



# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

## FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

## ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

## BEZKONTAKTNÍ MĚŘENÍ TEPOVÉ FREKVENCE Z OBLIČEJE

FACE-DETECTION BASED TOUCHLESS MEASUREMENT OF HEART RATE

### DIPLOMOVÁ PRÁCE

MASTER'S THESIS

### AUTOR PRÁCE

AUTHOR

Bc. Lucie Chmelíková

### VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Oto Janoušek, Ph.D.

BRNO 2016

# Diplomová práce

magisterský navazující studijní obor **Biomedicínské a ekologické inženýrství**

Ústav biomedicínského inženýrství

**Studentka:** Bc. Lucie Chmelíková

**ID:** 147485

**Ročník:** 2

**Akademický rok:** 2015/16

**NÁZEV TÉMATU:**

## Bezkontaktní měření tepové frekvence z obličeje

**POKYNY PRO VYPRACOVÁNÍ:**

1) Nastudujte problematiku bezkontaktní detekce tepové frekvence z barevných změn obličeje ve videosekvenci a proveďte v této oblasti literární rešerši. 2) Navrhněte způsob odhadu tepové frekvence ze změn barvy obličeje. 3) Zaznamenejte videosekvence několika obličejů v různých prostředích, lišících se osvětlením, mírou pohybu obličeje, úhlem a vzdáleností kamery od obličeje. 4) V programovém prostředí Matlab vytvořte aplikaci umožňující rozpoznání obličeje ve scéně a následnou detekci tepové frekvence z barevných změn obličeje. 5) Ověřte přesnost odhadu tepové frekvence, např. doprovodným záznamem vhodného biosignálu. 6) Proveďte diskuzi získaných výsledků a na jejich základě vytvořte doporučení pro optimální záznam videosekvencí.

**DOPORUČENÁ LITERATURA:**

[1] RUBINSTEIN, Michael. Analysis and visualization of temporal variations in video. Massachusetts Institute of Technology, 2014. Disertační práce. Massachusetts Institute of Technology. Vedoucí práce William T. Freeman.

[2] WU, Hao-Yu, Michael RUBINSTEIN, Eugene SHIH, John GUTTAG, Frédo DURAND a William FREEMAN. Eulerian video magnification for revealing subtle changes in the world. ACM Transactions on Graphics. 2012, 31(4): 1-8. DOI: 10.1145/2185520.2185561. ISSN 07300301.

**Termín zadání:** 8.2.2016

**Termín odevzdání:** 20.5.2016

**Vedoucí práce:** Ing. Oto Janoušek, Ph.D.

**Konzultant diplomové práce:**

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

**UPOZORNĚNÍ:**

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

## **UPOZORNĚNÍ:**

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

## **ABSTRAKT**

Diplomová práce se zabývá studii bezkontaktní a neinvazivní metody pro odhad tepové frekvence z barevných změn obličeje. Bezkontaktní měření je založeno na snímání osob videokamerou a ze získaných obrazových sekvencí jsou vhodným přístupem získány hodnoty tepové frekvence. Teoretická část práce je věnována popisu tepové frekvence a metod vedoucích k měření tepové frekvence z barevných změn v obličeji. Také obsahuje hodnocení sledovacích algoritmů. Praktická část se zabývá popisem programu k bezkontaktnímu měření tepové frekvence a jeho programové řešení. Zároveň práce obsahuje statistické vyhodnocení funkčnosti tohoto řešení.

## **ABSTRACT**

This thesis deals with the study of contactless and noninvasive methods for estimation of heart rate. Contactless measurement is based on capturing person faces by video camera and from sequences of pictures are estimated values of the heart rate. The theoretical part describes heart rate and methods that are being used to estimate heart rate from color changes in the face. It also contains testing of tracking algorithms. Practical part deals with user interface of program for contactless measurement of heart rate and its software solution. Thesis also contains statistical evaluation of program functionality.

## **KLÍČOVÁ SLOVA**

Bezkontaktní detekce parametru, tepová frekvence, Viola – Jones, ROI, ICA, JADE algoritmus

## **KEY WORDS**

Contactless measurement, heart rate, Viola – Jones, ROI, ICA, JADE algorithm

CHMELÍKOVÁ, L. *Bezkontaktní měření tepové frekvence z obličeje*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2016. 73 s. Vedoucí diplomové práce Ing. Oto Janoušek, Ph.D.

# PROHLÁŠENÍ

Prohlašuji, že svou diplomovou práci na téma Bezkontaktní měření tepové frekvence z obličeje jsem vypracovala samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této práce jsem neporušila autorská práva třetích osob, zejména jsem nezasáhla nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědoma následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009S

podpis autora

# PODĚKOVÁNÍ

Na tomto místě bych ráda poděkovala vedoucímu diplomové práce Ing. Otovi Janouškovi, Ph.D. za cenné připomínky, odborné rady a poskytnuté materiály, kterými mi pomohl k vypracování práce. Dále bych chtěla poděkovat svým nejbližším za podporu.

V Brně dne 20. května 2016

podpis autora

# OBSAH

SEZNAM OBRÁZKŮ .....	III
SEZNAM TABULEK .....	IV
ÚVOD .....	1
1. TEPOVÁ FREKVENCE.....	2
1.1 Biologické faktory ovlivňující tepovou frekvenci .....	2
1.2 Metody měření tepové frekvence.....	2
2. DETEKCE OBLIČEJE V OBRAZE .....	4
2.1 Viola Jones algoritmus .....	4
2.1.1. Haarovy příznaky .....	4
2.1.2. Integrální obraz.....	5
2.1.3. AdaBoost .....	6
2.1.4. Kaskádování .....	7
2.1.5. Trénovací množiny .....	7
3. BEZKONTAKTNÍ MĚŘENÍ TEPOVÉ FREKVENCE Z VIDEA .....	9
3.1 Metoda založená na pohybu hlavy .....	9
3.2 Detekce založená na změně barev v obličeji.....	10
4. SLEDOVACÍ ALGORITMY .....	12
4.1 CAM Shift.....	12
4.2 KLT algoritmus .....	14
5. TESTOVÁNÍ ALGORITMŮ .....	16
5.1 Změna světelných podmínek.....	16
5.2 Změna polohy hlavy.....	18
5.3 Změna vzdálenosti.....	19
5.4 Překrytí části obličeje .....	21
5.5 Zhodnocení výsledků .....	22
6. METODY ZPRACOVÁNÍ SIGNÁLU .....	23
6.1 Analýza nezávislých komponent.....	23
6.1.1. JADE algoritmus .....	23
6.2 Spektrální analýza .....	25
7. PROGRAM PRO BEZKONTAKTNÍ DETEKCI TEPOVÉ FREKVENCE .....	27
7.1 Detekce obličeje .....	28
7.2 Sekvence obrazů.....	29
7.2.1. Normalizace signálu .....	29
7.2.2. Filtrace signálů .....	31
7.2.3. Analýza nezávislých komponent (ICA) .....	31
7.2.4. Spektrální analýza komponent.....	32
7.2.5. Výpočet tepové frekvence .....	33
8. UŽIVATELSKÉ PROSTŘEDÍ APLIKACE .....	35
9. PRŮBĚH A METODIKA MĚŘENÍ.....	39
9.1 Snímací aparatura.....	39

9.1.1. Kamera.....	39
9.1.2. Akviziční jednotka Biopac .....	40
9.1.3. Osvětlení.....	41
9.1.4. Průběh testování .....	41
10. ANALÝZA ZÍSKANÝCH DAT .....	42
10.1 Naměřené hodnoty .....	42
10.1.1. Korelační analýza .....	42
10.1.2. Chyby měření.....	43
10.2 Statistické hodnocení.....	46
10.3 Hodnocení získaných výsledků.....	48
<b>ZÁVĚR .....</b>	<b>50</b>
<b>POUŽITÉ ZDROJE .....</b>	<b>51</b>
<b>SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK.....</b>	<b>55</b>
<b>SEZNAM PŘÍLOH .....</b>	<b>56</b>

# SEZNAM OBRÁZKŮ

Obrázek 1: Příznaky podobné Haarově vlnce [18].....	5
Obrázek 2: Integrální obraz [18] .....	6
Obrázek 3: Nový slabý klasifikátor je vybrán v průběhu boostingu, váhy označených příkladů jsou vždy adaptovány v následujícím kroku boostingu [14] .....	7
Obrázek 4: Schéma ukazující kaskádovitý řetězec algoritmu .....	7
Obrázek 5: Yale Face databáze obsahující 16 128 obrazů 28 lidských tváří v 9 pózách s 64 různými světelnými podmínkami [25] .....	8
Obrázek 6: Schéma detekce tepové frekvence za pomoci této metody [5] .....	10
Obrázek 7: Podmínky snímání [24].....	11
Obrázek 8: Vývojový diagram CAM shift algoritmu [30] .....	13
Obrázek 9: Shi - Tomasi: Výběr dobrých znaků [4] .....	14
Obrázek 10: Givensihova rotace [1].....	24
Obrázek 11: Neparаметrické metody výpočtu výkonového spektra [2] .....	25
Obrázek 12: Vývojový diagram výpočtu tepové frekvence .....	27
Obrázek 13: Získané RGB signály z kamery .....	30
Obrázek 14: Filtrované RGB signály v pásmu 0,75 až 4 Hz.....	31
Obrázek 15: Získané komponenty ICA analýzy.....	32
Obrázek 16: Výkonová spektra ICA komponentů .....	33
Obrázek 17: Uživatelské rozhraní programu při spuštění .....	35
Obrázek 18: Dostupnost tlačítek před měřením .....	36
Obrázek 19: Nedostupná tlačítka během měření .....	37
Obrázek 20: Vypsání aktuální tepové frekvence a možnost dalšího měření .....	38
Obrázek 21: Snímací kamera DFK 23U445 [33] .....	39
Obrázek 22: Spektrální citlivost sensoru kamery [33] .....	40
Obrázek 23: Panel nástrojů software IC Capture 2.4 .....	40
Obrázek 24: Možnost nastavení výkonu osvětlení [9] .....	41
Obrázek 25: Graf korelace měřené veličiny .....	43
Obrázek 26: Kvantily normálního rozložení a získaných hodnot .....	47

# SEZNAM TABULEK

Tabulka 1: Vybrané odkazy na databáze obrázků tváří.....	8
Tabulka 2: Výhody a nevýhody sledovacích algoritmů .....	15
Tabulka 3: Příklad frekvencí získaných maxim z jednotlivých komponent .....	33
Tabulka 4: Získané hodnoty testovacího měření.....	42
Tabulka 5: Tabulka vypočtených chyb:.....	45
Tabulka 6: Vlastnosti analyzovaných dat.....	45
Tabulka 7: Testová statistika .....	48

# ÚVOD

Tepová frekvence je jeden z nejdůležitějších indikátorů fyziologického stavu člověka. Konvenční měření tepové frekvence jsou založena na speciálních elektronických či optických senzorech a většina měřících přístrojů vyžaduje fyzický kontakt přístroje s kůží pacienta, což může být v některých případech pro pacienta omezující a nepříjemné. Vzdálené monitorování pacientů se stává nezbytností a standardem. Mezi některými monitorovanými parametry je i monitorace kardiovaskulárních hodnot. Ty poskytují informace o funkčnosti srdce a tím slouží jako jedny z ukazatelů správnosti fungování organismu. Z toho důvodu je vyvíjeno mnoho nových přístupů k možnostem měření parametrů srdce či respiračního systému.

Pro vzdálené monitorování pacientů je v některých případech využíváno videokamery, díky které je možné provádět analýzy bezkontaktně. Konkrétně v této diplomové práci jsou studovány principy pro odhad tepové frekvence pomocí bezkontaktních a neinvazivních přístupů. Tato práce je detailněji zaměřená na snímání tepové frekvence z obličeje pomocí videokamery.

Práce je rozdělena na dvě části, první, teoretická obsahuje na začátku informace o tepové frekvenci, jejích vlastnostech a o možnostech jejího běžného snímání. Dále je představen algoritmus Viola Jones, který umožňuje detekci obličeje ve videosekvencích, či při snímání naživo. Pro představu o prozatímních možnostech dálkové detekce parametrů jsou ve třetí kapitole uvedeny metody pro detekci tepové frekvence z videosekvencí, které již byly představeny. Neposlední teoretická kapitola seznamuje s algoritmy, které umožňují sledování obličeje ve videu. Jedním z nich je CAM Shift algoritmus a druhým KLT. Následující, šestá kapitola, je již teoretickým úvodem pro druhou, praktickou část diplomové práce. Důležitou součástí vytvořeného programu je algoritmus analýzy nezávislých komponent JADE, kterým se zabývá tato kapitola a současně je představena metoda spektrálního zpracování signálu.

Samotný program pro bezkontaktní detekci tepové frekvence z barevných změn obličeje je hlavním tématem sedmé kapitoly, kde jsou jeho jednotlivé kroky a použité funkce představeny. Pro jeho návrh je využito programového prostředí MATLAB. Uživatel programu po spuštění vidí uživatelské rozhraní a pro seznámení se s ním je vhodná kapitola osm. Ta detailně popisuje a vysvětluje jednotlivé ovládací prvky programu a jeho chování během měření. Pro ověření jeho funkčnosti bylo nezbytné provést testovací měření s referenčním přístrojem. Jedná se o Biopac, který umožňuje měření tepové frekvence pomocí fotopletysmografické sondy. Testováno bylo 10 dobrovolníků a v desáté kapitole je sepsaná statistika a vyhodnocení důvěryhodnosti programu.

# 1. Tepová frekvence

Tok krve je v lidském těle zajištěn pomocí srdce, které svými stahy distribuuje krev v uzavřeném systému cév. Zevním projevem funkce srdce na obvodových tepnách je tep (puls). Při vypuzení systolického objemu krve ze srdce dochází k roztažení srdečnice a rozšíření jejího pružného proximální části. V následující diastole se srdečnice stáhne a tak tlačí krev do krevního řečiště. Na povrchových tepnách můžeme zaznamenat tento jev jako tep.

## 1.1 Biologické faktory ovlivňující tepovou frekvenci

Tepovou frekvenci mohou ovlivňovat různé faktory, jako jsou například fyzická kondice, věk či přítomnost některých drog v krvi. Za normálních podmínek je však tepová frekvence u všech jedinců stejného věku a pohlaví zhruba stejná. Hlavní vliv na klidovou tepovou frekvenci má anatomie srdce. Dalším faktorem je nastavení autonomních řídicích systémů člověka. Jedním z faktorů je dodávání kyslíku do tkání, především do mozku. Předávání kyslíku tkání zajišťuje červená krvinka a tudíž je směrodatný hematokrit, tedy přenosová kapacita krve pro kyslík. Hodnota tepové frekvence je ovlivněna i momentálním stavem psychiky. [32]

Celý systém řízení tepové frekvence je postaven na zpětnovazebním mechanismu. Existují různé způsoby regulace tepové frekvence.

- 1) Homeometrická autoregulace – vlivem této regulace se projevuje takzvaný frekvenční efekt. To znamená, že čím větší je frekvence srdce, tím větší je síla stahů, což ovšem platí pro určité klidové hodnoty tepové frekvence. Díky pozitivní zpětné vazbě se dále zvyšuje tepová frekvence. [12]
- 2) Neurohumorální regulace – tepová frekvence srdce je kontinuálně řízená pomocí nervů. Pro klidovou tepovou frekvenci je podstatný vliv parasympatického systému, který snižuje tepovou frekvenci, naopak pod vlivem sympatiku se tepová frekvence zvyšuje. Nervové řízení zajišťují hormony adrenalin a noradrenalin. [12]

## 1.2 Metody měření tepové frekvence

Tepová frekvence je veličina, jejímž měřením je získána informace o správnosti funkce srdce a změny tepové frekvence indikují stav fyzické kondice člověka. Hodnocení tepové frekvence může být založeno na měření několika různých biosignálů. V první řadě je to samotná elektrická aktivita srdce, dále akustický signál, změny tlaku krve v oběhovém systému či změny objemu tkáně. [15]

- 1) **Vyhodnocení tepové frekvence z EKG signálu** – bývá velice často využívanou součástí kardiometru, které jsou zahrnuty do větších monitorovacích systémů.

Principiálně je metoda založena na hodnocení časových výskytů QRS komplexů z EKG signálu za pomoci detekce R - vlny. [15]

- 2) **Vyhodnocení tepové frekvence z akustického signálu** – akustickým signálem je myšlena srdeční ozva, která vzniká důsledkem změny rychlosti proudění krve a činnosti srdečních chlopní. Srdeční ozvy jsou 4 a každá reprezentuje určitou fázi cyklu srdce. Metoda pracující na tomto principu se nazývá auskultační a přístrojem je fonokardiograf. [15]
- 3) **Vyhodnocení tepové frekvence z průběhu arteriálního tlaku krve na končetině** – tím, že krevní tlak kolísá mezi horní a spodní mezí, může být určen systolický (maximální) a diastolický (minimální) tlak v arteriích. Hodnotí se frekvence změn tlaků. Přístroj vyhodnocující tyto změny tlaků se nazývá tonometr. [15]
- 4) **Vyhodnocení tepové frekvence ze změn objemu tkáně** – pro hodnocení se využívá pletysmografie, hodnotící objemové změny částí těla. Hodnotíme časové změny signálu a z nich odvozujeme tepovou frekvenci. Využívá se fotoelektrický pletysmograf (nebo lze použít i pulsní oxymetr), který pracuje s vlnovými délkami světla, které pohlcuje krevní barvivo. [15]

Hodnota tepové frekvence je výrazně ovlivněna stavem pacienta. Tepová frekvence se měří jako počet srdečních stahů za minutu. Pro klidovou tepovou frekvenci jsou udávány hodnoty 70 až 80 tepů za minutu, při námaze může tep narůst až na 150 až 200 tepů za minutu. Naopak ve spánku se tepová frekvence snižuje o 10 až 20 tepů za minutu. [35]

## 2. Detekce obličeje v obraze

Detekce obličeje ve scéně je v poslední době předmětem častého výzkumu. Nachází uplatnění v různých oborech jako například kriminalistika či identifikace osob. Pro detekci obličeje je využívána celá řada algoritmů. Jedním z nich je Viola Jones algoritmus pro rozpoznávání objektů. Byl zveřejněn P. Violou a M. Jonesem v roce 2001 a umožňuje výpočetně nenáročně a korektně detekovat obličej. Pro detekci využívá Haarovy vlnky, kdy jsou testovány sady Haarových příznaků v každé oblasti obrazu s využitím klasifikátoru AdaBoost. [29]

### 2.1 Viola Jones algoritmus

Detekce obličeje pomocí tohoto algoritmu je založená na principu učení s učitelem, tj. využívá předchozí manuální klasifikaci, co je a co není obličej. Při učení systém dostane k dispozici řadu obrazů, na kterých je zobrazena lidská tvář a k tomu informaci o tom, že právě tohle je obličej. Na druhou stranu je systému poskytnuta databáze obrazů, na kterých obličej není a informace, že v těchto obrazech lidskou tvář nenalezne. Systém se na základě těchto znalostí snaží nalézt společně vlastnosti dodaných obrazů s obličejem, aby registroval a sesbíral co nejvíce znalostí o tom, podle čeho lze lidskou tvář rozpoznat. Po naučení klasifikátoru je systému dodán obraz a systém automaticky klasifikuje přítomnost či absenci obličeje na základě získaných zkušeností. [29]

#### 2.1.1. Haarovy příznaky


Extrahování příznaků z obrazu využívá Haarovy vlnky. Jde o jednu z nejstarších vlnek, která je využita pro výpočet Haarových příznaků. Příznaky jsou vstupem do již zmíněného procesu učení trénovacího, potažmo klasifikačního algoritmu. Čím větší množina příznaků je získána, tím větší je pravděpodobnost toho, že bude vybrán slabší klasifikátor s větší mírou přesnosti. Algoritmus Viola Jones se snaží kombinovat několik slabších příznaků, které mají minimální výpočetní nároky. Typické příznaky jsou právě Haarovy vlnky (tzv. Haar – like features). Jsou reprezentovány rozdílem jasů mezi obdélníkovými oblastmi, viz Obrázek 1. Hodnota příznaku je počítána jako suma pixelů obrazu, které odpovídají světlé části a od ní je odečtena suma pixelů odpovídajících tmavé části. [29]

$$F_{haar} = E(R_{White}) - E(R_{Black}), \quad (1)$$

kde  $F_{haar}$  je odezva příznaku a  $E(R_{White})$  je suma pixelů světlé části obrazu a  $E(R_{Black})$  suma pixelů obrazu tmavé části. [18]

Existuje několik druhů příznaků. Mohou být tvořeny různým počtem světlých a tmavých oblastí – dvěma, třemi či čtyřmi oblastmi ve tvaru obdélníků. Každý z nich reprezentuje buď hranový, čarový nebo diagonální příznak. Příznaky aplikujeme na celý vstupní obraz a v průběhu algoritmu se mění velikost příznaků (jednotlivých obdélníků).

