



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY



**FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ**

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF BIOMEDICAL ENGINEERING

BEZKONTAKTNÍ DETEKCE FYZIOLOGICKÝCH PARAMETRŮ Z OBRAZOVÝCH SEKVENCÍ

NON-CONTACT DETECTION OF PHYSIOLOGICAL PARAMETERS FROM IMAGE SEQUENCES

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. TEREZA BRŠLICOVÁ

VEDOUCÍ PRÁCE

SUPERVISOR

doc. Ing. RADIM KOLÁŘ, Ph.D.

BRNO 2015



VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

Ústav biomedicínského inženýrství

Diplomová práce

magisterský navazující studijní obor
Biomedicínské inženýrství a bioinformatika

Studentka: Bc. Tereza Bršlicová

ID: 133958

Ročník: 2

Akademický rok: 2014/2015

NÁZEV TÉMATU:

Bezkontaktní detekce fyziologických parametrů z obrazových sekvencí

POKYNY PRO VYPRACOVÁNÍ:

1) Prostudujte a popište metody pro odhad tepové a dechové frekvence člověka, případně i dalších fyziologických parametrů, pomocí neinvazivních a bezkontaktních přístupů. Zaměřte se na metody využívající optický způsob měření pomocí běžné průmyslové kamery. 2) Navrhněte experiment, pomocí kterého bude možné získat sadu obrazových sekvencí osob se známou tepovou i dechovou frekvencí, a experiment zrealizujte minimálně pro 10 osob. Při návrhu experimentu uvažujte i osvětlení pomocí infračerveného zdroje. 3) Navrhněte postup pro odhad fyziologických parametrů z naměřených sekvencí. 4) Tuto metodu implementujte ve zvoleném programovém prostředí. 5) Metodu otestujte na získaných sekvencích a upravte s ohledem na dosažení automatizovaného zpracování sekvencí a s ohledem na rychlost zpracování. 6) Metodu vyhodnoťte a dostatečně diskutujte dosažené výsledky i s ohledem na způsob akvizice sekvencí.

DOPORUČENÁ LITERATURA:

[1] SUN, Y. et al. Use of ambient light in remote photoplethysmographic systems: comparison between a high-performance camera and a low-cost webcam. *Journal of Biomedical Optics*. 2012, 17(3), s. 037005-1 – 10.

[2] ZHAO, F., Li M., QIAN Y. a TSIEN, J. Z. Remote measurements of heart and respiration rates for telemedicine. *PloS One*. 2013, 8(10), s. e71384.

Termín zadání: 9.2.2015

Termín odevzdání: 22.5.2015

Vedoucí práce: doc. Ing. Radim Kolář, Ph.D.

Konzultanti 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.

Abstrakt

Diplomová práce se zabývá studii bezkontaktních a neinvazivních metod pro odhad tepové a dechové frekvence. Bezkontaktní měření spočívá ve snímání osob běžnou videokamerou a ze získaných sad obrazových sekvencí jsou vhodnými přístupy vyhodnoceny hodnoty fyziologických parametrů. Teoretická část práce je věnována především popisu jednotlivých metod a jejich implementace. Praktická část popisuje návrh a realizaci experimentu pro bezkontaktní detekci tepové a dechové frekvence. Experiment byl uskutečněn na 10 dobrovolnících se známou hodnotou tepové a dechové frekvence, což zajišťoval sofistikovaný systém BIOPAC. Zpracování a analýza naměřených dat byla provedena v programovém prostředí Matlab. Nakonec bylo provedeno srovnání výsledků z bezkontaktní detekce a referenčního měření systémem BIOPAC. Výsledky experimentu jsou statisticky vyhodnoceny a diskutovány.

Abstract

This thesis deals with the study of contactless and non-invasive methods for estimating heart and respiratory rate. Non-contact measurement involves sensing persons by using camera and the values of the physiological parameters are then assessed from the sets of image sequences by using suitable approaches. The theoretical part is devoted to description of the various methods and their implementation. The practical part describes the design and realization of the experiment for contactless detection of heart and respiratory rate. The experiment was carried out on 10 volunteers with a known heart and respiratory rate, which was covered by using of a sophisticated system BIOPAC. Processing and analysis of the measured data was conducted in software environment Matlab. Finally, results from contactless detection were compared with the reference from measurement system BIOPAC. Experiment results are statistically evaluated and discussed.

Klíčová slova

Bezkontaktní detekce fyziologických parametrů, časově-frekvenční analýza, analýza nezávislých komponent, autoregresní model, rychlá Fourierova transformace, ROI, algoritmus JADE.

Keywords

Non-contact detection of physiological parameters, time-frequency analysis, independent component analysis, auto-regressive model, fast Fourier transform, ROI, JADE algorithm.

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..

Prohlášení

Prohlašuji, že svou diplomovou práci na téma Bezkontaktní detekce fyziologických parametrů z obrazových sekvencí 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. 40/2009Sb.

V Brně dne 20. května 2015

podpis autora

Poděkování

Na tomto místě bych ráda poděkovala vedoucímu diplomové práce doc. Ing. Radimu Kolářovi, Ph.D. za cenné připomínky, odborné rady a poskytnuté materiály, kterými mi pomohl k vypracování práce. Dále bych chtěla poděkovat svým nejbližším za podporu nejen při vypracování této práce, ale po celou dobu mého studia.

V Brně dne 20. května 2015

podpis autora

Obsah

Úvod	1
1 Bezkontaktní detekce fyziologických parametrů	3
1.1 Vývoj bezkontaktního měření	3
1.2 Obecný postup bezkontaktního měření	5
2 Metody bezkontaktní detekce	7
2.1 Časově-frekvenční analýza	7
2.1.1 STFT	7
2.1.2 SPWVD	8
2.1.3 Aplikace časově-frekvenční analýzy pomocí SPWVD	9
2.2 Analýza nezávislých komponent	10
2.2.1 Rekonstrukce dynamického systému	11
2.2.2 Separace fyziologického signálu	12
2.2.3 Aplikace ICA pro bezkontaktní detekci	13
2.3 Odhad tepu založená na znalostech pigmentaci kůže	14
2.3.1 Zjednodušený popis modelu lidské kůže	15
2.3.2 Výpočet tepové frekvence z pixelů kůže	16
2.4 Autoregresní model	18
2.4.1 Odhad tepové frekvence pomocí AR modelu	21
2.4.2 Odhad dechové frekvence pomocí AR modelu	22
2.4.1 Odhad saturace krve kyslíkem pomocí AR modelu	23
3 Návrh a realizace experimentu	24
3.1 Prostředí experimentu	24
3.1.1 Snímací aparatura	24
3.1.2 Okolní osvětlení	25
3.1.3 Parametry a nastavení snímání	26
3.2 Biopac MP35	27
3.2.1 Ruční spínač	28
3.2.2 PPG senzor	29
3.2.3 Respirační pás	29
3.2.4 EKG svody	30
3.3 Průběh měření	31

4	Zpracování a analýza naměřených dat	32
4.1	Zpracování dat z referenčního měření	32
4.1.1	Detekce QRS pro získání hodnoty tepové frekvence.....	34
4.1.2	Realizace detektoru v prostředí Matlab.....	34
4.2	Zpracování videosekvencí pro bezkontaktní detekci.....	36
4.3	Algoritmus ICA	39
4.4	Spektrální analýza.....	42
4.4.1	Ukázky spektrální analýzy pro tepovou frekvenci.....	44
4.4.2	Ukázky spektrální analýzy pro dechovou frekvenci	47
4.5	Volba oblasti ROI.....	49
4.6	Vliv IR záření na měření.....	50
5	Výsledky experimentu a diskuze.....	55
5.1	Výsledky detekce tepová frekvence.....	55
5.2	Výsledky detekce dechové frekvence	59
5.3	Statistické vyhodnocení výsledků.....	61
5.4	Diskuze dosažených výsledků	67
	Závěr.....	69
	Použité zdroje	70
	Seznam použitých symbolů a zkratk	73
	Příloha: Obsah přiloženého DVD.....	74

Seznam obrázků

Obr. 1: Region of interest (ROI), upraveno podle [8]	6
Obr. 2: Časově-frekvenční analýza - příklad, převzato z [15].....	7
Obr. 3: Postup pro bezkontaktní odhad tepu metodou SPWVD, upraveno podle [1]	9
Obr. 4: Ukázka použití SPWVD na PPG signál, převzato z [1].....	9
Obr. 5: Blind source separation (BSS) – ICA, blokový diagram, převzato a upraveno podle [18]	10
Obr. 6: Schéma bezkontaktní metody využívající ICA, upraveno podle [2]	13
Obr. 7: Konkrétní příklad bezkontaktní metody využívající ICA, převzato z [2].....	14
Obr. 8: Spektrum hemoglobinu, převzato a upraveno podle [19]	15
Obr. 9: Blokový diagram pro odhad tepu metodou založenou na znalostech pigmentaci kůže, upraveno podle [3]	17
Obr. 10: Výsledky odhadu tepu metodou založenou na znalostech pigmentaci kůže, převzato z [3].....	18
Obr. 11: Blokové diagramy AR modelů, převzato a upraveno podle [4].....	19
Obr. 12: Blokový diagram obecného AR modelu, převzato a upraveno podle [14].....	20
Obr. 13: USB 3.0 Color Industrial Camera - DFK 23UM021, převzato z [17]	25
Obr. 14: Spektrální citlivost videokamery, převzato z [17]	25
Obr. 15: Panel nástrojů softwaru IC Capture 2.3	26
Obr. 16: BIOPAC MP35	28
Obr. 17: Hand Switch	28
Obr. 18: PPG senzor	29
Obr. 19: Respirační pás	29
Obr. 20: EKG svody	30
Obr. 21: Vzhled prostředí softwaru AcqKnowledge	30
Obr. 22: Prostředí experimentu	31
Obr. 23: Ukázka původních dat.....	33
Obr. 24: Ukázka upravených dat	33
Obr. 25: Detektor QRS komplexů, upraveno podle: [23].....	34
Obr. 26: Výsledky jednotlivých kroků detekce QRS	36
Obr. 27: Jednotlivé kroky experimentu bezkontaktní detekce TF a DF.....	36

Obr. 28: Příklad jednoho snímku měření s vyznačenými oblastmi ROI.....	37
Obr. 29: RGB signály před a po normalizaci	38
Obr. 30: Ukázka signálu před a po normalizaci dle rovnice 4.3	38
Obr. 31: Givensova rotace, převzato z [22].....	40
Obr. 32: Výstup algoritmu JADE.....	41
Obr. 33: Ukázka rozkladu signálu na komponenty pomocí ICA	41
Obr. 34: Ukázka nejednoznačnosti komponent.....	42
Obr. 35: Hannovo okno v časové oblasti [25].....	43
Obr. 36: Výkonové spektrum získané analýzou FFT	44
Obr. 37: Výkonové spektrum získané analýzou FFT s Hannovým oknem.....	45
Obr. 38: Detail výkonového spektra komponenty IC2 provedená analýzou FFT.....	45
Obr. 39: Detail výkonového spektra komponenty IC2 provedená analýzou FFT s Hannovým oknem.....	46
Obr. 40: Výkonové spektrum po aplikaci FFT s nejednoznačnou volbou komponenty	46
Obr. 41: Výkonové spektrum po aplikaci FFT.....	47
Obr. 42: Výkonové spektrum metody FFT s Hannovým oknem	48
Obr. 43: Variabilita rozměrů a poloh oblastí ROI.....	49
Obr. 44: Vzhled scény se základním osvětlením a ukázka oblasti ROI.....	50
Obr. 45: Scény s IR osvětlením.....	51
Obr. 46: Příklad při osvětlení viditelným světlem (v podobě lampy)	52
Obr. 47: Příklad při osvětlení v podobě kombinace lampa + IR dioda	53
Obr. 48: Příklad při osvětlení v podobě samostatného IR záření	53
Obr. 49: Absorpční spektrum hemoglobinu	54
Obr. 50: Příklad kvantil-kvantilového grafu.....	64

Úvod

Monitorování fyziologických parametrů je nedílnou součástí každodenních činností vykonávaných ve většině odvětví zdravotnické péče, v oblastech výzkumu či při zátěžových testech u sportovců. Dynamické odchylky při detekování fyziologických parametrů mohou odhalit změny ve fyziologickém stavu organismu a mohou signalizovat příčiny vzniku některých onemocnění či života ohrožující stavy. Nejčastěji jsou zjišťovány parametry kardiovaskulárního systému, jelikož nám poskytují informace o činnosti a funkci srdce. Spolu s respiračními parametry slouží jako ukazovatele správné činnosti organismu jako celku.

Standardní technologie monitorování fyziologických parametrů vyžadují senzory, které jsou určitým způsobem připevněny na tělo pacienta. Příkladem je metoda elektrokardiografie (EKG) využívající 12-svodového monitorování činnosti srdce, kde je zapotřebí devíti elektrod zapojených na hrudi a končetinách vyšetřované osoby. Jedná se o jedinou metodu, která dokáže vykreslit EKG signál, je však také využívána pro zjištění tepové či dechové frekvence. Pro měření těchto dvou parametrů se může zdát zbytečné používat tolik elektrod. Veličinu tepové frekvence je možné změřit pomocí pulsní oxymetrie, která primárně udává procentuální hodnotu nasycení krve kyslíkem. Tato pletysmografická metoda je principiálně založena na průchodu paprsků světla tkání pacienta. Pulsní oxymetry jsou v dnešní době nepostradatelnou součástí na jednotkách intenzivní péče, jelikož dokáží varovat před nedostatečným zásobením tkání kyslíkem tzv. hypoxií a zároveň ukazují aktuální tepovou frekvenci pacienta. Senzor pulsního oxymetru je připevněn na prst nebo na ušní lalůček, což nemusí být pro pacienty úplně komfortní. Dlouhodobé monitorování pomocí takového senzoru může být zatíženo pohybovými artefakty a způsobovat tak nepřesnosti měření. Tyto důvody zřejmě započaly vývoj bezkontaktní detekce fyziologických parametrů.

Výstupem pulsní oxymetrie může být kromě procentuální hodnoty také pletysmografická křivka znázorňující záznam monitorování v podobě pulsních vln. Poskytuje informace o kardiovaskulárním systému. Fotopletysmografické technologie jsou založeny na principech interakce tkáně a speciálních druhů světla (červené a infračervené oblasti spektra). Na začátku 21. století výzkumy prokázaly, že pulsní vlnu lze získat i pomocí digitální videokamery, přičemž jako zdroj světla bylo použito běžné okolní světlo. Můžeme tedy tvrdit, že se fotopletysmografická technologie stala odrazovým můstkem pro bezkontaktní detekci fyziologických parametrů.

Bezkontaktní detekce spočívá v monitorování pacienta videokamerou, která je umístěna obvykle 1 až 3 metry od pacienta. Záznam videosekvencí je následně vhodně upraven a zpracován příslušnou analýzou, jejíž výsledkem je odhad hodnoty fyziologického parametru. Metody bezkontaktní detekce jsou neustále inovovány a je hledán zlatý standard, který umožní jednoduché a spolehlivé monitorování vitálních funkcí.

V diplomové práci jsou studovány principy a metody pro odhad tepové a dechové frekvence pomocí bezkontaktních a neinvazivních přístupů. Práce je rozdělena na pět kapitol. První kapitola je věnována vývoji bezkontaktního měření a poté seznámení s obecným principem bezkontaktní detekce fyziologických parametrů z obrazových sekvencí. Podrobnému popisu a postupu jednotlivých metod je věnována druhá kapitola. Metody se liší především v oblasti analýzy obrazových sekvencí získaných monitorováním pacienta videokamerou. Jedná se o časově-frekvenční analýzu, analýzu nezávislých komponent a autoregresní modelování. Třetí kapitola je věnována návrhu a realizaci experimentu, který spočívá v získání sady obrazových sekvencí pomocí běžné videokamery. Experiment byl proveden na 10 dobrovolnících, kterým byla detekována tepová a dechová frekvence. Kapitola popisuje prostředí experimentu, které zahrnuje videokameru, příslušný software a okolní osvětlení. Videosekvence byly zachyceny od dobrovolníků, u kterých byla známa hodnota tepové i dechové frekvence. To zajišťoval sofistikovaný systém BIOPAC, který poskytoval referenční hodnoty měření a umožnil nám tak kontrolovat správnost a odchylky měření. Naměřené data byla zpracována v prostředí Matlab. Čtvrtá kapitola popisuje jednotlivé kroky a ukázky zpracování a analýzy dat. Výsledky experimentu jsou interpretovány a diskutovány v páté kapitole. Je zde provedeno také statistické testování dat, která nám vyhodnotí statistickou významnost naměřených hodnot.

1 Bezkontaktní detekce fyziologických parametrů

Přístupy pro bezkontaktní a neinvazivní měření fyziologických parametrů spočívají ve snímání osoby vzdáleně digitální videokamerou. Zaznamenávána je většinou tvář a hrudník pacienta. Data určená ke zpracování jsou v podobě série videosekvencí. Objemové změny zapříčiněné srdeční pulsací či pohyby hrudníku způsobené dýcháním můžeme z videosekvencí odhalit pomocí vhodné analýzy obrazů. V současné době bylo totiž dokázáno, že lze provádět monitorování fyziologických funkcí vzdáleně běžnou kamerou s použitím pouze okolního světla.

1.1 Vývoj bezkontaktního měření

Předchůdcem metod bezkontaktního měření fyziologických parametrů je technologie známá jako pulsní oxymetrie, jež byla objevena již v sedmdesátých letech dvacátého století. Metoda umožňuje hodnotit míru nasycení krve kyslíkem a měřit tepovou frekvenci. Činnost srdce totiž zapříčiňuje rytmické objemové změny kapilární krve a tím i změnu absorpce procházejícího světla. Princip metody spočívá v odlišnostech mezi absorpčními spektry dvou typů hemoglobinů obsažených v krvi – oxyhemoglobin (HbO_2) a deoxyhemoglobin (Hb). Nezbytnou součástí měření je senzor, který je cíleně umístěn na část těla s bohatým prokrvením, zpravidla je připevněn na prst nebo ušní lalůček. Senzor je vybaven zdrojem světelného záření a detektorem, přičemž zdroj obsahuje dvě diody, z nichž každá vysílá světlo o jiné vlnové délce. Deoxyhemoglobin absorbuje více v červené oblasti spektra (660 nm) a oxyhemoglobin výrazněji absorbuje v infračervené oblasti (940 nm). Výsledná hodnota saturace je zjištěna z poměru absorpcí zmíněných látek (HbO_2 a Hb). Informace o změnách činnosti kardiovaskulárního systému mohou být reprezentovány jako tzv. PPG signál v podobě křivky, kterou reprezentují pulsní vlny. Nevýhodou konvenční měření oxymetrem je náchylnost na pohybové artefakty. [4, 10, 11]

První kroky vývoje bezkontaktní detekce fyziologických parametrů byly realizovány na počátku 21. století, počínaje rokem 2005. Hlavní myšlenou byl fakt, že objemové změny v cévách v průběhu srdečního cyklu mění dráhu dopadajícího okolního světla. V roce 2005 byl uskutečněn první experiment s CMOS kamerou vzdálenou 0.7 m od pacientovy paže. Na paži působilo nekoherentní monochromatické světlo o vlnových délkách 660, 810 a 940 nm. Signály z tohoto experimentu obsahovaly důkaz změn amplitud ve složkách charakterizujících změny tepové i dechové frekvence. Od tohoto mezního bodu bylo až dodnes vytvořeno několik prací a článků o snahách co nejlépe a nejpřesněji získat hodnoty fyziologických parametrů z video sekvencí. [4]

Články z roku 2007 popisují další experiment. Tentokrát jde o imitaci pulsního oxymetru, ovšem místo senzoru byla použita videokamera a dvě LED diody s vlnovými délkami 760 a 880 nm. Současně byly zachyceny dvě PPG vlny s rychlostí 16 snímků za sekundu. Výsledky popisují vynikající shodu mezi odhadem tepu z videokamery a z měření tepu konvenčním oxymetrem. Výsledky tedy dokázaly možnosti bezkontaktního měření tepové frekvence, avšak bezkontaktní odhad nasycení krve kyslíkem nebyl v této práci doposud prokázán. [4]

Původně se totiž práce soustředily především na bezkontaktní měření saturace krve kyslíkem (proto bylo do experimentu zakomponováno osvětlení o různých vlnových délkách). Posléze však výsledky dokazovaly možnost měření jiných parametrů, a proto se začaly experimenty soustředit na odhad tepové a dechové frekvence, přičemž jako osvětlení bylo postačující běžné okolní světlo. Publikace z roku 2008 dokazují, že je možné PPG signály získat pomocí videokamery vzdálené od měřené osoby více jak 1 metr s použitím denního světla v kombinaci s normálním osvětlením zářivkami. Jako oblast zájmu zde byla poprvé využita tvář respondenta. Ve zpracování obrazů je použita rychlá Fourierova transformace. Zároveň bylo dokázáno, že ze tří složek (RGB kanálů) obrazu poskytuje zelený kanál nejsilnější fotopletysmografický signál. [2, 4]

Články se dále zabývaly například srovnáváním různých druhů videokamer dle jejich kvality. Srovnávají výsledky detekce z videokamer s lepšími parametry oproti levnějším webkamerám či kamerám z mobilních telefonů. Jiné práce zase diskutují vlivy různých druhů osvětlení na měření. [1, 7]

Od roku 2010 byly prováděny inovace především v oblastech použití nejvhodnějších metod analýzy a zpracování naměřených dat. V pracích se objevovaly především metody časově frekvenční analýzy, vlnkové transformace nebo Fourierovy transformace. Metody však umožňovaly především odhadovat tepovou frekvenci, popřípadě dechovou. S možností bezkontaktní detekce saturace krve kyslíkem přišli vědci až v roce 2013. Bylo zapotřebí dvou videokamer a každá obsahovala před objektivem filtr o odlišné vlnové délce (520 a 660 nm). [4, 23]

Nejnovější metoda byla představena v roce 2014. Zahrnuje bezkontaktní odhad tří parametrů (tep, dech i saturace) s použitím jediné videokamery. Využívá moderní metodu analýzy – autoregresní model. [4]

Bylo prokázáno, že bezkontaktní měření vitálních funkcí videokamerou je možné a že se jedná o významný krok v oblasti lékařské diagnostiky a telemedicíny.

1.2 Obecný postup bezkontaktního měření


Primárním parametrem, který je měřen bezkontaktními metodami, je tepová frekvence – HR (Heart Rate), udávaná v tepech za minutu (bpm – beats per minute). Nejen pulsní změny kardiovaskulárního systému, ale také dýchání, respektive dýchací pohyby modulují amplitudu PPG vlny, a proto můžeme touto metodou měřit i dechovou frekvenci – RR (Respiration Rate). Dalším kardiovaskulárním parametrem, který lze bezkontaktně detekovat příslušnými metodami, je saturaci krve kyslíkem – SpO₂.

Bezkontaktní měření vitálních funkcí spočívá v odhadu vybraného fyziologického parametru tak, že je určitá část těla pacienta snímána vzdáleně pomocí RGB videokamery. Za určitý čas je získána série videosekvencí, ze kterých je poté příslušnými postupy vytvořen PPG signál, ze kterého je možné odhadnout daný parametr.

Je nutno brát v úvahu několik kritérií, které mají významný vliv na toto měření. V první řadě mezi ně patří okolní osvětlení. Dále je důležité správně uvážit parametry a nastavení zvolené videokamery, vhodně zvolit vzdálenost videokamery od pacienta a nakonec uvážit metodu analýzy a zpracování videosekvencí. [1, 2, 3]

Obecný postup bezkontaktního měření můžeme rozdělit do několika kroků:

1. Snímání scény videokamerou po určitý čas, řádově jde o desítky sekund. Získané videosekvence jsou zpracovány a následuje jejich analýza.
2. Máme sérii snímků, ve které je vybrána oblast zájmu, tzv. ROI (region of interest). Zkoumanou částí pacienta je nejčastěji tvář. Jinou možností však může být například dlaň, paže či hrudník pacienta. Na Obr. 1 je příklad ROI pacientovy tváře (bílý obdélník). Otázkou je, zda tuto oblast ROI bude umět algoritmus vytvořit automaticky, či ho bude nutné vybírat manuálně. Manuální selekce bude zřejmě výhodnější, abychom se vyhnuli jakýmkoliv odchýlkám či artefaktům. [8]
3. Po vybrání oblasti ROI následuje další krok zpracování, respektive předzpracování získaných videosekvencí. Jedná se o získání signálu z oblastí ROI. Často je obraz (oblast ROI) rozkládán do tří kanálů RGB (red, green, blue). Jednotlivý kanál je získán jako průměrný jas ze všech pixelů oblasti ROI.



