



**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

**AUTOMATICKÁ DETEKCE STRESU POMOCÍ  
BIOLOGICKÝCH SIGNÁLŮ**

AUTOMATIC DETECTION OF STRESS USING BIOLOGICAL SIGNALS

**BAKALÁŘSKÁ PRÁCE**

BACHELOR'S THESIS

**AUTOR PRÁCE**

AUTHOR

**Tomáš Votýpka**

**VEDOUCÍ PRÁCE**

SUPERVISOR

**Ing. Radovan Smíšek**

**BRNO 2020**



# Bakalářská práce

bakalářský studijní obor **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

**Student:** Tomáš Votýpka

**ID:** 203691

**Ročník:** 3

**Akademický rok:** 2019/20

**NÁZEV TÉMATU:**

## Automatická detekce stresu pomocí biologických signálů

**POKYNY PRO VYPRACOVÁNÍ:**

1) Seznamte se s problematikou detekce stresu pomocí biologických signálů, proveďte literární rešerši. 2) Proveďte rešerši databází biologických signálů s přítomnou informací o emocích/stresu. 3) V programovém prostředí MATLAB realizujte algoritmus detekující stres. 4) Otestujte algoritmus na veřejné databázi. 5) Dle výsledků algoritmus optimalizujte. 6) Diskutujte dosažené výsledky, porovnejte dosažené výsledky s výsledky dosaženými jinými autory.

**DOPORUČENÁ LITERATURA:**

[1] Marco A. Jiménez-Limas, Carlos A. Ramírez-Fuentes, Blanca Tovar-Corona, and Laura I. Garay-Jiménez, Feature selection for stress level classification into a physiological signals set, Electrical Engineering Computing Science and Automatic Control (CCE) 2018 15th International Conference, pp. 1-5, 2018.

[2] Birjandtalab Javad, Diana Cogan, Maziyar Baran Pouyan, and Mehrdad Nourani, A Non-EEG Biosignals Dataset for Assessment and Visualization of Neurological Status, 2016 IEEE International Workshop on Signal Processing Systems (SiPS), Dallas, pp. 110-114, 2016.

**Termín zadání:** 3.2.2020

**Termín odevzdání:** 5.6.2020

**Vedoucí práce:** Ing. Radovan Smíšek

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

**UPOZORNĚNÍ:**

Autor bakalářské práce nesmí při vytváření bakalářské 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**

Bakalářská práce je zaměřena na detekci stresu. Tato práce definuje pojem stres, analyzuje vhodné biologické signály k detekci stresu, představuje databáze biologických signálů, které byly využity pro detekci stresu a zmiňuje metody automatické detekce stresu. Následně byl v programovém prostředí MATLAB implementovaný program detekující stres. Pro realizaci programu byla využita volně dostupná databáze non-EEG signálů. Modely klasifikující stres, byly vytvořeny pomocí 4 metod strojového učení pro binární klasifikaci a 3 metod strojového učení pro klasifikaci 4 psychických stavů. Úspěšnosti klasifikačních úloh jsou shrnuty v závěru práce.

## **KLÍČOVÁ SLOVA**

Stres, detekce stresu, biologické signály, databáze biologických signálů, extrakce příznaků, strojové učení, klasifikace, MATLAB.

## **ABSTRACT**

Bachelor's thesis is focused on stress detection. This thesis defines the concept of stress, analyzes the appropriate biological signals for stress detection, presents databases of biological signals, that were used for stress detection and mentions methods of automatic stress detection. Then, a stress detection program was implemented in the MATLAB software environment. A freely available database of non-EEG signals was used to implement the program. Models classifying stress were created using 4 machine learning methods for binary classification and 3 machine learning methods for classifying 4 psychical states. Efficiency of the classification was summarized in the conclusion of this thesis.

## **KEYWORDS**

Stress, stress detection, biological signals, biological signal databases, feature extraction, machine learning, classification, MATLAB.

VOTÝPKA, Tomáš. *Automatická detekce stresu pomocí biologických signálů*. Brno, 2020. Bakalářská práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce Radovan Smíšek.

## PROHLÁŠENÍ

Prohlašuji, že svou bakalářskou práci na téma „Automatická detekce stresu pomocí biologických signálů“ jsem vypracoval samostatně pod vedením vedoucího bakalářské 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 bakalářské práce dále prohlašuji, že v souvislosti s vytvořením této práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si 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. 40/2009Sb.

V Brně dne .....

.....

(podpis)

## PODĚKOVÁNÍ

Poděkování patří vedoucímu bakalářské práce panu Ing. Radovanu Smíškovi za odborné vedení, trpělivost, konzultace a cenné rady při vytváření této bakalářské práce.

V Brně dne .....

.....

(podpis)

# OBSAH

Úvod	1
<b>1 Stres</b>	<b>3</b>
1.1 Definování stresu	3
1.1.1 Stresory	4
1.1.2 Teorie životních událostí	5
1.2 Stresová reakce (stresový syndrom)	6
1.2.1 Alostáza	6
1.2.2 Akutní a chronický stresový syndrom	6
1.2.3 1. fáze stresové reakce – poplachová reakce	7
1.2.4 2. fáze stresové reakce – všeobecný adaptační syndrom	8
<b>2 Analýza vhodných biosignálů</b>	<b>10</b>
2.1 Biosignály	10
2.2 Akcelerometr	11
2.3 Teplota pokožky	12
2.4 Elektrodermální aktivita (EDA)	12
2.5 Saturace krve kyslíkem (SpO <sub>2</sub> )	14
2.6 Variabilita tepové frekvence (HRV)	14
<b>3 Přehled databází biologických signálů</b>	<b>16</b>
3.1 A Non-EEG Dataset for Assessment of Neurological Status	16
3.2 Stress Recognition in Automobile Drivers Dataset	19
3.3 Detection of stress patterns from GSR sensor dataset	22
<b>4 Metody automatické detekce stresu</b>	<b>24</b>
4.1 Posouzení a vizualizace neurologického stavu pomocí metody GMM	24
4.1.1 Shlukovací metoda GMM a vizualizace dat	24
4.1.2 Výsledky studie	26
4.2 Zhodnocení úspěšnosti klasifikace stresu pomocí klasifikátorů využívající strojového učení	26
4.2.1 Použitá sada dat	26
4.2.2 Předzpracování dat a extrakce příznaků	27
4.2.3 Klasifikátory strojového učení	28
4.2.4 Výsledky jednotlivých klasifikátorů	29

<b>5</b>	<b>Teoretický úvod do praktické části práce</b>	<b>30</b>
5.1	Víceúrovňová diskretní vlnková transformace . . . . .	30
5.2	Extrakce příznaků . . . . .	31
5.3	Selekce příznaků . . . . .	32
5.3.1	Analýza hlavních komponent . . . . .	32
5.4	Trénovací, testovací sada a křížová validace . . . . .	33
5.4.1	K-násobná křížová validace . . . . .	34
5.5	Metriky pro vyhodnocení úspěšnosti klasifikace modelů . . . . .	35
5.5.1	Klasifikační přesnost . . . . .	35
5.5.2	Matice neurčitosti . . . . .	35
5.5.3	Plocha pod křivkou (AUC) . . . . .	36
5.5.4	F1 skóre . . . . .	37
<b>6</b>	<b>Praktická část práce</b>	<b>38</b>
6.1	Základní informace o vstupních datech . . . . .	38
6.1.1	Nahrání dat a jejich základní analýza . . . . .	39
6.2	Úprava dat a vytvoření matic pro strojové učení . . . . .	41
6.2.1	Předzpracování signálů . . . . .	41
6.2.2	Převzorkování dat . . . . .	42
6.2.3	Extrakce příznaků . . . . .	42
6.2.4	Standardizace hodnot . . . . .	42
6.2.5	Přiřazení anotace a tvorba matic strojového učení . . . . .	43
6.3	Výběr dat . . . . .	44
6.3.1	Selekce příznaků podle schopnosti rozlišit stavy . . . . .	44
6.3.2	Selekce založená na kolinearitě příznaků . . . . .	46
6.4	Návrh a učení klasifikačních modelů . . . . .	48
6.4.1	Rozdělení dat . . . . .	48
6.4.2	Učení modelů pomocí klasifikačních algoritmů . . . . .	49
6.5	Vyhodnocení jednotlivých klasifikačních modelů . . . . .	50
6.5.1	Klasifikace binární . . . . .	51
6.5.2	Klasifikace 4 psychických stavů . . . . .	52
6.6	Diskuze . . . . .	53
<b>7</b>	<b>Závěr</b>	<b>56</b>
	<b>Literatura</b>	<b>57</b>
	<b>Seznam obrázků</b>	<b>61</b>
	<b>Seznam tabulek</b>	<b>62</b>

Seznam příloh	62
A Obsah CD	63

# ÚVOD

Stres je bezesporu populární pojem moderní doby, o kterém se často hovoří v médiích, veřejných sdělovacích prostředcích a veřejností bývá často vnímán v negativním slova smyslu. Stal se již víceméně nedílnou součástí života téměř každého člověka na zemi, což je samozřejmě způsobeno dnešní uspěchanou dobou, která vznik stresového stavu pouze podněcuje. Stres má tedy obrovský dopad a vliv na dnešní dobu, kdy se bohužel mnoho lidí stresuje každý den. Stres totiž může výrazně ovlivnit fyzické a psychické (duševní) zdraví organismu. To je jeden z mnoha důvodů, proč je příhodné stresové situace detekovat. Touto problematikou se tato práce zabývá.

V první kapitole dochází k definování stresu. Jsou vysvětleny některé pojmy pojící se ke stresu společně s mechanismy, které stres spouštějí. Je popsán vliv životních situací na stres a samotný průběh stresové reakce z psychologického i fyziologického hlediska s ohledem na délku jeho působení.

Druhá kapitola vysvětluje pojem biologický signál a je provedena analýza vhodných biologických signálů k detekci stresu, kterých bylo využito v řadě výzkumných prací. Zejména je zde kladen důraz na rozbor biosignálů, kterých bylo využito v praktické části práce.

Třetí kapitola představuje databáze biologických signálů, jejichž data byla ve studiích, z které databáze pocházejí, využita pro detekci stresu či neurologických stavů. Data z první popsané databáze byly využity v praktické části práce.

Ve čtvrté kapitole jsou provedeny řešerše 2 metod automatické detekce stresu, které posloužily jako podpůrné texty při vytváření programu v praktické části.

Pátá kapitola slouží jako teoretický úvod pro vytvoření programu detekující stres. Jsou zde popsány a vysvětleny pojmy z praktické části práce. První podkapitola vysvětluje princip fungování Víceúrovňové diskrétní vlnkové transformace. Druhá a třetí podkapitola se zabývají extrakcí a selekcí příznaků. Procesu rozdělení dat ve strojovém učení se věnuje čtvrtá podkapitola a v rámci poslední páté podkapitoly dochází k popisu metrik, kterých bylo využito pro vyhodnocení úspěšnosti modelů.

Šestá kapitola se věnuje praktické části práce. Je zde popsán proces realizace programu detekující stres v programovém prostředí MATLAB od nahrání dat z databáze, přes úpravu a výběr dat, po klasifikaci výsledných modelů. V první podkapitole jsou uvedeny podstatné informace o databázi a je zde popsán proces nahrání dat a jejich základní analýza. Úprava dat formou převzorkování, extrakcí příznaků a standardizací hodnot byla realizována v podkapitole druhé. Následný výběr příznaků, které nejlépe reprezentovaly klasifikační modely, byl proveden pomocí dvou sekekcí přístupů ve třetí podkapitole. Čtvrtá podkapitola pojednává o návrhu a učení klasifikačních modelů, které byly navrženy pomocí 4 klasifikačních algoritmů pro binární klasifikaci a 3 klasifikačních algoritmů bylo využito pro návrh modelů



pro klasifikaci do 4 psychických stavů. Pátá a šestá podkapitola vyhodnocuje modely a diskutuje výsledky.

# 1 STRES

Termín stres pochází původem z mechaniky. V této oblasti fyziky je stres chápán jako vystavení materiálu zátěži a dal by se definovat Hookovým zákonem elasticity pomocí vzorce 1.1: [1]

$$stres = k \cdot napětí \quad (1.1)$$

V tomto vzorci představuje  $k$  konstantu, nazvanou Youngův modul, která reprezentuje elasticitu materiálu a typ stresu, který je aplikován na tvorbu napětí (strain). Napětí (strain) vyjadřuje v mechanice reakci materiálu na stres. [1]

Toto pojetí stresu lze převést z mechaniky do oblasti fyziologie stresu – nauky o tom, jak organismus reaguje na stres. Původem maďarský, posléze kanadský fyziolog Hans Selye převedl pojetí stresu z technické literatury do lékařského slovníku v částečně odlišných souvislostech a rozdílném významu. Pokud bychom brali jako materiál, který je vystaven zátěži, lidské tělo, mohlo by ve výše uvedeném vzorci napětí představovat důsledek různých tlaků na fyziologické, psychologické a jiné zátěže. Hans Selye však neužil pro dané důsledky působení různých tlaků termínu napětí (strain), ale stres. Konstanta  $k$  je tomto fyziologickém pojetí stresu chápána jako vulnerabilita (zranitelnost) člověka podléhajícímu tlaku těžké zátěžové situace. Stres (v české terminologii „zátěž“) by se zase dal definovat jako stresogenní situace nebo soubor stresorů (tlaků). [1] [2] [3]

Obecně by se dalo říci, že stres je pro lidské tělo zátěžová situace, do které se dostává, když na něj doléhají různé druhy tlaků. [1]

## 1.1 Definování stresu

V předešlých letech se o stresu hovořilo jako o negativním emocionálním zážitku doprovázeným souborem fyziologických, behaviorálních a kognitivních změn, které se zaměřují na změnu situace ohrožující člověka nebo na přizpůsobení se situacím, které nelze změnit. V současné době se termínem napětí (strain) rozumí emocionální stav člověka při situaci, kdy se cítí ohrožen, a který je doprovázen soubory fyziologických jevů. [1]

Velice důležitý pro stresovou situaci (stres) je poměr mezi mírou (intenzitou) stresogenní situace (souborem stresorů) a schopnostmi určitou situaci zvládnout. Stresová situace vznikne pouze za předpokladu, že míra intenzity stresogenní situace převyšuje schopnost zvládnout danou situaci. Jedná se o tzv. nadlimitní zátěž, která je provázána vnitřním napětím (strain) a kritickým ohrožením rovnováhy (homeostázy) organismu. [1] [4]

Většinou se organismus neocitne v nadlimitní zátěži vlivem jednoho velkého individuálního stresoru, ale častěji působením souhry více stresorů, či jejich projevení se v časové návaznosti. Takovýmito stresory mohou být např. běžné každodenní starosti (daily hassles), které nepředstavují sami o sobě závažný problém a většinou se jim nevěnuje přílišná pozornost. Tyto běžné každodenní starosti však mohou přerůst v nadlimitní množství a mohou vést k vážným potížím. [1] [5]

V následující kapitole bude popsáno, co jsou to stresory.

### 1.1.1 Stresory

Stresory mohou být chápány jako nepříznivé vlivy (tlaky), které mohou přivést člověka do tíživé osobní situace. Jsou to tedy spouštěče potenciální stresové reakce organismu. Vesměš by se dalo říci, že se jedná o tzv. negativní životní faktory (životní události, bolestné vzpomínky), pomocí kterých je navozen pocit ohrožení, strach, že se něco stane a pocit, že ztrácíme kontrolu. [1] [3] [5]

Stresory je obecně možno rozdělit do 4 základních kategorií, kterými jsou stresory:

1. fyzikální – teplo, chlad, tlak atd.
2. chemické – jedy, toxiny, alkohol, otravy, infekce atd.
3. biologické – hlad, žízeň, bolest atd.
4. psychosociální – úzkost, strach atd. [4]

Člověk se nejčastěji setkává s tzv. každodenními stresory, které jsou většinou kombinací různých vlivů. Tyto stresory běžného života lze dále dělit do 4 kategorií na stresory: [4] [5]

1. vztahové – neshody s rodiči nebo partnerem, žárlivost, narození dítěte a jeho vliv na členy rodiny, společné bydlení s rodiči atd.
2. pracovní a výkonové – nízký příjem, jenž není dostačující na uživení rodiny, nadměrné dluhy a splátky, ztráta práce nebo její hrozba, práce v těžkých podmínkách jako např. hluk, prach, špatné osvětlení atd
3. související se životním stylem – nedostatečné množství přátel nebo příjemných aktivit, monotónní a stereotypní životní styl, absence koníčků a zájmů atd.
4. nemoci, závislosti a handicap – tělesná či psychická nemoc vlastní nebo člena rodiny, závislost na drogách, alkoholu či lécích u partnera nebo dětí, hazardní hráčství nebo závislost na automatech u člena rodiny atd. [5]

Ve spojení se stresory je též záhodno zmínit tzv. salutory. Salutory (z latinského slova „salus“ a anglického výrazu „salutary“ – posilující zdraví) jsou pozitivní životní faktory, které posilují a povzbuzují organismus v těžké situaci, dodávají mu sílu, odvahu i výdrž v boji se stresem. [1]

### 1.1.2 Teorie životních událostí

Životní událostí se rozumí jakákoliv situace, která přiměje člověka změnit jeho rutinní život. Člověk je totiž navyklý žít takto rutinně a změna pro něj představuje stresor. Pokud je změn překračujících rutinu mnoho, odolnost ke stresu se snižuje. Stresová reakce se však ve většině případech nespustí okamžitě po zjevení životní události, ale po určité časové latenci. [5] Američtí psychologové Holmes a Rahe vypracovali v 60. letech minulého století teorii životních událostí, která vyjádřila význam změn v životě člověka. Na základě svých studií přidělili jednotlivým událostem určité indexy závažnosti – body. Autoři teorie se vyptávali stovek lidí na to, jaké těžké životní události v životě prožili a požadovali, aby poté nastínily náročnost jejich zvládnutí. Pro vyhodnocení využili metodu párového porovnání (pair comparison method), což je metoda běžně užívaná při škálování v psychometrice. Výsledná stupnice (škála) těžkých životních událostí se skládá z 43 situací, kde nejtěžší situací, s hodnotou 100 bodů, bylo vyhodnoceno úmrtí životního partnera. [1] [3] [5]

Vliv těchto těžkých životních událostí se během roku sčítá a pokud člověk za poslední rok získá 150 – 300 bodů, může se jednat o výraznou stresovou zátěž, která může mít dopad na jeho zdravotní stav. Při překročení hodnoty 300 bodů lze téměř s jistotou očekávat nepříznivé zdravotní důsledky. [3] [5]

Tato stupnice upoutala pozornost mnohých proto, že odhalila odlišnou tíhu těžkých životních situací a též proto, že nastínila příležitost možnosti lepšího studia vztahu mezi životními událostmi, stresem a přítomností nemoci. [1] Bodový systém Holmese a Raheho však zaznamenal i kritiku a to proto, že předpokládá univerzální platnost pro všechny. Např. pro některé jedince představuje rozvod velice negativní a pro jiné zase pozitivní životní událost. Nejedná se tedy o absolutní měřítko stresu, ale pouze o jakýsi indikátor, který dobře funguje pro stanovení následující reakce u psychických poruch a psychosomatických reakcí. Obecně tedy zvládnutí životních událostí závisí nejenom na součtu bodů, ale také např. na konstruktivnímu přístupu k dané situaci. Životními událostmi nelze jen tak objasnit důvod začátku stresové reakce. [1] [3] [5]