Začíná se na velikosti 1x1 a proces končí dosažením rozměru vstupního obrazu. Příkladem může být vstupní obraz o velikosti 19x19 pro který existuje 64 tisíc hodnot pro příznaky, které jsou vstupem do učícího procesu klasifikačního algoritmu AdaBoost (viz podkapitola 2.1.3). V obraze je tedy vypočteno mnoho odezev příznaků, na základě kterých je rozhodnuto o přítomnosti či nepřítomnosti obličeje. Typy příznaků zobrazené na Obrázek 1 dole patří k základním příznakům, v nynější době se již používají i odvozené příznaky právě od těchto základních, které jsou natočené o 45 stupňů. [29] [18]



Obrázek 1: Příznaky podobné Haarově vlnce [18]

Pro výpočet příznaků pro detektor Viola Jones je efektivnější využít tzv. integrální obraz.

### 2.1.2. Integrální obraz


Pro jednodušší aplikaci Haarových příznaků je potřeba převést vstupní obraz na obraz integrální. Tato reprezentace vstupních hodnot slouží pro jednodušší a rychlejší výpočet jednotlivých příznaků. Zjednodušeně je integrální obraz reprezentací vstupního obrazu, v němž jsou jasové hodnoty pixelů kumulativně sečteny v jednotlivých řádcích a sloupcích. Tyto sumy lze vyjádřit rovnicemi [14]

$$s(x, y) = s(x, y - 1) + i(x, y), \quad (2)$$

$$ii(x, y) = ii(x - 1, y) + s(x, y), \quad (3)$$

kde  $s(x, y)$  je kumulovaný součet jasových hodnot v řádku a  $i(x, y)$  jsou hodnoty původního vstupního obrázku. Hodnota  $ii(x, y)$  představuje výsledný integrální obraz. Dále pak musí platit  $s(x, 0) = 0$  a  $ii(0, y) = 0$ . [14] [29]

Výpočet samotných příznaků je pak zásadně jednodušší, protože pro výpočet sumy libovolného obdélníku v obraze pak stačí pouze dvě operace sčítání a jedna operace odčítání. Ukázka principu výpočtu integrálního obrazu je zobrazen na Obrázek 2. [29]



Obrázek 2: Integrální obraz [18]

I v případě výpočtů v integrálním obraze by bylo zapotřebí provádět veliké množství početních operací a proto detekce využívá klasifikátor AdaBoost, který využívá kombinaci slabých klasifikátorů. [29]


### 2.1.3. AdaBoost

AdaBoost (jde o zkratku Adaptive Boosting) je klasifikační algoritmus, který se zakládá na metodě strojového učení – tzv boosting. Cílem boostingu je využití zmíněných slabých klasifikátorů, které můžeme označit jako slabé žáky (weak learners), vznikající pomocí výběru vzorků z trénovací množiny. Slabší klasifikátory jsou přidávány jeden k druhému a vzniká tak soubor klasifikátorů, označovaný jako silný žák (strong learner). Celková klasifikační přesnost je tedy zvýšená (boosted). Samotný klasifikátor využívá pár stovek či tisíců slabých klasifikátorů, kde každý z nich je optimalizovaný na jeden Haarův příznak a ve výsledku jsou zkombinovány do jednoho efektivního a přesného silného klasifikátoru. [29]

AdaBoost je nazýván adaptivní z toho důvodu, že v každém kroku boostingu učící algoritmus vybere přesně jeden slabý klasifikátor, který nejlépe separuje dodanou vstupní učící množinu obsahující pozitivní a negativní případy (obrázky obsahující, či neobsahující obličeje). V každém následujícím kroku je nesprávně určenému případu udělena vyšší váha a naopak správně určenému případu udělena váha nižší s nejmenší chybou klasifikace při dané váze, takže v dalším kroku je hledán slabý klasifikátor, který bude lépe klasifikovat doposud chybně určená měření. Proces trénování probíhá v T krocích a může být popsán rovnicí č.4. [14] [29]

$$H(n) = \begin{cases} 1 & \text{jestliže } \sum_{t=1}^T \alpha_t h_t(n) \geq \lambda \sum_{t=1}^T \alpha_t, \\ 0 & \text{jinak} \end{cases} \quad (4)$$

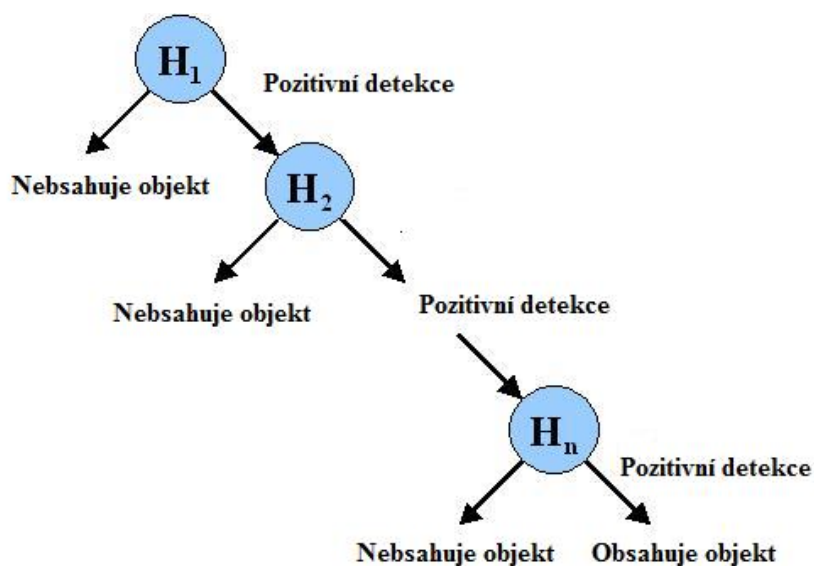
kde  $\alpha$  je váha každého slabého klasifikátor  $h_t()$  a  $\lambda$  reprezentuje práh silného klasifikátoru. AdaBoost redukuje trénováním chybu exponenciálně, v závislosti na tom, jak roste počet klasifikátorů. Na Obrázek 3 je ukázán výběr klasifikátorů. [14]



Obrázek 3: Nový slabý klasifikátor je vybrán v průběhu boostingu, váhy označených příkladů jsou vždy adaptovány v následujícím kroku boostingu [14]

### 2.1.4. Kaskádování

Pokud by jednotlivé obrazy měly být procházeny postupně pomocí jednotlivých podoken, tak by byl proces velice zdlouhavý. Algoritmus je tedy řešen jako kaskádní, kdy je vstupní obraz nejdříve přepočítáván pomocí několika málo příznaků a to z toho důvodu, že ze zkušeností vyplývá, že většina oken bude negativních a nebudou obsahovat žádný objekt a jenom menší část bude oblastí zájmu, kde bude možno klasifikovat detekci jako pozitivní. Při pozitivní detekci oblasti dochází teprve k tomu, že algoritmus začne využívat rozšířenou sadu klasifikátorů. V každém dalším kroku se algoritmus snaží vyřadit co nejvíce negativních podoken a určit místa s pozitivní detekcí. Vizualní zpracování je vidět na Obrázek 4. [23] [29]



Obrázek 4: Schéma ukazující kaskádovitý řetězec algoritmu [23]

### 2.1.5. Trénovací množiny

Na extrakci příznaků z obrazu a trénování klasifikátoru navazuje samotná detekce obličeje v obraze. Nejprve je důležité mít vhodnou trénovací množinu. Je mnoho druhů databází, kde lze získat požadovanou trénovací množinu, či si lze vytvořit vlastní, například z videosekvence. Pro příklad je zde několik odkazů na databáze.[14]

Tabulka 1: Vybrané odkazy na databáze obrázků tváří

Databáze lidských tváří		
CVL Face Database	<a href="http://www.lrv.fri.uni-lj.si/facedb.html">http://www.lrv.fri.uni-lj.si/facedb.html</a>	[27]
The Psychological Image Collection at Stirling	<a href="http://pics.psych.stir.ac.uk/">http://pics.psych.stir.ac.uk/</a>	[11]
Labeled Faces in the Wild	<a href="http://vis-www.cs.umass.edu/lfw/">http://vis-www.cs.umass.edu/lfw/</a>	[19]
The MUCT Face Database	<a href="http://www.milbo.org/muct/">http://www.milbo.org/muct/</a>	[25]

Většina databází obsahuje trénovací data buď barevná, nebo šedotónová a jsou v nich zahrnuty jak profily osob, tak pohledy z boku. Většina z databází je dostupná volně ke stažení. Všechny vzory by měly mít stejné rozměry a rozlišení. Na Obrázek 5 je ukázka z dostupné databáze obrázků. [14]



Obrázek 5: Yale Face databáze obsahující 16 128 obrázků 28 lidských tváří v 9 pózách s 64 různými světelnými podmínkami [25]

Při vlastní detekci je obraz zpracováván po částech a ty jsou vybírány pomocí posuvného pod – okna, které mění svoji pozici v rámci obrazu a mění i svoji velikost.

Výhodou detekce pomocí Viola Jones algoritmu je velice rychlý výpočet příznaků a také pro jejich výběr. Je nejefektivnější pro detekci tváří ve frontální pozici. Nevýhodou je jeho neschopnost detekce tváří natočených o více než 45° a je velice citlivý na světelné podmínky.

### **3. Bezkontaktní měření tepové frekvence z videa**

S rozvojem nositelných a chytrých (smart technologies) technologií pro měření biologických veličin vzrostla potřeba měřit biosignály bezkontaktně. Bezkontaktní monitorování je zvláště důležité například u malých novorozeňat nebo u starších lidí, kteří mají křehkou tělesnou schránku. Stárnutí populace vyžaduje vzdálené monitorování mimo klinické prostředí, kdy je možné lékařům poskytnout dlouhodobé záznamy a vývoj změn biosignálů pro vyšetření a následující statistické vyhodnocení. Začíná být kladen důraz na měření tepové frekvence a dalších parametrů za pomoci videa, vzhledem k tomu, že videokamery jsou v populaci běžně dostupné. V této kapitole budou probány různé přístupy hodnocení tepové frekvence z videa. V poměrně nové oblasti bezkontaktního měření tepové frekvence vzniklo několik algoritmů, které jsou založeny právě na detekci obličeje a následných výpočetních metodách při zpracování obrazů a videa. Existuje několik přístupů k této problematice, které v principu využívají následující metody.

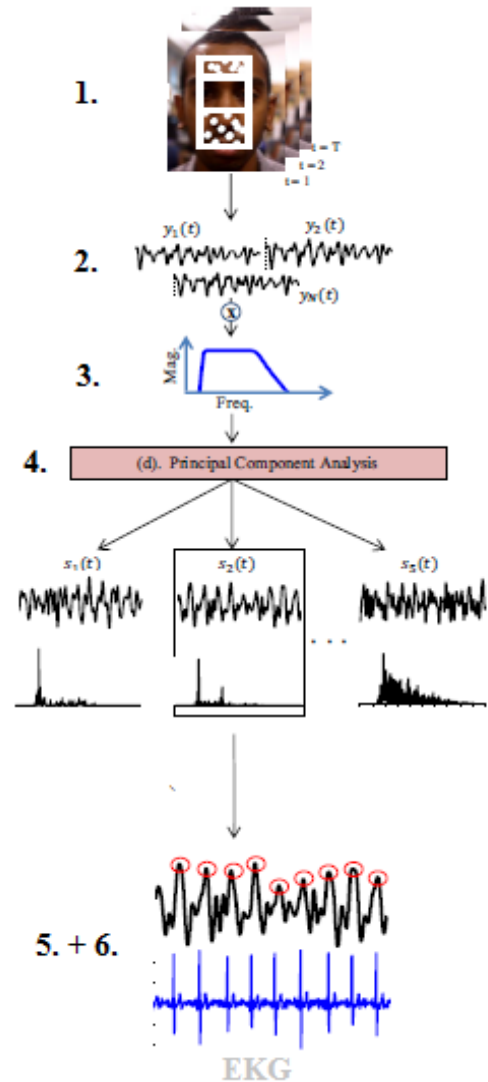
#### **3.1 Metoda založená na pohybu hlavy**

Tato metoda je založena na měření jemných pohybů hlavy, které jsou způsobeny třetím Newtonovým zákonem, která je způsobena pohybem krve v cévách při každém srdečním tepu. Tím, jak je krev cyklicky pumpována ze srdce do hlavy přes abdominální aortu a karotidy způsobuje to, že se hlava pohybuje v periodických cyklech. Vytvořený algoritmus detekuje puls právě z tohoto pohybu. Metoda v první řadě zaznamenává video, kde se nachází hlava pacienta a je lokalizován obličej pomocí detekovacího a sledovacího algoritmu, v tomto případě se jedná o Viola Jones detektor. Je vybráno od středu 50% zobrazeného detekovaného obdélníku na šířku a 90% na výšku pro zajištění stoprocentní detekce samotného obličeje. Odfiltrování mechanických pohybů hlavy a pohybů očí se děje pomocí klasifikátorů. Sledovací algoritmus používaný touto metodou je Lukas Kanade sledovací algoritmus. Izolací pohybu zodpovědného za pulsování tepen a žil je získán 1D signál, což nám umožňuje extrahovat jednotlivé pulsy ze zobrazených vrcholů signálu. K samotnému zobrazení vrcholů napomáhá analýza PCA (Principal Component Analysis), která pomocí dekompozice signálů dovede vybrat správný zdroj pro analýzu z dodaného signálu. Vybírá signál, který popisuje požadované pohyby hlavy. To se děje tak, že je analyzováno spektrum separovaného kanálu. Průběh metody lze názorně vidět na následujícím Obrázek 6. [5]

Metoda lze tedy zjednodušit do následujících bodů:

1. Detekce oblasti obličeje a sledování daného objektu
2. Vybrání signálu reprezentujícího tepové frekvence
3. Filtrace signálu
4. PCA
5. Detekce vrcholů z kanálu obsahující srdeční tep
6. Porovnání detekovaného tepové frekvence s EKG

Přehledně lze vše vidět na následujícím obrázku:




Obrázek 6: Schéma detekce tepové frekvence za pomoci této metody [5]

### 3.2 Detekce založená na změně barev v obličeji

Metody založené na barevných změnách v obličeji bude využito i pro následující diplomovou práci, proto jejímu popisu bude věnován větší důraz. Je opět více přístupů pro hodnocení videa, na které je snímán obličej osoby, z něhož je hodnocena tepová frekvence. Metoda využívá separace signálu z barevných kanálů ze snímaného videa. [24]

Principiálně je metoda založená na sledování barevných změn v obličeji jednoduchá. Je zapotřebí vytvořit prostředí, které obsahuje pacienta, webkameru, viz Obrázek 7. Pro měření je vhodné mít konstantní osvětlení. [24]



Obrázek 7: Podmínky snímání [24]

Po nasnímání sekvence videozáznamů pomocí videokamery je provedena úprava sejmutého signálu. Nejdříve je za potřeby detekovat tvář za použití Viola Jones Algoritmu a následně jeho sledování ve scéně. Je vybráno 60% šířky a 60% délky detekovaného ROI (region of interest) obsahujícího obličejovou část hlavy, čímž vzniklo nové ROI v obličejí používané pro výpočty. Oblast zájmu je následně separovaná do 3 RGB kanálů a pixely v ROI jsou prostorově zprůměrovány. Tím je získáno rozdělení RGB signálu do jednotlivých barevných stop. Ty jsou vstupem do analýzy nezávislých komponentů (ICA – independent compound analysis) a tím jsou získány 3 komponenty zdrojového signálu. V tomto případě druhý kanál obsahuje požadovaný signál s tepovou frekvencí. Následně je aplikována Fourierova transformace pro získání spekter jednotlivých komponentů. Tepová frekvence koresponduje s dominantním vrcholem ve spektru. Detekce tepové frekvence za pomocí ICA může být někdy znesnadněna přítomností artefaktů. To lze eliminovat tím, že je nastaven práh, který říká, že při přesáhnutí určité velikosti rozdílu tepové frekvence mezi jednotlivými měřeními, nebude ze spektra signálu vybrána nejvyšší vrchol, ale bude použit druhý nejvyšší vrchol. Pokud by nebyl nalezen vhodný vrchol spektra, tak bude algoritmem zamítnut dodaný signál a nebude možné provádět analýzu tepové frekvence. [24]

