



# 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

## **ROZPOZNÁNÍ STRESU POMOCÍ BIOLOGICKÝCH SIGNÁLŮ MĚŘENÝCH NOSITELNÝMI ZAŘÍZENÍMI**

STRESS RECOGNITION USING BIOLOGICAL SIGNALS MEASURED BY WEARABLE DEVICES

**DIPLOMOVÁ PRÁCE**

MASTER'S THESIS

**AUTOR PRÁCE**

AUTHOR

**Bc. Ondřej Surkoš**

**VEDOUCÍ PRÁCE**

SUPERVISOR

**Ing. Lukáš Smital, Ph.D.**

**BRNO 2024**

# Diplomová práce

magisterský navazující studijní program **Bioinženýrství**

Ústav biomedicínského inženýrství

**Student:** Bc. Ondřej Surkoš

**ID:** 222686

**Ročník:** 2

**Akademický rok:** 2023/24

**NÁZEV TÉMATU:**

## **Rozpoznání stresu pomocí biologických signálů měřených nositelnými zařízeními**

**POKYNY PRO VYPRACOVÁNÍ:**

1) Prostudujte problematiku detekce stresu pomocí multimodálních biologických signálů. Zaměřte se především na využití elektrokardiogramu, fotopletysmogramu, elektrodermální aktivity, elektromyogramu, respirace, tělesné teploty nebo akcelerometru. 2) Provedte rešerši veřejných databází (např. na PhysioNetu) a vyhledejte data vhodná pro detekci stresu. Sestavte databázi pro účely této diplomové práce, včetně anotací stresu. 3) Zmapujte metody/příznaky, které se dají pro rozpoznání stresu využít. Příznaky s využitím vhodných dat statisticky zhodnoťte. Dosažené výsledky diskutujte. 4) Na základě předchozích poznatků navrhnete vlastní algoritmus pro rozpoznání stresu. Návrh implementujte ve vhodném programovém prostředí. Ověřte robustnost navrženého algoritmu na kompletní databázi a výsledky diskutujte. 5) Navrženou metodu porovnejte s výsledky jiných autorů, diskutujte výhody i nevýhody vašeho řešení. 6) Provedte diskusi dosažených výsledků, formulujte podmínky použitelnosti vašeho návrhu.

**DOPORUČENÁ LITERATURA:**

[1] SCHMIDT, Philip; REISS, Attila; DUERICHEN, Robert; et al., 2018. Introducing WESAD, a Multimodal Dataset for Wearable Stress and Affect Detection. Online. Dostupné z: <https://doi.org/10.1145/3242969.3242985>.

[2] HOVSEPIAN, Karen; AL'ABSI, Mustafa; ERTIN, et al., 2015. CStress: Towards a Gold Standard for Continuous Stress Assessment in the Mobile Environment. Online. Dostupné z: <https://doi.org/10.1145/2750858.2807526>.

**Termín zadání:** 5.2.2024

**Termín odevzdání:** 22.5.2024

**Vedoucí práce:** Ing. Lukáš Smital, Ph.D.

**doc. Ing. Radim Kolář, Ph.D.**  
předseda rady studijního programu

**UPOZORNĚNÍ:**

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

## ABSTRAKT

S rostoucím významem duševního zdraví ve společnosti a s narůstající dostupností nositelných technologií se nabízí unikátní příležitost využít biologické signály pro monitorování a řízení stresu v každodenním životě. Diplomová práce se zaměřuje na automatické rozpoznávání stresu pomocí biologických signálů měřených nositelnými zařízeními. V teoretické části jsou proto definovány klíčové pojmy týkající se stresu a nositelných zařízení a popsány vybrané biologické signály, které jsou relevantní pro detekci stresu. Práce rovněž představuje několik veřejně dostupných datasetů a popisuje současné metody rozpoznávání stresu, společně s dosaženými výsledky. Praktická část práce se věnuje konstrukci datasetu, předzpracování dat a vývoji algoritmu pro rozpoznání stresu v programovém prostředí MATLAB. Využity jsou zejména techniky strojového učení jak při extrakci a selekci příznaků, tak také při samotné klasifikaci. Výkonosti navržených modelů, které dosahovali přesnosti až 81,1 % v případě sjednoceného datasetu, 97,1 % v případě datasetu WESAD a 80 % v případě datasetu Non-EEG Biosignals, jsou uvedeny a diskutovány v závěrečné části práce, společně se zjištěním velkého vlivu metodologie a využitých zařízení při akvizici dat na výkonnost jednotlivých modelů.

## KLÍČOVÁ SLOVA

Stres, biologické signály, nositelná zařízení, klasifikace, algoritmus, strojové učení, MATLAB.

## ABSTRACT

With the growing importance of mental health in society and the increasing availability of wearable technology, biological signals offer a unique opportunity to monitor and manage stress in everyday life. The diploma thesis focuses on the automatic stress recognition of biological signals measured by wearable devices. Therefore, in the theoretical part, key terms related to stress and wearable devices are defined and selected biological signals relevant for stress detection are described. The work also presents several publicly available datasets and describes current stress recognition methods, together with the achieved results. The practical part of the work is devoted to the construction of the dataset, data preprocessing and the development of an algorithm for recognizing stress in the MATLAB program environment. In particular, machine learning techniques are used both for feature extraction and selection, as well as for the classics themselves. The performance of the proposed models, which reached an accuracy of up to 81.1 % in the case of the unified dataset, 97.1 % in the case of the WESAD dataset and 80 % in the case of the Non-EEG Biosignals dataset, are presented and discussed in the final part of the work, together with by finding a great influence of the methodology and the equipment used during data acquisition on the performance of individual models.

## KEYWORDS

Stress, Biological Signals, Wearables, Classification, Algorithm, Machine Learning, MATLAB.

SURKOŠ, Ondřej. *Rozpoznání stresu pomocí biologických signálů měřených nositelnými zařízenými*. Diplomová práce. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství, 2024. Vedoucí práce: Ing. Lukáš Smital, Ph.D.

## Prohlášení autora o původnosti díla

<b>Jméno a příjmení autora:</b>	Bc. Ondřej Surkoš
<b>VUT ID autora:</b>	222686
<b>Typ práce:</b>	Diplomová práce
<b>Akademický rok:</b>	2023/24
<b>Téma závěrečné práce:</b>	Rozpoznání stresu pomocí biologických signálů měřených nositelnými zařízeními

Prohlašuji, že svou závěrečnou práci jsem vypracoval samostatně pod vedením vedoucí/ho závěrečné práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené závěrečné práce dále prohlašuji, že v souvislosti s vytvořením této závěrečné práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno .....

.....

podpis autora\*

---

\*Autor podepisuje pouze v tištěné verzi.

## PODĚKOVÁNÍ

Rád bych poděkoval vedoucímu diplomové práce panu Ing. Lukáši Smitalovi Ph.D. za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci.

# Obsah

<b>Úvod</b>	<b>11</b>
<b>Cíle práce</b>	<b>13</b>
<b>1 Stres</b>	<b>14</b>
1.1 Definice stresu . . . . .	14
1.2 Biologie stresu . . . . .	15
1.2.1 Sympaticko-adrenomedulární systém . . . . .	15
1.2.2 Hypotalamo-hypofýsární-adrenokortikální systém . . . . .	16
1.3 Vliv stresu na biologické signály . . . . .	18
<b>2 Biologické signály</b>	<b>20</b>
2.1 Elektrodermální aktivita . . . . .	21
2.2 Tělesná teplota . . . . .	22
2.3 Tepová frekvence . . . . .	23
2.4 Pohyb . . . . .	24
<b>3 Nositelná zařízení</b>	<b>25</b>
<b>4 Dostupné datasety</b>	<b>28</b>
4.1 A Non-EEG Biosignals Dataset . . . . .	28
4.2 WESAD Dataset . . . . .	30
4.3 Stress-predict Dataset . . . . .	32
<b>5 Metody automatického rozpoznání stresu</b>	<b>34</b>
5.1 Rozpoznání stresu pomocí modelu strojového učení SVM . . . . .	34
5.2 Posouzení a vizualizace neurologického stavu pomocí Gaussian Mixture modelu . . . . .	37
5.3 Detekce stresu s využitím strojového a hlubokého učení . . . . .	41
<b>6 Praktická část</b>	<b>44</b>
6.1 Předzpracování dat . . . . .	45
6.2 Tvorba datasetu . . . . .	47
6.3 Extrakce a selekce příznaků . . . . .	48
6.3.1 Extrakce příznaků . . . . .	48
6.3.2 Selekcce příznaků . . . . .	50
6.4 Klasifikační modely strojového učení . . . . .	51
6.4.1 Rozdělení dat . . . . .	57
6.4.2 Parametry klasifikačních modelů . . . . .	58

<b>7</b>	<b>Výsledky práce</b>	<b>59</b>
7.1	Experiment 1 . . . . .	59
7.2	Experiment 2 . . . . .	61
7.3	Experiment 3 . . . . .	63
7.4	Experiment 4 . . . . .	65
<b>8</b>	<b>Diskuze</b>	<b>66</b>
	<b>Závěr</b>	<b>68</b>
	<b>Literatura</b>	<b>69</b>
	<b>Seznam příloh</b>	<b>75</b>
<b>A</b>	<b>Obsah elektronické přílohy</b>	<b>76</b>

# Seznam obrázků

1.1	Anatomie SAM systému . . . . .	16
1.2	Anatomie HPA systému . . . . .	17
2.1	Záznam signálů EEG . . . . .	20
2.2	Signál složek SCL a SRC. . . . .	21
2.3	Diagram mechanismu regulace tělesné teploty . . . . .	22
2.4	Vliv sympatiku a parasympatiku na tepovou frekvenci . . . . .	23
3.1	Nositelná zařízení . . . . .	25
3.2	Apple watch ultra2 GPS . . . . .	26
3.3	Glukometr . . . . .	27
3.4	Videoanalýza s využitím Protern.io . . . . .	27
4.1	Zařízení Affectiva Q Curve a Nonin 3150 Wireless WristOx2 Oximeter	28
4.2	Ukázka surových multi-modálních biologických signálů subjektu 1 . .	29
4.3	Umístění zařízení RespiBAN a připojených senzorů . . . . .	30
4.4	Ukázka jednotlivých verzí protokolu . . . . .	31
4.5	Hodinky Empatika E4 . . . . .	32
4.6	Protokol měření datasetu Stress-predict . . . . .	33
5.1	Přehled zpracování dat a kroků strojového učení modelu cStress . . .	36
5.2	Přehled procesu posouzení neurologického stavu . . . . .	38
5.3	2D vizualizace dat metodou PCA a t-SNE . . . . .	39
5.4	Vývojový diagram algoritmu . . . . .	41
6.1	Vývojový diagram algoritmu. . . . .	44
6.2	Biologické signály subjektu 1 datasetu Stress-predict. . . . .	46
6.3	Rozdělení signálů na dílčí části podle stavu měřeného subjektu. . . .	47
6.4	Signál SCL, SCR a SMNA společně s detekcí peaků. . . . .	49
6.5	Koncept Bootstrap agregace . . . . .	50
6.6	Koncept Decition Tree . . . . .	52
6.7	Koncept Random Forrest . . . . .	53
6.8	Koncept Support vector machine . . . . .	54
6.9	Koncept K-nearest neighbors . . . . .	54
6.10	Koncept Logistické regrese . . . . .	55
6.11	Koncept Adaptiv Boostingu . . . . .	56
6.12	10-ti násobná křížová validace . . . . .	57

# Seznam tabulek

5.1	Cross-validační výkon modelu na trénovacím datasetu . . . . .	36
5.2	Matice záměn cross-validace tréninkové skupiny dat . . . . .	37
5.3	Matice záměn testového datasetu . . . . .	37
5.4	Matice záměn a statistické metriky modelu . . . . .	40
5.5	Extrahované příznaky jednotlivých signálů . . . . .	42
5.6	Výkonost jednotlivých klasifikátorů . . . . .	43
6.1	Extrahované příznaky jednotlivých signálů. . . . .	49
6.2	Selektované příznaky pro jednotlivé časové intervaly. . . . .	51
6.3	Shrnutí parametrů klasifikačních modelů . . . . .	58
7.1	Úspěšnost klasifikačních modelů na námi vytvořeném datasetu (10s) .	60
7.2	Úspěšnost klasifikačních modelů na datasetu WESAD (10s) . . . . .	60
7.3	Úspěšnost klasifikačních modelů na datasetu Non-EEG Biosignals (10s)	61
7.4	Úspěšnost klasifikačních modelů na námi vytvořeném datasetu (30s) .	61
7.5	Úspěšnost klasifikačních modelů na datasetu WESAD (30s) . . . . .	62
7.6	Úspěšnost klasifikačních modelů na datasetu Non-EEG Biosignals (30s)	62
7.7	Úspěšnost klasifikačních modelů na námi vytvořeném datasetu (60s) .	63
7.8	Úspěšnost klasifikačních modelů na datasetu WESAD (60s) . . . . .	64
7.9	Úspěšnost klasifikačních modelů na datasetu Non-EEG Biosignals (60s)	64
7.10	Úspěšnost klasifikačních modelů jednotlivých datasetů proti sobě. . .	65

# Úvod

V dnešním rychlém tempu moderního života čelíme stálému tlaku z množství povinností, termínů a společenských očekávání. Tyto neustálé požadavky z pracovního, akademického a osobního života mohou mít významný dopad na naše zdraví, protože přispívají k chronickému stresu, který se stává běžnou součástí naší každodenní existence. Stres nejenže formuje naše každodenní zážitky, ale také významně ovlivňuje naše fyzické a psychické zdraví.

V rámci práce se zaměříme na využití nositelných zařízení pro měření biologických signálů, které nám umožňují lépe porozumět mechanismům stresu. Tato zařízení jsou integrována do našeho každodenního života a poskytují kontinuální monitoring fyziologických reakcí, jako například srdeční frekvence a změny vodivosti kůže. Tyto biomarkery nám umožňují identifikovat reakce lidského těla na stresové podněty.

Mapování rozpoznávání stresu prostřednictvím nositelných technologií není pouze akademickým úsilím, ale stává se důležitým krokem k praktickým aplikacím. Lepší porozumění stresu a jeho dekodování skrze nositelná zařízení nabízí možnosti pro zlepšení kvality života v naší propojené společnosti. Toto zkoumání představuje společný zájem, který může přinést klíčové poznatky pro zdravotní péči a osobní wellness.

První kapitola práce se věnuje stresu a jeho biologickým aspektům. V této kapitole jsou definovány klíčové pojmy související se stresem, probíráme biologii stresu a jeho dopady na lidský organismus. Toto teoretické základní poznání je nezbytné pro pochopení zkoumané oblasti a poskytuje klíčové informace pro vývoj algoritmu, který je schopen rozpoznat stres.

Druhá kapitola se podrobně zabývá biologickými signály, které hrají klíčovou roli v automatickém rozpoznávání stresu. Kapitola se soustředí na ty signály, které byly specificky vybrány pro použití v praktické části této práce. Kromě toho jsou zde podrobně vysvětleny důvody, proč jsou tyto signály považovány za validní ukazatele pro rozpoznávání stresu. Vysvětlujeme, jak jsou tyto signály ovlivněny stresovými reakcemi v těle a jak tato změna umožňuje jejich účinné využití pro detekci stresu.

Třetí kapitola je zaměřena na nositelná zařízení, která hrají stále významnější roli v moderní technologii a zdravotní péči. V této kapitole nejprve definujeme pojem nositelné zařízení a objasňujeme možnosti použití. Dále podrobně shrneme, jak jsou nositelná zařízení využívána v různých oborech, včetně sportu, osobního wellness, a zejména v monitorování zdravotního stavu. Poskytujeme také přehled několika příkladů populárních nositelných zařízení, které se používají pro sběr biologických signálů relevantních pro detekci stresu.

Čtvrtá kapitola poskytuje komplexní přehled veřejně dostupných datasetů, které obsahují biologické signály od subjektů, jež byly měřeny nositelnými zařízeními během expozice různým stresovým podnětům. Tato kapitola detailně popisuje charakteristiky jednotlivých datasetů, včetně typů biologických signálů a specifik experimentálních podmínek, pod kterými byla data získána. Tyto datasety jsou klíčové pro tvorbu konečného datasetu v praktické části této práce, kde poslouží jako vstupní data pro vývoj a validaci našeho algoritmu pro rozpoznání stresu.

Pátá kapitola poskytuje přehled metod automatického rozpoznání stresu, které jsou v současnosti využívány. V této kapitole jsou prezentovány různé studie, které se zaměřily na toto téma. Detailně popisuje jednotlivé přístupy k detekci stresu, způsoby jejich aplikace a uvádí výsledky dosažené v rámci těchto studií. Analýza těchto metod umožňuje ucelený pohled na stávající techniky a poskytuje základ pro pochopení jejich efektivity a omezení.

Poslední kapitola se zaměřuje na praktické aspekty této práce, kde hlavním cílem je tvorba algoritmu pro automatické rozpoznání stresu. Kapitola nejprve podrobně popisuje vstupní data získaná z nositelných zařízení a procesy jejich předzpracování, které zahrnují převzorkování a filtraci jednotlivých biologických signálů. Důležitou součástí práce bylo také vytvoření datasetu, který slouží jako základ pro následnou analýzu a vývoj klasifikačních modelů. Následně se věnujeme metodám extrakce příznaků a jejich selekci, kde jsou vybrány ty nejrelevantnější pro použití v klasifikačních modelech strojového učení. V této části je podrobně popsán také proces binární klasifikace, který slouží k rozlišení, zda subjekty jsou či nejsou vystaveny stresovému podnětu.

Výsledky dosažené v této práci jsou detailně shrnuty v kapitole nazvané Výsledky práce. Diskuze se zaměřuje na výhody a nevýhody navrženého algoritmu, přičemž jsou tyto aspekty porovnávány s výsledky jiných studií a prací na podobné téma.

# Cíle práce

## Literární rešerše

Prvním cílem diplomové práce je provést důkladnou literární rešerši zaměřenou na oblast stresu a metod jeho automatického rozpoznávání. Cílem je také zhodnotit a shrnout dostupné datasety, které jsou relevantní pro tuto tematiku, s důrazem na jejich vhodnost, obsah a metody sběru dat.

## Tvorba datasetu

Druhým cílem realizované studie je selekce datasetů na základě kritérií jako jsou relevance, objem a metodologie získávání dat. Následně bude vytvořen sjednocený dataset, který bude sloužit jako základ pro praktickou část této práce. Tento dataset bude obsahovat biologické signály subjektů, které byly vystaveny stresovým podnětům a jejichž data byla zaznamenána pomocí nositelných zařízení a opatřena příslušnými anotacemi.

## Rozpoznání stresu

Třetím, a zároveň hlavním cílem práce, je vývoj algoritmu pro automatické rozpoznání stresu na základě analýzy biologických signálů získaných z vybraných datasetů. V rámci tohoto procesu budou z dat extrahovány relevantní příznaky a provedena jejich selekce za účelem optimalizace vstupů pro klasifikační modely strojového učení. Hlavním výstupem práce bude implementace modelu binární klasifikace, která bude schopna určit, zda je subjekt vystaven stresové situaci.

# 1 Stres

## 1.1 Definice stresu

Podle Světové zdravotnické organizace, World Health Organization (WHO) [1], se stres projevuje jako stav úzkosti nebo psychického napětí, který je vyvolán náročnými situacemi. Jde o běžnou lidskou reakci, která nás motivuje k řešení výzev a hrozeb v našem životě. Každý člověk zažívá určitou úroveň stresu, avšak způsob, jakým na stres odpovídáme, má klíčový vliv na naši celkovou pohodu.

Světová zdravotnická organizace dále konstatuje, že stres má dopad jak na psychické, tak na fyzické zdraví člověka. Zatímco mírné množství stresu může být užitečné a napomáhat nám v běžných denních činnostech, příliš vysoké úrovně stresu mohou vést k vážným fyzickým i psychickým potížím. Rozvoj dovedností pro efektivní zvládnutí stresu může značně přispět ke snížení pocitu přetížení a podporovat naši celkovou mentální a fyzickou pohodu.