Obr. 1: Region of interest (ROI), upraveno podle [8]

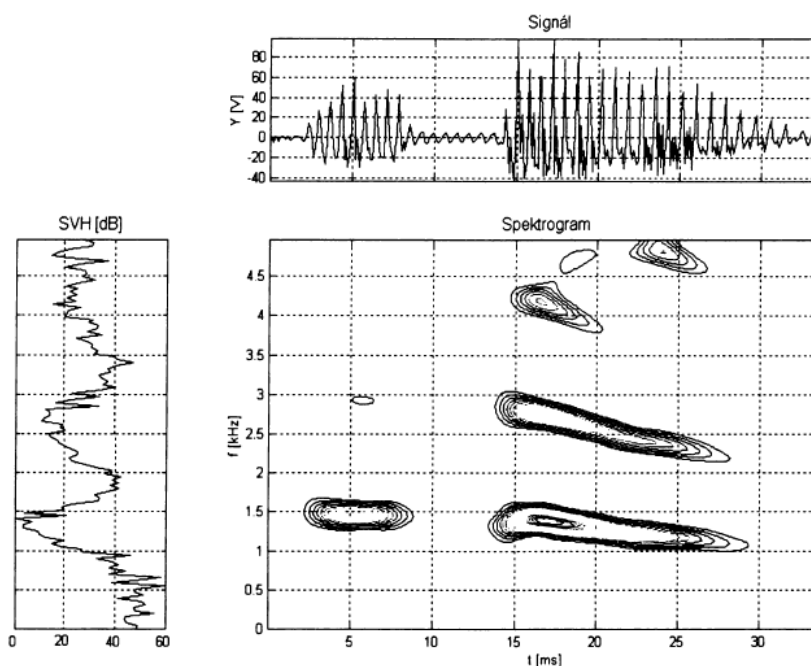
4. Finální analýza signálu se liší v závislosti na zvolené metodě bezkontaktní detekce. Přístupů, jak měřit bezkontaktně fyziologické parametrů (v našem případě tepová a dechová frekvence, případně saturace kyslíku krvi) s využitím videokamery, je v dnešní době několik.
5. Výsledkem příslušné analýzy je odhad měřeného parametru.

Každá z metod přistupuje k problematice trochu jiným způsobem. V další kapitole jsou jednotlivé metody podrobně popsány. [1, 2, 8]

2 Metody bezkontaktní detekce

2.1 Časově-frekvenční analýza

Pro účely této práce je jednou z možností zpracování získaných signálů aplikace časově-frekvenční analýzy (TFR – time-frequency analysis). Analýza nám poskytuje časové rozložení frekvenčního spektra. Časově-frekvenční analýza výrazně zjednodušuje interpretaci signálů. Slouží ke zkoumání změn ve frekvenčním složení signálu v průběhu času příslušného experimentu. Pro představu je na Obr. 2 znázorněna ukázka výsledku časově-frekvenční analýzy. Horní graf reprezentuje časový průběh měřené veličiny, tzv. časová historie amplitudy. Vlevo je frekvenční výkonová hustota získaná převedením časového průběhu signálu do frekvenční roviny pomocí Fourierovy transformace. Časově-frekvenční spektrogram je znázorněn uprostřed. K získání a určení časové lokalizace frekvenčních komponent je potřeba použít příslušné transformační postupy či výpočetní metody. Takovými prostředky jsou tzv. časově-frekvenční transformace. Transformací existuje celá řada a je možné je rozdělit dle linearity. [14, 15]



Obr. 2: Časově-frekvenční analýza - příklad, převzato z [15]

2.1.1 STFT

Nejnámější a pravděpodobně nepoužívanější je krátkodobá Fourierova transformace (STFT – Short Time Fourier Transform). Jde o modifikaci známé Fourierovy transformace, která umí frekvenční složky lokalizovat v čase s konstantním rozlišením. Můžeme říci, že STFT je vlastně kompromisem mezi časovou a frekvenční reprezentací signálu. [7]

STFT rozděljuje signál na dostatečně malé realizace, u kterých je možné očekávat stacionaritu, prostřednictvím vynásobení určité okénkové funkce a signálu. Postupuje se tak, že na každý výřez je aplikována Fourierova transformace a okno se postupně posunuje v čase. STFT je lineární a obecně komplexní transformace, jejíž definiční vztah je následující [7, 15]:

$$STFT(\tau, f) = \int_{-\infty}^{\infty} [x(t) \cdot g(t - \tau)] \cdot e^{-j2\pi f t} \cdot dt, \quad (2.1)$$

kde $x(t)$ je časová reprezentace signálu, t je čas, τ je časové posunutí okénka, g je okénková funkce.

STFT je lineární transformací, jejíž výhodou je především rychlost výpočtu a časově frekvenční rozlišení. Avšak výsledné rozlišení v čase a frekvenci je zatíženo tzv. Heisenbergovým principem neurčitosti. [15]

2.1.2 SPWVD


K nelineárním metodám časově-frekvenční analýzy patří Wigner-Villova transformace, respektive její známá modifikace tzv. SPWVD (Smoothed Pseudo Wigner-Ville distribution), nazývaná pseudo nebo vyhlazená Wigner-Villova transformace, definovaná jako [15]:

$$SPWVD(t, f) = \int h(\tau) \int g(s - t) x\left(s + \frac{\tau}{2}\right) x^*\left(s - \frac{\tau}{2}\right) e^{-2j\pi f \tau} ds d\tau. \quad (2.2)$$

V rovnici je x časová reprezentace signálu $x(s)$, označení $*$ značí komplexní konjugaci, t je čas, τ je posunutí podél časové osy, $g(s)$ a $h(\tau)$ jsou dvě vyhlazovací okna, jejichž efektivní délka nezávisle stanovuje čas a frekvenci vyhlazujícího rozsahu.

Popsané řešení pomocí vyhlazování sice potlačuje interferenci, avšak zhoršuje rozlišení. Proto je SPWVD jistým kompromisem mezi vyhlazením a rozlišením. Tato metoda distribuce dokáže poskytnout funkční charakteristiky srovnatelné se zlatým standardem měření tepové frekvence pomocí PPG senzoru. Výhodou SPWVD je její indiferentnost vůči posunu. [1, 15]

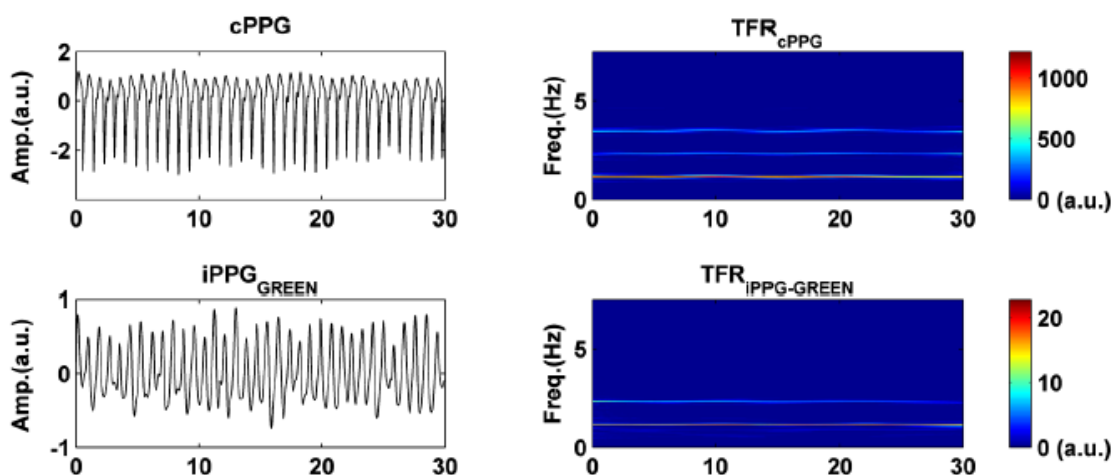
2.1.3 Aplikace časově-frekvenční analýzy pomocí SPWVD



Obr. 3: Postup pro bezkontaktní odhad tepu metodou SPWVD, upraveno podle [1]

Vstupních obrazové sekvence, kde byla manuálně zvolena oblast ROI, jsou rozloženy Bayerovou funkcí na tři kanály RGB. Z jednotlivých kanálů, respektive z ROI oblasti každého kanálu, byl získán odpovídající PPG signál průměrných hodnot pixelů. Na signály byl použit filtr pásmové propusti (Butterworth filtr) s omezením frekvencí od 0.5 do 4 Hz, který umožňuje zachycení rozsáhlejšího rozsahu naměřených tepových frekvencí. Pro další zpracovávání signálu pomocí TFR stačilo vybrat ze tří PPG signálů (red, green, blue) pouze jeden z nich. Zde se jevila jako nejvhodnější volba signál ze zeleného kanálu. [1]

Na signál ze zeleného kanálu byla následně aplikována časově-frekvenční analýza v podobě SPWVD. Výsledné spektrum je možné pozorovat na Obr. 4 **Chyba! Nenalezen zdroj odkazů..**




Obr. 4: Ukázka použití SPWVD na PPG signál, převzato z [1]

Vlevo jsou signály časových průběhů průměrných hodnot pixelů (cPPG – signál získaný konvenčním měření pomocí pulsního oxymetru, iPPG_{GREEN} – signál získaný CMOS kamerou). Vpravo potom výsledek časově-frekvenční analýzy. Výsledný odhad tepové frekvence získáme odečtením frekvence ze spektrogramu. Bude-li hodnota na frekvenční ose například 1.2 Hz, tepová frekvence bude 72 tepů za minutu (vynásobeno konstantou 60). [1]

Bezkontaktní detekce využívající časově-frekvenční analýzu byla aplikována pouze na měření parametru tepové frekvence.

2.2 Analýza nezávislých komponent

Analýza nezávislých komponent (ICA - Independent Component Analysis) se řadí pod metodu s názvem Slepá separace signálů (BSS – Blind Source Separation). Jejím principem je oddělování zdrojových signálů z jejich směsí, přičemž nejsou známy žádné konkrétní informace o směšovací proces. ICA je metoda sloužící k odhalování nezávislého zdroje signálu ze souboru pozorování, které jsou složeny z lineárně mixovaných složek základního zdrojového signálu. Odhadované zdrojové signály jsou nezávislé komponenty, protože jsou statisticky nezávislé jeden na druhém. Použití této poměrně nové metody v odvětví biomedicínské analýzy signálů rychle roste. Nejčastější využití nalézá například na odstranění šumu z elektrokardiogramu (EKG) a elektroencefalogramu (EEG). [8]



Obr. 5: Blind source separation (BSS) – ICA, blokový diagram, převzata a upraveno podle [18]

Z diagramu pro ICA vyplývá, že máme naměřené signály $x = [x_1, x_2, \dots, x_n]^T$, jež jsou regulární kombinací originálních (zdrojových) signálů $s = [s_1, s_2, \dots, s_n]^T$. Metoda je použitelná při splnění základních požadavků a předpokladů.

- 1 Asi nejdůležitějším předpokladem pro ICA je, že originální signál musí obsahovat složky pouze lineárně mixované.
- 2 Je požadováno Gaussovské rozložení originálních signálů s_i . Pokud by byly nekorelované, značilo by to značnou nezávislost.
- 3 Dále by měly být zdrojové signály statisticky nezávislé. I když algoritmy ICA jsou schopné kvalitně separovat i takové příklady signálů, které jsou nepatrně závislé.
- 4 Předpokládá se nulová střední hodnota naměřených signálů x_i .
- 5 Počet hledaných nezávislých komponent musí být menší nebo roven počtu detektorů.
- 6 Dále je nutné, aby bylo časové zpoždění signálů při cestě od zdroje k detektoru zanedbatelné.

7 Signály by neměly být narušeny šumem.

[8, 16, 17]

ICA vyžaduje jako vstupní signál vícekanálový zdroj. To je v našem případě splněno formou záznamu z barevné videokamery (RGB kamera), která poskytuje záznam ze tří kanálů – červený, zelený a modrý. K odhadu tepové a dechové frekvence tato metoda aplikuje na jednocanálové obrazy kombinaci nelineární rekonstrukcí dynamického systému a příslušných technologií ke zpracování obrazů. [2, 8]

2.2.1 Rekonstrukce dynamického systému

Kardiovaskulární i kardiorespirační autonomní systémy jsou ve své podstatě dynamické. V průběhu srdečního cyklu upravují změny objemu krve množství absorpce světla v cévách a tím upravují i modulaci množství odraženého světla z okolního zdroje. Při dýchání upravují délku dráhy světla dýchací pohyby, kde následné změny odraženého světla jsou známkou časových změn dýchacích událostí. Obrazové senzory kamery zachycují odražené světlo spolu s nežádoucími rušivými artefakty. V důsledku toho jsou snímány signály pro tepovou pulsní vlnu a respirační vlnu zvláště v podobě dvou oblastí zájmu – obličej pro snímání tepu, hrudník pro snímání dýchání. [2, 8]

K popisu nelineární dynamiky stavového prostoru je potřeba rekonstrukce založené na teorému časových zpoždění (time-delay embedding theorem), který ustanovuje schopnost rekonstrukce stavového prostoru jako ekvivalentu k originálnímu (nepozorovanému) stavovému prostoru složeného ze všech dynamických proměnných z pouze jednoho pozorovaného signálu. Nechť τ_s je vzorkovací interval, který je obvykle daný převrácenou hodnotou snímkovací frekvence f_s z obrazu získaného konkrétním zařízením. Vektor zpoždění lze poté vyjádřit jako [2]:

$$X(t) \equiv (x_t, x_{t+\tau}, x_{t+2\tau}, \dots, x_{t+(m-1)\tau}), \quad (2.3)$$

kde $\tau = d\tau_s$ je čas zpoždění, m je dimenze vnoření. Minimální požadavek je, že m musí být tak velké, jako je dimenze konečného stavu systému. Základem metody je popis kardiovaskulárního či kardiorespiračního systému pomocí tzv. „embedding matrix“. Tato matice může být sestavena z řady následných zpoždovacích vektorů, které jsou získány z pozorovaného signálu. Obecně může taková matice vypadat takto [2]:

$$X = \begin{bmatrix} x_t & x_{t+\tau} & \dots & x_{t+n\tau} \\ x_{t+\tau} & x_{t+2\tau} & \dots & x_{t+(n+1)\tau} \\ \vdots & \vdots & & \vdots \\ x_{t+(m-1)\tau} & x_{t+m\tau} & \dots & x_{t+(m+n-1)\tau} \end{bmatrix}. \quad (2.4)$$

V praxi, počet zpoždění vektoru n udává délku pozorovaného analyzovaného signálu. Nicméně počet zpoždění ve vektoru musí mít délku minimálně stejně dlouhou, jako má jeden z fyziologických signálů. [8]

2.2.2 Separace fyziologického signálu

Matice obsahuje fyziologické informace ve formě směsi, kterou je nutné dekonstruovat. Zde je vhodné použít analýzu nezávislých komponent (ICA), která z matice dokáže odhalit počáteční (základní) zdroj signálu. Zaznamenané signály z červeného, zeleného a modrého kanálu jsou označeny jako $x_1(t)$, $x_2(t)$ a $x_3(t)$. Jsou to amplitudy zaznamenaných signálů v časovém okamžiku, respektive jde o průměrnou hodnotu všech pixelů z vybrané oblasti ROI. [2, 8]

Jedním z požadavků pro použití metody ICA je, že počet realizovaných zdrojů nesmí překročit počet pozorování. Z toho důvodu jsou myšleny tři zdrojové originální signály $s_1(t)$, $s_2(t)$ a $s_3(t)$ [2]:

$$x_i(t) = \sum_{j=1}^3 a_{ij}s_j(t), \quad (2.5)$$

kde pro každé $i = 1, 2, 3$. Hlavním předpokladem ICA je, že je zkoumaný signál složený z lineárně mixovaných směsí. Tento fakt můžeme potom reprezentovat jako mixovací rovnici, která zní [2]:

$$\mathbf{x}(t) = \mathbf{A} \cdot \mathbf{s}(t). \quad (2.6)$$


Kde $\mathbf{x}(t)$ je matice zkoumaného signálu o velikosti $m \times n$, respektive jde o sloupcový vektor $\mathbf{x}(t) = [x_1(t), x_2(t), x_3(t)]^T$, \mathbf{A} je směšovací matice o velikosti $m \times m$ (v našem případě 3×3) složenou z mixovaných koeficientů a_{ij} a $\mathbf{s}(t)$ je matice $m \times n$ složená z nezávislých zdrojových signálů, $\mathbf{s}(t) = [s_1(t), s_2(t), s_3(t)]^T$.

Cílem ICA je nalézt lineární transformaci, tedy separační matici \mathbf{W} , která je aproximací převrácené originální směšovací matice \mathbf{A} . Matice \mathbf{W} má tedy podobu inverzní matice k matici \mathbf{A} , $\mathbf{W} = \mathbf{A}^{-1}$. Výsledkem je odhad vektoru $\hat{\mathbf{s}}(t)$, který se skládá ze základních zdrojů signálu [2, 8]:

$$\hat{\mathbf{s}}(t) = \mathbf{W} \cdot \mathbf{x}(t). \quad (2.7)$$

Důležité je na tomto místě ještě jednou připomenout předpoklad, že hledáme $\hat{\mathbf{s}}_i$, která jsou nezávislá. Hledáme tedy zdrojové signály s co nejmenší společnou informací, tzv. mírou závislosti. [8]

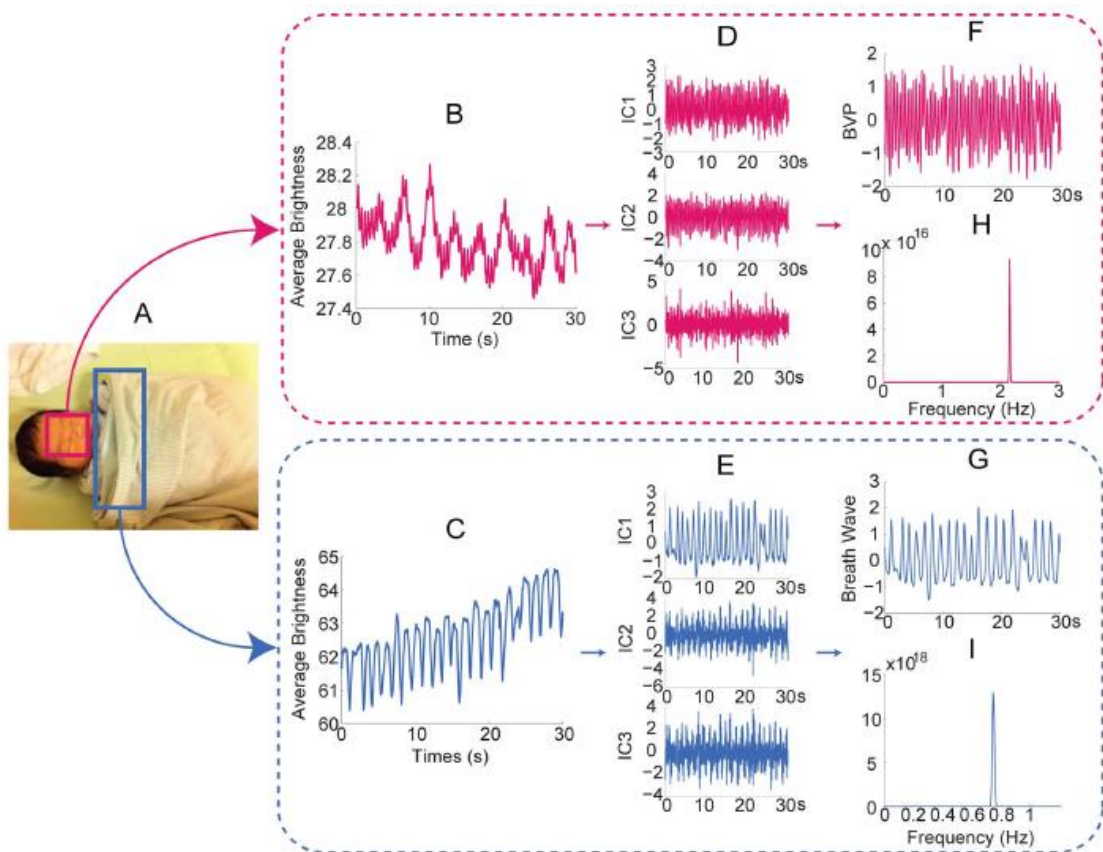
2.2.3 Aplikace ICA pro bezkontaktní detekci



Obr. 6: Schéma bezkontaktní metody využívající ICA, upraveno podle [2]

Schéma na Obr. 6 znázorňuje postup celé metody bezkontaktní detekci dechové a tepové frekvence s využitím analýzy nezávislých komponent. Po sběru dat v podobě série videosekvencí v čase následuje výběr oblastí zájmu ROI. Pro tepovou frekvenci bude vybrán obličej, pro dechovou frekvenci horní část hrudníku. Následně je pro každý ROI v sérii snímků získán průměrný jas pixelů v časové řadě $x(t)$. Jelikož absorpce hemoglobinu je nejlepší v zelené oblasti ve spektru viditelného světla, jsou využita pouze data ze zeleného kanálu. ICA je provedena k rozložení „embedding“ matice na tři nezávislé zdrojové signály. Za účelem získání požadované hodnoty jednotlivého fyziologického parametru, byl z těchto tří signálů vybrán pouze ten, jehož výkonové spektrum obsahuje nejvyšší hodnotu poměru vrcholů vzhledem k celkové energii signálu. [2]

Vybraný zdroj signálu byl poté vyhlazen pomocí posuvného filtru klouzavého průměru a ke snížení ostatního šumu byla provedena autokorelace. Posledním krokem je rychlá Fourierova transformace na vybraném zdroji a díky ní je získáno frekvenční spektrum daného fyziologického parametru. Výsledná hodnota konkrétní tepové a dechové frekvence je dopočítána z nejvyšší hodnoty ve výkonovém spektru vynásobené hodnotou 60. Konkrétněji, pro lepší představu je na Obr. 7 uveden příklad takové detekce dechové a tepové frekvence z videozáznamu kojence. [2]



Obr. 7: Konkrétní příklad bezkontaktní metody využívající ICA, převzato z [2]

(A) Růžově jsou znázorněny signály získané z obličeje pacienta k odhadování hodnoty tepové frekvence. Modře potom detekován hrudník pacienta k získání hodnoty dechové frekvence. (B, C) Průměrné jasové hodnoty zaznamenané v čase 30 sekund. (D, E) Aplikování ICA. (F, G) Zrekonstruovaný (vyhlazen a odstraněn šum) vybraný signál s největším poměrem vrcholů. (H, I) Výsledné výkonové spektrum signálů. [2]

Na Obr. 7 je hodnota ve frekvenčním spektru tepové frekvence je rovna 2.15 Hz, což odpovídá tepové frekvenci 129 tepů za minutu. U dechové frekvence je hodnota nejvyššího píku 0.73 Hz a odpovídá dechové frekvenci 44 dechů za minutu. [2]

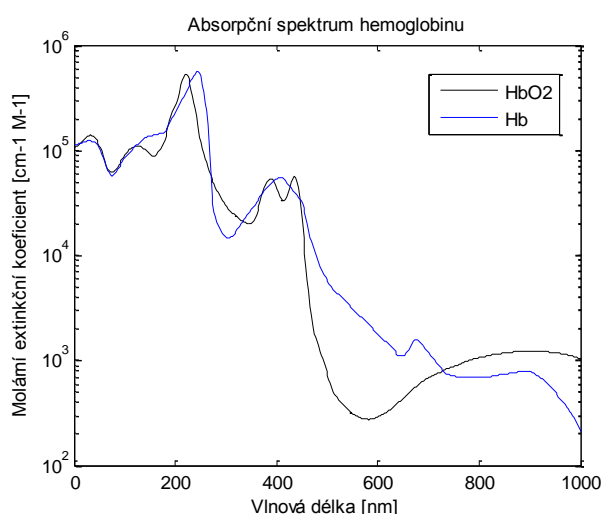
2.3 Odhad tepu založená na znalostech pigmentaci kůže

Odhad tepové frekvence využívající metodu ICA se může zdát jako relativně výpočetně náročný. Také se při řešení nebere v úvahu vliv okolního osvětlení. Z tohoto důvodu byla navržena metoda, jejíž principy se velmi blíží principům konvenčního měření kardiovaskulárních parametrů pomocí optického oxymetru. Při využití této nové metody není nutné využívat „složitých“ postupů potřebných k implementaci ICA. Samotnému představení této metody je zde nejprve diskutován model kůže a jeho pigmentové a spektrální vlastnosti. [3]

2.3.1 Zjednodušený popis modelu lidské kůže

Lidská kůže je strukturně složena ze tří vrstev. Vnější pokožka (epidermis), která obsahuje v hlubších vrstvách kožní barvivo melanin. Škára (dermis) je bohatě prokrvená vazivová vrstva kůže obsahující krevní cévy, žlázy a nervová zakončení. Poslední vrstvou je podkožní tuková tkáň obsahující receptory tlaku a tahu.

