

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

BAKALÁŘSKÁ PRÁCE

Brno, 2024

Daniel Viliam Bartoš



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY

A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

STANOVENÍ KVALITY A TEPOVÉ FREKVENCE ZE SIGNÁLŮ PPG SNÍMANÝCH Z OBLIČEJE POMOCÍ CHYTRÉHO TELEFONU

ESTIMATION OF QUALITY AND HEART RATE FROM PPG SIGNALS SENSED FROM FACE USING
SMARTPHONE

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Daniel Viliam Bartoš

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Andrea Němcová, Ph.D.

BRNO 2024

Bakalářská práce

bakalářský studijní program **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Student: Daniel Viliam Bartoš

ID: 240305

Ročník: 3

Akademický rok: 2023/24

NÁZEV TÉMATU:

Stanovení kvality a tepové frekvence ze signálů PPG snímaných z obličeje pomocí chytrého telefonu

POKYNY PRO VYPRACOVÁNÍ:

1) Proveďte literární rešerši v oblasti využití chytrého telefonu pro snímání PPG záznamů z obličeje. Zaměřte se také na možnosti stanovení kvality a tepové frekvence (TF) z PPG. 2) Nasnímejte sadu dat pomocí chytrého telefonu za různých podmínek. Jako referenci nasnímejte elektrokardiogram. 3) Zpracujte nasnímaná data do podoby PPG záznamů a vytvořte algoritmus pro stanovení jejich kvality. 4) Vytvořte algoritmus pro stanovení TF z PPG. 5) Porovnejte přesnost algoritmu pro stanovení TF s referencí. 6) Vyhodnoťte přesnost stanovení TF s ohledem na podmínky snímání a kvalitu dat. 7) Porovnejte výsledky stanovení TF s ostatními autory. Diskutujte výsledky a použitelnost vašich algoritmů.

DOPORUČENÁ LITERATURA:

[1] ALLEN, John, KYRIACOU, Panicos A., ed. Photoplethysmography: technology, signal analysis and applications. London: Academic Press, 2022. ISBN 978-0-12-823374-0.

[2] MAESTRE-RENDON, J. Rodolfo, Tomas A. RIVERA-ROMAN, Arturo A. FERNANDEZ-JARAMILLO, Nancy E. GUERRÓN PAREDES a José Javier SERRANO OLMEDO. A Non-Contact Photoplethysmography Technique for the Estimation of Heart Rate via Smartphone. Applied Sciences [online]. 2020, 10(1). ISSN 2076-3417. Dostupné z: doi:10.3390/app10010154.

Termín zadání: 5.2.2024

Termín odevzdání: 29.5.2024

Vedoucí práce: Ing. Andrea Němcová, Ph.D.

doc. Ing. Jana Kolářová, Ph.D.
předseda rady studijního programu

UPOZORNĚNÍ:

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

ABSTRAKT

Tato práce zkoumá zpracování a snímání signálů fotopletysmografie (PPG), hodnocení kvality PPG, odhad tepové frekvence a možnost snímání pomocí chytrého telefonu. Hlavním cílem práce je získat signály PPG z videa obličeje pomocí chytrého telefonu. Následně bude navržen algoritmus pro posouzení kvality PPG signálů a algoritmus pro určení tepové frekvence.

KLÍČOVÁ SLOVA

PPG, fotopletysmogram, EKG, chytrý telefon, tepová frekvence, kvalita PPG.

ABSTRACT

This thesis explores the processing and capturing of photoplethysmographic signals (PPG), quality assessment of PPG, heart rate estimation, and the potential for capturing signals using a smartphone. The main objective of the thesis is to obtain PPG signals from facial video using a smartphone camera. Methods will be suggested to assess the quality of PPG signals and calculate the heart rate.

KEYWORDS

PPG, photoplethysmogram, ECG, smartphone, heart rate, PPG quality

BARTOŠ, Daniel Viliam. *Stanovení kvality a tepové frekvence ze signálů PPG snímaných z obličeje pomocí chytrého telefonu*. Bakalářská práce. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství, 2024. Vedoucí práce: Ing. Andrea Němcová, Ph.D.

Prohlášení autora o původnosti díla

Jméno a příjmení autora: Daniel Viliam Bartoš
VUT ID autora: 240305
Typ práce: Bakalářská práce
Akademický rok: 2023/24
Téma závěrečné práce: Stanovení kvality a tepové frekvence ze signálů PPG snímaných z obličeje pomocí chytrého telefonu

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

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

Brno

.....

podpis autora*

*Autor podepisuje pouze v tištěné verzi.

PODĚKOVÁNÍ

Rád bych poděkoval mé vedoucí bakalářské práce paní Ing. Andree Němcové, Ph.D. za trpělivost a ochotu. Dále bych chtěl poděkovat všem měřeným účastníkům.

Obsah

Úvod	13
1 Kardiiovaskulární systém	14
1.1 Srdce	14
1.2 Cévní systém	14
1.3 Převodní systém srdeční	15
1.4 Srdeční frekvence	15
1.4.1 Měření srdeční frekvence	16
2 Elektrokardiografie	18
2.1 Elektrokardiogram	18
2.2 Zapojení EKG	19
3 Fotopletysmografie	20
3.1 PPG signál	21
3.2 Klinické využití	22
3.3 Možnosti snímání PPG pomocí chytrého telefonu	22
3.3.1 Vzdálená fotopletysmografie (rPPG)	23
4 Stanovení kvality PPG signálu	25
4.1 Extrakce příznaků	26
4.2 Stanovení kvality bez využití umělé inteligence	26
4.3 Stanovení kvality s využitím umělé inteligence	30
4.4 Hodnocení algoritmů klasifikace	32
5 Stanovení TF z PPG	34
6 Snímání dat	37
6.1 Protokol měření	37
7 Předzpracování dat	39
8 Algoritmus stanovení kvality záznamu	45
8.1 Model KNN	51
8.2 Model SVM	53
9 Stanovení tepové frekvence	55
9.1 Hodnocení algoritmů stanovení tepové frekvence	56

10 Přehled podobných studií	59
10.1 Studie Poh et al. (2010)	59
10.2 Studie Tarassenko et al. (2014)	59
10.3 Studie Trirongjitmoah et al. (2024)	60
11 Diskuze	61
Závěr	63
Literatura	64
Seznam symbolů a zkratk	70
A Obsah elektronické přílohy	72

Seznam obrázků

1.1	Převodní systém srdeční [4]	16
2.1	EKG křivka [12]	18
2.2	12-svodové zapojení EKG [15]	19
3.1	Schématické zobrazení transmisního (vlevo) a reflektivního (vpravo) režimu PPG. Převzato a upraveno z [8].	20
3.2	Kompozice PPG signálu. Převzato a upraveno z [8]	21
3.3	PPG průběh reprezentující změny objemu tkáně. Převzato a upraveno z [8].	22
3.4	Model odrazu světla od kůže. Pouze rozptýlený (difúzní) odraz obsahuje užitečnou informaci o AC složce. Převzato a upraveno z [22] . . .	23
4.1	PPG záznamy rozděleny podle kvality do tří tříd. Převzato a upraveno z [25].	26
4.2	Blokové schéma stanovení kvality z fyziologických limitů kardiovaskulární soustavy. Převzato a upraveno z [26].	28
4.3	Ilustrace modelu KNN pro dva příznaky x_1 a x_2 . Převzato a upraveno z [31]	31
4.4	Matice záměn	32
5.1	Spektrum signálu získané pomocí FFT. Spektrální čára s největší amplitudou je označena červenou značkou. Převzato a upraveno z [37]	35
6.1	Doporučené umístění elektrod [44]	37
6.2	Úsek nezpracovaného EKG záznamu	38
7.1	Blokové schéma akvizice PPG signálu	39
7.2	Výběr oblasti zájmu pomocí barevného klíčování	40
7.3	Výběr oblasti zájmu pomocí automatické detekce obličeje	40
7.4	Surový PPG signál – kvalitní	41
7.5	Surový PPG signál – nekvalitní	41
7.6	Filtrovaný PPG signál	42
7.7	Derivovaný PPG signál	43
7.8	Úsek filtrovaného EKG s označenými R vlnami	44
8.1	Hodnocení modelu KNN pomocí průměrné přesnosti klasifikace . . .	45
8.2	Histogram rozdělení kvality úseků do dvou tříd	46
8.3	Analýza hlavních komponent z šesti příznaků. 1 – kvalitní, 0 – nekvalitní	47
8.4	Krabicové grafy pro perfuzi kvalitních a nekvalitních úseků	47
8.5	Krabicové grafy šikmosti kvalitních a nekvalitních úseků	48
8.6	Krabicové grafy špičatosti kvalitních a nekvalitních úseků	48
8.7	Krabicové grafy entropie kvalitních a nekvalitních úseků	49
8.8	Krabicové grafy pro ZCR kvalitních a nekvalitních úseků	49

8.9	Krabicové grafy pro SNR kvalitních a nekvalitních úseků	50
8.10	Hodnocení modelu KNN pomocí průměrné přesnosti klasifikace . . .	52
8.11	Hodnocení modelu KNN pomocí průměrné plochy pod ROC křivkou .	52
8.12	Matice záměn pro model KNN	53
8.13	Matice záměn pro model SVM	54

Seznam tabulek

8.1	Výsledky Mann-Whitney U testu pro jednotlivé příznaky	51
8.2	Hodnocení modelu KNN pro stanovení kvality úseků signálu	53
8.3	Hodnocení modelu SVM pro stanovení kvality úseků signálu	54
9.1	Výsledky metod stanovení TF pro kvalitní úseky stanovené modelem KNN	57
9.2	Výsledky metod stanovení TF pro nekvalitní úseky stanovené mode- lem KNN	57
9.3	Výsledky metod stanovení TF pro kvalitní úseky stanovené modelem SVM	58
9.4	Výsledky metod stanovení TF pro nekvalitní úseky stanovené mode- lem SVM	58
10.1	Stanovená TF ze tří různých rPPG signálů. Převzato a upraveno z [48]	60

Úvod

V dnešní době kdy se mobilní technologie neustále rozvíjí a chytrý telefon již vlastní přes 85% lidí celosvětově [1], se nabízí příležitost využít senzory, zabudované do chytrých telefonů, pro snímání různých zdravotních parametrů. Využití chytrých telefonů pro zdravotní monitorování umožňuje nepřetržité sledování zdravotních parametrů. To může významně přispět k prevenci a včasnému odhalení zdravotních problémů. Navíc, vzhledem k široké dostupnosti chytrých telefonů, mohou tyto technologie zpřístupnit zdravotní monitorování širší populaci.

Tepová frekvence (TF) poskytuje údaje o kardiovaskulárním zdraví a celkové fyzické kondici jedince. Umožňuje nám sledovat jak srdce pracuje v běžných podmínkách nebo pod zátěží. TF lze považovat za ukazatel celkového zdravotního stavu osoby. Například zvýšená klidová TF (nad 90 tepů za minutu) byla posouzena jako nezávislý rizikový faktor zvyšující míru úmrtnosti u jinak zdravých osob [2].

Tato práce se bude zabývat bezkontaktním snímáním fotopletysmografického záznamu (PPG) pomocí kamery chytrého telefonu, algoritmické zhodnocení kvality naměřeného PPG a určení TF.

Teoretická část práce se věnuje anatomii a fyziologii kardiovaskulárního systému, dále se zabývá možnostmi měření TF. V další kapitole je popsána elektrokardiografie a princip vytvoření elektrokardiogramu. Třetí kapitola se zabývá popisem principu vzniku PPG signálu, možnostmi snímání pomocí chytrého telefonu a princip vzdálené fotopletysmografie. Čtvrtá kapitola popisuje možnosti stanovení kvality PPG pomocí různých metod. Konec teoretické části se zabývá metodami stanovení TF z PPG záznamů.

Praktická část práce se věnuje měřením záznamů od jedenácti účastníků a extrakcí PPG z videosekvencí. Dále popisuje algoritmické řešení rozřazení PPG signálu podle kvality záznamu a hodnotí úspěšnost algoritmů. Následně jsou popsány metody stanovení TF, které jsou hodnoceny proti referenční TF. Konečné kapitoly práce stručně popisují jiné studie zabývající se vzdálenou fotopletysmografií a jejich výsledky. Dále poskytuje souhrn výsledků této práce, možné vylepšení a limitace.

1 Kardiovaskulární systém

Kardiovaskulární systém je orgánový systém, který zajišťuje cirkulaci krve do všech tkání lidského těla, a to v dostatečném množství. Všechny tkáně ovšem vykazují jiný stupeň metabolismu, vyžadují jinou energetickou potřebu, a to vše v různém čase. Ústředními orgány kardiovaskulárního systému je srdce, pracující jako hnací jednotka, a velmi složitý cévní systém [3].

1.1 Srdce

Srdce je ústřední orgán kardiovaskulárního systému, je uložen v prostoru mezi plíci.

Tento orgán je založen na kontrakčních schopnostech speciálního typu svalu, nazývaný myokard, který obaluje dutý prostor. Při zkrácení tohoto svalu (systola) dojde ke zmenšení vnitřního objemu, a pokud je dutina naplněna krví, je pak krev vytlačována z dutiny ven. Při ochabnutí svalstva (diastola) se dutiny znovu plní krví. Lidské srdce má tyto dutiny hned čtyři. Pravou a levou síň, ty pomáhají při plnění krve do hlavních dutin srdce, jimiž jsou pravá a levá komora. Směr proudu krve je zajišťován chlopněmi. Celkově se pak dá říct, že je srdce tvořeno ze dvou do série spojených čerpadel, tj. levá a pravá část orgánu. Levá polovina zajišťuje systémový (tělní) oběh a pravá polovina zajišťuje plicní oběh [4].

Jedná se o orgán velmi efektivní, je schopný pumpovat krev do celého těla bez jediné přestávky a je to jediný orgán, který si zajišťuje svůj přísun krve. Za život průměrně dojde až k třem miliardám kontrakcí. Srdce v klidu přečerpá kolem 5 litrů krve za minutu, přibližně objem krve v lidském těle. Tento výdej se však může zvětšit až více než pětinašobně, u zdravého jedince, v případě vysoké fyzické námahy, a to zejména zrychlením srdeční frekvence [3, 5].

