

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky  
a komunikačních technologií

DIPLOMOVÁ PRÁCE

Brno, 2019

Bc. Kristýna Hlaváčová



# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

## FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

## ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

## DETEKCE K-KOMPLEXŮ VE SPÁNKOVÝCH SIGNÁLECH EEG

DETECTION OF K-COMPLEXES IN SLEEP EEG SIGNALS

### DIPLOMOVÁ PRÁCE

MASTER'S THESIS

### AUTOR PRÁCE

AUTHOR

Bc. Kristýna Hlaváčová

### VEDOUCÍ PRÁCE

SUPERVISOR

doc. Ing. Jiří Kozumplík, CSc.

BRNO 2019

# Diplomová práce

magisterský navazující studijní obor **Biomedicínské inženýrství a bioinformatika**  
Ústav biomedicínského inženýrství

**Studentka:** Bc. Kristýna Hlaváčová

**ID:** 174502

**Ročník:** 2

**Akademický rok:** 2018/19

## NÁZEV TÉMATU:

### Detekce K-komplexů ve spánkových signálech EEG

#### POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s metodami detekce K-komplexů ve spánkových signálech EEG. 2) Prostudujte Stockwellovu transformaci, navrhňte a realizujte algoritmus detekce K-komplexů s jejím využitím. 3) Dále navrhňte a realizujte algoritmus detekce s využitím Teagerova-Kaiserova energetického operátoru (TKEO). 4) Otestujte spolehlivost realizovaných metod na veřejně dostupných datech obsahujících i referenční polohy K-komplexů určené expertem. 5) Získané výsledky statisticky vyhodnoťte, porovnejte s výsledky dosažených jinými autory na stejných datech a vypracujte studii shrnující výsledky práce.

#### DOPORUČENÁ LITERATURA:

[1] 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.

[2] Zidelmal, Z., Amirou, A., Ould-Abdeslam, D., Moukadem, A., Dieterlen, A.: QRS Detection Using S-Transform and Shannon Energy. Computer Methods and Programs in Biomedicine, 116, Elsevier, 2014, pp 1–9.

**Termín zadání:** 4.2.2019

**Termín odevzdání:** 17.5.2019

**Vedoucí práce:** doc. Ing. Jiří Kozumplík, CSc.

**Konzultant:**

**prof. Ing. Ivo Provozník, Ph.D.**  
*předseda oborové rady*

#### UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

## **Abstrakt**

Tato diplomová práce se zabývá problematikou detekce K-komplexů ve spánkových signálech EEG. Záznam z elektroencefalografu je důležitý pro neinvazivní diagnostiku a výzkum aktivity mozku. Snímaný signál se používá pro vyšetření fází spánku, projevů poruch, stavů vědomí a vlivů různých látek. Tato práce se věnuje automatické detekci K-komplexů, jelikož manuální označování grafoelementů je komplikované. Bylo využito dvou přístupů-Stockwellovy transformace a filtrace pásmovou propustí s následnou aplikací operátoru TKEO. Algoritmy byly vytvořeny v prostředí MATLAB R2014a.

## **Klíčová slova**

K-komplex, grafoelement, Elektroencefalografie (EEG), Stockwellova transformace, pásmová propust, TKEO

## **Abstract**

This master's thesis deals with issues of the detection of K-complexes in EEG sleep signals. Record from an electroencephalograph is important for non-invasive diagnosis and research of brain activity. The scanned signal is used to examine sleep phases, disturbances, states of consciousness and the effects of various substances. This work follows the automatic detection of K-complexes, because the manual labeling of graphoelements is complicated. Two approaches were used – Stockwell transform and bandpass filtration followed by TKEO operator application. All algorithms were created in the MATLAB R2014a.

## **Keywords**

K-complex, grafoelement, Electroencephalography (EEG), Stockwell transform, bandpass, TKEO



## **Bibliografická citace:**

HLAVÁČOVÁ, K. *Detekce K-komplexů ve spánkových signálech EEG*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2019. 78s. Vedoucí práce: doc. Ing. Jiří Kozumplík, CSc.

## **Prohlášení**

„Prohlašuji, že svou diplomovou práci na téma Detekce K-komplexů ve spánkových signálech 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 závěrečné 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 vědoma následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brně dne .....

.....

podpis autora

## **Poděkování**

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

V Brně dne .....

.....

podpis autora

# Obsah

1.	Úvod .....	1
1	Bdění a spánek.....	2
1.1	Bdění.....	2
1.2	Spánek.....	2
1.2.1	Non-REM spánek.....	3
1.2.2	REM spánek.....	3
2	Elektroencefalografie .....	5
2.1	Snímání signálu EEG.....	5
2.1.1	Umístění elektrod .....	5
2.2	Elektroencefalograf.....	6
2.2.1	Přístroje používané v souvislosti s EEG .....	7
2.3	Deskriptory EEG vzorců.....	7
2.4	Základní vlny EEG záznamu.....	9
2.4.1	Grafoelementy .....	10
2.4.2	Artefakty.....	12
3	Metody detekce K-komplexů.....	14
3.1	Metoda detekce využívající vlnkovou transformaci.....	14
3.2	Metoda detekce využívající Teagerův-Kaiserův operátor .....	16
3.3	Metoda detekce využívající umělou neuronovou síť .....	17
3.4	Metoda detekce založená na měřených parametrech a odvození pravděpodobnosti výskytu komplexu.....	20
3.5	Metoda detekce založená na CWT s vlnkami tvarově souhlasnými s K- komplexy .....	24
4	Realizace algoritmu .....	28
4.1	Popis databáze EEG signálů.....	29
4.2	Předzpracování signálu.....	30
4.2.1	Stockwellova transformace.....	31
4.2.2	Lineární filtrace pásmovou propustí.....	34
4.3	Odhad obálky signálu .....	34
4.3.1	Umocnění na druhou .....	35
4.3.2	Shannonova energie.....	36
4.3.3	Aplikace Teagerova-Kaiserova operátoru.....	38
4.4	Detekce vrcholů pomocí prahů .....	40
4.5	Detekce vrcholů na základě doby trvání vlny a podmínka mezi extrémy .	42
4.6	Rozhodnutí o K-komplexu.....	44
5	Porovnání výsledků .....	50
6	statistické vyhodnocení.....	55

6.1	Referenční hodnoty.....	56
6.2	Zhodnocení realizovaných metod .....	61
6.3	Srovnání s dalšími metodami.....	68
7	Závěr .....	70
	Literatura .....	72
	Seznam symbolů, veličin a zkratk.....	75
	Seznam příloh.....	76

## Seznam obrázků

Obr. 1.1 Spánkový cyklus dospělého člověka v rámci 8 hodin [14] .....	4
Obr. 2.1 Systém 10-20 [4] .....	6
Obr. 2.2 Základní vlny EEG signálu [10] .....	10
Obr. 2.3 Grafoelemety vyskytující se v EEG signálu [10] .....	11
Obr. 2.4 Artefakty ovlivňující záznam EEG [10] .....	13
Obr. 3.1 Desetisekundový záznam signálu s typickým tvarem K-komplexu [3] .....	14
Obr. 3.2 Rozklad vlnkové transformace na jednotlivá pásma [3] .....	15
Obr. 3.3 K-komplex s vyznačenými časy a extrémní výchylek signálu [3] .....	16
Obr. 3.4 Podmínky pro detekci vrcholu [3] .....	17
Obr. 3.5 Použitá dopředná neuronová síť [22] .....	18
Obr. 3.6 Charakteristické znaky pro tvar K-komplexu [22] .....	19
Obr. 3.7 Křivka prahování poskytující pravděpodobnost skutečného K-komplexu [1] .....	20
Obr. 3.8 Označení významných bodů na reálném K-komplexu a jiné vlně [1] .....	21
Obr. 3.9 Vzor vlnky s původním K-komplexem [18] .....	26
Obr. 3.10 Úsek EEG se škálovaným [18] .....	26
Obr. 4.1 Schéma navrženého detektoru K-komplexů .....	29
Obr. 4.2 Původní signál s vyznačenými počátky K-komplexů dle experta 1 .....	30
Obr. 4.3 Úsek původního zašuměného signálu s vyznačenými počátky K-komplexů expertem 1 .....	31
Obr. 4.4 Úsek původního signálu-expert 1 .....	33
Obr. 4.5 Spektrogram úseku signálu .....	33
Obr. 4.6 Původní a filtrovaný signál pásmovou propustí-expert 1 .....	34
Obr. 4.7 Úsek původního signálu-expert 1 .....	36
Obr. 4.8 Odhad obálky signálu umocněním energie signálu na druhou-expert 1 .....	36
Obr. 4.9 Úsek původního signálu-expert 1 .....	37
Obr. 4.10 Odhad obálky signálu Shannonovou energií-expert 1 .....	37
Obr. 4.11 Úsek původního signálu-expert 1 .....	39
Obr. 4.12 Odhad obálky signálu TKEO-expert 1 .....	39
Obr. 4.13 Odhad obálky signálu umocněním na druhou-expert 1 .....	40
Obr. 4.14 Odhad obálky signálu TKEO s vrcholy a postupnými prahy-expert 1 .....	41
Obr. 4.15 Odhad obálky signálu Shannonovou energií s vrcholy a postupnými prahy-expert 1 .....	41
Obr. 4.16 Filtrovaný signál s detekovanými vrcholy splňující podmínku sklonu-expert 1 .....	43
Obr. 4.17 Filtrovaný signál s detekovanými vrcholy splňující podmínku extrémů mezi minimální a maximální výchylkou-expert 1 .....	43

Obr. 4.18 Filtrovaný signál s detekovanými vrcholy splňující podmínku extrémů a sklonu mezi minimální a maximální výchylkou-expert 1.....	44
Obr. 4.19 Úsek původního signálu-expert 1 .....	45
Obr. 4.20 Výsledek detekce po S-transformaci s odhadem obálky umocněním na druhou a podmínkou sklonu-expert 1 .....	45
Obr. 4.21 Výsledek detekce po filtraci pásmovou propustí s odhadem obálky s využitím operátoru TKEO a podmínkou sklonu-expert 1.....	46
Obr. 4.22 Výsledek detekce po S-trasformaci a s odhadem obálky Shannonovou energií a podmínkou sklonu-expert 1.....	46
Obr. 4.23 Úsek původního signálu-expert 1 .....	47
Obr. 4.24 Výsledek detekce po S-transformaci s odhadem obálky umocněním na druhou-expert 1.....	47
Obr. 4.25 Výsledek detekce po filtraci pásmovou propustí s odhadem obálky s využitím operátoru TKEO-expert 1 .....	48
Obr. 4.26 Výsledek detekce po S-trasformaci a s odhadem obálky Shannonovou energií-expert 1 .....	48
Obr. 5.1 Úsek původního signálu s vyznačenými počátky K-komplexů expertem 1 .....	50
Obr. 5.2 Úsek původního signálu s vyznačenými počátky K-komplexů expertem 2 .....	50
Obr. 5.3 Výsledek detekce po S-transformaci s odhadem obálky umocněním na druhou-expert 1.....	51
Obr. 5.4 Výsledek detekce po S-transformaci s odhadem obálky umocněním na druhou-expert 2.....	51
Obr. 5.5 Výsledek detekce po filtraci pásmovou propustí s odhadem obálky s využitím operátoru TKEO-expert 1 .....	52
Obr. 5.6 Výsledek detekce po filtraci pásmovou propustí s odhadem obálky s využitím operátoru TKEO-expert 2 .....	52
Obr. 5.7 Výsledek detekce po S-trasformaci s odhadem obálky Shannonovou energií-expert 1 .....	53
Obr. 5.8 Výsledek detekce po S-trasformaci s odhadem obálky Shannonovou energií-expert 2 .....	53
Obr. 6.1 Graf počtu ohodnocených K-komplexů jednotlivými experty .....	57
Obr. 6.2 Graf porovnání falešně pozitivních a falešně negativních detekcí-expert 1 .....	58
Obr. 6.3 Graf porovnání senzitivity a prediktivity-expert 1 .....	59
Obr. 6.4 Graf porovnání falešně pozitivních a falešně negativních detekcí-expert 2 .....	60
Obr. 6.5 Graf porovnání senzitivity a prediktivity-expert 2 .....	60

Obr. 6.6 Graf porovnání falešně pozitivních a falešně negativních detekcí-expert 1 .....	65
Obr. 6.7 Graf porovnání senzitivity a prediktivity-expert 1 .....	66
Obr. 6.8 Graf porovnání falešně pozitivních a falešně negativních detekcí-expert 2 .....	67
Obr. 6.9 Graf porovnání senzitivity a prediktivity-expert 2 .....	67



## Seznam tabulek

Tab. 6.1 Počet ohodnocených K-komplexů jednotlivými experty .....	56
Tab. 6.2 Statistické parametry pro porovnání hodnocení experta 1 vůči expertu 2 .....	57
Tab. 6.3 Statistické parametry pro porovnání hodnocení experta 2 vůči expertu 1 .....	59
Tab. 6.4 Statistické parametry pro metodu operátor TKEO-sklon .....	61
Tab. 6.5 Statistické parametry pro metodu Stockwellova transformace-sklon.....	62
Tab. 6.6 Statistické parametry pro metodu operátor TKEO-extrém.....	62
Tab. 6.7 Statistické parametry pro metodu Stockwellova transformace-extrém ....	63
Tab. 6.8 Statistické parametry pro metodu operátor TKEO-sklon a extrém .....	63
Tab. 6.9 Statistické parametry pro metodu Stockwellova transformace-sklon a extrém.....	64
Tab. 6.10 Statistické parametry pro metodu S-transformace s Shannonovou energií-sklon .....	64
Tab. 6.11 Soubor metod využívající se pro detekci K-komplexů ve spánkových signálech EEG.....	69

# 1. ÚVOD

Elektroencefalografie se v dnešní době uplatňuje jako neinvazivní způsob vyšetření signálů pocházejících z mozku. Jedná se o šetrnou metodu, která není pro pacienta stresující a nijak nepoškozuje jeho organismus. Signály EEG hrají důležitou roli při diagnostice různých onemocnění spojených s funkcí mozku. Použití této vyšetřovací metody je hojné při diagnostice stavů vědomí, projevů metabolických potuch, fází spánku a vlivů drog a dalších toxických látek. Detekce K-komplexů může odhalit onemocnění, jakými jsou například syndrom neklidných nohou [15], epilepsie [2] či obstruktivní spánková apnoe [5].

Na začátku práce je uveden popis biologických dějů, které se opakují v denním rytmu života člověka, jedná se o bdění a spánek. Charakteristika těchto stavů je důležitá pro pochopení fungování aktivity lidského mozku a signálů s ní spojených.

Druhá kapitola se zaměřuje na vysvětlení funkce a technického sestavení elektroencefalografu a přístrojů, které se používají v souvislosti s daným zařízením při vyšetření. Dále jsou charakterizovány typické základní vlny díky nimž, můžeme analyzovat záznam EEG. Uvádím zde i jednotlivé grafoelementy, mezi které patří K-komplexy a artefakty, které mohou ovlivňovat snímaný signál.

Následující část obsahuje literární rešerši o používaných metodách detekcí K-komplexů. Popisují zde zejména metodu detekce využívající vlnkovou transformaci, jež nachází hojné uplatnění při zpracování signálů v medicíně i jiných odvětvích. Uvádím metodu detekce s aplikací Teagerova-Kaseirova operátoru, která byla předlohou pro vytvoření jedné části diplomové práce. Dále je objasněna metoda detekce využívající umělou neuronovou síť, jelikož se tento přístup využívá při zpracování nelineárních signálů, a metoda detekce založená na CWT s vlnkami tvarově souhlasnými s K-komplexy. Součástí diplomové práce jsou data, která byla získána při studii detekce založené na měřených parametrech a odvození pravděpodobnosti výskytu komplexu, jež je vysvětlena v tomto oddílu.

Čtvrtá kapitola vysvětluje vytvořený algoritmus pro automatickou detekci K-komplexů, který byl navržen v prostředí MATLAB R2014a. Byly vyvinuty tyto metody: metoda detekce využívající Stockwellovu transformaci a odhad obálky umocněním signálu na druhou a Shannonovu energii a metoda lineární filtrace pásmovou propustí s aplikací Teagerova-Kaiserova operátoru. Rozhodnutí o označení K-komplexu tvoří srovnání výsledků detekce vrcholů těchto metod s výsledkem detekce filtrovaného signálu.

Závěr je shrnutím vybraných metod, jejich statistickým zhodnocením, srovnáním s jinými studiemi a dalších návrhů na případné zlepšení detekčních algoritmů.

# 1 BDĚNÍ A SPÁNEK

Jedním z biologických dějů, jež se periodicky opakují v cirkadiánním rytmu je střídání bdění a spánku. Spánek je nezbytným elementem pro správné fungování nervové soustavy. Spánek a bdění se vzájemně doplňují.

Spánek je projevem útlumu v centrálním nervovém systému šířící se po rozsáhlých korových a některých podkorových oblastech. Ve spánku se činnost centrálního nervstva pozměňuje tak, že se její funkční projevy rozlišují od stavu bdělosti, někdy to nazýváme "bdělými body v mozkové kůře". Označuje se tak například schopnost matky vzbudit se při velmi slabém nářku potomka, zatímco k okolí hluku zůstává lhostejná.

Pojem vědomí má v neurovědních souvislostech dva základní významy. Je to bdělost a stav uvědomování si sama sebe a reality okolí. Vědomí, které je chápáno jako bdělost se označuje jako vigilita. Na rozdíl od bdělé pozornosti, jež bývá nazývána vigilancí. V době vigility jedinec reaguje na běžnou aferentaci. Při vigilanci je možný nárůst efektivity sensorického systému. Ten je bdělou pozorností zaneprázdněn, ale i útlumem jiných systémů. Příkladem může být kočka sledující myš, kterou nezajímají běžné zvukové podněty; v jejich kochleárních jádrech není možné zaznamenat vzruchovou činnost [17].

## 1.1 Bdění

Pro stav bdělosti je typická činnost vzestupného facilitačního systému retikulární formace, nespecifického systému talamu a některých vegetativních center hypotalamu.

Vedlejší větve specifických dostředivých drah směřující k nespecifickému vzestupnému aktivačnímu systému jsou pro stav bdělosti signifikantní. Jedinec snáze usne, jestliže dochází ke snižování aferentnosti - např. při nižší intenzitě smyslového dráždění v tichu a temnu.

Probouzecí reakce je uvedení v činnost výše postavených struktur, což je umožněno retikulární formací. Působení ascendentního aktivačního systému je nespecifické. Podrážděním smyslu je vyvolána aktivace vzestupného aktivačního systému pozbývá modalitní specifičnost. K probuzení může dojít také aktivací korových oblastí i činností limbického systému [17].