## 4. Sledovací algoritmy

Cílem je sledovat pozici stejného objektu v sekvenci obrazů, tedy ve videu. To lze provádět buď za pomoci přímého výpočtu rozdílu mezi odpovídajícími si pixely, nebo za pomoci registrace změny intenzity či barvy v jednotlivých obrazech. Můžeme tedy detekovat změny osvětlení, barvy nebo obojího dohromady. Občas je velice těžké mezi nimi okem rozlišit a proto musíme detekovat a měřit změnu pozice. Je několik různých přístupů, v této kapitole jsou představeny 2 algoritmy pro sledování pohybu

### 4.1 CAM Shift

Metoda CAM Shift algoritmus neboli Continuously Adaptive Mean shift algoritmus je založená na sledování objektu pomocí například sledování kontury. Objekt sledujeme pomocí křivky, jejíž parametry jsou reprezentované rozložením hustoty pravděpodobnosti a v průběhu sledování je upravujeme pomocí naučeného dynamického modelu. Je to vlastně adaptovaný MEAN Shift algoritmus, který hledá v rozložení hustoty lokální extrém a navíc mění adaptivně velikost sledovacího okna. Tento algoritmus je velice vhodný na aplikaci pro statické obrazy, ale je málo účinný na využití v dynamických rozloženích barvy, jako je například video. Je to proto, že vyhledávací okno má fixní velikost S rozšířením o kontinuální adaptaci rozměrů okna procházející jednotlivé obrazy, lze využít CAM Shift algoritmus pro sledování objektů ve videu velice úspěšně. [4] [8]

(1) Inicializační proces [17]

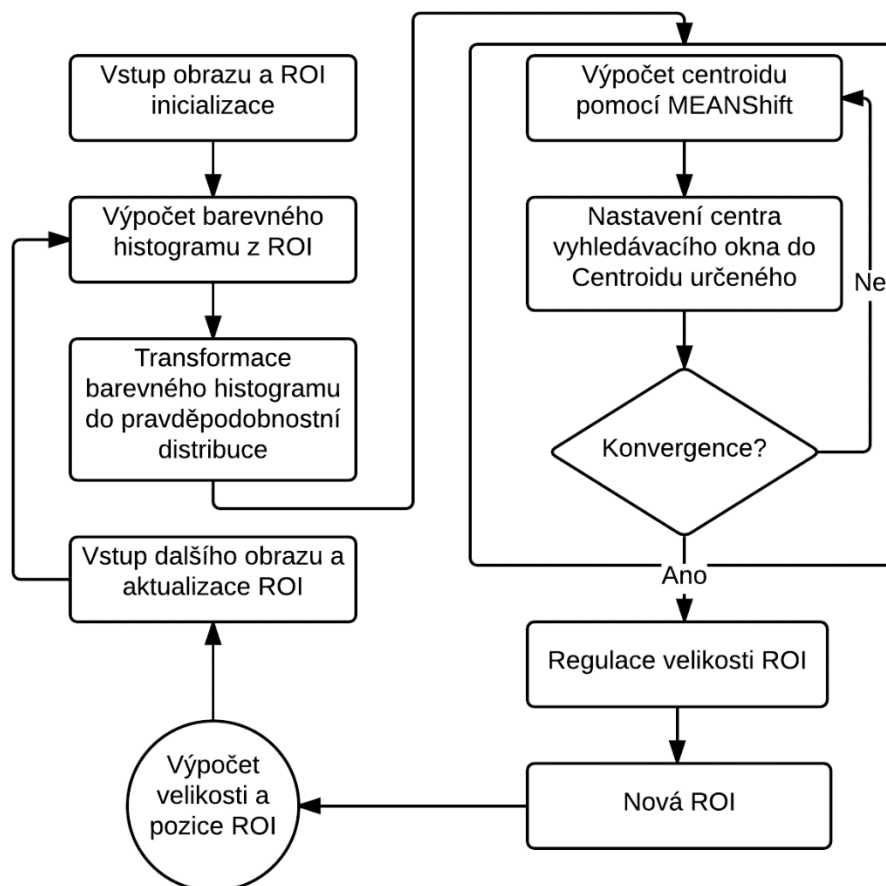
- a. Určení ROI vstupního obrazu – je volena startovací poloha vyhledávacího okna MEAN Shift
- b. Vybrání vyhledávacího okna – regionu, který má být sledován v následujícím zpracovávání snímků z kamery
- c. Konverze vstupního ROI do HSV obrázku
- d. Výpočet histogramu – iterací MEAN Shift metody nalézáme centroid pravděpodobnosti obrazu a ukládáme polohu centroidu
- e. Získání distribuční funkce barevné pravděpodobnosti obrazu – normalizovaný barevný histogram – z vybrané oblasti je počítána pravděpodobnostní rozložení obrazu a to říká, s jakou pravděpodobností se pixel s danou intenzitou vyskytuje v obraze

(2) Sledování [17]

- a. Aktualizace parametrů sledovacího okna
- b. Posun okna do nalezeného centroidu pravděpodobnosti zvoleného regionu
- c. Postup do dalšího obrazu, zpět na (1)

CAM Shift algoritmus tedy zlepšuje vyhledávací schopnost MEAN shift algoritmu. Je to robustní vyhledávací algoritmus, který je v dnešní době využíván pro sledování. Je vhodný pro použití pro objekty, které mají jednoduchý a konstantní vzhled, není však doporučován pro detekci komplexnějších objektů. Je velice citlivý na pohyb objektu a změnu barevných podmínek. Jakmile je sledováno více podobně zbarvených objektů, dochází ke křížení trajektorií vektorů a detekce může být méně účinná. [17] [30]

Vývojový diagram je vidět na Obrázek 8:



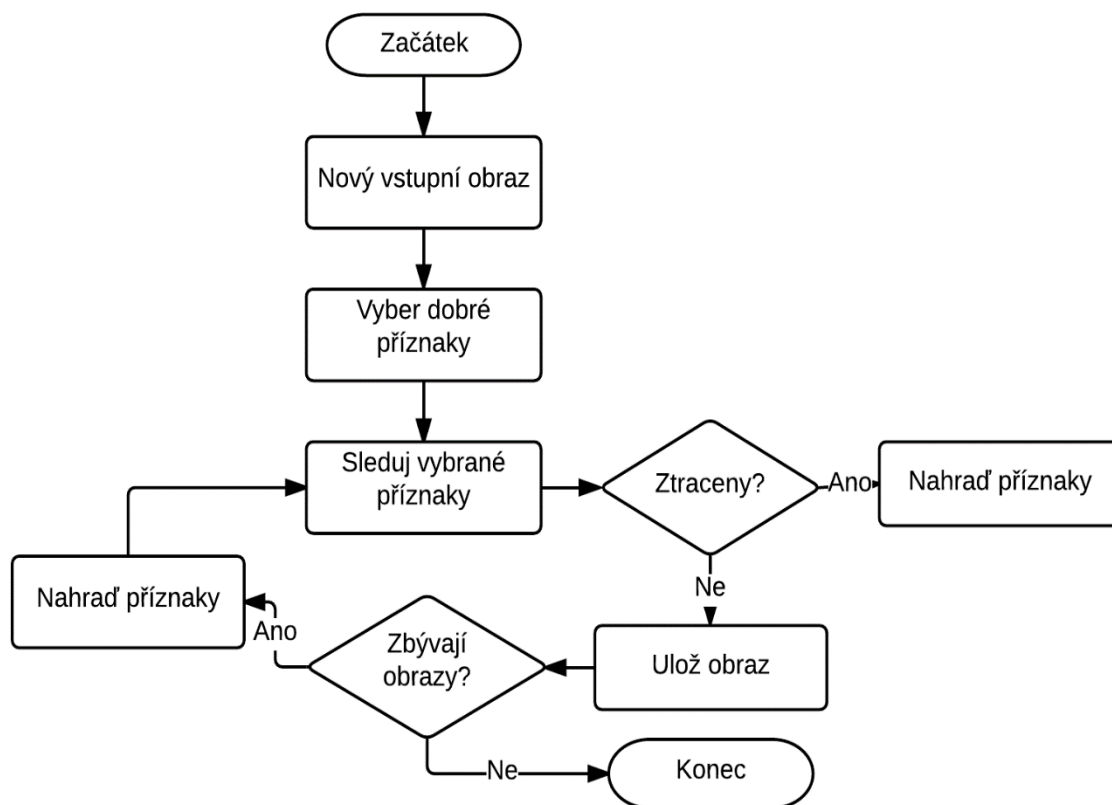
Obrázek 8: Vývojový diagram CAM shift algoritmu [30]

## 4.2 KLT algoritmus

KLT je zkratka pro Kanade – Lucas – Thomasi algoritmus. Má nejlepší výsledky v přesnosti a v real – time sledování objektů. V jeho nejzákladnější formě se algoritmus snaží hledat posun bodů zájmu a jejich směr a velikost pohybu. Jedná se tedy o detekci pohybu bodů zájmu ve videosekvenci. Metoda byla poprvé představena Lucasem a Kanadem v roce 1981 a poté modifikována za pomoci Tomasiho v roce 1994. Lucas – Kanade vytvořili metodu, za pomoci které lze sledovat objekt z jednoho obrazu do druhého a poté Tomasi – Kanade umožnili lepší výběr příznaků pro sledování. [21] [31] [34]

Technika je založená na zjišťování pohybu pomocí Lucas – Kanade schématu optického toku a vybrání dobrých znaků v obraze na sledování (Shi - Tomasi). Vyhovující znaky obrazu na sledování určíme na základě minimálního vlastního čísla  $2 \times 2$  gradientních matic vypočítaných v každém bodě obrazu, kde větší hodnoty signalizují větší změny a tedy také větší vhodnost pro tento účel. Drobné změny polohy bodů ve dvou po sobě jdoucích snímcích dopočítáme pomocí Lucas – Kanade rovnic, v případě větších změn využijeme Newton – Raphsonovu metodu. [21] [31] [34][17]

Vývojový diagram je znázorněn na následujícím Obrázek 9:



Obrázek 9: Shi - Tomasi: Výběr dobrých znaků [4]

Zde můžeme vidět porovnání výhod a nevýhod jednotlivých algoritmů:

Tabulka 2: Výhody a nevýhody sledovacích algoritmů

	Výhody	Nevýhody
KLT algoritmus	Vysoká přesnost	Náročné na paměť
	Kratší výpočetní čas	
	Robustní - lépe snáší šum, změny jasů a vývoj dynamiky scény	
CAM Shift	Výpočetně méně náročný	Neefektivní při velké dynamice scény

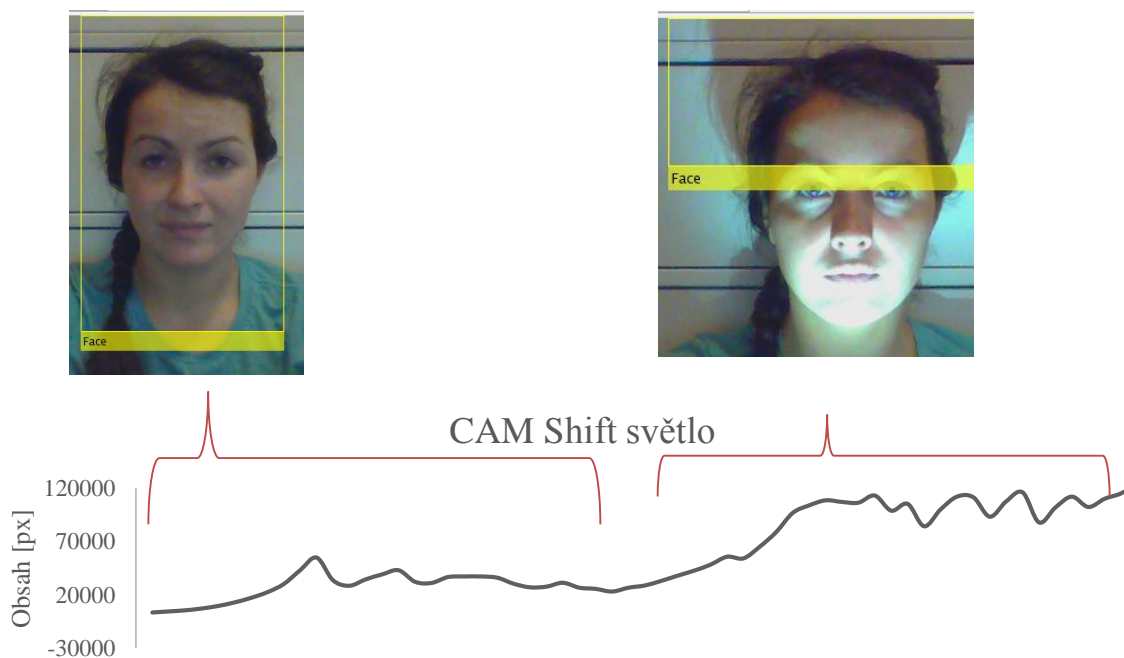
## 5. Testování algoritmů

Pro detekci obličeje a jeho sledování byly testovány dva algoritmy. Jsou popsány v 4. kapitole - Sledovací algoritmy. První z testovaných algoritmů je CAM Shift a druhý KLT algoritmus. Byly podrobeny různým situacím a jsou zhodnoceny jak subjektivně, tak objektivně pomocí měření obsahu detekovaného ROI. Byly zaznamenávány časové úseky a z nich hodnocena změna obsahu, výsledky lze vidět v grafech.




### 5.1 Změna světelných podmínek

Pro změnu světelných podmínek byla vybrána situace, kdy je snímáno video za denního osvětlení a poté je obličej nasvícen stolní lampou.

CAM Shift





KLT






## 5.2 Změna polohy hlavy

Změna polohy hlavy byla provedena náklonem na jednu a na druhou stranu.

### CAM Shift





### KLT




### 5.3 Změna vzdálenosti

Na začátku testování vlivu vzdálenosti byla vzdálenost od kamery přibližně 30 centimetrů a v průběhu snímání byl obličej oddálen na přibližně 100 centimetrů.


CAM Shift



KTL





→ KLT vzdálenost → Rostoucí vzdálenost





## 5.4 Překrytí části obličeje

Pro překrytí byl vybrán papír velikosti A4 a v průběhu snímání jím byla zakryta polovina obličeje.

CAM Shift



KLT



## 5.5 Zhodnocení výsledků

Hodnocení probíhá za denního světla doplněného o rozsvícení pokojového světla. Při rapidní změně světelných podmínek dochází u CAM Shiftu ke ztrátě sledovaného obličeje do té míry, že i z obrázků je patrné, že již vůbec nezabírá oblast celého obličeje, ale jenom tu část, kde je schopný určit jeho původní barvu. Naopak u KLT algoritmu dochází k podstatné změně velikosti ROI, kdy je algoritmus schopen vhodné příznaky pouze u části tváře.

Při změně polohy obličeje testované osoby vidíme, že u CAM Shift algoritmu došlo k podstatnému zmenšení oblasti zájmu (hodnoty klesly o více než 50 000 pixelů), kdežto u KLT algoritmu je změna velikosti pouze v rámci několika tisíc pixelů a naopak oblast zájmu se zvětšuje.

Při změně vzdálenosti je patrné u CAM Shiftu z grafu, že se velikost ROI v čase mění velice nepravidelně. Naopak u KLT algoritmu je velice názorné, že s rostoucí vzdáleností se zmenšuje i detekované ROI.

Překrytím obličeje u CAM Shiftu dochází ke zmenšení ROI na viditelnou část obličeje. Je vidět, že změna obsahu detekované oblasti zájmu je o více než 50 000 pixelů. Naopak u KLT algoritmu je velikost ROI stabilní, ačkoliv si lze všimnout drobných fluktuací velikosti obsahu. Je to ale zanedbatelná hodnota, pohybuje se v rozmezí  $\pm 300$  pixelů.

Celkový výsledek tedy potvrzuje Tabulka 2. KLT algoritmus lze z testování považovat za vysoce přesný, s lepší časovou odezvou a obecně lépe snáší změny osvětlení.