V literatuře [2] se uvádí čtyři typy stresu:

1. Akutní stres - krátkodobý stres.
2. Epizodický akutní stres - epizodický akutní stres je akutní stres, který se zdá být nekontrolovatelný. Vrací se opakovaně a velmi často. Může mít negativní dopad na fyzické i psychické zdraví jedince.
3. Chronický stres - konzistentní pocit nátlaku a přetížení po dlouhý časový úsek. Může způsobovat vážné fyzické i psychické problémy.
4. Eustres - eustres je zábavný a vzrušující. Je známý jako pozitivní typ stresu, který vás dokáže nabít energií. Je spojený s návaly adrenalinu.

Stresové spouštěče se odborně označují jako stresory. Stresor může být chemické nebo biologické povahy a zahrnuje látky, stavy prostředí, vnější podněty nebo události, které organismus vnímá jako zdroje stresu. Z psychologického hlediska jsou stresory definovány jako události nebo situace, které jednotlivci vnímají jako vysoce náročné nebo jako hrozbu pro jejich bezpečnost. [3]

## 1.2 Biologie stresu

Autoři studie [4] uvádí, že stres, i když často studovaný jako psychologický jev, může být viděn z biologické perspektivy, jelikož ho doprovází řada fyziologických změn. U savců jsou ovlivněny stresové reakce dvěma odlišnými, ale vzájemně propojenými systémy: sympaticko-adrenomedulárním systémem (SAM) a hypotalamo-hypofýsární-adrenokortikální systémem (HPA).

SAM systém je součástí sympatického oddělení autonomního nervového systému, uvolňuje epinefrin (adrenalin) z dřene nebo středu nadledvin. Zvýšení cirkulujícího epinefrinu usnadňuje rychlou mobilizaci metabolických zdrojů a organizování odezvy boje/útěku. [4]


Systém HPA, naproti tomu produkuje glukokortikoidy (kortizol u lidí, kortikosteron u hlodavců, dále GC), což jsou steroidní hormony. Na rozdíl od epinefrinu, který neprochází do značné míry hematoencefalickou bariérou, hlavním cílem GC je mozek. [4]

### 1.2.1 Sympaticko-adrenomedulární systém

Chromafinní buňky v dřeni nadledvin jsou sekreční buňky, které mají evoluční a funkční podobnost s postgangliovými sympatickými neurony a jsou považovány za součást sympatického nervového systému. Tyto buňky jsou aktivovány sympatickými pregangliovými neurony, které se nacházejí v intermediolaterální šedé hmotě míchy. Předgangliové sympatické neurony vysílají axony přes ventrální kořeny míchy a vytvářejí cholinergní synapse s chromafinními buňkami. [4]

Když jsou tyto buňky stimulovány, uvolňují katecholaminy, zejména epinefrin (Epi) a v menší míře noradrenalin (NE). Tyto látky se vážou na adrenoreceptory v různých cílových orgánech a hrají klíčovou roli v reakcích boje nebo útěku. Například, Epi a NE zvyšují tepovou frekvenci a srdeční výdej, způsobují rozšíření cév ve svalech a zúžení cév jinde, což zajišťuje efektivní prokrvení mozku a svalů. Epi také podporuje rozklad glykogenu v játrech, což vede k zvýšení hladiny glukózy v krvi a poskytuje energii pro obranné reakce. [4]

Ačkoli Epi a NE neprocházejí hematoencefalickou bariérou, jejich periferní účinky na mozek jsou paralelně zprostředkovány noradrenalinem produkovaným v locus coeruleus. Tento region mozku podporuje během psychosociálního stresu bdělost, vzrušení a soustředění pozornosti a také se podílí na aktivaci systému HPA. [4]

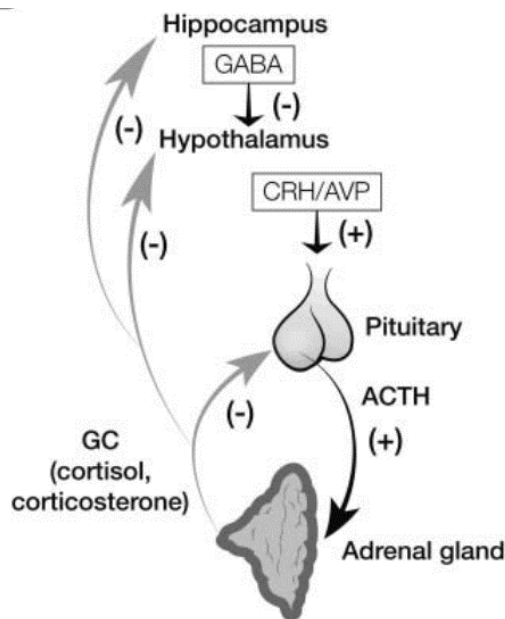


Obr. 1.1: Anatomie SAM systému, převzato z [4]

### 1.2.2 Hypotalamo-hypofýsární-adrenokortikální systém

Sekvence událostí vedoucí k produkci glukokortikoidů začíná v paraventrikulárních jádrech hypotalamu, kde dochází k uvolnění kortikotropin uvolňujícího hormonu (CRH) a arginin vasopresinu (AVP). Tyto hormony jsou transportovány malými krevními cévami do přední části hypofýzy, kde podněcují sekreci adrenokortikotropního hormonu (ACTH). [4]

ACTH poté působí na receptory v kůře nadledvin, což stimuluje produkci a uvolňování glukokortikoidů (GC) do krevního oběhu. GC pronikají do cytoplazmy buněk po celém těle a v mozku, kde se vážou na specifické receptory. Existují dva hlavní typy receptorů, na které se GC vážou: mineralokortikoidní receptor (MR) a glukokortikoidní receptor (GR). Většina tělesných buněk využívá GR pro interakci s GC, díky přítomnosti enzymu 11-beta hydroxysteroid dehydrogenázy (11 beta-HSD), který zabraňuje vazbě GC na MR. V mozku, kde je množství tohoto enzymu minimální, se GC mohou vázat jak na MR, tak na GR. Je důležité poznamenat, že GC mají vyšší afinitu k vazbě na MR než na GR, což hraje klíčovou roli při regulaci bazálních i stresových reakcí v rámci systému HPA. [4]



Obr. 1.2: Anatomie HPA systému, převzato z [4]

Jak uvádí [4], v klidovém stavu jsou mineralokortikoidní receptory (MR) zhruba z 80-90 % nasyceny glukokortikoidy (GC), zatímco glukokortikoidní receptory (GR) jsou aktivovány převážně během vrcholu cirkadiálního cyklu nebo v situacích, kdy jsou hladiny GC zvýšené kvůli stresu. GR jsou primárně zodpovědné za zprostředkování stresových reakcí GC, kdežto MR se podílí na regulaci základních funkcí, jako je citlivost neuronů na neurotransmitery, kontrola cirkadiálního rytmu osy HPA s maximem při probuzení a minimem 30 minut po zahájení dlouhého spánku a udržení krevního tlaku.

Zatímco základní účinky jsou často vnímány jako odlišné od stresových účinků GC, mají v kontextu stresu podpůrnou roli. GR mají negativní vliv na neuronální plasticitu a učení v hipokampu, zatímco MR na základní úrovni GC podporují synaptickou plasticitu. MR zvyšují dostupnost glukózy v mozku, kdežto GR snižují celkové využití glukózy, což může ohrozit přežití buněk. Navíc GR aktivují dráhy do paraventriculárního jádra, inhibují produkci kortikotropin uvolňujícího hormonu (CRH) a tím ukončují stresovou odpověď osy HPA. Existuje otázka, proč by GR, aktivované během stresu, měly nepříznivé účinky. Argumentuje se, že tyto inhibiční účinky GR jsou evolučně nezbytné pro regulaci akutní stresové odpovědi a obnovení buněčné homeostázy. [4]

Pojem allostáza označuje udržení životaschopnosti organismu prostřednictvím aktivace reakcí SAM a HPA, zatímco alostatická zátěž vyjadřuje náklady spojené s opakovanými nebo dlouhodobými stresovými odpověďmi. [4]

## 1.3 Vliv stresu na biologické signály

Autoři studie na téma vlivu stresu na biologické signály [5] uvádějí, že stres je přirozenou reakcí těla na změny nebo výzvy, které mohou vyvolat jak fyzické, tak mentální odpovědi. Stres ovlivňuje několik biologických signálů, které lze spolehlivě měřit jako jsou elektrokardiogram (ECG), elektromyogram (EMG), elektroencefalogram (EEG), elektrodermální aktivita (EDA). Tento vliv je zvláště významný u signálů spojených se srdcem, kůží a dalšími tělesnými funkcemi. Porozumění těmto signálům pomáhá lépe monitorovat a řídit stresové reakce.

Autoři však také uvádějí, že organismus každého člověka reaguje na různé stresory odlišně. To může učinit automatické rozpoznání stresu obtížným úkolem.

### Signály srdce

Srdeční funkce je regulována dvěma hlavními neuromodulačními systémy: parasympatickým nervovým systémem (PNS), který používá neurotransmitter acetylcholin, a sympatickým nervovým systémem (SNS), který využívá norepinefrin. Aktivace SNS během stresových situací vede k zesílení srdeční frekvence a zvýšení síly srdeční kontrakce. Tato reakce umožňuje rychlejší cirkulaci krve po těle, což zajišťuje okamžité dodání kyslíku do orgánů a svalů, čímž tělo reaguje na stresor. [5] [6]

Stres má významný dopad na krevní tlak a je spojen s vyšším rizikem vzniku kardiovaskulárních onemocnění. Časté vystavení stresu aktivuje SNS, což má za následek vazokonstrikci, tedy zúžení krevních cév, které komplikuje normální průtok krve. Toto zúžení může vést ke zvýšení systolického, diastolického i středního arteriálního tlaku, zejména během mentálně náročných úkolů, jako je mentální aritmetika. [5]

Kromě vlivu na krevní tlak, stres také zvyšuje tepovou frekvenci, což je další významný indikátor stresu. Srdeční frekvence, což je počet srdečních tepů za minutu, představuje jednu nejrozšířenějších a nejpřímějších metod pro rozpoznání stresu. Alternativou je měření středního intervalu RR, intervalu mezi po sobě jdoucími srdečními údery, který má inverzní vztah k srdeční frekvenci. Tyto metriky poskytují přesné údaje o reakci srdečního systému na stresové podněty. [5] [6]

### Signály získané z kůže

Když jsou lidé vystaveni stresovým situacím, je velmi pravděpodobné, že dosáhnou maximálních hodnot elektrodermální aktivity (EDA), což je jev přímo ovlivněný sympatickým nervovým systémem (SNS). Aktivace SNS zvyšuje činnost potních žláz a způsobuje náhlé změny v srdečním tepu a dýchání během emocionálně náročných

momentů. Tyto změny se odrážejí ve zvýšení úrovně skin conductance level (SCL) a skin conductance response (SCR), což jsou parametry, které se účinně využívají k měření intenzity stresu. Výzkumy rovněž potvrzují významný vztah mezi aktivitou potních žláz a mentálními procesy a psychofyzilogickými stavy. [5]

Dalším důležitým ukazatelem stresu je proměnlivost teploty kůže. Zjištění ukazují, že stres způsobuje zvýšení teploty čela. Vyšší úroveň úzkosti může vést k zvýšení teploty kolem očí, což souvisí s napětím svalů v této oblasti, které může omezit průtok krve. Jakmile se svalové napětí uvolní, krev se do těchto oblastí vrátí, což vede k lokálnímu zahřátí tkání. [5]

### **Signály hlavy**

Elektroencefalogram (EEG) je běžně využívaná metoda pro sledování neurofyzilogických změn, které nastávají v reakci na externí podněty nebo během vykonávání specifických úkolů. Je známo, že levá přední část mozku je spojena s emocemi, které vyvolávají přístup, jako je štěstí a hněv, zatímco pravá přední část se váže na emoční stavy vedoucí k vyhýbání se, jako jsou smutek a strach. V období stresu se v pravé frontální oblasti obvykle projevuje zvýšená alfa aktivita ve srovnání s levou frontální oblastí. Tento fenomén je zachycen pomocí indexu asymetrie EEG, který se vypočítá jako rozdíl přirozených logaritmů výkonu alfa vln pravé a levé hemisféry. Tento index je považován za spolehlivý ukazatel emočního vzrušení a je klíčovým prvkem mnoha studií zaměřených na rozpoznávání specifických psychických stavů. [6]

Nicméně použití EEG s elektrodami připevněnými na hlavě může být pro některé jedince nepohodlné, což může potenciálně zkreslit výsledky měření. Z tohoto důvodu se nabízí alternativa v podobě měření průměru zornic, které by mohlo představovat vhodnější metodu pro hodnocení stresu. Podle některých studií dochází ve stresových situacích k častějšímu rozšiřování zornic. Stres rovněž vyvolává rychlejší pohyby očí, což poskytuje další možný ukazatel pro detekci stresového stavu. [5]


### **Signály svalů**

Studie potvrzují, že držení těla a celková pohybová aktivita jsou spolehlivými indikátory stresové úrovně; přičemž omezení pohybů může signalizovat vyšší úroveň stresu. Stresové situace aktivují sympatický nervový systém (SNS), což vede ke zvýšení svalového tonu a tedy k tonickým i fázickým změnám v energii EMG (elektromyografie). Dále bylo zjištěno, že nejvýraznější změny EMG signálů jsou pozorovatelné u trapézového svalu, když je testovaná osoba vystavena stresovému podnětu. [6]

## 2 Biologické signály

Signál je jev fyzikální, chemické, biologické, ekonomické či jiné materiální povahy, nesoucí informaci o stavu systému, který jej generuje, a jeho dynamice. Signál lze obecně popsat pomocí funkce  $x(t)$   $R$  nezávislých proměnných  $t$  oboru  $O$ . Nezávislou proměnnou  $t$  bývá zpravidla čas, prostorové souřadnice, či jejich kombinace. [7]

Jako biosignály můžeme označit veškeré signály, jejichž přítomnost můžeme zaznamenat v živých organismech. Jedná se mimo jiné o průběhy elektrických napětí, mechanické pohyby, proměnlivá magnetická pole, změny chemických koncentrací, změny teplot a zvuky. [8]



Obr. 2.1: Záznam signálů EEG, převzato z [7]

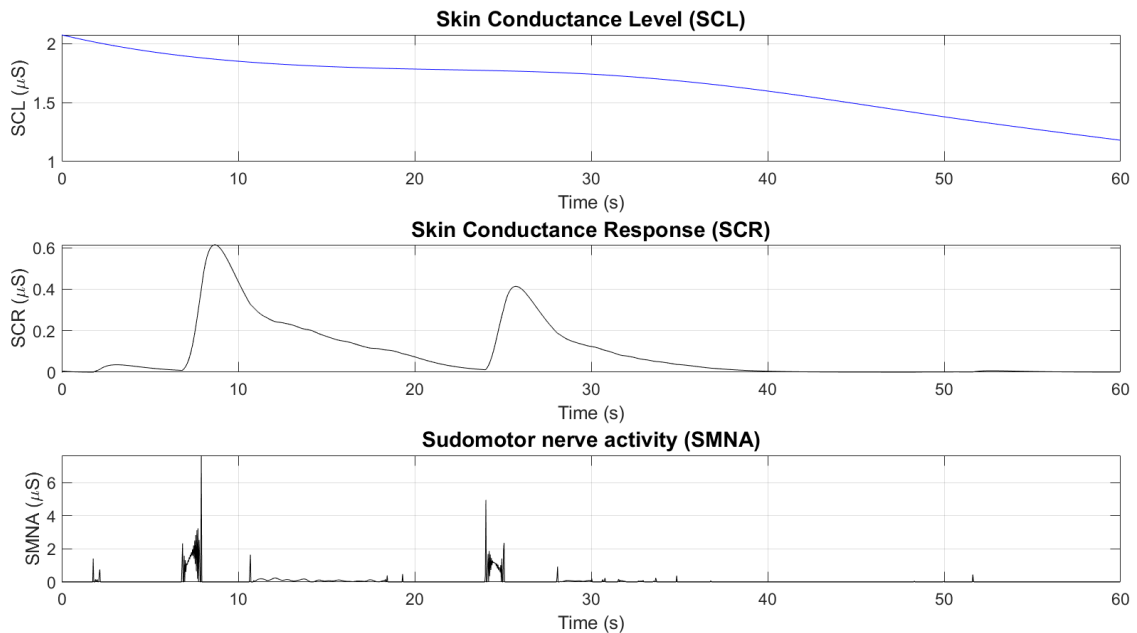
Pro účely dalšího zpracování je vhodné uvést rozdělení signálu podle jeho rozměrů. Jednorozměrné biosignály představují časovou posloupnost hodnot měřené veličiny, například teplotní průběh, časový průběh saturace kyslíkem nebo záznam signálů EEG (viz. obrázek 2.1). Dvojměrné biosignály odpovídají řadě biosignálů získaných ve stejný čas a stejného dvojměrného prostoru. Jedná se obvykle o obrazová data. Trojměrné biosignály jsou reprezentací signálu získaného s ohledem na prostorové rozložení jeho zdrojů. Reprezentací takového signálu může být například matice vektorů. Trojměrnými biosignály jsou například data získaná z CT. [9]

V následujících podkapitolách se budeme věnovat jednotlivým biologickým signálům, které budou využity v následné praktické části a jsme schopni je získat pomocí nositelných zařízení. Vyhňeme se tedy biologickým signálům jako jsou například elektrokardiogram (EKG) a elektroencefalogram (EEG).

## 2.1 Elektrodermální aktivita

Elektrodermální aktivita (EDA) je termín označující změny v elektrických vlastnostech kůže, které jsou řízeny autonomním nervovým systémem. Tradiční teorie uvádí, že elektrický odpor kůže se mění v závislosti na aktivitě potních žláz. Kožní vodivost, která je jednou z nejčastěji zkoumaných vlastností EDA, se kvantifikuje aplikací elektrického napětí mezi dvěma body na kůži a měřením proudu, který těmito body prochází. [10]

Odborná literatura [11] uvádí, že komplex EDA obsahuje jak pomalu měnící se tonickou složku (úroveň kožní vodivosti: SCL), tak i rychlé fázické složky (Skin Conductance Responses: SCRs) (viz obrázek 2.2) vyvolané aktivitou sympatických neuronů ovlivňujících potní žlázy, zejména aktivitou sudomotorického nervu (SMNA).



Obr. 2.2: Signál složek SCL a SRC.

Podle [10], je distribuce potních žláz v lidském těle variabilní, s nejvyšší koncentrací v oblastech rukou a nohou (200–600 potních žláz na  $\text{cm}^2$ ). Reakce kůže a svalové tkáně na vnější i vnitřní podněty mohou způsobit variace vodivosti v řádu mikrosiemens.

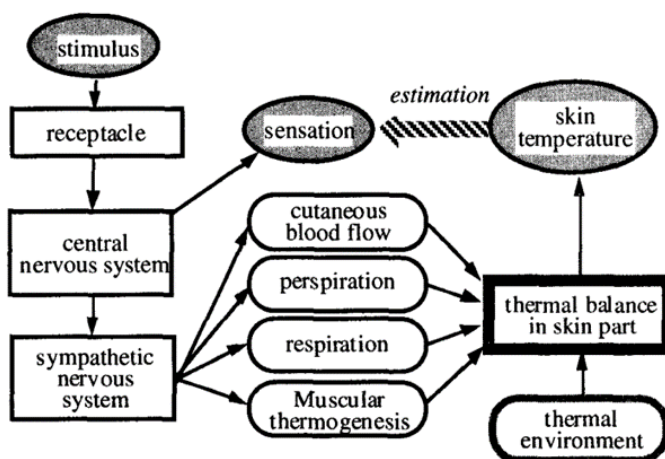
Na základě výše popsaných vlivů sympatického nervového systému na elektrodermální aktivitu a spojení mezi kognitivními stavy, vzrušením, emocemi a pozorností lze elektrodermální aktivitu využít jako objektivní ukazatel emočního stavu a je často využívána v algoritmech pro rozpoznání stresu. Příkladem je studie [12] pracující na ComEDA algoritmu pro rozpoznání stresu využívající elektrodermální aktivitu.