## 1.2 Spánek

V období spánku dochází k opakujícím se jevům. Spánek elementárně rozdělujeme do dvou skupin: Non-REM spánek (pomalý, s pomalými vlnami, telencefalický) a REM spánek (aktivovaný, paradoxní, rhombocefalický). Každá z těchto skupin má ještě další dělení, jež je uvedeno níže. Za noc proběhnou zhruba čtyři cykly, kdy se

střídají fáze REM a Non-REM spánku. Periodicita spánku se ontogenicky mění, a to jak potřeba spánku, tak jeho struktura. Fáze REM při narození jedince představuje 50 % doby spánku. S navyšujícím se věkem se interval spánku snižuje, čímž dochází i k poklesu regenerace těla jedince [17].

### 1.2.1 Non-REM spánek

Jedná se o první fázi spánku, která se diferencuje na:

- Stadium 1: Na signálu EEG zaniká  $\alpha$  aktivita a je nahrazena aktivitou  $\theta$ . Toto stadium odpovídá somnolenci, kdy jedinec dřímá, ale ještě reaguje na výzvu k otevření očí.
- Stadium 2: Jedinec spí a nereaguje na standardně hlasitou řeč. V elektroencefalogramu můžeme pozorovat  $\theta$  aktivitu, jejíž průběh je přerušován spánkovými vřeteny (stoupající a klesající amplituda) a K-komplexy (pomalé, nepravidelné  $\delta$  vlny před spánkovým vřetenem). Druhé stadium trvá celkem 50 % doby spánku.
- Stadium 3: Při pohledu na záznam EEG je viditelné, že je tvořen 20-50 %  $\delta$  vln. Dále se v signálu objevují hlavně  $\theta$  vlny. V menším výskytu zde také mohou být spánková vřetena a K-komplexy. Třetí fáze se vytrácí ke konci spánku.
- Stadium 4: Signál EEG je v tomto stádiu vymezen nejméně z 50 %  $\delta$  vlnami. Zpravidla nepozorujeme spánková vřetena ani K-komplexy. Třetí a čtvrté stádium zahrnuje asi 15 % celkové doby spánku. Poslední stádium Non-REM se vyskytuje v první polovině spánku [17].


### 1.2.2 REM spánek

REM spánek přichází na řadu zhruba po 90 minutách. Záznam z elektroencefalografu je nepravidelný a pozorujeme kombinaci vln  $\alpha$  a  $\beta$ .

U jedince dochází ke ztrátě svalového tonu. Výjimku však tvoří okohybné svaly, které se nepravidelně fázicky smršťují. Dochází k očním pohybům, podle čehož byl odvozen i název tohoto spánkového cyklu (Rapid Eye Movement). V této fázi jedinec takzvaně sní.

Převládající aktivita sympatiku způsobuje pokles motility gastrointestinálního traktu, zvýšení krevního tlaku a srdeční frekvence. Dýchání je rychlejší a nepravidelné. V tomto cyklu připomíná signál EEG spíše bdělý stav, avšak práh pro probuzení je zvýšený. Jedná se tedy o hluboký spánek, a proto bývá někdy označován jako paradoxní.

Spánek REM zaujímá asi 25 % celkové doby trvání spánku. Každý interval REM trvá 5-20 minut. Období fáze REM v cyklech v průběhu spánku je postupně delší a dochází zde ke spontánnímu probuzení [17].



Obr. 1.1 Spánkový cyklus dospělého člověka v rámci 8 hodin [14]

Na vodorovné ose je zaznamenán čas v hodinách a na svislé ose jsou jednotlivá stádia Non-REM spánku.

## 2 ELEKTROEKCEFALOGRAFIE

Aktivita nervových buněk centrálního nervového systému je doprovázena elektrickými jevy. Tyto jevy můžeme zaznamenat a na jejich základě provádět diagnostiku. Základem elektrické aktivity nervových buněk je depolarizace a repolarizace jejich buněčné membrány. Ta putuje z těla buňky do výběžků-dendritů a neuritů. Dochází tak ke vzniku elektrického dipólu, který se stává zdrojem lokálních proudů. Tkáň mozku zahrnuje obrovské množství synapsí, které jsou zdroji excitačních nebo inhibičních elektrických potenciálů. Prostorovým a časovým součtem elementárních elektrických dějů vzniká výsledný obraz elektrické aktivity mozku, který je podkladem elektrodiagnostické neinvazivní metody elektroencefalografie nebo také zkráceně EEG. Méně často je potřeba měřit aktivitu přímo z povrchu kůry mozku pomocí inertních elektrod pomocí elektrokorťografu ECoG. Vyšetření se provádí u poruch funkcí mozku v neurologii, ale také v psychiatrii. Užívá se k diagnostice epilepsie, spánkových poruch, nádorů atd., tedy při potřebě určení rozložení elektrické činnosti v určitých oblastech mozku [16] [9].

Kromě snímání spontánní elektrické aktivity se z diagnostických důvodů provádí i nepřímé sensorické dráždění mozku kůry. Toto se děje například s využitím zrakového nebo sluchového analyzátoru. Odpovědí na takové podráždění jsou evokované potenciály, které se zaznamenávají stejnou technikou jako EEG [16].

Daný záznam závisí na mnoha faktorech. Je podmíněn zejména věkem jedince a jeho psychickým stavem, sensorickou stimulací, pohyby očí, jazyka a svalů. Dále podléhá také tomu, zda-li subjekt užívá léky, drogy či alkohol a v jaké míře je na nich závislý.

### 2.1 Snímání signálu EEG


Jak již bylo uvedeno [16], signál EEG je dán sumací veškerých elektrických dějů snímaných elektrodou. Abychom mohli porovnávat záznamy EEG je třeba určit si podmínky snímání. Pacient by měl být v sedě a uvolněný. Oči má mít zavřené a ústa pootevřená. Rozmístění elektrod, jejich počet a propojení je dle standardního systému 10-20, který je vysvětlen níže. Posuvná rychlost papíru zapisovače je 3 cm/s a citlivost přístroje je určena na 100  $\mu\text{V}/\text{cm}$ . Kmitočtová charakteristika zesilovače je v rozmezí 0,5 až 110 Hz, z čehož se za užitečné pásmo považuje zhruba 30 až 60 Hz [6].

#### 2.1.1 Umístění elektrod

Pro umístění elektrod na povrchu lebky se využívá rozměřování vycházející z výčnělků na lebce, a následné rozdělení vzdáleností po 10 % a 20 %, jehož mezinárodní název je systém 10-20 (Obr. 2.1). Vymezuje se tak umístění a název každé z 19 základních elektrod. Rozměry elektrod musí být malé, aby se dalo

přesně určit místo snímání. Písmena na schématu označují oblast mozku, nad kterou se elektroda nachází: frontální, centrální, parietální (temenní), temporální (spánkový), okcipitální (týlní) a aurikulární (ušní). Lichá čísla se používají pro levou hemisféru a sudá čísla pro hemisféru pravou.

Další možnou strukturou rozmístění elektrod je systém 10-10. Pro výzkumné účely se může použít až 128 elektrod. Toto maximum je dáno prostorovým omezením na lebce [21] [10] [6] [9].



Obr. 2.1 Systém 10-20 [4]

Tento systém se využívá pro umístění elektrod na lebce. Elektrody musí být nepolarizovatelné (mají stálý elektroodový potenciál). Z tohoto důvodu se používají elektrody ze vzácných kovů jako je zlato, nebo stříbrné elektrody s vrstvou AgCl v kombinaci s roztoky snižujícími přechodový odpor elektroda-kůže. Takovým roztokem je například přesycený fyziologický roztok. Dále se aplikují i elektroodové gely a pasty s volnými ionty Cl<sup>-</sup>. Elektrody se upevňují na lebku lepením pomocí koloida nebo EEG pasty. EEG pasta se využívá v případě, kdy je potřeba dlouhodobý záznam. Nasazením elastické čepice dochází také k fixaci elektrod. V závislosti na obvodu hlavy jedince mají čepice různé rozměry. Do elektrod se posléze aplikuje injekční stříkačkou EEG gel [21].

Speciální elektrody se využívají při snímání polygrafických záznamů, kdy se stejným přístrojem registrují křivky očních pohybů-elektrookulogram (EOG), svalové aktivity-elektromyogram (EMG), činnosti srdce-elektrokardiogram (EKG), dýchání a dechové pohyby, pohyby těla, saturace kyslíku v periferní krvi atd. Rozdílností záznamů je odlišné nastavení zesílení a filtrů než pro EEG. Používá se vzorkovací frekvence 64 Hz, která je nižší [21].

## 2.2 Elektroencefalograf

Základním prvkem EEG je diferenční zesilovač. Součástka zesílí elektrický signál na

povrchu hlavy z desítek mikrovoltů na úroveň vhodnou pro další zpracování, zobrazení a záznam (jednotky voltů). Základním požadavkem na zesilovač je velký vstupní odpor-desítky  $M\Omega$ , rozdílové zesílení řádově  $10^6$ , minimální vlastní šum a velká hodnota CMR. Přístroj je složen z přepínače, který přivádí na měřič odporu elektrod signál ze svodových míst. Měřič odporu kontroluje velikost přechodového odporu, aby nedocházelo ke zkreslení měření. Dohlíží se tak na správnost zapojení elektrod. Na přepínač je napojen zdroj kalibračního napětí. Za přepínač je instalován zesilovač, filtry: horní propust, dolní propust a úzkopásmovou zadrž a další zesilovač. Nakonec je zapojen registrační systém. Obsluhující pracovník musí mít možnost si do záznamu vložit značky vymezuující určité děje [6] [9].

### **2.2.1 Přístroje používané v souvislosti s EEG**

Ve spojení s elektroencefalografem se obvykle používají fotostimulátory, fonostimulátory, magnetické záznamy signálu a analyzátory signálu EEG.

Fotostimulátor je zábleskové zařízení, které umožňuje vysílat na pacienta světelné podněty s danou dobou trvání, intenzitou a opakovací frekvencí. Ze světelného záblesku je možné odebrat elektrický impuls značící vyslání světelného záblesku. Impuls je využit k vytvoření značky v záznamu nebo ke spuštění zprůměrování při počítačovém zpracování signálu. K vytvoření záblesku se využívá xenonové výbojky nebo zářivkové trubice. Od použité výbojky se odvíjí konstrukce fotostimulátoru [6].

Fonostimulátor vytváří definované akustické podněty, které se přivádí k pacientovi pomocí sluchátek nebo reproduktorové skříně. V případě využití sluchátek je možnost střídat podněty pro pravé a levé ucho nebo podněty kombinovat s šumem. I v tomto případě je nutné zaznamenat počátek a konec impulsu značkami [6].

Vícekanálový magnetický záznam signálu je využíván pro déle trvající záznamy při zkoumání činnosti aktivity mozku. Používá se měřících magnetofonů, které jsou složeny z modulátoru a demodulátoru a tvoří tedy tzv. modem. Modemy se speciální úpravou se používají k přenosu biologických signálů po telefonním vedení [6].

Jako analyzátor EEG signálu se dříve používalo frekvenční pravítko. Jedná se o průhledné pravítko umožňující pro posuvnou rychlost 3 cm/s odečíst hodnoty kmitočtů jednotlivých vln a velikosti amplitud signálu. Tento proces byl velmi náročný. S rozvojem výpočetní techniky se pro analýzu signálu využívají počítače, na kterých je možné měnit volbu druhu analýzy změnou programu [6].

### **2.3 Deskriptory EEG vzorců**

Elektroencefalogram je popisován na základě vzorců a jejich vlastností. Ve vzorcích musí být rozpoznána frekvence, amplituda, tvar, distribuce, šíření, symetrie,



synchronie, rytmicita, periodicita, perzistence a reaktivita. Pomocí deskriptorů můžeme od sebe odlišit normální a abnormní vlny křivek [24].

- Frekvence je počet vln, jež se opakují za 1 s a je vyjádřena v Hz. Obvykle se shrnuje do frekvenčních pásem  $\alpha$ ,  $\beta$ ,  $\theta$  a  $\delta$ , která jsou rozvedena níže v části 2.4. Někdy se užívá pojmenování vln pod 8 Hz jako vlny pomalé a s frekvencí nad 13 Hz jako vlny rychlé.
- Úroveň signálu představuje vertikální rozměr vzorce a její jednotkou v tomto případě je mikrovolt. Můžeme ji rozdělit do 3 tříd na amplitudu nízkou (pod 20  $\mu\text{V}$ ), střední (20-50  $\mu\text{V}$ ) a vysokou (nad 50  $\mu\text{V}$ ). Měření přesné hodnoty rozkmitu je sporné a záleží na mnoha faktorech jako je třeba vzdálenost mezi elektrodami.
- Tvar se uvádí ve vztahu k morfologii vln. Pravidelné vlny jsou takové, které mají zhruba symetrický vzestupný a sestupný úsek. Dokonalé souměrnosti v případě EEG signálu není nikdy dosaženo. Série pravidelných vln, která je nazývána rytmem se může podobat sinusoidnímu, pilovitému nebo arkádovému tvaru. Vlny, jež nemají souvislou křivku a souměrné vzestupné a sestupné fáze označujeme jako nepravidelné. Díky kolísání křivky okolo nulové linie můžeme rozeznat vlny monofázické, bifázické, trifázické nebo polyfázické. Pokud není nulová linie prořazena, pak je vzorec první superponován na druhý. Trazient je vzorec vyčnívající proti pozadí amplitudou či frekvencí, např. hrot.
- Distribuce je elektroda nebo elektrody, ve kterých je EEG signál nejlépe zachycován. Generalizovaná distribuce jsou vzorce, jež jsou zachycovány ve stejné době v elektrodách na obou stranách hlavy nebo veškerých elektrodách. V případě difuzní distribuce se vzorec vyskytuje v elektrodách nad oběma hemisférami stejně, zatímco lateralizovaný vzorec se vyskytuje nad jednou polovinou hlavy. Činnost ložisková (fokální) je redukována na jednu elektrodu. Mnoha sousedními elektrodami je snímána aktivita regionální.
- Šíření je zmiňováno, pokud se vzorec vyskytuje s nižší amplitudou nebo menším fázovým posunem v další elektrodě.
- Symetrie se vztahuje k amplitudě a jedná se o popis činností stejného charakteru nad stejnými místy na skalpu. Dokonce drobné rozdíly mohou být klinicky významné.
- Synchronie charakterizuje vzájemnou časovou souvislost jednotlivých vln a vzorců. Současný výskyt dvou nebo více vzorců vyskytujících se ve shodném čase, ale nejsou-li ve fázi nazýváme jako simultánní. Bilaterální je synchronie nalézající se na stranově odpovídajících elektrodách.

Asynchronní označíme vzorce, které jsou nad oběma hemisférami bez konstantního časového vztahu.

- Reaktivita je navozená změna ve vzorci zevními stimuly, které se používají při zjištění odpovědi na podráždění.
- Rytmicita se týká opakování jednotlivých vln. Mohou být rytmické, jejichž jednotlivé vlny se opakují se shodnou frekvencí, či naopak arytmičné. Rytmičné mohou být i nepravidelné vlny.
- Perzistenci charakterizujeme frekvencí, s níž se vzorec v delší části nalézá. Frekvenci popisujeme indexem jako podíl z doby natáčení, během kterého se EEG vzorec vyskytne.
- Periodicita představuje popis opakujících se tranzientů pojmu periodicita.

## 2.4 Základní vlny EEG záznamu

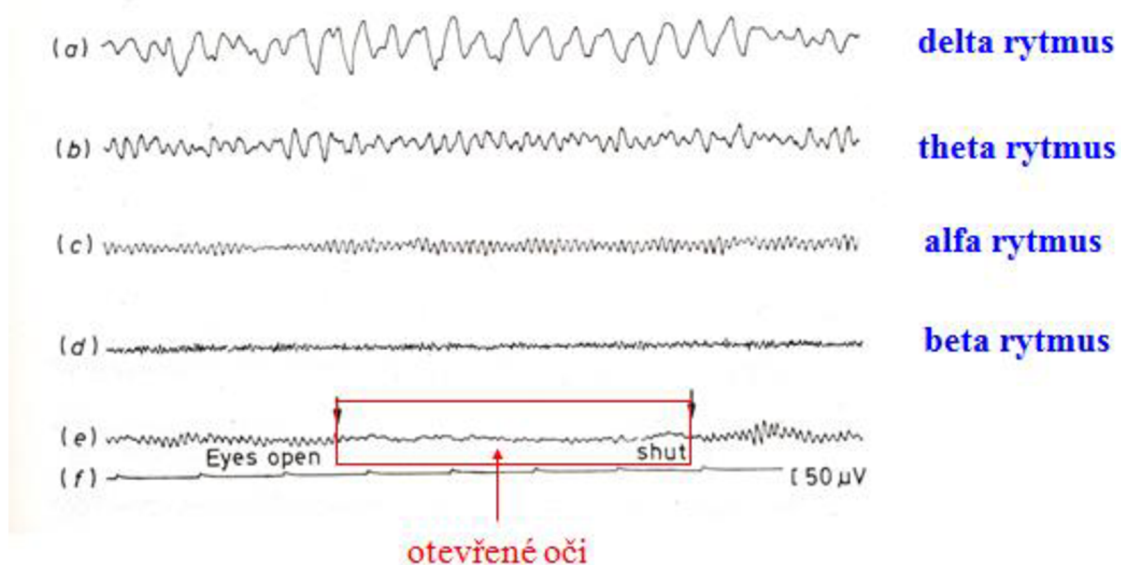
Sinusoidní vlny signálu EEG se dělí podle frekvence měřené mezi minimy nebo maximy do čtyř základních pásem označovaných řeckými písmeny  $\alpha$ ,  $\beta$ ,  $\theta$  a  $\delta$  [21].

Vlny  $\delta$  mají kmitočet od 0,5 do 4 Hz a jejich velikost bývá 100  $\mu\text{V}$ . Vycházejí z centrální oblasti mozku. Tento rytmus je pomalý a normálně se vyskytuje u novorozenců a u dospělého jedince indikují spánek. Pokud se jeho přítomnost prokáže u dospělého člověka v bdělém stavu, tak poukazuje na určitou patologii [9] [10].

V kmitočtovém rozsahu 4-8 Hz s velikostí do 15  $\mu\text{V}$  se nacházejí vlny  $\theta$ , které mají málokdy rytmický charakter. Dříve bývaly označovány jako polyfázické vlny nebo také zadní pomalé vlny mladistvých. Vychází z centrální oblasti mozku. Rytmus se objevuje při usínání a přechází ve vlny  $\delta$ . U mladých jedinců se může vyskytovat při emocích [9] [24].

Rytmus  $\alpha$  má frekvenční ohraničení 8-13 Hz a střední velikost úrovně signálu u dospělých jedinců je 20-80  $\mu\text{V}$ . Aktivita  $\alpha$  má význam pro hodnocení signálu EEG pomyslnou startovní čáru. Vychází z posterioerní části mozku. Aktivita  $\alpha$  bývá sinusoidního charakteru a některé vlny mohou mít ostré obrysy. Rytmičné vlny odpovídají stavu klidu a relaxace, kdy má jedinec zavřené oči, ale nespí. Aktivita mizí, pokud jedinec otevře oči, rušením okolními podněty nebo ospalostí [10].

