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

AUTOMATICKÁ DETEKCE GRAFOELEMENTŮ VE SPÁNKOVÝCH SIGNÁLECH EEG

DIPLOMOVÁ PRÁCE
MASTER'S THESIS

AUTOR PRÁCE Bc. ANEŽKA BALCAROVÁ
AUTHOR

BRNO 2015

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

AUTOMATICKÁ DETEKCE GRAFOELEMENTŮ VE SPÁNKOVÝCH SIGNÁLECH EEG

AUTOMATIC DETECTION OF GRAPHOELEMENTS IN SLEEP EEG

DIPLOMOVÁ PRÁCE
MASTER'S THESIS

AUTOR PRÁCE Bc. ANEŽKA BALCAROVÁ
AUTHOR

VEDOUCÍ PRÁCE doc. Ing. JIŘÍ KOZUMPLÍK, CSc.
SUPERVISOR

BRNO 2015

VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

Ústav biomedicínského inženýrství

Diplomová práce

magisterský navazující studijní obor
Biomedicínské a ekologické inženýrství

Studentka:	Bc. Anežka Balcarová	***ID:***	124996
Ročník:	2	***Akademický rok:***	2014/2015

NÁZEV TÉMATU:

Automatická detekce grafoelementů ve spánkových signálech EEG

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s principy rozpoznání jednotlivých spánkových stádií ze signálů EEG a s grafoelementy, které se v těchto signálech vyskytují. 2) Prostudujte metody detekce K-komplexů. 3) Vyberte alespoň dvě metody a realizujte je na vybraných úsecích signálu EEG. 4) Ověřte funkčnost a spolehlivost realizovaných metod na dodaných polysomnografických signálech s vyznačenými úseky korespondujícími s jednotlivými spánkovými stádii. 5) Vypracujte studii shrnující výsledky práce.

DOPORUČENÁ LITERATURA:

[1] DUMAN F., ERDAMAR A., EROGUL O., TELATAR Z., YETKIN S. Efficient sleep spindle detection algorithm with decision tree. Expert Systems with Applications, Vol. 36, 2009, pp. 9980–9985.
[2] ERDAMAR A., DUMAN F., YETKIN S. A wavelet and teager energy operator based method for automatic detection of K-Complex in sleep EEG. Expert Systems with Applications, Vol. 39, 2012, pp. 1284–1290.

Termín zadání:	9.2.2015	***Termín odevzdání:***	22.5.2015

Vedoucí práce: doc. Ing. Jiří Kozumplík, CSc.
Konzultanti diplomové práce:

prof. Ing. Ivo Provazník, Ph.D.
Předseda oborové rady

UPOZORNĚNÍ:

Prohlášení

Prohlašuji, že svou diplomovou práci na téma Automatická detekce grafoelementů ve spánkových signálech EEG jsem vypracoval 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 autorka uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením tohoto projektu jsem neporušila autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědoma 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 .....

podpis autora

Poděkování

Děkuji vedoucímu diplomové práce doc. Ing. Jiřímu Kozumplíkovi, CSc. za účinnou metodickou, pedagogickou a odbornou pomoc a nesmírnou trpělivost při zpracování mé diplomové práce.

V Brně dne .....

podpis autora

Abstrakt:

Tato práce je zaměřena na spánkový signál EEG, především na vyhledávání spánkových grafoelementů a dále také na zpracování signálu, které této segmentaci předchází. Jsou zde nastíněny charakteristiky spánkových grafoelementů, metody detekce spánkových grafoelementů a problémy spjaté s jejich klasifikací.

Principy dvou vybraných metod detekce k-komplexu jsou vysvětleny a zpracovány v prostředí MATLAB. Výsledky automatické detekce K-komplexů pomocí vybraných metod jsou srovnány s výsledky klasifikace dvou expertů.

Klíčová slova:

Elektroencefalograf (EEG), Polysomnografie (PSG), spánkové grafoelementy, K-komplex, Target Energy Operator (TEO), vlnková transformace

Abstract:

This project is aimed at sleeping EEG signal, especially at searching of sleeping graphoelements and next at processing signal, witch this segmentation go before. Charakterization of sleeping graphoelements and problems with their classification are outlined here.

Principle of two detection methods of k-komplex are explained and processed by Matlab with graphically representation of results. Results of automatic classification are compared with scoring of two experts.

Key words:

Elektroencefalograf (EEG), Polysomnography (PSG), sleeping graphoelements, K-komplex, Target Energy Operator (TEO), Wavelet transform

Bibliografická citace:

BALCAROVÁ, A. Automatická detekce grafoelementů ve spánkových signálech EEG. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2015. 64 s. Vedoucí diplomové práce doc. Ing. Jiří Kozumplík, CSc..

Obsah

Úvod

Spánková elektroencefalografie nese spoustu užitečných informací o spánkových stádiích, potažmo o fyziologii a patofyziologii spánku. Během spánku získáváme dlouhé záznamy aktivity mozku a je třeba se v nich správně orientovat. Vzhledem k tomuto velkému objemu dat a časové náročnosti při hodnocení spánkového EEG medicínskými odborníky se v poslední době klade důraz na vývoj programů, které by napomáhaly medicínským odborníkům při této klasifikaci.

Automatické detektory, které hrají v současné době podpůrnou roli v hodnocení spánkového EEG, využívají různé algoritmy pro detekci grafoelementů. S postupem času se detektory zdokonalují, avšak dosud nejsou schopny nahradit hodnocení medicínským odborníkem.

Tato práce se snaží nastínit problematiku automatické detekce grafoelementů ve spánkovém EEG a provést tuto detekci K-komplexu pomocí dvou vytvořených automatických detektorů. Automatické detektory využívají v této práci dvou metod, jeden detektor je založený na výpočtu operátoru TEO a aplikaci rozhodovacích parametrů a druhý na rozkladu signálu vlnkovou transformací a následné aplikaci rozhodovacích parametrů.

Obě tyto metody jsou srovnány s ohodnocenými K-komplexy, které byly získány od dvou různých expertů a výsledky jsou statisticky zpracovány a okomentovány.

Polysomnografie PSG

Polysomnografie je diagnostická vyšetřovací metoda zabývající se vyšetřením spánku. Záznam EEG ve spánkovém záznamu slouží především k rozpoznání bdělosti a jednotlivých stádií spánku, které lze určit pomocí rozkmitu, frekvence a tvaru EEG vln *[1]*.

Standardizované polysomnografické vyšetření obvykle obsahuje záznam EEG, EOG, EMG, EKG, pulzní oxymetr, měření průtoku vzduchu (orální a nasální), snímání dýchacího úsilí břicha a hrudníku, snímání pohybu končetin a snímání chrápání. Speciální vyšetření potom mohou obsahovat přídavné modality jako rozšířené EEG, jícnový manometr, monitor oxidu uhličitého, snímač pH jícnu a další *[2]*.

Základní modality pro vyšetření spánkových stádií jsou EEG, EOG a EMG. Tyto pak napomáhají k odhalení různých spánkových poruch *[2]*.

Snímání EEG

Používané elektrody jsou většinou kruhové stříbrné, pokryté vrstvou chloridu stříbrného tzv. Ag/AgCl elektrody.

Přechodový odpor mezi elektrodou a pokožkou pacienta by měl být menší než 3 $k\Omega$, proto se pokožka nejdříve odmastí a poté se do otvoru kruhových elektrod nanáší vodivý gel. Při snímání EEG je potřeba přechodový odpor sledovat.

Rozmístění elektrod (Obrázek 1) při PSG vyšetření je standardní mezinárodní rozmístění 10 / 20 (jak v sagitální, tak koronární rovině jsou elektrody rozloženy tak že v každé pomyslné linii jsou vzdáleny 10 – 20 – 20 – 20 – 20 – 10 % její celkové délky) *[3]*. PSG měření používá k měření EEG pouze elektrody centrální C3 a C4 dále jsou párové elektrody okcipitální a frontální nahrazeny nepárovými elektrodami Oz okcipitální, Pz parietální, Cz centrální, Fz frontální, Fpz frontální referenční elektroda a M1, M2 jako referenční elektrody k centrálním elektrodám *[4]*.

EEG signál

EEG signál lze považovat za realizaci náhodného procesu (stochastický proces), jeho vlastnosti lze vypočítat pomocí statistických operací z jedné realizace (ergodický proces) tak, že průměrujeme vzorky v čase. O EEG signálu můžeme dále říct, že je po částech stacionární (kvazistacionární) *[14]*.

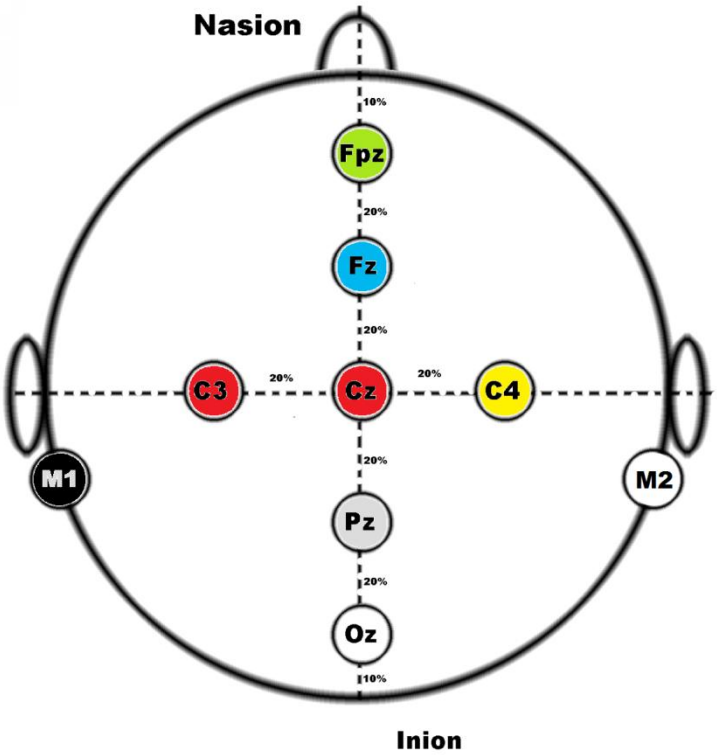

Obrázek 1: Rozmístění elektrod při PSG EEG *[5]*

Spánek

Spánek je fázický, periodicky se opakující stav určitého aktivačního stupně CNS. Je reverzibilní, je jednou z forem vědomí, opakem bdělosti, převažují v něm anabolické pochody. Pro organismus je nezbytný, a to jak pro funkce tělesné, tak pro potřeby psychické. Spánek není z hlediska fyziologického ani psychického homogenní. V dnešní době má již dobře zjištěnou architekturu. Kvalita spánku souvisí s kvalitou vigility (definice spánku podle Doc. MUDr. Karela Hyneka, CSc., Univerzita Karlova v Praze, 1. LF a VFN, Psychiatrická klinika).

Fáze spánku

Jsou a byly hodnoceny podle nejrůznějších skórovacích systémů. Jednotlivé spánková stádia mají svá specifika, která umožňují skórovacím systémům zařadit stav, ve kterém se pacient nachází, do jednotlivých fází.

Základní rozdělení fází spánku je na fázi REM a fázi NREM

V roce 2007 byl American Academy of Sleep Medicine (AASM) sestaven nový standardní systém hodnocení spánkových fází. Hlavní změnou bylo definování stavu bdělosti W a úpravy v jednotlivých fází NREM. Podle tohoto standardu tedy rozeznáváme fáze W (bdělý stav), N1 až N3 fáze (NREM fáze) a R fázi (REM), které jsou znázorněné na obrázku (Obrázek 2).

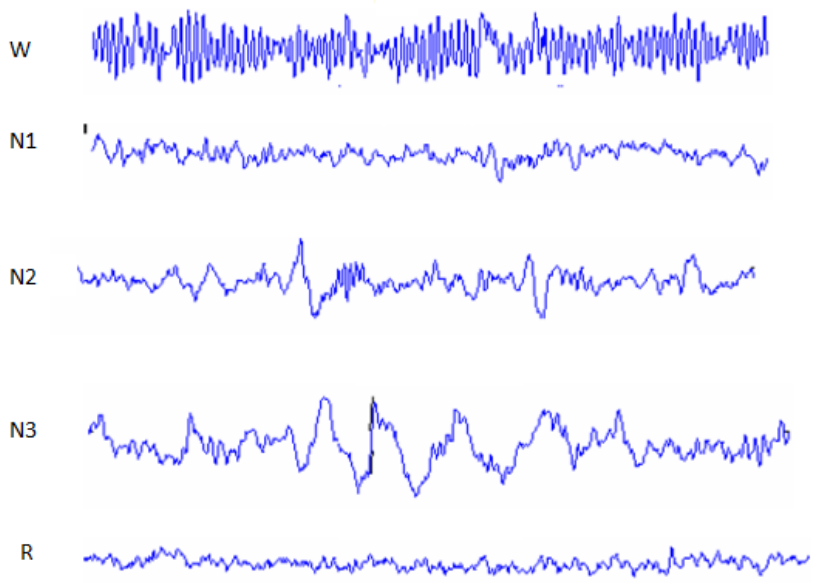

Obrázek 2: Ukázka jednotlivých fází spánku podle AASM

Fáze W

Stádium bdělosti, pro kterou je charakteristická nízká úroveň aktivity. Při zavřených očích je skórována za fázi W, právě když je sledována alfa aktivita alespoň v 50 % epochy *[6]*. Při otevřených očích se v záznamu vyskytuje aktivita beta.

Fáze NREM

Fáze Non Rapid Eyes Movement

- N1 - Fáze lehkého spánku, pro kterou je charakteristické nízký rozkmit signálu, frekvence 2 – 7 *Hz* (četné vlny theta) a ostré vertexové vlny *[3]*.
  Epocha je rozpoznána jako N1 fáze při poklesu alfa aktivity pod 50% spektrálního pásma *[6]*.
  Převážně ve frontálním mozkovém laloku lze pozorovat spánková vřetena, která probíhají přibližně v 18 – 25 cyklech za sekundu. Lze je identifikovat jako skupinu rytmických vln postupně rostoucí poté pozvolně klesající výchylky *[7]*.

- N2 – Fáze charakteristická spánkovými vřeteny o frekvenci 9 – 14 *Hz* (sigma aktivita) a četnými K-komplexy *[3]*.
  Tato fáze tvoří 40 až 50 % z celého spánku. Během druhé fáze se vlny zpomalují, vyskytují se občasné nárazy rychlých vln. Pomalé frekvence, které většinou převládají, se pohybují od 0,7 do 4 cyklů za sekundu (u dětí jsou extrémy vyšší s velice nápadnými týlními píky, které s věkem postupně klesají) *[7]*.

- N3 – Fáze byla dříve označována jako dvě samostatné fáze NREM3 a NREM4. Dohromady tvoří více než 20 % celkového spánku.
  Během fáze ustává svalová aktivita a pohyby očí a člověka lze v této fázi jen těžko probudit. Člověk probuzený během této fáze se cítí unavený a dezorientovaný a trvá několik minut než je schopný vstát *[7]*.
  Fáze je bohatá na delta vlny (do 2 *Hz*, minimálně 75 μV), jejich zastoupení je 20 – 50 % epochy u NREM3 a více než 50 % u NREM4 *[3], [8]*. Spánková vřetena jsou stále přítomna s frekvencí 12 až 14 *Hz*, avšak jejich výskyt mizí s přibývající hloubkou spánku *[7]*.

Fáze REM

Fáze Rapid Eyes Movement

Fáze s nízkým rozkmitem signálu a frekvenčně nepravidelnou desynchronizovanou aktivitou (někdy pilové vlny 2 až 6 *Hz*). Záznam EOG ukazuje rychlé pohyby očí, jak již napovídá název REM, tepová a dechová frekvence vzrůstá a svalové kontrakce mizí (nastává téměř paralytický stav). Tato fáze je doprovázena sněním. Paralýza u pacientů s poruchou REM spánku (RBD – REM sleep behaviour disorder) je narušena, což způsobuje pacientům obtíže, jako jsou živé sny, mluvení čí křik ze spaní, záškuby, posed, kopání, mlácení pažemi, skákání z postele atd. *[3], [7]*.

REM spánek představuje 20 až 25 % celkového spánku. Následuje po NREM spánku a nastává během normálního 8 – 9 hodinového spánku 4 – 5x. V extrémních individuálních případech může být REM fáze velice krátká, někdy dokonce může nastat i její absence. Při hodnocení této fáze nás zajímá mimo jiné i doba mezi začátkem spánku a první fází REM spánku (první fáze REM spánku by měla nastat mezi 60 – 90 minutami od začátku spánku) *[7]*.

V této fázy nelze pozorovat K-komplexy a spánková vřetena.

Archytektura spánku - Hypnogram

Spánek je organizován do cyklů (70 – 100 minut), které se během spánku opakují (4 – 6 cyklů za noc). V jednotlivých cyklech se podle určitých pravidel střídají REM a NREM fáze. Polysomnografická data jsou pomocí skórovacích metod rozpoznána jako určité fáze. Skórování je prováděno v třicetisekundových epochách.

Hypnogram získáme, přiřadíme-li jednotlivým epochám jejich spánková stádia. Na hypnogramu pak je přehledně vykreslena celonoční architektura s jednotlivými cykly (Obrázek 3). Pomocí hypnogramu je následně možné diagnostikovat určitá spánková i jiná onemocnění na základě atypické distribuce spánkových stádií. Bylo vědecky dokázáno, že

například změny v délce trvání REM spánku mohou doprovázet psychické stavy, jako jsou deprese a sebevražedné sklony, či další psychická onemocnění jako je schizofrenie *[7]*.

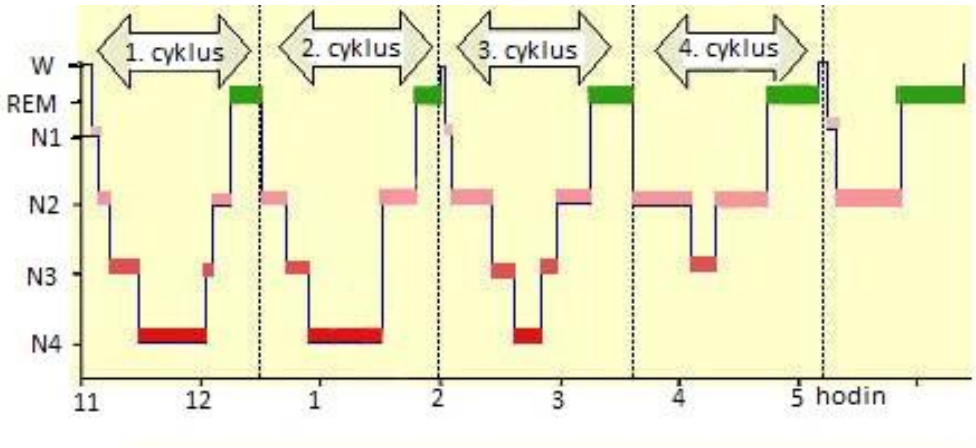

Obrázek 3: Architektura spánku

Klasifikace EEG aktivity

Pro klasifikaci je velmi důležité správně rozeznat jednotlivé elementy EEG, které utvářejí EEG křivku u jak zdravých jedinců, tak jedinců s onemocněním CNS. Odborník musí správně klasifikovat, zda je EEG záznam normální či abnormální, zda je-li kontaminovaný artefakty. Kritéria „normality“ byla stanovena na základě rozsáhlých studií na velkém množství zdravých pacientů, kteří neměli žádné potíže. Hranice mezi normálními a abnormálními záznamy je však velice tenká a musíme na tuto skutečnost brát zřetel.

Hlediska hodnocení aktivity

Při klasifikaci hodnotíme následující hlediska *[9]* :

- Frekvenci [Hz] – počet opakování vln za jednu vteřinu či trvání jedné vlny za milisekundu
- Absolutní rozkmit signálu [μV] – od nejnižší záporné po nejvyšší kladnou výchylku
  - Suprese – snížení rozkmitu, může být patologickým projevem
  - Hypersynchronie – vzestup rozkmitu zapříčiněný zmnožením počtu neuronů
  - Paroxysmální aktivita – přerušuje stávající charakter křivky, je náhlým nástupem vyššího extrému (i několikanásobně) oproti předcházejícímu a následovné aktivitě, rychle odeznívá
- Tvar vln (morfologie)
  - Monomorfní – EEG aktivita je tvořena pouze jednou frekvencí (často sinusoidní)
  - Polymorfní – EEG aktivita je tvořena směsí frekvencí
  - Sinusoidní – EEG aktivita je tvořena sinusoidními vlnami
  - Transient – typická skupina vln nebo ojedinělá vlna, která se odlišuje od základní aktivity (PŘ: hrot, ostrá vlna)
  - Komplex – seskupení dvou či více vln stejné nebo i různé frekvence odlišující se od základní aktivity (PŘ: K-komplex)
  - Bifasická vlna – má dva vrcholy, tj. vrchol pozitivní a vrchol negativní
- Množství aktivity – zastoupení určité aktivity z hlediska trvání a pravidelnosti
  - Kontinuální – výskyt jedné aktivity bez přerušení
  - Intermitentní – výskyt jedné aktivity pouze v krátkých úsecích
  - Pravidelná aktivita – aktivita má stabilní frekvenci
  - Nepravidelná aktivita – aktivita má nestabilní frekvenci
- Lokalizace – upřesnění výskytu aktivity či grafoelementů, např:
  - Generalizovaná – aktivita se vyskytuje ve všech svodech
  - Laterální – aktivita se vyskytuje nad levou hemisférou
  - Bilaterální – aktivita se vyskytuje oboustranně od určitého místa
  - Ložisková – aktivita se vyskytuje v určitém přesném místě

- Symetrická – aktivita se vyskytuje ve stejné kvantitě i kvalitě na obou stranách (symetricky) nad určitou oblastí
- Periodická – aktivita se může vyskytovat v určitých oblastech periodicky

Typy aktivity

Pro správnou klasifikaci EEG je důležité znát charakteristické vlny a další útvary, které signalizují určitou změnu stavu mozkové činnosti pacienta. Charakteristika vln se s věkem mění. Některé vlny, které jsou například v dětství naprosto fyziologické, mohou být patologické v dospělosti.