## 6. Metody zpracování signálu

### 6.1 Analýza nezávislých komponent

Analýza nezávislých komponent umožňuje rozložit signál na jednotlivé zdrojové komponenty, ze kterých se skládá původní signál. Jedná se o tzv. slepou separaci signálů. Funguje tak, že oddělí zdrojový signál ze směsí, i bez znalostí o jejich původním smísení. Odhadované zdrojové signály by měly pro použití této metody být na sobě statisticky nezávislé. ICA vyžaduje pro vstup vícekanálový zdroj. V tomto případě se jedná o záznam z RGB kamery, který tuto podmínku splňuje a proto je možné této analýzy využít. [24]

ICA algoritmus předpokládá, že pozorovaný signál je lineární směs zdrojových signálů, což můžeme reprezentovat mixážní rovnicí:

$$\mathbf{x}(t) = \mathbf{A} \cdot \mathbf{s}(t), \quad (5)$$

kde  $\mathbf{x}(t)$  je sloupcový vektor ve tvaru  $\mathbf{x}(t) = [x_1(t), x_2(t), x_3(t)]^T$ , který reprezentuje vstupní signál, matice  $\mathbf{s}(t) = [\mathbf{s}_1(t), \mathbf{s}_2(t), \mathbf{s}_3(t)]^T$  obsahující nezávislé zdrojové signály a čtvercová směšovací matice  $\mathbf{A}$  obsahuje směs mixážních koeficientů  $s_{ij}$  o velikosti  $m \times n$ . Cílem ICA je nalezení separační matice  $\mathbf{W}$ , které je aproximací inverzní matice k originální směšovací matici  $\mathbf{A}$ , kde výstupem rovnice

$$\hat{\mathbf{s}}(t) = \mathbf{W} \cdot \mathbf{x}(t), \quad (6)$$

je určení vektoru  $\mathbf{s}(t)$ , který obsahuje základní zdrojové signály. Pro správné určení nezávislých zdrojů  $\mathbf{W}$  je důležité mít co nejmenší míru závislosti u zdrojových signálů. [24]

#### 6.1.1. JADE algoritmus

V této diplomové práci je využito pro separaci signálů algoritmu JADE (Joint Approximate Diagonalization of Eigen matrices). Je založen na práci pánů Cardoso a Souloumiac z roku 1993 a provádí separaci pomocí společné aproximační diagonalizace vlastních matic. [7] [8]

Pro lepší představu o fungování algoritmu je vhodné si jej rozdělit na části:

- 1) Nalezení vlastních čísel a symetrických matic vhodných k diagonalizaci
- 2) Proces aproximační diagonalizace nalezených matic

Pro pochopení fungování algoritmu je důležité říct, že hledaný signál je lineární kombinací směšovací matice a náhodného signálu, smíseném s aditivním šumem o neznámém rozptylu. Vše lze přehledně vidět v následující rovnici.

$$\mathbf{x}(t) = A \cdot \mathbf{s}(t) + \mathbf{n}(t), \quad (7)$$

kde  $\mathbf{x}(t)$  je hledaný signál,  $A$  směšovací matice,  $\mathbf{s}(t)$  představuje náhodný signál a  $\mathbf{n}$  reprezentuje aditivní šum. [1] [7] [8]

Pro nalezení symetrických matic, které jsou vhodné pro diagonalizaci, jejímž výstupem jsou vlastní čísla, je důležité vstupní signál upravit za pomoci matice náhodných čísel  $W$ , která provádí proces bělení. Tzv. *whitening* probíhá tak, že signál je vynásoben s touto bělicí maticí a je získána rovnice

$$\mathbf{y}(t) = W \cdot \mathbf{x}, \quad (8)$$

o proměnných  $W$  – náhodná matice a  $\mathbf{x}$  – vstupní signál. Z  $\mathbf{y}(t)$  jsou následně odhadovány kumulační koeficienty čtvrtého řádu, nezbytné pro druhý krok algoritmu. Aproximační diagonalizace vlastních matic je v tomto případě založena na Givensihových rotacích. Diagonalizací matice je myšlen proces hledání odpovídající diagonální matice pro požadovanou matici, která diagonalizovat lze. V každém kroku iterace programu probíhá výpočet Givensihových úhlů a rotací prostřednictvím matice  $\Theta_{kl}$  (Givensihova rotace - Obrázek 10). [1] [7]

$$\Theta_{kl} = \begin{bmatrix} 1 & 0 & \dots & \downarrow^k & \dots & \downarrow^l & \dots \\ 0 & 1 & 0 & 0 & \dots & 0 & \dots \\ & & \dots & \ddots & & \vdots & \\ k \longrightarrow & 0 & \dots & \cos \theta_{kl} & \dots & -\sin \theta_{kl} & \dots \\ & & & \vdots & \ddots & \vdots & \\ l \longrightarrow & 0 & \dots & \sin \theta_{kl} & \dots & \cos \theta_{kl} & \dots \\ & & & \vdots & & \ddots & \\ & \dots & & 0 & \dots & 0 & 1 \end{bmatrix}$$

Obrázek 10: Givensihova rotace [1]

Kde  $\theta_{kl}$  je úhel, který je počítán v každém kroku. [1] [7]

Pro názornost funkčnosti algoritmu JADE je v následujících odstavcích uvedena jeho charakteristika v programovém prostředí.

```
function [A, S] = jade (X, m)
```

Vstupní parametr  $X$  je vektor vzorků vstupního signálu z  $n$  senzorů a  $m$  je volitelný parametr, který udává počet zdrojů. Pokud jej neudáme, funkce JADE automaticky bere stejný počet zdrojů, jako je senzorů. Výstupem, reprezentovaným jako  $A$  je odhad mixážní matice a výstupem  $S$  je odhad zdrojových signálů o velikosti.

Funkce provádí separaci zdrojových signálů, v případě, že:

$X$  je matice o rozměrech  $n \times T$  modelovaná jako

$$S = A^{-1} \cdot X, \quad (9)$$

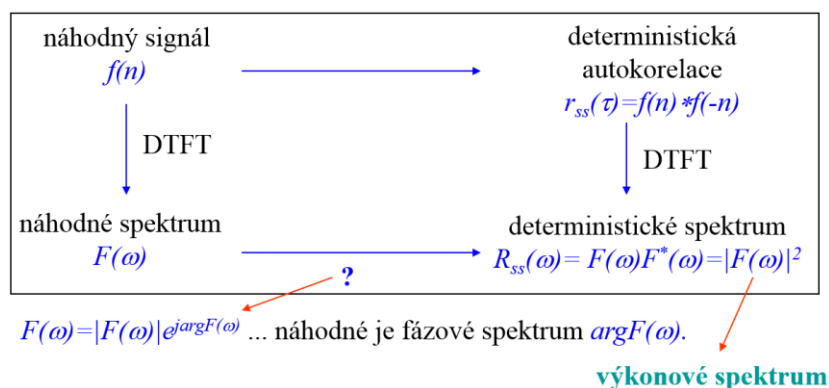
kde  $A$  je neznámá matice o velikost  $n \times m$  a  $S$  je matice odhadovaného signálu s vlastnostmi:

- Pro každé  $t$  jsou komponenty  $S(:, t)$  statisticky nezávislé
- Pro každé  $p$  jsou  $S(p, :)$  realizace zdrojového signálu s nulovou střední hodnotou

## 6.2 Spektrální analýza

Komponenty získané z ICA algoritmem JADE jsou následně podrobeny spektrální analýze pomocí funkce *fft* z knihovny programového prostředí MATLAB. Pro každou komponentu zvlášť je tvořeno výkonové spektrum Fourierovou transformací. Jedná se tedy o neparametrickou metodu, kdy je velice snadný výpočet. Z jednotlivých komponent by mělo být zřejmé, která obsahuje jako zdroj tepovou frekvenci. Tato složka je vidět ve většině případů ve všech třech komponentách. Kvůli tomuto jevu byla Fourierova transformace aplikována na všechny komponenty. [2]

Principiálně funguje spektrální analýza tak, že je převedena časová rovina signálu do frekvenční. Převod může být proveden dvěma způsoby. V případě této práce je využito metody periodogramu, kdy se jedná o souborový průměr jednotlivých výkonových spekter z  $M$  realizací o délce  $N$  vzorků, viz Obrázek 11. [2]



Obrázek 11: Neparametrické metody výpočtu výkonového spektra [2]

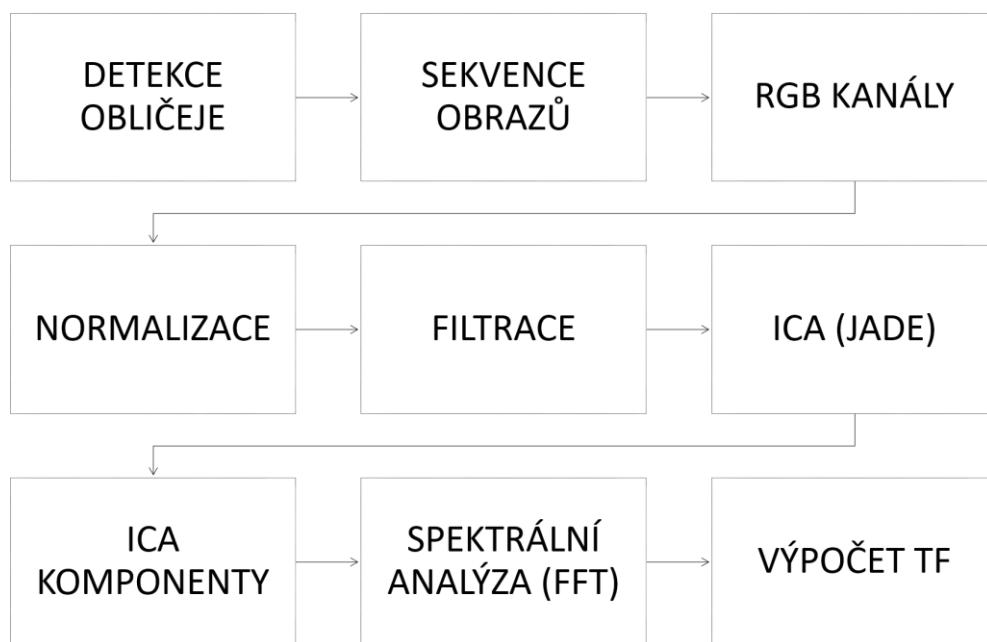
Pro naše případy byla použita pro výpočet výkonového spektra větev:

*Náhodný signál* → *DTFT* → *Náhodné spektrum* → *Výkonové spektrum*

## 7. Program pro bezkontaktní detekci tepové frekvence

Pro implementaci aplikace a samotné zpracování signálů je využito programového prostředí MATLAB (verze R2014a).

V následujících bodech je detailně popsáno zpracování signálu. Jednotlivé kroky jsou vidět v následujícím blokovém diagramu (Obrázek 12) a detailněji jsou rozepsány v jednotlivých podkapitolách.



Obrázek 12: Vývojový diagram výpočtu tepové frekvence

Zevrubný popis jednotlivých kroků programu:

- Detekce obličeje – je nutné v první řadě detekovat obličej, protože v něm probíhá nejvýrazněji změna tepové frekvence, je tedy žádoucí získat pro analýzu co nejvíce signálů obsahující tepovou frekvenci namísto rušivého signálu pozadí
- Sekvence obrazů – pro analýzu je nutné sejmut jednotlivé obrazy z videa
- RGB kanály – po získání sekvencí obrazů z nich získáváme jednotlivé RGB kanály, aby byly separované pro vstup do ICA analýzy
- Normalizace – normalizace signálu je nutná pro získání poměrových hodnot jednotlivých barevných kanálů namísto jejich jasové reprezentace
- Filtrace – filtrace signálu je nezbytná pro získání pásma, ve kterém se fyziologicky vyskytuje tepová frekvence
- ICA analýza – separace vstupních signálů na jednotlivé zdrojové komponenty

- ICA komponenty – vzniklé komponenty jsou vstupem do samotné analýzy pro získání tepové frekvence
- Spektrální analýza – převodem signálu z časové do frekvenční roviny jsou získány výkonová spektra jednotlivých komponent, ze kterých lze odečíst nejvyšší frekvence, které reprezentují tepovou frekvenci v komponentách
- Výpočet TF – pomocí jednoduchého vzorce jsou získané frekvenční hodnoty převáděny na počet tepů za minutu a tím je získána požadovaná hodnota tepové frekvence

## 7.1 Detekce obličeje

Detekce obličeje v programu je prováděná pomocí funkce *DetectFace.m* ve tvaru:

```
function DetectFace(varargin)
```

vstupem do funkce je proměnná *varargin*, která dovolí funkci přijmout libovolný počet proměnných. Výstupem je ohraničení detekovaného obličeje. Mimo jiné funkce umožňuje vícenásobnou detekci obličeje v případě neúspěšné první detekce a neúspěšné detekce z důvodu nepřítomnosti obličeje v obraze.

## 7.2 Sekvence obrazů

V dalším kroku je spouštěno nahrávání obrazů ze snímání scény funkcí *ImageSave.m* ve tvaru:

```
function ImageSave(varargin)
```

Vstupem do funkce je opět proměnná *varargin*, výstupem je nasnímání sekvence obrazů v požadovaném časovém úseku, který je možné uživatelem nastavit. Tato hodnota je vstupem do funkce a po zadanou dobu tato funkce umožňuje vidět ubíhající čas na stopkách zobrazených v uživatelském prostředí aplikace. Po ukončení snímání obrazů funkce *ImageSave.m* volá funkci *Analysis.m*, ve které probíhá samotné zpracování signálu pro výpočet *fft* a spektrální analýzu.

Funkce *Analysis.m* je v programu ve tvaru:

```
function bpm = Analysis(videoFrames)
```

vstupem do funkce je 4D matice obrazů, kdy první hodnota z proměnné *videoFrames* indexuje řádky, druhá sloupce, třetí RGB složky a poslední prvek jsou samotné obrazy jdoucí po sobě. Výstupem je aktuální hodnota tepové frekvence.

### 7.2.1. Normalizace signálu

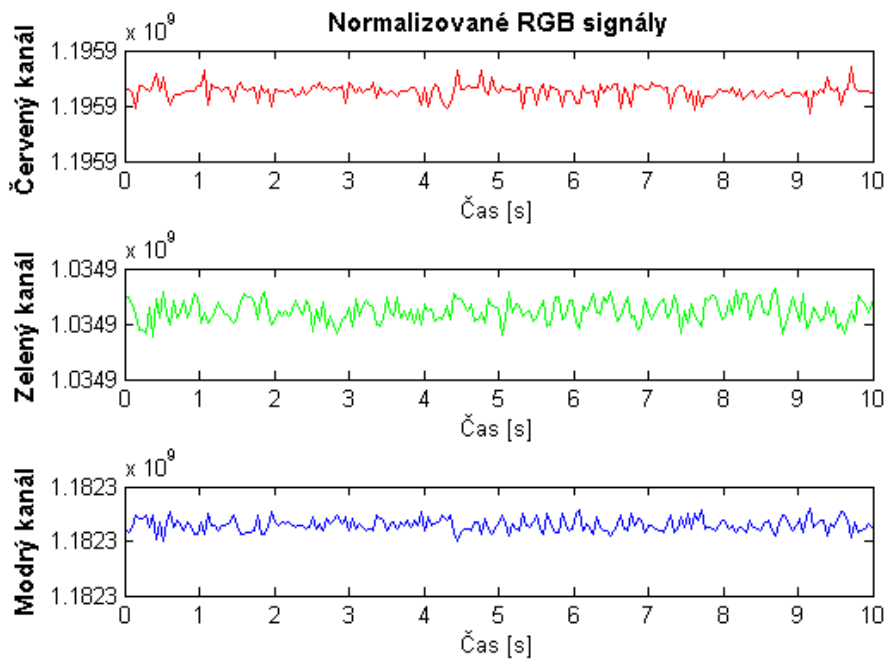
Vstupem pro tento proces je získaná proměnná *videoFrames*, která obsahuje veškerou potřebnou informaci v podobě zaznamenaných obrazů. Pro získání signálu je potřeba sečíst všechny hodnoty z obrazu v řádcích a sloupcích. To je zajištěno tím, že v programu použijeme za sebou dvakrát funkci *sum*. Normalizací signálu je pak myšlen proces, kdy je zastoupení jednotlivých barev reprezentováno proporcionalně vůči ostatním barvám v obraze namísto jasové reprezentace. Platí jednoduché vzorce: [36]

$$r = \frac{R}{R + G + B} \quad (10)$$

$$g = \frac{G}{R + G + B} \quad (11)$$

$$b = \frac{B}{R + G + B} \quad (12)$$

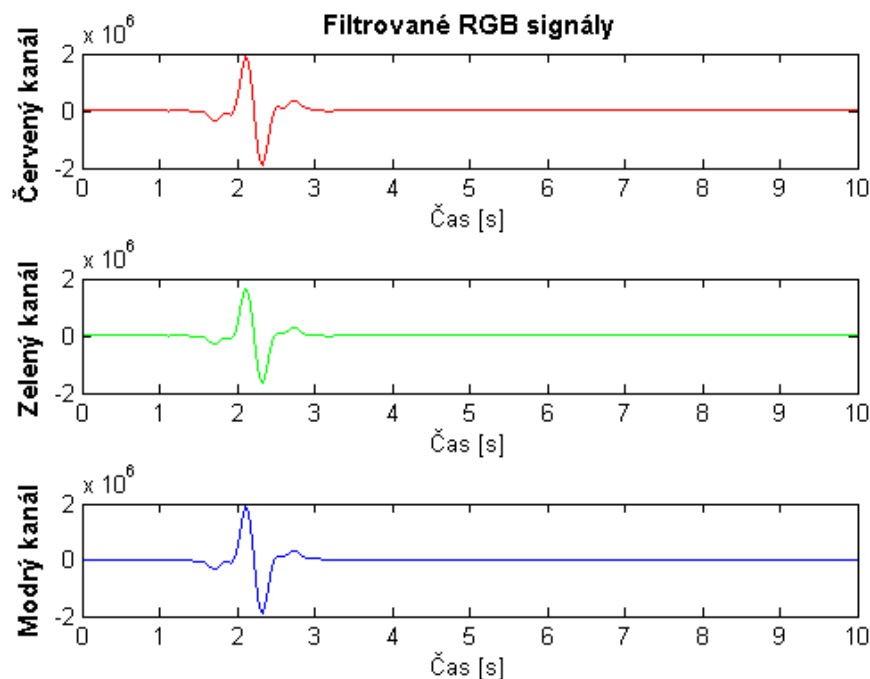
Na Obrázek 13 můžeme vidět výsledné normalizované signály:



Obrázek 13: Získané RGB signály z kamery

## 7.2.2. Filtrace signálů

Filtrování signálu je provedeno pomocí funkce *filter*, kde je v první řadě potřeba navrhnout filtr. V tomto případě je použit filtr pásmová propust, kdy je důležité filtrovat oblast, ve které se fyziologicky vyskytuje tepová frekvence. To je rozmezí od 40 do 240 tepů za minutu. Ve frekvenční oblasti se jedná o rozmezí od 0,7 do 4 Hz. Po filtraci je zpoždění ošetřeno pomocí funkce *circshift* a takto zpracovaný signál vstupuje do ICA analýzy. Výsledek filtrace je vidět na Obrázek 14:



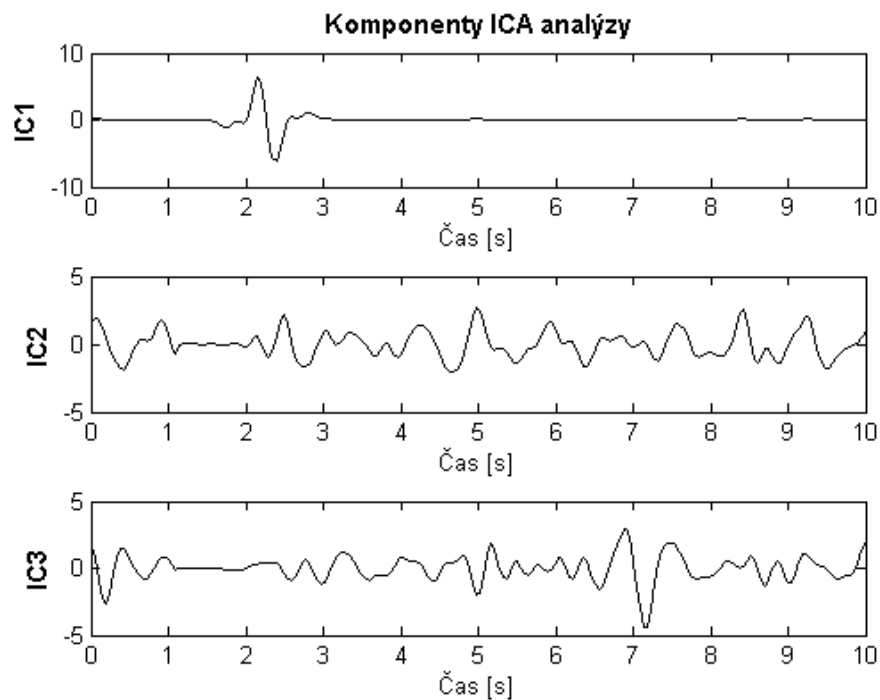
Obrázek 14: Filtrované RGB signály v pásmu 0,75 až 4 Hz

## 7.2.3. Analýza nezávislých komponent (ICA)

Funkcí, kterou je prováděna analýza nezávislých komponentů je v programu volána jako *jade* ve tvaru:

```
[~, icaOutput] = jade(filteredRGB)
```

Vstupem do funkce je jsou normalizované filtrované signály z RGB kanálů sejmutých z videokamery a *icaOutput* je výstupní matice tří komponent. Vzniklé komponenty jsou vidět na následujícím obrázku (Obrázek 15).



