ze skupiny «oscilujících», nacházející mezi «neoscilujícími», přičemž poslední by měly patřit do jednoho termu (např. Relaxace);
4. přiřazujeme indexy určené v kroku 3 do termu sousedních obklopujících indexů;
5. zbývající indexy, neodpovídající podmínce 3, zařadíme do skupiny Neznámý stav, protože nevíme možnosti usuzování o stavu v tomto případě;
6. dostáváme posloupnost hodnot rozdělených do 3 nebo 4 skupin (v závislosti na FIS, výstup kterého upravujeme), poslední skupina bude vždycky Neznámý stav (viz Obr.26, Obr.29).

Důvodem proč pracujeme s přesně stanovenými hodnotami (1, 2 nebo 3) je zaprvé lepší prezentovatelnost, zadruhé efektivnější implementace v programovém prostředí. Podle výsledku algoritmu však máme možnost se podívat na výchozí «pravděpodobnostní» data, ale již klasifikované do jednotlivých skupin.


Následující obrázky (viz Obr.22-Obr.27) ukazují výsledky aplikaci algoritmu zpracování na FIS prvního a čtvrtého klasifikátoru.



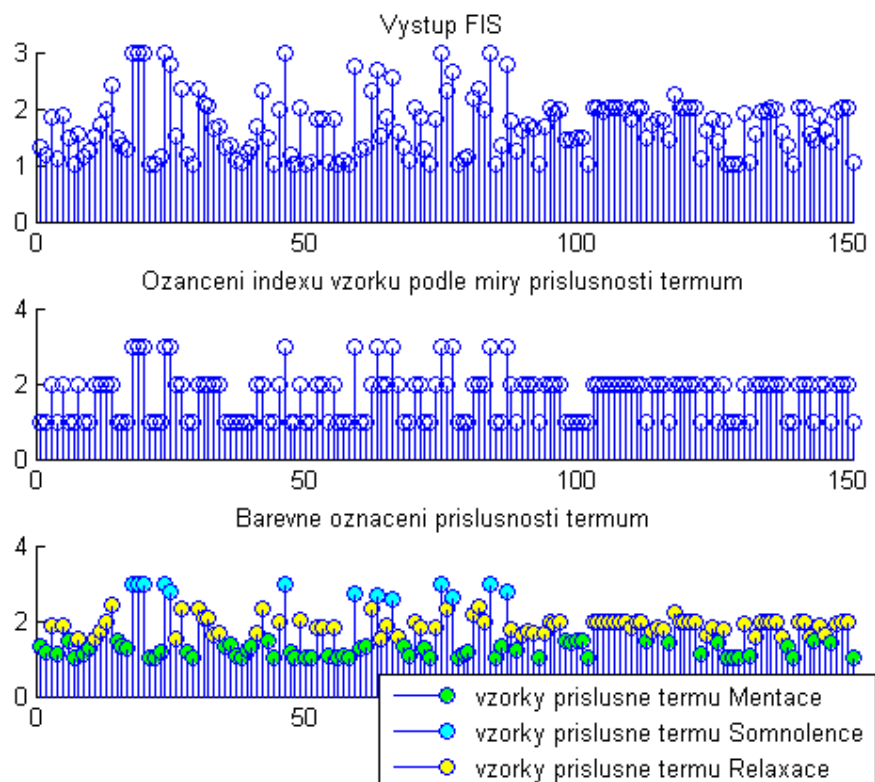
Obr. 24 První etapa zpracování výstupu FIS (na příkladu FIS1)



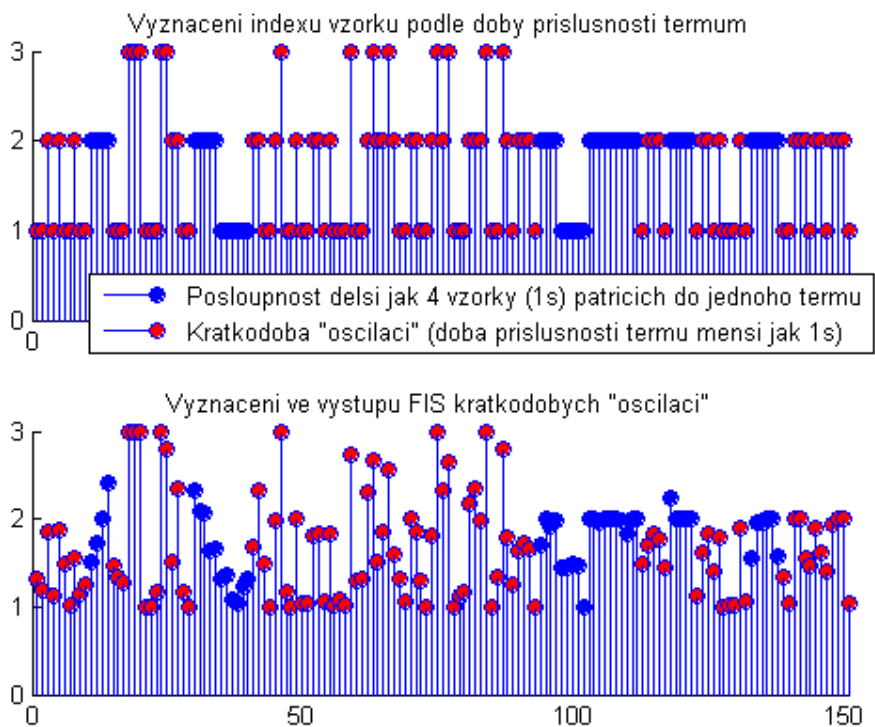
Obr. 25 Druhá etapa zpracování výstupu FIS (na příkladu FIS1)



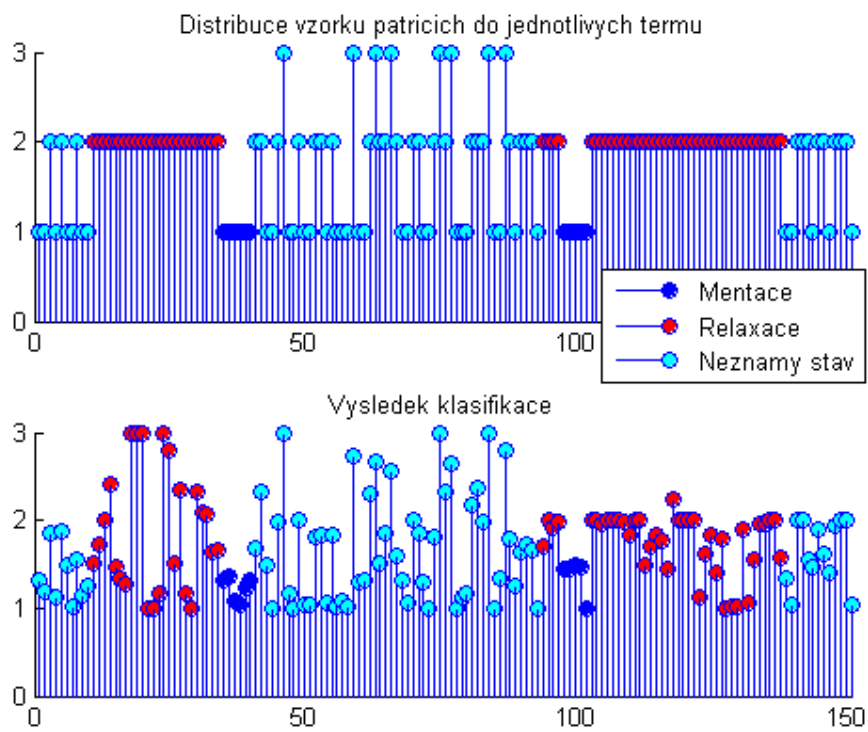
Obr. 26 Závěrečná etapa zpracování výstupu FIS (na příkladu FIS1)



Obr. 27 První etapa zpracování výstupu FIS (na příkladu FIS4)



Obr. 28 Druhá etapa zpracování výstupu FIS (na příkladu FIS4)




Obr. 29 Závěrečná etapa zpracování výstupu FIS (na příkladu FIS4)

5 Popis a struktura programu v prostředí MATLAB

Navržená metoda detekcí mikrosnánku byla implementována na osobním počítači s operačním systémem Windows® XP. K realizaci programu je použito prostředí MATLAB 7.0. Je vytvořen program komunikující s uživatelem v grafickém prostředí, který umožňuje automatickou klasifikaci signálů EEG. Soubory programu a zdrojový kód jsou k dispozici na přiloženém datovém mediu.