1.2 Cévní systém

Cévní systém zajišťuje adekvátní přísun kyslíku a živin do všech tkání těla a současně odvádění odpadních látek pro následné vyloučení. Je také součástí lymfatického systému. Skládá se ze dvou hlavních částí: malého krevního oběhu, který vede krev chudou na kyslík do plic, kde dojde k výměně plynů, a velkého krevního oběhu, který rozvádí již krev bohatou na kyslík, do celého těla. Krevní cévy dělíme na arterie (tepny), vény (žíly) a kapiláry [3].

Aby se krev dostala až do kapilární sítě musí srdce vyvinout značný tlak, který musí především překonat odpor krevního řečiště. Při vypuzení krve ze srdce se po stěnách tepen šíří tlakově–objemová vlna, kterou nazýváme arteriální pulz. Rychlost

šíření pulzu v periferních tepnách je 8–10 m/s. Rychlost proudění krve je výrazně pomalejší, ale stále pulzního charakteru. Rychlost průtoku krve je dáno především průsvitem cév [4].

Kapiláry jsou cévy s velmi malým průměrem (mezi 5 a 20 μm), avšak s velmi velkou funkční plochou (asi 1000 m^2). Díky velké ploše a pomalému průtoku jsou tyto cévy vhodné k optimální difúzi látek mezi krví a tkáněmi [3, 4, 5].

Vény jsou zodpovědné za návrat krve zpátky do srdce. Pracují za mnohem nižšího tlaku a nižších průtokových rychlostí. Aby se zabránilo stagnaci krve, je tento proces podporován několika mechanismy. Proudění krve je zajišťováno především srdcem a negativním nitrohrudním tlakem, je také významně podporován kontrakcemi kosterního svalstva. Určitý význam pro posun krve mají i tepny, které svou pulzací stlačují doprovodné žíly. V neposlední řadě jsou žíly dolních končetin opatřeny chlopněmi, aby se zabránilo zpětnému toku krve a otékání žil [3, 5].

1.3 Převodní systém srdeční


Srdce do jisté míry funguje automaticky, je za to zodpovědný tzv. převodní systém srdeční (PSS), jedná se o specializovanou svalovou tkáň, jejíž buňky jsou schopné autonomně vytvářet vzruchy a tyto vzruchy rozvádět [4, 6].

Membránové napětí na buňkách tohoto systému spontánně vzrůstá a jakmile překročí prahovou hodnotu, vzniká akční potenciál (AP), který se systémem rozvede po srdci a dojde ke kontrakci srdeční svaloviny. Po skončení AP se membránové napětí nestabilizuje, ale jeho hodnota znovu roste. Tento mechanismus se opakuje, proto tyto buňky slouží jako zdroj vzruchů [4].

Vzruch se ve zdravém srdci nejdříve tvoří v sinoatriálním (SA) uzlu, protože je zde spontánní depolarizace nejrychlejší. Odtud se elektrický vzruch šíří přes síně do atrioventrikulárního (AV) uzlu. Hisův svazek pak s krátkým zpožděním předá vzruch komorám, který se rozvede Tawarovými raménky, ty se větví ještě na Purkyňova vlákna, která signál dále rozvádějí po svalovině komor. V případě patologického stavu, kdy SA uzel nefunguje správně, může být jeho funkce nahrazena jinou částí PSS, např. AV uzlem, jehož spontánní depolarizace je pomalejší než SA uzlu. Anatomie PSS je znázorněna na Obr. 1.1 [3, 7].

1.4 Srdeční frekvence

Fyziologická srdeční frekvence, za kterou je zodpovědná spontánní elektrická aktivita SA uzlu, je pod vlivem vegetativního nervového systému. Sympatický nervový



Obr. 1.1: Převodní systém srdeční [4]

system srdeční frekvenci zvyšuje, zatímco parasympatický nervový systém ji snižuje. Který z těchto systému bude převládat ovlivňuje mnoho faktorů. Tato regulace umožňuje srdci se přizpůsobit různým situacím a potřebám těla [3, 4].

Klidová srdeční frekvence by měla být v rozmezí 60–90 tepů za minutu, přičemž zvýšené hodnoty jsou nejen indikátorem špatné tělesné zdatnosti, ale i rizikovým faktorem úmrtnosti, nezávislým na fyzické zdatnosti [2]. Jestliže je srdeční frekvence vyšší, jedná se o tachykardii, která je fyziologická při námaze, a v případě pomalejší srdeční činnosti, mluvíme o bradykardii, která je fyziologická např. ve spánku [4].

1.4.1 Měření srdeční frekvence

Srdeční frekvence poskytuje informace o funkci srdce, její pravidelné měření může odhalit nepravidelnosti srdeční akce, které mohou být známkou srdečních onemocnění nebo jiných zdravotních problémů [2]. Z tohoto důvodu se již několik desetiletí srdeční frekvence monitoruje v oblastech kritické péče, jako jsou např. jednotky intenzivní péče, či na oddělení urgentního příjmu. Monitorování srdeční frekvence může pomoci identifikovat potenciální komplikace, reagovat na akutní stavy a sledovat účinnost léčby [8].

Měření srdeční frekvence může být součástí sledování fyzické kondice. Když se tělo vystavuje zátěži, začne srdeční frekvence stoupat, aby se zvýšilo množství krve dodáváno svalům. Sledování této odezvy poskytuje informace o tom, jak účinně srdce pracuje a jak tělo zvládá zátěž. Sledování srdeční frekvence může pomoci identifikovat optimální intenzitu zátěže při cvičení, například pracovat v určitém frekvenčním rozsahu pro zlepšení kardiovaskulární kondice [9].

Nejjednodušší metodou pro určení TF je pohmatem na pulzujících tepnách, které jsou umístěny v blízkosti povrchu těla, nejčastěji na předloktí. Registrace této tlakově-objemové změny se nazývá sfygmogram [3].

Další jednoduchou metodou je poslechem, tzv. fonografie využívá srdeční ozvy tvořené funkcí srdečních chlopní a prouděním krve. Tímto způsobem se dají detekovat srdeční šelesty, což je patologický stav, vzniklý turbulencí krve nebo vibrací tkáně [10].


Pokročilejší metody pro vyšetření nejen srdečního rytmu, zahrnují přístupy: elektrokardiografie (EKG) a fotopletysmografie (PPG). EKG je metoda měření elektrické aktivity srdce a je blíže popsána v kapitole 2. PPG sleduje objemové změny cévního systému pomocí měření absorpce světla a je hlavním tématem této práce, blíže je tato metoda popsána v kapitole 3.

2 Elektrokardiografie

Elektrokardiografie představuje základní neinvazivní metodu pro vyšetřování srdeční aktivity, sloužící jako důležitý indikátor při diagnostice různých srdečních onemocnění. Elektrická aktivita srdce se projeví změnami elektrického potenciálu i na povrchu těla, jelikož buňky myokardu nejsou depolarizovány současně. Elektrický impuls se postupně šíří buňkami myokardu, a jelikož jsou lidské tkáně vodivé, vznikají na povrchu těla potenciály, které můžeme zaznamenávat pomocí elektrod. Tomuto záznamu se říká elektrokardiogram [4, 11].

2.1 Elektrokardiogram

Křivka EKG je vytvořená z časového průběhu tzv. srdečního vektoru, ten odpovídá sumě velikostí a směru elektrického pole všech kardiomyocytů v daný okamžik. Podle konvence je pozitivní výchylka na EKG křivce, když vlna depolarizace směřuje směrem k elektrodě a záporná výchylka, když putuje od elektrody. Křivku EKG můžeme rozdělit na několik složek, znázorněných na Obr 2.1. Rozlišujeme vlny a kmity, úseky a intervaly [3, 11].



Obr. 2.1: EKG křivka [12]

Vlna P reprezentuje počáteční vzruch na SA uzlu a následnou depolarizaci svaloviny síní, trvá 80–100 ms. Úsek PQ také trvá 80–100 ms a odpovídá zbrzdění vzruchu v atrioventrikulárním uzlu. Toto zpomalení má význam pro oddělení systoly síní od systoly komor [4, 7].

Komplex QRS představuje depolarizaci komorového svalstva ve směru od levé komory k pravé, také v tuto dobu repolarizuje svalstvo síní. První záporný kmit je

označen jako Q, každý pozitivní kmit jako R a všechny negativní kmity komplexu po kmitu R se označují S (jestliže je v komplexu více R nebo S kmitů, označí se následující kmity s apostrofem). Fyziologicky trvá do 110 ms [4, 7].

Úsek ST představuje nulovou elektrickou aktivitu srdce. Fáze plató, neboli refrakterní doba srdce, je úsek kdy srdce není citlivé na nové podněty k vyvolání kontrakce. Zabraňuje se tím tak nekontrolovaným nebo příliš častým srdečním stahům. Vlna T pak značí postupnou repolarizaci myokardu komor. Celý interval QT (od začátku QRS komplexu po konec vlny T) je ovlivněn tepovou frekvencí, při frekvenci 72 tepů za minutu trvá 350–400 ms [4, 7].


Po vlně T se, nejčastěji u dětí, může ještě vyskytovat vlna U, která nemá jasný původ, ale nejspíše značí pomalejší depolarizaci Purkyňových vláken [11, 13].

2.2 Zapojení EKG

Standardní EKG využívá několik typů svodů, z nichž každý poskytuje specifický pohled na srdeční činnost. Standardní Eithovenovy svody, známé také jako končetinové svody (I, II, III), měří elektrickou aktivitu mezi končetinami. Goldbergovy rozšířené končetinové svody (aVR, aVL, aVF) zaznamenávají úbytek napětí mezi danou končetinou a průměrnou hodnotou napětí z ostatních dvou končetinových svodů. Hrudní elektrody (V1 až V6) umístěné na hrudníku monitorují elektrickou aktivitu v horizontálním směru [3, 11].

Při správném umístění elektrod lze získat informace o elektrické aktivitě v různých částech srdce a v různých fázích srdečního cyklu. Například svody V1 a V2 jsou citlivé na elektrickou aktivitu pravé komory, zatímco svody V5 a V6 se zaměřují na levou komoru [14].


Pro získání komplexního obrazu srdeční elektrické aktivity se běžně používá 12-svodové zapojení, znázorněné na Obr. 2.2. Toto zapojení je tedy tvořeno třemi Eithovenovými svody, třemi Goldbergovými svody a ze šesti hrudních svodů.




Obr. 2.2: 12-svodové zapojení EKG [15]

3 Fotopletysmografie

Fotopletysmografie (PPG) je neinvazivní optická měřicí metoda, snímající změny objemu krve v dané tkáni. Obvykle používá senzor tvořený světelnou diodou (LED), vyzařující světlo určité vlnové délky, a fotodetektoru, který detekuje intenzitu světla prošlého tkání nebo odraženého od tkáně. Intenzita světla detekovaného fotodetekto-rem je ovlivněna množstvím krve v dráze světla. [8, 16] Množství krve se mění v důsledku pulzujících změn objemu krve v tepně. Když je krve v daný moment více, je absorpce světla vyšší a měřená intenzita světla nižší. Přístup měřící intenzitu prošlého světla se nazývá trasmisní a přístup využívající odraženého světla se nazývá reflektivní [17]. Oba přístupy jsou znázorněny na Obr. 3.1. Většina absorpce světla je způsobena okolními tkáněmi, ale taky nepulzující složkou arteriální krve. PPG záznam má z tohoto důvodu velkou stejnosměrnou složku (DC) a malou pulzující složku (AC) [16]. Tento princip je ilustrován na Obr. 3.2. Pulzující složka je především ovlivněna objemem krve v měřené oblasti a mění se s každým srdečním cyklem. Naopak nepulzující složka zahrnuje statické vlastnosti, jako je odraz od pokožky a kostí, a také pomalu se měnící vlastnosti, které korespondují s průměrným objemem krve v tkáni. DC složka je tedy závislá na respiraci, teplotě, celkovém objemu krve, žilnímu návratu. Dnes je PPG snímán řadou klinických i spotřebitelských zařízení, od pulzních oxymetrů a chytrých hodinek, po prsteny a náhrdelníky, jinak známé jako *wearables*, neboli nositelná elektronika [16, 18, 19, 20].




Obr. 3.1: Schématické zobrazení transmisního (vlevo) a reflektivního (vpravo) režimu PPG. Převzato a upraveno z [8].



Obr. 3.2: Kompozice PPG signálu. Převzato a upraveno z [8]

3.1 PPG signál

Průběh PPG, který je zobrazen na Obr. 3.3, představuje data ze senzoru, která jsou často vyjádřena jako změny v objemu krve, které jsou závislé na absorpci světla tkáněmi. Zaznamenaný průběh se skládá z jednotlivých pulzů. Každý pulz začíná systolickou fází, ta končí systolickým peakem, po ní následuje diastolická fáze a cyklus se opakuje. Diastolický peak je způsoben odrazem tlakové vlny od periferií. Mezi systolickým a diastolickým peakem je tzv. dikrotický zářez, který odpovídá uzavření srdečních chlopní [16]. Vlnová délka použitého světla pro měření a vyhodnocování výsledků, také ovlivňuje výsledný signál, jelikož různé vlnové délky pronikají do různých hloubek kůže. [16, 17]. Dlouhé vlnové délky světla mají nižší absorpci tkáněmi, a proto dokážou pronikat hlouběji do kůže a dosáhnout větších tepen, kde je přítomná hlavní pulzující složka krve. Naopak krátké vlnové délky světla jsou absorbovány povrchovějšími vrstvami tkání, a jsou tedy více ovlivněny změnami v objemu kapilární krve. Jak se objem krve zvětšuje, dojde k rozšíření tepen díky jejich elastickým vlastnostem, což může vést ke stlačení okolní tkáně. Srdeční tep tak způsobuje dynamické změny ve vzdálenostech mezi blízkými kapilárami, což se projevuje jako změny v hustotě kapilár a tím se mění i optické vlastnosti tkáně [8, 17, 20].



Obr. 3.3: PPG průběh reprezentující změny objemu tkáně. Převzato a upraveno z [8].

3.2 Klinické využití

Zpočátku umožňovaly kontinuální monitorování saturace kyslíkem během anestezie. V intenzivní péči se pulzní oxymetry často používají k monitorování TF u novorozenců a mohou pomoci zabránit vystavení nedonošených dětí nebezpečným hladinám přídavného kyslíku, což může vést ke slepotě. Na nemocničních odděleních se pulzní oxymetry používají k získání měření TF a saturace kyslíkem u akutně nemocných pacientů, což lze využít k identifikaci časných známek klinického zhoršení [20].

