

bakalářská práce

# Klasifikace dlouhodobých EEG záznamů

*Jiří Vošmik*



Květen 2014

Ing. Václav Gerla, Ph.D.

České vysoké učení technické v Praze

Fakulta elektrotechnická, Katedra kybernetiky



## **Poděkování**

Rád bych poděkoval vedoucímu bakalářské práce Ing. Václavu Gerlovi Ph.D. za přínosné konzultace, které dopomohly této práci ke vzniku.

## **Prohlášení**

Prohlašuji, že jsem předloženou práci vypracoval samostatně, a že jsem uvedl veškeré použité informační zdroje v souladu s Metodickým pokynem o dodržování etických principů při přípravě vysokoškolských závěrečných prací.

V Praze dne 22. 5. 2014

## **Abstrakt**

Cílem této práce je porovnání výsledků klasifikátorů k-nejbližších sousedů, naivního bayesovského klasifikátoru, support vector machine a skrytých markovských modelů při použití na reálných záznamech EEG. Použité EEG záznamy byly záznamy spánkové, EEG signály s artefakty a komatózní EEG signály. Před vlastní klasifikací byla provedena normalizace a selekce nejlepších příznaků všech záznamů pro snížení dimenze příznakového prostoru. Dále byla provedena optimalizace parametrů k-nejbližších sousedů a support vector machine. Klasifikátory byly hodnoceny především na základě jejich přesnosti, senzitivity, specificity a času výpočtu.

## **Abstrakt**

Aim of this thesis is comparison of k-nearest neighbors, naive bayes classifier, support vector machine and hidden markov models based on their performance on real EEG datasets. Sleep, artifact and coma datasets were used. Prior to the classification, feature normalisation and selection were used in order to reduce feature space dimensionality of the datasets. Next, hyperparameter optimisation for k-nearest neighbors and support vector machine was performed. Classifiers were compared using the following measures: accuracy, sensitivity, specificity and time complexity.

# Obsah

<b>1. Úvod</b>	<b>1</b>
<b>2. EEG</b>	<b>2</b>
2.1. Vznik EEG . . . . .	2
2.2. Záznam EEG . . . . .	3
2.3. Zpracování EEG signálu . . . . .	4
2.3.1. Předzpracování signálu . . . . .	4
2.3.2. Segmentace signálu . . . . .	4
2.3.3. Extrakce příznaků . . . . .	5
2.3.4. Normalizace příznaků . . . . .	5
2.3.5. Selektce příznaků . . . . .	6
<b>3. Klasifikace</b>	<b>8</b>
3.1. Klasifikátory . . . . .	8
3.1.1. k-Nejbližších Sousedů . . . . .	8
3.1.2. Naivní bayesovský klasifikátor . . . . .	9
3.1.3. Support vector machine . . . . .	10
3.1.4. Skryté markovské modely . . . . .	11
3.2. Metody pro porovnání klasifikátorů . . . . .	13
3.2.1. Křížová validace . . . . .	13
3.2.2. Měřítko přesnosti . . . . .	13
<b>4. Použitá data</b>	<b>15</b>
4.1. Spánková data . . . . .	15
4.2. EEG data s artefakty . . . . .	16
4.3. Komatózní data . . . . .	17
<b>5. Praktická část</b>	<b>18</b>
5.1. Normalizace a selektce příznaků . . . . .	18
5.1.1. Spánková data . . . . .	19
5.1.2. Data s artefakty . . . . .	20
5.1.3. Komatózní data . . . . .	21
5.2. Optimalizace parametrů k-NN a SVM . . . . .	22

5.3. Výsledky klasifikace . . . . .	24
5.3.1. Křížová validace na úrovni záznamů pro spánková data . . . . .	25
5.3.2. Křížová validace na úrovni segmentů pro první záznam spánkových dat . . . . .	26
5.3.3. Křížová validace na úrovni segmentů pro všechny čtyři záznamy spánkových dat . . . . .	28
5.3.4. Křížová validace na úrovni záznamů pro EEG data s artefakty . . . . .	30
5.3.5. Křížová validace na úrovni segmentů pro všechny čtyři záznamy EEG dat s artefakty . . . . .	32
5.3.6. Křížová validace na úrovni segmentů pro všechny čtyři záznamy komatózních dat . . . . .	34
5.3.7. Křížová validace na úrovni segmentů pro první záznam komatózních dat . . . . .	35
5.4. Porovnání klasifikátorů . . . . .	36
5.4.1. Porovnání klasifikátorů podle výsledků ve všech experimentech . . . . .	36
5.4.2. Porovnání klasifikátorů podle výsledků na jednotlivých typech dat . . . . .	37
<b>6. Závěr</b>	<b>38</b>
<b>Přílohy</b>	
<b>A. Extrahované příznaky</b>	<b>39</b>
<b>B. Vizualizace selektovaných příznaků</b>	<b>44</b>
<b>Literatura</b>	<b>49</b>





# 1. Úvod

Elektroencefalografie je v současnosti důležitá diagnostická metoda, která umožňuje analyzovat činnost mozku. Lékaři používají EEG například k diagnostice spánkových poruch, epilepsie nebo komatu. Zpracování dlouhých záznamů EEG je nicméně zdoluhavá práce a proto je v současnosti vynakládáno mnoho úsilí ve snaze vytvořit systém, který by tuto práci dokázal vykonávat autonomně, rychle a spolehlivě. Takový systém by lékařům ušetřil mnoho práce a času a byl by užitečným nástrojem v lékařské praxi.

Cílem této bakalářské práce je v prostředí programu MATLAB implementovat několik klasifikačních metod a následně porovnat jejich výsledky nad reálnými EEG záznamy za účelem nalezení klasifikátoru, který by nejlépe dokázal usnadnit lékařům vyhodnocování záznamů EEG. Porovnávané klasifikátory jsou support vector machine, naivní bayesovský klasifikátor, k-nejbližších sousedů a skryté markovské modely. Tyto klasifikátory budou porovnávány podle jejich výsledků na spánkových záznamech, záznamech s artefakty a na komatózních EEG signálech.

V kapitole 2 jsou uvedeny základní informace o EEG signálu a jeho zpracování. Kapitola 3 popisuje použité klasifikátory a metody použité k vyhodnocení jejich úspěšnosti. V kapitole 4 jsou popsány použité skupiny záznamů EEG. Kapitola 5 se zabývá zpracováním dat, postupem vlastní klasifikace a jejími výsledky. Kapitola 6 shrnuje dosažené výsledky.

## 2. EEG


Elektroencefalografie je diagnostická metoda, která zaznamenává elektrickou aktivitu generovanou mozkovými strukturami. Elektroencefalogram je vlastní elektrická aktivita naměřená z povrchu hlavy [1].

### 2.1. Vznik EEG

Lidský mozek se skládá převážně z nervových buněk (neuronů) a z podpůrných buněk (gliových buněk), které se nacházejí mezi neurony. Neurony reagují na podněty a přenášejí informace na dlouhé vzdálenosti. Každá nervová buňka se skládá z těla a z výběžků. Tělo neuronu má jediné jádro a obsahuje většinu metabolismu buňky. Axon je dlouhý výběžek schopný přenášet elektrický signál a u obratlovců může dosahovat délky až několik metrů. Dendrity jsou krátké výběžky, které jsou napojeny na axony nebo na dendrity jiných neuronů a přijímají impulzy od jiných neuronů nebo odesílají impulzy jiným neuronům. V lidském mozku je každý neuron propojen s dalšími přibližně 10 000 jinými neurony, většinou skrze dendrity. Spojení dvou neuronů se nazývá synapse [2]. Typická stavba neuronu je vyobrazena na Obr. 1.

Mozková aktivita především souvisí s proudy přenášenými mezi synapsami axonů a dendritů nebo dendritů různých neuronů. Na membráně neuronu lze detekovat elektrický potenciál se zápornou polaritou a tento potenciál se mění v závislosti na synaptických aktivitách. Pokud neuron přenáší informaci (tzv. akční potenciál), pak je v neuronech na něj napojených vyvolán excitační post-synaptický potenciál (EPSP) nebo inhibiční post-synaptický potenciál (IPSP) v závislosti na typu synapse, kterou končí první neuron. EPSP vyvolá depolarizaci membrány neuronu, zatímco IPSP vyvolá hyperpolarizaci membrány. V případě, že depolarizace membrány neuronu překročí určitou hranici, neuron se aktivuje a sám vysílá akční potenciál.

Při aktivaci neuronů v dendritech vznikají elektrické proudy, které vytvářejí elektrické pole měřitelné elektroencefalografy [2]. EEG měří hlavně proudy, které vznikají



**Obrázek 1.** Stavba neuronu [3]

během synaptických excitací dendritů pyramidových neuronů v mozkové kůře. Elektrické proudy v mozku se sestávají převážně z pohybu iontů  $\text{Na}^+$ ,  $\text{K}^+$ ,  $\text{Ca}^{++}$  a  $\text{Cl}^-$  přes kanály v membráně neuronů.

Vzhledem k tomu, že EEG signál musí projít skrz lebku, skalp a několik dalších vrstev hlavy, pouze velmi velké množství podobně prostorově orientovaných neuronů dokáže generovat elektrické pole měřitelné na povrchu hlavy [1].

## 2.2. Záznam EEG


Elektroencefalograf je systém pro záznam EEG skládající se z elektrod, zesilovačů, filtrů, analogově digitálních převodníků a ze záznamového zařízení.

Elektrody snímají signál z povrchu hlavy a zesilovače slabý snímaný signál zesilují na úroveň, kde může být přesně digitalizován. Výstup každého zesilovače je jeden kanál EEG, který je dále digitalizován analogově digitálním převodníkem pro umožnění dalšího zpracování výpočetní technikou.

Standardní rozmístění elektrod je tzv. 10-20 systém. Název 10-20 označuje proporci onální vzdálenosti mezi ušima a nosem, kde jsou umístěné elektrody. Tento systém používá 21 elektrod, které jsou rozmístěny tak, aby dobře pokryly všechny oblasti mozku. Elektrody jsou označeny písmenem podle svého umístění na lebce: F (frontal), C (central), T (temporal), P (posterior), O (occipital). Dále jsou elektrody očíslovány lichými

## 2. EEG

číslky na levé straně hlavy a sudými čísly na straně pravé [1]. Rozmístění elektrod podle systému 10-20 je znázorněno na Obr. 2.



Obrázek 2. Pozice elektrod pro 10-20 systém [4]

## 2.3. Zpracování EEG signálu

### 2.3.1. Předzpracování signálu

Naměřený EEG signál je nutné připravit pro další zpracování. Použití různých metod předzpracování závisí na typu dat, jejich zašumělosti a na tom, jak budou dále zpracovávány. Mezi nejdůležitějšími metodami předzpracování signálu jsou filtrování a převzorkování.

Filtrace odstraňuje nežádoucí složky signálu. Horní propusti se používají pro odfiltrování frekvenčních složek s  $f < 0.1$  Hz, dolní propusti se používají pro odfiltrování vysokofrekvenčního šumu s  $f > 70$  Hz a pásmová zadrž se používá pro odstranění rušení z napájecí sítě s  $f = 50$  Hz .

Signály naměřené s vysokou vzorkovací frekvencí jsou při dalším zpracování náročné na paměť a zpomalují vyhodnocování EEG dat, takže je často vhodné takové signály převzorkovat s nižší vzorkovací frekvencí [5].

### 2.3.2. Segmentace signálu

EEG je obecně nestacionární signál, jeho statistické charakteristiky se tedy mění s časem. Pro extrakci příznaků a následnou klasifikaci je proto nutná segmentace, neboli rozdělení signálu na časové segmenty, které jsou téměř stacionární.

Segmentace může být konstantní nebo adaptivní. Při konstantní segmentaci je EEG rozdělen na segmenty se stálou délkou. Optimální délka segmentů se liší pro různé typy EEG záznamů, ale obvykle se používá konstantní segmentace s délkou v řádu jednotek až desítek sekund. Adaptivní segmentace rozděluje záznam na segmenty s různou délkou podle jejich charakteristik. Toto umožňuje rozdělit záznam na stacionárnější segmenty než konstantní segmentace [5] [2].