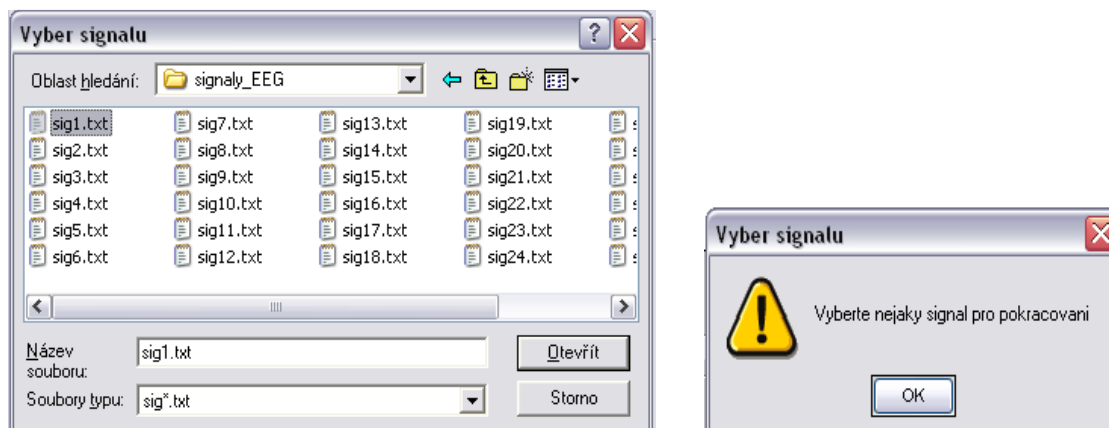
Pro vytvoření grafického uživatelského rozhraní (GUI – Graphic User Interface) je použit modul GUIDE (Graphical User Interface Development Environment) vývojového prostředí MATLAB 7.0. [1], [9]. Program se skládá z 8 souborů s příponou *.fig (figure) a 17 souborů s příponou *.m (m-file). Program lze spustit z nainstalovaného prostředí MATLAB souborem ANALYZA_EEG.m (všechny soubory musí být ve stejném adresáři).

Na obrázku 30 je náhled na první okno programu. Po spuštění je potřeba načíst vstupní signál (jsou uloženy ve formátu *.txt) z hlavního menu v nabídce Soubor/Otevřít (viz Obr.31, a).



Obr. 30 Okno zobrazení signálu a jeho spektra

První okno obsahuje 2 ohraničená menší okna, která slouží pro zobrazení načtených vstupních signálu v čase a jejich spekter (pro znázornění spektrálního složení signálů EEG). Zobrazení spektru se dá zvětšit (šipka při dosažení pole zobrazení spektra přejde do stavu «zoom»).



Obr. 31 Okna programu: a) Výběr signálu (vlevo), b) Varovací okno Výběr signálu (vpravo)

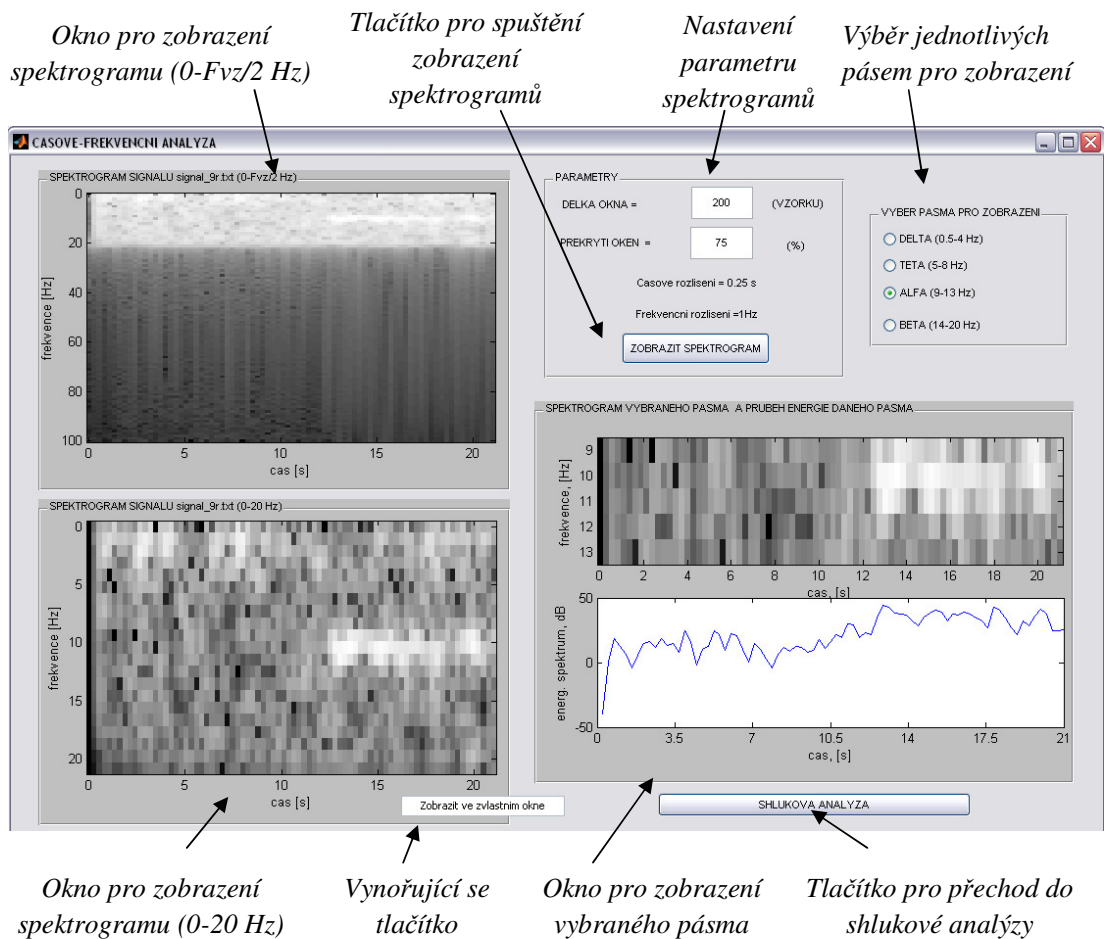
Případ pokračování bez vybraného vstupního signálu je ošetřen varovacím okénkem (viz Obr.31, b).

Po načtení vstupních dat lze přejít do časově-frekvenční analýzy stiskem tlačítka CASOVE-FREKVENCNI ANALYZA.