Tabulka (Tabulka 1) a obrázek (Obrázek 4) ukazuje charakteristiky základních pěti mozkových aktivit.

Tabulka 1: Přehled základních aktivit a jejich charakteristiky u dospělého člověka *[10], [9], [7]*

rytmus	frekvence [Hz]	rozkmit [µV]	popis	lokalizace
delta	0,5 až 4	do 100	Primárně spjatý s hlubokým spánkem. Fyziologický u novorozenců, zatímco u bdělých dospělých patologický.	difúzní
theta	4 až 7,5	do 150	Vyskytuje se při usínání poté přechází v delta rytmus. Spojuje se také s hlubokou meditací. Větší výskyt u bdělých dospělých je patologický.	frontálně, centrálně
alfa	8 až 13	do 50	Vyjadřuje stav klidu (relaxace, zavřené oči), je citlivým indikátorem změn vigility, již při pouhé ospalosti frekvence poklesá a dochází k rozpadu alfa rytmu s příměsí theta vln.	okcipitálně
beta	14 až 26	do 30	Indikuje duševní činnost, soustředění, analytické myšlení. Při stresu a panických stavech je patrná vyšší úroveň beta aktivity.	frontálně
gama	30 až 45	velmi nízký rozkmit do 10	Souvislost se stresovými mechanizmy a anxietou. Někdy se také označují jako rychlé beta vlny.	centrálně, okcipitálně

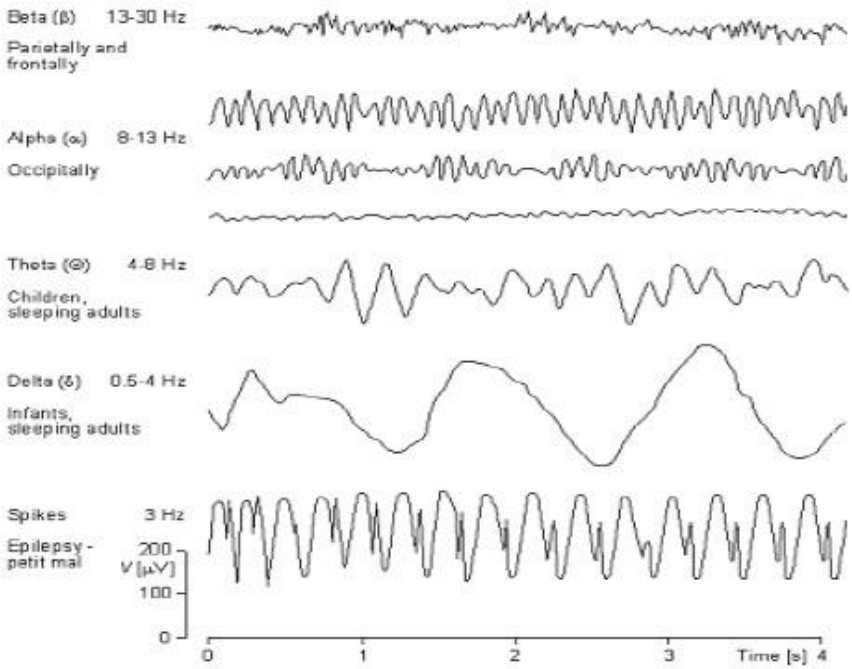

Obrázek 4: Charakteristické vlny EEG *[10]*

Grafoelementy EEG

Další vlnové tvary, které se ojediněle vyskytují v EEG, se nazývají grafoelementy *[13]*.

Pro odborníka je důležité tyto grafoelementy dokonale znát, jelikož jejich výskyt v záznamu vypovídá jednak o kvalitě záznamu EEG (z hlediska artefaktů) jednak o specifické biologické činnosti mozku (fyziologie, patofyziologie CNS).

Grafoelementy podle původu a významu dělíme na *[13]*:

- Artefakty technické – Signály vznikající jako projev technického zařízení, které je součástí EEG zařízení nebo jeho okolí. Můžeme rozlišovat artefakty z elektrod, z přístroje, z vnějšího rušení, …
- Artefakty biologické – Signály vznikající v elektrodách z biologických projevů jako je např. mrkání, polykání, pohyby očí, …
- Projevy specifické biologické činnosti mozku
    - Fyziologické – Vyskytují se například ve spánkových stádiích – vertexové vlny, K-komplexy,…
    - Patofyziologické – Poukazují na patologii CNS – hroty, komplexy hrot-vlna, polymorfní delta rytmus, ostré vlny …

Spánkové grafoelementy

Hlavními spánkovými grafoelementy, které napomáhají ke klasifikaci jednotlivých spánkových stádií, jsou spánková vřetena a K-komplexy.

Spánková vřetena (sigma rytmus)

Definice dle glosáře termínů běžně používaných odborníky na elektroencefalografii:

Spánkové vřeteno je definováno jako náraz o frekvenci 11 až 15 *Hz*, ale většinou 12 až 14 *Hz*. Nastává během spánku, zpravidla je globálně rozšířené, ale vykazuje vyšší rozkmit signálu nad centrální oblastí hlavy. Rozkmit kolísá, ale většinou se v dospělosti pohybuje kolem 50 μV *[15]*.

Je pro něj charakteristický postupný vzestup a poté pozvolné snižování rozkmitu (Obrázek 5). Častěji se vyskytují během fází lehkého spánku, ačkoli je ověřený i jejich výskyt v NREM3 a NREM4 fázích hlubokého spánku, a trvá po dobu 2 až 3 sekund *[16]*.

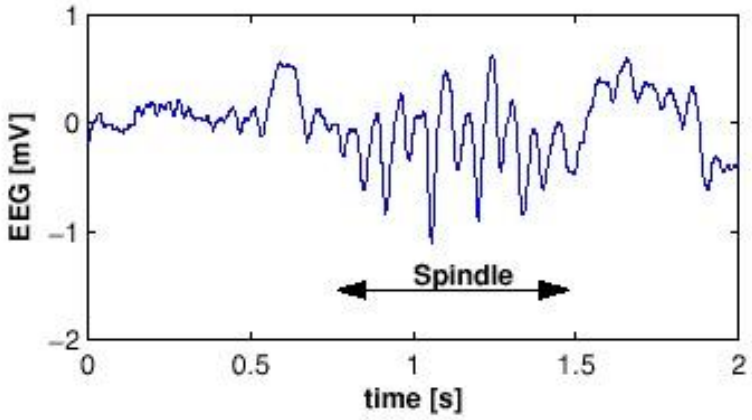

Obrázek 5: Charakteristický průběh spánkového vřetene

K-komplexy

Definice dle glosáře termínů běžně používaných odborníky na elektroencefalografii:

K-komplex je definován jako náraz poněkud variabilního vzezření, skládající se obyčejně z negativní pomalé vlny vysokého rozkmitu následované menší pozitivní pomalou vlnou, často spojený se spánkovým vřetenem (Obrázek 6). Rozkmit dosahuje maxima frontálně. K-komplex se vyskytuje během NREM spánku spontánně nebo jako odezva na náhlý smyslový stimul (není specifický pro žádnou smyslovou modalitu) *[15]*.

K-komplexy nevznikají pouze spontánně, ale také jako odpověď na kortikální, talamický či smyslový podnět. Pouze spontánně buzené K-komplexy jsou získávány pomocí záznamu v bezzvukovém prostředí, kde by výskyt evokovaných K-komplexů měl být spíše ojedinělý.

Určení K-komplexu se potýká s řadou obtíží - zapojení elektrod, problémy s diferenčním systémem, nastavením filtrace,… Zvláště bipolární snímání je nevhodné vzhledem k odčítání signálů. Neurologická aktivita podporující vznik K-komplexu se rozkládá na rozsáhlé kortikální oblasti. Bipolární elektrody detekují diferenci mezi rozkmity signálu v různých kortikálních místech. Pokud jsou tyto diference malé, což pro většinu případů K-komplexů jsou, zaznamenaný signál bude mít malý rozkmit a nejasnou polaritu, takže K-komplex nebude rozeznán *[16]*.

Vzhledem k relativně mlhavé definici a všem obtížím při určení K-komplexu byla vytvořena databáze charakteristických znaků K-komplexu a potažmo algoritmy automatické detekce *[16]*.

Vznik k-komplexu na buněčné úrovni

Ke správné klasifikaci K-komplexu je třeba znát souvislosti na buněčné úrovni. Dříve se totiž klasifikace prováděla pouze podle studií, které definovali tvary K-komplexů a často požadovali návaznost spánkových vřeten (dnes již víme, že toto kritérium nemusí být splněno, aby šlo o plnohodnotný K-komplex). Studia zabývající se vznikem K-komplexu na buněčné úrovni ukázali správnou cestu k nalezení správných klasifikačních metod *[16]*.

Neuronový membránový potenciál K-komplexu se pohybuje mezi dvěma voltážemi hladinami. Fáze depolarizace je řízena aktivitou sympatik, hyperpolarizační fáze je charakteristická absencí síťové aktivity. Tyto dvě hladiny membránového potenciálu tedy korespondují s bifázickým charakterem K-komplexu *[16]*.

Oblast depolarizace, která odráží synchronní excitaci rozsáhlé oblasti neuronů, je extracelulárně reflektována jako oblast negativního potenciálu. Vertikální dendrity pyramidových neuronů navrací tyto hluboké proudy na kortikální povrch, kde je detekována pozitivní vlna. Tak je tedy spojena první komponenta K-komplexu (pozitivní vlna) s depolarizační fází *[16]*.

Během druhé fáze (hyperpolarizace), která je doprovázena prudkým snížením extracelulární koncentrace Ca^{2+} , je v kortikální síti snížena synaptická účinnost a facilitace neuronů. Synchronní hyperpolarizace neuronů je odrážena jako pozitivní vlna potenciálu dané oblasti a na kortikálním povrchu detekujeme negativní vlnu. Tato fáze reprezentuje druhou komponentu bifázické vlny K-komplexu *[16]*.

Z těchto poznatků vyplývá, že se K-komplex vyskytuje s frekvencí menší než 1 *Hz* (především v rozmezí 0,6 až 0,9 *Hz*).

Malý posun frekvence pomalých oscilací, stejně jako tvarové modifikace, které doprovází měnící se hloubku spánku, mohou být vysvětleny s přihlédnutím na vnitřní vlastnosti neuronových membrán. Míra progresivní hyperpolarizace thalamokortikálních neuronů

koreluje s hloubkou spánku a ovlivňuje postupnou redukci doby trvání depolarizační fáze pomalých kortikálních oscilací spolu s urychlením rytmu (což ovlivňuje tvar a oscilační frekvenci). Pro hlubší stádia spánku pomalých vln (NREM3 a NREM4, Obrázek 6) je tedy nutné rozšířit kritéria rozpoznání K-komplexů, jelikož v těchto fázích se frekvence K-komplexů zvedá a může se překrývat s pásmem delta vln a tím jsou K-komplexy hůře rozpoznatelné *[16]*.

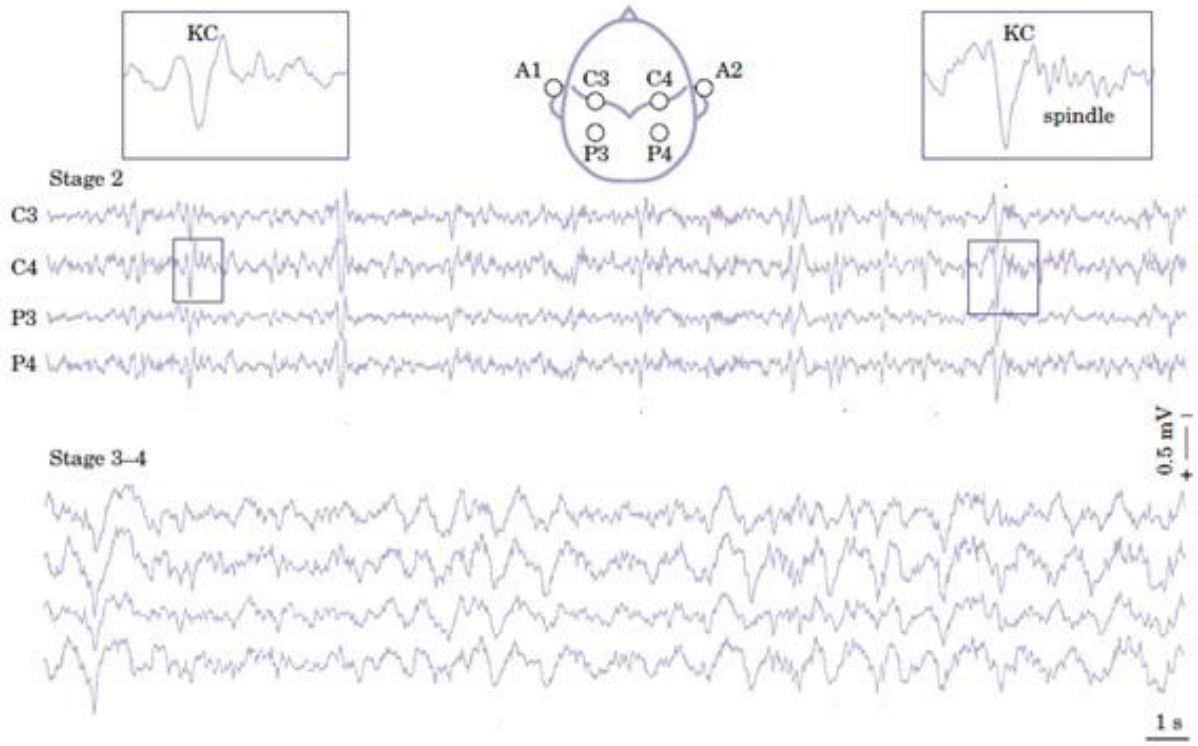

Obrázek 6: K-komplexy během N2 a N3 fáze *[16]*

Buněčné napětí, které je podkladem pro vznik K-komplexů, je synapticky přenášeno do thalamu, kde spouští spánkové skupinové oscilace jako jsou spánková vřetena a vnitřní talamické delta vlny.

Automatická detekce

Automatická detekce spánkových grafoelementů slouží jako podpora hodnocení spánkového EEG odbornými medicínskými pracovníky. Vzhledem k rozsáhlému objemu dat, která jsou během snímání spánkového EEG získána, napomáhá automatická detekce k rychlosti hodnocení těchto záznamů. Výhodou automatických detektorů oproti odborníkovi je tedy především rychlost klasifikace a absence subjektivního hodnocení. Nicméně, poslední slovo v hodnocení EEG má vždy lidský odborník.

Předzpracování signálu

Samotnou automatickou klasifikaci předchází řada operací a úprav signálu, které napomáhají správné a úspěšné klasifikaci.

Jedná se zejména o odstranění artefaktů, které se mohou v signálu vyskytovat a segmentaci signálu.

Ve spánkovém EEG se vyskytují zajímavé složky signálu ve frekvenčním pásmu rozsahu 0,5 až 35 *Hz* a je třeba toto frekvenční pásmo zbavit rušivých artefaktů.

Artefakty jsou podle původu děleny na:

- Biologické, původcem je z organismu pacienta
  Pro EEG jsou hlavními biologickými rušivými artefakty pohyby očí, mrkání, svalová a srdeční aktivita.
- Technické, původcem jsou technické komponenty EEG, okolní technické zařízení, elektrická síť, atd.
  Pro EEG jsou hlavními technickými rušivými artefakty kolísání nulové izolinie způsobené pohyby elektrod a síťový brum.

Po odstranění rušivých artefaktů je nutná segmentace signálu. Segmentace vychází z charakteru EEG signálu. EEG signál je nestacionární signál (tzn., že jeho charakteristiky se v čase mění) a pro jeho hodnocení je nutné získat stacionární úseky.

Segmentaci rozdělujeme podle délky stacionárního úseku na segmentaci:

- Konstantní, segmenty mají stejnou délku
  Předpokládáme kvazi-stacionaritu signálu. Výhodou této segmentace je, že všechny segmenty mají stejnou délku *[14]*.
- Adaptivní, segmenty mají různou délku
  Segmenty mají různou délku podle stacionarity signálu. Výhodou je právě zaručená stacionarita v jednotlivých úsecích, nevýhodou je pak různá délka úseků.

Použité algoritmy automatické detekce spánkových grafoelementů

Automatická detekce spánkového EEG využívá řadu algoritmů, které byly během času zdokonalovány. V dnešní době se hojně využívá například vlnkové transformace, fuzzy příslušnosti a neuronových sítí.

Tato práce je inspirovaná článkem *A wavelet and teager energy operator based method for automatic detection of K-Complex in sleep EEG [18]*. Jak název napovídá, jedná se o detekci využívající vlnkovou transformaci a TEO.

Nejlépe patrné jsou K-komplexy na záznamu kanálu C3M2, který je v této práci pro detekci využíván *[18]*.

Detekce s využitím TEO

Target Energy Operator (TEO) se využívá při zpracování signálu jako operátor energie. TEO na výstupu zvyšuje okamžité změny signálu, to znamená, že dojde ke zvýšení rozkmitu a frekvence v signálu. Naopak, TEO potlačuje jemné přechody a aktivitu pozadí porovnává s okolními operátory.

TEO vychází z první a druhé derivace spojitého signálu v čase. Pro diskrétní signál se využívá aproximace času na vzorky a vyjadřuje se jako:

$$\psi_{Ts}(n) = \psi_s^{\,2}(n) - \psi_s(n-1)\psi_s(n+1) \ , \qquad (1)$$

kde $\psi_{Ts}(n)$ je výstup TEO *n*-tého vzorku a $\psi_s(n)$ popisuje hodnotu n-tého vzorku původního signalu *[18]*.

Algoritmus detekce K-komplexu s využitím TEO

1. Předzpracování signálu vybraného kanálu C3M2 pomocí Butterworthovým filtrem typu dolní propusti 10-tého řádu s ostrým přechodem a mezní frekvencí 5 *Hz*.
   Tímto filtrováním odstraníme rušivé průběhy vyšších frekvencí, jako jsou například rušivé EMG a nižších frekvencí jako jsou například pohyby očí.
2. Aplikace algoritmu TEO na filtrovaný signál.
   Aplikací TEO se zvýrazní ostré přechody a utlumí činnost pozadí.
3. Aplikace rozhodovacích parametrů na TEO signál (Obrázek 7). Hodnoty rozhodovacích parametrů byly získány experimentálně *[18]*.
   - Hraniční minimální hodnota píku pro detekci $A_{th} > 30\ \mu V^2$
   - Minimální doba trvání *t1* 350 *ms*
     Prezentuje minimální dobu trvání kladné vlny K-komplexu na nulové linii.

- Minimální doba trvání *t2* 50 *ms*
  Prezentuje minimální dobu trvání kladné vlny K-komplexu na linii hraniční minimální hodnoty píku A_{th}.

4. Vyhodnocení vlny jako K-komplexu, pokud splňuje všechny podmínky stanovené rozhodovacími parametry.

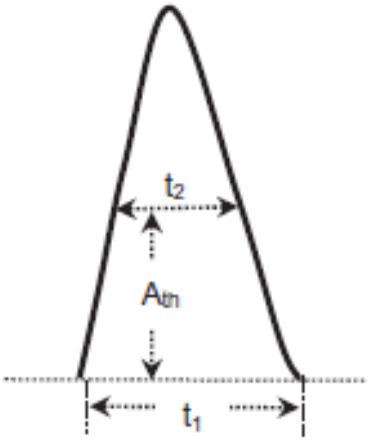

Obrázek 7: Rozhodovací parametry TEO *[18]*

Detekce s využitím vlnkové transformace

Vlnková transformace je efektivní metodou pro zpracování nestacionárních signálů ve frekvenční oblasti. Nejedná se o jedinou transformaci, ale o souhrn transformací vzájemně se lišících podle tvaru bázové funkce, která bývá označována jako tzv. vlnka. Mateřská vlnka (bázová funkce) má nenulové hodnoty pouze na konečném časovém intervalu, a proto je kterákoli hodnota spektra ovlivněna pouze odpovídajícím úsekem analyzovaného signálu. Vlnková transformace tedy umožňuje časovou lokalizaci událostí v získaném spektru *[19]*.

Vlnková transformace s diskrétním časem (DTWT), je odvozena ze spojité vlnkové transformace pro diskrétní báze. Nevýhodou DTWT však je, že není invariantní vůči posunu v čase, to znamená, že DTWT je závislá na volbě počátku transformovaného signálu a tudíž DTWT verze signálu *x(n)* není rovna posunuté verzi DTWT signálu *x(n)*. Pro odstranění této nevýhody vznikla stacionární vlnková transformace (SWT), která na rozdíl od DTWT neprovádí decimaci (podvzorkování) signálu a v důsledku toho jsou délky signálu všech úrovní signálu stejně dlouhé jako signál původní. Modifikace filtrů v každém stupni rozkladu se provádí zředěním jejich impulzních charakteristik nulami *[21]*.

V prvním kroku prochází originální signál *x(n)* filtrem typu dolní propust *g(n)* a filtrem typu horní propust *h(n),* které vychází z výchozí formulace vlnky (Obrázek 8). Horní propust poskytuje koeficienty tzv. detailů *D* a dolní propust koeficienty tzv. aproximace *A*. Na rozdíl od DTWT nedochází u SWT u výstupů filtrů k podvzorkování *[20]*.

Koeficienty aproximace lze dalším stupněm filtrů, získáme tak další stupeň rozkladu tzn. další soubor koeficientů aproximace a detailů. Takto lze pokračovat do vyčerpání vstupní sekvence. Dostáváme tedy zvolený počet rozkladu signálu bez decimace se stejnou délkou sekvence jako originální signál *[20]*, *[21]*.