3.3 Možnosti snímání PPG pomocí chytrého telefonu

Jedna z možností je využití integrované kamery a blesku. Blesk telefonu funguje jako konstantní nebo pulzující světelný zdroj, který proniká skrz kůži uživatele, obvykle na prstu nebo ušním lalůčku. Světlo, které se následně odrazí je zachyceno kamerou telefonu. Různé vlnové délky světla jsou absorbovány krví v různé míře, což umožňuje detekci změn v krevním objemu během srdečního cyklu. Snímky získané kamerou jsou analyzovány na změny v intenzitě světla, které korelují s pulzacemi krevního objemu. Tato data jsou následně zpracována algoritmy pro odhad srdeční frekvence a potenciálně dalších kardiovaskulárních parametrů [21].

Kvalita a přesnost měření této metody však může být ovlivněna vnějšími světelnými podmínkami, pohybem prstu, nebo nekonzistentním přiložením prstu k blesku a kameře. Blesk telefonu a kamera jsou navrženy zejména pro fotografické účely. Kamery v chytrých telefonech jsou vybaveny různými optickými filtry a mají určité citlivosti na různé vlnové délky. Například infračervené filtry, které jsou běžné v

mnoha kamerách, mohou redukovat nebo eliminovat detekci vlnových délek, které se často využívají k měření PPG. Blesk telefonu vyzařuje bílé světlo, které obsahuje potřebné vlnové délky, ovšem intenzita a homogenita osvětlení může být pro účely PPG snímání nedostatečná. Účinnost osvětlení může být také ovlivněna i rozložením a směřováním světelného zdroje (blesku) vzhledem k objektivu kamery a snímanému objektu (například prstu) [21].


Pro dosažení přesných výsledků je proto potřeba kalibrace zařízení a algoritmické zpracování dat, které musí zohlednit rozdíly mezi různými modely telefonů.

Obdobná metoda využívá displej jako zdroj světla, zatímco přední kamera telefonu snímá, jak světlo prochází prstem uživatele. Tento přístup je speciální v tom, že umožňuje využívat různé barvy světla emitovaného displejem (červená, zelená, modrá) během měření, což může pomoci zlepšit přesnost měření tím, že poskytne více datových bodů pro analýzu [21].

Další metody využívají externích PPG senzorů, které lze nosit na těle nebo umístit na kůži. Tyto senzory posílají data do aplikace na chytrém telefonu přes Bluetooth nebo USB. Tato zařízení mohou poskytovat přesnější měření v reálném čase. Bývají často navrženy pro sledování fitness, či monitorování spánku [20].

3.3.1 Vzdálená fotopletysmografie (rPPG)

Tato metoda umožňuje pořizovat PPG bez nutnosti přímého kontaktu s pacientem, což znamená menší nepohodlí a riziko infekce. Využívá výhradně reflektivní metodu pořizování PPG. Přímý odraz od pokožky neobsahuje žádný užitečný signál. K dosažení relevantního signálu musí světlo proniknout do hlubších vrstev kůže a až poté se odrazit [22]. Toto odražené světlo je následně snímáno kamerou jak ilustruje Obr. 3.4.



Obr. 3.4: Model odrazu světla od kůže. Pouze rozptýlený (difúzní) odraz obsahuje užitečnou informaci o AC složce. Převzato a upraveno z [22]

Vzhledem k tomu, že je tato metoda snadno integrovatelná do běžně dostupných zařízení, je nutné brát v potaz různé faktory jako osvětlení nebo typ kamery, které by mohli ovlivnit přesnost měření. Barva kůže, těžké fyzické cvičení nebo různé patologické stavy mohou také ztěžovat správnou analýzu. Proto obvykle metoda vyžaduje pokročilé algoritmy pro zpracování obrazu a extrakci užitečných dat z videa.

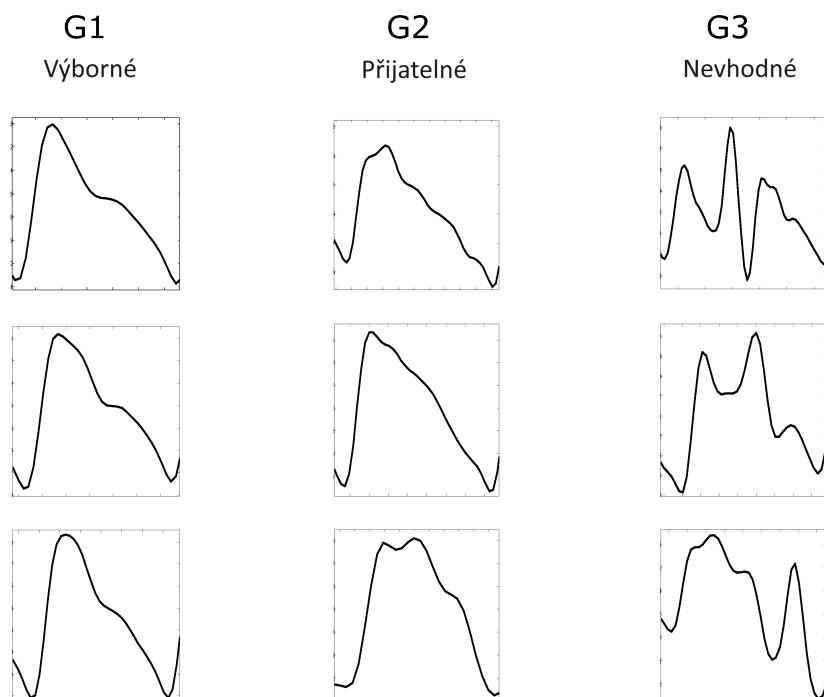
U rPPG je nejdříve nutné vybrat oblast zájmu, tedy obličej, ideálně jeho nejprokrvenější části. Z této oblasti zájmu se extrahuje signál pomocí průměrování intenzit jednotlivých pixelů. [23].

4 Stanovení kvality PPG signálu

Díky snadnému měření a schopnosti poskytovat více informací o stavu pacienta z jediného signálu se PPG stává velmi oblíbeným monitorovacím nástrojem. Jeho největší nevýhodou je však vysoká náchylnost k pohybovým artefaktům, která omezuje jeho spolehlivost. Proto je třeba tyto a další artefakty odhalit a nespolehlivé části signálu odstranit. Výsledky pozdější analýzy signálu nebudou zkreslené a zvýšíme tím tak spolehlivost měření. [24]. Kvalitu PPG je nutné definovat v závislosti na použité aplikaci. Pro tuto práci bude postačovat, aby PPG bylo dostatečně kvalitní k tomu, aby bylo možné spolehlivě odečíst tepovou frekvenci.

Obecně můžeme PPG signály dělit na signály s vysokou kvalitou, které jsou vhodné pro klinickou analýzu, a na signály s nízkou kvalitou, které mohou obsahovat významné množství artefaktů. Pro rozeznání kvality signálu se často využívají algoritmy pro zpracování signálů, které hodnotí stabilitu a pravidelnost pulzové vlny, stejně jako přítomnost očekávaných fyziologických charakteristik, jako je tvar vlny, amplituda a intervaly mezi pulzy. Při stanovení kvality PPG signálů je také možné využít pokročilejší metody strojového učení, které mohou klasifikovat signály automaticky na základě trénovacích dat značených odborníky [25].

Elgendi [25] klasifikoval PPG do tří tříd (výborná, přijatelná a nevhodná) jak znázorňuje Obr.4.1. Třída G1 reprezentuje nejkvalitnější PPG záznamy. Signály jsou charakterizovány svou pravidelností a dobře rozlišitelnými systolickými a diastolickými fázemi. Mají konzistentní amplitudu a minimum šumu nebo artefaktů. Tyto signály jsou považovány za nejspolehlivější a nejvhodnější pro klinické hodnocení a analýzu. Signály třídy G2 mají dobrou kvalitu, ale mohou obsahovat některé artefakty nebo menší nepravidelnosti. Tyto chyby však nemusí znemožňovat jejich klinické využití. Obvykle lze z těchto signálů extrahovat potřebné fyziologické informace. Třída G3 zahrnuje signály, které jsou zcela nevhodné pro diagnostiku. Bývají silně ovlivněny artefakty nebo šumem. Mohou vykazovat velké nepravidelnosti v amplitudě a frekvenci, což značně ztěžuje nebo absolutně znemožňuje interpretaci takových dat [25].



Obr. 4.1: PPG záznamy rozděleny podle kvality do tří tříd. Převzato a upraveno z [25].

4.1 Extrakce příznaků

Extrakce příznaků z PPG signálu je první krok pro následnou analýzu. Obvykle se začíná předzpracováním signálu, jako je filtrace signálu pro odstranění šumu a artefaktů. Následuje detekce charakteristických bodů, nejčastěji se detekují systolické peaky. Poté jsou z signálu extrahovány časové příznaky, jako je časová délka mezi peaky (PP intervaly), amplituda systolických a diastolických peaků, a šířka pulzní vlny. Frekvenční analýza může odhalit další příznaky. Morfologická analýza zkoumá tvar PPG signálu, odhaluje vzestupné a klesající úseky. Statistické metody, jako jsou např. popisné statistiky šikmost a špičatost, jsou používány k popisu distribuce signálu. Pro podrobnější zkoumání se v dnešní době často využívá analýza vlnkové transformace [16, 25].

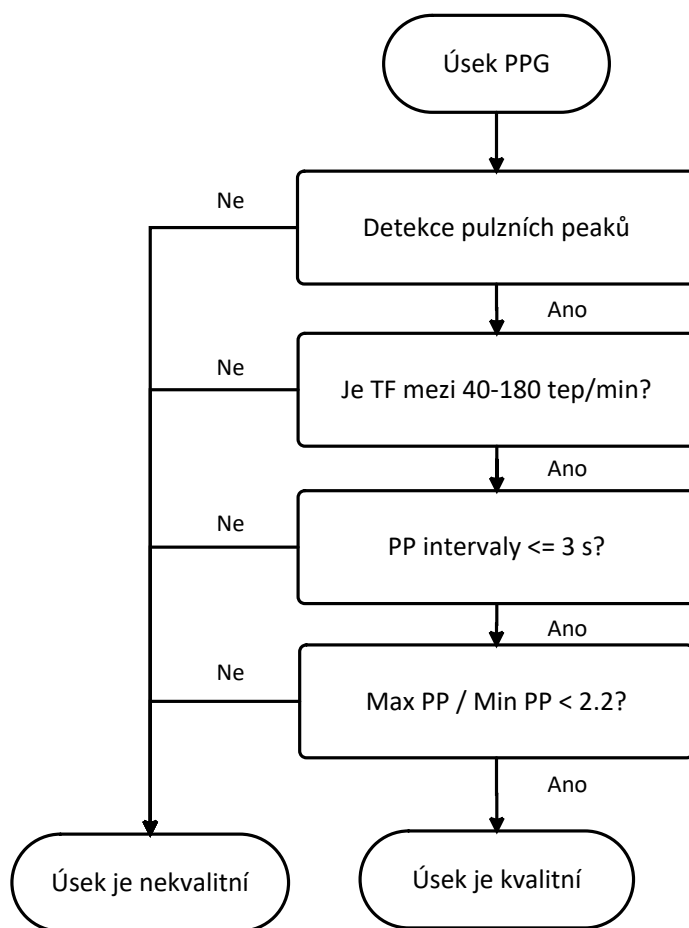
4.2 Stanovení kvality bez využití umělé inteligence

Metody stanovení kvality PPG bez využití umělé inteligence (AI) se zaměřují na základní analýzu signálu a využívají různé statistické, časové a frekvenční charakteristiky signálu. Existuje mnoho metod stanovení kvality PPG. Nejjednodušší metody používají souhrn kroků, které identifikují zřejmě nepřijatelné signály pomocí fyziolo-

gický parametrů [24]. Základem pro tyto metody je detekce pulzních peaků, což samo o sobě může být obtížné, vzhledem k morfologii PPG signálu. Algoritmy detekují tyto peaky a hodnotí jejich pravidelnost a intervaly mezi nimi. Nekvalitní signály mohou obsahovat náhodné nebo chybějící peaky způsobené pohybovými artefakty nebo šumem. Jestliže algoritmus neidentifikuje v signálu žádné peaky, tak se nejspíše jedná o chybný signál. Po detekci peaků v úseku PPG pak můžeme postupovat podle vývojového diagramu zobrazeného na Obr.4.2 [24]. Úsek signálu (obvykle 10 sekund) je označen jako nekvalitní jestliže:

- TF nespadá do rozmezí mezi 40 a 180 tepy za minutu.
- Intervaly mezi peaky (PP intervaly) jsou delší než 3 sekundy.
- Poměr mezi nejdelším PP intervalem a nejkratším PP intervalem je vyšší než 2,2.

Variace tohoto postupu mohou využívat i dalších parametrů např. šířku pulzní vlny PPG, její amplitudu a podobné [24, 27].



Obr. 4.2: Blokové schéma stanovení kvality z fyziologických limitů kardiovaskulární soustavy. Převzato a upraveno z [26].

Další používané metody se zabývají výpočtem indexů kvality signálu (SQI) a následnému porovnání s prahovými hodnotami pro kvalitní a nekvalitní úseky. Pro nastavení prahů, je nutné nejdříve signály anotovat a rozdělit je na kvalitní a nekvalitní. Nejběžnějšími ukazateli kvality jsou podle Elgendiho[25]:

- **Perfuze:** poměr mezi AC a DC složkou PPG signálu [25]. Je definována jako:

$$P_{SQI} = [(y_{max} - y_{min})/|\bar{x}|] \times 100, \quad (4.1)$$

kde P_{SQI} je index perfuze, $|\bar{x}|$ je statistický průměr nefiltrovaného PPG signálu a y je filtrovaný signál [25].

- **Koeficient šikmosti:** měří a popisuje asymetrii distribuce dat kolem své střední hodnoty [25]. Je definována jako:

$$S_{SQI} = 1/N \sum_{i=1}^N [x_i - \widehat{\mu}_x/\sigma]^3, \quad (4.2)$$

kde $\widehat{\mu}_x$ označuje empirický odhad průměru a σ empirický odhad směrodatné odchylky nefiltrovaného signálu $[x_i]$. N představuje počet vzorků signálu [25].