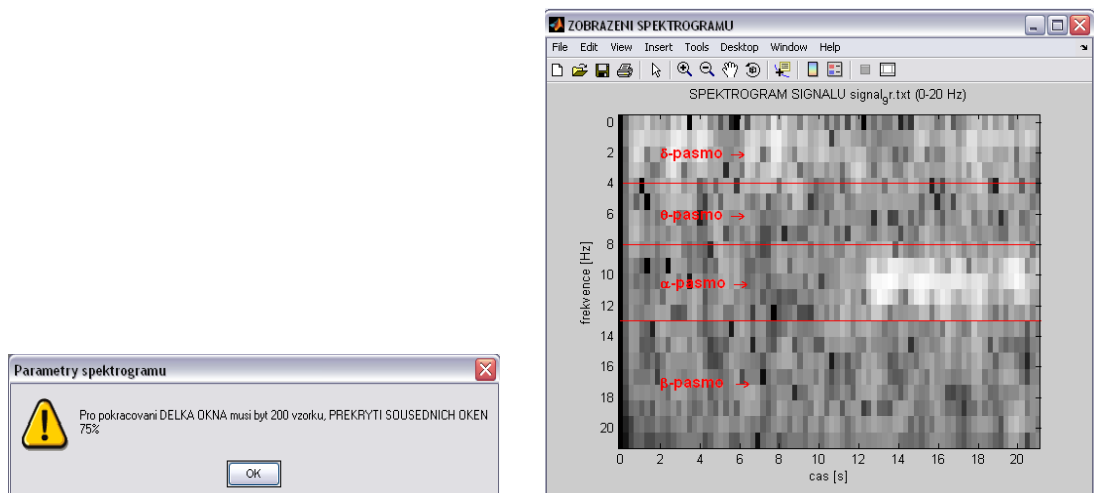
Otevře se další okno (viz Obr.32). Na začátku uživatel musí zadat parametry potřebné pro vytvoření spektrogramu signálu: délku okna (ve vzorcích) a překrytí sousedních oken (v procentech). Důležitým je ukončit nastavení každého parametru stiskem tlačítka počítače Enter. Uživatel může vidět časové a frekvenční rozlišení, která budou dosažena při těchto hodnotách parametrů.

Pro libovolné hodnoty vstupních parametru (délka okna a překrytí oken) program umožňuje jen zobrazení celkového spektrogramu. Další analýza (zobrazení jen zajímavých pásma a ostatní kroky analýzy EEG) je možná jen pro určité hodnoty těchto parametrů, a to jsou délka okna = 200 vzorků a přesah = 75%. Tyto hodnoty zabezpečují rozlišení v časové ose 0.25 s a v kmitočtové ose 1 Hz, což jsou optimální parametry pro další zpracování. Program hlásí tyto požadavky ve speciálním varovacím okně (viz Obr.33, a). Spektrogramy signálu se zobrazují hned po stisknutí tlačítka ZOBRAZIT SPEKTROGRAM: spektrogram celého pásma 0-100 Hz (hodnota 100 Hz odpovídá polovině vzorkovacího kmitočtu) a pásma, které bude použité pro další analýzu 1-20 Hz (pásma alfa až beta). Kliknutím na pole spektrogramu 1-20 Hz je možné zobrazit spektrogram ve zvláštním okně (a to s vyznačením jednotlivých pásem) a uložit do vybrané složky (viz Obr.33, b).

Dá se zobrazit zajímavé pásmo (jedno ze čtyř) v speciálním ohraničeném okně, přičemž se kromě spektrogramu pásma zároveň zobrazí časový průběh střední hodnoty energie spektra.

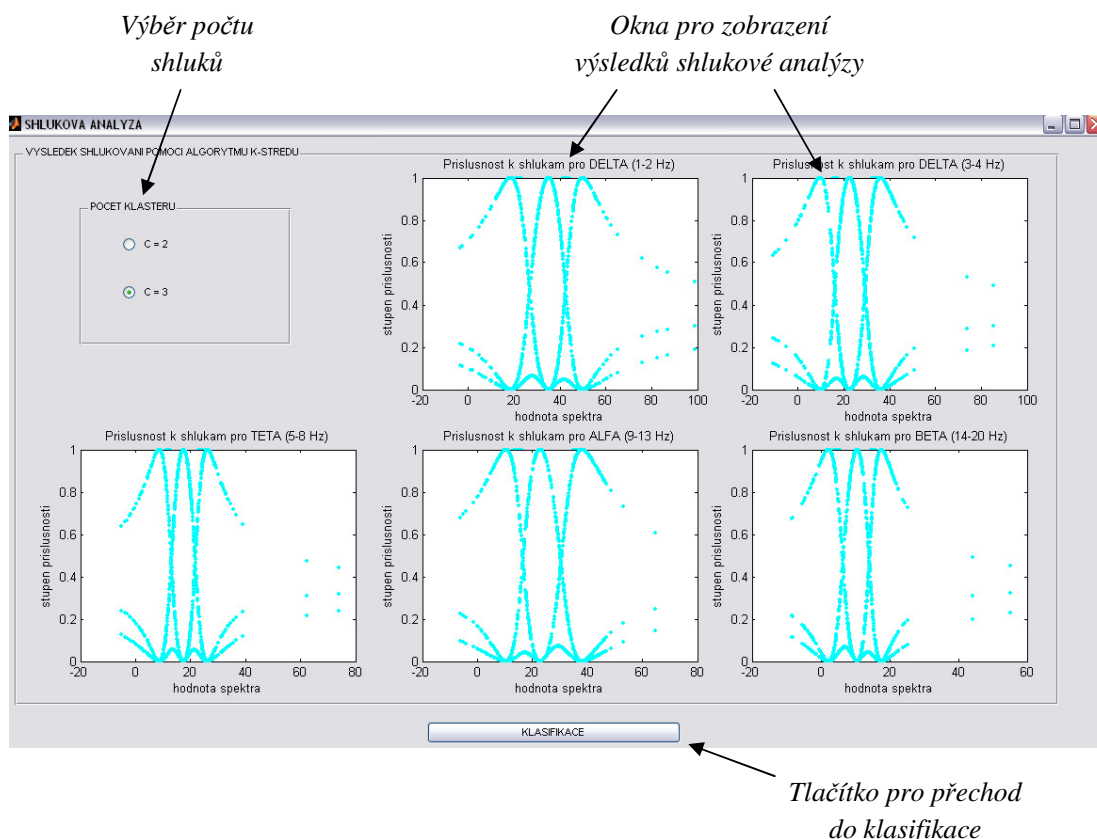


Obr. 32 Okno časově-frekvenční analýzy signálů



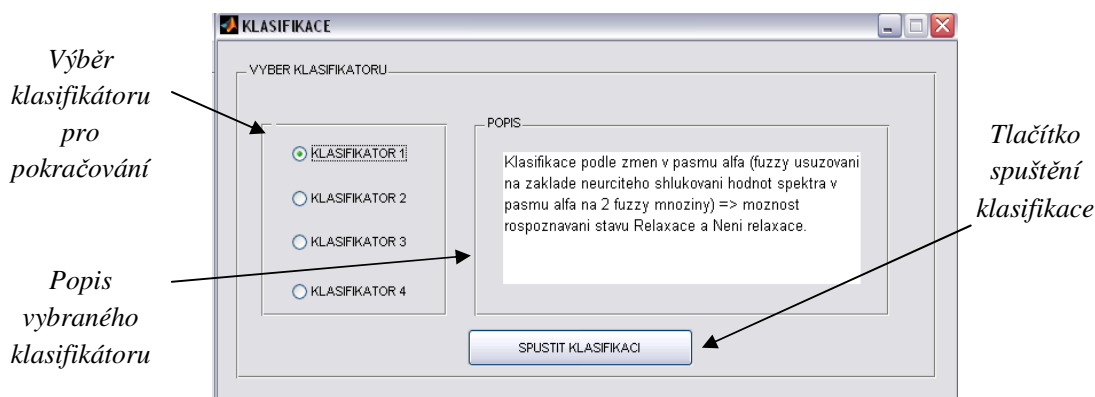
Obr. 33 Okna programu: a) Varovací okno PARAMETRY SPEKTROGRAMU (vlevo) b) ZOBRAZENI SPEKTROGRAMU (vpravo)