## 2.2 Tělesná teplota

Tělesná teplota označuje přirozenou teplotu organismu, která je nezbytná pro jeho normální fungování. Každý živočišný druh má specifickou tělesnou teplotu, ovlivněnou řadou faktorů. Podle [13] slouží k regulaci tělesné teploty organismu vícero mechanismů. Prvním reakčním krokem na nepříznivé teplotní podmínky je vazomotorická regulace, která ovlivňuje průtok krve kůží. V případě potřeby snížení tepelných ztrát dochází k vazokonstrikci, zatímco vazodilatace slouží ke zvýšení ochlazovacího efektu. Druhým mechanismem je upravování svalové aktivity, včetně třesu a změny svalového tonusu. V situacích, kdy ani tyto mechanismy nedostačují k adekvátní regulaci tělesné teploty, se aktivuje mechanismus pocení.

Tyto mechanismy jsou mimo jiné ovlivněny sympatickou nervovou aktivitou, jakožto reakcí mozku na okolní podněty. V přítomnosti stresového podnětu je omezen průtok krve v končetinách a je zvýšeno pocení. Oba tyto jevy mají přímý vliv na tělesnou teplotu. [14]

Mechanismus regulace teploty jako reakce na okolní stimuly je znázorněn na obrázku 2.3.



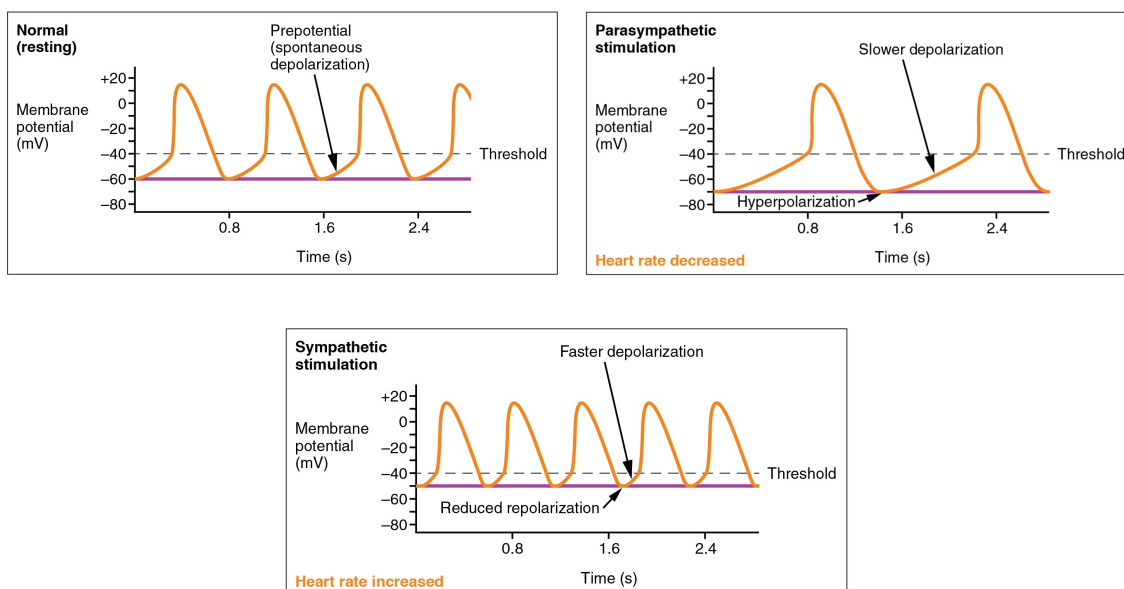
Obr. 2.3: Diagram mechanismu regulace tělesné teploty, převzato z [14]

Jak bylo uvedeno, tělesná teplota se mění v závislosti na aktivitě sympatického nervového systému, která se zvyšuje v situacích, kdy je organismus ohrožen nebo vystaven stresovému podnětu. Tyto poznatky nám umožňují zahrnout tělesnou teplotu do procesu rozpoznávání stresu pomocí biologických signálů.

## 2.3 Tepová frekvence

Frekvence srdečních tepů, známá jako tepová frekvence, udává počet srdečních kontrakcí za minutu. Tato frekvence se může různit v závislosti na fyziologických potřebách těla a je ovlivněna širokou škálou faktorů, včetně genetiky, fyzické kondice, úrovně stresu nebo psychického stavu, stravovacích návyků, užívání léků, hormonálního profilu, prostředí a dalších. [15]

Jak již bylo naznačeno výše, [15] uvádí, že zatímco srdeční rytmus je za normálních okolností plně regulován sinoatriálním uzlem, srdeční frekvence je ovlivňována sympatickým a parasympatickým vstupem do tohoto uzlu. Sympatický vstup, poskytovaný akceleračním nervem, zvyšuje srdeční frekvenci prostřednictvím uvolňování norepinefrinu do buněk sinoatriálního uzlu (SA uzlu), zatímco parasympatický vstup, přinášený bloudivým nervem, snižuje srdeční frekvenci prostřednictvím uvolňování acetylcholinu do buněk sinoatriálního uzlu. Stimulace akceleračního nervu tak vede k urychlení srdeční frekvence, naopak stimulace bloudivého nervu má opačný účinek a způsobuje její snížení. Obrázek 2.4 naznačuje změnu rychlosti depolarizace v závislosti na aktivitě sympatiku a parasympatiku. Můžeme si všimnout, že se mění i minimální hodnota membránového potenciálu, vyznačená fialovou barvou.



Obr. 2.4: Vliv sympatiku a parasympatiku na tepovou frekvenci, převzato z [15]

Autoři [15] uvádí, že normální klidová srdeční frekvence dospělého člověka je 60–100 tepů za minutu. Klidová srdeční frekvence ultratrénovaného sportovce je znatelně nižší a může se pohybovat okolo 40 tepů za minutu.

Na základě těchto poznatků můžeme říci, že tepová frekvence je vhodným biologickým signálem pro rozpoznání stresu, a proto bude tepová frekvence dalším signálem vstupujícím do našeho algoritmu pro rozpoznání stresu pomocí biologických signálů.

## 2.4 Pohyb

Stresové hormony adrenalin a kortizol zaplavují při stresovém období organismus. Svaly se při tom všem napnou, pak se uvolní, když stresor odezní, což může způsobovat zprvu omezení pohybu a následné otřesy. Úzkostné třesení obvykle trvá, dokud stresová reakce neskončí. [17] Těchto otřesů a pohybů nejen končetin můžeme využít, jakožto ukazatele stresového období.

Pro měření pohybu obecně, můžeme využít akcelerometrů. Akcelerometr je zařízení umožňující měření a analýzu lineárního a úhlového zrychlení a tedy i pohybu. Je schopný měřit sílu zrychlení v jednotkách g, existují verze, které pracují v jedné, dvou nebo třech rovinách. V dnešní době jsou nejčastěji využívány tříosé akcelerometry, které sestávají z trojice akcelerometrů. Každý z těchto akcelerometrů měří zrychlení ve specifickém směru - v rovinách X, Y a Z. [16]

Mezi základními druhy akcelerometrů vynikají tři typy: kapacitní akcelerometry MEMS, piezoelektrické akcelerometry a piezorezistivní akcelerometry. [16]


Princip činnosti kapacitních akcelerometrů spočívá v umístění hmoty na pružiny. Tyto pružiny jsou připojeny jedním koncem k deskám hřebenového kondenzátoru a druhým koncem k připojené hmotě. Když je senzor vystaven síle, působící na zařízení, hmotnost se pohybuje po pružinách, což způsobuje změnu vzdálenosti mezi kondenzačním prvkem a hmotou. Tato změna vzdálenosti ovlivňuje kapacitu. Kapacitní akcelerometry, vytvořené pomocí technologie MEMS (Mikroelektromechanické systémy), jsou široce využívány v zařízeních nošených na těle, mobilních zařízeních a v různých spotřebních elektronických produktech. [16]

Dalším typem akcelerometrů jsou senzory využívající piezorezistivní jev. Tyto akcelerometry jsou vybaveny materiálem s piezorezistivními vlastnostmi, který se deformuje pod působením vnější síly, což způsobuje změnu odporu. Tato změna odporu je následně přeměněna na elektrický signál, který je zachycen přijímačem integrovaným s akcelerometrem. Piezorezistivní akcelerometry se vyznačují širokým měřicím pásmem. Funkční princip piezoelektrického akcelerometru sdílí podobnosti s piezorezistivními obvody. Avšak, na rozdíl od piezorezistivních zařízení, piezoelektrický akcelerometr nezmění svůj odpor pod vlivem zrychlení. Místo toho generuje elektrické napětí o hodnotě odpovídající zrychlení. [16]

### 3 Nositelná zařízení

Nositelná technologie zahrnuje technická zařízení navržená k nošení v blízkosti nebo na těle uživatele, která jsou vybavena integrovanými elektronickými a optickými senzory pro těsný kontakt s biologickou tkání. Senzory, umístěné přímo na kůži nebo do ní zabudované, efektivně detekují, analyzují a přenášejí informace o stavu měřeného subjektu. Tyto senzory mohou být součástí elektronických zařízení, všité do oblečení nebo integrální součástí kontaktních čoček. Příklady umístění nositelných zařízení můžeme vidět na obrázku 3.1. Zařízení jsou často napájena lehkými bateriemi nebo bezdrátově a umožňují bezdrátovou komunikaci s jinými zařízeními. [18] [19]

Z důvodu schopnosti snímání a sběru dat, společně se schopností bezdrátové výměny těchto dat přes internet s výrobcem, operátorem a/nebo dalšími připojenými zařízeními, aniž by vyžadovala lidský zásah, se nositelná zařízení řadí do skupiny Internet of things (internet věcí). [18]



Obr. 3.1: Nositelná zařízení, převzato z [19]

Jak v této souvislosti uvádí [20], v dnešní době nám nositelné zařízení mohou obstarat mnoho užitečných dat, mimo jiné například:

1. Tepovou frekvenci.
2. Elektrodermální aktivitu.

3. Saturaci krve kyslíkem.
4. Teplotu těla.
5. Teplotu okolního vzduchu.
6. Nadmořskou výšku.
7. Data popisující kvalitu spánku.
8. Data o fyzické aktivitě.

Nositelná zařízení si získala popularitu v mnoha oblastech díky své dostupnosti a pokročilým funkcím.

Chytré hodinky, jako jeden z neznámějších příkladů (viz. obrázek 3.2), nám poskytují rozmanitá data o aktivitách uživatelů. Jsou také vybaveny GPS a podporují řadu aplikací, které usnadňují komunikaci s ostatními. Kromě toho, díky integrovaným sensorům, mohou monitorovat zdravotní ukazatele jako jsou srdeční tep, kvalita spánku a hladina kyslíku v krvi, což umožňuje uživatelům lépe dbát o své zdraví a kondici. Navíc moderní chytré hodinky mohou přijímat notifikace přímo z vašeho telefonu a některé modely dokonce umožňují přijímat telefonní hovory nebo platit prostřednictvím NFC.



Obr. 3.2: Apple watch ultra2 GPS, převzato z [21]

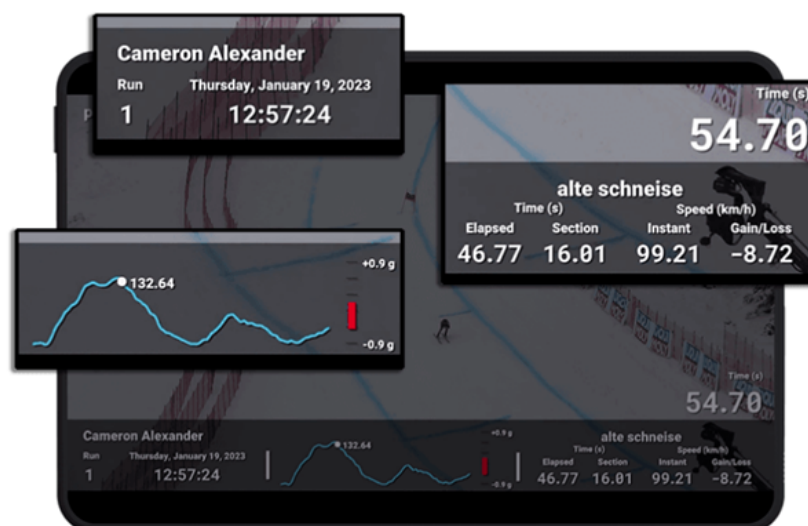
Dalším příkladem využití nositelných zařízení je monitorování zdravotního stavu uživatele, například péče o zdraví diabetiků v podobě kontinuálního měření hladiny glukózy v intersticiální tekutině pomocí chytrých glukometrů (viz. obrázek 3.3). Kontinuální monitor glukózy (CGM) používá vlákno potažené enzymy k detekci glukózy v intersticiální tekutině. Tyto senzory měří obsah glukózy v krvi nepřetržitě 24 hodin denně až po dobu několika týdnů. Data získaná z těchto glukometrů lze

bezdrátově přenášet do mobilních aplikací, kde jsou dále analyzována. [22] [23]



Obr. 3.3: Glukometr, převzato z [24]

V neposlední řadě se nositelná zařízení využívají ve sportu pro monitoring a analýzu tréninkových metod a výkonosti sportovců. Příkladem takového zařízení je Protern.io [25]. Protern.io je nositelné zařízení určené především pro tréninky alpských lyžařů a měření času. Pomocí vysoce přesné GPS a akcelerometrů monitoruje a zaznamenává přesnou polohu, rychlost, zrychlení a další metriky související s tréninkovými aktivitami sjezdových lyžařů (viz. obrázek 3.4).



Obr. 3.4: Videoanalýza s využitím Protern.io, převzato z [25]

## 4 Dostupné datasety

V této kapitole budou popsány některé z veřejně dostupných datasetů, obsahující biologické signály měřených subjektů, které byli vystaveni sledu stresových podnětů. Tyto datasety budou následně využity v praktické části pro tvorbu komplexní databáze, která poslouží jako vstup našeho algoritmu.

### 4.1 A Non-EEG Biosignals Dataset

Výzkumný tým na Univerzitě v Texasu v Dallasu se zaměřil na využití nositelných technologií k vytváření komplexní databáze multimodálních biologických signálů. Tento přístup má za cíl hodnotit neurologický stav bez tradičních metod využívajících povrchové nebo implantované elektrody pro sběr EEG signálů. Výzkumníci zkoumají možnosti monitorování neurologického stavu prostřednictvím biosignálů zachycených nositelnými zařízeními na zápěstí, která jsou navržena tak, aby byla uživatelsky pohodlná a efektivní. [26]


Data byla shromážděna prostřednictvím dvou nositelných zařízení. První z nich, Affectiva Q Curve, zaznamenává elektrodermální aktivitu (EDA), teplotu těla (Temp) a pohyb skrze třídimenzionální akcelerometr (Acc) při vzorkovací frekvenci 8 Hz. Druhé zařízení, bezdrátový oxymetr Nonin 3150 WristOx2, monitoruje srdeční frekvenci (HR) a saturaci kyslíku v krvi (SpO2) s použitím pulzní oxymetrie a pracuje při vzorkovací frekvenci 1 Hz. Časová synchronizace obou zařízení byla realizována jejich společným propojením s notebookem vybaveným speciálně vyvinutým softwarem pro integraci s těmito nositelnými přístroji. Obě zařízení můžeme vidět na obrázku 4.1. [26]



Obr. 4.1: Zařízení Affectiva Q Curve (vlevo) a Nonin 3150 Wireless WristOx2 Oximeter (vpravo), převzato z [26]

Souhrn signálů měřené výše uvedenými zařízeními, jejichž příklad můžeme vidět na obrázku 4.2:

1. Elektrodermální aktivita (EDA).
2. Teplota těla.
3. Pohyb zápěstí.
4. Tepová frekvence (HR).
5. Saturace krve kyslíkem (SpO2).



Obr. 4.2: Ukázka surových multi-modálních biologických signálů subjektu 1, přezato z [26].

Cílem bylo rozlišit reakce na různé typy stresu. Byl navržen protokol skládající se z jednotlivých částí, popsaných níže, v předem daném pořadí. Experimentu se zúčastnilo 20 vysokoškolských studentů (14 mužů a 6 žen). [26]


1. První relaxace: 5 minut.
2. Fyzický stres: Stoj po dobu jedné minuty, chůze na páse rychlostí 1 mph po dobu 2 minut, běh na páse rychlostí 3 mph po dobu 2 minut.
3. Druhá relaxace: 5 minut.
4. Kognitivní stres: Počítání pozpátku po sedmi od čísla 2485 po dobu 3 minut. Následoval Stroopův barevný slovní test (Stroop-CW). V rámci tohoto testu bylo požadováno, aby subjekty identifikovaly barvu inkoustu, kterou bylo slovo vytištěno, namísto samotného slova, které označuje barvu. Subjekt byl upozorněn bzučákem na případnou chybu.
5. Třetí relaxace: 5 minut.
6. Emoční stres: Subjektům byly ukázány části z hororových filmů. Jedna část trvá 1 minutu. Části filmu byly z apokalyptického filmu "The Horde".
7. Čtvrtá relaxace: 5 minut. [26]

## 4.2 WESAD Dataset

Skupina vědců v čele s Philipem Schmidtem, ve spolupráci s Robert Bosch GmbH a Siegen Univerzitou, si dala za cíl vytvořit nový multimodální, veřejně dostupný dataset pro rozpoznání stresu. Tímto datasetem je dataset WESAD. [27]

Dataset WESAD shromažďuje biologické signály od subjektů, kterým byly prezentovány stresové a zábavné podněty. Konkrétně zahrnuje signály jako elektrokardiogram (EKG), elektromyogram (EMG), respirační aktivitu (RESP), elektrodermální aktivitu (EDA), teplotu těla (TEMP) a pohybová data získaná z akcelerometrů (ACC). Tyto údaje byly zaznamenány pomocí zařízení RespiBAN Professional a náramku Empatica E4, což umožnilo monitorování fyziologických reakcí v kontrolovaném experimentálním prostředí. [27]

RespiBAN Professional je vybaven senzory pro měření pohybu, prostřednictvím třídímenzionálního akcelerometru, a respirační aktivity. Toto zařízení také slouží jako rozbočovač pro připojení až čtyř dalších modulů. Byl umístěn na hrudi zkoumaného subjektu a zaznamenával respirační aktivity a pohyb pomocí akcelerometru. Dále, s využitím přídatných modulů, byly snímány elektrokardiogram, elektrodermální aktivita, elektromyogram a tělesná teplota, vše s vzorkovací frekvencí 700 Hz. Umístění RespiBAN Professional a připojených senzorů v průběhu měření lze vidět na obrázku 4.3. [27]



Obr. 4.3: Umístění zařízení RespiBAN a připojených senzorů, převzato z [27].

Empatica E4 je nositelné zařízení, které obsahuje čtyři typy senzorů: fotoplethysmografický senzor (PPG), senzor elektrodermální aktivity, třídímenzionální akcelerometr a senzor pro měření teploty kůže. Většina těchto senzorů zaznamenává data s frekvencí 4 Hz, zatímco akcelerometr má vyšší vzorkovací frekvenci 32 Hz. Během experimentů bylo zařízení Empatica E4 umístěno na zápěstí nedominantní ruky zkoumaného subjektu, což umožnilo neinvazivní a pohodlné monitorování biologických signálů. [28]

Cílem studie bylo indukovat tři specifické afektivní stavy u účastníků: neutrální, stresový a zábavný. Aby se účastníci po expozici stresovým a zábavným podmínkám vrátili do klidového stavu, byla součástí protokolu také řízená meditace. Tento experimentální protokol byl navržen tak, aby systematicky a efektivně vyvolával tyto afektivní stavy u měřených subjektů. Jednotlivé části protokolu (viz. Obr. 4.4):

1. Příprava: Účastníci byli instruováni, aby hodinu před začátkem studie nekonsumovali kofein ani tabák a v den měření se vyhýbali náročnému fyzickému cvičení. Před zahájením byl každý účastník požádán o přečtení a podepsání formuláře souhlasu.
2. Baseline: Po připevnění měřicích přístrojů započalo 20-ti minutové měření v klidovém stavu, během něhož měl subjekt k dispozici časopisy. Tato fáze měla za cíl navodit neutrální afektivní stav.
3. Zábava: Subjekt sledoval soubor jedenácti zábavných videí o celkové délce 392 sekund. Mezi jednotlivými klipy byla zařazena pětisekundová pauza.
4. Stres: Byl proveden Trier Social Stress Test (TSST), který zahrnoval pětiminutovou prezentaci před panelem expertů o silných a slabých stránkách subjektu, následovanou počítáním od 2023 k nule po sedmnáctkách. V případě chyby subjekt začínal znovu.
5. Meditace: Po stresové fázi následovala sedmiminutová řízená meditace v pohodlné poloze, jejímž účelem bylo uklidnění subjektu.