- **Koeficient špičatosti:** statistický ukazatel charakterizující, jak výrazně jsou hodnoty pravděpodobnostního rozdělení koncentrované kolem středu distribuce [25]. Je definován jako:

$$K_{SQI} = 1/N \sum_{i=1}^N [x_i - \widehat{\mu}_x/\sigma]^4, \quad (4.3)$$

kde $\widehat{\mu}_x$ označuje empirický odhad průměru a σ empirický odhad směrodatné odchylky nefiltrovaného signálu $[x_i]$. N představuje počet vzorků signálu [25].

- **Entropie:** vyjadřuje, jak dobře lze předpovídat následující hodnotu signálu na základě předchozích hodnot [25]. Je definována takto:

$$E_{SQI} = - \sum_{n=1}^N x[n]^2 \log_e(x[n]^2), \quad (4.4)$$

kde x je nefiltrovaný signál a N je počet vzorků tohoto signálu [25].

- **Počet průchodu nulou (ZCR):** udává, jak často se signál mění svým znaménkem, tedy frekvence s jakou se signál mění z kladné hodnoty na zápornou nebo naopak [25]. Je definován takto:

$$Z_{SQI} = 1/N \sum_{n=1} \mathbb{I}\{y < 0\}, \quad (4.5)$$

kde y je filtrovaný PPG signál, N je počet vzorků tohoto signálu a \mathbb{I} je indikátorová funkce, $\mathbb{I}\{A\}$ je 1 jestliže je argument A pravdivý, jinak 0 [25].

- **Poměr signálu k šumu (SNR):** vyjadřuje poměr rozptylu signálu a rozptylu šumu v signálu [25]. Je definován takto:

$$N_{SQI} = \frac{\sigma_{\text{signál}}^2}{\sigma_{\text{šum}}^2}, \quad (4.6)$$

kde $\sigma_{\text{signál}}^2$ je směrodatná odchylka absolutní hodnoty filtrovaného signálu a $\sigma_{\text{šum}}^2$ je směrodatná odchylka filtrovaného signálu [25].


Prahy pro klasifikaci mohou být nastaveny heuristicky, ovšem takto nastavené prahové hodnoty, mohou být přizpůsobeny konkrétní sadě dat. Výkonnost klasifikace pak nemusí být dostatečná při práci s jinými daty [24].

4.3 Stanovení kvality s využitím umělé inteligence

Stanovení kvality PPG s využitím umělé inteligence a strojového učení umožňuje zautomatizovat a zpřesnit procesy, které by jinak vyžadovaly značnou míru lidského úsilí a subjektivního hodnocení. Metody, které využívají umělou inteligenci, mohou mít velmi přesné výsledky, tím zjednodušují analýzu a zvyšují efektivitu diagnostiky [24, 28]. Mezi klasické metody strojového učení patří:

- **Metoda podpůrných vektorů (SVM):** Tento algoritmus strojového učení je využíván pro klasifikaci, regresi a detekci vzorů v datech. Při klasifikaci PPG dat SVM identifikuje hyperrovinu (nadrovinu) nebo sady hyperrovin, které dokáží optimálně rozdělit signály na kvalitní a nekvalitní. Mohou využívat tzv. kernelové triky, které dokáží transformovat původní příznaky do nových prostorů, kde mohou být lineárně odděleny, což zlepšuje výkon modelu při klasifikaci složitějších dat. Běžně používanými kernely jsou lineární, polynomické a RBF (Radial Basis Function) [29, 30].
- **K-nejbližších sousedů (KNN):** KNN je jeden z nejjednodušších algoritmů strojového učení. Je to metoda používaná pro klasifikaci a regresi, která přiřazuje objektům třídu na základě toho, jaké třídy mají jejich nejbližší sousedé v trénovacím datasetu. Nový datový bod tedy bude přiřazen ke skupině, které je si nejvíce podobný, znázorněno na Obr.4.3. Podobnost se může počítat pomocí několika vzdálenostních metrik, jako např. Euklidovská vzdálenost, či Manhattanová vzdálenost. Důležitý parametr této metody je parametr K , který udává počet nejbližších sousedů. Tento parametr by měl být zvolen na základě vstupních dat. Pokud vstupní data obsahují více odlehlých hodnot nebo šumu, je obvykle lepší vyšší hodnota K . Hlavní nevýhodou algoritmu je, že při práci s velkými datasety se stává výpočetně náročným [31].
- **Rozhodovací stromy:** Tato metoda se využívá pro klasifikační i regresní úlohy. Tato metoda modeluje rozhodovací proces pomocí stromové struktury,

kde každý uzel reprezentuje otázku nebo test na jednom nebo více příznacích. Každá větev z tohoto uzlu pak odpovídá možné odpovědi. Série těchto otázek vede k postupnému rozdělování datové sady a nakonec k určení cílové třídy nebo hodnoty. K určení, jak efektivně uzel odděluje různé třídy, se často používají metriky jako Giniho index nebo entropie. Rozhodovací stromy jsou snadno vizualizovatelné a jejich výsledky lze dobře interpretovat. Je ovšem nutné správně nastavit podmínky pro ukončení, jelikož jsou náchylné k přetrénování. To může vést k nadměrně komplikovaným modelům, které nejsou schopné generalizovat na nová data [30].



Obr. 4.3: Ilustrace modelu KNN pro dva příznaky x_1 a x_2 . Převzato a upraveno z [31]

Pokročilejší metody využívající umělou inteligenci, jako např. konvoluční neuronové sítě (CNN) mohou poskytovat velmi vysokou přesnost v klasifikaci kvality PPG signálů. V článku [32] dosáhli přesnosti stanovení kvality až 97,5 %, právě pomocí CNN. Umožňují také snížit potřebu předzpracování signálu, resp. je možné se vyhnout počítání jednotlivých příznaků ze signálu, v článku [33] použili 60 sekundový PPG záznam jako vstupní data do CNN. Nevýhodou této a dalších pokročilých metod bývá fakt, že vyžadují obrovské množství trénovacích dat a výpočetních zdrojů k efektivnímu naučení [34].


Nicméně existují techniky, které mohou snížit množství potřebných dat a zároveň udržet nebo dokonce zlepšit výkon modelů. Například, metody jako je *transfer learning*, umožňuje efektivněji využívat dostupná data. *Transfer learning* zahrnuje převzetí modelu, který byl předtím natrénován na rozsáhlých a obecných datových sadách, a jeho následném doladění pro určité úlohy, což může snížit potřebu nových trénovacích dat [34]. Další technikou, která může pomoci překonat omezení velkého

množství dat, je použití augmentace dat, kde jsou stávající data uměle rozšířena pomocí různých technik. Pro signálová data mohou takové modifikace být např. přidání šumu, změna amplitudy signálu, filtrace signálu či časová deformace. Tyto metody mohou pomoci modelu lépe generalizovat a zlepšit jeho odolnost vůči přeučení [34].

Obecně metody umělé inteligence mohou mít velmi přesné výsledky, ovšem nemusí být vždy zcela pochopeno spojení, mezi použitými příznaky a výsledným stanovením kvality. Jelikož nemusí být jasné, jak bylo výsledků dosaženo, může být těžké předvídat omezení systému. V klinickém prostředí pak může být složité výsledky interpretovat a vysvětlit rozhodnutí modelu, což může omezovat jejich klinickou přijatelnost [24, 28].

4.4 Hodnocení algoritmů klasifikace

Pro hodnocení klasifikačních modelů se používá několik metrik, které pomáhají určit výkon a efektivitu klasifikace. Jsou také velmi praktické pro porovnávání modelů. Pro kompletní pohled na výkon klasifikačního modelu může být vykreslena matice záměn, pro ilustraci zobrazena na Obr.4.4.



Obr. 4.4: Matice záměn

Matice záměn zobrazuje počet skutečných a predikovaných instancí pro každou třídu. Kde TP je počet správně klasifikovaných pozitivních instancí, TN je počet správně klasifikovaných negativních instancí, FP je počet nesprávně klasifikovaných negativních instancí jako pozitivní a FN je počet nesprávně klasifikovaných pozitivních instancí jako negativní. Z matice záměn lze vypočítat metriky jako:

- **Přesnost:** Základní metrika pro hodnocení klasifikačního modelu, která udává, jak dobře model správně klasifikuje instance. Vzorec pro výpočet přesnosti je [24, 30]:

$$Přesnost = \frac{TP + TN}{TP + TN + FP + FN}, \quad (4.7)$$

- **Senzitivita:** Měří schopnost modelu správně identifikovat pozitivní instance. Vzorec pro výpočet senzitivity je [24, 30]:

$$Senzitivita = \frac{TP}{TP + FN}, \quad (4.8)$$

- **Specifita:** Měří schopnost modelu správně identifikovat negativní instance. Vzorec pro výpočet specifity je [24, 30]:

$$Specifita = \frac{TN}{TN + FP}, \quad (4.9)$$

- **F1 skóre:** Metrika, která je vhodná v případě nevyvážených tříd. Zahrnuje jak přesnost modelu, tak jeho schopnost detekovat všechny pozitivní případy. Vzorec pro F1 skóre je [30]:

$$F1 = \frac{2 \cdot TP}{2 \cdot TP + FP + FN}, \quad (4.10)$$

Další užitečnou metrikou je plocha pod ROC křivkou. ROC křivka je dvou-rozměrné zobrazení výkonnosti klasifikátoru. Jestliže vypočítáme plochu pod touto křivkou, dostaneme hodnotu mezi 0 a 1, kde hodnota 1 značí perfektní klasifikátor a hodnota 0,5 náhodný klasifikátor. Žádný klasifikátor by neměl mít plochu pod ROC menší než 0,5, jelikož by to znamenalo, že i náhodná klasifikace by přinášela lepší výsledky [30, 35].

5 Stanovení TF z PPG

Přímočará metoda pro stanovení TF z PPG je detekce systolických peaků. Jelikož je každý vrchol v časovém záznamu přímo spojen s konkrétním srdečním úderem, je tato metoda intuitivní a srozumitelná. Avšak implementace takové metody může být technicky náročná. Jedním z hlavních omezení této metody je vysoká náchylnost k šumu a artefaktům, které mohou v PPG signálech vznikat, zejména v důsledku pohybu. Toto rušení může vést k detekci falešných peaků nebo k přehlížení skutečných peaků, což vyžaduje použití různých algoritmů pro filtraci a analýzu signálu.

Ve studii [36] nejdříve signál filtrovali a poté byl signál diferencován. To může pomoci odhalit změny v signálu, které odpovídají rychlým změnám v průtoku krve, které jsou způsobené srdečními údery. Po diferenciaci vypočítali 75. percentil amplitud diferencovaného signálu. Tento práh slouží k identifikaci peaků, které mají větší amplitudu než 75 % ostatních hodnot v signálu. Peaky nad tímto prahem jsou považovány za potenciální srdeční údery. Výběr 75. percentilu je kompromisem mezi zachycením všech srdečních tepů a minimalizací falešně pozitivních detekcí. Po detekci peaků se následně, obvykle z 10 s záznamu, spočítá medián TF.

Další z možných metod stanovení TF je popsána v článku [37]. Autoři aplikují algoritmus rychlé Fourierovy transformace (FFT) pro získání diskrétní Fourierovy transformace (DFT) signálu. Vzorec pro DFT je definován následovně [37]:

$$X^{(N)}(K) = \sum_{n=0}^{N-1} x(n)e^{-j2\pi kn/N}, \quad (5.1)$$

kde $X^{(N)}(K)$ je K -tá složka DFT signálu $x(n)$ o délce N , $x(n)$ jsou hodnoty signálu ve časové oblasti a $e^{-j2\pi kn/N}$ je komplexní exponenciála, která reprezentuje frekvenční složky v daném okamžiku [38].

FFT převádí signál časového záznamu do frekvenční oblasti. Z výsledků FFT je možné vypočítat amplitudy frekvenčních složek. Jednotlivé amplitudy představují intenzitu jednotlivých frekvencí v signálu. Pro stanovení TF identifikujeme frekvenční složku, která má nejvyšší amplitudu. Na Obr.5.1 je červenou značkou znázorněna frekvenční složka, která odpovídá TF.

Variace tohoto postupu je využití Lomb-Scargle Periodogramu (LSP), tato metoda přizpůsobuje sinusoidální funkce k datům, za účelem odhalení periodicity. Vzorec pro výpočet LSP je následující [39]:

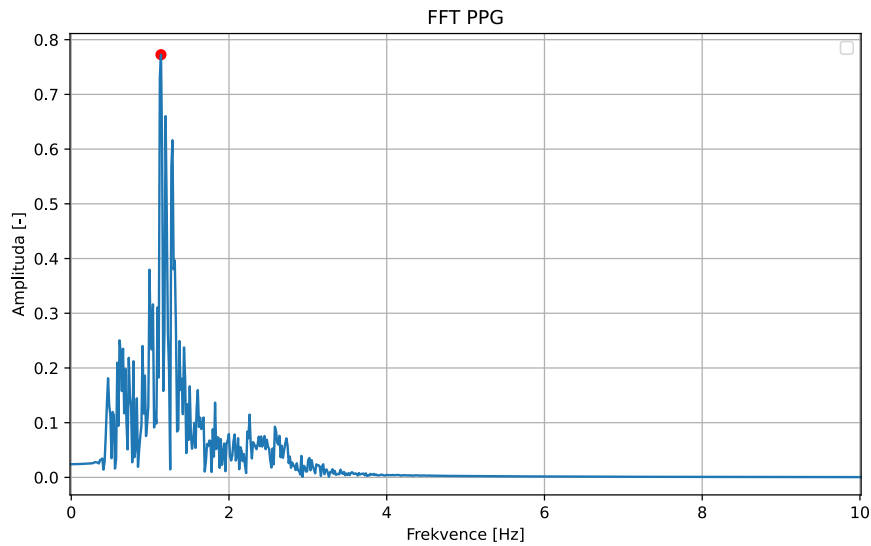
$$P(f) = \frac{1}{2\sigma^2} \left(\frac{[\sum_n (y_n - \bar{y}) \cos \omega(t_n - \tau)]^2}{\sum_n \cos^2 \omega(t_n - \tau)} + \frac{[\sum_n (y_n - \bar{y}) \sin \omega(t_n - \tau)]^2}{\sum_n \sin^2 \omega(t_n - \tau)} \right) \quad (5.2)$$

$P(f)$ je výkonová spektrální hustota jako funkce frekvence f , y_n jsou jednotlivé naměřené hodnoty signálu, \bar{y} je průměrná hodnota naměřených hodnot, σ je směro-

datná odchylka naměřených hodnot, ω je úhlová frekvence ($\omega = 2\pi f$), t_n jsou časové okamžiky jednotlivých měření a τ je časový posun, definovaný jako:

$$\tau = \frac{1}{4\omega} \tan^{-1} \left(\frac{\sum_n \sin 2\omega t_n}{\sum_n \cos 2\omega t_n} \right) \quad (5.3)$$

Následné kroky pro odhalení TF, jsou stejné jako po aplikaci FFT, čili odhalení dominantní frekvence. Obecně se LSP používá pro odhadování spektrální hustoty výkonu, při práci s nerovnoměrně vzorkovanými daty. LSP může lépe zvládat šum a odlehlé hodnoty ve srovnání s klasickým periodogramem [40]. Podle článku [41] umožňuje zohlednit přirozenou variabilitu RR intervalů a lépe si poradí s mezerami v souboru dat, umožňující přesnější analýzu, která je méně ovlivněna ektopickými nebo chybějícími kmity.