Při stisku tlačítka SHLUKOVA ANALYZA se uživateli zobrazí okno (viz Obr.34), v němž se dá provést fuzzy shlukování všech pásem spektrogramu, a to na 2 nebo 3 shluků (výběrem odpovídajícího tlačítka). Pásmo delta je rozdělené do dvou dílčích: takzvané rychlé a pomalé delta pásma. Data o shlukování jsou zapsaná do souboru V2_M2.mat a V3_M3.mat pro použití v dalším kroku zpracování. Přičemž tlačítko pro přechod do následujícího okna (KLASIFIKACE) je dostupné jen poté, když budou v paměti počítače oba tyto soubory.



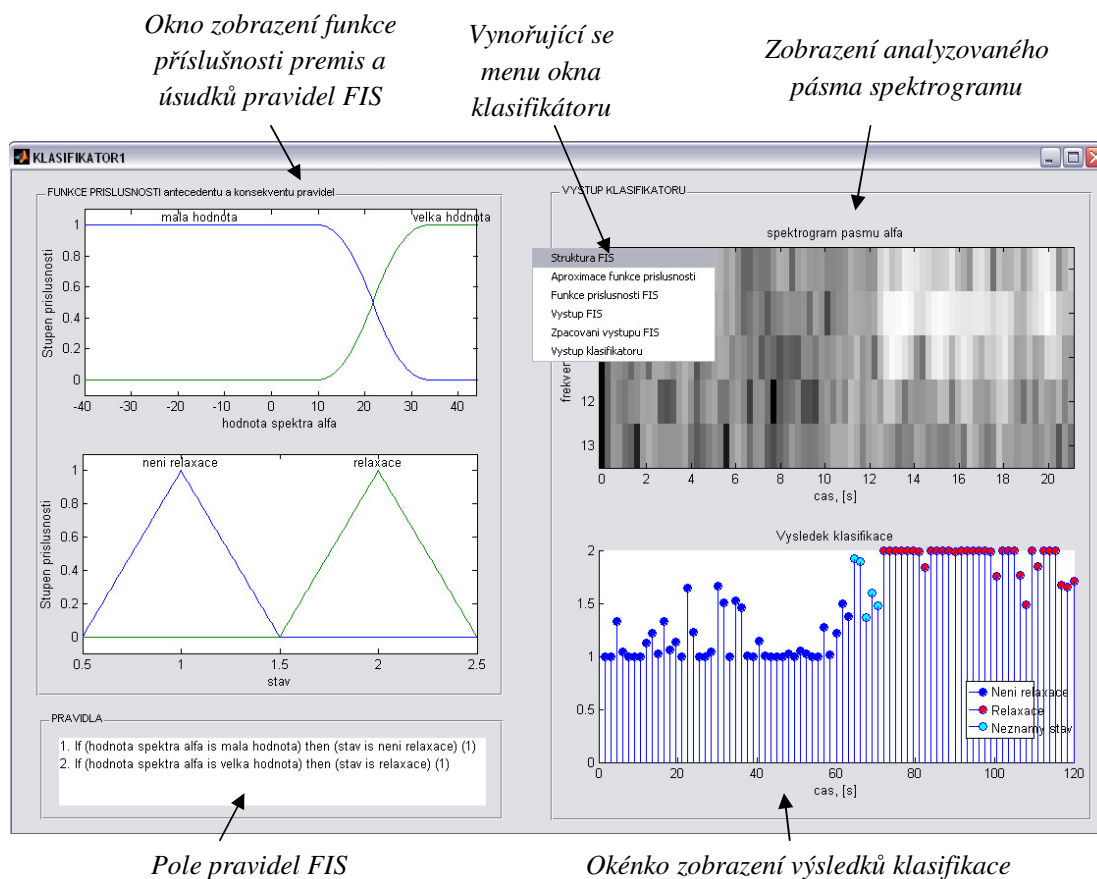
Obr. 34 Okno shlukové analýzy

Okno KLASIFIKACE (viz Obr.35) je určené pro výběr klasifikátoru. Vedle každého klasifikátoru je stručný popis, podle kterého se dá zorientovat při výběru.




Obr. 35 Okno pro výběr klasifikátoru

Zbývající 4 okna (KLASIFIKATOR1, KLASIFIKATOR2, KLASIFIKATOR3, KLASIFIKATOR4) znázorňují strukturu jednotlivých klasifikátorů a výsledky klasifikace. Na obrázku 36 je ukázka okna pro zobrazení jednoho z klasifikátorů.



Obr. 36 Okno KLASIFIKATOR

Každé z nich obsahuje ohraničené okno s ilustrací funkci příslušnosti pro premisy a úsudky pravidel. Samotná pravidla jsou vedle funkcí příslušnosti. Dále v oknech klasifikátorů jsou výsledky klasifikace, zobrazené pro lepší porozumění spolu se spektrogramem a časovým průběhem energie spektru příslušného pásma. Kliknutím na pole okna (mimo okének s obrázky) se uživatel dostane do menu (viz Obr.37), v němž si může vybrat různé možnosti zobrazení systému klasifikace a výsledků v jednotlivých oknech.




Obr. 37 Menu oken klasifikátorů

První záložka slouží pro zobrazení struktury navrhnutého fuzzy systému (včetně počtu vstupních příznaků, výstupních elementů, názvu systému, názvu použité metody usuzování (Mamdaniho metoda))(viz Obr.38, a). Druhá umožňuje zobrazit aproximaci funkci příslušnosti premis pravidel FIS na základě výsledků fuzzy shlukování (viz Obr.38, b), třetí - funkci příslušnosti pro premisy a úsudky pravidel (viz Obr.39, a).

a)

b)

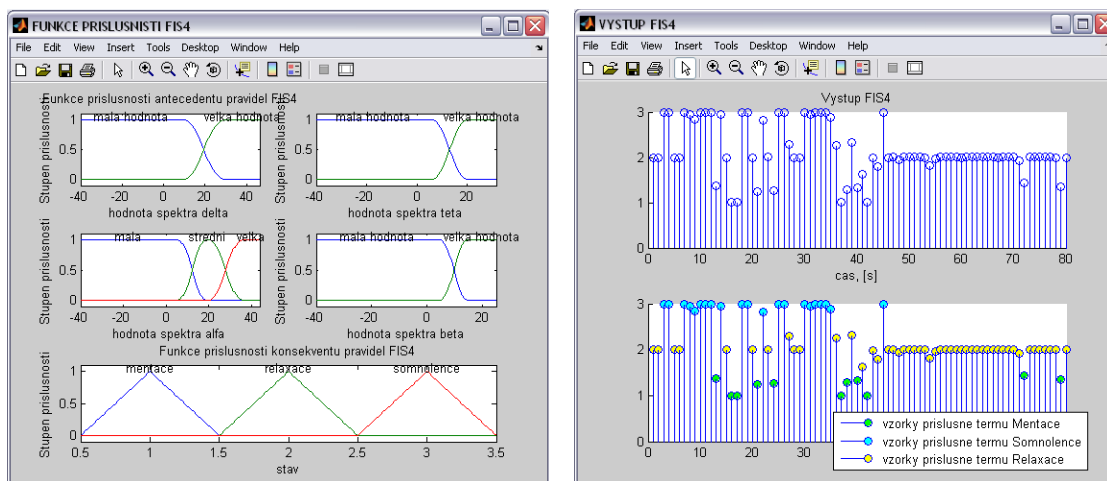


Obr. 38 Okna klasifikátoru: a) STRUKTURA FIS b) APROXIMACE FUNKCE PRISLUSNOSTI FIS