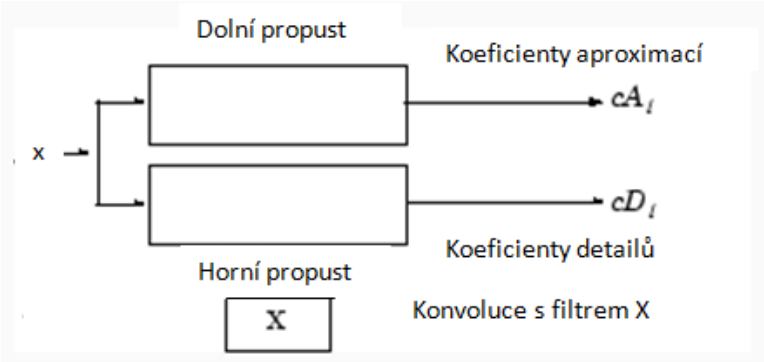

Obrázek 8: První krok rozkladu SWT

Algoritmus detekce K-komplexu s využitím VT

1. Aplikace SWT na signál.
   Provedeme čtyři stupně rozkladu pomocí stacionární vlnkové transformace s využitím vlnky (bázové funkce) sym4 z rodiny Symlet (Obrázek 9), která se svým tvarem přibližuje tvaru K-komplexu. Tato bázová funkce se čtyřmi stupni rozkladu je převzata ze článku *A wavelet and teager energy operator based method for automatic detection of K-Complex in sleep EEG [18]*.

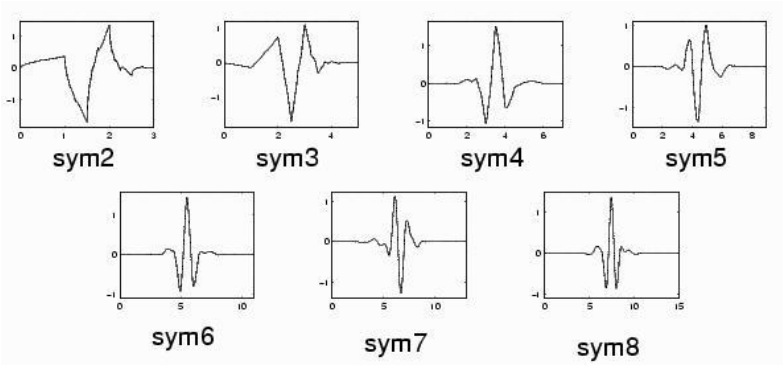

Obrázek 9: Tvary bázových funkcí rodiny Symlet

Tyto čtyři stupně rozkladu jsou znázorněny na obrázku (Obrázek 10).

Z rozkladu vlnkovou transformací získáváme soubory koeficientů aproximací a detailů v jednotlivých frekvenčních pásmech. Pro nás je stěžejní pásmo 0 – 6,25 *Hz*, které jsme získali čtyřstupňovým rozkladem. Jelikož se K-komplexy vyskytují s frekvencí kolem 1 *Hz* (do 2 *Hz*), je toto pásmo dostatečné, abychom neztratili potřebné detaily, a zároveň se zbavíme rušivých signálů o vyšších frekvencích *[18]*.

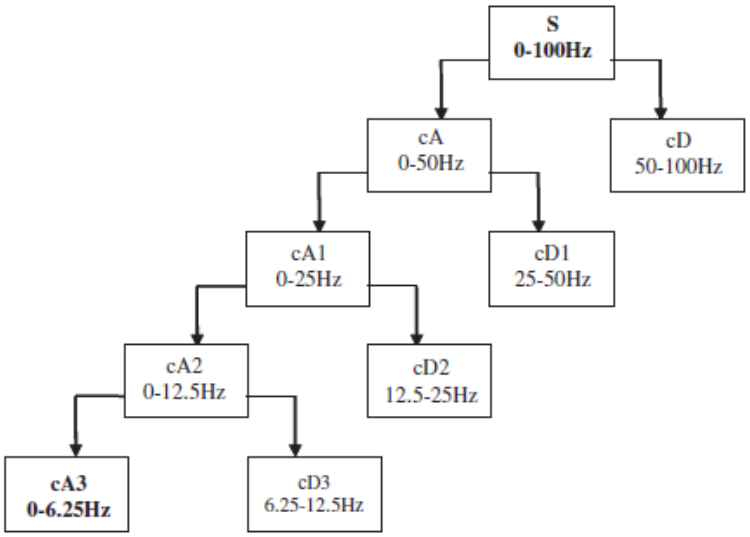

Obrázek 10: Čtyři stupně rozkladu VT *[18]*

2. Aplikace rozhodovacích parametrů na signál výsledného pásma.
   Rozhodovací parametry jsou názorně zobrazeny na obrázku (Obrázek 11) a jsou jimi:
   - Doba trvání t_{total}
     Je součtem doby trvání negativní a pozitivní vlny K-komplexu, vyjádřena jako: $t_{total} = t_{negative} + t_{positive}$ a t_{total} musí být v rozmezí 0,5 až 1,5 s.
   - Doba trvání $t_{negative}$
     Je dobou trvání negativní vlnky K-komplexu na nulové linii a musí být delší než $t_{total} / 4$.
   - Doba trvání $t_{positive}$
     Je dobou trvání pozitivní vlnky K-komplexu na nulové linii a musí být delší než $t_{total} / 4$.

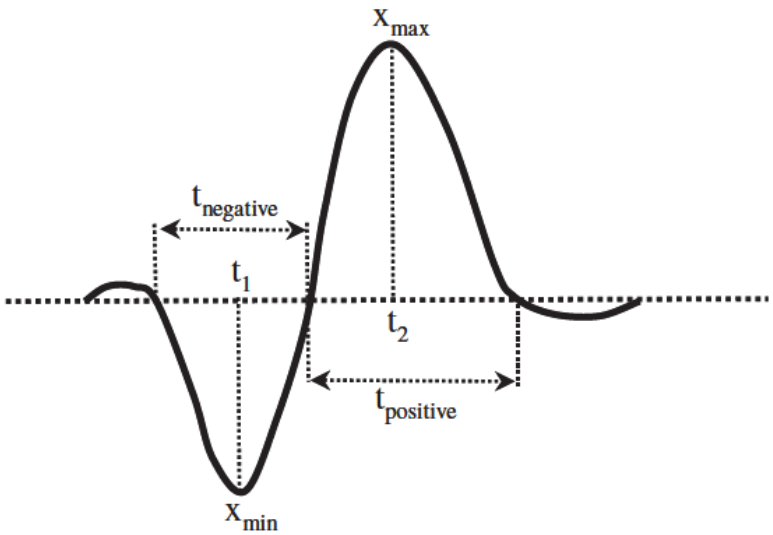

Obrázek 11: Rozhodovací parametry VT *[18]*

3. Kontrola sklonu K-komplexu.

   Sklon K-komplexu by měl být větší než 100 μV za 0,5 s. Vypočítáme ho jako:

   $$Sklon = \frac{(x_{\max} - x_{\min})}{(t_2 - t_1)}, \qquad (2)$$

   kde x_{max} je maximální rozkmit signálu v pozitivní vlně a x_{min} je minimální hodnota rozkmitu signálu v negativní vlně.

4. Vyhodnocení vlny jako K-komplexu, pokud splňuje všechny podmínky stanovené rozhodovacími parametry a projde kontrolou sklonu.

Signál použitý při vývoji automatických detektorů

Pro vývoj automatických detektorů a porovnání detekce s hypnogramem jsou v práci užity pacientské záznamy signálů EEG, které byly sejmuty v rámci studie RELIEF v Kardiovaskulárním spánkovém centru, Nemocnice u Svaté Anny.

K dispozici bylo získáno pět celonočních záznamů EEG, z něhož je v této práci použit pacientský záznam *009.mat* (byl vybrán zcela náhodně). Samozřejmé je, že je možná detekce spánkových grafoelementů pomocí vytvořeného programu v EEG ve kterémkoli z poskytnutých pacientských záznamů (*009.mat, 022.mat, 030.mat, 038.mat, 050.mat*).

Pacientský záznam obsahuje všechny snímané kanály PSG, pro práci jsou důležité pouze kanály EEG, a hypnogram. V rámci této studie byly snímány čtyři kanály EEG a to Fz-Cz, Cz-Oz, C3-M2, C4-M1(viz dříve Obrázek 1).

Hypnogram zobrazuje skóre signálu, je prováděno v epochách po třiceti sekundách, a zařazuje jednotlivé epochy do spánkových stádií. Označení spánkových stádií je uvedeno v následující tabulce (Tabulka 2).

Tabulka 2: Označení spánkových fází v hypnogramu

označení v hypnogramu	označení fáze spánku
0	W bdělost
1	N1
2	N2
3	N3
5	REM
9	nezařaditelné epochy

Z kanálů EEG je vybrán C3M2, ve kterém by měli být K-komplexy zřetelné *[18]*. Signál je vzorkován vzorkovací frekvencí *256 Hz*. Na spektru tohoto signálu je patrné užití pásmové zádrže na 50 *Hz* (Obrázek 12).

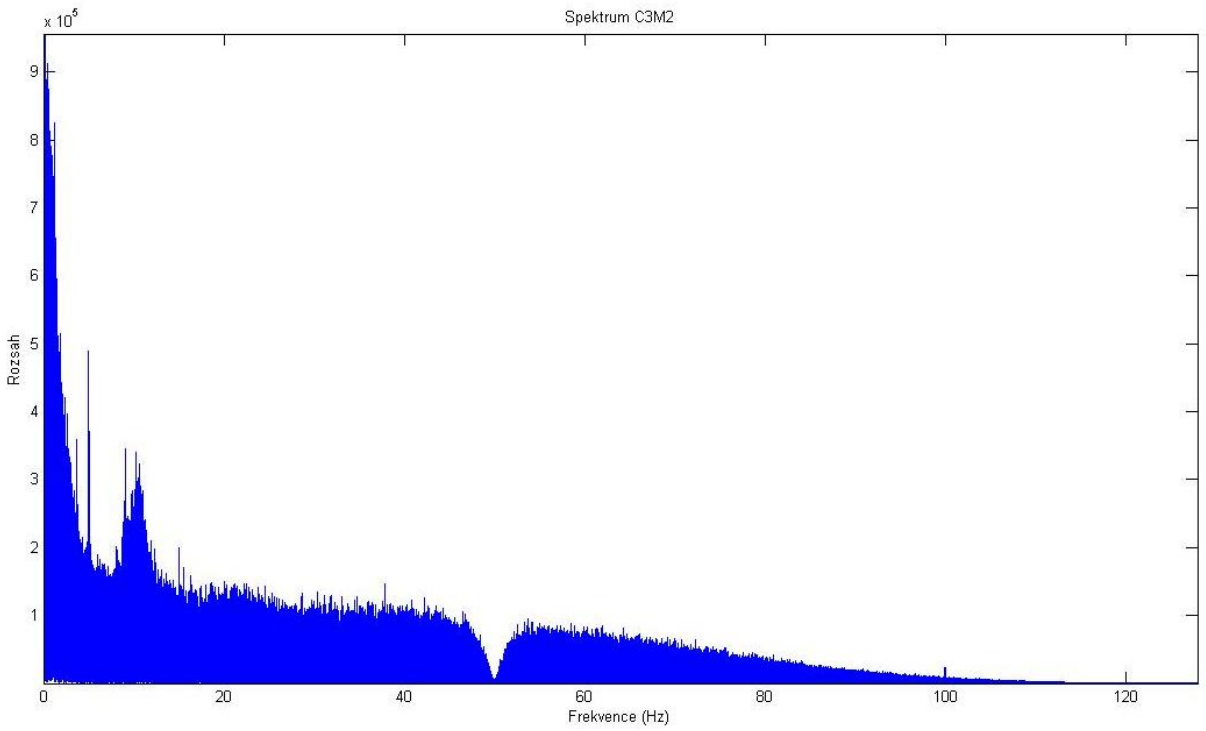

Obrázek 12: spektrum C3M2 signálu

Programové řešení a hodnocení K-komplexů v celonočním záznamu

Skript automatické detekce: *Kkomplex.m*, vzhledem k paměťové velikosti signálu byl pro rychlou demonstraci použit výňatek 3000 *s* a skript upraven pro tento krátký úsek *Kkomplex_demonstrace.m*.

Programové řešení je rozdělené do tří dílčích částí:

- Načtení a úprava potřebných signálů
- Aplikace metody detekce K-komplexu s využitím TEO
- Aplikace metody detekce K-komplexu s využitím VT

Načtení a úprava potřebných signálů

Pro prezentaci programového řešení a výsledků detekce K-komplexů je použit signál *009.mat*, který obsahuje buňkové pole *PSG{10,24}*. Buňkové pole obsahuje jednotlivé signály sejmuté během polysomnografického vyšetření a další doplňující informace.

Pro detekci K-komplexů je vybrán kanál C3M2, který by měl být pro detekci nejvhodnější *[18]*.

Z buňkového pole jsou načteny a vykreslena data hypnogramu se zvýrazněnými epochami N2 fází, pro které jsou K-komplexy charakteristické (Obrázek 13).

Zkrácený záznam pro rychlou demonstraci výsledků *zkraceny_009.mat* obsahuje již zmíněný výňatek signálu EEG.

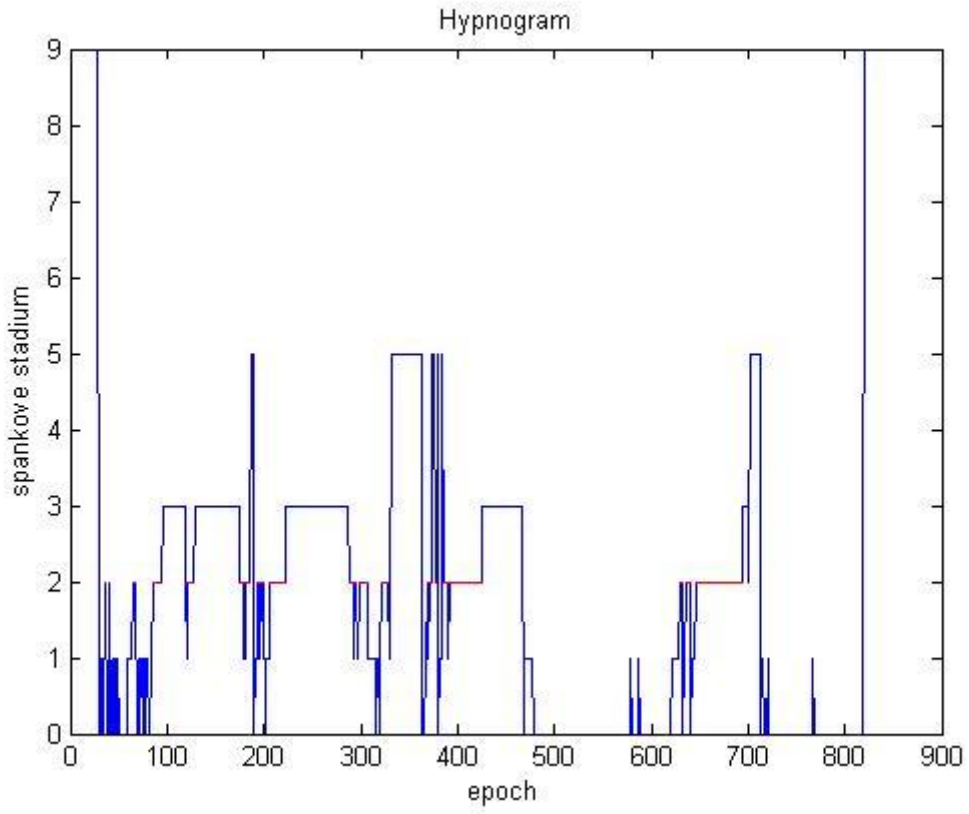

Obrázek 13: Hypnogram 009.mat

Pro hodnocení v čase je zavedena časová osa s krokem jedné sekundy. Signál EEG je snímán se vzorkovací frekvencí 256 vzorků za sekundu. Jeden vzorek tak odpovídá $1/fvz = 1/256 = 0{,}0039s$

```
t = [1/fvz:1/fvz:length(C3M2)*1/fvz];
```

Dále je vytvořena funkce, která umožňuje zadat epochy, se kterými chceme pracovat *(a,b)*, a vrací přepočítané hodnoty začátku, konce a délky vybraného úseku na pořadí a počet vzorků.

```
function [zacatek konec delka]= vyber_useku(a,b)
```

Aplikace metody detekce K-komplexu s využitím TEO

V rámci předzpracování signálu před aplikací TEO je signál filtrován Butterworthovým filtrem typu dolní propust (filtr, který má málo zvlněné frekvenční spektrum a konverguje k nule u maximální frekvence) s mezní frekvencí 5 *Hz* (Obrázek 16, B).

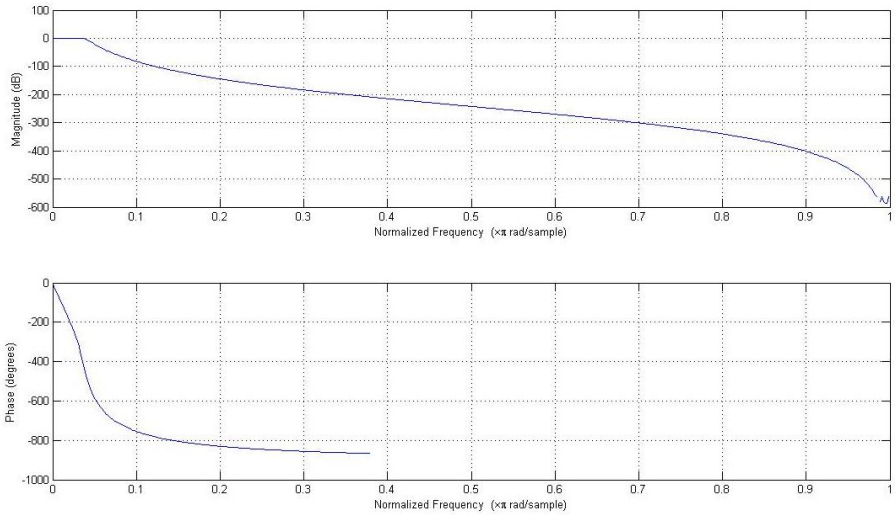

Obrázek 14: Frekvenční charakteristika navrženého Butterworthova filtru

```
fc = 5; % mezni frekvence (Hz)
order = 10; % rad filtru
[B,A] = butter(order,2*fc/fvz); % definovani Butterworthova filtru
Butterworth_C3M2 = filter(B,A,C3M2); % filtrovani signalu
```

Takto filtrovaný signál (Obrázek 15 a 16 C) pak prochází cyklem s rovnicí pro výpočet TEO.

```
TEO_C3M2(k+1) =((Butterworth_C3M2(k+1))^2) - (Butterworth_C3M2(k) *
Butterworth_C3M2(k+2)); % rovnice pro vypocet TEO
```

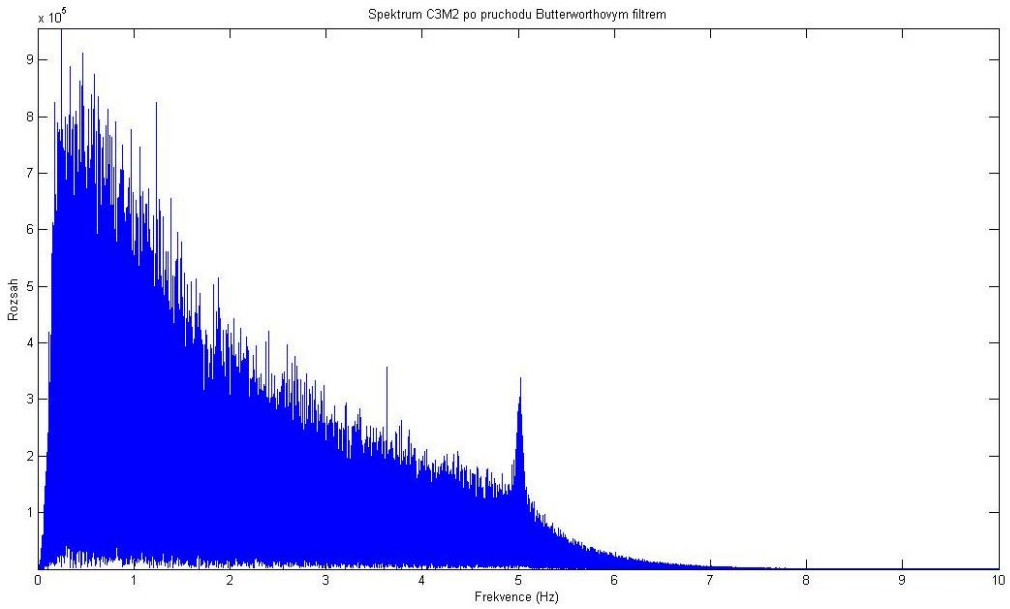

Obrázek 15: Spektrum C3M2 po průchodu Butherworthovým filtrem

TEO zvýrazní rychlé změny v signálu a potlačí pozadí (Obrázek 11, C). Cyklus pro aplikaci rozhodovacích parametrů *T1*, *T2* a *Ath* (popsané dříve) obsahuje tři dílčí cykly:

1. Cyklus projíždí signál, vyhledává úseky signálů minimální délky *T1*, jejichž rozkmit je vyšší než 0 (ověřuje zda je vlna kladná a trvá déle než minimální dobu *T1*).
2. Pokud je vlna kladná a je delší nebo rovna minimální doba trvání *T1* prochází cyklem, který ověřuje, zda se v rámci této vlny najde úsek minimální délky *T2*, jehož vzorky jsou vyšší než *Ath*.
3. Pokud je i tato podmínka splněna, je tento úsek, vyhodnocený jako K-komplex vložen do matice výsledků (Obrázek 11, D).