Skupinu zakončují vlny  $\beta$ , které mají kmitočet od 13 do 30 Hz s velikostí rozkmitu do 30  $\mu\text{V}$ . Vychází především z centrální oblasti mozku. Aktivita  $\beta$  ubývá v případě, kdy je jedinec ospalý a usíná. Tento rytmus odpovídá zvýšené pozornosti při duševní činnosti [10] [24].



Obr. 2.2 Základní vlny EEG signálu [10]

### 2.4.1 Grafoelementy

V záznamu EEG se vyskytují také další charakteristické vlny, které se nazývají jako grafoelementy. Tyto vlny jsou obvykle vázané na patologické jevy a jejich znalost je důležitá pro klasifikaci poruch rytmu.

V normálních EEG signálech se méně často vyskytují  $\lambda$  vlny. Jsou to bi-trifázické vlny s pozitivní či jindy negativní polaritou. Vznik těchto vln je podmíněn trhavým očním pohybem a bývá způsoben, pokud je jedinci zobrazován dobře osvětlený barevný vzor. Někdy se může měnit v artefakty způsobené pohybem očí. Abnormitou je jejich nízká výchylna. Nejčastěji se vyskytují u dětí [24].

Dalším rytmem, který bývá popisován, ale nepatří do základní skupiny vln je rytmus  $\mu$ . Ten se často vyskytuje u psychicky narušených jedinců. Má frekvenci od 7 do 11 Hz s amplitudou do 50  $\mu$ V. Tvar vln je arkádový a připomíná opakující se řecké písmeno  $\mu$  [10] [24].


Pozitivní okcipitální ostré tranzienty ve spánku nebo také POSTS připomínají vlny  $\lambda$ . Jsou to pozitivní, monofázické, trojúhelníkové vlny s vyšší asymetrickou amplitudou. Nepravidelně se opakují s periodicitou až 6x za sekundu. Nejčastěji se vyskytují u mladých dospělých jedinců, kteří byli částečně probuzeni a rychle usínají [24].

Vertexové vlny jsou negativní, synchronní a symetrické vlny. Pro tyto vlny je charakteristická změna fáze přes střední čáru. Opakování vertexových vln je nepravidelné. Málokdy se vyskytují častěji než dvě za sekundu [24].

Sinusoidní vřetenovitý tvar mají spánková vřetena, která jsou také klasifikována jako grafoelementy. Jejich frekvence je v rozmezí od 11 do 15 Hz,

nejčastěji však 14 Hz. Jsou souměrné a synchronní s trváním několik málo sekund a širokou distribucí [24].

Posledním zmiňovaným grafoelementem je K-komplex, který je velmi podobný vertexovým vlnám. Na rozdíl od těchto vln má však komplex delší trvání a je méně ostrý. Mohou mít bifázický nebo trifázický tvar a jsou mnohdy předcházeny nebo následovány pozitivní částí. Za komplexem se většinou vyskytuje spánkové vřeteno. Jejich výskyt může být vyvolán zevními podněty. Jestliže se komplexy vyskytují samovolně, tak jsou pravděpodobně odpovědí na aferentní podněty interoreceptorů. Mohou se také řetězit do skupin. Popis K-komplexů je často subjektivní a může vést k chybám [24].



**Obr. 2.3 Grafoelementy vyskytující se v EEG signálu [10]**

V prvním průběhu a) je na obrázku (Obr. 2.3) viditelný K-komplex, ve druhém b) jsou vlny  $\lambda$ . Dále c) je uveden  $\mu$  rytmus. V pořadí čtvrté d) jsou zobrazeny hroty o délce trvání 20-30 ms, v bodě e) je uveden příklad ostrých vln 70-200 ms. Jako další f) jsou zaznamenány komplexy hrotů a vln. Spánková vřetena jsou viditelná v bodě g). Předposlední h) jsou ostré vlny v délce trvání 70-200 ms a vyobrazenou skupinu i) uzavírají vícehrotové useky.

## 2.4.2 Artefakty

Grafoelementy, které nejsou způsobeny elektrickou aktivitou mozku nazýváme jako artefakty. V práci jsou rozděleny do tří skupin na artefakty z prostředí, EEG přístroje a pacienta. Níže je uvedena jejich bližší specifikace [4].

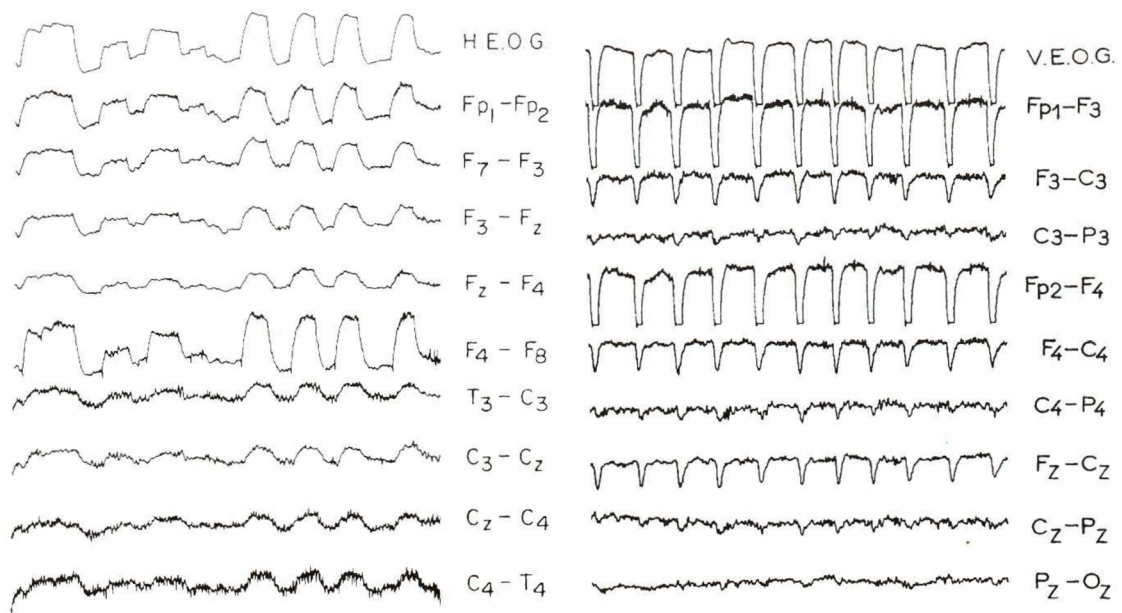
Artefakty z prostředí mohou vznikat z okolí pacienta a EEG přístroje. Vznikají na bázi interference se zdroji elektrické energie nebo jiného elektromagnetického pole s bližší nebo větší vzdáleností od okolí elektroencefalografu [4].

Jestliže se v okolí EEG vyskytují zdroje silného elektromagnetického pole, pak se v signálu může projevit artefakt ze střídavého proudu, který má charakteristický kmitočet 50 Hz v Evropských zemích nebo 60 Hz v USA. Běžnou příčinou je rozdíl v impedancích elektrod. Na elektrodách s různou impedancí se indukují různá napětí. Jejich diference je zesílena a smíšena s bioelektrickým signálem [4].

Z okolních přístrojů s odlišným kmitočtem a morfologií, než je střídavý proud (zapnutí a vypnutí osvětlení, zvonění telefonu, ventilace, aktivita signalizačních systémů, infuzní soupravy) se mohou také vyskytovat artefakty. Ty se mohou objevit v signálu i při pohybu osob v místnosti nebo péčí zdravotnického personálu o pacienty [4].

Mezi artefakty z elektroencefalografu patří nejběžnější artefakty elektrodové. Příkladem je distribuce ve svodech z jedné společné elektrody při bipolárním zapojení, ve všech svodech ze znečištění referenční elektrody při unipolárním zapojení nebo ze zemnicí elektrody. Dále se mohou vytvořit artefakty z nevhodně umístěné EEG čepice, z kabelů mezi elektrodami a hlavou EEG a při poruše adaptéru nebo elektroencefalografu.

Následně se mohou vyskytovat artefakty z pacienta, které můžeme nazvat také jako biologické nebo fyziologické [4]. Na další straně na Obr. 2.4 jsou vyobrazeny v pravé části artefakty způsobené pohyby očí a v levé části jsou artefakty vyvolané opakovaným mrkáním.




(a)

(b)

**Obr. 2.4 Artefakty ovlivňující záznam EEG [10]**

### 3 METODY DETEKCE K-KOMPLEXŮ

V této části jsou uvedeny některé metody automatické detekce K-komplexů ve spánkových signálech EEG. Detekce těchto grafoelementů je složitá, jelikož i jednotliví odborníci mohou zhodnotit jeden elektroencefalogram zcela odlišně. Mezi nejvíce používané metody patří vlnková transformace a neuronové sítě.



Obr. 3.1 Desetisekundový záznam signálu s typickým tvarem K-komplexu [3]

Na vodorovné ose je čas [s] a na svislé ose je rozkmit signálu [ $\mu\text{V}$ ].

#### 3.1 Metoda detekce využívající vlnkovou transformaci

Vlnková transformace se řadí mezi účinné metody zpracování v časově-frekvenční oblasti pro nestacionární signály [3]. Je to transformace se společnými rysy, které se odlišují tvarem bázové funkce (tzv. vlnky). Po transformaci je signál rozdělen do jednotlivých podpásem.

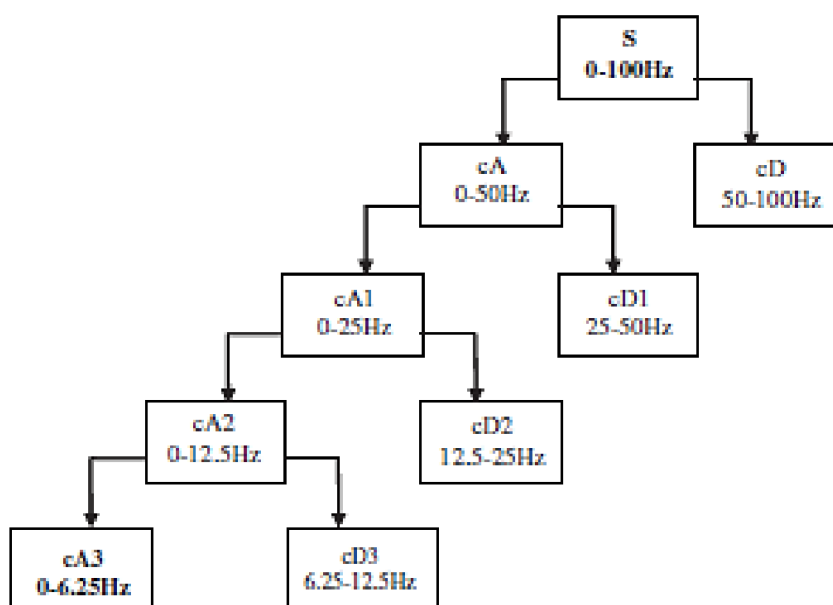
V prvním kroku je na původní signál  $x(n)$  aplikována horní propust  $g(n)$  a následně dolní propust  $h(n)$ . Po filtraci dochází k eliminaci poloviny vzorků dle Nyquistova kritéria. Zmíněný postup je vyjádřen matematicky následovně

$$Y_{high}[k] = \sum x[n] \cdot g[2k - n] \quad (3.1)$$

$$Y_{low}[k] = \sum x[n] \cdot h[2k - n], \quad (3.2)$$

kde  $Y_{high}[k]$  a  $Y_{low}[k]$  jsou výstupy filtrů, kdy filtrací s horní propustí (3.1) získáme detaily a z dolní propusti (3.2) získáme aproximace vlnkové transformace. Tento postup může být použit opakovaně, získáme tak rozklad signálu do požadovaných frekvenčních intervalů.

Detekční algoritmus této metody [3] obsahuje diskrétní vlnkovou transformaci k postupnému (dyadickému) rozkladu dat do čtyř podpásem pomocí banky filtrů sym stupně 4. Volba banky filtrů a počet úrovní rozkladu byl zvolen podle charakteristiky K-komplexů, které bylo nutné detekovat v signálu EEG. Tvar vlnky „sym4“ se nejvíce přibližuje tvaru grafoelementu K-komplexu, proto byl tento tvar vybrán jako nejvhodnější. Komplexy obsahují nízkofrekvenční komponenty, které se pohybují okolo 1 Hz. Podpásmo od 0 Hz do 6,25 Hz obsahuje tedy veškeré potřebné informace pro detekci. Rozklad na jednotlivá pásma s využitím vlnkové transformace je uveden níže na Obr. 3.2.



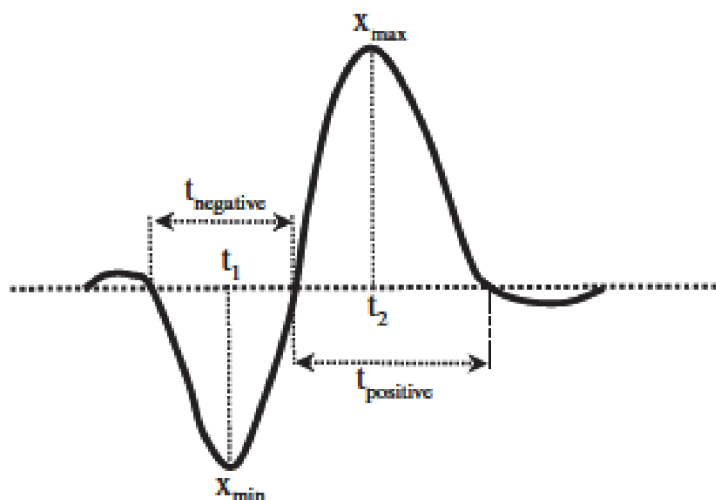
**Obr. 3.2 Rozklad vlnkové transformace na jednotlivá pásma [3]**

Po této transformaci signálu vyhledává algoritmus charakteristické znaky komplexů jako je velikost úrovně signálu a doba trvání komplexu mezi extrémy (maximum a minimum). Na nulové linii je celková doba trvání K-komplexu vypočtena jako

$$t_{total} = t_{neg} + t_{pos} \quad (3.3)$$

kde  $t_{neg}$  je doba trvání v negativní fázi a  $t_{pos}$  je doba trvání v pozitivní fázi. Tento interval je od 0,5 s do 1,5 s. Dalším důležitým kritériem je, že  $t_{neg}$  a  $t_{pos}$  musí mít větší hodnotu než  $1/4 t_{total}$ , aby nedocházelo k chybným detekcím, které by mohly být způsobeny malými vlnami jako je delta a hrot [3].





Obr. 3.3 K-komplex s vyznačenými časy a extrémy výchylek signálu [3]

Po splnění těchto podmínek dochází ještě k testování sklonu vzestupu komplexu. Nárůst musí být větší než  $100 \mu\text{V}$  za  $0,5 \text{ s}$ . Sklon narůstá od  $x_{\min}$ , což je minimální výchylka do  $x_{\max}$ , která vyjadřuje maximální výchylku dle [3]

$$\text{Slope} = \frac{x_{\max} - x_{\min}}{t_2 - t_1}. \quad (3.4)$$

### 3.2 Metoda detekce využívající Teagerův-Kaiserův operátor

K-komplex má tvar vlny. Vykazuje typické znaky jako jsou ostré klesající a stoupající hrany, které jsou charakterizovány rozkmitem a dobou trvání. Tyto významné znaky můžeme zviditelnit použitím obálky signálu, která je zvýrazní a potlačí vedlejší průběhy, jež nejsou potřebné.

Teagerův-Kaiserův Energetický Operátor (TKEO) odvozuje energii harmonického signálu. Nejčastěji se aplikuje v případě, kdy se vytváří obálka signálu EKG pro rozpoznávání signifikantních tvarů jako jsou např. komplexy QRS. Operátor byl prvně využit na řečové signály [10]. Operátor zdůrazní náhlé změny jako jsou nespojitosti, zvýšení či snížení frekvence a úrovně signálu. Na druhou stranu dokáže vyhladit měkké přechody a činnost pozadí [3].


V předcházející práci [3] je operátor TKEO aplikován na signál filtrovaný dolní propustí. Signál byl filtrován Butterworthovým propustným filtrem 10 řádu s ostrým přechodem, který umožnil utlumení vyšších frekvencí, které mohou

vznikat díky artefaktům z EMG a nižších frekvencí způsobených artefakty pohybů očí. Operátor je počítán z jednotlivých vzorků signálu, tedy z diskrétní aproximace, podle vzorce [3]

$$\psi_{Ts}(n) = \psi_s^2(n) - \psi_s(n-1) \cdot \psi_s(n+1), \quad (3.5)$$

kde  $\psi_s(n)$  je popsáno jako n-tá hodnota vzorku signálu a  $\psi_{Ts}(n)$  jako n-tá hodnota výstupu TKEO.

Dále je nutné k detekci přidat podmínky pro hodnoty kladné výchylky a dobu trvání ve dvou místech K-komplexu, jelikož předcházející postup nezajišťuje dostatečně korektní výsledek. První podmínkou je tedy nalezení vrcholů nad hodnotu prahu výchylky  $A_{th}$ , která musí být větší jak  $30 \mu V$ . Současně však musí tato výchylka grafoelementu trvat po dobu  $t_1$  alespoň 350 ms mezi průchody nulou a po dobu  $t_2$  alespoň 50 ms v úrovni detekce prahu [3].



Obr. 3.4 Podmínky pro detekci vrcholu [3]

Podmínky pro detekci vrcholu jsou tedy  $A_{th}$  větší jak  $30 \mu V$ ,  $t_1$  alespoň 350 ms a  $t_2$  alespoň 50 ms.

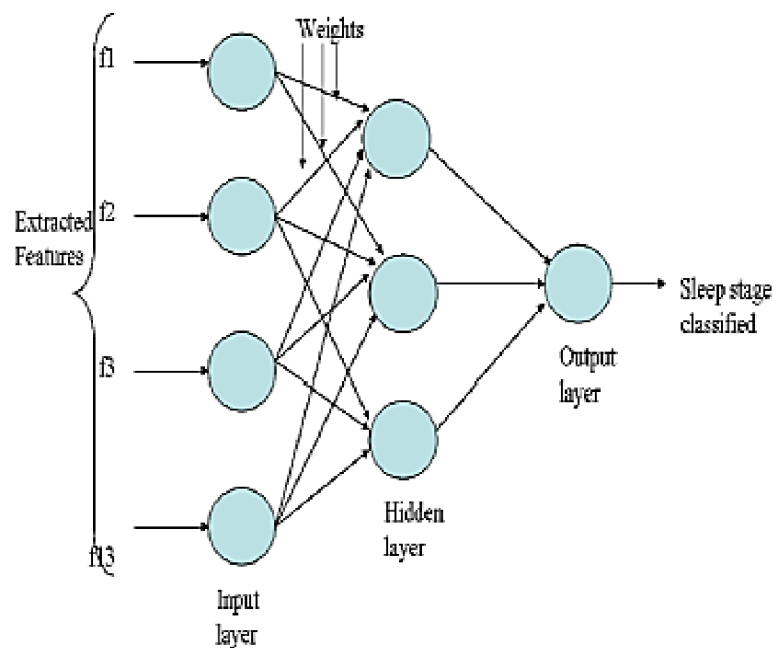
### 3.3 Metoda detekce využívající umělou neuronovou síť

K-komplex je přechodný děj, který přispívá k hodnocení spánkových fází. Vyskytuje se s frekvenčním rozsahem od 0,5 do 2 Hz, s rozkmitem větším jak  $100 \mu V$ . Grafoelementy se objevují každých 1 – 1,7 minut a většinou jsou následovány spánkovými vřeteny [22]. Předmětem následující metody [22] je nalezení známého tvaru K-komplexu v zašuměném signálu EEG.