Při výběru čtvrté se pak otevře okénko s výstupem fuzzy usuzování (Obr.39, b).

a)

b)



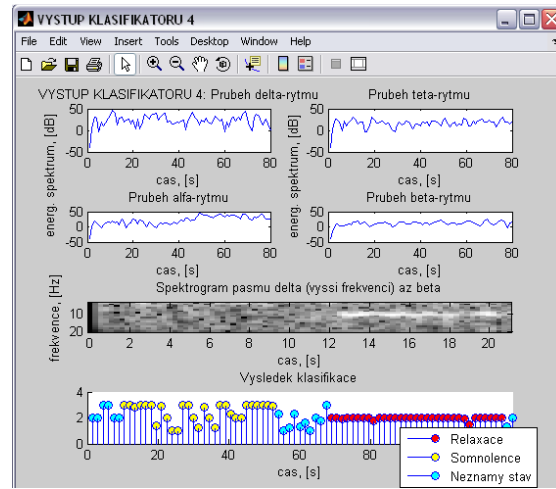
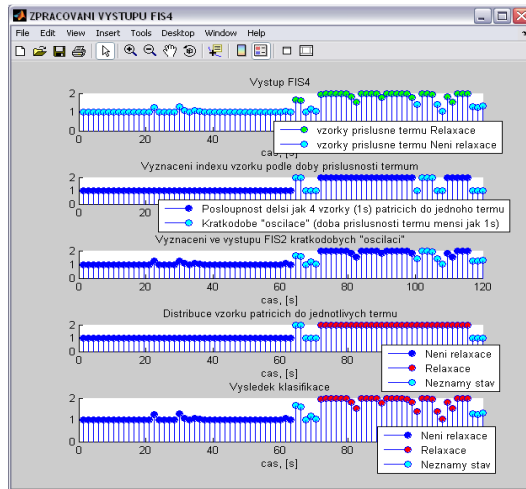
Obr. 39 Okna klasifikátoru: a) FUNKCE PRISLUSNOSTI FIS, b) VYSTUP FIS

Dále se dá podívat na zpracování tohoto výsledku speciálním algoritmem, eliminujícím krátkodobá «kmitání» výstupních hodnot (viz Obr.40, a). Na závěr je možnost zobrazení výstupu klasifikátoru (viz Obr.40, b), kde vzorky přiřazené k nějakému klasu a nepřijřazené k žádnému označené různou barvou (jako v hlavním okně klasifikátoru jsou spolu

s výsledkem zobrazený spektrogram a časový průběh vstupu klasifikátoru). Všechny obrázky jsou uvedené ve zvláštních oknech, dá se je uložit do paměti počítače.

a)

b)



Obr. 40 Okna klasifikátoru: a) ZPRACOVANI VYSTUPU FIS, b) VYSTUP KLASIFIKATORU


6 Výsledky

Navržená metoda klasifikace mikrospánku je otestována na signálech, naměřených v laboratoři bioniky ÚBMI, jejíž popis je uveden v kapitole 2. Jako vstupní data pro analýzu byly použity signály deseti pokusných osob dobou trvání 21s.

Klasifikace se provádí na základě změn spektrálního složení signálů EEG v čase. Do časově-frekvenční oblasti je dostáváme pomocí krátkodobé Fourierové transformace. Parametry vybrané pro tvorbu spektrogramu (délka okna a překrytí oken) zaručují časové rozlišení 0,25 s a frekvenční rozlišení 1 Hz.


Pro klasifikaci byly použity pouze dva klasifikátory: KLASIFIKATOR1 a KLASIFIKATOR2. Použití dalších dvou klasifikátorů se ukázalo jako neefektivní v důsledku toho, že se nepodařilo u žádné pokusné osoby vyvolat mikrospánek. Tedy žádný vstupní signál neobsahuje těch charakteristických změn, které by měli být v signálech s nálezem mikrospánku (somnolence). Ale je zajímavé, že ve většině ze signálů se projevil jev «rozpadání» alfa aktivity, což je příznakem začátku hypnagogia. Nepodařilo se však nalézt patřičné změny v pásmu delta (vysoká energie), což znehodnocuje klasifikaci pomocí těchto klasifikátorů.

Na obrázku 41 je ukázka mizení a zase zvýšení alfa po pěti minutách klidového stavu vleže se zavřenými očima. Tento stav má projevy podobné mentaci. Je patrné snížení delta a teta, což je v rozporu s teoretickými předpoklady. Všechny osoby jsou zdravé. Tedy můžeme odmítnout vliv nějaké choroby na mozkovou činnost. Je pravděpodobné, že nalezené změny alfa jsou první fází hypnagogia a v případě prodloužení experimentu by se začali projevovat i změny v delta pásmu.



Obr. 41 *Nález rozpadání alfa energie*

Při návrhu funkce příslušnosti pro KLASIFIKTOR2 byla předpokládána jeho lepší detekovací schopnosti (viz kapitola 4.3). Potvrzení toho bude znázorněno na příkladu klasifikaci jednoho ze signálů (viz Obr.42) .




Obr. 42 Srovnání výsledků klasifikaci

Na časovém průběhu signálu EEG a na jeho spektrogramu je patrná zvýšená energie alfa v době 9-11s a 13-14s. To jsou okamžiky, kdy osoba zavírala oči. Interval mezi nimi je 1s. Jak je vidět, první klasifikátor zařadil do skupiny Relaxace celý úsek signálu od 10s do 19s. Takže ve skupině Relaxace máme po klasifikaci nejenom skutečně patřící do ní úseky ale navíc dosti dlouhý úsek signálu, ve kterém se sice objevilo krátkodobé zvýšení energie, ale ne v důsledku relaxaci.

Na rozdíl od předcházejícího druhu klasifikátor správně rozlišil dva okamžiku zavření oči a navíc nezařadil do skupiny «falešné» vzorky signálu. Odpověď je patrná z obrázku 43.

FIS prvního klasifikátoru pracuje s funkcí příslušnosti, navržené podle výsledků fuzzy shlukování na 2 shluky. Druhý klasifikátor využívá dělení pásma alfa na 3 shluky. První klasifikátor zařadí do Relaxace vzorky s hodnotou již od kolem 27 dB, když druhý má «prahovou» hodnotu kolem 31 dB, což je postačující rozdíl pro mnohem lepší lokalizaci změn v energetickém spektru.