Obr. 5.1: Spektrum signálu získané pomocí FFT. Spektrální čára s největší amplitudou je označena červenou značkou. Převzato a upraveno z [37]

Pokročilejší způsob stanovení TF používá stacionární vlnkovou transformaci (SWT) pro analýzu PPG signálu. Jedná se o metodu, která efektivně odděluje užitečné signálové složky od šumu a artefaktů. SWT je aplikována na předzpracovaný signál a výsledkem transformace jsou různé komponenty (úrovně), které reprezentují signál v různých frekvenčních pásmech. Každá úroveň poskytuje informace o určité části frekvenčního spektra signálu. Pro stanovení TF nás zajímají hlavně frekvenční pásma, kde jsou fyziologicky očekávány frekvence odpovídající srdečnímu tepu. Vyšší frekvenční pásma, která mohou obsahovat převážně šum nebo artefakty, jsou často

ignorována. V relevantních frekvenčních pásmech se hledají vrcholy, které odpovídají systolám v srdečním cyklu. Nalezení těchto vrcholů může být automatizováno pomocí algoritmů pro detekci vrcholů, které vyhledávají lokální maxima v signálu. Po identifikaci vrcholů se měří intervaly mezi nimi a vypočítává se TF jako medián nebo průměr frekvencí z těchto intervalů, převedených na tepy za minutu [42, 43].

6 Snímání dat

Pro praktickou část této bakalářské práce byla vytvořena databáze obsahující 22 EKG záznamů a videí obličeje. Měření podstoupilo celkově 11 účastníků, 10 mužů ve věku od 21 až po 23 let a jedna žena ve věku 21 let. Každá měřená osoba byla seznámena s riziky a s průběhem měření, poté podepsala informovaný souhlas.

Snímání PPG záznamu bylo prováděno pomocí chytrého mobilního telefonu Samsung Galaxy S10e vybaveného 12 Mpx senzorem. Rozlišení videa bylo nastaveno na 1920×1080 px, se vzorkovací frekvencí 60 Hz (snímků za sekundu). Vyvážení bílé bylo nastaveno na 4200 K.

Jakožto reference byl nasnímán jednosvodový EKG signál přístrojem Bittium Faros 180. EKG signál byl nasnímán vzorkovací frekvencí 1000 Hz. Pro kontakt s kůží měřené osoby byly použity elektrody Kendall H34SG. Před aplikací byla pokožka omyta a odmaštěna. Elektrody byly umístěny podle Obr.6.1.

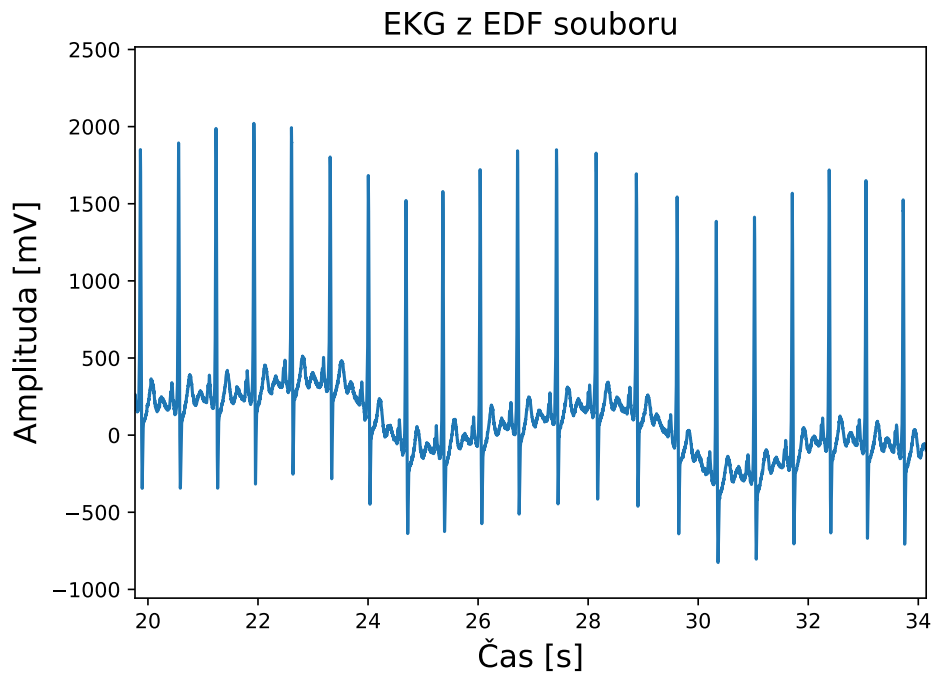


Obr. 6.1: Doporučené umístění elektrod [44]

Oba záznamy byly načteny a zpracovány v programovacím jazyce Python. Pro práci s videozáznamem byla využita knihovna OpenCV a pro práci s EKG záznamem knihovna PyEDFlib. Ukázka nezpracovaného EKG záznamu je zobrazena na Obr.6.2.

6.1 Protokol měření

Účastníkovi byly připevněny elektrody pro měření EKG signálu. Dále byl posazen metr před kameru mobilního telefonu. Měřená osoba se snažila zůstat co nejvíce v

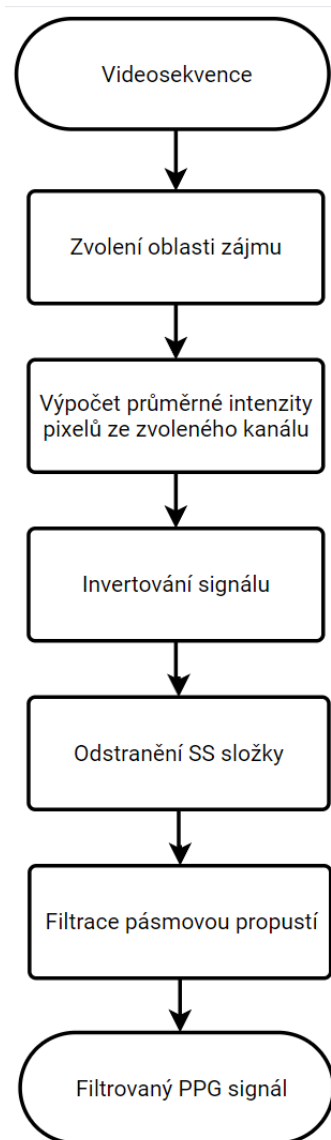


Obr. 6.2: Úsek nezpracovaného EKG záznamu

klidu po dobu jedné minuty. Poté bylo nahrávání EKG a videa ukončeno a účastník byl vyzván k provedení 30 dřepů. Po zátěži se účastník znovu posadil a spustilo se nahrávání, které opět trvalo jednu minutu. Tímto postupem byla získána data z období klidu a po fyzické zátěži.

7 Předzpracování dat

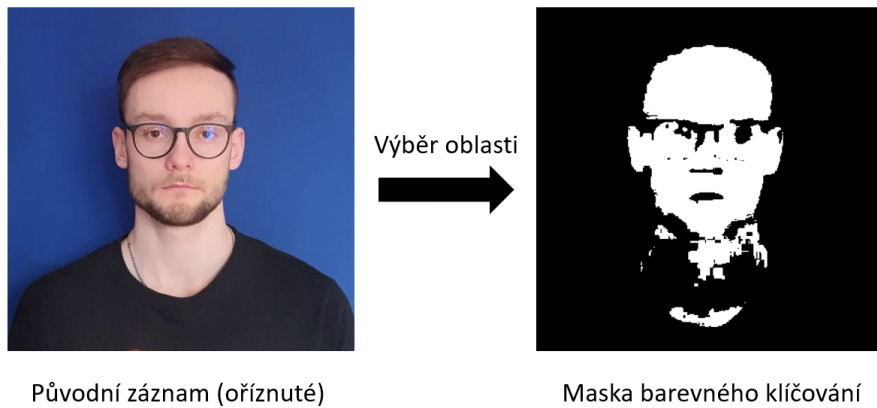
Prvním krokem algoritmu bylo zpracování videosekvence do podoby PPG signálu. Celý postup je znázorněn v blokovém schématu na Obr.7.1.



Obr. 7.1: Blokové schéma akvizice PPG signálu


Nejdříve byla zvolena oblast zájmu (ROI), ze které byl vypočítán PPG signál. Původně bylo zamýšleno použití metody barevného klíčování pro výběr obličeje. Program zobrazil sérii snímků náhodně vybraných z celého záznamu a uživatel následně vybral odstín obličeje, který zajistil optimální pokrytí masky. ROI se přepočítala každou sekundu, čili každých 60 snímků. Tato metoda výběru ROI je zobrazena na Obr.7.2, bílá maska značí, jaká část obrazu bude použita k výpočtu PPG signálu. Hlavní nevýhoda této metody je její výpočetní náročnost a obecně nižší kvalita

získaného PPG záznamu.



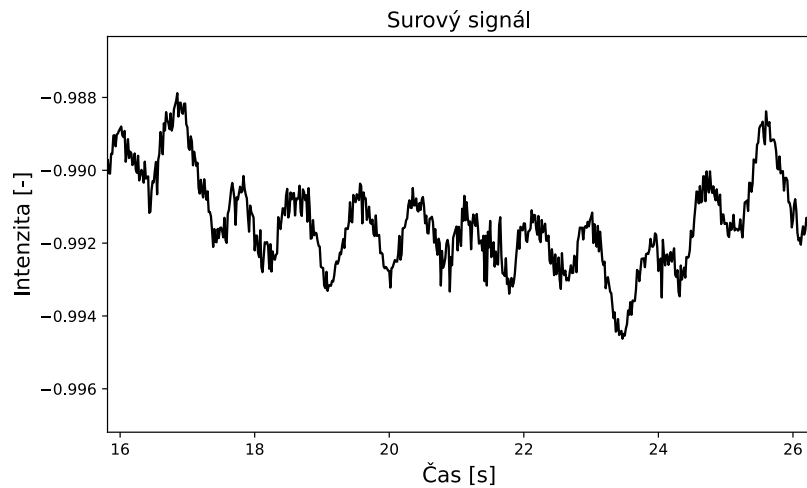
Obr. 7.2: Výběr oblasti zájmu pomocí barevného klíčování

Proto byla pro další analýzu zvolena automatická detekce obličeje podle článku [37], upravená pro účely této práce. Tato metoda nejprve automaticky detekuje obličej z prvních dvou sekund záznamu a spočítá průměrnou pozici obličeje. Z této pozice je poté vybrána ROI z čela. Protože jedna měřená osoba měla v čele vlasy, byla přidána funkce, která detekuje, zda se v zadané ROI nacházejí vlasy. Tato funkce převádí ROI na odstíny šedi a vypočítá průměrnou intenzitu pixelů. Pokud je průměrná intenzita menší než 50, znamená to, že se v ROI nacházejí vlasy a algoritmus automaticky vybere líce jako novou ROI. Pro účely této práce pracuje tato funkce dostatečně, avšak její použití je omezené pouze na tmavé odstíny vlasů. Výběr ROI je zobrazen na Obr.7.3.

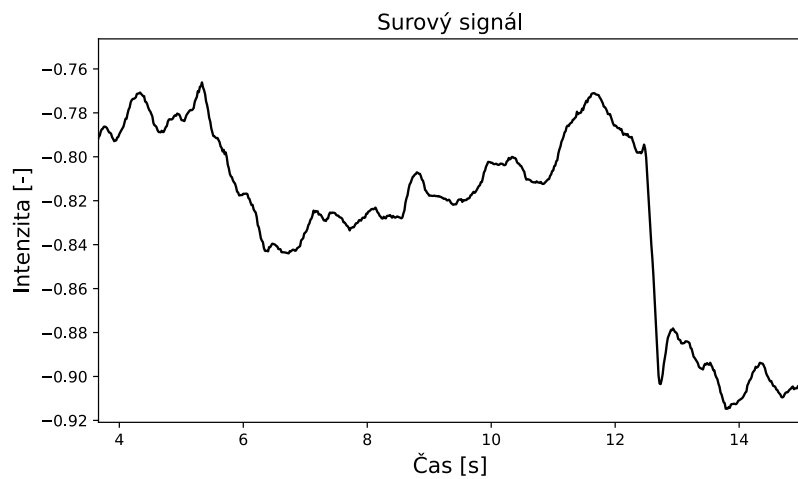


Obr. 7.3: Výběr oblasti zájmu pomocí automatické detekce obličeje

Poté byla pro každý snímek vypočítána průměrná intenzita pixelů jednotlivých snímků. Signál byl vypočítán pouze ze zeleného kanálu [17]. Jelikož signál získáváme pomocí odrazu světla od tkáně, je vhodné signál invertovat. Získaný surový signál s dobrou kvalitou je zobrazen na Obr.7.4. Nekvalitní úsek signálu je zobrazen na Obr.7.5, tyto nekvalitní záznamy jsou způsobeny nejčastěji mimovolným pohybem hlavy, či obličejových svalů měřené osoby, a také nekonstantním osvětlením obličeje, při jeho snímání.

