

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

BAKALÁŘSKÁ PRÁCE



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

AUTOMATICKÁ DETEKCE STRESU POMOCÍ NON-EEG BIOLOGICKÝCH SIGNÁLŮ

AUTOMATIC STRESS DETECTION USING NON-EEG BIOLOGICAL SIGNALS

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Ondřej Malina

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Radovan Smíšek

BRNO 2019



Bakalářská práce

bakalářský studijní obor **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Student: Ondřej Malina

ID: 185951

Ročník: 3

Akademický rok: 2018/19

NÁZEV TÉMATU:

Automatická detekce stresu pomocí non-EEG biologických signálů

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s problematikou stanovení stresu pomocí biologických non-EEG signálů. 2) Realizujte v programovém prostředí MATLAB algoritmus klasifikující stres. 3) Otestujte algoritmus na databázi A Non-EEG Dataset for Assessment of Neurological Status. 4) Dle výsledků algoritmus optimalizujte. 5) Diskutujte dosažené výsledky, porovnejte dosažené výsledky s výsledky dosaženými jinými autory.

DOPORUČENÁ LITERATURA:

[1] Birjandtalab, Javad, Diana Cogan, Mazyar Baran Pouyan, and Mehrdad Nourani, A Non-EEG Biosignals Dataset for Assessment and Visualization of Neurological Status, 2016 IEEE International Workshop on Signal Processing Systems (SiPS), Dallas, TX, 2016, pp. 110-114. doi: 10.1109/SiPS.2016.27

[2] Bakker J, Pechenizkiy M, Sidorova N. What's your current stress level? Detection of stress patterns from GSR sensor data. Proc - IEEE Int Conf Data Mining, ICDM 2011:573–80. doi:10.1109/ICDMW.2011.178.

Termín zadání: 4.2.2019

Termín odevzdání: 24.5.2019

Vedoucí práce: Ing. Radovan Smíšek

Konzultant:

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

UPOZORNĚNÍ:

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

ABSTRAKT

Tato práce se věnuje problematice detekce stresu za využití non-EEG biosignálů. První část se zabývá vymezením stresu a pojmům s ním souvisejícím. Popisuje možné pohledy na fenomén stresu, zmiňuje možné příčiny stresu, stejně jako fyziologické a psychologické projevy krátkého i dlouhodobého působení stresu. Dále se tato práce zabývá několika různými metodami používaných k detekci stresu pomocí non-EEG signálů. Za tímto účelem jsou v této práci k nalezení krátké rešerše článků, věnující se této tématice. V poslední kapitole je popsán návrh algoritmu, který je určený k detekci a klasifikaci stresu. K tomuto účelu využívá metodu shlukové analýzy c-means, metody strojového učení SVM a logistické regrese. K jeho realizaci byla použita data z databáze Non-EEG Dataset for Assessment of Neurological Status. Výstupem algoritmu je sada naučených modelů určených k detekci přítomnosti různých druhů stresu. Při testování modelů jsme dospěli k závěru, že náš algoritmus je schopný detekovat přítomnost stresu a výskyt fyzického stresu s relativně dobrými výsledky. Algoritmus se nic méně příliš nehodí k detekci jakéhokoliv druhu psychického stresu.

KLÍČOVÁ SLOVA

Stres, fyziologický stres, psychický stres, detekce stresu, non-EEG biosignály, metoda c-means, metody strojového učení, metoda podpůrných vektorů, logistická regrese, PhysioNet

ABSTRACT

This work deals with the issue of stress detection using non-EEG biosignals. The first part deals with the definition of stress and related concepts. It describes possible perspectives on stress phenomenon, mentions possible causes of stress as well as physiological and psychological manifestations of short and long-term effects of stress. Furthermore, this work deals with several different methods used to detect stress by non-EEG signals. To this end, a short research of articles dealing with this topic is found in this work. The last chapter describes the design of the algorithm, which is intended for the detection and classification of stress. For this purpose, it uses the c-means clustering method, SVM machine learning methods, and logistic regression. The data from the Non-EEG Dataset for Assessment of Neurological Status were used for its implementation. When testing the models, we conclude that our algorithm is able to detect the presence of stress and the occurrence of physical stress with relatively good results.

KEYWORDS

Stress, physiological stress, psychological stress, stress detection, non-EEG biosignals, c-mean, machine learning methods, support vector machines, logistic regression, PhysioNet

MALINA, Ondřej. *Automatická detekce stresu pomocí non-EEG biologických signálů*. Brno, 2019, 53 s. Bakalářská práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce: Ing. Radovan Smíšek

PROHLÁŠENÍ

Prohlašuji, že svou bakalářskou práci na téma „Automatická detekce stresu pomocí non-EEG biologických signálů“ jsem vypracoval samostatně pod vedením vedoucího bakalářské práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené bakalářské práce dále prohlašuji, že v souvislosti s vytvořením této bakalářské 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

PODĚKOVÁNÍ

Rád bych poděkoval vedoucímu bakalářské práce panu Ing. Radovanu Smíškovi, za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci. Také bych rád poděkoval své rodině za podporu, kterou mi během psaní této práce poskytla.

Brno

.....

podpis autora

Obsah

Úvod	10
1 Stres a jeho mechanismy	11
1.1 Definice stresu	11
1.1.1 Stresory	11
1.1.2 Všeobecný adaptační syndrom	12
1.1.3 Rozdělení stresu	12
1.2 Fyziologický stres	13
1.2.1 Reakce „fight or flight“	13
1.2.2 Fyziologické děje v jednotlivých fázích GAS	14
1.2.3 Teorie kortiko-viscerální patologie	15
1.3 Psychický stres	15
1.3.1 Eustres a Distres	16
1.3.2 Kognitivně behaviorální přístup a coping	17
1.3.3 Kognitivní stres a emoční stres	17
1.4 Holistický pohled	17
1.4.1 Chronický únavový syndrom	18
2 Metody automatické detekce stresu	19
2.1 Vizualizace neurologického stavu za užití shlukovací metody GMM	19
2.1.1 Použitá data	19
2.1.2 Aplikace metody GMM	20
2.1.3 Výsledky metody GMM	21
2.2 Detekce stresu pomocí GSR senzorů za využití metod fit a ADWIN	21
2.2.1 Měření GSR senzory	22
2.2.2 Vyhodnocování získaných dat	22
2.2.3 Dosažené výsledky	23
2.3 Porovnání úspěšnosti detekce stresu pomocí různých klasifikátorů využívajících strojového učení	23
2.3.1 Použitá data	23
2.3.2 Úprava dat a klasifikační modely	24
2.3.3 Výsledky studie	24
2.4 Detekce stresu za použití State-Space modelů	25
2.4.1 Použitá datová soubory	25
2.4.2 Popis metody	26
2.4.3 Dosažené výsledky	27
2.5 Detekce stresu s využitím fuzzy logiky	29

2.5.1	Získání databáze	30
2.5.2	Systém detekce stresu	30
2.5.3	Výsledky	31
3	Výsledky studentské práce	32
3.1	Vstupní data a jejich popis	32
3.2	Popis algoritmu	34
3.2.1	Nahrání a úprava dat	35
3.2.2	Metoda c-means a tvorba matic pro strojové učení	37
3.2.3	Strojové učení modelů a jejich testování	37
3.3	Dosažené výsledky	38
3.3.1	Detekce přítomnosti či absence stresu	38
3.3.2	Detekce přítomnosti fyzického stresu	40
3.3.3	Detekce přítomnosti psychického stresu	41
3.3.4	Detekce přítomnosti kognitivního psychického stresu	42
3.3.5	Detekce přítomnosti emočního psychického stresu	43
3.4	Srovnání dosažených výsledků a diskuze	44
4	Závěr	47
	Literatura	48
	Seznam symbolů, veličin a zkratk	51
	Seznam příloh	52
A	Obsah přiloženého CD	53

Seznam obrázků

1.1	Yerkes-Dodsonuv zákon stresu a výkonnosti[4]	16
1.2	Fáze stresu	18
2.1	Postup při zpracování signálu z GSR senzorů [10]	23
2.2	Výsledky detekce stresu pomocí State-Space modelu na subjektu z databáze Stress Recognition in Automobile Drivers Dataset [14]	28
2.3	Výsledky detekce stresu pomocí State-Space modelu na subjektech z databáze Non-EEG Dataset for Assessment of Neurological Status [14]	29
3.1	Surový signál před předzpracováním, subjekt 1 [9]	34
3.2	Blokové schéma algoritmu	35
3.3	Vizualizace načtených dat subjektu 1 pomocí příkazu plotATM, doplněné o místa působení stresorů, získané z anotace. Na horním grafu se nachází signál z akcelerometru, EDA a teploty pokožky. Na dolním grafu se nachází signály tepové frekvence a saturace krve	36
3.4	Boxplot jednotlivých údajů pro modely detekující přítomnost či absenci stresu	39
3.5	Boxplot jednotlivých údajů pro modely detekující přítomnost fyzického stresu	40
3.6	Boxplot jednotlivých údajů pro modely detekující přítomnost emočního psychického stresu	44

Seznam tabulek

2.1	Výsledky experimentu detekce stresu za využití metody GMM-1	21
2.2	Výsledky experimentu detekce stresu za využití metody GMM-2	21
2.3	Přesnost klasifikátorů dle použitých metody strojového učení	25
3.1	Tabulka s informacemi o jednotlivých subjektech	33
3.2	Tabulka výsledků modelů detekce přítomnosti či absence stresu	39
3.3	Tabulka výsledků modelů detekujících přítomnosti fyzického stresu . .	40
3.4	Tabulka výsledků senzitivity a specificity modelů detekujících přítom- nosti psychického stresu	41
3.5	Tabulka výsledků přesnosti modelů detekujících přítomnosti psychic- kého stresu	42
3.6	Tabulka výsledků modelů detekujících přítomnosti kognitivního psy- chického stresu	42
3.7	Tabulka výsledků modelů detekujících přítomnosti emočního psychic- kého stresu	43
3.8	Tabulka porovnávací výsledky dosažené pomocí námi navržené me- tody s metodou autorů článku [9]	46
3.9	Tabulka srovnání různých metod strojového učení autorů článku [12] s našimi.	46

Úvod

Přestože pomocí snímání signálu EEG lze poměrně přesně detekovat stres, má tato metoda velké omezení v tom, že ji lze realizovat pouze ve specializovaných zařízeních (nemocnicích, neurologických laboratořích apod.) a nelze ji efektivně využít pro dlouhodobější detekci v běžných podmínkách.

Oproti tomu detekce stresu pomocí non-EEG signálů je možné lehce realizovat i v běžných životních situacích, což této metodě poskytuje široké pole uplatnění například při nastavování dobré strategie zvládání stresu v zaměstnání, či během řízení auta, predikování suicidálního chování u psychiatrických pacientů nebo ověřování účinnosti medikace psychofarmaky.

Tuto skutečnost ještě podporuje fakt, že v poslední době dochází k masivnímu rozšiřování zařízení typu fitness smartwatch a healthwatch, které jsou cenově dostupné a jsou schopny detekovat řadu biosignálů využitelných k detekci stresu.

Tato práce se věnuje ve své první části popisu stresu, jeho mechanismů a projevů, možným příčinám jeho vzniku a možnostem jeho klasifikace.

Dále se tato práce zabývá různými možnostmi detekce stresu pomocí non-EEG signálů. V rámci zmapování tohoto tématu je v práci přítomno několik rešerší, které se zabývají danou problematikou. Zvláštní důraz je kladen na informace ohledně toho, jaké typy signálů autoři prací použili k detekci stresu, jak tyto signály byly snímány a pomocí jakých metod byly klasifikovány.

V posledním oddíle si tato práce klade za cíl navrhnout algoritmus, vhodný k detekci a klasifikaci stresu z non-EEG signálů. K tomuto účelu využívá signály z databáze non-EEG Dataset for Assessment of Neurological Status, která obsahuje 5 non-EEG signálů pořízených snímáním pohybů zápěstí, změny konduktance kůže, změny teploty pokožky, saturace krve a tepové frekvence. Mimo tyto signály algoritmus využívá shlukovou analýzu fuzzy c-means a metody strojového učení SVM a logistické regrese.

1 Stres a jeho mechanismy

Stres je pojem, se kterým se setkáváme zcela běžně, a to takřka každý den. I přes tuto skutečnost však není tento výraz snadné definovat, neboť jej používá jak laická veřejnost, tak celá řada vědeckých oborů a v každé oblasti se význam tohoto slova liší. Společným prvkem těchto definic je nicméně to, že se vždy jedná o ohrožení či narušení integrity živé (popř. i neživé) hmoty. [1]

Pro široký význam tohoto slova se omezme jen na oblasti zájmu, které jsou pro nás v souvislosti s touto prací relevantní a definujme si stres tak, jak je chápán z pohledu dnešní medicíny ¹.

1.1 Definice stresu

V medicíně je stres chápán jako funkční stav živého organismu, při němž je tento organismus vystaven působení vnější výrazné zátěže, jejímž působením je v organismu ohrožený stav homeostázy (stálosti vnitřního prostředí). Odpovědí organismu na tyto podmínky je pak řada obraných reakcí, jež mají za úkol zachovat homeostázu a zabránit poškození či dokonce smrti organismu. [1] [2] [3]

1.1.1 Stresory

Vnější faktory, které působí na organismus výraznou zátěží a vyvolávají v organismu stresovou reakci, nazýváme obecně jako stresory. Stresorem je většinou nějaká životní událost, ale může jím být i vnitřní prožitek (např. bolestná vzpomínka).