Umělé neuronové sítě se využívají pro zpracování nelineárních signálů [20]. Pro klasifikaci EEG záznamu byla použita třívrstvá umělá dopředná neuronová síť

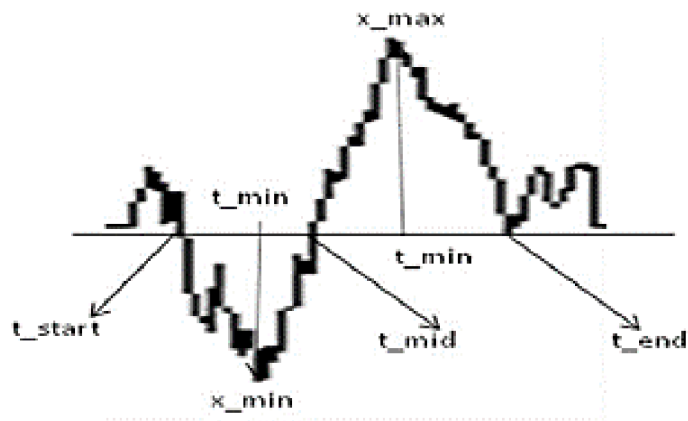
se strukturou vstup-skrytá vrstva-výstup se zpětnou vazbou. Algoritmus zpětného šíření chyby zahrnuje šíření chyb zpětně, je nutné aktualizovat váhy skrytých vrstev, tak aby byla minimální nejmenší kvadratická chyba.

Výstupy jsou spočteny iterativně, dokud nedojde k přijatelné minimální úrovni chyby. Pro výpočet byla aplikována sigmoidální funkce pro přenosovou funkci neuronu. Vstupní a jim odpovídající výstupní vektory byly použity pro trénování sítě, dokud nejsou upraveny vstupní vektory. Během fáze trénování se váhy postupně upravují na základě sady vstupů a jim odpovídající množině požadovaných výstupů. Algoritmus zpětné vazby vyžadoval úpravu vah při zpětném prohledávání – od chybného výstupu ke vstupu [22].



**Obr. 3.5 Použitá dopředná neuronová síť [22]**

Funkce jsou extrahovány výpočtem prahových hodnot pravděpodobnosti založených na měření trvání a amplitudy. Příznaky byly vybrány tak, aby co nejlépe odpovídaly vizuálním kritériím. Ty byly odvozeny z významných bodů, jak je zobrazeno Obr. 3.6 níže.



Obr. 3.6 Charakteristické znaky pro tvar K-komplexu [22]

Jednotlivé šipky vyznačují body, díky kterým dochází k rozměření tvaru K-komplexu. Body  $x_{min}$  a  $t_{min}$  odpovídají minimální hodnotě pseudo K-komplexu, naopak  $x_{max}$  a  $t_{max}$  korespondují s maximální hodnotou EEG v intervalu,  $t_{start}$  a  $t_{end}$  označují začátek a konec trvání komplexu. Bod  $t_{mid}$  a  $x_{mid}$  vyznačuje v průběhu místo, kde dochází k průchodu nulovou linií mezi minimální a maximální výchylkou v tomto pořadí [22].

Dále jsou popsány definované funkce s využitím bodů, jež byly charakterizovány dle tvaru K-komplexu výše.

Dobrá trvání tohoto grafoelementu je reprezentována jako

$$f1 = (t_{end} - t_{start}). \quad (3.6)$$

Rozkmit extrémních hodnot maxima a minima je dán vztahem

$$f2 = (x_{max} - x_{min}). \quad (3.7)$$

Pokud jde o ostrost prvního negativního vlnění ve srovnání s druhou pozitivní vlnou, pak jsou relevantní kritéria

$$f3 = \frac{(t_{end} - t_{mid})}{(t_{mid} - t_{start})}. \quad (3.8)$$

Aby bylo zjištěno, zda amplituda negativní složky je alespoň 50 % složky s kladnou výchylkou je použit následující vzorec

$$f4 = \frac{|x_{min}|}{x_{max}}. \quad (3.9)$$

Ostrost negativní vlny je reprezentována vztahem


$$f5 = \frac{|x_{min}|}{(t_{mid} - t_{start}) \cdot fvz}, \quad (3.10)$$

kde  $fvz$  označuje vzorkovací frekvenci.

Hodnoty byly normalizovány v intervalu od 0 do 1, kvůli zamezení dominantnosti některého z příznaků. Extrahované příznaky byly přiváděny na vstup umělé neuronové sítě trénované se zpětnou vazbou [22].

### 3.4 Metoda detekce založená na měřených parametrech a odvození pravděpodobnosti výskytu komplexu

Postup je založen na extrakci specifických rysů a na použití pravděpodobnostních prahů. Podstatou byla snaha o omezení počtu falešných detekcí pomocí víceúrovňového přístupu. V každé etapě se srovnává nová charakteristika tzv. pseudo komplexu s prahem, který určí, zda se jedná o K-komplex či ne. Metoda byla uvedena v článku *Automatic K-complexes Detection in Sleep EEG Recordings using Likelihood Thresholds* [1].




Obr. 3.7 Křivka prahování poskytující pravděpodobnost skutečného K-komplexu [1]

Algoritmus každému pseudo komplexu dává určitou pravděpodobnost, dle shody se skutečným komplexem. Probabilita je vypočtena dle její charakteristické hodnoty a předem definované prahové křivky. Na výše uvedeném obrázku je vyobrazen názorný příklad při zhodnocení prahové křivky poskytující pravděpodobnost, že se jedná o skutečný K-komplex. Pseudo komplexy o délce trvání 0,4 s budou přijaty, ale s probabilitou jen 0,5 [1].

Prahové křivky byly vytvořeny na základě učební databáze. U všech funkcí byly zkoumány identifikované K-komplexy experty a podle jejich vlastností byl vybrán nejlepší odpovídající tvar křivky, která je zobrazena na obrázku výše [1].

Na základě nejlepšího odrazu vizuálních kritérií byly vybrány zvolené charakteristiky, většinou na základě významných bodů shodujících se s tvarem K-komplexu. Body  $val\_min$  a  $t\_min$  (x) označují minimální hodnotu rozkmitu EEG signálu a jeho pozici. Maximální hodnotu výchylky a její pozici vyznačují body  $val\_max$  a  $t\_max$  (\*), které odpovídají intervalu  $(t\_min, t\_min + 1s)$ . K nalezení bodu  $t\_start$  dochází procházením signálu zprava doleva od  $t\_min$ . Počáteční bod se shoduje s prvním lokálním maximem, které je větší než minimální hodnota  $val\_min/2$ . Jestliže je zmíněné maximum větší než  $0 \mu V$  dochází k přesunu  $t\_start$  (o), aby odpovídal prvnímu vzorku, který je větší jak  $0 \mu V$ . Koncový bod komplexu  $t\_end$  ( $\square$ ) musí následovat za  $t\_max$  a nesmí být větší než  $-5 \mu V$ . První bod větší než  $0 \mu V$  je označen jako  $t\_mid1$  ( $>$ ) při procházení signálu EEG zleva doprava. Opakem je bod  $t\_mid2$  ( $<$ ), který je při stejném směru procházení signálu první hodnotou menší než  $-5 \mu V$  [1].



Obr. 3.8 Označení významných bodů na reálném K-komplexu a jiné vlně [1]

Při tomto postupu, se nejprve detekují veškerá lokální minima, pro která jsou vypočteny difference výchylek s rozdíly předchozích a následujících maximálních hodnot. Lokální minimum je považováno za negativní ostrou vlnu, pokud je výsledek rozdílu dostatečný. K testování, zda se negativní vlna nachází

před vlnou pozitivní dochází na základě funkce odrážející spojitost rostoucí strany K-komplexu

$$f1 = \frac{t\_mid2 - t\_mid1}{t\_end - t\_start}. \quad (3.11)$$

Interval trvání komplexu je reprezentován jako

$$f2 = t\_end - t\_start. \quad (3.12)$$

Následně dochází k extrakci souboru funkcí ověřující přijatelnost výchylky komplexu. V první řadě se vypočte rozkmit mezi extrémními hodnotami výchylek

$$f3 = val\_max - val\_min. \quad (3.13)$$

V rámci algoritmu studie [1] se rozhoduje, jestli je výchylka pseudo K-komplexu dostatečná na základě srovnání s pozadím signálu elektroencefalogramu. Uznány jsou komplexy s výchylkou, která není menší než průměrná úroveň EEG odvozená z 2 s předcházejícího bodu  $t\_start$  nebo není menší než střední úroveň signálu EEG odvozena od předchozích 2 s ( $t\_start - 2s$ )

$$f4 = \frac{val\_max - val\_min}{\min(amplEEG_{t\_start - 2 : t\_start}, amplEEG_{t\_start - 4 : t\_start - 2})} \quad (3.14)$$

V rámci 15 s kolem pseudo K-komplexu byla vypočtena celková výchylka pozadí EEG signálu

$$f5 = \frac{val\_max - val\_min}{mean\_EEG\_amplitude\_on\_15s} \quad (3.15)$$

k zavržení pseudo K-komplexu dochází, pokud je střední výchylka signálu v rámci 15 s kolem komplexu příliš vysoká [1].

Pro zajištění, aby výchylka negativní vlny tvořila alespoň polovina složka pozitivní výchylky, se použije předpis

$$f6 = \frac{|val\_min|}{val\_max}. \quad (3.16)$$

Ostrost první negativní vlny ve srovnání s druhou pozitivní vlnou je kontrolována pomocí

$$f7 = \frac{t\_end - t\_mid1}{t\_mid1 - t\_start}. \quad (3.17)$$

Výsledek předchozího podílu však může být někdy menší než 1. Proto byla ostrost negativní vlny vypočtena s použitím dalších atributů

$$f8 = \frac{|val\_min|}{(t\_end - t\_start) \cdot fsampling}, \quad (3.18)$$

kde *fsampling* je vzorkovací frekvence signálu [1].

Jestliže je průběh vlny složitý, tak může dojít ke špatnému odhadu ostrosti. Z tohoto důvodu bylo využito filtrace metodou nejmenšího čtvercového zrychlení LSA (Least Square Acceleration) vypočítávající druhou derivaci ideální paraboly k negativní ostré vlně [1].

Nakonec je využito další charakteristiky

$$f9 = \frac{val\_max - val\_min}{(t\_end - t\_start) \cdot fsampling}. \quad (3.19)$$

Extrakcí z významných bodů pseudo K-komplexu získáme tyto příznaky a je vyloučeno velké množství falešně pozitivních detekcí. Mnoho z nich se však nachází ve třetí fázi spánku, kde se nacházejí  $\delta$  vlny, takže výpočet *f5* (3.15) není dostačující. Proto je třeba prozkoumat okolí 5 s kolem komplexu a vypočítat relativní výkon v pásmu  $\delta$  vln [1].

Aplikací tohoto algoritmu na elektroencefalografický signál byl získán soubor hodnot určující K-komplexy. Nakonec je využito minimální pravděpodobnosti, z níž se vychází pro globální pravděpodobnost

$$globální\_probabilita = min\_probabilita \cdot (1 - (0,1 \cdot probabilita < 0,6)) \quad (3.20)$$



Po výpočtu finální pravděpodobnosti pro každý pseudo komplex byla zvolena hodnota prahu 0,69. K-komplex byl označen, jestliže výsledná probabilita pseudo K-komplexu byla vyšší než hodnota prahová [1].

### 3.5 Metoda detekce založená na CWT s vlnkami tvarově souhlasnými s K-komplexy

V této studii se zkonstruovala vlnka odpovídající tvaru K-komplexu a následně je použita k detekci s pomocí spojitě vlnkové transformace (CWT-Continuous Wavelet Transform). Metoda je názorněji popsána v článku *K-complex Detection Based on Pattern Matched Wavelets* [18].

Pro testování byla využita veřejně dostupná databáze [1], ze které bylo vybráno 5 pacientů a následně soukromá databáze tvořená dvěma subjekty. K-komplex, dle nejnovějších studií, je definován jako negativní ostrá vlna bezprostředně následovaná vlnou pozitivní, která je pomalejší a vyčnívá z pozadí EEG signálu s celkovou minimální dobou trvání 0,5 s [7].

Pro vývoj vlnky shodného tvaru byla aplikována polynomiálně založená metoda [18]. Jeden K-komplex detekovaný expertem byl použit pro návrh vlnky, která vstupuje do CWT a musí splňovat následující podmínku

$$\int_{-\infty}^{\infty} \frac{|\hat{\psi}(\omega)|^2}{|\omega|} d\omega < \infty, \quad (3.21)$$

kde  $\hat{\psi}(\omega)$  je Fourierova transformace  $\psi(t)$ .

Pro jednotnou podporu CWT lze podmínku zapsat jako

$$\int_a^b \psi(t) d(t) = 0, \quad (3.22)$$

vlnka v předcházející rovnici je nulová střední funkce v rozsahu od  $a$  do  $b$  [18].

Tvarově shodná vlnka vyhovující rovnici výše je sestavena z rodiny funkcí  $F = \{ \rho_i \}$ , přičemž  $i$  jde od 1 do  $N$ . V této studii bylo využito časových polynomů až do 10 stupně. Rovnice (3.22) tedy vede na zjednodušení pomocí rodiny funkcí

$$\sum_{i=1}^N \alpha_i M_i = 0, \quad (3.23)$$

kde

$$M_i = \int_a^b \rho_i(t) dt \quad (3.24)$$

neznámou hodnotu  $\alpha_i$  při diskrétním vzorkování lze vypočítat s využitím Lagrangeových multiplikátorů

$$\begin{pmatrix} G & M^t \\ M & 0 \end{pmatrix} \begin{pmatrix} \alpha \\ \lambda \end{pmatrix} = \begin{pmatrix} B \\ 0 \end{pmatrix}, \quad (3.25)$$


kde  $\lambda$  je Lagrangeův multiplikátor,  $M$  je získáno z řešení rovnice (3.24) a  $G$ ,  $B$  jsou dány pomocí

$$G_{ij} = \sum_{k=1}^k \rho_i(t_k) \rho_j(t_k) \quad (3.26)$$

$$B_i = \sum_{k=1}^k y_k \rho_i(t_k) \quad (3.27)$$


kde  $y_k$  je originální vzor pro vytvoření tvarově shodné vlnky [18].

Pro vytvoření první vlnky bylo využito jednoho K-komplexu z databáze [1] ohodnoceného expertem 1, který můžeme vidět na obrázku níže (Obr. 3.9). Průměr více vizuálně hodnocených komplexů byl vyloučen, jelikož tvar takové vlnky byl příliš hladký.



Obr. 3.9 Vzor vlnky s původním K-komplexem [18]

Se získanou vlnkou, z předešlých kroků, byla CWT použita na dekompozici signálu do více stupňů od 0,02 s do 5,12 s, s krokem 0,05 s. Výsledkem byla transformace se značně jemným rozlišením.



Obr. 3.10 Úsek EEG se škálogramem [18]

Jelikož K-komplex má dobu trvání od 0,5 s do 2 s, tak maximální CWT by měla být v tomto rozmezí. Bylo zkoumáno zda-li se maximální koeficient nachází v tomto rozsahu a jeho hodnota je vyšší než daný práh. Pokud ano, tak došlo k označení vzoru za K-komplex. Minimální rozkmit byl stanoven na 80  $\mu\text{V}$  a nejlepších výsledků bylo dosaženo s prahem 400. Posledním krokem bylo odstranění pomalých oscilací [18].

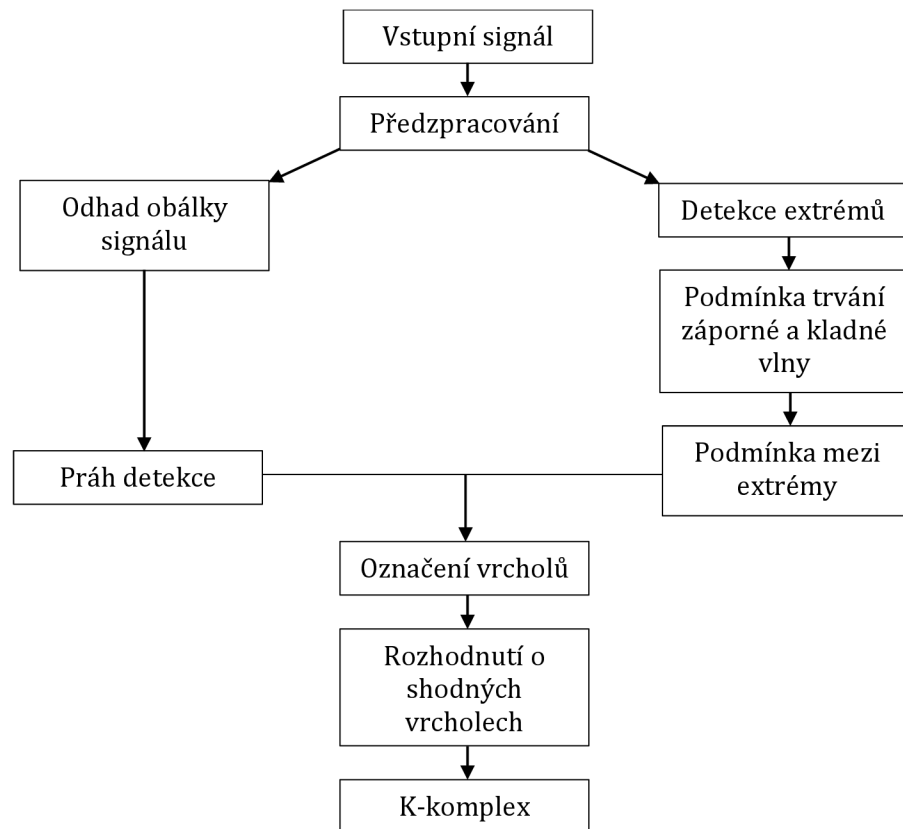
## 4 REALIZACE ALGORITMU

Následující část se zabývá popisem vytvořeného algoritmu pro detekci K-komplexů ve spánkových signálech EEG, který byl vytvořen v prostředí MATLAB R2014a. Předlohou pro vytvořený algoritmus byly předcházející práce *QRS detection using S-Transform and Shannon energy* [25] a *A wavelet and teager energy operator based method for automatic detection of K-Complex in sleep EEG* [3]. První z uvedených článků [25] byl zvolen pro pochopení problematiky S-transformace a druhý [9] byl vzorem pro přibližné nastavení parametrů detekce K-komplexů. Byly vytvořeny přístupy, jejichž postup je znázorněn na schématu níže (Obr. 4.1).