#### Version A



#### Version B



Obr. 4.4: Ukázka jednotlivých verzí protokolu, převzato z [27].

Mezi jednotlivými fázemi protokolu byli účastníci požádáni o vyplnění dotazníku zaměřeného na jejich psychický stav a pohodu. Tento subjektivní dotazník poskytuje hodnocení každé části protokolu a slouží jako "ground truth" pro vyhodnocování studie. Alternativně autor studie navrhuje využití délek jednotlivých fází protokolu jako anotací k datovému souboru. Experimentu se zúčastnilo 15 subjektů. [27]

## 4.3 Stress-predict Dataset

V neposlední řadě zde zmíníme skupinu vědců z Irska a Spojeného království, který stojí za vytvořením datasetu Stress-predict Dataset a pilotní studií provedenou na tomto datasetu [29]. Cílem jejich studie byl sběr biologických dat pomocí nositelných zařízení, statistická analýza dat s ohledem na úroveň stresu a posouzení aktivit vyvolávající stres.

V průběhu experimentu se zúčastnilo 35 subjektů ve věkovém rozmezí 18 až 75 let, kteří absolvovali standardizované protokoly určené k vyvolání stresu. Experiment trval 60 minut a probíhal v kontrolovaném laboratorním prostředí. Podmínkami pro účast byly zdravotní způsobilost, znalost anglického jazyka a podepsání informačního souhlasu. [29]

Stejně jako v případě předchozího datasetu WESAD (kapitola 4.2), byla pro sběr dat využita zařízení Empatica E4, jak je zobrazeno na obrázku 4.5. Toto nositelné zařízení bylo použito k zaznamenání fotoplethysmografických (PPG), elektrodermálních aktivit (EDA), teploty (TEMP) a pohybových dat. Ostatní parametry byly odvozeny z těchto naměřených dat. Empatica E4 byla umístěna na nedominantní ruce zkoumaných subjektů. [29]



Obr. 4.5: Hodinky Empatica E4, převzato z [29].

Naměřené signály, společně s dopočítanými signály ze signálu PPG:

1. Elektrodermální aktivita (EDA).
2. Teplota těla.
3. Pohyb zápěstí.
4. Tepová frekvence (HR).
5. Blood volume pulse (BVP).
6. Mezi-stahové intervaly (IBI). [29]

Experimentální protokol se skládal ze tří částí navržených tak, aby vyvolaly adekvátní fyziologické reakce, a relaxačních fází mezi jednotlivými stresovými podněty. Výběr specifických testů byl založen na dřívějších výzkumech, které prokázaly, že tyto testy indukují nejintenzivnější fyziologické reakce. Na obrázku 4.6 můžeme vidět tokový diagram tohoto protokolu.



Obr. 4.6: Protokol měření datasetu Stress-predict, převzato z [29].

Následuje stručný popis jednotlivých částí protokolu: [29]

1. Stroopův barevný slovní test (Stroop-CW). V rámci tohoto testu bylo po dobu 6ti minut požadováno, aby subjekty identifikovaly barvu inkoustu, kterou bylo slovo vytištěno, namísto samotného slova, které označuje barvu.
2. Trier Social Stress Test, který zahrnuje pětiminutovou prezentaci nebo pracovní pohovor před panelem expertů, následovaný pětiminutovým prováděním komplexního aritmetického úkolu.
3. Hyperventilace, která zahrnovala řízené provádění zrychleného a hlubokého dýchání, sloužící k vyvolání fyziologické stresové reakce po dobu dvou minut.

Mezi každým stresovým podnětem byla začleněna pětiminutová odpočinková fáze, jejímž cílem bylo umožnit probandům zotavit se z předchozí stresové aktivity. Pokud však zdravotní sestra, která měření prováděla, posoudila, že subjekt po uplynutí standardní doby zotavení zůstává ve stresu, bylo možné tuto pauzu dle potřeby prodloužit. Tímto způsobem se zajistilo, že účastníci přistupovali k další fázi protokolu v plně regenerovaném stavu. Kromě toho byli účastníci vyzváni, aby před zahájením a po dokončení experimentálního měření vyplnili dotazník. Tato metoda poskytovala objektivnější hodnocení stresové úrovně u každého subjektu. [29]

## 5 Metody automatického rozpoznání stresu

Tato kapitola je věnována metodám automatického rozpoznání stresu. Automatickým rozpoznáním stresu je myšleno využití algoritmů strojového učení k analýze fyziologických dat k identifikaci stresu. Jsou zde uvedeny některé, v současnosti nejčastěji využívané metody a jejich výsledky.

### 5.1 Rozpoznání stresu pomocí modelu strojového učení SVM

Tým vědců z amerických univerzit vyvinul model cStress, který má ambici stát se zlatým standardem pro kontinuální hodnocení stresu pomocí nositelných zařízení [30]. Hlavním impulsem pro vývoj tohoto modelu byla absence dobře ověřeného modelu pro posouzení stresu, navzdory pokrokům v oblasti medicíny.

Autoři [30] identifikovali pět hlavních výzev při tvorbě modelu cStress. První výzvou je absence uznávané definice stresu. Druhou překážkou je neexistence zlatého standardu pro hodnocení stresu. Třetím problémem je obtížnost zachycení přesných dat kvůli šumu a problémům s umístěním elektrod během celodenního měření. Čtvrtá výzva se týká proměnných, které mohou zkreslit měření, jako jsou například pohyby končetin, které mohou být zaměněny za stresové reakce. Pátou výzvou je rozpoznání a identifikace specifických znaků, které umožňují odlišit stresovou reakci od jiných stavů.

Dále stanovili autoři dvě kritéria pro uznání modelu cStress jako zlatého standardu. První kritérium je schopnost reprodukovatelnosti modelu na nezávisle shromážděných datech v laboratorních i terénních podmínkách. Druhé kritérium vyžaduje, aby model dosáhl minimálně 90 % přesnosti s méně než 5 % mírou falešně pozitivních výsledků na laboratorních datech a alespoň 70 % přesnosti na datech z terénního měření.

V rámci realizované studie [30] bylo pro sběr dat použito nositelné zařízení AutoSense, které je vybaveno biomedicínskými senzory, včetně senzoru pro indukční pletismografii (RIP), dvousvodového elektrokardiografu, 3D akcelerometru a senzorů pro měření dýchání. Data z těchto senzorů jsou přenášena bezdrátově pomocí protokolu ANT do mobilního zařízení. Vzorkovací frekvence senzorů jsou nastaveny na 128 Hz pro EKG, 21,3 Hz pro dýchání a 16 Hz pro akcelerometr. [30]

Celkem byla provedena tři měření, z nichž dvě proběhla v laboratorních podmínkách a jedno v terénu. Data z prvního laboratorního měření, které zahrnovalo 24 subjektů, byla využita jako trénovací a validační sada pro model. Data z druhého

laboratorního měření sloužila jako nezávislá testovací sada, která nebyla použita během fáze učení modelu. Data z terénního měření byla následně použita pro ověření výkonnosti modelu v náročnějších podmínkách reálného života. [30]

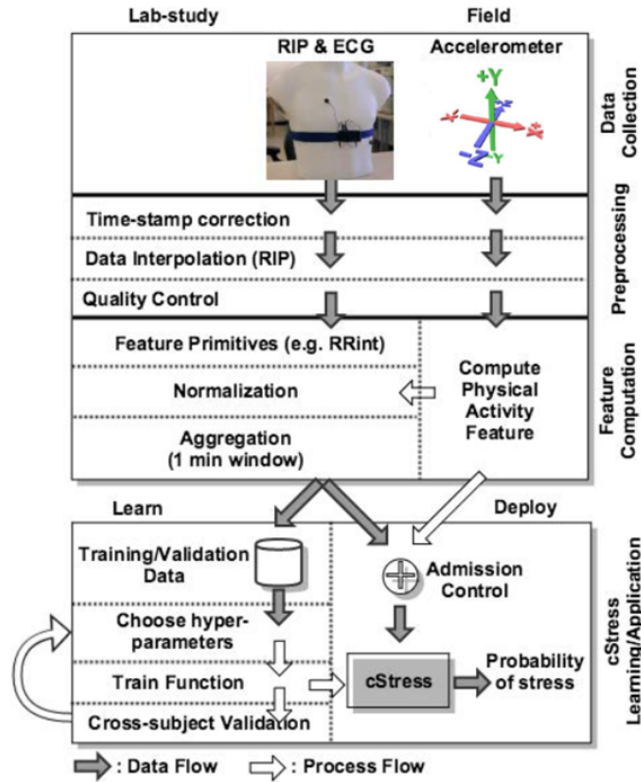
Obě laboratorní měření byla prováděna dle předem definovaného šestifázového protokolu. Účastníci prvního laboratorního měření, které sloužilo k získání trénovací a validační sady dat, absolvovali tento protokol jak v sedě, tak ve stoje. Během druhého laboratorního měření byl protokol prováděn pouze v sedě. Důvodem této změny bylo zjištění, že změna držení těla nemá významný vliv na stresovou reakci účastníků. Jednotlivé fáze protokolu jsou popsány níže. [30]

1. 30 minut pohodlného sezení pro získání takzvané baseline.
2. Socioevaluatní výzva - 4 minuty příprava a následující 8mi minutová přednáška na předem zadané téma před výzkumným štábem.
3. Kognitivní výzva - účastník obdržel třímístné číslo a byl požádán aby sečetl číslice daného třímístného čísla a poté přičetl sumu těchto tří číslic k původnímu třímístnému číslu. Tento úsek trval 4 minuty.
4. Fyzický stres - účastník byl požádán aby nechal svou ruku ponořenou v ledové vodě po dobu 90 vteřin.
5. Následoval 30 minut odpočinku.
6. Průběžné vyplňování dotazníku během celého měření.

V rámci terénního měření byli účastníci instruováni, aby nosili senzory sedm dní ve svém běžném prostředí. Bylo jim doporučeno mít senzory na sobě po celou dobu, kdy jsou vzhůru. Účastníci byli rovněž požádáni, aby během dne vyplňovali dotazník přibližně patnáctkrát denně. [30]

Na obrázku 5.1, na straně 36, je prezentován přehled jednotlivých kroků modelu cStress, od zpracování dat až po učící a validační proces.

První fáze zpracování dat zahrnovala jejich předzpracování, kde byla data z jednotlivých senzorů synchronizována a chybějící vzorky doplněny pomocí interpolace. Následně byly signály rozděleny do jednodominutových bloků, z nichž byly extrahovány statistické příznaky z časové i frekvenční oblasti. V EKG signálech byly identifikovány QRS komplexy a R vlny, což umožnilo získání R-R intervalů a variability srdeční frekvence. Tyto extrahované příznaky poté sloužily jako vstupy pro klasifikační algoritmus Support Vector Machine (SVM), což je L2-regulovaný model minimalizující ztrátovou funkci. Výkonnost modelu byla hodnocena pomocí F1 skóre, které je často používáno v aplikacích strojového učení pro klasifikaci. [30]



Obr. 5.1: Přehled zpracování dat a kroků strojového učení modelu cStress, převzato z [30].

V tabulce 5.1 jsou prezentovány výkonnostní metriky validační skupiny modelu cStress, včetně F1 skóre a plochy pod křivkou (AUC), spolu se zvolenými hyperparametry modelu, jako jsou parametry Radial Basis Function  $\gamma$  a parametr soft-marginu C.

Feature Set	Accuracy						Optimal hyper-parameters		
	F1	AUC	Hit-rate	TPR	FPR	C. Kappa	C	$\gamma$	Bias
All	0.81	0.96	0.93	0.84	0.05	0.77	90.5097	0.000345267	0.339329
ECG	0.78	0.95	0.92	0.72	0.05	0.73	2	0.00552427	0.340407
HRV	0.56	0.78	0.84	0.55	0.1	0.46	724.077	0.0220971	0.250926
RIP	0.75	0.93	0.9	0.83	0.09	0.69	1448.15	0.000488281	0.308312

Tab. 5.1: Cross-validační výkon modelu na trénovacím datasetu, převzato z [30].

Tabulky 5.2 a 5.3 zobrazují matice záměn aplikované na trénovací a testovací datové sady, které odpovídají prvnímu a druhému laboratornímu měření. Celková matice záměn byla sestavena kombinací jednotlivých matic záměn od všech účastníků měření.

	Classified By Model		
	Stressed	Not stressed	Total
Stressed	236 (84 %)	46 (16 %)	282
Not stressed	61 (5 %)	1 191 (95 %)	1252
Total	291	1237	1534

Tab. 5.2: Matice záměn cross-validace tréninkové skupiny dat, převzato z [30].

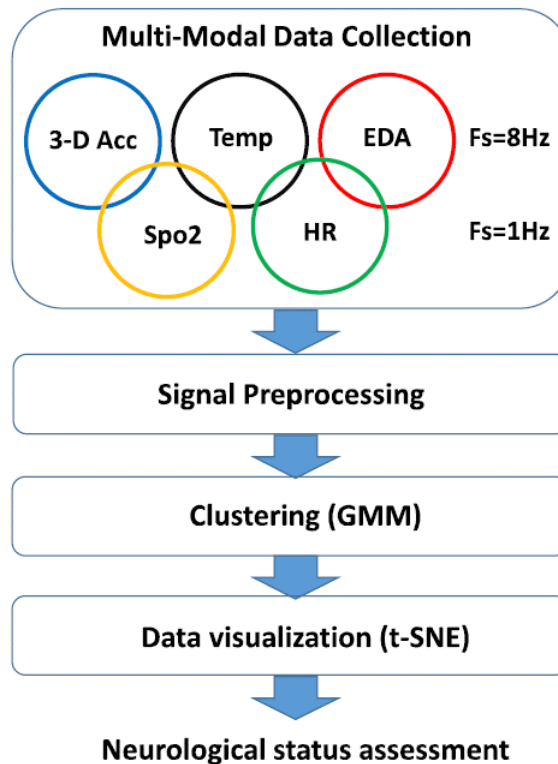
	Classified By Model		
	Stressed	Not stressed	Total
Stressed	351 (89 %)	45 (11 %)	396
Not stressed	56 (5 %)	1 149 (95 %)	1205
Total	407	1194	1501

Tab. 5.3: Matice záměn testového datasetu, převzato z [30].

Navržený model cStress dosáhl dle autorů [30] dobré přesnosti na nezávislém datasetu v laboratoři i v terénu a představuje významný krok směrem ke zlatému standardu pro kontinuální hodnocení stresu pomocí signálů získaných nositelnými zařízeními.

## 5.2 Posouzení a vizualizace neurologického stavu pomocí Gaussian Mixture modelu

Autoři datasetu "A Non-EEG Biosignals Dataset" [26], který je referencován v kapitole 4.1 této práce, využili tento dataset pro hodnocení neurologického stavu pomocí shlukovacího algoritmu Gaussian Mixture Model (GMM), s podporou technik pro redukci dimenzionality dat k vizualizaci. Procedura akvizice dat, včetně elektrodermální aktivity (EDA), teploty, akcelerace, srdeční frekvence (HR) a saturace kyslíku v krvi (SpO2), využitých přístrojů, měřícího protokolu a charakteristiky vstupních dat, je podrobně popsána v kapitole 4.1.




Obr. 5.2: Přehled procesu posouzení neurologického stavu, převzato z [26].

Jak můžeme vidět na obrázku 5.2, prvním krokem analýzy bylo předzpracování signálů, při kterém byla data převzorkována na jednotnou frekvenci 1 Hz. Vzhledem k rozdílným rozsahům signálů byla následně provedena jejich standardizace. S ohledem na disproporci v množství dat mezi relaxačními a stresovými stavy byly pro vyvážení datasetu použity pouze údaje z první relaxační fáze a všech fází stresu. [26]

V další fázi byl pro klasifikaci neurologických stavů aplikován model GMM. Tento model využívá takzvané učení bez učitele a jeho účelem je nalézt maximální pravděpodobnost pro statistický model a definovat různé shluky. Anotace byly využity výhradně pro účely validace efektivity navrhovaného modelu. [26]

Pro vizualizaci dat byly vytvořeny reprezentace v 2D a 3D prostoru (viz obrázku 5.3 na straně 39), protože vizualizace v prostoru s více než třemi dimenzemi není možná. K tomuto účelu byly využity metody redukce dimenzionality. První použitou metodou byla analýza hlavních komponent (PCA), která identifikuje nové osy s maximálním rozptylem, poskytující nejvyšší množství informací, ale tato metoda nemusí být schopna uchovat vzájemné vzdálenosti mezi body v datovém prostoru. Jako alternativa byla použita technika t-distributed Stochastic Neighbor Embedding (t-SNE), která mapuje body z vysokodimenzionálního prostoru do prostoru s nižší dimenzí. Tato metoda se snaží udržet vzájemné vztahy mezi sousedními datovými body, což umožňuje přesnější zachycení struktury dat. [26]



Obr. 5.3: 2D vizualizace dat metoda PCA nahoře vpravo, 2D vizualizace dat metoda t-SNE nahoře vlevo a 3D vizualizace dat metoda t-SNE dole, převzato z [26].

Autoři [26] aplikovali dvě metody redukce dimenzionality, PCA a t-SNE, aby mohli porovnat účinnost t-SNE s tradiční PCA. Z vizuálních srovnání na obrázcích 5.3 je patrné, že t-SNE je účinnější při kategorizaci různých neurologických stavů. Je důležité poznamenat, že obě tyto metody byly využity výhradně pro vizualizační účely a veškeré shlukování bylo provedeno v originálním vysokodimenzionálním datovém prostoru.

Class	Relaxation	Physical	Emotional	Cognitive
Relaxation	94.2	0.1	5.4	0.3
Physical stress	1.8	90.9	3.8	3.5
Emotional stress	13.4	5	65.8	15.8
Cognitive stress	1	1.4	10.2	87.3
Sensitivity	85.4	93.3	77.2	86.4
Specificity	93.6	91.1	70.2	86.4
Precision	94.2	90.8	65.8	87.4
Accuracy	84.6			

Tab. 5.4: Matice záměn a statistické metriky modelu [%], převzato z [26].