Obrázek 15: Získané komponenty ICA analýzy

#### 7.2.4. Spektrální analýza komponent

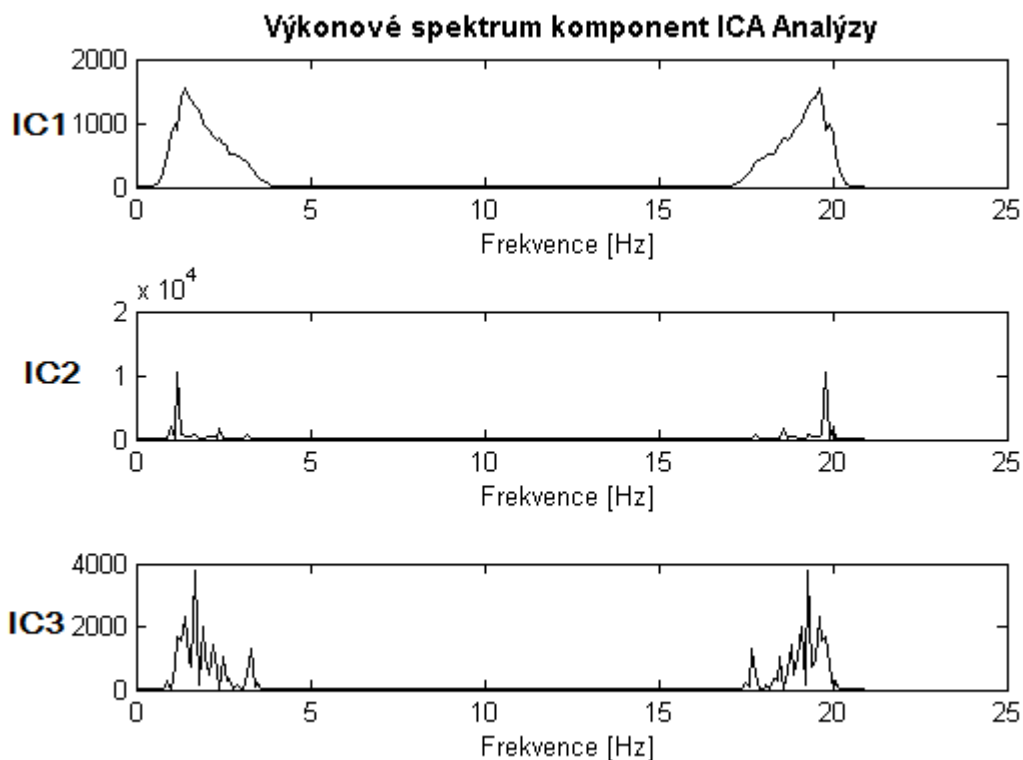
Poté, co získáme jednotlivé komponenty z analýzy, je potřeba pro výpočet tepové frekvence získat jednotlivá výkonová spektra komponent. Pro výpočet výkonového spektra využíváme Fourierovu transformaci. Získáváme tak výkonová spektra jednotlivých signálů s výrazným vrcholem v oblasti od 0,7 do 4 Hz, což odpovídá tepové frekvenci testované osoby.

Zápis získání výkonového spektra je následující:

```
spectrum = abs(fft(icaOutput, size(icaOutput, 2) * 10, 2)) .^ 2
```

vstupem jsou komponenty ICA analýzy v proměnné *icaOutput*, délka proměnné zjištěná pomocí funkce *size* a je potřeba indexovat druhý prvek z výsledné matice této funkce. Umocněním získaného spektra získáváme požadované spektrum výkonové.

Na následujícím Obrázek 16 je vidět výsledek.



Obrázek 16: Výkonová spektra ICA komponentů

Z obrázku je zřejmé, že nejvýrazněji se projevila složka IC2, ale je vidět, že i IC1 a IC3 obsahují složku o stejné, či podobné frekvenci.

Tabulka 3: Příklad frekvencí získaných maxim z jednotlivých komponent

Komponenta	Frekvence (Hz)
IC1	0,9333
IC2	1,4667
IC3	1,1333

### 7.2.5. Výpočet tepové frekvence

Pro výpočet tepové frekvence vybíráme maximální hodnoty ze spektra komponent IC analýzy. V těch se vyskytují separované signály tepové frekvence a ostatní signály jako jsou kupříkladu šum z kamery či nepatrné pohyby obličeje. Je vybírán maximální výkon ve spektrech jednotlivých kanálů a indexujeme jejich pozici ve spektru. Získáváme tak indexy značící, kde se na ose  $x$  vyskytuje maximum. Tyto hodnoty jsou dále používány jako index pro frekvenční osu, kde je již získána hodnota frekvence v Hz. Pro převod frekvence na tepy za minutu je použit vzorec

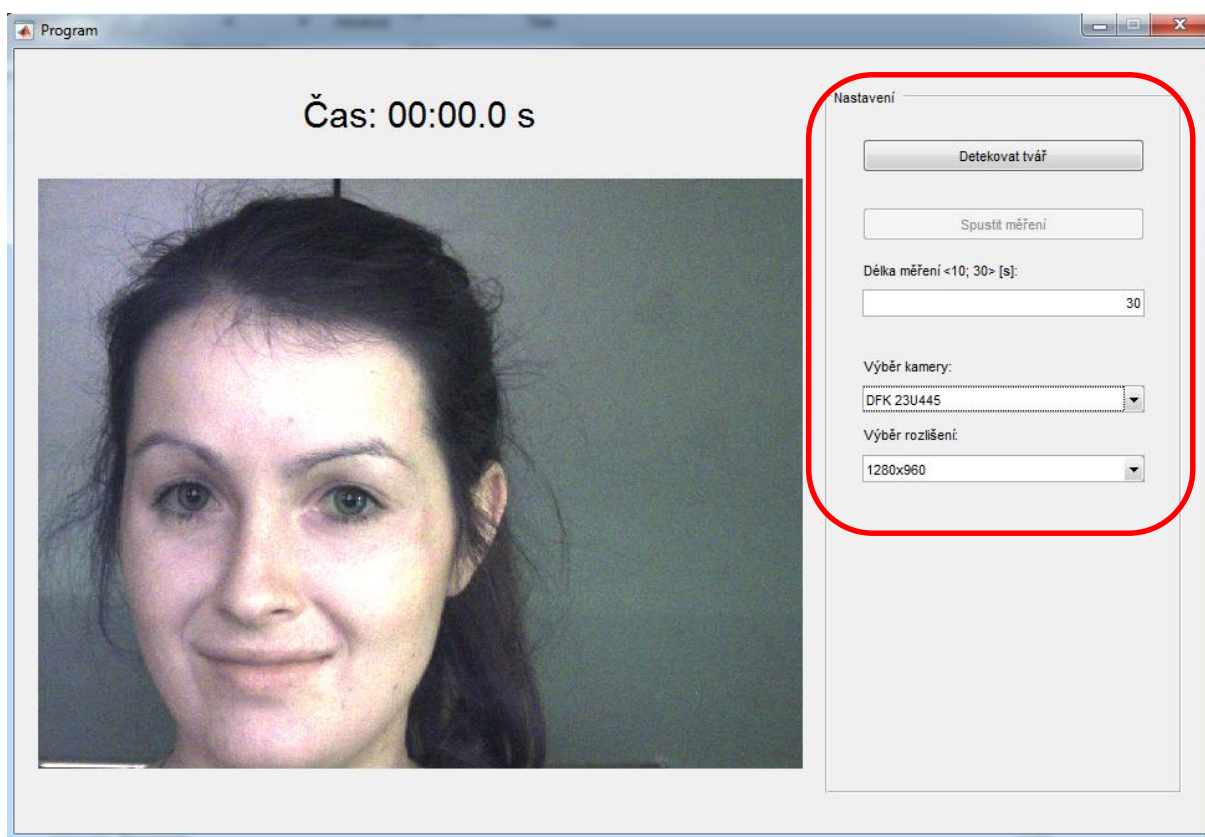
$$TF = f \cdot 60, \quad (13)$$

kde  $TF$  je počet tepů za minutu,  $f$  je nalezená frekvence a tuto hodnotu násobíme šedesáti pro převod na minuty.  $TF$  ze všech tří složek je následovně průměrováno ze všech tří komponent.

## 8. Uživatelské prostředí aplikace

Uživatelské prostředí pro aplikaci je tvořeno v prostředí MATLAB za použití funkcí dostupných z knihovny prostředí. Je využito funkcí *uicontrol*, *handle*, *callback* a také funkcí, které jsou schopny získávat anebo nastavovat hodnoty jednotlivých prvků využitých v programu, a to funkce *set* a *get*.

Po spuštění programu pomocí funkce *Program.m* dochází k otevření hlavního okna programu, které je rozdělené na dvě poloviny jak je vidět na Obrázek 17. Jedna slouží pro vykreslení obrazu z kamery a druhá pro nastavování požadovaných hodnot a pro spuštění detekce a měření.

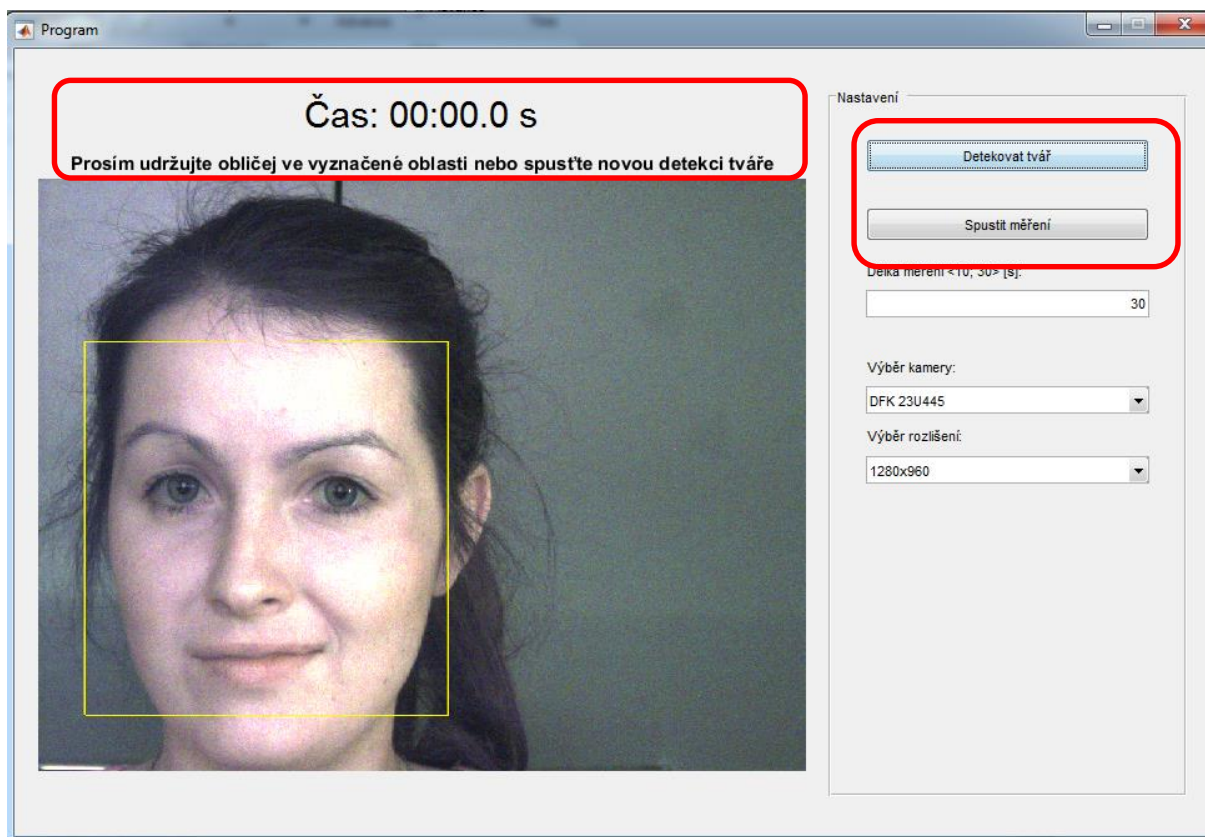


Obrázek 17: Uživatelské rozhraní programu při spuštění

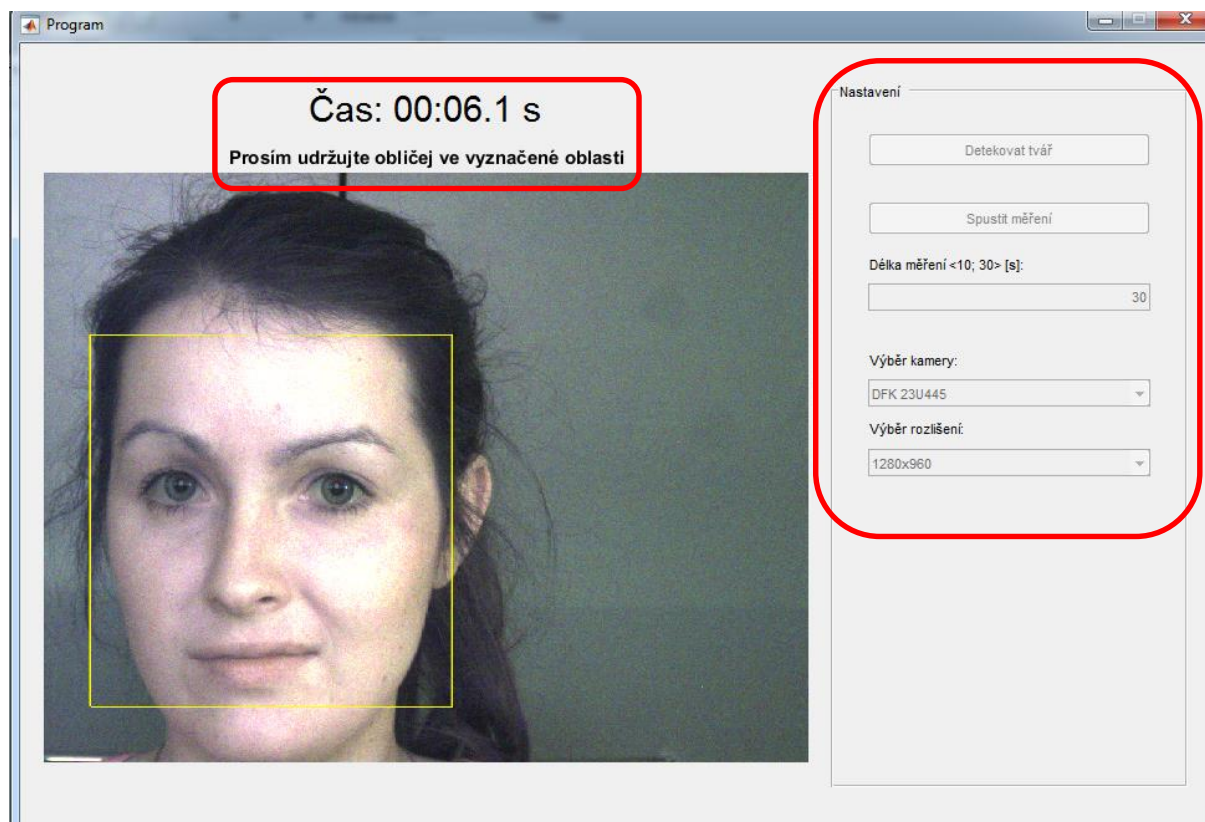
Před začátkem měření je možné nastavovat kameru dle výběru ze seznamu dostupných kamer nazvaný jako *Výběr kamery*. Zde se ukazují kamery, které jsou pro počítač dostupné. Po vybrání požadované kamery lze nastavit správné rozlišení, které má kamera použít. Defaultně, na začátku měření, je nastaveno rozlišení, které je nastavené ve vlastnostech kamery.

Doba měření je defaultně nastavena na 10 vteřin, ale rozmezí možných hodnot je 10 až 30 vteřin. Při zadání nečíselné hodnoty, se opět nastaví defaultních 10 vteřin.

Pro započetí měření je potřeba detekovat tvář v obraze. Tato funkce je dostupná pod tlačítkem *Detekovat tvář*. V případě úspěšné detekce je zobrazen čtverec, kde byl nalezen obličej a je vypsáno dialogové okno, „*Prosím udržujte obličej ve vyznačené oblasti nebo spusťte novou detekci tváře*“. To dává volbu opětovné detekce tváře v případě, že se uživateli aktuální detekce nelíbí. V druhém případě, že tvář detekovaná není vůbec, je zobrazeno dialogové okno „*Detekce tváře se nezdařila, prosím opakujte pokus*“. V takovémto případě opět nutné použít tlačítko *Detekovat tvář*. Předtím, než je správně detekovaná tvář, nelze spustit měření. Po správné detekci je již tlačítko *Spustit měření* dostupné, viz následující Obrázek 18.