V algoritmu je na vstupní signál použita S-transformace se zvoleným rozsahem 0,5-2 Hz, na jejíž výsledek je aplikován odhad obálky vytvořený umocněním signálu na druhou. V jednom z přístupů byl pro odhad obálky signálu zvolen výpočet Shannonovi energie. Detekovány jsou vrcholy nad zvoleným násobkem směrodatné odchylky obálky 30 s v úseku. Nezávisle na předchozím postupu je dále použita filtrace pásmovou propustí v rozmezí 0,5-2 Hz na vstupní signál. Hledány jsou maximální a minimální výchylky filtrovaného signálu. Z dob trvání pozitivních a negativních částí vln jsou vybrány ty, které vyhovují podmínce a je vypočtena určitá hodnota mezi jednotlivými extrémními hodnotami komplexů. V závěru se porovnávají výsledky S-transformace a filtrovaného signálu pásmovou propustí. Pokud se výsledky shodují, tak dochází k označení daného útvaru jako K-komplex.

Ve druhé verzi je EEG signál na vstupu filtrován pásmovou propustí v rozsahu 0,5-2 Hz. Z filtrovaného signálu je vypočten odhad obálky signálu s využitím operátoru TKEO. Detekovány jsou extrémy nad násobkem směrodatné odchylky obálky v úseku 30 s. Další část je stejná jako v prvním algoritmu. Nezávisle na předchozím postupu je využita filtrace pásmovou propustí v rozmezí 0,5-2 Hz. Ve filtrovaném signálu jsou nalezeny maximální a minimální výchylky. Z intervalů trvání pozitivních a negativních částí jsou vybrány ty, které vyhovují podmínce trvání a je vypočtena daná hodnota mezi jednotlivými extrémními hodnotami komplexů.

V závěru dochází k porovnání výsledků filtrovaného signálu s použitím TKEO a pouze filtrovaného signálu. Jestliže jsou výsledky shodné, označí se útvar jako K-komplex.



Obr. 4.1 Schéma navrženého detektoru K-komplexů

## 4.1 Popis databáze EEG signálů


Použitá databáze záznamů deseti signálů EEG ze svodu CZ-A1 (vrchol hlavy-levý ušní lalůček) vznikla ve spánkové laboratoři nemocnice André Vésale, která se nachází v belgickém městě Montigny-le-Tilleul. Vzorkovací frekvence je 200 Hz doba trvání jednotlivých signálů je 30 min.

Záznamy byly nezávisle předloženy dvěma expertům, kteří ohodnotili výskyty K-komplexů, jejich začátky a konce. První expert ohodnotil všech 10 záznamů. Druhý expert klasifikoval pouze prvních 5 spánkových signálů EEG, které byly naměřeny u 4 žen a 1 muže ve věkovém rozmezí 20-47 let [18]. Hodnotitelé se ve svých výsledcích klasifikací značně liší. Avšak i přes tuto skutečnost budou signály s klasifikací K-komplexů od těchto odborníků využity pro statistické zhodnocení na konci diplomové práce. V diplomové práci je uveden popis algoritmu na prvním signálu z této databáze, který byl ohodnocen oběma experty [1].


## 4.2 Předzpracování signálu

Jelikož signály obsahují šumové složky je nutné nejprve provést jejich předzpracování. Tato operace zbaví signál šumu a lépe zviditelní průběhy, které jsou potřebné k analýze záznamu EEG. Oblast šumu a užitečné pásmo se může prolínat, proto je důležité zvolit určitý kompromis, aby nedošlo k nechtěné degradaci signálu. V této práci byla použita Stockwellova transformace a lineární filtrace pásmovou propustí.

Na obrázku (Obr. 4.2 a Obr. 4.3) níže pozorujeme zašuměný vstupní signál, který je vykreslen modře, s vyznačenými počátky K-komplexů dle experta 1, ty jsou zaznamenány červenými čarami. Již při prvním pohledu na původní signál vidíme, že zhruba v intervalu od 0 s do 120 s je velmi obtížné rozlišit, jestli se v daném úseku nachází nějaký K-komplex, a to pravděpodobně díky šumu s vysokými hodnotami výchylek. Důležité je však zdůraznit, že odborník hodnotí vždy záznam EEG po úseku 30 s, čímž dokáže lépe rozlišit charakteristické znaky. Při analýze by mohlo dojít k vyloučení úseku od 0 s do 120 s. V následujícím průběhu se šumové složky vyskytují také, ale již s menší hodnotou rozkmitu než v předešlém intervalu, ale i přesto je nutné zařadit předzpracování signálu.



Obr. 4.2 Původní signál s vyznačenými počátky K-komplexů dle experta 1



**Obr. 4.3 Úsek původního zašuměného signálu s vyznačenými počátky K-komplexů expertem**  
1

## 4.2.1 Stockwellova transformace

Stockwellova transformace (S-transformace) byla navržena v roce 1996 [23]. Dnes se využívá při detekci QRS komplexů v signálech elektrokardiografu. Prozatím není z publikací o detekcích K-komplexů ze signálů EEG známo, že by se tato transformace používala stejně často jako u detekcí QRS komplexů v signálech EKG. Představuje novou metodu, jež je použita pro složité průběhy srdeční činnosti [25], založenou na S-transformaci a nové časově frekvenční reprezentaci. Výstupem ST je rozklad libovolného vstupního signálu na časově-frekvenční složky.

S-transformace udává rozlišení závislé na frekvenci při zachování přímého vztahu s Fourierovým spektrem. Tato transformace je na pomezí krátkodobé Fourierovy transformace (STFT) a vlnkové transformace (WT). K libovolné frekvenční složce tak můžeme v časově frekvenční oblasti, aniž bychom použili jakýkoliv digitální filtr.

Standardní ST časově proměnlivého vstupního signálu  $x(t)$  je dáno jako

$$S(\tau, f) = \int_{-\infty}^{+\infty} x(t) \cdot \omega(t - \tau) \cdot e^{j2\pi ft} dt, \quad (4.1)$$

kde  $\omega(t)$  je časové okno se středem v čase 0 a používá se pro extrahování segmentu ze signálu  $x(t)$ . S-transformace může být definována pomocí určité okénkové funkce  $\omega(t)$ , normalizovaný gaussian



$$\omega(t) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{t^2}{2\sigma^2}}, \quad (4.2)$$

kde  $\sigma$  charakterizuje šířku Gaussova okna a jedná se o tzv. měřítkový faktor, který byl vybrán, jelikož je nejvíce kompaktní ve frekvenci a čase. Okénkové funkci je umožněna translace  $\tau$  a dilatace (s proměnlivou šířkou  $\sigma$ ). Pokud je měřítkový faktor volen jako

$$\sigma(f) = \frac{1}{|f|}, \quad (4.3)$$

pak je výsledkem Gaussovou okénko délkově závislé na kmitočtu

$$\omega(t-\tau) = \frac{|f|}{\sqrt{2\pi}} e^{-\frac{(t-\tau)^2 f^2}{2}}. \quad (4.4)$$

Funkce S-transformace je pak přepsána do tvaru

$$S(\tau, f) = \frac{|f|}{\sqrt{2\pi}} \int_{-\infty}^{+\infty} x(t) \cdot e^{-\frac{(t-\tau)^2 f^2}{2j}} e^{-j2\pi ft} dt, \quad (4.5)$$

kde  $\tau$  a  $f$  označují čas spektra a frekvenci. S-transformace připomíná spojitou vlnkovou transformaci se specifickou mateřskou vlnkou a korekcí fázového faktoru.

Diskrétní Stockwellovu transformaci konečného signálu  $x(nT)$ ,  $n=0,1,\dots,N-1$  se zvoleným kmitočtovým krokem  $F$  můžeme zapsat dle [11] jako


$$DST(lT, kF) = T \sum_{n=0}^{N-1} x(nT) \frac{kF}{\sqrt{2\pi}} e^{-\frac{((nT-lT)^2 (kF)^2)}{2}} e^{-j2\pi kFnT}. \quad (4.6)$$

Výsledkem je barevný 2D obraz, který nazýváme jako spektrogram, kde index  $l$  odpovídá časovému posunu a index  $k$  odpovídá kmitočtu. Na horizontální ose je vynesena čas a na vertikální ose je frekvence. Škála barev pro vykreslení je dalším rozměrem obrazu.


V této práci je použita S-transformace, jejíž vytvořená funkce byla poskytnuta vedoucím práce. S-transformace probíhá v pásmu omezeném od 0,5 Hz

do 2 Hz, jelikož tento kmitočet je charakteristický pro K-komplex. Vzorkovací frekvence je nastavena na 200 Hz a kroky transformace 1 vzorek a 0,1 Hz.

Na obrázku (Obr. 4.5) je spektrogram původního signálu a pro srovnání je uveden i vstupní signál na stejném úseku s počátky K-komplexů (Obr. 4.4), které jsou vyznačeny červeně podle hodnocení prvního experta. Různé hodnoty spektrogramu jsou odlišeny barevnou škálou od modré po červenou barvu. Místa s vyšší energií mají žlutou až červenou barvu, zatímco místa s nižší energií jsou modrá.



**Obr. 4.4 Úsek původního signálu-expert 1**




**Obr. 4.5 Spektrogram úseku signálu**

## 4.2.2 Lineární filtrace pásmovou propustí

Druhým zvoleným přístupem je filtrace pásmovou propustí. Opět se tak zbavíme šumových složek a získáme důležité průběhy k analýze elektroencefalogramu, jež požadujeme.

Pásmová propust byla vytvořena ve stejném intervalu kmitočtu jako S-transformace, tedy v pásmu od 0,5 Hz do 2 Hz, aby se mohly výsledky předzpracování signálu dále srovnat a být smysluplně využity v dalších krocích postupu.

Dochází k výraznému potlačení šumu a sníží se i výchyly signálu, ale v takové míře, že je možné rozeznat v zobrazeném průběhu extrémní hodnoty, které mohou být označeny jako K-komplexy. Filtrovaný signál je významný v dalších krocích algoritmu.



Obr. 4.6 Původní a filtrovaný signál pásmovou propustí-expert 1

Zelený průběh představuje úsek původního signálu a černý průběh je signál filtrovaný pásmovou propustí. Červené značky jsou označením počátků K-komplexů expertem 1.

## 4.3 Odhad obálky signálu

Výstup z předzpracování signálu byl využit pro výpočet odhadu obálky signálu. V této práci došlo k výpočtu odhadu obálky signálu, při předzpracování S-transformací, umocněním reálné složky energie signálu na druhou. Další možností byl výpočet Shanonovy energie. V případě lineární filtrace pásmovou propustí byl vytvořen odhad obálky signálu pomocí Teagerova-Kaiserova operátoru; dle

předchozích studií [3] [25]. Zmíněné metody výpočtu odhadu obálky signálu byly využity nezávisle na sobě.

### 4.3.1 Umocnění na druhou

Do následujícího oddílu vstupuje výstup Stockwellovy transformace, tedy energie signálu. Pro zvýraznění významných znaků a potlačení nedůležitých průběhů je využito odhadu obálky signálu.

Nejprve bylo zapotřebí sečíst sloupce výstupní matice  $ST$ , z nichž byly vybrány absolutní hodnoty reálné části výstupu Stockwellovy transformace. Dále se normalizovaly hodnoty, aby se nacházely v rozmezí od 0 do 1 a to podle následujícího vzorce

$$ST_{norm} = \frac{ST_{real}}{|\max(ST_{real})|}, \quad (4.7)$$

kde  $ST_{real}$  jsou hodnoty reálné části Stockwellovy transformace.


V této části je vytvořena obálka umocněním reálné složky výstupu S-transformace dle vzorce

$$SE = (ST_{norm})^2 \quad (4.8)$$


kde  $ST_{norm}$  je normalizovaná energie reálné složky a  $SE$  je odhad obálky signálu po umocnění na druhou. Díky tomu jsou potlačeny hodnoty výchylek menší jak 1 a naopak jsou zvýrazněny výchylky větší jak 1. Reálná složka pro umocnění byla vybrána experimentálně, jelikož její průběh se jevil jako nejvhodnější. Nakonec došlo k normalizaci vypočteného odhadu obálky umocněním na druhou podle následujícího vzorce

$$SE = \frac{SE}{|\max(SE)|}. \quad (4.9)$$

Odhad obálky signálu umocněním výstupní energie Stockwellovy transformace je vykreslen modře (Obr. 4.8), červeně jsou označeny K-komplexy expertem 1. Pro srovnání je výše uveden i vstupní signál (Obr. 4.7) s vyznačenými komplexy. Tento přístup byl vybrán, jelikož se jedná o nejjednodušší výpočet odhadu obálky signálu, který se hojně používá při zpracování signálů.



**Obr. 4.7 Úsek původního signálu-expert 1**



**Obr. 4.8 Odhad obálky signálu umocněním energie signálu na druhou-expert 1**


### 4.3.2 Shannonova energie

Další metodou pro vytvoření odhadu obálky signálu byl výpočet Shannonovy energie [25]. Vstupem do vzorce pro Shannonovu energii byla výstupní energie ze Stockwellovy transformace, a to její absolutní hodnota reálné složky.


Bylo zapotřebí normalizovat hodnoty dle předchozího vzorce (4.7), aby se jednotlivé přístupy mohly srovnávat. Následně byl aplikován vzorec pro Shannonovu energii

$$SE = -((ST_{norm}^2) \cdot \log(ST_{norm}^2)) \quad (4.10)$$

kde  $ST_{norm}$  je normalizovaná energie reálné složky a  $SE$  je odhad obálky signálu po výpočtu Shannonovy energie. Tato energie je použita, jelikož zaručí potlačení velmi vysokých hodnot a zdůrazní ty, jejichž úroveň je malá či střední. Tudíž dochází k vyhlazení signálu [11]. Nakonec došlo k normalizaci vypočtené Shannonovy energie podle vzorce (4.9), tím je maximální hodnota výchylky rovna jedné.



**Obr. 4.9 Úsek původního signálu-expert 1**



**Obr. 4.10 Odhad obálky signálu Shannonovou energií-expert 1**

Odhad obálky signálu s využitím Shannonovy energie (Obr. 4.10) je vykreslen modře, červeně jsou označeny K-komplexy expertem 1. Pro srovnání je výše uveden i vstupní signál s vyznačenými komplexy.

Oproti předchozímu řešení odhadu obálky signálu dosahují výchyly signálu vyšších hodnot a často mají podobnou hodnotu, a to díky druhé normalizaci. Důležité je zmínit, že její průběh není příliš hladký, což může vést k falešným detekcím.

### 4.3.3 Aplikace Teagerova-Kaiserova operátoru

Posledním zvoleným přístupem pro vytvoření odhadu obálky signálu byla aplikace Teagerova-Kaiserova operátoru [3]. Vstupem do výpočtu odhadu obálky je signál po filtraci pásmovou propustí. Nejprve bylo třeba normalizovat hodnoty filtrovaného signálu následujícím způsobem

$$xfn = \frac{xf}{|\max(xf)|}. \quad (4.11)$$

Operátor TKEO byl vypočten dle následujícího vztahu


$$tkeo(n) = xfn^2(n) - xfn(n-1) \cdot xfn(n+1), \quad (4.12)$$

kde  $tkeo(n)$  je n-tá výstupní hodnota a  $xfn(n)$  je n-tá vstupní hodnota filtrovaného signálu. Odhad obálky signálu byl normalizován obdobným způsobem jako výše uvedený vztah (4.11), aby se hodnoty nacházely v rozmezí od 0 do 1 a mohlo se provést pozdější porovnání metod. Normalizace je uvedena jako


$$tkeo = \frac{tkeo}{|\max(tkeo)|}, \quad (4.13)$$

kde  $tkeo$  je odhad obálky filtrovaného signálu pásmovou propustí.

Odhad obálky signálu vypočtený s použitím operátoru TKEO (Obr. 4.12) je vykreslen modře, červeně jsou označeny K-komplexy expertem 1. Pro srovnání je výše uveden i vstupní signál s vyznačenými komplexy.



**Obr. 4.11 Úsek původního signálu-expert 1**



**Obr. 4.12 Odhad obálky signálu TKEO-expert 1**

Na průbězích zvolených odhadů obálek signálu pozorujeme, že se od sebe odlišují zejména tvarem a hodnotami výchylek. V případě použití odhadu obálky TKEO jsou výchylky odhadů obálky v některých úsecích mnohem vyšší, než když je vytvořen odhad obálky pouhým umocněním reálné složky, avšak ne tak příliš jako je při použití Shannony energie. Dále je patrné, že obálky signálů při aplikaci výpočtu pro Shannonovu energii a operátor TKEO nemají hladké průběhy.




## 4.4 Detekce vrcholů pomocí prahů

Vrcholy, které by mohly být označeny jako K-komplexy, byly detekovány v úsecích 30 s, jelikož v tomto intervalu jsou záznamy posuzovány odborníkem. Detekce vrcholů pomocí prahů probíhá v odhadu obálky signálu.


Pro určení prahů se použila směrodatná odchylka, která byla počítána vždy z úseku 30 s odhadu obálky signálu. Získané hodnoty směrodatných odchylek byly vynásobeny číslem 4, které bylo stanoveno experimentálně. Násobky pak byly použity jako minimální prahové hodnoty pro detekci vrcholů. K těmto prahům byla ještě přidána podmínka, že minimální vzdálenosti mezi vrcholy by neměly být menší jak 1 s.

Na obrázcích níže (Obr. 4.13-Obr. 4.15) jsou detekované vrcholy označeny růžovou kružnicí a jednotlivé prahy po 30 s mají zelenou barvu. Počátky K-komplexů ohodnocené prvním odborníkem jsou označeny červeně.


Vypočtené prahové hodnoty u různých odhadů obálek se liší, díky hodnotám úrovní signálu, které jsou vždy jiné. Nejvyšší prahy jsou při aplikaci Shannonovy energie, dále s operátorem TKEO a nejnižších prahových hodnot dosahuje algoritmus s výpočtem odhadu obálky umocněním reálné složky energie na druhou.



Obr. 4.13 Odhad obálky signálu umocněním na druhou-expert 1



**Obr. 4.14** Odhad obálky signálu TKEO s vrcholy a postupnými prahy-expert 1



**Obr. 4.15** Odhad obálky signálu Shannonovou energií s vrcholy a postupnými prahy-expert 1

Z výsledků detekcí nad prahy je názorné, že některé vrcholy mohly být vynechány nebo jsou nadbytečné. Výpočet prahových hodnot je komplikovaný, jelikož mnoho studií se liší ve zvolených prahových hodnotách a jejich výpočtech. Zatím tedy není jednotné pravidlo pro prahové hodnoty. Pro zlepšení detekce vrcholů by měla být prahová hodnota řešena pravděpodobně jiným způsobem, a to například postupným hledáním dalších vrcholů pod a nad prahem do přijatelné mezní hodnoty.