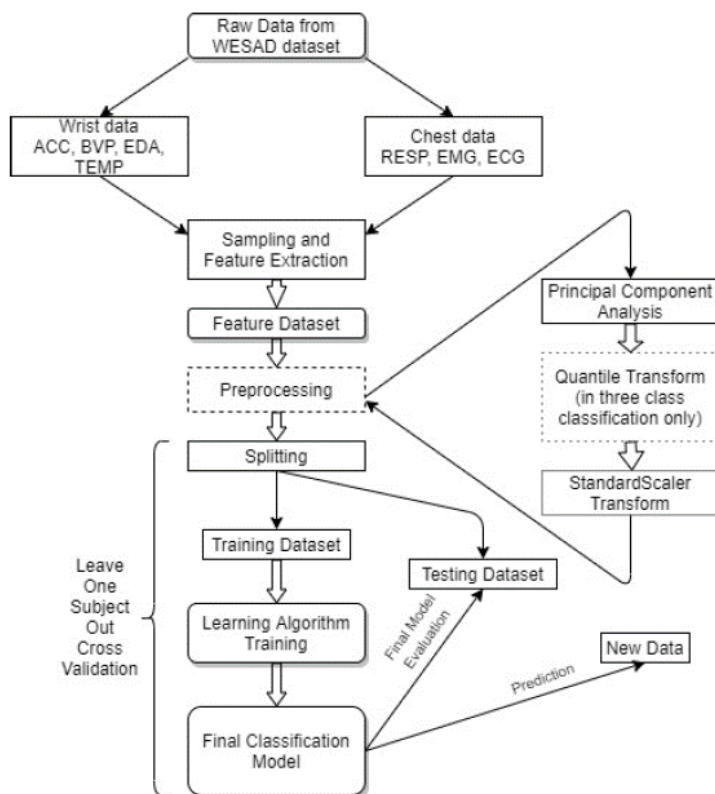
Tabulka 5.4 poskytuje vizualizaci matice záměn, statistických metrik a celkové přesnosti modelu, a zároveň umožňuje srovnání těchto parametrů s výsledky získanými pomocí klasifikace neuronovou sítí [31]. Autoři práce poukazují na to, že i přes použití experimentálního přístupu učení bez učitele, jsou výsledky jejich metody porovnatelné s metodami, které využívají učení s učitelem. To naznačuje, že techniky shlukování mohou být efektivně využity pro rozlišování mezi různými neurologickými stavy i bez předchozích znalostí o datech. [26]

## 5.3 Detekce stresu s využitím strojového a hlubokého učení

Dvojice vědeckých pracovníků z Ústavu informatiky a výpočetní techniky Národního technologického institutu v Indii se zaměřila na detekci stresu v rámci svého výzkumu, nazvaného "Stress Detection with Machine Learning and Deep Learning using Multimodal Physiological Data" [32]. Hlavním cílem studie bylo vyvinout metodu pro automatickou detekci stresu z biologických signálů zaznamenaných během situací vyvolávajících stres.

Vstupní data studie pocházela z datasetu WESAD, jehož popis je podrobně uveden v kapitole 4.2. Algoritmus byl vyvíjen v programovacím jazyce Python.

Ve vývojovém diagramu na obrázku 5.4 je znázorněn postup práce. Byla provedena filtrace signálů, po které následovala extrakce statistických příznaků ze signálů EDA, EMG, EKG, BVP, TEMP a Acc. Tyto příznaky byly extrahovány z posuvných oken o délce jedné sekundy a zahrnovaly statistické parametry jako směrodatná odchylka, průměr, maximální a minimální hodnoty, dominantní frekvence, sklon signálu a další. Detaily extrahovaných charakteristik jednotlivých signálů jsou uvedeny v tabulce 5.5. [32]



Obr. 5.4: Vývojový diagram algoritmu, převzato z [32].

Modality	Features	Description
ACC	$\mu_{ACC,i}, \sigma_{ACC,i}, \min_{ACC,i}, \max_{ACC,i}, i \in \{x, y, z, 3D\}$	Mean, standard deviation, minimum and maximum value for each axis separately and combined over all axes
ECG	$\mu_{ECG}, \sigma_{ECG}, \min_{ECG}, \max_{ECG}$	Mean, standard deviation, minimum and maximum value of the ECG
BVP	$\mu_{BVP}, \sigma_{BVP}, \min_{BVP}, \max_{BVP}, f_{BVP}^{peak}$	Mean, standard deviation, minimum, maximum and peak frequency of the BVP
EDA	$\mu_i, \sigma_i, \min_i, \max_i, i \in \{EDA_{phasic}, EDA_{tonic}, SMNA\}$	Mean, standard deviation, minimum, maximum value of the EDA signal, SCR/ISL and separate SMNA driver of phasic component
EMG	$\mu_{EMG}, \sigma_{EMG}, \min_{EMG}, \max_{EMG}, f_{EMG}^{peak}$	Mean, standard deviation, minimum, maximum and peak frequency of the EMG
RESP	$\mu_{RESP}, \sigma_{RESP}, \min_{RESP}, \max_{RESP}$	Mean, standard deviation, minimum and maximum value of the RESP
TEMP	$\mu_{TEMP}, \sigma_{TEMP}, \min_{TEMP}, \max_{TEMP}, \beta_{TEMP}$	Mean, standard deviation, minimum, maximum and slope of the TEMP

Tab. 5.5: Extrahované příznaky jednotlivých signálů, převzato z [32] .

V další fázi byl realizován vývoj klasifikačního algoritmu, přičemž bylo experimentováno se šesti různými modely strojového učení: rozhodovacími stromy (Decision Trees), náhodnými lesy (Random Forests), AdaBoost, metodou K-nejbližších sousedů (K-Nearest Neighbors), lineární diskriminační analýzou (Linear Discriminant Analysis) a podpůrnými vektory (Support Vector Machines). Byly implementovány také metody hlubokého učení založené na neuronových sítích. Tyto algoritmy byly aplikovány jak na binární klasifikaci (stav klidu versus stres), tak na klasifikaci tří tříd (klid/stres/zábava). [32]

Při zpracování dat byla použita metoda analýzy hlavních komponent (PCA), přičemž byl počet cílových komponent nastaven na hodnotu 20. Kromě toho byl pro 3-třídní klasifikaci použit Quantile Transformer, který transformuje vstupní příznaky tak, aby lépe odpovídaly normálnímu rozložení. Tento přístup se zaměřuje na roztažení nejběžnějších hodnot příznaků a zmenšuje vliv outlierů. Jako finální krok předzpracování dat byla provedena standardizace příznaků. [32]

Pro proces učení a ověřování modelů byla zvolena metodika leave-one-out cross-validation, která zajišťuje robustní validaci na jednotlivých vzorcích dat. [32]

V rámci optimalizace parametrů pro jednotlivé klasifikační algoritmy byly nastaveny následující hodnoty. Pro Random Forest (RF) a Decision Tree (DT) klasifikátory byl stanoven minimální počet vzorků potřebný k rozdělení uzlu na hodnotu 10 a byla omezena maximální hloubka stromů na 4, přičemž pro úlohy 3-třídní klasifikace byla maximální hloubka zvýšena na 9. AdaBoost (AB) ensemble využíval jako základní klasifikátor rozhodovací stromy, s limitem minimálního počtu vzorků pro rozdělení nastaveným na 5 pro 3-třídní klasifikaci a na 10 pro binární klasifikaci. Klasifikátor K-Nearest Neighbors (KNN) byl konfigurován s 9 sousedy pro oba typy

klasifikačních úloh. [32]

Co se týče neuronové sítě, byla strukturována s jednou vstupní vrstvou, dvěma skrytými vrstvami a dvěma vrstvami výstupními. V kontextu binární klasifikace byl mezi skryté vrstvy zařazen dropout s koeficientem 0,25, aby se předešlo přeučení. Jako aktivační funkce byla pro binární klasifikaci zvolena sigmoidní funkce, zatímco pro klasifikaci do tří tříd byla použita funkce softmax. [32]

Techniques	three-class		binary	
	F1-score	Accuracy	F1-score	Accuracy
DT	53.73	68.16	84.92	87.59
RF	63.09	75.95	88.32	89.53
AB	67.55	78.19	89.88	91.06
LDA	64.66	74.83	87.60	90.15
kNN	66.76	74.71	84.63	87.92
SVM	73.57	81.65	92.31	93.20
ANN	78.71	84.32	94.24	95.21

Tab. 5.6: Výkonost jednotlivých klasifikátorů, převzato [32].

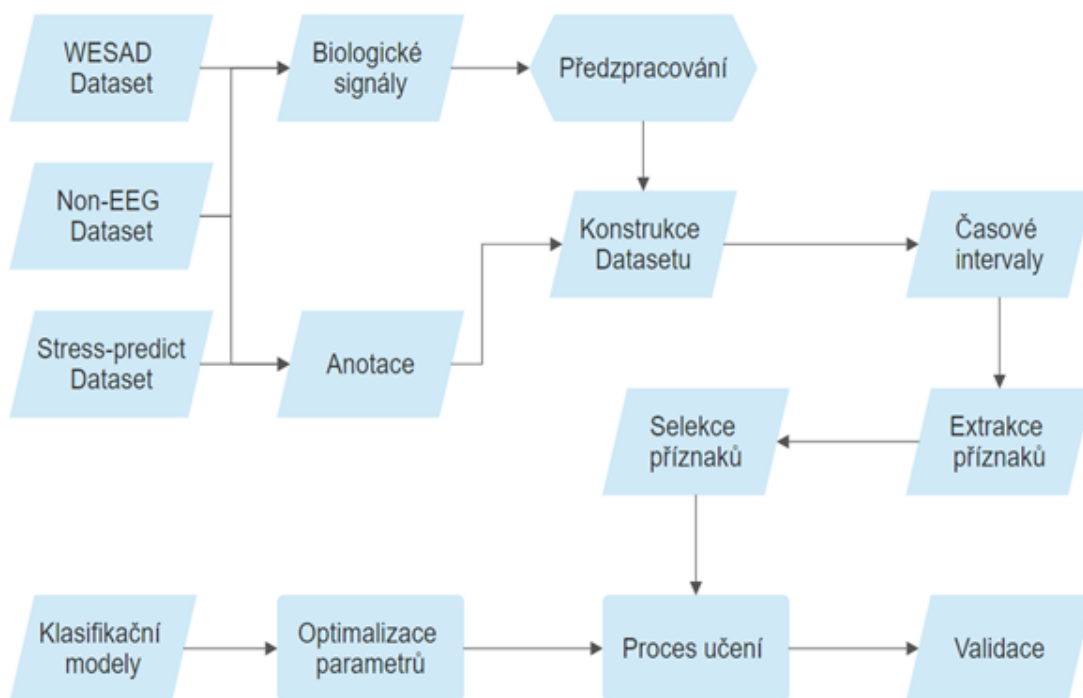
Jak je patrné z údajů prezentovaných v tabulce 5.6, nejvyšší přesnosti dosáhla umělá neuronová síť s přesností 95,21 % v případě binární klasifikace a 84,32 % v případě klasifikace do tří tříd. Z klasifikačních modelů strojového učení si nejlépe vedl model SVM, který dosáhl přesnosti 93,2 % v případě binární klasifikace a přesnosti 81,65 % v případě klasifikace do tří tříd.

## 6 Praktická část

Praktická část je věnována tvorbě algoritmu pro rozpoznání stresu pomocí biologických signálů v programovém prostředí MATLAB.

Na obrázku 6.1 můžeme vidět vývojový diagram algoritmu. Prvním bodem vývojového diagramu je analýza a předzpracování dat jednotlivých datasetů zmíněných v kapitole 4. Následně je provedena segmentace jednotlivých signálů na základě stavu měřeného subjektu a vytvoření datasetu, jakožto vstupu pro náš algoritmus, společně s přiřazením příslušných anotací. Dalším krokem je extrakce a selekce vhodných příznaků pro následné učení zvolených klasifikačních modelů strojového učení. Závěrem praktické části je provedena evaluace těchto modelů.

Jednotlivých částem algoritmu a jejich detailnímu popisu budou věnovány následující kapitoly.



Obr. 6.1: Vývojový diagram algoritmu.

## 6.1 Předzpracování dat

Vstupními daty našeho algoritmu jsou biologické signály subjektů z datasetů zmíněných v kapitole 4, včetně jejich akvizice a protokolu měření. Každý dataset obsahuje několik biologických signálů, pro naše účely budeme nadále pracovat pouze s průnikem těchto signálů všech zmíněných datasetů.

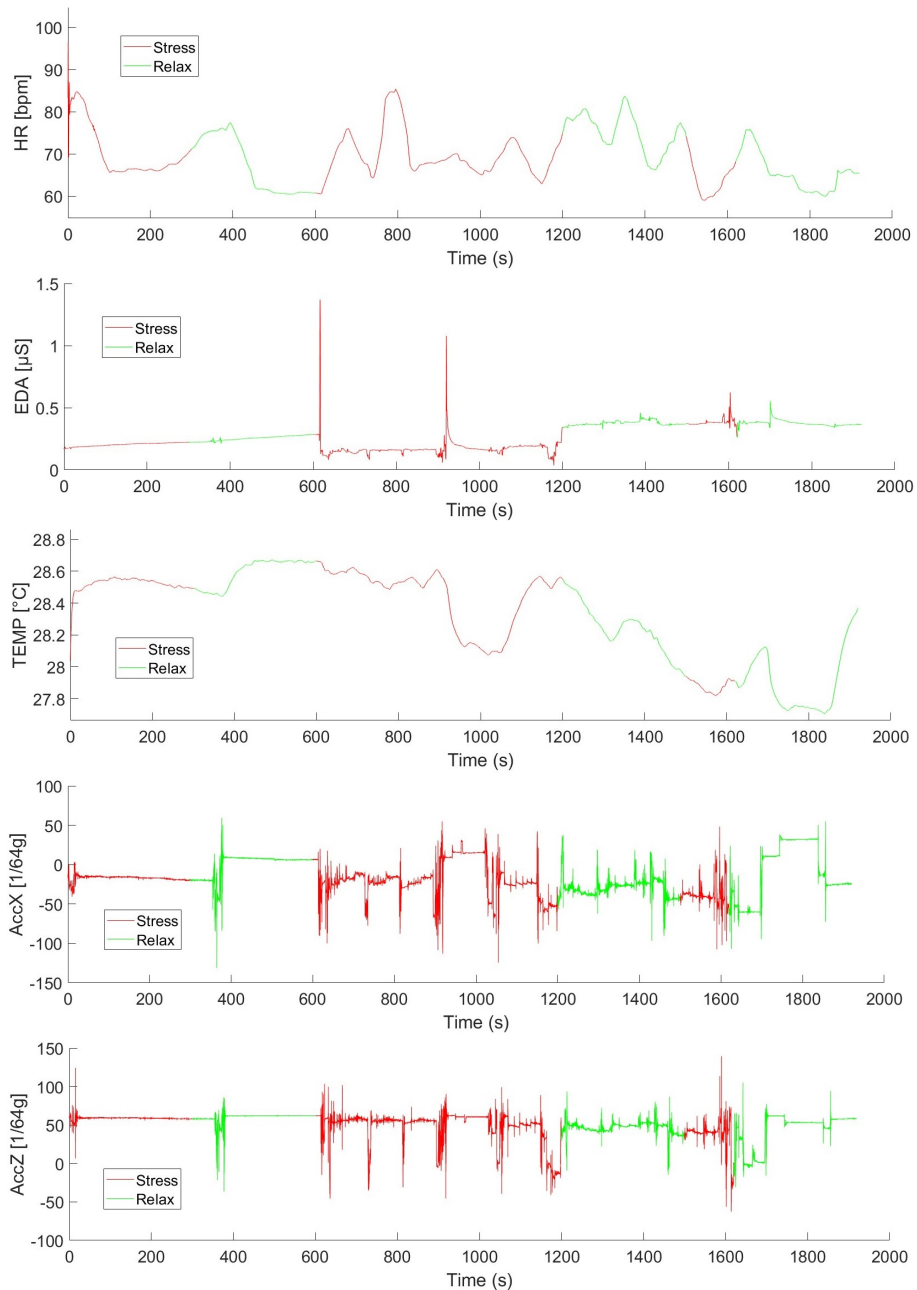
Těmito signály jsou:

1. Elektrodermální aktivita (EDA).
2. Teplota těla (Temp).
3. Tepová frekvence (HR).
4. Pohyb (Data z akcelerometru).

Detailnímu popisu vlivu stresu na jednotlivé biologické signály, a tedy i zdůvodnění pro selekci těchto signálů, byla věnována kapitola 2.

Ačkoli autoři výše zmíněných datasetů [27][26][29] uvádí, že chybějící hodnoty byli již nahrazeny, bylo pomocí příkazů *isnan* a *isinf* ověřeno, že jednotlivé biologické signály neobsahují žádné chybějící hodnoty a jsou tak připraveny pro následné zpracování. Z důvodu odlišných vzorkovacích frekvencí jednotlivých biologických signálů, bylo provedeno převzorkování všech signálů na nejvyšší vzorkovací frekvenci, se kterou byla provedena akvizice dat všech tří datasetů, zmíněných v kapitole 4, tedy 32 HZ. Tato vzorkovací frekvence, jakožto nejvyšší využitá při akvizici byla zvolena z důvodu faktu, že podvzorkování některých signálů by mohlo mít za následek ztrátu cenné informace. Dalším krokem předzpracování byla filtrace jednotlivých signálů, za účelem potlačení šumu obsaženého v jednotlivých signálech, který by mohl zkomplikovat následnou klasifikaci. Byl využit Butterworthův filtr 3. řádu, typu dolní propust, navržen v programovém prostředí dostupnou funkcí "*butter*". Mezní frekvence pro jednotlivé signály byly zvoleny: EDA - 1HZ, Temp - 0,05HZ, HR - 3HZ, Acc - 10HZ. Tyto kroky předzpracování signálu byly aplikovány na biologické signály všech tří využitých datasetů.

Na obrázku 6.2 můžeme vidět příklad biologických signálů subjektu 1 z datasetu Stress-predict. Signály jsou vyznačeny barevně podle stavu pacienta v průběhu akvizice dat.



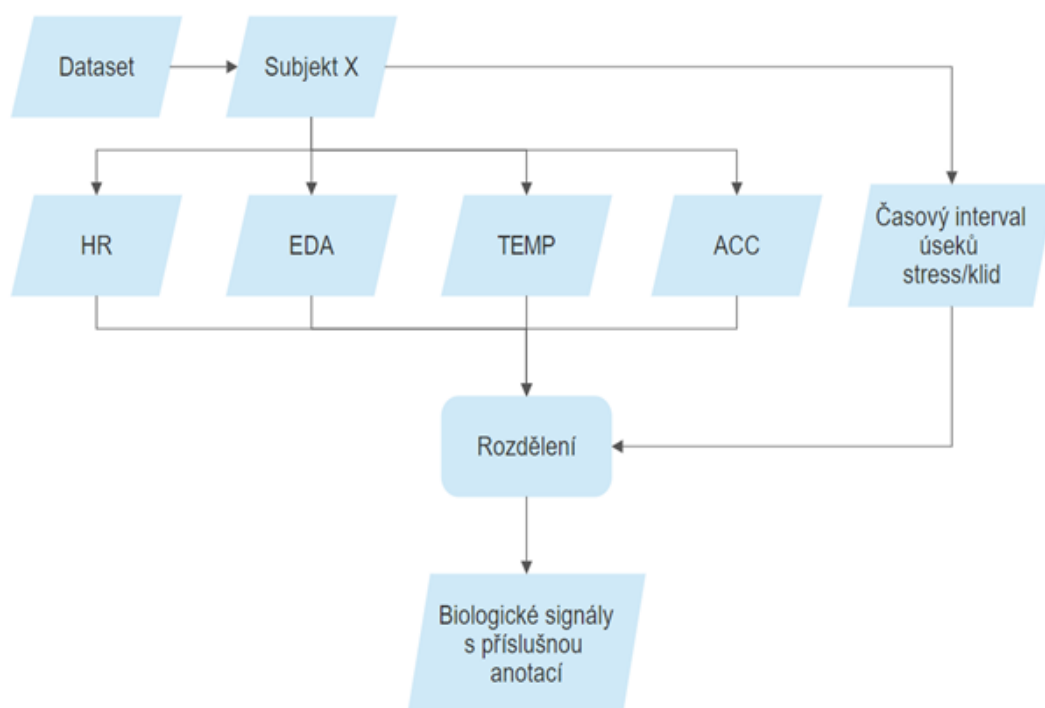
Obr. 6.2: Biologické signály subjektu 1 datasetu Stress-predict.

Zelená barva značí časový interval, kdy byl subjekt v klidu, naopak červená barva značí časový interval kdy byl subjekt vystaven stresovému podnětu. Na první pohled si můžeme všimnout peaků v signálu EDA v době stresu. Ostatní signály neobsahují očividné změny s přítomností stresu.

## 6.2 Tvorba datasetu

Dataset pro následnou práci byl vytvořen spojením všech dříve zmíněných datasetů a to datasetu A Non-EEG Biosignals Dataset (20 subjektů), datasetu Stress-predict Dataset (35 subjektů) a dataset WESAD (15 subjektů), které jsou popsány v kapitole 4. Tyto datasety byly vybrány primárně z důvodu velkého průniku měřených signálů a existence časového popisu jednotlivých stresových podnětů.