[1] [4]

Stresory lze rozdělit do čtyř hlavních skupin na:

- fyzikální: teplo, chlad, tlak, zasažení zářením či elektrickým proudem atd.
- chemické: intoxikace jedy, alkoholem či jinými toxiny, infekce, hypoglykemie atd.
- biologické: hlad, žízeň, bolest, popáleniny, polytraumata, hemoragický stres atd.
- psychosociální: úzkost, strach, sexuální nedostatečnost, hospitalizace atd. [1]

Intenzita stresorů může nabývat velké variační šíře, což ostatně dobře demonstruje Teorie životních událostí publikovaná Thomasem H. Holmesem a Richardem H. Raheem [5]. Holmes a Rahe na základě velkého počtu klinických studií sestavili tabulku různých stresorů, kde ke každému z nich přiřadili určitý počet bodů dle

¹Vyjma pohledu lékařské biochemie, kde je stres chápán jako narušení buněčné integrity vyvolané převahou volných kyslíkových radikálů, což je pro tuto práci irelevantní

míry intenzity, kterou stresor působí na organismus (např. úmrtí partnera má v této tabulce hodnotu 100 bodů, svatba 50, Vánoce 12 atd.). Dle součtu nasbíraných bodů za určité časové období posléze vyhodnocovali, jaké míře stresu byla osoba vystavena. Je nutné si ovšem uvědomit, že výsledky získané za pomoci této metody jsou spíše orientační, neboť vedle samotné intenzity stresoru hraje významnou roli také míra akceptace stresu (tedy rozdílná míra vlivu různých druhů stresorů na pacienta), stejně jako individuální stresová tolerance jednotlivých jedinců. [1] [4]

1.1.2 Všeobecný adaptační syndrom

Všeobecný adaptační syndrom, jinak též GAS (General Adaptation Syndrome), je pojem, který jako první použil kanadský fyziolog a lékař rakousko-maďarského původu Hans Selye, který je dnes považován za otce moderního výzkumu stresu. Selye na tuto myšlenku přišel vlastně náhodou, kdy si při výzkumu vlivu nově izolovaných hormonů na laboratorních myších všiml, že pokud je organismus zvířete závažně poškozen akutní nespecifickou noxou (je-li vystaven stresorům) objeví se typický syndrom, jehož symptomy jsou nezávislé na charakteru noxy. Selye tento jev definoval jako celkovou a nespecifickou snahu organismu adaptovat se na nově vzniklou situaci a popsal průběh tohoto syndromu ve třech fázích: [3] [4]

- první fáze (6-48 hodin) - Spustí se poplachové reakce. Začínají pracovat obranné mechanismy. Organismus se pokouší zvládnout stresovou situaci. Jedná se o akutní stres.
- druhá fáze (po 48 hodinách)-Organismu se začíná adaptovat na zátěž. Stres přechází z akutního do chronického.
- třetí fáze (1-3 měsíce)-Vyčerpání organismu důsledkem dlouhodobého zvládání stresu. Adaptivní procesy selhávají. Organismus ztrácí rezistenci. Rezervní zásoby energie organismu jsou vyčerpány. Dochází k těžkému poškození organismu a ke smrti. [3] [4] [6]

1.1.3 Rozdělení stresu

Dnešní medicína, v souladu s Descartesovou doktrínou dualismu těla a duše, rozlišuje stres fyziologický a psychický.

V současnosti se tyto dvě pojetí stresu postupně sblíží a existují tendence nahlížet na stres uceleně, holisticky, a to již jen z toho důvodu, že některé jevy spojené se stresem nelze vysvětlit pouze z pohledu fyziologie nebo psychologie. [1]

1.2 Fyziologický stres

Fyziologický přístup pojímá stres jako fyziologické účinky široké řady averzních až přímo škodlivých vlivů prostředí na organismus. Samotná stresová reakce je potom chápána jako logická reakce organismu na okolní vlivy. [4]

Ve své podstatě vychází toto pojetí z několika obecných koncepcí a závěrů vyvozených ze známých teorií.

1.2.1 Reakce „fight or flight“

První touto koncepcí je reakce na ohrožení známá jako reakce „fight or flight“ (útok nebo útěk), kterou popsal v roce 1915 americký fyziolog Walter B. Cannon. Vycházel ze své předchozí teorie homeostázy. Reakční reakci popsal jako rychlý kompenzační mechanismus směřující k udržení či plnému obnovení vnitřní rovnováhy organismu. Výsledkem jeho bádání byl popis aktivace sympato-adrenomedulárního systému při primární jednoduché stresové reakci, která ovlivňuje činnost většiny orgánů v těle. [3] [4]

Při této reakci dochází k ovlivňování organismu jednak pomocí nervového aparátu a pak také pomocí endokrinního systému.

Nervový systém se při této reakci prosazuje především změnou aktivity vegetativního nervového systému (ANS), tedy částí nervového systému, která není ovládaná vůlí.

Na jedné straně dochází ke stimulaci sympatiku, který zvyšuje tepovou frekvenci a tlak, čímž se zvyšuje perfuze kosterní a srdeční svalovinou a plicemi. Díky jeho zvýšené aktivitě dilatují bronchioly, což zajišťuje větší alveolární výměnu plynů a zároveň dochází k vasokonstrikci na periferiích, čímž se centralizuje oběh.[6]

Na straně druhé je tlumena aktivita parasympatiku, což má za důsledek snížené perfuze krve systémem GIT, tím pádem se snižuje peristaltika a zastavuje trávení. Snižuje se aktivita slinných žláz. Jeho sníženou aktivitou jsou dilatované zornice a centralizuje se krevní oběh.[6]

Endokrinní systém se na této reakci podílí aktivací osy hypotalamus-hypofyzanadledviny. Primární podnět k sekreci hormonů přichází z hypotalamu, jakožto řídicího centra celého endokrinního systému. Pod jeho vlivem dochází k vyplavení hormonů z hypofýzy, které dále ovlivňují činnost dalších žláz s vnitřní sekrecí, u stresové reakce konkrétně činnost nadledvin.[6]

Kůra nadledvin produkuje hormony steroidní povahy, glukokortikoidy (konkrétně kortizol a kortizon), které regulují metabolismus. Díky jejich činnosti dochází v těle k anabolickým dějům při nichž jsou odbourávány zásobní látky, nejdříve glykogen, později zásoby tukové povahy, a jsou přeměňovány na energii. [6]

Z dřeně nadledvin se uvolní adrenalin, který patří do skupiny katecholaminů. Tento hormon připravuje tělo na extrémní zátěž. Urychluje srdeční činnost, centralizuje oběh, působí bronchodilatačně, ovlivňuje hladinu inzulínu (negativně) a glukagonu (pozitivně) v krvi čímž zvyšuje glykémii. Adrenalin a kortizol jsou antagonisté, kortizol zabráňuje poškození organismu při zvýšeném množství adrenalinu. Adrenalin, noradrenalin a glukokortikoidy tvoří skupinu stresových hormonů. [6]

1.2.2 Fyziologické děje v jednotlivých fázích GAS

Další z teorií, ze které toto pojetí vychází, je samozřejmě Selvyeho všeobecný adaptační syndrom. Selvye byl vůbec první, kdo použil pojem stres v lékařském kontextu a přenesl tak tento pojem z technického slovníku do lékařské literatury. Přestože Selvye později své poznatky přenesl i do humánních rovin, prvotně svůj jev popsal u laboratorních zvířat, u kterých (samozřejmě už jen z pozice toho, že byl studentem medicíny), popisoval změny odehrávající se na fyziologické úrovni. [4]

Podíváme-li se na GAS z fyziologického hlediska tak, jak to udělal Selvye se svými laboratorními zvířaty, můžeme v jeho jednotlivých fázích pozorovat tyto fyziologické změny:

- první fáze (6-48 hodin) - po vystavení noxe, lze pozorovat zmenšování objemu lymfatických orgánů tj. thymu, sleziny, jater a lymfatických uzlin. V pleurální a peritoneální dutině se začíná hromadit ve větší míře transsudát. Klesá svalový tonus a klesá tělesná teplota. V trávicím systému (především v žaludku, tenkém střevu a appendixu) a na kůži se mohou objevit defekty. Zvyšuje se lakrimace (slzení) a salivace (slinění). [4]
- druhá fáze (po 48 hodinách) - se začínají objevovat defekty nadledvin (výrazně se zvětšují a objevují se v nich lipoidní granuly). V hypofýze se objevuje velké množství bazofilních granulocytů. Zastaví se růstové pochody a gonády mohou atrofovat. Pokud byla před poškozením přítomna laktace, zastavuje se stejně jako menstruační cyklus. Přední lalok hypofýzy omezuje produkci růstového hormonu a gonadotropních hormonů ve prospěch zvýšené produkce tyreotropních a adrenotropních systémů. [4]
- třetí fáze (1-3 měsíce) - dochází k ní, jestliže je organismus dále vystaven v plném rozsahu toxické noxe. Organismus ztrácí rezistenci, dostává se do stavu, v němž bylo na začátku první fáze, což je stav exhausce. Organismus plně vyčerpá své zásoby a nakonec umírá. [4]

Je zde nutné dodat, že Selvye při formulování těchto poznatků, vystavoval svá zvířata vskutku extrémní zátěži. Svě subjekty vystavoval chladu, způsoboval jim spinální šok (způsobený operativním přetnutím míchy), extrémní fyzické námaze, popřípadě je intoxikoval různými látkami jako byl např. atropin, adrenalin, morfin či formaldehyd. [4]

1.2.3 Teorie kortiko-viscerální patologie

Poslední velkou oblastí, ze které toto pojetí stresu vychází, jsou výzkumy a studie související se zkoumáním kortiko-viscerálního a limbického systému. [1]

Tyto výzkumy vychází z Pavlovových prací o podmíněných reflexech, kde Pavlov popisuje sekreci žaludečních šťáv jako autonomní jev, kdy impulsy pro tento stimul poskytují viscerální aferentní dráhy. Pojem kortiko-viscerální vztahy, který definovala Pavlovova škola, vytvořil základ pro teorii kortiko-viscerální patologie, kterou dále rozpracovali K.M. Bykov a I.T. Kurtsin. Popsali, že při nadměrně, patologické stimulaci těchto drah, které jsou normálně aktivované i při stresu, dochází k obdobným patologiím v oblasti nadledvin a GIT jako při GAS. Na základě těchto výzkumů se Bykov s Kutozovem snažili objasnit např. vznik psychosomatických onemocnění. [1] [7] Obdobné jevy byly popsány i při stimulaci určitých autonomních jader limbického systému. [7]

1.3 Psychický stres

Psychický stres je možné definovat jako dynamickou interakci *psýché* člověka na prostředí. Psychické tlaky (stresory), jsou v organismu schopné vyvolat stresovou odpověď a to i přesto, že nejsou hrozbou pro naše fyzické přežití. [4] [1]

Podkladem pro toto pojetí stresu je několik teorií. Stresory lze rozdělit do čtyř hlavních skupin na:

- hlubinné pojetí psychologie a vývoj pudových sil, které vypracoval S. Freud
- teorie o vědomém a nevědomém prožívání životních zážitků
- typologie postojů vůči konfliktů
- modely typologií osobností, vypracované např. Hansem Eysenckem nebo Rayem Rosenmanem

Psychické reakce na stres jsou typicky přizpůsobení, úzkost a deprese.

Přizpůsobení je vlastně adaptací na nově vzniklou situaci. U člověka se stabilizuje jeho psychický stav, dochází k racionalizaci situace.[8]

Úzkost je nepříjemný prožitek, který má silný vegetativní doprovod. Vede k vyčerpání a únavě organismu. Typicky k ní patří pocit ohrožení, problémy s koncentrací, pocity návalů horka a zimy, třes aj.[8]

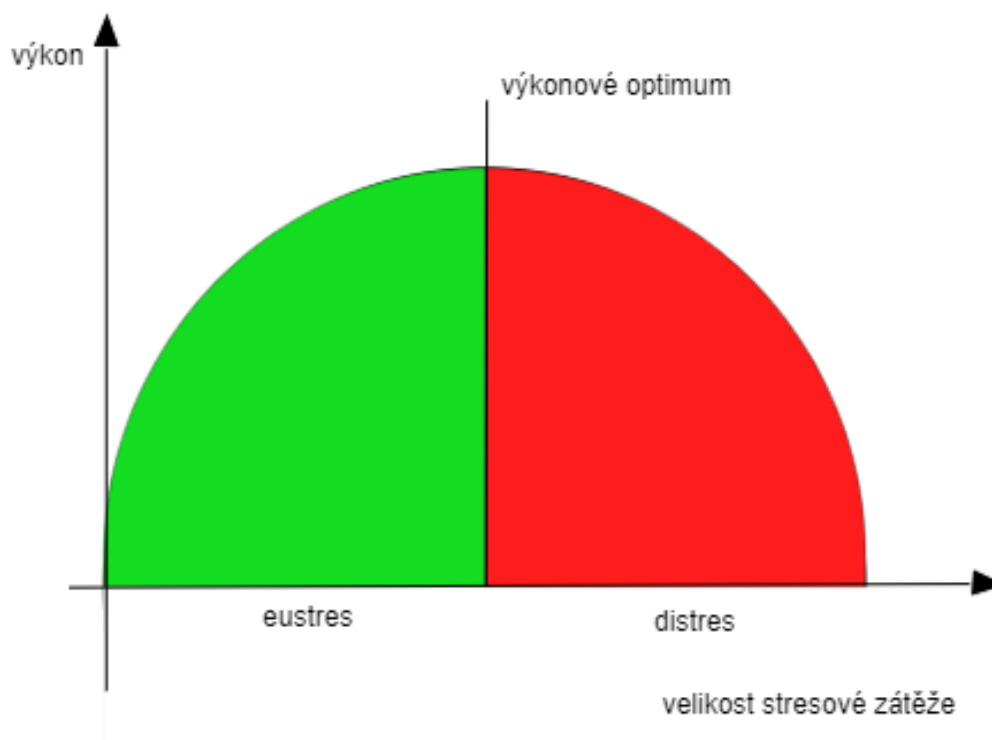
Deprese je psychické onemocnění, řadí se mezi afektivní poruchy. Projevuje se pocity deprivace, únavy, osamělosti, skleslou náladou, ztrátou chuti k jídlu, ztrátou schopnosti se radovat a celkovou apatii. Nutnou podmínkou pro diagnózu deprese je to, aby stav trval minimálně dva týdny.[8]

1.3.1 Eustres a Distres

Přesto, že v laické společnosti je stres chápán převážně jako věc negativní, není tomu tak. Stres jako takový je možné z hlediska psychologie dělit na dva druhy a to na eustres a distres. [3]

Eustres (také pozitivní stres či prestres) je stres, který je pro člověka příznivý, vede k větší odolnosti organismu, člověka stimuluje a v akutním ohrožení jej zachraňuje. [1] [4]

Distres (neboli též negativní stres) je chronický traumatický stres, který je pro lidský organismus nepříznivý a poškozují psychické i tělesné zdraví. [1] [4]



Obr. 1.1: Yerkes-Dodsonův zákon stresu a výkonnosti[4]

Každý člověk má své výkonové optimum položené specificky. S tím souvisí i to, že na rozdílné stresory o různé intenzitě reaguje každý jedinec rozdílnou mírou stresové zátěže. Nedá se tedy přesně určit jaká míra stresu je ještě pozitivní a kdy se už jedná o distres (viz. 1.1).