### 2.3.3. Extrakce příznaků

Příznaky jsou vlastnosti každého objektu (v tomto případě vlastnosti segmentů EEG signálu), které tento objekt charakterizují. Příznaky vhodné pro klasifikaci by měly mít následující vlastnosti:

- Robustnost. Příznaky by měly být odolné vůči přítomnosti šumu
- Rozhodovací schopnost. Příznaky objektů v různých třídách by měly mít odlišné hodnoty a měly by být separovatelné
- Spolehlivost. Příznaky by pro objekty ve stejné třídě měly mít podobné hodnoty
- Nezávislost. Příznaky by měly být nekorelované

Příznakový vektor  $\mathbf{x}$  je vektor obsahující všechny příznaky daného objektu. Příznakové vektory s  $M$  příznaky lze znázornit jako body v  $M$ -dimenzionálním příznakovém prostoru [6].

Extrakce příznaků z EEG signálu je vypočítání různých numerických příznaků z každého segmentu signálu. Tyto příznaky budou při klasifikaci použity pro zařazení daného segmentu do třídy.

### 2.3.4. Normalizace příznaků

Různé příznaky často mají odlišné poměry mezi minimálními a maximálními hodnotami. Příznaky s vyššími hodnotami pak mohou mít vyšší vliv na funkci klasifikátorů než příznaky s nižšími hodnotami, které mohou mít lepší diskriminační schopnost. Pro správnou funkci některých klasifikátorů proto může být důležitá normalizace příznaků [7].

V této práci je použita normalizace všech příznaků na stejné intervaly  $\langle 0, 1 \rangle$ . Normalizovaný příznak  $x'_i$  je vypočítán podle vzorce

$$x'_i = \frac{x_i - \min_i}{\max_i - \min_i} \quad (1)$$

## 2. EEG

kde  $x_i$  je  $i$ -tý příznak před normalizací a  $\min_i$  a  $\max_i$  jsou jeho minimální a maximální hodnoty v celé množině dat.

Další často používaná metoda je normalizace příznaků na nulovou střední hodnotu a jednotkovou směrodatnou odchylku. Normalizovaný příznak je vypočítán podle vzorce

$$x'_i = \frac{x_i - \bar{x}}{\sigma_x} \quad (2)$$

kde  $\bar{x}$  a  $\sigma_x$  jsou střední hodnota a směrodatná odchylka příznaku před normalizací.

Normalizaci příznaků je nutné provést dohromady pro všechny záznamy, které budou klasifikovány společně [5].

### 2.3.5. Selektce příznaků

Složitost klasifikace obvykle závisí na dimenzi příznakového prostoru  $M$  a na velikosti trénovací množiny  $N$  a s rostoucí dimenzí příznakového prostoru se zvyšuje potřebná velikost trénovací množiny pro správnou funkci klasifikátorů. Při konečné velikosti trénovací množiny se při zvyšování dimenze příznakového prostoru od dimenze 1 nejprve zlepšují výsledky klasifikátorů, ale po určité kritické hodnotě se se výsledky klasifikátorů začnou zhoršovat. Pro snížení výpočetní náročnosti a zachování generalizační schopnosti klasifikátorů je proto často vhodné snížit dimenzi příznakového prostoru vynecháním příznaků, které mají nízkou diskriminační schopnost [6].

Existuje mnoho různých metod pro selekci příznaků, které se dají mimo jiné rozdělit na filtry a wrappery. Filter vybírá příznaky podle jejich obecných charakteristik, zatímco wrapper vybírá příznaky pomocí přesnosti cílového klasifikátoru při použití daného příznaku.

Vzhledem k faktu, že cíl této práce je porovnání různých klasifikátorů, byla pro výběr příznaků zvolena metoda ReliefF, která podle výše zmíněného rozdělení patří do první skupiny. Myšlenka za touto metodou je, že užitečný příznak by měl mít odlišné hodnoty u prvků z dat, které mají rozdílné třídy, a podobné hodnoty u prvků ve stejné třídě. Binární Relief náhodně vybírá jeden prvek z dat a hledá jeho nejbližšího souseda ze stejné třídy a jeho nejbližšího souseda z druhé třídy. Všem příznakům je dále přiřazeno skóre na základě porovnání jejich hodnot u nejbližších sousedů s hodnotami patřícími vybranému prvku a tento proces  $m$ -krát opakuje.

Rozšíření ReliefF dokáže zpracovávat data s více třídami a redukuje vliv šumu použitím  $k$  nejbližších sousedů. Data s více třídami jsou zpracovány nalezením  $k$  nejbližších

sousedů ze stejné třídy a z každé z ostatních tříd pro každý vybraný prvek. Příspěvky nejbližších sousedů ke skóre příznaku jsou dále váženy podle apriorní pravděpodobnosti jejich třídy. Vstupní parametry algoritmu jsou počet nejbližších sousedů  $k$  a počet opakování  $m$  [8]. V této práci byly použity hodnoty  $k = 10$  a  $m$  rovné celkovému počtu segmentů z dat.

## 3. Klasifikace

Klasifikace je rozřazování objektů do rozdílných tříd. V této práci se konkrétně jedná o rozřazování jednotlivých segmentů EEG signálu. Každý segment je charakterizován svým příznakovým vektorem, na základě něhož jednotlivé klasifikátory rozhodují o příslušnosti daného segmentu k dané třídě.

Všechny v této práci používané klasifikátory jsou algoritmy učení s učitelem, což znamená, že k učení využívají trénovací množinu skládající se z příznakových vektorů a informací o třídě každého segmentu.

V následujícím textu, pokud nebude řečeno jinak, bude použito toto značení:  $\mathbf{x}_n$  označuje příznakový vektor  $n$ -tého objektu ze souboru dat,  $y_n$  označuje skutečnou třídu  $n$ -tého objektu,  $\hat{y}_n$  označuje odhadnutou třídu  $n$ -tého objektu,  $n \in \{1, \dots, N\}$ , kde  $N$  je velikost souboru dat.  $y \in \{1, \dots, K\}$ , kde  $K$  je počet tříd.  $x_m$  označuje  $m$ -tý prvek příznakového vektoru,  $m \in \{1, \dots, M\}$ , kde  $M$  je dimenze příznakového prostoru.

### 3.1. Klasifikátory

#### 3.1.1. k-Nejblížších Sousedů

Algoritmus k-nejblížších sousedů (k-nearest neighbors, k-NN) je klasifikátor, který určuje třídu testovaného objektu jako třídu, která se nejčastěji vyskytuje u  $k$  k němu v nějakém smyslu nejblížších sousedů z trénovací množiny. Učení klasifikátoru k-NN tedy odpovídá uložení celé trénovací množiny do paměti a zpracování dat probíhá až při klasifikaci testovací množiny.

Parametr  $k$  je přirozené číslo a jeho volba by měla být provedena s ohledem na charakteristiky klasifikovaných dat a počet tříd. Pro klasifikaci do dvou tříd je vhodné volit  $k$  liché, aby se zamezilo nerozhodnému stavu. Pro více tříd nerozhodnému stavu s jistotou zabránit nelze, ale nastává s nižší pravděpodobností pro vyšší  $k$ . Vyšší  $k$  dále vede k hladší rozhodovací hranici klasifikátoru v příznakovém prostoru, zatímco nižší



$k$  k hranici více ovlivňované každým prvkem z trénovací množiny, což může způsobit horší výsledky klasifikátoru naučeného na zašuměných datech [6].

Jako měřítko pro výběr nejbližších sousedů je použita nějaká metrika. V této práci byla použita euklidovská metrika, která počítá vzdálenost  $d$  mezi dvěma vektory  $\mathbf{a}$  a  $\mathbf{b}$  podle vzorce:

$$d(\mathbf{a}, \mathbf{b}) = \sqrt{\sum_{m=1}^M (a_m - b_m)^2} \quad (3)$$

### 3.1.2. Naivní bayesovský klasifikátor

Bayesovské rozhodování pro minimalizaci pravděpodobnosti chybného rozhodnutí vede na klasifikátor, který zařadí příznakový vektor  $\mathbf{x}$  do třídy podle následujících vztahů:

$$\hat{y} = \arg \max_{j \in \{1, \dots, K\}} P(Y = j | X = \mathbf{x}) \quad (4)$$

$$P(Y = j | X = \mathbf{x}) = \frac{P(X = \mathbf{x} | Y = j)P(Y = j)}{\sum_{k=1}^K P(X = \mathbf{x} | Y = k)P(Y = k)} \quad (5)$$

Apriorní pravděpodobnost  $P(Y = j)$  a pravděpodobnost  $P(X = \mathbf{x} | Y = j)$ , často označovaná jako věrohodnost, jsou odhadovány z dat v trénovací množině. Množství dat v trénovací množině pro získání dobrého odhadu věrohodnosti vzrůstá exponenciálně s dimenzí příznakového prostoru, takže pro velké dimenze příznakového prostoru často není získání takového odhadu reálné. Pro takové případy se proto používá předpoklad statistické nezávislosti jednotlivých příznaků. S ohledem na tento předpoklad lze pro odhad věrohodnosti použít následující vzorec:

$$P(X = \mathbf{x} | Y = j) = \prod_{m=1}^M P(X = x_m | Y = j) \quad (6)$$

Tuto metodu odhadu věrohodnosti používá naivní bayesovský klasifikátor (Naive bayes classifier, NB), který příznakové vektory  $\mathbf{x}$  zařazuje do tříd podle vztahu (7).

$$\hat{y} = \arg \max_{j \in \{1, \dots, K\}} P(Y = j | X = \mathbf{x}) = \arg \max_{j \in \{1, \dots, K\}} \prod_{m=1}^M P(X = x_m | Y = j) \quad (7)$$

Naivní bayesovský klasifikátor má často dobré výsledky i pro data, kde předpoklad nezávislosti jednotlivých příznaků neplatí. [7]

### 3.1.3. Support vector machine

Support vector machine (SVM) je lineární klasifikátor, který rozděljuje objekty do dvou tříd  $y \in \{-1, 1\}$ . Třída příznakového vektoru  $\mathbf{x}$  je určena jako:

$$\hat{y} = \text{sign}(\mathbf{w} \cdot \mathbf{x} + b) \quad (8)$$

Pro lineárně separovatelnou trénovací množinu existuje vždy alespoň jedna dvojice  $\mathbf{w}$  a  $b$  taková, aby pro všechny prvky z trénovací množiny byla splněna podmínka

$$y_n(\mathbf{w} \cdot \mathbf{x}_n + b) > 0 \quad (9)$$

Dvojic parametrů  $\mathbf{w}$  a  $b$ , které splňují tuto podmínku, může pro lineárně separovatelná data ovšem existovat mnoho. SVM hledá optimální separující nadrovinu určenou těmito parametry, čehož je dosaženo maximalizací minimální vzdálenosti separující nadroviny od všech prvků trénovací množiny, což je hodnota označovaná jako tzv. margin. Margin lze kvantifikovat jako  $\frac{2}{\|\mathbf{w}\|}$  a problém nalezení optimální dvojice  $\mathbf{w}$  a  $b$  lze formulovat jako minimalizaci výrazu

$$\frac{1}{2} \|\mathbf{w}\|^2 \quad (10)$$

za podmínky

$$y_n(\mathbf{w} \cdot \mathbf{x}_n + b) \geq 1 \quad n = 1, 2, \dots, N \quad (11)$$

Tento problém lze převést na hledání lagrangeových multiplikátorů  $\lambda_n \geq 0$ ,  $n = 1, 2, \dots, N$ , které maximalizují výraz

$$L(\lambda) = \sum_{n=1}^N \lambda_n - \frac{1}{2} \sum_{n=1}^N \sum_{m=1}^N \lambda_n \lambda_m y_n y_m K(\mathbf{x}_n, \mathbf{x}_m) \quad (12)$$

za podmínek

$$\lambda_n \geq 0 \quad (13)$$

$$\sum_{n=1}^N \lambda_n y_n = 0 \quad (14)$$

Po vyřešení tohoto problému jsou všechna  $\lambda_n$  nulová, kromě těch  $\lambda_n$ , které přísluší příznakovým vektorům  $\mathbf{x}_n$ , které jsou nejbližší separující nadrovině. Těmto vektorům se říká podpurné vektory neboli support vectors a jako jediné se projeví ve výsledku učení klasifikátoru. Jejich počet je dále značený  $N_s$  a množina všech podpurných vektorů je dále značená jako  $SV$ . Výsledné  $\mathbf{w}$  a  $b$ , lze získat pomocí vztahů:

$$\mathbf{w} = \sum_{n \in SV} \lambda_n y_n \mathbf{x}_n \quad (15)$$

$$b = \frac{1}{N_s} \sum_{n \in SV} \left( y_n - \sum_{m \in SV} \lambda_m y_m K(\mathbf{x}_n, \mathbf{x}_m) \right) \quad (16)$$