Prvním krokem bylo rozdělení jednotlivých biologických signálů subjektů na části, podle toho, zda byl měřený subjekt v daný časový úsek v klidu nebo byl vystaven stresovému podnětu. Počet úseků jednotlivých biologických signálů se liší subjekt od subjektu v závislosti na faktu, kolika stresovým podnětům byl subjekt v průběhu akvizice vystaven. Paralelně s tímto krokem byla ke každé části signálu přiřazena anotace právě podle stavu subjektu v daný časový úsek v průběhu akvizice dat (viz. obrázek 6.3). Tento krok byl proveden pro každý výše zmíněný dostupný dataset.



Obr. 6.3: Rozdělení signálů na dílčí části podle stavu měřeného subjektu.

Tímto krokem jsme vytvořili 380 nových úseků (140 non-EEG, 210 Stress-predict a 30 WESAD) obsahující všechny signály zmíněné v kapitole 6.1 a k nim příslušné anotace, jelikož po celou dobu akvizice daného úseku podléhali subjekty jednomu stavu (klid nebo stres). Délky signálů jednotlivých úseků jsou v tuto chvíli odlišné.

Dalším krokem bylo ošetření rozdílných délek signálů jednotlivých subjektů. Pro tento krok jsme zvolili délku signálu 10, 30 a 60 sekund. Všechny signály jednotlivých subjektů byli rozděleny na 10-ti, 30-ti a 60-ti sekundové intervaly. Opět byla ke každému subjektu uložena příslušná anotace. Tímto krokem, pro interval 10 sekund, jsme obdrželi 14111 10-ti sekundových úseků jednotlivých signálů (4578 Non-EEG, 6721 Stress-predict a 2812 WESAD) s příslušnými anotacemi.

Tímto zpracováním, rozdělením jednotlivých signálů a přiřazením příslušných anotací jsme vytvořili poměrně velký dataset pro následnou práci a rozpoznání stresu. Tento dataset bude následně různě rozdělován na trénovací a testovací skupiny podle potřeb.

## 6.3 Extrakce a selekce příznaků

V následující části práce je věnována pozornost extrakci příznaků a metodám selekce příznaků.

### 6.3.1 Extrakce příznaků

Po vytvoření datasetu (viz. kapitola 6.2) a přiřazení patřičných anotací ke všem subjektům, jsme začali s extrakcí příznaků.


Extrakce příznaků může být definována jako transformace surových dat na numerické prvky nesoucí validní informaci o původních datech. Extrakce příznaků může být provedena manuálně za předpokladu dostatečné znalosti v dané oblasti. Druhou možností je automatická extrakce příznaků využitím specializovaných algoritmů nebo sítí hlubokého učení bez nutnosti zásahu člověka. [33]

Jak již bylo zmíněno, cílem extrakce příznaků bylo extrahovat příznaky, které ponесou relevantní informace a tím budou nápomocny v následující binární klasifikaci. Příznaky byli extrahovány ze signálů všech měřených subjektů, jak z časové, tak i spektrální oblasti. Příkladem statistických příznaků časové oblasti jsou průměry, směrodatné odchylky, maxima, minima a jiné. Příkladem příznaku spektrální oblasti je dominantní frekvence signálu.

Dále byl proveden rozklad signálu EDA na jednotlivé složky signálu, tedy tonicou (SCL), fázovou (SCR) a odhad aktivity sudomotorického nervu (SMNA). Tyto složky jsou podrobně popsány v kapitole 2.1. Tento rozklad byl proveden pomocí funkce `cvxEDA`. [34]

Mimo již zmíněných statistických příznaků byla tonická složka SCL byla využita pro extrahování korelace hodnot signálu s časem, jinými slovy sklon signálu. Fázická složka SCR a SMNA byli využity pro detekci peaků a získání počtu peaků v časovém okně. Detekce peaků byla provedena pomocí funkce `findpeaks`, s parametry

$MinPeakHeight = 0,05$ ,  $MinPeakDistance = 2$  sekundy a  $MinPeakProminance = 0,05$  pro složku SCR a  $MinPeakHeight = \text{průměr} + 2 * \text{směrodatná odchylka} + 1$ ,  $MinPeakDistance = 2$  sekundy pro odhad SMNA (viz. obrázek 6.4).



Obr. 6.4: Signál SCL, SCR a SMNA společně s detekcí peaků.

Celkem bylo extrahováno 84 příznaků z jednotlivých signálů jak z časové tak i frekvenční oblasti. Tyto příznaky jednotlivých signálů můžeme vidět v tabulce 6.1, společně se s popisem těchto příznaků.

Signál	Příznaky	Popis
HR	$\mu_{HR}, \sigma_{HR}, \sigma_{HR}^2, max_{HR}, min_{HR}, P2P_{HR}, median_{HR}, E_{HR}, DF_{HR}, Corr_{HRt}$	Průměr, směrodatná odchylka, rozptyl, maximum, minimum, peak2peak, median, energie, dominantní frekvence a korelace signálu HR s časem.
EDA	$\mu_i, \sigma_i, \sigma_i^2, max_i, min_i, P2P_i, median_i, E_i, DF_i, SCR_{events}, SMNA_{events}, Corr_{SCLt}$ $i \in \{EDA, SCL, SCR, SMNA\}$	Průměr, směrodatná odchylka, rozptyl, maximum, minimum, peak2peak, median, energie a dominantní frekvence signálu EDA, SCL, SCR a SMNA, počet peaků v časovém okně SCR a SMNA a korelace signálu SCL s časem
TEMP	$\mu_{TEMP}, \sigma_{TEMP}, \sigma_{TEMP}^2, max_{TEMP}, min_{TEMP}, P2P_{TEMP}, median_{TEMP}, E_{TEMP}, DF_{TEMP}, Corr_{TEMPt}$	Průměr, směrodatná odchylka, rozptyl, maximum, minimum, peak2peak, median, energie, dominantní frekvence signálu a korelace signálu TEMP s časem.
Acc	$\mu_{Acci}, \sigma_{Acci}, \sigma_{Acci}^2, max_{Acci}, min_{Acci}, P2P_{Acci}, median_{Acci}, E_{Acci}, DF_{Acci}, i \in \{x, y, z\}$	Průměr, směrodatná odchylka, rozptyl, maximum, minimum, peak2peak, median, energie a dominantní frekvence jednotlivých os i akcelerometru.


Tab. 6.1: Extrahované příznaky jednotlivých signálů.

### 6.3.2 Selekcce příznaků

Z důvodu extrakce mnoha příznaků, které při jejich využití mohlo být kontraproduktivní, jsme přistoupili k selekci příznaků.

Jednou z klíčových metod, které jsme využili k selekci příznaků, bylo využití funkce *TreeBagger*, neboli Random forrest, z programového prostředí MATLAB. *TreeBagger* umožňuje konstrukci souboru rozhodovacích stromů pro klasifikaci nebo regresi. Jednotlivé rozhodovací stromy mají tendenci k přerůstání a ztráty generalizace. Z toho důvodu využívá *TreeBagger* Bootstrap agregace, neboli *bagging*. [35]

Bagging je metoda využívaná ve statistice a strojovém učení ke zlepšení stability a přesnosti algoritmů. Prvním krokem Baggingu je Bootstapping, který složí ke generování různých podmnožin trénovací skupiny. Výběr těchto nově generovaných podmnožin trénovací skupiny provádí náhodně a je možné, že v jedné podmnožině se objeví jeden a ten samý vzorek vícekrát. Tyto podmnožiny jsou dále rozděleny na InBag, pro trénování a Out-of-Bag (OOB), pro validaci. Následuje paralelní trénink slabých klasifikátorů a posledním krokem je agregace, kde výsledná klasifikace je dána většinou výsledkem jednotlivých klasifikátorů. [36]



Obr. 6.5: Koncept Bootstrap agregace, převzato z [37].

Při selekci příznaků je pro nás obzvláště důležitý parametr *OOBPredictorImportance*, který měří důležitost jednotlivých prediktorů pomocí permutace. Pokud má prediktor vliv na predikci, pak by permutace jeho hodnot v OOB měla ovlivnit chybu modelu. Tohoto parametru tedy můžeme využít pro selekci nejdůležitějších příznaků pro klasifikaci. [38]

Tímto krokem jsme z původních 84 extrahovaných příznaků selektovali 40 nejvýznamějších příznaků, 10 pro každý signál, na základě parametru *OOBPredictorImportance*.

Selektované příznaky vykazovaly známky silné korelace. Z toho důvodu jsme přistoupili k odstranění korelovaných příznaků. Porovnali jsme důležitost jednotlivých korelovaných dvojic příznaků s korelačním koeficientem větším než 0,69 a příznak s nižší důležitostí jsme odstranili. Tímto krokem jsme redukovali počet příznaků na 13 až 16 v závislosti na trénovací skupině dat. V tabulce 6.2 jsou uvedeny selektované příznaky pro jednotlivé délky časových intervalů.

Interval [s]	Příznaky	Počet
10	$\min_{HR}, \max_{HR}, Corr_{HRt}, Corr_{SCLt}, \min_{SCL}, \min_{SCR}, \min_{Temp}, \text{median}_{AccZ}, e_{AccY}, \min_{AccZ}, e_{AccZ}, \text{median}_{AccY}, \max_{AccX}$	13
30	$\mu_{HR}, Corr_{HRt}, Corr_{SCLt}, \text{median}_{SCR}, \min_{SCL}, \sigma_{SCL}, \sigma_{EDA}^2, p2p_{Temp}, \min_{Temp}, \min_{AccZ}, \mu_{AccZ}, \max_{AccZ}, \text{median}_{AccY}, e_{AccZ}, \sigma_{AccZ}^2, \max_{AccX}$	16
60	$\min_{HR}, \mu_{HR}, Corr_{HRt}, \text{median}_{SCL}, Corr_{SCLt}, \min_{SCL}, \sigma_{SCL}, \sigma_{SCL}^2, \text{mean}_{Temp}, e_{AccZ}, \min_{AccZ}, \text{mean}_{AccZ}, \text{mean}_{AccY}$	13

Tab. 6.2: Selektované příznaky pro jednotlivé časové intervaly.

## 6.4 Klasifikační modely strojového učení


V této kapitole se budeme věnovat klasifikačním modelům strojového učení. Pro účely klasifikace byli zvoleno následujících sedm modelů strojového učení, jejichž názvy nejsou pro další účely práce překládány do českého jazyka, neboť anglická terminologie je v českém prostředí všeobecně využívána:

1. Decition Tree (DT).
2. Random Forrest (RF).
3. Support Vector Machine (SVM).
4. K-Nearest Neightbors (KNN).
5. Linear Discriminant Analysis (LDA).
6. Adaboost Decition Tree (AB).
7. Logistic Regression (LR).

Základem pro výběr výše uvedených klasifikačních modelů pro náš algoritmus byla literární rešerše v úvodu této práce. Výše zmíněné klasifikační modely se v literatuře uvádí jako vhodné pro klasifikační úlohy podobného typu a jsou hojně využívány. Příkladem může být model cStress, popsán v kapitole 5.1, který využívá

klasifikačního modelu SVM. [30] Dalším příkladem je studie Ústavu informatiky a výpočetní techniky Národního technologického institutu v Indii, viz. 6.4, kde využili a porovnali vícero modelů využitých pro rozpoznání stresu. Těmito modely byli DT, RF, AB, LDA, KNN a SVM. [32] Důvodem pro zvolení vyššího počtu klasifikačních modelů strojového učení pro tuto klasifikační úlohu, je možnost současného porovnání a vyhodnocení vhodnosti jednotlivých klasifikačních modelů pro tuto problematiku. Zvolené klasifikační modely strojového učení byli vytvořeny pomocí aplikace Classification learner dostupné v programovém prostředí MATLAB.

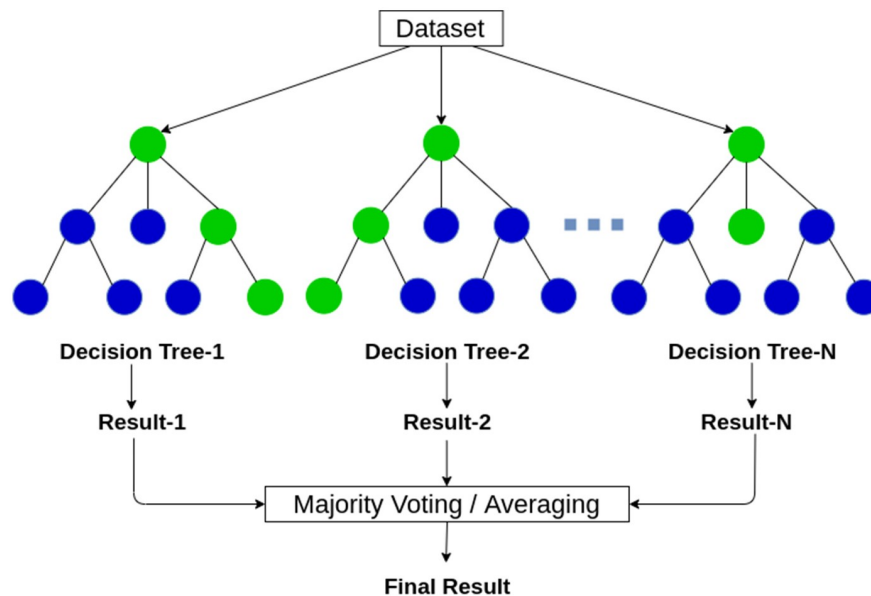
**Decition Tree**, neboli rozhodovací strom, je neparametrický algoritmus, využívající učení s učitelem, pro klasifikační a regresní úlohy. Má hierarchickou stromovitou strukturu skládající se z kořene (inicializační uzel), uzlů, větví a listů. Každý uzel využívá podmíněné kontrolní příkazy, na základě kterých se rozhodne jakou větví bude testovaný vzorek poslán dále strukturou stromu. Poslední částí hierarchické struktury je list, který určuje výsledek klasifikace nebo regrese. Rozhodovací stromy poskytují snadno interpretovatelné výsledky s možností vizualizace, avšak mají tendenci k přeučení, ztráty generalizační schopnosti a jsou velmi citlivé na outliery, tedy hodnoty značně odlišné od hodnot průměrných. Koncept příkladového rozhodovacího stromu můžeme vidět na obrázku 6.6. [39]



Obr. 6.6: Koncept Decition Tree, převzato z [40].


Algoritmus **Random Forest**, ve volném překladu náhodný les, implementuje metodu, která spočívá v kombinaci klasifikátorů a techniky bagging, detailně popsané v sekci 6.3.2. Tento algoritmus staví na konstrukci souboru rozhodovacích stromů, přičemž každý strom je generován z unikátního souboru tréninkových dat, který je vytvořen právě metodou bagging. Pro další snížení korelace mezi jednotlivými stromy je využíván také mechanismus feature bagging, což je proces náhodné

selekce podmnožin příznaků, probíhající paralelně s výběrem tréninkových vzorků. Přibližně jedna třetina tréninkové sady je vyčleněna do skupiny Out-of-Bag (OOB), která je následně použita pro validaci jednotlivých klasifikátorů. V případě klasifikace je konečným výsledkem modelu většinové hlasování mezi slabými klasifikátory. Koncept příkladového náhodného lesa můžeme vidět na obrázku 6.7. [41]




Obr. 6.7: Koncept Random Forrest, převzato z [42].

**Support vector machines (SVM)** neboli metoda podpůrných vektorů je metoda strojového učení s učitelem, sloužící zejména pro klasifikační úkoly. Cílem je nalezení nadroviny, na základě maximalizace rozpětí mezi podpůrnými vektory, která rozděluje prostor příznaků tak, že vzorky trénovací skupiny dat s odlišnou třídou leží v opačných poloprostorech. V neseparabilním příkladě využívá SVM soft-marginu, kde připouští misklasifikaci některých vzorků za účelem lepší generalizační schopnosti modelu. SVM dokáže řešit jak lineární, tak také nelineární klasifikační úlohy. Při řešení nelineárních klasifikačních úloh využívá SVM funkci jádra k transformaci dat do nového, z pravidla, vícerozměrného prostoru, za účelem možnosti lineárního oddělení. Koncept příkladového modelu SVM můžeme vidět na obrázku 6.8. [43]



Obr. 6.8: Koncept Support vector machine, převzato z [43].


Algoritmus **K-nearest neighbors** je neparametrický učící algoritmus s učitelem, který klasifikuje objekty na základě jejich vzdáleností v příznakovém prostoru. Pro měření těchto vzdáleností se nejčastěji používají Euklidovská a Manhattenská metrika. V kontextu klasifikačních úloh algoritmus vyhodnocuje vzdálenost testovaného vzorku od všech vzorků v trénovací množině. Přiřazení třídy probíhá na základě hlasování, kde se jako výsledná třída určuje ta, která převažuje mezi  $K$  nejbližšími sousedy testovaného vzorku. KNN je jedním z nejpopulárnějších a nejjednodušších algoritmů strojového učení, je robustní vůči šumu ale výpočetně náročný. Koncept příkladového modelu KNN můžeme vidět na obrázku 6.9. [44]



Obr. 6.9: Koncept K-nearest neighbors, převzato z [45].

**Linear Discriminant analysis (LDA)**, neboli lineární diskriminační analýza, je sofistikovaná metoda pro redukci dimenzionality, která se běžně používá v dohledaných klasifikačních úlohách. Tato technika transformuje data z prostoru s vyšší dimenzí do prostoru s nižší dimenzí tím, že optimalizuje separaci tříd. Specificky, LDA dosahuje toho, že maximalizuje vzdálenost mezi průměry tříd, zatímco simultánně minimalizuje rozptyl uvnitř každé třídy. To je realizováno nalezením lineárních diskriminantů, které efektivně maximalizují poměr rozptylu mezi třídami a rozptylu uvnitř třídy. Tento proces identifikuje přednostní směry ve příznakovém prostoru, jež nejúčinněji rozlišují mezi třídami. Důležité je poznamenat, že maximální dimenze výstupního prostoru z LDA je omezena počtem tříd v datasetu minus jedna. [46]

**Logistická regrese** je metoda pro vytvoření statistického modelu, který se používá v klasifikačních úlohách. Výstupem logistické regrese je pravděpodobnost příslušnosti každého vzorku do určité, předem definované třídy. Pro převod lineární kombinace vstupních proměnných na pravděpodobnost v rozmezí 0 až 1 se často využívá sigmoidální funkce. Optimalizace parametrů modelu se provádí pomocí metody gradientního sestupu, což je technika pro minimalizaci ztrátové funkce, konkrétně logistické ztráty, která je definována jako součet záporných logaritmů pravděpodobností správně klasifikovaných příkladů. Koncept modelu LR, pojednávajícího o splnění či nesplnění zkoušky na základě doby studia můžeme vidět na obrázku 6.10. [49] [50]



Obr. 6.10: Koncept Logistické regrese, převzato z [49].


**AdaBoost**, neboli Adaptive Boosting, je pokročilá technika boosting, která využívá kombinaci slabých klasifikátorů s adaptivní úpravou vah. Typicky se jako slabé klasifikátory používají jednorovňové rozhodovací stromy, známé jako pařezy. Proces adaptivního boostingu spočívá v iterativním trénování sekvence těchto klasifikátorů, přičemž každá iterace se zaměřuje na odlišné podmnožiny trénovacích dat. V průběhu každé iterace algoritmus přiděluje vyšší váhy vzorkům, které byly v předchozí iteraci chybně klasifikovány. Tím se zvyšuje důraz na obtížnější případy v následujících iteracích, což umožňuje postupné zlepšování výkonu jednotlivých slabých klasifikátorů. Výstupy každého klasifikátoru mají vliv na trénování následujících klasifikátorů, čímž je zajištěno, že každý následný klasifikátor se stává efektivnějším v klasifikaci složitějších případů. Váhy přiřazené jednotlivým klasifikátorům jsou určeny na základě jejich úspěšnosti při klasifikaci a hrají klíčovou roli při finální agregaci výsledků z těchto klasifikátorů. Tento iterativní tréninkový proces pokračuje až do splnění stanovené kritériální podmínky, což zajišťuje optimalizaci celkové klasifikační účinnosti modelu. Koncept příkladového modelu, využívající adaptivní boosting, můžeme vidět na obrázku 6.11. [47]



Obr. 6.11: Koncept Adaptiv Boostingu, převzato z [48].