1.3.2 Kognitivně behaviorální přístup a coping

Kognitivně behaviorální přístup je proces vypořádání se se stresorem. Jedná se v podstatě o srozumitelnou myšlenku, že problém, se kterým se potýkáme není něco samostatně existujícího. Člověk pak racionálně začne vnímat stresor buď jako ohrožení nebo jako výzvu. [4]

Coping je pak definovaný jako způsoby nebo strategie zvládnání zátěží či vyrovnávání se s nimi, obranné techniky a mechanismy. Oproti tomu kognitivně behaviorální přístup zahrnuje coping i nevědomé obranné mechanismy.[9]

Jak kognitivně behaviorální přístup, tak coping vycházejí z konceptu zvládnání stresu, který navrhl R.S. Lazarus

1.3.3 Kognitivní stres a emoční stres

Někteří autoři psychický stres dále dělí na stres kognitivní a stres emoční.[9]

Kognitivní stres je stres takového druhu, který je spjat s požadavkem nějaké náročné duševní práce spojenou se zpracováním a interpretací informací (vyřešení matematické rovnice, studium apod.). Může se manifestovat ztrátou koncentrace, podrážděností a frustrací.

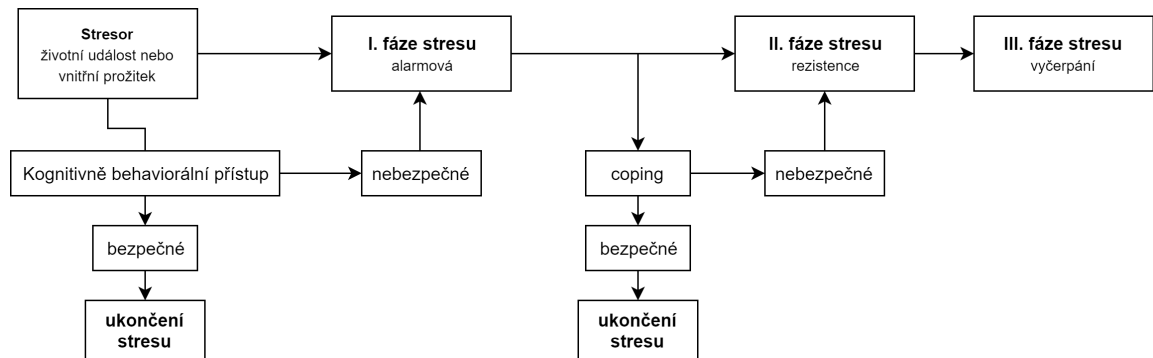
Emoční stres je pak definován jako druh duševní zátěže, který vyplývá z mimořádných či averzních situací a má silnou afektivní odezvu. Ta se manifestuje například jako strach, nebo úzkost.

1.4 Holistický pohled

Holistický pohled se snaží spojit dohromady fyziologické a psychologické pojetí stresu do jednoho celistvého rámce. Důkazem toho, že tyto tendence jsou správné, je skutečnost, že mnohé jevy spojené se stresem nejdou uspokojivě vysvětlit ani jedním z klasických pohledů na stres. [1] [4]

Propojenosti fyziologické a psychického stresu si povšiml už sám Selvye. Poté, co se mu podařilo popsat GAS na jeho laboratorních krysách, povšiml si, že podobné příznaky, jako pozoroval na stresovaných zvířatech, je možné pozorovat i u lidí, kteří byli vystaveni abnormálnímu psychickému tlaku. (Údajně jako první materiál k této domněnce mu posloužily klinické záznamy o vyčerpání válečných pilotů po

opakovaných úspěšných akcích). Stresový model se tak stal významným pracovním nástrojem psychosomatického přístupu. [4]



Obr. 1.2: Fáze stresu

Psychické trauma má ve své podstatě analogický důsledek jako trauma tělesné.[4]

Z tohoto závěru vycházel i další slavný vědec Franz Alexandr. Ten stanovil ve svých pracích prvních sedm psychosomatických onemocnění (bylo mezi nimi např. bronchiální astma, duodenální peptický vřed nebo ulocerální kolitida) [4]

Psychosomatická onemocnění jsou dobrým příkladem provázání psychického a fyziologické působení stresu.

1.4.1 Chronický únavový syndrom

Dobrym příkladem provázanosti fyziologické a psychické složky stresu je také chronický únavový syndrom, při kterém na organismus působí pravděpodobně celé spektrum různých stresorů, jak fyzického tak psychického rázu. Tělesný i duševní stav jedince pak odpovídá III. fázi GAS. Jedinec je nadměrně unavený, trpí bolest kloubů a svalů, apatie, poruchy paměti a kognitivních funkcí. [6]

2 Metody automatické detekce stresu

Tato kapitola je věnovaná různým metodám používaným k automatické detekci stresu za použití non-EEG signálů.

Za účelem zmapování tohoto tématu jsme vybrali několik odborných článků, které se věnují této problematice a udělali z nich krátké rešerše. Tyto rešerše jsou členěné dle jednotlivých studií v podkapitolách níže.

Při výběru studií a tvorbě rešerší jsme se zaměřil především na to, jaké typy signálů byly pro detekci použity, jak tyto signály byly snímány, pomocí jakých příznaků byl stres detekován a jaké úspěšnosti při detekci stresu jednotlivé metody dosahují.

2.1 Vizualizace neurologického stavu za užití shlukovací metody GMM

Birjandtalab Javada a kolektiv z Texaské university v Dalasu se ve svém článku [9] věnují výzkumu možnosti detekce stresu za pomoci analýzy záznamů získaných paralelním snímáním pěti non-EEG signálů, pomocí aplikace shlukovací metody modelu Gaussovského mixu.

2.1.1 Použitá data

Autoři článku [9] navrhli experiment, při němž snímali pět různých non-EEG signálů u 20 subjektů (14 mužů a 6 žen mezi 19 a 33 lety). Konkrétně byly snímány tyto signály:

- tepové frekvence
- saturace krve
- pohyby zápěstí ¹
- změny konduktance(EDA)²
- teplota kůže

Tepová frekvence a saturace krve byly snímány pomocí pulzního oxymetru Nonin 3150 Wireless WristOx2 se vzorkovací frekvencí 1 Hz. Pohyby zápěstí, změny EDA a teploty kůže byly snímány pomocí zařízení Affectiva Q umístěném na zápěstí subjektu. Vzorkovací frekvence tohoto zařízení je 8 Hz [9]

¹pohyby zápěstí byl snímány pomocí akcelerometru ve třech osách, x, y, z

²někdy též označované jako galvanická reakce kůže (GSR)

V nevrhnutém experimentu, při němž snímali u 20 subjektů (14 mužů a 6 žen, ve věku mezi 19 a 33 lety) výše uvedené signály. Subjekty byly vystavovány stresorů, jejichž působením se autoři snažili docílit navození stresové reakce. Tyto jednotlivé fáze byly prokládány obdobími, během nichž se snažili subjekt uvést do co nejvíce relaxovaného stavu. [9]

Samotné schéma experimentu vypadalo takto:

1. první relaxace 5 minut - sezení, poslech meditační hudby
2. fyzický stres 5 minut - běh na běžecím trenažéru
3. druhá relaxace 5 minut
4. kognitivní stres - početní příklady, Stroopův test³
5. třetí relaxace 5 minut
6. emocionální stres - sledování ukázky z hororového filmu
7. čtvrtá relaxace 5 minut

Během čtyř relaxačních fází byly subjekty požádány, aby seděly tiše a poslouchaly hudbu Binaurálu, který je běžně používána při meditacích. Jedná se o tichou a uklidňující hudbu.[9]

Data získaná během tohoto experimentu jsou volně přístupná na stránkách PhysioNetu jako databáze Non-EEG Dataset for Assessment of Neurological Status a jsou také použita v praktické části této práce. Podrobnější jsou tato data popsána v kapitole 3.1. [9]

2.1.2 Aplikace metody GMM

Při vyhodnocování získaných údajů autoři nejdříve provedli předzpracování dat a odstranili neplatné datové body. Autoři článku [9] v něm bohužel neuvádějí jaké konkrétní metody úpravy dat použili, aby tohoto předzpracování docílili. Následně autoři data standardizovali tak, že hodnotu každého prvku vydělili rozptylem signálu. Z další analýzy byly vynechány záznamy pořízené během druhé a třetí relaxace, aby došlo k vyvážení zastoupení signálů pořízených během různých stavů v datovém souboru. Poté autoři takto získaná a upravená data shlukovaly, pro každý subjekt zvlášť pomocí shlukové metody GMM (Gaussian Mixture Model). Po aplikaci této metody shlukové analýzy došlo k solidnímu oddělení různých stresových stavů. Výsledky byly posléze vizualizovány do 2D/3D prostoru. Obě vizualizace vizualizace získaných dat ,2D stejně jako 3D, mají své výhody a nevýhody. Ve 2D zobrazení je jednodušší sledovat datové body než ve 3D zobrazení. Vizualizace v 3D však umožňuje zkoumat datové body z různých úhlů a při této reprezentaci je mnohem jednodušší si

³test pozornosti, typickou úlohou tohoto testu jen čtení názvu barev napsaných jinak barevným inkoustem

představit, jak se jednotlivé hodnoty signálů liší mezi různými neurologickými stavy. [9]

2.1.3 Výsledky metody GMM

Celková přesnost měření stresu za použití této metody dosahuje 84,6%. Bližší výsledky experimentu viz. tabulky 2.1 a 2.2. [9]

Tab. 2.1: Výsledky experimentu detekce stresu za využití metody GMM-1 [9]

	RELAX	FYZICKÝ STRES	EMOČNÍ STRES	KOGNITIVNÍ STRES
RELAX	94%	0,1%	5,4%	0,3%
FYZICKÝ STRES	1,8%	90,9%	3,8%	3,5%
EMOČNÍ STRES	13,4%	5%	65,8%	15,8%
KOGNITIVNÍ STRES	1%	1,4%	10,2%	87,3%

Tab. 2.2: Výsledky experimentu detekce stresu za využití metody GMM-2 [9]

	RELAX	FYZICKÝ STRES	EMOČNÍ STRES	KOGNITIVNÍ STRES
SENZITIVITA	85,4%	93,3%	77,2%	86,4%
SPECIFICITA	93,6%	91,1%	70,2%	86,4%

2.2 Detekce stresu pomocí GSR senzorů za využití metod fit a ADWIN

Problematice metody stanovení stresu pomocí GSR senzorů, které sledují galvanickou reakci kůže, se věnují v článku [10] Jorn Bakker a kolektiv z Univerzity Techniky v Eindhoven. Záměrem této práce bylo především mapovat a predikovat stresové situace, jimž jsou vystavováni zaměstnanci na pracovištích, za účelem možnosti zavedení účinných strategií zvládnání stresu, které by minimalizovaly negativní vliv stresu

na zdraví jedince. Na základě teoretických předpokladů byla realizovaná pilotní terénní studie, která probíhala na 5 subjektech v průběhu čtyř týdnů. Její výsledky jsou shrnuty v závěru článku [10].