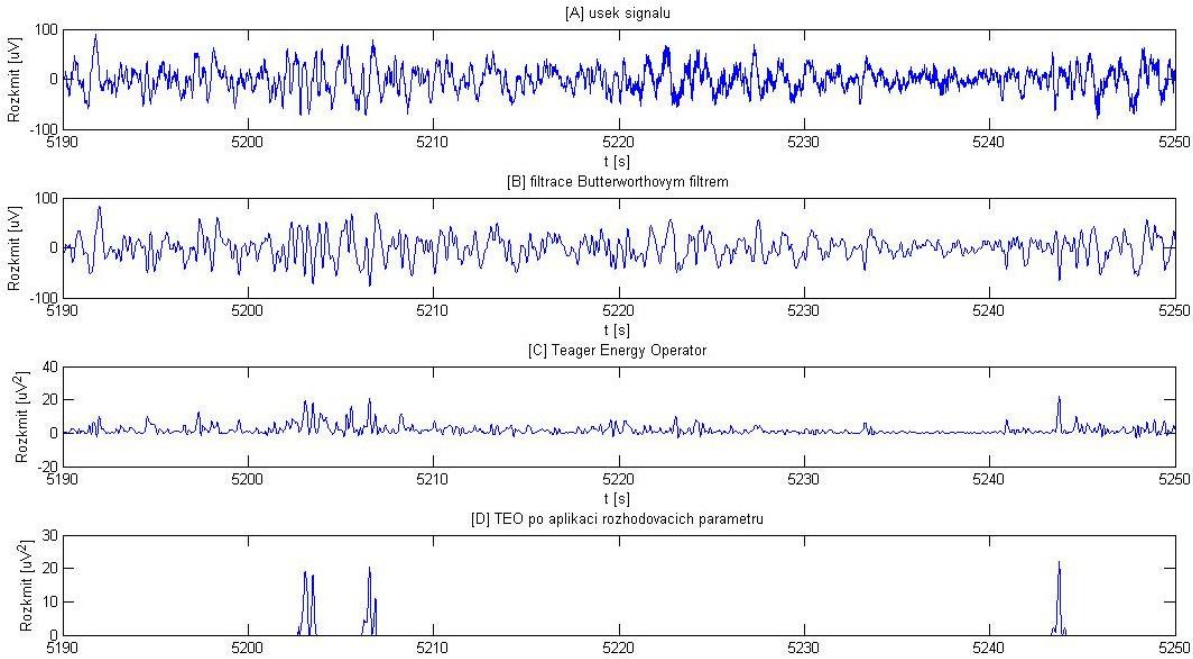

Obrázek 16: A: úsek signálu dvou epoch, B: úsek signálu po filtraci Butterworthovým filtrem, C: úsek signálu po aplikaci TEO, D: vyhodnocené K-komplexy po aplikaci rozhodovacích parametrů

Aplikace metody detekce K-komplexu s využitím VT

Pro programové řešení je použit rozklad stacionární vlnkovou transformací pomocí funkce Matlabu *swt*. Použité jsou čtyři stupně rozkladu a bázová funkce *sym4 [18]*.

```
[WTA,WTD] = swt(C3M2,4,'sym4');
```

Výstupem každého stupně rozkladu je soubor koeficientů aproximací a detailů (Obrázek 17).

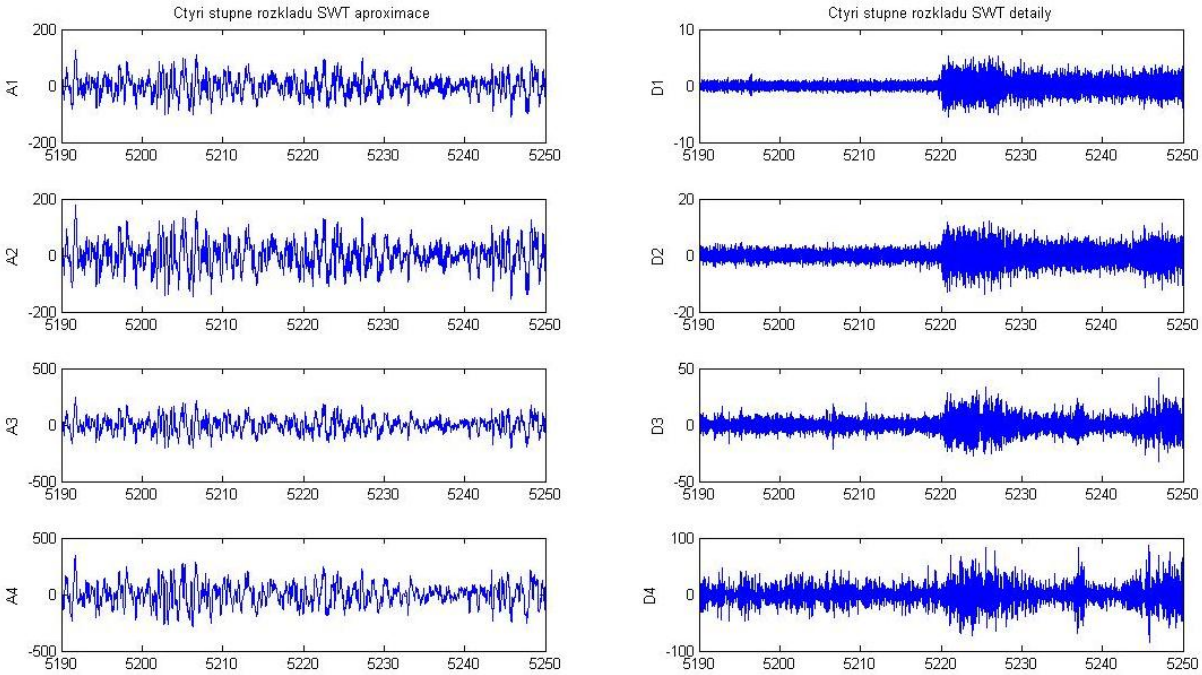

Obrázek 17: Čtyři stupně rozkladu SWT, vpravo detaily jednotlivých stupňů rozkladu, vlevo aproximace jednotlivých stupňů rozkladu

Výstupní pásmo signál je (teoreticky) v rozmezí *0* až *6,25 Hz*.

Rozhodovací parametr t_{total} je definován jako dvě hraniční doby trvání – maximální doba trvání K-komplexu (*ttotalmax*) a minimální doba trvání K-komplexu (*ttotalmin*). Oba časy jsou převedeny na počet vzorků.

```
ttotalmax = ceil(1.5/(1/fvz)); % maximalni cas trvani K komplexu prevedeny
na pocet vzorku
ttotalmin = ceil(0.5/(1/fvz)); % minimalni cas trvani K komplexu prevedeny
na pocet vzorku
```

Tato metoda bere v potaz zápornou a kladnou vlnu K-komplexu, proto je třeba najít místa, kde signál přechází přes nulu – aplikace cyklu, který projíždí signál a hledá přechody přes nulu.
Následující cyklus projíždí signál a kontroluje, zda jsou úseky signálu (vyhodnocené v předešlém cyklu od nuly po nulu), delší nebo rovny *ttotalmin*, kratší nebo rovny *ttotalmax* a dále zda doba trvání záporné a kladné vlny odpovídá podmínce:
$t_{negative} > t_{total} / 4$ a $t_{negative} > t_{total} / 4$
Po ověření dob trvání následují cykly pro vyhledání maxima v kladné a minima v záporné vlně a především jejich poloha.

Pokud úsek signálu splňuje všechny doby trvání K-komplexu, je aplikován poslední rozhodovací parametr, který rozhodne o klasifikaci K-komplexu. Tímto parametrem je sklon mezi zápornou a kladnou vlnou získaného úseku signálu. Pro výpočet sklonu je využita poloha minim a maxim vypočítaná v předešlých cyklech a s ní korespondující hodnota minima a maxima v původním signálu.

```
slope = (signal_max - signal_min)/(poloha_xmax_VT - poloha_xmin_VT);
```

Sklon musí být větší než 100 μV za 0,5 s. Pro program je třeba opět přepočet času na počet vzorků.

```
slope > 100/(ceil(0.5/(1/fvz))) % posuzovani zda je parametr slope vetsi
nez 100uv za 0,5s
```

Pokud je i tato podmínka splněna, je úsek vyhodnocen jako K-komplex a vložen do matice výsledků a vykreslen (Obrázek 18).

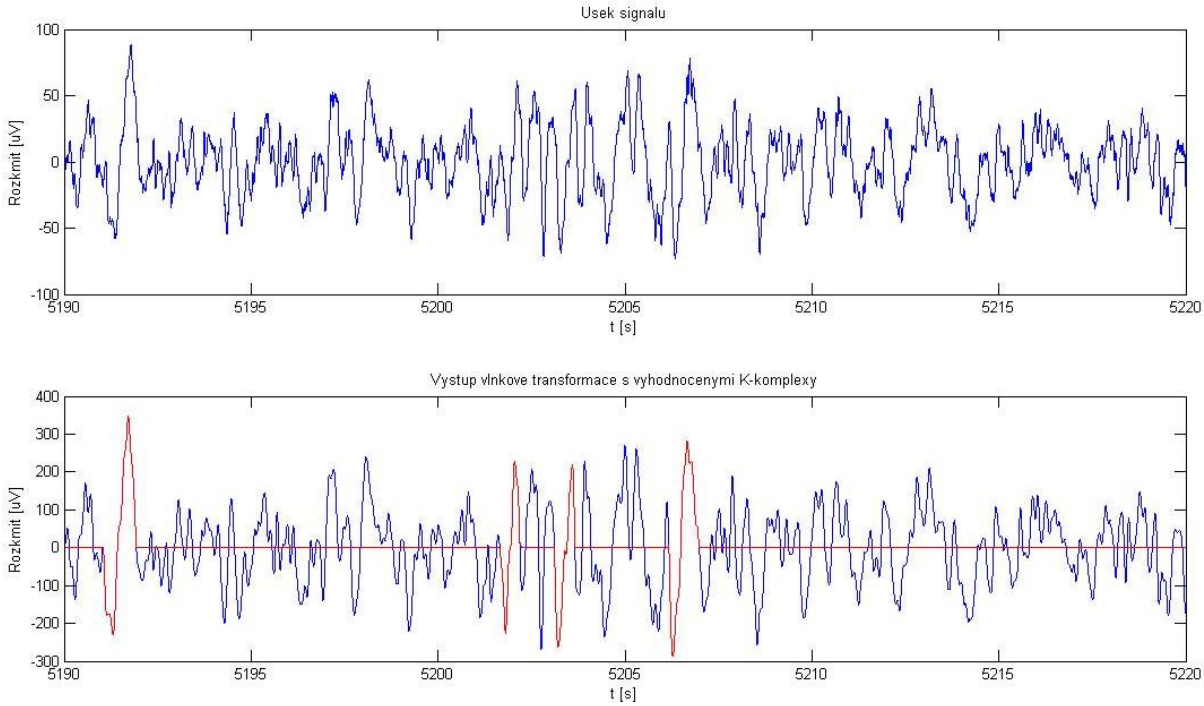

Obrázek 18: Vyhodnocené K-komplexy po splnění všech rozhodovacích parametrů (epochy 173 až 175)

Srovnání automatické detekce celonočního záznamu s hypnogramem

V rámci celonočního záznamu EEG signálu (*009.mat*, kanál C3M2) bylo pomocí vytvořeného programu vyhodnoceno metodou s využitím TEO 141 K-komplexů a metodou s využitím VT 481 K-komplexů (záznam obsahoval náběžnou a sestupnou hranu, která byla v hypnogramu hodnocena jako nezařaditelný úsek, tyto úseky jsou proto z hodnocení vynechány a hodnoceny epochy 29 až 819).

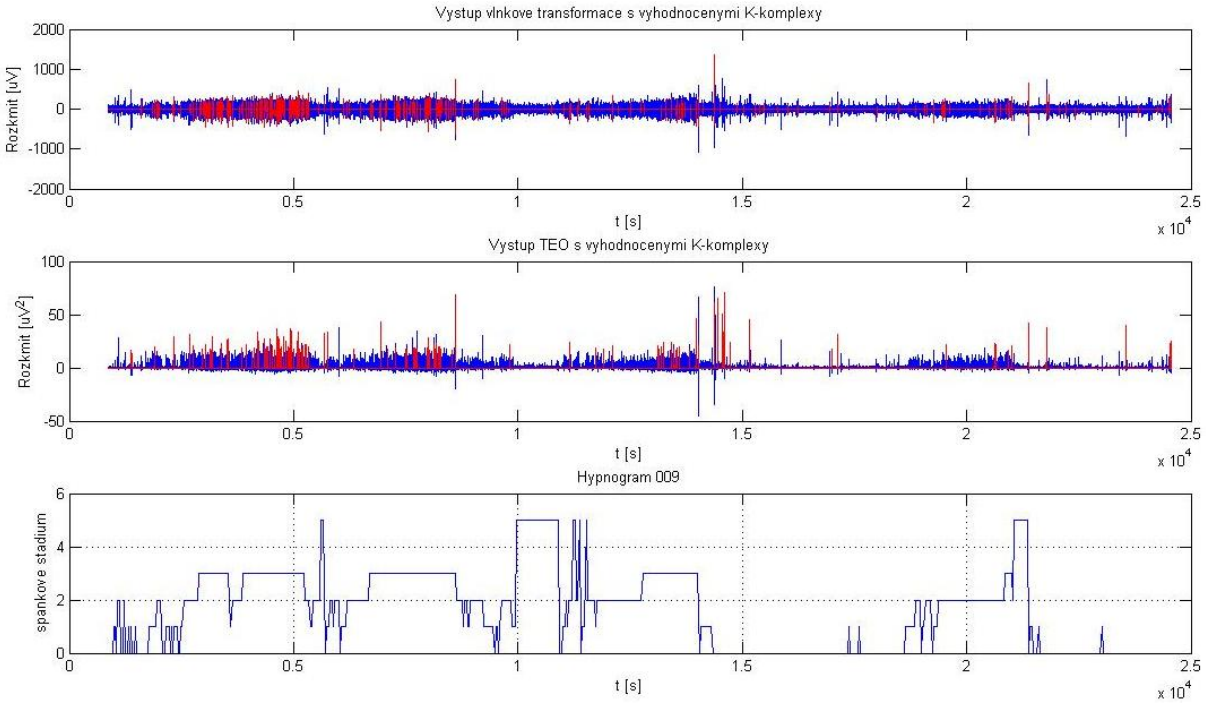

Obrázek 19: Výsledky hodnocení K-komplexů v celonočním záznamu, porovnání s hypnogramem (epochy 29 až 819)

Je vidět, že v celonočním záznamu spánkového EEG jsou K-komplexy sdruženy v určitých oblastech a většinou korelují s N2 a N3 fázemi hypnogramu (Obrázek 19). Programové řešení obou metod hodnotí více K-komplexů v N3 fázi. Ačkoli je výskyt K-komplexů pro obě tyto fáze charakteristický, s přibývající hloubkou spánku (v N3 fázi) přibývá delta aktivita a K-komplexy by měly být hůře rozpoznatelné *[16]*. Vzhledem k tomu by i četnost ohodnocených K-komplexů měla být teoreticky vyšší v N2 fázi, což se programovým řešením nepotvrdilo.

Na následujících obrázcích je vidět hodnocení K-komplexů oběma metodami v N2 (Obrázek 20) a N3(Obrázek 21) fázi spánku. Je patrné, že počet K-komplexů v obou fází spánku stejné délky se liší. Pro N2 fázi spánku v epochách 85 až 95 byly vyhodnoceno TEO metodou 3 a VT metodou 6 K-komplexů. Pro N3 fázi spánku v epochách 266 až 276 bylo vyhodnoceno TEO metodou 10 a VT metodou 13 K-komplexů.

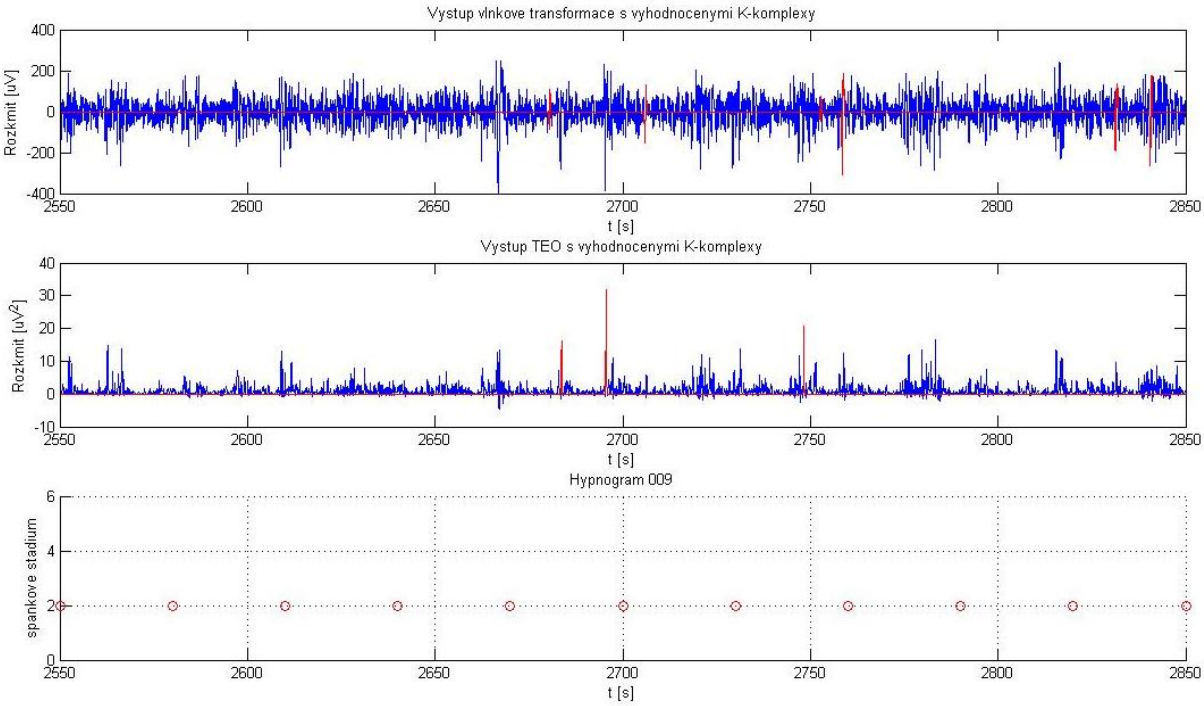

Obrázek 20: Hodnoceni v úseku signálu N2 fáze (epochy 85 až 95)

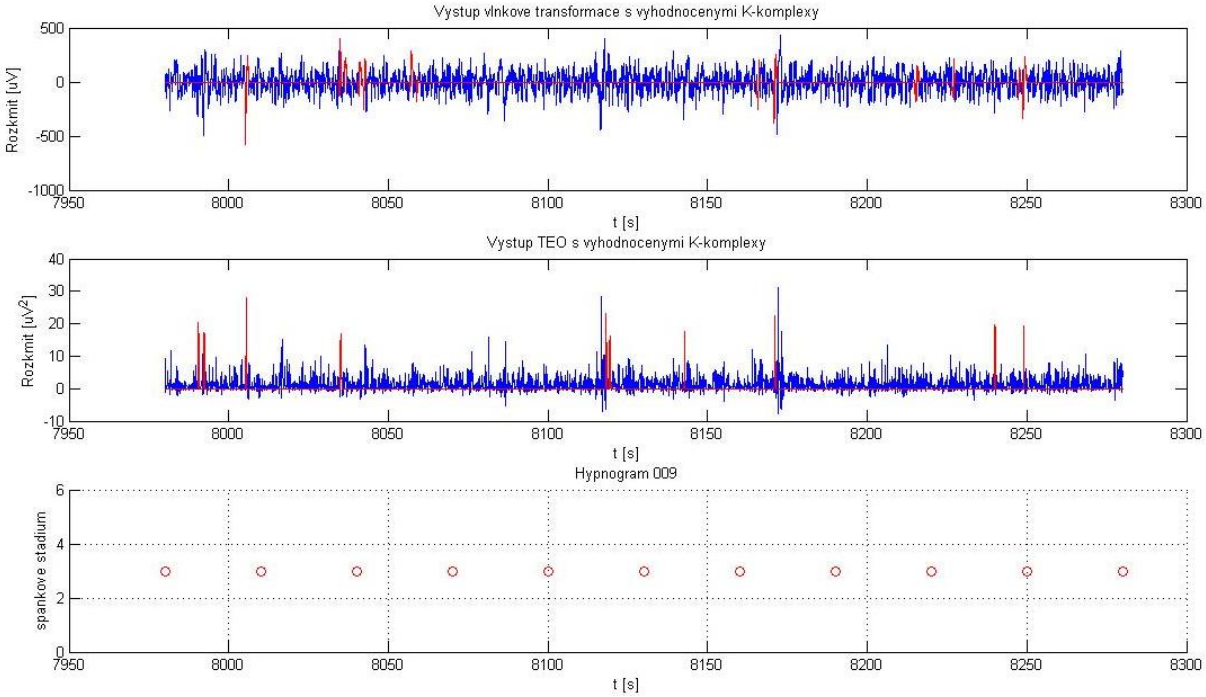

Obrázek 21: Hodnoceni v úseku signálu N3 fáze (epochy 266 až 276)

Ve fázích bdělosti (v hypnogramu 0) a REM fázi (v hypnogramu 5) by měly K-komplexy vymizet (Obrázek 22 a 23). Programové řešení potvrdilo vymizení K-komplexů, výsledky jsou v tomto ohledu téměř stoprocentní.