Při absorpci světla hraje velmi důležitou roli melanin v pokožce a hemoglobin ve škáře. Koncentrace melaninu se liší v závislosti na fototypu kůže. Hemoglobin i melanin silně absorbují světlo v ultrafialové oblasti (UV) a ve viditelné části spektra. Na Obr. 8 lze vypořadovat spektrum hemoglobinu v průběhu různých vlnových délek. Ve větších vlnových délkách blíživících se infračervené části spektra absorpce hemoglobinu klesá. [3]



Obr. 8: Spektrum hemoglobinu, převzato a upraveno podle [19]

Nedávnými výzkumy bylo prokázáno, že je možné vyjádřit absorpenci kůže jako lineární kombinaci absorpance melaninu a absorpance hemoglobinu v logaritmickém měřítku. Při těchto výpočtech je použit Lambert-Beerův zákon, dle kterého lze definovat absorpenci kůže A při dané vlnové délce λ jako [3]:

$$A(\lambda) = v_m(\lambda)c_m + v_h(\lambda)c_h + A_0(\lambda), \quad (2.8)$$

kde index m znamená melanin a h hemoglobin, c je koncentrace pigmentu, v značí koeficient pigmentového zeslabení (spektrální průřez) a průměr délky fotonů prošlých vrstvou kůže. A_0 v rovnici reprezentuje základní absorpenci kůže a zbytkový pigment. Rovnice může být platná jen tehdy, pokud bude saturace arteriálního kyslíku konstantní. Absorpance bývá často vyjádřena jako [3]:

$$A = -\log \frac{I}{I_0}, \quad (2.9)$$

zde se počítá s intenzitou dopadajícího světla I_0 a s intenzitou světla již prošlého objektem I .

Spojením rovnic (2.8) a (2.9) dostaneme [3]:

$$I = I_0 \exp\{-(v_m c_m + v_h c_h + A_0)\}. \quad (2.10)$$

Model pixelových intenzit odpovídajících jednotlivým polohám v obrazu kůže, označeným jako P_i (kde $i = R, G, B$) v pozicích (x, y) , můžeme zapsat jako [3]:

$$P_i(x, y) = k \int L(x, y, \lambda) S_i(\lambda) d\lambda, \quad (2.11)$$

kde S_i je funkce spektrální odezvy na senzor kamery a k je koeficient zesílení kamery. Budeme-li brát S_i jako funkci delta a zaměníme-li rovnici (2.10) za (2.11), potom při zanedbání x a y získáme na obou stranách tyto logaritmy [3]:

$$\log P_R = -\{v_m(R)c_m + v_h(R)c_h + A_0(R)\} + \log kE(R) \quad (2.12)$$

$$\log P_G = -\{v_m(G)c_m + v_h(G)c_h + A_0(G)\} + \log kE(G) \quad (2.13)$$

$$\log P_B = -\{v_m(B)c_m + v_h(B)c_h + A_0(B)\} + \log kE(B) \quad (2.14)$$

2.3.2 Výpočet tepové frekvence z pixelů kůže

Nejprve definujeme nový parametr Q , který reprezentuje logaritmus podílů z dvou zvolených kanálů. Vypočítáme ho vzájemným odečtením rovnic (2.12) a (2.13), výsledek bude vypadat takto [3]:

$$Q = \log \frac{P_R}{P_G} = -(\Delta v_m c_m + \Delta v_h c_h) + \log \frac{E(R)}{E(G)}, \quad (2.15)$$

kde $\Delta v_m = v_m(R) - v_m(G)$ a $\Delta v_h = v_h(R) - v_h(G)$.

Červený kanál byl vybrán kvůli tomu, že implicitně představuje koncentraci krve, zatímco zelený kanál byl zvolen proto, že údajně obsahuje řetězce pletysmografického signálu v rámci všech tří signálů. Pokud zanedbáme účinky pohybu a budeme předpokládat, že oblast kůže není vystavena po delší dobu UV záření, můžeme predikovat, že koncentrace melaninu v oblastech kůže v průběhu detekce bude konstantní. Odečtení mezi po sobě jdoucími snímky definuje parametr ΔQ [3]:

$$\Delta Q^t(x, y) = Q^{t+1}(x, y) - Q^t(x, y) = -\Delta v_h c_h(x, y) + \Delta \log \frac{E(R, x, y)}{E(G, x, y)}. \quad (2.16)$$

V rovnici (2.16) t představuje číslo snímku a parametr Δc_h obsahuje informace týkající se koncentrace hemoglobinu v krvi. Dle definice odpovídá frekvence této

koncentrace frekvenci tepové (HR). Odkážeme-li se na princip funkce optického oxymetru, můžeme parametr $\Delta v_h \Delta c_h$ asociovat se střídavými složkami, zatímco termín $\Delta \log$ lze interpretovat jako stejnosměrné složky, pokud však bude osvětlení konstantní. Předchozí rovnici proto můžeme přepsat na jinou [3]:

$$\Delta c_h(x, y) = \frac{[\Delta Q(x, y) - a]}{b}. \quad (2.17)$$

Proměnná a bude konstantní v případě, bude-li konstantním osvětlení. Totéž platí i pro parametr b v závislosti na definici v_h . Parametry a a b lze vyjádřit rovnicemi [3]:

$$a = \Delta \log \frac{E(R, x, y)}{E(G, x, y)}, \quad (2.18)$$


$$b = -\Delta v_h. \quad (2.19)$$

Po vysvětlení všech okolností můžeme konečně vyjádřit rovnici, která vyjadřuje signál časových sérií $y(t)$ sloužící k odhadnutí tepové frekvence z každé oblasti obrazu. Bereme v úvahu, že video sekvence jsou složeny ze z snímků [3].

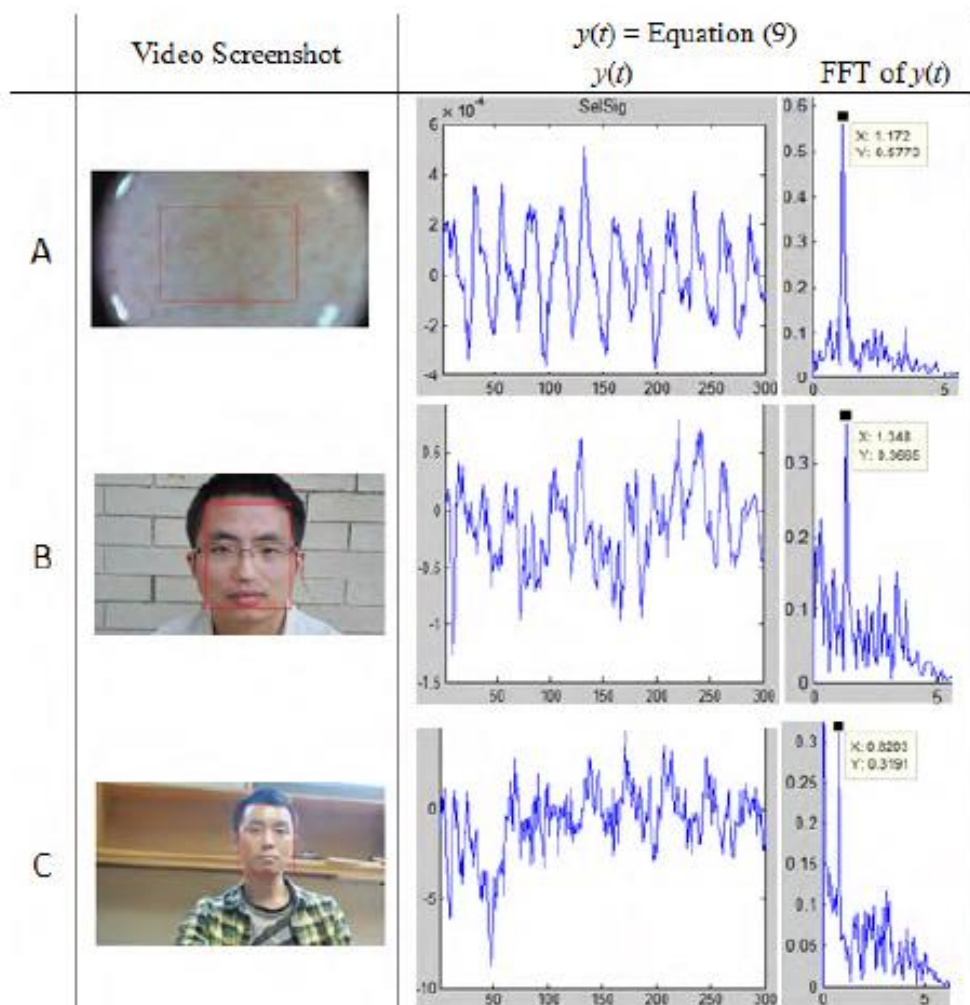
$$y(t) = [\Delta Q^1, \Delta Q^2, \dots, \Delta Q^{z-1}] = \left[\log \frac{\bar{P}_R^2 \bar{P}_G^1}{\bar{P}_G^2 \bar{P}_R^1}, \log \frac{\bar{P}_R^3 \bar{P}_G^2}{\bar{P}_G^3 \bar{P}_R^2}, \dots, \log \frac{\bar{P}_R^z \bar{P}_G^{z-1}}{\bar{P}_G^z \bar{P}_R^{z-1}} \right] \quad (2.20)$$

Horní index každého P_i reprezentuje číslo snímku t .

Nakonec je na signál $y(t)$ aplikována diskrétní Fourierova transformace. Odhad tepové frekvence je poté získán jako hodnota polohy nejvyššího vrcholu ze spektra. Vynásobíme-li tuto hodnotu $\times 60$, dostaneme hodnotu tepové frekvence v tepech za minutu. Nesmíme zapomenout, že ze signálu je nutné eliminovat šum. Proto je vhodné signál $y(t)$ ještě před výpočtem FFT předzpracovat pomocí filtrace pásmovou propustí (128 bodů, Hammingovo okno, 0.6 – 3 Hz). Celkový postup metody je znázorněn pomocí diagramu na Obr. 9 Konkrétní příklad takového postupu je potom znázorněn na Obr. 10. [3]



Obr. 9: Blokový diagram pro odhad tepu metodou založenou na znalostech pigmentaci kůže, upraveno podle [3]

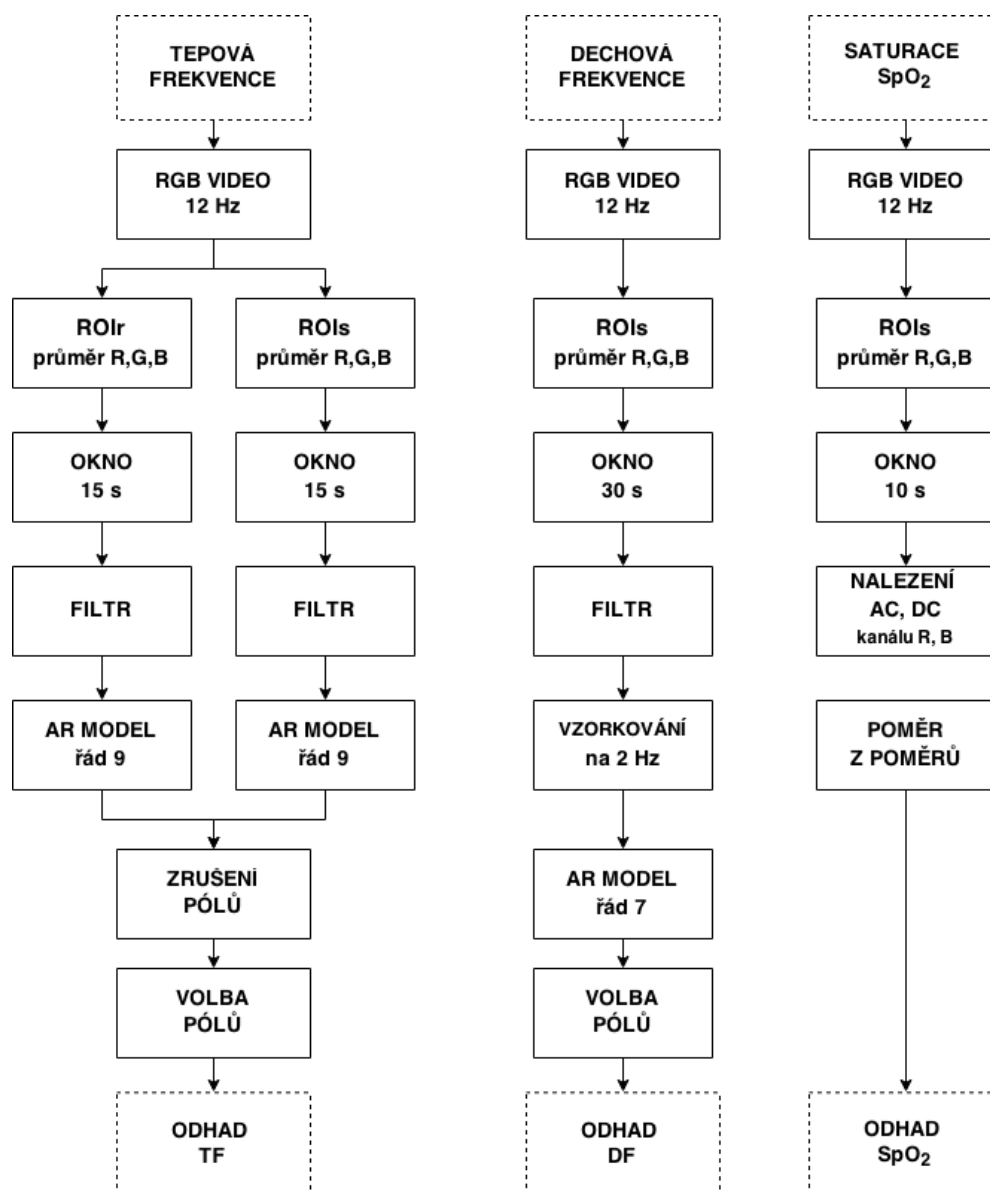


Obr. 10: Výsledky odhadu tepu metodou založenou na znalostech pigmentaci kůže, převzato z [3]

2.4 Autoregresní model

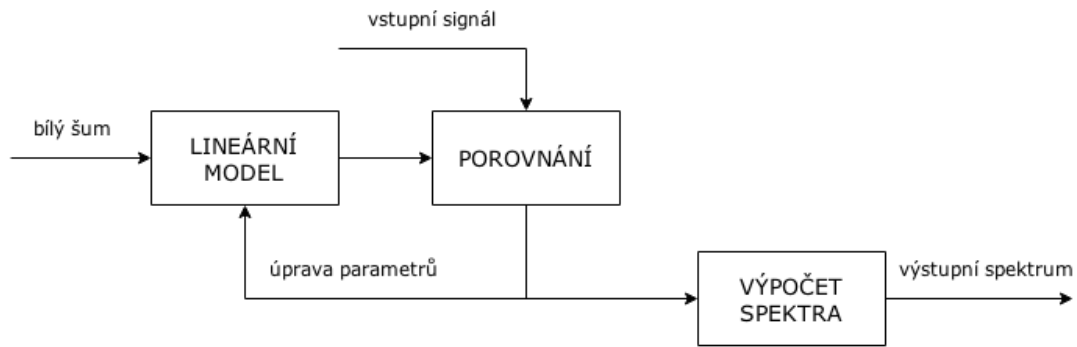
Jedním z nejnovějších přístupů bezkontaktní detekce vitálních funkcí je moderní metoda využívající autoregresní (AR) model. Pomocí takové metody dokážeme odhadovat tři kardio-respirační parametry – tepová frekvence, dechová frekvence a nasycení krve kyslíkem. Blokové diagramy na Obr. 11 znázorňují jednotlivé postupy při zpracování video sekvencí. [4]

Prvotním krokem k získání jednorozměrného fyziologického signálu pro každý barevný kanál je i v této metodě zvolení oblasti ROI. Oblast zájmu zde není jen ROI měřeného obličeje, ale počítá se zde taky s referenčním pozadím. Celý obraz je segmentován do 3 částí: obličej, pozadí a horní část těla. [4]



Obr. 11: Blokové diagramy AR modelů, převzato a upraveno podle [4]

Ke stanovení výkonového spektra může sloužit kromě Fourierovy transformace i parametrická metoda využívající Autoregresní model (AR). Ze všech metod odhadujících spektrum je tato metoda nejvíce robustní a nevyžaduje tolik informací týkajících se původu či charakteru zkoumaných dat. Samozřejmě znát takové informace je při práci s modelem výhodou. Model je zde chápán jako lineární proces k odhadování výkonového spektra. Hlavním předpokladem je, že model je řízen Gaussovským bílým šumem. Šum obsahuje na všech frekvencích stejnou energetickou hodnotu. To znamená, že výkonové spektrum bude přes všechny frekvence konstantní. Parametry modelu je možné nastavovat, aby byl získán co nejlepší a ideální výstup, který hledáme. Do modelu vstupuje signál, který je spektrálně plochý, takže spektrum na výstupu je přímým odrazem přenosové funkce modelu, který odráží vstupní spektrum. AR model nalézá uplatnění především pro odhad spekter obsahujících ostré vrcholy. [4, 14]



Obr. 12: Blokový diagram obecného AR modelu, převzato a upraveno podle [14]

Blokový diagram na Obr. 12 znázorňuje základní princip AR modelování. Přenosová funkce AR modelu obsahuje v čitateli konstantu a ve jmenovateli polynom. Proto je model v anglických literaturách někdy nazýván jako „all-pole model“. AR model vyhledává odpovídající frekvence v signálu, který považujeme po dobu analýzy za stacionární. [14]

$$x(n) = - \sum_{k=1}^p a_k x(n-k) + e(n). \quad (2.21)$$

Předpokládáme, že hodnota aktuálního vzorku $x(n)$, je lineární kombinací p předchozích hodnot $x(n)$ a $e(n)$, kde $e(n)$ představuje aktuální hodnoty distribuce Gaussovského bílého šumu. V rovnici (2.21) udává hodnota p řád modelu, n je počet vzorků, x je lineární regrese předchozích hodnot a $e(n)$ reprezentuje chybu regrese. [4, 14]

AR modelování můžeme také přeformulovat do podoby takového systému, kde bude vstupem bílý šum $e(n)$ a výstupem bude $x(n)$. V definičním oboru z -transformace, kde přenosová funkce $H(z)$ ze vstupu na výstup může být zapsána jako [4]:

$$H(z) = \frac{1}{\sum a_k z^{-k}}. \quad (2.22)$$

Jmenovatel může být součinitelem produktu p , jako [4]:

$$H(z) = \frac{z^p}{(z - z_1)(z - z_2) \dots (z - z_p)} = \frac{z^p}{P_1 P_2 \dots P_p}. \quad (2.23)$$

P_1, P_2, \dots, P_p jsou vektory vystupující z jakéhokoliv bodu z v komplexní rovině každého p pólu $z H(z)$, z_1, z_2, \dots, z_p . Tyto póly (každý je buď skutečný nebo jedním z komplexně sdruženého páru) jsou kořeny jmenovatele přenosové funkce $H(z)$. Póly, které jsou nad reálnou osou ve frekvenční oblasti, odpovídají spektrálním vrcholům modelovaného signálu. Póly s vyšším rozsahem odpovídají vrcholům s vyšším rozsahem.

Frekvence f každého vrcholu je dána fázovým úhlem θ odpovídajícího pólu [4]:

$$\theta = 2\pi f \Delta t, \quad (2.24)$$

kde Δt je vzorkovací interval a úhel θ je vyjádřen v radiánech.

2.4.1 Odhad tepové frekvence pomocí AR modelu

Nejprve jsou identifikovány oblasti ROI. ROI_s pro obličej a referenční ROI_r pro pozadí. Následně je vypočtena pro každý snímek průměrná intenzita barev (nejčastěji pouze pro zelenou barvu), tedy prostorové průměrování oblastí ROI. Z prostorových průměrů obou oblastí ROI (ROI_s i ROI_r) jsou zrekonstruovány časové řady $x(n)$ pro časové okno, s délkou ideálně 15 s. Délka okna 15 sekund odpovídá přibližně 20 srdečním cyklům, což je dostačující počet cyklů pro přesný odhad a zároveň pro zpracování bez příliš dlouhého zpoždění. PPG průběh oken je filtrován prostřednictvím filtru pásmová propust, čímž je zajištěno zvýraznění frekvence zájmu. Pro odhadování tepové frekvence je mezní frekvence pro pásmovou propust zvolena 0.7 a 5 Hz. Tyto hodnoty odpovídají hodnotám tepové frekvence 42 a 300 tepů za minutu a představují očekávaný rozsah tepové frekvence člověka. [4]

AR model jsme tak přiřadili k časovým řadám získaným z ROI_r. Při 12 snímcích za sekundu a pro okno délky 15 sekund získáme 180 vzorků v každém okně pro odhadnutí koeficientů AR modelu. Výběr řádu modelu stanovuje kompromis mezi požadavkem identifikace dominantní tepové frekvence a potřebou modulace tvaru spektra mezi tepovou frekvencí a poloviční vzorkovací frekvencí. Stejným způsobem byl získán samostatný AR model pro ROI_s. V obou případech (ROI_r, ROI_s) byl použit řád 9. [4]

V algoritmu pro tepovou frekvenci je zahrnut proces rušení pólu. Pokud totiž bezkontaktně monitorujeme PPG, získaný signál bude obsahovat aliasingové složky pocházející z okolního umělého světla, které se nacházející na podobných frekvencích jako frekvence srdečního tepu. To je zapříčiněno kvůli snímkovací frekvenci videokamery, která je mnohem nižší než frekvence „blikajícího“ umělého světla. Korekce tohoto problému je provedena diferenciální technikou, která je založena na potlačení komponent, které nesouvisejí s fyziologickými informacemi. Póly nesoucí informace o aliasingových složkách budou odstraněny ze jmenovatele přenosové funkce. Nyní máme v AR modelu identifikovány póly pro ROI_r, které odpovídají frekvencím složek umělého světla. Tyto složky najdeme také v AR modelu pro ROI_s. Testem totožnosti pólů v obou oblastech ROI získáme parametr m , což je stupeň shody ROI_s s ROI_r. Zrušením pólu v oblast ROI_s nám vytváří nový AR model nesoucí informace o srdeční frekvenci – ROI_k. [4]

Pól s největším rozměrem mezi 0 Hz a hodnotou odpovídající poloviční vzorkovací frekvence u AR modelu ROI_k je pólem srdeční frekvence. Vynásobíme-li úhel θ (v radiánech) s $60fs/2\pi$, kde fs je vzorkovací frekvence v Hz, získáme tepovou frekvenci vyjádřenou v tepech za minutu. Radius tohoto pólu je údajem o amplitudě srdeční frekvence v zeleném kanálu pro příslušné okno. Okno délky 15 sekund je posouváno o jednu vteřinu a opakují se výše zmíněné kroky pro každé nové okno. [4, 14]

2.4.2 Odhad dechové frekvence pomocí AR modelu

Dýchací pohyby způsobují odchylky v podobě nízkofrekvenční amplitudy v signálu $x(n)$ získané z oblasti ROI_s . Velikost oblasti zájmu ROI_s při odhadu dechové frekvence bývá obvykle menší než u odhadu tepové frekvence. K filtraci je možné využít opět pásmovou propust nebo dolní propust s horní mezní frekvencí 0.7 Hz (42 dechů za minutu). Oba typy filtrů vyžadují úzké přechodové pásmo. Z filtrovaného signálu byla získána nízkofrekvenční složka dýchání a samostatný AR model je aplikován na časovou řadu prostřednictvím okna s délkou 30 sekund k identifikaci pólu dýchací frekvence. [4]

I pokud použijeme nízkou vzorkovací frekvenci (12 snímků za sekundu) je zapotřebí signál převzorkovat. Pro dechové frekvence 15 dechů za minutu (tj. 0.25 Hz) bude fázový úhel θ pólu frekvence dýchání jen 0.3 radiány (7.5°). Abychom zvýšili úhlové rozlišení je potřeba videosignál filtrovaný pásmovou propustí převzorkovat na 2 Hz. Tím zvýšíme úhel pólu odpovídající dechové frekvence z 0.25 Hz na $\pi/4$ radiánu (45°). [4]

Opět je zde potřeba identifikovat dominantní dýchací frekvenci a modelovat tvar spektra mezi dýchací frekvencí a poloviční vzorkovací frekvencí. Definujeme proto konkrétní úsek nulových pólů s hodnotami od 18° do 126°, tzn. od 0.1 do 0.7 Hz (odpovídající hodnotám respirační frekvence 6 až 24 dechů za minutu). Z tohoto úseku budou vybrány ty póly, které mají velikost alespoň 95% z nejvyššího rozsahu pólu a z nich bude vybrán pól, mající nejmenší úhel. Tento pól bude reprezentovat hodnotu dechové frekvence. [4]

Úhel pólu v AR modelu udává hodnotu píku ve frekvenčním spektru. Rozsah (od 0 do 1) určuje sílu této frekvenční složky. Dominantní pól v AR modelu pro tepovou frekvenci (řád 9) a dominantní pól pro dechovou frekvenci (řád 7) byly vybrány na základě specifických kritérií. [4]

2.4.3 Odhad saturace krve kyslíkem pomocí AR modelu

Konvenční pulsní oxymetry pracují na principu spektrální analýzy světla procházejícího krví nasycené kyslíkem. Z principů oxymetrie je předpokládáno, že útlum světla je způsoben průtokem arteriální krve do měřeného místa a saturace je potom odhadována ze změn amplitud pulsačních složek na dvou vlnových délkách. Saturace tedy závisí na množství složek obsažených v krvi v závislosti na jejich absorpci. Přístup měření saturace kyslíku je založen na Lambert-Beerově zákonu pro absorpci. Rovnice pro saturaci kyslíku zní [4]:

$$SpO_2 = A - B \frac{\left(\frac{I_{ac}}{I_{dc}}\right) \lambda_1}{\left(\frac{I_{ac}}{I_{dc}}\right) \lambda_2}, \quad (2.25)$$

kde A a B jsou empiricky stanovené koeficienty, I_{ac} a I_{dc} jsou příslušné amplitudy pulsních (ac) a stejnosměrných (dc) složek transmitovaného nebo odraženého světla vlnových délek λ_1 a λ_2 . Běžné pulsní oxymetry využívají vlnové délky 660 nm (R) a 940 nm (blízké IR). Koeficienty A a B jsou odhadovány pomocí dat získaných z kalibračních pokusů. [4]

Viditelné světlo používané při bezkontaktním monitorování fyziologických parametrů však prochází do kožní tkáň velmi omezeně. Na obličeji, přesněji na čele, dochází k procesu vaskularizace neboli ke vzniku krevních cév zásobovaných nadočnicovou tepnou. Mnoho studií dokázalo, že čelo je místem s lepšími vlastnostmi pro vyhodnocování parametru nasycení krve kyslíkem oproti standardnímu místu měření, kterým je doposud elektroda připevněná na prstu horní končetiny. [4]

Odhad saturace krve kyslíkem využívá poznatky a výsledky z odhadu pro tepovou frekvenci uváděnou v kapitole 2.4.1. Hodnoty vypočtené tepové frekvence jsou použity pro odhad množství AC a DC složek z rovnice (2.25) pro vlnovou délku odpovídající červené a modré oblasti spektra. DC hodnota byla vypočítána pomocí okna s klouzavým průměrem o velikosti 10 sekund. AC hodnota byla odhadována z průměrné výšky mezi vrcholem a nejnižším bodem v každém okně o velikosti 10 sekund. [4]

3 Návrh a realizace experimentu

Po nastudování článků zabývajících se bezkontaktní detekcí fyziologických parametrů byly promyšleny a vyhodnoceny možnosti realizace experimentu. Hlavní komponenty experimentu je videokamera, stativ, přídavné IR osvětlení v podobě dvou LED diod s vlnovou délkou 850 nm, notebook a systém BIOPAC pro kontrolní měření vitálních funkcí.