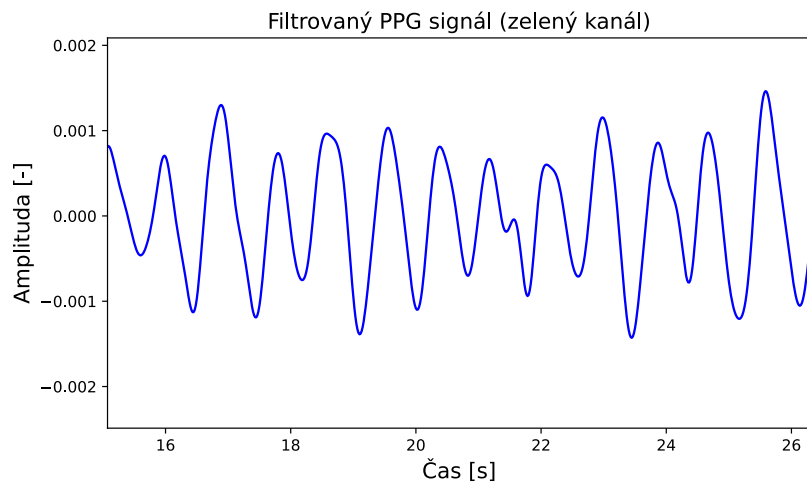


Obr. 7.4: Surový PPG signál – kvalitní



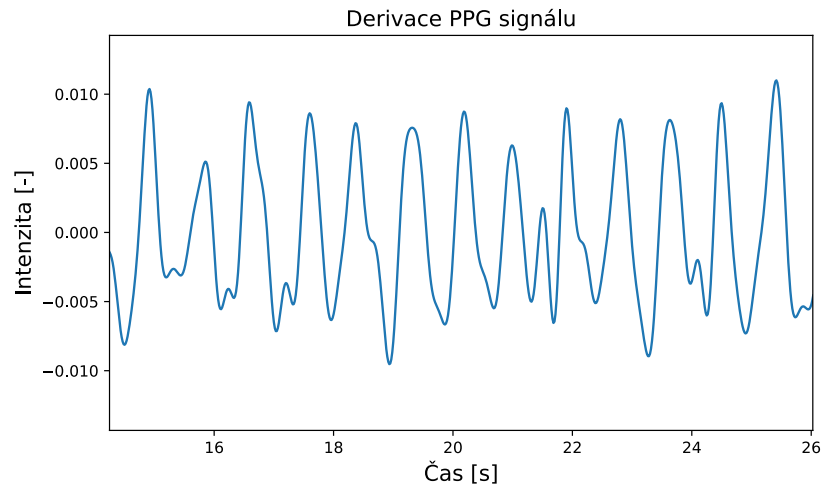
Obr. 7.5: Surový PPG signál – nekvalitní

Dalším krokem bylo signál filtrovat a získat z něj tak pouze pulzující AC složku, která se stává základem pro další práci se signálem. Podle doporučené literatury [37] byl použit Butterworthův filtr 5. řádu typu pásmová propust, s mezními frekvencemi 0,5 Hz a 3,1 Hz. Filtrovaný signál je zobrazen na Obr.7.6.



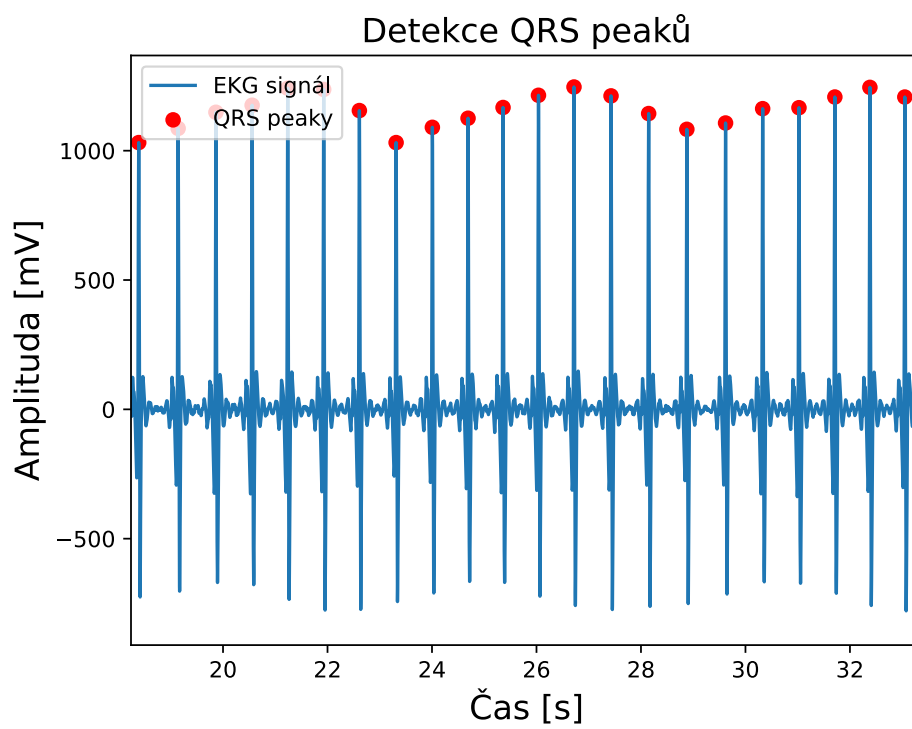
Obr. 7.6: Filtrovaný PPG signál

Pro vhodnější vyhodnocení TF ze signálu, byl signál numericky derivován. Konkrétně byl vytvořen gradient mezi každými dvěma sousedními hodnotami v poli signálu. Tato derivace lépe zachycuje rychlost změny získaného signálu v čase a lze dokonaleji odečíst srdeční cykly [37]. Derivaci signálu ilustruje Obr.7.7.



Obr. 7.7: Derivovaný PPG signál

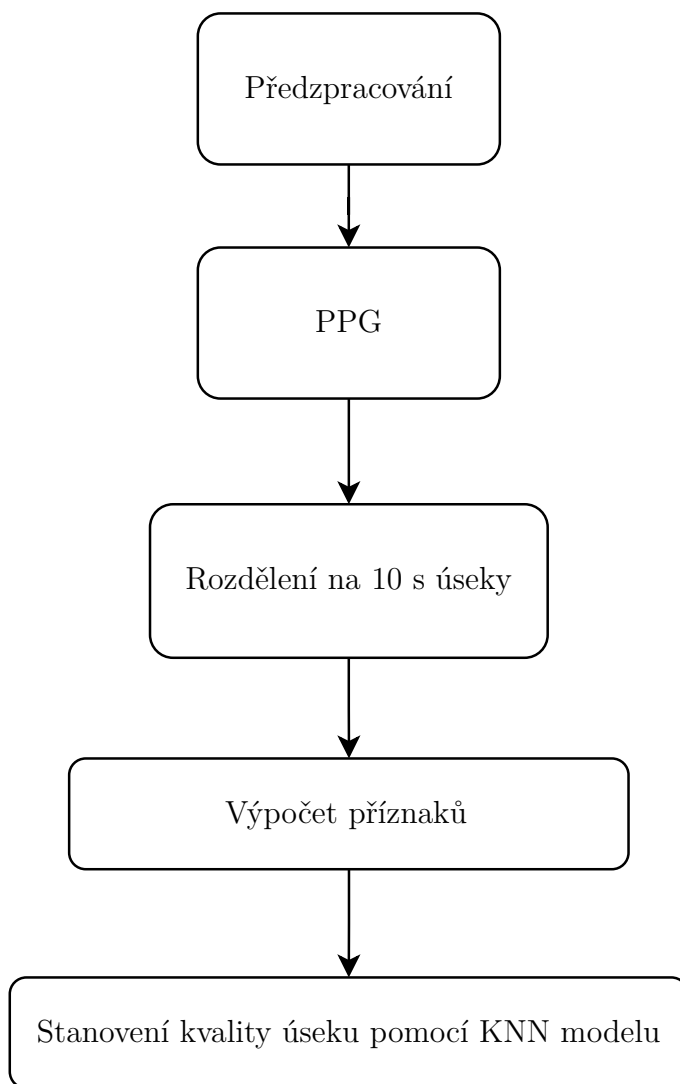
Jakožto reference byl pořízený EKG záznam. Ten byl filtrován pomocí Butterworthova filtru 5. řádu typu pásmová propust, s mezními frekvencemi 8 Hz a 100 Hz. Mezní frekvence byly vybrány heuristicky, pro zvýraznění QRS komplexů. Filtrovaný signál je zobrazen na Obr.7.8. Z filtrovaného EKG signálu byly nalezeny pozice QRS peaků pomocí jednoduchého prahování. Prahová hodnota byla nastavena na 98. percentil amplitudy celého signálu. Všechny záznamy byly vizuálně zkontrolovány.



Obr. 7.8: Úsek filtrovaného EKG s označenými R vlnami

8 Algoritmus stanovení kvality záznamu


Pro stanovení kvality záznamu se dá využít mnoho různých metod, či jejich kombinace. Postup stanovení kvality použit v této práci je znázorněn v blokovém schématu na Obr.8.1. Nový PPG záznam byl předzpracován, rozdělen na 10 s úseky a byly vypočítány příznaky. Následně KNN model ohodnotil kvalitu úseku.



Obr. 8.1: Hodnocení modelu KNN pomocí průměrné přesnosti klasifikace


Pro učení modelu byl minutový záznam PPG převzorkován na vzorkovací frekvenci referenčního EKG, poté byly záznamy synchronizovány. Dále bylo PPG zpracováváno po 10 s úsecích, z těchto úseků bylo vypočítáno 6 příznaků: perfuze (4.1), šikmost (4.2), špičatost (4.3), entropie (4.4), počet průchodů nulou (4.5) a poměr signálu k šumu (4.6). Tyto příznaky jsou popsány v kapitole 4.2. Bylo vytvořeno frekvenční spektrum daného úseku, kdy frekvence s nejvyšší amplitudou byla pova-

žována za TF. Tato TF byla porovnána s TF referenčního EKG záznamu. Jestliže se TF mezi PPG a EKG záznamem lišila o více než 5 tepů za minutu, byl 10 sekundový úsek PPG označen jako nekvalitní, jinak byl označen za kvalitní. Celkově bylo takto zhodnoceno 137 záznamů, jelikož pět měření trvalo 70 s a tyto úseky byly ponechány v analýze. Z těchto záznamů bylo 68 označených jako kvalitní a 69 záznamů jako nekvalitní, jak znázorňuje histogram na Obr.8.2. Každý úsek signálu byl tedy popsán svou kvalitou a šesti příznaky.




Obr. 8.2: Histogram rozdělení kvality úseků do dvou tříd

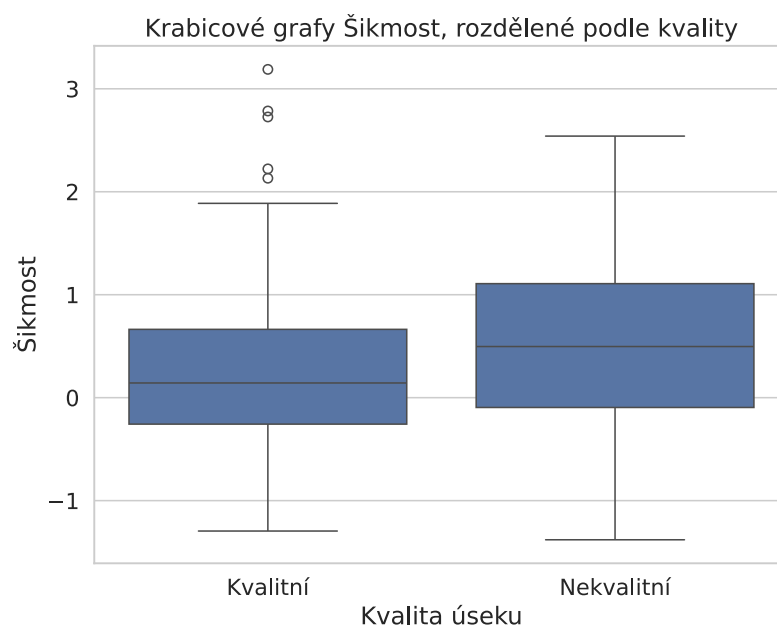
Pro příznaky byly vytvořeny krabicové grafy, k zobrazení rozložení dat mezi kvalitním PPG a nekvalitním PPG. Lze vidět, že dochází ke značnému překrytí mezi kvalitními a nekvalitními signály. Nejlepší rozdělení kvality zajišťuje entropie signálu, avšak i tyto hodnoty se mezi sebou překrývají. Příznaky šikmosti a špičatosti se překrývají hodně mezi kvalitními a nekvalitními signály, a tak mohou být méně podstatné pro vyhodnocení kvality. Pro lepší vizualizaci rozložení kvalitních a nekvalitních signálů byla použita metoda analýzy hlavních komponent (PCA), znázorněna na Obr.8.3, která redukuje všechny použité příznaky do dvou hlavních komponent (PC) na základě největšího rozptylu v datech. PC1 přispívá k 49 % celkového rozptylu, PC2 se podílí na 26 % celkového rozptylu, dohromady se tedy podílí na 75 % variace v datech.




Obr. 8.3: Analýza hlavních komponent z šesti příznaků. 1 – kvalitní, 0 – nekvalitní




Obr. 8.4: Krabicové grafy pro perfuzi kvalitních a nekvalitních úseků




Obr. 8.5: Krabicové grafy šikmosti kvalitních a nekvalitních úseků




Obr. 8.6: Krabicové grafy špičatosti kvalitních a nekvalitních úseků



Obr. 8.7: Krabicové grafy entropie kvalitních a nekvalitních úseků



Obr. 8.8: Krabicové grafy pro ZCR kvalitních a nekvalitních úseků



Obr. 8.9: Krabicové grafy pro SNR kvalitních a nekvalitních úseků

Pro statistické zhodnocení relevantnosti příznaků byl aplikován Shapiro-Wilkův test, pro zjištění, zda jsou data normálně rozdělena. Výsledky ukázaly, že pro všechny příznaky byla p-hodnota mnohem menší než 0,05, což znamená, že příznaky nejsou normálně rozděleny. Následně byl na příznaky aplikován neparametrický Mann-Whitneyho U test, aby se zjistilo, zda existují statisticky významné rozdíly mezi kvalitními a nekvalitními úseky PPG signálu. Výsledky, zobrazeny v Tab.8.1, ukázaly, že příznaky perfuze, entropie, SNR a ZCR vykazují statisticky významné rozdíly mezi kvalitními a nekvalitními úseky PPG signálu. Naopak příznaky šikmost a špičatost nevykazují statisticky významné rozdíly mezi těmito skupinami.