Obr. 43 Srovnání funkci příslušnosti FIS1 a FIS2

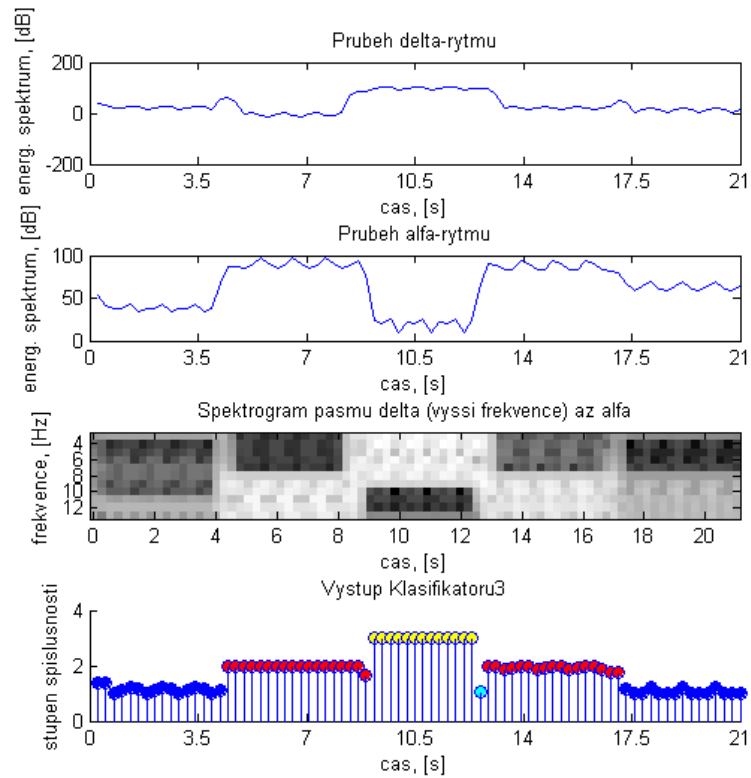
Ověření funkčnosti dvou zbývajících klasifikátorů provedeme pomocí simulovaného EEG signálu. Výsledky klasifikací jsou na obrázcích 44 a 45.

Žlutou barvou jsou označeny vzorky, přiřazený klasifikátorem ke skupině Somnolence, červenou – Relaxace, modrou – Mentace, modrozelenou pak je označen neznámý stav (tedy klasifikátor neumí rozhodnout k jaké skupině tyto vzorky přiřadit).

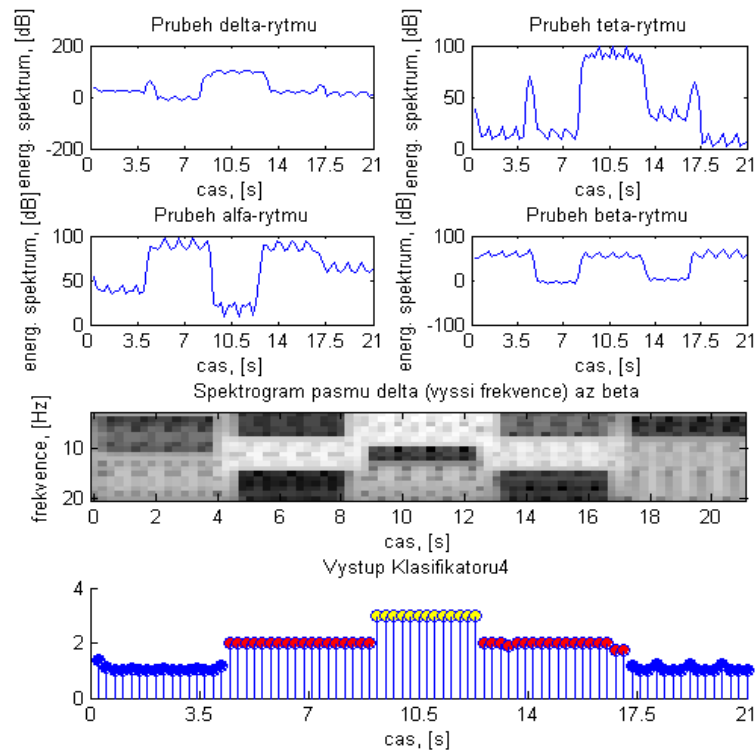
Jak je vidět, rozhodování na základě změn pouze ve dvou pásmech alfa a delta se dá opravdu považovat za postačující, neboť se výsledky pro tyto klasifikátory liší nevýznamně.

Výsledky klasifikace jsou více než uspokojivé. Reální signály se ale moc liší od simulovaného v Matlabu. V reálných signálech se většinou neseťkáváme s natolik výraznými charakteristickými změnami spektra při změnách psychofyziologického stavu. Za normální nález se často považují opačné projevy. Mozek každého člověka odpovídá různě na vnější podněty a změny prostředí. V praxi se setkáváme s různými projevy během bdělosti, únavy, ospalosti apod. Dokonce můžeme pozorovat diametrálně protikladnou odezvu mozků různých osob na mentální zatížení a únavu. Signály EEG bývají zkreslený, např. kdy měřená osoba je nenajedená, nebo je zneklidněná apod. Práce se signály z mozku je obtížná a požaduje praxi v tomto oboru.

Kvantitativní hodnocení výsledků klasifikací je v tabulce 2.



Obr. 44 Výstup KLASIFIKATORU 3 pro simulovaný signál



Obr. 45 Výstup KLASIFIKATORU 4 pro simulovaný signál

Název signálu	KLASIFIKATOR 1					KLASIFIKATOR 2				
	<i>N</i>	<i>TP</i>	<i>FP</i>	<i>TN</i>	<i>FN</i>	<i>N</i>	<i>TP</i>	<i>FP</i>	<i>TN</i>	<i>FN</i>
signal_1	5	21	10	44	0	4	17	4	55	0
signal_2	14	32	2	31	1	14	23	0	43	0
signal_3	11	33	1	35	0	10	29	0	36	5
signal_4	6	34	5	35	0	25	17	0	38	0
signal_5	0	33	1	46	0	0	33	0	47	0
signal_6	7	16	16	41	0	5	10	0	65	0
signal_7	5	29	6	40	0	16	19	0	45	0
signal_8	12	29	20	19	0	17	24	0	29	10
signal_9	0	36	19	24	1	22	9	0	36	13
signal_10	17	9	40	14	0	6	5	0	69	0
signal_11	9	21	18	32	0	4	13	0	59	4
signal_12	16	5	2	57	0	0	5	1	74	0
signal_13	5	45	3	27	0	3	4	0	73	0
signal_14	0	49	2	29	0	0	50	1	29	0
signal_15	0	30	2	47	0	0	30	3	47	0
signal_16	9	46	1	18	6	6	4	0	28	42
signal_17	8	16	4	41	11	14	10	0	45	11
signal_18	8	38	18	11	5	10	25	4	36	5
signal_19	19	46	7	8	0	12	10	0	10	48
signal_20	18	25	6	31	0	3	20	6	47	4
signal_21	13	14	2	51	0	0	14	2	64	0
signal_22	10	5	18	47	0	2	9	0	68	1
signal_23	9	21	3	47	0	8	23	1	48	0
signal_24	0	33	24	23	0	15	17	2	43	3

signal_25	3	20	5	52	0	1	20	1	56	2
signal_26	5	35	8	32	0	10	32	0	38	0
signal_27	9	39	0	32	0	3	36	0	40	1
signal_28	7	56	0	17	0	13	10	0	39	18
signal_29	16	21	31	12	0	9	0	0	52	19
signal_30	0	37	5	38	0	4	33	5	38	0
Σ	241	874	279	982	24	236	551	30	1397	186
TPR	0.97					0.75				
TNR	0.78					0.98				

Tab. 2 Kvantitativní hodnocení výsledků klasifikace

V tabulce 2 jsou použity zkratky:

N – počet vzorků nepřiznaných klasifikátorem k žádnému stavu,

TP (true positive, pravdivě pozitivní) – počet vzorků patřících úsekům signálů se zaznamenaným stavem relaxace, přiznaných klasifikátorem do skupiny Relaxace,

FP (false positive, falešně pozitivní) – počet vzorků patřících úsekům signálů se zaznamenaným stavem odlišným od relaxace, přiznaných klasifikátorem do skupiny Relaxace,

TN (true negative, pravdivě negativní) – počet vzorků patřících úsekům signálů se zaznamenaným stavem odlišným od relaxace, přiznaných klasifikátorem do skupiny Není relaxace,

FT (false negative, falešně negativní) – počet vzorků patřících úsekům signálů se zaznamenaným stavem relaxace, přiznaných klasifikátorem do skupiny Není relaxace.