3.1 Prostředí experimentu

Experiment se odehrával v jedné z místností Ústavu biomedicínského inženýrství. Vybavení a přístroje byly použity následující:

- Videokamera – sběr dat
- Osvětlení – 2 x IR osvětlovací lampa a 1 x lampa s bílým světlem
- Zdroj pro IR osvětlení
- Systém BIOPAC
- Notebook s příslušným softwarem pro sběr dat

Pro měření bylo potřeba natočit scénu, ve které bude hlavním předmětem zájmu obličej a hrudník zkoumané osoby. Ideální nastavení se jevilo tak, že osoba seděla nehybně na židli a kamera ji snímala ze vzdálenosti 1 m.

Bylo provedeno a otestováno několik variant nastavení videokamery i okolního osvětlení. Také systém BIOPAC byl kalibrován a vhodně nastaven pro účely této práce. Nejvhodnější a konečná podoba celého experimentu je popsána níže v jednotlivých podkapitolách.

3.1.1 Snímací aparatura

Videokamera, jakožto nejvýznamnější součást celého experimentu, byla vybrána od společnosti Imaging Source, a to díky své vynikající kvalitě obrazu, díky zabudování velmi citlivého senzoru poskytujícího výjimečnou kvalitu obrazu i za špatných světelných podmínek a v neposlední řadě díky vysoké rychlosti zaznamenávání snímků, tzv. snímkovací frekvenci.


Konkrétně byla k dispozici USB 3.0 Color Industrial Camera model DFK 23UM021 (Obr. 13), která dokáže zaznamenávat obrazové sekvence rychlostí až 60 fps. [17]



Obr. 13: USB 3.0 Color Industrial Camera - DFK 23UM021, převzato z [17]

Pomocí softwarové aplikace IC Capture, Image Acquisition (version 2.3.394.1917) bylo možné zachytit a zobrazit jednotlivé snímky jak ve formě obrazových sekvencí, tak v podobě datových toků ve formátu AVI.

Spektrální citlivost videokamery využitě pro náš experiment je znázorněna na Obr. 14. Spektrální citlivost RGB videokamery je funkcí vlnové délky popisující relativní účinnost detekce světla pro jednotlivé barevné filtry a obrazové senzory. Tuto charakteristiku je dobré znát a využít ji pro výběr okolního osvětlení. [17]



Obr. 14: Spektrální citlivost videokamery, převzato z [17]

3.1.2 Okolní osvětlení

Experiment se uskutečnil v místnosti, kde bylo přizpůsobeno okolní osvětlení tak, aby do scény neprostupovalo ostré sluneční světlo. Okolní osvětlení bylo zvoleno umělé v podobě žárovky (lampy), která poskytuje stálé a spojitě světelné spektrum v podobě žlutého světla.


K dispozici bylo také přídavné osvětlení v podobě IR Illuminatoru o vlnové délce 850 nm. IR spektrum není lidským okem viditelné, ale pro videokamery citlivé na IR oblasti spektra umožňuje pracovat i ve velmi nízkém osvětlení. V našem případě do této kategorie lze zařadit i videokameru použitou pro náš experiment. Dle spektrální citlivosti kamery z Obr. 14 lze tvrdit, že IR oblast spektra zasahuje do všech tří složek RGB.

Jedním z bodů zadání je otestovat vliv IR záření na naměřená data. Jelikož IR záření se vyznačuje nežádoucími účinky na lidský organismus, nebylo by vhodné dobrovolníkům ozařovat obličej. Z tohoto důvodu byla do experimentu zařazena scéna, ve které je dobrovolníkům snímána videokamerou paže, a to jen po nezbytně krátkou dobu.

3.1.3 Parametry a nastavení snímání

Na videokameře používané v experimentu bylo možné manuálně nastavit pouze zaostření a clonu. Přesné parametry těchto veličin nebylo možné z kamery odečíst, proto nelze údaje vyjádřit v číselných hodnotách. Měřeny byly dva druhy scén (tvář s hrudníkem a paže). Vzhledem k tomu, že scény byly jinak zkonstruovány (odlišná vzdálenost kamery, jiné osvětlení, apod.), měly také odlišné nastavení parametrů clony i zaostření. Bylo však usilováno především o to, aby tyto parametry byly nastaveny pro danou scénu stejně pro každé měření. Po kalibraci a nastavení již s těmito parametry nebylo manipulováno.

Software IC Capture potom zprostředkoval náhled v reálném čase a umožňoval nastavení ostatních parametrů snímání. Nastavovala se vzorkovací frekvence, rozlišení a formát snímání. V panelu pro úpravu obrazu bylo možné nastavit jas, kontrast, vyvážení barev, ostrost, zesílení, expozici či gamma korekci. Zachycené snímky pak byly ukládány v podobě videosekvencí ve zvoleném formátu. Panel nástrojů softwaru IC Capture je zobrazen na Obr. 15.



Obr. 15: Panel nástrojů softwaru IC Capture 2.3

Snímání bylo provedeno ve formě obrazových sekvencí grafického formátu *bmp*. Rozlišení videokamery bylo zvoleno 1280x720. Vzorkovací frekvence (fps) bylo možné nastavit až na hodnoty 60 fps, ovšem v závislosti na rozlišení obrazu. Čím větší rozlišení, tím menší snímkovací frekvenci bylo možné volit. Pro naše měření bylo postačující nastavit snímkovací frekvenci na 30 fps. Vzhledem k tomu, že délka jednoho měření byla 10 sekund, tak očekávaná hodnota naměřených snímků byla 300. Výsledný počet naměřených snímků však nedosáhnul očekávaného množství. Navíc tento počet u

jednotlivých měření kolisal. Počet zachycených snímků je pravděpodobně ovlivňován použitým hardwarem. Dalším aspektem, který ovlivňoval frekvenci snímání je nastavení parametru expozice a zesílení. Bylo zjištěno, že s rostoucí hodnotou expozice klesal počet zachycených snímků. Zároveň počet zachycených snímků klesal se snižováním hodnot parametru zesílení. Nicméně tento nedostatek byl při analýze dat korigován tak, že fps byla individuálně dopočítána na hodnotu odpovídající reálnému počtu zachycených snímků.

Lampa vyzařující žluté světlo nebyla natočena přímo na měřenou osobu, ale byla odkloněna. Dotyčný tak byl osvětlen s menší úrovní světla. Pro ideální vzhled scény byla věnována pozornost nastavení parametrů zesílení, expozici a gamma korekci.

Parametr zesílení (gain) dokáže zvýšit citlivost videokamery při neměnicím se expozičním čase. Toto zvýšení zapříčiní zjasnění obrazu, což je užitečné při sníženém osvětlení či při krátké expoziční době. Nevýhodou je však to, že se zvyšujícím se zesílením se zesiluje šum v obraze.

Všechny monitory vykazují nelineární zobrazení vstupního jasu pixelů zachycených fotoaparátem či videokamerou. Nelinearitu mezi zachyceným a zobrazeným pixelem popisuje parametr gamma. K upravení zmíněné nelinearity slouží gamma korekce. Ovlivňuje tak rozložení jasů (tmavost a světlost) a má vliv také na barvy obrazu (sytost a vyblednutí). Uživatelská příručka poskytovaná k softwaru IC Capture doporučuje pro USB přenos dat nastavit gamma korekci na hodnotu 100. Tato hodnota tedy zůstala pro všechny měření pevně nastavena. [17]

Dalším důležitým parametrem je expoziční čas, tedy doba působení světla na senzor. Tato veličina je udávána v sekundách, jedná se obvykle o velmi krátkou dobu (např. 1/8, 1/25, 1/30, 1/100). Je ovlivněna clonou a funguje podobně jako závěrka u fotoaparátu. Čím delší je expoziční čas, tím více světla projde na senzor a tím více bude výsledný obraz světlejší. Doporučuje se, aby expoziční doba byla nastavena na dvojnásobek snímkovací frekvence (fps). Máme-li 30 fps, ideální nastavení expozice bude na hodnotu 1/30 sekund. [17]

3.2 Biopac MP35

Pro kontrolu správnosti bezkontaktního odhadu fyziologických parametrů byl využit sofistikovaný systém BIOPAC. Hardwarové a softwarové vybavení systému BIOPAC je studentská laboratoř, která umožňuje snímání a zaznamenání základních fyziologických parametrů. Systém poskytuje širokou škálu možností zaznamenávání biologických signálů. Hardware BIOPAC MP35 převádí naměřené analogové signály na digitální a pomocí USB portu je přenáší do počítače. Příslušný software AcqKnowledge umožňuje data zobrazovat a ukládat. [20]



Obr. 16: BIOPAC MP35

Panel měřicí jednotky je vybaven pěti vstupními porty. Z nich jeden port je určen ke kontrole zapojení elektrod (označen jako Electrode Check). Ostatní čtyři porty fungují jako měřicí kanály s označením CH1 až CH4. Na tyto kanály je možné připojit příslušné komponenty pro měření. Signály získané z tohoto systému sloužily jako referenční hodnoty, od kterých se vyhodnocovala správnost a funkčnost zvolené metody a algoritmu. Pro potřeby této práce bylo využito čtyř kanálů – ruční spínač, PPG senzor, respirační pás a EKG elektrody. [20]

3.2.1 Ruční spínač

Naměřená data bylo nutné synchronizovat tak, abychom mohli srovnávat data z BIOPACu ve stejném časovém okamžiku, jako data sbíraná videokamerou v podobě videosekvencí. K označení okamžiku začátku měření sloužil ruční spínač (Hand Switch), jehož sepnutí způsobilo změnu signálu z nulové konstantní hodnoty na rychlý a výrazný kmit. Od polohy kmitu byla pak surová data ořezána na délku 10 000 vzorků, představující čas 10 sekund. Ruční spínač je vyobrazen na Obr. 17.



Obr. 17: Hand Switch

3.2.2 PPG senzor

Fotopletysmografický senzor umístěný na prstu ruky testované osoby umožňoval zaznamenávat pulsní křivku krevního objemu pomocí optické metody (Obr. 18). Senzor je vybaven IR emitorem a fotodiodou, jež vysílá světlo, které je po průchodu tkání modulováno v závislosti na změnách objemu v krevním řečišti. V principu se jedná o metodu založenou na průchodu světelných paprsků tkání a následné detekci jejich odrazu, absorpci či rozptylu. Výstupem je pletysmografická křivka. [20]



Obr. 18: PPG senzor

3.2.3 Respirační pás

K zaznamenávání dechových pohybů sloužil respirační pás. Nasazuje se na hrudník či břicho vyšetřované osoby. V signálu z tohoto kanálu lze pozorovat vlny, které reprezentují dýchací pohyby. Detekce dechové frekvence je prováděna ručně tak, že počet nádechu za čas 10 s byl vynásoben šesti. Výsledkem je přibližná hodnota počtu dechů za minutu.



Obr. 19: Respirační pás


3.2.4 EKG svody

K monitorování EKG byl použit kanál se třemi končetinovými svody. Měřená osoba měla na končetinách přilepeny elektrody a na ně byly připnuty svodové kabely, viz Obr. 20. Černý svod reprezentoval zemnicí elektrodu a byl umístěn na pravou dolní končetinu. Červený kabel potom na levou horní končetinu a bílý kabel na levou horní končetinu. Z naměřeného EKG signálu byla detekována a spočítána hodnota tepové frekvence. [20]



Obr. 20: EKG svody

Monitorované signály bylo možné pozorovat v softwaru AcqKnowledge. Data byla uložena a archivována pro další zpracování. Grafické prostředí ovládacího programu pro systém Biopac – AcqKnowledge je vyobrazeno na Obr. 21. První (horní) kanál představuje signál PPG, pod ním dech, dále spínač a ve spod EKG křivka. Ruční spínač je v jednotkách voltů, ostatní signály jsou v milivoltech.



Obr. 21: Vzhled prostředí softwaru AcqKnowledge

3.3 Průběh měření

Experiment byl realizován na 10 dobrovolnících. Dobrovolník byl usazen na židli a byl vyzván k nehybnému a klidovému setrvání v dané pozici. Na končetinách měl připevněny elektrody pro snímání EKG, na prstu levé ruky byl připevněn senzor pro měření pletysmografické křivky a kolem hrudníku hrudní pás pro detekci dechové frekvence. Snímání trvalo jen několik desítek sekund. Videokamera byla spuštěna pouze na 10 s. K označení začátku měření sloužil v systému BIOPAC ruční spínač. Na Obr. 22 je ukázáno prostředí experimentu a měření jednoho z dobrovolníků.



Obr. 22: Prostředí experimentu

Získané videosekvence byly dále upraveny a zpracovány v programovém prostředí Matlab, kde vhodným algoritmem získáme odhad tepové a dechové frekvence.

4 Zpracování a analýza naměřených dat

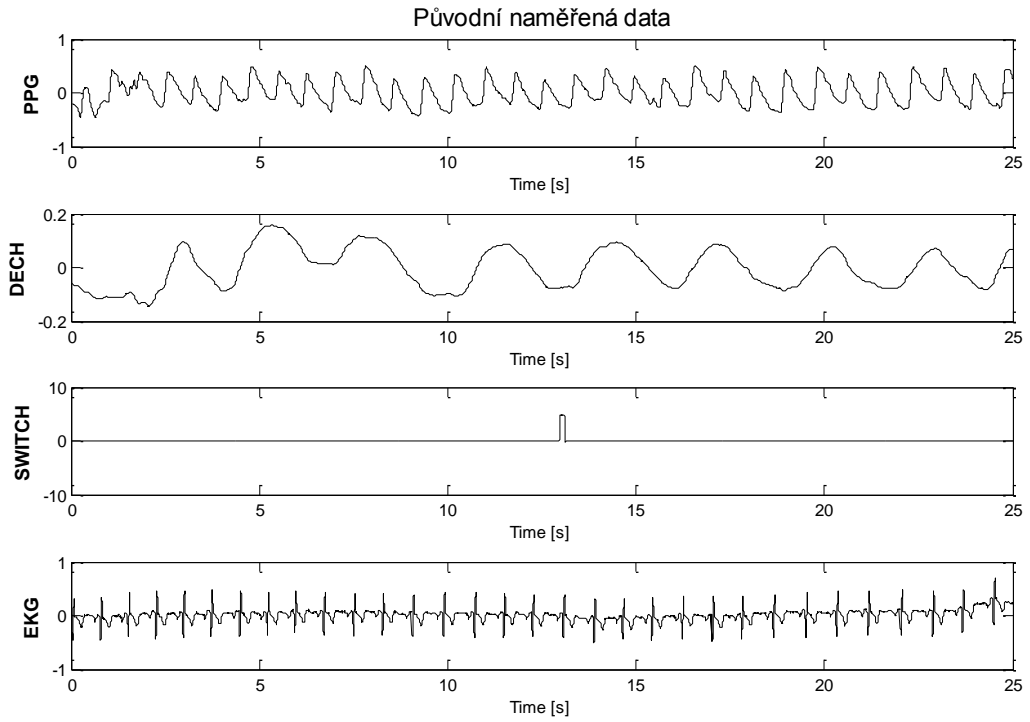
Pro implementaci naměřených dat bylo zvoleno programové prostředí Matlab (verze R2013a). Nejprve byla zpracovávána referenční data získána ze systému BIOPAC. Tyto data poté sloužily jako kontrolní hodnoty pro porovnání správnosti výsledků bezkontaktní detekce fyziologických parametrů. Další zpracování a analýza se týkala dat (sérií videosekvencí) získaných videokamerou od všech dobrovolníků.

4.1 Zpracování dat z referenčního měření

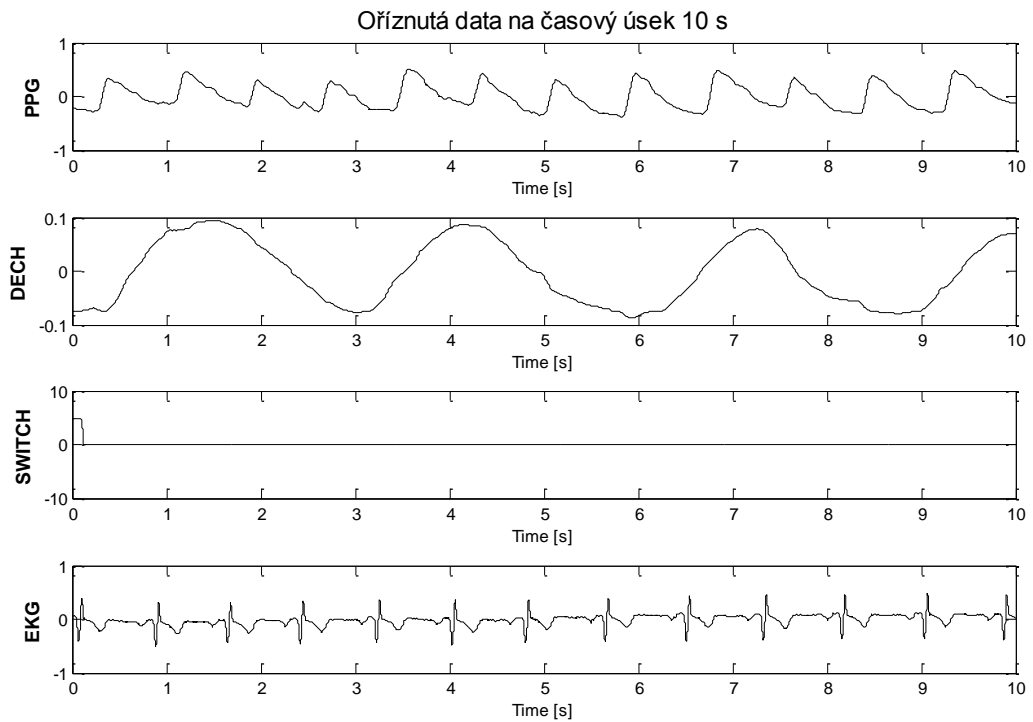
Grafické prostředí softwaru AcqKnowledge umožňuje naměřené data ukládat v podobě tzv. MAT-File. S takovými daty lze pracovat v prostředí Matlab. Data jsou uložena jako matice hodnot uspořádaných podle pořadí naměřených signálů (parametrů). Máme-li čtyři signály, soubor bude obsahovat matici o čtyřech sloupcích obsahujících hodnoty odpovídající funkčním hodnotám signálu. Délka matice potom odpovídá délce signálu ve vzorcích v jednotkách milisekund. [25]

Surová data získaná naměřením ze systému BIOPAC spočívala především ve zkrácení a ořezání na požadovanou hodnotu. Od nejvyšší hodnoty z kanálu switch, který odpovídal začátku měření, byla data oříznuta na 10 000 vzorků odpovídajícím 10 sekundám.

Na Obr. 23 a Obr. 24 je ukázka signálů získaných systémem BIOPAC. V prvním případě jde o surové a zatím nezpracované data. V dalším jsou vzorky ořezány od mezní hodnoty způsobeného spínačem na délku 10 sekund. Jelikož byla prováděna bezkontaktní detekce pouze parametrů tepové a dechové frekvence, proto nás pro další zpracování zajímaly především kanál 2 a 4.



Obr. 23: Ukázka původních dat




Obr. 24: Ukázka upravených dat

Dechová frekvence byla počítána manuálně. Počet nadechnutí za 10 sekund byl vynásoben šesti. Fyziologické hodnoty klidového dýchání se pohybují okolo hodnot 14 až 16 dechů za minutu. To znamená, že v časovém úseku 10 sekund budou očekávány 2.5 až 3 nádechy. Přesnou hodnotu dechů za minutu nebude možné úplně změřit, proto nás bude zajímat především odhad tohoto parametru pro srovnání s bezkontaktní detekcí, což se může zdát postačující.

Hodnota tepové frekvence byla získána z časového průběhu signálu EKG. Byly detekovány QRS komplexy a následně byl proveden odhad poloh R kmitů, z nichž byl dopočítán počet tepů za minutu. Pro detekci byla vybrána metoda založená na umocnění signálu EKG.

4.1.1 Detekce QRS pro získání hodnoty tepové frekvence

Cílem detekce QRS je nalezení vektoru poloh R kmitů v signálu EKG. Byl vytvořen detektor, který je založen na umocnění filtrovaného vstupního signálu. Jednotlivé kroky detekce je možné vidět na Obr. 25. [23]



Obr. 25: Detektor QRS komplexů, upraveno podle: [23]

Máme vstupní signál EKG, který je v první řadě filtrován pásmovou propustí (PP). Konkrétně s dolní mezní frekvencí 8 Hz a horní mezní frekvencí 22 Hz. Taková filtrace odstraní ze signálu síťové rušení i nežádoucí drift, který postihuje složky dosahujících hodnot do 2 Hz. Dále je díky PP signál EKG zbaven vln P, T, popřípadě i U, které pro detekci R kmitů nejsou potřebné. Následuje krok umocnění signálu způsobující zdůraznění vrcholů a také převod veškerých hodnot signálu do kladných čísel. Signál ještě není úplně vyhovující, proto je ještě jednou filtrován, tentokrát filtrem typu dolní propust (DP). DP odfiltruje složky s mezním kmitočtem 20 Hz. Nyní je signál předzpracován a je připraven na tzv. prahování. To spočívá v hledání maxim podle adaptivních prahových kritérií. Tím bude docíleno nalezení jednotlivých R kmitů v EKG signálu. Nakonec jsou zjištěny polohy jednotlivých R kmitů, ze kterých je dopočítán počet tepů za minutu. [23]

4.1.2 Realizace detektoru v prostředí Matlab

Program *detekce.m* umožňuje v signálu EKG detekovat jednotlivé R kmity, určit vektor poloh těchto kmitů a nakonec vypočítat tepovou frekvenci. Výstupem je tak konečný počet kmitů a hodnota tepové frekvence v tepech za minutu.

Nejprve je signál načten a uložen do proměnné x . Parametry filtrů PP a DP jsou nastaveny pomocí příkazu *fir1* (N , Wn , 'type'). N znamená řád filtru neboli hodnota čitatele polynomu přenosové funkce, Wn udává mezní frekvence a 'type' určuje druh filtru. Pro PP byl použit řád 120, horní a dolní mezní frekvence byla zadána dvouprvkovým vektorem s hodnotami [8 22] a díky tomu druh filtru nemusel být zadán. U filtru DP byl zvolen řád 70, hodnota mezní frekvence 20 a označení druhu filtru jako 'low'.