2.2.1 Měření GSR senzory

Měření stresu pomocí senzorů GSR je velmi náročné. Jedním z problémů je to, že dráha ANS, která zodpovídá za pocení, není aktivována pouze během stresové reakce, ale může být spuštěna i jinými faktory jako je teplota či vlhkost. [10]

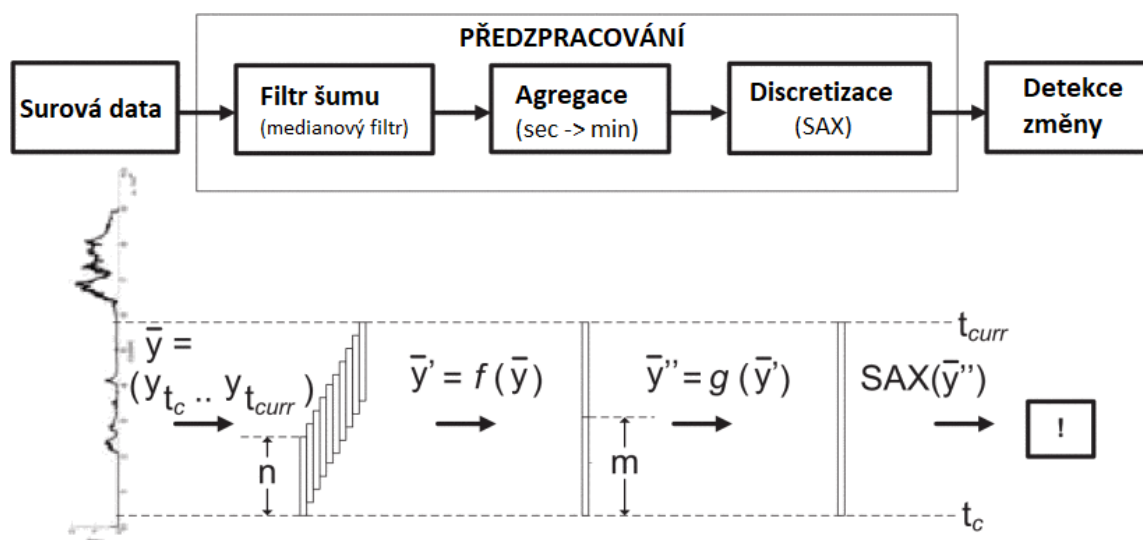
Druhým problémem je, že data získaná pomocí těchto senzorů, bývají značně zatížena šumem a nepřesnostmi v měření. Kvalita signálu GSR závisí především na kontinuitě kontaktu mezi pokožkou a zařízením. U některých subjektů může být kvalita ovlivněna také přílišnou suchostí pokožky. Častým problémem též bývá to, že se subjekt nechtěně dotýká měřících elektrod (např. opřené ruce o stůl, zvyk dotýkat se hodinek, či si uhlazovat rukávy atd.), čímž je vyvinut zvýšený tlak na elektrody, což se v záznamu projeví jako gap (mezera). [10]

2.2.2 Vyhodnocování získaných dat

Po získání surových dat ze senzorů je nutné tyto údaje nejdříve předzpracovat a až po té přejít k samotné detekci stresu. Autoři článku během vyhodnocování experimentu prováděli předzpracování signálu v několika krocích (viz. též Obr. 2.1 níže)

Jako první je na signál aplikovaný mediánový filtr. Tento filtr by měl vyfiltrovat místní šum a zachovat přitom ostré okraje píků. Poté je signál agregován a nakonec byl signál diskretizován (pomocí metody SAX).

Detekce změn pak byla prováděna dvěma metodami. První z těchto metod byla metoda zjišťování změny založené na monitorování výkonu pomocí neparametrického testu (fit). Při této metodě se předpokládá, že úroveň stresu u subjektu je mezi dvěma změnami stavu stabilní. Data jsou postupně procházena a pro každý nový bod vznikají dvě sady signálů. První je sada referenční, která ještě neobsahuje nový bod. Druhá je sada testovací, která nový bod již obsahuje. Pro každou sadu se počítá zvláště střední kvadratická chyba (MSE). Pokud mezi hodnotami těchto dvou sad existuje významný rozdíl, považuje se to za bod změny stavu. [10] Druhou metodou pak byla detekce změn na základě nezpracovaných dat pomocí adaptivního okna (ADWIN). Metoda ADWIN funguje následovně: při posloupnosti signálů se kontroluje, zda existují statisticky významné rozdíly mezi průměry každého možného rozdělení sekvence. Pokud je zjištěn statisticky významný rozdíl, nejstarší část dat nejvíce nazpět od detekovaného bodu se vynechá a postup dělení se opakuje, dokud neexistují významné rozdíly v případném rozdělení sekvence. [10]



Obr. 2.1: Postup při zpracování signálu z GSR senzorů [10]

Při vyhodnocování úspěšnosti detekce stresu byly využity záznamy, které si každý z účastníků pokusu během studie vedl a do kterých zaznamenával údaje o svých denních aktivitách (schůzky, briefinky, zasedání atd.) spolu s informacemi o tom, jak byla která situace pro něj subjektivně stresující.[10]

2.2.3 Dosažené výsledky

Senzitivita metody fit byla v průměru 66%, zatím co u metody ADWIN pouhých 8%. Autoři článku předpokládají, že existují dva důvody, proč je skutečná pozitivní hodnota ADWIN tak nízká. První je ten, že tato metoda nezjistí malé vrcholy. Druhý důvod je, že změnu nezaznamená v případech, kdy signál pomalu stoupá, nebo klesá.[10]

2.3 Porovnání úspěšnosti detekce stresu pomocí různých klasifikátorů využívajících strojového učení

Tým vědců z UPIITA v Mexico City provedl pokus, při němž srovnával úspěšnost několika klasifikátorů stresu využívající různé metody strojového učení. Své výsledky zveřejnil v článku [12]

2.3.1 Použitá data

Pro pokus vědci použili sadu dat z databáze Physionet, která obsahovala údaje od 16 subjektů, pořízených snímáním signálů EKG, EMG, respirace, HRV a GSR

měřené jednak na dlani levé ruky a pak na chodidle levé nohy, během řízení osobního automobilu v různých dopravních situacích a trasách.

Z této sady bylo pro pokus vybráno pouze 11 subjektů, protože u zbylých pěti záznamů chyběly některé potřebné informace. Všechny signály obsažené v databázi, měli vzorkovací frekvenci 15,5 Hz [12]

2.3.2 Úprava dat a klasifikační modely

Při analýze signálů HRV a respirace bylo zjištěno, že tyto záznamy jsou zatíženy velkým množstvím šumu. Pro jeho odstranění byla na signály aplikovaná víceúrovňová diskrétní vlnková transformace.[12]

Po odstranění šumu byly ze signálů extrahovány dva nelineární prvky, konkrétně entropie a korelační rozměr, a tři lineární prvky energie, střední a směrodatná odchylka. Tyto hodnoty byly vypočítány z 5 minutových, nepřekrývajících se segmentů dat a byly využity při klasifikaci.[12]

Pro strojové učení byly nakonec použity pouze signály HRV, respirace a oba signály z GSR.

Z těchto signálů byly poté vybrány úseky, které jsou dále využívány jako učební množina (80% z těchto dat) a testovací množina (20% z těchto dat) pro vytvoření klasifikátorů, využívajících různé metody strojového učení. Klasifikátory byly testovány 1000 krát a jejich přesnost byla zprůměrována, aby se zabránilo přeučení metody. [12]

Konkrétní použité metody:

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

[12]

2.3.3 Výsledky studie

Z výsledků této studie (viz tabulka 2.3) plyne, že žádná z metod nepřekročila hranici přesnosti 80%. Jako nejsilnější z metod v tomto pokusu vyšla metoda logické regrese

Tab. 2.3: Přesnost klasifikátorů dle použitých metody strojového učení [12]

METODA	PŘESNOST
K-NN	64,28%
SVM (lineární jádro)	68,66%
SVM (gaussovské jádro)	67,48%
Naïve Bayes	67,57%
Náhodný les	72,15%
logická regrese	77,27%

(logistic regression) s hodnotou přesnosti 77,27%. Naopak nejhorších výsledků dosáhla metoda za použití modelu K-NN. Ta to metoda dosáhla pouze 64,28% přesnosti. [12]

2.4 Detekce stresu za použití State-Space modelů

Autoři článku [14] ve své publikaci představují svůj experiment, ve kterém se zabývají možností detekce stresu ze záznamů změny elektrické vodivosti kůže, měřené přenosnými zařízeními. Během vyhodnocování a detekce stresových stavů přitom využívají State-Space modelů.

Signál vodivosti pokožky je složen z tonické a fázové aktivity. Pomalu se měnící základní signál je tonická část EDA signálu, také nazývaná, jako základní úroveň vodivosti kůže (SCL). Rychleji se měnící část (fázová aktivita) souvisí s vnějšími podněty nebo nespecifickou aktivitou organismu. Tato fázová část signálu lze modelovat jako konvoluce mezi řídicím impulsem a funkcí bi-exponenciální impulzní odezvy (IRF). Individuální odezvy vodivosti kůže (SCRs) mohou být izolovány konvolucí specifického píku s IRF. Výskyt SCRs bývá doprovázený vzrušením nebo stresem měřeného subjektu. [14]

2.4.1 Použité datové soubory

Autoři pracovali s dvěma skupinami signálů z dvou různých zdrojů, pořízenými různými autory a naměřené pomocí různých typů zařízení.

Prvním zdrojem byla databáze Non-EEG Dataset for Assessment of Neurological Status, pořízená Birjandtalab Javad, Cogan Diana, Pouyan Baran Maziyar a Nourani Mehrdad z Texaské university v Dalasu, prezentovaná v článku [9] (viz. kapitola Vizualizace neurologického stavu za užití shlukovací metody GMM). Dle autorů článku [14] mohou pohybové artefakty a změny v faktoru zesílení mohou znehodnotit signály pořízené snímáním EDA. Z těchto důvodů bylo vyřazeno 14

subjektů z původních 20 v databázi. Pro další analýzu byly použity signály pořízené od subjektů 1,5,8,9,12 a 16. Autoři se u zbývajících signálů zaměřili pouze na psychický stres a úseky, kde byly dle anotace subjekty vystaveny stresorům způsobující fyzický stres, byly ze signálu odstraněny. Aby byl u signálů minimalizován vliv šumu, byla použita v programovacím prostředí MATLAB funkce findpeaks, pomocí které byli vybrány místa obsahující dominantní hroty, omezené na minimální amplitudu a vzdálenost dvou po sobě jdoucích hrotů. [9] [14]

Druhým zdrojem dat, ze kterého autoři článku čerpali, je databáze Stress Recognition in Automobile Drivers Dataset. Tato databáze obsahuje EDA záznamy 17 řidičů osobního automobilu, které byli pořízené během řízení automobilu po dálnici, po zpoplatněné silnici a během jízdy po městě. Záznam byl doplněn 15 minutami, kdy řidič seděl v relaxovaném stavu v zaparkovaném autě se zavřenýma očima. Tato anotace není veřejně dostupná a její využití je zpoplatněno. Proto autoři pracují pouze s jedním záznamem. Důvodem zařazení tohoto signálu je především to, že na rozdíl od záznamů z databáze Non-EEG Dataset for Assessment of Neurological Status, které byly kompletně pořízeny v laboratorních podmínkách, obsahuje tato databáze záznamy stresových reakcí nasnímané během reálných situací. Tato databáze byla využita i autory v článku[12] (viz kapitola Porovnání úspěšnosti detekce stresu pomocí různých klasifikátorů využívajících strojového učení). [12] [14]

2.4.2 Popis metody

Zkoumané signály byly rozděleny na úseky o délce 1 sekundy. Ke každému úseku byla přiřazena hodnota 1, pokud se v daném úseku nachází hrot, nebo 0, pokud se v úseku hrot nenachází. Pomocí State-Space modelu sledujeme úroveň kognitivního stresu napříč celým signálem. State-Space model se skládá ze stavové rovnice (state equation), která popisuje úroveň latentního napětí, a pozorovací rovnice (observation equation), která popisuje jak výskyt hrotů souvisí se stavem subjektu. Autoři předpokládají, že Gaussova stavová rovnice popisuje úroveň latentního napětí. Jako pozorovací rovnice autoři použili Bernoulliho pravděpodobnostní model.[14]

Proměnná K je definovaná jako celkový počet úseků v signálu a je indexovaná jako $k = 1, 2, \dots, K$. Pro pozorovací rovnici je použita proměnná s_k k označení detekovanému signálu v úseku k ($s = 1$ představuje přítomnost hrotu v úseku, $s_k = 0$ jeho absenci). q_k definujeme jako pravděpodobnost, že se hrot objeví v úseku k . Pro stavovou rovnici je definovaná proměnná z_k která udává hladinu úroveň vodivosti kůže. Vzhledem k hodnotě stavového procesu z_k definuje model pravděpodobnosti pozorování. Model pravděpodobnosti pozorování může být popsán pomocí Bernoulliho distribuce takto: [14]

$$P(s_k|q_k) = q_k^{s_k} (1 - q_k)^{1-s_k} \quad (2.1)$$

kde q_k je definováno jako:

$$q_k = \frac{1}{1 + e^{-(\alpha+z_k)}} \quad (2.2)$$

Parametr α souvisí s pravděpodobností, že se hrot vyskytuje v úseku na začátku experimentu. Je nastaveno, že $z_0 = 0$ a pomocí rovnice 2.2 je vypočítané q_0 . Vývoj stresového stavu definujeme rovnicí: [14]

$$z_k = z_{k-1} + \epsilon_k \quad (2.3)$$

kde σ je definovaná jako:

$$\epsilon_k \sim N(0, \sigma^2) \quad (2.4)$$

Autoři dále pozorovali hodnotu $S_{1:K} = s_1, s_2, \dots, s_K$, která indikuje přítomnost či absenci hrotů. Jejich cílem bylo odhadnout hodnoty $Z_{1:K} = (z_0, z_1, \dots, z_K)$ a σ_ϵ^2 pro odhad hodnoty q_k pro každé k . Aby docílili co nejlepšího odhadu těchto dvou hodnot, aplikovali autoři článek EM-algoritmus. Tento algoritmus se skládá z dvou, kroků, tzv. E-kroku a M-kroku. V E-kroku je aplikován algoritmus rekurzivní nelineární filtrace bodového procesu (point process recursive nonlinear filter algorithm). Tento algoritmus určuje hodnotu $z_{k|k}$ v úseku k , kde je při výpočtu skutečná hodnota parametru σ_ϵ^2 nahrazena jejím odhadem. Po té v je v E-kroku aplikován vyhlazovací filtr s pevným oknem. V M-kroku se maximalizuje odhad hodnoty parametru σ_ϵ^2 a algoritmus se vrátí k E-kroku. Algoritmus iteruje mezi E-krokem a M -krokem až do konvergence výsledku. [14]


2.4.3 Dosažené výsledky

Výsledky dosažené otestováním metody na výše zmíněných datech jsou zobrazené na obrázcích 2.3 a 2.2.

