

Západočeská univerzita v Plzni
Fakulta aplikovaných věd
Katedra informatiky a výpočetní techniky

Bakalářská práce

Detekce stresových situací na základě analýzy biosignálů

Prohlášení

Prohlašuji, že jsem bakalářskou práci vypracoval samostatně a výhradně s použitím citovaných pramenů.

V Plzni dne 22. června 2016

Petr Kopal

Poděkování

Děkuji vedoucímu bakalářské práce Ing. Pavlu Mautnerovi, Ph.D. za odborné vedení bakalářské práce a cenné rady. Dále děkuji všem dobrovolníkům, kteří obětovali svůj volný čas a přispěli tak k výsledkům této práce a v neposlední řadě své rodině za podporu a zázemí.

Abstract

Stress can be very dangerous for us, therefore it would be appropriate to somehow draw attention to dangerous situations. Is it, however, possible to automatically detect stress? This bachelor thesis deals with the detection of stress based on the analysis of biomedical signals, which might help us to solve the problem of automatic stress detection. Specifically, the design and implementation of an experimental Java application to classify situations (into rest and close to stress situations) using biosignals GSR and HR (calculated from ECG). These biosignals will be obtained using the Arduino with a measuring sensor E-Health platform and then sent through the serial port to a PC for further processing. The classifier used will be a Three-layer Perceptron neural network, which will be trained specially for each tested subject. This experiment will focus primarily on the situations associated with the computer (such as counting examples, slideshow, playing mini-games etc.).

Abstrakt

Stres může být pro člověka velmi nebezpečný, proto by bylo vhodné na nebezpečné situace nějakým způsobem upozornit. Jde ovšem stres automaticky detekovat? Tato bakalářská práce se zabývá detekcí stresových situací na základě analýzy biosignálů, s jejíž pomocí bychom možná mohli problém automatické detekce vyřešit. Konkrétně jde o návrh a implementaci experimentální Java aplikace pro klasifikování situací (na klidové a blízké stresu) za pomoci příznaků z biosignálů GSR a HR (vypočteného z EKG). Tyto biosignály budou získávány pomocí Arduina s měřícím senzorem E-Health platform a dále zasílány pomocí sériového portu do PC k dalšímu zpracování. Jako klasifikátor bude použita neuronová síť Třívrstvý perceptron, která bude pro každého testovaného jedince vždy speciálně natrénována. Tento experiment bude zaměřen především na situace spojené s počítačem (jako počítání příkladů, promítání obrázků, hraní miniher atd.).

Obsah

1	Úvod	1
2	Stres a jeho detekce	2
2.1	Stres	2
2.2	Detekce Stresu	2
2.3	Biosignály	5
3	Analýza vhodných biosignálů	6
3.1	EEG	6
3.1.1	EEG při detekci stresu a emocí	7
3.2	GSR	7
3.2.1	GSR při detekci stresu a emocí	8
3.3	EKG	9
3.3.1	EKG při detekci stresu a emocí	9
3.4	BVP	11
3.4.1	BVP při detekci stresu a emocí	12
3.5	Ostatní použitelné biosignály	12
3.6	Výběr biosignálu	13
3.7	Výběr HW pro měření	13
3.7.1	Arduino	13
3.7.2	E-health Senzor Shield V2.0 platform	14
4	Návrh systému pro detekci stresu	15
4.1	Možnosti aplikace	15
4.2	Tvorba scénáře měření	16
4.2.1	Měření v klidu (baseline)	16
4.2.2	”Stresující”registrační okno	16
4.2.3	Počítání na čas	17
4.2.4	Minihra	18
4.2.5	Promítání obrázků	18
4.2.6	Krátké video	19

4.3	Naměření dat	19
4.3.1	Měřicí program v Arduinu	19
4.3.2	Filtrování hodnot	19
4.4	Příznaky a jejich extrakce	21
4.4.1	Příznaky (Features)	21
4.4.2	Návrh příznaků	21
4.5	Vyhodnocení signálu	23
4.5.1	Neuronové sítě	23
4.5.2	Vícevrstvý perceptron	25
4.5.3	Návrh neuronové sítě pro klasifikaci	26
5	Měření a získání trénovacích dat	28
5.1	Příprava měření	28
5.1.1	Napojení měřicí desky	28
5.1.2	Konfigurace knihovny E-health	28
5.1.3	Příprava GSR senzoru	29
5.1.4	Příprava EKG senzoru	29
5.1.5	Nahrání programu pro měření	30
5.2	Získaná data	31
5.2.1	Klidový stav	31
5.2.2	Stimulovaný stav	32
5.3	Získané příznaky	34
5.3.1	Pouze z GSR	34
5.3.2	Pouze z HR	36
5.3.3	Oba biosignály	36
5.4	Poznatky z měření	36
6	Implementace	39
6.1	Sběr dat z Arduina	39
6.1.1	Třída pro příjem dat – Arduino.java	39
6.1.2	Ukládání do souboru	41
6.1.3	FIR.java	41
6.2	Extrakce příznaků	41
6.2.1	FeatureExtractor.java	41
6.2.2	FeatureExtractorOffline.java	44
6.2.3	FeatureExtractorOnline.java	44
6.3	Klasifikace situací	45
6.3.1	StressClasificator.java	45
6.4	Grafické uživatelské rozhraní	46
6.4.1	Hlavní okno	46
6.4.2	Okna pro scénáře	47

7	Dosažené výsledky	49
7.1	Výsledky pouze pro GSR	50
7.1.1	Klidový stav	51
7.1.2	Stimulovaný stav	51
7.2	Výsledky pouze pro HR	52
7.2.1	Klidový stav	53
7.2.2	Stimulovaný stav	53
7.3	Výsledky pro oba biosignály	53
7.3.1	Klidový stav	54
7.3.2	Stimulovaný stav	54
8	Závěr	56
A	Další grafy biosignálu GSR	61
B	Uživatelský manuál	63
B.1	SW požadavky	63
B.2	Překlad	63
B.2.1	Konfigurace knihovny RXTXcomm	63
B.2.2	Překlad	63
B.3	Spuštění	64
B.4	Nahrání programu do Arduina	64
B.4.1	Instalace Arduino IDE	64
B.4.2	Konfigurace knihovny e-Health	64
B.4.3	Nahrání programu	64
B.5	Výběr módu aplikace	65
B.5.1	Online mód	65
B.5.2	Offline mód	66
B.5.3	Detekční mód	69
C	Obsah CD	70

1 Úvod

Co si můžeme představit pod pojmem stres? Stres lze chápat jako stav organismu, který je obecnou odezvou na jakoukoliv výrazně působící zátěž – fyzickou nebo psychickou (blíže vysvětleno v kapitole 2).

Mnoho lidí se každodenně stresuje a lze také předpokládat, že existuje blízký vztah mezi stresem a duševním zdravím. Psychologický stres dokonce může mít vliv i na fyzické zdraví. Proto by bylo vhodné stresové situace nějakým způsobem rozpoznávat a tím na ně osobu upozornit. Můžeme však tyto stresové situace automaticky detekovat? Odpověď na tuto otázku možná dostanete přečtením této práce.

Jedním z cílů této bakalářské práce bylo prostudování výzkumných prací týkajících se této problematiky. Na jejich základě lze říci, že k účelu detekce stresu mohou být použity biosignály jako elektroencefalogram (EEG), vodivost kůže (GSR), elektrokardiogram (EKG), atd. (blíže popsáno v kapitole 3). Dalším úkolem této práce je zvolit vhodný biosignál, případně sadu biosignálů, pro senzory dostupné na KIV, navrhnout scénář měření. Dále navrhnout metodu detekce stresu a implementovat ji ve vhodném programovacím jazyce. V neposlední řadě je nutné aplikaci otestovat na dostatečném počtu osob, zhodnotit její použitelnost a získané výsledky důkladně zdokumentovat pro případné budoucí navazující výzkumné projekty zabývající se touto problematikou.

Po analýze biosignálů jsem se rozhodl použít příznaky získané pomocí GSR a HRV (výpočtem z EKG). Tyto hodnoty získám pomocí vývojové desky Arduino s měřícím senzorem e-Health platform dostupným na KIV.

Oblast činností, na kterou se zaměřím bude především spojena s počítačem. Například počítání příkladů, hraní postřehových her, promítání obrázků atd. (blíže popsáno v kapitole 4). Některé činnosti budou časově omezeny, abych zjistil jakou roli hraje časový limit na získaných biosignálech a tím možná i při detekci stresu.

Druhá polovina práce se bude týkat její realizace. Tedy naměřením hodnot, extrakcí příznaků, zvolením umělé neuronové sítě ke klasifikaci, samotnou implementací aplikace a dokumentací výsledků.

2 Stres a jeho detekce

Nejprve se společně zaměříme na úvod do problematiky stresu a jeho detekce a podrobněji si dané pojmy popíšeme.

2.1 Stres

Přestože o stresu často mluvíme, není pro nás jednoduché ho nějak popsat či definovat.

Podle definice, jež byl přijata na mezinárodním kongresu o stresu, je stres „nespecifická reakce organismu na jakýkoliv vliv, který na organismus působí“ [11]. Podle R. L. Atkinsonové je považován stres za situaci, v níž se lidé setkají s událostmi, jež vnímají jako ohrožení své tělesné nebo duševní pohody. Tyto události obvykle nazýváme stresory a reakce lidí na ně stresové reakce. Při stresu se uplatňují obranné mechanismy, které pomáhají organismu vystavenému nebezpečí ke zvládnutí situace.

Hlavními obrannými mechanismy jsou např. vytěsnění (vyločení bolestivých impulzů či vzpomínek z vědomí), racionalizace (přidělení logických či sociálně žádoucích motivů činnostem) a popření (popření existence nepříjemné vnější reality).

Běžnými stresovými faktory (stresory) jsou např. faktory fyzikální (prudké světlo, nadměrný hluk, nízká či vysoká teplota. . .), psychické (zodpovědnost, práce, škola. . .) a nebo sociální (osobní vztahy, životní styl). V dnešní době podstupujeme stresové situace, které nevedou k ohrožení života, ale při dlouhodobém působení mohou mít vliv na případná onemocnění z nich vyplývající. Stres jako takový se dá řešit jedině odstraněním jeho příčin. [12]

2.2 Detekce Stresu

Vzhledem k významu psychického stresu v moderním životě vzniklo na téma detekce stresu mnoho studií. Řada výzkumných prací dospěla tak daleko, že vznikly i přístroje automaticky detekující stres. Efektivní automatická de-


tekce stresu je nutnou podmínkou k vývoji systémů, které jsou schopny zvýšit zprostředkování lidské stresové reakce do té míry, aby mohly zabránit následkům akutních stresových příhod (reakcí) nebo chronickému stresu. Ve většině studií byly pro detekci použity biometrické signály jako vodivost kůže (SC - skin conductance, v literatuře též jako galvanic skin response (GSR)), elektrokardiogram (EKG), krevní tlak (BVP), elektromyogram (EMG), dýchání (RSP), teplota kůže a elektroencefalogram (EEG) [3].

U těchto biosignálů je známo, že mohou zachytit emocemi řízené změny vzniklé aktivací autonomního nervového systému (ANS). Reakce ANS se ukázaly dokonce jako spolehlivý prostředek pro automatické rozpoznávání emocí (emotion recognition - ER) [4]. Sady příznaků získané sledováním těchto biosignálů u jednoho či více testovaných subjektů jsou dále použity pro trénovací data klasifikátorů, které se snaží předvídat emoce. Lidská fyziologie však stejně jako fyziologická reakce na emoční podněty trpí vysokou individuální variabilitou [5].

Vzhledem k této skutečnosti jsou účinné automatické systémy ER obvykle závislé na testovaném subjektu. To znamená, že jsou trénovány pouze s datasy získanými od jednoho monitorovaného uživatele. Méně triviální je případ subjektově nezávislých ER systémů, které jsou trénovány datasy od více testovaných subjektů. Tyto systémy jsou schopny detekovat emoce mezi různými jedinci. Vzhledem k tomu, že jsou trénovány datasy od různých jedinců, rozdíl mezi nimi neumožňují, aby byly systémy dostatečně efektivní. Je tedy známo, že tyto systémy nejsou příliš účinné vzhledem k subjektově závislým systémům.

Za účelem snížení rozdílů mezi testovanými subjekty jsou sledované biosignály během extrakce příznaků normalizovány na základě výchozích nahrávek (baseline recordings) každého subjektu. Ve většině posledních studií týkajících se subjektově nezávislých ER systémů je výchozí hodnota příznaků typicky odečtena od nově naměřené hodnoty. Další častou metodou je používání některých statistických veličin (jako např. průměrná hodnota, směrodatná odchylka, minimum, maximum) [6], aby se zkreslili údaje získané od různých jedinců a přivedli je ke společnému základu. Například „normalizované SC“ bylo spočítáno odečtením minimální hodnoty z výchozích od aktuální a vydělením velikostí rozsahu výchozích hodnot. Ovšem ani s použitím těchto metod nebylo dosaženo stejných výsledků jako u subjektově závislých (subject-dependent) systémů. Je tedy zřejmé, že jsou zapotřebí sofistikovanější přístupy k řešení rozdílů biosignálů mezi jedinci.

Zajímavou studií související s touto prací je studie zabývající se zkoumáním použití psychologie v adaptivním herním designu[7]. V této práci používají autoři příznaky získané naměřením biosignálů GSR a BVP. Testovaní jedinci byli monitorováni při hraní populární 3D videohry Super Mario 64. Měření bylo rozděleno do několika částí, přičemž po každé části následovala desetiminutová přestávka. Obtížnost hry se v každé části stupňovala a zároveň byly počítány hráčům neúspěšné pokusy, tj. počet chyb. Závěrečné výsledky práce ukazují zvyšující se hladinu GSR a současně HR při zvyšujícím se počtu chyb. Zároveň také rostoucí hodnotu GSR pro jednotlivé úrovně hry v závislosti na odehraném čase (nejnižší pro jednoduchou obtížnost, vyšší pro střední úroveň obtížnosti a nejvyšší pro nejtěžší obtížnost, více na následujícím grafu).



Obrázek 2.1: Závislost GSR na obtížnosti hry a odehrané době

U HR není závislost na odehraném čase triviální a jednoznačně patrná. Z poznatků vyplývajících z této studie by zaměření se na chyby a stupňující obtížnost hry, mohlo být při detekci stresu u hráčů hrajících některou hru v této práci velmi klíčové.

V další problematice blízké práci [8] autoři opět volí jako příznaky, příznaky získané z GSR a ty pomocí bezdrátové komunikační technologie Zigbee přenáší do počítače, kde s nimi pracují a vyhodnocují je. Pro testované subjekty mají připraveno několik scénářů (např. klidový stav, čtení, psaní,

aritmetické operace, hluboké dýchání,...), při kterých jim je měřena úroveň GSR. V konečných výsledcích autoři stanovili limitní hranici mezi klidovým a stresovým stavem popsanou rovnicí 2.1.

$$limit = \frac{stressaverage * 0.6 + relaxaverage * 0.4}{2} \quad (2.1)$$

Vše co je nad touto hodnotou má hodnotu 1 a co je pod touto hodnotou má hodnotu -1. Tento poznatek by také mohl být v budoucím výzkumu užitečný.

Protože v předchozím textu bylo několikrát použito slovo biosignál bylo by vhodné ho alespoň trochu vysvětlit.

2.3 Biosignály

Biosignál lze chápat jako jakýkoli změřený projev živého organismu. Nemusí přitom jít o vlastní činnost organismu (tj. aktivní činnost), ale může jít i o pasivní reakci organismu s vnějším fyzikálním či chemickým podnětem. Biosignálem je i jedna hodnota či řada různých hodnot změřených v jednom okamžiku [19].

Biosignály můžeme dělit podle mnoha hledisek. Například podle jejich chování v čase je rozlišujeme na deterministické (jednoznačně určené počátečními podmínkami) a stochastické (chování v sobě zahrnuje náhodný prvek), dále například podle rozměru signálu na jednorozměrné (časová posloupnost hodnot změřeného parametru), dvojrozměrné (řada biosignálů sejmuta v jednom čase z definovaných míst dvojrozměrného prostoru) a trojrozměrné (např. CT, 3D ultrazvuk).