Samotná filtrace signálu byla provedena pomocí příkazu *filter* (b , a , X), kde a reprezentuje číselník a b jmenovatel přenosové funkce a X je signál, který chceme filtrovat. Za parametr b byl dosazen filtr PP/DP a za a byla dosazena 1. Signál je tak filtrován, umocněn a následuje hledání R kmitů. To bylo prováděno pomocí adaptivního prahování popsaného níže. [24, 25]

Adaptivní prahování spočívá v prohledávání a porovnávání jednotlivých vzorků s detekčním prahem. K tomu je použit hlavní cyklus *while* a několik podmínek pro rozhodovací pravidla. Šířka QRS komplexu v signálech je stanovena na 100 vzorků, podle čehož byla nastavena velikost okna. Okno je aplikováno tehdy, je-li nalezen vzorek s hodnotou vyšší než práh. Následně je v okně hledáno maximum, které odpovídá kmitu R. Práh není stanoven pevně, ale je schopen se po každé detekci přizpůsobit. To znamená, že je spočten průměr ze všech nalezených R kmitů a potom je hodnota nastavena na 40%. Je nutné dodržet podmínku, aby vzdálenost mezi aktuálně porovnávanou hodnotou a posledním detekovaným R kmitem nepřesáhla 1.66ti násobek průměrné délky. Není-li podmínka dodržena, program sníží práh detekce a nastane nové prohledávání. Jednotlivé kroky a výsledek detekce je zobrazen na Obr. 26. [26]

Filtrace signálů způsobila zpoždění, které je nutné ošetřit. Počet vzorků zpoždění byl počítán podle vzorce [23]:

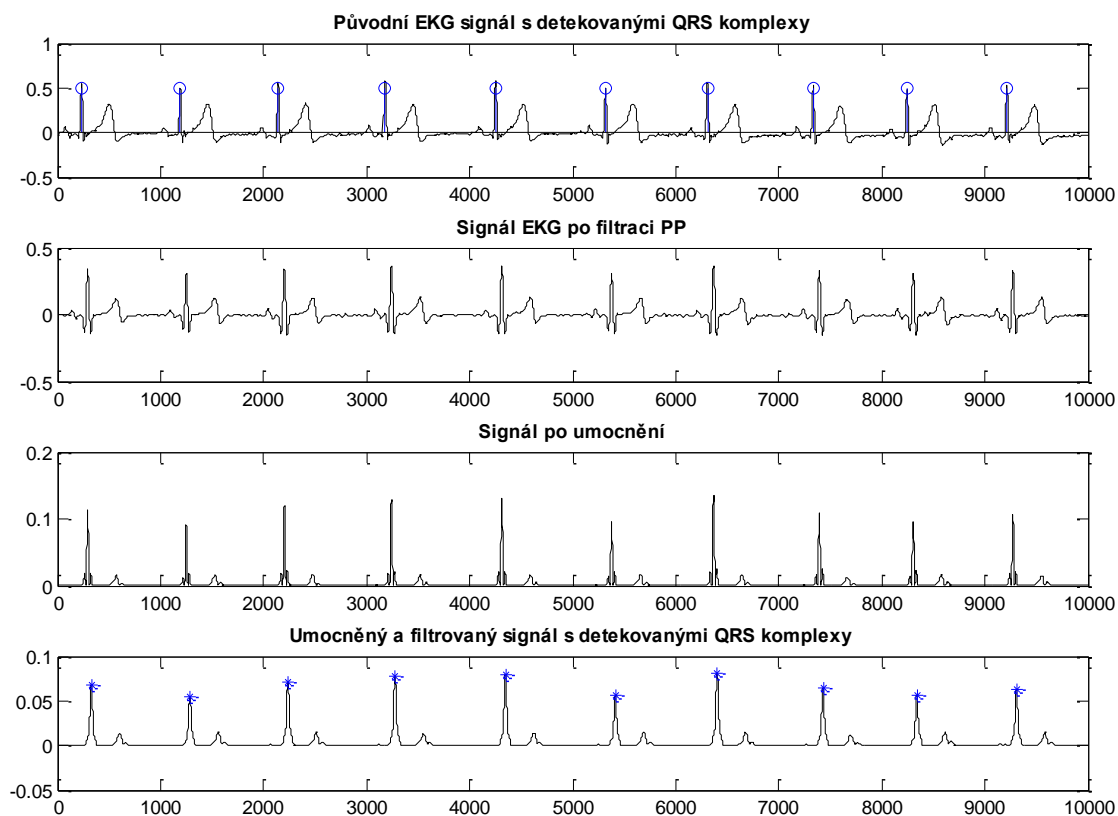
$$\text{zpoždění} = \frac{N - 1}{2}, \quad (4.1)$$

kde N je délka filtrovaného signálu. Zpoždění bylo spočítáno pro oba filtry využitě v detektoru a následně byly obě zpoždění sečteny. Při vykreslování signálu bylo potom zpoždění odečteno od poloh R kmitů.

Proměnná *polohy* obsahuje vektor hodnot, které vyjadřují čísla vzorků, na kterých se nalézají jednotlivé R kmity. Následně je vypočítán vektor vzdáleností mezi jednotlivými R kmity. Vzdálenosti jsou udány v počtu vzorků. Známe nyní vektor vzdáleností mezi R kmity v časovém úseku 10 sekund. Počet R kmitů za minutu vypočítáme pomocí vzorce:

$$\text{tep} = \frac{60}{\frac{\mu}{f \cdot vz}}. \quad (4.2)$$


V rovnici (4.2) parametr μ vyjadřuje průměrnou hodnotu ze vzájemných vzdáleností jednotlivých R kmitů a fvz je vzorkovací frekvence. Po skončení programu je v Command Window vypsán počet nalezených komplexů a přesná hodnota tepové frekvence v počtu tepů za minutu.



Obr. 26: Výsledky jednotlivých kroků detekce QRS


4.2 Zpracování videosekvencí pro bezkontaktní detekci

Následuje popis zpracování a analýzy obrazových sekvencí naměřených pro bezkontaktní odhad tepové a dechové frekvence. Blokový diagram na Obr. 27 znázorňuje jednotlivé kroky algoritmu, pomocí kterého bylo dosaženo výsledného odhadu parametru tepové frekvence (TF) a dechové frekvence (DF). Jednotlivé kroky budou postupně popsány.



Obr. 27: Jednotlivé kroky experimentu bezkontaktní detekce TF a DF

Program vytvořený pro bezkontaktní detekci je nazván *ICA.m*. V první řadě byly načteny obrazy prostřednictvím *for* cyklu do proměnné datového typu buňkové pole. Příkazem *imshow* byl zobrazen první obraz ze série a následně příkaz *ginput* vyzval uživatele k výběru dvou souřadnicových bodů (levý horní a pravý dolní bod čtverce či obdélníku) pro určení výřezu oblasti ROI. Ukázka je na Obr. 28, kde jsou také znázorněny orientační a doporučené oblasti pro výběr ROI. Pro tepovou frekvenci ROI obličeje, pro dechovou frekvenci ROI hrudníku a břicha. Souřadnice zvolené oblasti ROI byly uloženy do proměnné *a* a *b*. V dalším zpracování už bylo pracováno pouze s vybranou oblastí ROI.

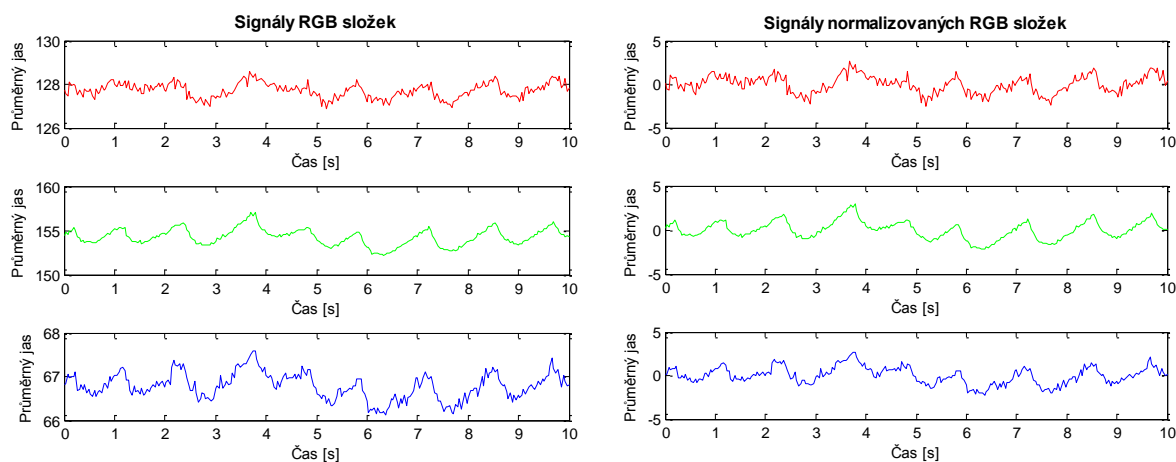


Obr. 28: Příklad jednoho snímku měření s vyznačenými oblastmi ROI

Následoval další *for* cyklus, ve kterém byl proveden rozklad na tři RGB složky reprezentujících průměrnou jasovou hodnotu pixelů v celé ploše zvolené oblasti ROI. Byly získány tři stopy - $x_R(t)$, $x_G(t)$, $x_B(t)$, které bylo nutné před použitím normalizovat podle rovnice [8]:

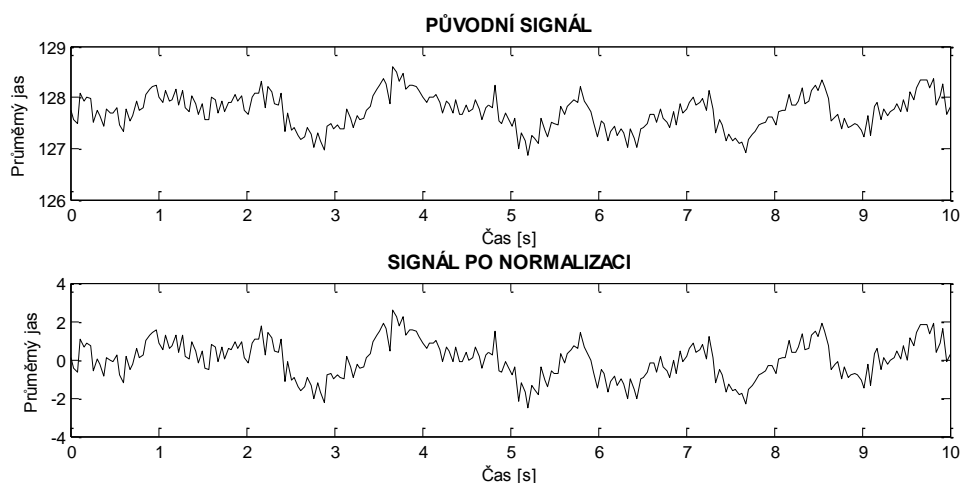
$$x'_i(t) = \frac{x_i(t) - \mu_i}{\sigma_i}, \quad (4.3)$$

kde pro každé $i = R, G, B$ je μ_i je průměr a σ_i je směrodatná odchylka. Normalizací bylo docíleno transformace původního signálu $x_i(t)$ na signál $x'_i(t)$, který se vyznačuje nulovou střední hodnotou a jednotkovým rozptylem. Normalizace byla provedena proto, jelikož jedním z požadavků používaného algoritmu JADE popsaného v další kapitole, je právě nulová střední hodnota. Znormalizované signály jsou vykresleny jako závislost průměrného jasu na čase v sekundách. Na Obr. 29 je ukázán rozdíl mezi původními a normalizovanými signály. Jednotlivé RGB složky jsou rozlišeny příslušnými barvami pro daný kanál [2, 8]



Obr. 29: RGB signály před a po normalizaci

Obr. 29 vyobrazuje rozdíl, který způsobí normalizace RGB složek. Můžeme si zde povšimnout, že jasové hodnoty normalizovaných signálů mají nižší velikost a především se vyznačují požadovanou nulovou střední hodnotou. Detailní podobu signálu červené složky před a po normalizaci můžeme vidět na Obr. 30.



Obr. 30: Ukázka signálu před a po normalizaci dle rovnice 4.3

Máme nyní tři normalizované signály (vektory čísel) reprezentující tři složky, tedy kanály RGB. Metoda pro další zpracování byla zvolena analýza nezávislých komponent (ICA). Jedním z důvodů byla především schopnost metody detekovat dva parametry stejným algoritmem (tepová a dechová frekvence). Způsob tohoto přístupu pro bezkontaktní detekci obou parametrů byl publikován v článku, jež sloužil jako inspirace k realizaci praktické části této práce. [2]

Následující kroky zpracování se věnují rozkladu signálů na tři nezávislé zdrojové signály použitím analýzy ICA.

4.3 Algoritmus ICA

Jak již bylo uvedeno v kapitole 2.2, analýza nezávislých komponent dokáže rozložit signál na zdrojové komponenty, ze kterých byl signál původně složen. Komplexní signály jsou v prostředí Matlab separovány pomocí algoritmu JADE (Joint Approximate Diagonalization of Eigenmatrices). Algoritmus byl v programu použit podle [21] a vychází ze vztahu [22]:

$$\vec{x}(t) = A * \vec{s}(t) + \vec{n}(t) \quad (4.4)$$

kde $\vec{x}(t)$ je hledaný signál s rozměrem m , A je směšovací matice o rozměru $n \times m$, \vec{s} je náhodný vektor (signál) o rozměru n a \vec{n} reprezentuje aditivní šum s neznámým rozptylem o rozměru n . [21, 22]

Algoritmus JADE provádí separaci signálu pomocí metody nazývané společná aproximační diagonalizace vlastních matic. Takový rozklad je v algoritmu uskutečněn v několika krocích. V podstatě můžeme algoritmus rozdělit na dvě hlavní části. První část spočívá v nalezení sady symetrických matic a vlastních čísel určených k diagonalizaci a druhá část se věnuje samostatné aproximační diagonalizaci matic. [21]

Úplně prvním krokem algoritmu je úprava signálu procesem bělení (tzv. whitening). Je vytvořena náhodná matice W , pomocí které dojde k vybělení bílého šumu tak, že je proveden součin matice W a vstupního signálu \vec{x} . Po bělení signálu získáme [22]:

$$\vec{y}(t) = W \cdot \vec{x} \quad (4.5)$$

Následuje proces odhadu kumulačních koeficientů z aktuální proměnné \vec{y} . Konkrétně jde o kumulační koeficient čtvrtého řádu, který je vlastně symetrickou maticí. Poté je proveden výpočet a předzpracování významných vlastních čísel, které jsou důležité pro další krok. Ten spočívá ve zmiňované aproximační diagonalizaci vlastních matic. [21]

Principem diagonalizace vlastních čtvercových matic je nalezení základních ortonormálních změn, a tím matice diagonalizovat jak nejvíc to jde. Toho je v algoritmu dosaženo prostřednictvím matice Θ_{kl} , která je nazývána jako Givensova rotace (Obr. 31). V každém kroku je v algoritmu prostřednictvím *for* cyklu počítána a aktualizována hodnota Givensova úhlu a rotace. Přesnosti je dosaženo, jsou-li všechny matice v sadě dostatečně zaměněny. Pokud tomu tak není, je možné příslušnými přístupy optimalizovat kritéria diagonality. Finálním krokem je odhad směšovací matice a konečná separace signálu. [21, 22]

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

Obr. 31: Givensova rotace, převzato z [22]

Předpokladem pro algoritmus je nulová střední hodnota vstupního signálu. Výhodou JADE algoritmu je jeho fungování bez nutnosti nastavování parametrů. Nevýhodou může být, že je v praxi omezen počet zdrojů (ne však senzorů). Toto omezení se nevztahuje pro aplikaci této práce. [22]

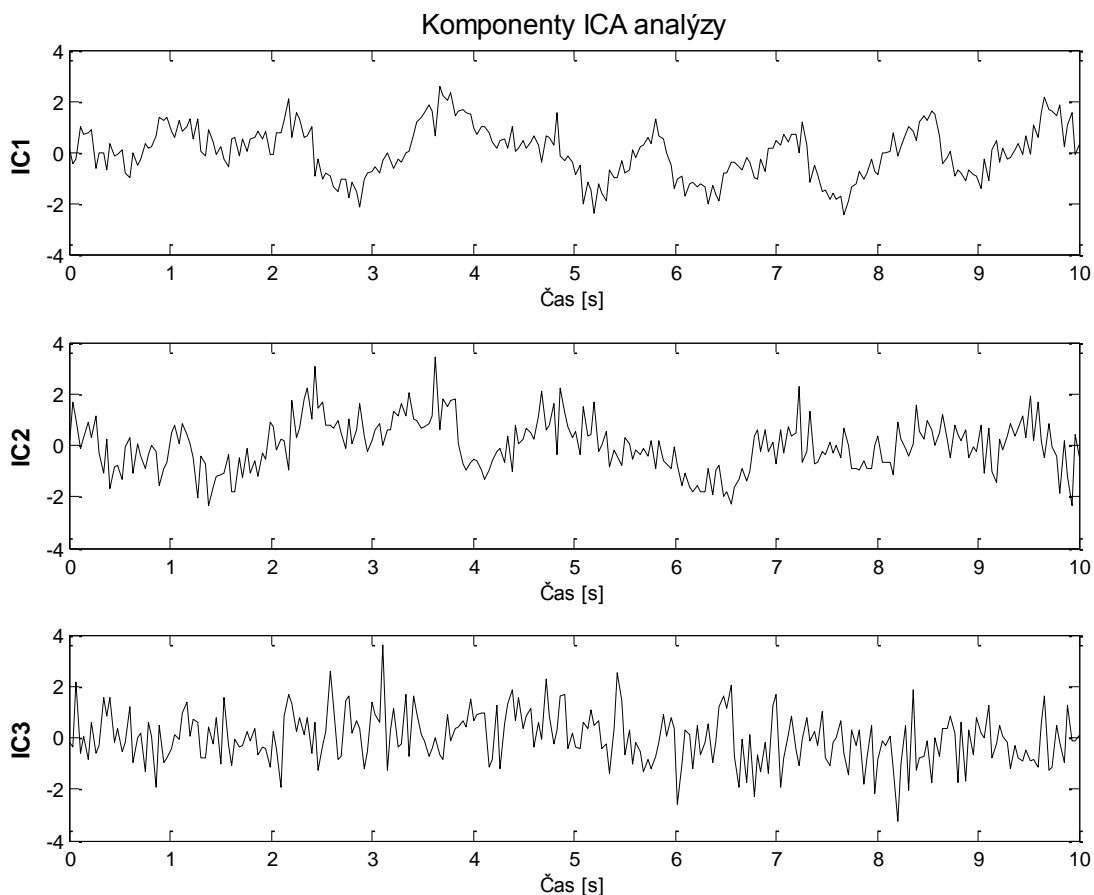
Hlavička algoritmu JADE má tvar:

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

Vstupní parametr X představuje matici vstupních dat. V našem případě představují řádky matice hodnoty normalizovaných signálů z kanálů RGB. Druhý vstupní parametr m je volitelný a reprezentuje počet zdrojů. Na výstupu funkce získáme matici S o velikosti $3 \times n$ (délka signálu), která obsahuje hledané informace o zdrojových signálech. Vykreslením těchto tří řádků získáme výsledné nezávislé komponenty analýzy. Funkci potom v programu *ICA.m* voláme jako:


```
[~, Out1] = jade ([n_sigr; n_sigg; n_sigb]);
```

kde n_sigr , n_sigg , n_sigb jsou normalizované signály a $Out1$ je výstupní matice tří komponent. Výsledkem ICA analýzy jsou vykreslené komponenty v závislosti na čase. Názorná ukázka je vyobrazena na Obr. 32, který znázorňuje ICA analýzu aplikovanou na signály z oblasti ROI obličeje (detekce tepové frekvence).



Obr. 32: Výstup algoritmu JADE

Po vykreslení komponent v závislosti na čase lze v ideálním případě podle vzhledu signálu jednoznačně určit, která komponenta nese informace potřebné pro detekovaný parametr. Takový případ je ukázán na Obr. 33. Vlevo jsou vykresleny komponenty při detekci tepové frekvence, vpravo pro dechovou frekvenci.

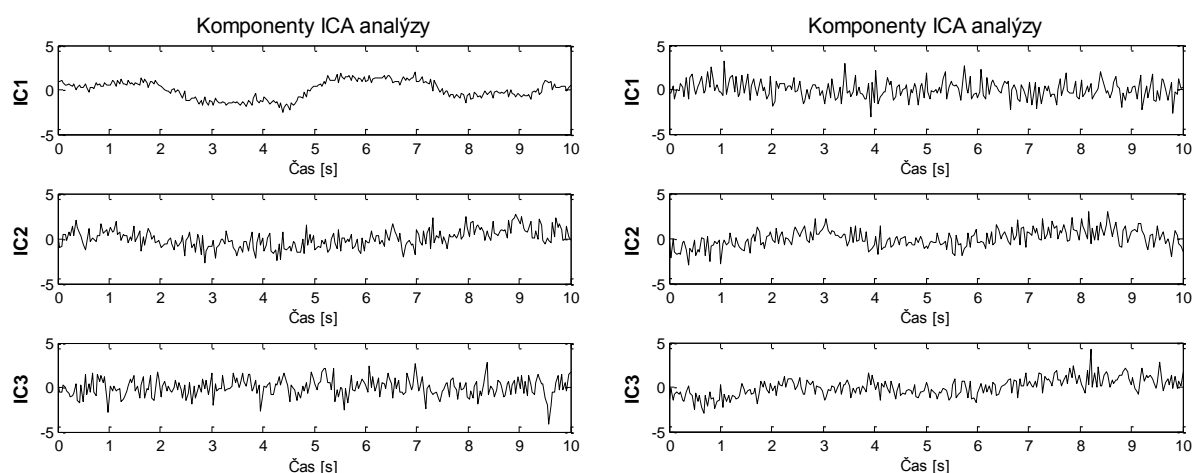


Obr. 33: Ukázka rozkladu signálu na komponenty pomocí ICA

V případě tepové frekvence je zvolena druhá komponenta IC2. Tepová frekvence moduluje amplitudy této komponenty do podoby pulsací. U 8 případů z 10 bylo pro tepovou frekvenci určení komponenty jednoznačné. U zbylých dvou případů se vzhled komponent poměrně podobal a rozhodování bylo provedeno až ze spektra, tedy po aplikování FFT.

U dechové frekvence (Obr. 33 vpravo) je jednoznačnou volbou komponenta IC1, která představuje pulsace nádechů. Při analýze ICA u dechové frekvence nastal pouze jeden případ z deseti, kdy nebylo jednoznačné určit správnou komponentu.

Ukázka příkladu nejednoznačnosti komponent je na následujícím obrázku. Vlevo analýza ICA pro tepovou frekvenci, kdy bylo rozhodováno mezi IC2 a IC3. Vpravo pro dechovou frekvenci měly všechny tři komponenty podobný průběh. Volba komponenty byla provedena až po spektrální analýze prostřednictvím FFT.



Obr. 34: Ukázka nejednoznačnosti komponent

4.4 Spektrální analýza


Algoritmus JADE nám rozložil signál na zdrojové komponenty. Abychom získali výsledný odhad tepové či dechové frekvence, budeme muset signály převést z časové do frekvenční oblasti. K tomu se jevila nejvhodněji rychlá Fourierova transformace (FFT). Odhad výkonového spektra signálu lze také pomocí metody periodogramu, která je dána definičním vztahem [13]:

$$P_{xx}(f) = \frac{1}{M} \sum_{i=1}^M \frac{1}{N} |F_{f_i}(f)|^2. \quad (4.6)$$

Vztah vyjadřuje souborový průměr individuálních výkonových spekter vycházejících z M realizací a délce N vzorků.

V praxi se číslicové zpracování provádí obvykle pomocí FFT s výpočtem kvadrátů absolutních hodnot a výsledek obsahuje pouze vzorky spektra. Periodogram může pracovat i v případě jediné realizace tak, že ji rozdělí na kratší segmenty a pro každý segment je vypočítán periodogram. [13, 24]

V časové oblasti mohou vznikat nespojitosti signálu (nenávaznost period), které mohou mít nepříznivý vliv na výsledné spektrum. Ke korekci těchto nežádoucích jevů slouží různé typy váhovacích oken. Jedním z nich je například Hannovo váhovací okno, jehož tvar v časové oblasti je znázorněn na Obr. 35. Okno bylo zvoleno díky svým vlastnostem a jeho počátku i konci v nulové hodnotě. [25]



Obr. 35: Hannovo okno v časové oblasti [25]

Koeficienty Hannova okna jsou počítány pomocí následující rovnice [25]:


$$w(n) = 0.5 \left(1 - \cos\left(\frac{2\pi n}{N}\right) \right) \quad (4.7)$$

Realizace spektrální analýzy byla provedena dvěma způsoby. Jedním způsobem byla klasická FFT a druhým byla FFT vynásobena Hannovým oknem. V obou případech byla délka signálu vynásobena konstantou 20, což umožnilo vypočítat více spektrálních koeficientů. V prostředí Matlab byla spektrální analýza komponent provedena prostřednictvím příkazu *fft*. Funkce vrací výsledek rychlé Fourierovy transformace ve formě vektoru obsahujícího komplexní hodnoty. Po jeho vykreslení získáme výsledné spektrum, ve kterém byl hledán vrchol, nacházející se v oblasti od 0.8 do 1.5 Hz pro tepovou frekvenci a od 0.23 do 0.33 Hz pro dechovou frekvenci.