Pro lineárně neseparabilní data lze problém rozšířit o tzv. volné proměnné (slack variables)  $\xi_n$ ,  $n = 1, 2, \dots, N$ , které umožní umístit separující nadrovinu tak, že některé vektory  $\mathbf{x}$  z trénovací množiny nespĺňují podmínku (9). Optimalizační problém se poté dá zapsat jako minimalizace

$$\frac{1}{2}\|\mathbf{w}\|^2 + C \sum_{n=1}^N \xi_n \quad (17)$$

za podmínek

$$y_n(\mathbf{w} \cdot \mathbf{x}_n + b) \geq 1 - \xi_n \quad n = 1, 2, \dots, N \quad (18)$$

$$\xi_n \geq 0 \quad n = 1, 2, \dots, N \quad (19)$$

neboli maximalizace

$$L(\lambda) = \sum_{n=1}^N \lambda_n - \frac{1}{2} \sum_{n=1}^N \sum_{m=1}^N \lambda_n \lambda_m y_n y_m K(\mathbf{x}_n, \mathbf{x}_m) \quad (20)$$

za podmínek

$$C \geq \lambda_n \geq 0 \quad (21)$$

$$\sum_{n=1}^N \lambda_n y_n = 0 \quad (22)$$

kde  $C$  je regularizační konstanta.

Funkce  $K(\mathbf{x}_n, \mathbf{x}_m)$  v rovnici (12) je takzvaná jádrová funkce (kernel function), která umožňuje transformovat příznakový prostor do vyšší dimenze, ve které mohou být lineárně separovatelné data, která v původním příznakovém prostoru lineárně separovatelná nebyla. Když tato transformace není použita, jádrová funkce odpovídá pouze skalárnímu součinu. V této práci je použit RBF (radial basis function) kernel.

$$K(\mathbf{x}_n, \mathbf{x}_m) = \exp\left(-\frac{\|\mathbf{x}_n - \mathbf{x}_m\|^2}{\sigma^2}\right) \quad (23)$$

Rozšíření binární SVM na více tříd je možné provést několika způsoby. V této práci byl použit one-against-one přístup. One-against-one trénuje  $K(K-1)/2$  binárních klasifikátorů, každý oddělující jednu dvojici tříd. Rozhodnutí o třídě testovaného vektoru je poté učiněno na základě většinového hlasování binárních klasifikátorů [7] [9].

#### 3.1.4. Skryté markovské modely

Předchozí popsané klasifikátory předpokládají nezávislost jednotlivých tříd a tyto klasifikátory klasifikují každý segment záznamu nezávisle na ostatních segmentech. Pokud

### 3. Klasifikace

byl tedy příznakový vektor  $\mathbf{x}_n$  zařazen do třídy  $i$ , další vektor  $\mathbf{x}_{n+1}$  mohl být zařazen do jakékoli jiné třídy. V případě některých záznamů EEG (například spánkových) lze předpokládat závislost jednotlivých tříd a záznamy se dají klasifikovat jako celé posloupnosti segmentů. Skryté markovské modely (Hidden markov models, HMM) používají kontextuální informaci obsaženou v datech a klasifikace každého příznakového vektoru je závislá na výsledku klasifikace předchozího příznakového vektoru [7].

Skrytý markovský model  $\lambda = (A, B, \pi)$  je charakterizován následujícími parametry:

- $K$  je počet skrytých stavů modelu
- $S = \{1, 2, \dots, K\}$  je množina možných skrytých stavů modelu. V tomto případě je totožná s množinou všech možných tříd.
- $M$  počet různých pozorování na výstupu modelu
- $V = \{v_1, v_2, \dots, v_M\}$  je konečná množina možných pozorování
- Matice přechodu  $A = \{a_{ij}\}$ , kde každý prvek  $a_{ij}$  označuje pravděpodobnost přechodu modelu ze stavu  $i$  do stavu  $j$
- Rozdělení pravděpodobnosti pozorování na výstupu modelu  $B = \{b_{ij}\}$ , kde každý prvek  $b_{ij}$  označuje pravděpodobnost pozorování  $v_j$  v případě, že se model nachází ve stavu  $i$
- Rozdělení pravděpodobnosti počátečních stavů modelu  $\pi = \{\pi_i\}$ , kde každý prvek  $\pi_i$  označuje pravděpodobnost, že model začne ve stavu  $i$

V případě, že výstupy modelu jsou spojité signály nebo vektory a není je možné modelovat konečnou množinou pozorování, lze použít skryté markovské modely, které modelují své výstupy jako spojité náhodné veličiny. V této práci bylo pro modelování pravděpodobnosti pozorování vektoru  $\mathbf{x}$ , když se model nachází ve stavu  $i$ , použito normální rozdělení, často se používá směs normálních rozdělení.

$$b_i(\mathbf{x}) = \rho(\mathbf{x}, \mu_i, \mathbf{U}_i) \quad (24)$$

Symboly  $\mu_i$  a  $\mathbf{U}_i$  zde označují vektor středních hodnot a kovarianční matici pro stav  $i$ .

Klasifikace se v tomto případě shoduje s hledáním optimální posloupnosti tříd  $Y = y_1 y_2 \dots y_N$ , pro danou posloupnost pozorování  $X = \mathbf{x}_1 \mathbf{x}_2 \dots \mathbf{x}_N$  a model  $\lambda$ . Tento problém lze vyřešit s pomocí tzv. Viterbiho algoritmu [10].

## 3.2. Metody pro porovnání klasifikátorů

### 3.2.1. Křížová validace

Křížová validace (cross-validation) je metoda testování přesnosti klasifikátorů, kde část dat je odebrána z trénovací množiny před trénováním klasifikátoru a následně je použita jako testovací množina. Pomocí této metody lze získat dobrý odhad skutečné chyby klasifikátoru.

Tzv.  $k$ -násobná křížová validace ( $k$ -fold cross-validation) rozdělí data do  $k$  stejně velkých částí. Jedna tato část je použita jako testovací množina a zbytek dat jako trénovací množina. Tento proces je opakován  $k$ -krát tak, že každá část je jako testovací množina použita právě jednou. Pro velké  $k$  je odhad chyby velmi přesný, ale má vysoký rozptyl a výpočet dlouho trvá. Pro malé  $k$  je odhad chyby méně přesný, ale výpočet je rychlejší. V praxi se často volí hodnota  $k = 10$  [6].

### 3.2.2. Měřítko přesnosti

Pro porovnání jednotlivých klasifikátorů je třeba zavést nějaká měřítko, která dokáží konzistentně kvantifikovat jejich úspěšnost a vhodnost. V dalším textu jsou popsána měřítko vybraná pro porovnávání klasifikátorů v této práci.

Většina měřítek přesnosti není vypočítána přímo z výstupů klasifikátorů, ale z chybové matice (confusion matrix), což je matice vytvořená z výsledků klasifikace, která reprezentuje jak jsou jednotlivé prvky testovací množiny klasifikátorem zařazeny do tříd s ohledem na jejich skutečnou třídu.

Prvky matice  $n_{ij}$  jsou čísla, která určují kolik prvků testovací množiny bylo klasifikátorem zařazeno do třídy  $i$  v případě, že jejich skutečná třída byla  $j$ . Diagonální prvky matice tedy reprezentují počty správně oklasifikovaných prvků z testovací množiny, zatímco nediagonální prvky matice reprezentují počty špatně oklasifikovaných prvků z testovací množiny.

Základní použité měřítko je přesnost (accuracy). Přesnost vyjadřuje celkový poměr správně oklasifikovaných prvků z testovací množiny a dá se vypočítat podle vzorce:

$$ACC = \frac{1}{N} \sum_{i=1}^K n_{i,i} \quad (25)$$

Toto měřítko je společné pro všechny třídy a nabývá hodnot od 0 (žádný prvek testovací množiny nebyl správně klasifikován) do 1 (perfektní klasifikace).

### 3. Klasifikace

Pro výpočet dalších měřítek, které hodnotí úspěšnost klasifikátoru pro každou klasifikovanou třídu zvláště je nutné zavést další pomocná měřítka. Pro každou třídu  $i$  lze rozlišit 4 případy výsledku klasifikace: true positive (TP), false positive (FP), true negative (TN) a false negative (FN).

True positive jsou prvky testovací množiny správně oklasifikované jako  $i$ .

$$TP_i = n_{ii} \quad (26)$$

False positive jsou prvky testovací množiny špatně oklasifikované jako  $i$ .

$$FP_i = \sum_{j=1}^K n_{i,j} - n_{i,i} \quad (27)$$

False negative jsou prvky testovací množiny špatně neoklasifikované jako  $i$ .

$$FN_i = \sum_{j=1}^K n_{j,i} - n_{i,i} \quad (28)$$

True negative jsou prvky testovací množiny správně neoklasifikované jako  $i$ .

$$TN_i = N - TP_i - FP_i - FN_i \quad (29)$$

Z předchozích hodnot lze pro každou třídu  $i$  vypočítat senzitivitu (sensitivity nebo také TP Rate) a specifitu (specificity nebo také TN Rate).

$$TPR_i = \frac{TP_i}{TP_i + FN_i} \quad (30)$$

$$TNR_i = \frac{TN_i}{TN_i + FP_i} \quad (31)$$

Senzitivita odpovídá podílu prvků testovací množiny, které patří do dané třídy a klasifikátor je tam správně zařadil. Specifita odpovídá podílu prvků testovací množiny, které nepatří do dané třídy a klasifikátor je tam správně nezařadil. Obě tyto měřítka tedy nabývají hodnot od 0 do 1 [11].

## 4. Použitá data

V této práci byly pro porovnání klasifikátorů použity tři různé typy záznamů: Spánková data, komatózní data a EEG data s artefakty.

### 4.1. Spánková data

K dispozici je 5 záznamů spánkových dat, které obsahují 10 kanálů EEG. Každý záznam je rozdělen do segmentů s konstantní 30-ti sekundovou délkou, ze kterých již byly extrahovány příznaky. Pro každý kanál jich bylo vyextrahováno 157 a celkový počet příznaků každého segmentu tak je 1570. Jejich seznam je uveden v příloze A.

Spánková data jsou rozdělena do šesti tříd, které odpovídají jednotlivým fázím spánku: bdělost (wake), non-rapid eye movement 1-4 (NREM1, NREM2, NREM3, NREM4) a rapid eye movement (REM). Vzhledem k vysoké podobnosti NREM1 s NREM2 a NREM3 s NREM4 byly pro klasifikaci tyto dvojice tříd sloučeny.

Označení tříd spánkových dat použité v klasifikaci je uvedeno v Tab. 1. Celkové zastoupení klasifikovaných tříd ve všech záznamech spánkových dat je uvedeno v Tab. 2. Přehled záznamů spánkových dat je uveden v Tab. 3.

**Tabulka 1.** Označení tříd pro spánková data

Číslo třídy	1	2	3	4
Popis třídy	REM	NREM3+NREM4	NREM1+NREM2	wake

**Tabulka 2.** Celkové zastoupení klasifikovaných tříd ve spánkových datech

Třída	1	2	3	4
Počet segmentů	737	1274	1517	1199

#### 4. Použitá data

**Tabulka 3.** Přehled použitých záznamů spánkových dat

Záznam č.	1	2	3	4	5
Počet segmentů	985	874	1003	941	978
Zastoupené třídy	1,2,3,4	1,2,3	1,2,3,4	1,2,3,4	1,2,3,4

### 4.2. EEG data s artefakty

Použitá EEG data s artefakty byly měřeny celkem pro pět subjektů. Záznamy jsou zpracovány konstantní 2 sekundovou segmentací. Každý záznam se skládá z 19 kanálů EEG a pro každý kanál bylo vyextrahováno 160 příznaků. Celkový počet příznaků je tedy 3040. Jejich seznam je uveden v příloze A. Data s artefakty lze rozdělit do tří tříd: normální aktivita (bez artefaktů), svalový pohyb a pohyb očí.