Nejčastěji si ale pojem biosignálu spojujeme s elektrickými projevy organismu, které jsou pro tuto práci velmi podstatné.

Elektrickými biosignály jsou například již zmíněné biosignály EKG, HRV, EEG, GSR (EDR, SCR), EMG, které podrobněji popíší v následující kapitole.

3 Analýza vhodných biosignálů

Prvním krokem, který je potřeba udělat, aby později bylo možné přistoupit k samotné realizaci práce a implementaci požadované detekční metody je volba vhodného biosignálu, ze kterého získáme příznaky pro samotnou detekci. Ze souvisejících výzkumů vyplývá, že nejvhodnějšími biosignály pro tento problém jsou EEG, GSR, EKG (HRV), BVP a EMG. Nyní si podrobněji rozebereme vhodné biosignály.

3.1 EEG

Elektroencefalogram (zkráceně EEG) je neinvazivní diagnostická metoda sloužící k záznamu elektrické aktivity mozku. Tato metoda je založena na změnách polarizace neuronů mozkové kůry. Zařízení, které tento záznam pořizuje se nazývá elektroencefalograf. Změny jsou snímány povrchovými elektrodami, které má subjekt umístěné na hlavě. Jeho elektrody jsou schopny zachytit změny napětí v řádu mV. Protože jsou amplitudy signálu velmi nízké je nutné tento signál zesílit pomocí zesilovače.

Hodnocení encefalografických záznamů spočívá v amplitudové a frekvenční analýze. Podle frekvence běžně rozlišujeme čtyři druhy mozkových vln: alfa, beta, theta, a delta. Přičemž pro detekci stresu jsou nejdůležitější alfa a beta vlny (druhy mozkových vln blíže popsány v tabulce 3.1).

Název	Frekvence	Výskyt
Alfa	8-13Hz	zavřené oči v bdělém stavu, klid, relaxace, pocit únavy
Beta	13-30Hz	vnímání, koncentrace, mentální aktivita, stres
Theta	4-8Hz	sný, hluboký spánek, relaxace
Delta	0.5-4Hz	koma, regenerace mozku, hluboké uvolnění

Tabulka 3.1: Druhy mozkových vln

3.1.1 EEG při detekci stresu a emocí

Výzkumy týkající se detekce stresu pomocí EEG se spíše zaměřují na rozpoznávání pozitivních a negativních emocí nebo dělení emocí na štěstí, smutek, klid a strach [9].

Hlavním aspektem neurofyziologického výzkumu emocí je hemisferická specializace. Zatímco levá hemisféra se zdá být více spojena se zpracováním pozitivních emocí a s ním souvisejícím chováním, pravá hemisféra se zdá být více spojena se zpracováním negativních emocí a obranných reakcí [10].

Tyto rozdíly jsou reprezentovány modelem emočního zpracování, ve kterém hraje důležitou roli přední kůra mozková. Důkazy na podporu tohoto modelu byly získány ze studií týkajících se asymetrie v prefrontální (prefrontal) EEG alfa aktivitě. U pozitivních nálad bylo prokázáno jejich spojení s poměrně větší levou prefrontální (left-prefrontal) aktivitou a u negativních nálad s poměrně větší pravo-prefrontální (right-prefrontal) aktivitou. Pravá prefrontální mozková kůra (kortex) může mít kritický podíl na reakci na stres, protože je základní složkou jak emoční, tak bdělostní (vigilance) sítě. Některé studie naznačují, že vysoké hladiny pravostranné prefrontální aktivace jsou spojeny s negativním afektivním stylem a oslabeným imunitním systémem. Důležitým poznatkem je tedy, že prefrontální kortex může zprostředkovat, do jaké míry psychosociální stres ovlivňuje duševní a fyzické zdraví. [10]

3.2 GSR


Zařízení, které pomocí dvou elektrod umístěných na bříscích dvou sousedních prstů (většinou prostředníček a ukazováček) měří vodivost kůže. Bříška prstů obsahují nejvíce potních žláz, které mají vliv na změnu kožního odporu (GSR). Je stanovena měření slabého proudu kolem kůže, měření změn v proudění elektrické energie nebo měření proudu, který generuje tělo samo (měření GSR na obrázku 3.1). Vztah mezi vodivostí a odporem udává následující vzorec 3.1.

$$G = \frac{1}{R}[S] \quad (3.1)$$

S rostoucí sekrecí potu kožní odpor klesá a elektrodermální aktivita a vodivost roste. Naměřené hodnoty se pohybují v řádech mikro Siemens.

GSR je spojována s korelací (vzájemnou souvislostí) s emocemi, pozor-


ností a stresem. Zařízení detekuje jinou vodivost pokud je jedinec v klidu a jinou pokud je ve stresu. Řada studií také zjistila korelaci mezi učením a zvýšenou hodnotou GSR.



Obrázek 3.1: GSR měření

3.2.1 GSR při detekci stresu a emocí

Účast zařízení GSR při detekci stresu a emocí je velmi častá. Typickou GSR reakci můžeme vidět na následujícím obrázku [obr 3.2]. Velká část studií zabývajících se touto problematikou používá GSR at' už jako hlavní zdroj příznaků nebo alespoň doprovodný.



Obrázek 3.2: Typická GSR reakce

Způsob extrakce příznaků se téměř u každého výzkumného týmu liší, ale v zásadě lze říci, že je nejprve naměřena klidová hodnota GSR testovaného

subjektu (v některých pracích je použita první či druhá derivace signálu – např. [3]) tj. její průměrná hodnota na určitém intervalu a dále pak rozdíl nově naměřené oproti průměrné hodnotě. Ve studii [14] zabývající se vizualizací a vyhodnocením stresu počítačových uživatelů jsou jako příznaky brány: počet reakcí, střední hodnota GSR na intervalu, amplituda reakce, doba stoupání k vrcholu amplitudy a energie reakce (tj. – obsah energie pod stoupající částí křivky). Pracují dále i s dalšími příznaky z jiných biosignálů (především BVP), ale podíl GSR na celkovém počtu příznaků byl nejvyšší.


Jako způsob klasifikace autoři zvolili SVM klasifikátory. Jejich úspěšnost se pohybuje mezi 57-80% v závislosti jaký SVM klasifikátor byl použit. Ve výzkumu [8] byly použity klasifikátory BayesNet (93,73%), J48 (93,79%) a SMO (91,95%) a ve studii [3] byl zvolen klasifikátor na bázi lineární diskriminační analýzy (LDA, 95%).

3.3 EKG

Elektrokardiogram je záznam časové změny elektrického potenciálu způsobené srdeční aktivitou. Záznam je pořízen zařízením s názvem elektrokardiograf. Hodnoty EKG představují rozdíl napětí při šíření akčního potenciálu myokardem (srdečním svalem) a pohybují se v řádu jednotek až desítek mV. Typická EKG křivka je opakující se cyklus tří elektrických entit: P vln (arteriální depolarizace), QRS komplexu (ventrikulární depolarizace) a T vlny (ventrikulární depolarizace). Tyto hodnoty jsou znázorněny na obrázku 3.3. Pomocí EKG můžeme zjistit tzv. EKG desatero (srdeční akce, srdeční rytmus, srdeční frekvence, P vlna, PQ interval, QRS komplex, ST úsek, T vlna, QT interval, elektrická osa srdeční). Pro detekci stresu je především významná variabilita srdečního tepu (HRV), kterou lze pomocí EKG získat výpočtem.

3.3.1 EKG při detekci stresu a emocí

EKG zaujímá ve studiích týkajících se detekce stresu stejně jako GSR přední příčky v jeho použitelnosti při získávání příznaků.




Obrázek 3.3: Variace QRS komplexů

Metody pro výpočet HRV z EKG

Pro výpočet srdečního tepu z hodnoty napětí EKG je třeba změřit dobu v intervalu RR mezi dvěma GRS komplexy (R je vrchol EKG vlny podle QRS komplexu).


Pokud máme k dispozici EKG writer (dnes jsou spíše běžné digitální EKG, ale princip výpočtu bude více méně shodný), nastavíme ho na rychlost 25mm/s. Tlusté čáry na čtverečkovaném papíře reprezentují 5 mm (= 0,2s) části a tenké čáry 1 mm (= 0,04s). Detailněji k prohlédnutí na obrázku 3.4.



Obrázek 3.4: Popis čtvercové sítě

Jsou zde 3 jednoduché metody výpočtu:

- **Metoda počítání čtverců** – je ideální pro pravidelné srdeční rytmy. Používá sekvenci **300-150-100-75-60-50-43-37**. Začínáme počítat od 1. nalezeného QRS komplexu a končíme na 2. nalezeném QRS komplexu. Každá dosažená tlustá čára symbolizuje číslo v sekvenci. Pokud bude druhý vrchol mezi čarami použijeme aritmetický průměr mezi hodnotami. Tato metoda je znázorněna na obrázku 3.5.



Obrázek 3.5: Ukázka metody počítání čtverců

- **Metoda dosazení do vzorce:**

$$HR = \frac{25(mm/s) * 60(s)}{pocet - malych - ctvercu - mezi - RR} \quad (3.2)$$

- **Metoda vyznačování:**

- Nepravidelné srdeční rytmy jsou nejlépe determinovány 3 sekundovou vyznačovací metodou. Tj. získání počtu QRS komplexů, které jsou v rámci 3 sekund. Tento počet je vynásoben 20 a získáme srdeční tep v tepech za minutu

Ve spojení s dalšími biosignály používá podobné klasifikační metody jako jsou uvedeny u GSR.

3.4 BVP

Krevní tlak (BVP – Blood volume pulse) je tlak, kterým působí krev na stěnu cévy. Je vytvářen působením srdce jako krevní pumpy a souvisí se stavbou

a funkcemi krevního oběhu. Tlak se zvláště ve velkých cévách mění také v závislosti na čase – nejvyšších hodnot dosahuje ve vypuzovací fázi srdeční akce (systolický tlak), nejnižší ve fázi plnění srdečních komor (diastolický tlak). BVP blízce koreluje se srdečním tepem (HR), s kterým se v oblasti detekce stresu často pracuje.

3.4.1 BVP při detekci stresu a emocí

Příznaky získané pomocí BVP můžeme nahradit příznaky získané pomocí EKG a opačně. Proto se většinou tyto dva biosignály spolu nepoužívají. BVP bývá ve výzkumu detekce stresu zastoupen společně s GSR (stejně jako u EKG).

Jak již bylo řečeno, využívá se především k získání hodnoty srdečního tepu. Oproti EKG je BVP méně invazivní metodou monitorování. HR stoupá pod tlakem, aby se zvýšil průtok krve, kterou se zásobují pracující svaly či aby připravil tělo na „fight or flight“ („bojuj nebo uteč“) reakci (tj. aby tělo čelilo stresu či před ním uniklo). HR je považován za cenný ukazatel celkové úrovně aktivity. Podle studie [16] je vysoký srdeční tep spojen s nervózním stavem a opačně.

3.5 Ostatní použitelné biosignály

Electromyogram (EMG) je záznam elektrické aktivity svalů při odpočinku a při kontrakci (stahu). V oblasti detekce stresu se příznaky získané z EMG většinou používají pouze jako doplňkové.

Dalším nepříliš používaným biosignálem je teplota kůže. Některé výzkumy jako např. Detekce stresu u řidičů [17] ji ale využívají i jako hlavní zdroj příznaků. Vycházejí z faktu, že okrajové části těla jako jsou končetiny či nos jsou citlivé na stres.

Posledním biosignálem, který pouze zmíním je záznam dýchání. Tato problematika je blíže popsána v článku [18].

3.6 Výběr biosignálu

Po analýze biosignálů následuje rozhodnutí o tom, který biosignál je pro tuto práci nejvhodnější. Po delší úvaze jsem se rozhodl pro použití biosignálu GSR.

K rozhodnutí mě vedlo několik důvodů. Největším kladem GSR bylo jeho zastoupení ve většině výzkumných prací týkající se této problematiky a také celková úspěšnost při použití těchto příznaků. Extrakce příznaků není pro laika tak složitá jako např. u EEG. HW pro měření není příliš komplikovaný na obsluhu.

Druhým nejvhodnějším kandidátem by byl biosignál EKG nebo BVP, které bych navrhoval použít pokud nebudou příznaky získané z GSR dostatečně rozlišovat stavy stresu a klidu či jako další variantu detekce. Rozhodně, ale nemá smysl tyto dva biosignály (myšleno BVP a EKG) používat společně. Protože je oba využíváme především k získání HRV a vedlo by to k zbytečné redundanci příznaků.

Jako nepříliš vhodné biosignály pro svou práci považuji EEG a EMG u nichž extrakce příznaků není zrovna jednoduchá a vyžaduje velmi důkladné prostudování problematiky a příprava na měření je poněkud zdlouhavá (EEG by bylo vhodné použít pokud bychom se soustředili na rozpoznávání emocí).


3.7 Výběr HW pro měření

Jelikož jsem zvolil jako hlavní biosignál GSR, laboratoř KIV nám nabízí dvě alternativy, jak ho měřit. První variantou je vývojová deska Arduino (nebo jednočipový počítač Raspberry PI) s měřicí deskou E-health Sensor platform a druhou alternativou je Shimmer senzor. Z důvodu snazší implementace a možnosti práce z domova (vlastním Arduino) jsem se rozhodl použít první variantu tedy Arduino s měřícím senzorem e-Health platform. Nyní si podrobněji popíšeme tato zařízení.

3.7.1 Arduino

Arduino je Open-Source prototypová platforma pro snadný návrh a vývoj elektronických programovatelných zařízení. Arduino desky jsou schopné číst

vstupy (jako např. světlo na senzoru, stisknutí tlačítka, zaslání zprávy...) a přeměnit ji na výstup (zapnutí LED diody, motoru, atd.). Deska se řídí zasláním instrukcí jejímu mikroprocesoru. K tomuto účelu lze použít programovací jazyk učený pro Arduino (založený na Wiringu – jazyk pro podobnou desku jako Arduino s mikrokontrolerem a IDE) a Arduino IDE (pro nahrání instrukcí). Již byla vyvinuta celá řada modelů a modifikací. Pro mojí práci však přichází v úvahu zejména modely Arduino UNO a Arduino Mega dostupné v laboratoři KIV.



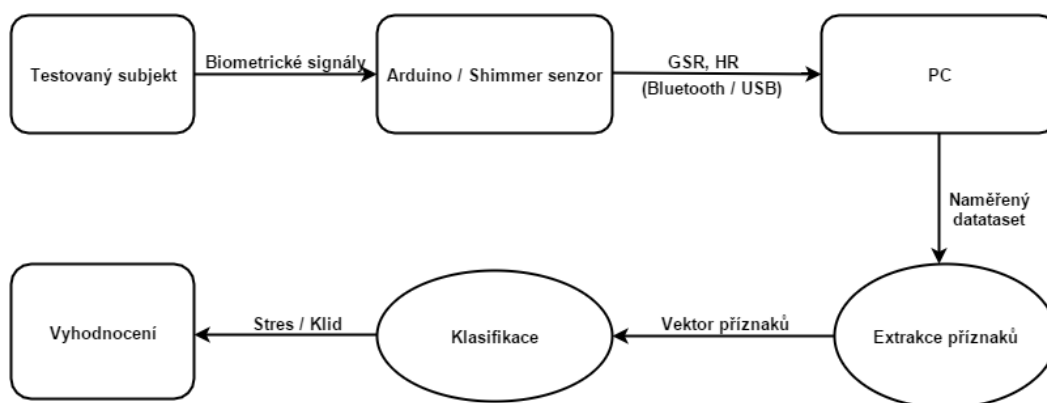
Obrázek 3.6: Arduino Mega

3.7.2 E-health Sensor Shield V2.0 platform

E-health Sensor umožňuje přes Arduino a Rapsberry Pi provádět výzkumy, u kterých je zapotřebí monitorovat lidské tělo. Je k dispozici 10 různých senzorů (mezi jinými např. GSR, EKG, EMG – dostupných na KIV). Biometrická data lze posílat některým ze šesti různých způsobů bezdrátové komunikace (Wi-Fi , 3G , GPRS , Bluetooth , 802.15.4 a ZigBee) v závislosti na aplikaci. Data mohou být zaslána do Cloudu k dlouhodobému uložení či vizualizovaná v reálném čase zasláním přímo do počítače nebo chytrého telefonu.