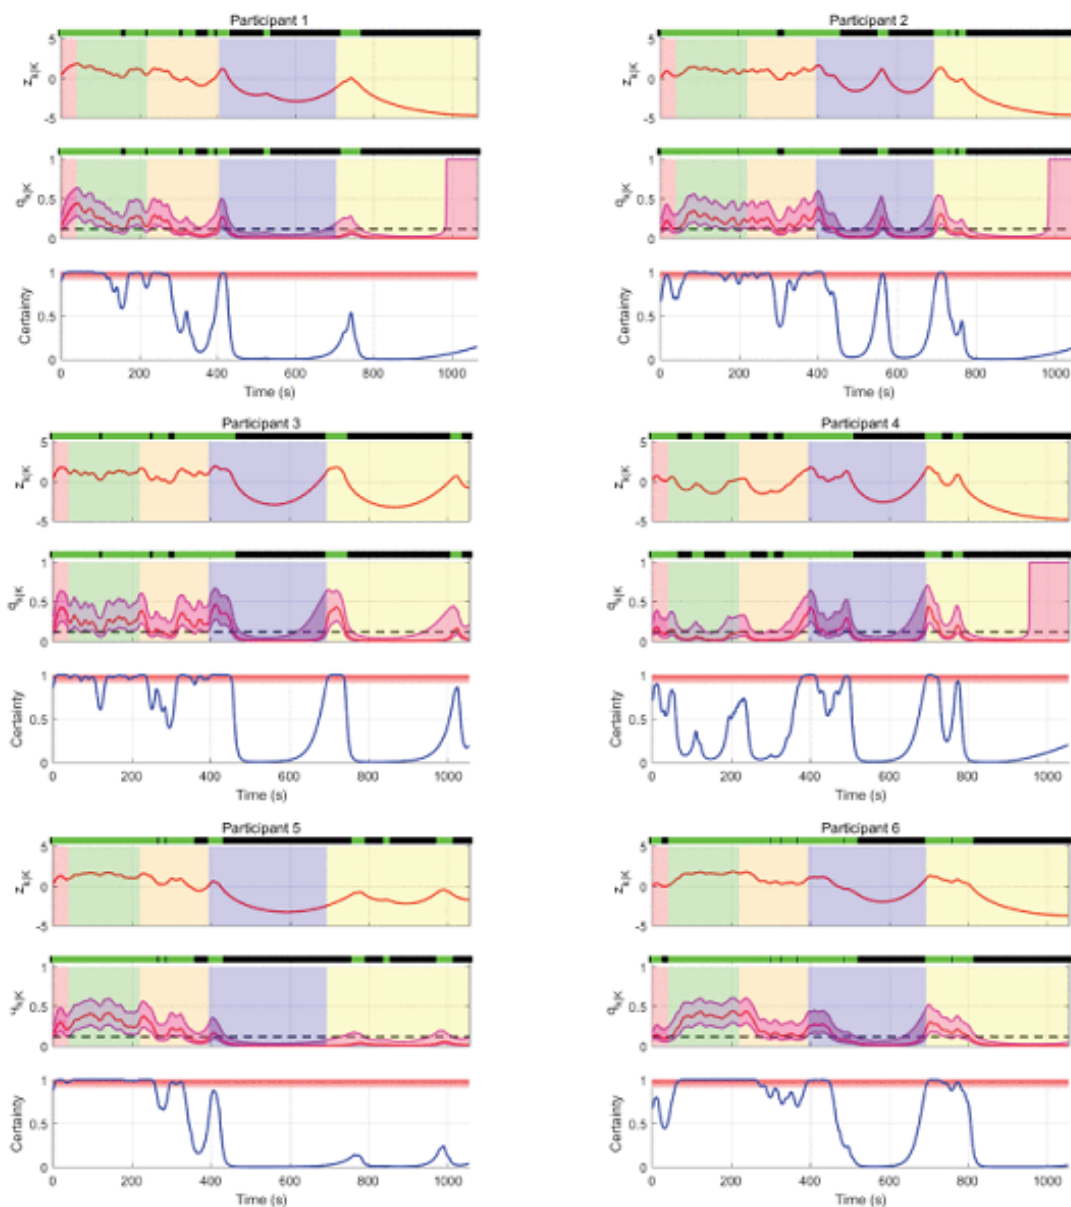
Při testování metody na šesti vybraných subjektech z databáze Non-EEG Dataset for Assessment of Neurological Status (viz. 2.3) je patrné, že u všech subjektů metoda zaznamenala zvýšenou úroveň stresu během vystavení subjektu stresorům navozující kognitivní stres (zelená oblast) i během krátkého emočního stresu, který mu předcházela (růžová oblast). Naproti tomu při vystavení subjektu emočnímu stresu během sledování hororového snímku (fialová oblast), bylo zaznamenáno zvýšení stresu pouze na začátku a na konci ukázky. To může svědčit o nevhodnosti této metody při detekci psychického emočního stresu, nebo o špatném zvolení

stresoru při navozování stresové reakce během experimentu. Zbývající žluté oblasti grafu představují období, kdy měl být subjekt uveden do relaxovaného stavu.

Na obrázku 2.2 jsou zobrazené výsledky použití metody State-Space modelu na subjektu z databáze Stress Recognition in Automobile Drivers Dataset. Zelená pole představují dobu odpočinku, fialová jízdu po městě, růžová jízdu po zpoplatněné silnici a žlutá jízdu po dálnici. Z obrázku je patrné, že úroveň stresu během jízdy po městě a po zpoplatněných silnicích se prakticky neliší. Při jízdě po dálnici je dle předpokladů, úroveň stresu o něco nižší než při jízdě po městě a zpoplatněných silnicích. Bez dalších anotací dopravních situací nebo jiných záznamů je obtížné korelovat kolísání úrovně stresu v rámci každého typu vozovky s čímkoli konkrétnějším. Zajímavá je ovšem zvýšená úroveň stresu během druhého odpočinku. Dle doprovodných informací k záznamu je však tato skutečnost způsobená tím, že během této fáze subjekt potřeboval odejít na toaletu, což se zřejmě projevilo stresovou odpovědí.



Obr. 2.2: Výsledky detekce stresu pomocí State-Space modelu na subjektu z databáze Stress Recognition in Automobile Drivers Dataset [14]



Obr. 2.3: Výsledky detekce stresu pomocí State-Space modelu na subjektech z databáze Non-EEG Dataset for Assessment of Neurological Status [14]

2.5 Detekce stresu s využitím fuzzy logiky

V článku [15] představují jeho autoři Alberto de Santos Sierra, Carmen Sanchez Avila, Javier Guerra Casanova a Gonzalo Bailador del Pozo, kteří působí na Polytechnické univerzitě v Madridu, systém detekce psychického stresu založený na využití fuzzy logiky. Pro detekci stresu při tom využívají záznamy tepové frekvence (HR) a GSR.

2.5.1 Získání databáze

Při vytváření systému implementovali jeho autoři svoji vlastní sadu dat, kterou naměřili během experimentu, který si sami namodelovali. [15]

Experiment byl proveden v laboratoři lidské psychologie na fakultě psychologie, Univerzitě Complutense v Madridu (UCM). Měření bylo prováděno v místnosti vybavené tepelnou, akustickou a elektromagnetickou izolací (prostory se nacházely uvnitř Faradayovi klece). [15]

Experimentu se zúčastnilo 80 žen, převážně studentek Fakulty psychologie a Fakulty sociálních prací UCM. Věk účastnic se pohyboval mezi 19 a 32 lety (průměrný věk účastníka byl 21,8 let). Absence mužských subjektů je zřejmě způsobena tím, že nábor dobrovolníků do studie probíhal na dvou výše zmíněných fakultách, které na této UCM navštěvují převážně ženy. [15]

Data byla naměřená na přístroji I-330-C2 PHYSIOLAB (J a J Engineering), který je schopný zároveň zaznamenat a uložit vedle využitých signálů HR a GSR i záznam EKG, EMG a rychlost dýchání měřeného subjektu. Senzory přístroje byly připevněny k na prstu ruky, zápěstí a kotníku. Vzorkovací frekvence signálu HR a GSR je 1 Hz. [15]

Pro navození stresové reakce autoři experimentu zvolili metodu kdy kombinovali záměrnou hyperventilaci a řízený rozhovor, při kterém byly podávány otázky, které by měli mít anxiogenní vliv na subjekt. [15]

Účastníci experimentu byli rozděleni do dvou skupin. Ve skupině jedna vypadalo schéma experimentu tak, že jako první, proběhla klidová fáze (označovaná, jako BL1), kdy se měl subjekt nacházet v relaxovaném stavu, dále probíhala tzv. stimulační úloha, během které byl subjekt instruován k hyperventilaci (označovaná autory jako HV), poté následoval řízený rozhovor (označován jako TP). Po této fázi následuje fáze poststresu, kdy subjekt přechází ze stresového stavu do fáze relaxace (označená autory jako BL2). V druhé skupině došlo k výměnně fáze HV a TP. Schéma experimentu tedy pro druhou skupinu vypadalo takto: BL1, TP, HV a BL2. [15]

2.5.2 Systém detekce stresu

Při tvorbě systému detekce stresu, autoři postupovali ve dvou krocích. V první řadě je nutná extrakce šablony tak, aby systém mohl vytvořit profil subjektu. Druhým krokem je vytvoření vlastního detekčního systému. [15]

Matematicky jsou signály HR a GSR považovány za stochastické signály. Autoři zavádějí množinu H , představující množinu hodnot, kterých může signál HR nabývat a množinu G , která představují množinu hodnot, kterých může nabývat signál GSR. Každá fáze experimentu obsahuje dvě množiny. Množinu h , kdy $h \in H$. Každá šablona

y tedy obsahuje čtyři množin signálu (dva z každé fáze experimentu), viz. rovnice 2.5.

$$y = [(h1, g1), (h2, g2), (h3, g3), (h4, g4)] \in HxG \quad (2.5)$$

Poté co je získaná hodnota y je pro každý pár vypočítaná průměrná hodnota ζh , ζg a směrodatné odchylky σh a σg . Tím získáme konečnou šablonu stresu T , kdy $T = (\zeta hi, \zeta gi, \sigma hi, \sigma gi)$, $i = 1, 2, 3, 4$. Šablona je dále použita v samotných detekčních systémech.

Autoři představují dvě možné implementace systému. První je ruční implementace, kde jsou parametry pevně zadané a absentují zde jakékoliv postupy učení, a druhým je pak implementace automatická, kde si systém přizpůsobuje své interní parametry. Hlavní rozdíly mezi implementacemi spočívají v fuzzy algoritmu rozhodování.

Ruční implementace je založena na fuzzy algoritmu Mamdani. Tento systém používá šablonu T k popisu předchozích skupin funkcí a implementací výstupu v intervalu $[0, 1]$ s trojúhelníkovými distribucemi.[15][16]

Automatická implementace využívá adaptivní neuro-fuzzy inferenčním systému (ANFIS). Jedná se o hybridní adaptivní síť, která je založena na fuzzy interferenčním systému typu Takagi-Sugeno, který je implementován společně s umělými neuronovými sítěmi. [15] [17]

Přestože automatická implementace dosahuje vyšší úspěšnosti při diferenciaci stresu od relaxačního stavu, je tato metoda oproti ruční implementaci daleko víc časově náročná [15]

2.5.3 Výsledky

Autoři článku uvádějí, že výskyt stresu vyskytující se v časovém úseku o délce 10 sekund je systém schopen detekovat s přesností 99,5 %. Snížíme-li akviziční dobu na 3-5 sekund, dosahuje tato metoda stále solidní 90% přesnosti.[15]

Slabinou tohoto řešení detekce stresu, je ovšem to, že systém je vždy nastavován na individuální údaje od jednoho subjektu. Nelze jej tedy všeobecně aplikovat bez toho, aby jsme měli nejdříve od měřeného jedince předem naměřená a anotovaná data.[15]

Autoři textu také připouští, že výsledky dosažené jejich metodou, za použití této databáze, nemusí být zcela zobecnitelné pro celou populaci vzhledem k tomu, že data se kterými pracují pochází pouze od žen v poměrně úzkém věkovém rozmezí. [15]

3 Výsledky studentské práce

Součástí této práce je návrh algoritmu detekující a klasifikující stres z non-EEG signálů. Návrh tohoto programu je realizován v programovém prostředí MATLAB. Algoritmus využívá metody fuzzy shlukové analýzy c-means a metod strojového učení SVM a logické regres.

Výstupem algoritmu je sada modelů, které lze použít k detekci přítomnosti či absence stresu, výskytu fyzického stresu, psychického stresu, psychického-kognitivního stresu a psychického-emočního stresu.

Sada modelů, stejně jako algoritmus a další data použitá k jejich vytvoření jsou k dispozici na příloženém nosiči CD.

3.1 Vstupní data a jejich popis

Při vývoji tohoto programu byla použita data z databáze A Non-EEG Dataset for Assessment of Neurological Status, která je volně k dispozici na webovém portálu databanky fyziologických signálů PhysioNet. Tato konkrétní databáze byla pořízena v roce 2016 v Laboratoři kvality života na univerzitě v Texasu v Dallasu (Quality of Life Laboratory at University of Texas at Dallas). Jejimi autory jsou Birjandtalab Javad, Cogan Diana, Pouyan Baran Maziyar a Nourani Mehrdad (viz kapitola 2.1). [9] [13]

Tato databáze obsahuje záznamy z 5 non-EEG signálů, od 20 různých subjektů, pořízené dvěma mobilními zařízeními.

Snímané non-EEG signály byly: tepová frekvence, saturace krve, pohyby zápěstí (akcelerometr), změny konduktance kůže, teplota kůže.