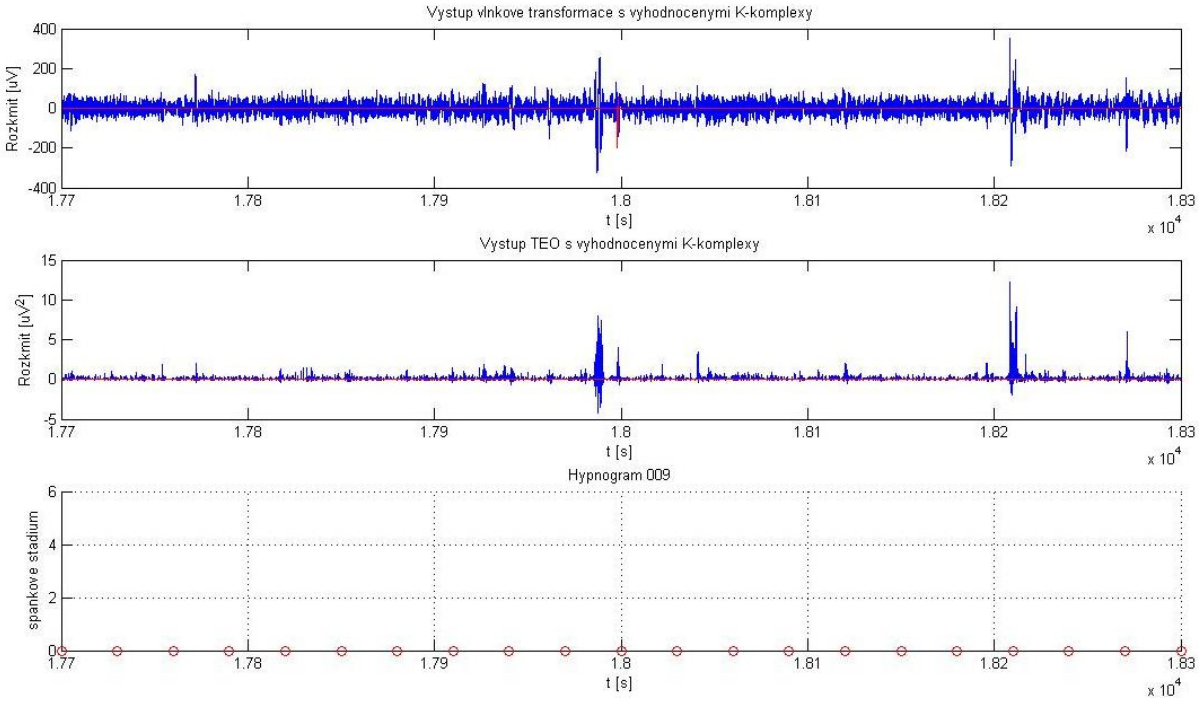

Obrázek 22: Hodnoceni v úseku signálu bdělosti (epochy 590 až 610)

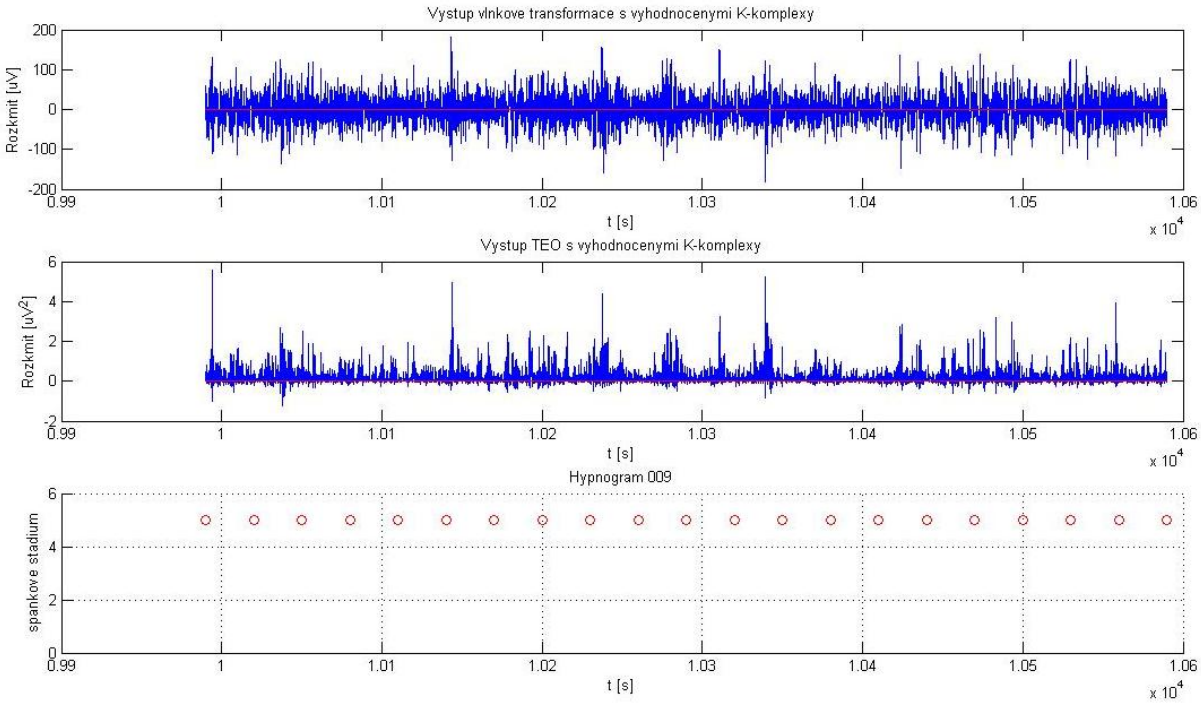

Obrázek 23: Hodnoceni v úseku signálu REM fáze (epochy 333 až 353)

Detekce na dalších dvou obrázcích (Obrázek 24 a 25) ukazuje vyhodnocené K-komplexy v rámci N2 a N3 fází spánku. Patrný je rozdíl počtu a také shoda u některých detekovaných K-komplexů metodou s využitím TEO oproti metodě s využitím VT.

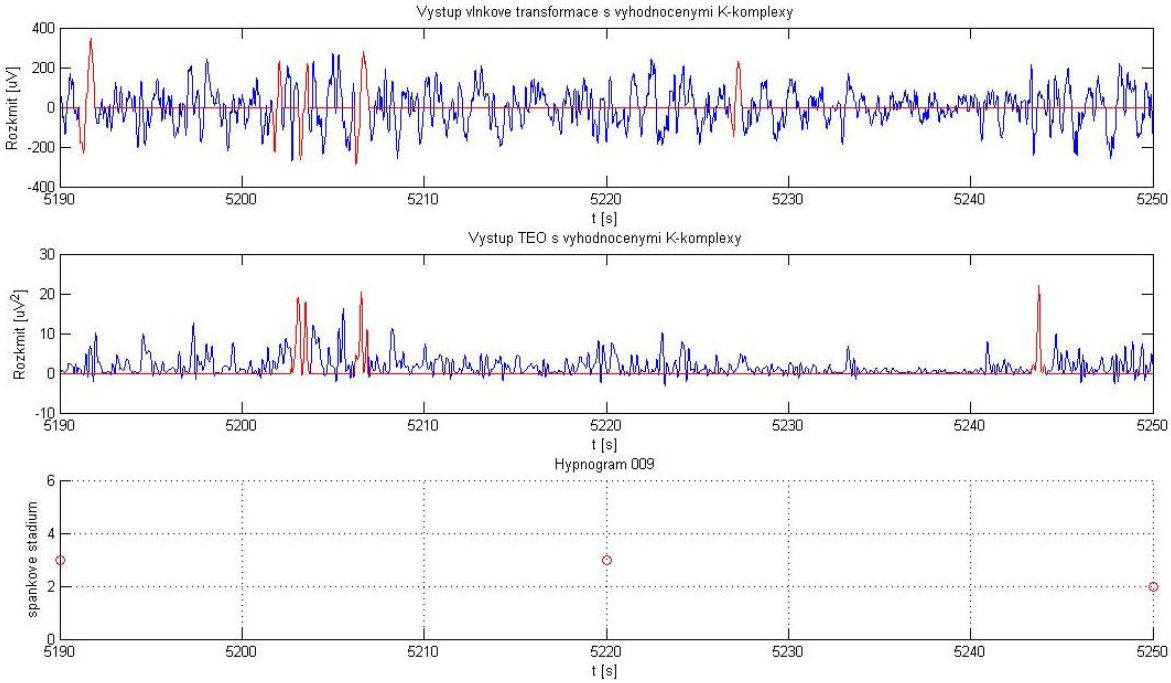

Obrázek 24: Hodnocení K-komplexů v epochách 173 až 175

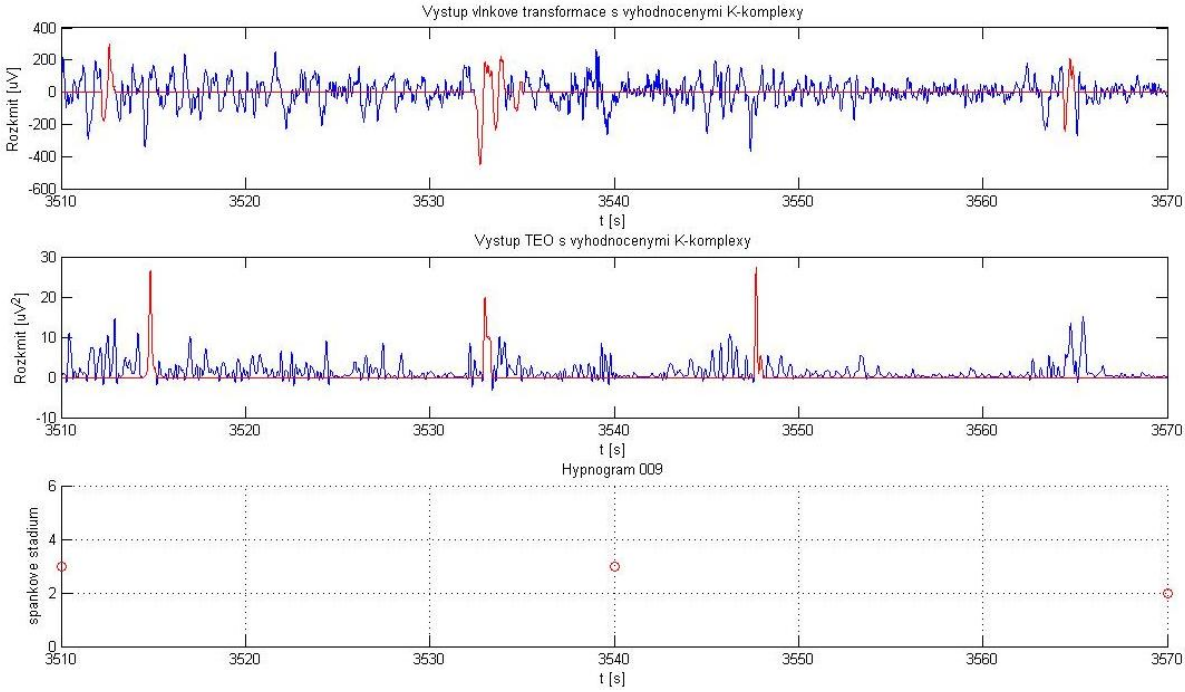

Obrázek 25: Hodnocení K-komplexů v epochách 117 až 119

Přechod spánkových fází N3 - N2 - REM (Obrázek 26), kde oba detektory hodnotí K-komplexy v N3 fázi, v N2 fázi je pak K-komplex zaznamenán jen VT metodou a nepřítomnost K-komplexů v REM fázi je opět potvrzena oběma metodami.

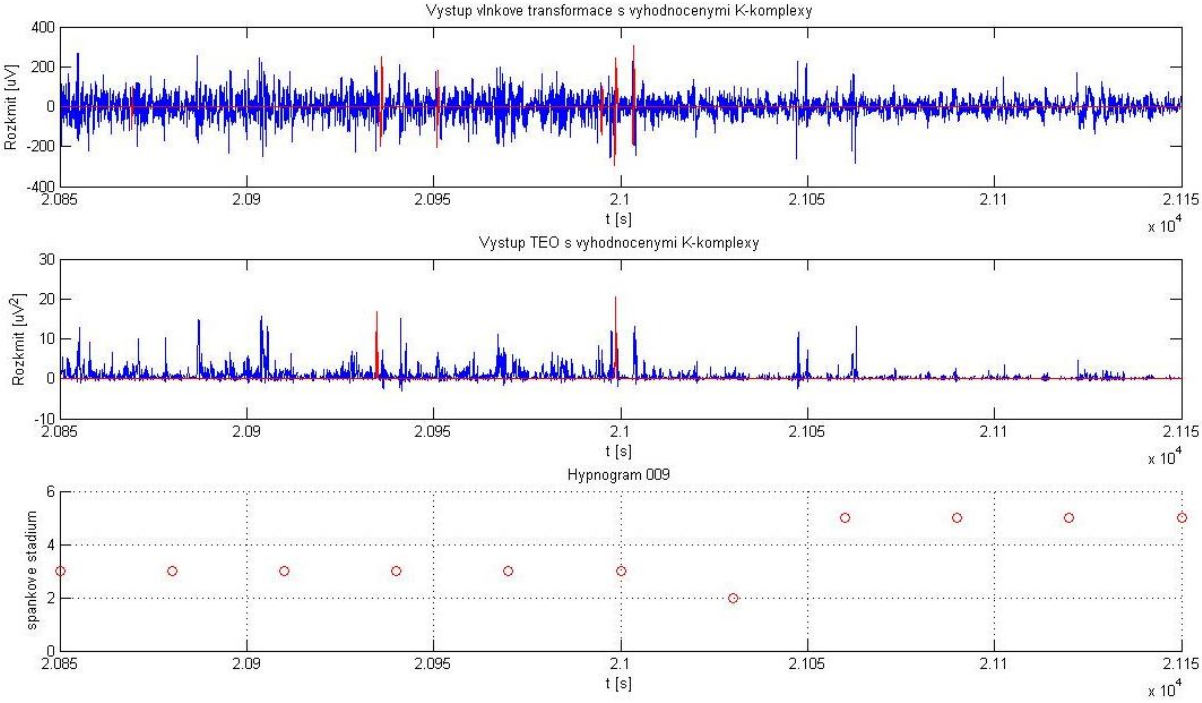

Obrázek 26: Hodnocení K-komplexů v epochách 695 až 705

Signály použité pro statistické hodnocení výsledků

Ohodnocené signály, které jsou v této práci použity pro hodnocení výsledků automatické detekce K-komplexů pomocí metod s využitím TEO a vlnkové transformace, jsou původem ze Spánkové laboratoře Nemocnice André Vésale (Montigny-le-Tilleul, Belgie). Tyto signály byly použity i v odborné práci popsané v článku *Automatic K-complexes detection in sleep EEG recordings using likelihood thresholds [22]* a statistické výsledky jsou srovnány s výsledky této práce.

Databáze s názvem *databaze.mat* obsahuje třicetiminutové záznamy deseti signálů získaných od zdravých jedinců. Tyto signály byly sejmuty jako součást PSG vyšetření (byly snímány tři kanály EEG) a do databáze byly vloženy signály kanálu Cz-M1 (viz. značení dříve, Obrázek 1). Signál je vzorkován frekvencí 200 *Hz*.

K dispozici jsou výsledky ohodnocení dvou expertů a automatického detektoru (popsaný v článku *[22]*). Tato data jsou převedena do souboru *expert.xlsx*.

K hodnocení jsou využívány výsledky hodnocení experta1, který ohodnotil všech deset signálů a experta2, který ohodnotil pouze prvních pět signálů.

Programové řešení hodnocení výsledků

Skript hodnocení výsledků: *Hodnoceni_vysledku.m*

Programové řešení hodnocení výsledků automatické detekce K-komplexů obsahuje tři dílčí částí:

- Načtení potřebných dat
- Automatická detekce K-komplexů metodami s využitím TEO a VT
- Hledání shod detekce K-komplexu mezi experty a metodami automatické detekce a statistické výpočty

Statistické ohodnocení probíhá vždy v rámci jednoho signálu, celková statistika je dopočítána a shrnuta v přiloženém souboru *statistika.xlsx*.

Načtení potřebných dat

Načtení databáze s pacientskými signály *databaze.mat*.

Vytvoření spojení *expert.xlsx*, kde jsou uloženy výsledky hodnocení expertů. Pro přenos dat je vždy nutné mít tento soubor otevřený. Pokud je proměnná *spojeni* rovna *0* ke spojení mezi Matlabem a Excelem nedošlo.

```
spojeni=ddeinit('excel','expert.xlsx');
```

Pokud není soubor *expert.xlsx* otevřen nebo dojde k přerušení informačního toku, Matlab vypíše chybové hlášení.

Hodnocení expertů obsahuje pro každý signál počátky ohodnocených K-komplexů a jejich dobu trvání (tudíž je možné dopočítat i konec K-komplexu). Tato data je třeba načíst.

```
% pacient1
x = databaze(:,1);
e1k = ddereq(spojeni,'r3c2:r3c35'); % hodnoceni K-komplexu v prvnim pac
zaznamu expertem1
e1t = ddereq(spojeni,'r4c2:r4c35'); % hodnoceni delky trvani K-komplexu v
prvnim pac zaznamu expertem1
e2k = ddereq(spojeni,'r25c2:r25c20'); % hodnoceni K-komplexu v prvnim pac
zaznamu expertem2
e2t = ddereq(spojeni,'r26c2:r26c20'); % hodnoceni delky trvani K-komplexu v
prvnim pac zaznamu expertem2
```

Pro načtení potřebných hodnot do matice, je zadán rozsah buněk, z nichž jsou data načítána.

Pro statistické ohodnocení se vždy vybírá jeden pacientský signál a k němu další potřebná data, v jehož rámci bude statistika vypočítána.

Automatická detekce K-komplexů s využitím VT a TEO

Po načtení potřebných dat probíhá automatická detekce s využitím VT a TEO. Teoretický základ i programové řešení obou těchto metod bylo popsáno v předcházejících kapitolách.

U vyhodnocených K-komplexů je stanoveno maximum kladné vlny, jehož poloha je brána jako poloha K-komplexu.

Hledání shody detekce K-komplexu mezi experty a metodami automatické detekce a statistické výpočty

Pro hledání shod v automatické detekci a hodnocení experty je využito maximálních hodnot kladných vln K-komplexů. U ohodnocených K-komplexů experty máme k dispozici polohu počátku a dobu trvání, potažmo, můžeme stanovit konec K-komplexu a maximální hodnotu v jeho kladném píku.

Zvolení maximální hodnoty kladné vlny K-komplexu se zdálo vhodné z toho důvodu, že počátky (ani konce) ohodnocených K-komplexů experty, neleží na nulové linii. Je to dáno způsobem hodnocení, kdy expert má k dispozici kurzor, kterým do signálu vpisuje značky počátků K-komplexů a není vyžadováno přesné umístění značky na nulovou linii.

Při hledání shod je tedy brána jako vztažná hodnota poloha maximální hodnoty kladné vlny K-komplexu ohodnoceného expertem a porovnávána s polohou maximální hodnoty kladné vlny K-komplexu rozsahu ± 0,5 *s* vyhodnocené automatickým detektorem (tedy 1 *s*, což je průměrná doba trvání K-komplexu *[22]*). Tomuto rozsahu odpovídá 100 vzorků signálu.

Shoda polohy maxima je vyznačena žlutou čárou v grafu výsledků automatické detekce (Obrázek 27 a 28).

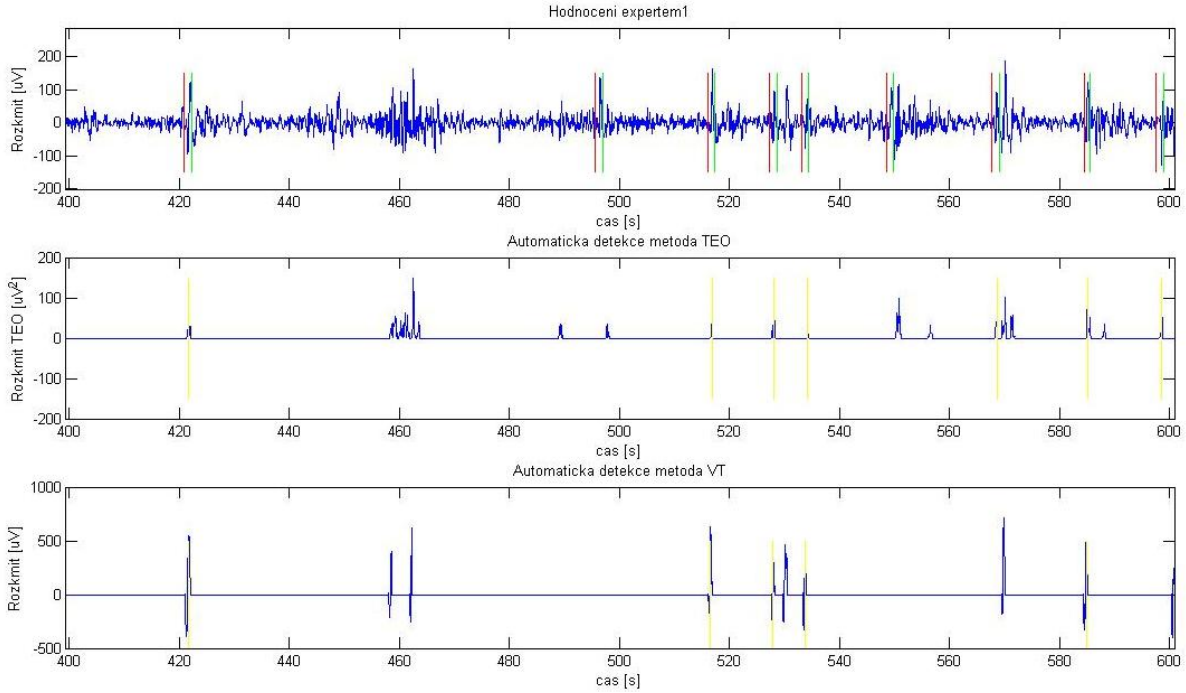

Obrázek 27: Žlutě vyznačené shody s expertem1 v maximech ohodnocených K-komplexů

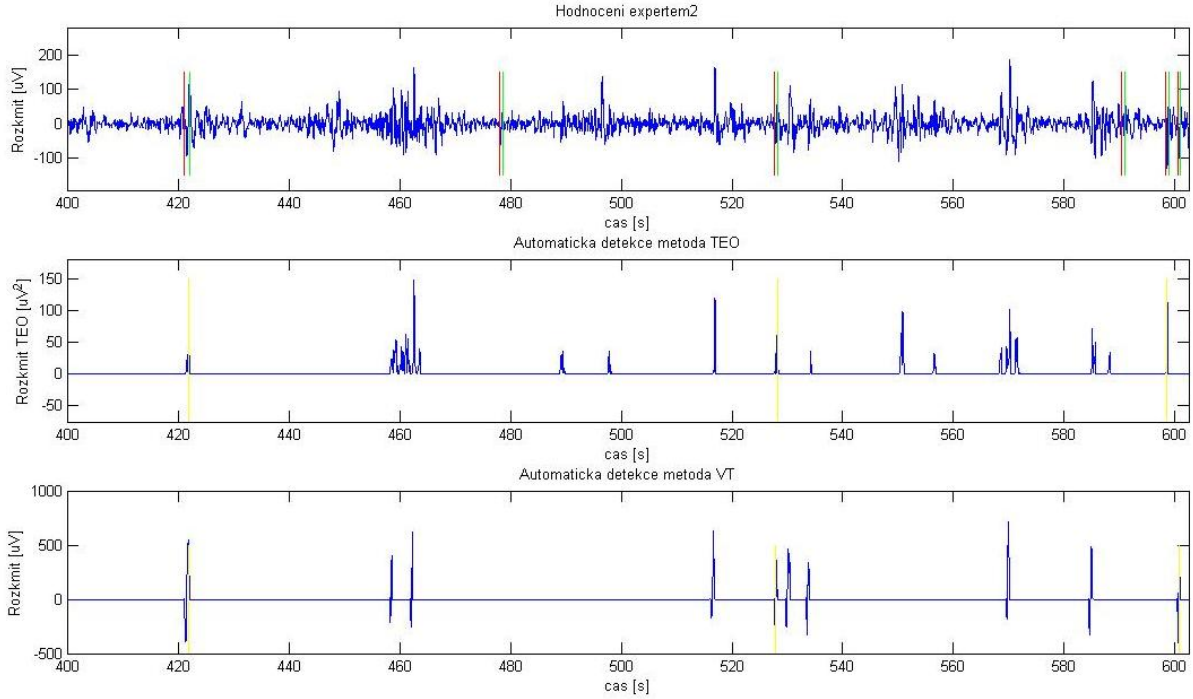

Obrázek 28: Žlutě vyznačené shody s expertem2 v maximech ohodnocených K-komplexů

Pro lepší demonstraci grafických výsledků je zajištěný současný zoom a posun všech tří grafů. Statistika je programově počítána na základě vzorců popsaných v následující kapitole.