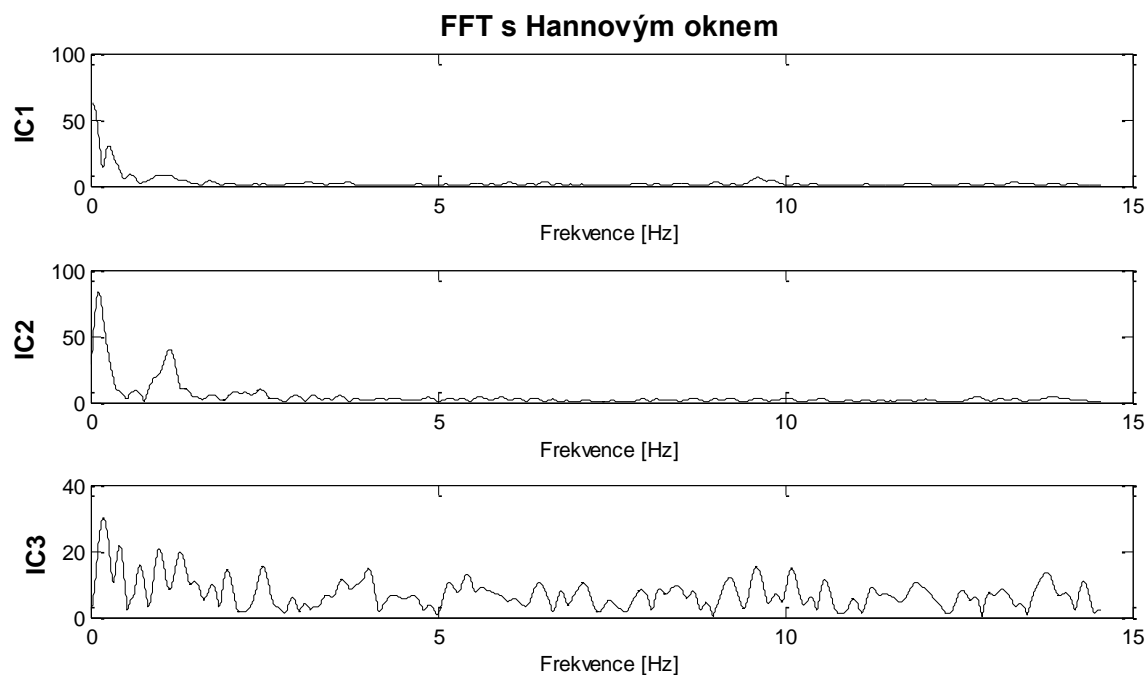
Podle metody popsané v kapitole 2.2 je vhodné aplikovat FFT pouze na jednu zvolenou komponentu, která bude obsahovat nejvyšší hodnotu poměru vrcholů vzhledem k celkové energii signálu. Jinak řečeno, je hledána komponenta, která kopíruje srdeční a dechovou pulsaci a obsahuje užitečné informace o detekovaném parametru. Určit toto kritérium je v některých případech velmi subjektivní a nastalo pár případů, kdy bylo obtížné zvolit ideální komponentu. Z toho důvodu byla pro jistotu vždy provedena FFT na všechny tři komponenty a až z výsledných spekter byla vybrána příslušná komponenta. Ve většině případech však bylo patrné, ve kterém spektru se projevuje výrazný vrchol odpovídající hledané veličině.

4.4.1 Ukázky spektrální analýzy pro tepovou frekvenci

Ukázku výsledných spekter pro jednotlivé komponenty ICA můžeme pozorovat na následujících obrázcích. Vykreslována je vždy polovina spektra. Pro porovnání rozdílů je zde ukázáno, jak vypadá spektrum klasické FFT (Obr. 36) a FFT s váhovacím Hannovým oknem (Obr. 37). V obou případech je zobrazeno spektrum pro všechny tři komponenty. Jedná se o příklad, kdy se jednoznačně projevuje hledaný vrchol u jedné z komponent (IC2).

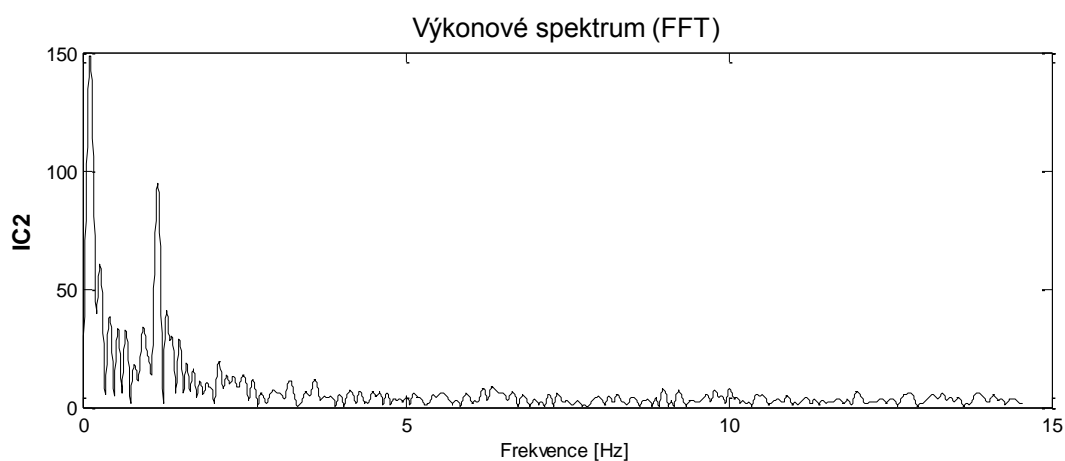


Obr. 36: Výkonové spektrum získané analýzou FFT

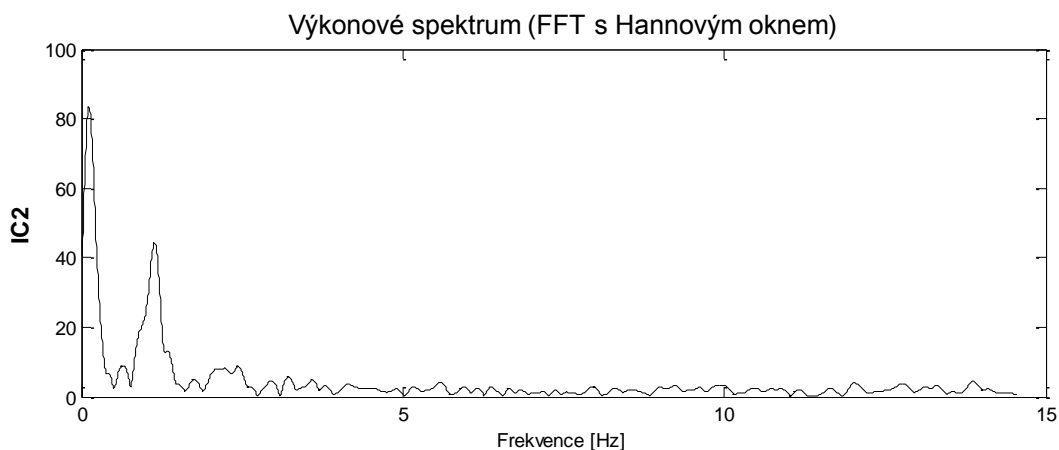


Obr. 37: Výkonové spektrum získané analýzou FFT s Hannovým oknem

Ukázky na obrázcích znázorňují výsledky detekce tepové frekvence. První komponenta (IC1) obsahuje pouze minimální náznak pulsace v oblasti kolem hledané frekvence pro tepovou frekvenci, avšak ne tak patrný a významný, jako u druhé komponenty (IC2). Třetí komponenta (IC3) nenesla hledané informace. IC2 byla proto vybrána pro konečný odhad tepové frekvence. Detail spektra vybrané komponenty znázorňuje Obr. 38 a Obr. 40.



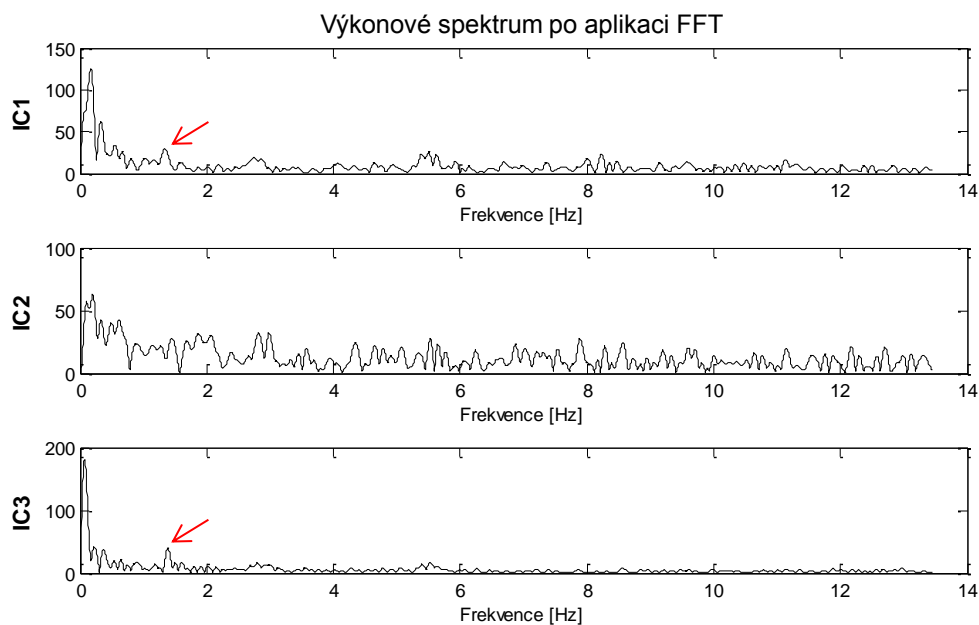
Obr. 38: Detail výkonového spektra komponenty IC2 provedená analýzou FFT



Obr. 39: Detail výkonového spektra komponenty IC2 provedená analýzou FFT s Hannovým oknem

Hodnota vrcholu byla zjišťována pomocí datového kurzoru (Data Cursor). Pro IC2 na Obr. 38 odpovídala hodnota vrcholu 1.15 Hz, na Obr. 39 hodnotě 1.13 Hz. Tento rozdíl je minimální, ale můžeme tvrdit, že váhovací okno zde vykonalo funkci filtrace a vyhlazení signálu, což způsobilo přijatelnější podobu spekter a tím pádem i usnadnilo výběr komponenty. K vyhodnocení výsledků bylo použito obou přístupů a prostřednictvím statistické analýzy byl hledán rozdíl mezi použitými metodami.


Výjimečně se našel se i případ, u kterého nebylo tak zřejmé a jednoznačné, kterou komponentu vyhodnotit za výsledný odhad. Takový výsledek je možné pozorovat na Obr. 40. Spektrum komponent IC1 a IC3 je relativně podobné a vrchol reprezentující hledanou frekvenci má menší očekávanou výšku (znázorněno šipkami). Samozřejmě rozhodující roli ve výběru správné komponenty nesoucí klíčovou a výslednou hodnotu měl vzhled komponent po analýze ICA (viz kapitola 4.3).



Obr. 40: Výkonové spektrum po aplikaci FFT s nejednoznačnou volbou komponenty

4.4.2 Ukázky spektrální analýzy pro dechovou frekvenci

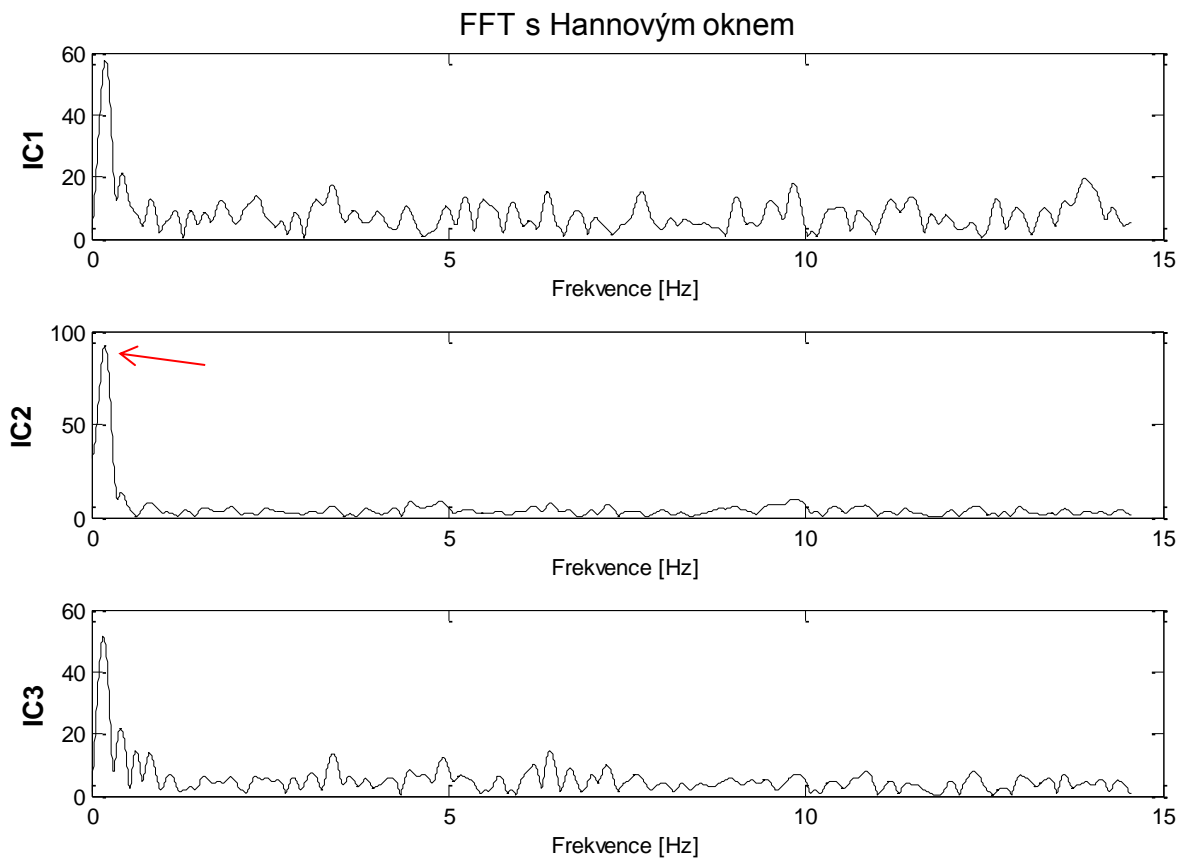
Výkonové spektrum bezkontaktní detekce dechové frekvence měl oproti tepové frekvenci rozdílnou podobu. Jak již bylo zmíněno, výsledná frekvence reprezentující dýchání byla očekávána v úzkém rozmezí 0.23 až 0.33 Hz. Hledaný vrchol, který nesl informace o dechové frekvenci, byl velmi výrazný. Ukázka na Obr. 41



Obr. 41: Výkonové spektrum po aplikaci FFT

Na obrázku jsou vykresleny spektra klasické FFT pro všechny tři komponenty. Všechny tři spektra obsahují výrazný vrchol v očekávané oblasti. Výhodou u detekce dechové frekvence bylo to, že v předchozím kroku, tedy při volbě komponenty ICA, bylo (až na jednu výjimku) jasné a jednoznačné, která z komponent nese informace týkající se hodnoty dechové frekvence. Pozornost tak byla věnována spektru jediné komponenty, ve kterém byla hledána výsledná hodnota. Ze spekter na Obr. 41. byla jednoznačně vybrána komponenta IC2. Červenou šipkou je vyznačen vrchol nesoucí výslednou hodnotu dechové frekvence. Spektrální analýza u detekce dechové frekvence přinášela většinou kvalitní a očekávané výsledky.

Metoda FFT s váhovacím Hannovým oknem přinášela také kvalitní výsledky detekce dechové frekvence. Ukázka spekter FFT s oknem je na Obr. 42. Jedná se o stejné měření jako v předešlém případě u klasické FFT.



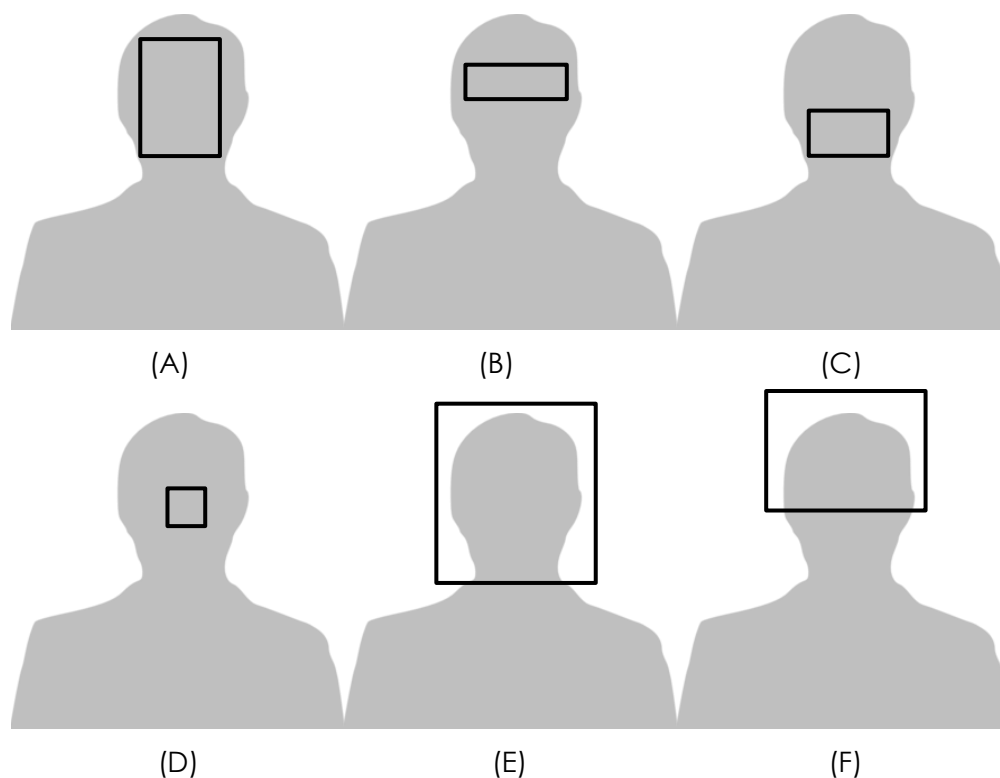
Obr. 42: Výkonové spektrum metody FFT s Hannovým oknem

Hodnoty dechové frekvence se u obou metod jen nepatrně liší. Vrchol ve spektru komponenty IC2 na Obr. 41 s klasickou FFT má hodnotu 0.1851 Hz odpovídající cca 11 dechům za minutu. U analýzy FFT s Hannovým oknem je hodnota vrcholu komponenty IC2 na Obr. 42 rovna 0.1951 Hz, což odpovídá 11.7 dechů za minutu.

4.5 Volba oblasti ROI

Oblast zájmu, která vstupuje do analýzy bezkontaktní detekce, je ve vytvořeném programu volena manuálně. Jak již bylo zmíněno, uživatel je vyzván ke zvolení dvou souřadnicových bodů, které ohraničují vybranou oblast ROI. Při opakovaném měření je nízká pravděpodobnost, že bude vybrána pokaždé stejná oblast, i když se budeme snažit dodržet pravidlo, že při detekci tepové frekvence vybíráme oblast obličeje a při detekci dechové frekvence oblast hrudníku. Z toho důvodu byla vytvořena tato kapitola, která se bude věnovat zkoumání vlivu různých velikostí oblastí ROI při měření.

Ke zkoumání vlivu velikosti a polohy oblastí ROI na výsledné parametry bylo provedeno experimentování na datech naměřených pouze od jednoho zvoleného dobrovolníka. Program byl spuštěn opakovaně a při každém spuštění byly měněny velikosti a polohy ROI oblastí. Byly vybrány ukázky jednotlivých poloh (velikostí) ROI. Na Obr. 43: Variabilita rozměrů a poloh oblastí ROI je šest příkladů s různými velikostmi a polohami ROI oblastí.



Obr. 43: Variabilita rozměrů a poloh oblastí ROI


Následuje popis a výsledky ze situací vyobrazených na Obr. 43. Výběr ROI na příkladu (A) vykazuje ideální vzhled spektra i výslednou hodnotu dechové frekvence. Při výběru ROI kolem oblasti očí (B) a úst (C) byly výsledné hodnoty frekvence stejné jako v případě (A), jediná změna se projevila snížením výšky výsledného vrcholu. S klesající velikostí oblasti ROI tedy klesá výška hledaného vrcholu ve spektru. To potvrdil případ

(D), kde výška vrcholů ve spektru byla značně nižší než v předchozích případech. Nalezený vrchol se zde vyznačoval mírnou odchylkou hodnot frekvence, řádově v jednotkách setin. Překvapivé výsledky přinesly případy (E) a (F), kde bylo předpokládáno, že výsledné hodnoty frekvence budou nepříznivě ovlivněny pozadím. I přesto, že vybraná oblast ROI z menší míry zasahovala do pozadí, stále byla analýza schopna detekovat hledaný parametr. Ve spektru byl tak opět nalezen vrchol (nižší než v případě (A), ale i tak znatelný) s hodnotou frekvence totožnou jako v případě (A). Důležité je dodržet, aby v oblasti ROI bylo více jak 50% tváře monitorované osoby.

Stejné výsledky byly prokázány i při volbě ROI v oblasti hrudníku, která sloužila k detekci dechové frekvence. Bylo dokázáno, že algoritmus je schopen detekovat tepovou (resp. dechovou) frekvenci i pokud budeme měnit velikost ROI či měnit polohu této oblasti.

4.6 Vliv IR záření na měření


K ověření vlivu infračerveného záření na měření byla zkonstruována scéna, ve které byla snímána videokamerou ruka dobrovolníka. Kamera byla vzdálená 30 cm a LED dioda IR záření byla ve vzdálenost pouhých 5 cm od ruky. Rozlišení snímků bylo zvoleno na hodnotu 1024x768. Snímkovací frekvence byla opět nastavena na 30 snímků za sekundu. Jednotlivé scény byly natáčeny pouze po dobu 5 sekund. Opět nebylo zachyceno očekávané množství snímků (150). Navíc při měření bylo manipulováno s nastavením parametrů zesílení a expozice, které významně ovlivňují počet zachycených snímků. Expozice i zesílení mají vliv především na jas snímané scény. Protože zkoumání vlivu IR probíhalo i za sníženého osvětlení, bylo potřeba s těmito parametry experimentovat a dosáhnout co nejideálnější scény. Zvyšování hodnot zesílení však zanášelo do obrazu šum. Snaha byla nalézt takové nastavení, aby byl šum v obraze minimální s ohledem na dostatečný jas obrazu. Vzhled scény je na Obr. 44. Jako oblast zájmu ROI byla volena část označená v obrázku bílým čtvercem.



Obr. 44: Vzhled scény se základním osvětlením a ukázka oblasti ROI

Aby bylo možné sledovat rozdíl mezi měřeními s IR a bez IR, bylo naměřeno několik scén s různými možnostmi osvětlení a nastavení. Jako první byla zachycena scéna s klasickým osvětlením žlutým světlem z lampy (Obr. 44). Do dalších scén potom bylo zakomponováno IR světlo. Jednak byla použita kombinace lampy s IR, dále pak použití samotného IR světla bez okolního osvětlení. Testování vlivu IR záření bylo prováděno pouze na 2 dobrovolnících, kterým byla změřena kontrolní hodnota tepové frekvence.

V analýze získaných videosekvencí byl potom hledán postup, kterým bude možné nalézt důkaz působení IR záření na projev pulsační složky ve spektru. Vycházíme z poznatku spektrální citlivosti videokamery použité v experimentu, která vypovídá o tom, že vlnová délka IR oblasti spektra (850 nm) by se měla dostat do všech tří RGB složek (viz Obr. 14, kapitola 3).



Obr. 45: Scény s IR osvětlením

Snímky na Obr. 45 znázorňují další dva druhy scén. Vlevo byla zkonstruována scéna s použitím kombinace mezi světlem z lampy a IR diody. Vpravo na snímanou scénu působí samostatně IR záření.