### 6.4.1 Rozdělení dat

Naše trénovací a testovací fáze bude rozdělena do tří experimentů, které se odlišují délkou časových úseků měřených biologických signálů. Konkrétně se jedná o úseky o délkách 10, 30 a 60 sekund. Volba různých délek úseků byla motivována snahou určit optimální délku pro automatickou detekci stresu. Rozdělení na trénovací a testovací skupinu bylo provedeno náhodným rozdělením subjektů poměrem 4:1. Pro trénink a validaci klasifikačních modelů bude použita metoda k-násobná křížová validace, přesněji 10-ti násobná křížová validace. Křížová validace je metoda převzorkování dat k posouzení schopnosti generalizace klasifikačních modelů a k zabránění přeučení. [51] U k-násobné křížové validace je tréninková sada dat rozdělena na k přibližně stejně velkých podmnožin. Model je posléze trénován pomocí k-1 podmnožin. Zbývající podmnožina, neboli validační podmnožina dat je využita pro validaci. Tento postup se iterativně opakuje, dokud každá podmnožina nebyla využita jako podmnožina validační.



Obr. 6.12: 10-ti násobná křížová validace, převzato z [51].

Po rozdělení dat na trénovací a testovací sadu došlo k normalizaci příznakového prostoru tím způsobem, že byl normalizován příznakový prostor tréninkové skupiny dat a následně byl získanými parametry, průměrem a rozsahem hodnot tréninkové sady, normalizován také příznakový prostor testovací skupiny dat. Normalizace transformuje rozsah vstupních dat do rozsahu -1 až 1. Tímto krokem jsme zajistili normalizaci obou skupin dat, aniž bychom jakýmkoli způsobem využili testovací skupinu dat.

## 6.4.2 Parametry klasifikačních modelů

Úspěšná aplikace klasifikačních modelů, a tedy zisk kvalitních výsledků, závisí do značné míry na vhodném nastavení parametrů jednotlivých modelů. V této kapitole budou uvedeny parametry jednotlivých využitých modelů uvedených v kapitole 6.4, které byly získány jejich optimalizací, za ziskem nejlepších výsledků. Parametry těchto modelů můžeme vidět v tabulce 6.3. Parametry jednotlivých modelů, které nejsou uvedeny v tabulce 6.3, byli ponechány na výchozím nastavení jednotlivých klasifikačních modelů v aplikaci Classification learner.

Model	Parametr	Hodnota/způsob
Decision Tree	SplitCriterion	Gini's diversity index
	MaxSplits	20
	MinParent	10
	MinLeaf	1
	MergeLeaves	On
	Prune	On
	NVarToSample	All
Random Forest	N_estimators	100
	NVarToSample	4
	MinParent	1
	MinLeaf	2
Support Vector Machine	KernelFunction	Gaussian
	KernelScale	0.9
	BoxConstraint	1
	Solver	SMO
K-Nearest Neighbors	K	50
	Distance Metric	Euclidean
	Weights	Equal
Linear Discriminant Analysis	DiscrimType	Diaglinear
Adaboost Decition Tree	N_estimators	50
	MaxSplits	20
	MinParent	2
	MinLeaf	1
	NVarToSample	4
Logistic Regression	ScoreTransform	Logit
	BetaTolerance	0,0001
	Regularization	Ridge (L2)

Tab. 6.3: Shrnutí parametrů klasifikačních modelů

## 7 Výsledky práce

V této kapitole budou uvedeny výsledky klasifikačních modelů jednotlivých experimentů. Důležité je také uvést fakt, že jsme z námi vytvořeného datasetu v kapitole 6.2, vyřadili biologické signály subjektů z datasetu Stress-predict Dataset. Důvodem vyřazení bylo podezření na špatné anotace signálů tohoto datasetu. Tento dataset obsahuje ke každému subjektu soubor obsahující časové údaje o začátku a konci jednotlivých částí protokolu, ale počet těchto časových údajů, u některých subjektů, neodpovídá protokolu a také jednotlivé časové údaje přesně neodpovídají časovým údajům v tabulce o časovém průběhu protokolu jednotlivých subjektů. Z tohoto důvodu budou nadále uvedeny výsledky získané na vytvořeném datasetu spojením datasetu WESAD, Non-EEG predict a na těchto datasetech zvlášť.

K evaluaci klasifikačních modelů jsou využity metriky jako přesnost klasifikace [%] a F1 skóre. Přesnost (ACC) je poměr mezi správně klasifikovanými vzorky a celkovým počtem vzorků v sadě dat. Přesnost nabývá hodnot v intervalu  $\langle 0,1 \rangle$  a vypočítá se podle rovnice 7.1. [52]

$$ACC = \frac{\#correctlyclassifiedsamples}{\#allsamples} = \frac{TP + TN}{TP + FP + TN + FN} \quad (7.1)$$

F1 skóre je harmonickým průměrem precision a recall. Precision představuje přesnost pozitivních předpovědí, zatímco Recall představuje, jak dobře model dokáže identifikovat skutečné pozitivní případy. F1 skóre nabývá hodnot v intervalu  $\langle 0,1 \rangle$  a vypočítá se podle rovnice 7.2. [52]

$$F1 = 2 \times \frac{precision \times recall}{precision + recall} = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (7.2)$$

### 7.1 Experiment 1

Experiment 1 je věnován práci s biologickými signály o délce intervalu 10-ti sekund. Níže jsou uvedeny výsledky klasifikačních modelů provedené na validační a testovací skupině dat. Tabulka 7.1 ukazuje výsledky jednotlivých klasifikačních modelů při využití námi vytvořeného datasetu. Tabulky 7.2 a 7.3 ukazují výsledky jednotlivých klasifikačních modelů při využití datasetu WESAD a Non-EEG Biosignals zvlášť.

Model	Validační skupina		Testovací skupina	
	Přesnost [%]		F1 skóre	Přesnost [%]
DT	84.5		0.66	75.8
RF	97.2		0.65	76.0
SVM	76.9		0.66	73.7
KNN	77.2		0.66	72.7
LDA	64.7		0.69	69.9
AB	80.8		0.68	77.1
LR	71.8		0.58	68.6

Tab. 7.1: Úspěšnost klasifikačních modelů na námi vytvořeném datasetu, časový interval 10 sekund.

Jak můžeme vidět v tabulce 7.1, na testovací sadě dat sjednoceného datasetu naše modely dosahovali přesnosti až 77,1 % v případě modelu využívajícího adaptivní boosting. Dalšími modely s přesností blíží se modelu AB jsou modely RF s přesností 76 %, model DT s přesností 75,8 %. F1 skóre těchto modelů se pohybuje v hodnotách 0,65 až 0,69 s výjimkou modelu LR který dosáhl F1 skóre 0,58 společně s nejnižší úspěšností 68,6 %. Jak nám F1 skóre napovídá, modely mají tendenci, v případě chyby, určit stav subjektu jako falešně negativní, spíše než falešně pozitivní.

Model	Validační skupina		Testovací skupina	
	Přesnost [%]		F1 skóre	Přesnost [%]
DT	91,4		0.71	80
RF	97,6		0.66	80,2
SVM	90,3		0.95	96,8
KNN	84		0.83	85,6
LDA	81,5		0.87	89,7
AB	86,6		0.88	91,4
LR	82		0.96	97,1

Tab. 7.2: Úspěšnost klasifikačních modelů na datasetu WESAD, časový interval 10 sekund.

V tabulkách 7.2 a 7.3 můžeme vidět úspěšnosti klasifikačních modelů na jednotlivých datasetech zvlášť. Klasifikační modely vykazovaly znatelně vyšší přesnost na datasetu WESAD s přesností až 97,1 % a F1 skóre 0,96, v případě modelu LR. V případě datasetu Non-EEG Biosignals byla nejvyšší dosažená přesnost 71,8 % a F1 skóre 0,66, v případě modelu LR a AB.

Model	Validační skupina	Testovací skupina	
	Přesnost [%]	F1 skóre	Přesnost [%]
DT	86,2	0,6	67,8
RF	97,1	0,6	64,6
SVM	83,1	0,64	71,3
KNN	84,3	0,61	69,4
LDA	72,1	0,66	72,4
AB	80,5	0,6	71,8
LR	79,6	0,66	71,8

Tab. 7.3: Úspěšnost klasifikačních modelů na datasetu Non-EEG Biosignals, časový interval 10 sekund.

## 7.2 Experiment 2

Experiment 2 je věnován práci s biologickými signály o délce intervalu 30-ti sekund. Níže jsou uvedeny výsledky klasifikačních modelů provedené na validační a testovací skupině dat. Tabulka 7.4 ukazuje výsledky jednotlivých klasifikačních modelů při využití námi vytvořeného datasetu. Tabulky 7.5 a 7.6 ukazují výsledky jednotlivých klasifikačních modelů při využití datasetu WESAD a Non-EEG Biosignals zvlášť.

Model	Validační skupina	Testovací skupina	
	Přesnost [%]	F1 skóre	Přesnost [%]
DT	77,6	0,53	69,6
RF	94,1	0,69	78
SVM	77,8	0,66	74,4
KNN	73,1	0,6	70,2
LDA	67	0,59	68
AB	80,3	0,63	74,4
LR	68,3	0,46	66,6

Tab. 7.4: Úspěšnost klasifikačních modelů na námi vytvořeném datasetu, časový interval 30 sekund.

V případě intervalu o délce 30-ti sekund sjednoceného datasetu, dosahoval nejvyšší přesnosti model RF, 78 % a F1 skóre 0,69 na testovací skupině dat (viz. tab. 7.4), což je o 2 % vyšší přesnost stejného modelu oproti intervalu o délce 10-ti sekund na stejné skupině testovacích dat. Dále došlo k dosažení vyšší přesnosti oproti ex-

perimentu 1 u model SVM, a to 74,4 %, společně s F1 skórem 0,66. Oproti tomu například přesnost modelu DT klesla na 69,6 % v porovnání s předchozím experimentem kde stejný model dosahoval přesnosti 75,8 %. Obdobně tomu tak bylo i u ostatních modelů s mírným poklesem úspěšnosti.

Jak můžeme vidět v tabulkách 7.5 a 7.6, nejvyšší úspěšnosti na datasetu WESAD dosáhli modely LDA a LR s přesností 96,7 % a F1 skórem 0,95. V porovnání s předchozím experimentem nedošlo ke značným odchylkám přesnosti jednotlivých modelů a modely SVM a LR dosahovaly u obou experimentů nejvyšších dosažených přesností. Přesnosti modelů na datasetu Non-EEG Biosignals dosáhly v průměru vyšších přesností v porovnání s předchozím experimentem. Nejúspěšnějším modelem byl model LDA s přesností 77,1 % a F1 skórem 0,69, který měl taktéž nejvyšší úspěšnost v experimentu 1. Nejnižší přesnosti u intervalu 30-ti sekund dosáhl, u obou datasetů, model DT.

Model	Validační skupina	Testovací skupina	
	Přesnost [%]	F1 skóre	Přesnost [%]
DT	85,9	0,7	69,6
RF	95	0,79	87,5
SVM	89,1	0,94	95,7
KNN	80,2	0,89	91,8
LDA	75,5	0,95	96,7
AB	85,7	0,79	87
LR	81,2	0,95	96,7

Tab. 7.5: Úspěšnost klasifikačních modelů na datasetu WESAD, časový interval 30 sekund.

Model	Validační skupina	Testovací skupina	
	Přesnost [%]	F1 skóre	Přesnost [%]
DT	85,8	0,61	63
RF	94	0,65	71
SVM	82,2	0,66	72,7
KNN	80,1	0,64	70,4
LDA	76	0,69	77,1
AB	81,9	0,64	74,1
LR	81,2	0,68	73,7

Tab. 7.6: Úspěšnost klasifikačních modelů na datasetu Non-EEG Biosignals, časový interval 30 sekund.

## 7.3 Experiment 3

Experiment 3 je věnován práci s biologickými signály o délce intervalu 60-ti sekund. Níže jsou uvedeny výsledky klasifikačních modelů provedené na validační a testovací skupině dat. Tabulka 7.7 ukazuje výsledky jednotlivých klasifikačních modelů při využití námi vytvořeného datasetu. Tabulky 7.8 a 7.9 ukazují výsledky jednotlivých klasifikačních modelů při využití datasetu WESAD a Non-EEG Biosignals zvlášť.

Model	Validační skupina	Testovací skupina	
	Přesnost [%]	F1 skóre	Přesnost [%]
DT	80,9	0,58	70,5
RF	90,6	0,73	81,1
SVM	79,3	0,72	77,5
KNN	72,4	0,65	73,4
LDA	68,9	0,58	70,9
AB	79,1	0,69	76,6
LR	70,9	0,59	70,9

Tab. 7.7: Úspěšnost klasifikačních modelů na námi vytvořeném datasetu, časový interval 60 sekund.

Jak můžeme vidět v tabulce 7.7, při časovém intervalu 60-ti sekund dosahovali modely na testovací skupině dat sjednoceného datasetu přesnosti až 81,1 % a F1 skóre 0,73, v případě modelu RF. Druhým nejúspěšnějším modelem je model SVM s přesností 77,5 % a F1 skórem 0,72. Obecně můžeme vidět nárůst přesností u většiny modelů v experimentu 3 oproti experimentům předchozím. Nejnižší úspěšnosti dosahoval model DT s přesností 70,5 %.

Tabulky 7.8 a 7.9 opět uvádějí úspěšnost klasifikačních modelů na jednotlivých datasetech zvlášť. Nejvyšší přesnosti na testovací skupině datasetu WESAD dosahovali modely SVM, LDA a LR s přesností 96,7 % a F1 skórem 0,96 v případě modelů SVM a LDA a 0,95 v případě modelu LR. Nejnižší přesnost jsme zaznamenali u modelu KNN a to 89,1 %. Na testovací skupině dat datasetu Non-EEG Biosignals dosahoval nejvyšší přesnosti model LR a to 80 % s F1 skórem 0,74. Následovaly modely LDA s přesností 77,9 % a RF s přesností 77,2 %. Nejnižší přesnosti dosáhl model AB a to 73,8 %. Můžeme si všimnout, že modely testované na skupině dat datasetu Non-EEG Biosignals dosahovali vyšších přesností v porovnání s předchozími experimenty.

Model	Validační skupina	Testovací skupina	
	Přesnost [%]	F1 skóre	Přesnost [%]
DT	83,4	0,89	92,4
RF	94	0,89	92,4
SVM	88,6	0,96	96,7
KNN	78,3	0,85	89,1
LDA	76,4	0,96	96,7
AB	84,2	0,9	93,5
LR	81,5	0,95	96,7

Tab. 7.8: Úspěšnost klasifikačních modelů na datasetu WESAD, časový interval 60 sekund.

Model	Validační skupina	Testovací skupina	
	Přesnost [%]	F1 skóre	Přesnost [%]
DT	84,6	0,67	75,2
RF	90,5	0,64	77,2
SVM	82,9	0,69	76,6
KNN	78,4	0,66	75,9
LDA	74,3	0,71	77,9
AB	80,5	0,68	73,8
LR	81,9	0,74	80

Tab. 7.9: Úspěšnost klasifikačních modelů na datasetu Non-EEG Biosignals, časový interval 60 sekund.

## 7.4 Experiment 4

V posledním analyzovaném experimentu byli otestovány data jednoho datasetu na klasifikačních modelech strojového učení naučených na datech druhého datasetu. Tento experiment byl proveden za účelem zisku informace, zda odlišnost protokolu a využitých zařízení při akvizici dat výrazně ovlivní klasifikační schopnosti jednotlivých klasifikátorů.

V tomto experimentu využijeme délku vstupních signálů 60 sekund, z důvodu největší úspěšnosti klasifikačních modelů z předchozích experimentů. V tabulce 7.10, můžeme vidět výsledky klasifikačních modelů. Vlevo jsou uvedeny výsledky modelů natrénovaných na trénovací skupině datasetu WESAD a jako testovací skupina posloužily signály datasetu Non-EEG Biosignals. Na pravé straně poté opačně. Jinými slovy, dataset uveden v tabulce nad hodnotami F1 skóre a přesností byl využit jako testovací skupina dat.

V případě datasetu WESAD jakožto testovací skupiny pro klasifikační modely naučené na datasetu Non-EEG Biosignals, s délkou vstupních signálů 60 sekund, byla nejvyšší dosažená přesnost 59,1 % a F1 skóre 0,52 v případě modelu AB. V opačném případě byla dosažena nejvyšší přesnost s využitím modelu DT a to 54,1 % a F1 skóre 0,58.

V tabulce 7.10 můžeme vidět rapidní pokles úspěšnosti všech modelů oproti předešlým experimentům a tedy můžeme říci, že modely naučené na jednom datasetu nemají schopnost správně rozpoznat stres z biologických signálů datasetu druhého.

Model	Dataset Non-EEG Biosignals		Dataset WESAD	
	F1 skóre	Přesnost [%]	F1 skóre	Přesnost [%]
DT	0,58	54,1	0,61	56,7
RF	0,64	49,6	0,47	48,5
SVM	0,55	45,3	0,53	48,3
KNN	0,5	43,4	0,61	50,7
LDA	0,5	40,1	0,53	43,5
AB	0,65	52,1	0,64	59,1
LR	0,62	48,8	0,51	46,1

Tab. 7.10: Úspěšnost klasifikačních modelů jednotlivých datasetů proti sobě.

## 8 Diskuze

Hlavním cílem práce bylo vytvoření algoritmu pro automatické rozpoznání stresu pomocí biologických signálů měřených nositelnými zařízeními. Vstupem byli veřejně dostupné datasety obsahující biologické signály subjektů, které podstupovaly sadu stresových podnětů. Datasety, obsahující různé stresové podněty a využívající různé přístroje pro akvizici dat, nám umožňují vytvořit robustní algoritmus pro rozpoznání stresu. Klasifikační algoritmus byl vytvořen s využitím klasifikačních modelů strojového učení jako jsou Decision Tree, Random Forrest, Support Vector Machine, Linear Discriminant Analysis, AdaBoost Decision Tree a Logistic Regression. V procesu tvorby a optimalizace algoritmu bylo k řešení různých výzev využito nástroje ChatGPT, za účelem efektivního řešení problémů spojených s kódováním a debuggováním.

Evaluace algoritmu byla rozdělena do čtyř experimentů v závislosti na délce vstupních signálů (10, 30 a 60 sekund). Nejlepších výsledků na testovací skupině dat sjednoceného datasetu jsme získali s využitím délky vstupních signálů 60 sekund. Nejúspěšnějším modelem byl Random Forrest s přesností 81,1 % a F1 skórem 0,73. Při délce vstupních signálů 30 sekund byl nejúspěšnějším modelem opět Random Forrest s přesností 78 % a F1 skórem 0,69. Nejúspěšnějším modelem experimentu s délkou vstupních signálů 10 sekund byl model AdaBoost Decision Tree s přesností 77,1 % a F1 skórem 0,68. V rámci jednotlivých datasetů byla úspěšnost modelů značně vyšší u datasetu WESAD a to až 97,1 % a F1 skóre 0,96 u modelu Logistic Regression při délce vstupních signálů 10 sekund. U datasetu Non-EEG Biosignals dosáhl nejvyšší přesnosti také model Logistic Regression a to přesností 80 % a F1 skóre 0,74 při délce vstupních signálů 60 sekund. Nejlépe rozpoznávaným stresem byl fyzický stres, naopak modely měli tendenci k nerozpoznání kognitivních stresových podnětů. Tento výsledek může poukazovat na silnější reakci organismu na fyzický stres než na stres kognitivní.