Hodnocení výsledků

Signály použité pro statistické hodnocení výsledků jsou ohodnoceny experty, proto je možné statistické zhodnocení výsledků.

Hodnocení výsledků automatické detekce grafoelementů není jednoduché, výsledky se srovnávají s ohodnocením signálů lidskými experty, které je do značné míry zatíženo subjektivní chybou. Neexistuje tedy žádný pevný standard, podle kterého by byly automatické detektory hodnoceny, a proto se každé hodnocení musí brát s dostatečnou rezervou. Je důležité mít stále na mysli to, k čemu mají automatické detektory sloužit. V současné době nemají nahradit práci expertů, ale být podpůrným nástrojem pro hodnocení grafoelementů a pomoci expertům se snáze a rychleji orientovat v dlouhých záznamech signálů.

Je zřejmé, že co do počtu ohodnocených K-komplexů se budou experti a automatické detektory značně lišit. Již zmíněným problémem je, že se mezi sebou značně liší i výsledky expertů, jak v počtu, tak v poloze ohodnocených K-komplexů (Tabulka 3).

Tabulka 3: Počet ohodnocených K-komplexů experty a automatickou detekcí VT a TEO u pěti signálů

počet vyhodnocených K-komplexů				
signal	expert1	expert2	VT	TEO
1	34	19	63	153
2	45	8	45	67
3	12	3	12	18
4	78	14	111	330
5	39	20	64	111
6	28	X	64	89
7	11	X	56	61
8	4	X	6	16
9	5	X	15	20
10	16	X	7	30
celkem pro 5 signálů	208	64	295	679
celkem pro 10 signálů	272	X	443	895

Pro statistické zhodnocení výsledků detekce K-komplexů se využívá základních charakteristik testu TPR (True Positive Rate, Senzitivita, míra pravdivé pozitivity) a TNR (True Negative Rate, Specificcita, míra pravdivé negativity), chyba 1. typu FPR (False Positive Rate) a potestovou pravděpodobnost PPV+ (Positive Predictive Value, prediktivní hodnota pozitivního testu). Tyto statistické hodnoty bývají v odborných článcích nejčastěji prezentovány při zhodnocení výsledků automatické detekce spánkových grafoelementů. Pro možnost srovnání proto jsou i v této práci prezentovány tyto statistické hodnoty.

TP (pravdivě pozitivní) jsou výsledky automatického detektoru a experta, mezi kterými byla nalezena shoda.

FP (falešně pozitivní) jsou výsledky, které automatický detektor ohodnotil jako K-komplexy, ale expertem ohodnoceny nebyly. *FP* odpovídá rozdílu mezi celkovým počtem K-komplexů vyhodnocených automatickou detekcí a *TP* K-komplexů.

FN (falešně negativní) výsledky jsou K-komplexy, které expert ohodnotil jako K-komplexy, ale automatickým detektorem ohodnocen nebyly. *FN* odpovídá rozdílu mezi celkovým počtem K-komplexů ohodnocených expertem a *TP* K-komplexů.

Jediným problémem spojeným se statistikou je určení hodnoty *TN* (True Negative). Řešením je aproximace. Jako množina všech testovaných K-komplexů se bere celý signál, tedy úseky signálu délky 1 *s* (průměrná doba trvání K-komplexů). Potom celá testovaná množina třicetiminutového signálu má 1800 potenciálních K-komplexů *[22]*.

Použijeme-li tuto aproximaci, můžeme poté *TN* vypočítat jako:

$$TN = 1800 - TP - FN - FP \tag{3}$$

Kde *TP* je počet pravdivě pozitivních detekcí, *FN* je počet falešně negativních detekcí a *FP* je počet falešně pozitivních detekcí.

Senzitivita – pravděpodobnost, že detekce bude v případě přítomnosti K-komplexu v signálu pozitivní.

$$TPR[\%] = \frac{TP}{TP + FN} * 100 \tag{4}$$

Kde *TP* (True Positive) je počet pravdivě pozitivních detekcí a *FN* (False Negative) je počet falešně negativních detekcí.

Specificita – pravděpodobnost, že detekce bude v případě nepřítomnosti K-komplexu v signálu negativní.

$$TNR[\%] = \frac{TN}{TN + FP} * 100 \tag{5}$$

Kde *TN* (True Negative) je počet pravdivě negativních detekcí a *FP* (False Positive) je počet falešně pozitivních detekcí.

FPR – pravděpodobnost, že detekce bude v případě nepřítomnosti K-komplexu v signálu pozitivní.

$$FPR[\%] = \frac{FP}{FP + TN} * 100 = 100 - TNR \tag{6}$$

Kde *FP* (False Positive) je počet falešně pozitivních detekcí, *TN* (True Negative) je počet pravdivě negativních detekcí a TNR (True Negative Rate, Specificita).

PPV+ - pravděpodobnost, že vyhodnocený K-komplex automatickou detekcí je skutečným K-komplexem. Jedná se o tzv. potestovou pravděpodobnost.

$$PPV + [\%] = \frac{TP}{TP + FP} * 100 \tag{7}$$

Kde *TP* (True Positive) je počet pravdivě pozitivních detekcí a *FP* (False Positive) je počet falešně pozitivních detekcí.

Statistické hodnocení podle dvou standardů expert1 a expert2

Expert1 ohodnotil deset signálů, expert2 prvních pět signálů. Na základě tohoto hodnocení je vytvořena statistika hodnocení automatických detektorů. Celková statistika je zvlášť vypočítána pro pět a deset signálů. Jelikož expert2 ohodnotil pouze prvních pět signálů, jeví se jako správné porovnávat celkové statistiky (vytvořené na základě ohodnocení experta1 a experta2) právě těchto signálů.

Na první pohled je v tabulce výsledků patrné (Tabulka 4), že navrhnuté automatické detektory jsou méně senzitivní a více specifické, což značí nižší počet falešně pozitivních detekcí a vyšší počet falešně negativních detekcí *[23]*.

Prediktivita je u obou detektorů relativně nízká, bohužel, není zdroj se kterým by byla hodnota srovnána.

Podrobnější tabulky statistiky jsou zahrnuty v příloze (Tabulka 5 až 8).

Expert1 jako standard

Bereme-li jako standard pro vytvoření statistiky hodnocení výsledků experta1, vidíme, že senzitivita automatického detektoru s využitím vlnkové transformace je relativně nízká zatímco automatický detektor s využitím TEO vykazuje přijatelnou hodnotu senzitivity. Srovnáme-li s výsledky prezentovanými ve článku *Automatic K-complexes detection in sleep EEG recordings using likelihood thresholds [22]*, kde *TPR* (senzitivita) je 61,72 % a *FPR* je 0,53 % (tzn. *TNR* je 99,47%), můžeme konstatovat, že automatická detekce s využitím VT má statisticky horší výsledky a automatická detekce s využitím TEO má statisticky lepší výsledky co do senzitivity detekce než automatický detektor popsaný v tomto článku. Hodnoty *FPR* jsou vyšší než v článku, nicméně jsou dostatečně nízké.

Expert2 jako standard

Je patrné, že výsledky statistického hodnocení obou detektorů jsou obecně lepší, vezmeme-li jako standard ohodnocení K-komplexů expertem2. Ve článku jsou prezentovány výsledky statistiky s expertem2 *TPR* (senzitivita) 60,94 % a *FPR* 1,53 % (tzn. *TNR* je 98,47%). Hodnoty *FPR* jsou vyšší než v článku, ale jak bylo řečeno, hodnoty jsou dostatečně nízké.

Tabulka 4: Výsledky statistiky

		senzitivita (TPR) [%]	specificita (TNR) [%]	FPR [%]	prediktivita [%]
VT X expert1	pro 5 signálů	50,5	97,8	2,16	35,6
	pro 10 signálů	45,6	98,2	1,80	28,0
TEO X expert1	pro 5 signálů	75,5	94,1	5,9	23,1
	pro 10 signálů	67,6	96,0	4,0	20,6
VT X expert2	pro 5 signálů	76,6	97,2	2,8	16,6
TEO X expert2	pro 5 signálů	82,8	93,0	7,0	7,8

Závěr

Úkolem této práce bylo seznámení s problematikou automatické detekce spánkových grafoelementů, speciálně K-komplexů, a realizace dvou metod automatické detekce v programovém prostředí Matlab.

Při realizaci vybraných metod automatické detekce se ukázalo, že definice rozhodovacích parametrů není vůbec jednoduchá a v každé z metod se do jisté míry liší, stejně tak se i liší výsledky metod (což je samozřejmě dáno i aplikací rozdílných úprav a výpočtů spjatých s TEO a VT). Problémy s detekcí K-komplexů vyplývají z variability tohoto spánkového grafoelementu.

Pro práci byly využity dvě sady signálů získané z různých zdrojů. Na první sadě signálů byly vysvětleny principy automatické detekce a vizuálně srovnány s hypnogramem. Výsledky ve srovnání s hypnogramem jsou v pořádku, výskyt K-komplexů je soustředěn do N2 a N3 fází hypnogramu, pro které je tento grafoelement charakteristický. Druhá sada signálů obsahuje i ohodnocené K-komplexy od dvou expertů, proto jsou na základě těchto ohodnocení možné statistické výpočty. Programově jsou nalezeny shody nalezených K-komplexů automatickými detektory s experty (tyto shody korespondují s hodnotou *TP*) a dále provedeny statistické výpočty *TPR, TNR, FPR* a prediktivita.

Zhodnocení výsledků není jednoduché, neexistuje standard pro srovnání výsledků hodnocení. Jako standard se bere hodnocení experta, ovšem každý expert zatěžuje výsledek subjektivní chybou, proto i srovnávání jednotlivých automatických detektorů mezi sebou není zcela objektivní.

Tato práce srovnává výsledky detekce se dvěma experty a takto získané statistické hodnoty poté s výsledky automatické detekce popsané v článku *Automatic K-complexes detection in sleep EEG recordings using likelihood thresholds [22],* která využívá stejné signály i ohodnocení stejnými experty jako tato práce a vykazuje výsledky *TPR* 61,72 % (standard expert1) a 60,94 % (standard expert2) a *FPR* 0,53 % (standard expert1) a 1,53 % (standard expert2). Je tedy možné konstatovat obecně lepší výsledky u automatického detektoru s využitím TEO a u automatického detektoru s využitím VT se standardem v expertu2. Poněkud horší výsledky jsou zaznamenány u metody VT se standardem v experteu1.

V rámci testování signálu byla vyzkoušena i různá obměna rozhodovacích parametrů a u metody s využitím VT i změna počtu stupňů rozkladu ve vlnkové transformaci. Žádná z těchto změn neměla pozitivní vliv na statistické hodnocení detektorů, proto se zdá nastavení rozhodovacích parametrů a počet stupňů rozkladu ve vlnkové transformaci zcela v pořádku.

Co se týče metod použitých pro detekci, jeví se jako přijatelnější pro použití v praxi automatický detektor s využitím TEO. Jeho výsledky jsou přijatelné a mohl by být použit jako

podpůrný prostředek pro experty ohodnocující signál. Metoda s využitím VT je sofistikovanější, co do úpravy signálu a rozhodovacích parametrů, nicméně neukázalo se, že by byla významně lepší, spíše naopak.

Použitá literatura

[1] SPRIGGS, William H. Essentials of polysomnography: a training guide and reference for sleep technicians. Second edition. Jones & Bartlett Publishers, 2014, p. ISBN 978-128-4030-273.

[2] GEYER, James D, Paul R CARNEY a Troy PAYNE. Atlas of polysomnography. 2nd ed. Philadelphia, PA: Lippincott Williams, c2010, xv, 329 p. ISBN 16-054-7228-X.

[3] POKORNÝ, Jan. Přednáška FBMI CVUT: Elektroencefalografie. [online]. [cit. 2014-10-02]. Dostupné z: http://fbmi.cvut.cz/files/nodes/657/public/EEG.pdf

[4] SCHATZMILLER, R. Sleep Stage Scoring. Medscape, 2012. Aktualizováno 2012-05-05 [cit. 2014-10-1]. Dostupné z WWW: <http://emedicine.medscape.com/article/1188142- overview>.

[5] Měření polysomnografických (PSG) signálů v rámci grantu „Význam spánkové apnoe v patofyziologii a léčbě fibrilace síní". Manuál k měření, NS 100 98-4.

[6] RONZHINA, M. Sleep scoring using artificial neural networks. Sleep Medicine Reviews 16, 2012, pp. 251-263.

[7] SANEI, Saeid a Jonathon CHAMBERS. EEG signal processing. Hoboken, NJ: John Wiley, c2007, xxii, 289 p. ISBN 04-700-2581-6.

[8] ZOUBEK, L. Automatic Classification of Human Sleep Recordings Combining Artifact Identification and Relevant Features Selection. Academic dissertation. Grenoble: Université Joseph Fourier, Ostrava: Technical University of Ostrava, 2008.

[9] MIŠUREC, Jiří a Milan CHMELAŘ. Elektroencefalografie: vybrané kapitoly z obecné elektroencefalografie, přístrojové a registrační techniky a technické minimum. 1. vyd. Brno: Institut pro další vzdělávání středních zdravotnických pracovníků, 1990, 194 s. ISBN 80-701-3065-2.

[10] KOZUMPLÍK, J. Elektroencefalogram. Část 1. [přednáška z předmětu Analýza biologických signálů] 2012

[11] WILLIAMS, Robert L, Ismet KARACAN a Carolyn J HURSCH. Electroencephalography (EEG) of human sleep: clinical applications. Second edition. New York: Wiley, xiv, 169 p. ISBN 04-719-4686-9.

[12] SYSLOVÁ, Zuzana, Dušan SYSEL, Oto MASÁR, Eliška KUBÍKOVÁ a Mária BROZMANOVÁ. Elektroencefalografia v praxi. V Tribunu EU vyd. 1. Brno: Tribun EU, 2010, 134 s. Librix.sk. ISBN 978-80-7399-913-1.

[13] ROZMAN, Jiří. Elektronické přístroje v lékařství. Vyd. 1. Praha: Academia, 2006, 406 s., xxiv s. barev. obr. příl. Česká matice technická (Academia). ISBN 80-200-1308-3.

[14] KRAJČA, Vladimír a Jitka MOHYLOVÁ. Číslicové zpracování neurofyziologických signálů. 1. vyd. V Praze: České vysoké učení technické, 2011, 168 s. ISBN 978-80-01-04721-7.

[15] A glossary of terms most commonly used by clinical electroencephalographers. Electroencephalography and Clinical Neurophysiology [online]. 1974, vol. 37, issue 5, s. 538-548 [cit. 2015-05-15]. DOI: 10.1016/0013-4694(74)90099-6.

[16] AMZICA, Florin a Mircea STERIADE. The functional significance of K-complexes. Sleep Medicine Reviews. 2002, roč. 6, č. 2, 139–149. DOI: 10.1053.

[17] DUMAN F., ERDAMAR A., EROGUL O., TELATAR Z., YETKIN S. Efficient sleep spindle detection algorithm with decision tree. Expert Systems with Applications, Vol. 36, 2009, pp. 9980–9985.

[18] ERDAMAR A., DUMAN F., YETKIN S. A wavelet and teager energy operator based method for automatic detection of K-Complex in sleep EEG. Expert Systems with Applications, Vol. 39, 2012, pp. 1284–1290.

[19] JAN, Jiří. Číslicová filtrace, analýza a restaurace signálů. 2. upr. a rozš. vyd. Brno: VUTIUM, 2002, 427 s. ISBN 80-214-1558-4.

[20] ŠMÍD, Radislav. Úvod do vlnkové transformace: Výukový materiál ČVUT FEL katedra měření. Praha 6, 2001, 9 s. Dostupné z: http://measure.feld.cvut.cz/groups/diag/download/Wavelet-intro8859.pdf

[21] NASON, G.P. a B.W. SILVERMAN. The Stationary Wavelet Transform and some Statistical Applications. ANTONIADIS, A. a G. OPPENHEIM. Wavelets and statistics. New York: Springer-Verlag, 1995, s. 281–299. Lecture notes in statistics, 103. ISBN 03-879-4564-4.

[22] DEVUYST, Stéphanie, et al. Automatic K-complexes detection in sleep EEG recordings using likelihood thresholds. In: Engineering in Medicine and Biology Society (EMBC), 2010 Annual International Conference of the IEEE. IEEE, 2010. p. 4658-4661.

[23] PROVAZNÍK, Ivo. Pravděpodobnost v bioinformatice a Pravděpodobnost v bioinformatice 2 [online]. [cit. 2015-05-06]. Dostupné z: https://www.vutbr.cz/elearning/file.php/134626/Prednasky/05_Pravdepodobnost_v_biomedicine.pdf https://www.vutbr.cz/elearning/file.php/134626/Prednasky/06_Pravdepodobnost_v_biomedicine_2.pdf. Přednáška předmětu AUMI. VUT, FEKT, UBMI.