## 1.2 Stresová reakce (stresový syndrom)

Jestliže se organismus ocitne ve stresogenní situaci, čili setká se se stresorem, může být vyvolána stresová reakce, která je charakteristická rychlou mobilizací energie a rychlou kaskádou změn, které slouží k připravenosti organismu na boj nebo útěk. Tento mechanismus byl zděděn po dávných předcích. Pomáhá nám přenést se přes situaci ohrožení, kdykoliv ji rozpoznáme. Tato situace ohrožení však nemusí být vždy pravdivá. Obecně by se dalo říct, že nás stresová reakce varuje před hrozícím nebezpečím a poté dostává a udržuje tělo i mysl ve stavu pohotovosti, dokud toto nebezpečí nepomine. [1] [5]

Při stresové reakci dochází v organismu k narušení jeho integrity a vytvářejí se obranné a kompenzační mechanismy, které jsou účinnější než při poruchách homeostázy. [4]

### 1.2.1 Alostáza

Pro stresovou reakci je významné zmínit pojem alostáza, což je snaha organismu udržet si své systémy jako např. kyselost, tělesnou teplotu, hladinu glukózy apod. na jistém optimálním rozpětí prostřednictvím změny. Alostáza je proces podporující homeostázu organismu, tj. udržení daných fyziologických parametrů v rovnováze v situacích, kdy u jedince dochází ke změnám životních podmínek, či prochází rozličnými životními etapami. [2]

Pro zachování alostázy je vyvoláno mnoha změn v organismu. Na dosažení alostázy má organismus mnoho mechanismů, které se nazývají primárními činiteli (mediátory). Těmi jsou hormony, které se uvolňují v hypothalamu a hypofýze. Vzniká alostatický stav, který způsobuje nerovnováhu mezi primárními činiteli. Vlivem něj může v organismu dojít k např. hypertenzi, poruchám srdečního rytmu, vzniku záležitostí atd. [2]

Alostatický stav souvisí s termínem alostatický stres. Tento typ stresu vede k patologickým změnám v organismu a k jeho tělesnému poškození. [4]

### 1.2.2 Akutní a chronický stresový syndrom

Z hlediska trvání stresové reakce může být náhlý (krátkodobý, akutní) stres užitečný. Slouží jako varovný signál, že „bychom měli něco dělat“. Déle trvajícím stres může vést ke značným potížím, jako např. poškození psychiky nebo psychosomatiky. [5]

Akutní stres trvá maximálně pár hodin. Převládá v něm aktivace sympatoadrenální osy (SAS) a osy hypothalamus – hypofýza – nadledvina (HHN). V organismu se mobilizuje rezervní energie, která je bezprostředně využita pro umožnění organismu přežít danou situaci. Dochází k aktivaci systému nervového, endokrinního,

kardiorespiračního a pohybového a k utlumení činnosti trávicího, reprodukčního a vylučovacího systému. [4]

Při chronickém stresu se aktivují déle trvající nervové, imunologické a hormonální procesy. Délka jeho trvání představuje týdny, měsíce a někdy i roky. Zprostředkování chronického stresu je umožněno pomocí serotoninu, který integruje informace v limbickém, hypotalamickém, hypofyzárním a nadledvinkovém systému. Objevují se strukturální změny jako např. zmenšení sleziny, zvětšení nadledvinek nebo atrofie brzlíku, čímž se docílí redukce lymfocytů. Chronický stres je také často provázen potlačením růstu a sexuálních funkcí, kdy u žen může být pozorována snížená schopnost ovulace a otěhotnění a u mužů zase snížená schopnost produkovat testosteron a dosáhnutí dostačující erekce. Jestliže je organismus již starší, lze u něj zpozorovat vyšší hladinu stresových hormonů i za klidových situací. Při stresové reakci se však tato hladina ještě zvyšuje. To je způsobeno tím, že receptory stresových hormonů již ve stáří nejsou tak citlivé. [4]

### 1.2.3 1. fáze stresové reakce – poplachová reakce

Americký fyziolog Walter B. Cannon interpretoval poplachovou reakci jako krátkodobý kompenzační mechanismus spějící ke znovunastolení homeostázy. Původní Cannonova představa o stresu byla akutní reakce organismu na bezprostřední ohrožení, tedy jestli organismus vyhodnotí situaci jako ohrožující, zahájí poplachovou reakci. Tato reakce je řízena převážně adrenergním systémem a bývá označována jako Cannonův stres. [3]

Jestliže se organismus střetne se stresem, čili vyhodnotí podnět jako stresový, spustí se poplach v organismu. Dochází k mobilizaci obranných mechanismů a energetických zdrojů. Zvýšenou činnost zaznamenává zejména sympatický nervový systém, který je takto intenzivně aktivován vyplavením většího množství adrenalinu (epinefrinu) a noradrenalinu do krevního řečiště. To se projeví zrychlením srdečního tepu a dechu, zvýšením krevního tlaku a sekrece potních žláz, rozšířením zornic, zúžením cév v kůži, aby nedocházelo ke krvácení při zranění. Takto aktivovaný sympatikus má rovněž za následek uvolnění zásobní energie ve formě cukrů, tuků a škrobů. Krevním řečištěm se tato energie společně s kyslíkem dostává směrem k mozku, kosterním svalům, srdci a plicím. Nejen sympatikus ale i parasympatikus se začleňuje do této reakce. Jeho působením se omezuje přísun energie a kyslíku systémům jako např. trávicí ústrojí, které nejsou v dané situaci nezbytné k přežití. [1] [4] [5]

Tato rychlá kaskáda změn připraví organismus na reakci typu „boj nebo útěk“. Ukázalo se však, že tato reakce byla pro člověka účinná v historických dobách, kdy člověk čelil více fyzickému nebezpečí než dnes, kdy je vystaven spíše psychickým

hrozbám, na které není tento typ reakce zas tak užitečný, protože již není tolik možností s někým fyzicky bojovat a mnohdy kam utéct. Jestli se východisko boje nebo útěku nejeví jako úspěšné, organismus se může dostat do stavu útlumu a rezignace. [1] [5]

#### 1.2.4 2. fáze stresové reakce – všeobecný adaptační syndrom

Hans Selye uváděl zvířata do těžkých situací a pozoroval změny jejich fyziologických funkcí. Zjistil, že pokud je organismus zvířete závažně poškozen akutní nespecifickou noxou (např. expozice chladu), objevuje se stále stejný obraz, kdy dochází vždy k témuž souboru fyziologických reakcí, jejichž symptomy nejsou závislé na charakteru noxy a spíše jsou odpovědí na poškození organismu. Došel k závěru, že stresový syndrom je celková snaha organismu adaptovat se na nově vzniklou situaci, kterou lze přirovnat např. k procesu zánětu nebo imunitní reakci. Tento stabilní, avšak nespecifický vzor odpovědi pojmenoval GAS – (General Adaptation Syndrome) – všeobecný adaptační syndrom. V tomto syndromu vyznačil 3 fáze: [1] [3]

*První fáze*, nazývaná též poplachová, alarmová či Cannonův stres, byla popsána v předchozí kapitole, protože Cannon, který se zabýval problematikou stresu jako první již před Selyem, měl o stresové reakci představu jako o akutní reakci na bezprostřední ohrožení. Až poté navázal na Cannonovu pionýrskou práci Selye a představil svoji koncepci o jednotném obrazu stresu. [1] [3] [4]

*Druhá fáze*, označovaná též jako fáze rezistence, adaptační, se zahájí zhruba po 48 hodinách od poškození (prvním střetnutím se stresorem). Jedná se o dlouhodobější reakci, která by měla vést ke zklidnění organismu. Nastává v okamžiku opakovaného působení stresoru, kdy vlastní boj organismu se stresorem se stává nevyhnutelným a kdy došlo k vyčerpání poplachové reakce. Přejití z poplachové na adaptační fázi může nastat i za situace, že překážku či problém nebyl organismus schopen vyřešit. Tělo se snaží vytvořit si ochranu pro překonání či přečkání nepříznivé situace. Dochází k aktivaci parasympatiku, který má za následek výrazné zesílení útlumové složky a přednostnímu zajištění funkcí, které organismus vykonává při útlumové fázi. Takováto funkce je např. trávení. Příčinou zastavení růstových pochodů v organismu a atrofii gonád má na starost přední lalok hypofýzy, který snižuje produkci růstového hormonu a gonadotropních hormonů, aby mohlo docházet ke zvýšené produkci tyreo tropních a adrenotropních systémů, které se zdají být v dané situaci potřebnější. Adrenokortikotropní hormon, který je uvolněn z hypofýzy, stimuluje kůru nadledvin k produkci kortizolu a kortizonu, které mobilizují energii. Kortizol a kortizon zprostředkovávají také zpětnou vazbu pro hypotalamus. Pokud je hladina těchto hormonů dostačující, přestane mozek dávat impulzy pro pokračování stresové reakce. Může tak dojít k doznění stresové reakce. [1] [3] [4] [5]

*Třetí fáze* je poté stav setrvávající expozice organismu noxou v celé své šíři i nadále po dobu jednoho až tří měsíců, kdy si nedokázal k dané noxe vybudovat rezistenci. Organismus přestává odporovat a navrácí se do stavu první fáze, označovaný při tomto prodělání již všech tří fází jako stav exhauce. [3]



## 2 ANALÝZA VHODNÝCH BIOSIGNÁLŮ

Stres není fyzikální veličina a nelze jej tedy přímo měřit. Stres však lze odvodit měřením skutečných fyzikálních veličin, které se mění s pocitem. K měření těchto veličin je zapotřebí senzorů, které je nutné na měřený subjekt nasadit během jejich snímání. K tomu se vážou jisté problémy jako např. provádění měření na reálných místech, fyzické nepohodlí nošením některých senzorů a stres spojený s měřením. [6]

Některé z těchto fyzikálních veličin, vhodně detekující stres dle článků, z kterých tato kapitola vychází, jsou popsány v této kapitole. Fyzikální veličiny jsou měřeny senzory a následně ukládány do počítače jako biosignály, které se potom analyzují. Úlohou této kapitoly je zejména přiblížit čtenáři biologické signály, které byly využity v praktické části.

### 2.1 Biosignály

Biosignálem se rozumí jakýkoliv projev, který se změní činností živého organismu. Nemusí se přitom jednat pouze o vlastní činnost organismu (tj. aktivní činnost) jako např. EKG<sup>1</sup> nebo krevní tlak, ale může se jednat i o pasivní reakci organismu s vnějším fyzikálním či chemickým podnětem. Biosignál může představovat jednu hodnotu či řadu různých hodnot, které se změní v jednom okamžiku. [7]

Biosignály je možno rozdělit podle různých hledisek. Jedním z hledisek možnosti rozdělení biosignálů je podle jejich chování se časem. Zde rozlišujeme biosignály *deterministické*, které jsou jednoznačně určené (determinované) počátečními podmínkami a *stochastické*, které zahrnují ve svém chování náhodný prvek. Dále se mohou dělit podle jejich rozměru na jednorozměrné, dvojrozměrné a trojrozměrné. *Jednorozměrné biosignály* znázorňují časovou posloupnost hodnot změřeného parametru jako např. časový průběh teploty pokožky či saturace krve kyslíkem nebo trojice hodnot napětí získaných z končetinových svodů EKG jako časová posloupnost vektorů naměřených parametrů. *Dvojrozměrné biosignály* odpovídají řadě biosignálů snímaných v jednom čase z definovaných míst dvojrozměrného prostoru. Tento prostor vzniká řezem trojrozměrného prostoru či sumací signálů ležících vně zobrazované roviny a většinou se jedná o obrazová data reprezentovaná maticí čísel z výstupů klinických zobrazovacích metod jako např. rentgenový či ultrazvukový snímek. *Trojrozměrné biosignály* jako např. 3D ultrazvuk nebo obraz CT jsou reprezentací biosignálů, které byly snímány s ohledem na prostorové rozložení jejich zdrojů a mohou být reprezentovány maticemi vektorů. Takovéto biosignály lze opět

---

<sup>1</sup>elektrokardiogram


zaznamenávat v čase, ale jejich snímání je pro měřící zařízení (např. 4D sonografie) obtížné z hlediska paměti i výpočetní náročnosti. [7]

Biosignály jsou však zejména spojovány s elektrickými projevy organismu. Některým těmto elektrickým biosignálům, jež vhodně detekují stres, je v této práci věnována pozornost a jsou v následujících podkapitolách podrobněji popsány.

## 2.2 Akcelerometr

Akcelerometry jsou polohové čidla, která měří zrychlení, což je charakteristika pohybu popisující způsob změny rychlosti objektu v čase a lze je použít jako senzory pohybu, které jsou implementovány do zařízení umístěných na zápěstí, čímž je možno sledovat např. závislost pohybů rukou na stresujících podnětech. Zrychlení je obvykle měřeno v metrech za sekundu na druhou ( $m/s^2$ ) a je akcelerometry měřeno na jedné, dvou nebo třech osách. V této práci je využíván tříosý akcelerometr, který měří zrychlení na třech osách – x, y a z a v dnešní době se jedná nejspíš o nejběžněji používaný typ akcelerometru z důvodů klesajících nákladů na jejich výrobu. [8]

Akcelerometry v sobě obsahují kapacitní desky, jež jsou buď pevně připojeny, nebo se na pružinách pohybují ve vztahu k sobě navzájem, čímž představují pohyblivou zátěž. Dojde-li na některé z os akcelerometru k pohybu, vychýlí se zátěž, čímž se změní kapacita mezi deskami, která je vyhodnocena jako pohyb na dané ose a také lze z ní zjistit zrychlení. Dalším možným způsobem měření zrychlení je za pomoci piezoelektrických materiálů, které vydávají elektrický náboj při jejich vystavení mechanickému namáhání. Grafické znázornění principu fungování piezoelektrického akcelerometru je na obrázku 2.1. Na levém obrázku není piezoelektrický materiál mechanicky namáhán a tím pádem nevydává elektrický náboj. Na obrázku 2.1 vpravo dochází k jeho mechanickému namáhání, které má za následek vydávání elektrického náboje a možnosti měření zrychlení. [8]



Obr. 2.1: Princip piezoelektrického akcelerometru při jeho vystavení se mechanickému namáhání, převzato z [8]

## 2.3 Teplota pokožky

Teplota pokožky se zdá být účinným ukazatelem pro objektivní hodnocení lidských pocitů a tedy i stresu, uvádí studie [6], jelikož je řízena sympatickou nervovou aktivitou, která je odrazem průběhu zpracování informací v mozku. Na teplotu pokožky mají značný vliv změny krevního průtoku. Pokud se organismus dostane do stresového stavu, dojde k poklesu průtoku krev vlivem vazokonstrikce, což zapříčiní pokles množství dodaného tepla do kůže a dojde k poklesu teploty kůže. [6]

Ve studii [6] byla dále zjištěna vysoká korelace mezi stresem a teplotou pokožky za pomoci regresní rovnice, která vypočítala intenzitu stresu z teplot kůže na nose a čele, jež se jeví jako platné ukazatele pro detekci stresu, protože právě zde dochází ke změnám teplot podle aktivit sympatických nervů. Obecně lze ale říci, že končetiny a jiné okrajové části těla jsou velmi citlivé na stres. V této studii byla teplota kůže měřena bezkontaktně pomocí infračerveného záření infračervenou kamerou v reálném čase. [6]

## 2.4 Elektrodermální aktivita (EDA)

Velmi často používaným biosignálem při detekci stresu je elektrodermální aktivita (zkráceně EDA), která je ve studiích mnohdy označována jako galvanická reakce kůže (GSR). Stres je spojován s autonomním nervovým systémem (ANS) a právě změny autonomního nervového systému, přesněji sympatického nervového systému, vyvolané událostmi souvisejícími se stresem (jako např. emoční vzrušení či fyzická námaha), způsobují elektrické změny měřené na povrchu kůže (různé elektrické fenomény kůže jako odpor, vodivost a potenciál) představující elektrodermální

aktivitu. [9] [10]

Nejčastěji měřeným elektrickým fenoménem kůže je pravděpodobně její vodivost (označována jako SC – Skin Conductance). Na vzniku signálu mají největší podíl potní žlázy, které mají vliv na změnu kožního odporu (SR – Skin Resistance). Vztah mezi vodivostí a odporem udává vzorec 2.1: [14]

$$G = \frac{1}{R} [S] \quad (2.1)$$

kde G představuje kožní vodivost a R kožní odpor. Jednotkou kožní vodivosti je siemens – S. Naměřené hodnoty se však nejčastěji pohybují v řádech mikro Siemens [ $\mu$ S]. Kožní vodivost je tedy převrácenou hodnotou kožního odporu a pokud se sekrece potu z potních žláz bude zvyšovat, dojde k snížení kožního odporu a zároveň tedy ke zvýšení kožní vodivosti. Prožívání stresových situací je obecně spojováno se zvýšením kožní vodivosti. [11]

Vodivost kůže lze měřit přiložením elektrického potenciálu mezi dvěma body kontaktu s kůží, nejčastěji formou dvou elektrod umístěných bříšcích dvou sousedních prstů. Bříška prstů obsahují póry, jež citlivě reagují na psychogenní podněty, které mohou být spojené se stresem na rozdíl od jiných částí těla. Následně je měřen výsledný slabý proud mezi těmito sousedními bříšky prstů. Zařízení pro měření elektrodermální aktivity v dřívějších dobách neslo název psychogalvanometr. Současně vypadající měřicí systém je znázorněn na obrázku 2.2. [12] [13]



Obr. 2.2: Měření elektrodermální aktivity, [14]

Signál elektrodermální aktivity v sobě zahrnuje dvě ústřední složky, a to hladinu vodivosti kůže (SCL – skin conductance level), což je pomalu se měnící část a odezvu vodivosti kůže (SCR – skin conductance response), které jsou výsledkem sympatické nervové aktivity. Změny SCL nejsou závislé na změnách stavu prostředí, zato změny

SCR závislé na těchto změnách jsou. Jestliže se odečte od signálu elektrodermální aktivity jeho složka SCL, získá se SCR složka. [12]

## 2.5 Saturace krve kyslíkem (SpO<sub>2</sub>)

Saturace krve kyslíkem či množství okysličeného hemoglobinu v krvi (zkráceně SpO<sub>2</sub>) je odhad množství kyslíku v krvi, který je vypočítáván z její saturace kyslíkem, což je poměr okysličeného hemoglobinu (HbO<sub>2</sub>) k deoxygenovanému hemoglobinu (Hb). Okysličená krev má jasně červené zbarvení a neokysličená krev má oproti tomu zbarvení tmavě červené. Pulzní oxymetr měří saturaci krve kyslíkem (arteriální oxygenaci) tím, že emituje červené a infračervené světlo přes prst či jiné dobře prokrvené části těla a stanovuje, jak se jednotlivá světla v krvi absorbovala, tedy měří poměr infračerveného a červeného světla přenášeného prstem. Fyziologické hodnoty saturace krve kyslíkem se pohybují v rozmezí 95–100 %. [9] [15]

Ve studii [15] byla zjištěna určitá spojitost mezi SpO<sub>2</sub> a teplotou končetin, a to výrazné zvýšení SpO<sub>2</sub> při lokálním snížení tělesné teploty organismu (hypotermii) vlivem vazokonstrikce cév, aniž by současně docházelo ke změně arteriálního parciálního tlaku O<sub>2</sub> (pO<sub>2</sub>) a výrazné snížení SpO<sub>2</sub> při lokálním zvýšení tělesné teploty (hypertermii) vlivem vazodilatace cév. [15] Vliv teploty na stres byl popsán v kapitole 2.3.