Označení tříd dat s artefakty použité v klasifikaci je uvedeno v Tab. 4. Celkové zastoupení klasifikovaných tříd ve všech záznamech dat s artefakty je uvedeno v Tab. 5. Přehled záznamů dat s artefakty je uveden v Tab. 6.

**Tabulka 4.** Označení tříd pro EEG data s artefakty

Číslo třídy	1	2	3
Popis třídy	normální aktivita	svalový pohyb	pohyb očí

**Tabulka 5.** Celkové zastoupení klasifikovaných tříd v EEG datech s artefakty

Třída	1	2	3
Počet segmentů	519	97	180

**Tabulka 6.** Přehled použitých záznamů EEG dat s artefakty

Záznam č.	1	2	3	4	5
Počet segmentů	180	149	164	154	149
Zastoupené třídy	1,2,3	1,2,3	1,2,3	1,2,3	1,2,3



### 4.3. Komatózní data

Komatózní data se skládají z pěti záznamů. Každý záznam je nasegmentován s konstantní 30-ti sekundovou segmentací a ze segmentů byly již vyextrahovány příznaky. Každý záznam má 9 kanálů a pro každý kanál bylo vygenerováno 157 příznaků, takže celkový počet příznaků je 1413. Jejich seznam je uveden v příloze A. Použité záznamy obsahují 7 tříd, které odpovídají hloubce komatu: C1, C2, C3, C4, C5, C6, C7. Třída C7 odpovídá nejhlubšímu komatu.

Označení tříd komatózních dat použité v klasifikaci je uvedeno v Tab. 7. Celkové zastoupení klasifikovaných tříd ve všech záznamech komatózních dat je uvedeno v Tab. 8. Přehled záznamů komatózních dat je uveden v Tab. 9.

**Tabulka 7.** Označení tříd pro komatózní data

Číslo třídy	1	2	3	4	5	6	7
Popis třídy	C1	C2	C3	C4	C5	C6	C7

**Tabulka 8.** Celkové zastoupení klasifikovaných tříd v komatózních datech

Třída	1	2	3	4	5	6	7
Počet segmentů	2142	9590	2418	6653	772	3561	3902

**Tabulka 9.** Přehled použitých záznamů komatózních dat

Záznam č.	1	2	3	4	5
Počet segmentů	6058	5756	5583	5633	5858
Zastoupené třídy	1,2,3,4,5,6,7	1,2,3,4,5,6,7	1,2,3	1,2,3,4,5,6	1,2,3,4,5

## 5. Praktická část

Cílem práce je porovnání výsledků jednotlivých klasifikátorů nad reálnými EEG záznamy. Všechny tři skupiny dodaných záznamů jsou již předzpracované, nasegmentované a mají vyextrahované příznaky. Dalšími v této práci provedenými kroky jsou normalizace a selekce příznaků uvedené v části 5.1, optimalizace parametrů některých klasifikátorů popsaná v části 5.2, vlastní klasifikace v části 5.3 a zhodnocení výsledků klasifikátorů popsané v části 5.4.

Pro normalizaci a selekci příznaků byl použit software Weka popsaný v [12]. Pro klasifikaci byla použita implementace k-NN a SVM ze Statistics Pattern Recognition Toolbox [13], dále implementace NB ze Statistics Toolbox [14] a implementace HMM z Hidden Markov Model Toolbox [15].

V této práci byly dále v prostředí programu MATLAB naprogramovány funkce pro klasifikaci, které umožňují již implementovaným klasifikátorům předávat data v jednotném formátu a které zaručují, že všechny klasifikátory budou pro každý experiment trénovány a testovány na stejných množinách. Dále byla naprogramována funkce pro vypočítání měřítek popsaných v části 3.2.2.

### 5.1. Normalizace a selekce příznaků


Příznaky vygenerované pro záznamy jsou různých druhů a mají často velmi odlišné dynamické rozsahy. Pro správnou funkci klasifikátorů je proto nutné je normalizovat. Tento předpoklad byl potvrzen při předběžném testování, kde na nenormalizovaných datech dosahovaly klasifikátory výrazně horších výsledků než na datech normalizovaných. Dále, vzhledem k vysoké dimenzi příznakového prostoru u všech tří skupin záznamů, je k další klasifikaci vhodné vybrat pouze příznaky s vysokou rozhodovací schopností. Všechny tři skupiny záznamů byly proto normalizovány metodou popsanou v rovnici (1) a následně byly pomocí algoritmu ReliefF vybrány nejlepší příznaky z každé skupiny. Normalizace a selekce příznaků byly provedeny nad všemi záznamy v každé skupině dohromady.

Počet příznaků, které byly použity pro klasifikaci, byl pro každou skupinu záznamů vybrán s ohledem na celkový počet segmentů dané skupiny záznamů tak, aby tento počet byl mnohonásobně vyšší než počet použitých příznaků. U komatózních záznamů byla dále zohledněna jejich vysoká délka (viz Tab. 9) a byl vybrán počet příznaků umožňující rychlou klasifikaci.

### 5.1.1. Spánková data

Pro spánková data bylo vygenerováno 1570 příznaků a celkový počet segmentů všech záznamů je 4871. Pro zachování dobrého poměru počtu segmentů proti počtu příznaků bylo vybráno 200 nejlepších příznaků.

Obr. 3 zobrazuje porovnání průběhu čtyř z 200 vybraných příznaků pro spánková data s ohodnocením lékaře během prvních 5 hodin prvního záznamu. Porovnání pro ostatní záznamy lze nalézt v příloze B.




**Obrázek 3.** Porovnání průběhu čtyř vybraných příznaků ze spánkových dat a ohodnocení od lékaře pro prvních pět hodin záznamu 1

### 5.1.2. Data s artefakty

Záznamy EEG dat s artefakty mají 3041 vygenerovaných příznaků a dohromady mají 796 segmentů. Pro tyto záznamy bylo vybráno 60 nejlepších příznaků.

Obr. 4 zobrazuje porovnání průběhu čtyř ze 60 vybraných příznaků pro data s artefakty s ohodnocením lékaře pro první záznam. Porovnání pro ostatní záznamy lze nalézt v příloze B.

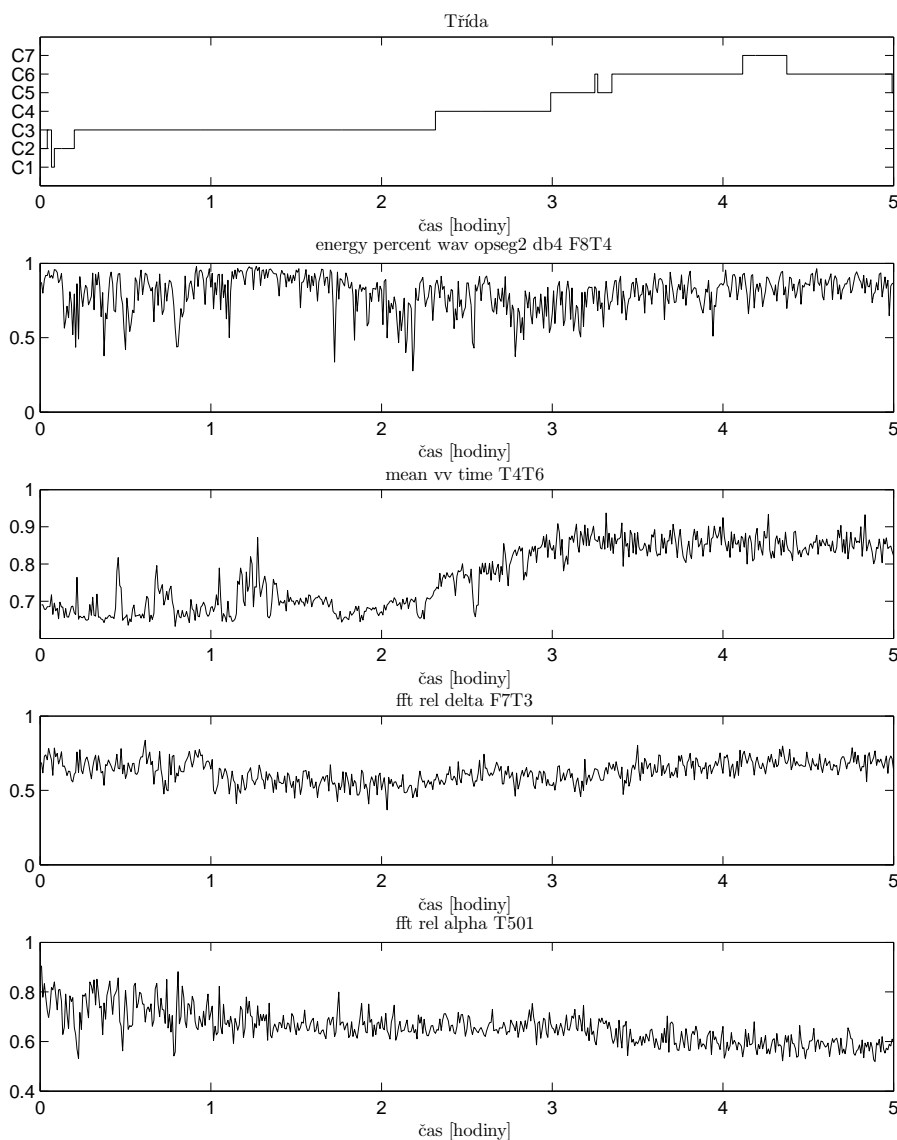


**Obrázek 4.** Porovnání průběhu čtyř vybraných příznaků z dat s artefakty a ohodnocení záznamu od lékaře pro záznam 1

### 5.1.3. Komatózní data

Komatózní data mají 1413 příznaků a celkový počet segmentů je 28 888. Pro komatózní data bylo vybráno 200 nejlepších příznaků.

Obr. 5 zobrazuje porovnání průběhu čtyř ze 200 vybraných příznaků pro komatózní data s ohodnocením lékaře pro prvních pět hodin záznamu 1.



**Obrázek 5.** Porovnání průběhu čtyř vybraných příznaků z komatózních dat a ohodnocení záznamu od lékaře pro prvních pět hodin záznamu 1

## 5.2. Optimalizace parametrů k-NN a SVM

Klasifikátory k-NN a SVM mají vstupní parametry, které je nutné optimalizovat. Pro k-NN je to počet nejbližších sousedů  $k$ , pro SVM jsou to regularizační konstanta  $C$  a parametr jádrové funkce  $\sigma$ .

Postup optimalizace byl pro každý z klasifikátorů a každou skupinu záznamů následující:


- Z všech tří skupin záznamů byl vyčleněn jeden záznam, který byl použit jako validační množina a nebyl použit v další klasifikaci. V případě dat s artefakty a spánkových dat to byl záznam 5, v případě komatózních dat to byl záznam 1.
- Klasifikátor byl natrénován pomocí zbylých záznamů pro několik hodnot vstupních parametrů
- Natrénovaný klasifikátor byl otestován na validační množině
- Byly vybrány parametry či dvojice parametrů, se kterými klasifikátor dosáhl nejvyšší přesnosti na validační množině

U k-NN byl testován parametr  $k$  v rozsahu  $\langle 1, 20 \rangle$ . U SVM byly testovány všechny dvojice  $C$  a  $\sigma$  z kartézského součinu množin  $C = \{10, 100, 1000\}$  a  $\sigma = \{0.1, 0.2, 0.5, 1\}$

Pro spánková data byly takto zvoleny parametry  $k = 9$ ,  $C = 100$  a  $\sigma = 1$ , výsledné přesnosti jsou uvedeny v Tab. 10 a na Obr. 6. SVM dosáhl stejné nejvyšší hodnoty přesnosti pro několik dvojic parametrů, použité parametry byly z těchto dvojic pro nedostatek dalších dat a zkušeností zvoleny náhodně.