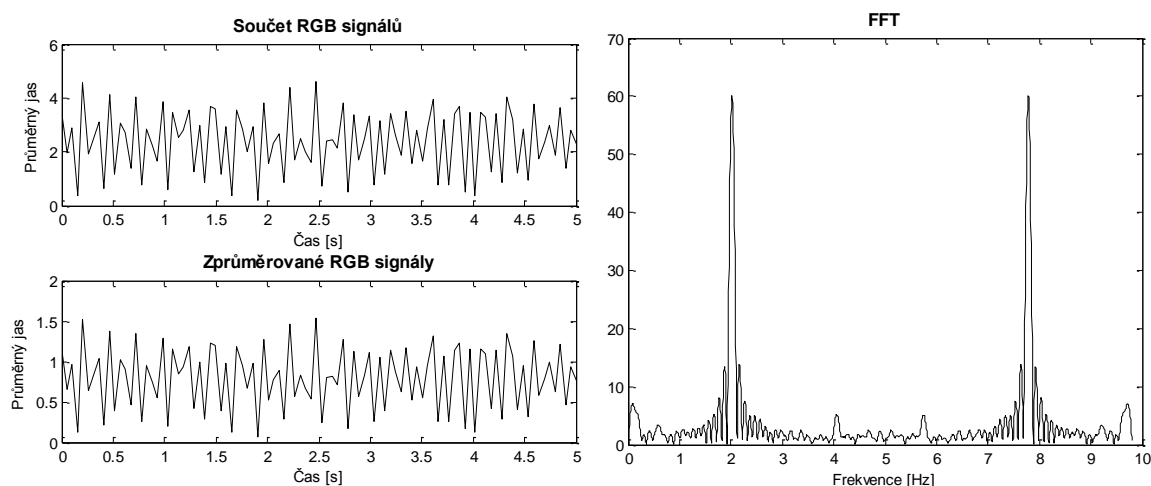
Vybraná měření jsou očíslována a vypsána do Tab. 1. Očekávaný počet zachycených snímků byl 150. Tento počet nebyl zachycen u žádného z měření. Měření s pořadovým číslem 4, 5 a 6 jsou v tabulce znázorněny pouze pro důkaz, že parametry zesílení a expozice významně ovlivňují počet zachycených snímků. Vzhledem k nízkému počtu zachycených snímků nebyly tyto data použita k další analýze. Nízký počet sekvencí zapříčinilo nastavení hodnoty zesílení v závislosti na nastavení expozice. Testování probíhalo pouze na zbylých sedmi měřeních.

Tab. 1: Parametry vybraných měření


č.	druh osvětlení	zesílení [dB]	expozice [s]	počet zachycených snímků
1	IR	14,44	0,0333	107
2	lampa	9,2	0,0476	98
3	lampa + IR	9,2	0,0476	90
4	IR	8,3	0,1250	32
5	IR	5,59	0,2500	19
6	IR	10,1	0,0769	59
7	IR	13,7	0,0400	97
8	IR	14,07	0,0333	127
9	IR	14,62	0,0303	124
10	lampa	10,83	0,0208	115

Postup zpracování a analýzy videosekvencí je totožný jako postup popsáný v předchozích podkapitolách (Obr. 27). Po rozkladu na složky RGB byla aplikována metoda ICA a následně FFT. Z neznámé příčiny výsledky neposkytují očekávaný vzhled spektra, ze kterého bychom mohli získat hodnotu tepové frekvence.

Bylo experimentováno se signály z RGB složek. Signály byly zprůměrovány. Součet všech tří vektorů reprezentujících RGB složky byl vydělen počtem vektorů, tedy třemi. Získali jsme pulsační signál jasových hodnot z ROI oblasti v čase, na který byla aplikována FFT. Hledány byly vlivy IR záření na spektrum. Příklady spekter pro různé druhy osvětlení jsou na následujících obrázcích.



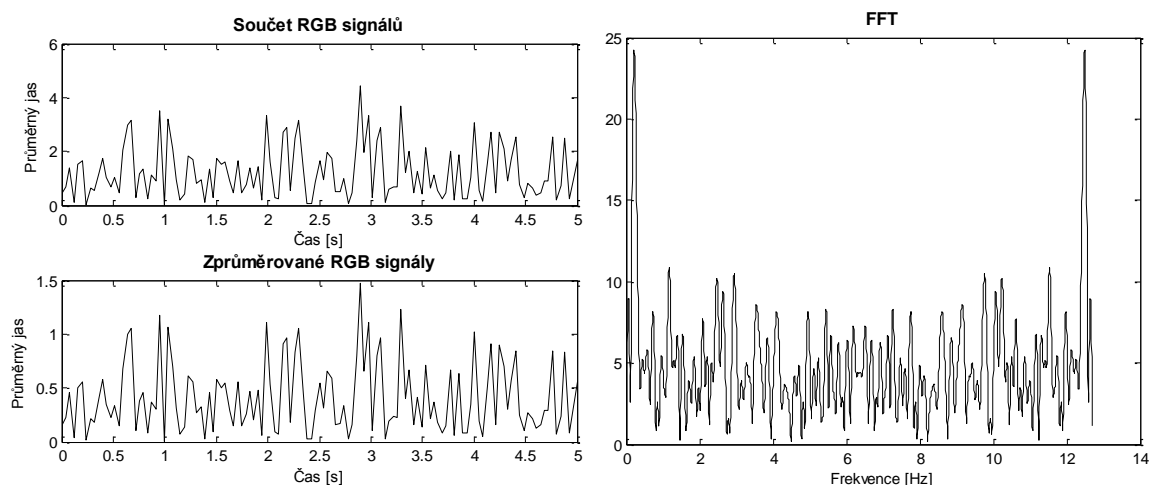
Obr. 46: Příklad při osvětlení viditelným světlem (v podobě lampy)



Obr. 47: Příklad při osvětlení v podobě kombinace lampa + IR dioda


Jak průběhy pulsačního signálu v čase, tak výkonového spektra se u obou příkladů na Obr. 46 a Obr. 47 velmi podobají. Dokazuje to fakt, že viditelné světlo v podobě žárovky má zde dominantní vliv. Vliv IR spektra se na Obr. 47 význačně neprojevovalo. Tepová frekvence měřené osoby byla 76 tepů za minutu. Hodnota vrcholu se v obou spektrech pohybuje kolem 2 Hz, což by odpovídalo tepové frekvenci 120 tepů za minutu. Pro bezkontaktní detekci tepové frekvence tyto spektra také nelze použít.

Chceme-li sledovat vliv IR složek, musíme ostatní viditelné světlo v experimentu vynechat. Důkazem toho je signál i spektrum na Obr. 48. Můžeme si povšimnout, že i zprůměrované RGB signály nenesou podobu jednotvárné pulsace, ale obsahují náznak chaotického pulsování. Spektrum je zde zcela odlišné než v předchozích případech.



Obr. 48: Příklad při osvětlení v podobě samostatného IR záření

Hemoglobin obsažený v krvi obsahuje různá absorpční spektra ve viditelné, červené a infračervené oblasti. Závisí na tom, zda je krev okysličená či odkysličená. Absorpce oxyhemoglobinu klesá se zvyšující se vlnovou délkou a v blízkém IR spektru (800 nm) je tedy absorpce nižší než ve viditelné oblasti spektra. Deoxyhemoglobin má průběh absorpční křivky odlišný. Absorpční spektra obou typů hemoglobinů jsou vykresleny na Obr. 49. [29]



Obr. 49: Absorpční spektrum hemoglobinu

Ze scén zkonstruovaných pro bezkontaktní detekci tepové frekvence z oblasti paže měřené osoby se nepodařilo získat požadované výsledky. Spektrum neobsahovalo vrchol reprezentující hledaný parametr. Byl pouze prokázán vliv IR záření na pulsace v signálu i na výsledné výkonové spektrum. Působí-li na měřenou scénu samostatné IR světlo, ve výsledném výkonovém spektru se projevují pulsace rozdílného charakteru a velikosti než u spekter získaných z měření s viditelným okolním světlem. Můžeme tedy jen spekulovat, zda by IR osvětlení nějakým způsobem ovlivnilo výsledky bezkontaktní detekce tepové frekvence či nikoliv.

Význam vlastností IR spektrálních složek nachází uplatnění především v bezkontaktní detekci parametru SpO_2 . Metody bezkontaktní detekce parametru nasycení krve kyslíkem využívají v experimentech diody emitující světlo v oblasti blízkého infračerveného spektra (NIR) v interakci s oblastí červeného (R) spektra. Tyto přístupy tak imitují konstrukci a principy pulsního oxymetru. Bylo dokázáno, že kamera je schopna vzdáleně sledovat perfúzi a saturaci kyslíku z tkáně. [24, 29]

5 Výsledky experimentu a diskuze

Monitorování bylo provedeno na 10 dobrovolnících ve věku 20 až 30 let. Z nichž 7 osob bylo mužského a 3 osoby ženského pohlaví. U žádného z dobrovolníků nebyly zjištěny zdravotní potíže týkající se onemocnění srdce či jiné predispozice, které by mohly ovlivnit měření. Veškeré měření bylo prováděno v klidovém stavu monitorované osoby. V Tab. 2 jsou informace týkající se dobrovolníků, kteří se zúčastnili experimentu. V posledním sloupci jsou zmíněny dopočítané hodnoty snímkovací frekvence v jednotkách fps, podle počtu zaznamenaných snímků. Protože se tento parametr u každého měření lišil, bylo nutné hodnotu snímkovací frekvence nastavovat před každým spuštěním programu.

Tab. 2: Informace o dobrovolnících, hodnoty snímkovacích frekvencí

Č.	Pohlaví	Věk	Snímkovací frekvence [fps]
1	M	25	29,4
2	Ž	23	28,4
3	M	24	27,7
4	M	24	27,2
5	M	23	26,8
6	M	23	29,1
7	Ž	24	29,7
8	M	26	26,9
9	Ž	20	27,3
10	M	30	27,8

5.1 Výsledky detekce tepová frekvence


Prvním parametrem, který byl monitorován, je tepová frekvence. Jelikož byla měřená klidová tepová frekvence, očekávané hodnoty tepové frekvence se pohybovaly v rozmezí od 50 do 90 tepů za minutu, což odpovídá frekvencím cca 0.8 až 1.5 Hz.

Interpretace dat pro tepovou frekvenci je znázorněna v Tab. 3. Dobrovolníkům byla přiřazena čísla od 1 do 10. Druhý a třetí sloupec vyznačuje data, která byla získána z kontrolního měření EKG pomocí systému BIOPAC a detektoru QRS komplexů. Nejprve tedy detekovaný počet stahů za 10 sekund. Ze zjištěných poloh R kmitů následují vypočtené hodnoty odpovídající tepovým frekvencím za minutu. Čtvrtý až sedmý sloupec odpovídá hodnotám z bezkontaktní detekce tepu. Jsou zde porovnávány dvě metody. První s použitím spektrální analýzy pomocí klassické FFT a druhá pomocí FFT s Hannovým oknem (FFTh). Nejprve je vždy hodnota frekvence odpovídající hledanému vrcholu ve výkonovém spektru a vedle dopočítaná hodnota na počet tepů za minutu (frekvence vynásobená hodnotou 60).


Tab. 3: Výsledné hodnoty detekce tepové frekvence

TEPOVÁ FREKVENCE						
Č.	EKG [p. stahů]	EKG [tep/min]	ICA (FFT) [Hz]	ICA (FFT) [tep/min]	ICA (FFTh) [Hz]	ICA (FFTh) [tep/min]
1	11	65,3	1,0400	62,4	1,0150	60,9
2	13	81,2	1,2900	77,4	1,2650	75,9
3	10	60,1	1,0800	64,8	1,0800	64,8
4	14	88,4	1,3450	80,7	1,3350	80,1
5	9	54,8	0,8352	50,1	0,8402	50,4
6	12	70,9	1,1700	70,2	1,1450	68,7
7	11	66,4	1,1150	66,9	1,1100	66,6
8	16	96,6	1,5150	90,9	1,5050	90,3
9	11	64,5	1,0000	60,0	0,9702	58,2
10	12	71,7	1,1700	70,2	1,1600	69,6

Z hlediska kontroly kvality a přesnosti měření nás tedy zajímají modře vyznačené hodnoty – tepová frekvence změřená systémem BIOPAC (EKG) oproti hodnotám získaným bezkontaktní detekcí (ICA). Pro přehlednější srovnání metod jsou data vykreslena do grafu. Grafické znázornění vzájemné závislosti výsledků dvou metod umožňuje korelační diagram. Každý bod v grafu reprezentuje dvojici výsledků. Na ose y jsou hodnoty referenčního měření pomocí EKG, na ose x potom výsledky z metody ICA. Body v grafu jsou proloženy lineární regresní přímkou.



Graf 1: Korelační graf závislosti hodnot tepové frekvence z EKG na hodnotách získaných metodou ICA (klasická metoda FFT)



Graf 2: Korelační graf závislosti hodnot tepové frekvence z EKG na hodnotách získaných metodou ICA (FFT s Hannovým oknem)

Oba korelační diagramy vyjadřují pozitivní korelaci mezi veličinami. Znamená to, že naměřené hodnoty jsou dostatečně asociované a nenacházíme žádné odlehlé hodnoty (extrémy). Vyjádření linearitu vzájemného vztahu dvou korelovaných veličin lze také pomocí Pearsonova korelačního koeficientu r , který lze vypočítat pomocí vztahu [27]:

$$r = \frac{\sum[(x_i - \bar{x})(y_i - \bar{y})]}{\sqrt{\sum(x_i - \bar{x})^2 \cdot \sum(y_i - \bar{y})^2}}, \quad (5.1)$$

kde x_i a y_i jsou dvojice veličin, které srovnáváme, \bar{x} a \bar{y} jsou aritmetické průměry těchto veličin. Koeficient může nabývat hodnot $\langle -1; 1 \rangle$. Platí, že čím větší bude absolutní hodnota r , tím více jsou veličiny korelovány. Rovná-li se koeficient nule, tak spolu proměnné nekorelují. Hodnota $r = 1$ značí přímou (pozitivní) lineární závislost veličin a v grafech ji vyznačuje regresní přímka. Korelační koeficientu pro metodu FFT je roven 0.9612, pro metodu FFT s Hannovým oknem 0.9661. [27]

U každého měření je dále důležité stanovit chyby. Absolutní chyba měření (δ) udává rozdíl mezi skutečnou (X) a naměřenou (x) hodnotou. V našem případě je skutečnou hodnotou výsledek měření tepové frekvence z EKG a naměřená hodnota je bezkontaktní odhad tepu (dechu) pomocí ICA.

$$\delta = |X - x| \quad (5.2)$$

Kvalitu měření je možné vyhodnotit také pomocí relativní chyby měření. Relativní chyba (ζ) je definována jako podíl absolutní chyby měření a skutečné naměřené hodnoty. Jedná se o procentuální vyjádření absolutní chyby měření. Hodnota relativní chyby závisí na velikosti naměřené veličiny.

$$\zeta = \frac{\delta}{X} \cdot 100 \quad (5.3)$$

V Tab. 2 jsou znázorněny chyby měření tepové frekvence. δ_1 reprezentuje absolutní chybu měření mezi tepovou frekvencí detekovanou z EKG a detekcí bezkontaktní metodou ICA s klasickou FFT. δ_2 znázorňuje totéž, s tou změnou, že porovnává výsledky s detekcí metodou ICA, která využívá FFT s Hannovým oknem.

Tab. 4: Chyby měření tepové frekvence

č.	absolutní chyba		relativní chyba	
	δ_1 [tep/min]	δ_2 [tep/min]	ζ_1 [%]	ζ_2 [%]
1	2,9381	4,4381	4,4968	6,7925
2	3,8091	5,3091	4,6905	6,5376
3	4,6597	4,6597	7,7480	7,7480
4	7,7053	8,3053	8,7159	9,3946
5	4,7326	4,4326	8,6291	8,0821
6	0,7449	2,2449	1,0500	3,1643
7	0,4548	0,1548	0,6845	0,2330
8	5,7391	6,3391	5,9387	6,5596
9	4,4815	6,2695	6,9501	9,7229
10	1,4690	2,0690	2,0497	2,8869
průměr	3,6734	4,4222	5,0953	6,1121

Pro vyhodnocení, která z metod přináší celkově menší rozdíl výsledných hodnot oproti referenční (skutečné) naměřené hodnotě, byl proveden aritmetický průměr jednotlivých chyb. Z výsledků můžeme konstatovat, že průměrná hodnota absolutních odchylek byla menší u metody využívající klasickou FFT oproti FFT s Hannovým oknem. Průměrná relativní chyba byla vypočítána u klasické FFT na 5.1 % a u FFT s Hannovým oknem na 6.1 %. FFT s Hannovým oknem kompenzuje chyby tím, že přináší kvalitnější vzhled výkonového spektra. Ovšem pro bezkontaktní detekci a požadavek co nejlepších (nejpřesnějších) výsledků měření je zde vhodnější zvolit klasickou metodu FFT bez Hannova okna.

Z hlediska porovnání úspěšnosti bezkontaktní detekce tepové frekvence můžeme vyhodnotit, že většina výsledků se relativně přibližuje referenčním hodnotám měření. Až na pár výjimek se odchylky významně nevzdalují od srovnávaných hodnot. Největší

odchylka měření u metody FFT má velikost 7.7 tepů, u metody FFT s Hannovým oknem má maximální chyba velikost 8.3 tepů. Obě maxima se vyskytly u téhož dobrovolníka (měření). V publikacích, které studují bezkontaktní detekce fyziologických parametrů stejnou metodou, se průměrná odchylka tepové frekvence pohybuje kolem 3.1 tepů za minutu. Naše průměrné odchylky 3.7 a 4.4 tepů za minutu považují za úspěšné. [2]

5.2 Výsledky detekce dechové frekvence

Hodnoty klidové dechové frekvence byly očekávány v rozmezí od 14 do 20 dechů za minutu, což odpovídá úzkému rozsahu frekvencí cca 0.23 až 0.33 Hz. Některé zdroje uvádějí, že fyziologický rozsah respirační frekvence se pohybuje v rozmezí už od 12 až do 24 dechů za minutu. [11]


Na tomto místě bych také ráda zmínila okolnosti týkající se manuálního počítání dechů ze signálu získaného referenčním měřením. Tento signál má podobu několika vln, jehož počet amplitud odpovídá dýchacím pohybům. Máme časový úsek 10 sekund, ve kterém se jedinec nadechne například dvakrát, tudíž signál obsahuje 2 vlny (vrcholy). V některých případech se však počátek či konec vlny nemusí nacházet právě v daném úseku (v úseku se nevyskytuje celá vlna). Právě proto bylo subjektivní odhadnout přesný počet nádechů v tomto úseku, a tím pádem i přesné dopočítání počtu dechů za minutu. Nutno podotknout, že takový způsob odhadování může způsobit nepatrné odchylky.

Výsledky monitorování dechové frekvence je možné pozorovat v Tab. 2. Opět jsou zde porovnávány data z BIOPACu a bezkontaktního měření prostřednictvím ICA a odhadu spektra metodou FFT.


Tab. 5: Výsledné hodnoty detekce dechové frekvence

DECHOVÁ FREKVENCE						
Č.	Pás [p.dechů]	Pás [dech/min]	ICA (FFT) [Hz]	ICA (FFT) [dech/min]	ICA (FFTh) [Hz]	ICA (FFTh) [dech/min]
1	2,0	12,00	0,197	11,83	0,202	12,13
2	2,0	12,00	0,181	10,84	0,186	11,13
3	2,0	12,00	0,220	13,17	0,220	13,17
4	2,0	12,00	0,201	12,06	0,196	11,78
5	2,5	15,00	0,203	12,16	0,198	11,89
6	2,0	12,00	0,200	12,01	0,195	11,71
7	2,0	12,00	0,235	14,09	0,255	15,31
8	2,0	12,00	0,185	11,09	0,208	12,49
9	1,5	9,00	0,170	10,17	0,160	9,57
10	3,0	18,00	0,292	17,49	0,282	16,91

Chyba! Nenalezen zdroj odkazů. a Chyba! Nenalezen zdroj odkazů. znázorňují korelační diagramy pro výsledné hodnoty dechové frekvence.



Graf 3: Korelační graf závislosti hodnot dechové frekvence z respiračního pásu na hodnotách získaných metodou ICA (klasická metoda FFT)



Graf 4: Korelační graf závislosti hodnot dechové frekvence z respiračního pásu na hodnotách získaných metodou ICA (metoda FFT s Hannovým oknem)

Korelační grafy vykreslující výsledky detekce dechové frekvence se vyznačují také pozitivní korelací. Na první pohled je však patrné, že se kolem korelační přímky nacházejí odlehle hodnot. To potvrzuje i výpočet koeficientů, který vyšel pro metodu FFT 0.8109, pro metodu FFT s Hannovým oknem 0.7315.

Pro úplnost následuje opět tabulka s absolutními a relativními chybami měření.

Tab. 6: Chyby měření dechové frekvence

č.	absolutní chyba		relativní chyba	
	δ_1 [dech/min]	δ_2 [dech/min]	ζ_1 [%]	ζ_2 [%]
1	0,17	0,13	1,45	1,05
2	1,16	0,87	9,70	7,25
3	1,17	1,17	9,75	9,75
4	0,06	0,22	0,50	1,80
5	2,84	3,11	18,92	20,76
6	0,01	0,29	0,05	2,45
7	2,09	3,31	17,40	27,60
8	0,91	0,49	7,55	4,05
9	1,17	0,57	13,00	6,33
10	0,51	1,09	2,83	6,03
průměr	1,008	1,124	8,115	8,707

Tab. 2 ukazuje chyby při měření tepové frekvence. Absolutní chyba mezi referenčním měření tepové frekvence a bezkontaktním měřením tepu metodou ICA s klasickou FFT - δ_1 , a metodou FFT s Hannovým oknem - δ_2 . A relativní chyba taktéž pro obě metody (ζ_1 pro klasickou FFT, ζ_2 pro FFT s Hannovým oknem).

Průměr relativní odchylky byl vypočítán u FFT na 8.1 % a u FFT s Hannovým oknem na 8.7 %. V obou případech je vyšší než u měření tepové frekvence. Průměrná hodnota absolutních chyb detekce dechové frekvence je 1 dech za minutu u klasické FFT a 1.1 dech za minutu u FFT s Hannovým oknem. Opět přesnější měření u klasické metody FFT. Maximální odchylka měření u metody FFT má velikost 2.8 dechů, u metody FFT s Hannovým oknem má nejvyšší chyba velikost 3.3 tepů. Hodnoty bezkontaktní detekce dechu se velmi přibližují hodnotám referenčního měření. Publikace, které se zabývají stejnou problematikou, uvádějí ve výsledcích průměrnou odchylku na 0.09 dechů za minutu. [2]

5.3 Statistické vyhodnocení výsledků

Nyní jsme obdrželi data, které je vhodné statisticky vyhodnotit. Základním prostředkem statistiky je testování hypotéz, které spočívá ve zkoumání vlivu jedné veličiny na druhé. Testujeme pomocí pokládání hypotéz, které s danou pravděpodobností buď potvrdíme či zamítneme. Nulová hypotéza (H_0) představuje jev náhody neboli žádný rozdíl mezi testovanými soubory dat. H_0 je zamítnuta, pokud bude nalezen vliv zkoumaných veličin (hodnoty se budou lišit). V opačném případě není vliv veličin nalezen nebo není dostatečně silný, aby se projevil v daném testování. Alternativní hypotéza (H_1) předpokládá vliv jevů nenáhodného charakteru (existence difference) a značí přítomnost

závislosti mezi veličinami. Alternativní hypotéza je opakem nulové hypotézy. Na základě testování hypotéz se určuje tzv. testovací kritérium, označováno jako statistika t . Statistické testy umožňují stanovit s jakou pravděpodobností je daný jev náhodný či nikoliv. [27]

Při testování statistických hypotéz se mohou vyskytovat chyby dvojího druhu. Chyba I. druhu je způsobena chybným zamítnutím hypotézy H_0 , i když tato hypotéza platí. Chyba I. druhu je definována jako hladina významnosti testu (α). Chybu II. druhu způsobuje chybné potvrzení hypotézy H_0 , přičemž H_0 neplatí. Chyba II. druhu se označuje jako síla testu (β). Vždy se snažíme postupovat tak, aby pravděpodobnost obou chyb byla co nejmenší a zanedbatelná. Chyby jsou na sobě závislé tak, že čím vyšší bude α , tím menší bude β , a naopak. Neexistuje jednotné řešení, které by zajistilo optimální nastavení obou chyb. Zpravidla se volí takový přístup, že na začátku testování je zvolena hladina významnosti testu na velmi nízkou hodnotu (nejčastěji na hodnotu 0.05). [27]

Statistické testy se dělí z hlediska různých kritérií. Prvním z dělení je na parametrické a neparametrické. Parametrické testy berou v úvahu informace o rozložení vstupních dat, neparametrické testy nikoliv (nelze předpokládat normální rozdělení). Další členění testů je z hlediska závislosti používaných dat. U párových testů existuje závislost mezi srovnávanými skupinami a u nepárových testů jsou srovnávaná data na sobě zcela nezávislá. Poslední dělení spočívá v počtu srovnávaných dat. Jednovýběrové testy srovnávají jeden vzorek s referenční hodnotou, dvouvýběrové porovnávají navzájem dva soubory dat (vzorky). [27]

Naměřená data byla zaznamenána do tabulek a zpracovávána v softwaru STATISTICA 12. Prostředí programu poskytuje spoustu možností pro analýzu a správu dat, jejich vizualizaci a umožňuje využití široké škály statistických testů.