## 2.6 Variabilita tepové frekvence (HRV)

Variabilita tepové frekvence (HRV – Heart rate variability) znázorňuje změny (variace) v časovém období mezi dvěma po sobě jdoucími srdečními rytmy (R–R intervaly). Proces získávání HRV je následující: v signálu EKG jsou detekovány R píky, z kterých je extrahován signál variability R–R intervalu v EKG označovaný jako RRV, ze kterého je HRV vypočítáno ze vztahu 2.2: [10] [11]

$$HRV = \frac{60}{RRV} \quad (2.2)$$

Signály RRV a HRV obsahují dvě základní složky:

- základní složku obsahující nízkou frekvenci - projevují se některé náhlé změny způsobené stresovými událostmi,
- periodickou složku - zahrnuje sympatickou a parasympatickou aktivitu. [11]

HRV může být ovlivněno jak stresem, tak i např. patologickými stavy a srdečními chorobami. HRV je výsledkem regulace sinusového uzlu autonomního nervového systému (ANS), který je dále dělen na sympatické a parasympatické větve. Sympatikus

má tendenci zvyšovat HR a parasimpatikus snižovat. Tepová frekvence (HR) se jeví jako jeden z nejméně běžných parametrů související se stresem, kdy dojde ke zvýšení HR při zažívání stresové události. Tepová frekvence po určitý časový interval je extrahována z HRV. [11] [16]

V řadě výzkumných prací, zabývajících se problematikou detekce stresu, byly k tomuto účelu často využívány i jiné biologické signály. Zejména pak biosignály, které dobře zachycují emocemi řízené změny vzniklé aktivací autonomního nervového systému (ANS). Takovým biosignálem je např. elektroencefalogram (EEG), jehož záznam elektroencefalografem<sup>2</sup> je hodnocen amplitudovou a frekvenční analýzou. V EEG se standardně rozlišují 4 typy mozkových vln podle frekvence: alfa, beta, theta a delta, z nichž pro detekci stresu jsou nejvýznamnější alfa (8-13 Hz) a beta (13-30 Hz) mozkové vlny. Monitorace EEG však není za běžných denních podmínek proveditelná, a lze ji realizovat ve specializovaných zařízeních k tomu uzpůsobených. Krevní tlak (BVP - Blood volume pulse), je dalším biosignálem vhodným k detekování stresu. Blízce však koreluje s tepovou frekvencí srdce (HR), a proto se tyto 2 biosignály ve společném zastoupení často nepoužívají. V neposlední řadě bývají ve studiích zabývajících se touto tematikou také zastoupeny biosignály: elektromyogram (EMG), snímající záznam elektrických impulsů ze svalových vláken, fotopletysmogram (PPG - photoplethysmogram), snímající v této souvislosti změny objemu krve a záznam dýchání (RSP). [9] [14] [17]

---

<sup>2</sup>zařízení pořizující záznam EEG

## 3 PŘEHLED DATABÁZÍ BIOLOGICKÝCH SIGNÁLŮ

V této kapitole budou popsány databáze biologických signálů, jejichž data posloužila k detekci stresu.

Následující podkapitoly jsou koncipovány jako rešerše článků věnující se detekci stresu a v kterých jsou data, podle kterých se dá stres detekovat, popsány.

### 3.1 A Non-EEG Dataset for Assessment of Neurological Status

Tým vědců v čele s Javadem Birjandtalabem se ve své studii [9] zabírají detekcí stresu pomocí aplikace shlukovací metody modelu Gaussovského mixu. K detekci využívají data pěti paralelně snímaných non-EEG signálů. [9]

Signály byly snímány komfortním, efektivním a neinvazivním způsobem v laboratoři Quality of Life Technology na Texaské universitě v Dalasu senzory umístěnými na zápěstí. Jedná se o tyto signály: [9]

- Pohyby zápěstí
- Tělesná teplota
- Elektrodermální aktivita (EDA) <sup>1</sup>
- Tepová frekvence (HR)
- Saturace krve kyslíkem (SpO<sub>2</sub>) <sup>2</sup>

Signál elektrodermální aktivity, reflektující změny sympatického nervového systému, společně se signály pohybů zápěstí a tělesné teploty, byly snímány zařízením Affectiva Q Curve umístěným na zápěstí levé ruky během experimentu. Zbylé dva biosignály byly snímány pulzním oxymetrem Nonin 3150 Wireless WristOx<sub>2</sub>, sestávající se z prstové manžety, umístěné na ukazováčku pravé ruky, snímající saturaci krve kyslíkem, která je propojena se zařízením na pravém zápěstí pro měření tepové frekvence. Obrázek 3.1 zobrazuje oba tyto přístroje. [9]

---

<sup>1</sup>někdy též označována jako galvanická reakce kůže (GSR) nebo změna vodivosti kůže

<sup>2</sup>označována též jako množství okysličeného hemoglobinu




Obr. 3.1: Zařízení Affectiva Q Curve pro sběr dat pohybů zápěstí, tělesné teploty a změn konduktance kůže (vlevo) a zařízení Nonin 3150 Wireless WristOx<sub>2</sub> pro sběr dat tepové frekvence a saturace krve (vpravo), převzato z [9]

Databáze zahrnuje záznamy z 5 non-EEG signálů, které snímají neurologický stav 20 zdravých subjektů, z nichž 14 jsou muži a 6 ženy ve věku 19–33 let. Navrhnutý experiment měl za cíl rozlišit odezvy na různé typy stresů, vystavením subjektů stresorům, jež měly za úkol daný stresový stav navodit. Jednotlivé navozené stresové stavy byly prokládány fázemi relaxace, které měly za úkol měřený subjekt uvést do co nejvíce klidového stavu, kdy byl subjekt požádán, aby seděl v klidu a poslouchal tichou, relaxační hudbu Binaurálu, která se využívá při meditacích. Experiment byl proveden v následujících krocích: [9]

1. První relaxace: 5 minut.
2. Fyzický stres: 1 minuta stání ve stoje, 2 minuty chůze na běžecském pásu rychlostí 1 míle za hodinu (1,6 km/h) a 2 minuty chůze/běh na rychlostí 3 míle za hodinu (4,8 km/h).
3. Druhá relaxace: 5 minut.
4. Kognitivní stres: 3 minuty počítání pozpátku po sedmi, počínaje číslem 2485 a Stoopův test, který spočívá ve čtení názvů barev napsaných odlišně barevným inkoustem a poté říci, jakou barvu měl inkoust. V obou testech byl subjekt upozorněn na chybu bzučákem.
5. Třetí relaxace: 5 minut.
6. Emoční stres: 1 minuta očekávání spuštění pěti minutového hororového klipu. Po 1 minutě byl subjektu ukázán klip z filmu zombie apokalypsy The Horde.
7. Čtvrtá relaxace: 5 minut. [9]





Obr. 3.2: Vizualizace surových signálů subjektu 1 před předzpracováním, převzato z [9]

Tab. 3.1: Informace o jednotlivých subjektech, převzato z [9]

Subjekt ID	Věk	Pohlaví	Výška [cm]	Váha [kg]
1	30	Muž	177	94
2	28	Muž	172	68
3	28	Muž	177	91
4	22	Muž	167	58
5	30	Muž	182	82
6	30	Žena	167	58
7	33	Žena	157	90
8	27	Muž	182	64
9	25	Muž	177	68
10	23	Muž	180	64
11	26	Muž	170	71
12	32	Žena	162	53
13	20	Žena	167	64
14	19	Žena	160	50
15	23	Muž	165	64
16	24	Muž	180	54
17	23	Muž	167	57
18	23	Muž	177	64
19	22	Muž	167	64
20	24	Žena	160	44

Signály jsou v databázi uloženy již v předzpracovaném stavu a neobsahují žádné neplatné datové body. Ojedinele se však při experimentu stalo, že při snímání signálů tepové frekvence a saturace došlo k výpadku měření způsobeným uvolněním či po-

sunutím manžety. V takovém případě byly chybějící záznamy nahrazeny posledními platnými vzorky. Podrobnější údaje o tom, jaké metody byly použity pro předzpracování signálů, však studie [9] neuvádí. Vyobrazení surových signálů je znázorněno na obrázku 3.2. V tabulce 3.1 jsou základní informace o subjektech, na kterých byla data měřena.

Tato databáze je volně přístupná na webovém portálu PhysioNet z PhysioBank databáze jako A Non-EEG Dataset for Assessment of Neurological Status a je pro tuto práci stěžejní zejména pak v praktické části, kdy jsou data z této databáze použity pro návrh, testování a vyhodnocení algoritmu. Značná výhoda této databáze tkví v tom, že obsahuje anotace psychických stavů, oznamující časové okamžiky, kdy byl subjekt vystaven stresorům a kdy nikoliv.

## 3.2 Stress Recognition in Automobile Drivers Dataset

Tvůrce databáze, Jennifer A. Healey, společně s Rosalind W. Picard navrhli experiment, při kterém bylo monitorováno 17 zdravých subjektů během jízdy v automobilu na dálnicích, zpoplatněných silnicích a městských ulicích v Bostonu, Massachusetts za účelem prozkoumání proveditelnosti automatizovaného rozpoznání stresu. Předem stanovená trasa, po které se subjekty během experimentu pohybovaly, byla navržena tak, aby je vedla do situací spojených s různou úrovní stresu. [18]

Záznamy od 16 subjektů trvají mezi 65 – 93 minutami. Výjimkou je subjekt 17, který má záznam rozdělený na dvě části a trvá 29 a 25 minut. [18]

Sada dat se celkově skládá z 6 biologických signálů, kterými jsou:

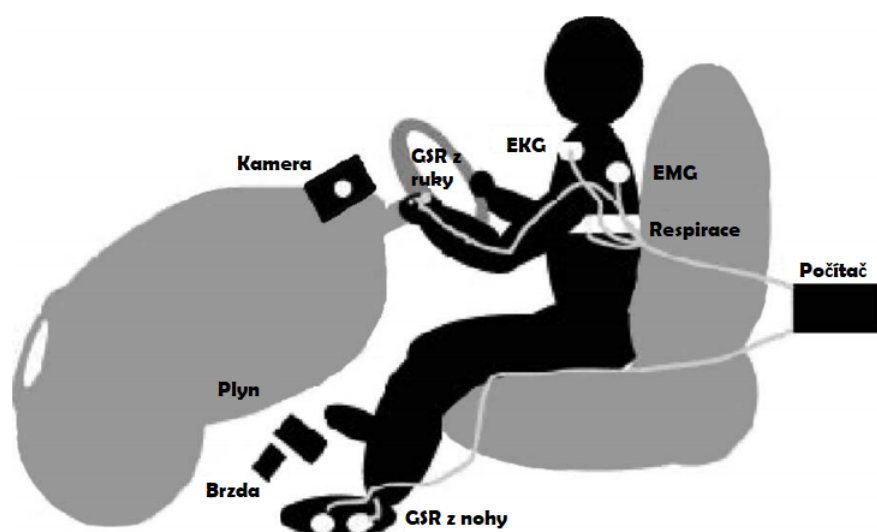
- EKG,
- EMG,
- respirace,<sup>3</sup>
- HRV,
- GSR z ruky a nohou. [18]

Měření těchto signálů probíhalo pomocí 4 typů senzorů, celkově však fyziologických senzorů bylo 5. Senzor pro měření záznamu EKG byl umístěn na hrudi. EKG elektrody byly konfigurovány tak, aby docházelo k minimalizaci pohybových artefaktů při řízení a zároveň docházelo k maximalizaci R vln, jejichž detekcí bylo možno dopočítat signál HRV. Senzor pro měření elektromyografického signálu byl umístěný

---

<sup>3</sup>také nazývána jako saturace krve kyslíkem (SpO<sub>2</sub>)

na levém rameni, konkrétně na trapézovém svalu, který se jeví jako vhodný indikátor emočního stresu. Dva senzory byly použity pro zaznamenání vodivosti kůže. Tyto senzory byly umístěny na dlani levé ruky pomocí elektrod na ukazováčku a prostředníčku a na chodidle levé nohy elektrodami situovanými na jeho dvou obloucích. Signál respirace byl měřen Hallovým elastickým senzorem připevněným kolem bránice subjektu, který zaznamenával expanzi hrudní dutiny. Na obrázku 3.3 je vyobrazeno schéma zapojení všech těchto senzorů na měřený subjekt během jízdy automobilem. [18]




Obr. 3.3: Umístění senzorů během experimentu, převzato z [18]

Všechny senzory byly v upraveném voze řady Volvo S70 připojeny k AD převodníku FlexComp a následně k vestavěnému počítači v zadní části tohoto vozu. [18]

Signály snímané senzory byly vzorkovány rozdílnou vzorkovací frekvencí z důvodu zachycení potřebné informace pro každý signál a omezené vzorkovací frekvenci AD převodníku FlexComp. Signál EKG byl vzorkován vzorkovací frekvencí 496 Hz, respirace a vodivost kůže měly vzorkovací frekvenci 31 Hz a signál EMG 15,5 Hz. Ve voze byly také přítomny 3 digitální kamery pro snímání subjektu a trasy během experimentu. [18]

Na obrázku 3.4 je příklad signálů, zaznamenaných během experimentu s přiloženou informací o relativní době trvání jednotlivých událostí. Vertikální jednotky jednotlivých signálů nejsou zobrazeny, jelikož je každý signál je upraven tak, aby zobrazoval potřebné množství detailů. [18]



Obr. 3.4: Příklad signálů zaznamenaných během experimentu, převzato z [18]

Celkem bylo dokončeno 27 jízd, z nichž šest bylo absolvováno řidiči, kteří se zúčastnili experimentu pouze jednou a 3 jej absolvovali sedmkrát po dobu několika dní. Některé sady dat se však ukázaly být nekompletní např. z důvodu pádu senzoru vodivosti kůže z ruky během experimentu či velkému zašumění signálu EKG, a tudíž nemožnosti extrakce R-R intervalů (R vln) nezbytné pro dopočítání signálu HRV nebo došlo ke kompletní ztrátě sady dat z důvodu náhodného přepsání této sady. [18]

Tato databáze obsahuje záznamy stresových reakcí během reálných situací na rozdíl od např. databáze A Non-EEG Dataset for Assessment of Neurological Status, popsané v kapitole 3.1, u které byly záznamy pořízené v laboratorních podmínkách. [18]

### 3.3 Detection of stress patterns from GSR sensor dataset

Vědci Jorn Bakker, Mykola Pechenizkiy a Natalia Sidorova z Univerzity Techniky v Eindhovenu se ve své studii [19] věnují stanovení stresu pomocí GSR senzorů. Realizovali proto pilotní terénní studii, kdy shromáždili data z GSR senzorů pomocí hodinek v normálních (nelaboratorních) podmínkách. [19]

Studie byla zrealizována za účelem zavedení vhodných strategií pro zvládnání stresu u zaměstnanců na pracovištích, které by minimalizovaly negativní vliv stresu na jejich zdraví. [19]

GSR data byla měřena na pěti pracovnících v časovém intervalu 4 týdnů pomocí hodinek, které měli na sobě během své pracovní doby. Celkově bylo provedeno 72 měření, z nichž 26 bylo následně vyloučeno z důvodů malé variability GSR dat nebo nedostatečného použitelného signálu vlivem špatného kontaktu senzorů s pokožkou. Ve zbývajících 56 měření byly vizuálně anotovány změny v GSR signálech, kterých bylo dohromady 368, což činí zhruba 6,5 změn během 1 měření. Shrnutí těchto poznatků je uvedeno v tabulce 3.2. [19]

Tab. 3.2: Hlavní charakteristiky datasetu, převzato z [19]


Počet pracovníků	5
Počet měření	72
Průměrný počet měření na pracovníka	14
Celkový počet změn v GSR signálech	368
Průměrný počet změn během 1 měření	6,5
Průměrné množství vzorků z 1 měření	98721

Průměrné množství vzorků naměřených během jednoho den na pracovníkovi bylo 98721, jelikož vzorkovací frekvence byla 4 Hz a průměrná pracovní doba trvá 8 hodin. [19]

Pracovníci měli mimo jiné za úkol, vést si záznamy o schůzkách, které během měření (pracovní doby) proběhly s přiloženou informací o tom, jaké pocity před proběhnutím dané schůzky pociťovali (např. natěšený, neutrální, nervózní). [19]

Při vyhodnocení úspěšnosti detekce však těchto přiložených informací nebylo využito vzhledem k tomu, že studie měla za cíl detekovat GSR vrcholy a bylo zjištěno, že mnoho těchto vrcholů se nevyskytovalo během žádných ze zaznamenaných schůzek. Dalším faktem je též to, že stres spojený se schůzkou mohl předcházet události, znázorněno na obrázku 3.5 nahoře, kdy se úroveň GSR postupně zvyšuje před stresující událostí (červeně lemovaný vrchol) či mohl nadále ovlivňovat pracovníka

po proběhnutí schůzky (červeně lemovaný vrchol na obrázku 3.5 dole), kdy se úroveň GSR nevrací na úroveň, kterou měla před proběhnutím schůzky, což může znamenat, že pracovník je stále zaneprázdňen tím, co se stalo a je v neustálé stresové situaci, tudíž nedošlo k relaxačnímu procesu. [19]



Obr. 3.5: Stres před schůzkou (nahore) a po schůzce (dole), převzato z [19]

## 4 METODY AUTOMATICKÉ DETEKCE STRESU

Tato kapitola slouží jako rozšíření kapitoly 3, ve které byly uvedeny a popsány databáze biologických signálů, které posloužily k detekci stresového stavu. V následujících podkapitolách jsou popsány metody automatické detekce stresu, kterými se mimo jiné články, uvedené v kapitole 3, zabývají. Tyto publikace slouží také jako podpůrné texty pro vytváření vlastního programu detekce stresu, kterým se zabývá kapitola 6.