**Tabulka 10.** Výsledná přesnost SVM pro různé  $C$  a  $\sigma$  u spánkových dat

	$\sigma = 0.1$	$\sigma = 0.2$	$\sigma = 0.5$	$\sigma = 1$
$C = 10$	0.2055	0.2832	0.3609	0.3609
$C = 100$	0.2076	0.2832	0.3609	0.3609
$C = 1000$	0.2076	0.2832	0.3609	0.3609




**Obrázek 6.** Výsledná přesnost SVM pro  $k$  od 1 do 20 u spánkových dat

Pro data s artefakty byly zvoleny parametry  $k = 5$ ,  $C = 10$  a  $\sigma = 1$ , výsledné přesnosti jsou uvedeny v Tab. 11 a na Obr. 7.


**Tabulka 11.** Výsledná přesnost SVM pro různé  $C$  a  $\sigma$  u dat s artefakty

	$\sigma = 0.1$	$\sigma = 0.2$	$\sigma = 0.5$	$\sigma = 1$
$C = 10$	0.4698	0.4698	0.4765	0.5839
$C = 100$	0.4698	0.4698	0.4765	0.5772
$C = 1000$	0.4698	0.4698	0.4765	0.5772



**Obrázek 7.** Výsledná přesnost  $k$ -NN pro  $k$  od 1 do 20 u dat s artefakty

Vzhledem k důvodům popsaným dále nebyl pro klasifikaci komatózních dat použit klasifikátor SVM, tudíž byl pro tato data optimalizován pouze parametr  $k$ . Jeho optimální hodnota byla určena jako  $k = 2$ . Výsledná přesnost pro testované hodnoty  $k$  je zobrazena na Obr. 8.



**Obrázek 8.** Výsledná přesnost  $k$ -NN pro  $k$  od 1 do 20 u komatózních dat

### 5.3. Výsledky klasifikace

Testování klasifikátorů bylo provedeno dvěma způsoby: křížovou validací na úrovni jednotlivých záznamů a křížovou validací na úrovni jednotlivých segmentů záznamů.

Při křížové validaci na úrovni záznamů byl vždy jeden záznam použit jako testovací množina a zbylé tři záznamy byly použity jako trénovací množina. Toto bylo opakováno čtyřikrát tak, aby každý záznam byl jako testovací množina použit právě jednou. Při křížové validaci na úrovni jednotlivých segmentů byl z každé skupiny záznamů vybrán jeden nebo více záznamů, na kterých byla provedena 10-násobná křížová validace.

Pro všechny skupiny záznamů byly navrženy tři typy experimentů: křížová validace na úrovni záznamů, křížová validace na úrovni segmentů pro všechny záznamy a křížová validace na úrovni segmentů pro jeden ze záznamů. Z důvodu nízké délky artefaktových záznamů (viz. Tab. 6) nebyla pro tyto záznamy provedena křížová validace na úrovni segmentů pro pouze jeden záznam. Záznamy komatózních dat obsahují různé počty tříd (viz. Tab. 9) a při křížové validaci na úrovni záznamů by nastávala situace, kdy testovací množina obsahuje třídy, které neobsahovala trénovací množina. Křížová validace na úrovni záznamů pro komatózní data proto nebyla použita.

Celkem bylo tedy provedeno 7 experimentů a jejich seznam je uveden v Tab. 12.

**Tabulka 12.** Seznam provedených experimentů

Experiment č.	Použitá data	Použité záznamy	Úroveň KV	Výsledky
1	spánková	1-4	záznamy	5.3.1
2	spánková	1	segmenty	5.3.2
3	spánková	1-4	segmenty	5.3.3
4	artefaktová	1-4	záznamy	5.3.4
5	artefaktová	1-4	segmenty	5.3.5
6	komatózní	2-5	segmenty	5.3.6
7	komatózní	2	segmenty	5.3.7

Zde je vhodné poznamenat, že klasifikátory HMM a SVM nebyly použity pro všechny pokusy, jelikož je jejich použití omezeno různými podmínkami na podobu trénovací množiny.

Trénovací množina HMM se musí skládat z celých záznamů, tudíž je použití tohoto klasifikátoru omezeno na experimenty s křížovou validací na úrovni záznamů. Dále



může být HMM použit pouze na záznamy, které mají závislé třídy, tedy na záznamy spánkových a komatózních dat. Jediný experiment, který splňuje tyto podmínky a pro který byl tudíž použit klasifikátor HMM, je experiment 1.

Klasifikátor SVM nebyl použit pro experimenty s komatózními záznamy kvůli jejich vysoké délce. Předběžné testování ukázalo, že časová náročnost SVM pro komatózní záznamy je v řádu hodin. Tento klasifikátor byl proto pro komatózní záznamy posouzen jako nevhodný.

### 5.3.1. Křížová validace na úrovni záznamů pro spánková data

Výsledná přesnost, průměrná doba výpočtu a průměrná specifická a senzitivita všech klasifikátorů jsou uvedeny v Tab. 13. Hodnoty specifické a senzitivity pro jednotlivé třídy a klasifikátory jsou uvedeny v Tab. 14, Tab. 15, Tab. 16 a Tab. 17. Obr. 9 zobrazuje průběhy tříd odhadnuté jednotlivými klasifikátory v porovnání s průběhem určeným lékařem. Konkrétně jsou to třídy odhadnuté klasifikátory trénovanými na 1. 2. a 4. záznamu a testované na 3. záznamu spánkových dat.

**Tabulka 13.** Přesnost, průměrná senzitivita a specifická a průměrná doba výpočtu všech klasifikátorů pro 1. experiment

	SVM	k-NN	NB	HMM
přesnost	0.4002	0.3948	0.4206	0.4082
senzitivita	0.4248	0.4039	0.4418	0.4360
specifická	0.8086	0.8068	0.8121	0.8109
čas [s]	113.35	0.7495	21.02	0.1128

**Tabulka 14.** Specifická a senzitivita klasifikátoru SVM pro jednotlivé třídy pro 1. experiment

třída	1	2	3	4
senzitivita	0.1346	0.6451	0.3623	0.5572
specifická	0.8996	0.7765	0.7064	0.8610

Přesnost všech klasifikátorů se liší pouze v řádu několika procent a žádný klasifikátor nedosáhl uspokojivé přesnosti. Nejvyšší přesnosti dosáhl naivní bayesovský klasifikátor s hodnotou 42%, nejnižší přesnosti dosáhl klasifikátor k-nejbližších sousedů s hodnotou 39.5%. Skryté markovské modely a support vector machine dosáhly přesnosti 40.8%,

**Tabulka 15.** Specifická a senzitivita klasifikátoru k-NN pro jednotlivé třídy pro 1. experiment

třída	1	2	3	4
senzitivita	0.1527	0.6569	0.3290	0.4769
specifická	0.8588	0.7967	0.7195	0.8524

**Tabulka 16.** Specifická a senzitivita klasifikátoru NB pro jednotlivé třídy pro 1. experiment

třída	1	2	3	4
senzitivita	0.2802	0.7232	0.2143	0.5497
specifická	0.8191	0.8317	0.8012	0.7965

**Tabulka 17.** Specifická a senzitivita klasifikátoru HMM pro jednotlivé třídy pro 1. experiment

třída	1	2	3	4
senzitivita	0.4728	0.7619	0.1940	0.3153
specifická	0.7179	0.7754	0.8007	0.9497

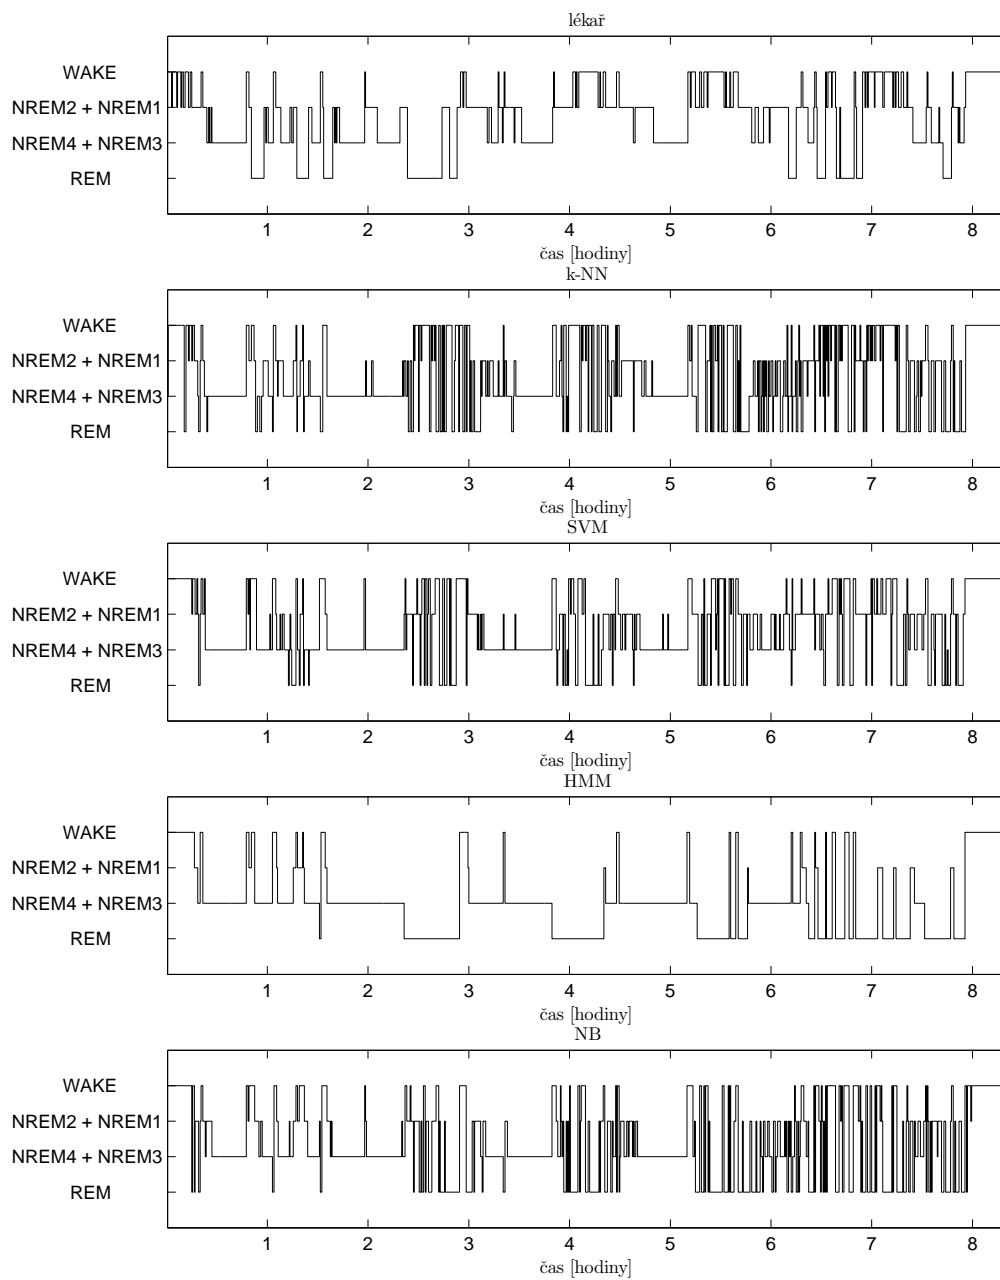
respektive 40%.

Klasifikátor SVM potřeboval nejdelší čas pro učení a klasifikaci, naivní bayesovský klasifikátor byl druhý nejpomalejší. K-nejbližších sousedů a skryté markovské modely byly nejrychlejší s časy výrazně rychlejšími než SVM a NB.

Z pohledu přesnosti klasifikace jednotlivých tříd lze podotknout, že HMM má výrazně lepší podíl správně identifikovaných segmentů patřící do první třídy, tedy REM. Toto lze pravděpodobně vysvětlit tím, že REM fáze je velmi podobná bdělosti, ale tyto dvě fáze málokdy přicházejí po sobě, což je kontextová informace, kterou HMM s výhodou využívá.