4 Návrh systému pro detekci stresu

Nyní jsme se již dostali k realizační části práce a naším prvním úkolem bude navrhnout jak bude vypadat systém pro detekci stresu. Nejprve bude nutné testovaný subjekt nějakým způsobem stimulovat abychom se pokusili vyvolat situace blízké stresu, bude tedy potřeba vytvořit nějaký scénář měření. Dále hodnoty biosignálů musíme naměřit a zaslat k dalšímu zpracování do PC, kde extrahujeme příznaky signálu a na jejich základě klasifikujeme danou situaci. Pro prvotní ilustraci je takto navržený systém zobrazen na obrázku 4.1.



Obrázek 4.1: Schéma navrženého systému

4.1 Možnosti aplikace

Pro začátek si řekněme, co by tato aplikace měla vlastně umět. V první řadě samozřejmě nějakým způsobem měřit příslušné biosignály a tyto hodnoty přijímat z měřícího zařízení a ukládat je do souborů. Další vhodnou funkcí by byla extrakce příznaků at' už offline pro vytvoření trénovacích příznaků tak také online při samotném měření. Tím se dostáváme k další podstatné funkci aplikace, tedy klasifikaci příslušných situací na základě naměřených hodnot. Pro snadnou obsluhu by jednoznačně nemělo chybět snadně ovladatelné grafické uživatelské rozhraní.

4.2 Tvorba scénáře měření

Jak již bylo řečeno, tato práce se zaměřuje především na měření biosignálů v situacích spojených s počítačem nebo vyžadujících soustředění. Měření bude rozděleno na dvě etapy. V první etapě budou naměřené hodnoty pouze ukládány do souborů (tzv. datasetů) s kterými budeme dále offline pracovat, ale v druhé části kromě ukládání do souboru mohou být naměřené hodnoty i online vyhodnocovány.

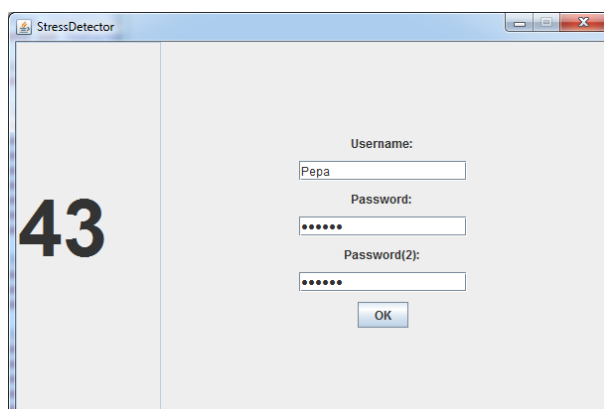
Nyní si rozebereme scénář měření (tj. všechny dílčí úkoly). Před každým úkolem bude následovat vždy minutová pauza pro uvolnění a aby nedocházelo k ovlivňování výsledků z výsledků předešlého úkolu. Jednotlivé scénáře by měly testovaný subjekt donutit k práci, snaze o dosažení dobrého výsledku a zároveň ukázat vliv časového limitu, či score na hodnotách biosignálů a tím možná i na míře stresu.

4.2.1 Měření v klidu (baseline)

První úkol, který zároveň vyžaduje nejméně aktivity ze strany měřeného subjektu je měření v klidu. Testovaný subjekt bude instruován, aby se uvolnil a zůstal v klidu, případně myslel na něco pozitivního. Během této činnosti mu bude po dobu dvou minut snímána jeho GSR a HR. Tyto hodnoty budou sloužit jako referenční (tj. na základě blízké shody aktuálně měřené situace s klidovou vyhodnotíme situace také jako klidovou, v opačném případě jako možnou stresovou situaci).

4.2.2 "Stresující" registrační okno

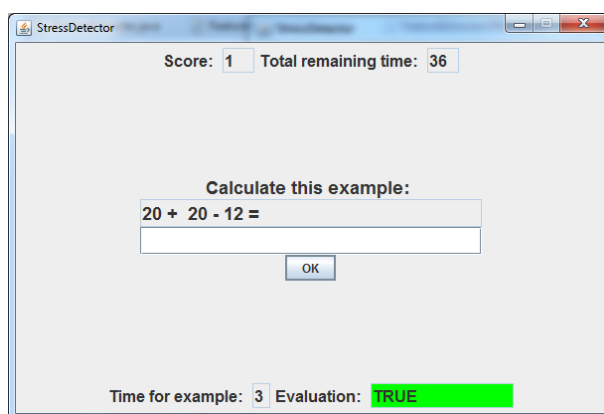
V další části bude mít testovaný subjekt dostat se přes registrační okno (tedy zaregistrovat se) v časovém limitu jedné minuty. Tedy pouze vyplní libovolné jméno a dvakrát zopakuje heslo. Registračnímu oknu se však mnoho věcí nelíbí a vždy když na to testovaný subjekt upozorní smaže mu vyplněná hesla. Úkolem tedy není nijak simulovat zaregistrování subjektu, ale jeho „vytrhnutí“ z klidového stavu. Tuto část provádíme zhruba 1x – 2x v závislosti na úspěšnosti subjektu. Pro větší představu je registrační okno k dispozici na následujícím obrázku 4.2.



Obrázek 4.2: Stresující registrační okno

4.2.3 Počítání na čas


Jak již název prozrazuje, v této části měření půjde o počítání jednoduchých náhodně generovaných příkladů složených pouze z operací sčítání, odčítání a násobení. Aby to nebylo příliš snadné, má testovaný subjekt vždy na odpověď pouze 7 sekund. Pokud do této doby neodpoví, bude příklad vyhodnocen jako špatný. Subjektu je počítáno scóre za vypočtené příklady a okno je doplněno o zvuky (simulující např. hodiny, správný či špatný výsledek), aby dodaly situaci na dramatickosti. Opět je tato situace k prohlédnutí na následujícím obrázku 4.3.



Obrázek 4.3: Okno s příklady

4.2.4 Minihra

Čtvrtým úkolem bude jednoduchá minihra, kterou bude v první fázi testovaný subjekt hrát, aby dosáhl co nejlepšího výsledku (půjde o některou z online postřehových her). Druhá fáze bude o trochu obtížnější, protože v ní půjde kromě hraní hry i o odpovídání na otázky či příklady (cca na 3-5 sekund) a za každou chybnou odpověď bude odečten 1 bod. Také by bylo vhodné subjekt nějakým způsobem motivovat (např. odměnou za nejlepší výsledek, či vzájemným soupeřením o lepší výsledek). Na obrázku 4.4 je znázorněna jedna z použitých miniher s názvem "Rain of Arrows"



Obrázek 4.4: Online minihra Rain of Arrows

4.2.5 Promítání obrázků

V páté části opět nebude muset testovaný subjekt být příliš aktivní. Jeho úkolem bude pouze sledování promítaných obrázků. Obrázků bude 6 (některé budou pozitivní – např. příroda a jiné negativní – obrázky zobrazující násilí apod.) a budou se střídát cca po 10 sekundách.

4.2.6 Krátké video

Poslední část bude spočívat ve sledování videa, které bude mít ze začátku klidný průběh a následně něčím testovaný subjekt vyleká (hlasitý zvuk, náhlý vstup nějakého objektu na scénu...). Tento scénář bude pouze při prvním měření subjektu

4.3 Naměření dat

Biometrické signály GSR a EKG (HR) získané od testovaného subjektu budou měřeny pomocí měřicí desky pro Arduino (či případně i Shimmer senzorem). Naměřená data budou následně přes technologii USB (či Bluetooth) pomocí sériového portu přeneseny do počítače, kde bude probíhat extrakce příznaků. Nejprve, ale bude nutné tyto příznaky navrhnout. Každý testovaný subjekt bude mít svou složku obsahující jeho datasety a podsložku se získanými příznaky.

4.3.1 Měřicí program v Arduinu

První krok, který bylo třeba vykonat byla implementace programu, který za pomoci měřicí desky získává biosignály GSR a EKG a odesílá je prostřednictvím sériového portu do počítače. Tuto činnost obstarává program s názvem `gsr-ecg-measuring.ino`, který nahrajeme pomocí Arduino IDE do zařízení. Program začne měření teprve až dostane příslušnou zprávu od PC a samotné měření je zrealizováno funkcemi knihovny `e-Health`. Data jsou odesílána ve formátu `String` a hodnoty (uložené v datovém formátu `float`) vodivosti kůže a EKG napětí jsou od sebe odděleny mezerou (Zkoušel jsem data odesílat i v binární podobě ve formátu `float`, ale bohužel při jejich čtení někdy přicházely nesmyslné hodnoty). Měření je opět pozastaveno zasláním zprávy od PC.

4.3.2 Filtrování hodnot

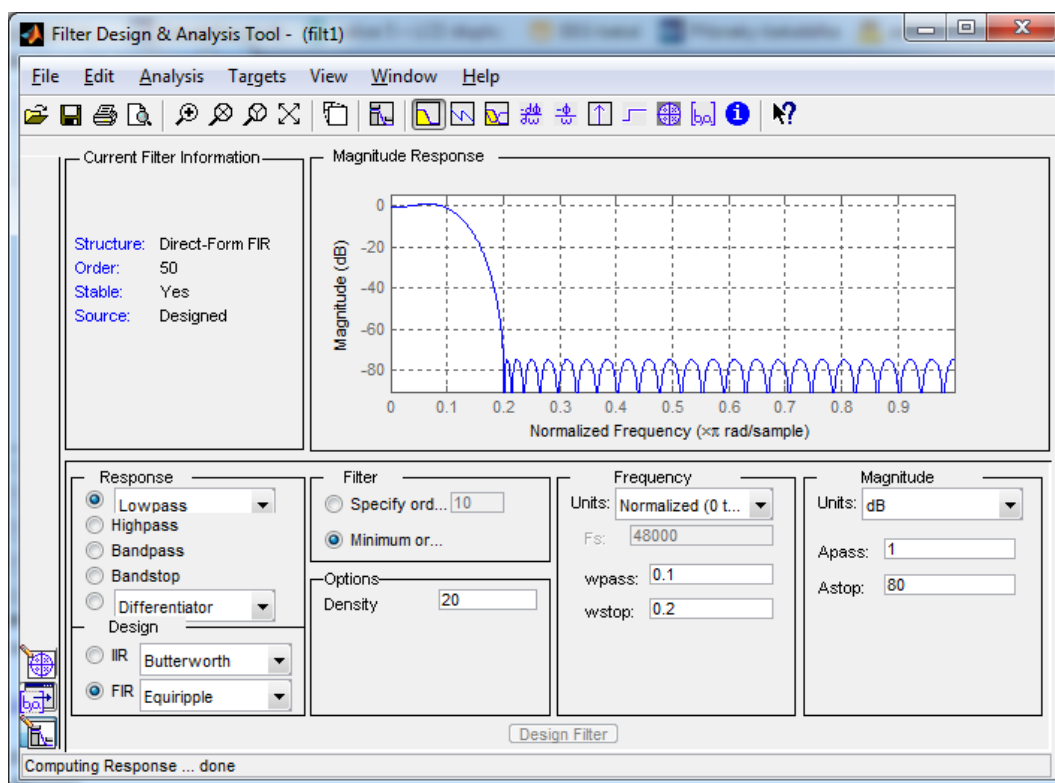
Jelikož původně naměřené hodnoty mohou poměrně výrazně kolísat je vhodné použít na ně nějaký filtr, který nás zbaví nežádoucích hodnot. Pro svou jednoduchost a zároveň účinnost jsem zvolil filtr FIR. Ten jsem nejprve navrhl

a vyzkoušel nástrojem sptool dostupném v Matlabu s nastavením, které je zobrazeno na následujícím obrázku 4.5.

Filtr FIR

Filtr s konečnou impulzní odezvou (FIR, finite impulse response) je diskretní lineární filtr. Je definován pomocí impulzních koeficientů. Jeho výstup je definován časovým popisem pomocí impulzní odezvy, který udává následující vzorec 4.1 kde $x[n]$ je vstupní signál, $h[n]$ je impulzní odezva, $y[n]$ je výstupní signál a N je řád filtru:

$$y[n] = h[n] * x[n] = \sum_{k=0}^n h[k]x[n - k] \quad (4.1)$$



Obrázek 4.5: Nastavení filtru v nástroji sptool

A získané koeficienty filtru jsem uložil do souboru „coef.txt“. Tyto koeficienty pak dále používám při vytvoření filtru v javě. Samotné filtrování probíhá

pomocí metody `float getOutputSample(float inputSample)`, jejíž parametrem je pouze příslušná naměřená hodnota. Jelikož filtru nějakou dobu trvá než správně zabere je vstupní pole hodnot prodlouženo o 100 prvních hodnot, abychom o ně nepřišli a po použití filtru je opět tato část odříznuta.

4.4 Příznaky a jejich extrakce

4.4.1 Příznaky (Features)

Ve strojovém učení (machine learning) a v rozpoznávání vzorů (pattern recognition) je příznak definován jako individuální měřitelná vlastnost pozorovaného jevu [2]. Příznaky jsou obvykle číselné hodnoty, ale používají se také řetězce (strings) či grafy (např. v syntaktickém rozpoznávání vzorů (syntactic pattern recognition)). V našem případě lze zjednodušeně říci, že hledáme takové hodnoty a vlastnosti naměřených biosignálů, kterými bychom dokázali popsat stav jako klidový či naopak blízký stresu.

Počáteční sada příznaků (raw features) může být redundantní nebo příliš velká než aby se dala použít. Z tohoto důvodu je důležité vybrat z příznaků vhodnou podmnožinu nebo vytvořit novou menší sadu příznaků k usnadnění učení, zvýšení obecnosti a interpretovatelnosti. Proces získávání příznaků se nazývá extrakce příznaků (feature extraction). Zvolení vhodných příznaků je jedním z nejdůležitějších výzkumných problémů v této oblasti. Výsledná množina číselných příznaků se též nazývá vektor příznaků. S tímto vektorem dále pracujeme při konečné klasifikaci (zařazování do tříd). Algoritmy, které při klasifikaci pracují s vektorem příznaků jsou např. metoda nejbližšího souseda (nearest neighbor), umělé neuronové sítě či Bayesovské učení.

4.4.2 Návrh příznaků

Při návrhu příznaků se snažím, aby byly příznaky pokud možno co nejjednodušší, ale zároveň co nejúspěšnější při klasifikaci a zároveň se částečně inspiroji souvisejícími výzkumy. Samozřejmě bychom měli nalézt takové příznaky, které se pokud možno liší v klidových a ve stresových situacích.

GSR příznaky

Prvním příznakem, který nás může napadnout je klasický aritmetický průměr hodnot na daném časovém intervalu. Na základě měření však bylo zjištěno, že při dalším měření se mohou hodnoty výrazně lišit (podrobněji v kapitole měření). A tudíž by příznaky mohly být pokaždé jiné. Proto jako příznak volím průměr z hodnot, od kterých nejprve odečtu minimum (tyto hodnoty popisuje vzorec 4.2 a tento příznak udává vztah 4.3).

$$GSR_{Trf}(i) = GSR(i) - GSR_{min} \quad (4.2)$$

$$GSR_{MeanTrf} = \frac{1}{n} \sum_{i=0}^n GSR_{Trf}(i) \quad (4.3)$$

Dalším příznakem je rozdíl mezi maximem a minimem. Třetím příznakem je podíl druhé části intervalu na celkovém součtu (vzorec 4.4).

$$GSR_{secPow} = \frac{\sum_{i=n/2}^n GSR_{Trf}(i)}{\sum_{i=0}^n GSR_{Trf}(i)} \quad (4.4)$$

Čtvrtým příznakem je rozdíl mezi aktuálním průměrem GSR a hodnotou z předchozího měřeného intervalu. A posledním příznakem je doba nárůstu GSR vydělená 5, aby nebyla váha příznaku příliš velká oproti ostatním (vzorec 4.5, maxId - index globálního maxima v poli hodnot GSR, prevLocMinId - index předchozího lokálního minima v poli GSR, 100 - vzor. frekvence).

$$GSR_{Raise} = \frac{GSR_{maxId} - GSR_{prevLocMinId}}{5 * 100} \quad (4.5)$$

Pokud výsledky získané za pomoci tohoto vektoru příznaků nebudou dostatečné přistoupím k použití některých příznaků použitých ve studii [14] (Autoři studie zde na signálu uplatňují Lagrangerův interpolační algoritmus), Prvním zmíněným příznakem je počet GSR reakcí na zvoleném vzorkovacím intervalu (number of response). Přičemž typická GSR reakce byla znázorněna na obr. 3.2. Druhým příznakem je průměrná hodnota GSR na daném intervalu. Třetím příznakem je velikost amplitudy reakce. Čtvrtým příznakem je doba stoupání (rising time) a posledním příznakem je energie reakce. Energií rozumíme plochu pod stoupající křivkou. Posledním příznakem je rozdíl mezi aktuální hodnotou GSR a předešlé.