### 4.1 Posouzení a vizualizace neurologického stavu pomocí metody GMM

V článku [9] se autoři zaměřují na vizualizaci a hodnocení neurologického stavu pomocí aplikace shlukovací metody modelu Gaussovského mixu (Gaussian Mixture Model). Byl navrhnut experiment, jenž měl subjekty uvést do daných neurologických stavů a byla též použita redukční technika pro vizualizaci a analýzu dat ve 2D/3D prostoru. Popis experimentu, způsob snímání a popis databáze byl proveden v kapitole 3.1. V této podkapitole bude popsáno, jakým způsobem autoři článku data zpracovali a vyhodnotili. [9]

Pět biosignálů <sup>1</sup>, které se prokázaly jako vhodné ukazatele různých neurologických stavů, bylo v navrženém experimentu neinvazivně snímáno <sup>2</sup> pomocí nositelných senzorů, jež byly popsány v kapitole 3.1. Dvě zařízení, zaznamenávající biologické signály, je snímali s rozdílnou vzorkovací frekvencí a existují tedy vždy 2 datové soubory na subjekt. Konkrétně byly signály pohybů zápěstí, teploty a elektrodermální aktivity snímány se vzorkovací frekvencí  $F_{vz}=8$  Hz a signály tepové frekvence a saturace vzorkovací frekvencí  $F_{vz}=1$  Hz. U dat získaných z prvního zařízení došlo následně k osminásobnému podvzorkování tak, aby všechny signály měly shodnou vzorkovací frekvenci 1 Hz a mohlo dojít k tomu, že každý datový bod bude odpovídat 1 sekundě dat. [9]

#### 4.1.1 Shlukovací metoda GMM a vizualizace dat


Po sběru dat provedením experimentu, popsáním v kapitole 3.1, a předzpracování odstraněním neplatných datových bodů byla data standardizována vydělením hodnoty každého prvku rozptylem signálu. Pro vyvážení všech neurologických stavů v datovém souboru byly odstraněny data z druhé, třetí a čtvrté relaxace a byla

---

<sup>1</sup>konkrétně se jedná o tzv. non-EEG či extracerebrální signály

<sup>2</sup>tj. senzory nepronikají do organismu

ponechána pouze data z první relaxace pro následnou analýzu. Na tyto data byla aplikována shlukovací metoda modelu Gaussovského mixu (metoda GMM), která data od každého subjektu seskupila do čtyřech různých neurologických stavů (jak již známo z kapitoly 3.1, čtyři neurologické stavy představují fázi relaxace, fyzický, emoční a kognitivní stres). Po vizualizaci stresových stavů a relaxační fáze došlo k redukci dimenze dat do 2D/3D prostoru technikou nelineární redukce rozměrů t-SNE (t-distributed Stochastic Neighbor Embedding, česky t-distribuované stochastické usazování sousedů), kterou autoři článku upřednostňují před metodou PCA z důvodu nemožnosti PCA zachovat vzdálenost sousedních bodů při procesu redukce rozměrů. Srovnání těchto dvou metod při seskupování neurologických stavů je ukázáno na obrázku 4.1, kde je vidět, že technika t-SNE (vpravo) lépe oddělila neurologické stavy než PCA (vlevo). Lze též podotnout, že rozměry P1, F1 a P2, F2 nepředstavují původní rozměry, ale 2 nové dimenze. T-SNE nejprve v původním prostoru spočítá párové podobnosti všech datových bodů, tedy určitou míru, která blízkým párům přiřadí vysoké číslo a vzdáleným párům číslo malé. V prostoru o nižší dimenzi se pak iterativně snaží rozmístit datové body původního prostoru tak, aby pravděpodobnostní rozdělení podobností všech párů datových bodů bylo co nejpodobnější rozložení původnímu. Výsledky namapované do 2D a 3D prostoru poté poskytují představu o tom, jak se jednotlivé hodnoty signálů liší mezi různými neurologickými stavy. Obě vizualizace mají své výhody a nevýhody. Ve 2D prostoru je jednodušší sledovat datové body než ve 3D prostoru, avšak 3D prostor umožňuje zkoumání datových bodů z různých úhlů. [9]



Obr. 4.1: Vizualizace dat do 2D prostoru v různých neurologických stavech pro subjekt 14, srovnání PCA (vlevo) a t-SNE (vpravo) [9]



### 4.1.2 Výsledky studie

Shlukovací metoda GMM dokázala oddělit 4 neurologické stavy s celkovou přesností 84,6 %. Podrobnější výsledky z hlediska matice záměn, senzitivity a specifity jsou uvedeny v tabulce 4.1 dle článku [9].

Tab. 4.1: Podrobnější výsledky: matice záměn, senzitivita a specifita pro 4 neurologické stavy, průměr ze všech 20 subjektů, převzato z [10]

Fáze	Relax	Fyzický	Emoční	Kognitivní
Relax	92,4 %	0,1 %	5,4 %	0,3 %
Fyzický stres	1,8 %	90,9 %	3,8 %	3,5 %
Emoční stres	13,4 %	5 %	65,8 %	15,8 %
Kognitivní stres	1 %	1,4 %	10,2 %	87,3 %
Senzitivita	85,4 %	93,3 %	77,2 %	86,4 %
Specifita	93,6 %	91,1 %	70,2 %	86,4 %

## 4.2 Zhodnocení úspěšnosti klasifikace stresu pomocí klasifikátorů využívající strojového učení

Carlos A. Ramírez-Fuentes společně s dalšími vědci z UPIITA v Mexico City navrhli postup klasifikace stresu použitím lineárních a nelineárních příznaků extrahovaných z fyziologických signálů za účelem vytvoření klasifikátorů využívajících metod strojového učení. [10]

### 4.2.1 Použitá sada dat

Pro práci byla použita sada dat z databáze PhysioNet, popsána v kapitole 3.2, která obsahuje záznamy několika fyziologických signálů od 16 subjektů. U pěti subjektů však byla nalezena absence některých informací potřebných pro následnou práci, takže ve výsledku byly využity záznamy fyziologických signálů pouze od jedenácti subjektů, které obsahovaly kompletní informace. [10]


Signály byly zaznamenávány při projíždce subjektů po předem stanovené trase, která byla navržena tak, aby tyto subjekty vedla do situací spojené s různou úrovní stresu. [10] [18]

Již zmíněná sada dat se skládá celkově z 6 fyziologických signálů, kterými jsou EKG, EMG, respirace, HRV a GSR měřené na dlani levé ruky a chodidle levé nohy. I přes původně rozdílné vzorkovací frekvence těchto signálů se všechny signály nakonec podvzorkovaly na frekvenci  $F_{vz} = 15,5$  Hz. [10]

## 4.2.2 Předzpracování dat a extrakce příznaků

Signály HRV a respirace byly zatíženy značným množstvím vysokofrekvenčního šumu. Tento šum byl ze signálů odstraněn využitím víceúrovňové diskrétní vlnkové transformace, která rozložila tyto 2 signály na aproximace a details za použití mateřské vlnky typu Daubechies (Db1). HRV signál byl rozložen na 8. úroveň, kde z něho byla získána a odstraněna 8. aproximace. Respirační signál byl rozložen pouze na 6. úroveň, kde byla 6. aproximace získána a odstraněna. Následně byly oba signály zrekonstruovány aplikací víceúrovňové inverzní diskrétní vlnkové transformace. [10]

Signál HRV před a po aplikaci víceúrovňové diskrétní vlnkové transformace znázorňuje obrázek 4.2. [10]



Obr. 4.2: Signál HRV před a po filtraci [10]

Jak v HRV, tak v respiračních signálech byly zachovány informace související s těmito signály a nesouvisející informace jako např. vysokofrekvenční šum byly sníženy. [10]

Po odstranění vysokofrekvenčního šumu ze signálů HRV a respirace, byly z každého signálu extrahovány lineární a nelineární příznaky. Tyto příznaky byly vypočítány z nepřekrývajících se segmentů trvajících 5 minut, pořízených během celé doby jízdy. [10]

Pro charakterizaci nelineárních vlastností signálů byly extrahovány dva příznaky: přibližná entropie a korelační rozměr. [10]

*Přibližná entropie  $ApEn$*  (angl. Approximate Entropy) kvantifikuje nepravidelnost časové řady. Pro výpočet přibližné entropie bylo nutné si předem stanovit tyto tři parametry: [10]

- velikost okna  $m$
- toleranci srovnávací hodnoty  $r$

- délku dat  $N$

Následně byl vypočítán index  $\phi^m(r)$  a nakonec přibližná entropie  $ApEn$  se dvěma různými hodnotami  $m$ , a to s  $m = 2$  a  $m = 3$  dle vzorce 4.1: [10]

$$ApEn(m, r, N) = \phi^m(r) - \phi^{m+1}(r) \quad (4.1)$$

*Korelační rozměr CD* byl vypočítán v rozsahu hodnot  $r$  s parametry  $m = 2$  a  $m = 3$  jako: [10]

$$CD = \lim_{r \rightarrow 0} \lim_{N \rightarrow \infty} \left[ \frac{\log \phi^m(r)}{\log(r)} \right] \quad (4.2)$$

Pro další analýzu ApEn a CD byl již dále uvažován jenom parametr velikosti okna  $m = 3$ , protože zvyšoval variace mezi dvěma stresovými stavy (nízký a vysoký stres) narozdíl od parametru  $m = 2$ , který poskytoval nadbytečné informace. [10]

Pro charakterizaci lineárních vlastností signálu byly extrahovány tři příznaky: energie, střední a směrodatná odchylka každého segmentu signálu. Bylo zjištěno, že energie a střední odchylka vykazují velmi podobné variace a zachovávají stejné změny v průběhu času. Ačkoliv se oba příznaky liší ve svých velikostech, příznaky byly standardizovány tak, aby vyhovovaly klasifikátorům. Pro další analýzu byla uvažována pouze energie. [10]

### 4.2.3 Klasifikátory strojového učení

Pro klasifikátory strojového učení byly na základě předchozích výzkumných prací vybrány 4 ze 6 dostupných signálů: HRV, respirace a GSR z ruky a nohy. Vzniklý datový soubor byl rozdělen na 2 části, které sloužily jako trénovací množina (80 % dat) a 20 % dat bylo použito jako testovací množina pro testování přesnosti šesti různých klasifikátorů strojového učení, které byly vybrány na základě jejich schopnosti zvládat malé množství dat. Vybrané klasifikátory byly 1000 krát testovány a jejich přesnost byla zprůměrována, aby nedošlo k přeučení. Konkrétní použité klasifikátory byly následující: [10]

- Algoritmus K-nejbližších sousedů (K-nearest neighbours (K-NN)),
- Metoda podpůrných vektorů s lineárním jádrem (Support vector machines (SVM) with a linear kernel),
- Metoda podpůrných vektorů s gaussovským jádrem (Support vector machines (SVM) with a Gaussian kernel),
- Naïve Bayesův klasifikátor (Naïve Bayes classifier),
- Metoda náhodný les (Random forest classifier),

- Metoda logické regrese (Logistic regression). [10]

#### 4.2.4 Výsledky jednotlivých klasifikátorů

Nejprve bylo bráno v potaz všech 5 příznaků pro již zmíněných šest klasifikátorů. Žádný z nich však nepřekročil hranici přesnosti 80 %, protože ne všechny příznaky poskytují rozdílné informace. Z obou GSR signálů byl nakonec vybrán pouze GSR z nohy, protože vykazoval stabilnější signál oproti GSR z ruky, kde ruka řidiče měla během snímání větší mobilitu, což mělo za následek větší pohyb senzorů a tím se způsobovaly některé artefakty při záznamu signálu. [10]

Dále bylo zjištěno, že 3 příznaky postačí k nejlepší interpretaci klasifikace. Těmito příznaky byly korelační rozměr HRV, respirace a GSR nohou. V tabulce 4.2 jsou uvedeny konečné přesnosti každého klasifikátoru. [10]

Tab. 4.2: Přesnost klasifikátorů s CD HRV, respirace a GSR nohy, převzato z [10]

<b>Klasifikátor</b>	<b>Přesnost [%]</b>
KNN (n = 5)	76.18
SVM (lineární jádro)	77.36
SVM (gaussovské jádro)	76.21
Naïve Bayes	70.81
Náhodný les	75.48
Logická regrese	81.39

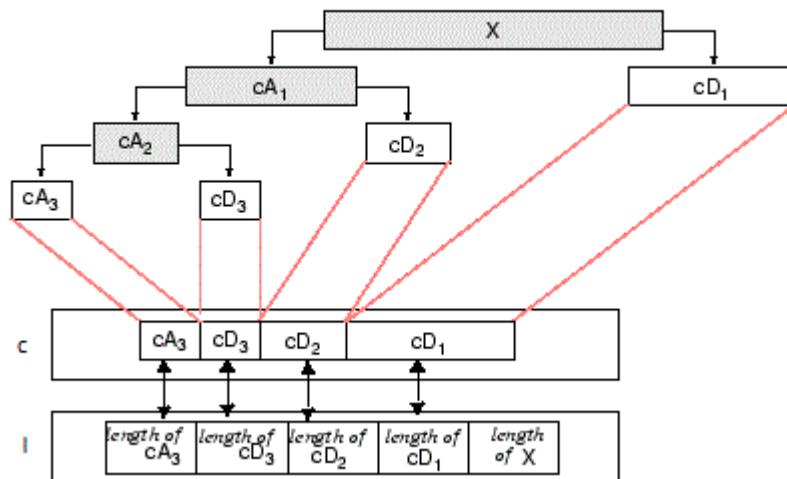
Z výsledků přesností je patrné, že nejlepších výsledků dosáhl klasifikátor logistické regrese s přesností 81,39 % při použití pouze korelačního rozměru signálů jako jediného příznaku. Důvodem nejlepšího výkonu klasifikace metodou logistické regrese autoři článku spatřují v tom, že je to lineární klasifikátor, který dobře funguje i při malém množství dat. Při uvažování korelačního rozměru jako jediného příznaku se nezlepšila pouze přesnost klasifikátoru logistické regrese, ale průměrná přesnost všech šesti klasifikátorů se zlepšila o více než 5 %. [10]

# 5 TEORETICKÝ ÚVOD DO PRAKTICKÉ ČÁSTI PRÁCE

V praktické části práce je užíváno některých pojmů a termínů, o kterých se autor práce domnívá, že by potřebovali hlubší kontext. Na tento popud vznikla následující kapitola, ve které jsou rozvedeny tyto pojmy a termíny z teoretického hlediska.

## 5.1 Víceúrovňová diskretní vlnková transformace

Víceúrovňová diskretní vlnková transformace rozloží vstupní signál  $X$  filtrem typu horní propust na aproximace ( $cA$ ) a detaily ( $cD$ ), viz. obrázek 5.1. Detaily ve spektru představují vysoké frekvence a aproximace frekvence nízké. Víceúrovňovou diskretní vlnkovou transformací se v každé nové úrovni odstraňují detaily a zůstávají aproximace (nízkofrekvenční složky), na které je znovu aplikována horní propust a opět dochází k rozložení na aproximace a detaily. Na námi zvolené úrovni poté může dojít k odebrání aproximačního pásma a signál se zrekonstruuje aplikací víceúrovňové inverzní diskretní vlnkové transformace. Tímto způsobem můžeme ze signálů odstranit jejich zatížení např. vysokofrekvenčním šumem. [20] [21]



Obr. 5.1: Princip fungování víceúrovňové diskretní vlnkové transformace, převzato z [21]

Ačkoliv má ve strojovém učení předzpracování signálů (tedy např. odstranění vysokofrekvenčního šumu) nezanedbatelný vliv na výslednou přesnost modelu, bylo zjištěno, že se signály z databáze, s kterou praktická část pracuje, nacházejí již v


základním předzpracovaném stavu a neobsahují žádné neplatné datové body (viz kapitola 3.1 a později 6.1.1 a 6.2.1) [9]. Z toho důvodu bylo rozhodnuto ponechat způsob předzpracování víceúrovňovou diskretní vlnkovou transformací jako volitelný prvek pro případ, že by byl algoritmus otestovaný na datech, která se v základním předzpracovaném stavu ještě nenacházejí (tedy např. jsou zatíženy vysokofrekvenčním šumem).

Jako hlavní podpůrný text a inspirací pro následné vytvoření funkce pro předzpracování signálů víceúrovňovou diskretní vlnkovou transformací v MATLABu, byla studie [10], kde její autoři ze signálu tepové frekvence odstranili pouze 8. aproximační pásmo a aproximační pásmo šesté u signálu saturace krve mateřskou vlnkou typu Daubechies (Db1) (viz. také kapitola 4.2.2).

## 5.2 Extrakce příznaků

Extrakce příznaků (angl. Feature Extraction) transformuje původní data do vektoru příznaků, jenž mohou mít zcela odlišnou interpretaci. Předpokládá se však, že extrahované příznaky budou obsahovat relevantní informace vstupních dat. [22] [23]

Proces extrakce příznaků je vyobrazen na obrázku 5.2 společně s rovnicí 5.1. Cílem extrakce příznaků je nalezení množiny  $F'$  (pravá strana rovnice) z původní množiny  $F$  (levá strana rovnice), která maximalizuje schopnost algoritmu správně klasifikovat data.



Obr. 5.2: Extrakce příznaků, [24]

$$\{f_1, \dots, f_i, \dots, f_n\} \rightarrow \{g_1(f_1, \dots, f_n), \dots, \{g_j(f_1, \dots, f_n), \dots, \{g_m(f_1, \dots, f_n)\} \quad (5.1)$$

Extrahování příznaků je prováděno pomocí funkcí, kterými jsou např. směrodatná odchylka, průměr, maximum a minimum nebo energie signálu.

Jedná se o jeden ze stěžejních postupů předzpracování dat ve strojovém učení, který má značný vliv na celkovou úspěšnost klasifikace.


## 5.3 Selekcce příznaků

Selekcce příznaků (angl. Feature Selection) je následuje po extrakci příznaků, a je prováděna za účelem redukce dimenzionality snížením počtu příznaků a výběru takové podmnožiny příznaků, která správně klasifikuje data a maximalizuje rozlišitelnost různých tříd takovým způsobem, aby se podařilo zachovat co nejvíce původní informace. [22]

Premisa pro použití této metody je, že některé extrahované příznaky mohou být pro klasifikaci redundantní nebo irelevantní a jejich odstraněním nedojde k velké ztrátě informace. Neprovedením tohoto kroku se může zkomplikovat celý proces učení a může dojít k výraznému snížení výkonu klasifikačního algoritmu (Classifier Performance). [23]

Cílem selekcce příznaků je poté nalezení množiny  $F' \subseteq F$ , což znamená, že do množiny  $F'$  z množiny  $F$  jsou vybrány ty pouze ty příznaky, jenž jsou pro klasifikaci nejpodstatnější.

Grafické znázornění selekcce příznaků je vyobrazeno na obrázku 5.3 společně s rovnicí 5.2:



Obr. 5.3: Selekcce příznaků, [24]

$$\{f_1, \dots, f_i, \dots, f_n\} \rightarrow \{f_{i_1}, \dots, f_{i_j}, \dots, f_{i_m}\}, \quad (5.2)$$

kde  $i_j \in \{1, \dots, n\}$ ;  $j = 1, \dots, m$ ;  $i_a = i_b \Rightarrow a = b$ ;  $a, b \in \{1, \dots, m\}$ .