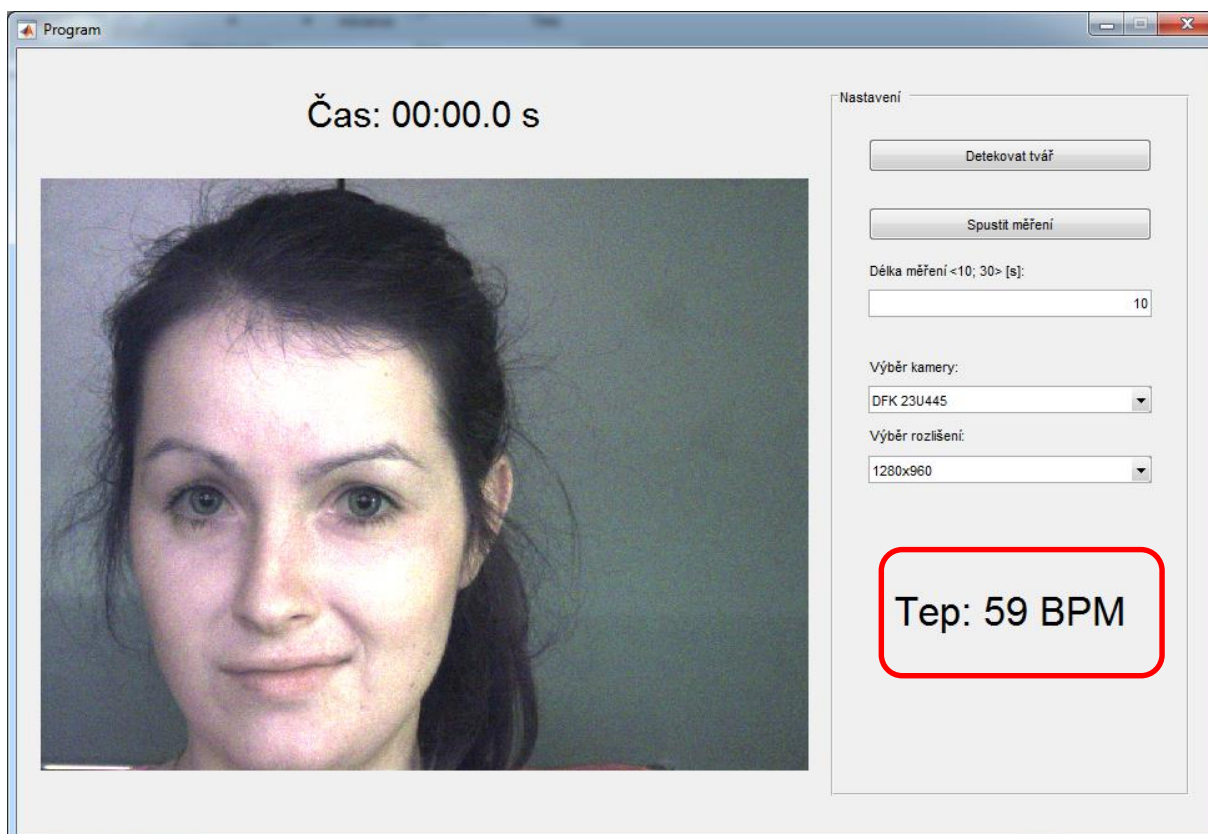


Obrázek 18: Dostupnost tlačítek před měřením



Obrázek 19: Nedostupná tlačítka během měření

Po spuštění měření je vypsána dialogové okno „*Prosím, udržte obličej ve vyznačené oblasti*“ a je nezbytné toto upozornění následovat a držet hlavu ve vyznačeném čtverci, aby byly správně nasnímány signály. Nad videem s nahráváním běží stopky po dobu nastavenou v políčku *Délka měření*. V průběhu měření jsou všechna tlačítka nedostupná (Obrázek 19). Jakmile časomíra dosáhne požadované hodnoty, nuluje se a vypíše se dialogové okno „*Probíhá analýza tepové frekvence*“. Po dokončení analýzy se zobrazí ve spodní oblasti levého panelu dialogové okno s informací o tepové frekvenci v podobě „*Tep: XXX BPM*“ a program se vrací na začátek a lze zpustit další detekci, viz Obrázek 20.



Obrázek 20: Vypsaná aktuální tepová frekvence a možnost dalšího měření

## 9. Průběh a metodika měření

Experiment byl realizován na 10 dobrovolnících a snímání trvalo 15 vteřin. To je dostačující hodnota pro získání 17 až 20 tepů za minutu. Pro testování byla vybrána místnost na ústavu biomedicíny. V následujících podkapitolách jsou popsány použité přístroje a podmínky experimentu.

### 9.1 Snímací aparatura


V následující kapitole jsou rozebrány jednotlivé technické komponenty a jejich nastavené parametry používané při testování programu.

#### 9.1.1. Kamera

Snímání obličeje je realizováno pomocí kamery od společnosti Imaging Source. Je to typ USB 3.0 Color Industrial Camera model DFK 23U445, viz Obrázek 21. Její rozlišení je 1280 x 960 a její senzor je Sony ICX445A, který dovede snímat kvalitně i špatně osvětlenou scénu. Vzhledem k tomu, že světelné podmínky pro detekci obličeje jsou velice důležité, bude tato kamera vyhovovat. Na Obrázek 22 jsou zobrazeny spektrální vlastnosti kamery. Pro její správnou funkci je potřeba instalovat softwarovou aplikaci IC Capture, Image Acquisition (version 2.4.612.2455). Poté lze zobrazit snímky buď ve formě sekvence, nebo jako datový tok. [33]




Obrázek 21: Snímací kamera DFK 23U445 [33]



Obrázek 22: Spektrální citlivost sensoru kamery[33]

Manuální nastavení na videokameře je dostupné pouze pro zaostření a nastavení clony. Nelze přesně určit toto nastavení, protože není možné z manuálního nastavení odečíst číselné hodnoty. Během měření zůstávaly hodnoty beze změny. Pro detailnější nastavení kamery je dostupný Software IC Capture, který umožňuje náhled na snímanou scénu v reálném čase a je možné zde nastavit další parametry snímání jako je vzorkovací frekvence, rozlišení a formát snímání.



Obrázek 23: Panel nástrojů software IC Capture 2.4

Nastavení pro potřeby testování bylo následující, viz Obrázek 23:

- Rozlišení kamery: 1280 x 960 (jiné není dostupné)
- Vzorkovací frekvence: 15 fps

### 9.1.2. Akviziční jednotka Biopac

Jako kontrola pro správnost bezkontaktního odhadu tepové frekvence je využit systém Biopac. Je dostupný ve studentské laboratoři, kde probíhalo testování aplikace. Akviziční hardware dovede převádět měřený analogový signál na digitální, který lze pak dále zpracovávat. Přenos je zajištěn pomocí USB portu do počítače. Snímané biosignály mohou být zobrazeny

v software AcqKnowledge, kde je možné je ukládat a znovu zobrazovat. Systém umožňuje snímání základních fyziologických signálů, z nichž pro potřebu této práce je využito snímání tepové frekvence pomocí fotopletysmografického (PPG) senzoru.

PPG prstový senzor funguje na fotopletysmografickém principu. Dovede zaznamenávat pulsní křivku krevního objemu pomocí optické metody. Senzor obsahuje IR zdroj světla a fotodiodu. Světelný paprsek je vyslán skrz tkáň, kde je modulován v závislosti na změnách objemu krve. Detekujeme odražené, absorbované či rozptýlené záření a výstupem je pletysmografická křivka. [6]

### 9.1.3. Osvětlení

V místnosti konání experimentu bylo uzpůsobeno prostředí tak, že vliv ostrého slunečního světla byl co nejmenší. Měření pomocí vzniklého programu může být silně ovlivněno okolním osvětlením, proto bylo zvoleno umělé osvětlení v podobě lampy. Dostupná lampa byla Digital Light – 1000, od firmy FOMEI. Zdrojem světla je zde halogenová žárovka. Na Obrázek 24 je vidět možnost nastavení požadovaného výkonu osvětlení. [9]



Obrázek 24: Možnost nastavení výkonu osvětlení [9]

### 9.1.4. Průběh testování

Dobrovolník se usadil na židli a byla mu nasazena PPG sonda pro referenční měření a byl vyzván k nehybnému a klidovému setrvání na daném místě, ve stejné pozici. Před začátkem měření dobrovolník zavřel oči, aby byl zmírněn vliv pohybu očí v obraze, který by mohl dodávat do dat zbytečný šum. Po detekci obličeje bylo spuštěno měření, které trvalo 15 vteřin. Po skončení časového úseku měření byl bezkontaktně detekován tep a odečtena jeho

hodnota z okna programu. Referenční hodnota byla odečtena ze stejného časového úseku měření fotopletysmografické sondy v systému Biopac. Hodnoty byly zaznamenány a dále podrobeny statistickému vyhodnocení.

## 10. Analýza získaných dat

V následujících kapitolách jsou uvedeny získané hodnoty měření a výsledky statistické analýzy.

### 10.1 Naměřené hodnoty

Při testování bylo přítomno 10 dobrovolníků, z toho 6 žen a 4 muži. Jejich věk se pohyboval od 24 let do 29 let. Byly pořizovány 15 vteřinové záznamy a následující Tabulka 4 ukazuje naměřené hodnoty.

Tabulka 4: Získané hodnoty testovacího měření

Dobrovolník	Pohlaví	Věk	Program [tep/min]	Biopac [tep/min]
1	Žena	24	69,0	72,0
2	Žena	24	80,0	82,0
3	Žena	25	70,0	72,0
4	Žena	24	72,0	76,0
5	Žena	26	63,0	64,0
6	Žena	23	73,0	80,0
7	Muž	29	100,0	96,0
8	Muž	24	78,0	84,0
9	Muž	23	60,0	60,0
10	Muž	22	67,0	68,0

Pro hodnocení funkčnosti programu je potřeba provést analýzu získaných dat. Pro toto měření je využito metody korelace a vypočet relativní a absolutní chyby měření. V následujících kapitolách je detailnější popis metod a jejich výsledky.


#### 10.1.1. Korelační analýza

Metoda korelace je použita pro zjištění závislosti dvou naměřených řad hodnot. Míra korelace je určena rozmezím  $<-1; 1>$  a to korelačním koeficientem  $r$ . V případě, že jsou na sobě dvě veličiny závislé, je absolutní hodnota koeficientu větší. Korelační koeficient je počítán dle vzorce [37]:

$$r = \frac{\sum[(x_i - \bar{x}) \cdot (y_i - \bar{y})]}{\sqrt{\sum(x_i - \bar{x})^2 \cdot (y_i - \bar{y})^2}}, \quad (14)$$

kde  $x_i, y_i$  jsou odchylky jednotlivých hodnot a  $\bar{x}, \bar{y}$  jsou průměry obou veličin. Pro názornost lze zobrazit i korelační graf, kde je zobrazena přímka lineární regrese s koeficientem  $R^2$ , značící míru vhodnosti použité regresní rovnice. Hodnoty blízké 1 naznačují, že odchylka regresní přímky od naměřených hodnot je minimální. [37]

Na Obrázek 25 je graf korelace měřené hodnoty z bezkontaktního měření s referenční veličinou získanou pomocí systému Biopac. Na ose  $x$  jsou měřené hodnoty z Biopacu a na ose  $y$  jsou hodnoty ze vzniklého programu. Dle vypočtené hodnoty spolehlivosti  $R$  je vidět, že získané hodnoty následují lineární trend. Získaná hodnota korelačního koeficientu je 0,961 což naznačuje, že jsou na sobě hodnoty závislé, viz Obrázek 25.



Obrázek 25: Graf korelace měřené veličiny

### 10.1.2. Chyby měření

Pro hodnocení kvality a správnosti měření je důležité vyhodnotit i chyby měření. Chybou měření je myšlen rozdíl mezi naměřenou hodnotou (v našem případě bezkontaktní měření) a skutečnou hodnotou (měření referenčního). Důležité je, že skutečná hodnota měření je neznámá a nelze tedy tímto způsobem chybu měření počítat. Z rozdílu neměřené a odhadnuté hodnoty lze stanovit absolutní chybu. Ta charakterizuje velikost intervalu, ve které lze s určitou pravděpodobností očekávat, že se bude skutečná hodnota vyskytovat. Výsledkem je tedy následující rovnice: [13]

$$x = x_0 \pm \delta x_0, \quad (15)$$

kde  $x$  je skutečná hodnota měřené veličiny  $X$ ,  $x_0$  je odhad skutečné hodnoty  $x$  a  $\delta x_0$  je absolutní chyba odhadu, která leží v intervalu  $(x_0 - \delta x_0, x_0 + \delta x_0)$ . [13]

Kvalita měření je tedy hodnocena touto absolutní chybou, nebo pomocí relativní chyby. Ta je počítána jako podíl absolutní chyby a odhadované hodnoty. [13]

$$\xi x_0 = \frac{\delta x_0}{x_0} \quad (16)$$

Je to bezrozměrná veličina a bývá často vyjadřovaná v procentech (vynásobení získané hodnoty z předchozího vzorce číslem 100). [13]

V našem případě je považováno za skutečnou hodnotu měření z referenčního přístroje.

Tabulka 5: Tabulka vypočtených chyb:

Číslo měření	Měřené hodnoty	Referenční měření	Absolutní chyba	Relativní chyba
	[tep/min]	[tep/min]	$\delta$ [tep/min]	$\xi$ [%]
1	69,0	72,0	3,0	4,2
2	80,0	82,0	2,0	2,4
3	70,0	72,0	2,0	2,8
4	72,0	76,0	4,0	5,3
5	63,0	64,0	1,0	1,6
6	73,0	80,0	7,0	8,8
7	100,0	96,0	4,0	4,2
8	78,0	84,0	6,0	7,1
9	60,0	60,0	0,0	0,0
10	67,0	68,0	1,0	1,5
Průměr	73,2	75,4	2,2	2,9

Pro hodnocení, jakou přináší metoda bezkontaktní detekce chybu, byl vypočítán aritmetický průměr jednotlivých chyb. Průměr absolutní chyby je 2,2 tep/min a průměr relativní chyby je 2,9 %. Porovnáním úspěšnosti bezkontaktní detekce oproti referenčnímu měření lze konstatovat, že většina výsledků je přibližuje referenčním hodnotám měření. Kromě jedné výjimky se měření hodnoty významněji nevzdalují od srovnávacích hodnot. Maximální odchylka měření nastala v případě měření číslo 6, kdy je rozdíl 7 tep/min.

Pro statistické zhodnocení je nutno uvést základní popisnou statistiku dostupného souboru. Bylo využito tabulkového nástroje firmy Microsoft Excel. Je shrnuta v následující Tabulka 6.

Tabulka 6: Vlastnosti analyzovaných dat

	Program	Biopac
Střední hodnota	73,20	75,40
Medián	71,00	74,00
Modus	-	72,00
Směrodatná odchylka	11,22	10,59
Rozptyl výběru	125,96	112,04
Minimum	60,00	60,00
Maximum	100,00	96,00
Počet	10,00	10,00

Popisná statistika udává údaje o velikostech, průměru, směrodatné odchylce, minimu, maximu, nejčastější a střední hodnotě. [26].

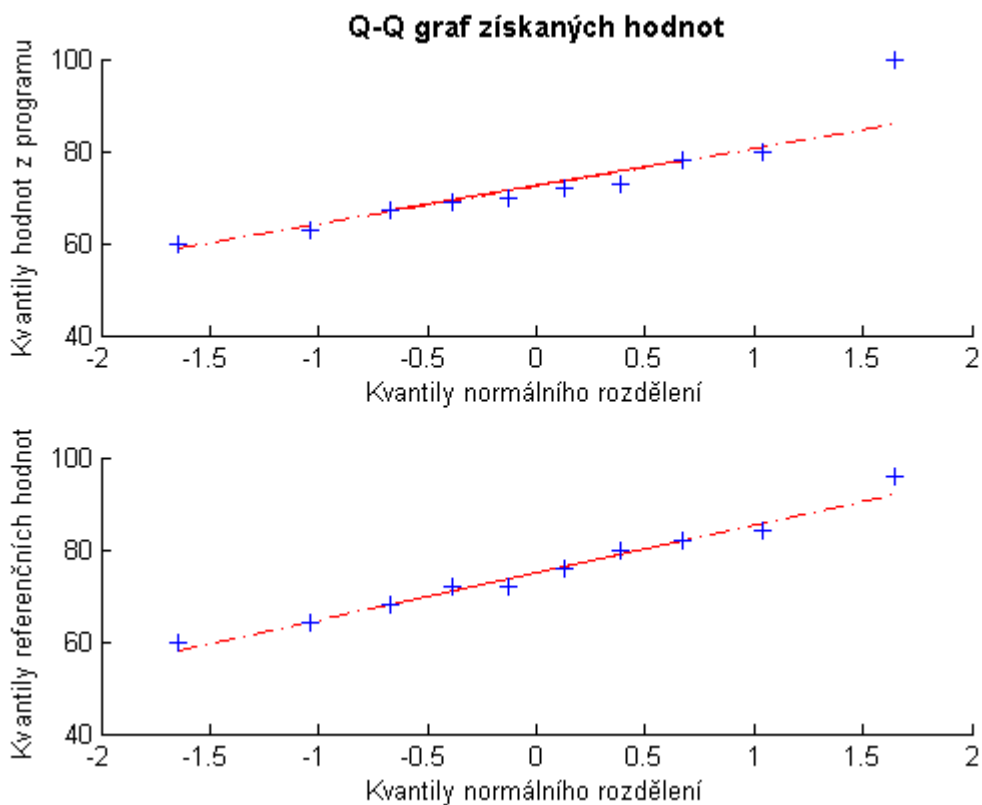
## 10.2 Statistické hodnocení

Prostředkem pro statistiku je testování hypotéz, kdy je zkoumán vliv jedné veličiny na druhou. Statistickou hypotézou je rozuměno jakékoliv tvrzení, které se týká vlastností základního souboru. Rozhodovací pravidlo, kterým se řídíme při rozhodování o platnosti, či neplatnosti hypotézy se nazývá statistický test. V první řadě je podstatné formulovat výzkumnou otázku do formy nulové a alternativní statistické hypotézy, které poté klademe při testování proti sobě. Nulová hypotéza vyjadřuje obvykle žádný, neboli nulový rozdíl mezi testovanými soubory dat. Naopak alternativní hypotéza by měla popírat platnost nulové hypotézy  $H_0$ . Nejčastěji je vyjadřována jako existence difference mezi soubory nebo existence závislosti mezi proměnnými. Poté, pokud statistickým testováním nedokážeme opak, předpokládáme, že platí nulová hypotéza. [7] [26]

Pro vhodné vyhodnocení získaných hodnot je nutné zjistit, jakým testem tato data lze analyzovat pro získání relevantních výsledků. Je potřeba určit, jaké mají rozdělení pravděpodobnosti. V případě normální pravděpodobnosti rozdělení dat je možné využít tzv. parametrické testy. Jejich využití je dávana přednost před testy neparametrickými, u kterých není nutné znát rozdělení pravděpodobnosti. [7] [26]

Normálním rozdělením je myšleno spojitě rozdělení pravděpodobnosti a je reprezentováno Gaussovou křivkou zvonovitého tvaru. Hodnoty této pravděpodobnosti jsou symetricky shlukované okolo střední hodnoty a vytváří tak charakteristickou křivku popsanou parametrem  $\mu$  - střední hodnota a rozptylem normálního rozdělení  $\sigma^2$ . Je voleno testování normality pomocí Shapirova – Wilkova testu, který říká, že výběr pochází z normálního rozložení a tato nulová hypotéza je zamítnuta tehdy, když je hodnota testové statistiky menší nebo rovna kritické hodnotě tohoto testu normality. [7] [26]

Realizace Shapirova – Wilkova testu proběhla v programu MATLAB a na hladině alfa rovné 0,05 nebyla nulová hypotéza o normálním rozložení veličin zamítnuta a lze tedy přistoupit k parametrickému testování dat. Výstup Shapirova – Wilkova testu lze reprezentovat Q-Q grafem. Pokud zobrazené body leží v blízkosti přímky Obrázek 26. Nejpoužívanější test spadající do této kategorie je t-test, který je pro testování použit. [7] [26]



Obrázek 26: Kvantily normálního rozložení a získaných hodnot

Pro potřeby této diplomové práce byla zvolena následující nulová a alternativní hypotéza:

- $H_0$ : Rozdíl mezi hodnotami měřenými bezkontaktně a hodnotami měřenými referenčním měřením je **nulový**
- $H_1$ : Rozdíl mezi hodnotami měřenými bezkontaktně a hodnotami měřenými referenčním měřením je **nenulový**

Hodnotit budeme v tomto případě pomocí t-testu, který je založen na ověření rozdílu dvou středních hodnot testovaných souborů. Jde o srovnání hodnot testované a kontrolní skupiny dat. Je vybrán dvouvýběrový t-test a to z toho důvodu, že je třeba porovnávat dva soubory naměřených dat a to opakovaně na jedné skupině dobrovolníků. [26].