HR příznaky

Jako první vhodný příznak pro HR se opět nabízí použití vypočtené průměrné hodnoty HR v intervalu 10s, který skutečně použiji, ale vydělím ho 60 (klidová hodnota HR), aby neměl příznak příliš velkou váhu. Dalším příznakem by mohla být např. hodnota transformovaného průměru (stejný postup jako u GSR) a posledním příznakem rozdíl mezi aktuální hodnotou HR a hodnotou z předchozího intervalu.


4.5 Vyhodnocení signálu

Navržený vektor příznaků dále pokračuje do klasifikační metody, která bude vyhodnocovat, zda jsou získané biosignály v rámci desetisekundového intervalu příznačné spíše pro stresovou situaci či jsou ještě v klidové normě. Klasifikační metoda bude pravděpodobně tvořena některou z neuronových sítí a proto si je nyní trochu přiblížíme (O dalších klasifikačních metodách jako je metoda nejbližšího souseda či Bayesovské učení, které nebudou v této práci použity se můžete dočíst s příslušné literatuře).

4.5.1 Neuronové sítě

Neuronové sítě jsou jeden z výpočetních modelů používaných v umělé inteligenci, který napodobuje činnost odpovídajících biologických struktur. Skládají se z umělých neuronů [obrázek 4.6], jejichž předlohou je neuron biologický. Neurony mohou mít libovolné množství vstupů, ale pouze jeden výstup. Jsou vzájemně propojeny (tzv. synapsemi), navzájem si předávají signály a transformují je pomocí určitých přenosových funkcí. Umělé neuronové sítě mohou být použity k rozpoznávání, klasifikaci či kompresi obrazu, predikci časových řad, aj. [13]

- x_i jsou vstupy
- w_i jsou synaptické váhy
- Θ je práh
- $S(x)$ je aktivační funkce neuronu



Obrázek 4.6: Model umělého neuronu

- Y je výstup neuronu

Přenosová (aktivační) funkce neuronu

- Jejím úkolem je převést hodnotu vstupního potenciálu na výstupní hodnotu neuronu

Typy aktivačních funkcí

- sigmoidální $f_s(u) = \frac{1}{1+e^{-u}}$
- hyperbolický tangens $f_s(u) = \tanh(u)$
- znaménková funkce $f_s(u) = \text{sgn}(u)$
- Heavisideova funkce $f_H(u) = 1 \text{ pro } u > 0, 0 \text{ pro } u < 0$

Aby byla síť účinná a dávala přesné výsledky, je nutné ji nejprve naučit množinou obrazů zvanou trénovací množina. Během tohoto procesu síť nastavuje jednotlivé váhy, tak aby výsledek byl co nejpřesnější. Učení zpravidla probíhá do té doby než síť dosáhne požadované účinnosti nebo maximálního počtu iterací.

Učení sítě může být dvojího charakteru:


- **Učení s učitelem** - při učení s učitelem jsou neuronové síti předkládány požadované výsledky a srovnávány s naučenými mechanismy

- např. Perceptron, Vícevrstvý perceptron, Time delay neural network (TDNN)
- **Učení bez učitele** - není založeno na vyhodnocování výstupů – síť si sama třídí vstupy do skupin podle podobnosti a charakteristických znaků.
- např. ART1, ART2, Kohonenova síť

Protože jsem se rozhodl, že ve své práci použiji Vícevrstvý perceptron, tak si ho nyní blíže rozebereme.

4.5.2 Vícevrstvý perceptron

Základní stavební prvek neuronové sítě se nazývá perceptron (z historických důvodů. V dnešní době však dochází k záměně a používá se spíše slovo "neuron" viz předešlé definice neuronu). Vícevrstvý perceptron (Multi Layer Perceptron - MLP) se skládá ze tří vrstev perceptronů (neuronů). Konkrétně tedy z vrstvy vstupní, skryté a výstupní [obrázek 4.7]. Počet vstupních neuronů je dán počtem vstupů matematického modelu, počet výstupních neuronů je ovlivněn jeho kódováním a počet neuronů ve skryté vrstvě je volen na základě složitosti úlohy (většinou maximum ze vstupu a výstupu). Síť je standardně učená pomocí učení s učitelem a algoritmu zpětné propagace.



Obrázek 4.7: Vícevrstvý perceptron

Algoritmus zpětné propagace

1. Počáteční inicializace vah a prahů jednotlivých neuronů
2. Přivedení vstupního vektoru a definice požadované výstupní odezvy, uzly skryté vrstvy jsou aktivační fce aplikované na lineární kombinaci vstupních hran (Dopředná propagace). Váhy neuronů se adaptují podle následující vzorce 4.2, kde w_{ij} jsou váhy mezi i-tým skrytým uzlem (popř. vstupním uzlem) a uzlem j-tým v čase t , η je koeficient učení, δ_j je chyba a x_j je j-tá složka vstupního vektoru:

$$w_{ij}(t + 1) = w_{ij}(t) + \eta \delta_j x_j \quad (4.6)$$

3. Zpětná propagace - chyby výsledku dopředné propagace propagovány zpětným průchodem (modifikují parametry akt. fce).
4. Algoritmus končí při zanedbatelných chybách výsledku dopředné propagace

4.5.3 Návrh neuronové sítě pro klasifikaci

Již bylo naznačeno, že jsem se pro klasifikaci rozhodl použít vícevrstvý perceptron (konkrétně třívrstvý). Vytvořím ho za pomoci knihovny (frameworku) Neuroph ve verzi 2.92 dostupném pro Javu. Vstupní počet neuronů bude roven počtu složek příznakového vektoru (v závislosti který biosignál použijeme, případně zda použijeme oba) a počet výstupních neuronů bude roven počtu tříd na které klasifikujeme, tedy 2. Typ učení bude s učitelem se zpětnou propagací. Budeme tedy muset určit, které příznakové vektory odpovídají klidovému stavu a které by mohly souviset se stresem. Učení bude probíhat do té doby než bude chyba učení menší než 0.01. Jako aktivační funkce bude zvolen hyperbolický tangens.

Neuroph knihovna (framework)

Neuroph je objektově orientovaný framework pro umělé neuronové sítě napsaný v Javě. Může být použit pro jejich vytváření, trénování a testování. Podporuje běžné neuronové sítě jako Perceptron, Vícevrstvý Perceptron, Kohonenovu síť či Hopfieldovu síť. Kromě frameworku je k dispozici i aplikace Neuroph studio, která je pohodlnější díky grafickému rozhraní. Tato aplikace

je vhodná pro počáteční seznámení s navrhováním neuronových sítí, výběru vhodné sítě k dalšímu použití a případnému natrénování s příslušnými data-sety. Takto natrénovaná síť může být uložena a následně nahrána do cílové aplikace (díky API) nebo může být vytvořena programově přímo v Javě.

Trénování sítě

K učení sítě je potřeba pro každý testovaný subjekt vytvořit individuální trénovací data. Ty budou odpovídat příznakovým vektorům z měření, které budou typické pro dané klasifikované stavy (klid, blízké stresu). Jak budou trénovací data vypadat se dozvíme v následující kapitole.


5 Měření a získání trénovacích dat

5.1 Příprava měření

Před samotným měřením je zapotřebí nejprve vykonat několik činností.

5.1.1 Napojení měřící desky

Pro začátek je nutné měřící desku e-Health platform spojit s Arduinem pomocí pinů, tak aby co nejvíce doléhaly k sobě. Detail spojení je k dispozici na následujícím obrázku 5.1 (U verze mega je měřící deska menší než Arduino, ale je s ním také kompatibilní).



Obrázek 5.1: Detail spojení Arduina s měřící deskou e-Health


5.1.2 Konfigurace knihovny E-health

Aby bylo možné implementovat měřící algoritmus je dále potřeba nainstalovat např. Arduino IDE, či jiný program umožňující nahrání programu a přidat do něj knihovnu e-Health, která je k dispozici na přiloženém CD (či ke stažení na [20]). Tuto knihovnu je nutné zkopírovat do složky libraries v Arduino IDE. Pro nainstalování knihovny je nutné mít vypnuté Ar-

duino IDE. Pokud vše proběhlo správně měla by se knihovna zobrazit v menu Scetch/Import Library menu. (Pozn. pokud využíváte staženou knihovnu – bude zřejmě nutné mírně sáhnout do kódu kvůli chybě při překladu, pokud využijete knihovnu přiloženou na CD je již tento problém vyřešen). Podrobněji je popsán proces konfigurace knihovny v příloze Uživatelský manuál.

5.1.3 Příprava GSR senzoru

GSR senzor se skládá ze dvou elektrod (s připínacím suchým zipem), které je nutné k měřicí desce nejprve připojit pomocí šroubováku. Elektrody nejsou polarizované a nezáleží tedy na jejich prohození. Piny, na které se mají dráty od elektrod připojit jsou vidět na následujícím obrázku 5.2. Senzor funguje jako Ohmmetr, protože měří elektrický odpor materiálu. Před samotným připnutím na ruku je vhodné elektrody pomazat vodivým gelem. Elektrody se připínají na spodní stranu článků prstů na nedominantní ruce.




Obrázek 5.2: Schéma zapojování jednotlivých senzorů na e-Health

5.1.4 Příprava EKG senzoru

EKG senzor je složen ze tří elektrod (kladné, záporné a neutrální - obrázek 5.3 a obrázek 5.2 piny, které měří EKG). Ty je opět nutné připojit dráty k

měřicí desce. Pokud bychom měřili EKG samostatně zapojíme všechny elektrody podle obrázku 5.3, ale pokud současně chceme měřit i hodnoty GSR musíme vynechat neutrální elektrodu, jelikož při jejím zapojení nefunguje měření GSR (Zjištěno pokusem a následně potvrzeno v dokumentaci, podrobněji popsáno v poznátcích z měření). Proto zapojíme pouze kladnou a zápornou elektrodu a elektrody (odlepíme ochranný plast) přilepíme na místa znázorněná na obrázku 5.3 (kladnou na stejné místo, ale zápornou místo neutrální elektrody).



Obrázek 5.3: Zapojení elektrod EKG

5.1.5 Nahrání programu pro měření

Pokud již máme vše připraveno, nic nám nebrání k nahrání programu do mikroprocesoru arduina. To provádíme pomocí Arduino IDE. Abychom vyzkoušeli správné napojení knihovny e-Health vybereme některý z příkladových projektů (GSR/EKG) této knihovny a nahrajeme ho do Arduina.


5.2 Získaná data

Data byla měřena vzorkovací rychlostí cca 100 vzorků/s (nebyla nastavena přesná rychlost, ale je experimentálně přibližně ověřena (bohužel jsem zjistil pozdě, že Arduino nabízí také časovač), ale první polovina měřených dat byla měřena rychlostí pouze 75 vzorků/s) – tato rychlost je dostatečná pro detekci QRS komplexů v EKG signálu a pro GSR až nadbytečná (nicméně v některých výzkumech používají autoři rychlost až 200-360 vzorků/s).

5.2.1 Klidový stav

GSR


O hodnotách vodivosti kůže biosignálu GSR naměřených v klidovém stavu lze říci, že se pohybují v daném měření přibližně na stejné úrovni v rozmezí $2 \mu\text{S}$ a většinou po delší době spíše klesají. Avšak nelze globálně říci, že při dalším měření jsou hodnoty vodivosti přibližně stejné. Existují jedinci, kteří mají hodnoty v jiném měření značně vyšší či nižší než při předchozím měření. Na obrázku 5.4 je k ilustraci graf hodnot jednoho z měřených subjektů (více grafů je k prohlédnutí v příloze).



Obrázek 5.4: Graf vodivost kůže pro klidový stav

EKG(HR)

Hodnoty klidového HR vypočítaného z EKG pomocí metody počítání čtverců (přibližně 10 hodnot, které jsou zprůměrovány v intervalu 10s) se u většiny měřených subjektů pohybují kolem 60-70 tepů/min. Mezi dílčími hodnotami HR měřených subjektů většinou nedochází v intervalu 10s k výraznému navýšení, ale u některých dochází bez známé příčiny (mohlo jít např. o chybu v měření) ke skoku o cca 15 tepů/min po dobu např. dvou QRS komplexů a následnému opětovnému snížení na průměrnou hodnotu (graf na obrázku 5.5).




Obrázek 5.5: Graf srdečního tepu pro klidový stav

5.2.2 Stimulovaný stav

GSR

Hodnoty vodivosti kůže biosignálu GSR při stimulovaném stavu jsou však vysoce individuální. U většiny jedinců v příslušných scénářích dosahují naměřené hodnoty výraznějšího nárůstu oproti klidovému stavu. Nicméně někteří jedinci vykazují téměř shodné hodnoty jako při klidovém stavu bez vý-

raznějšího nárůstu. Tento stav lze přikládat k jejich nedostatečné stimulaci, protože brali měření příliš lehkovážně či se nesnažili dosáhnout co nejlepšího výsledku. Jako nejlepší stimulační scénáře se ukázaly počítání na čas a mini-hra. Zároveň lze na scénáři minihry pozorovat korelaci s nejvyšším dosaženým výsledkem (čas zaznamenan) a nejvyšší hodnotou GSR. Toto tvrzení dokládá obrázek číslo 5.6. Dále také korelace délky hry a rostoucí GSR. Naopak nejhorších stimulačních výsledků dosahuje promítání obrázků (tento scénář by byl zřejmě vhodnější pokud bychom měřili biosignál EEG a emoce).




Obrázek 5.6: Graf vodivosti kůže pro stimulovaný stav

EKG(HR)

Intuitivně opět platí, že při stimulovaných činnostech dochází také ke zvyšování hodnot HR. Orientačně se hodnoty pohybují mezi 65-90 tepy/min a globálně lze tedy říci, že při stimulovaných činnostech je průměrná hodnota tepu vyšší. Tento stav lze logicky odůvodnit tím, že při stimulovaném měření je od testovaného subjektu vyžadována činnost, či soustředění oproti klidovému měření. Nicméně průběh získaných hodnot není rozhodně triviální a jednoznačně. Protože průběhy hodnot jsou pro jednotlivá měření většinou rozdílné jak v rámci jednoho testovaného subjektu tak v rámci množiny všech

testovaných subjektů. Na obrázku číslo 5.7 je znázorněn graf srdečního tepu pro scénář hraní minihry.



Obrázek 5.7: Graf srdečního tepu pro stimulovaný stav

5.3 Získané příznaky

5.3.1 Pouze z GSR

Hodnoty příznaků jednoho z testovaných subjektů získaných pouze z vodivosti kůže měřené po intervalech 10 sekund jsou popsány v tabulce 5.1. Řádky symbolizují jednotlivé příznakové vektory, které byly vybrány jako typické pro dané klasifikační třídy a sloupce tedy znázorňují jednotlivé příznaky. První sloupec uvádí průměrnou hodnotu signálu, vypočtenou odečtením minimální hodnoty od všech hodnot v intervalu a jejich aritmetickým průměrem. Druhý příznak je poměr druhé části hodnot (jejich součtu) ku celkovému součtu. Ve třetím sloupci je rozdíl maximální hodnoty a minimální.