Použité zkratky

EEG	Elektroencefalografie
PSG	Polysomnografie
EOG	Elektrookulografie
EKG	Elektrokardiografie
EMG	Elektromyografie
CNS	Centrální Nervová Soustava
REM	Rapid Eye Movement, fáze spánku
NREM	Non-Rapid Eye Movement, fáze spánku
AASM	American Academy of Sleep Medicine
W	Weak, fáze bdělosti
N1	první fáze NREM spánku
N2	druhá fáze NREM spánku
N3	třetí fáze NREM spánku, dříve označované zvlášť jako NREM3 a NREM4
RBD	REM sleep behaviour disorder
TEO	Target Energy Operator
DTWT	Discrete Time Wavelet Transform, vlnková transformace diskrétní v čase
WT, VT	Wavelet Transform, vlnková transformace
SWT	Stationary Wavelet Transform, stacionární vlnková transformace
A	aproximace
D	detaily
TP	True Positive, pravdivě pozitivní
FP	False Positive, falešně pozitivní
TN	True Negative, pravdivě negativní
FN	False Negative, falešně negativní
TPR	True Positive Rate, míra pravdivé pozitivity
FPR	False Positive Rate, míra falešné pozitivity
TNR	True Negative Rate, míra pravdivé negativity

Seznam obrázků

Seznam tabulek

Přílohy

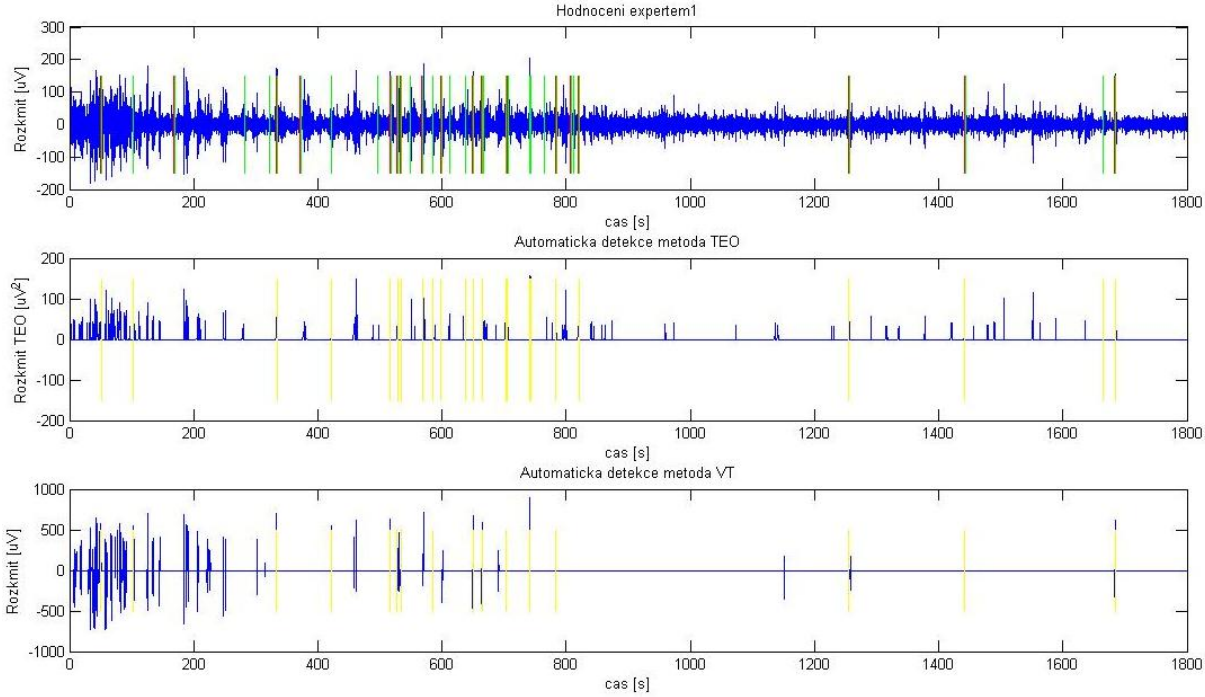

Obrázek 29: Hodnocení pacientského záznamu 1 expertem1 a metodami VT a TEO

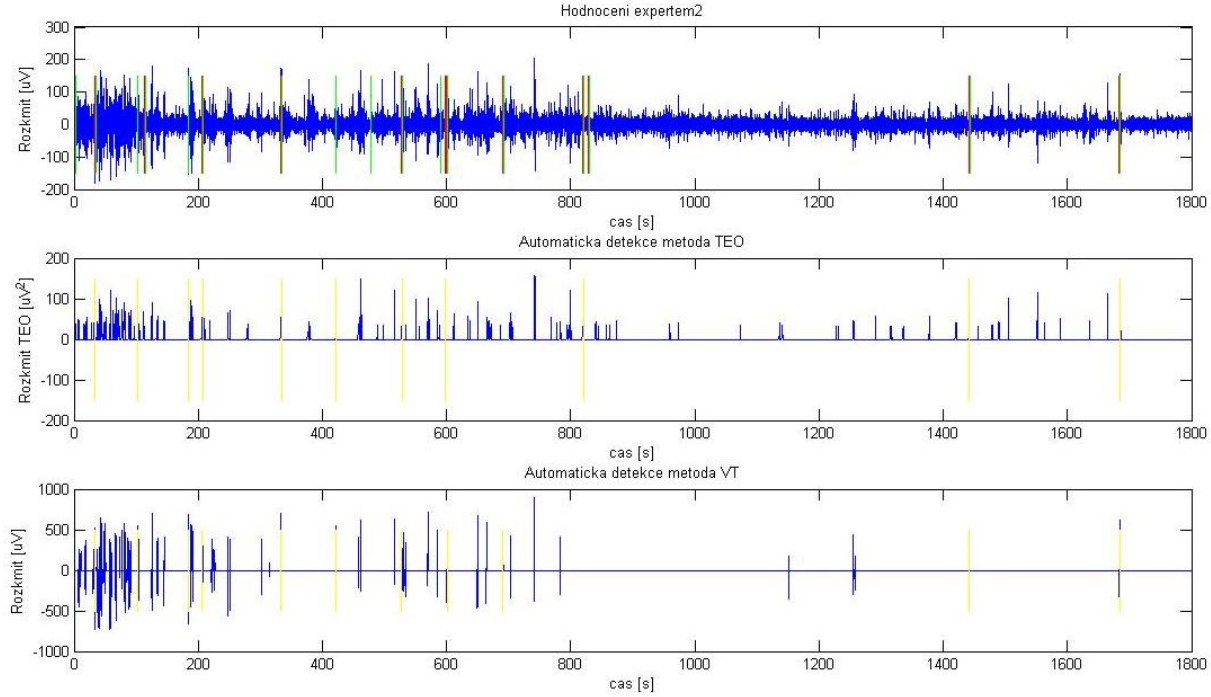

Obrázek 30: Hodnocení pacientského záznamu 1 expertem2 a metodami VT a TEO

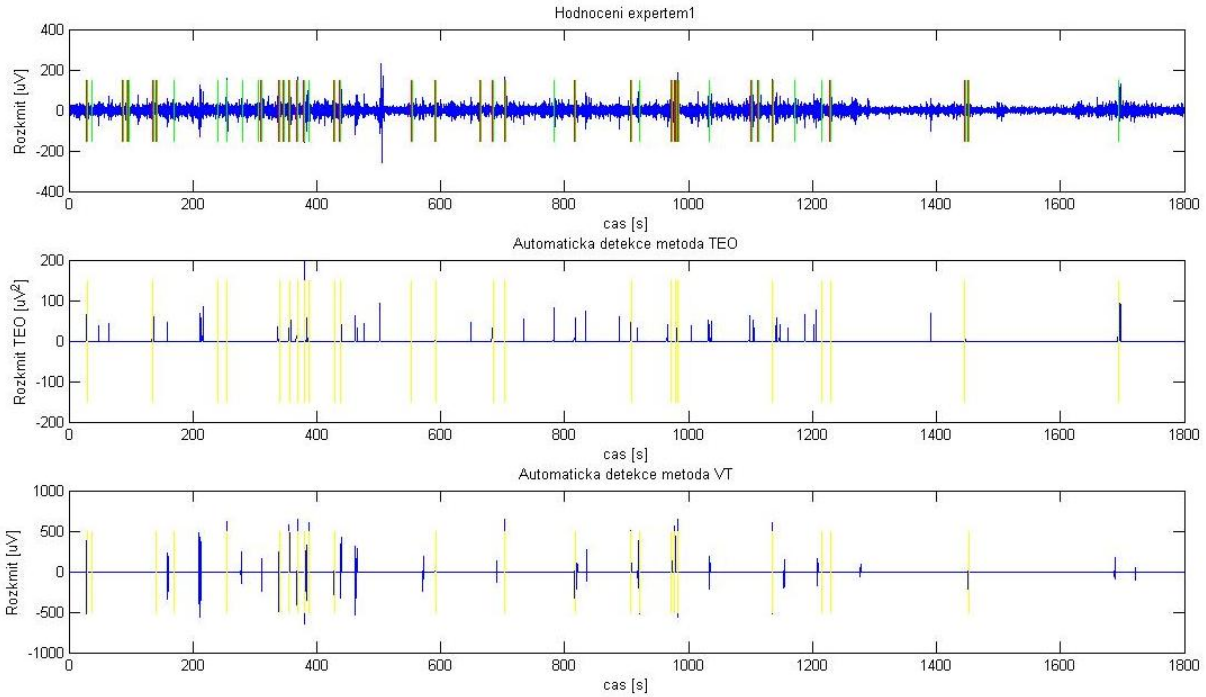

Obrázek 31: Hodnocení pacientského záznamu 2 expertem1 a metodami VT a TEO

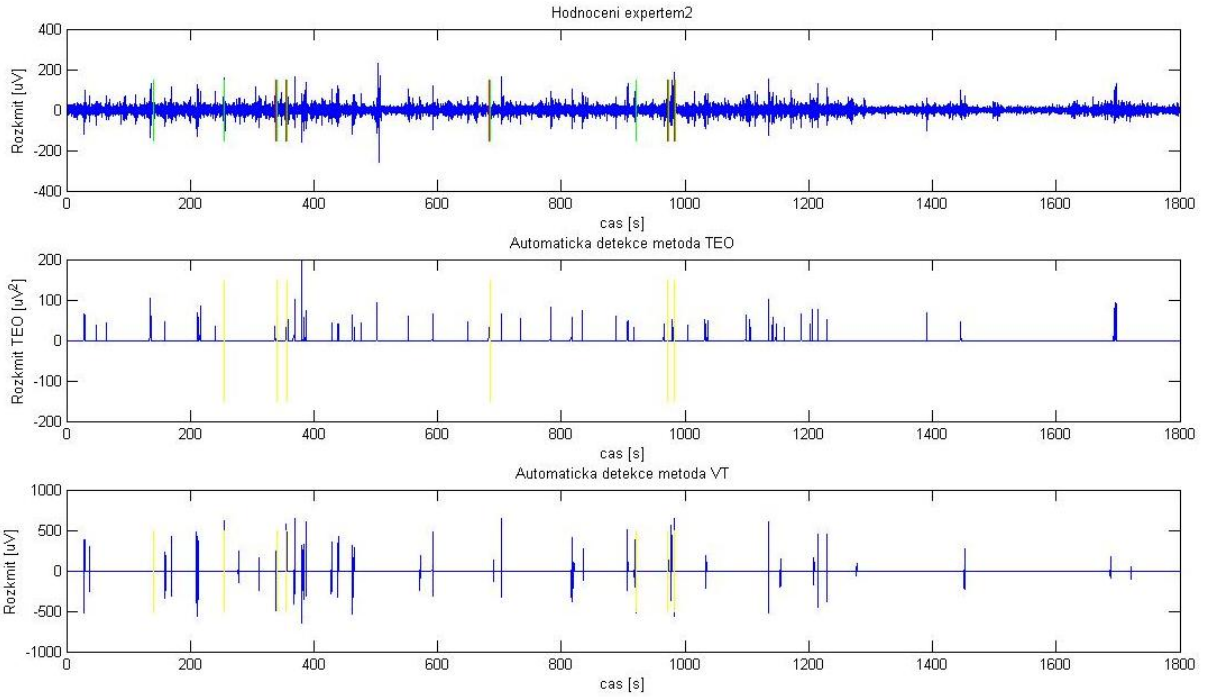

Obrázek 32: Hodnocení pacientského záznamu 2 expertem2 a metodami VT a TEO

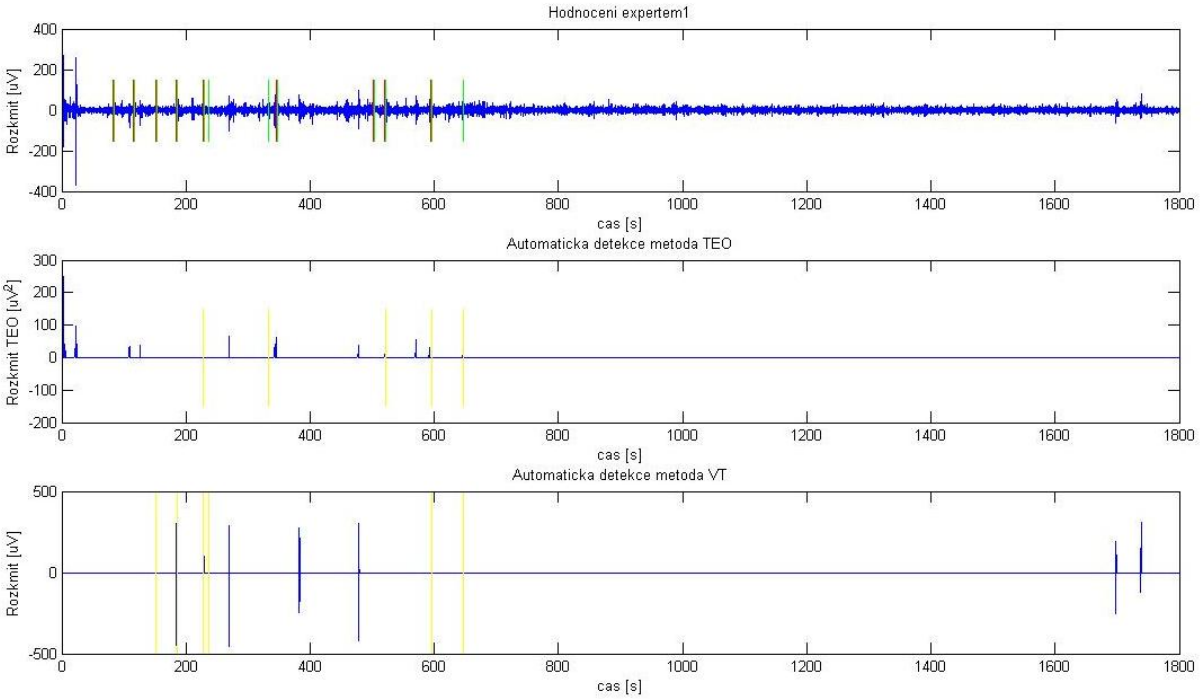

Obrázek 33: Hodnocení pacientského záznamu 3 expertem1 a metodami VT a TEO

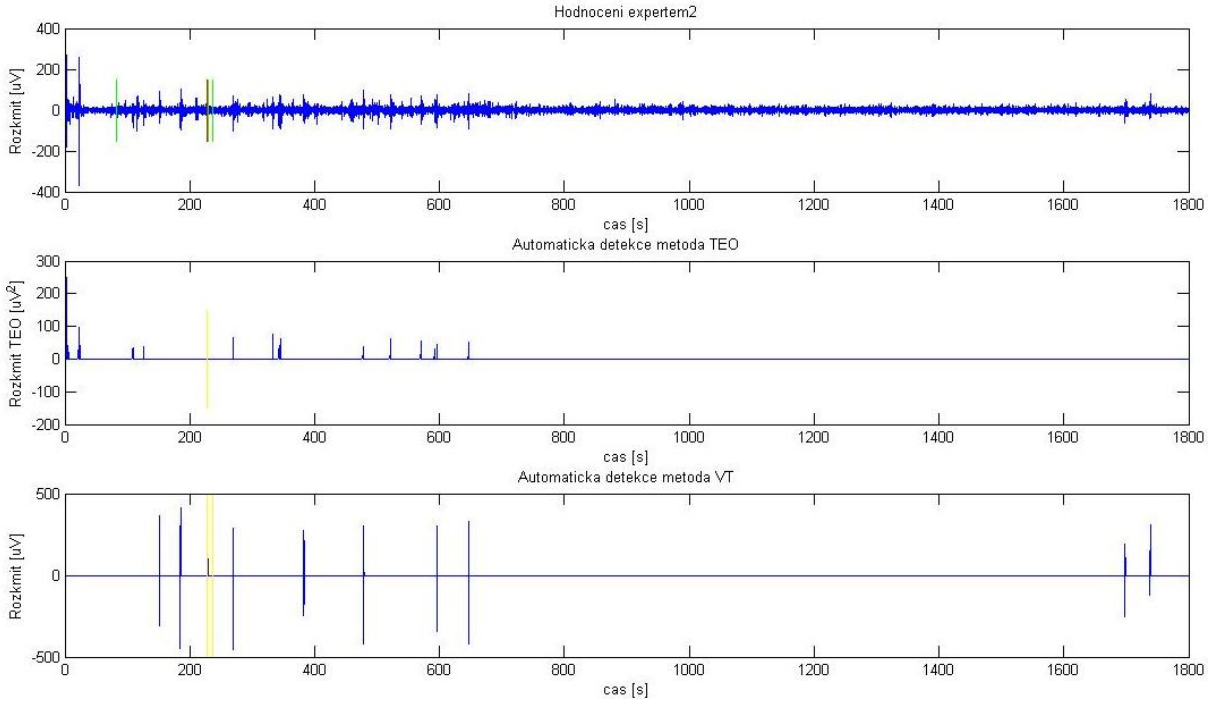

Obrázek 34: Hodnocení pacientského záznamu 3 expertem2 a metodami VT a TEO

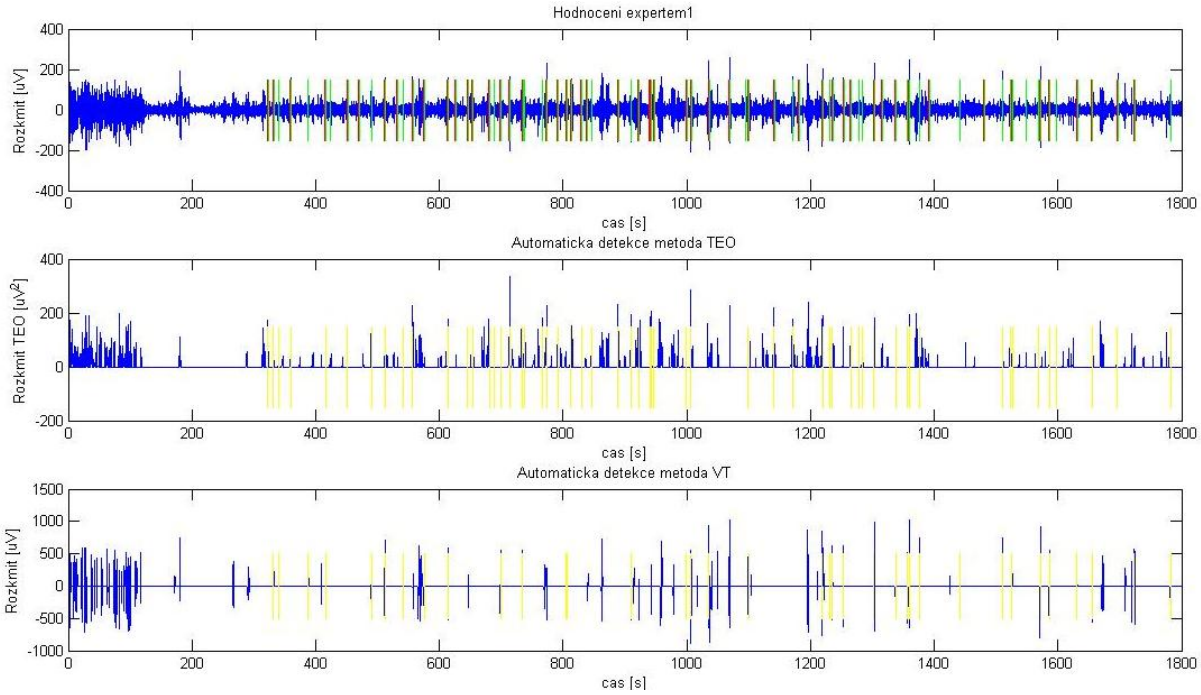

Obrázek 35: Hodnocení pacientského záznamu 4 expertem1 a metodami VT a TEO

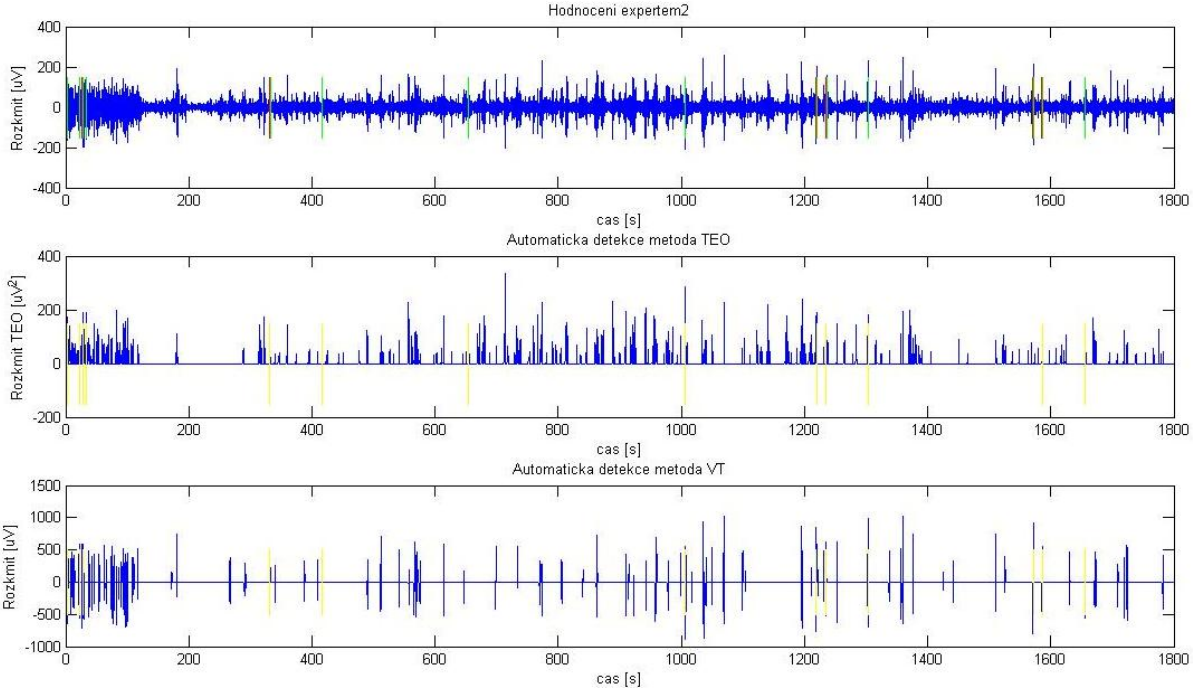

Obrázek 36: Hodnocení pacientského záznamu 4 expertem2 a metodami VT a TEO

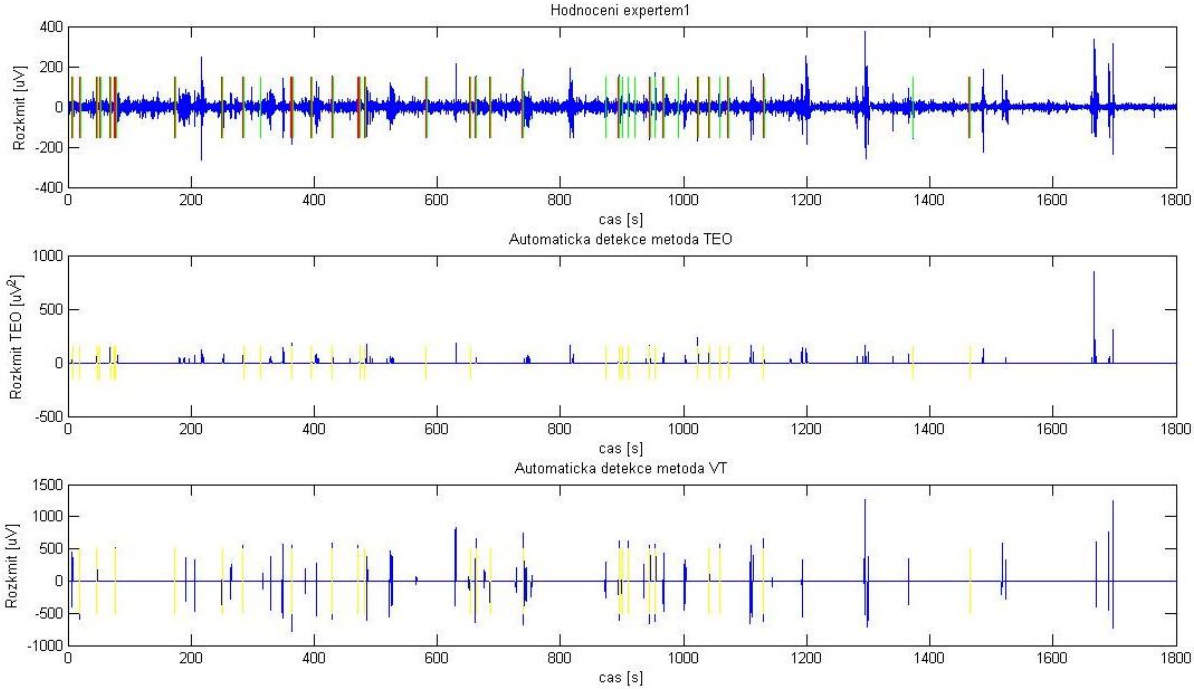

Obrázek 37: Hodnocení pacientského záznamu 5 expertem1 a metodami VT a TEO

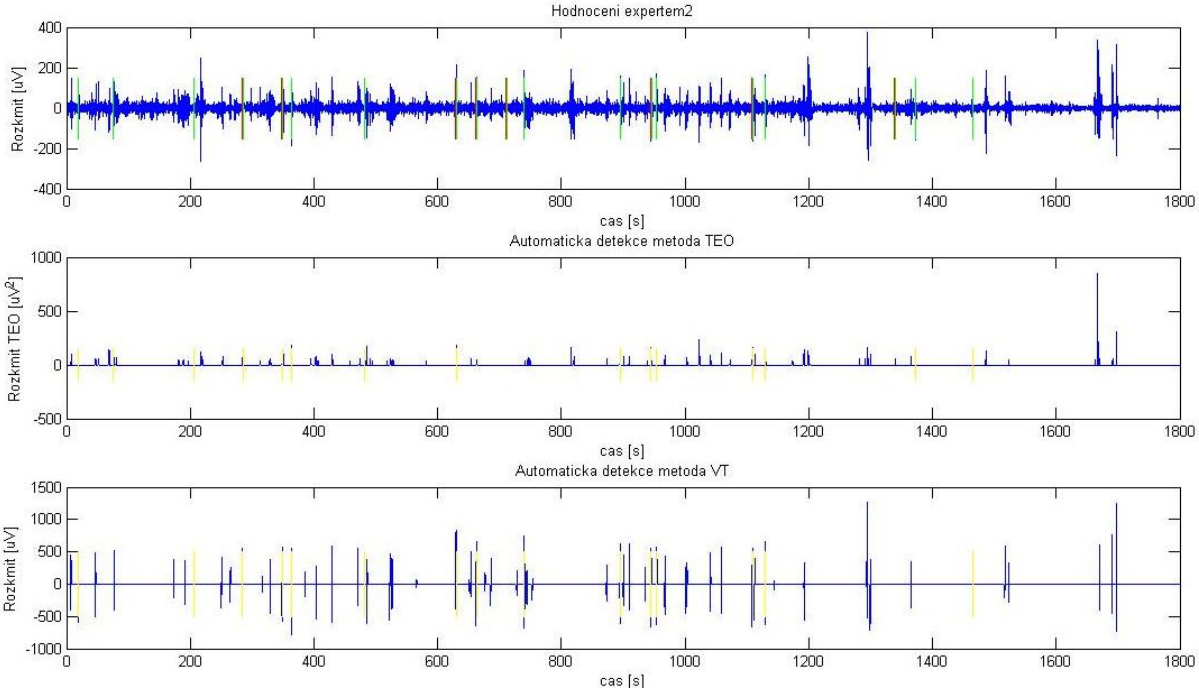

Obrázek 38: Hodnocení pacientského záznamu 5 expertem2 a metodami VT a TEO

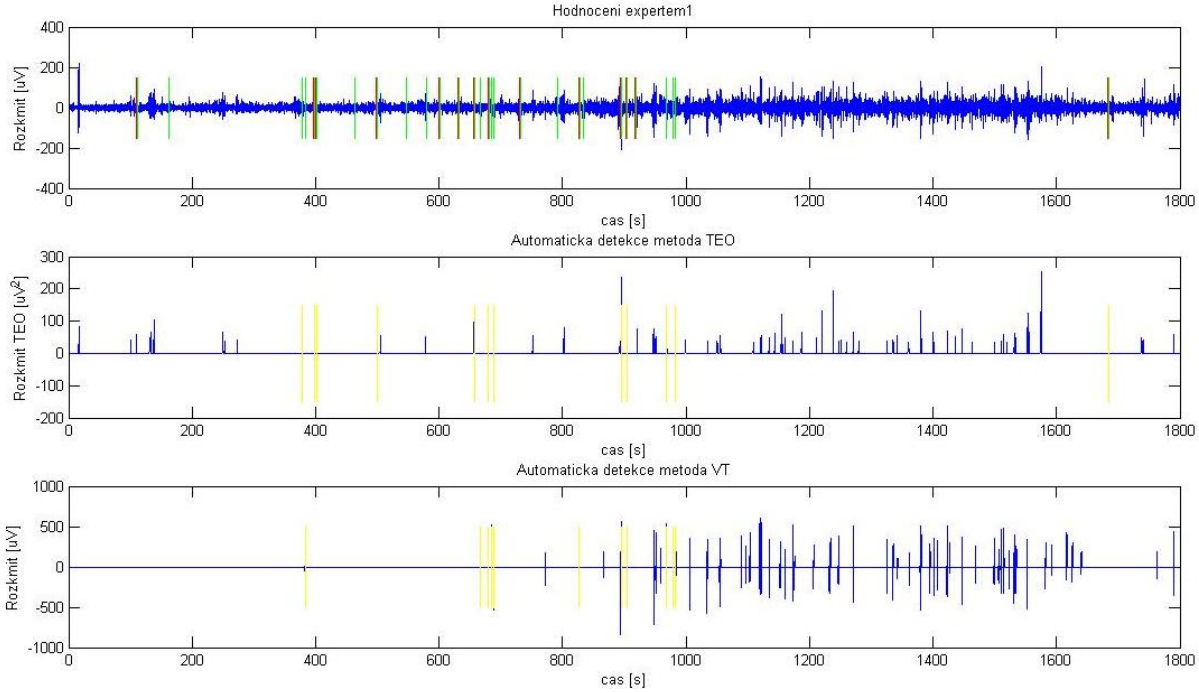

Obrázek 39: Hodnocení pacientského záznamu 6 expertem1 a metodami VT a TEO

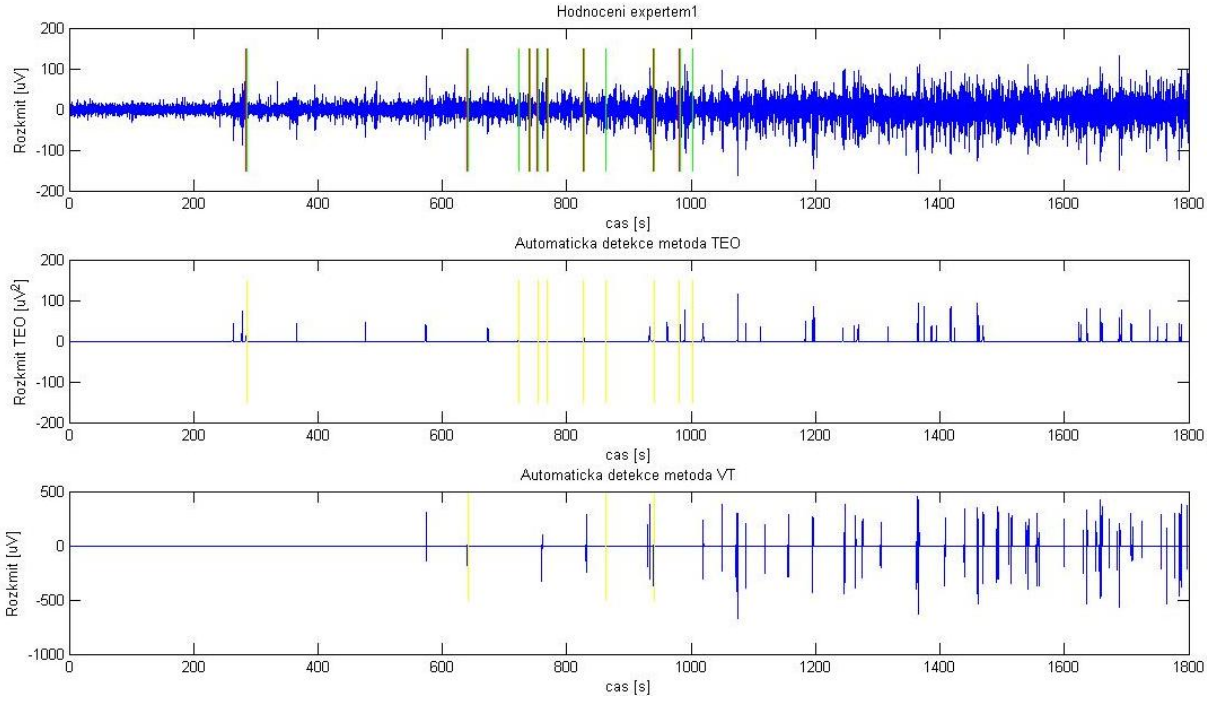

Obrázek 40: Hodnocení pacientského záznamu 7 expertem1 a metodami VT a TEO

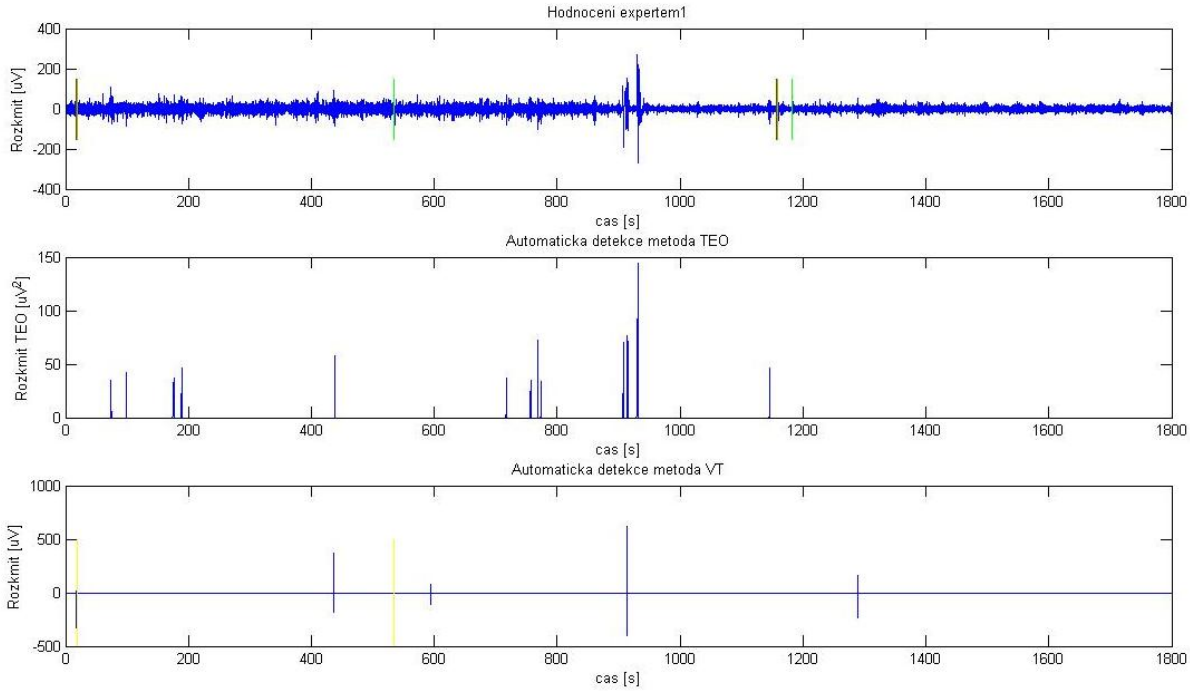

Obrázek 41: Hodnocení pacientského záznamu 8 expertem1 a metodami VT a TEO

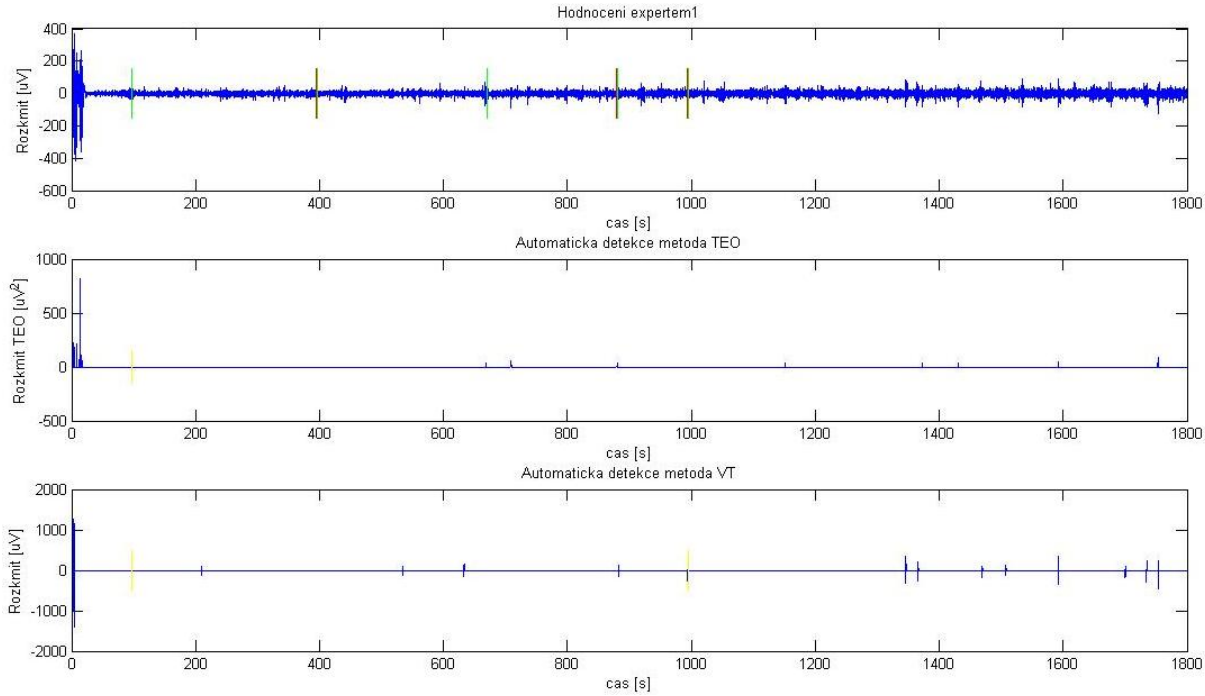

Obrázek 42: Hodnocení pacientského záznamu 9 expertem1 a metodami VT a TEO

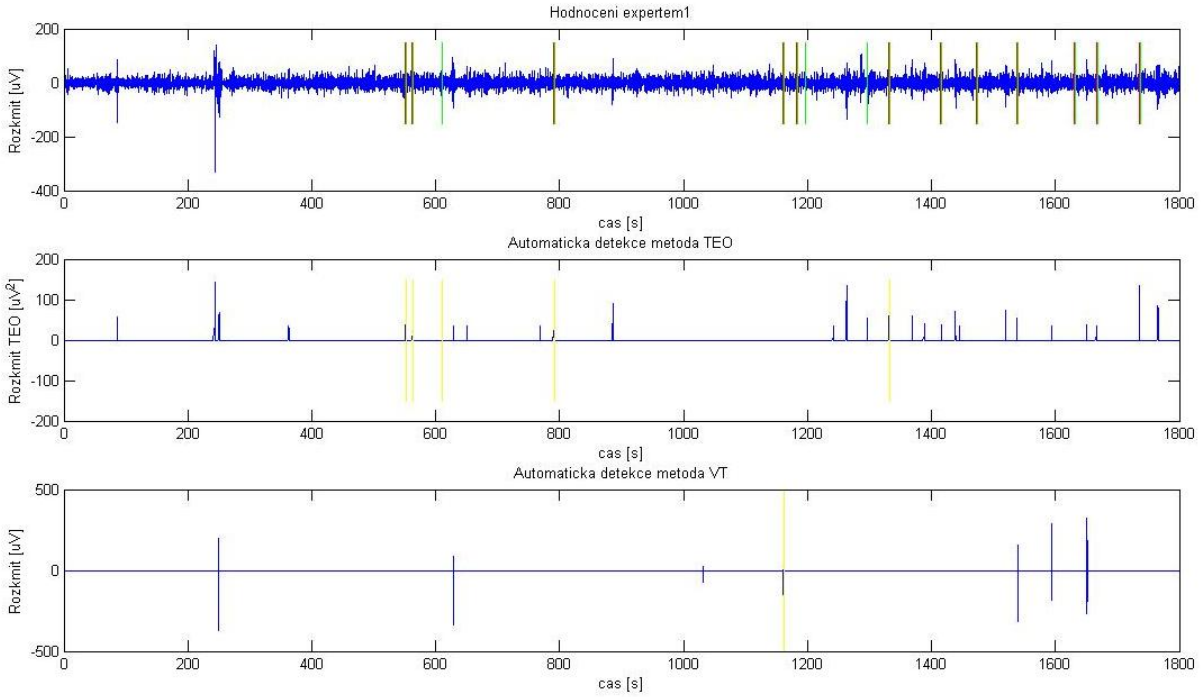

Obrázek 43: Hodnocení pacientského záznamu 10 expertem1 a metodami VT a TEO

Tabulka 5: Statistika expert1 X TEO