Tepová frekvence a saturace krve byly snímány pomocí pulzního oxymetru Nonin 3150 Wireless WristOx2 se vzorkovací frekvencí 1 Hz. Pohyby zápěstí (záznam tři signálů, byl snímán pohyb v osách x, y, z), změny EDA a teploty kůže byly snímány pomocí zařízení Affectiva Q umístěném na zápěstí subjektu se vzorkovací frekvence 8Hz. [9]

Signály obsažené v databázi byly pořízené od 20 studentů-dobrovolníků (14 mužů a 6 žen, ve věku mezi 19 a 33 lety). Podrobné informace o jednotlivých subjektech jsou obsaženy v tabulce 3.1. [9]

Všechny subjekty byly podrobeni experimentu, během něhož byly subjekty exponovány fyzickým a psychickým stresorům. Mezi vystavováním subjektů jednotlivým stresorům byla vždy vložena fáze, kdy byl subjekt uveden do relaxační fáze.

Tab. 3.1: Tabulka s informacemi o jednotlivých subjektech [9]


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

Na začátku experimentu byl subjekt vždy uveden na 5 minut do relaxovaného stavu. Poté byl vystaven na 5 minut fyzickému stresoru, který měl podobu chůze a posléze běhu na běžeckém trenažéru. Následovala další 5 minutová fáze, kdy byl subjekt uveden do relaxovaného stavu. Pak následoval krátký časový úsek, kdy autoři experimentu subjektu vysvětlili, že bude podroben testům, zkoumající jeho kognitivní schopnosti a jak tyto testy budou probíhat. Autoři tento krátký časový úsek označili jako úsek, kdy byl subjekt vystaven krátkému emočnímu stresu. Následovala expozice kognitivními stresory, které měly podobu dvou testů. Při prvním byl subjekt nucen tři minuty z hlavy odečítat 7 od čísla 2485. Poté následoval Stroopův test, během něhož musel subjekt číst názvy barev napsané jinak barevným inkoustem. Kdykoliv subjekt během těchto dvou kognitivních testů udělal chybu, ozval se zvuk bzučáku. Následovala další pětiminutová relaxační fáze. Poté byl subjekt vystaven emočnímu stresoru, kterým byla 5 minutová ukázka z hororového filmu *The Horde*. Experiment je zakončený opět 5 minuty relaxace. K navození relaxovaného

stavu autoři používali meditační hudbu Binaurálu.[9]

Ke každému subjektu je na stránkách PhysioNetu poskytnuta i anotace záznamů v souboru formátu .txt, kde je vedle údajů o subjektu popsáno i to, v jaký časový okamžik byl subjekt vystaven různým typům stresorům a kdy byl naopak uveden do stavu relaxace.

Signály se v databázi nacházejí již v předzpracovaném stavu a byly z nich odstraněny neplatné datové body (bližší údaje o tom, jaké metody byly použity k předzpracování a úpravě signálu nejsou v článku [9] obsaženy). Jakou podobu měl surový signál než byl předzpracován je patrné na obrázku 3.1



Obr. 3.1: Surový signál před předzpracováním, subjekt 1 [9]

3.2 Popis algoritmu

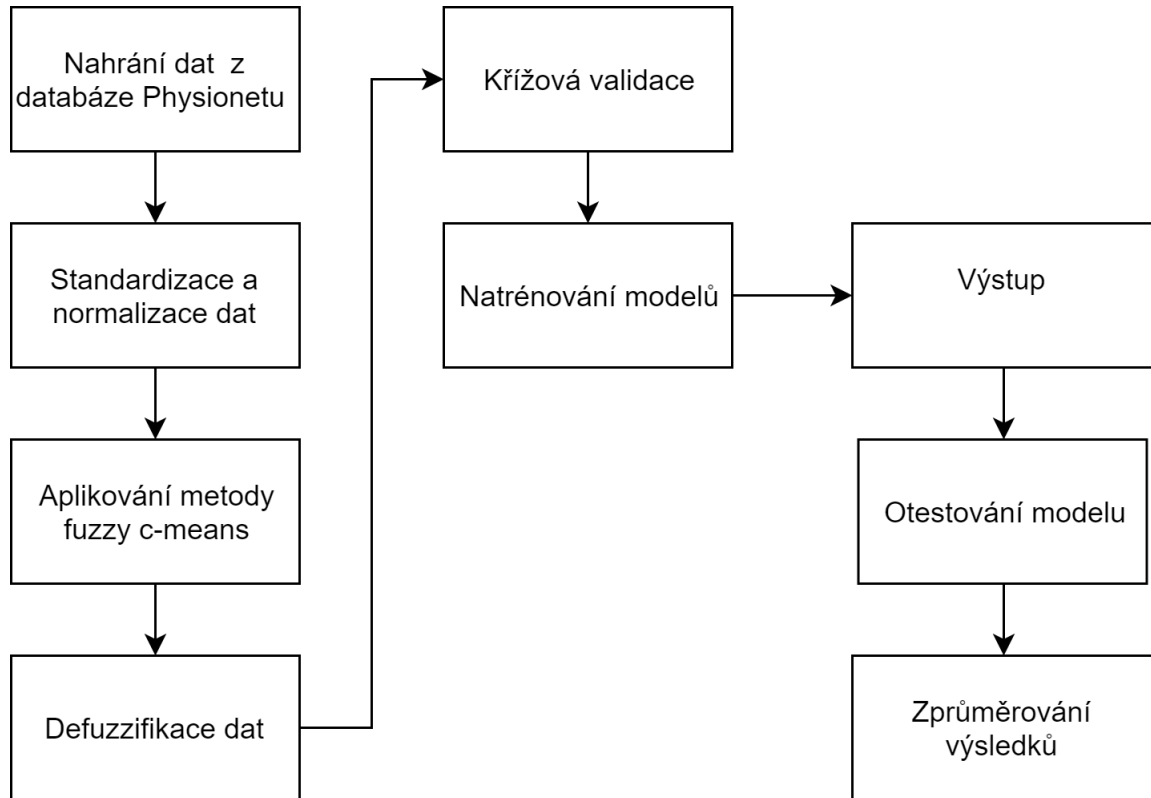
Celý algoritmus je realizovaný v programovacím prostředí MATLAB. Konkrétně byly použity verze programu MATLAB R2017a a MATLAB R2018b. Algoritmus se skládá z tří hlavních částí, samostatných skriptů.

V první části dochází k načtení signálu z databanky Physionetu. Dále pak dochází k normalizaci (popřípadě standardizaci). Normalizovaná/standardizovaná data jsou podrobena shlukové analýze c-means. Data jsou posléze defuzzifikovaná a upravena tak, že výstupem této části jsou matice s daty vhodnými pro trénování modelů pomocí metod strojového učení.

V druhé části dochází postupnému dělení signálu na trénovací množinu (která obsahuje 80% původního signálu) a testovací množinu (která obsahuje 20% původního signálu). V některých případech je trénovací matice ještě dále upravována (zmnožení některých úseků, vymazání jiných repetitivních fází) pro lepší natrénování modelu. Je aplikována pětinasobná křížová validace, tudíž ke každému případu detekce dostaneme pět natrénovaných modelů.

Třetí část slouží pro testování modelu. Vstupem je natrénovaný model a testovací množina, výstupem je pak hodnota specificity, senzitivity a přesnost testovaného modelu.

Průběh algoritmu je patrný z blokového schéma na obrázku 3.2



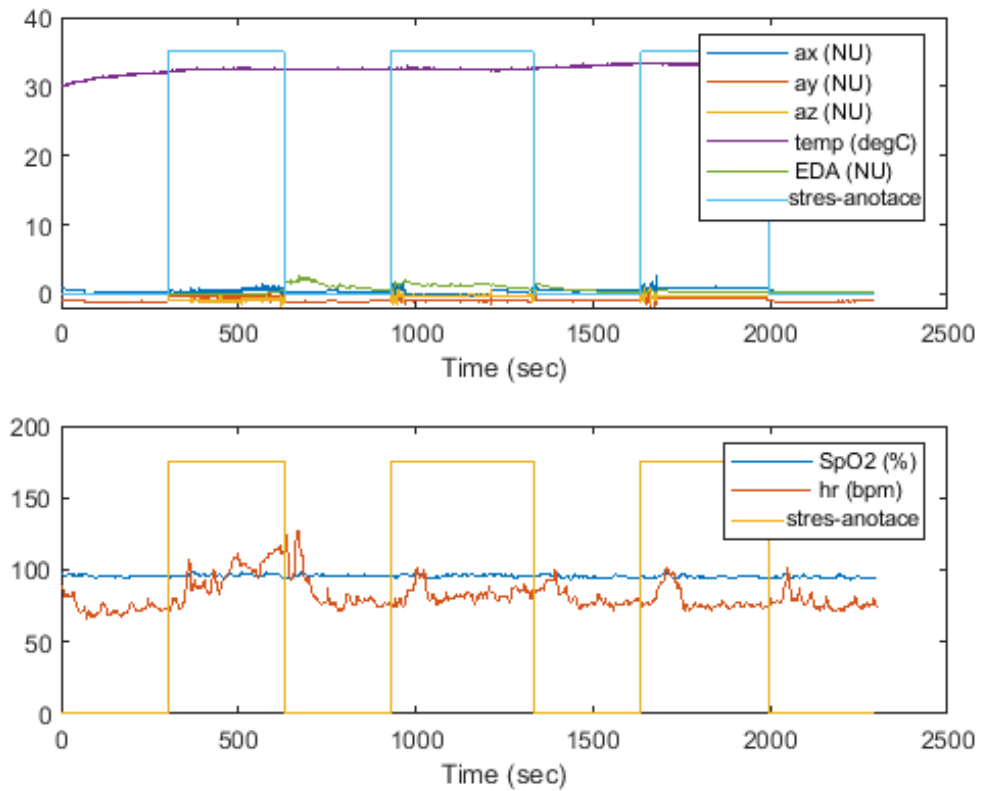
Obr. 3.2: Blokové schéma algoritmu

3.2.1 Nahrání a úprava dat

Pro nahrání dat z PhysioNetu je nejprve potřeba do prostředí MATLAB přidat softwarový balík knihoven a aplikací pro zpracování, automatickou analýzu a vytváření nových záznamů signálů WFDB ¹(WaveForm DataBase), který je volně ke stažení na stránkách PhysioNetu.

Pomocí funkce plotATM, obsažené v knihovně WFDB je možné si zobrazit non-EEG signály v závislosti na čase, což je vhodné pro lepší představu o rozsahu signálů viz. Obr. 3.3.

¹Konkrétně jsem při realizaci algoritmu použil verzi 0.10.0



Obr. 3.3: Vizualizace načtených dat subjektu 1 pomocí příkazu plotATM, doplněné o místa působení stresorů, získané z anotace. Na horním grafu se nachází signál z akcelerometru, EDA a teploty pokožky. Na dolním grafu se nachází signály tepové frekvence a saturace krve

Po nahrání dat byla provedena standardizace dat získaných z akcelerometru dle vzorce:

$$z_i = \frac{x_i - \mu_i}{\sigma_i}$$

kde z = Z-skóre, μ = střední hodnotě, σ = směrodatná odchylka, i je index příznaku

U ostatních dat, tj. u dat ze saturace krve, tepové frekvence, EDA a teploty pokožky, jsem provedl normalizaci dat dle vzorce:

$$z_{ij} = \frac{x_i - \min_j(x_{ij})}{\max_j(x_{ij} - \min_j(x_{ij}))}$$

kde j je index objektu, i je index příznaku

Tím dochází k homogenizaci dat.

3.2.2 Metoda c-means a tvorba matic pro strojové učení

Po standardizaci a normalizaci dat je možné přistoupit k provedení fuzzy shlukování na základě shlukové metody c-means. Shlukování je prováděno pro každý non-EEG signál zvlášť, bez závislosti na ostatních signálech. Ve výsledku to tedy znamená, že až na údaje z akcelerometru (tři signály z jednotlivých os akcelerometru) se jedná o jednorozměrné signály.

Umístění výchozích centroidů je zvoleno napevno na základě empirických zkušeností, získaných odzkoušením několika různých variant postavení výchozích centroidů, z nichž použitá varianta byla vybrána na základě dobrého rozdělení prvků a nízkého počtu iterací potřebných pro dosažení finálních shluků. Parametr q , který má řídit neostrost hranic výsledných shluků, je nastaven na hodnotu 2. Velikost minimálního rozdílu mezi dvěma iteracemi ϵ pak na hodnotu 10^{-5} . Byli odzkoušeny i jiné varianty hodnoty ϵ , ale všechny menší hodnoty než 10^{-5} aproximovaly vždy ke stejnému výsledku. Počet výchozích centroidů je stanoven na tři tak, aby od sebe rozdělené shluky reprezentovali příslušnost dat k stavu fyzického stresu, psychického stresu či relaxace.

Rozdělená fuzzy data prochází následně defuzzifikací. Výsledkem pak je pro každý signál matice binárních dat o třech řádcích a počtu sloupců odpovídající délce původního signálu. Každý řádek v této matici symbolizuje jeden shluk (stav fyzického stresu, stav psychického stresu, relaxovaný stav), jednička pak značí příslušnost časového bodu ke shluku a nula značí to, že k němu nepřísluší.

Z těchto dat jsou pak sestaveny matice pro strojové učení modelů a jejich testování. Těchto matic je celkem pět (matice pro model detekce přítomnosti či absence stresu, matice pro model detekce fyzického stresu, matice pro model detekce psychický stresu, matice pro model detekce kognitivního psychického stresu a matice pro model detekce emočního psychického stresu). Všechny tyto matice obsahují šest sloupců a počet řádků odpovídající sumě délek všech signálů nahraných z databáze. Prvních pět sloupců obsahuje defuzzifikovaná data získaná shlukováním jednotlivých signálů. Rozdílná vzorkovací frekvence signálů je vyřešena interpolací vzorků signálu tepové frekvence a saturace krve. Šestý sloupec matice obsahuje binární údaj získaný z anotace o tom, jestli byl subjekt v daném časovém bodu vystaven (příslušnému) stresoru či nikoliv. Předpokládáme, že pokud byl subjekt vystaven stresoru, nacházel se ve stresovém stavu.