Dalším příznakem je rozdíl aktuální průměrné hodnoty ku předchozí (tedy

nárůst/pokles od předchozího intervalu. A poslední příznak udává dobu nárůstu od minima k maximu vydělenou 5 (aby neměl tento vstupní neuron příliš velkou váhu vůči ostatním). Pokud rozdíl maxima a minima je menší než 1 je tato hodnota automaticky 0.

mean	secH/Sum	max-min	acM-Prev	raise T	S	B
0.24317889	0.18602839	0.71144676	0.14079717	0.0	0	1
0.21152839	0.39304015	0.5040512	-0.0316505	0.0	0	1
0.14205794	0.4263915	0.2840681	-0.06947045	0.0	0	1
0.078813784	0.50103116	0.18835068	-0.06324416	0.0	0	1
0.100195006	0.67007613	0.26357746	0.021381222	0.0	0	1
0.09146426	0.3951485	0.22690296	-0.34930784	0.0	0	1
0.14927891	0.6042585	0.35103512	0.05781465	0.0	0	1
0.27211487	0.26661265	0.5510874	-0.8167454	0.0	0	1
0.690901	0.6736814	1.3907089	-0.15440196	1.348	0	1
0.49430653	0.52505654	1.1343508	-0.19659445	1.546	0	1
0.5071975	0.80999213	1.4716825	0.012890965	0.798	0	1
1.0888603	0.6052276	1.7426453	0.9395814	0.918	1	0
0.84530294	0.5583733	1.499836	0.57318807	0.968	1	0
1.0073631	0.8344352	1.9629965	0.63160634	0.766	1	0
0.6846186	0.81450564	1.3568993	0.4421251	1.264	1	0
1.140173	0.6044227	1.8610706	0.45555437	1.936	1	0
1.0538138	0.79816073	2.2511826	0.7842461	1.728	1	0
0.9089144	0.5783867	1.9989471	0.6596316	0.464	1	0

Tabulka 5.1: GSR příznaky jednoho z testovaných subjektů, které představují jeho trénovací dataset

Šestý a sedmý sloupec tabulky naznačuje hodnotou 1 na jakou klasifikační třídu bude příznakový vektor trénován (S - stres, B - baseline). Třídy příznakového vektoru byly zvoleny na základě informací získaných ze souvisejících výzkumů, kde stresové situace byly popisovány vyšší hodnotou GSR a klidové hodnotou nižší a také na základě informací získaných od testovaných subjektů. Nicméně jde pouze o experimentální klasifikaci (ve skutečnosti nemusejí vektory odpovídat stresu, ale mohou naznačovat, některé závislosti příznaků na testovaných situacích).

5.3.2 Pouze z HR

Příznaky získané pouze ze srdečního tepu jsou zobrazeny v tabulce 5.2. Konkrétně tedy průměrná hodnota srdečního tepu na intervalu 10s vydělená 60 (standardní klidový tep), transformovaná průměrná hodnota srdečního tepu – odečteno minimum od všech hodnot a z nich vytvořen průměr a posledním příznakem je rozdíl srdečního tepu v aktuálním intervalu oproti předchozím 10s. Opět jsem zde při rozhodování, které třídě bude daný vektor odpovídat uplatnil znalosti získané z výzkumů či pocitů testovaných subjektů.

Mean / 60	Transf mean	Ac - prev	S	B
1.181	13.053237	5.385048	1	0
1.516	9.625237	20.200294	1	0
1.2512	16.096712	6.9306564	1	0
1.275906	18.045912	7.2172394	1	0
1.0789116	7.1257524	-3.6320724	0	1
1.091605	4.7063737	-2.4604263	0	1
1.0733156	4.6128016	-9.015152	0	1
1.0991544	5.9118614	-2.9768295	0	1
1.0478256	2.0190735	-12.738792	0	1
1.04748005	2.8995156	0.2697487	0	1

Tabulka 5.2: HR příznaky jednoho z testovaných subjektů, které představují jeho trénovací dataset

5.3.3 Oba biosignály

Závislost příznaků získaných z obou biosignálů současně není příliš dobře patrná, nicméně jakožto stresové vektory byly experimentálně stanoveny ty vektory, kde zde byl patrný jak nárůst průměrné hodnoty GSR, tak i průměrné hodnoty srdečnímu tepu jak oproti předchozímu intervalu tak velikostí.

5.4 Poznatky z měření

Během měření jsem vypořádal několik důležitých poznatků, které by mohly být užitečné pro případné budoucí navazující výzkumné projekty zabývající se podobnou problematikou. Shrnuj je do následujících bodů.

GSR M	GSR %scd	GSR M-m	GSR Ac-P	GSR Raise	HR M/60	HR Trans	HR Ac-P	S	B
0,42	0,37	0,72	-0,08	0,00	1,03	1,74	-3,46	0	1
0,32	0,27	0,68	-0,09	0,00	1,13	5,31	6,10	0	1
0,50	0,31	0,97	0,07	0,00	1,05	1,36	-1,46	0	1
0,26	0,39	0,62	-0,03	0,00	1,05	1,78	-2,22	0	1
0,17	0,40	0,32	-0,09	0,00	1,03	1,46	-1,17	0	1
1,38	0,85	3,52	0,88	1,22	1,25	11,77	9,98	1	0
0,92	0,67	1,77	0,44	1,46	1,27	10,31	9,69	1	0

Tabulka 5.3: Příznaky pro oba biosignály zároveň od jednoho z testovaných subjektů

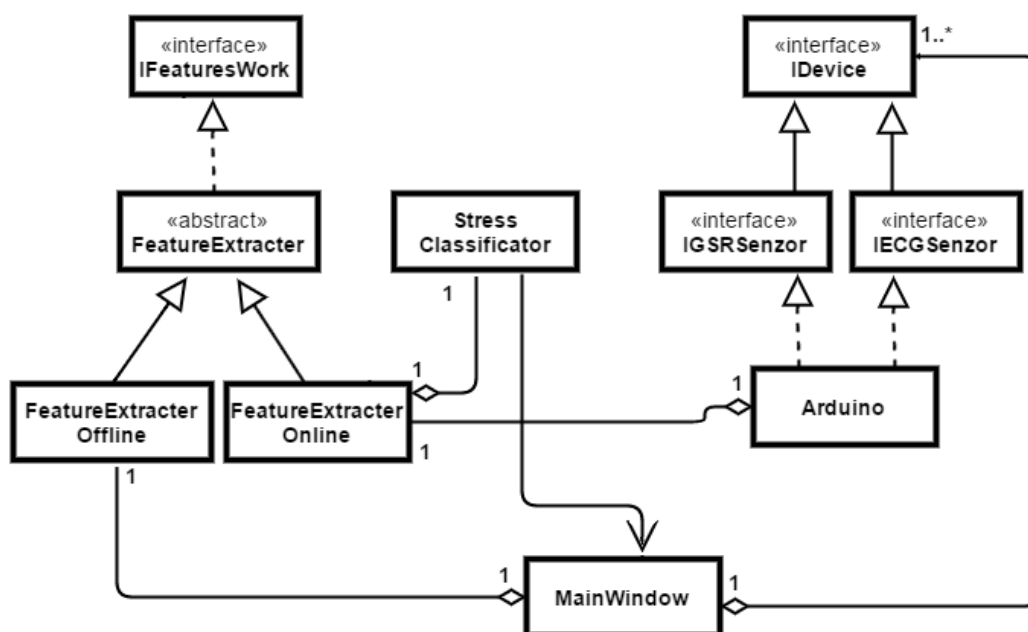
- Chyba při měření GSR a EKG současně při použití měřicí desky** - Pokud budeme chtít měřit současně GSR a EKG se všemi třemi zapojenými elektrodami budeme jako hodnotu GSR stále dostávat hodnotu -1 (nakonec jsem se dočetl i na fóru autorů). Tento problém jsem zmírnil zapojením pouze kladné a záporné elektrody. To však mělo za následek „zašumění“ hodnot EKG. Ty však pro detekci QRS komplexů stále stačily. Někdy bohužel, ale nefunguje ani tento postup. Doporučuji si nejprve před měřením zkontrolovat funkčnost EKG například pomocí sériového plotteru v Arduino IDE a pokud neuvidíme typickou EKG křivku omezíme se pouze na měření GSR či EKG.
- Problém s výrazně suchou / velmi vlhkou kůží** - Má-li testovaný subjekt výrazně suchou kůží jsou jeho hodnoty vodivosti kůže blízké nule či nejdou změřit (-1). Namažeme-li elektrody vodivým gelem, zvýšíme tím hodnotu vodivosti, ale pokud má subjekt extrémně suchou kůží nepomůže ani toto opatření. Naopak při velmi vlhké kůži jsou hodnoty vodivosti vysoké a značně kolísají a je tedy obtížné u takového jedince změny při stimulaci detekovat, protože k výrazným změnám dochází i v klidové fázi.
- Problém při hýbání s prsty / s rukou, na které jsou umístěny elektrody GSR** - Dojde-li během měření k pohybu prstů či ruky v naměřeném datasetu se tato činnost může projevit náhlým razantním zvýšením či snížením hodnot. Je tedy žádoucí měřený subjekt poučit, aby rukou hýbal co nejméně a nejlépe si ji někam položil. Je dobré ho stále kontrolovat, jestli na toto opatření časem nezapomněl.
- Zvýšení hodnot při přechodu na novou činnosti** - Pokud testovaný subjekt vykonává novou činnost, kterou ještě nedělal nebo přejde

na jinou činnost dojde k nárůstu hodnot biosignálů. Nebylo by tedy na škodu občas obměnit některou z činností za novou (např. u minihry).

- **Nárůst hodnot při časově omezených činnostech** - Stejně jako nové činnosti má na nárůst hodnot vliv také časový limit (u některých i délka činnosti).
- **Korelace vysoké hodnoty GSR s dosaženým score ve hře**
- **Samovolný pokles vodivosti** - Po delší době dochází k navyknutí na vykonávanou činnost, či k uklidnění a tím k poklesu vodivosti kůže

6 Implementace

V této kapitole se pokusím popsat, jak jsem navržený systém detekce implementoval v programovacím jazyce Java 1.8 za použití knihoven Java Swing a Neuroph. UMLdiagram zobrazující nejdůležitější třídy této aplikace je zobrazen na obrázku 6.1.



Obrázek 6.1: UML diagram pro nejdůležitější třídy aplikace

6.1 Sběr dat z Arduina

6.1.1 Třída pro příjem dat – Arduino.java

Nejprve bylo zapotřebí vytvořit třídu pro příjem dat z měřicího senzoru (v našem případě z Arduina komunikující po sériovém portu). Tuto práci obstarává třída s intuitivním názvem Arduino. Třída musí implementovat rozhraní IDevice, IGSRSensor a IIEKGSenzor, která následně popíší.

Rozhraní IDevice

- Obsahuje základní metody, které musí bezpodmínečně mít každá třída reprezentující zařízení

- **Metody:**

- `public boolean initialize()` – metoda pro inicializaci zařízení, návratová hodnota udává, zda inicializace proběhla úspěšně
- `public void close()` – metoda pro ukončení spojení mezi senzorem a PC
- `public void sendMsg(String msg, boolean isStart)` – metoda pro zasílání zpráv senzoru
- `public boolean isFull()` – kontrolní metoda, zkoumající, zda již není buffer pro naměřené hodnoty plný
- `public void startFeatureExtractorOnline` – metoda spouštějící vlákno s online extraktorem příznaků
- `public void restartValues()` – metoda nastavující defaultní hodnoty
- gettery a settry

Rozhraní IGSRSensor

- Odděděno od rozhraní IDevice

- Navíc má metodu `float [] getGSR()` pro získání GSR hodnot z bufferu

Rozhraní IEKGSensor

- Odděděno od rozhraní IDevice

- Navíc má metodu `float [] getEKG()` pro získání EKG hodnot z bufferu

6.1.2 Ukládání do souboru

Pro další práci s hodnotami je nutné je nejprve uložit do souboru. Na kterém můžeme následně testovat navržené příznaky. Tuto činnost obstarává třída `FeatureExtractorOnline`. Nejprve jsou, ale hodnoty předzpracovány pomocí filtru `FIR` (implementován ve stejnojmenné třídě) a až pak jsou postupně zapisovány do souboru vybraného uživatelem.

6.1.3 FIR.java

Třída reprezentující filtr s konečnou impulzní odezvou.

6.2 Extrakce příznaků

Nyní se dostáváme k jedné z nejdůležitějších částí aplikace a tou jsou třídy umožňující extrakci příznaků. Protože online a offline extrakce, budou mít mnoho společných metod pro samotné získávání (nastavení) příznaků budou oba dědit třídu `FeatureExtractor`.

6.2.1 FeatureExtractor.java

Abstraktní třída obsahující všechny metody pro získávání příznaků. Na základě atributu `int featureFlag` rozhodne, které příznaky bude vytvářet.

GSR příznaky

Tyto příznaky vytváří pokud je `featureFlag` roven konstantě pro `GSR_SENZOR` či `BOTH_SENZORS`, která reprezentuje měření obou biosignálů naráz.

- Hlavní atributy:

- `float [] gsr` – naměřené hodnoty biosignálu GSR v intervalu posledních 10 sekund

- `float [] features` – pole s extrahovanými příznaky
- `float gsrMean` – normalizovaná průměrná hodnota GSR na intervalu 10 sekund
- `float gsrMax` – maximální hodnota GSR v intervalu
- `float gsrMin` – minimální hodnota GSR v intervalu
- `float gsrFirstHalf` – součet velikostí signálu GSR v prvních 5 sekundách
- `float gsrSecondHalf` – součet velikosti signálu GSR v druhých 5 sekundách

Hlavní metody:

- `protected void findGSRExtremes()` – metoda nalezne maximum a minimum biosignálu GSR v intervalu 10 sekund a nastaví příslušné atributy
- `protected void transformGSRValues()` – metoda odečte od všech hodnot signálu GSR jeho minimum a vypočte takto transformovanou průměrnou hodnotu a nastaví příslušné atributy
- `protected void createGSRFeatures()` – metoda vytvoří (nastaví) GSR příznaky

EKG(HR) příznaky

S těmito příznaky se pracuje pokud je `featureFlag` roven konstantě pro `ECG_SENZOR`, tedy měříme pouze biosignál EKG nebo opět `BOTH_SENZORS`, při měření obou.

- Hlavní atributy:

- `float [] ecg` – naměřené hodnoty biosignálu EKG v intervalu posledních 10 sekund
- `float [] heartRatio` – vypočítané hodnoty srdečního tepu v intervalu posledních 10 sekund (cca 10 - 20 hodnot)

- `float meanHeartRate` – průměrná hodnota srdečního tepu
- `float minHeartRate` – minimální hodnota srdečního tepu
- `float maxHeartRate` – maximální hodnota srdečního tepu
- `intt [] extreme_id` – indexy lokálních maxim ekg signálu – vrcholy QRS komplexů

Hlavní metody:

- `protected void findEcgExtremes()` – metoda nalezene lokální maxima signálu EKG – tedy vrcholy QRS komplexů a uloží je do pole `ecg_intervals`
- `protected void createECGFeatures()` – metoda vytvoří příznaky získané z EKG – metoda vytvoří příznaky získané z EKG
- `protected void setHeartRatio()` – metoda vypočítá hodnoty srdečního tepu na základě vzdálenosti mezi QRS komplexy, vypočítá z nich průměrnou hodnotu a uloží do příslušných atributů

Rozhraní IFeatureWork

- Obsahuje základní metody, které musí mít každá třída pracující s příznaky

Metody:

- `public int onlyFromGSRFeatures()` – pracuje pouze s GSR příznaky
- `public int onlyFromECGFeatures()` – pracuje pouze s ECG příznaky
- `public int fromBothFeatures()` – pracuje s oběma druhy příznaků

6.2.2 FeatureExtractorOffline.java

Třída, která je potomkem již zmíněné abstraktní třídy FeatureExtractor a implementuje rozhraní IFeatureWork. Jak již z názvu vyplývá tato třída pracuje offline s naměřenými dataseťmi biosignálů. Ze souboru vybraného uživatelem získává za pomoci přepsaných metod rozhraní IFeatureWork a zděděných metod třídy FeaturesExtractor příznakové vektory. Ty jsou metodou void addFeaturesToList() postupně přidávány do atributu featuresList. Takto projdeme celý vstupní soubor a výsledný seznam příznaků lze vykreslit do tabulky metodou atributu baselinePN public void createTable(ArrayList<Float []> rows, Object [] columnNames).