Této problematice byly již v minulosti věnovány některé studie, které vycházely zejména z využití klasifikačních modelů strojového učení a neuronových sítí. Příkladem studie, která využívala jako vstupní data biologické signály dataset WESAD, je studie [32]. Její autoři využili řady klasifikačních modelů strojového učení, společně s neuronovou sítí. Nejlepších výsledků dosahovala navržená neuronová síť s přesností 95,21 %. Z klasifikačních modelů strojového učení dosáhl nejlepších výsledků model SVM s přesností 93,2 %. Při porovnání našich výsledků s touto studií, jsme dosáhli na datasetu WESAD vyšší přesnosti u některých klasifikátorů, avšak s větším rozptylem mezi jednotlivými klasifikátory.

Druhému námi využitému datasetu se věnovali přímo autoři datasetu Non-EEG Biosignals [26], jenž využili přístup učení bez učitele a pomocí Gaussian Mixture

modelu vytvořili algoritmus pro rozpoznání stresu. Autoři přitom dosáhli úspěšnosti 84,6 % při klasifikaci do čtyř tříd podle druhu stresu. Tímto krokem dokázali, že je možné rozlišit stresové situace i bez předchozích znalostí o vstupních datech. Touto metodou dosáhli autoři lepších výsledků, než dosahovali námi navržené klasifikátory na stejném datasetu.

Při využití jednoho datasetu jakožto vstupu našeho algoritmu, dosahují námi navržené klasifikátory případě datasetu WESAD podobné úspěšnosti jako ve zmíněné literatuře [32]. V případě datasetu Non-EEG Biosignals byla námi dosažená úspěšnost klasifikačních modelů o řádově jednotky procent nižší než u výše uvedených studií. Avšak odlišností našeho přístupu oproti výše uvedeným studiím, je využití více odlišných datasetů. Každý dataset sebou přitom nese určitá specifika, jako například přístroj použitý při akvizici dat, různý protokol měření, různé stresové podněty a podobně. Tyto odlišnosti mohou hrát roli při konečné klasifikaci a našim přístupem jsme se chtěli zaměřit a vytvořit algoritmus, který bude schopen rozpoznat stress, nehledě na způsobu akvizice vstupních dat.

V rámci realizované studie jsme dospěli k závěru, že odlišnosti v jednotlivých datasetech jsou tak veliké, že klasifikátory natrénované na jednom datasetu, i když dosahovaly vysoké přesnosti na testovací skupině dat stejného datasetu, nebyly schopny rozpoznat stress na jiném datasetu. Tento závěr může úzce souviset s hlavním limitem realizovaných analýz. Reakce na stress je velmi individuální a způsob akvizice dat, hraje velkou roli při následné klasifikaci. Nabízí se tedy myšlenka, že pro vyvinutí algoritmu pro rozpoznání stresu, využitelného v reálném životě při každodenním nošení nositelných zařízení, je potřeba nashromáždit dostatečné množství dat, které bude obsahovat biologické signály subjektů, které podstoupily nejrůznější typy stresových podnětů a jejich akvizice byla provedena pomocí senzorů, které jsou využity i v nositelném zařízení, které by případně vytvořený algoritmus využívalo.

## Závěr

Diplomová práce se zabývala automatickým rozpoznáním stresu pomocí biologických signálů měřených nositelnými zařízeními. Byl vytvořen algoritmus, v programovém prostředí MATLAB, využívající metod strojového učení, především klasifikačních modelů. Vstupem tohoto algoritmu byly biologické signály z vícero veřejně dostupných datasetů. Nejvyšší dosažená přesnost klasifikačních modelů byla 81,1% v případě sjednoceného datasetu. V případě využití jednotlivých datasetů jsme dosáhli přesnosti až 97,1% u datasetu WESAD a 80% u datasetu Non-EEG Biosignals. Po provedení experimentů jsme došli k závěru, že klasifikační modely naučené na jedné databázi, nejsou schopny správně klasifikovat stres na databázích jiných. Tento poznatek může sloužit jakožto podklad a výzva pro budoucí práce zabývající se touto problematikou.

# Literatura

- [1] *Stress*. Online. World Health Organization. 2023. Dostupné z: <https://www.who.int/news-room/questions-and-answers/item/stress>. [cit. 2024-04-19].
- [2] *What Is Stress?* Online. Verywellmind. 2022. Dostupné z: <https://www.verywellmind.com/stress-and-health-3145086>. [cit. 2024-04-19].
- [3] *Stressor*. Online. In: , Wikipedia contributors. Wikipedia: the free encyclopedia. San Francisco (CA): Wikimedia Foundation, 2023. Dostupné z: <https://en.wikipedia.org/wiki/Stressor>. [cit. 2024-04-19].
- [4] GUNNAR, Megan a QUEVEDO, Karina. The Neurobiology of Stress and Development. Online. *Annual Review of Psychology*. 2007, roč. 58, č. 1, s. 145-173. ISSN 0066-4308. Dostupné z: <https://doi.org/10.1146/annurev.psych.58.110405.085605>. [cit. 2024-04-19].
- [5] GUPTA, Gaytri; KHAN, Munna; SHERWANI, Kashif IK a MANAULLAH. Overview of the effect of physiological stress on different biological signals. Online. 2023 *International Conference on Recent Advances in Electrical, Electronics & Digital Healthcare Technologies (REEDCON)*. 2023, s. 251-255. ISBN 978-1-6654-9382-6. Dostupné z: <https://doi.org/10.1109/REEDCON57544.2023.10150828>. [cit. 2024-04-19].
- [6] GIANNAKAKIS, Giorgos; GRIGORIADIS, Dimitris; GIANNAKAKI, Katerina; SIMANTIRAKI, Olympia; RONIOTIS, Alexandros et al. Review on Psychological Stress Detection Using Biosignals. Online. *IEEE Transactions on Affective Computing*. 2022, roč. 13, č. 1, s. 440-460. ISSN 1949-3045. Dostupné z: <https://doi.org/10.1109/TAFFC.2019.2927337>. [cit. 2024-04-16].
- [7] *2.1 Signál, veličina, funkce, časová řada*. Online. Matematickabiologie. Dostupné z: <https://portal.matematickabiologie.cz/index.php?pg=analiza-a-modelovani-dynamicky-biologicky-dat-signaly-a-linearni-systemy-kapitola-pocatecni-2-nejdulezitejsi-pojmy-2-1-signal-velicina-funkce-casova-rada>. [cit. 2024-04-19].
- [8] *Biosignály z pohledu biofyziky*. Online. WikiSkripta. 2023. Dostupné z: [https://www.wikiskripta.eu/w/Biosign%C3%A1ly\\_z\\_pohledu\\_biofyziky](https://www.wikiskripta.eu/w/Biosign%C3%A1ly_z_pohledu_biofyziky). [cit. 2024-04-19].
- [9] *Biosignály/Druhy*. Online. Wikiversity. 2014. Dostupné z: <https://cs.wikiversity.org/wiki/Biosign%C3%A1ly/Druhy>. [cit. 2024-04-19].

- [10] *Elektrodermální aktivita - Electrodermal activity*. Online. Encyclopedia. 2021. Dostupné z: [https://wikijii.com/wiki/Electrodermal\\_activity](https://wikijii.com/wiki/Electrodermal_activity). [cit. 2024-04-19].
- [11] DR J BRAITHWAITE, Jason; DR G WATSON, Dr Derrick G Watson; JONES, Robert a ROWE, Mickey. *A Guide for Analysing Electrodermal Activity (EDA) & Skin Conductance Responses (SCRs) for Psychological Experiments*. 2.0. 2015.
- [12] NARDELLI, Mimma; GRECO, Alberto; SEBASTIANI, Laura a SCILINGO, Enzo Pasquale. ComEDA: A new tool for stress assessment based on electrodermal activity. Online. *Computers in Biology and Medicine*. 2022, roč. 150, č. 106144, s. 1-8. ISSN 00104825. Dostupné z: <https://doi.org/10.1016/j.compbio.2022.106144>. [cit. 2024-04-19].
- [13] *Tělesná teplota*. Online. WikiSkripta. 2023. Dostupné z: [https://www.wikiskripta.eu/w/T%C4%9Blesn%C3%A1\\_teploata](https://www.wikiskripta.eu/w/T%C4%9Blesn%C3%A1_teploata). [cit. 2024-04-19].
- [14] KATAOKA, H.; KANO, H.; YOSHIDA, H.; SAIJO, A.; YASUDA, M. et al. Development of a skin temperature measuring system for non-contact stress evaluation. Online. *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)*. 1998, roč. 20, č. 2, s. 940-943. ISBN 0-7803-5164-9. Dostupné z: <https://doi.org/10.1109/IEMBS.1998.745598>. [cit. 2024-04-19].
- [15] *Heart rate*. Online. In: , Wikipedia contributors. Wikipedia: the free encyclopedia. San Francisco (CA): Wikimedia Foundation, 2024. Dostupné z: [https://en.wikipedia.org/wiki/Heart\\_rate](https://en.wikipedia.org/wiki/Heart_rate). [cit. 2024-04-19].
- [16] *JAK FUNGUJE A K ČEMU SLOUŽÍ AKCELEROMETR?* Online. TME. 2020. Dostupné z: <https://www.tme.eu/cz/news/library-articles/page/22568/jak-funguje-a-k-cemu-slouzi-akcelerometr/>. [cit. 2024-04-19].
- [17] *What Is Anxiety Shaking?* Online. PsychCentral. 2022. Dostupné z: <https://psychcentral.com/anxiety/anxiety-shaking>. [cit. 2024-04-19].
- [18] *Wearable technology*. Online. In: , Wikipedia contributors. Wikipedia: the free encyclopedia. San Francisco (CA): Wikimedia Foundation, 2024. Dostupné z: [https://en.wikipedia.org/wiki/Wearable\\_technology](https://en.wikipedia.org/wiki/Wearable_technology). [cit. 2024-04-19].
- [19] YETISEN, Ali K.; MARTINEZ-HURTADO, Juan Leonardo; ÜNAL, Barış; KHADEMHOSEINI, Ali a BUTT, Haider. *Wearables in Medicine*. Online.

- Advanced Materials*. 2018, roč. 30, č. 33, s. 1-26. ISSN 0935-9648. Dostupné z: <https://doi.org/10.1002/adma.201706910>. [cit. 2024-04-19].
- [20] WITT, Daniel R.; KELLOGG, Ryan A.; SNYDER, Michael P. a DUNN, Jessilyn. Windows into human health through wearables data analytics. Online. *Current Opinion in Biomedical Engineering*. 2019, roč. 9, s. 28-46. ISSN 24684511. Dostupné z: <https://doi.org/10.1016/j.cobme.2019.01.001>. [cit. 2024-05-19].
- [21] *Koupit Apple Watch Ultra 2*. Online. In: Apple. 2024. Dostupné z: <https://www.apple.com/cz-edu/shop/buy-watch/apple-watch-ultra>. [cit. 2024-04-19].
- [22] *Wearable technology*. Online. YASAR, Kinza. Techtarget. 2023. Dostupné z: <https://www.techtarget.com/searchmobilecomputing/definition/wearable-technology>. [cit. 2024-04-19].
- [23] *Glucose Sensors: What They Are & How They Work*. Online. AquaMatrix. 2024. Dostupné z: <https://agamatrix.com/blog/glucose-sensors/>. [cit. 2024-04-16].
- [24] *3D-printed glucose biosensors on track for use in wearables*. Online. Builtin. 2019. Dostupné z: <https://builtin.com/iot-internet-things-wearables/3d-printed-glucose-biosensors-track-use-wearables>. [cit. 2024-04-19].
- [25] *Protern.io*. Online. Protern.io. 2024. Dostupné z: <https://protern.io/>. [cit. 2024-04-16].
- [26] BIRJANDTALAB, Javad; COGAN, Diana; POUYAN, Maziyar Baran a NOURANI, Mehrdad. A Non-EEG Biosignals Dataset for Assessment and Visualization of Neurological Status. Online. *2016 IEEE International Workshop on Signal Processing Systems (SiPS)*. 2016, s. 110-114. ISBN 978-1-5090-3361-4. Dostupné z: <https://doi.org/10.1109/SiPS.2016.27>. [cit. 2024-04-19].
- [27] SCHMIDT, Philip; REISS, Attila; DUERICHEN, Robert; MARBERGER, Claus a VAN LAERHOVEN, Kristof. Introducing WESAD, a Multimodal Dataset for Wearable Stress and Affect Detection. Online. *Proceedings of the 20th ACM International Conference on Multimodal Interaction*. 2018, s. 400-408. ISBN 9781450356923. Dostupné z: <https://doi.org/10.1145/3242969.3242985>. [cit. 2024-04-19].
- [28] *E4 wristband technical specifications*. Online. Empatika support centre. 2024. Dostupné z: <https://support.empatika.com/hc/en-us/articles/202581999-E4-wristband-technical-specifications>. [cit. 2024-04-17].

- [29] IQBAL, Talha; SIMPKIN, Andrew J.; ROSHAN, Davood; GLYNN, Nicola; KILLILEA, John et al. Stress Monitoring Using Wearable Sensors: A Pilot Study and Stress-Predict Dataset. Online. *Sensors*. 2022, roč. 22, č. 21, s. 1-16. ISSN 1424-8220. Dostupné z: <https://doi.org/10.3390/s22218135>. [cit. 2024-04-19].
- [30] HOVSEPIAN, Karen; AL'ABSI, Mustafa; ERTIN, Emre; KAMARCK, Thomas; NAKAJIMA, Motohiro et al. CStress. Online. *Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing*. 2015, s. 493-504. ISBN 9781450335744. Dostupné z: <https://doi.org/10.1145/2750858.2807526>. [cit. 2024-04-19].
- [31] COGAN, D.; POUYAN, M. Baran; NOURANI, M. a HARVEY, J. A wrist-worn biosensor system for assessment of neurological status. Online. *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. 2014, s. 5748-5751. ISBN 978-1-4244-7929-0. Dostupné z: <https://doi.org/10.1109/EMBC.2014.6944933>. [cit. 2024-04-19].
- [32] BOBADE, Pramod a VANI, M. Stress Detection with Machine Learning and Deep Learning using Multimodal Physiological Data. Online. *2020 Second International Conference on Inventive Research in Computing Applications (ICIRCA)*. 2020, s. 51-57. ISBN 978-1-7281-5374-2. Dostupné z: <https://doi.org/10.1109/ICIRCA48905.2020.9183244>. [cit. 2024-04-19].
- [33] *Feature Extraction*. Online. MathWork. 2024. Dostupné z: <https://www.mathworks.com/discovery/feature-extraction.html>. [cit. 2024-04-14].
- [34] GRECO, Alberto; VALENZA, Gaetano; LANATA, Antonio; SCILINGO, Enzo a CITI, Luca. CvxEDA: a Convex Optimization Approach to Electrodermal Activity Processing. Online. *IEEE Transactions on Biomedical Engineering*. 2015, roč. 63, č. 4, s. 1-1. ISSN 0018-9294. Dostupné z: <https://doi.org/10.1109/TBME.2015.2474131>. [cit. 2024-04-19].
- [35] *TreeBagger*. Online. MathWorks. 2024. Dostupné z: <https://www.mathworks.com/help/stats/treebagger.html>. [cit. 2024-05-06].
- [36] *What is bagging?* Online. IBM. 2024. Dostupné z: <https://www.ibm.com/topics/bagging>. [cit. 2024-05-06].
- [37] *Bagging vs Boosting in Machine Learning*. Online. In: Geeksforgeeks. 2022. Dostupné z: <https://www.geeksforgeeks.org/bagging-vs-boosting-in-machine-learning/>. [cit. 2024-05-06].

- [38] *OobPermutedPredictorImportance*. Online. MathWorks. 2024. Dostupné z: <https://www.mathworks.com/help/stats/classreg.learning.regr.regressionbaggedensemble.oobpermutedpredictorimportance.html#bv92si-1>. [cit. 2024-05-06].
- [39] *What is Decision Tree? [A Step-by-Step Guide]*. Online. Analyticsvidhya. 2024. Dostupné z: <https://www.analyticsvidhya.com/blog/2021/08/decision-tree-algorithm/>. [cit. 2024-05-06].
- [40] *Decision Trees*. Online. In: Bot Penguin. 2024. Dostupné z: <https://botpenguin.com/glossary/decision-trees>. [cit. 2024-05-06].
- [41] *What is random forest?* Online. IBM. 2024. Dostupné z: <https://www.ibm.com/topics/random-forest>. [cit. 2024-05-09].
- [42] *Random Forest Algorithm Explained* Online. In: Github.io. 2021. Dostupné z: <https://anasbrital98.github.io/blog/2021/Random-Forest/>. [cit. 2024-05-09].
- [43] *What are SVMs?* Online. IBM. 2023. Dostupné z: <https://www.ibm.com/topics/support-vector-machine>. [cit. 2024-05-09].
- [44] *What is the k-nearest neighbors (KNN) algorithm?* Online. IBM. 2024. Dostupné z: <https://www.ibm.com/topics/knn>. [cit. 2024-05-09].
- [45] *How to use k-Nearest Neighbors (KNN) with Python (Scikit-Learn example)*. Online. In: JC CHOUNARD. 2023. Dostupné z: <https://www.jcchouinard.com/k-nearest-neighbors/>. [cit. 2024-05-09].
- [46] *Linear Discriminant Analysis in Machine Learning*. Online. Geeksforgeeks. 2024. Dostupné z: <https://www.geeksforgeeks.org/ml-linear-discriminant-analysis/>. [cit. 2024-05-09].
- [47] *AdaBoost Algorithm: Understand, Implement and Master AdaBoost*. Online. In: Analyticsvidhya. 2024. Dostupné z: <https://www.analyticsvidhya.com/blog/2021/09/adaboost-algorithm-a-complete-guide-for-beginners/>. [cit. 2024-05-09].
- [48] *Implementing the AdaBoost Algorithm From Scratch*. Online. In: Geeksforgeeks. 2024. Dostupné z: <https://www.geeksforgeeks.org/implementing-the-adaboost-algorithm-from-scratch/>. [cit. 2024-05-09].

- [49] *Logistic regression*. Online. In: Wikipedia: the free encyclopedia. San Francisco (CA): Wikimedia Foundation, 2024. Dostupné z: [https://en.wikipedia.org/wiki/Logistic\\_regression](https://en.wikipedia.org/wiki/Logistic_regression). [cit. 2024-05-11].
- [50] *What is logistic regression?* Online. IBM. 2024. Dostupné z: <https://www.ibm.com/topics/logistic-regression>. [cit. 2024-05-11].
- [51] BERRAR, Daniel. Cross-Validation. Online. *Encyclopedia of Bioinformatics and Computational Biology*. 2019, roč. 1, s. 542-545. ISBN 9780128114322. Dostupné z: <https://doi.org/10.1016/B978-0-12-809633-8.20349-X>. [cit. 2024-05-13].
- [52] HICKS, Steven A.; STRÜMKE, Inga; THAMBAWITA, Vajira; HAMMOU, Malek; RIEGLER, Michael A. et al. On evaluation metrics for medical applications of artificial intelligence. Online. *Scientific Reports*. 2022, roč. 12, č. 1. ISSN 2045-2322. Dostupné z: <https://doi.org/10.1038/s41598-022-09954-8>. [cit. 2024-05-19].

# Seznam příloh

A Obsah elektronické přílohy

76

# A Obsah elektronické přílohy

Elektronická příloha této práce obsahuje skripty se zdrojovými kódy. Detailní popis funkcí skriptů a jejich částí se nachází v každém z nich. Všechny kódy jsou vytvořeny v programovém prostředí MATLAB R2023b.

Příloha této práce neobsahuje klasifikační modely, z důvodu jejich velikosti. Tyto modely jsou dostupné na odkazu:

[https://github.com/Surkec/Stress\\_recognition.git](https://github.com/Surkec/Stress_recognition.git)

```
/ .....kořenový adresář
├── Dataset_spojeni.m .....Spojení dat jednotlivých datasetů
├── main.m .....hlavní skript pro extrakci a selekci příznaků a rozdělení dat
├── NonEEG_zpracovani.m .....zpracování dat datasetu Non-EEG Biosignals
├── StressPredict_zpracovani.m .....zpracování dat datasetu Stress Predict
└── WESAD_zpracovani.m .....zpracování dat datasetu WESAD
```