3.2.3 Strojové učení modelů a jejich testování

Matice, určené pro strojové učení modelů a jejich testování jsem exportoval do dalšího skriptu, kde jsem je vždy rozdělil na pět částí. Čtyři části (80% původní matice)

posloužilo k učení modelu zbylá pětina (20% původní matice) posléze posloužila k testování modelu.

Pro učení modelů posloužila knihovna Classification Learner, která je již implementovaná v MATLABU. Na základě heuristických pokusů s menšími vzorky dat a informací z odborných článků (viz. kapitola 2) bylo rozhodnuto zvolit pro učení modelu metodu podpůrných vektorů (SVM) s hrubým gaussovským jádrem a jako druhá metoda byla zvolena metoda logistické regrese.

Vzhledem k tomu, že metody strojového učení se během trénování orientovaly na dosažení co nejvyšší přesnosti, docházelo u všech modelů (s výjimkou modelu pro detekci přítomnosti či absence stresu) vzhledem k nízkému poměru úseků, kdy by subjekt vystaven stresoru a úsekům kdy stresoru vystaven nebyl, k zvýšení specifity na úkor senzitivity. Na základě toho zjištění, byli trénovací matice (opět s výjimkou matic určených pro trénování modelu pro detekce přítomnosti či absence stresu) upraveny. Došlo u nich k repetičím částí úseku obsahující záznam vystavení subjektu příslušnému stresoru a jiné úseky, především obsahující záznamy z relaxované části, byli z matice odstraněny.

Po naučení modelů, byly tyto modely otestovány příslušnými testovacími maticemi. Z kontingenčních tabulek byla dopočítána jejich senzitivita, specifita a přesnost (viz 3.3).

3.3 Dosažené výsledky


V této části práce jsou k dispozici výsledky klasifikační úspěšnosti navrženého algoritmu a jeho jednotlivých částí (jednotlivých modelů). Výsledky jsou seřazeny do tabulek dle jejich příslušnosti k jednotlivým modelům.

3.3.1 Detekce přítomnosti či absence stresu

Modely detekující stres, ať již ho vyvolal jakýkoliv stresor, dosahují průměrné přesnosti pro SVM model 61,01% a pro LR model 67,92% (viz tabulka 3.2). Celkově se pro tento typ detekce jeví jako výhodnější použít LR modelů, neboť dosahuje nejen o trochu lepší přesnosti než SVM model, ale dosahuje i lepší průměrné senzitivity (což je u detekce stresu přednější parametr než senzitivita) a ani jeho rozptyl jednotlivých hodnot není tak velký jako u SVM modelu (viz. obrázek 3.4).

Tab. 3.2: Tabulka výsledků modelu detekce přítomnosti či absence stresu, SVM - metoda podpůrných vektorů, LR - metoda logistické regrese

ID MODELU	SPECIFICITA		SENZITIVITA		PŘESNOST	
	SVM	LR	SVM	LR	SVM	LR
1	53,59%	75,75%	77,46%	62,88%	64,88%	67,40%
2	81,92%	81,92%	68,19%	68,19%	75,22%	75,22%
3	35,90%	52,35%	53,05%	70,51%	42,99%	54,90%
4	82,84%	89,27%	80,65%	55,27%	81,83%	73,54%
5	39,36%	74,8%	40,92%	62,39%	40,15%	68,58%
PRŮMĚR	58,58%	74,81%	64,05%	63,84%	61,01%	67,92%
ROZPTYL	0,1043	0,0382	0,0282	0,0035	0,1410	0,02551
ODCHYLKA	0,3229	0,1955	0,1679	0,0591	0,3755	0,1597




Obr. 3.4: Boxplot jednotlivých údajů pro modely detekující přítomnost či absenci stresu

3.3.2 Detekce přítomnosti fyzického stresu

Detekce fyzického stresu z non-EEG signálů je všeobecně jednodušší, než detekce psychického stresu. Zvláště v signálech tepové frekvence, v údajích z akcelerometru, ale třeba i teplotě pokožky, bývají zpravidla zjevné odchylky od izolinie.

Tab. 3.3: Tabulka výsledků modelů detekujících přítomnosti fyzického stresu, SVM - metoda podpůrných vektorů, LR- metoda logistické regrese

ID MODELU	SPECIFICITA		SENZITIVITA		PŘESNOST	
	SVM	LR	SVM	LR	SVM	LR
1	91,22%	91,22%	65,52%	65,52%	87,69%	87,69%
2	96,07%	97,57%	93,67%	90,12%	95,72%	96,48%
3	96,15%	96,60%	74,67%	73,43%	93,19%	93,4%
4	90,51%	92,80%	48,21%	34,29%	83,54%	83,16%
5	96,86%	97,64%	38,01%	34,26%	88,05%	88,15%
PRŮMĚR	94,16%	95,16%	64,01%	59,52%	89,63%	89,77%
ROZPTYL	0,1043	0,0382	0,0480	0,0610	0,0093	0,0108
ODCHYLKA	0,0429	0,0419	0,2191	0,2470	0,0964	0,1043



Obr. 3.5: Boxplot jednotlivých údajů pro modely detekující přítomnost fyzického stresu

Z obou typů testovaných modelů jsme v tomto případě dostali velmi podobné údaje (viz. tabulka 3.3). Přesto se mode, využívající metodu SVM, zdá být pro detekci fyzického stresu nepatrně lepší, neboť dosahuje lepších výsledků senzitivity (64,1%) oproti LR metodě, která dosáhla senzitivity 59,52%. Také rozptyl výsledků SVM metody je o trochu lepší než LR metody (viz. obrázek 3.5)

3.3.3 Detekce přítomnosti psychického stresu

Detekce psychického stresu z non-EEG signálů je oproti detekci fyzického stresu znatelně složitější, již vzhledem k tomu, že změny v těchto signálech není dost často možné jednoduše interpretovat.

Dalším problémem detekce tohoto stavu je, že na rozdíl od fyzického stresu (či detekci celkového stresu, kde se stres porovnával s relaxačními fázemi) byl psychický stres během sběru dat vyvoláván dohromady čtyřmi odlišnými stresory.

Výsledky detekce psychického stresu, kterých dosahuje detekční algoritmus nejsou příliš uspokojivé (viz. tabulky 3.4 a 3.4). Přesto, že modely dosahují přesnosti přes 67%, jejich senzitivita není vyšší než 21%.

Z tohoto důvodu jsme se v tomto případě, mimo modelu SVM a LR využívající binární data, pokusili natrénovat i LR model jenž pracuje s defuzzifikovanými daty. Přesto, že tento model dosáhl lepší průměrné senzitivity než modely pracující s binárními daty, jeho výsledky nejsou uspokojivé.

Tab. 3.4: Tabulka výsledků modelů detekujících přítomnosti psychického stresu, SVM - metoda podpůrných vektorů, LR- metoda logistické regrese

TYP VSTUPNÍCH DAT	SPECIFICITA			SENZITIVITA		
	BIN	BIN	FUZZY	BIN	BIN	FUZZY
MODELU	SVM	LR	LR	SVM	LR	LR
1	95,25%	94,25%	50,38%	9,36%	9,49%	35,69%
2	95,69%	96,66%	49,32%	7,79%	9,92%	47,86%
3	84,26%	82,02%	64,42%	18,34%	36,8%	64,91%
4	84,57%	93,17%	76,09%	30,38%	11,98%	20,05%
5	92,75%	86,56%	74,41%	25,13%	35,71%	23,52%
PRŮMĚR	90,50%	90,53%	63,04%	18,2%	20,78%	38,4%
ROZPTYL	0,0339	0,0339	0,0480	0,0018	0,0328	0,0064
ODCHYLKA	0,0802	0,0419	0,1813	0,0978	0,1416	0,1842

Tab. 3.5: Tabulka výsledků modelů detekujících přítomnosti psychického stresu, SVM - metoda podpůrných vektorů, LR- metoda logistické regrese

TYP VSTUPNÍCH DAT MODELU	PŘESNOST		
	BIN	BIN	FUZZY
	SVM	LR	LR
1	66,99%	66,36%	45,55%
2	65,66%	67,03%	48,81%
3	65,92%	69,44%	64,77%
4	69,66%	70,83%	60,67%
5	68,38%	68,25%	56,27%
PRŮMĚR	67,32	67,32%	55,2%
ROZPTYL	0,0093	0,0011	0,0256
ODCHYLKA	0,0964	0,0337	0,1601

3.3.4 Detekce přítomnosti kognitivního psychického stresu

U detekce kognitivního psychického stresu jsme narazili na stejný problém jako u celkového psychického stresu. Přestože oba modely, jak SVM, tak LR, dosahují velmi vysoké specifity (viz tabulka 3.6), jejich průměrná senzitivita, a tím i záchyt stavu kognitivního stresu je nízký. U modelů SVM senzitivita dosahuje 18,46% a u LR modelů dokonce pouhých 14,07%. Průměrná přesnost těchto metod se pak u modelů SVM 81,08% a u LR 80,81%.

Tab. 3.6: Tabulka výsledků modelů detekujících přítomnosti kognitivního psychického stresu, SVM - metoda podpůrných vektorů, LR- metoda logistické regrese

MODELU	SPECIFICITA		SENZITIVITA		PŘESNOST	
	SVM	LR	SVM	LR	SVM	LR
1	94,48%	99,04%	16,26%	0,01%	82,26%	83,58%
2	96,73%	93,65%	0%	0,3%	83,09%	80,78%
3	90,89%	91,22%	34,77%	36,9%	82,32%	82,80%
4	90,82%	97,39%	32,47%	14,88%	76,70%	77,42%
5	98,14%	94,31%	8,81%	16,86%	81,07%	79,51%
PRŮMĚR	94,12%	95,12%	18,46%	14,07%	81,08%	80,81%
ROZPTYL	0,0225	0,0205	0,0023	0,0019	0,0093	0,0024
ODCHYLKA	0,04710	0,0437	0,1500	0,1416	0,0964	0,0498


3.3.5 Detekce přítomnosti emočního psychického stresu

U emočního naprosto selhaly metody strojového učení, kterým byla na vstup vložena binární data. Metody pak aproximovali tak, že dosáhly vysoké senzitivity, ale ve čtyřech z pěti případů nulové senzitivity. Tak tomu bylo i nadále a to i přesto, že v trénovacích maticích byly několika násobně zmnožené úseky, obsahující signály evokující přítomnost emočního psychického stresu.

Uchýlili jsme se proto k tomu, že jsem na vstup metodám vložili původní ne-defuzzifikovaná data. Získané výsledky sice již jsou relevantnější, ovšem senzitivita metod je stále značně nízká (viz. tabulka 3.7). Výsledky jednotlivých modelů nabývají značně rozdílných hodnot (viz. obrázek 3.6).

Tab. 3.7: Tabulka výsledků modelů detekujících přítomnosti emočního psychického stresu, SVM - metoda podpůrných vektorů, LR- metoda logistické regrese

MODELU	SPECIFICITA		SENZITIVITA		PŘESNOST	
	SVM	LR	SVM	LR	SVM	LR
1	52,79%	53,78%	51,48%	40,56%	52,57%	51,5%
2	41,21%	51,84%	75,04%	66,09%	48,00%	54,7%
3	81,15%	91,28%	21,17%	0,09%	72,78%	77,27%
4	90,94%	97,16%	13,61%	8,83%	79,22%	83,78%
5	97,83%	73,64%	0,01%	16,28%	81,38%	63,93%
PRŮMĚR	72,78%	73,54%	33,58%	26,53%	66,79%	66,23%
ROZPTYL	0,0891	0,0105	0,1211	0,0866	0,0958	0,0005
ODCHYLKA	0,3481	0,2944	0,2986	0,2663	0,3096	0,2801



Obr. 3.6: Boxplot jednotlivých údajů pro modely detekující přítomnost emočního psychického stresu

3.4 Srovnání dosažených výsledků a diskuze

Přestože navržený algoritmus je schopný relativně dobře detekovat fyzický stres a docela ucházející jsou i výsledky celkového stresu. Při detekci psychického stresu, celkového či některého jeho typu (emočního i kognitivního) selhává. Důvodů tohoto výsledku spatřujeme hned několik.

Prvním z nich je ten, že příznaky stresové reakce (především tedy psychického stresu) silně podléhají v non-EEG signálech intraindividuální variabilitě, což znamená, že stres se může ve svých projevech subjekt od subjektu značně lišit. Většiny studii, které jsou řešované v kapitole 2., pracuje postupně se signálem od jednoho pacienta, kterému přizpůsobí metodu na míru, dle jeho fyziologie. Detekční algoritmus, který jsme navrhli, bere data z celé databáze jako celek a snaží se hledat takové řešení, které by stavělo na projevech stresu, které jsou společné všem (nebo alespoň většině) subjektům z databáze.

Dalším důvod shledávám, v samotné použité databázi non-EEG signálů. Fyzický stres byl vyvolán pouze jedním typem stresoru. Stejně tak do relaxovaného stavu byly subjekty uvedeny pomocí stejné metody. Naproti tomu při vyvolávání psychic-

kého stresu, byly subjekty exponovány různými stresory. U navození kognitivního stresu to byly dva rozličné testy, při navození emočního stresu to pak byl jednou verbální projev, po druhé pak kinematografická ukázka, což nutně nemuselo vyvolat pokaždé stejnou reakci.