### 5.3.1 Analýza hlavních komponent

Analýza hlavních komponent (Principal component analysis – PCA) posuzuje a pro-  
věřuje kvalitu mnohorozměrných dat. PCA se řadí mezi symetrické metody <sup>1</sup> zpra-  
cování vícerozměrných dat určené zejména k potlačení šumu nebo redukci dimenze  
dat (počtu příznaků). [25]

<sup>1</sup>což znamená, že příznaky v ní mají stejné postavení

Cílem metody PCA je nahradit původní, korelované příznaky, jež jsou lineárně závislé, tzv. hlavními komponentami, které již nejsou vzájemně korelované (jsou ortogonální). Výsledkem je redukování dimenze dat, tedy snížení původního počtu příznaků, aniž by došlo ke značné ztrátě informace. Hlavní komponenty jsou prvky v nové množině, jež jsou lineární kombinací původních příznaků a očekává se od nich, že budou co nejlépe reprezentovat původní příznaky, tedy budou maximálně snižovat variabilitu čili rozptyl dat. [26]

Vstupem metody PCA je matice  $X$ , která má data uspořádána do rozměru  $n \times p$  [26]:

$$X_{n \times p} = \begin{bmatrix} X_{11} & X_{12} & \dots & X_{1p} \\ X_{21} & X_{22} & \dots & X_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ X_{n1} & X_{n2} & \dots & X_{np} \end{bmatrix},$$

kde řádky  $n$  jsou reprezentovány počty vzorků a sloupce  $p$  počty původních příznaků. [26]

Výstupem je poté matice  $Z$ , která je rekonstrukcí matice  $X$ , kdy z matice  $X$  je vybráno pouze těch  $k$  hlavních komponent, které nejvíce přispívají ke snížení celkové variability dat. [26]

K rozlišení  $n$  vzorků matice  $X$  tedy nepřispívají ty původní příznaky, které mají malý či nulový rozptyl. Tímto způsobem umožňuje metoda PCA analyzovat pouze menší počet nekorelovaných hlavních komponent namísto velkého množství původních příznaků. [26]

## 5.4 Trénovací, testovací sada a křížová validace

Ve strojovém učení bývají obvykle data vhodně rozdělena na dvě datové sady - trénovací a testovací (v některých případech na tři: trénovací, validační a testovací). K naučení modelu se použijí trénovací data a otestování úspěšnosti tohoto modelu poté probíhá na testovacích datech, což jsou data, jež nejsou součástí trénovacích dat a u kterých je předem známé skutečné správné zařazení do daných tříd. Pokud by se použila shodná data pro trénování i testování modelu, mohlo by dojít k tzv. přeučení modelu, kdy model správně zařazuje natrénovaná data, ale zato selhává u dat nově nasazených. [27]

Výsledky klasifikace potom mohou být nadhodnoceny<sup>2</sup> či podhodnoceny. Použitím křížové validace je snaha těmto situacím předejít. Křížová validace odhaduje, jak dobře daný model, natrénovaný na trénovacích datech, bude schopný pracovat s

---

<sup>2</sup>nadhodnocením dat je myšleno, že model je příliš navyklý na trénovací data

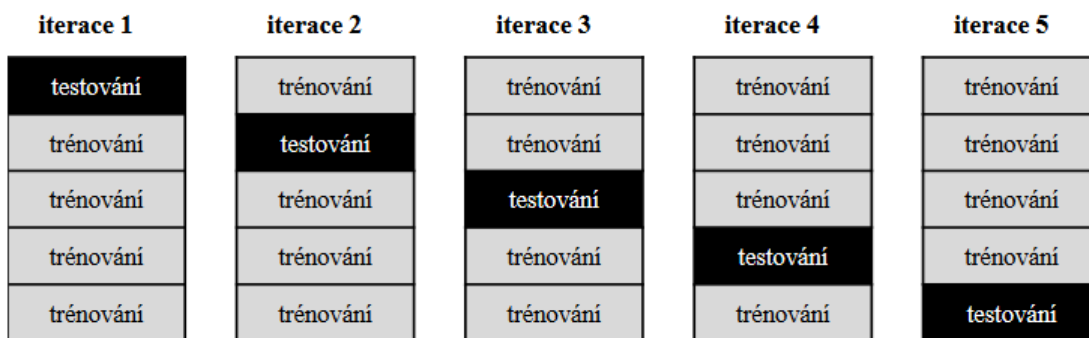


testovacími daty. Křížovou validací je získáván objektivní, nezaujatý odhad predikce chyby, který je důležitý pro předpověď budoucí predikční přesnosti spolu s výběrem vhodného klasifikátoru ze setu. [27] [28]

Křížovou validací je set dat rozdělen na několik komplementárních subsetů a následně je provedeno trénování modelu výběrem jednoho ze subsetů. Zbylé data se poté použijí k ověření přesnosti. Aby byla objektivnost co nejvyšší, je provedeno několik opakování s tím, že v každém cyklu je vybrán jiný subset k natrénování. [28]

### 5.4.1 K-násobná křížová validace

Existují různé typy křížových validací. Mezi nejpoužívanější patří *K-násobná křížová validace* (Křížová validace o k-přeloženích, angl. K-fold cross validation). Z původního souboru dat je u tohoto typu křížové validace vytvořeno k subsetů, z nichž vždy jeden je vybrán pro validaci a zbylých k-1 subsetů je využito pro trénování modelu, viz obrázek 5.4, kde validační subset je znázorněn jako „testování“, jelikož se v každém kroku ověřuje jeho přesnost. Tento proces je k krát opakován, vždy s jiným použitým subsetem pro validaci. Značnou výhodou tohoto typu křížové validace je ta, že všechna data jsou využita k trénování i validaci. V praktické části práce byla využita tzv. *10-fold cross validation* (kdy k=10), tedy křížová validace o 10 přeloženích, která je většinou též v praxi hojně využívána. [27] [28]



Obr. 5.4: Rozdělení datové sady na trénovací a validační při k-násobné křížové validaci (zde k=5), převzato z [27]

Speciálním případem je potom tzv. Leave-one-out cross validation neboli „odlož-jeden-mimo“ křížová validace, kdy k=N a funguje tak, že z celého souboru dat je v každé z N iterací vybrán jeden vzorek pro validaci a zbylých N-1 slouží na trénování. Tento typ křížové validace je časově i výpočetně nejnáročnější a je tedy zejména vhodný pro malé soubory dat. [27] [28]

## 5.5 Metriky pro vyhodnocení úspěšnosti klasifikace modelů

Nezbytnou součástí každého algoritmu strojového učení je jeho vyhodnocení na datech, která se neúčastnila procesu učení modelu, tedy na datech testovacích. Pro jeho vyhodnocení se používá určitých metrik, jako je např.: [29]

- Klasifikační přesnost,
- Matice neurčitosti (Confusion Matrix),
- Plocha pod křivkou (AUC),
- F1 Skóre. [29]

Častým problémem však bývá okolnost, že model podává uspokojivé výsledky pro jednu z vyhodnocovacích metod, ale zcela špatné pro metriku jinou. Nejvíce využívaná z metrik zmíněných výše je klasifikační přesnost pro měření výkonu výsledného modelu. Nelze se však spokojit pouze s touto metrikou pro vyhodnocení, jelikož by nešlo k dostatečnému posouzení celkové kvality modelu. [29]

### 5.5.1 Klasifikační přesnost

Klasifikační přesnost je poměr počtu správných predikcí k celkovému počtu všech vstupních vzorků, viz. vzorec 5.3.

$$Přesnost = \frac{\text{Počet správných predikcí}}{\text{Celkový počet provedených predikcí}} \quad (5.3)$$

Tento způsob vyhodnocení modelů ale může být problémový v případech, kdy počet vzorků různých tříd je nerovnoměrně zastoupený. Tehdy může nastat situace tzv. falešné přesnosti modelu, kdy jsou vzorky přiřazovány té třídě, která má větší zastoupení. K takovému případu by mohlo dojít například při vyhodnocování určitého typu stresu, kdy je určitý typ stresu navozený po kratší dobu než třeba relaxační fáze nebo ostatní typu stresů dohromady. [29]

### 5.5.2 Matice neurčitosti

Matice neurčitosti poskytuje jako výstup matici, tvořící základ pro další typy metrik a popisuje celkový výkon modelu. Pokud je přítomný klasifikátor, který předpovídá třídu pro každý vstupní vzorek a je dostupné správné rozdělení vzorků, lze využít matici neurčitosti jako metodu pro vyhodnocení ve tvaru: [29]

Tab. 5.1: Matice neurčitosti, [29]

	<b>Pozitivní predikce</b>	<b>Falešná predikce</b>
<b>Opravdu pozitivní</b>	Správně pozitivní	Falešně negativní
<b>Opravdu negativní</b>	Falešně pozitivní	Správně negativní

kde čtyři hodnoty obsažené v matici jsou definovány pro 2 třídy vzorků (0 a 1) následovně: [29]

- Správně pozitivní: případy, kdy klasifikátor predikuje 1 a opravdová hodnota je též 1.
- Správně negativní: případy, kdy klasifikátor predikuje 0 a opravdová hodnota je též 0.
- Falešně pozitivní: případy, kdy klasifikátor predikuje 1, avšak opravdová hodnota je 0.
- Falešně negativní: případy, kdy klasifikátor predikuje 0, avšak opravdová hodnota je 1. [29]

Klasifikační přesnost lze poté z matice vypočítat jako součet hodnot na hlavní diagonále, jež jsou vyděleny počtem všech vzorků: [29]

$$\text{Klasifikační přesnost} = \frac{\text{Správně pozitivní} + \text{Správně negativní}}{\text{Celkový počet všech vzorků}}. \quad (5.4)$$

### 5.5.3 Plocha pod křivkou (AUC)

Plocha pod křivkou (AUC - Area Under Curve) klasifikátoru je rovna pravděpodobnosti toho, že model klasifikuje náhodně pozitivní příklad s větší vahou, než než náhodně negativní případ. Pro definování AUC jsou důležité tyto 2 pojmy: [29]

- Četnost správně pozitivní hodnoty (TPR - True Positive Rate), také nazývána jako senzitivita, je definována jako: [29]

$$TPR = \frac{TP}{TP + FN}. \quad (5.5)$$

Dle rovnice 5.5 lze říci, že senzitivita představuje poměr správně pozitivních datových bodů k všem opravdu pozitivním datovým bodům. [29]

- Četnost falešně pozitivní hodnoty (FPR - False Positive Rate) je definována jako: [29]

$$FPR = \frac{FP}{FP + TN}. \quad (5.6)$$

Dle rovnice 5.6 lze usoudit, že FPR je poměr falešně pozitivních datových bodů k všem opravdu negativním datovým bodům. [29]

TPR i FPR jsou definovány v rozsahu hodnot od 0 do 1. AUC je poté plocha pod křivkou ROC, což je křivka, která vykresluje 2 parametry, a to právě TPR (osa y) a FPR (osa x). Je tedy zřejmé, že AUC bude mít také rozmezí hodnot od 0 do 1. Pokud bude hodnota AUC malá, tedy bude se blížit 0, znamená to, že model zařazuje hodnoty špatně. Čím větší bude hodnota AUC, tím lépe bude model klasifikovat hodnoty a jeho výkon bude taktéž lepší. [29]

Z FPR lze následně vyjádřit specifitu (TNR) jako:

$$TNR = 1 - FPR = \frac{TN}{TN + FP} \quad (5.7)$$

#### 5.5.4 F1 skóre

F1 skóre je definováno jako harmonický průměr mezi pozitivní prediktivní hodnotou (PPH, Precision) a TPR (senzitivita, Recall). Vztah pro výpočet TPR již byl uveden výše (viz. kapitola 5.5.3). PPH je počet správně pozitivních výsledků, který je vydělený počtem pozitivních výsledků, které jsou predikovány klasifikátorem. PPH je uvedeno v rovnici 5.8: [29]

$$PPH = \frac{TP}{TP + FP} \quad (5.8)$$

F1 skóre je poté možno matematicky vyjádřit jako: [29]

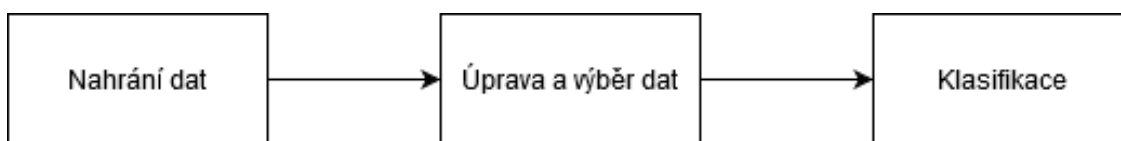
$$F1 = 2 \cdot \frac{1}{\frac{1}{precision} + \frac{1}{recall}} \quad (5.9)$$

F1 skóre počítá přesnost a robustnost klasifikátoru. Vysoká PPH a nižší TPR sice signalizují obrovskou přesnost klasifikátoru, zato je zde však při těchto hodnotách parametrů velké množství hodnot, které klasifikátor obtížně klasifikuje. Z toho důvodu je snaha najít rovnováhu mezi PPH a TPR. Rozsah hodnot F1 skóre se opět pohybuje v rozmezí mezi 0 a 1. Obecně platí, že čím vyšší je F1 skóre, tím je také lepší model. [29]

## 6 PRAKTICKÁ ČÁST PRÁCE

Tato kapitola pojednává a představuje realizaci programu, detekující stres, který byl implementován v programovém prostředí MATLAB (konkrétní verze byla MATLAB R2018a), a má mimo jiné také za úkol klasifikovat stres do různých stavů.

Při vytváření algoritmu byla snaha co nejlépe zachytit stresové fáze a odlišit je od psychického stavu klidové relaxační fáze daného subjektu. Pro tento účel byly využity klasifikační algoritmy pro sestavení sad klasifikačních modelů z vhodně upravených vstupních dat, jejichž klasifikační výkony posléze otestovány. Na obrázku 6.1 je zobrazeno obecné základní schéma programu pro detekci a klasifikaci stresu.



Obr. 6.1: Základní schéma navrženého programu

### 6.1 Základní informace o vstupních datech

Cílem praktické části práce byl návrh systému, jenž bude dobře a spolehlivě detekovat stresové stavy a otestovat je na některé z veřejných databází obsahující biologické signály, které reflektují stres. Jako pravděpodobně nejvhodnější variantou se jeví volně dostupná databáze A Non-EEG Dataset for Assessment of Neurological Status z webového portálu PhysioNet, popsaná v kapitole 3.1. Důvodem tohoto výběru je zejména to, že signály z databáze zaznamenané během experimentu byly snímány komfortní cestou. Dalším důvodem je ten, že data v databázi jsou poskytována ve WFDB formátu a pro každý měřený subjekt obsahují jeden soubor anotací, který označuje přechody psychických stavů, tedy oznamuje časové okamžiky, kdy byl daný subjekt vystaven některému z typu stresů, či byl ve fázi relaxace. [9] [30]

Databáze obsahuje záznamy pěti non-EEG signálů měřených na 20 vysokoškolských studentech, z nichž 14 byly muži a 6 ženy ve věku 19 až 33 let (podrobnější informace o jednotlivých vysokoškolských studentech-subjektech: viz. tabulka 3.1 v kapitole 3.1). Signály byly snímány dvěma zařízeními umístěnými na zápěstích obou rukou. Z toho důvodu existují vždy 2 záznamy na subjekt, každý s rozdílnou vzorkovací frekvencí. První záznam obsahuje 3 signály z akcelerometru (pohyb v osách x, y, z), teplotu pokožky a signál elektrodermální aktivity (EDA), který je vzorkovaný vzorkovací frekvencí  $f_{vz}=8$  Hz. Druhý záznam obsahuje signály tepové

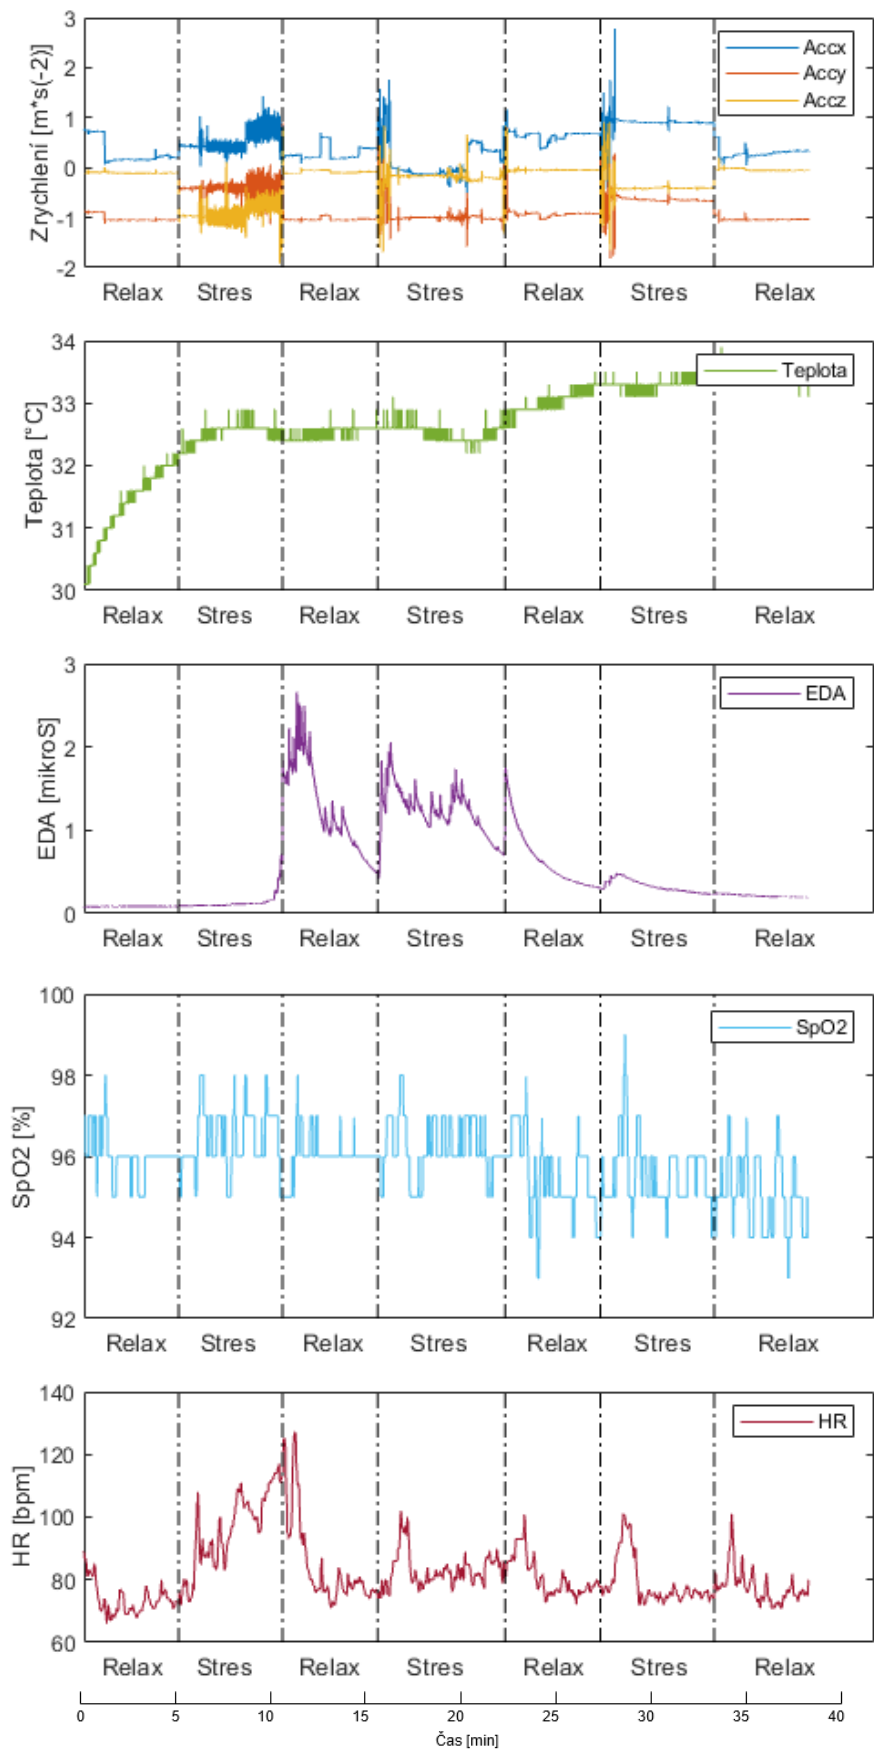
frekvence (HR) a saturace krve kyslíkem ( $\text{SpO}_2$ ) se vzorkovací frekvencí  $f_{vz}=1$  Hz. [9]

Studie [9] měla za cíl rozlišit odezvu subjektů na 4 odlišné vnější podněty (z nichž 3 byly stresory). Pro tento účel byl zrealizován experiment, v jehož průběhu byly subjekty uváděny do fyzického a psychického (emočního a kognitivního) stresu (podrobnější analýza experimentu, viz kapitola 3.1). Mezi jednotlivými stresovými stavy byly subjekty vždy uvedeny do 5-ti minutové relaxační fáze. Samotný experiment je též zahájen a ukončen navozením subjektů do relaxační fáze. Celkem je tedy možno rozlišit 7+1 psychických stavů. V rámci kognitivního stresu totiž jemu v anotacích předchází krátký časový úsek, kdy autoři experimentu subjektům vysvětlovali následující část měření (tedy počítání po sedmi pozpátku a Stoopův test) a tento úsek stanovili jako vystavení se krátkému emočnímu stresu. [9]

### 6.1.1 Nahrání dat a jejich základní analýza

Aby bylo možné s daty z databanky PhysioNetu pracovat, byl do MATLABu přidán softwarový balík aplikací a knihoven WFDB (konkrétní verze byla 0.10.0), který je možné volně stáhnout na stránkách PhysioNetu, umožňující nahrání, zobrazení, zpracování a analýzu signálů a vytváření nových záznamů.