### 5.3.2. Křížová validace na úrovni segmentů pro první záznam spánkových dat

Výsledná přesnost, průměrný čas výpočtu a specifická a senzitivita všech klasifikátorů jsou uvedeny v Tab. 18. Hodnoty specifické a senzitivity pro jednotlivé třídy a klasifikátory jsou uvedeny v Tab. 19, Tab. 20 a Tab. 21. Na Obr. 10 je vyobrazen průběh jednotlivých tříd odhadnutých klasifikátory v porovnání s lékařským ohodnocením záznamu.



**Obrázek 9.** Porovnání průběhu výsledků jednotlivých klasifikátorů s lékařským ohodnocením záznamu pro 1. experiment

Nejvyšší přesnosti dosáhl klasifikátor SVM s 82% správně oklasifikovanými segmenty, nejhorší přesnosti dosáhl naivní bayesovský klasifikátor se 69%, k-nejbližších sousedů správně oklasifikoval 76% segmentů. SVM byl výrazně nejpomalejší, zatímco k-NN nej-

**Tabulka 18.** Přesnost, průměrná senzitivita a specifická a průměrná doba výpočtu všech klasifikátorů pro 2. experiment

	SVM	k-NN	NB
přesnost	0.8203	0.7695	0.6904
senzitivita	0.8246	0.7757	0.7019
specifická	0.9389	0.9224	0.8961
čas [s]	19.07	0.03	2.92

**Tabulka 19.** Specifická a senzitivita klasifikátoru SVM pro jednotlivé třídy pro 2. experiment

třída	1	2	3	4
senzitivita	0.8170	0.8792	0.7869	0.8153
specifická	0.9461	0.9717	0.9059	0.9321

**Tabulka 20.** Specifická a senzitivita klasifikátoru k-NN pro jednotlivé třídy pro 2. experiment

třída	1	2	3	4
senzitivita	0.7679	0.8357	0.7082	0.7912
specifická	0.9106	0.9614	0.9044	0.9130

**Tabulka 21.** Specifická a senzitivita klasifikátoru NB pro jednotlivé třídy pro 2. experiment

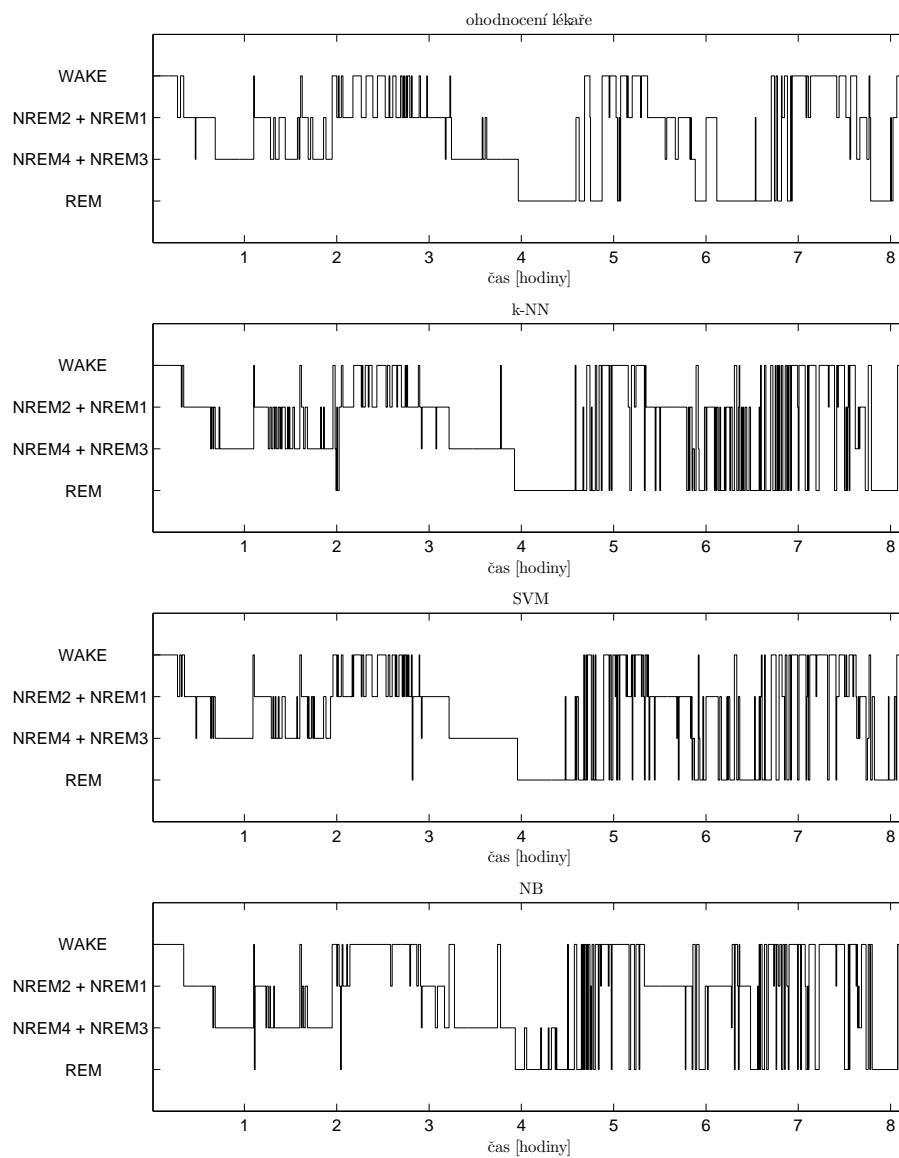
třída	1	2	3	4
senzitivita	0.5536	0.8502	0.5443	0.8594
specifická	0.9290	0.9344	0.9059	0.8152

rychlejší.

Hodnoty specifickosti jsou pro všechny klasifikátory velmi podobné, ale naivní bayesovský klasifikátor za k-NN a SVM výrazně zaostává v senzitivě pro první a třetí třídu, tedy fáze REM a NREM1+NREM2.

### 5.3.3. Křížová validace na úrovni segmentů pro všechny čtyři záznamy spánkových dat

Přesnost, průměrné hodnoty specifickosti a senzitivity a průměrná doba výpočtu všech klasifikátorů jsou uvedeny v Tab. 22. Hodnoty specifickosti a senzitivity jednotlivých tříd



**Obrázek 10.** Porovnání průběhu výsledků jednotlivých klasifikátorů s lékařským ohodnocením záznamu pro 2. experiment

a klasifikátorů jsou uvedeny v Tab. 23, Tab. 24 a Tab. 25.

Přesnosti klasifikátorů SVM a k-NN se v porovnání s experimentem 5.3.2 zvýšily na 85,8%, respektive 79,8%, zatímco přesnost naivního bayesovského klasifikátoru se snížila na 58,2%.

SVM je opět nejpomalejší klasifikátor a oproti experimentu 5.3.2 průměrný čas po-

**Tabulka 22.** Přesnost, průměrná senzitivita a specifická a průměrná doba výpočtu všech klasifikátorů pro 3. experiment

	SVM	k-NN	NB
přesnost	0.8583	0.7978	0.5822
senzitivita	0.8600	0.7933	0.5813
specifická	0.9513	0.9312	0.8609
čas [s]	544.31	0.37	10.94

**Tabulka 23.** Specifická a senzitivita klasifikátoru SVM pro jednotlivé třídy pro 3. experiment

třída	1	2	3	4
senzitivita	0.8605	0.9082	0.8079	0.8633
specifická	0.9739	0.9655	0.9157	0.9504

**Tabulka 24.** Specifická a senzitivita klasifikátoru k-NN pro jednotlivé třídy pro 3. experiment

třída	1	2	3	4
senzitivita	0.7536	0.8758	0.7488	0.7950
specifická	0.9502	0.9562	0.8867	0.9320

**Tabulka 25.** Specifická a senzitivita klasifikátoru NB pro jednotlivé třídy pro 3. experiment

třída	1	2	3	4
senzitivita	0.5308	0.7408	0.4269	0.6269
specifická	0.8570	0.8726	0.8557	0.8584

třebný k jeho trénování a klasifikaci narostl více než 25-krát. Druhým nejpomalejším klasifikátorem byl naivní bayesovský klasifikátor a nejrychlejší byl k-nejbližších sousedů.

Naivní bayesovský klasifikátor zaostává za SVM a k-NN v hodnotách specifické pro třídy 1 a 3.

### 5.3.4. Křížová validace na úrovni záznamů pro EEG data s artefakty

Přesnost, průměrný čas výpočtu a průměrné hodnoty specifické a senzitivity všech klasifikátorů jsou uvedeny v Tab. 26. Hodnoty specifické a senzitivity jednotlivých tříd a klasifikátorů jsou uvedeny v Tab. 27, Tab. 28 a Tab. 29.

Na Obr. 11 jsou vyobrazeny výstupy jednotlivých klasifikátorů v porovnání s průběhem lékařského ohodnocení záznamu. Konkrétně se jedná o výsledky pro 4. záznam dat s artefakty a pro klasifikátory naučené na 1.-3. záznamu.

**Tabulka 26.** Přesnost, průměrná senzitivita a specifická a čas výpočtu všech klasifikátorů pro 4. experiment

	SVM	k-NN	NB
přesnost	0.8649	0.8240	0.7505
senzitivita	0.7746	0.7205	0.7263
specifická	0.8942	0.8689	0.8561
čas [s]	3.87	0.01	0.79

**Tabulka 27.** Specifická a senzitivita klasifikátoru SVM pro jednotlivé třídy pro 4. experiment

třída	1	2	3
senzitivita	0.9454	0.7028	0.6756
specifická	0.7405	0.9484	0.9937

**Tabulka 28.** Specifická a senzitivita klasifikátoru k-NN pro jednotlivé třídy pro 4. experiment


třída	1	2	3
senzitivita	0.8979	0.6846	0.5789
specifická	0.7117	0.9047	0.9903

**Tabulka 29.** Specifická a senzitivita klasifikátoru NB pro jednotlivé třídy pro 4. experiment

třída	1	2	3
senzitivita	0.7344	0.6289	0.8155
specifická	0.8082	0.8696	0.8905

Zde z pohledu přesnosti nejlépe klasifikoval SVM s 86.5%, následovaný k-NN s 82.4% a naivní bayesovský klasifikátor byl nejméně přesný se 75%. Je ovšem nutné podotknout, že vzhledem k nerovnoměrnému rozdělení jednotlivých tříd u artefaktových dat (viz Tab. 5) je toto měřítko značně vychýlené. Senzitivita jednotlivých tříd ukazuje, že naivní bayesovský klasifikátor častěji než k-NN a SVM správně zařadil segmenty z

## 5. Praktická část



**Obrázek 11.** Průběh odhadnutých tříd pro klasifikátory naučené na 1.-3. záznamu artefaktových dat a otestované a 4. záznamu artefaktových dat. V tomto případě SVM klasifikoval bezchybně

3. třídy (pohyb očí), ale méně často správně zařadil segmenty z 1. třídy (normální aktivitu).

Nejvyšší čas výpočtu má SVM s více než 3 sekundami, nejkratší k-NN s 0.01 sekundy. Naivní bayesovský klasifikátor trénování a klasifikaci provedl za 0.79 sekundy.

### 5.3.5. Křížová validace na úrovni segmentů pro všechny čtyři záznamy EEG dat s artefakty

Přesnost a průměrné hodnoty specifity, senzitivity a průměrný čas výpočtu všech klasifikátorů jsou uvedeny v Tab. 30. Hodnoty specifity a senzitivity jednotlivých tříd a klasifikátorů jsou uvedeny v Tab. 31, Tab. 32 a Tab. 33.