Před začátkem statistické analýzy dat je nutné si uvědomit, jaké data máme k dispozici a podle toho se rozhodnout, jaký test bude nejvhodnější. Naše naměřená data jsou párová, to znamená, že mezi nimi existuje nějaká vazba. Máme totiž u každého měření stejný počet osob, kteří byli podmaněni stejným podmínkám.

Volba mezi parametrickým či neparametrickým testem spočívá v ověření normality dat. Bylo tedy potřeba zjistit, zda existuje rozdíl mezi zpracovávaným a normálním rozložením dat. Toho je docíleno prostřednictvím ověření nulové hypotézy, na němž jsou založeny testy normality. Normalitu dat lze ověřovat několika přístupy, respektive testy. Pro naše data se jevil nejvhodnější Shapirův-Wilkův test normality, protože je určený pro malý počet opakování (např. 10 pacientů, 10 měření). Data by neměla obsahovat významné odchylky od normalit. Proto byly před použitím testu zkontrolovány tvary histogramů pro jednotlivé naměřené parametry. Normalitu můžeme potvrdit, podobá-li se rozložení histogramu Gaussově křivce a nejsou-li přítomny žádné odlehlé hodnoty. [27]

Testujeme nyní hypotézu, pochází-li náhodný výběr z normálního rozložení. Shapirův-Wilkův test normality má testovou statistiku W , pomocí které dokážeme stanovit shodu či neshodu rozložení. Nebudou-li se rozložení shodovat (neplatí normalita dat), potom na předem dané hladině významnosti zamítneme nulovou hypotézu. Shapirův-Wilkův test není výpočetně náročný, avšak využijeme zde možnosti softwaru STATISTICA, který zprostředkovává výpočet parametru W . Nulovou hypotézu zamítneme tehdy, je-li hodnota W nižší než předem stanovená prahová hodnota uváděná ve statistických tabulkách. [27]

Test normality byl proveden na referenčních datech z EKG a na datech získaných analýzou ICA. Výsledky testu pro hodnoty měření tepové frekvence nalezneme v Tab. 6 a pro dechovou frekvenci Tab. 7.

Tab. 7: Shapiro-Wilkův test pro tepovou frekvenci


Proměnná	Testy Normality		
	N	W	p
EKG [tep/min]	10	0.935487	0.503974
ICA [tep/min] FFT_h	10	0.983258	0.980201
ICA [tep/min] FFT	10	0.982443	0.976890

Tab. 8: Shapiro-Wilkův test pro dechovou frekvenci

Proměnná	Testy Normality		
	N	W	p
Pás [dech/min]	10	0.848961	0.056458
ICA [dech/min]	10	0.903142	0.237124

Kritická hodnota Shapiro-Wilkova testu pro $N = 10$ na hladině významnosti $\alpha = 0.05$ byla podle statistických tabulek 0.842. Tím pádem pro všechny parametry nezamítneme nulovou hypotézu na hladině významnosti 0.05. Třetím parametrem v tabulce je *p-hodnota*, která také vypovídá o nezamítnutí nulové hypotézy, protože $p > 0.05$. [27, 28]

Výstupem Shapiro-Wilkova testu může být také tzv. Q-Q graf (kvantil-kvantilový). Normální rozdělení platí, pokud všechny body Q-Q grafu budou ležet v blízkosti přímky. Příklad kvantil-kvantilového grafu vytvořeného v STATISTICE je na Obr. 50.



Obr. 50: Příklad kvantil-kvantilového grafu

Máme ověřenou normalitu dat a budeme tedy vybírat statistický test z kategorie parametrických testů. Parametrické testy se při splnění podmínek (především normální rozdělení) vyznačují vysokou silou testování. Dokážou odhalit i takové rozdíly, které neparametrické testy nezvládnou.

Nejčastěji používaným parametrickým testem je Studentův t-test. Princip spočívá v ověřování rozdílu dvou středních hodnot μ . Obvykle se jedná o srovnávání hodnot mezi testovanou a kontrolní skupinou dat. Podle počtu výběrů vybíráme mezi jednovýběrovým a dvouvýběrovým t-testem. Jednovýběrový test srovnává soubor dat s referenční hodnotou (jediným číslem), což by v našem případě nemělo ten správný význam. Jednoznačnou volbou pro náš experiment bude dvouvýběrový t-test. Ten umožňuje porovnávat dva soubory naměřených dat opakovaně na jedné skupině jedinců. [27]

Zvolený Studentův dvouvýběrový párový t-test budeme testovat na hladině významnosti $\alpha = 0.05$. Před testováním je nutné stanovit nulovou (H_0) a alternativní (H_1) hypotézu, které pro náš experiment zní:

H_0 – Rozdíl mezi referenčními hodnotami a hodnotami naměřené pomocí bezkontaktní detekce je *nulový*.

H_1 – Rozdíl mezi referenčními hodnotami a hodnotami naměřené pomocí z bezkontaktní detekce je *nenulový*.

Na začátek testování je vhodné vypsát vlastnosti a charakteristiky analyzovaných dat. K tomu slouží popisná statistika, která je znázorněna v Tab. 9 pro měření tepové frekvence a v Tab. 10 pro měření dechové frekvence. Charakteristiky přehledně sumarizují jednotlivé statistické ukazatele (veličiny). [27]

Tab. 9: Popisná statistika měření tepové frekvence

Proměnná	Popisná Statistika					
	N	Průměr	Minimum	Maximum	Rozptyl	Sm. Odch.
EKG [tep/min]	10	72.01171	54.84460	96.63910	169.8859	13.03403
ICA [tep/min] FFTh	10	68.55240	50.41200	90.30000	130.4290	11.42055
ICA [tep/min] FFT	10	69.36120	50.11200	90.90000	132.4447	11.50846

Tab. 10: Popisná statistika měření dechové frekvence

Proměnná	Popisná Statistika					
	N	Průměr	Minimum	Maximum	Rozptyl	Sm. Odch.
Pás [dech/min]	10	12.49020	10.17000	17.49000	4.338952	2.083015
ICA [dech/min]	10	12.60840	9.57000	16.91400	4.427122	2.104073

Popisná statistika poskytuje přehled o velikostech, průměru, rozptylu a směrovací odchylky našich dat. Některé z charakteristik popisné statistiky jsou využity ve výpočtech parametrů t-testu. Nyní budou popsány a definovány jednotlivé parametry důležité pro aplikaci Studentova t-testu. Základem je testovací kritérium t , jež je definováno dle vztahu [27]:

$$t = \frac{|\bar{x}|}{\sqrt{\frac{s^2}{N}}}, \quad (5.4)$$

kde \bar{x} značí aritmetický průměr, s^2 je rozptyl a N je počet naměřených hodnot v jednom souboru dat. Testovací kritérium je porovnáno s tabulkovou hodnotou t_t , kde poté mohou nastat dva případy:

$t \leq t_t$ – znamená statisticky *nevýznamný* rozdíl středních hodnot při $\alpha = 0.05$

$t > t_t$ – znamená statisticky *významný* rozdíl středních hodnot při $\alpha = 0.05$

Dalším důležitým parametrem Studentova t-testu je počet stupňů volnosti ν , který lze jednoduše vypočítat tak, že od počtu naměřených hodnot N odečteme konstantu 1. Zde je tedy počet stupňů volnosti roven číslu 9. Opět zde využijeme výsledek p-hodnoty, kterou budeme porovnávat s předem zvolenou hladinou významnosti 0.05. Při výsledku $p < \alpha$ bude zamítnuta nulová hypotéza.

Tab. 11: Studentův t-test pro tepovou frekvenci s FFTh

Studentův párový t-test								
	průměr	sm. odch.	N	rozdíl	sm. odch. rozdílu	t	v	p
EKG [tep/min]	72.01171	13.03403						
ICA [tep/min] FFTh	68.55240	11.42055	10	3.459310	3.762223	2.907669	9	0.017377

Tab. 12: Studentův t-test pro tepovou frekvenci s FFT

Studentův párový t-test								
	průměr	sm. odch.	N	rozdíl	sm. odch. rozdílu	t	v	p
EKG [tep/min]	72.01171	13.03403						
ICA [tep/min] FFT	69.36120	11.50846	10	2.650510	3.532585	2.372667	9	0.041726

Výsledná p -hodnota t -testu u vyhodnocování naměřených hodnot tepové frekvence nám potvrzuje zamítnutí nulové hypotézy na hladině významnosti 0.05. Důvodem toho je fakt, že p je v obou případech menší než α . Tedy potvrzuje, že nastaly statistické změny naměřených dat vůči referenčním. Čím menší je hodnota p , tím nastaly větší statisticky významné změny. Tudíž velikost hodnoty p nám potvrzuje, že při metodě využívající FFT nastaly menší změny při měření ($p = 0.041726$) než v případě metody FFT s Hannovým oknem ($p = 0.017377$).

Výsledné testovací kritérium budeme srovnávat opět s hodnotou vyhledanou ve statistických tabulkách, které odpovídá hodnotě 1,833. Hodnoty t v obou případech u detekce tepové frekvence jsou vyšší než hodnota z tabulek a můžeme tedy potvrdit statisticky významný rozdíl středních hodnot. [28]

Tab. 13: Studentův t-test pro dechovou frekvenci s FFT

Studentův párový t-test								
	průměr	sm. odch.	N	rozdíl	sm. odch. rozdílu	t	v	p
Pás [dech/min]	12.60000	2.366432						
ICA [dech/min]	12.49020	2.083015	10	0,109800	1,394472	0,248996	9	0,808953

Tab. 14: Studentův t-test pro dechovou frekvenci s FFT s Hannovým oknem

Studentův párový t-test								
	průměr	sm. odch.	N	rozdíl	sm. odch. rozdílu	t	v	p
Pás [dech/min]	12.60000	2.366432						
ICA [dech/min]	12,6084	2,104073	10	-0,008400	1,655996	-0,016041	9	0,987552

Statisticky významný rozdíl středních hodnot nemůžeme prokázat u dat získaných měřeními parametru dechové frekvence. Testovací kritérium t je totiž nižší než daná hraniční hodnota ($1,833 > t$). V tomto případě také nemůžeme zamítnout nulovou hypotézu proto, že $p > \alpha$. Znamená to, že jsme nenalezli statisticky významné změny výsledných hodnot získaných bezkontaktní detekcí dechové frekvence a referenčního měření. Můžeme tak tvrdit, že bezkontaktní detekce byla v tomto případě úspěšná a zdařilá.

5.4 Diskuze dosažených výsledků

Praktická část práce vykazuje zdařilé výsledky získané novodobou metodou bezkontaktní detekce fyziologických parametrů. Statistické výsledky měření prokazují relativně vysoký stupeň přesnosti mezi hodnotami odhadovanými bezkontaktní detekcí a referenčním měřením. Celkově můžeme konstatovat, že při měření nedošlo k hrubým či nadměrným odchylkám. Takové chyby bývají zapříčiněny především nesprávným zvolením metody či závadou aparatury. Na tomto místě budou diskutovány odchylky našich výsledků od referenčních hodnot, které mohlo způsobit několik možných aspektů.

Jedním z nich je rychlost snímkovací frekvence. I přesto, že byla do experimentu zakomponována videokamera vyznačující se možnostmi nastavení rychlosti až na 60 fps, nebylo možné tuto vlastnost plně využít. Rychlost snímání byla ovlivňována nastavováním parametrů snímání a pravděpodobně také použitým hardwarem při přenosu dat. Kompromisem mezi kvalitou obrazu a počtem zachycených snímků byla zvolena rychlost 30 fps. Můžeme pouze spekulovat, zda by zvýšení fps přineslo přesnější výsledky či nikoliv.

Je ověřeno, že kvalita snímků a použité osvětlení hrají v podstatě jednu z hlavních rolí při bezkontaktní detekci. Úspěšnou detekci zaručuje dostatečně ostrý obraz s přiměřeným osvětlením. To znamená ne příliš ostré světlo, ale také ne příliš nízké osvětlení. To bylo ověřeno při prvotních pokusech, kdy byla získána i data s nedokonalým nastavením osvětlení či zaostření. Výsledky nepřinášely zdařilé ani očekávané výsledky. Postupně však byly postupy zdokonaleny a nakonec bylo dosaženo pozitivních výsledků. Hlavní pozornost při nastavování byla věnována parametru zesílení a expozice. Příliš velké zesílení zanášelo do obrazů nežádoucí šum, který způsoboval nekvalitní výsledky. Proto bylo hledáno optimální nastavení s ideální hodnotou jasu a minimálním šumem v obraze. Je tedy možné, že ne vždy se podařilo docílit ideálního nastavení. Domnívám se, že činitel osvětlení a ostrosti byl důležitý především při detekci tepové frekvence, protože byly hledány změny v prokrvení obličeje, které nejsou zrakem viditelné. Oproti tomu dýchací změny jsou výraznějšího charakteru a zřejmě je jednodušší je detekovat. Možná to je důvodem zdařilejších výsledků u detekce dechové frekvence.

Byl zkoumán také vliv volby oblasti ROI, především kvůli manuálnímu způsobu volby. Při opakované analýze dat od téhož dobrovolníka byla zkoumána variance hodnot získaných pro různé velikosti zvolené ROI. Volba ROI není pevně stanovená, proto není zaručené, že bude při každém novém měření vybrána tatáž oblast. Bylo však zjištěno, že manuální volba ROI nezanáší do výsledků značné chyby. Na výsledky analýzy nemá vliv difference velikostí oblasti ROI. Důležité je pouze dodržet oblast tváře pro tepovou frekvenci a oblast hrudníku pro dechovou frekvenci.

Samozřejmě nejde opomenout také chyby způsobené lidským faktorem. Měří-li jeden pozorovatel jeden parametr vícekrát, začnou se vyskytovat nepatrné systematické chyby měření. Ty mají však nízkou hodnotu a můžeme je v tomto případě zanedbat.

Experiment se uskutečnil u osob, které nevykazovali žádný významný pohyb. Otázkou je, jaký vliv na měření by měly pohyby vyšetřované osoby. Vezmeme-li v úvahu, že bychom chtěli metodu bezkontaktní detekce zařadit do praxe a kontinuálně monitorovat vitální funkce, museli bychom počítat s pohyby pacienta. Zkoumání tohoto aspektu je nad rámec této práce. Avšak byly publikovány články, které se zabývaly právě zkoumáním vlivu pohybu na bezkontaktní detekci. Vědci dokázali navrhnout přístupy, které umožňovali odstranění pohybových artefaktů. Úspěšnost detekce pak byla překvapivě vysoká.

Z dosažených výsledků můžeme vyhodnotit, že se podařilo prakticky zrealizovat měření fyziologických parametrů bezkontaktně a vzdáleně pomocí běžné videokamery. Vyhodnocení statistickými testy dokazuje, že i vzhledem ke zmíněným nedostatům či omezením experiment přinesl vynikající výsledky.

Závěr

PPG systémy jsou brány jako průkopnické zobrazovací technologie založené na interakci světelných zdrojů, typicky v červené až v blízké infračervené oblasti elektromagnetického spektra. V současnosti jsou čím dál více zkoumány dálkové (bezkontaktní) pletysmografické metody, které využívají okolní osvětlení. Díky takovým metodám je umožněno za pomoci videokamery získat hodnoty fyziologických parametrů. Nejvíce je zatím studován odhad tepové a dechové frekvence.

V diplomové práci je pojednáváno o nových metodách a algoritmech sloužících k bezkontaktnímu měření fyziologických parametrů s využitím běžné videokamery. První kapitola popisuje historický vývoj bezkontaktní detekce vitálních funkcí a její obecný postup. Po nastudování okolností a podmínek metod vysvětlených v druhé kapitole byl vybrán jeden z přístupů, který byl vhodný pro účely této práce. Byl tak navržen experiment, pomocí kterého bylo možné bezkontaktně detekovat tepovou a dechovou frekvenci. Realizace experimentu spočívala v monitorování 10 dobrovolníků videokamerou, kterým byla zároveň měřena kontrolní tepová a dechová frekvence systémem BIOPAC. Získané videosekvence i data ze zařízení BIOPAC byly zpracovány v prostředí Matlab. Na zpracované videosekvence byla aplikována analýza nezávislých komponent a následně spektrální analýza prostřednictvím rychlé Fourierovy transformace. Rychlá Fourierova transformace byla použita dvojím způsobem. Jednou bez použití váhovacího okna, v druhém případě byl vstupní signál násoben Hannovým váhovacím oknem. Ve výsledném spektru byla potom hledána hodnota odpovídající velikosti tepové (resp. dechové) frekvence. Data získaná bezkontaktní detekcí byla porovnávána s referenčními daty. Byly porovnávány také změny, které způsobí váhovací okno ve spektrální analýze. Veškeré výsledky byly nakonec analyzovány příslušnými statistickými testy.

V diplomové práci bylo prakticky zrealizováno měření tepové a dechové frekvence bezkontaktně a vzdáleně pomocí běžné videokamery. Dosažené výsledky měření prokazují relativně vysoký stupeň přesnosti mezi hodnotami odhadovanými bezkontaktní detekcí a referenčním měřením.

Použité zdroje

- [1] SUN, Y. et al. *Use of ambient light in remote photoplethysmographic systems: comparison between a high-performance camera and a low-cost webcam.* Journal of Biomedical Optics. 2012, 17(3), s. 037005-1 – 10.
- [2] ZHAO, F., Li, M., QIAN, Y. and TSIEN, J. Z. *Remote measurements of heart and respiration rates for telemedicine.* PloS One. 2013, 8(10), s. e71384.
- [3] XU, S., SUN, L. a ROHDE, G.K. *Robust efficient estimation of heart rate pulse from video.* Biomed. Opt. Express 5, 1124-1135 (2014), dostupné z <http://www.opticsinfobase.org/boe/abstract.cfm?URI=boe-5-4-1124>
- [4] TARASSENKO, L. et al. *Non-contact video-based vital sign monitoring using ambient light and auto-regressive models.* Physiological Measurement. 35 (2014) 807-831
- [5] SUN, Y., HU, S. et al. *Motion-compensated noncontact imaging photoplethysmography to monitor cardiorespiratory status during exercise.* Journal of Biomedical Optics. 0001;16(7):077010 (2011)
- [6] SCULLY, C., LEE, J., MEYER, J. et al. *Physiological Parameter Monitoring from Optical Recordings With a Mobile Phone.* Biomedical Engineering, IEEE Transactions on , vol. 59, no.2, pp.303,306, Feb. 2012
- [7] YU Y-P., KWAN B-H., LIM Ch-L., WONG S-L., RAVEENDRAN P. *Video-based heart rate measurement using short-time Fourier transform,* Intelligent Signal Processing and Communications Systems (ISPACS), 2013 International Symposium on , vol., no., pp.704,707, 12-15 Nov. 2013
- [8] POH, M-Z, MCDUFF, D.J. and PICARD, R. W. *Non-contact, automated cardiac pulse measurements using video imaging and blind source separation.* Optics Express 18 (2010): 10762. ©2011 Optical Society of America.
- [9] LEMPE, G., et al., *Camera Based Measurement of Cardiorespiratory Signals.* Tm-Technisches Messen, 2013. 80(5): p. 179-184.
- [10] ROZMAN, J. a kol.: *Elektronické přístroje v lékařství.* Praha:Academia, s 406, 2006, ISBN80-200-1308-3.
- [11] FONG, B., FONG, A. C. M., LI, C. K. *Telemedicine Technologies: Information Technologies in Medicine and Telehealth.* Wiley, s 259, 2011.

- [12] CHMELAŘ, M: ROZMAN, J.: *Lékařská přístrojová technika*. Praha:SNTL, 1982, ISBN 412-33326.
- [13] JAN, Jiří. *Číslicová filtrace, analýza a restaurace signálů*. 2. upr. a rozš. vyd. Brno: VUTIUM, 2002, 427 s. ISBN 80-214-1558-4.
- [14] SEMMLOW, John L. *Biosignal and biomedical image processing: MATLAB-based applications*. London: Taylor, 2004, xviii, 423 p. Signal processing (Marcel Dekker, Inc.), 22. ISBN 08-247-4803-4.
- [15] SMUTNÝ, Jaroslav a Luboš PAZDERA. *Časově frekvenční analýza reálných signálů: MATLAB-based applications*. 1. vyd. Brno: ECON, 2003, 191 s. Signal processing (Marcel Dekker, Inc.), 22. ISBN 80-864-3323-4.
- [16] T-P. JUNG, S. MAKEIG, T-W. LEE, M.J. MCKOEWN, G. BROWN, A.J. BELL, and T.J. SEJNOWSKI. *Independent Component Analysis of Biomedical Signals*. In The 2nd Int'l Workshop on Independent Component Analysis and Signal Separation, 2000.
- [17] 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/dfk23um021/
- [18] CHOWDHURY, R. H., REAZ, M. B. I., et al. *Surface Electromyography Signal Processing and Classification Techniques*. Sensors 2013, 13, 12431-12466.
- [19] SCOTT PRAHL, Oregon Medical Laser Center. *Optical Absorption of Hemoglobin* [online]. © SAP 1999 [cit. 2014-11-29]. Dostupné z: <http://omlc.org/spectra/hemoglobin/>
- [20] BIOPAC MP System Hardware Guide. Goleta USA, 2008. Dostupné z WWW: http://www.biopac.com/Manuals/mp_hardware_guide.pdf
- [21] CARDOSO, J.,F. *Source separation of complex signals with JADE*. Copyright © 2013.
- [22] AFSARI, 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

- [23] KOZUMPLÍK, J.: Zpracování biologických signálů (AABS): *Detektory komplexů QRS*. Elektronická přednáška FEKT VUT v Brně, 2012. Dostupné z: <https://www.vutbr.cz/elearning/>
- [24] KONG, L. et al. *Non-contact detection of oxygen saturation based on visible light imaging device using ambient light*. ©2013 Optical Society of America
- [25] The MathWorks. *Signal Processing Toolbox* [online]. © 1994-2015 [cit. 2015-03-03]. Dostupné z: <http://www.mathworks.com/>
- [26] SCHWARZ, D. *Lineární a adaptivní zpracování dat*. Vyd. 1. Brno: Akademické nakladatelství CERM, 2012. 100 s. ISBN 978-80-7204-779-6.
- [27] JARKOVSKÝ, J. a L. DUŠEK. *Biostatistika*. Elektronická přednáška z předmětu biostatistika (ASTA) [online]. Institut biostatistiky a analýz, Masarykova univerzita, 2014, [cit. 2015-05-04]. Dostupné z: http://is.muni.cz/el/1411/podzim2014/ASTAp/um/Analyza_dat_2014.pdf
- [28] LINDA, Bohdan a Jana KUBANOVÁ. *Statistické tabulky a vzorce*. Vyd. 2. dopl. Pardubice: Univerzita Pardubice, 2001, 38 s. ISBN 80-7194-337-1.
- [29] WARD, Thomas, K. HUMPHREYS a MARKHAM. 2013. *A CMOS camera-based system for non-contact pulse oximetry imaging* [online]. [cit. 2015-04-20]. Dostupné z: https://www.researchgate.net/publication/228718494_A_CMOS_camera-based_system_for_non-contact_pulse_oximetry_imaging

Seznam použitých symbolů a zkratek

apod.	a podobně
AR	Autoregresní model
AVI	Audio Video Interleave
bmp	Bitmap
bpm	beats per minute
BSS	Blind Source Separation
cca	cirka
CMOS	Complementary Metal Oxide Semiconductor
DF	Dechová Frekvence
EEG	Elektroencefalografie
EKG	Elektrokardiografie
FFT	Fast Fourier Transform
fps	Frames per second
HR	Heart Rate
ICA	Independent Component Analysis
IR	InfraRed, Infračervený
JADE	Joint Approximate Diagonalization of Eigenmatrices
např.	například
NIR	Near InfraRed
PPG	Photoplethysmography, fotopletysmografie
R	Red, Červený
resp.	respektive
RGB	Red-Green-Blue
ROI	Region of interest
RR	Respiration Rate
SpO2	Saturation of Peripheral Oxygen
SPWVD	Smoothed Pseudo Winger-Ville distribution
STFT	Short Time Fourier Transform
TF	Tepová Frekvence
TFR	Time-frequency analysis
tzn.	to znamená
tzv.	takzvaný
USB	Universal Serial Bus
UV	Ultra Violet, ultrafialový

Příloha: Obsah přiloženého DVD

Přiložené DVD obsahuje dvě složky (programy, videosekvence) a návod k programům.

1. programy

- ICA
 - *ICA.m*
 - *jade.m*
- EKG
 - *detektor.m*
 - *data z EKG měření 1 – 10 (MAT-files)*
- biopac
 - *biopac.m*
 - *data z měření systémem BIOPAC (MAT-files)*

2. videosekvence

- naměřené snímky jsou příliš velké, proto jsou na DVD poskytnuty pouze videosekvence od 4 vybraných dobrovolníků (č. 4, č. 5, č. 6 a č. 8)

3. návod k programům