Hlavní atributy:

- BaselinePanel baselinPN – instance panelu pro vypisování hodnot a vykreslení tabulky s příznaky
- ArrayList<Float []> featuresList – seznam s příznaky pro manipulaci s nimi

6.2.3 FeatureExtractorOnline.java

Opět třída, která je potomkem třídy FeatureExtractor a implementuje rozhraní IFeatureWork. Od předchozí třídy se liší tím, že kromě získávání příznaků umožňuje také zápis měřených hodnot do souboru či detekci situací za pomoci instance třídy StresClasificator (popsáno v kapitole klasifikace situace) a proto funguje jako vlákno (implementuje rozhraní Runnable).

Hlavní atributy:

- `IGSRSensor gsrSensor` – senzor měřící GSR
- `IECGSensor ecgSensor` – senzor měřící EKG
- `StressClasificator strClas` – instance stresového klasifikátoru pro detekci situace za posledních 10 sekund

Získávání hodnot z měřícího senzoru

Třída má k dispozici referenci na konkrétní senzor(y), kterým je měřen biosignál(y). Jednou z metod `setValues()`, vždy čeká až příslušný senzor nastaví hodnotu `isFull` na `true`. Tomu se děje právě tehdy, když naměřil 1000 dalších hodnot odpovídajících posledním 10 sekundám měření. Tyto hodnoty následně předzpracuje pomocí již zmíněného filtru FIR a pokud si to uživatel přeje, tak hodnoty dále ukládá do souboru. Na takto předzpracované hodnoty používá metody zděděné třídy `FeatureExtractor` pro nastavení příznaků.

Předání hodnot k detekci

Při aktivním módu detekce jsou výsledné vektory příznaků klasifikovány pomocí třídy `StressClasificator`.

6.3 Klasifikace situací

Ke klasifikaci situace slouží již několikrát zmíněná třída `StressClassificator.java`, která byla vytvořena za pomoci knihovny `Neuroph` ve verzi 2.92.

6.3.1 `StressClasificator.java`

Třída klasifikující zkoumaný vektor (a tím i činnost v posledních 10 sekundách) jako klidový nebo naopak vektor, který by mohl být příznačný pro stresovou situaci.

Hlavní atributy:

- `MultiLayerPerceptron perceptron` – instance třívrstvého perceptronu
- `int featureModeFlag` – celé číslo označující aktivní měřicí mód

Hlavní metody:

- `public void trainNeuralNetworkFromFile(String trainDSName)` – metoda natrénující neuronovou síť pomocí trénovacího datasetu
- `public void testNeuralNetwork(Dataset testSet)` – metoda testující neuronovou síť pomocí testovacího datasetu
- `public int testFeatureVectore(FeatureVector fv)` – metoda testující konkrétní vektor příznaků – návratová hodnota udává třídu do, které byl síť zařazen

6.4 Grafické uživatelské rozhraní

Grafické uživatelské rozhraní aplikace je tvořeno především třídou s intuitivním názvem `MainWindow` a dále třídami reprezentující některé scénáře měření. Jak již bylo uvedeno v úvodu této kapitoly bylo vytvořeno za pomoci knihovny Java Swing.

6.4.1 Hlavní okno

Na základě rozhodnutí uživatele je vytvořeno okno, jehož vzhled odpovídá aktuální vybrané činnosti, kterou chce provádět. Je tedy dostupné ve 3 různých modifikacích (práce s ním je uvedena v příloze Uživatelská dokumentace).

Offline mód

Pokud uživatel vybere z počáteční nabídky mód offline bude vytvořeno toto okno. Pro práci v tomto módu nemusí být připojen žádný měřicí senzor.

Je určen především pro extrakci příznaků, vytváření souboru s trénovacími vektory či klasifikaci příznaků získaných ze souboru. Umožňuje volbu aktuální testované osoby, vstupních a výstupních souborů a také případnou filtraci hodnot pomocí filtru FIR.

Online mód

Tento mód je k dispozici po zvolení nabídky online. Použijeme ho tehdy, pokud ještě nemáme od testovaného subjektu k dispozici žádné trénovací vektory a nemůžeme tedy ještě situace detekovat. Při tomto módu už je nutné mít aktivní některý z měřících senzorů (jinak nebude možné začít měřit). Slouží tedy pro měření prvních datasetů od dané osoby. Hodnoty vodivosti kůže (z GSR) a napětí (z EKG) jsou zároveň vypisovány v dolním panelu po intervalu 0,25s. Stejně jako u předchozího módu je zde volba aktuální měřené osoby, výstupního souboru a také možnost zvolení některého ze scénářů měření.

Detekční mód

Detekční mód získá uživatel vybráním volby detection z počáteční nabídky. Opět je zde nutnost aktivního senzoru a bez něj nebude možné spustit měření. Tento mód volíme tehdy, pokud již máme připravený soubor s trénovacími vektory či uloženou celou natrénovanou neuronovou sít'. Funkcí tohoto módu je samozřejmě klasifikace aktuálního získaného vektoru příznaků (tedy posledních 10 sekund měření). Uživatel může zvolit, zda chce také současně ukládat naměřené hodnoty do souboru a opět vybírá aktuální testovanou osobu či jeden z dostupných scénářů měření. Naměřené hodnoty jsou opět zobrazovány v dolním panelu.

6.4.2 Okna pro scénáře

Okno, které se zobrazí pokud je uživatel v online či detekčním módu, vybere z nabídky některý ze scénářů a stiskne tlačítko start scenario.

Okno pro promítání obrázků

Otevře se pokud je vybrán scénář s názvem Image showing. Okno obsahuje pouze panel, do kterého jsou vykreslovány obrázky a vlákno, kterým jsou obrázky měněny po 10 sekundách.

Okno pro počítání příkladů

Při volbě scénáře s názvem Math dojde k zobrazení okna pro počítání příkladů. Centrální panel obsahuje tři textová pole. Jedno s náhodně generovanými příklady, druhé pro zadávání vlastního výsledku příkladu a další textové pole určuje, zda je odeslaný výsledek správně či nikoliv. Jsou zde ještě dvě další textové pole, které zobrazují odpočítávání času (jedno čas celkový a druhé čas na příklad). Na celou úlohu je jedna minuta času a na každý příklad sedm sekund.

Okno s registračním formulářem

Okno s registračním formulářem se testovanému subjektu zobrazí při vybrání scénáře s názvem Login. Cílem testovaného subjektu je registrovat se jednoduchým formulářem se třemi textovými poli (pro jméno a dvakrát heslo) a jedním tlačítkem do nějakého systému. Pokud neodpovídá formát uživatelského jména či hesla nebo je zde nějaký jiný problém je testovaný subjekt informován dialogovým oknem. Pravý panel obsahuje textové pole, které odpočítává jednu minutu a pokud se do té doby uživatel nezaregistruje, dojde k ukončení okna.

7 Dosažené výsledky

Aplikace byla testována celkem na 10 testovaných subjektech ve věku 21 – 54 let. Z toho byly 3 ženy a 7 mužů. Největší část testovaných subjektů byla ve věku 21 - 25 let. Každému subjektu byly během jednoho až dvou měřících dnů (podle jeho časových možností) naměřeny hodnoty biosignálů při popsání scénářích měření. Všem subjektům byly naměřeny hodnoty vodivosti kůže (z GSR), ale pouze 5 z nich hodnoty biosignálu EKG (z toho pouze u 3 měřeno současně s GSR). Oba biosignály nebyly měřeny současně u všech subjektů z důvodu špatné kompatibility těchto dvou senzorů na měřícím senzoru e-Health platform (již popsáno v kapitole poznatky z měření).

Při druhé fázi se již měřilo za současné klasifikace příznakových vektorů pomocí neuronové sítě. Konkrétně Třívrstvého Perceptronu, který byl naučen pro každý subjekt zvláště jeho vlastními příznakovými vektory. V této fázi byla opět měřena klidová hodnota (baseline), ale následně byl testovaný subjekt stimulován pouze scénáři, které dosáhly v předchozím měření nejlepších výsledků (byly zde vidět rozdíly oproti baseline), ale delší dobu. Obecně lze říci, že pouze počítáním a minihrou. Aby bylo možné hodnotit úspěšnost klasifikátoru bylo nutné zaznamenávat názor testovaného subjektu na dané měřené intervaly (tedy zda situaci považuje spíše za klidovou či blízkou stresu).

Důležitým poznatkem však je, že žádný z testovaných subjektů nehodnotil stimulované situace jako typicky stresové, ale spíše, jako situace kdy byl nervózní či kdy po něm bylo vyžadováno nejvíce soustředění. Nebylo by tedy na škodu vymyslet nějaký náročnější scénář měření. Takovýmto scénářem by mohla být například detekce stresu u hráčů hrajících šachy (profesionálněji) či subjekt měřit při nějaké důležitější práci.

Dosažené výsledky se však mírně různí v závislosti na použitých příznacích (tedy zda bylo měřeno pouze GSR, pouze HR či oba biosignály) i na testovaných subjektech. Proto si tyto výsledky rozdělíme do 3 tříd a jednotlivě je zhodnotíme.

7.1 Výsledky pouze pro GSR

Výsledky získané pouze pomocí biosignálu GSR se ukázaly při testování jako poměrně vhodné a úspěšné. Nicméně existují jedinci, pro které je tento způsob detekce absolutně nevhodný, konkrétně pro jedince s velmi suchou / vlhkou pokožkou.

Celkovou úspěšnost klasifikátoru za použití pouze biosignálu GSR udává tabulka 7.1. Sloupec s názvem "Klid Úsp" udává úspěšnost klasifikátoru pro klidový stav (baseline), tedy kolik měřených intervalů bylo vyhodnoceno správně (podle názoru testovaného subjektu) z celkového počtu intervalů. Další sloupec znázorňuje tuto úspěšnost přepočtenou na procenta. Intuitivně je tomu tak v následujících dvou sloupcích, které ale představují úspěšnost klasifikátoru pro stimulovaný stav.

Č. subj.	GSR Klid Úsp	Klid % Úsp	GSR Stimul Úsp	Stimul % Úsp
1	12/18	0,67	38/82	0,46
2	13/17	0,76	58/75	0,77
3	14/16	0,88	62/76	0,82
4	15/17	0,88	66/78	0,85
5	11/12	0,92	48/61	0,79
6	14/16	0,88	54/65	0,83
7	11/13	0,85	44/52	0,85
8	15/19	0,79	58/79	0,73
9	12/14	0,86	58/67	0,87
10	13/16	0,81	49/63	0,78
Celkem	130/158	0,83	535/698	0,77

Tabulka 7.1: Výsledky klasifikátoru pracující pouze s biosignálem GSR

7.1.1 Klidový stav

O úspěšnosti klasifikátoru při klidových situacích lze říci, že dosahuje celkem dobrých výsledků. Většinu situací hodnotí správně jako klidové, ale také se zde mohou místy objevovat krátké úseky, ve kterých chybně klasifikuje situaci jako stresovou z důvodu přísně nastavených trénovacích datasetů nebo špatně zvolených příznaků. V tabulce 7.2 můžete vidět výsledky z klidového měření jednoho z testovaných subjektů. Kromě již dříve popsaných příznaků v prvních pěti sloupcích je zde sloupec s názvem Class, který symbolizuje na kterou třídu byl interval touto aplikací klasifikován a poslední sloupec s názvem User Opinion, který ukazuje jak situaci vnímal testovaný subjekt (1 odpovídá stresové situaci a 0 odpovídá klidové situaci).

GSR Mean	GSR %sec	GSR max-min	GSR Ac-Prev	GSR Raise	Class	User Opinion
0,41	0,24	1,13	0,18	0,03	0	0
0,26	0,32	0,68	-0,15	0,00	0	0
0,54	0,77	1,25	0,28	1,69	0	0
0,39	0,52	0,83	-0,15	0,00	0	0
1,25	0,39	1,71	0,86	1,10	1	0
0,50	0,26	1,16	-0,75	0,33	0	0
0,52	0,75	1,09	0,02	1,24	0	0
0,56	0,47	1,10	0,05	1,09	0	0

Tabulka 7.2: Příklad testování klasifikace příznakových vektorů situací získaných při klidovém měření od jednoho ze subjektů pouze pomocí GSR

7.1.2 Stimulovaný stav

Výsledky klasifikátoru související se stimulovaným stavem již nejsou tak přesné jako v předchozím případě. Příčinou by mohla být nedostatečná stimulace subjektů, jelikož většina testovaných subjektů nevnímala žádné situace jako typicky stresové. Zvolené příznaky byly také příliš přísné a tedy docházelo k nesprávnému klasifikování klidových situací (určené subjektem) na stresové. Tabulka 7.3 znázorňuje testování při scénáři hraní minihry.

GSR Mean	GSR %sec	GSR max-min	GSR Ac-Prev	GSR Raise	Class	User Opinion
0,94	0,16	2,77	-0,13	0,08	0	0
0,54	0,29	1,35	-0,40	0,59	0	0
1,21	0,87	3,06	0,66	1,53	1	0
0,79	0,21	1,98	-0,42	0,09	0	0
0,75	0,22	2,45	-0,04	0,52	0	0
0,52	0,88	1,83	-0,23	0,74	0	0
0,60	0,84	1,75	0,08	1,33	0	0
1,89	0,66	4,14	1,29	0,89	1	0
2,30	0,74	4,73	0,42	1,65	1	1
1,49	0,52	3,43	-0,82	0,22	0	0
1,42	0,33	3,96	-0,07	0,03	0	0
0,49	0,36	1,09	-0,93	0,03	0	0

Tabulka 7.3: Příklad testování klasifikace příznakových vektorů situací získaných při stimulované činnosti od jednoho ze subjektů pouze pomocí GSR

7.2 Výsledky pouze pro HR

Výsledky klasifikátoru pracující pouze s příznaky HR bohužel dosahují nižší úspěšnosti než tomu bylo u příznaků pouze s GSR. Jedním z důvodů může být že mnou navržená metoda pro detekci QRS komplexů v EKG signálu nefungovala vždy úplně správně a proto vypočítané hodnoty HR nemusely být přesné. Tyto výsledky jsou shrnuty v tabulce číslo 7.4.

Č. Subj.	HR Klid Úsp	Klid % Úsp	HR Stimul Úsp	Stimul % Úsp
1	13/18	0,72	55/75	0,73
2	13/17	0,71	53/76	0,70
3	11/14	0,79	56/74	0,76
4	15/17	0,88	52/70	0,74
5	9/14	0,64	38/62	0,61
Celkem	60/80	0,75	254/357	0,71

Tabulka 7.4: Výsledky biosignálu pracující pouze s biosignálem HR

7.2.1 Klidový stav

Na tabulce 7.5 je znázorněno testování klidového stavu za použití pouze biosignálu HR.

HR Mean / 60	HR Transformed	HR Ac-Prev	Class	UO
1,0256724	1,7430569	-2,1251945	0	0
1,1272815	5,312951	6,096546	1	0
1,0575373	2,8357902	-4,184658	0	0
1,1945508	6,5995097	8,220806	1	0
1,071364	1,067553	-7,391197	0	0
1,0470554	1,3649832	-1,4585228	0	0
1,0913991	3,1600013	2,6606255	0	0
1,0539687	1,7797828	-2,2458267	0	0
1,0345458	1,45631	-1,1653748	0	0

Tabulka 7.5: Příklad testování klasifikace příznakových vektorů situací získaných při klidovém měření od jednoho ze subjektů pouze pomocí HR

7.2.2 Stimulovaný stav

Úspěšnost klasifikátoru měřícím subjekt ve stimulovaném stavu je opět nižší než při klidovém stavu. Na tabulce 7.6 můžete vidět příklad testování jednoho ze subjektů na scénáři počítání na čas.

7.3 Výsledky pro oba biosignály

Tyto výsledky nemůžeme považovat za příliš relevantní, jelikož tímto způsobem byly měřeny pouze u tří testovaných subjektů. Více jedinců nebylo možné římto způsobem změřit z důvodu nevhodně pracujícího měřícího senzoru (již vysvětleno dříve v kapitole poznatky z měření). Nicméně u těchto subjektů se jeví použití obou biosignálů zároveň jako nejméně úspěšné. Nejspíše z důvodu nekorelujících vysokých hodnot GSR s vysokými hodnotami HR. Pokud bychom chtěli použít oba biosignály zároveň bylo by vhodné použít jiný měřící senzor pro biosignál EKG či měřit přímo hodnoty HR. Výsledky tohoto módu shrnuje tabulka 7.7.