Nejvyšší přesnosti dosáhl SVM s 92.6%, který zároveň dosáhl nejlepší senzitivity pro všechny třídy. Klasifikátory k-NN a naivní bayesovský klasifikátor dosáhly přesnosti



**Tabulka 30.** Přesnost, průměrná senzitivita a specifická a čas výpočtu všech klasifikátorů pro 5. experiment

	SVM	k-NN	NB
přesnost	0.9258	0.8640	0.7512
senzitivita	0.8611	0.7694	0.7309
specifická	0.9391	0.8917	0.8738
čas [s]	10.69	0.004	0.70

**Tabulka 31.** Specifická a senzitivita pro jednotlivé třídy SVM pro 5. experiment

třída	1	2	3
senzitivita	0.9720	0.8438	0.7674
specifická	0.8571	0.9710	0.9893

**Tabulka 32.** Specifická a senzitivita pro jednotlivé třídy k-NN pro 5. experiment

třída	1	2	3
senzitivita	0.9333	0.6771	0.6977
specifická	0.7527	0.9383	0.9840

**Tabulka 33.** Specifická a senzitivita pro jednotlivé třídy NB pro 5. experiment

třída	1	2	3
senzitivita	0.7677	0.6458	0.7791
specifická	0.8681	0.8621	0.8913

86.4% a 75.1%. Nejvyšší průměrnou dobu výpočtu měl SVM s 10.69 sekundami, klasifikátory k-NN a NB měly průměrné doby výpočtu 0.004 sekund a 0.7 sekund.

Z porovnání senzitivit klasifikátorů pro všechny třídy je vidět, že nižší přesnost naivního bayesovského klasifikátoru byla mimo jiné opět způsobena nízkou senzitivitou pro třídu 1, která má v artefaktových záznamech dominantní zastoupení.

### 5.3.6. Křížová validace na úrovni segmentů pro všechny čtyři záznamy komatózních dat

Přesnost a průměrné hodnoty specifity, senzitivity a času výpočtu obou klasifikátorů jsou uvedeny v Tab. 34. Hodnoty specifity a senzitivity jednotlivých tříd a klasifikátorů jsou uvedeny v Tab. 35 a Tab. 36.

**Tabulka 34.** Přesnost, průměrná senzitivita a specifita a čas výpočtu obou klasifikátorů pro 6. experiment

	k-NN	NB
přesnost	0.8000	0.5834
senzitivita	0.6683	0.6453
specifita	0.9640	0.9324
čas [s]	13.24	159.96

**Tabulka 35.** Specifita a senzitivita klasifikátoru k-NN pro jednotlivé třídy pro 6. experiment

třída	1	2	3	4	5	6	7
senzitivita	0.7248	0.9081	0.6698	0.7574	0.3029	0.8140	0.5012
specifita	0.9737	0.9301	0.9641	0.9494	0.9831	0.9575	0.8800

**Tabulka 36.** Specifita a senzitivita klasifikátoru NB pro jednotlivé třídy pro 6. experiment

třída	1	2	3	4	5	6	7
senzitivita	0.6477	0.4779	0.5624	0.6420	0.4726	0.7286	0.9861
specifita	0.8708	0.9991	0.9556	0.8947	0.9665	0.8952	0.9448

Klasifikátor k-NN dosáhl lepší přesnosti 80% a pro výpočet potřeboval nižší čas 13.24 sekund. Naivní bayesovský klasifikátor dosáhl přesnosti 58.3% a jeho průměrný čas výpočtu byl 159.96 sekund.

Naivní bayesovský klasifikátor dále dosáhl nižších hodnot senzitivity pro všechny třídy s výjimkou tříd 5 a 7, přičemž jeho senzitivita pro třídu 7 byla výrazně vyšší než u k-NN a blížila se hodnotě přesné klasifikace této třídy.

### 5.3.7. Křížová validace na úrovni segmentů pro první záznam komatózních dat

Přesnost a průměrné hodnoty specifity, senzitivity a času výpočtu obou klasifikátorů jsou uvedeny v Tab. 37. Hodnoty specifity a senzitivity jednotlivých tříd a klasifikátorů jsou uvedeny v Tab. 38 a Tab. 39.

**Tabulka 37.** Přesnost, průměrná senzitivita a specifita a čas výpočtu obou klasifikátorů pro 7. experiment

	k-NN	NB
přesnost	0.6902	0.3905
senzitivita	0.3615	0.5362
specifita	0.9237	0.9010
čas [s]	0.86	22.68

**Tabulka 38.** Specifita a senzitivita klasifikátoru k-NN pro jednotlivé třídy pro 7. experiment

třída	1	2	3	4	5	6	7
senzitivita	0.7211	0.7908	0.1061	0.0926	0.1711	0.1477	0.5012
specifita	0.9126	0.6637	0.9664	0.9953	0.9816	0.9875	0.9587

**Tabulka 39.** Specifita a senzitivita klasifikátoru NB pro jednotlivé třídy pro 7. experiment

třída	1	2	3	4	5	6	7
senzitivita	0.8072	0.1753	0.7647	0.7407	0.2303	0.5455	0.5196
specifita	0.8998	0.9337	0.7044	0.9107	0.9770	0.9541	0.9273

Zde z pohledu přesnosti dosáhl lepších výsledků klasifikátor k-NN se 69%, naivní bayesovský klasifikátor dosáhl přesnosti 39.1%. Klasifikátor k-NN dále potřeboval k výpočtu nižší čas než naivní bayesovský klasifikátor.

Naivní bayesovský klasifikátor nicméně dosáhl vyšší průměrné senzitivity než k-NN a měl vyšší hodnoty senzitivity pro třídy 1,3,4,5 a 6. Jeho přesnost byla tedy ovlivněna nerovnoměrným rozložením tříd v prvním záznamu komatózních dat.

## 5.4. Porovnání klasifikátorů

Klasifikátory byly porovnány podle jejich celkových výsledků a podle jejich výsledků na jednotlivých typech záznamů.

### 5.4.1. Porovnání klasifikátorů podle výsledků ve všech experimentech

Support vector machine dosáhl nejvyšších hodnot přesnosti, průměrné senzitivity a průměrné specificity ve čtyřech z pěti experimentů, ve kterých byl testován. Výraznou nevýhodou tohoto klasifikátoru byla jeho časová náročnost, která byla ve všech experimentech nejvyšší ze všech klasifikátorů. Pro spánková data a data s artefakty se nicméně čas výpočtu pohyboval v řádu jednotek až desítek minut, takže pokud není velmi rychlá klasifikace prioritou, lze tento klasifikátor pro takto rozsáhlé záznamy použít. Pro záznamy s délkami podobnými jako délky komatózních záznamů použitých v této práci se časy výpočtu pro SVM pohybují v řádech hodin, tudíž je tento klasifikátor pro takové záznamy nevhodný.

K-nejbližších sousedů měl nejrychlejší čas výpočtu v šesti ze sedmi experimentů a jeho hodnoty přesnosti, specificity a senzitivity byly obvykle buď velmi blízké hodnotám klasifikátoru, který v daném experimentu dosáhl nejlepších hodnot, nebo byly v daném experimentu nejlepší. Tento klasifikátor lze vzhledem k jeho relativní jednoduchosti, rychlosti a přesnosti doporučit jako vhodný pro klasifikaci EEG záznamů.

Naivní bayesovský klasifikátor dosahoval poměrně nekonzistentních výsledků. Tento klasifikátor měl nejvyšší přesnost, průměrnou specificitu a senzitivitu v prvním experimentu, ale v ostatních experimentech již byl obvykle klasifikátorem nejméně úspěšným. Naivní bayesovský klasifikátor měl dále výrazně odlišné hodnoty specificity a senzitivity některých tříd od ostatních klasifikátorů. Použití tohoto klasifikátoru v experimentech specializovanějších na určité třídy by mohlo přinést dobré výsledky, v ostatních případech jsou klasifikátory k-NN a SVM spolehlivější a lepší volby.

Skryté markovské modely byly otestovány pouze v jediném experimentu a není tak dostatek dat pro hlubší porovnávání s ostatními klasifikátory. Výsledky tohoto klasifikátoru v experimentu 1 nicméně ukazují, že kontextová klasifikace může být pro některé typy záznamů EEG zajímavou alternativou, která si zaslouží hlubší výzkum.

### 5.4.2. Porovnání klasifikátorů podle výsledků na jednotlivých typech dat

Spánková data byla použita v experimentech 5.3.1, 5.3.2 a 5.3.3. V prvním experimentu dosáhl nejlepších výsledků naivní bayesovský klasifikátor, ale výsledky všech klasifikátorů byly poměrně vyrovnané. V experimentech 2 a 3 dosáhl nejlepších výsledků SVM následovaný k-NN a naivní bayesovský klasifikátor naopak měl výsledky nejhorší. Celkově byly jako nejvhodnější klasifikátory pro klasifikaci spánkových dat vyhodnoceny rychlý k-NN a pomalejší SVM.

EEG data s artefakty byla použita v experimentech 5.3.4 a 5.3.5. V obou těchto experimentech nejlepších výsledků dosáhl klasifikátor SVM, který vzhledem k nízké délce těchto záznamů nebyl výrazně pomalejší než ostatní klasifikátory a byl tak vyhodnocen jako nejvhodnější klasifikátor pro záznamy EEG s artefakty.

Komatózní data byla použita v experimentech 5.3.6 a 5.3.7. V těchto experimentech se jako nejvhodnější klasifikátor ukázal k-NN, který byl v obou případech úspěšnější a rychlejší než naivní bayesovský klasifikátor.

## 6. Závěr

Cílem této práce byla implementace několika klasifikačních metod v prostředí programu MATLAB a porovnání jejich výsledků nad reálnými EEG záznamy. Testované klasifikační metody byly k-nejbližších sousedů, support vector machine, naivní bayesovský klasifikátor a skryté markovské modely. Tyto metody byly porovnávány na základě jejich přesnosti, specifity, senzitivity a časové náročnosti. Pro ověření byly použity spánkové záznamy, dále pak záznamy s artefakty a komatózní EEG signály.

Vypočtené příznaky byly normalizovány a byla nad nimi provedena selekce příznaků. Dále byla provedena optimalizace parametrů k-nejbližších sousedů a support vector machine. Vlastní klasifikace byla provedena v sedmi experimentech, jejichž výsledky byly použity pro porovnávání jednotlivých klasifikátorů.

Žádný z testovaných klasifikátorů nedosáhl jednoznačně nejlepších výsledků, ale klasifikátory k-nejbližších sousedů a support vector machine byly posouzeny jako nejvhodnější metody klasifikace spánkových EEG záznamů. Pro klasifikaci záznamů s artefakty byl jako nejvhodnější klasifikátor vyhodnocen support vector machine a pro klasifikaci komatózních záznamů byl jako nejvhodnější vyhodnocen klasifikátor k-nejbližších sousedů. Naivní bayesovský klasifikátor dosáhl dobrých výsledků v některých provedených experimentech, nicméně jeho výsledky byly dále značně nekonzistentní. Skryté markovské modely nebyly v této práci dostatečně otestovány pro přímé porovnání s ostatními klasifikátory.

Pro hlubší zpracování tohoto tématu by bylo vhodné optimalizovat počet vybraných příznaků a porovnat více metod selekce příznaků. Dále by bylo možné použít další metody normalizace příznaků a sofistikovanější metody výběru optimálních parametrů k-nejbližších sousedů a support vector machine. Konečně, bylo by vhodné dále prozkoumat vhodnost skrytých markovských modelů pro záznamy EEG.

# Příloha A.

## Extrahované příznaky

V tabulkách Tab. 40, Tab. 41, Tab. 42, Tab. 43, Tab. 44, Tab. 45, Tab. 46, Tab. 47, Tab. 48 a Tab. 49 jsou uvedeny příznaky společné pro všechny typy dat a jejich stručný popis. V Tab. 50 jsou uvedeny příznaky vyskytující se pouze u artefaktových dat. Podrobnější popis příznaků lze najít v [5].