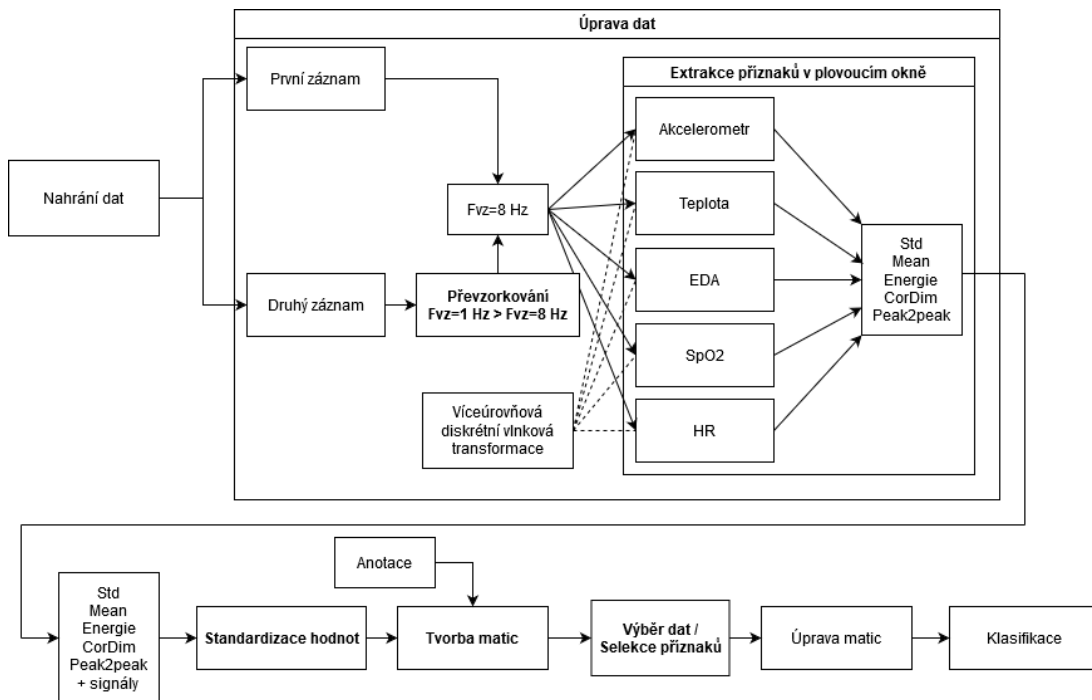
Další krokem bylo seznámení se s daty. Signály byly vykresleny a zobrazeny, jak je možné vidět na obrázku 6.2. Vizualizované signály konkrétního subjektu byly dle jeho anotace ve formátu \*.atr doplněny o místa, kde se stres vyskytoval a kde byla naopak vymezena relaxační fáze. V článku [9] bylo možné se dozvědět, že signály uložené v databázi se nacházejí již v předzpracovaném stavu a neobsahují žádné neplatné datové body. V kapitole 3.1 na obrázku 3.2 je možno vidět, jakou podobu měly signály konkrétního subjektu před předzpracování a nabízí možnost srovnání surových signálů se signály již po předzpracování.



Obr. 6.2: Vizualizace nahraných signálů subjektu 1, doplněné o jeho anotace

## 6.2 Úprava dat a vytvoření matic pro strojové učení

Úpravou dat se rozumí proces přeměny vstupních surových dat, získaných z měření, na strukturovaná data, většinou iterativní cestou. Strukturovanými daty se poté rozumí taková data, jež jsou vhodná pro procesy strojového učení. Proces úpravy dat tohoto programu je znázorněn na obrázku 6.3.



Obr. 6.3: Proces úpravy a výběru dat a tvorby matic pro strojové učení

### 6.2.1 Předzpracování signálů

Výsledná úspěšnost klasifikace bývá velmi často závislá na tom, jakým způsobem proběhlo předzpracování dat a jaké metody byly použity pro jejich předzpracování. Jedná se především o odstranění neúčinných složek signálů, zejména pak šumu, které signály zbytečně zatěžují a omezují výslednou přesnost klasifikačních modelů.

Jak již bylo zmíněno dříve, signály se již nacházejí v předzpracovaném stavu a proces předzpracování je tedy do jisté míry usnadněn. [9] Přesto však byla v MATLABu vytvořena funkce pro odstranění vysokofrekvenčního šumu (viz. kapitola 5.1) pro případ, že by byl program otestován na datech, které neprošly základní úpravou. V této funkci je možnost zvolení si, kolikáté aproximační pásmo bude odstraněno podle toho, jak velká míra zašumění by se v signálech vyskytovala.



## 6.2.2 Převzorkování dat

Každý ze dvou záznamů na subjekt získaný z databáze, měl rozdílnou vzorkovací frekvenci, a to  $f_{vz}=1$  Hz a  $f_{vz}=8$  Hz. Jelikož byly anotace obsaženy pouze u prvního záznamu se vzorkovací frekvencí 8 Hz, bylo nutné vzorkovací frekvence všech signálů sjednotit na 8 Hz, aby bylo později možné přiřadit anotace všem signálům. U signálů druhého záznamu ( $SpO_2$  a HR) došlo tedy k interpolaci chybějících vzorků.

## 6.2.3 Extrakce příznaků

Jakmile byly vzorkovací frekvence všech signálů sjednoceny, byly z nich extrahovány příznaky. Příznaky signálů byly extrahovány pro každý subjekt zvlášť v plovoucím okně délky 15 sekund, ve kterém docházelo k jejich vypočítávání.

Jak již bylo zmíněno v kapitole 5.2, extrahováním příznaků je snaha docílit co nejlepší klasifikace vstupních dat, tedy vybrat složky signálů s relevantními informacemi, které mají ke klasifikaci největší spojitost, a naopak vyloučit nevýznamné složky.

Bylo rozhodnuto extrahovat pro všechny signály každého subjektu celkem 5 příznaků, z nichž 4 byly lineární a 1 byl nelineární.

Korelační rozměr, jenž je nelineárním příznakem, byl vypočítán dle vzorce, který je uveden v kapitole 4.2.2 s parametrem vkladací dimenze o velikosti  $m=3$ .

Přehled extrahovaných příznaků ze signálů je uveden v tabulce 6.1.

Tab. 6.1: Souhrn extrahovaných příznaků pro všechny signály

Příznak	Stručný popis	Druh
Std	směrodatná odchylka	lineární
Mean	průměrná hodnota	lineární
Pow	energie signálu	lineární
CorDim	korelační rozměr	nelineární
Peak2peak	rozdíl maximální a minimální hodnoty	lineární

Celkově tedy bylo bráno v potaz 42 příznaků - 35 extrahovaných příznaků + 7 vstupních signálů.

## 6.2.4 Standardizace hodnot

Finálním krokem úpravy vstupních dat bylo standardizování všech extrahovaných příznaků. Na základě minimálních a maximálních hodnot každého extrahovaného příznaku ze signálů jednotlivých subjektů, byly jejich hodnoty převedeny do intervalu od 0 do 1 za účelem sjednocení významnosti jednotlivých dat z extrahovaných

příznaků, které budou dále použity pro klasifikaci. Výpočet pro standardizaci hodnot je uveden ve vzorci 6.1: [11]

$$z = \frac{x - \min(x)}{\max(x) - \min(x)}, \quad (6.1)$$

kde  $z$  představuje hodnotu příznaku po standardizaci a  $x$  hodnotu před standardizací. Ve vytvořené funkci byla vždy před uplatněním vzorce vypočítána maximální  $\max(x)$  a minimální  $\min(x)$  hodnota  $z$  celého příznaku před standardizací.

Kdyby nebyl tento krok učiněn, docházelo by k nerovnoměrnému rozložení významnosti jednotlivých extrahovaných příznaků, tedy některé příznaky by měly větší váhu než ostatní, což není ideální stav z toho důvodu, že příznaky s menšími hodnotami mohou být stejně, ne-li více důležité pro následnou klasifikaci. O tom, že extrahované příznaky mají rozdílné rozsahy hodnot, je možné se přesvědčit na základě vyobrazení vstupních dat na obrázku 6.2, jelikož příznaky jsou z těchto vstupních dat extrahovány, a tudíž bude-li rozdílný rozsah hodnot ve vstupních datech, bude i rozdílný rozsah hodnot u příznaků.

### 6.2.5 Přiřazení anotace a tvorba matic strojového učení


Jak již bylo zmíněno v kapitole 6.2.2 o převzorkování dat druhého záznamu (signálů  $\text{SpO}_2$  a HR) všech subjektů na shodnou vzorkovací frekvenci  $f_{vz}=8$  Hz s prvním záznamem, byl tento krok učiněn, aby bylo možné data z prvního a druhého záznamu od všech subjektů spojit matic. Jelikož byly anotace v databázi poskytovány pouze pro první záznam se vzorkovací frekvencí právě 8 Hz, nedošlo k podvzorkování dat jako například ve studii [9]. Vytvořené matice, obsahující data signálů a extrahovaných příznaků všech subjektů, byly doplněny o anotace, aby bylo později možné natrénování modelů klasifikačními algoritmy strojového učení a jejich vyhodnocení na testovacích datech, pomocí vytvořené funkce, která z načtených anotací od subjektů přidala do matic sloupec s informací o tom, v jakém stavu se subjekt na dané pozici zrovna nachází (předpokladem je, že pokud byl subjekt vystaven stresoru, nacházel se ve stresové fázi). Byly vytvořeny 2 matice. První z nich sloužila pro binární klasifikaci, kdy byl vytvořen vektor s binárními hodnotami, který podle anotací rozlišoval pouze fázi klidu a stresu a byl přidán jako poslední sloupec v matici. Druhá matice byla využita pro klasifikaci 4 stavů. Zde byl vytvořen vektor se čtyřmi možnými hodnotami podle anotací (klid - 0, fyzický stres - 1, emoční stres - 2 a kognitivní stres - 3), který byl taktéž přidán jako poslední sloupec matice.

## 6.3 Výběr dat

Po úpravě vstupních dat bylo zapotřebí vybrat data, která budou dobře reprezentovat klasifikační modely, budou vhodné pro klasifikační algoritmy a budou maximalizovat rozlišitelnost různých tříd. Z 42 extrahovaných příznaků bylo zachováno výsledných 19 příznaků, které byly selektovány pomocí dvou přístupů.

### 6.3.1 Selekcce příznaků podle schopnosti rozlišit stavy

Výběr příznaků podle toho, jak dobře dokáží od sebe odlišit 2 třídy (stres a klid) se jeví jako vhodný selekční přístup. Podmínkou uskutečnění této selekční metody byla přítomnost již vytvořených anotací.



Obr. 6.4: Rozlišení 2 stavů pro příznak Accy\_CorDim

V MATLABu byl poté vykreslen pro každý ze 42 příznaků boxplot neboli krabíkový graf, rozlišený do 2 tříd podle anotací a vizuálně porovnán s ostatními příznaky, jak dobře od sebe dokáže tyto 2 stavy rozlišit. Příkladem dobré diferenciaci do dvou stavů je například příznak korelačního rozměru signálu akcelerometru osy y, který je možno vidět na obrázku 6.4, kde vyobrazené „krabice“ obou stavů jsou ohraničené tzv. horním a dolním kvartilem (25. a 75. percentil) a lze zaznamenat, že u tohoto příznaku se tyto kvartily pro 2 stavy nekříží, což signalizuje dobrou rozeznatelnost.


Bylo zjištěno, že mnoho extrahovaných příznaků od sebe špatně odděluje stres a klid, a proto bylo tímto přístupem odstraněno 20 příznaků, které dané stavy nejhůře rozlišovaly.

Přehled ponechaných příznaků, jež solidně odlišili stresový a klidový stav, je patrný v tabulce 6.2.

Tab. 6.2: Souhrn ponechaných příznaků po prvním selekčním přístupu

<b>Příznak</b>	<b>Stručný popis</b>
Accx	signál akcelerometru osy x
Accx_Pow	energie pro osu x
Accx_CorDim	korelační rozměr osy x
Accx_Peak2peak	rozdíl maximální a minimální hodnoty v ose x
Accy_Std	směrodatná odchylka v ose y
Accy_CorDim	korelační rozměr osy y
Accy_Peak2peak	rozdíl maximální a minimální hodnoty v ose y
Accz	signál akcelerometru osy z
Accz_Mean	průměrná hodnota osy z
Accz_Pow	energie pro osu z
Accz_CorDim	korelační rozměr osy z
Temp	signál teploty
Temp_Pow	energie teploty
EDA_Std	směrodatná odchylka EDA
EDA_CorDim	korelační rozměr pro EDA
EDA_Peak2peak	rozdíl maximální a minimální hodnoty EDA
SpO <sub>2</sub> _Std	směrodatná odchylka SpO <sub>2</sub>
SpO <sub>2</sub> _Mean	průměrná hodnota SpO <sub>2</sub>
SpO <sub>2</sub> _CorDim	korelační rozměr SpO <sub>2</sub>
HR	signál tepové frekvence
HR_Mean	průměrná hodnota tepové frekvence
HR_Pow	energie tepové frekvence

Co se týče výběru příznaků pro klasifikaci do 4 psychických stavů, tak zde dle očekávání docházelo k většímu překrytí daných stavů. Z toho důvodu bylo rozhodnuto, že tento typ klasifikace bude využívat stejný soubor příznaků, s jakým dále pracovala klasifikace dvou stavů (tabulka 6.2). Pro zajímavost je na obrázku 6.5 uvedeno rozložení 4 psychických stavů již zmíněného příznaku korelačního rozměru signálu akcelerometru osy y.



Obr. 6.5: Rozlišení 4 stavů pro příznak Accy\_CorDim

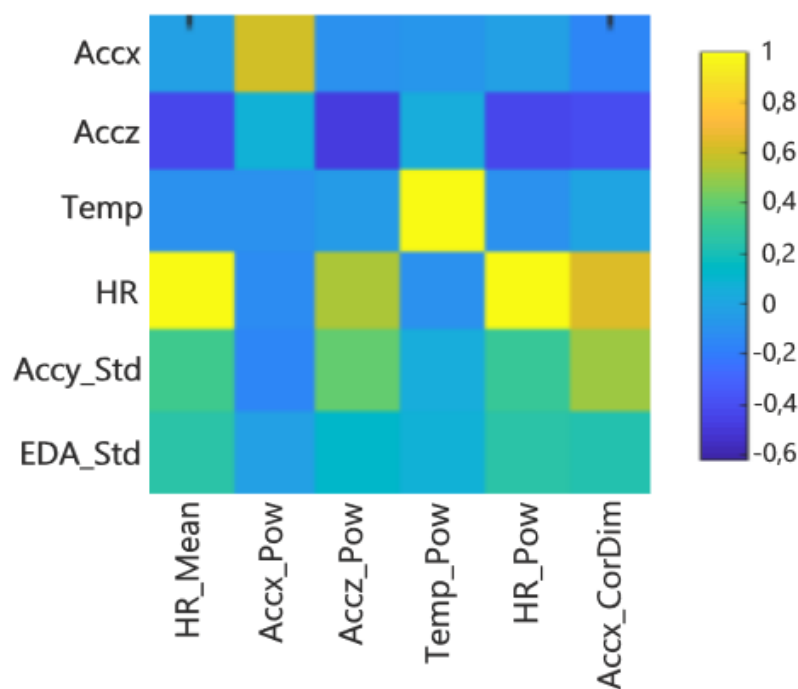
### 6.3.2 Selektce založená na kolinearitě příznaků

Mezi zachovanými příznaky byly přítomny takové příznaky, které si byly vzájemně velice podobné. Nabízí se tedy možnost zjištění takovýchto příznaků s vysokou kolinearitou. Tímto druhým přístupem selektce byly odstraněny ty příznaky, které měly korelaci s jiným příznakem přibližně rovnu jedné (tedy byly si přibližně podobné) a byl vždy ponechán pouze 1 z nich. Vybraný byl mezi dvěma příznaky s vysokou kolinearitou ten, který v minulém selekčním přístupu (kapitola 6.3.1) vykazoval lepší schopnost rozlišit stresový a klidový stav.

Na obrázku 6.6 jsou vykreslené kolinearity některých ponechaných příznaků z prvního selekčního přístupu. Pro lepší čitelnost a přehlednost je zde uvedena pouze část celkového obrázku (22 x 22 políček korelačních hodnot), která v této zredukované podobě zobrazuje např. vysoké korelační hodnoty signálu HR s extrahovaným příznakem HR\_Pow a HR\_Mean a také signálu Temp s extrahovaným příznakem Temp\_Pow spolu s přiloženou barevnou mapou korelačních hodnot v pravé části obrázku.

Následných procesů strojového učení se proto ještě neúčastnily tyto příznaky: HR, Temp\_Pow a HR\_Pow <sup>1</sup>.

<sup>1</sup>extrahovaný příznak HR\_Pow měl ještě vysokou korelaci s příznakem HR\_Mean, která není patrná z obrázku 6.6



Obr. 6.6: Korelační hodnoty některých ponechaných příznaků

V rámci kapitoly o výběru příznaků by bylo vhodné zmínit metodu selekce příznaků PCA (Analýza hlavních komponent), o které již bylo z teoretického hlediska pojednáno v kapitole 5.3.1. Jedná se totiž o jednu z nejvíce využívaných metod ve strojovém učení pro redukci počtu příznaků. Jelikož je tato selekční metoda součástí již v MATLABu implementované knihovny Classification Learner, o které budou mimojiné následující kapitoly v rámci trénování modelů pomocí klasifikačních algoritmů pojednávat, bylo rozhodnuto ověřit klasifikační výkon za použití této selekční metody.