Na základě údajů souhrnných v tabulce spočítáme sensitivitu (TPR – true-positive rate, míra pravdivé positivity) a specificitu (TNR – true-negative rate, míra pravdivé negativity) jako:

$$TPR = \frac{TP_{\Sigma}}{TP_{\Sigma} + FN_{\Sigma}}, \quad (37)$$

$$TNR = \frac{TN_{\Sigma}}{TN_{\Sigma} + FP_{\Sigma}}. \quad (38)$$

Senzitivita udává pravděpodobnost, že vzorky patřící úsekům signálu odpovídajícím době, kdy se osoba nacházela ve stavu relaxace, jsou přiznány klasifikátorem ke skupině Relaxace.

Specificita udává pravděpodobnost, že vzorky patřící úsekům signálu odpovídajícím době, kdy se osoba nacházela ve stavu mentace, jsou přiznány klasifikátorem ke skupině Mentace.

Při výpočtu *TPR* a *TNR* nebyly brány v úvahu vzorky, nepřijížené klasifikátorem do žádné skupiny. Tyto hodnoty se pohybují v rozmezí od 0 až do 31% v případě signálu *signal_4*. Průměrná hodnota se rovná 10% od celkového záznamu, což je hodně. Ale při detailnějším pohledu na tabulku je patrná nerovnoměrnost výskytu velkých hodnot. Pouze u některých signálů klasifikátor nemůže rozhodnout o příslušnosti vzorků do jednoho ze stavu. To se dá vysvětlit charakterem těchto signálů: přechod mezi stavem bdělosti a relaxace navzdýcky je dostatečně prudký a hodnoty zjevně prokazatelné. Jsou příklady, kdy se na první pohled nedá určit přesný okamžik začátku změn v signále. Pomáhají jen záznamy udělaný v průběhu měření EEG signálů. Zatím se nepodařilo najít nějaký teoretický podklad, který by pomohl zlepšit algoritmus. Proto tyto údaje nejsou stoprocentně přesné. Navíc hodnocení není možné považovat za absolutně objektivní v důsledku toho, že bylo provedeno bez přítomnosti neurofyziologu.

Dá se však porovnat oba klasifikátory. Vidíme, že senzitivita je větší u prvního klasifikátoru, druhý má zase vyšší hodnotu specificity. To znamená, že první klasifikátor je dobře rozlišuje stav relaxace a druhý – stav opačný.

Můžeme tedy shrnout výsledky pravděpodobnostní analýzy a praktické aplikace algoritmů a říci, že bychom použili první metodu v případě, kdy chceme nalézt samotnou přítomnost mikrosnánku. Ale může nastat situace, kdy daný klasifikátor nebude schopen rozlišit stav odlišný od mikrosnánku a bude větší pravděpodobnost zařazení do skupiny relaxace mimo skutečných ještě vzorky, který by tam patřit neměli. Druhý je zase schopen lepe odhalit stav mentace (tedy je pravděpodobně více citlivý na rychlé změny v signálech, kdy pozorujeme krátké a prudké přechody z jednoho stavu do jiného).

Závěr

Předmětem zájmu této práce je detekce stavu mikrosněpanku v signálech EEG a snaha o programovou realizaci navržené metodiky.

Hodnoceny jsou změny energetického spektra při změně stavu pokusné osoby. V důsledku toho, že bylo během měření obtížné vyvolat u měřených osob stav mikrosněpanku, částečně byl simulován reakcí aktivace (otevření/zavření očí). Za mikrosněpanek považujeme stav relaxace – klidový stav se zavřenými očima.

Navržená metoda klasifikace mikrosněpanku využívá k nalezení požadovaných změn v signálech aparát fuzzy logiky: nejprve jako způsob odhadu distribuce vstupních hodnot (fuzzy shlukování algoritmem K-středu), pak jako mechanismus usuzování (fuzzy inferenční systém, základem kterého je báze fuzzy pravidel a funkce příslušnosti premis a úsudků pravidel, podle kterých se provádí fuzzifikace/defuzzifikace). Celkem jsou navrženy 4 klasifikátory, lišící se konfigurací fuzzy inferenčního systému, který je základem každého z klasifikátorů. První dva klasifikátory pro usuzování o stavu mikrosněpanku či ne (relaxace/není relaxace) používají pásmo alfa spektrogramu EEG signálu. Třetí klasifikátor je doplněn pravidly stanovícími rozhodování na základě delta pásma. Tedy umožňuje klasifikaci již třech stavů: mentace, relaxace a somnolence (první klasifikátor stavu mentace a relaxace rozlišit neumí a zařazuje je do stavu „není relaxace“). Čtvrtý klasifikátor má rozhodovací mechanismus zahrnující všechna energetická pásma. Všechny klasifikátory provádí usuzování na základě Mamdaniho inference, defuzzifikace je realizována metodou těžiště.

Klasifikátory pracující s pásmem alfa jsou otestovány na 30 signálech sejmutých v laboratoři ÚBMI. Výsledky jsou kvantitativně zhodnoceny. Klasifikátory mají opačné hodnoty senzitivity a specifity: první klasifikátor je charakterizován senzitivitou 97%, specificitou 78%, druhý má 75% senzitivitu a 98% specificitu. Tyto údaje však nezahrnují procento vzorků, které nejsou zařazené klasifikátory do žádné skupiny. Přítomnost takových vzorků je dána tím, že algoritmus zpracování neobsahuje pravidla přiřazení do skupin jednotlivých vzorků anebo krátkých sekvencí „oscilujících“ vzorků, ležících mezi různými skupinami.

Funkčnost třetího a čtvrtého klasifikátorů je ověřena pomocí simulovaného signálu. Samozřejmě výsledky jsou v daném případě moc dobré, protože signál má energetický spektrum ideálně odpovídající všem teoretickým podkladům, uváděcím závislost spektra na stavu člověka.

Uvažovaný přístup ke klasifikaci mikrosněpanku je realizován a implementován prostřednictvím programového vybavení počítače. Je vytvořen uživatelský program s grafickým rozhraním.

Návazností na prezentovanou práci by mohlo být hledání dalších metod s cílem zvýšit klasifikační účinnost z pohledu správně detekovaných vzorků reprezentujících stav mikrosněpanku. Samozřejmě hlavním požadavkem na zpracovávané signály je přítomnost projevů mikrosněpanku (pravděpodobně by to bylo možné při měření za speciálních podmínek: delší doba snímání signálu, simulace nějaké unavující činnosti, případná deprivace spánku apod.). Nezbytnou je spolupráce s neurofyziologem, který by stanovil pravidla usuzování pro každý konkrétní případ, navrhnul tzv. zlatý standard, podle kterého by se dalo provést objektivní hodnocení metody.