Tab. 8.1: Výsledky Mann-Whitney U testu pro jednotlivé příznaky


Příznak	p-hodnota
Šikmost	0.087038
Špičatost	0.050901
Perfuze	7.85e-08
Entropie	1.42e-07
SNR	0.000721
ZCR	0.000240

V dalším kroku byla databáze záznamů použita k trénování modelů strojového učení. Jelikož naměřená databáze obsahuje relativně málo záznamů, byla využita v následujících testováních metoda křížové validace [30], pro maximální využití dostupných dat a k přehlednějším a objektivnějším výsledkům. Byl využit typ metody pod jménem skupinová k-násobná křížová validace. Křížová validace spočívá v rozdělení datasetu na k podskupin (trénovací a testovací) a testování proběhne k krát, takže každá podskupina je právě jednou použita jako testovací sada. Skupinová křížová validace upravuje klasickou křížovou validaci tak, aby zajistila, že se vzorky stejné skupiny, čili úseky jednoho měření, nedostanou jak do skupiny dat, na kterých se bude model učit, tak do skupiny dat, na kterém se model bude testovat. V tomto řešení byl parametr k nastaven na 5, tedy 80 % záznamů bylo využito na učení a zbylých 20 % na testování.


8.1 Model KNN

První testovaný model byl model KNN. U tohoto modelu je nejpodstatnější zvolit správný počet K , neboli počet nejbližších sousedů, které algoritmus zohlední při rozhodování o třídě nového bodu. Je obecně vhodné vybrat liché číslo, aby se zamezilo remízám v rozhodování. Pro objektivnější určení parametru K , je možné

graficky znázornit chování modelu s narůstajícím počtem K . Tato metoda je vizuální a pomáhá určit, jaký počet K , by měl být použit ke klasifikaci dat tak, aby byly výsledky co nejlepší, a zároveň nedocházelo k nadbytečnému dělení. Výkon lze hodnotit několika metrikami, které jsou popsány v sekci 4.4. V tomto řešení byla použita přesnost klasifikace modelu a plocha pod křivkou (AUC) ROC. Tyto vizualizace jsou zobrazeny na Obr.8.10 a Obr.8.11. Z grafů lze vidět, že se výkonost modelu výrazně zvyšuje, když se počet sousedů K zvyšuje z 1 na přibližně 10 a následně se po dosažení optimálního počtu sousedů K (okolo 10–15), výkonost modelu začíná stabilizovat a příliš se nemění, případně i klesá.




Obr. 8.10: Hodnocení modelu KNN pomocí průměrné přesnosti klasifikace



Obr. 8.11: Hodnocení modelu KNN pomocí průměrné plochy pod ROC křivkou

Dále byly pro různá K testovány všechny kombinace příznaků, bylo také testováno zda má na klasifikaci vliv odstranění odlehlých hodnot. Testování ukázalo, že pro nejlepší klasifikaci je vhodné ponechat všechny příznaky beze změny a parametr K nastavit na 13. Následně byla vykreslena matice záměn Obr.8.12, dále Tab. 8.2 prezentuje hodnocení modelu dvěma metrikami a jejich směrodatnými odchylkami. Z výsledků lze usoudit, že model poskytuje vyvážený výkon při klasifikaci kvalitních a nekvalitních úseků PPG signálu, je ovšem méně stabilní než druhý testovaný model SVM.



Obr. 8.12: Matice záměn pro model KNN


Tab. 8.2: Hodnocení modelu KNN pro stanovení kvality úseků signálu

Metrika	Hodnota [%]
Průměrná přesnost	73,13 ± 6,34
Průměrné ROC AUC	73,61 ± 7,23

8.2 Model SVM

Druhá testovaná metoda byla SVM. U této metody je důležité vybrat vhodný kernel (jádro). V této práci byl použit RBF kernel. Hyperparametry modelu SVM s RBF jádrem, byly optimalizovány pomocí metody Grid Search [30]. Grid Search prochází

všechny kombinace zadaných hyperparametrů a zvolenou metrikou hodnotí model pro každou kombinaci. Touto metodou byly získány parametry $C = 100$ a $gamma = 0,01$. Dále byly stejně jako pro KNN model zhodnoceny všechny kombinace příznaků. Jako nejlepší se prokázala kombinace příznaků perfuze, šikmost a SNR. Na Obr.8.13 lze vidět matici záměn a v Tab. 8.3 lze vidět průměrnou přesnost modelu a jeho diskriminační schopnost.



Obr. 8.13: Matice záměn pro model SVM

Tab. 8.3: Hodnocení modelu SVM pro stanovení kvality úseků signálu

Metrika	Hodnota [%]
Průměrná přesnost	$70,74 \pm 3,76$
Průměrné ROC AUC	$75,31 \pm 5,07$

9 Stanovení tepové frekvence

V této kapitole jsou popsány různé metody použité pro stanovení TF, včetně detekce peaků, spektrální analýzy pomocí periodogramu a Lomb-Scargle periodogramu, a kombinace metod:

1. **Stanovení TF pomocí detekce peaků:** Tato metoda využívá detekci peaků v PPG signálu k výpočtu TF. PPG signál sleduje změny objemu krve v tkáňích, které korelují s tepovou frekvencí. Vrcholy byly detekovány v numericky derivovaném PPG signálu, pomocí funkce, která hledá lokální maxima v daném signálu. Vrcholy byly hledány v 10 s úsecích s fixním prahem odpovídající 63. percentilu maximální amplitudy tohoto úseku. Tento práh určuje minimální výšku peaků, ze kterých bude následně počítána TF. Pro nastavení prahu bylo testováno rozmezí mezi 30. a 95. percentilem. Pro posouzení nejlepšího prahu byly TF z PPG porovnány s referencí a hodnoceny pomocí Pearsnova korelačního koeficientu. Algoritmus měl také nastavenou minimální vzdálenost mezi peaky, a to na třetinu vzorkovací frekvence. To odpovídá minimálnímu času mezi dvěma po sobě jdoucími údery na přibližně 333 ms, což odpovídá maximální TF 180 tep/min. Výstupem tohoto procesu bylo pole indexů detekovaných peaků. Následně byly počítány PP intervaly, což jsou časové rozdíly mezi po sobě jdoucími peaky. Tyto rozdíly byly počítány mezi sousedními prvky z pole indexů detekovaných peaků, převedených na časové hodnoty. Následně byl z PP intervalů spočítán medián. Nakonec je TF vypočítána jako převrácená hodnota mediánového PP intervalu v sekundách, vynásobená 60.
2. **Standardní periodogram a Lomb-Scargle periodogram (LSP):** Metody jsou založené na stejném principu, používají se k odhadu spektrální hustoty výkonu signálu. Dominantní frekvence PPG záznamu poté koreluje s TF. Periodogram a LSP vypočítal spektrální hustotu z numericky derivovaného 10 s úseku PPG. Výsledkem bylo pole frekvenčních složek a pole odpovídajících výkonů pro každou frekvenci. Následně byl nalezen index nejvyšší hodnoty výkonu, k tomuto indexu byla přiřazena dominantní frekvence, která byla nakonec vynásobena 60, abychom dostali TF v tep/min.
3. **Kombinace detekce peaků a periodogramu:** Pro kombinaci výsledků byl použit vážený průměr podle následujícího vztahu:

$$TF_{kombinace} = w_1 \cdot TF_P + w_2 \cdot TF_{peaky}, \quad (9.1)$$

Kde TF_P je TF stanovená periodogramem, TF_{peaky} je TF stanovená detekcí peaků, a w_1 a w_2 jsou váhy, jejichž součet je 1. Bylo testováno různé nastavení, nejlepší kombinací vah bylo w_1 nastaveno na 0,8 a w_2 nastaveno na 0,2.

9.1 Hodnocení algoritmů stanovení tepové frekvence

V této kapitole jsou hodnoceny algoritmy použité pro stanovení TF z PPG signálu. Cílem hodnocení je zhodnotit přesnost a spolehlivost jednotlivých metod a porovnat je s referenčními hodnotami získanými z EKG záznamů. Porovnání s referencí bylo provedeno jak pro všechny kvalitní úseky, tak pro všechny nekvalitní úseky. Stanovení TF probíhalo během křížové validace modelu, popsané v předchozí kapitole, tzn. že testované úseky model předtím neviděl. Nejdříve tedy ohodnotil jejich kvalitu a následně proběhlo stanovení TF. K hodnocení algoritmu byly použity následující metriky:

- **Mean Absolute Error (MAE):** MAE je průměrná absolutní chyba mezi skutečnými a predikovanými hodnotami. Je definována jako:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (9.2)$$

kde y_i jsou skutečné hodnoty, \hat{y}_i jsou predikované hodnoty a n je počet hodnot [30].

- **Root Mean Squared Error (RMSE):** RMSE je odmocnina střední kvadratické chyby mezi skutečnými a predikovanými hodnotami. Je citlivější na velké chyby oproti MAE. RMSE je definována následovně:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad (9.3)$$

kde y_i jsou skutečné hodnoty, \hat{y}_i jsou predikované hodnoty a n je počet hodnot [30].

- **Pearsonův korelační koeficient:** Pearsonův korelační koeficient (označovaný jako r) vyjadřuje sílu a směr lineární závislosti mezi dvěma proměnnými. Hodnoty korelačního koeficientu se pohybují v rozmezí od -1 do 1, kde r blízké 1 značí pozitivní korelaci, kdy hodnoty jedné proměnné rostou s hodnotami druhé proměnné. Hodnoty r blízké 0 značí, že mezi proměnnými není žádná lineární závislost a r blízké -1 znamená, že hodnoty jedné proměnné klesají s růstem hodnot druhé proměnné. Pearsonův korelační koeficient je definován jako:

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}}, \quad (9.4)$$

kde x_i a y_i jsou hodnoty dvou proměnných, \bar{x} a \bar{y} jsou jejich průměry [45].

Jako první byly metody stanovení TF testované na všech kvalitních úsecích, které byly stanoveny modelem KNN. V Tab. 9.1 výsledků lze vidět, že všechny tři metody poskytují podobné odhady TF, přičemž periodogram a LSP mají nižší

chyby ve srovnání s detekcí peaků. Kombinace metod však zachovává nízkou MAE a zároveň snižuje RMSE. Vysoké hodnoty korelace potvrzují přijatelnou spolehlivost všech metod při stanovení TF pro kvalitní úseky signálu.

Tab. 9.1: Výsledky metod stanovení TF pro kvalitní úseky stanovené modelem KNN

Metoda	MAE [tep/min]	RMSE [tep/min]	Korelace
LSP	4,30	7,39	0,91
Periodogram	4,15	7,60	0,91
Detekce peaků	5,69	7,48	0,91
Kombinace	4,05	6,94	0,93

Dále bylo stejnými metrikami zhodnoceno stanovení TF na nekvalitních úsecích, které lze vidět v Tab. 9.2. Z výsledků na nekvalitních úsecích vykazuje detekce peaků nejlepší výkon ze všech tří metod, zatímco periodogramy mají značně sníženou přesnost a spolehlivost. Všechny odhady jsou ovšem nepřesné, což zdůrazňuje důležitost předzpracování PPG signálu a stanovení kvality úseků před stanovením TF.

Tab. 9.2: Výsledky metod stanovení TF pro nekvalitní úseky stanovené modelem KNN

Metoda	MAE [tep/min]	RMSE [tep/min]	Korelace
LSP	19,33	28,85	0,35
Periodogram	17,85	26,27	0,45
Detekce peaků	13,55	19,74	0,55
Kombinace	16,14	23,26	0,50

Následně bylo testováno stanovení TF na kvalitních i nekvalitních úsecích, které byly stanoveny SVM modelem, jak lze vidět v Tab. 9.3 a v Tab. 9.4. Podle očekávání jsou výsledky horší, jelikož SVM model ohodnotil více nekvalitních úseků jako kvalitní, v porovnání s KNN modelem. Ze všech výsledků lze také vidět, že LSP poskytuje obecně horší, případně podobné výsledky jako standardní periodogram. Stanovení TF pomocí detekce peaků zajišťuje solidní výsledky a zároveň je z testovaných metod nejméně výpočetně náročná [45].

Tab. 9.3: Výsledky metod stanovení TF pro kvalitní úseky stanovené modelem SVM

Metoda	MAE [tep/min]	RMSE [tep/min]	Korelace
LSP	5,41	10,37	0,82
Periodogram	4,99	9,64	0,85
Detekce peaků	6,14	8,89	0,86
Kombinace	4,79	8,60	0,88

Tab. 9.4: Výsledky metod stanovení TF pro nekvalitní úseky stanovené modelem SVM

Metoda	MAE [tep/min]	RMSE [tep/min]	Korelace
LSP	19,28	28,89	0,38
Periodogram	18,00	26,46	0,47
Detekce peaků	13,67	19,76	0,57
Kombinace	16,27	23,48	0,52

10 Přehled podobných studií

V této kapitole jsou stručně popsány tři studie, zabývající se měřením rPPG ze záznamů z obličeje a stanovením TF. Autoři používají různé přístupy měření a zpracování rPPG záznamu a výsledky hodnotí metrikami jako jsou MAE, RMSE a korelační koeficient, které jsou popsány v sekci 9.1.

10.1 Studie Poh et al. (2010)

Ve studii [46] byl použit algoritmus pro stanovení TF z rPPG signálů získaných webkamerou. Video byla zaznamenána při 15 snímcích za sekundu s rozlišením 640×480 pixelů. Kamera byla od obličeje vzdálená 0,5 m. Reference byla snímána standardním pulzním oxymetrem. Tento přístup zahrnoval, automatické sledování obličeje pro výběr ROI, zpracování všech tří standardních barevných kanálů a využití analýzy nezávislých komponent (ICA) k extrakci PPG signálů. ICA je statistická a výpočetní technika používaná k oddělení zdrojových signálů z jejich směsí. Cílem ICA je transformovat pozorovaná data do komponent, které jsou statisticky nezávislé, tzn. že znalost jedné komponenty neprovádí žádnou informaci o ostatních komponentách [30]. Po analýze byla TF stanovena jako frekvence, která odpovídala nejvyšší amplitudě ve spektru vybrané komponenty ICA, ve frekvenčním pásmu 0,75–4 Hz.