## 4.5 Detekce vrcholů na základě doby trvání vlny a podmínka mezi extrémy

Při detekci se vychází z charakteristického tvaru K-komplexů. Grafoelement je typický nejdříve prudkým klesajícím a následně stoupajícím průběhem, jak je znázorněno na Obr. 3.3.

Ve filtrovaném signálu pásmovou propustí jsou detekovány extrémy výchylek – minimální a maximální hodnoty úrovně signálu. Nejdříve je nalezeno minimum a za ním přidružené maximum. Dále jsou vytvořeny negativní a pozitivní doby trvání. Negativní doba trvání je ta, která obsahuje hodnotu minima a pozitivní doba trvání zahrnuje maximum. Celková doba trvání komplexu je dána součtem negativní a pozitivní vlny (3.3). Celková doba trvání by měla být v rozmezí od 0,5 s do 1,5 s a současně negativní a pozitivní doby trvání by měly být větší, jak čtvrtina celkové doby trvání. Tato podmínka byla převzata z předchozí práce [3].

V další části byla definována podmínka o hodnotách mezi těmito extrémy, jelikož samotná předchozí podmínka není dostatečná. Nezávisle byly testovány 3 podmínky, a to rozkmit mezi extrémy, sklon a spojení podmínek rozkmitu mezi extrémy a sklonu.

Rozkmit mezi minimální a maximální hodnotou K-komplexu je v literatuře [3], [22], [18] definován různě. V této práci musel být rozkmit mezi extrémními hodnotami větší jak  $75 \mu\text{V}$ . Tato hodnota byl stanovena experimentálně. Určovat horní hranici detekce bylo bezpředmětné, jelikož nijak významně neovlivňovala dosažené výsledky.


Jako další možnost byl zvolen výpočet sklonu mezi extrémy, které splňují podmínku dob trvání dle vzorce (3.4). Experimentálně bylo určeno, že sklon by měl být větší, jak  $75 \mu\text{V}/0,5 \text{ s}$ .

Poslední analyzovanou podmínkou bylo spojení předchozích podmínek rozkmitu mezi extrémy a sklonu. Úroveň mezi extrémními hodnotami byla zvolena jako  $75 \mu\text{V}$  a současně platila podmínka o výpočtu sklonu, který měl být větší jak  $75 \mu\text{V}/0,5 \text{ s}$ .


Jestliže jsou splněny předchozí podmínky, pak je maximální hodnota označena jako detekovaný vrchol.

Na obrázcích na další straně (Obr. 4.16-Obr. 4.18) je označeno až příliš mnoho vrcholů. K největšímu snížení počtu detekovaných vrcholů dochází při společné podmínce o hodnotě mezi extrémními výchylkami a jejich sklonem, tato podmínka, ale v některých případech vyloučí i vrcholy, které by mohly být považovány za správné detekce. Nejvíce vrcholů je detekováno při výpočtu sklonu mezi jednotlivými extrémními hodnotami. Konečným rozhodnutím o K-komplexech může dojít ke zlepšení výsledku. Je však diskutabilní, kterou ze


zvolených podmínek vybrat pro nejlepší detekci, proto jsou zde uvedeny všechny tři možnosti.



**Obr. 4.16 Filtrovaný signál s detekovanými vrcholy splňující podmínku sklonu-expert 1**




**Obr. 4.17 Filtrovaný signál s detekovanými vrcholy splňující podmínku extrémů mezi minimální a maximální výchylkou-expert 1**




**Obr. 4.18 Filtrovaný signál s detekovanými vrcholy splňující podmínku extrémů a sklonu mezi minimální a maximální výchylkou-expert 1**

## 4.6 Rozhodnutí o K-komplexu


Z obrázků výše v podkapitole 4.5 je patrné, že jsou detekovány i vrcholy, které neodpovídají K-komplexům. Z tohoto důvodu je nutné zavedení konečného rozhodnutí o označení komplexů. Pro určení, co označit jako K-komplex, byly využity detekované vrcholy nad zvoleným prahem a detekované vrcholy splňující podmínku trvání a dále podmínku sklonu nebo výchylky mezi extrémními hodnotami či jejich společné použití sklonu a extrémů. Jestliže se detekované vrcholy oběma metodami shodují, dochází k finálnímu označení vrcholu jako K-komplex. V případě neshody se vrcholy vůbec neberou v úvahu. Na obrázcích níže jsou pro ilustraci uvedeny výsledné detekce s použitím podmínky sklonu mezi minimem a maximem výchylky signálu. Zbylé výsledky detekcí jsou popsány v kapitole 6 o statistickém zhodnocení vytvořených metod. Červeně jsou v obrázcích vyznačeny počátky K-komplexů expertem 1 a růžovými kružnicemi jsou vykresleny výsledky automatické detekce.




**Obr. 4.19** Úsek původního signálu-expert 1



**Obr. 4.20** Výsledek detekce po S-transformaci s odhadem obálky umocněním na druhou a podmínkou sklonu-expert 1




**Obr. 4.21 Výsledek detekce po filtraci pásmovou propustí s odhadem obálky s využitím operátoru TKEO a podmínkou sklonu-expert 1**




**Obr. 4.22 Výsledek detekce po S-trasformaci a s odhadem obálky Shannonovou energií a podmínkou sklonu-expert 1**

Na analyzovaném úseku signálu je detekce K-komplexů stejná ve všech verzích vytvořených algoritmů, ale liší se od označení K-komplexů odborníkem, na čemž je patrná problematika sladění detekční metody a vizuálního hodnocení určitého odborníka.

Bylo však dosaženo i rozličných detekcí K-komplexů v algoritmech mezi sebou, jak je uvedeno níže při výběru jiného intervalu (750-850 s) stejného signálu. Některé komplexy jsou označeny správně. Vyskytují se však i možnosti, kdy K-komplex označen nebyl nebo byl označen nesprávně.




**Obr. 4.23 Úsek původního signálu-expert 1**




**Obr. 4.24 Výsledek detekce po S-transformaci s odhadem obálky umocněním na druhou-expert 1**





**Obr. 4.25 Výsledek detekce po filtraci pásmovou propustí s odhadem obálky s využitím operátoru TKEO-expert 1**



**Obr. 4.26 Výsledek detekce po S-trasformaci a s odhadem obálky Shannonovou energií-expert 1**


Při odhadu obálky umocněním reálné složky na druhou (Obr. 4.24) byly na zvoleném úseku korektně označeny tři K-komplexy v časech 765 s, 784 s a 820 s. Další dva ohodnocené K-komplexy detekovány nebyly a jeden vrchol v čase 775 s je falešně označen jako K-komplex detekční metodou.

Detekce s použitím S-transformace a Shannonovy energie (Obr. 4.26) dává podobné výsledky na úseku signálu jako předešlá zhodnocená metoda. Navíc je ale správně označen vrchol v čase 813 s jako K-komplex, pravděpodobně díky jiné hodnotě prahu.


Výpočtem odhadu obálky s Teagerovým-Kaiserovým operátorem (Obr. 4.25) došlo ke správnému označení čtyř K-komplexů. Jediný vrchol, který nebyl označen jako K-komplex je v časovém okamžiku 808 s, jelikož je jeho úroveň vždy nižší než daný práh. Falešné označení K-komplexu v době 795 s je zapříčiněno charakteristickým chováním operátoru TKEO, kdy došlo v tomto případě k přehnanému zvýraznění špičkových hodnot.

## 5 POROVNÁNÍ VÝSLEDKŮ

V následující části práce dochází k porovnání výsledků vytvořených algoritmů na prvním signálu z dodané databáze [1]. Tento signál byl posuzován dvěma experty nezávisle na sobě a jejich výsledky označení K-komplexů se liší, což vede k obtížnému hodnocení dosažených výsledků. Uvedeny jsou metody využívající podmínku sklonu mezi minimem a maximem výchylky signálu. Souhrn výsledků dalších realizovaných algoritmů je popsán v kapitole o statistickém hodnocení metod v podkapitole 6.2.




Obr. 5.1 Úsek původního signálu s vyznačenými počátky K-komplexů expertem 1




Obr. 5.2 Úsek původního signálu s vyznačenými počátky K-komplexů expertem 2

Jako první je zobrazen výsledek detekce po použití Stockwellovy transformace a vytvoření odhadu obálky signálu umocněním reálné složky energie na druhou. Podmínkou mezi extrémními hodnotami je výpočet sklonu mezi minimem a maximem K-komplexu.




**Obr. 5.3 Výsledek detekce po S-transformaci s odhadem obálky umocněním na druhou-expert 1**




**Obr. 5.4 Výsledek detekce po S-transformaci s odhadem obálky umocněním na druhou-expert 2**

Druhá metoda byla zhotovena s použitím lineární filtrace pásmovou propustí na jejíž výsledek byl aplikován Teagerův-Kaiserův operátor pro vyhlazení signálu a zdůraznění požadovaných tvarů. Následně byla použita podmínka sklonu mezi extrémními hodnotami. Ukázka výsledku detekce K-komplexů na úseku signálu je uvedena níže (Obr. 5.5, Obr. 5.6).

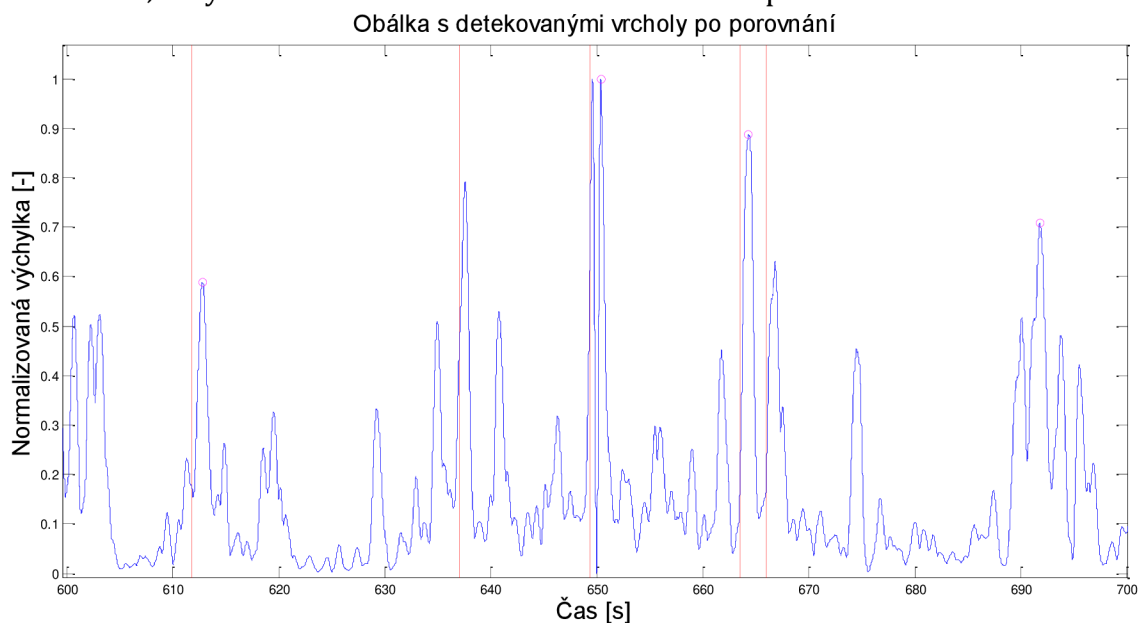


**Obr. 5.5 Výsledek detekce po filtraci pásmovou propustí s odhadem obálky s využitím operátoru TKEO-expert 1**




**Obr. 5.6 Výsledek detekce po filtraci pásmovou propustí s odhadem obálky s využitím operátoru TKEO-expert 2**

V následujícím algoritmu byla použita Stockwellova transformace a výpočet odhadu obálky signálu Shannonovou energií. Podmínka je shodná s předchozími metodami, tedy sklon mezi extrémními hodnotami komplexu.



**Obr. 5.7 Výsledek detekce po S-trasformaci s odhadem obálky Shannonovou energií-expert 1**



**Obr. 5.8 Výsledek detekce po S-trasformaci s odhadem obálky Shannonovou energií-expert 2**

Na obrázcích v této kapitole je na první pohled viditelná rozdílnost v hodnocení K-komplexů jednotlivými experty. První expert vizuálně zhodnotil více K-komplexů než druhý odborník, a navíc ještě v jiných časových úsecích, což při statistickém hodnocení vede k velkému počtu falešně pozitivních detekcí. Díky tomu bude komplikované vytvořené metody srovnat. Na prvních obrázcích při hodnocení expertem 1 došlo k vynechání vrcholu, který by mohl být označen,

nejspíše díky hodnotě prahu. Za tímto nedetekovaným K-komplexem je vyšší hodnota, jež ovlivnila prahovou hodnotu, která je vypočtena z násobku směrodatné odchylky na 30 s intervalu.

Stockwellova transformace je téměř srovnatelná s lineární filtrací pásmovou propustí ve shodném kmitočtovém pásmu od 0,5 Hz do 2 Hz. Odhady obálek signálu se odlišují, jelikož každý ze zvolených přístupů ovlivňuje úroveň signálu jinak. Umocněním na druhou dojde k potlačení neúčinných průběhů a zvýraznění určitých vyšších hodnot úrovně signálu v přijatelné míře. S použitím operátoru TKEO se výchyly zvýší a dochází k většímu rozdílu mezi nižšími a vyššími hodnotami, které mohou vést k vytvoření nesprávných vrcholů. Shannonova energie naopak zdůrazní hodnoty s nízkou úrovní signálu a utlumí velmi vysoké hodnoty, což je velmi názorně vidět na obrázku, kde jsou vyšší hodnoty na skoro stejné úrovni.

## 6 STATISTICKÉ VYHODNOCENÍ

Pro ohodnocení vytvořených algoritmů, byly vybrány některé předchozí práce, které byly řešeny na stejné databázi signálů [1], aby docházelo k objektivnímu zhodnocení na základě vybraných parametrů. K hodnocení byly vybrány parametry: senzitivita ( $TPR$ ), pozitivní prediktivita ( $PPV$ ), přesnost detekce ( $PD$ ) a falešná míra ( $FDR$ ) výskytů K-komplexů.

Nejdříve si tedy nadefinujeme proměnné, ze kterých vycházíme:

TP	správně pozitivní detekce K-komplexů
TN	správně negativní detekce K-komplexů
FP	falešně pozitivní detekce K-komplexů
FN	falešně negativní detekce K-komplexů

Účinnost detekce K-komplexů můžeme posuzovat mnoha možnostmi. Jednou z těchto možností je senzitivita ( $TPR$ ). Její hodnota nám říká, kolik K-komplexů, ze všech komplexů v signálu bylo detekováno

$$TPR = \frac{TP}{TP + FN} \cdot 100[\%]. \quad (6.1)$$

Další možností je pozitivní prediktivní hodnota ( $PPV$ ), která vyjadřuje pravděpodobnost, že K-komplex bude přítomný, pokud se bude jednat o pozitivní detekci

$$PPV = \frac{TP}{TP + FP} \cdot 100[\%]. \quad (6.2)$$

Přesnost detekce ( $PD$ ) je vyjádřena poměrem všech správně detekovaných K-komplexů i detekovaných komplexů s celkovým počtem K-komplexů. Přesnost detekce, je vyjádřena vzorcem

$$PD = \frac{TP}{TP + FN + FP} \cdot 100[\%]. \quad (6.3)$$

Poslední počítanou veličinou je falešná míra výskytů K-komplexů ( $FDR$ ). Jedná se o poměr nesprávně detekovaných K-komplexů ku veškerým pozitivním detekcím. Vzorec falešné míry výskytů je znázorněn jako



$$FDR = \frac{FP}{TP + FP} \cdot 100[\%]. \quad (6.4)$$

Spolehlivost detekčních metod byla počítána odděleně pro všechny metody, oba experty sjednocení a průnik hodnocení signálu experty.


## 6.1 Referenční hodnoty

Vybraná databáze signálů, která byla ohodnocena dvěma experty, byla popsána v kapitole 4.1. Pro pochopení složitosti hodnocení je nutné si analyzovat posouzení o vyskytujících se K-komplexech.

Jednotliví odborníci označili různý počet K-komplexů, jelikož hodnocení těchto grafoelementů podléhá subjektivnímu vnímání každého jedince. Z tohoto důvodu je v následující podkapitole uvedeno statistické hodnocení expertů vůči sobě, a to pouze na 5 signálech, které byly kontrolovány oběma experty.

**Tab. 6.1 Počet ohodnocených K-komplexů jednotlivými experty**

<b>Signál</b>	<b>Expert 1</b>	<b>Expert 2</b>
1	34	19
2	45	8
3	12	3
4	78	14
5	39	20
<b>celkem</b>	<b>208</b>	<b>64</b>




Obr. 6.1 Graf počtu ohodnocených K-komplexů jednotlivými experty

Z uvedených hodnot je patrné, jak se odborníci liší ve svých hodnoceních. První expert označil vždy více K-komplexů než druhý expert. Pokud se zaměříme na celkové hodnoty komplexů, které byly ohodnoceny, tak je rozdíl hodnocení viditelná na první pohled, kdy první expert označil 208 K-komplexů a druhý jen 64 grafoelementů.

V tabulce (Tab. 6.2) jsou uvedeny statistické parametry pro porovnání hodnocení experta 1 vůči expertu 2. Jedná se o případ, kdy ohodnocené K-komplexy od prvního odborníka jsou brány jako správné detekce a hledáme shody s druhým odborníkem.

Tab. 6.2 Statistické parametry pro porovnání hodnocení experta 1 vůči expertu 2


Signál	Expert 1	TP	FP	FN	TPR	PPV	PD	FDR
1	34	8	11	26	23,53	42,11	17,78	57,89
2	45	8	0	37	17,78	100,00	17,78	0,00
3	12	3	0	9	25,00	100,00	25,00	0,00
4	78	9	5	69	11,54	64,29	10,84	35,71
5	39	13	7	26	33,33	65,00	28,26	35,00
<b>celkem</b>	<b>208</b>	<b>41</b>	<b>23</b>	<b>167</b>	<b>19,71</b>	<b>64,06</b>	<b>17,75</b>	<b>35,94</b>



**Obr. 6.2 Graf porovnání falešně pozitivních a falešně negativních detekcí-expert 1**

Graf (Obr. 6.2) zobrazuje porovnání falešně pozitivních a falešně negativních detekcí, kdy označení K-komplexů expertem 1 byly brány jako referenční. Velké hodnoty falešně negativních detekcí poukazují na skutečnost, kdy je v signálu označen K-komplex, ale druhý expert jej neoznačil. Těchto hodnot bylo dosaženo právě díky většímu označení K-komplexů expertem 1.