Pro výpočet t-testu je nutno uvést jeho charakteristiku, kdy základem je testovací kritérium  $t$ , které je definované pomocí následující rovnice

$$t = \frac{|\bar{x}|}{\sqrt{\frac{s^2}{N}}}, \quad (17)$$

kde  $\bar{x}$  je aritmetický průměr,  $s^2$  je rozptyl a  $N$  je počet změřených hodnot. Testovacím kritériem je myšlena tabulková hodnota  $t_t$ , a poté mohou nastat dva případy:

- $t \leq t_i$  - nevýznamný rozdíl střední hodnoty měření při  $\alpha = 0.05$
- $t \geq t_i$  významný rozdíl střední hodnoty měření při  $\alpha = 0.05$

$\alpha$  značí hladinu významnosti, na které testujeme. V následující Tabulka 7 je vidět výsledek t-testu:

Tabulka 7: Testová statistika

Dvouvýběrový t-test s rovností rozptylů		
	Program	Biopac
Střední hodnota	73,200	75,400
Rozptyl	125,956	112,044
Pozorování	10,000	10,000
Společný rozptyl	119,000	
Stupeň volnosti	18,000	
$P(t \leq t_i)$	0,657	
Kritická hodnota	2,101	

Vypočtená testová statistika pro oboustranný t-test je rovna 0,657. Kritická hodnota pro dvouvýběrový t-test při 18 stupních volnosti je 2,101. Lze tedy konstatovat, že platí  $t \leq t_i$ . Dvouvýběrovým t-testem bylo prokázáno, že rozdíl mezi hodnotami měřenými bezkontaktně a hodnotami měřenými referenčním měřením je nulový. Tudiž nastaly pouze statisticky nevýznamné změny testovaných dat vůči referenčním. [26].

### 10.3 Hodnocení získaných výsledků

V praktické části diplomové práce bylo vytvořeno uživatelské prostředí aplikace umožňující bezkontaktní měření tepové frekvence pomocí videokamery. Statisticky zhodnoceno, vzniklé programové vybavení aplikace umožňuje měření s vysokou přesností, oproti konvenčnímu měření tepové frekvence. Během testování nedošlo k výraznějším odchylkám. Ty drobnější mohly být způsobeny například pohybovým artefaktem pacienta či drobnou změnou snímací aparatury a snímané scény. Doba zvolená pro snímání pacientů byla empiricky učena z průběžného testování aplikace při jejím vývoji. Je kompromisem mezi kvalitou získaných hodnot a početní náročností algoritmů. Při zvýšení doby měření v některých případech docházelo k neúměrnému prodloužení výpočetní doby. Další činitel prodloužení doby měření je velikost detekovaného čtverce obličeje. Při testování bylo zjištěno, že s větším čtvercem, ze kterého jsou získávány hodnoty, trvá měření déle, avšak neposkytuje lepší výsledky. Pro samotné měření bylo nejvhodnější, když detekovaný čtverec kopírovat rysy obličeje a nepřesahoval jej.

Další činitelem, který byl zjištěn, že velice významně ovlivňuje měření, je vliv okolního osvětlení. Nejlepších výsledků bylo dosahováno při konstantním a rovnoměrném osvětlení, které bylo dostupné v testovací místnosti.

# ZÁVĚR

V práci je pojednáváno o metodách a dostupných algoritmech pro bezkontaktní měření tepové frekvence s využitím běžné kamery, například u přenosného počítače. První kapitola slouží k popisu tepové frekvence a faktorů, které tepovou frekvenci ovlivňují. Pro doplnění jsou pak uvedeny již dostupné metody, kterými je tepová frekvence člověka snímána. Pro potřeby této práce je v druhé kapitole uvedeno seznámení s detekcí obličeje v obraze. Kapitola seznamuje čtenáře s Viola Jones algoritmem, který tuto detekci umožňuje. Nejnovější přístupy k bezkontaktnímu měření tepové frekvence z videa jsou předmětem třetí kapitoly. Na základě této kapitoly byl navržen program, který umožňuje detekci tepové frekvence z barevných změn v obličeji.

Principem je detekce jemných změn barev v jednotlivých barevných kanálech snímaného videa při jednotlivých tepech. Program funguje na základě analýzy nezávislých komponent. Tato metoda umožňuje separaci zdrojových komponent ze signálu skládajícího se z různých složek. V tomto případě jde o výraznou složku tepové frekvence doplněnou o šum z kamery a okolní šum snímané scény. Navržený algoritmus je detailně popsán v sedmé kapitole. K programu bylo vytvořeno účelné a snadno pochopitelné uživatelské prostředí, které umožňuje jednoduché používání a testování programu. Výhodou této aplikace je snímání a detekce v reálném čase, kdy není nutno zaznamenávat videosekvence a ty následně složitě zpracovávat. Zrychlení přináší i automatická detekce obličeje ve scéně, kdy není nutné ručně značit oblast zájmu snímání.

Vlastnosti uživatelského prostředí a popis jednotlivých bloků názorně popisuje osmá kapitola této práce. Pro zjištění kvality a korektnosti programu bylo prováděno testování na dobrovolnících a získané hodnoty byly porovnány s referenčním měřením. Získané výsledky vykazují relativně vysokou přesnost při bezkontaktní detekci tepové frekvence v porovnání s tradičním měřením pomocí fotopletysmografické sondy. Pro kvalitní detekci postačí měření o délce 15 vteřin při kvalitním a stejnoměrném osvětlení. Rychlost a vysoká přesnost měření je nesporná výhoda tohoto řešení měření pomocí videokamery. Dosaženými výsledky je zjištěno, že se povedlo vyvinout aplikaci, která umožňuje detekovat tepovou frekvenci z barevných změn v obličeji a i přes drobné nedostatky tato aplikace přináší kvalitní a relevantní výsledky.

V rámci semestrální práce byly testovány sledovací algoritmy, které by umožnily sledování obličeje ve scéně. Ty mohou být velice prospěšné a důležité v případě, že by bylo dále pokračováno v rozšiřování této diplomové práce. Jedna z možností by bylo měření tepové frekvence během pohybu pacienta. Tato realizace ale vyžaduje pokročilé programovací znalosti a komplexnější výpočetní algoritmus. Jelikož do ICA analýzy musí vstupovat obrazy o stejné velikosti, zpracování obrazů před analýzou by bylo komplikovanější a to z toho důvodu, že velikost ROI se během pohybu kontinuálně mění a vstupní data by bylo potřeba upravit sofistikovanými metodami.

## POUŽITÉ ZDROJE

- [1] AJARI, Bijan. Gradient Flow Based Matrix Joint Diagonalization for Independent Component Analysis [online]. University of Maryland, USA, 2004 [cit. 2015-04-29]. Dostupné z: [http://drum.lib.umd.edu/bitstream/1903/6468/1/MS\\_2004-4.pdf](http://drum.lib.umd.edu/bitstream/1903/6468/1/MS_2004-4.pdf)
- [2] Analýza a interpretace biologických dat: (MABD) 4. VUT Brno, 2016. Dostupné také z: <https://moodle.vutbr.cz/mod/folder/view.php?id=55680>
- [3] ANKIT, Gupta, Nair VIKAS a . Kanade Lucas Tomasi Tracker. *www.slideserve.com* [online]. 2002 [cit. 2015-12-10]. Dostupné z: <http://www.slideserve.com/suzette/kanade-lucas-tomasi-tracker>
- [4] ARTNER, Nicole. *A Comparison of Mean Shift Tracking Methods\** [online]. 2008, : 8 [cit. 2015-12-10]. Dostupné z: <http://www.cescg.org/CESCG-2008/papers/Hagenberg-Artner-Nicole.pdf>
- [5] BALAKRISHNAN, Guha, Fredo DURAND a Gutttag JOHN. Detecting Pulse from Head Motions in Video. *2013 IEEE Conference on Computer Vision and Pattern Recognition* [online]. 2013 [cit. 2016-01-02]. Dostupné z: [http://webcache.googleusercontent.com/search?q=cache:Dx9IFUwGrisJ:https://people.csail.mit.edu/mrub/vidmag/papers/Balakrishnan\\_Detecting\\_Pulse\\_from\\_2013\\_CVPR\\_paper.pdf+&cd=1&hl=cs&ct=clnk&gl=cz](http://webcache.googleusercontent.com/search?q=cache:Dx9IFUwGrisJ:https://people.csail.mit.edu/mrub/vidmag/papers/Balakrishnan_Detecting_Pulse_from_2013_CVPR_paper.pdf+&cd=1&hl=cs&ct=clnk&gl=cz)
- [6] BIOPAC MP System Hardware Guide. Goleta USA, 2008. Dostupné z WWW: [http://www.biopac.com/Manuals/mp\\_hardware\\_guide.pdf](http://www.biopac.com/Manuals/mp_hardware_guide.pdf)
- [7] BRŠLICOVÁ, T. Bezkontaktní detekce fyziologických parametrů z obrazových sekvencí. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2015. 74 s. Vedoucí semestrální práce doc. Ing. Radim Kolář, Ph.D.
- [8] CARDOSO, J.,F. Source separation of complex signals with JADE. Copyright © 2013.
- [9] Digital Light - 1000, trvalé světlo, FOMEI.FOMEI [online]. Hradec Králové: CS Technologies s.r.o., 2016 [cit. 2016-05-12]. Dostupné z: <https://www.fomei.com/produkty-digital-light-1000-trvale-svetlo-fomei-detail-221837>
- [10] GERG, Isaac, Adam ICKLES a Jamie MCCULLOCH. *CAMSHIFT Tracking Algorithm* [online]. 2003 [cit. 2015-12-10]. Dostupné z: <http://www.gergltd.com/cse486/project5/>
- [11] HANCOCK, Peter. Psychological Image Collection at Stirling. *Psychology, School of Natural Sciences University of Stirling* [online]. 2015 [cit. 2016-01-02]. Dostupné z: <http://pics.stir.ac.uk/>

- [12] HONZÍKOVÁ, Nataša. *Biologie člověka*. Brno, 2003. Dostupné také z: E-learning MBCL. Skripta. VUT.
- [13] Chyby měření. Fakulta aplikovaných věd západočeské univerzity v Plzni: Katedra Fyziky [online]. Plzeň: ZČÚ Plzeň, 2016 [cit. 2016-05-06]. Dostupné z: [http://www.kfy.zcu.cz/dokumenty/FP1/chyby\\_mereni.pdf](http://www.kfy.zcu.cz/dokumenty/FP1/chyby_mereni.pdf)
- [14] JÁNOŠ, Jiří. *Face detection in images*. Brno, 2008. Dostupné také z: [https://is.muni.cz/th/172438/fi\\_b/Face\\_Detection\\_in\\_Images.pdf?zpet=%2Fvyhledavani%2F%3Fsearch%3Ddetekce%20obli%C4%8Deje%26start%3D1](https://is.muni.cz/th/172438/fi_b/Face_Detection_in_Images.pdf?zpet=%2Fvyhledavani%2F%3Fsearch%3Ddetekce%20obli%C4%8Deje%26start%3D1). Bakalářská práce. Masarykova univerzita. Vedoucí práce RNDr. Stanislav Bartoň, Ph.D..
- [15] JINABO, Shi a Tomasi CARLO. Good features to track. In: Proceedings of IEEE Conference on Computer Vision and Pattern Recognition CVPR-94 [online]. Seattle, WA: IEEE Comput. Soc. Press, 1994, s. 593-600 [cit. 2016-04-30]. DOI: 10.1109/CVPR.1994.323794. ISBN 0-8186-5825-8. ISSN 1063-6919. Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=323794>
- [16] JIŘÍK, Ondřej. *Měření tepové frekvence*. Brno, 2012, 61 l. Dostupné také z: [https://www.vutbr.cz/www\\_base/zav\\_prace\\_soubor\\_verejne.php?file\\_id=56733](https://www.vutbr.cz/www_base/zav_prace_soubor_verejne.php?file_id=56733). Bakalářská práce. VUT.
- [17] KMEŤKO, Ján. *Ovládanie prezentácie pomocou kamery*. Brno, 2011. Dostupné také z: [https://is.muni.cz/th/139758/fi\\_m/dp.pdf](https://is.muni.cz/th/139758/fi_m/dp.pdf). Diplomová práce. Masarykova Univerzita. Vedoucí práce RNDr. Pavel Matula, Ph.D..
- [18] KRÁLÍK, Martin. *Detekce objektů v obraze s pomocí rozšířené sady Haarových příznaků a histogramu*. Brno, 2012, 58 l. Diplomová práce. Vysoké učení technické v Brně. Vedoucí práce Ing. RADIM BURGET, Ph.D..
- [19] Labeled Faces in the Wild. UNIVERSITY OF MASSACHUSETTS. *Labeled Faces in the Wild* [online]. 2015 [cit. 2016-01-02]. Dostupné z: <http://vis-www.cs.umass.edu/lfw/>
- [20] LEVANDOVSKA, Magdalena, Jacek RUMINSKI a Tomasz KOCEJKO. *Measuring pulse rate with a webcam: A non contact method for evaluating cardiac activity* [online]. Los Alamitos: IEEE Computer Society Press, 2009 [cit. 2015-12-16]. ISBN 978-836-0810-224. Dostupné z: [http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=6078233&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs\\_all.jsp%3Farnumber%3D6078233](http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=6078233&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs_all.jsp%3Farnumber%3D6078233)
- [21] LUCAS, Bruce D. a Takeo KANADE. An Iterative Image Registration Technique with an Application to Stereo Vision (DARPA). In: Proceedings of the 1981 DARPA Image Understanding Workshop [online]. Pittsburgh, Pennsylvania: Carnegie - Melton University, 1981, s. 121-130 [cit. 2016-04-30]. Dostupné z:

[https://www.ri.cmu.edu/pub\\_files/pub3/lucas\\_bruce\\_d\\_1981\\_2/lucas\\_bruce\\_d\\_1981\\_2.pdf](https://www.ri.cmu.edu/pub_files/pub3/lucas_bruce_d_1981_2/lucas_bruce_d_1981_2.pdf)

- [22] MALACH, T, P BAMBUCH a J MALACH. Detekce obličej v obraze s využitím prostředí MATLAB®. In: *Mezinárodní konference Technical Computing Prague 2011* [online]. Praha, 2011 [cit. 2015-12-16]. Dostupné z: [http://dsp.vscht.cz/konference\\_matlab/MATLAB11/prispevky/078\\_malach.pdf](http://dsp.vscht.cz/konference_matlab/MATLAB11/prispevky/078_malach.pdf)
- [23] MATES, Jiří. Detekce objektů pomocí scanning window. *Cw*. [online]. Czech Technical University, Prague, 2010 [cit. 2015-12-10]. Dostupné z: [https://cw.fel.cvut.cz/wiki/\\_media/courses/a4m33mpv/2010.05.03\\_viola-jones.pdf](https://cw.fel.cvut.cz/wiki/_media/courses/a4m33mpv/2010.05.03_viola-jones.pdf)
- [24] MCDUFF, Daniel, Rosalind PICARD a Ming-Zher POH. *Non-contact, automated cardiac pulse measurements using video imaging and blind source separation* [online]. 2010, 30.332010 [cit. 2015-12-10]. Dostupné z: <http://dspace.mit.edu/openaccess-disseminate/1721.1/66243>.
- [25] MILLBORROW, S. The MUCT Landmarked Face Database. *Pattern Recognition Association of South Africa*. 2010, (1). Dostupné také z: <http://www.milbo.org/muct/The-MUCT-Landmarked-Face-Database.pdf>
- [26] PAVLÍK, Tomáš a Ladislav DUŠEK. *Biostatistika* [online]. Vyd. 1. Brno: Akademické nakladatelství CERM, 2012, 131 s. [cit. 2014-04-19]. ISBN 978-80-7204-782-6. Dostupné z: <http://www.iba.muni.cz/res/file/ucebnice/pavlik-biostatistika.pdf>
- [27] PEER, Peter. CVL Face Database. *Computer Vision Laboratory* [online]. 1999 [cit. 2016-01-02]. Dostupné z: <http://www.lrv.fri.uni-lj.si/facedb.html>
- [28] PIETIKAINEN, Matti, Guoying ZHAO a Xisobai LI. *Remote heart rate measurement from face videos under realistic situations* [online]. 2014, 2014 [cit. 2015-12-10]. Dostupné z: [http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=6909939&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs\\_all.jsp%3Farnumber%3D6909939](http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=6909939&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs_all.jsp%3Farnumber%3D6909939)
- [29] PŘINOSIL, Jiří a Martin KROLIKOWSKI. Využití detektoru Viola-Jones pro lokalizaci obličej a očí v barevných obrazech. *Elektrorevue*. 2008, 21.8.2008. Dostupné také z: <http://elektrorevue.cz/cz/download/vyuziti-detektoru-viola-jones-pro-lokalizaci-obliceje-a-oci-v-barevných-obrazech/>
- [30] SHAO-FAN, Lien, Hsia KUO-HSIEN a Su JUHNG-PERNG. Moving Target Tracking based on CamShift Approach and Kalman Filter. In: *Applied Mathematics & Information Sciences: An International Journal* [online]. 9. 2015, s. 7 [cit. 2015-12-10]. Dostupné z: <http://www.naturalspublishing.com/files/published/u956oro5157k5y.pdfAdkfjladjf>

- [31] SVOBODA, Tomáš. CZECH TECHNICAL UNIVERSITY IN PRAGUE, CENTER FOR MACHINE PERCEPTION. *Kanade–Lucas–Tomasi Tracking (KLT tracker)*. Praha, 2008. Dostupné také z: [http://cmp.felk.cvut.cz/cmp/courses/Y33ROV/Y33ROV\\_ZS20082009/Lectures/Motion/klt.pdf](http://cmp.felk.cvut.cz/cmp/courses/Y33ROV/Y33ROV_ZS20082009/Lectures/Motion/klt.pdf)
- [32] Teorie klidové tepové frekvence. *Sportvital* [online]. 2010 [cit. 2015-12-10]. Dostupné z: [http://www.sportvital.cz/sport/trenink/vytrvalost/teorie-klidove-tepove-frekvence/\[35\]](http://www.sportvital.cz/sport/trenink/vytrvalost/teorie-klidove-tepove-frekvence/[35])
- [33] The Imaging Source: Technology based on standards. [online]. © 1991-2015. [cit. 2014-11-28]. Dostupné z: [http://www.theimagingsource.com/en\\_US/products/cameras/usb-cmos-ccd-color/dfk23u445/](http://www.theimagingsource.com/en_US/products/cameras/usb-cmos-ccd-color/dfk23u445/)
- [34] TOMASI, Carlo a Takeo KANADE. Detection and Tracking of Point Features. In: *Shape and Motion from Image Streams: a Factorization Method—Part 3: Technical Report CMU-CS-91-132*. 1991: CMU, 1991, s. 91-132. Dostupné také z: <https://www.ces.clemson.edu/~stb/klt/tomasi-kanade-techreport-1991.pdf>
- [35] VÍTKOVÁ, Jarmila. GYMNÁZIUM A SOŠPG, ZNOJMO. *Biologie člověka* [online]. Znojmo [cit. 2015-12-10]. Dostupné z: <http://skolajecna.cz/biologie/Documents/BiologieCloveka.pdf>
- [36] WINTRINGHAM, W.T. "Color Television and Colorimetry". In D L. MacAdam.: *Selected papers on colorimetry-fundamentals* [online]. Bellingham, Wash., USA: SPIE Optical Engineering Press, 1951 [cit. 2016-05-06]. ISBN 0-8194-1296-1. Dostupné z: [http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=4050515&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs\\_all.jsp%3Farnumber%3D4050515](http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=4050515&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs_all.jsp%3Farnumber%3D4050515)
- [37] ZVÁROVÁ, Jana. *Biomedicínská statistika I. : Základy statistiky pro biomedicínské obory* [online] . dotisk 1 vydání. Praha : Karolinum, 1998. 218 s. Dostupné také z <<http://www.euromise.cz/education/textbooks.html>>. ISBN 80-7184-786-0.

# SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK

4D	Four dimensions
B	Blue
bpm	beats per minute
CAM	Continuously Adaptive Mean
č.	číslo
DTFT	Discrete Time Fourier Transform
EKG	Elektrokardiografie
FFT	Fast Fourier Transform
fps	frames per second
G	Green
HSV	Hue, Saturation, Value
Hz	Hertz
ICA	Independent Compound Analysis
IC	Independent Compound
IR	Infra Red
JADE	Joint Approximate Diagonalization of Eigenmatrices
KLT	Kanade – Lucas – Tomasi
min	minuta
PCA	Principal Compound Analysis
PPG	PhotoPletysmoGram
PSD	Power Spectral Density
px	pixely
R	červený
RGB	Red – Green – Blue
ROI	Region Of Interest
s	sekunda
tj.	to je
TF	tepová frekvence
tzv.	takzvaný
USB	Universal Serial Bus

# SEZNAM PŘÍLOH

Příloha A: Návod k aplikaci

Příloha B: Obsah přiloženého DVD

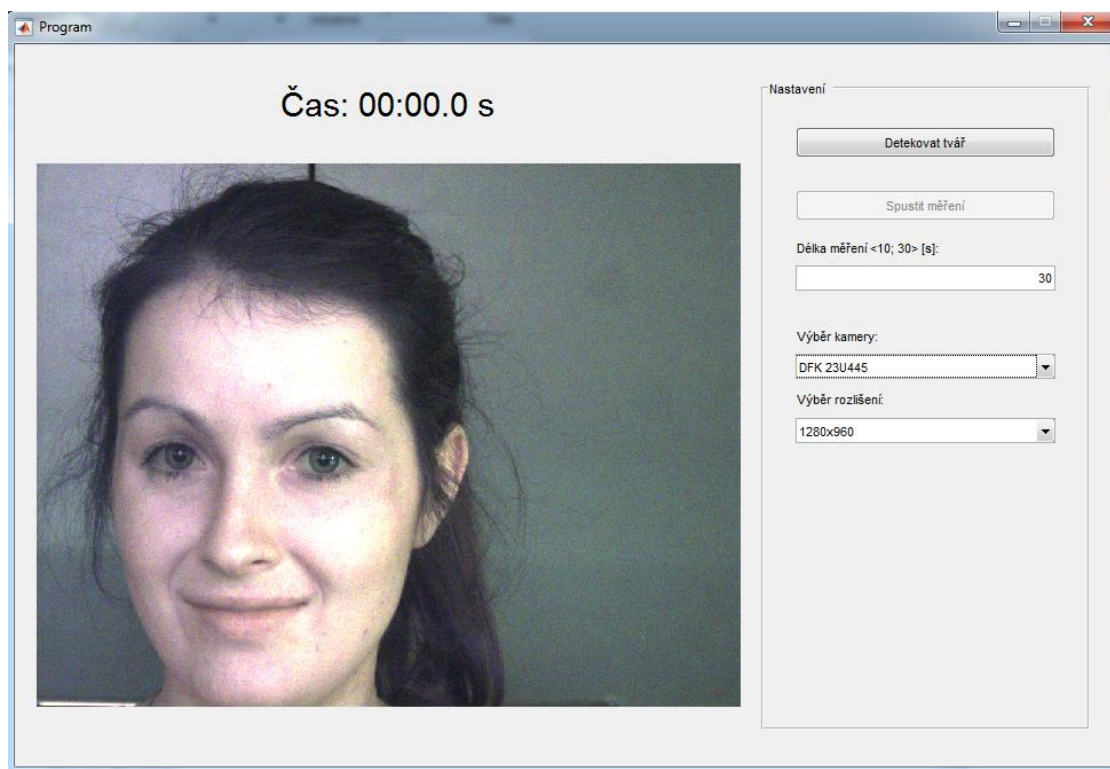
# NÁVOD K APLIKACI

*Bezkontaktní měření tepové frekvence z obličeje*

*Bc. Lucie Chmelíková*

## 1. Popis aplikace

Program, který spouští hlavní aplikaci je k nalezení pod názvem funkce *Program.m*. Po otevření funkce je nutné spustit její běh. Otevře se hlavní okno programu. Okno je pomyslně rozděleno na dvě části. V první se zobrazuje obraz z dostupné kamery, v druhé jsou tlačítka pro detekci a spuštění programu a zároveň tlačítka a textový editor pro nastavení požadovaných parametrů měření. Po spuštění aplikace je vidět, že tlačítko *Spustit měření* je nedostupné a to z toho důvodu, že nejprve musí proběhnout detekce obličeje. Zde je vidět hlavní okno zobrazené po spuštění aplikace:



V prvé řadě je však potřeba se zabývat textovým editorem s názvem *Délka měření* <10,30> [s]. Zde je potřeba zvolit požadovanou dobu snímání. Defaultně je nastavena hodnota 10 vteřin. Při zadání jiné než číselné hodnoty se opět automaticky nastaví tato hodnota.

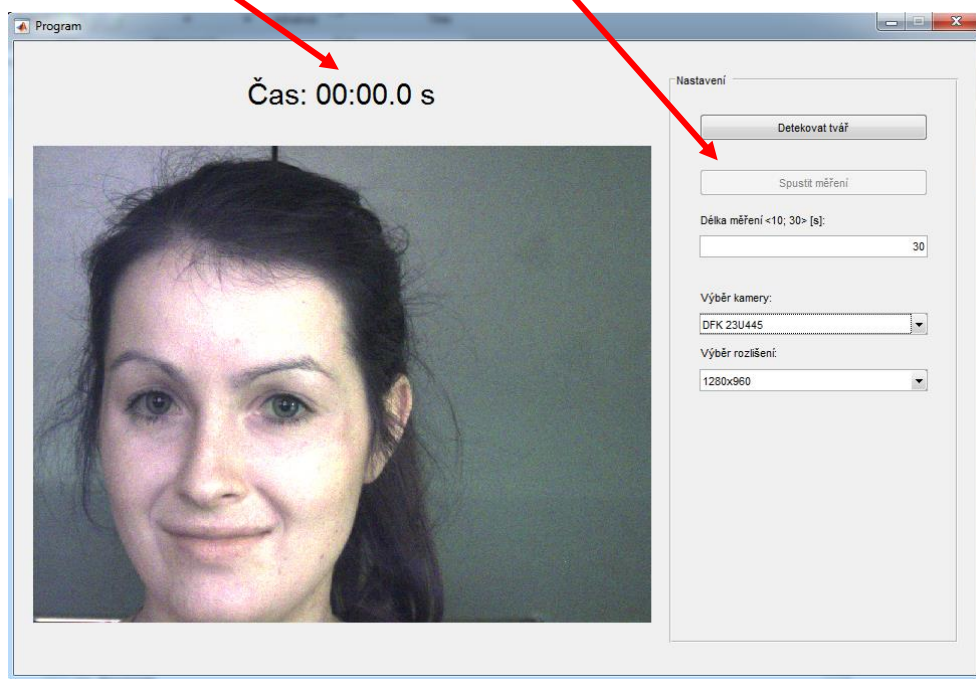
Při situaci, že je k počítači připojeno více kamer, lze v rozbalovacím menu *Výběr z kamery* vybrat požadovanou kameru a v rozbalovacím menu *Výběr rozlišení* lze vybrat vhodné rozlišení pro danou obrazovku. Je nutné podotknout, že pokud chce uživatel používat tuto aplikaci, je vhodné mít nainstalovány aktuální ovladače od všech dostupných kamer. Po nastavení všech požadovaných parametrů, lze přistoupit k samotnému měření.

## 2. Ovládání aplikace

### 2.1 Otevření programu

#### 2.1.1 Nedostupné tlačítko *Spustit měření*

#### 2.1.2 Vynulovaný čas



## 2.2 Nastavení požadovaných parametrů

Délka měření <10; 30> [s]:  
10

Výběr kamery:  
Integrated Camera

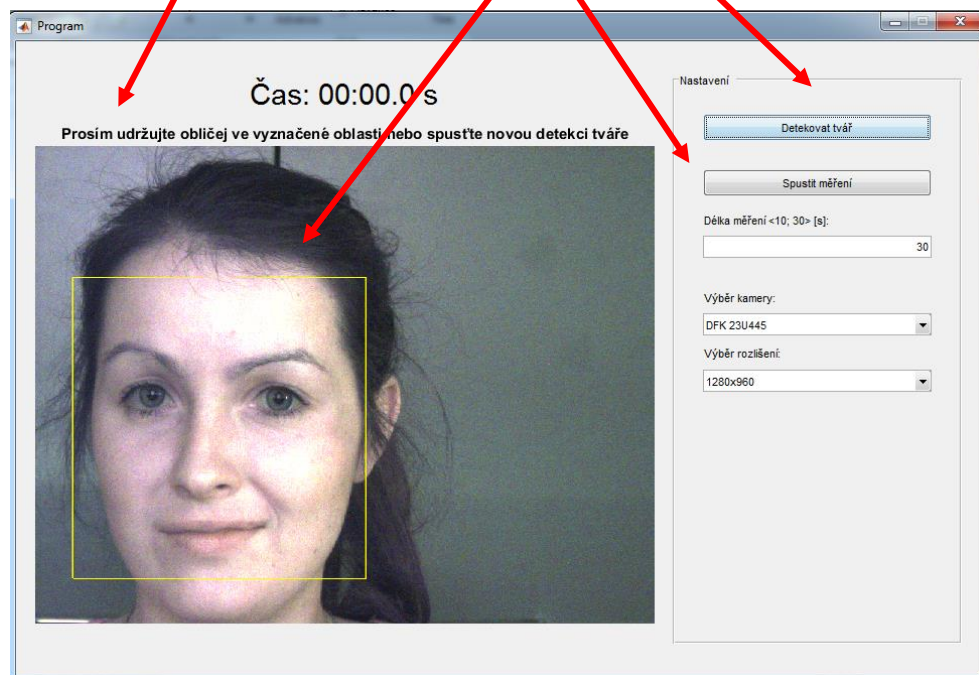
Výběr rozlišení:  
640x480

## 2.3 Stisk tlačítka *Detekovat tvář*

2.3.1 Zobrazení čtverce kolem detekovaného obličeje

2.3.2 Změna dostupnosti tlačítka *Spustit měření*

2.3.3 Vypsání dialogového okna s informací „Prosím udržujte obličej ve vyznačené oblasti, nebo spusťte novou detekci tváře“

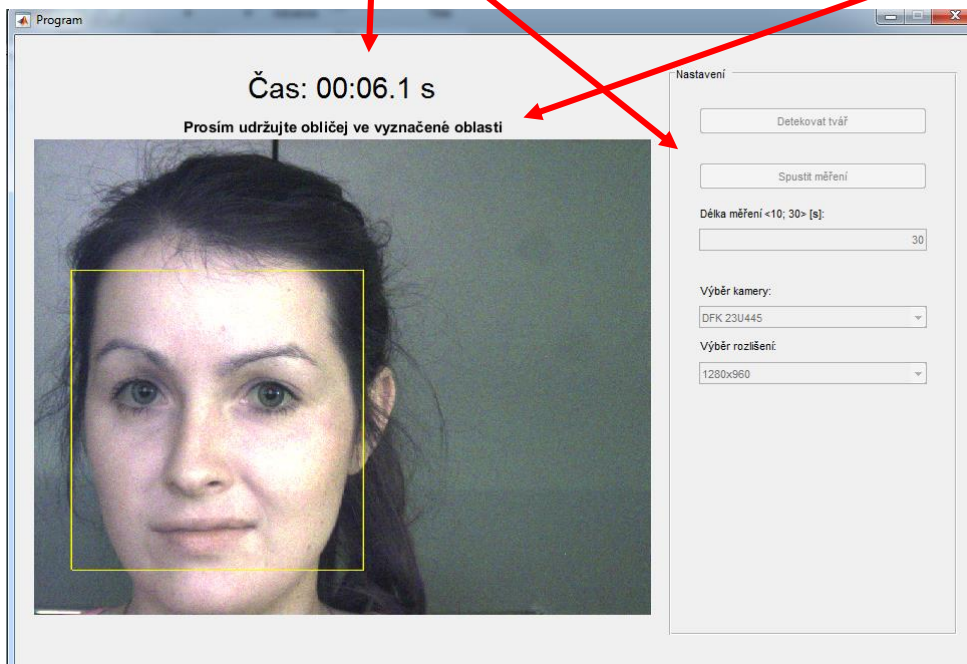


## 2.4 Stisk tlačítka *Spustit měření*

### 2.4.1 Automatické spuštění stopek

### 2.4.2 Změna dostupnosti tlačítek

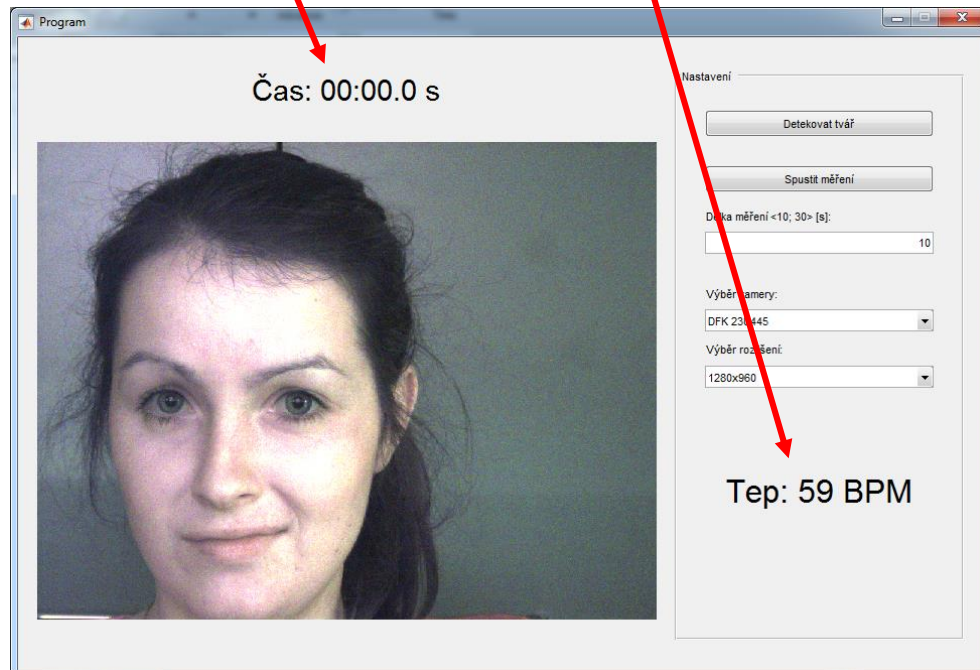
### 2.4.3 Vypsání dialogového okna: „*Prosím udržujte obličej ve vyznačené oblasti*“



## 2.5 Vypsání dialogového okna: „Tep: XXX BPM“

### 2.5.1 Vynulování stopek

### 2.5.2 Zmiznutí čtverce detekovaného obličeje



## 2.6 Konec měření zmáčknutím křížku – zavře se celé okno

## 3. Troubleshooting

### 3.1 Obličej není ve scéně

V případě, že po stisknutí tlačítka Detekovat obličej nedojde k detekci z důvodu nepřítomnosti testované osoby před kamerou, vypíše se dialogové okno:

*„Detekce tváře se nezdařila, prosím opakujte pokus“*

V tomto případě je nutné dodat testovanou osobu a pokus opakovat.

### 3.2 Detekce jiného předmětu než obličeje

V případě špatného nasvícení scény je možné, že se detekuje jiný objekt než obličej. V takové situaci je potřeba pohnout hlavou a spustit detekci znovu.

# PŘÍLOHA B

Příložené DVD obsahuje jednu složku a návod na ovládání aplikace:

## 1. Programy

- *Analysis.m* – funkce provádějící analýzu získaného signálu
- *CameraSettings.m* – funkce nastavení vlastností kamery
- *DetectFace.m* – funkce, která detekuje obličej ve scéně
- *ImageSave.m* – funkce ukládání získaných obrazů
- *jade.m* – funkce provádějící separaci signálů
- *NumberCheck.m* – kontrola správnosti zadání čísla do textového pole
- *Program.m* – spuštění celého programu
- *ResolutionSettings.m* – funkce pro nastavení rozlišení kamery

## 2. Návod k aplikaci