Problémem databáze je i to, že během průběhu experimentu neproběhlo žádné měření (např. měření EEG signálu), které by bylo možné brát za tzv. zlatý standard, podle kterého by pak byla posuzována implementovaná metoda. Jako vzor byla použita anotace signálů, kdy jsme předpokládali, že od zahájení expozice stresorem až po ukončení jeho působení se subjekt nachází v stresovém stavu, což samozřejmě nemusí zcela odpovídat realitě. Na tomto místě by bylo možné citovat autory článku [14], kteří ve své studii dokázali docela spolehlivě určit emoční psychický stres před zahájení kognitivních testů, nikoliv však stres během sledování filmové ukázky. Autoři článku [14] tuto skutečnost přisuzují tomu, že sledování hororového filmu zahrnovalo pouze pasivní angažmá, která u subjektu nemusela nutně vyvolat stresovou reakci.[14]

Dalším možným důvodem, který se nabízí při pohledu na získané výsledky, je přeučení modelů. Domnívám se ovšem, že tento důvod není tím, který stojí za neúspěchy v detekci. Knihovna, kterou jsme během programování využívali trénování modelu, má v sobě implementovanou funkci, kde se k předejití přeučení modelu používá křížová validace. Standardně jsme používali desetinásobnou křížovou validaci, ale speciálně v případech psychického stresu a kognitivního psychického testu, jsme několik modelů natrénovali s použitím padesátinásobné křížové validace a výstupy z těchto modelů byly takřka totožné s původními modely.

Porovnáme-li výsledky dosažené naším algoritmem s výsledky (viz. 3.8), kterých dosáhly autoři článku [9], pomocí metody shlukové analýzy GMM, při využití stejného datového souboru, musíme konstatovat, že naše metoda dosahuje mnohem horších výsledků a to nejen v oblasti klasifikace psychického stresu. Rozdíl ve výsledcích může být zapříčiněn již výše zmiňovaným použitím GMM metody pro každý subjekt zvlášť, zatímco, naše metoda pracuje zároveň z celým souborem dat.

Výsledky různých metod strojového učení autorů článku [12] je možné srovnat s výsledky, které jsme obdrželi během vývoje algoritmu. Naše výsledky jsou získané zprůměrování čtyř různých metod strojového učení pořízené vždy zprůměrováním čtyř modelů (kdy 3/4 zkušební matice posloužila jako trénovací množina a zbylá 1/4 jako testovací množina). Autoři článku [12], pracovali s odlišným souborem dat než my. Výsledky srovnání jsou prezentované v tabulce 3.9

Porovnáme-li naše výsledky senzitivity s autory článku [10], zjistíme, že jejich metoda dosahuje senzitivity 66% což jsou v podstatě porovnatelné výsledky, kterých dosáhl náš algoritmus (senzitivita pomocí modelů SVM 64,05%, pomocí LR 63,84%).

Tab. 3.8: Tabulka porovnávající výsledky dosažené pomocí námi navržené metody s metodou autorů článku [9]

	METODA GMM, POUŽITÁ V ČLÁNKU [9]		NÁŠ ALGORTIMUS VÝSTUP Z NEJLEPŠÍ METODY	
	SENZ.	SPEC.	SENZ.	SPEC.
RELAX	85,4%	93,6%	63,84%	74,81%
FYZICKÝ STRES	93,3%	91,1%	64,01%	94,16%
EMOČNÍ STRES	77,2%	70,2%	33,58%	72,78%
KOGNITIVNÍ STRES	86,4%	86,4%	18,46%	94,21%

Tab. 3.9: Tabulka srovnání různých metod strojového učení autorů článku [12] s našimi.

METODA	PŘESNOST
VÝSLEDKY DOSAŽENÉ AUTORY ČLÁNKU [12]	
K-NN	64,28%
SVM (lineární jádro)	68,66%
SVM (gaussovské jádro)	67,48%
LR	77,27%
VÝSLEDKY ZÍSKANÉ BĚHEM VYTVÁŘENÍ NAŠEHO ALGORITMU	
K-NN	59,57%
SVM (lineární jádro)	60,19%
SVM (gaussovské jádro)	61,44%
LR	61,39%

4 Závěr

V rámci této práce byla nastudována a popsána potřebná teorie z oblasti fyziologie, psychologie, zpracování signálů a informatiky. Na základě získaných informací byla vytvořena krátká úvodní kapitola popisující stres, jeho mechanismy a projevy, stejně jako možnosti jeho klasifikace.

Další kapitola byla věnována několika rešerším článkům, zabývajícím se problematikou detekce stresu pomocí non-EEG signálů. Při výběru studii a tvorbě rešerší jsme se zaměřili zejména na to, jaké typy signálů byly pro detekci použity, jak tyto signály byly snímány, pomocí jakých příznaků a metod byl stres detekován.

Závěrečná kapitola této práce je věnována popisu a výsledkům algoritmu, určenému k detekci a klasifikaci stresu, který jsme v rámci zadání této práce navrhli. Tento algoritmus používá k detekci a klasifikaci stresu metodu shlukové analýzy c-means a metod strojového učení SVM a logistické regrese.

Při realizaci algoritmu bylo použito sady biologických signálů non-EEG Dataset for Assessment of Neurological Status, která je volně dostupná na stránkách databanky fyziologických signálů PhysioNet. Tato databáze obsahuje 5 non-EEG signálů, získaných snímáním pohybů zápěstí, změny konduktance kůže, změny teploty pokožky, saturace krve a tepové frekvence.

Výstupem algoritmu je sada naučených modelů určených k detekci přítomnosti stresu, detekci fyzického stresu, psychického stresu, emočního-psychického stresu a kognitivního-psychického stresu.

Při testování modelů jsme dospěli k závěru, že náš algoritmus je schopný detekovat přítomnost stresu a výskyt fyzického stresu s relativně slušnou senzitivitou, specificitou a přesností. Algoritmus se nic méně příliš nehodí k detekci jakéhokoliv druhu psychického stresu, neboť modely určené k jejich detekci mají příliš nízkou senzitivitu.

Literatura

- [1] BARTUŇKOVÁ, Staša. *Stres a jeho mechanismy*. Praha: Karolinum, 2010. ISBN 978-80-246-1874-6.
- [2] LINHART, Jiří. *Slovník cizích slov pro nové století: základní měnové jednotky : abecední seznam chemických prvků : jazykovědné pojmy : 30 000 hesel*. Litvínov: Dialog, 2002. ISBN 80-858-4361-7.
- [3] JOSHI, Vinay. *Stres a zdraví*. Praha: Portál, 2007. Rádci pro zdraví. ISBN 978-80-7367-211-9.
- [4] VEČEŘOVÁ-PROCHÁZKOVÁ, Alena a Radkin HONZÁK. *Stres, eustres a distres: Stress, eustress and disstress*. Via practica: moderný časopis pre lekárov prvého kontaktu. Bratislava: SOLEN, 2009, 6(12), 491-495. ISSN 1336-4790.
- [5] HOLMES, Thomas H. a Richard H. RAHE. *The social readjustment rating scale*. Journal of Psychosomatic Research [online]. 1967, 11(2), 213-218 [cit. 2019-01-03]. DOI: 10.1016/0022-3999(67)90010-4. ISSN 00223999. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/0022399967900104>
- [6] ČEŠKA, Richard, ŠTULC, Tomáš, Vladimír TESAŘ a Milan LUKÁŠ, ed. *Interna. 2., aktualizované vydání [brožované ve 3 svazcích]*. V Praze: Stanislav Juhaňák - Triton, 2015. ISBN 978-80-7387-885-6.
- [7] SPILLER, Robin a David GRUNDY, ed. *Pathophysiology of the enteric nervous system: a basis for understanding functional diseases*. Malden, Mass.: Blackwell Publishing, 2004. ISBN 1-4051-2361-3.
- [8] VYMĚTAL, Jan. *Speciální psychoterapie. 2., přeprac. a dopl. vyd. Praha: Grada, 2007. Psyché (Grada)*. ISBN 978-80-247-1315-1.
- [9] BIRJANDTALAB, Javad, Diana COGAN, Maziyar Baran POUYAN a Mehrdad NOURANI. *A Non-EEG Biosignals Dataset for Assessment and Visualization of Neurological Status*. In: 2016 IEEE International Workshop on Signal Processing Systems (SiPS) [online]. IEEE, 2016, 2016, s. 110-114 [cit. 2018-11-26]. DOI: 10.1109/SiPS.2016.27. ISBN 978-1-5090-3361-4. Dostupné z: <http://ieeexplore.ieee.org/document/7780081/>
- [10] Bakker J, Pechenizkiy M, Sidorova N. BAKKER, Jorn, Mykola PECHE-NIZKIY a Natalia SIDOROVA. *What's Your Current Stress Level? Detection of Stress Patterns from GSR Sensor Data*. 2011 IEEE 11th International Conference on Data Mining Workshops. IEEE, 2011, 2011, , 573-580.

DOI: 10.1109/ICDMW.2011.178. ISBN 978-1-4673-0005-6. Dostupné také z: <http://ieeexplore.ieee.org/document/6137431/>

- [11] SINGH, Mandeep a Abdullah BIN QUEYAM. *Stress Detection in Automobile Drivers using Physiological Parameters: A Review*. 2011 IEEE 11th International Conference on Data Mining Workshops. International Journal of Electronics Engineering. 2013, (12), 7. ISSN 0973-7383.
- [12] JIMENEZ-LIMAS, Marco A., Carlos A. RAMIREZ-FUENTES, Blanca TOVAR-CORONA a Laura I. GARAY-JIMENEZ. *Feature selection for stress level classification into a physiological signals set*. In: 2018 15th International Conference on Electrical Engineering, Computing Science and Automatic Control (CCE) [online]. IEEE, 2018, 2018, s. 1-5 [cit. 2019-01-02]. DOI: 10.1109/ICEEE.2018.8533968. ISBN 978-1-5386-7033-0. Dostupné z: <https://ieeexplore.ieee.org/document/8533968/>
- [13] Goldberger AL, Amaral LAN, Sklo L, Hausdorff JM, Ivanov PCh, Mark RG, Mietus JE, Moody GB, Peng CK, Stanley HE. *PhysioBank, PhysioToolkit a PhysioNet: součásti nového výzkumného zdroje pro komplexní fyziologické signály*. Cirkulace 101 (23): e215-e220 [Circulation Electronic Pages; <http://circ.ahajournals.org/content/101/23/e215>]; 2000 (13. června).
- [14] WICKRAMASURIYA, Dilranjan S., Chaoxian QI a Rose T. FAGHIH. *A State-Space Approach for Detecting Stress from Electrodermal Activity*. In: 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) [online]. IEEE, 2018, 2018, s. 3562-3567 [cit. 2019-05-14]. DOI: 10.1109/EMBC.2018.8512928. ISBN 978-1-5386-3646-6. Dostupné z: <https://ieeexplore.ieee.org/document/8512928/>
- [15] DE SANTOS SIERRA, Alberto, Carmen SANCHEZ AVILA, Javier GUERRA CASANOVA a Gonzalo BAILADOR DEL POZO. *A Stress-Detection System Based on Physiological Signals and Fuzzy Logic*. IEEE Transactions on Industrial Electronics [online]. 2011, 58(10), 4857-4865 [cit. 2019-01-02]. DOI: 10.1109/TIE.2010.2103538. ISSN 0278-0046. Dostupné z: <http://ieeexplore.ieee.org/document/5680639/>
- [16] KLAPIL, Ondřej a Pavel JURA *Fuzzy systémy s netradičními antecedenty fuzzy pravidel* VUT. 2016
- [17] ŠAJNOVÁ, Lucie *užití adaptivního neuro-fuzzy inferenčního systému ve zpracování plodového EKG* [online]. 2008. VŠB – Technická univerzita Ostrava [cit. 2019-05-21].

- [18] SAGHAFI, Lili. *A Tutorial on Clustering Algorithms* [online]. 20.12.2017 [cit. 2019.05.20]. Dostupné z: https://home.deib.polimi.it/matteucc/Clustering/tutorial_html/index.html/

Seznam symbolů, veličin a zkratek

GAS	General Adaptation Syndrome
ANS	vegetativní (autonomní) nervový systém
GIT	gastrointestinální trakt
EDA	elektrodermální aktivita
GMM	Gaussian Mixture Model
GSR	galvanická reakce kůže
fit	metoda zjišťování změny založené na monitorování výkonu pomocí neparametrického testu
ADWIN	metoda detekce změn na základě nezpracovaných dat pomocí adaptivního okna
MSE	střední kvadratický chyba
UPIITA	The Interdisciplinary Professional Unit in Engineering and Advanced Technologies
EKG	elektrokardiografie
EMG	elektromyografie
HRV	Variabilita srdeční frekvence
K-NN	K-nearest neighbours
SVM	Support vector machines
SCL	skin conductance level (stupeň vodivosti kůže)
IRF	impulse response function
SCRs	Individual skin conductance responses
HR	Tepová frekvence
UCM	Univerzita Complutense v Madridu
BL1	označení klidové fáze během experimentu na UCM
HV	označení fáze během experimentu na UCM, kdy subjekt hyperventiloval
TP	označení fáze během experimentu na UCM, kdy byl subjekt podroben řízenému rozhovoru
BL2	označení poststresové fáze během experimentu na UCM
ANFIS	adaptivním neuro-fuzzy inferenčním systémem
LR	model logistické regrese

Seznam příloh

A Obsah přiloženého CD

53

A CD s příloženými soubory

Příložené CD obsahuje komprimovanou složku s daty a zdrojovými kódy nevrhnutého algoritmu, textový soubor obsahující pokyny ke spuštění programu. Program byl realizován v programovacím prostředí MATLAB R2017a a MATLAB R2018b. Dále toto CD obsahuje elektronickou verzi této práce.