V dalším grafu (Obr. 6.3) je srovnání senzitivity a prediktivity v případě, kdy jsou označení K-komplexů expertem 1 brány jako referenční. Senzitivita nedosahuje dobrých výsledků kvůli nízkým hodnotám správně pozitivních detekcí K-komplexů. Prediktivita je v případě druhého a třetího signálu 100 %, jelikož druhý expert zaznačil v rámci hodnocení velmi málo K-komplexů.




Obr. 6.3 Graf porovnání senzitivity a prediktivity-expert 1

V tabulce (Tab. 6.3) jsou uvedeny statistické parametry pro porovnání hodnocení experta 2 vůči expertu 1. Jedná se o případ, kdy ohodnocené K-komplexy od druhého odborníka jsou brány jako správné detekce a hledáme shody s prvním odborníkem.


Tab. 6.3 Statistické parametry pro porovnání hodnocení experta 2 vůči expertu 1

Signál	Expert 2	TP	FP	FN	TPR	PPV	PD	FDR
1	19	8	26	11	42,11	23,53	17,78	76,47
2	8	8	37	0	100,00	17,78	17,78	82,22
3	3	3	9	0	100,00	25,00	25,00	75,00
4	14	9	69	5	64,29	11,54	10,84	88,46
5	20	13	26	7	65,00	33,33	28,26	66,67
<b>celkem</b>	<b>64</b>	<b>41</b>	<b>167</b>	<b>23</b>	<b>64,06</b>	<b>19,71</b>	<b>17,75</b>	<b>80,29</b>



**Obr. 6.4 Graf porovnání falešně pozitivních a falešně negativních detekcí-expert 2**

Graf (Obr. 6.5) zobrazuje porovnání falešně negativních a falešně pozitivních detekcí K-komplexů, kdy označení K-komplexů expertem 2 byly brány jako referenční. Tedy opačný případ předchozího hodnocení (Tab. 6.2). Velké hodnoty falešně pozitivních detekcí nasvědčují tomu, že při označení K-komplexu expertem 2, bylo méně detekcí, jak při označení expertem 1, který jich ohodnotil více za správné.



**Obr. 6.5 Graf porovnání senzitivity a prediktivity-expert 2**

Na předcházejícím grafu (Obr. 6.5) je srovnání senzitivity a prediktivity v případě, kdy jsou označení K-komplexů expertem 2 brány jako referenční. Senzitivita dosahuje dobrých výsledků kvůli vysokým hodnotám správně pozitivních detekcí K-komplexů. Pozitivní prediktivita má tentokrát však hodnoty nižší, nejnižší hodnota 11,54 % je nalezena u čtvrtého signálu

Na uvedených výsledcích výše v tabulkách a grafech pozorujeme rozdílnost expertů v hodnocení signálů. První expert označil vždy více K-komplexů než druhý expert, od toho se odvíjí vypočtené hodnoty statistických parametrů. Největší rozdíl je patrný v případě výpočtu falešné míry výskytů K-komplexů (FDR).

## 6.2 Zhodnocení realizovaných metod

Následující část práce je věnována zhodnocení realizovaných metod. Celkový souhrn detekcí K-komplexů je uveden v tabulce (Tab. A 1) v příloze diplomové práce. Signály byly analyzovány dle označení experta 1 a experta 2. Navíc bylo využito sjednocení a průniku hodnocení obou expertů.

První metodou detekce, která byla testována je aplikace operátoru TKEO na filtrovaný signál pásmovou propustí. Jako podmínka pro detekci K-komplexů byl vybrán výpočet sklonu mezi extrémními hodnotami.

**Tab. 6.4 Statistické parametry pro metodu operátor TKEO-sklon**

<b>Metoda</b>	<b>TPR</b>	<b>PPV</b>	<b>PD</b>	<b>FDR</b>
Expert 1 TKEO sklon	61,03	36,09	29,33	63,91
Expert 2 TKEO sklon	62,50	15,69	14,34	84,31
Sjednocení TKEO sklon	61,70	37,83	30,63	62,17
Průnik TKEO sklon	78,05	12,55	12,12	87,45

Při nahlédnutí do tabulky (Tab. 6.4) je zřejmé, že nejlepšího výsledku pro senzitivitu bylo dosaženo při průniku hodnocení obou expertů 78,05 %. V případě dalších ohodnocení je senzitivita přibližně stejná. Nejvyšší hodnota pozitivní prediktivní hodnoty je při sjednocení hodnocení a také při hodnocení od prvního experta. Falešná míra výskytů K-komplexů má nejvyšší hodnotu při hodnocení signálu druhým expertem a při průniku hodnocení expertů. To mohlo být způsobeno tím, že algoritmus byl laděn zejména pro hodnocení prvního experta, a tudíž pak obsahoval více nesprávně detekovaných K-komplexů.

Další detekční metodou, jež byl zhotovena a analyzována je Stockwellova transformace s umocnění reálné složky signálu na druhou pro vytvoření odhadu obálky signálu. Podmínkou pro detekci K-komplexů je opět sklon.

**Tab. 6.5 Statistické parametry pro metodu Stockwellova transformace-sklon**

<b>Metoda</b>	<b>TPR</b>	<b>PPV</b>	<b>PD</b>	<b>FDR</b>
Expert 1 S-transformace sklon	60,66	37,76	30,33	62,24
Expert 2 S-transformace sklon	67,19	18,07	16,60	81,93
Sjednocení S-transformace sklon	61,35	39,59	31,68	60,41
Průnik S-transformace sklon	82,93	13,60	13,23	86,40

Na rozdíl od předchozí metody s využitím operátoru TKEO jsou tentokrát některé hodnoty senzitivity přívětivější, zejména v případě hodnocení expertem 2 a při průniku hodnocení expertů. Došlo ke snížení falešné míry výskytů komplexů, i když maximálně jen o 2 %. Tato metoda zlepšila výsledky pro hodnocení expertem 2 a průnik expertů. Zbývá ohodnocení zůstala zhruba stejná, tudíž bych považovala metodu se Stockwellovou transformací srovnatelnou ba i dokonce lepší než pouhou filtraci a aplikaci Teagerova Kaiserova operátoru.

Tyto dvě metody, jejichž předlohou byla zejména studie *a A wavelet and teager energy operator based method for automatic detection of K-Complex in sleep EEG* [3] poskytovaly nejpříznivější výsledky ze všech vytvořených detekčních metod.

Třetí metoda má stejné tělo jako algoritmus první. Drobnou obměnou je zde zvolená podmínka, která počítala úroveň signálu mezi minimální a maximální hodnotou K-komplexu a ne sklon, jako tomu bylo v předchozím případě.

**Tab. 6.6 Statistické parametry pro metodu operátor TKEO-extrém**

<b>Metoda</b>	<b>TPR</b>	<b>PPV</b>	<b>PD</b>	<b>FDR</b>
Expert 1 TKEO extrém	57,35	41,71	31,84	35,94
Expert 2 TKEO extrém	59,38	17,12	15,32	80,29
Sjednocení TKEO extrém	58,16	43,85	33,33	58,29
Průnik TKEO extrém	73,17	13,04	12,45	82,88

Při prvním pohledu do tabulky (Tab. 6.6) je jasně viditelné, že došlo ke zlepšení pozitivní prediktivní hodnoty, přesnosti detekce i falešné míry výskytů K-komplexů, pokud bereme jako srovnání předchozí detekční metodu TKEO s podmínkou sklonu. Došlo však ke snížení všech hodnot senzitivity. V případě průniku hodnocení expertů je hodnota senzitivity menší až o 5 %.

Následující metoda automatické detekce K-komplexů má stejný základ jako předešlá metoda se Stockwellovou transformací, kdy se vypočítal odhad obálky signálu umocněním reálné složky energie. Tento postup má však jednu odlišnost a

tou je zavedení podmínky počítající výchylku mezi extrémními hodnotami, tedy mezi minimální a maximální hodnotou K-komplexu.

**Tab. 6.7 Statistické parametry pro metodu Stockwellova transformace-extrém**

<b>Metoda</b>	<b>TPR</b>	<b>PPV</b>	<b>PD</b>	<b>FDR</b>
Expert 1 S-transformace extrém	55,88	42,58	31,87	56,15
Expert 2 S-transformace extrém	65,63	20,59	18,58	86,96
Sjednocení S-transformace extrém	58,51	46,22	34,81	57,42
Průnik S-transformace extrém	78,05	15,69	15,02	79,41

Při srovnání metody s předešlou, využívající Stockwellovu transformaci, je názorné navýšení pozitivní prediktivní hodnoty i lehce přesnost detekce. Snížily se hodnoty parametru falešné míry výskytů u všech hodnocení odborníky krom situace, kdy byl signál hodnocen druhým expertem, tato hodnota narostla o 5 %. Senzitivita je v této variantě detekce K-komplexů vždy nižší.

Následující výsledky statistických parametrů (Tab. 6.8) jsou pro metodu podobnou jako předešlý algoritmus využívající lineární filtraci pásmovou propustí a Teagerův-Kaiserův operátor pro výpočet odhadu obálky signálu. Podmínkou pro detekci K-komplexů zde byl definovaný sklon a současně také výchylka mezi minimální a maximální hodnotou K-komplexu.

**Tab. 6.8 Statistické parametry pro metodu operátor TKEO-sklon a extrém**

<b>Metoda</b>	<b>TPR</b>	<b>PPV</b>	<b>PD</b>	<b>FDR</b>
Expert 1 TKEO sklon+extrém	56,25	42,50	31,94	59,66
Expert 2 TKEO sklon+extrém	59,38	17,27	15,45	86,34
Sjednocení TKEO sklon+extrém	56,74	44,44	33,20	57,50
Průnik TKEO sklon+extrém	73,17	13,64	12,99	82,73

Z hodnot v tabulce při porovnání metody s aplikací TKEO pozorujeme pokles hodnot falešné míry výskytů K-komplexů až na hodnocení druhým expertem, tato hodnota je mírně vyšší oproti použití samotného sklonu o 2 % a při podmínce o extréměch dokonce o 6 %. Přesnost detekce a pozitivní prediktivní hodnota je u všech hodnocení lepší než v předešlých případech. Senzitivita je nižší. Srovnatelné hodnoty senzitivity jsou u metody s použitím podmínky o výchylce mezi extrémními hodnotami, a to při hodnocení druhým expertem, kdy je hodnota senzitivity 59,38 %, a při průniku hodnocení odborníků je senzitivita 73,17 %.



Předposlední analyzovaná metoda pro detekci K-komplexů využívá Stockwellovu transformaci a výpočet odhadu obálky signálu umocněním reálné složky energie. Zvolenou podmínkou byla hodnota sklonu a zároveň úroveň signálu mezi extrémními hodnotami.

**Tab. 6.9 Statistické parametry pro metodu Stockwellova transformace-sklon a extrém**

<b>Metoda</b>	<b>TPR</b>	<b>PPV</b>	<b>PD</b>	<b>FDR</b>
Expert 1 S-transformace sklon+extrém	55,51	43,14	32,06	55,56
Expert 2 S-transformace sklon+extrém	64,06	19,90	17,90	86,36
Sjednocení S-transformace sklon+extrém	56,74	45,71	33,90	56,86
Průnik S-transformace sklon+extrém	78,05	15,53	14,88	80,10

Hodnoty senzitivity jsou v tomto případě nižší ve srovnání s ostatními metodami založenými na Stockwellově transformaci. Senzitivita při průniku hodnocení obou expertů je stejná jako u metody s podmínkou o výchylce mezi extrémy, 78,05 %. Při hodnocení expertem 1 jsou získané hodnoty statistických parametrů nejlepší. Zbylé hodnoty senzitivity, prediktivity, přesnosti detekce a falešné míry detekce K-komplexů jsou oproti metodě s extrémy nižší, ale zase vyšší jako při použití podmínky se sklonem.

Poslední vytvořená metoda má základ ve Stockwellově transformaci. Odhad obálky signálu byl vypočten s použitím Shannonovy energie, což je odlišností od předešlých zhotovených postupů. Podmínkou mezi extrémními hodnotami úrovně signálu byl vypočtený sklon.

**Tab. 6.10 Statistické parametry pro metodu S-transformace s Shannonovou energií-sklon**


<b>Metoda</b>	<b>TPR</b>	<b>PPV</b>	<b>PD</b>	<b>FDR</b>
Expert 1 S-transformace SE sklon	58,46	38,41	30,17	53,78
Expert 2 S-transformace SE sklon	57,81	16,30	14,57	84,31
Sjednocení S-transformace SE sklon	59,22	40,34	31,57	61,59
Průnik S-transformace SE sklon	75,61	13,66	13,08	83,70

Z výsledků uvedených výše v tabulce (Tab. 6.10) nedochází u parametru falešné míry výskytů K-komplexů k lepším hodnotám než u ostatních metod. Přesnost detekce a pozitivní prediktivní hodnota by se dala srovnat s metodou TKEO s použitím podmínky o sklonu, jelikož se příliš neliší. Vyhodnocení senzitivity nedosahuje lepších výsledků, než jsou nejvyšší vypočtené hodnoty. Z toho důvodu nedošlo k rozšíření algoritmu S-transformace s výpočtem obálky

Shannonovou energií o podmínku s výchytkou mezi extrémními hodnotami komplexů ani spojení podmínek sklonu a extrémů.


V následující části jsou zobrazeny grafy shrnující výsledky senzitivity a pozitivní prediktivity vytvořených metod pokud je referenční hodnotou označení K-komplexu expertem 1 a zvláště expertem 2. Hodnoty odpovídají metodám v tomto pořadí:

1. TKEO-sklon
2. Stockwellova transformace-sklon
3. Expert 1xExpert 2/Expert 2xExpert 1
4. TKEO-extrém
5. Stockwellova transformace-extrém
6. Stockwellova transformace Shannonova energie-sklon
7. TKEO-sklon a extrém
8. Stockwellova transformace-sklon a extrém.



**Obr. 6.6 Graf porovnání falešně pozitivních a falešně negativních detekcí-expert 1**


Z grafu (Obr. 6.6) je patrné, že vytvořením metod došlo ke snížení falešně negativních detekcí K-komplexů oproti hodnocení mezi experty. Narostly však hodnoty falešně pozitivních detekcí. Detekčními algoritmy bylo označeno více K-komplexů, než bylo označeno expertem.




**Obr. 6.7 Graf porovnání senzitivity a prediktivity-expert 1**

V grafu na Obr. 6.7 je srovnání senzitivity a prediktivity v případě, kdy jsou označení K-komplexů expertem 1 brány jako referenční. Třetí metoda je zobrazena, aby bylo patrné, jak se hodnoty detekcí K-komplexů mezi odborníky liší. Nejlepších výsledků prediktivity dosahovala metoda S-transformace s podmínkou sklonu a extrému, za ní je hned S-transformace s podmínkou extrému. Nejpříznivějších hodnot senzitivity dosahovala metoda TKEO s podmínkou sklonu, která měla současně i nejhorší výsledek prediktivity, a S-transformace se stejnou podmínkou.

Na grafu níže (Obr. 6.8) je porovnání falešně pozitivních a falešně negativních detekcí zhotovených metod ve srovnání s druhým odborníkem. Falešně negativní hodnoty jsou shodné s hodnocením experta 2. Falešně pozitivní hodnoty narostly kromě metody Stockwellovy transformace s podmínkou extrémů, která je dokonce nižší než při hodnocení druhým odborníkem.



**Obr. 6.8 Graf porovnání falešně pozitivních a falešně negativních detekcí-expert 2**



**Obr. 6.9 Graf porovnání senzitivity a prediktivity-expert 2**

Senzitivita při srovnání s expertem 2 vyšla nejlépe v případě Stockwellovy transformace s podmínkou sklonu, dosahuje lepších hodnot než při srovnání s expertem 1. Dále následuje S-transformace s podmínkou extrému a S-transformace se společnou podmínkou sklonu a extrému. Nejhůře dopadla

senzitivita při S-transformaci a Shannonově energii. Hodnoty prediktivity pro hodnocení experta 2 jsou přibližně stejné.

Srovnání výsledků detekčních metod je složité, jelikož ani jednotliví odborníci se nedokáží shodnout na většině označených K-komplexů. Nejlepší hodnoty senzitivity z uvedených zhotovených přístupů jsou v případě S-transformace s podmínkou sklonu při srovnání s expertem 2. Nejhorších hodnot senzitivity dosahuje algoritmus s použitím Stockwellovy transformace s podmínkou extrémů při srovnání s hodnocením experta 1. Pozitivní prediktivní hodnota a přesnost detekce vyšla nejlépe u S-transformace s podmínkou o úrovni signálu mezi extrémními hodnotami a sklonem při hodnocení expertem 1, nejhorší výsledek prediktivity a přesnosti detekce byl při aplikaci operátoru TKEO s podmínkou sklonu při srovnání s druhým odborníkem. Falešná míra výskytů K-komplexů je nejvyšší, a tedy nejhorší u metody s využitím operátoru TKEO s podmínkou sklonu. Nejmenší, tím pádem nejlepší hodnoty falešné míry výskytů jsou v případě použití Teagerova-Kaiserova operátoru s podmínkou extrémů.

Z předešlé analýzy vytvořených algoritmů je možné považovat Stockwellovu transformaci, která byla předmětem diplomové práce, za metodu dosahující významných výsledků v případě detekce charakteristických znaků (K-komplexů) v zašuměných spánkových signálech. Pro důkladnější přezkoumání o přijatelnosti toho přístupu by bylo vhodné využít jinou databázi spánkových signálů EEG.

### 6.3 Srovnání s dalšími metodami

Porovnání vytvořených algoritmů s jinými studii, které byly vytvořeny, je značně komplikované. I když jsou metody testovány na stejné databázi spánkových signálů EEG [1], tak je zahrnutou do hodnocení jen prvních 5 signálů jako je tomu u studie založené na spojitě vlnkové transformaci [18]. V mnoha případech není uvedeno srovnání s hodnocením obou expertů a vybrán je nejčastěji jen první expert. Některé práce dokonce ani neuvádějí, který expert byl vybrán pro hodnocení dané studie, tím pádem není zřejmé, zda-li jejich dosažené výsledky mají signifikantní vypovídací hodnotu. Níže je uvedena tabulka (Tab. 6.11) souboru studií automatický detekcí K-komplexů ve spánkových signálech EEG, která obsahuje vědecké práce v rámci posledních 9 let. Zahrnula jsem do hodnocení také diplomovou práci [19], zabývající se stejnou problematikou s jiným řešením, která byla vytvořena na ÚBMI, jelikož byla testována na stejných datech, jako všechny vytvořené algoritmy v této práci.