**Tabulka 40.** Statistické příznaky

Příznak	Popis
MEAN	střední hodnota
STD	Směrodatná odchylka
MEDIAN	Medián
MIN VALUE	Maximální negativní amplituda
MAX VALUE	Maximální pozitivní amplituda
SKEWNESS	Koeficient šikmosti
KURTOSIS	Koeficient spířastosti
RMS	Kvadratický průměr

**Tabulka 41.** Příznaky založené na derivacích

Příznak	Popis
1st DIFF MEAN	Střední hodnota první derivace
1st DIFF MAX	Maximální hodnota první derivace
2nd DIFF MEAN	Střední hodnota druhé derivace
2nd DIFF MAX	Maximální hodnota druhé derivace

**Tabulka 42.** Příznaky založené na anlyze intervalu

Příznak	Popis
LINE LENGTH	Délka trajektorie signálu
MEAN VV AMPL	Průměrná amplituda špička-špička
VAR VV AMPL	Rozptyl amplitud špička-špička
MEAN VV TIME	Průměrný čas mezi špičkami
VAR VV TIME	Rozptyl časů mezi špičkami
MEAN VV SLOPE	Průměrná směrnice
VAR VV SLOPE	Rozptyl směrníc
ZERO CROSSING	Počet průchodů nulou
MIN MAX NUMBER	Počet lokálních extrémů
COEFF OF VARIATION	Variační koeficient
AMPL RANGE	Rozsah amplitud

**Tabulka 43.** Hjorthovy parametry

Příznak	Popis
HJORTH 2	Druhý Hjorthův parametr
HJORTH 3	Třetí Hjorthův parametr

**Tabulka 44.** Příznaky založené na entropii a nelineární energii

Příznak	Popis
ENTROPY SHANNON	Shannonova entropie
ENTROPY LOG	Spektrální entropie
NONLIN ENERGY	Průměrná nelineární energie



**Tabulka 45.** Frekvenční příznaky vypočítané z absolutního spektra EEG

Příznak	Průměrné hodnoty z frekvenčního pásma:
FFT ABS DELTA	0.1 - 3 Hz
FFT ABS DELTA1	0.1 - 1.5 Hz
FFT ABS DELTA2	1.5 - 3 Hz
FFT ABS THETA	3 - 7 Hz
FFT ABS THETA1	3 - 5 Hz
FFT ABS THETA2	5 - 7 Hz
FFT ABS ALPHA	7 - 12 Hz
FFT ABS ALPHA1	7 - 9.5 Hz
FFT ABS ALPHA2	9.5 - 12 Hz
FFT ABS BETA	12 - 30 Hz
FFT ABS BETA1	12 - 21 Hz
FFT ABS BETA2	30 - 40 Hz
FFT ABS GAMMA	30 - 40 Hz
FFT ABS GAMMA1	30 - 35 Hz
FFT ABS GAMMA2	35 - 40 Hz
FFT ABS WHOLE	0.1 - 40 Hz

**Tabulka 46.** Frekvenční příznaky vypočítané z relativního spektra EEG

Příznak	Průměrné hodnoty z frekvenčního pásma:
FFT REL DELTA	0.1 - 3 Hz
FFT REL DELTA1	0.1 - 1.5 Hz
FFT REL DELTA2	1.5 - 3 Hz
FFT REL THETA	3 - 7 Hz
FFT REL THETA1	3 - 5 Hz
FFT REL THETA2	5 - 7 Hz
FFT REL ALPHA	7 - 12 Hz
FFT REL ALPHA1	7 - 9.5 Hz
FFT REL ALPHA2	9.5 - 12 Hz
FFT REL BETA	12 - 30 Hz
FFT REL BETA1	12 - 21 Hz
FFT REL BETA2	30 - 40 Hz
FFT REL GAMMA	30 - 40 Hz
FFT REL GAMMA1	30 - 35 Hz
FFT REL GAMMA2	35 - 40 Hz
FFT REL WHOLE	0.1 - 40 Hz

**Tabulka 47.** Poměry frekvenčních příznaků vypočítané ze spektra EEG

Příznak	Popis
FFT DELTA THETA RATIO	ABS DELTA / ABS THETA
FFT DELTA1 ALPHA RATIO	ABS DELTA / ABS ALPHA
FFT THETA ALPHA RATIO	ABS THETA / ABS ALPHA
FFT DT ALPHA RATIO	(ABS DELTA + ABS THETA) / ABS ALPHA

**Tabulka 48.** Další příznaky vypočítané ze spektra EEG

Příznak	Popis
FFT SEF95	Spectral edge frequency 95%
FFT SP-ROLL OFF	Spectral edge frequency 85%

**Tabulka 49.** Příznaky založené na vlnkové transformaci (Wavelet transform)

Příznak	Popis
MIN WAV VALUE	Maximální negativní amplituda
MAX WAV VALUE	Maximální pozitivní amplituda
MEAN WAV VALUE	Střední hodnota
MEDIAN WAV VALUE	Medián
STD WAV VALUE	Směrodatná odchylka
SKEWNESS WAV VALUE	Koeficient šikmosti
KURTOSIS WAV VALUE	Koeficient špičatosti
WAV BAND	Energie pásma
WAV BAND REL	Relativní energie pásma
WAV BAND RATIO	Poměr energií pásem
WAV TOTAL ENERGY	Celková energie
ENTROPY LOG WAV	Spektrální entropie
ENTROPY WAV	Shannonova entropie
1st DIFF WAV MEAN	Střední hodnota první derivace
1st DIFF WAV MAX	Maximum první derivace
2nd DIFF WAV MEAN	Střední hodnota druhé derivace
2nd DIFF WAV MAX	Maximum druhé derivace
ENERGY PERCENT WAV	Podíl celkové energie
WAV ZERO CROSSING	Počet průchodů nulou
WAV COEFF OF VARIATION	Koeficient variace

**Tabulka 50.** Příznaky vyskytující se pouze u artefaktových dat


Příznak	Popis
AUTOCORR 2nd	Autokorelace 2. řádu
AUTOCORR 3rd	Autokorelace 3. řádu
BEATS	

## Příloha B.


### Vizualizace selektovaných příznaků

Porovnání průběhu čtyř z vybraných příznaků pro spánková data s prvními pěti hodinami spánkových záznamů jsou zobrazeny na Obr. 12, Obr. 13, Obr. 14 a Obr. 15.


Porovnání průběhu čtyř z vybraných příznaků pro data s artefakty s průběhy tříd jsou zobrazeny na Obr. 16, Obr. 17, Obr. 18 a Obr. 19.




**Obrázek 12.** Porovnání průběhu čtyř vybraných příznaků ze spánkových dat a ohodnocení od lékaře pro záznam 2




**Obrázek 13.** Porovnání průběhu čtyř vybraných příznaků ze spánkových dat a ohodnocení od lékaře pro záznam 3




**Obrázek 14.** Porovnání průběhu čtyř vybraných příznaků ze spánkových dat a ohodnocení od lékaře pro záznam 4




**Obrázek 15.** Porovnání průběhu čtyř vybraných příznaků ze spánkových dat a ohodnocení od lékaře pro záznam 5



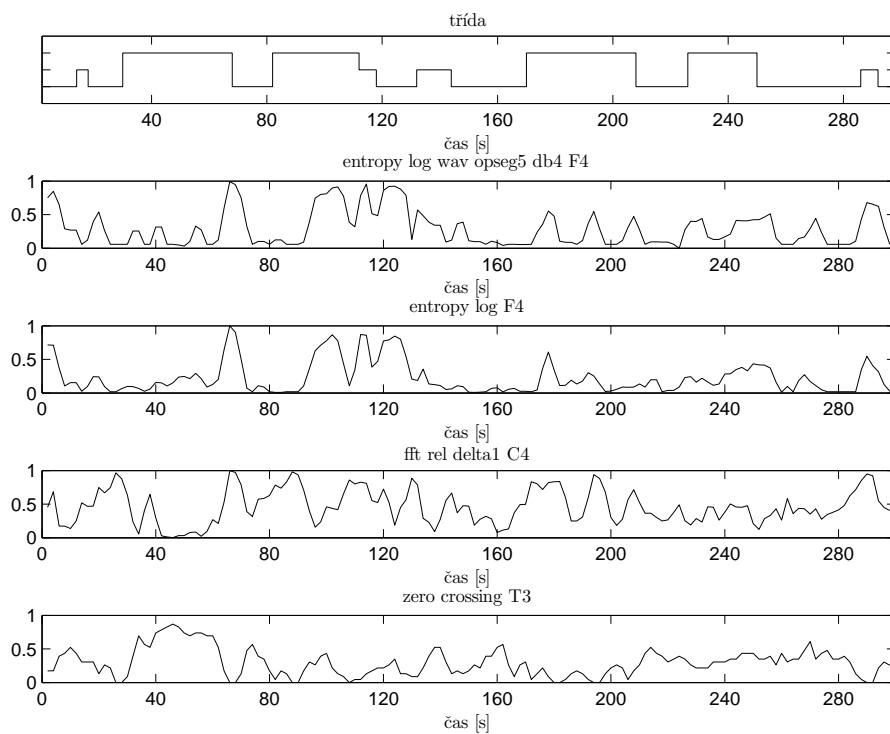
**Obrázek 16.** Porovnání průběhu čtyř vybraných příznaků z dat s artefakty a ohodnocení od lékaře pro záznam 2



**Obrázek 17.** Porovnání průběhu čtyř vybraných příznaků z dat s artefakty a ohodnocení od lékaře pro záznam 3



**Obrázek 18.** Porovnání průběhu čtyř vybraných příznaků z dat s artefakty a ohodnocení od lékaře pro záznam 4



**Obrázek 19.** Porovnání průběhu čtyř vybraných příznaků z dat s artefakty a ohodnocení od lékaře pro záznam 5



## Literatura

- [1] M. Teplan. *Fundamentals of EEG Measurment*. 2002. URL: <http://www.measurement.sk/2002/S2/Teplan.pdf>.
- [2] S. Sanei a J.A. Chambers. *EEG Signal Processing*. Wiley-Interscience, 2007. ISBN: 978-0-470-02581-9.
- [3] NERVOVÉ BUŇKY. 2012. URL: [http://cs.wikibooks.org/wiki/Nervov%C3%A9\\_bu%C5%88ky](http://cs.wikibooks.org/wiki/Nervov%C3%A9_bu%C5%88ky).
- [4] W. Mansor aj. *Integrating Neural Signal and Embedded System for Controlling Small Motor*. 2011. URL: <http://www.intechopen.com/books/advances-in-mechatronics/integrating-neural-signal-and-embedded-system-for-controlling-small-motor>.
- [5] V. Gerla. “Automated Analysis of Long-Term EEG Signals”. Doctoral Thesis. The Czech Technical University in Prague, Faculty of Electrical Engineering, Department of Cybernetics, 2012.
- [6] G. Dougherty. *Pattern Recognition and Classification*. New York: Springer, 2013. ISBN: 978-1-4614-5322-9.
- [7] S. Theodoridis a K. Koutroumbas. *Pattern Recognition*. 2nd Ed. Elsevier, 2009. ISBN: 978-1-59749-292-0.
- [8] M. A. Hall a G. Holmes. *Benchmarking Attribute Selection Techniques for Discrete Class Data Mining*. 2003. URL: <http://www.cs.waikato.ac.nz/~mhall/HallHolmesTKDE.pdf>.
- [9] Ch. M. Bishop. *Pattern Recognition and Machine Learning*. Springer, 2006. ISBN: 978-0387-31073-2.
- [10] L. R. Rabiner. “A tutorial on hidden Markov models and selected applications in speech recognition”. In: *PROCEEDINGS OF THE IEEE*. 1989.

- [11] V. Labatut a H. Cherifi. “Accuracy Measures for the Comparison of Classifiers”. In: *CoRR* abs/1207.3790 (2012). URL: <http://dblp.uni-trier.de/db/journals/corr/corr1207.html#abs-1207-3790>.
- [12] F. Eibe aj. *WEKA Manual for Version 3-6-0*. 2008. URL: <http://www.cs.waikato.ac.nz/ml/weka/documentation.html>.
- [13] V. Franc a V. Hlaváč. *Statistical Pattern Recognition Toolbox for Matlab User's guide*. 2004. URL: <http://cmp.felk.cvut.cz/cmp/software/stprtool/stprtool.pdf>.
- [14] MathWorks. *Statistics Toolbox User's guide*. 2014. URL: <http://www.mathworks.com/help/stats/index.html;jsessionid=18872340ff6c028b90c692389740>.
- [15] K. Murphy. *Hidden Markov Model (HMM) Toolbox for Matlab*. 1998. URL: <http://www.cs.ubc.ca/~murphyk/Software/HMM/hmm.html>.