Seznam použité literatury

- [1] ANUFRIEV, I.: *Priloženija GUI i deskriptornaja grafika*. [cit. 2009-02-12]. Dostupné z WWW: <<http://matlab.exponenta.ru/gui/index.php>>
- [2] BATYRŠIN, I.: *Osnovnye operacii nečjotkoj logiky i ich obobšenija*. [cit. 2009-02-15]. Dostupné z WWW: <http://fuzzysset.narod.ru/Book_2001.html/>
- [3] DONÁT, J., FABER, J.: *Metoda kontinuálního sledování spektrálních pásem EEG signálů*. [cit. 2008-02-29]. Dostupné z WWW: <<http://www.solen.cz/pdfs/neu/2005/01/08.pdf>>
- [4] DVOŘÁK, J.: *Zpracování neurčitosti. Fuzzy přístupy*. [cit. 2009-04-11]. Dostupné z WWW: <<http://www.uai.fme.vutbr.cz/~jdvorak/vyuka/es/Fuzzy.ppt>>
- [5] HOFFMANN, P., MARŠÁLEK, T., MATOUŠEK, V., MAUNTER, P., MERTA, M.: *Predikce mikrosopánku na základě analýzy EEG signálu*. [cit. 2008-10-21]. Dostupné z WWW: <<http://hilbert.chtf.stuba.sk/KUZV/download/kuzv-hoffmann-marsalek-matousek.pdf>>
- [6] CHUMAN, J.: *Modelování nelineárních systémů pomocí algoritmů shlukové analýzy*. Bakalářská práce. Praha, 2006 [cit. 2009-04-05]. Dostupné z WWW: <http://dce.felk.cvut.cz/knihovna/diplomky/2006/bp_2006_chuman_jiri/bp_2006_chuman_jiri.pdf>
- [7] JAN, J.: *Číslicová filtrace, analýza a restaurace signálů*. 2. vydání. Brno: Vysoké učení technické, 2002. 427 s. ISBN 80-214-2911-9.
- [8] KELBEL, J., ŠILHÁN, D.: *Shluková analýza*, [cit. 2009-02-10]. Dostupné z WWW: <<http://gerstner.felk.cvut.cz/biolab/X33BMI/slides/KMeans.pdf>>
- [9] KETKOV, J., KETKOV, A., ŠULC, M.: *MATLAB 7: programirovanie, číslennye metody*. Sankt-Peterburg: BHV-Peterburg, 2005 [cit. 2009-01-06]. Dostupné z WWW: <http://ketkov_ju_ketkov_a_shulc_m__matlab_7_programirovanie.html>
- [10] KOTOV, A., KRASILNIKOV, N.: *Klasterizacija dannyh*. [cit. 2009-01-15]. Dostupné z WWW: <<http://logic.pdmi.ras.ru/~yura/internet/02ia-seminar-note.pdf>>
- [11] KOZUMPLÍK, J., KOLÁŘ, R., JAN, J.: *Číslicové zpracování signálů v prostředí Matlab 1*. vydání. Brno: Vysoké učení technické, 2001. 72 s. ISBN 80-214-1964-4.
- [12] MERTA, M., MATOUŠEK, V.: *Klasifikace vybraných stavů osoby analýzou EEG záznamů*. [cit. 2008-02-20]. Dostupné z WWW: <<http://hilbert.chtf.stuba.sk/KUZV/download/kuzv-merta-matousek.pdf>>
- [13] NOVÁK, M., FABER, J., SVOBODA, P., TATARINOV, V., TICHÝ, T.: *Spánek za volantem?* [cit. 2008-03-25]. Dostupné z WWW: <<http://www.tigis.cz/prac/Index.htm>>
- [14] NOVÁK, M., VOTRUBA, Z., FABER, J.: *Jak ohrožuje pokles pozornosti řidičů vozidel bezpečnost jízdy*, [cit. 08-10-09]. Dostupné z WWW: <<http://filip.fd.cvut.cz/>>

- pdf/pokles_pozornosti_ridice.pdf?PHPSESSID=205dabfa6130e5e04ac20e0d2de7e8 >
- [15] PÍCHA, B.: *ALPHA MONITOR*. Diplomová práce. Brno, 2007.
 - [16] PROKŠ, J.: *Zpracování a analýza EEG*. [cit.2008-11-11]. Dostupné z WWW: <http://dsp.vscht.cz/konference_matlab/matlab02/proks.pdf>
 - [17] SLAVÍK, J.: *EEG Workshop*, [cit 2008-02-29]. Dostupné z WWW: <<http://www.volny.cz/slavi/j/DokumentaceHTML/Dokumentace.htm>>
 - [18] SVATOŠ, J.: *Biologické signály. I, Geneze, zpracování a analýza*. 2. vydání. Praha: České vysoké učení technické, 1998. 202 s. ISBN 80-01-01822-9.
 - [19] ŠTOVBA, S.: *Proektirovanie nečjotkich sistem sredstvami MATLAB*. Moskva: Gorjačaja linija Telekom, 2007. 288 s. ISBN 5-93517-359-X. Dostupné z WWW: <http://mirknig.com/2007/08/22/proektirovanie_nechetkikh_sistem_sredstvami_MATLAB.html>
 - [20] ŠTOVBA, S.: *Vvedenije v teoriju nečjotkich množestv i nečjotkuju logiku*. [cit. 2009-02-12]. Dostupné z WWW: <<http://matlab.exponenta.ru/fuzzylogic/book1/index.php>>
 - [21] VJATČENIN, D.: *Nečjotkije metody avtomatičeskoj klassifikacii*. Minsk: UP «Těchnoprint», 2004. 219 s. ISBN 985-464-529-0. Dostupné z WWW: <<http://mirknig.com/knigi/1181165633-nechetkie-metody-avtomaticheskij.html>>
 - [22] VOJTĚCH, Z.: *EEG v epileptologii dospělých*. 1. vydání. Praha: Grada, 2005. 680 s. ISBN 80-247-0690-3.
 - [23] ŽADIN, M.: *Biofizičeskie osnovy formirovanija elektroencefalogrammy*. Moskva: Nauka, 1984. Dostupné z WWW: <http://mirknig.com/2007/08/23/biofizicheskie_osnovy_formirovanija_jelektrojencefalogrammy.html>
 - [24] ŽÁK, L.: *Jeden ze způsobů zpracování nepřesných dat*. [cit. 2009-02-16]. Dostupné z WWW: <http://www.volny.cz/elzet/Libor/F_Shluk.pdf>
 - [25] ŽÁK, L.: *Shluková analýza I*. [cit. 2009-02-14]. Dostupné z WWW: <http://www.volny.cz/elzet/Libor/Aut_cl_1.pdf>
 - [26] ŽÁK, L.: *Shluková analýza III*. [cit. 2009-02-14]. Dostupné z WWW: <http://www.volny.cz/elzet/Libor/Aut_cl_3.pdf>

Použité zkratky

COA	Center Of Area
DFT	Discrete Fourier transform
EEG	elektroencefalografie
EMG	elektromyografie
EOG	elektrookulografie
FCM	Fuzzy C-means
FEKT	Fakulta elektrotechniky a komunikačních technologií
FIS	Fuzzy Inference System
FN	false negative
FOM	First Of Maxima
FP	false positive
GUIDE	Graphical User Interface Development Environment
GUI	Graphic User Interface
MOM	Mean Of Maxima
REM	Rapid Eye Movement
STFT	Short-time Fourier transform
TN	true negative
TNR	true negative rate
TP	true positive
TPR	true positive rate
ÚBMI	Ústav biomedicínského a ekologického inženýrství
VUT	Vysoké učení technické v Brně