**Tab. 6.11 Soubor metod využívající se pro detekci K-komplexů ve spánkových signálech EEG**

<b>Autor</b>	<b>Metoda</b>	<b>Úspěšnost</b>
Erdamar et al. 2012 [3]	WT, TKEO	TPR=80 %, FPR=7 %
Devuyt et al. 2010 [1]	Měřené parametry a odvození pravděpodobnosti výskytu komplexu	TPR=61,72 %, FDR=26,70 % (expert1) TPR=60,94 % (expert2)
Lajnef et al. 2015 [12]	WT, morfologická analýza hlavních komponent	TPR=83,1 %, FDR=36,31 % (expert1)
Patti et al. 2016 [18]	CWT, vlnky tvarově odpovídající K-komplexům	TPR=84 %, PPV=62 %
Pecníková 2016 [19]	WT, TKEO	TPR=52,9 %, PPV=26,3 % (expert1) TPR=68,8 %, PPV=15,2 % (expert2)
Pecníková 2016 [19]	Umělá neuronová síť	TPR=83,6 %, PPV=63,8 % (expert1) TPR=64,7 %, PPV=52,4 % (expert2)

Úspěšnosti automatické detekce K-komplexů této diplomové práce jsou srovnatelné zejména s hodnocením prvního experta, který ohodnotil všech 10 signálů EEG. Druhý expert vždy označil méně komplexů, a hlavně hodnotil jen 5 signálů z databáze. Tím zavádí do statistického zhodnocení značnou nepřesnost.

Při srovnání s jinými autory, jak je uvedeno v tabulce (Tab. 6.11), má vytvořená diplomová práce shodné hodnoty se studií [1] založené na měření parametrů a odvození pravděpodobnosti výskytu komplexu. Ještě také přichází v úvahu podobný výsledek s částí diplomové práce [19], která byla vytvořena obdobným postupem s využitím operátoru TKEO [3], která má však hodnoty senzitivity ještě zhruba o 10 % nižší, což by mohlo svědčit o lépe zvolených podmínkách pro detekci v této práci. Porovnání s dalšími metodami nepřikládám velkou váhu, jelikož byly vytvořeny jinými způsoby a jejich ohodnocení není dostatečné v rámci využití obou expertů a všech sejmutých signálů, jako tomu bylo ve vytvořené diplomové práci.

## 7 ZÁVĚR

Cílem diplomové práce bylo seznámení se s problematikou detekce K-komplexů ve spánkových signálech EEG a vytvoření algoritmu pro automatickou detekci K-komplexů. K tomu bylo přistoupeno dvěma způsoby dle zvolené studie [3], která se stala předlohou pro zhotovené řešení.

V první části práce je uveden popis biologických dějů, jimiž jsou bdění a spánek. Jsou zde charakterizovány jednotlivé fáze spánku pro porozumění signálům, které můžeme zaznamenat při vyšetření mozku.

Další kapitola se věnuje objasnění funkce a technického sestavení EEG přístroje. Byly popsány typické základní vlny díky nimž, můžeme analyzovat záznam EEG. Uvedena je řada grafoelementů, mezi které patří K-komplexy a artefakty ovlivňující snímaný signál.

Třetí oddíl obsahuje vybrané metody detekcí K-komplexů. Popsána je metoda detekce využívající vlnkovou transformaci, metoda detekce s aplikací Teagerova-Kaseirova operátoru, která byla předlohou pro vytvoření jedné části diplomové práce, a detekce využívající umělou neuronovou síť. Následně je znázorněn postup metody založené na měření parametrů a odvození pravděpodobnosti výskytu komplexu a metody detekce založené na CWT s vlnkami tvarově souhlasnými s K-komplexy.

Realizační část vysvětluje vytvořené algoritmy. První algoritmus využívá Stockwellovu transformaci v rozmezí 0,5-2 Hz, která byla aplikována na vstupní signál. Byla vytvořena obálka signálu po transformaci prostým umocněním signálu na druhou nebo výpočtem Shannonovy energie. Jako práh pro detekci vrcholů byl zvolen čtyřnásobek směrodatné odchylky z intervalu 30 s, jelikož v tomto trvání dochází k hodnocení záznamů odborníky. Dále byla použita filtrace pásmovou propustí v rozmezí 0,5-2 Hz a hledali se maximální a minimální výchylky filtrovaného signálu. Z dob trvání pozitivních a negativních částí vln jsou vybrány ty, které vyhovují podmínce a je vypočtena určitá hodnota mezi jednotlivými extrémními hodnotami komplexů. Posledním krokem bylo porovnání výsledků detekovaných vrcholů S-transformace a filtrovaného signálu. Jestliže došlo ke shodě výsledků, tak byl daný vrchol označen jako K-komplex.

Druhá zvolená možnost řešení obsahovala filtraci vstupního signálu pásmovou propustí v rozsahu 0,5-2 Hz. Na filtrovaný signál byla aplikována obálka TKEO. V dalších krocích se postupovalo jako v předchozím případě. Pro ilustraci jednotlivých kroků byl vybrán první signál z dodané databáze [1].

V neposlední řadě bylo provedeno statistické zhodnocení dosažených výsledků a porovnání s jinými autory. Vytvořené algoritmy jsou srovnatelné se studií *Automatic K-complexes detection in sleep EEG recordings using likelihood*

*thresholds* [1] a částí diplomové práce zabývající se *Automatickou detekcí K-komplexů ve spánkových signálech EEG* [19]. Na rozdíl od předcházející práce zhotovené algoritmy v této diplomové práci dosahují lepších hodnot specifity, a to až o 10 %. Databáze spánkových signálů EEG byla ohodnocena dvěma experty, kteří se ve svých výsledcích označení K-komplexů odlišují. Z toho důvodu se i získané výsledky statistického zhodnocení od sebe velmi liší. Hodnoty senzitivity byly obdobné v případě, kdy výsledky byly srovnávány s prvním odborníkem, díky tomu, že druhý odborník v každém z pěti signálů označil méně komplexů a tím zavádí do hodnocení značné zkreslení.

Výsledky diplomové práce nejsou dostatečně přesné z důvodu rozličného hodnocení spánkových signálů odborníky. Bylo by vhodné zhotovené postupy testovat na jiné databázi, popřípadě s jednotnějším hodnocením expertů. Ke zlepšení detekce by mohlo dojít při prohledávání nad a pod zvoleným prahem do určité přijatelné úrovně.



# Literatura

- [1] DEVUYST, S, T DUTOIT, P STENUIT a M KERKHOF. Automatic K-complexes detection in sleep EEG recordings using likelihood thresholds. *2010 Annual International Conference of the IEEE Engineering in Medicine and Biology*. IEEE, 2010, 2010 , 4658-4661. DOI: 10.1109/IEMBS.2010.5626447. ISBN 978-1-4244-4123-5. Dostupné také z: <http://ieeexplore.ieee.org/document/5626447/>
- [2] EL HELOU, J., V. NAVARRO, C. DEPIENNE, E. FEDIRKO, E. LEGUERN, M. BAULAC, I. AN-GOURFINKEL a C. ADAM. K-complex-induced seizures in autosomal dominant nocturnal frontal lobe epilepsy. *Clinical Neurophysiology* [online]. 2008, 119(10), 2201-2204 [cit. 2019-05-14]. DOI: 10.1016/j.clinph.2008.07.212. ISSN 13882457. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S1388245708008407>
- [3] ERDAMAR, Aykut, Fazıl DUMAN a Sinan YETKIN. A wavelet and teager energy operator based method for automatic detection of K-Complex in sleep EEG. *Expert Systems with Applications*. 2012, **39**(1), 1284-1290. DOI: 10.1016/j.eswa.2011.07.138. ISSN 09574174. Dostupné také z: <http://linkinghub.elsevier.com/retrieve/pii/S0957417411011110>
- [4] HOVORKA, Jiří, Tomáš NEŽÁDAL a Michal BAJAČEK. *EEG abnormita*. Praha: Maxdorf, c2006. ISBN 80-734-5093-3.
- [5] HUANG, Jingtao, Ian M. COLRAIN, M. Cecilia MELENDRES, et al. Cortical Processing of Respiratory Afferent Stimuli during Sleep in Children with the Obstructive Sleep Apnea Syndrome. *Sleep* [online]. 2008, 31(3), 403-410 [cit. 2019-05-14]. DOI: 10.1093/sleep/31.3.403. ISSN 1550-9109. Dostupné z: <https://academic.oup.com/sleep/article-lookup/doi/10.1093/sleep/31.3.403>
- [6] CHMELÁŘ, Milan. *Lékařská přístrojová technika I*. Brno: CERM, 1995. Učební texty vysokých škol. ISBN 80-858-6763-X.
- [7] IBER, C., S. ANCOLI-ISRAEL, A. CHESSON a S. F. QUAND. *The AASM manual for the scoring of sleep and associated events: rules, terminology and technical specifications*. 1. Westchester: Illinois: American Academy of Sleep Medicine, 2007.
- [8] JAN, Jiří. *Číslíková filtrace, analýza a restaurace signálů*. 2. upr. a rozš. vyd. Brno: VUTIUM, 2002. ISBN 80-214-1558-4.
- [9] KOLÁŘ, Radim. *Lékařská diagnostická technika: Přednáška*. FEKT VUT v Brně, 2015.
- [10] KOZUMPLÍK, Jiří. *Analýza biologických signálů: Přednáška*. Brno. FEKT VUT v Brně, 2016.
- [11] KOZUMPLÍK, Jiří. *Pokročilá analýza biologických signálů: Přednáška*. Brno. FEKT VUT v Brně, 2016.
- [12] LAJNEF, Tarek, Sahbi CHAIBI, Jean-Baptiste EICHENLAUB, Perrine M. RUBY, Pierre-Emmanuel AGUERA, Mounir SAMET, Abdennaceur KACHOURI a Karim JERBI. Sleep spindle and K-complex detection using tunable Q-factor

- wavelet transform and morphological component analysis. *Frontiers in Human Neuroscience* [online]. 2015, 9 [cit. 2019-05-14]. DOI: 10.3389/fnhum.2015.00414. ISSN 1662-5161. Dostupné z: <http://journal.frontiersin.org/Article/10.3389/fnhum.2015.00414/abstract>
- [13] MISITI, Michel, Yves MISITI, Georges OPPENHEIM, Francis CASTANIÉ a Henri MAÎTRE. *Les Ondelettes et leurs applications*. Paris: HERMES / LAVOISIER, 2003. ISBN 2746205262.
- [14] MLČOCH, Zbyněk. Spánkový cyklus dospělého člověka v průběhu 8 hodin. In: <Http://www.zbynekmlcoch.cz> [online]. 2012 [cit. 2019-01-02]. Dostupné z: <http://www.zbynekmlcoch.cz/informace/images/stories/clanek-obrazek-fotografie/spankovy-cyklus-REM-nonREM.png>
- [15] MONTPLAISIR, Jacques, Sylvie BOUCHER, Anik GOSSELIN, Gaétan POIRIER a Gilles LAVIGNE. Persistence of Repetitive EEG Arousals (K-Alpha Complexes) in RLS Patients Treated With L-DOPA. *Sleep* [online]. 1996, 19(3), 196-199 [cit. 2019-05-14]. DOI: 10.1093/sleep/19.3.196. ISSN 1550-9109. Dostupné z: <https://academic.oup.com/sleep/article-lookup/doi/10.1093/sleep/19.3.196>
- [16] MORNSTEIN, Vojtěch. *Lékařská biofyzika a přístrojová technika*. 4.vydání. Brno: Neptun, 2004. ISBN 80-902-8961-4.
- [17] MYSLIVĚČEK, Jaromír. *Základy neurověd*. Praha: TRITON, 2003. ISBN 80-7254-234-6.
- [18] PATTI, Chanakya Reddy, Haslaile ABDULLAH, Yutaka SHOJI, Amie HAYLEY, Claudia SCHILLING, Michael SCHREDL a Dean CVETKOVIC. K-complex detection based on pattern matched wavelets. 2016 IEEE EMBS Conference on Biomedical Engineering and Sciences (IECBES) [online]. IEEE, 2016, , 470-474 [cit. 2019-05-14]. DOI: 10.1109/IECBES.2016.7843495. ISBN 978-1-4673-7791-1. Dostupné z: <http://ieeexplore.ieee.org/document/7843495/>
- [19] PECNÍKOVÁ, Michaela. Automatická detekce K-komplexů ve spánkových signálech EEG. Antonínská 548/1 601 90 Brno, 2016. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií.
- [20] RANJAN, Rakesh, Rajeev ARYA, Steven Lawrence FERNANDES, Erukonda SRAVYA a Vinay JAIN. A fuzzy neural network approach for automatic K-complex detection in sleep EEG signal. *Pattern Recognition Letters*. 2018, **115**(1 November 2018), 74-83. DOI: 10.1016/j.patrec.2018.01.001. ISSN 01678655. Dostupné také z: <https://linkinghub.elsevier.com/retrieve/pii/S0167865518300023>
- [21] ROZMAN, Jiří. *Elektronické přístroje v lékařství*. Praha: ACADEMIA, 2006. ISBN 80-200-1308-3.
- [22] SHETE, V. V., Sapana SONAR, Ashwini CHARANTIMATH a Sachin ELGENDELWAR. Detection of K-Complex in sleep EEG signal with matched filter and neural network. *International Journal of Engineering Research & Technology: IJERT* [online]. 2012, 1(3), 1-4 [cit. 2019-01-02]. ISSN 2278-

0181. Dostupné z: <https://www.ijert.org/browse/volume-1-2012/may-2012-edition?start=20>
- [23] STOCKWELL, R.G., L. MANSINHA a R.P. LOWE. Localization of the complex spectrum: the S transform. *IEEE Transactions on Signal Processing*. 1996, 44(4), 998-1001. DOI: 10.1109/78.492555. ISSN 1053587X. Dostupné také z: <http://ieeexplore.ieee.org/document/492555/>
- [24] VOJTĚCH, Zdeněk. *EEG v epileptologii dospělých*. Praha: Grada, 2005. ISBN 80-247-0690-3.
- [25] ZIDELMAL, Z., A. AMIROU, D. OULD-ABDESLAM, A. MOUKADEM a A. DIETERLEN. QRS detection using S-Transform and Shannon energy. *Computer Methods and Programs in Biomedicine*. 2014, **116**(1), 1-9. DOI: 10.1016/j.cmpb.2014.04.008. ISSN 01692607. Dostupné také z: <https://linkinghub.elsevier.com/retrieve/pii/S0169260714001473>

# Seznam symbolů, veličin a zkratek

EEG	elektroencefalogram/elektroencefalograf
TKEO	Teager-Kaiser Energy Operator
REM	aktivovaný spánek
NonREM	spánek s pomalými vlnami
EOG	elektrookulogram
EMG	elektromyogram
EKG	elektrokardiogram
ECoG	elektrokortikogram
Hz	jednotka frekvence
s	jednotka času
$\mu\text{V}$	jednotka elektrického napětí
POSTS	pozitivní okcipitální ostré tranzienty
fvz	vzorkovací frekvence
LSA	Least Square Acceleration
CWT	Continuous Wavelet Transform
ST	Stockwellova transformace, S-transformace
STFT	Short Fourier Transform
WT	Wavelet Transform
TP	správně detekované komplexy
FP	špatně detekované komplexy
FN	špatně nedetekované komplexy
TN	správně nedetekované komplexy
TPR	senzitivita
PPV	pozitivní prediktivní hodnota
PD	přesnost detekce
FDR	falešná míra výskytů K-komplexů

# Seznam příloh

## A. Seznam výsledků detekcí K-komplexů

Tab. A 1 Seznam výsledků všech realizovaných metod

Metoda	TP	FP	FN	celkem expert	TPR	PPV	PD	FDR
Expert1 TKEO Sklon	166	294	106	272	61,03	36,09	29,33	63,91
Expert2 TKEO Sklon	40	215	24	64	62,50	15,69	14,34	84,31
Sjednocení TKEO Sklon	174	286	108	282	61,70	37,83	30,63	62,17
Průnik TKEO Sklon	32	223	9	41	78,05	12,55	12,12	87,45
Expert1 STOCKWELL Sklon	165	272	107	272	60,66	37,76	30,33	62,24
Expert2 STOCKWELL Sklon	43	195	21	64	67,19	18,07	16,60	81,93
Sjednocení STOCKWELL Sklon	173	264	109	282	61,35	39,59	31,68	60,41
Průnik STOCKWELL Sklon	34	216	7	41	82,93	13,60	13,23	86,40
Expert1xExpert2	41	23	167	208	19,71	64,06	17,75	35,94
Expert2xExpert1	41	167	23	64	64,06	19,71	17,75	80,29

<b>Metoda</b>	<b>TP</b>	<b>FP</b>	<b>FN</b>	<b>celkem expert</b>	<b>TPR</b>	<b>PPV</b>	<b>PD</b>	<b>FDR</b>
Expert1 TKEO Extrém	156	218	116	272	57,35	41,71	31,84	58,29
Expert2 TKEO Extrém	38	184	26	64	59,38	17,12	15,32	82,88
Sjednocení TKEO Extrém	164	210	118	282	58,16	43,85	33,33	56,15
Průnik TKEO Extrém	30	200	11	41	73,17	13,04	12,45	86,96
Expert1 STOCKWELL Extrém	152	205	120	272	55,88	42,58	31,87	57,42
Expert2 STOCKWELL Extrém	42	162	22	64	65,63	20,59	18,58	79,41
Sjednocení STOCKWELL Extrém	165	192	117	282	58,51	46,22	34,81	53,78
Průnik STOCKWELL Extrém	32	172	9	41	78,05	15,69	15,02	84,31
Expert1 STOCKWELL SE-Sklon	159	255	113	272	58,46	38,41	30,17	61,59
Expert2 STOCKWELL SE-Sklon	37	190	27	64	57,81	16,30	14,57	83,70
Sjednocení STOCKWELL SE-Sklon	167	247	115	282	59,22	40,34	31,57	59,66
Průnik STOCKWELL SE-Sklon	31	196	10	41	75,61	13,66	13,08	86,34

<b>Metoda</b>	<b>TP</b>	<b>FP</b>	<b>FN</b>	<b>celkem expert</b>	<b>TPR</b>	<b>PPV</b>	<b>PD</b>	<b>FDR</b>
Expert1 TKEO Sklon+Extrém	153	207	119	272	56,25	42,50	31,94	57,50
Expert2 TKEO Sklon+Extrém	38	182	26	64	59,38	17,27	15,45	82,73
Sjednocení TKEO Sklon+Extrém	160	200	122	282	56,74	44,44	33,20	55,56
Průnik TKEO Sklon+Extrém	30	190	11	41	73,17	13,64	12,99	86,36
Expert1 STOCKWELL Sklon+Extrém	151	199	121	272	55,51	43,14	32,06	56,86
Expert2 STOCKWELL Sklon+Extrém	41	165	23	64	64,06	19,90	17,90	80,10
Sjednocení STOCKWELL Sklon+Extrém	160	190	122	282	56,74	45,71	33,90	54,29
Průnik STOCKWELL Sklon+Extrém	32	174	9	41	78,05	15,53	14,88	84,47

B. Přílohy v souboru \*.zip

Skript PpTkeoExtem.m  
Skript PpTkeoSklon.m  
Skript PpTkeoExtemSklon.m  
Skript StShannonEnergySklon.m  
Skript UmocneniNaDruhouExtrem.m  
Skript UmocneniNaDruhouSklon.m  
Skript UmocneniNaDruhouExtremSklon.m  
Databáze signálů