HR Mean / 60	HR Transformed	HR Ac-Prev	Class	UO
1,1312772	1,8318541	1,9630585	0	0
1,1255203	1,4864379	-0,3454132	0	0
1,2032658	6,151171	4,6647263	1	1
1,0960281	1,6312467	-6,4342575	0	0
1,1202923	2,1440036	1,4558487	0	0
1,1520917	4,0519743	1,9079666	1	0
1,134536	3,9417164	-1,0533447	0	0
1,1796082	12,702034	2,704338	1	0
1,1578113	2,4232135	-1,3078232	0	0
1,1566947	1,3247552	-0,0669937	0	0
1,2395889	12,300865	4,973648	1	0
1,111087	1,5916871	-7,7101135	0	0
1,2328908	16,898983	7,308235	1	0

Tabulka 7.6: Příklad testování klasifikace příznakových vektorů situací získaných při stimulované činnosti od jednoho ze subjektů pouze pomocí HR

Č. Subj.	Oba Klid Úsp	Klid % Úsp	Oba Stimul Úsp	Stimul % Úsp
1	12.17	0,71	40/65	0,62
2	11.18	0,61	43/70	0,61
3	14/16	0,86	46/68	0,68
Celkem	37/51	0,73	129/203	0,64

Tabulka 7.7: Zhodnocení klasifikátoru pracujícího s oběma sadami příznaků

7.3.1 Klidový stav

Klidový stav lze i pomocí obou biosignálů zároveň poměrně dobře rozeznat. Příklad testování jednoho ze subjektů je na tabulce 7.8.

7.3.2 Stimulovaný stav

Na tabulce 7.9 můžeme vidět testované vektory příznaků při hraní minihry.

GSR Mean	GSR %scd	GSR Mx-Mi	GSR Ac-Pr	GSR Raise	HR M/60	HR Trf	HR Ac-Pr	C	O
0,42	0,37	0,72	0,24	0,00	1,03	1,74	-21,57	0	0
0,32	0,27	0,68	-0,09	0,00	1,13	5,31	6,10	0	0
0,25	0,50	0,62	-0,07	0,00	1,06	2,84	-4,18	0	0
0,46	0,64	1,12	0,22	1,44	1,19	6,60	8,22	1	0
0,43	0,30	1,20	-0,03	0,02	1,07	1,07	-7,39	0	0
0,50	0,31	0,97	0,07	0,00	1,05	1,36	-1,46	0	0
0,29	0,31	0,55	-0,20	0,00	1,09	3,16	2,66	0	0
0,26	0,39	0,62	-0,03	0,00	1,05	1,78	-2,25	0	0
0,17	0,40	0,32	-0,09	0,00	1,03	1,46	-1,17	0	0

Tabulka 7.8: Příklad testování klasifikace příznakových vektorů situací získaných při klidovém měření od jednoho ze subjektů za použití obou biosignálů

GSR Mean	GSR %sec	GSR Mx-Mi	GSR Ac-Pr	GSR Raise	HR Mean	HR Trf	HR Ac-Pr	C	O
1,09	0,56	1,80	0,75	0,42	1,08	5,64	1,63	1	0
0,35	0,68	0,86	-0,74	0,00	1,08	2,65	0,33	0	0
0,45	0,62	1,17	0,10	0,62	1,16	3,74	4,82	0	0
0,51	0,79	1,40	0,06	0,41	1,20	4,99	2,25	0	0
0,47	0,24	1,08	-0,04	0,09	1,12	4,10	-4,72	0	0
0,56	0,85	1,54	0,08	1,06	1,10	1,58	-1,60	0	0
1,07	0,73	2,19	0,51	1,58	1,12	2,94	1,36	1	0
0,78	0,32	1,84	-0,29	0,02	1,20	3,10	5,17	0	0
0,60	0,34	1,10	-0,18	0,73	1,14	2,36	-3,84	0	0
0,71	0,70	1,96	-0,08	1,14	1,13	1,83	1,96	0	0
1,34	0,61	2,20	0,63	1,66	1,12	1,45	-0,38	1	1
0,52	0,28	1,43	-0,82	0,15	1,15	3,68	1,25	0	0
0,79	0,70	1,95	0,27	0,95	1,10	1,63	-2,99	0	0
0,36	0,24	0,77	-0,43	0,00	1,12	2,14	1,46	0	0

Tabulka 7.9: Příklad testování klasifikace příznakových vektorů situací získaných při stimulované činnosti od jednoho ze subjektů za použití obou biosignálů

8 Závěr

Prvním cílem této práce bylo prostudování literatury týkající se detekce stresu pomocí biosignálů. Na základě těchto znalostí jsem provedl analýzu vhodných biosignálů. Po této analýze jsem se rozhodl použít jako hlavní zdroj příznaků biosignál GSR s doprovodnou účastí biosignálu HR vypočítaného z EKG pomocí metody počítání čtverců.

Dále jsem pro měření těchto biosignálů vybral Arduino s měřícím senzorem E-Health platform a vytvořil vlastní scénáře měření jak pro klidovou činnost tak pro činnosti stimulující testovaný subjekt. Také jsem navrhl vlastní sadu příznaků, která byla inspirována již provedenými souvisejícími výzkumy a navrhl metodu detekce stresových situací po desetisekundových intervalech pomocí třívrstvého perceptronu. Takto navržený systém jsem implementoval pomocí programovacího jazyka Java 1.8 a knihoven Java Swing pro vytvoření GUI a Neuroph pro práci s neuronovými sítěmi. Výsledná aplikace přijímá pomocí sériového portu naměřené biosignály z Arduina a dále je zpracovává a klasifikuje.

Navržená metoda detekce byla testována celkem na 10 subjektech (z toho 7 mužů a 3 ženy) a dosažené výsledky tohoto experimentu byly shrnuty v kapitole 7. Z těchto výsledků vyplývá, že stimulace subjektů nebyla dostatečná k vyvolání stresu jako takového nicméně tato metoda může být použita pro detekci situací, kdy je subjekt nervózní či je nejvíce psychicky vytížen. Tento poznatek může být základem pro budoucí výzkumy, které by mohly vést k navržení skutečného systému detekující stres. V porovnání s úspěšností jiných výzkumných týmů je však úspěšnost klasifikátoru cca o 10% horší. Nicméně alespoň jsem vyzkoušel praktickou realizaci této úlohy v našich podmínkách. Hlavní problém se kterým jsem se setkal byla nemožnost měření EEG a GSR současně pomocí měřícího senzoru e-Health platform. S tímto poznatkem bych pro případné budoucí související práce navrhoval zvolit jiný senzor měřící EEG či použít nějaký senzor, který měří rovnou HR. Případný zásah do kódu aplikace by při změně senzoru nebyl nikterak obtížný, protože aplikace již je na toto opatření částečně připravena.

Tato práce může mít přínos pro čtenáře, který se teprve začíná věnovat problematice detekce stresu za pomocí biosignálů, či pro případné navazující projekty. Nicméně dosažené výsledky nijak neposunuly současný výzkum a to je důkazem toho, že je zapotřebí se tomuto tématu stále věnovat a objevovat nové metody.

Použitá literatura

[1] Cohen, S., Kessler, R. and Gordon L. 1997. Measuring stress – A Guide for Health and Social, Scientists, Oxford University Press, ISBN: 9780195121209

[2] Bishop, Christopher (2006). Pattern recognition and machine learning. Berlin: Springer. ISBN 978-0-387-31073-2

[3] Subject-dependent biosignal features for increased accuracy in psychological stress detection, Dimitris Giakoumisa, Dimitrios Tzovarasa, George Hassapis, 2013, ISSN: 1071-5819

[4] Affect detection: an interdisciplinary review of models, methods, and their applications R. Calvo, S. D’Mello, 2010, ISSN: 1949-3045

[5] Toward machine emotional intelligence: analysis of affective physiological state R. Picard, E. Vyzas, J. Healey, 2001, ISSN: 0162-8828

[6] A fuzzy physiological approach for continuously modeling emotion during interaction with play technologies, R.L. Mandryk, M.S. Atkins, 2007, ISSN: 1071-5819

[7] Exploring the Use of Physiology in Adaptive Game Design, Shaomei Wu, Tao Lin, 2011, ISBN: 978-1-61284-458-9

[8] vědecký článek - A Stress Sensor Based on Galvanic Skin Response (GSR)

Controlled by ZigBeeMaría Viqueira Villarejo, Begona García Zapirain, and Amaia Méndez Zorrilla, Dostupné 10.4.2016 z [<http://www.sciencedirect.com/science/article/pii/S1071581912001760>]

[9] EEG Analysis for understanding stress based on affective Model basis function, Kazi Shahzabeen Rahnuma, Abdul Wahab, Norhaslinda Kamaruddin and Hariyati Majid, 2011, ISBN: 978-1-61284-843-3

[10] vědecký článek - Stress and EEG, Ssang-Hee Seo and Jung-Tae Lee, dostupné 22.4. 2016 z [http://cdn.intechopen.com/pdfs/10986/InTech-Stress_and_eeg.pdf]

[11] GEIST, B. Psychologický slovník. 2. vyd. Praha: Vodnář, 2000. 425 s. ISBN 80- 86226-07-7

[12] ATKINSON, Rita L.. Psychologie. Praha : Portál, 2003. ISBN 80-7178-640-3

[13] Neuronové sítě – přednáška, Ondřej Valenta, Václav Matoušek, dostupné dne 17.5. 2016 na adrese: [http://www.kiv.zcu.cz/studies/predmety/uir/predn/P5_NN/FThema5.pdf]

[14] Stress Detection in Computer Users Based on Digital Signal Processing of Noninvasive Physiological Variables, 2006, ISBN: 1-4244-0032-5 Jing Zhai, Armando Barreto

[15] Mental stress detection using heart rate variability and morphologic variability of EeG sinals, Costin, R.; Rotariu, C.; Pasarica, A., 2012, ISBN: 978-1-4673-1173-1

[16] The Emotions, chapter Physiology of Emotion, Studies in Emotion and Social Interaction. Cambridge:Cambridge, University Press, N. H. Frijda, 1986

[17] Feasibility study on driver's stress detection from differential skin temperature measurement, 2008, Yamakoshi, T.; Yamakoshi, K.; Tanaka, S.; Nogawa, M.; Park, S.B.; Shibata, M.; Sawada, Y.; Rolfe, P.; Hirose, Y., ISBN: 978-1-4244-1814-5

[18] Estimating Mental Stress Using a Wearable Cardio-Respiratory Sensor, Jongyoon Choi and Ricardo Gutierrez-Osuna, 2010, ISBN: 978-1-4244-8170-5

[19] Wikiverzita - Biosignály/Druhy - Online článek, dostupné dne 15.5. 2016 na adrese: [<https://cs.wikiversity.org/wiki/Biosign%C3%A1ly/Druhy>]


[20] Odkaz ke stažení knihovny e-Health: [<https://www.cooking-hacks.com/documentation/tutorial/biometric-sensor-platform-arduino-raspberry-pi-medical/>]

Seznam zkratek


- EEG – Elektroencefalogram - záznam elektrické aktivity mozku, Elektroencefalograf - zařízení provádějící toto vyšetření
- GSR – Galvanic Skin Response - záznam vodivosti kůže
- EKG – Elektrokardiogram - záznam časové změny el. potenciálu zp. srdeční aktivitou, Elektrokardiograf - zařízení provádějící toto vyšetření
- HR – Heart Rate, srdeční tep
- HRV – Heart Rate Variability – variabilita srdečního tepu
- EMG - Elektromyogram - záznam elektrické aktivity svalů
- SC – Skin Conductance – vodivost kůže
- RSP – Respiration - dýchání
- ANS - autonomní nervový systém
- BVP – Blood Volume Pulse – krevní tlak
- ER - Emotions Recognition - rozpoznávání emocí
- SVM - Support vector machines - klasifikátor, který hledá nadrovinu v prostoru příznaků, která optimálně rozděluje trénovací data
- SMO - Sequential minimal optimization - algoritmus pro trénování SVM
- FIR – Finite Impulse Response – jednoduchý konvoluční filtr
- J48 - open source implementace algoritmu C4.5 rozhodovací strom

A Další grafy biosignálu GSR


V této příloze jsou k dispozici některé další grafy naměřených hodnot biosignálu GSR.




Obrázek A.1: Graf GSR pro scénář počítání na čas



Obrázek A.2: Graf GSR pro scénář další minihry



Obrázek A.3: Graf GSR pro scénář registračního okna



Obrázek A.4: Graf GSR pro scénář minihry s počítáním příkladů zároveň

B Uživatelský manuál

Uživatelský manuál pro aplikaci Stressdetector.jar umožňující klasifikaci situací na klidové situace a situace blízké stresu.

B.1 SW požadavky

- OS Windows - minimálně Windows 7
- Java 1.8
- Apache Ant - pro překlad
- Arduino IDE - pro nahrání měřicího programu (na CD)

B.2 Překlad

B.2.1 Konfigurace knihovny RXTXcomm

Nejprve je nutné provést konfiguraci knihovny RXTXcomm pro práci se sériovým portem. Tu provedeme tak, že zkopírujeme soubor RXTXcomm.jar do složky `C:\Program Files\Java\jre1.8.0_51\lib\ext` (cesta nemusí být úplně totožná, ale poslední 2 adresáře by se měly shodovat). Protože knihovna má rozšíření v podobě .dll souboru musíme soubor rxtxSerial.dll zkopírovat do složky `C:\Program Files\Java\jre1.8.0_51\bin`. Pokud máme 32 bitový systém zvolíme 32 bitovou verzi dll.

B.2.2 Překlad

K přeložení slouží skript `build.xml`, který spustíme příkazem `ant` pomocí příkazové řádky spuštěné v aktuálním adresáři. Abychom mohli tento příkaz spustit musíme však mít na PC nainstalovaný program Apache Ant, který lze stáhnout například z <http://ant.apache.org/>.

B.3 Spuštění

Program můžeme jednoduše spustit pomocí kliknutí na soubor s názvem `StressDetector.jar` nebo pomocí příkazu `java -jar StressDetector.jar`. Pokud využíváme již přeložený jaru musíme mít ve stejné složce umístěný i soubor `rxtxSerial.dll` ve stejné bitové verzi jako systém. Bez tohoto opatření nebude program plně fungovat.

B.4 Nahrání programu do Arduina

Pokud není program v Arduinu, je zapotřebí ho tam nejprve nahrát nejlépe pomocí Arduino IDE.

B.4.1 Instalace Arduino IDE

Nainstalujte Arduino IDE do svého PC, instalační soubor je ke stažení na adrese <https://www.arduino.cc/en/Main/Software> nebo na CD ve složce `arduino`. Pokud máme aplikaci nainstalovanou musíme ještě nastavit typ našeho zařízení v položce nástroje -> vývojová deska: vybereme Arduino Mega nebo Arduino UNO podle toho které zařízení máme.

B.4.2 Konfigurace knihovny e-Health

Nejprve se ujistěte, že máte vypnuté Arduino IDE. Nyní zkopírujte knihovnu `e-Health` dostupnou na CD ve složce `arduino-libs` (zkopírujete tedy obsah této složky) do složky `libraries`, která se nachází uvnitř složky kde máte nainstalované Arduino IDE. Pokud jste postupovali správně zobrazí se knihovna v `Sketch->Import Library` menu.

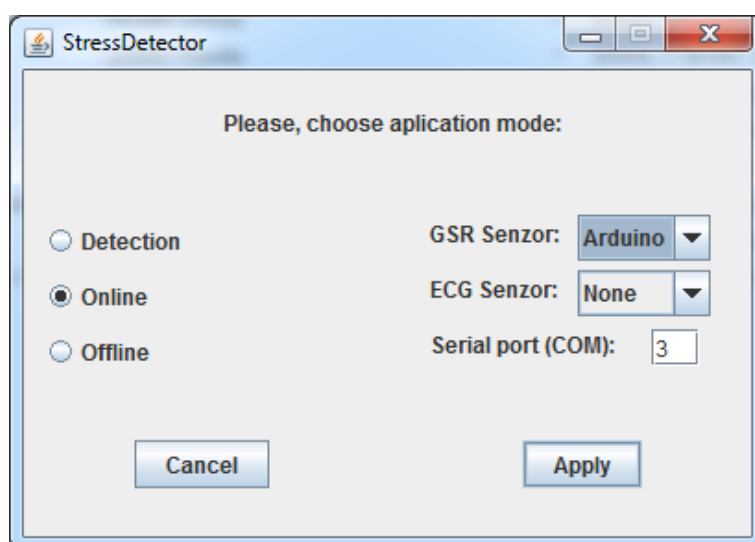
B.4.3 Nahrání programu

Nyní již nám nic nebrání k tomu abychom nahráli program s názvem `gsr-ecg-measuring.ino` do zařízení pomocí tlačítka nahrát (ikona šipky). Program

nalezneme na CD.