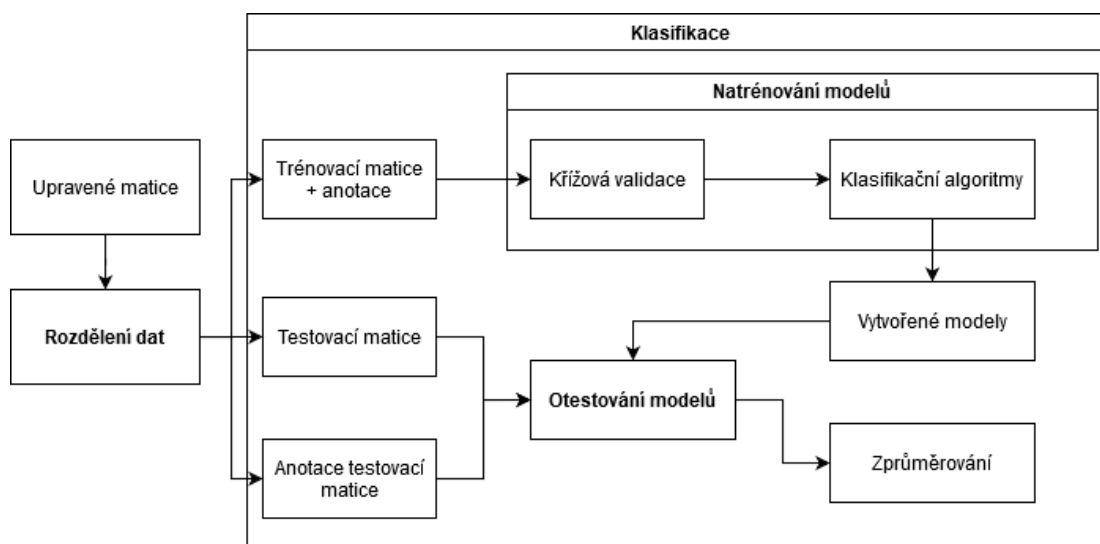
V rámci heuristických pokusů na menších datových souborech (5 subjektů) byla odzkoušena úspěšnost klasifikace pomocí metody PCA, která ve všech případech binární klasifikace, i klasifikace do 4 stavů, nezaznamenala lepších výsledků klasifikační přesnosti než při jejím nevyužití (a to jak na trénovací, tak testovací množině dat). Pro různé odzkoušené klasifikační algoritmy strojového učení bylo z 19 příznaků selekční metodou PCA vybráno 12 při zachování 95 % informace.

## 6.4 Návrh a učení klasifikačních modelů

Vytvořené matice strojového učení (kapitola 6.2) byly optimalizovány v kapitole 6.3 eliminací některých příznaků. Další a poslední část programu představuje vytvoření klasifikačních modelů z optimalizovaných matic pro strojové učení a otestování jejich úspěšnosti detekce stresu.

Proces klasifikace lze obecně rozdělit na 2 fáze, z nichž v první fázi, která je popsána v této kapitole, dochází k vytvoření a naučení se modelů na trénovacích datech prostřednictvím klasifikačních algoritmů a v druhé fázi, popsané v kapitole 6.5, poté dochází k vyhodnocení úspěšnosti vytvořených modelů na testovacích datech, které se neúčastnily procesu učení (podrobněji také viz. kapitola 5.4).

Klasifikační proces tohoto programu je znázorněný na obrázku 6.7.



Obr. 6.7: Klasifikační proces programu detekující stres

### 6.4.1 Rozdělení dat

V MATLABu byla vytvořena funkce pro rozdělení dat určených pro strojové učení na trénovací a testovací matice. Data, tedy vytvořené matice, byly náhodně rozděleny v poměru 4:1, což znamená, že z 20 subjektů (které představují celkový dataset) posloužilo 80 % dat (tedy 15 subjektů) k natřování modelů a zbytkových 20 % dat (tedy 5 zbylých subjektů) bylo využito pro otestování. Ze vzniklé testovací matice došlo v rámci této funkce ještě k vysektování posledního řádku s anotacemi, jelikož při vyhodnocení modelů na testovacích datech nemůže být předem známé rozdělení dat do daných stavů.

## 6.4.2 Učení modelů pomocí klasifikačních algoritmů

Vytvořená trénovací matice byla následně nahrána do knihovny Classification Learner v MATLABu, která v sobě mimo jiné obsahuje implementovanou funkci křížové validace (viz. kapitola 5.4.1), která slouží zejména k předejití přeučení trénovaných modelů, ale také k tomu aby nedocházelo k podhodnocení dat v trénovací matici. Pro tento účel byla aplikována 10-násobná křížová validace.

Binární klasifikační modely byly posléze z trénovacích matic sestaveny pomocí čtyř klasifikačních algoritmů, které byly vybrány na základě experimentů na menších datových sadách a informací z výzkumných prací (zejména studie [10] popsaná v kapitole 4.2):

- K-nejbližších sousedů (K-NN),
- Logistická regrese (LR),
- Metoda podpůrných vektorů (SVM),
- Rozhodovací strom (RS).

Parametry klasifikačních algoritmů byly víceméně ponechány ve výchozím nastavení Classification Learneru. Avšak některé parametry, algoritmů, které byly pozměněny od výchozího nastavení, či se nějakým způsobem váží k vyladění modelů, jsou zde uvedeny: <sup>2</sup>

- K-nejbližších sousedů (K-NN): Pro klasifikační algoritmus K-NN byl parametr „Number of neighbours“ nastaven na hodnotu 100. Tato hodnota vykazovala nejlepších výsledků klasifikační přesnosti při pokusech na menších datových sadách, a to jak na trénovacích, tak na testovacích datech oproti menším hodnotám tohoto parametru. Tento parametr určuje  $k$  nejbližších sousedů, kteří budou přiřazeni do jednotlivých tříd. Pro binární klasifikaci se tedy jeví jako nejlepší varianta tzv. hrubého rozlišení mezi třídami, které je zapříčiněno právě výběrem vysokého počtu sousedů vlivem daného parametru. Pro výpočet vzdáleností sousedů posloužila distanční metrika Euklidovské vzdálenosti.
- Metoda podpůrných vektorů (SVM): Byla vybrána metoda SVM s tzv. hrubým gaussovským jádrem, kdy dochází ke hrubému oddělení jednotlivých tříd pomocí gaussovského jádra. Již při řešení výběru parametrů pro K-NN bylo zjištěno, že hrubé oddělení mezi třídami se jeví jako nejlepší řešení při klasifikaci do 2 stavů (stresu a klidu). Parametr „Kernel function“ byl nastaven na „Gaussian“.

---

<sup>2</sup>klasifikační algoritmus logistické regrese byl zcela ponechán ve výchozím nastavení Classification Learneru



- Rozhodovací strom (RS): Parametr „Maximum number of splits“ byl v tomto klasifikačním algoritmu vybrán s hodnotou 20. Tímto parametrem je nastaveno maximální počet rozdělení vnitřních uzlů rozhodovacího stromu. Tato hodnota se jeví jako optimální z toho důvodu, že dosahovala lepších výsledků na menších vzorcích dat oproti menším hodnotám parametru, co se týče klasifikační přesnosti na trénovacích a testovacích datech a metriky AUC na trénovacích datech. Zde byla použita pro srovnání hodnota parametru 4. Také bylo dosaženo lepší klasifikační přesnosti na testovacích datech oproti větším hodnotám. Zde bylo pro srovnání využito hodnoty 100. Jako parametr kritéria rozdělení zde byla využita metrika Gini index, která vyhodnocuje kvalitu rozdělení do tříd.

Modely klasifikující 4 psychické stavy byly naučeny pomocí celkem tří klasifikačních algoritmů. Jedná se o tytéž klasifikátory, které byly využity při binární klasifikaci se stejnými ponechanými hodnotami parametrů. Avšak algoritmus logistické regrese nemohl být při této klasifikační úloze využit, jelikož se jedná o binární pravděpodobnostní klasifikátor.

## 6.5 Vyhodnocení jednotlivých klasifikačních modelů

Druhá fáze klasifikace spočívá ve vyhodnocení úspěšnosti natrénovaných modelů. Té bylo docíleno tak, že na data, která se neúčastnila procesu učení (viz. Rozdělení dat, kapitola 6.4.1), byla klasifikována podle naučených modelů.

Prvním cílem praktické práce bylo vytvoření modelů pro binární klasifikaci, které budou klasifikovat libovolný stres a odlišit jej od klidového stavu. Druhým cílem poté bylo sestavit modely, které budou klasifikovat 4 psychické stavy, kterými jsou: klid, fyzický, emoční a kognitivní stres.

Vyhodnocení jednotlivých klasifikačních algoritmů probíhalo tak, že nejprve byla vypočítána klasifikační přesnost a metrika AUC na trénovacích datech a následně proběhlo vyhodnocení přesnosti na datech testovacích. Klasifikační přesnost byla zvolena proto, že se jedná pravděpodobně o nejvíce užívanou metriku pro měření výkonů modelů a AUC se zase jeví jako metrika s dobrou vypovídající hodnotou, co se optimalizace modelů týče.

V následujících dvou kapitolách (kapitoly 6.5.1 a 6.5.2) jsou poté jednotlivé klasifikační algoritmy porovnány v tabulkách 6.3 a 6.6. Metoda, která dosahovala nejvyšší klasifikační přesnosti na testovacích datech, byla dále na tomto testovacím datasetu

vyhodnocena podle následujících metrik <sup>3</sup>:

- senzitivita,
- pozitivní prediktivní hodnota (PPH),
- F1 skóre.

Jelikož při binární klasifikační úloze senzitivita stresu představuje specifitu kličového stavu, bylo rozhodnuto využít pouze senzitivity pro vyhodnocení výsledného modelu. Senzitivita narozdíl od specifity zachycuje poměr správně pozitivních datových bodů, kdy klasifikátor predikuje 1 a opravdová hodnota je též 1, k všem opravdu pozitivním datovým bodům, což je pro danou klasifikaci přednější parametr než specifita, která představuje poměr správně negativních datových bodů, kdy klasifikátor predikuje 0 a opravdová hodnota je též 0, k všem opravdu negativním datovým bodům.

Nutno podotknout, že všechny výsledky, které jsou zde uvedeny, jsou průměry ze čtyř klasifikačních běhů, kdy v každém běhu docházelo k náhodnému rozdělení celého datasetu, takže pro trénování a testování dat bylo vždy využito jiných subjektů. Toho bylo učiněno z důvodu větší věrohodnosti výsledků.

### 6.5.1 Klasifikace binární

Při této klasifikační úloze dosahovala nejlepších výsledků klasifikační přesnosti metoda logistické regrese, a to průměrných 84,8 % ze 4 klasifikačních běhů na testovacích datech (viz. tabulka 6.3).

Tab. 6.3: Zprůměrované výsledky modelů na trénovacích a testovacích datech ze 4 klasifikačních běhů

ALGORITMUS	TRÉNOVACÍ DATA		TESTOVACÍ DATA
	PŘESNOST [%]	AUC [%]	PŘESNOST [%]
K-NN	99,1	99,5	80,9
LR	85,5	92,0	<b>84,8</b>
SVM	89,9	95,0	81,7
RS	86,5	92,5	77,0

Přesnost nejlepší metody byla dále otestována na testovacích datech pomocí metrik jich zmíněných výše. Výsledky jsou uvedeny v tabulkách 6.4 a 6.5. Důležité zde je zmínit, že rozdělení vzorků v matici záměn do jednotlivých tříd je pouze relativní, jelikož se jedná o průměry ze 4 klasifikačních běhů, kdy v každém ze čtyř

<sup>3</sup>metriky byly vybrány na základě kapitoly 5.5

běhů byl jinak náhodně rozdělený dataset, takže byly vždy využity jiné subjekty pro testování <sup>4</sup>.

Tab. 6.4: Dosažené výsledky nejlepší metody - LR - na testovacích datech při binární klasifikaci - zprůměrované ze 4 klasifikačních běhů

	<b>RELAX</b>	<b>STRES</b>	<b>PRŮMĚR</b>
<b>SENZITIVITA</b> [%]	88,8	79,5	84,2
<b>PPH</b> [%]	82,8	86,3	84,6
<b>F1-SKÓRE</b> [%]	85,2	81,7	83,5

Tab. 6.5: Matice neurčitosti (Confusion Matrix) nejlepší metody - LR - při binární klasifikaci - zprůměrované ze 4 klasifikačních běhů

	<b>RELAX</b>	<b>STRES</b>
<b>RELAX</b>	34010	4827
<b>STRES</b>	3867	30740

## 6.5.2 Klasifikace 4 psychických stavů

Logistická regrese je binární pravděpodobnostní klasifikátor, a proto nebyla u této klasifikační úlohy využita. Pro klasifikaci 4 stavů bylo tedy využito tří metod, kdy nejvyšší klasifikační přesnosti 75,9 % ze 4 klasifikačních běhů bylo dosaženo algoritmem SVM na testovacích datech, což je patrné z tabulky 6.6.

Tab. 6.6: Zprůměrované výsledky modelů na trénovacích a testovacích datech ze 4 klasifikačních běhů

<b>ALGORITMUS</b>	<b>TRÉNOVACÍ DATA</b>		<b>TESTOVACÍ DATA</b>
	<b>PŘESNOST</b> [%]	<b>AUC</b> [%]	<b>PŘESNOST</b> [%]
K-NN	98,8	99,0	68,7
SVM	88,4	97,0	<b>75,9</b>
RS	79,7	91,0	71,0

Tak jako v minulé klasifikační úloze, byla i při této klasifikaci dále vyhodnocena nejlepší metoda na testovacích datech podle totožných metrik, které jsou uvedené v tabulkách 6.7 a 6.8.

<sup>4</sup>každý subjekt měl jinou délku/odlišný počet vzorků

Tab. 6.7: Dosažené výsledky nejlepší metody rozlišující 4 stavy - SVM - na testovacích datech - zprůměrované ze 4 klasifikačních běhů

	Relax	Fyzický	Emoční	Kognitivní	PRŮMĚR
<b>SENZITIVITA [%]</b>	80,6	43,7	54,5	40,3	54,8
<b>PPH [%]</b>	85,9	96,2	57,6	70,8	77,6
<b>F1-SKÓRE [%]</b>	78,5	57,2	52,8	51,3	59,8

Tab. 6.8: Matice neurčitosti (Confusion Matrix) nejlepší metody - SVM - rozlišující 4 stavy - zprůměrované ze 4 klasifikačních běhů

	Relax	Fyzický stres	Emoční stres	Kognitivní stres
<b>Relax</b>	33920	63	3207	1805
<b>Fyzický stres</b>	190	10079	205	9
<b>Emoční stres</b>	3140	297	8063	1595
<b>Kognitivní stres</b>	957	345	1503	6892

## 6.6 Diskuze

Stres je možno monitorovat různými způsoby. Snímání biologických signálů se jeví jako pravděpodobně nejdostupnější a nejpohodlnější způsob detekce stresových stavů. Při tomto způsobu monitorace však nastává otázka, jaké biologické signály k detekci stresu použít. Tradičně je monitorace psychického stavu prováděna snímáním signálů EEG, kterými je sice možné velmi spolehlivě detekovat stres, avšak tato metoda má svá úskalí v tom, že ji lze provádět pouze ve specializovaných prostorách nemocnic, neurologických laboratořích či jiných zařízeních tomu uzpůsobených. Naproti tomu monitoraci psychického stavu pomocí extracerebrálních biologických signálů je možno realizovat v běžných každodenních podmínkách třeba pomocí platforem umístěných na zápěstí ruky (např. chytré hodinky). [9]

Na téma automatické detekce stresu již vzniklo mnoho výzkumných prací. Tyto studie se zabývají zejména vývoji systémů, které by mohly zabránit konsekvencím akutních stresových reakcí či chronickému stresu. V takových případech by bylo vhodné detekovat stres v reálných podmínkách.

Na základě těchto informací bylo rozhodnuto pro tuto práci využít volně dostupnou databázi non-EEG biologických signálů ze stránek PhysioNetu, která sice obsahuje data, která jsou naměřená v umělých podmínkách, zato jsou však snímána komfortní cestou dvěma senzory umístěnými na zápěstí. Navíc tato databáze obsahuje anotace s přechody jednotlivých psychických stavů, které oznamují, v jakém psychickém stavu byl subjekt v daný časový okamžik.

V této práci navržený a v programovém prostředí MATLAB zrealizovaný program pro detekci stresu dosahoval v některých ohledech značně odlišných hodnot, co se týče 2 klasifikačních úloh, které byly provedeny. Nejlepších výsledků na testovacích datech dosahovala ze 4 klasifikačních běhů metoda logistické regrese s průměrnou přesností 84,8 % pro klasifikaci binární, patrně z tabulky 6.3, a metoda SVM s průměrnou přesností 75,9 % pro klasifikaci dat do 4 psychických stavů, uvedeno v tabulce 6.6.

Srovnají-li se tyto 2 výsledky, lze konstatovat, že dle očekávání dochází u klasifikace 4 psychických stavů k horším výsledkům než při klasifikaci binární. Jelikož 3 ze 4 tříd (fyzický, emoční a kognitivní stres) jsou podtřídami jedné z binárních tříd (celkový stres), mohla tato klasifikace dosáhnout nanejvýš stejné úspěšnosti jako klasifikace binární. Toho však nebylo docíleno, což je patrné již při porovnání obrázků 6.4 a 6.5 v kapitole 6.3.1, kdy dochází k většímu překrytí jednotlivých psychických stavů. Tento jev se poté promítl do výsledků vyhodnocení metody SVM v tabulkách 6.7 a 6.8.

V kapitole 5.4 je zmíněno, že výsledky klasifikace mohou být nadhodnoceny, což znamená, že modely se přeúčí na trénovacích datech. Snaha těmito situacím předejít bylo použitím 10-násobné křížové validace. Avšak jev přeučení některých modelů je do jisté míry patrný ve výsledcích tabulek 6.3 a 6.6.

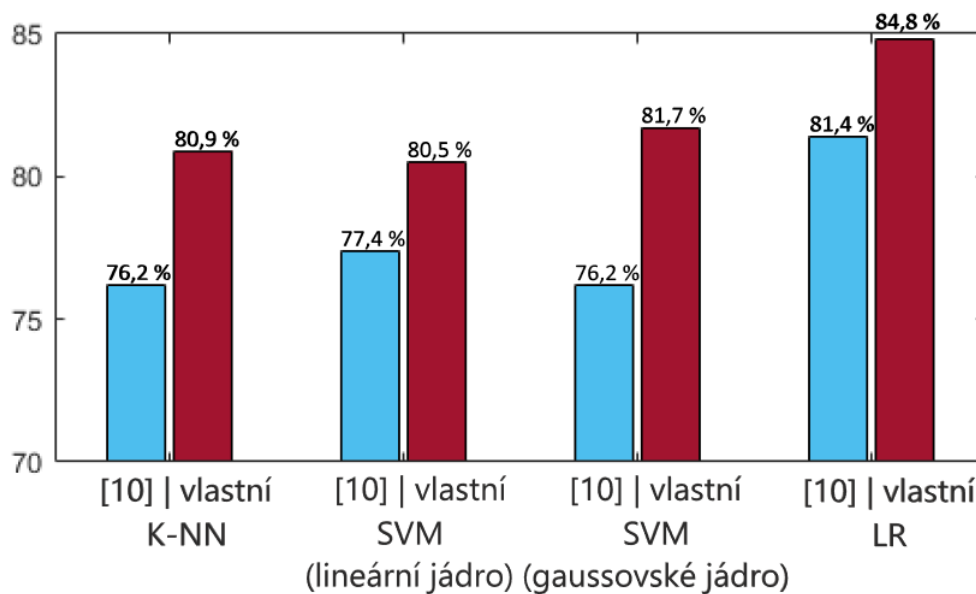
Výsledná senzitivita pro binární klasifikaci v této práci dosahuje 84,2 % pomocí metody logistické regrese, což je znatelně lepší výsledek, než který uvádějí autoři článku [19] metodou fit, jejichž senzitivita byla v průměru 66 %.