TEO X expert1										
signál	expert1	TEO	TP	FP	FN	TN	senzitivita (TPR) [%]	specificita (TNR) [%]	FPR [%]	prediktivita [%]
1	34	153	25	128	9	1638	73,5	92,8	7,2	16,3
2	45	67	27	40	18	1715	60,0	97,7	2,3	40,3
3	12	18	5	13	7	1775	41,7	99,3	0,7	27,8
4	78	330	66	264	12	1458	84,6	84,7	15,3	20,0
5	39	111	34	77	5	1684	87,2	95,6	4,4	30,6
6	28	89	12	77	16	1695	42,9	95,7	4,3	13,5
7	11	61	9	52	2	1737	81,8	97,1	2,9	14,8
8	4	16	0	16	4	1780	0,0	99,1	0,9	0,0
9	5	20	1	19	4	1776	20,0	98,9	1,1	5,0
10	16	30	5	25	11	1759	31,3	98,6	1,4	16,7
celkem pro 5 signálů	208	679	157	522	51	8270	75,5	94,1	5,9	23,1
celkem pro 10 signálů	272	895	184	711	88	17017	67,6	96,0	4,0	20,6

Tabulka 6: Statistika expert1 X VT

VT X expert1										
signál	expert1	VT	TP	FP	FN	TN	senzitivita (TPR) [%]	specificita (TNR) [%]	FPR [%]	prediktivita [%]
1	34	63	16	47	18	1719	47,1	97,3	2,66	25,4
2	45	45	23	22	22	1733	51,1	98,7	1,25	51,1
3	12	12	6	6	6	1782	50,0	99,7	0,34	50,0
4	78	111	37	74	41	1648	47,4	95,7	4,30	33,3
5	39	64	23	41	16	1720	59,0	97,7	2,33	35,9
6	28	64	11	53	17	1686	39,3	97,0	3,05	17,2
7	11	56	3	53	8	1736	27,3	97,0	2,96	5,4
8	4	6	2	4	2	1792	50,0	99,8	0,22	33,3
9	5	15	2	13	3	1773	40,0	99,3	0,73	13,3
10	16	7	1	6	15	1778	6,3	99,7	0,34	14,3
celkem pro 5 signálů	208	295	105	190	103	8602	50,5	97,8	2,16	35,6
celkem pro 10 signálů	272	443	124	319	148	17367	45,6	98,2	1,80	28,0

Tabulka 7: Statistika expert2 X TEO

TEO X expert2										
signál	expert2	TEO	TP	FP	FN	TN	senzitivita (TPR) [%]	specificita (TNR) [%]	FPR [%]	prediktivita [%]
1	19	153	13	140	6	1641	68,4	92,1	7,9	8,5
2	8	67	6	61	2	1731	75,0	96,6	3,4	9,0
3	3	18	1	17	2	1780	33,3	99,1	0,9	5,6
4	14	330	13	317	1	1469	92,9	82,3	17,7	3,9
5	20	111	20	91	0	1689	100,0	94,9	5,1	18,0
celkem pro 5 signálů	64	679	53	626	11	8310	82,8	93,0	7,0	7,8

Tabulka 8: Statistika expert2 X VT

VT X expert2										
signál	expert2	VT	TP	FP	FN	TN	senzitivita (TPR) [%]	specificita (TNR) [%]	FPR [%]	prediktivita [%]
1	19	63	12	51	7	1730	63,2	97,1	2,9	19,0
2	8	45	7	38	1	1754	87,5	97,9	2,1	15,6
3	3	12	2	10	1	1787	66,7	99,4	0,6	16,7
4	14	111	12	99	2	1687	85,7	94,5	5,5	10,8
5	20	64	16	48	4	1732	80,0	97,3	2,7	25,0
celkem pro 5 signálů	64	295	49	246	15	8690	76,6	97,2	2,8	16,6

Elektronické přílohy

Složka *Anezka_Balcarova_DP_prilohy.zip*:

- *Kkomplex.m* program automatického detektoru VT a TEO aplikovaný na celonoční záznam (nebo vybrané epochy) EEG z PSG databáze *009.mat*.
- *Kkomplex_demonstrace.m* program rychlé demonstrace výsledků automatické detekce VT a TEO aplikovaný na výřezu signálu EEG *zkraceny_009.mat*.
- *Hodnoceni_vysledku.m* program automatické detekce VT a TEO s demonstrací shod s expertem1 a expertem2 a statistické výpočty. Využívá signály z databáze *databaze.mat*.
- *Expert.xlsx* obsahuje data ohodnocení K-komplexů experty.
- *Statistika.xlsx* obsahuje výpočty celkové statistiky.

Soubor: *Anezka_Balcarova_DP.pdf*