B.5 Výběr módu aplikace

Při spuštění aplikace se nejprve zobrazí okno s výběrem počátečního nastavení. Toto okno je zobrazeno na následujícím obrázku. Vybereme si, který mód chceme použít a pokud chceme zvolit detekční nebo online mód musíme vybrat i senzory, kterými budeme biosignál(y) měřit. Zároveň musíme nastavit číslo sériového portu, ke kterému je připojeno Arduino.



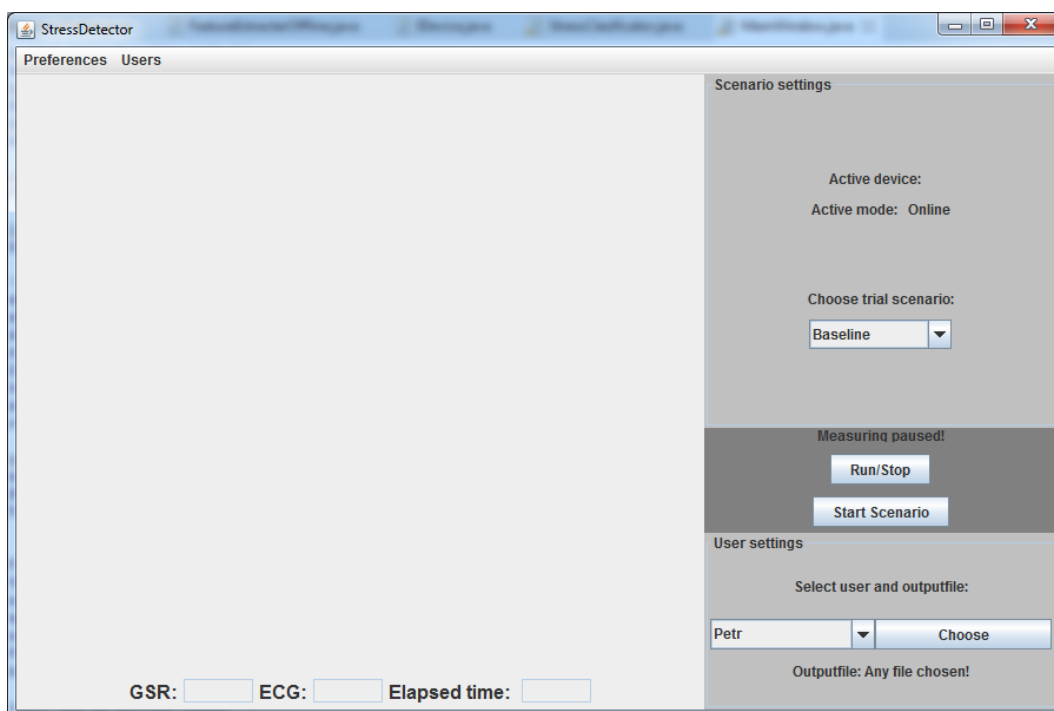
Obrázek B.1: Dialog pro výběr zařízení - konkrétně výběr online módu

B.5.1 Online mód

Online mód slouží k prvnímu měření subjektu (ještě nemáme natrénovanou neuronovou síť).

Měření biosignálů

Ke spuštění měření je potřeba mít připojený senzor, dále vybrat aktuálně měřeného uživatele z nabídky a zvolit umístění výstupního souboru s namě-



Obrázek B.2: Online mód po spuštění - ještě není zaplé měření

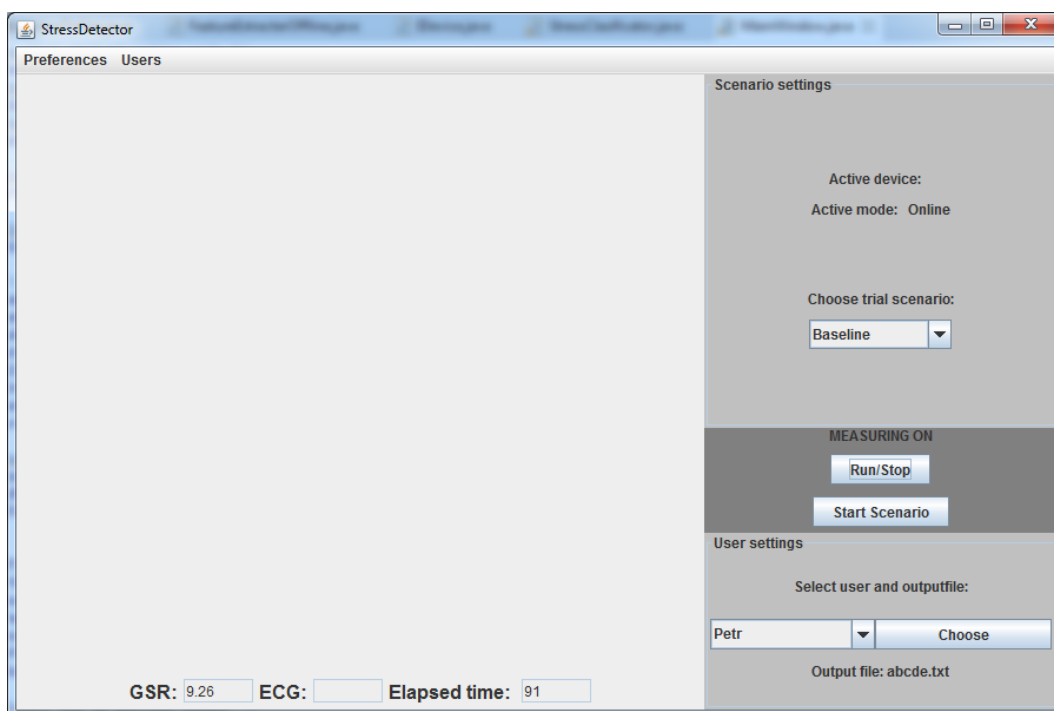
řenými hodnotami.

Výběr scénáře

Kromě samotného měření nabízí online mód i podklady pro některé ze scénářů měření. Scénář vybíráme pomocí komboboxu a akci potvrdíme stisknutím tlačítka start scenario.

B.5.2 Offline mód

Offline mód aplikace je určen k extrakci příznaků a jejich ukládání do trénovacích souborů. Pro zvolení tohoto módu nemusí být aktivní žádný měřicí senzor.



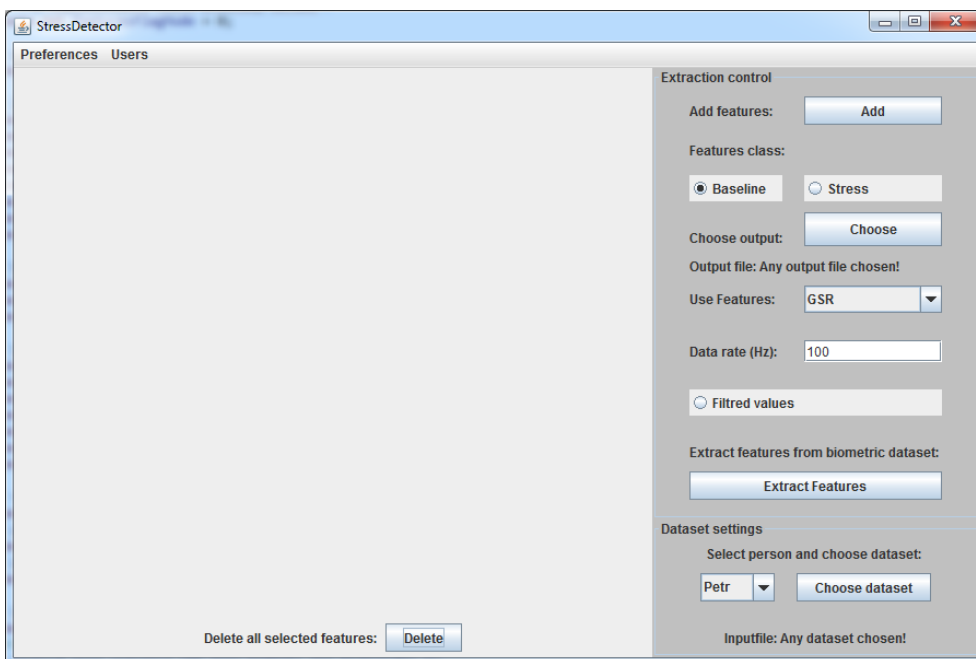
Obrázek B.3: Online mód - zaplé měření GSR

Extrakce příznaků

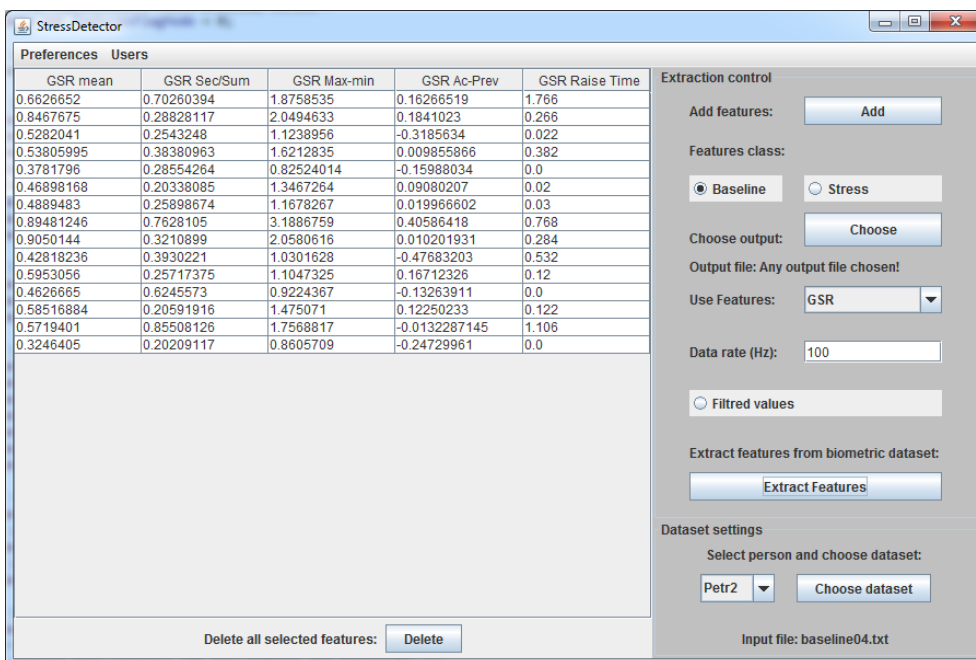
Než klikneme na tlačítko extract features musíme nastavit pro který senzor chceme příznaky měřit, dále vybrat testovaný subjekt a jeho příslušný dataset a pokud jsme vybrali senzor EKG musíme nastavit vzorkovací frekvenci při jaké byl dataset měřen. Nyní již můžeme vše potvrdit stiskem tlačítka extract features.

Tvorba trénovacích datasetů

Pokud již máme extrahované příznaky z konkrétního datasetu, nyní vybereme příznačné vektory pro danou třídu situací. Jestliže měříme v klidové fázi budeme příznaky ukládat jako baseline, pokud měříme ve stimulané činnosti vybereme výrazněji se lišící hodnoty nebo ty, u kterých jsme si zaznamenali časy, kdy je testovaný subjekt vnímal jako blízké stresu a přidáme je do trénovacího datasetu jako stresové.



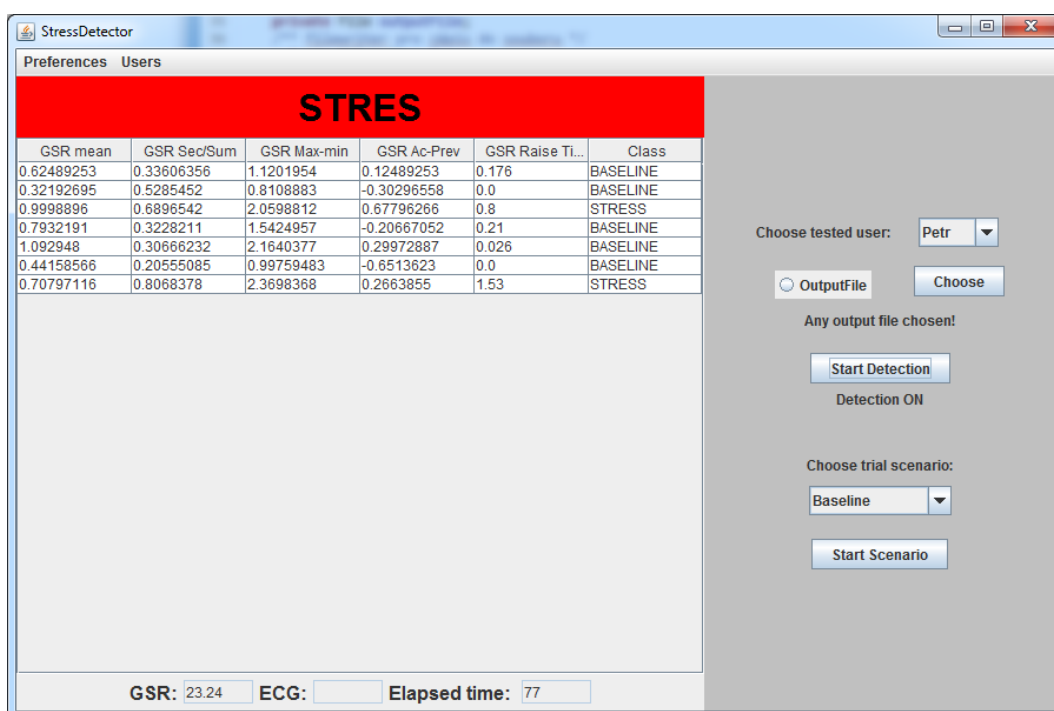
Obrázek B.4: Offline mód - defaultní nastavení



Obrázek B.5: Offline mód - extrakce příznaků

B.5.3 Detekční mód

Detekční mód vybereme tehdy, máme-li již vybrané příznakové vektory pro trénovací datasey (pro GSR mód trainGSR.txt, pro EKG mód trainECG.txt a pro oba biosignály trainBoth.txt). Pokud vytváříte vlastní trénovací dataset je nutné si dát pozor aby učení sítě neprobíhalo příliš dlouho. Je dobré dataset otestovat například v NeurophStudios a až poté ho použít. Po spuštění detekce se cca každých 10 sekund vyhodnotí situace na základě příznaků na klidovou nebo situaci blízko stresu a tyto hodnoty přidá do tabulky.



Obrázek B.6: Detekční mód - klasifikace situací

C Obsah CD

- arduino - složka obsahující soubory související s arduinoem
 - arduino-libs - složka obsahující knihovnu pro práci se sériovým portem
 - gsr-ecg-measuring - složka obsahující měřící program
 - arduino-1.6.8-windows.exe - instalační soubor Arduino IDE pro Windows
- bakalarka - složka obsahující text bakalářské práce a zdrojové soubory pro tex
- bin - složka obsahující aplikaci v binární podobě přeloženou Javou 1.8
- config - složka obsahující pomocné soubory pro běh aplikace
- datasets - složka obsahující naměřené datasety všech testovaných subjektů
- doc - složka obsahující dokumentaci k aplikaci ve formě javadoc
- dlls - složka obsahující rozšíření knihovny pro 32 bitovou verzi systému i pro 64 bitovou verzi systému
- images - složka obsahující obrázky použité v aplikaci
- lib - složka obsahující použité knihovny v jar podobě
- sounds - složka obsahující použité zvuky
- src - složka obsahující zdrojové soubory aplikace
- build.xml - Ant skript pro přeložení aplikace
- rtxtSerial.dll - rozšíření knihovny nutné pro běh aplikace - musí být umístěno u jaru
- StressDetector.jar - spustitelný jar aplikace