Další možné srovnání nabízí samotní autoři databáze non-EEG biologických signálů. Ve své studii [9] využívají metodu GMM pro klasifikaci do 4 psychických stavů. Z tabulky 6.9 je zjevné, že jejich navrhovaný klasifikační přístup dosahuje značně lepších hodnot senzitivity 3 typů stresů. Důvodem zejména vyšší senzitivity v této studii oproti výsledné senzitivě této práce byl pravděpodobně zapříčiněn tím, že autoři před aplikovací shlukové analýzy odstranili data z druhé, třetí a čtvrté relaxace, čímž došlo k vyvážení všech neurologických stavů.

Tab. 6.9: Srovnání senzitivity a přesnosti v této práci s autory článku [9]

		Relax	Fyzický	Emoční	Kognitivní
<b>Metoda</b>	<b>SENZ. [%]</b>	85,4	93,3	77,2	86,4
<b>GMM [9]</b>	<b>PŘES. [%]</b>	<b>84,6</b>			
<b>SVM</b>	<b>SENZ. [%]</b>	80,6	43,7	54,5	40,3
<b>(vlastní)</b>	<b>PŘES. [%]</b>	<b>75,9</b>			

Výsledky jednotlivých klasifikátorů strojového učení lze dále porovnat s autory článku [10]. Ve své studii však využívají jinou databázi, a to vytvořenou v rámci studie [18], která byla popsána v kapitole 3.2. Na obrázku 6.8, je možné vidět, že výsledné metody strojového učení dosahují v této práci dokonce o trochu lepších výsledků, než jakých bylo dosaženo autory [10].



Obr. 6.8: Porovnání výsledků přesnosti jednotlivých klasifikátorů strojového učení v této práci s autory článku [10]

## 7 ZÁVĚR

Prvním cílem této práce bylo prostudování potřebné teorie týkající problematiky detekce stresu pomocí biologických signálů. Na tento popud byla vytvořena kapitola týkající se stresu, provedena analýza vhodných biologických signálů pro detekci a zmíněny 2 metody automatické detekce stresu.

V rámci druhého cíle práce je věnována pozornost 3 databázím biologických signálů, které byly využity za účelem prozkoumání proveditelnosti automatizovaného rozpoznání stresu či neurologických stavů.

V souladu s ostatními cíly práce byly vytvořeny 2 kapitoly, z nichž první z nich slouží jako teoretický úvod do praktické části práce, jež popisuje a vysvětluje některé pojmy, které jsou poté z praktického hlediska aplikovány.

V poslední kapitole je poté popsán a zrealizován navržený program v programovém prostředí MATLAB, který je schopen detekovat stres s různou úspěšností. Pro jeho zrealizování byla využita data z databáze Non-EEG Dataset for Assessment of Neurological Status. Za použití klasifikačních algoritmů strojového učení je možné klasifikovat jednotlivé psychické stavy. První je binární klasifikace do 2 tříd na klid a stres a druhá je klasifikace 4 psychických stavů na klid a 3 typy stresů. Použité klasifikační algoritmy v této práci byly: K-nejbližších sousedů, logistická regrese, metoda podpůrných vektorů a rozhodovací strom. Pro dosažení nejlepších výsledků byly vstupní data upraveny, byly též extrahovány příznaky ze vstupních signálů a posléze vybrány ty příznaky, které mají k dané klasifikaci největší vztah podle 2 selekčních přístupů, kdy bylo vybráno 19 výsledných příznaků z 42 extrahovaných. Natrénované modely byly poté otestovány na testovacích datech, kdy nejlepších výsledků pro binární klasifikaci dosáhla metoda logistické regrese s průměrnou klasifikační přesností 84,8 % a pro klasifikaci 4 psychických stavů bylo nejlepších výsledků dosaženo metodou SVM s průměrnou klasifikační přesností 75,9 %. Pro nejlepší metody dané klasifikace bylo využito ještě dalších metrik pro jejich vyhodnocení.

## LITERATURA

- [1] KŘIVOHLAVÝ, Jaro. *Psychologie zdraví*. Vyd. 3. Praha: Portál, 2009. ISBN 978-80-7367-568-4.
- [2] JOSHI, Vinay. *Stres a zdraví*. Praha: Portál, 2007. Rádci pro zdraví. ISBN 978-80-7367-211-9.
- [3] VEČEŘOVÁ-PROCHÁZKOVÁ, Alena a Radkin HONZÁK. *Stres, eustres a distres: Stress, eustress and distress*. Via practica: moderný časopis pre lekárov prvého kontaktu. Bratislava: SOLEN, 2009, 6(12), 491-495. ISSN 1336-4790.
- [4] BARTŮŇKOVÁ, Staša. *Stres a jeho mechanismy*. Praha: Karolinum, 2010. ISBN 978-80-246-1874-6.
- [5] PRAŠKO, Ján a Hana PRAŠKOVÁ. *Proti stresu krok za krokom*. Praha: Grada, 2001. Psychologie pro každého. ISBN 80-247-0068-9.
- [6] KATAOKA, H., H. KANO, H. YOSHIDA, A. SAIJO, M. YASUDA a M. OSUMI, nedatováno *Development of a skin temperature measuring system for non-contact stress evaluation*. In: Proceedings of the 20th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Vol.20 Biomedical Engineering Towards the Year 2000 and Beyond (Cat. No.98CH36286)[online]. B.m.: IEEE, s.940–943 [vid.2019-04-17]. ISBN0-7803-5164-9. Dostupné z: doi: 10.1109/IEMBS.1998.745598
- [7] *Wikiverzita – Biosignály/Druhy* [online]. [cit. 2019-12-27]. Dostupné z: <<https://cs.wikiversity.org/wiki/Biosign%C3%A1ly/Druhy>>
- [8] TONI, K, nedatováno. *Accelerometer Basics -learn.sparkfun.com* [online] [vid.2019-01-02]. Dostupné z: <<https://learn.sparkfun.com/tutorials/accelerometer-basics/all>>
- [9] BIRJANDTALAB, Javad, Diana COGAN, Maziyar Baran POUYAN a Mehrdad NOURANI. *A Non-EEG Biosignals Dataset for Assessment and Visualization of Neurological Status*. In: 2016 IEEE International Workshop on Signal Processing Systems (SiPS) [online]. IEEE, 2016, 2016, s. 110-114 [cit. 2018-11-26]. DOI: 10.1109/SiPS.2016.27. ISBN 978-1-5090-3361-4. Dostupné z: <<http://ieeexplore.ieee.org/document/7780081/>>
- [10] JIMENEZ-LIMAS, Marco A., Carlos A. RAMIREZ-FUENTES, Blanca TOVAR-CORONA a Laura I. GARAY-JIMENEZ. *Feature selection for stress*



- level classification into a physiological signals set.* In: 2018 15th International Conference on Electrical Engineering, Computing Science and Automatic Control (CCE) [online]. IEEE, 2018, 2018, s. 1-5 [cit. 2020-01-02]. DOI: 10.1109/ICEEE.2018.8533968. ISBN 978-1-5386-7033-0. Dostupné z: <<https://ieeexplore.ieee.org/document/8533968/>>
- [11] RIGAS, George, Yorgos GOLETISIS a Dimitrios I. FOTIADIS. *Real-Time Driver's Stress Event Detection.* IEEE Transactions on Intelligent Transportation Systems [online]. 2012, 13(1), 221–234 [cit. 2020-03-04]. DOI: 10.1109/TITS.2011.2168215. ISSN 1524-9050.
- [12] BRAITHWAITE, Jason J, Dr DERRICK, G WATSON, Robert JONES a Mickey Rowe BIOPAC, 2013. *A Guide for Analysing Electrodermal Activity (EDA) & amp; Skin Conductance Responses (SCRs) for Psychological Experiments {via the BIOPAC MP36R & amp; AcqKnowledge software}* [online]. [cit.2020-02-02]. Dostupné z: <<https://www.biopac.com/wp-content/uploads/EDA-SCR-Analysis.pdf>>
- [13] *Systém psychofyziologický* [online]. Katedra psychologie, Filozofická fakulta, Univerzita Palackého v Olomouci [cit. 2020-02-19]. Dostupné z: <<https://psych.upol.cz/veda-a-vyzkum/laborator/system-psychofyziologicky/>>
- [14] KOPAL, Petr. *Detekce stresových situací na základě analýzy biosignálů.* Plzeň, 2016. [cit. 2020-04-02]. Dostupné z: <<https://theses.cz/id/x74i5y/>> Bakalářská práce. ZÁPADOČESKÁ UNIVERZITA V PLZNI. Fakulta aplikovaných věd
- [15] SCHRAMM, W M, A BARTUNEK a H GILLY, 1997. *Effect of local limb temperature on pulse oximetry and the plethysmographic pulse wave.* *International journal of clinical monitoring and computing.* [online]. 14(1), 17–22 [vid.2019-04-17]. ISSN0167-9945. Dostupné z: <<http://www.ncbi.nlm.nih.gov/pubmed/9127780>>
- [16] TARVAINEN, Mika P, NISKANEN, J P, LIPPONEN, J A, RANTA-AHO, P O, KARJALAINEN, P A. *Kubios HRV—A Software for Advanced Heart Rate Variability Analysis.* 4th European Conference of the International Federation for Medical and Biological Engineering 2009, 1022–1025.
- [17] CALVO, Rafael A. a Sidney D'MELLO. *Affect Detection: An Interdisciplinary Review of Models, Methods, and Their Applications.* IEEE Transactions on

- Affective Computing. 2010, 1(1), 18-37. DOI: 10.1109/T-AFFC.2010.1. ISSN 1949-3045.
- [18] HEALEY, J.A. a R.W. PICARD. *Detecting stress during real-world driving tasks using physiological sensors*. IEEE Transactions on Intelligent Transportation Systems. IEEE, 2005, 156 - 166. DOI: 10.1109/TITS.2005.848368. ISSN 1558-0016.
- [19] BAKKER, Jorn, Mykola PECHENIZKIY a Natalia SIDOROVA. *What's Your Current Stress Level? Detection of Stress Patterns from GSR Sensor Data*. 2011 IEEE 11th International Conference on Data Mining Workshops. IEEE, 2011, 2011, , 573-580. DOI: 10.1109/ICDMW.2011.178. ISBN 978-1-4673-0005-6. Dostupné také z: <<http://ieeexplore.ieee.org/document/6137431/>>
- [20] WALEK, Petr, Martin LAMOŠ a Jiří JAN. *Analýza biomedicínských obrazů počítačová cvičení FEKT VUT v Brně*. Fakulta elektrotechniky a komunikačních technologií VUT v Brně, 2015, 181. ISBN 978-80-214-4792-9.
- [21] *The MathWorks, Inc. - wavedec* [online]. [cit. 2019-12-27]. Dostupné z: <<https://www.mathworks.com/help/wavelet/ref/wavedec.html>>
- [22] SOMOL, Petr, Jana NOVOVIČOVÁ a Pavel PUDIL. *Moderní metody výběru příznaků ve statistickém rozpoznávání*. Oddělení rozpoznávání, Ústav teorie informace a automatizace AV ČR, v.v.i., Pod vodárenskou věží 4, 182 08 Praha 8, 48 s. Dostupné také z: <[https://is.muni.cz/www/castek/53116466/15-2013-Somol\\_et\\_al-Moderni\\_metody\\_vyberu\\_priznaku\\_ve\\_statistickem\\_rozpoznavani.pdf?verze=2017](https://is.muni.cz/www/castek/53116466/15-2013-Somol_et_al-Moderni_metody_vyberu_priznaku_ve_statistickem_rozpoznavani.pdf?verze=2017)>
- [23] GONZALEZ-SANCHEZ, Javier, Mustafa BAYDOGAN, Maria-Elena CHAVEZ-ECHEAGARAY, Winslow BURLESON a Robert K. ATKINSON, JEON, Myoungsoon, ed. *Affect Measurement: A Roadmap Through Approaches, Technologies, and Data Analysis*. Emotions and Affect in Human Factors and Human-Computer Interaction. Academic Press, 1, 255-288. DOI: 10.1016/B978-0-12-801851-4.00011-2. Dostupné z: <[https://www.researchgate.net/publication/315807942\\_Affect\\_Measurement\\_A\\_Roadmap\\_Through\\_Approaches\\_Technologies\\_and\\_Data\\_Analysis](https://www.researchgate.net/publication/315807942_Affect_Measurement_A_Roadmap_Through_Approaches_Technologies_and_Data_Analysis)>
- [24] *Extrakce a selekce příznaků* [online]. [cit. 2020-04-26]. Dostupné z: <[https://cw.fel.cvut.cz/old/\\_media/courses/a6m33dvz/dvz2017-06-extract-select.pdf](https://cw.fel.cvut.cz/old/_media/courses/a6m33dvz/dvz2017-06-extract-select.pdf)>
- [25] BATINA, Lejla, Jip HOGENBOOM a Jasper G.J. VAN WOUDEMBERG. *Getting More from PCA: First Results of Using Principal Component Analysis*

- for Extensive Power Analysis*. [online]. [cit. 2020-04-20]. Dostupné z: <[https://link.springer.com/chapter/10.1007/978-3-642-27954-6\\_24](https://link.springer.com/chapter/10.1007/978-3-642-27954-6_24)>
- [26] MELOUN, Milan a Jiří MILITKÝ. *Metoda hlavních komponent a exploratorní analýza vícerozměrných dat*. [online]. Katedra textilních materiálů, Technická universita v Liberci [cit. 2020-03-24]. Dostupné z: <<http://meloun.upce.cz/docs/publication/127a.pdf>>
- [27] KOMENDA, Martin. *Hodnocení úspěšnosti klasifikace* [online]. [cit. 2020-04-02]. Dostupné z: <[https://is.muni.cz/www/98951/41610771/43823411/43823458/Analyza\\_a\\_hodnoc/44563155/56154792/Vicerozmerky\\_-\\_kap11.6\\_Uspesnost\\_klasifikace.pdf](https://is.muni.cz/www/98951/41610771/43823411/43823458/Analyza_a_hodnoc/44563155/56154792/Vicerozmerky_-_kap11.6_Uspesnost_klasifikace.pdf)>
- [28] VYKOUPIIL, Pavel. *Inteligentní klasifikace příznaků pro podporu diagnostiky glaukomu* [online]. Brno, 2012 [cit. 2020-04-02]. Dostupné z: <[https://www.vutbr.cz/www\\_base/zav\\_prace\\_soubor\\_verejne.php?file\\_id=53062.](https://www.vutbr.cz/www_base/zav_prace_soubor_verejne.php?file_id=53062.)>  
Bakalářská práce. Vysoké učení technické v Brně. Vedoucí práce Ing. Václav Uher.
- [29] MISHRA, Aditya. *Metrics to Evaluate your Machine Learning Algorithm* [online]. 2018 [cit. 2020-05-28]. Dostupné z: <<https://towardsdatascience.com/metrics-to-evaluate-your-machine-learning-algorithm-f10ba6e38234>>
- [30] GOLDBERGER, A L, L A AMARAL, L GLASS, J M HAUSDORFF, P C IVANOV, R G MARK, J E MIETUS, G B MOODY, C K PENG a H E STANLEY *PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals*. *Circulation* 101(23):e215-e220 [Circulation Electronic Pages;<<http://circ.ahajournals.org/content/101/23/e215.full>>]; 2000 (13. června)

## SEZNAM OBRÁZKŮ

2.1	Princip piezoelektrického akcelerometru, [8]	12
2.2	Měření EDA, [14]	13
3.1	Zařízení Affectiva Q Curve a Nonin 3150 Wireless WristOx2, [9]	17
3.2	Surové signály subjektu 1 před předzpracováním, [9]	18
3.3	Umístění senzorů během experimentu, [18]	20
3.4	Příklad signálů zaznamenaných během experimentu, [18]	21
3.5	Stres před a po schůzce, [18]	23
4.1	Vizualizace dat do 2D prostoru v různých neurologických stavech, [9]	25
4.2	Signál HRV před a po filtraci	27
5.1	Princip fungování víceúrovňové diskrétní vlnkové transformace	30
5.2	Extrakce příznaků	31
5.3	Selekce příznaků	32
5.4	K-násobná křížová validace (k=5)	34
6.1	Základní schéma navrženého programu	38
6.2	Vizualizace nahraných signálů subjektu 1	40
6.3	Proces úpravy a výběru dat a tvorby matic pro strojové učení	41
6.4	Rozlišení 2 stavů pro příznak Accy_CorDim	44
6.5	Rozlišení 4 stavů pro příznak Accy_CorDim	46
6.6	Korelační hodnoty některých ponechaných příznaků	47
6.7	Klasifikační proces programu detekující stres	48
6.8	Porovnání výsledků přesnosti jednotlivých klasifikátorů strojového učení v této práci s autory článku [10]	55

## SEZNAM TABULEK

3.1	Informace o jednotlivých subjektech [9] . . . . .	18
3.2	Shrnutí datasetu, [19] . . . . .	22
4.1	Matice záměn, senzitivita a specificita pro 4 neurologické stavy . . . . .	26
4.2	Přesnost klasifikátorů s CD HRV, respirace a GSR nohy . . . . .	29
5.1	Matice neurčitosti, [29] . . . . .	36
6.1	Souhrn extrahovaných příznaků pro všechny signály . . . . .	42
6.2	Souhrn ponechaných příznaků po prvním selekčním přístupu . . . . .	45
6.3	Zprůměrované výsledky modelů na trénovacích a testovacích datech ze 4 klasifikačních běhů . . . . .	51
6.4	Dosažené výsledky nejlepší metody na testovacích datech při binární klasifikaci - zprůměrované ze 4 klasifikačních běhů . . . . .	52
6.5	Matice neurčitosti (Confusion Matrix) nejlepší metody při binární klasifikaci - zprůměrované ze 4 klasifikačních běhů . . . . .	52
6.6	Zprůměrované výsledky modelů na trénovacích a testovacích datech . . . . .	52
6.7	Dosažené výsledky nejlepší metody rozlišující 4 stavy na testovacích datech - zprůměrované ze 4 klasifikačních běhů . . . . .	53
6.8	Matice neurčitosti (Confusion Matrix) nejlepší metody rozlišující 4 stavy - zprůměrované ze 4 klasifikačních běhů . . . . .	53
6.9	Srovnání senzitivity a přesnosti v této práci s autory článku [9] . . . . .	54

## SEZNAM PŘÍLOH

A	Obsah CD
---	----------

63
----

## A OBSAH CD

- Program
  - `extrakce_priznaku` - funkce pro načtení subjektů, převzorkování signálů, aplikace Víceúrovňové diskrétní vlnkové transformace, extrakci příznaků a standardizaci hodnot
  - `krabicovy_graf` a `krabicovy_graf_4_stavy` - skripty pro první selekční přístup
  - `kolinearita` - skript pro druhý selekční přístup
  - `tvorba_matice_binarni` a `tvorba_matice_4_psych_stavy` - funkce pro vytvoření matice binární a matice 4 psychologických stavů pro strojové učení
  - `rozdeleni_dat` - rozdělí data na trénovací a testovací
  - `vyhodnoceni` a `vyhodnoceni_4_stavy` - skripty k otestování natrénovaného modelu
  - 2 natrénované modely - LR pro klasifikaci binární a SVM pro klasifikaci 4 stavů
- Textový soubor s pokyny ke spuštění a používání programu a popisem funkcí.