Tato metoda přinesla velmi dobré výsledky, hodnota RMSE byla 2,29 tep/min a korelační koeficient byl 0,98.

10.2 Studie Tarassenko et al. (2014)

Tato studie [47] se zabývala snímáním rPPG pacientům, během hemodialýzy. Kamera s 5 Mpx senzorem, byla přibližně metr od lůžka a snímala s frekvencí 12 snímků za sekundu. Reference byla měřena pulzním oxymetrem. Záznamy trvaly celou dobu dialýzy, přibližně 4 hodiny. Výběr ROI probíhal automaticky, autoři použili algoritmy pro sledování obličejových rysů. Signál byl analyzován v oknech s délkou 15 s. Nejdříve byla na signál aplikována pásmová propust s dolní mezní frekvencí 0,75 Hz a s horní mezní frekvencí 5 Hz (odpovídající 42–300 tep/min). Pro stanovení TF byl použit autoregresní (AR) model. AR model využívá předchozí hodnoty časové řady k předpovědi budoucích hodnot, u tohoto modelu je potřeba nastavit řád, který byl nastaven na 9.

V této studii byly snímány velmi dlouhé záznamy, pacient se mohl při snímání hýbat, mluvit apod. což zkreslovalo výsledky některých úseků. Autoři ovšem identifikovali 10 minutový úsek, během kterého se pacient příliš nehýbal. Výsledné MAE pro

stanovenou TF z tohoto úseku a TF snímanou z prstového oxymetru byla přibližně 3 tep/min.

10.3 Studie Trirongjitmoah et al. (2024)

Autoři studie [48] získali data od 100 účastníků, snímání probíhalo 5 min, 30–40 cm před webkamerou, se snímkovací frekvencí 20 snímků za sekundu a s rozlišením 680×480 px. Reference byla snímána oscilometrickým tonometrem. Výběr ROI zahrnoval automatickou detekci obličeje a výběr oblasti čela. Zpracovával se pouze zelený kanál. Na signál byla aplikována pásmová propust s dolní mezní frekvencí 0,7 Hz a s horní mezní frekvencí 4 Hz. Tímto způsobem byl získán první záznam ($rPPG_1$). Druhý záznam ($rPPG_2$) byl získán technikou POS [22] a zpracován stejně jako $rPPG_1$. Třetí záznam ($rPPG_3$) byl průměr $rPPG_1$ a $rPPG_2$. Na signály byla aplikována FFT, frekvence s největší amplitudou byla vynásobena 60 pro získání TF.

Výsledky stanovení TF byly velmi dobré, přičemž TF stanovená z $rPPG_1$ dosahovala největší chyby a $rPPG_3$ nejmenší, jak lze vidět v Tab. 10.1

Tab. 10.1: Stanovená TF ze tří různých rPPG signálů. Převzato a upraveno z [48]

Signál	MAE [tep/min]	RMSE [tep/min]
$rPPG_1$	4,38	10,67
$rPPG_2$	2,37	5,37
$rPPG_3$	2,32	3,89

11 Diskuze

Stanovení kvality PPG úseků před výpočtem TF je velmi důležitým krokem, který dokázal výrazně snížit chybu měření. Modely KNN a SVM dosahovaly srovnatelných výsledků stanovení kvality. Model SVM byl v klasifikaci méně přesný, ovšem vykazoval větší stabilitu. Pro oba modely byly testovány všechny kombinace příznaků, za výběru různých hyperparamterů. Byla také provedena statistická analýza jednotlivých příznaků, která neprokázala statisticky významný rozdíl mezi kvalitními a nekvalitními úseky, pro příznaky šikmost a špičatost. Ovšem kombinace různých příznaků má v tomto případě synergistický efekt, jelikož pro SVM model byly nejlepší tři příznaky, zahrnující právě šikmost, a dále perfuzi a SNR. Model KNN pracoval nejlépe, když měl k dispozici všechny příznaky. Vypočtené hodnoty příznaků se mezi kvalitními a nekvalitními úseky značně překrývaly, jak lze vidět v krabicových grafech v kapitole 8. Toto překrytí klasifikaci značně ztížilo, a tak modely dosahovaly přesnosti pouze kolem 70 %, pro dataset s přibližně stejným počtem kvalitních a nekvalitních úseků.

Stanovení TF nalezením dominantní frekvence z periodogramu byla obecně přesnější metoda než detekce peaků, jejich kombinace ovšem vykazovala nejlepší výsledky, jak lze vidět v tabulkách v sekci 9.1. Celkově je algoritmus horší v porovnání s ostatními autory. Algoritmy zmíněné v kapitole 10 mají odchylku od reference kolem 3 tep/min, což je na hranici měřící přesnosti použitých přístrojů pro referenční TF.

Možné vylepšení stanovení kvality PPG by zahrnovalo použití a testování jiných příznaků nebo použití složitějších modelů strojového učení. Tyto modely obvykle potřebují větší množství dat. Bylo by vhodné uměle rozšířit dataset dostupných záznamů, popřípadě zaznamenat více záznamů, za různých podmínek, jako např.: kognitivní zátěž a vyvolání stresové reakce, předem definované pohyby účastníků, proměnlivé osvětlení, proměnlivá teplota a vlhkost prostředí atd. Dostatečná různorodost dat by zajistila lepší generalizaci modelu na nová data. Přesné stanovení kvality signálů by vedlo k lepšímu stanovení TF, přičemž za současného použití komplexnějších metod stanovení TF, jako např. vlnková transformace, by měření vedlo k velmi přesným výsledkům.

Celkově je tento algoritmus vhodný maximálně pro domácí využití. Stanovení TF s ohledem na kvalitu záznamů bylo sice poměrně přesné, i přesto, že byly použity jednoduché a přímočaré techniky, chyby ovšem převážně vznikaly v nesprávné klasifikaci kvalitních a nekvalitních úseků PPG. Aplikace také nepracuje v reálném čase, což velmi omezuje její využití.

Prvotní metoda pro výběr ROI byla implementována pomocí barevného klíčování. Tato metoda se ovšem prokázala jako zcela nevhodná pro získání PPG zá-

znamu. Během jednoho měření měl účastník béžové tričko, které metoda zachycovala, z toho důvodu byl celý signál nekvalitní. Ve výsledných signálech ostatních účastníků byl celkově přítomný nízkofrekvenční šum, což předurčilo následnou analýzu k selhání. Metoda byla také velmi výpočetně náročná. Minutový video záznam se zpracovával přibližně 3 minuty, což bylo velmi nepraktické. Tento výpočetní čas by bylo možné snížit s použitím dedikované grafické karty a paralelního programování, ovšem tohle řešení by bylo nesmyslné pro reálné využití, jelikož hlavní argument pro využití mobilních telefonů a jiných nositelných zařízení pro měření TF je jejich nízká cena a dostupnost. Mobilní telefony sice jsou v dnešní době již velmi výkonné, ale využívat tento výkon pro takovouto aplikaci by bylo značně nepraktické. Naopak druhá metoda výběru ROI, která zvolila oblast pomocí automatického rozpoznání obličeje, byla praktičtější, přinášela lepší výsledky a nebyla tak výpočetně náročná. Další možné snížení výpočetní náročnosti by zahrnovalo snížení vzorkovací frekvence, autoři studie popsané v sekci 10.2 využívali kameru se snímkovací frekvencí 12 snímků za sekundu, dosahovali přitom velmi přesných výsledků. Teoreticky lze snímkovací frekvenci snížit více, avšak musí být splněn Shannonův vzorkovací teorém, aby se předešlo aliasingu TF.

Závěr

Tato práce se zabývá problematikou stanovení kvality a tepové frekvence ze signálu PPG snímaných z videa obličeje. Hlavním cílem bylo vyvinout algoritmy pro zpracování PPG signálů a následné stanovení jejich kvality a tepové frekvence, a porovnat přesnost těchto algoritmů s referenčními měřeními EKG.

Teoretická část práce se zabývá fyziologií srdce, principem vzniku a popisem EKG a PPG. Dále se zabývá možnostmi stanovení TF a metodami hodnocení kvality PPG.

Pro praktickou část práce byly nasnímány PPG signály z obličeje pomocí chytrého telefonu za různých podmínek od 11 účastníků. Pro referenci byl nasnímán EKG záznam, který sloužil jako zlatý standard k anotaci kvality PPG signálů a k porovnání přesnosti měření TF. Data byla předzpracována a byly vytvořeny algoritmy pro extrakci PPG signálů z videozáznamů. Pro stanovení kvality PPG signálů bylo využito metod strojového učení, konkrétně byly použity modely KNN a SVM. Stanovení kvality pro model KNN probíhalo s přesností 73,13 %, senzitivitou 70,6 %, specificitou 75,4 % a s F1 skóre 72,1 %. Pro SVM model bylo stanovení kvality obecně horší s přesností 70,74 %, senzitivitou 72,1 %, specificitou 69,6 % a s F1 skóre 70,9 %. Pro stanovení TF byly použity kvalitní úseky PPG identifikované pomocí klasifikačního modelu KNN. Byla použita kombinace metody detekce peaků v PPG signálu a metody určení dominantní frekvence z periodogramu. Z těchto dvou hodnot TF byl spočítán vážený průměr. Tato kombinace metod měla chybovost MAE 4,05 tep/min a RMSE 6,94 tep/min.

V závěru práce jsou stručně popsány metody a výsledky prací ostatních autorů, zaměřující se na rPPG a na stanovení TF z těchto záznamů. Diskuze se zaměřuje na analýzu výsledků, identifikaci problémů, praktičnosti algoritmu a navržení možných vylepšení metod, používaných pro stanovení kvality PPG signálů a TF.

Výsledky ukazují, že chytré telefony mohou být efektivním nástrojem pro bezkontaktní měření a monitorování kardiovaskulárního zdraví v běžných podmínkách.

Literatura

- [1] TURNER, Ash, 2024. HOW MANY SMARTPHONES ARE IN THE WORLD? Online. BankMyCell. Dostupné z: <https://www.bankmycell.com/blog/how-many-phones-are-in-the-world>. [cit. 2024-01-30].
- [2] JENSEN, Magnus Thorsten; SUADICANI, Poul; HEIN, Hans Ole a GYN-TELBERG, Finn, 2013. Elevated resting heart rate, physical fitness and all-cause mortality: a 16-year follow-up in the Copenhagen Male Study. Online. Heart. 2013-05-13, roč. 99, č. 12, s. 882-887. ISSN 1355-6037. Dostupné z: <https://doi.org/10.1136/heartjnl-2012-303375>. [cit. 2023-11-28].
- [3] MOUREK, Jindřich, 2012. Fyziologie: učebnice pro studenty zdravotnických oborů. 2., dopl. vyd. Sestra (Grada). Praha: Grada. ISBN 978-80-247-3918-2.
- [4] TROJAN, Stanislav, 2003. Lékařská fyziologie. Vyd. 4., přeprac. a dopl. Praha: Grada. ISBN 8024705125.
- [5] DYLEVSKÝ, Ivan, 2013. Základy funkční anatomie člověka. V Praze: České vysoké učení technické. ISBN 978-80-01-05249-5.
- [6] SEDMERA, David a VOSTÁREK, František. Moderní pohled na převodní systém srdeční. Online. Časopis lékařů českých. Roč. 2017, č. 156, article 8, s. 417-421. ISSN 1803-6597. Dostupné z: <https://www.prolekare.cz/casopisy/casopis-lekaru-ceskych/2017-8/moderni-pohled-na-prevodni-system-srdecni-62750>. [cit. 2023-11-30].
- [7] KITTNAR, Otomar, 2011. Lékařská fyziologie. Praha: Grada. ISBN 9788024730684.
- [8] GALLI, Alessandra; MONTREE, Roel J. H.; QUE, Shuhao; PERI, Elisabetta a VULLINGS, Rik, 2022. An Overview of the Sensors for Heart Rate Monitoring Used in Extramural Applications. Online. Sensors. Roč. 22, č. 11. ISSN 1424-8220. Dostupné z: <https://doi.org/10.3390/s22114035>. [cit. 2023-11-28].
- [9] ITO, Shigenori, 2019. High-intensity interval training for health benefits and care of cardiac diseases - The key to an efficient exercise protocol. Online. World Journal of Cardiology. 2019-7-26, roč. 11, č. 7, s. 171-188. ISSN 1949-8462. Dostupné z: <https://doi.org/10.4330/wjc.v11.i7.171>. [cit. 2024-01-28].
- [10] PAVLÍČEK, Jan a KLÁSKOVÁ, Eva, 2023. Heart murmur in children. Online. Česko-slovenská pediatrie. 2023-8-1, roč. 78, č. 5, s. 261-263. ISSN 00692328. Dostupné z: <https://doi.org/10.55095/CSPediatric2023/044>. [cit. 2023-11-29].

- [11] HAMPTON, John R. a HAMPTON, Joanna, 2022. EKG stručně, jasně, přehledně. Přeložil Leoš LANDA. Praha: Grada Publishing. ISBN 9788027113170.
- [12] HABERL, Ralph, 2012. EKG do kapsy. Praha: Grada. ISBN 978-80-247-4192-5.
- [13] BORSKÁ, Lenka, 2006. EKG desatero. Druhé korigované vydání. Brno: MSD. ISBN 80-86633-52-7.
- [14] SOVOVÁ, Eliška, 2006. EKG pro sestry. Sestra (Grada). Praha: Grada. ISBN 80-247-1542-2.
- [15] GAO, Xin, 2017. Non-invasive Detection and Compression of Fetal Electrocardiogram. Online. In: MICHAEL, Kevin A. (ed.). Interpreting Cardiac Electrograms - From Skin to Endocardium. InTech, 2017-10-18. ISBN 978-953-51-3571-5. Dostupné z: <https://doi.org/10.5772/intechopen.69920>. [cit. 2024-03-17].
- [16] ALLEN, John, 2007. Photoplethysmography and its application in clinical physiological measurement. Online. Physiological Measurement. 2007-03-01, roč. 28, č. 3, s. R1-R39. ISSN 0967-3334. Dostupné z: <https://doi.org/10.1088/0967-3334/28/3/R01>. [cit. 2023-11-28].
- [17] SVIRIDOVA, Nina; ZHAO, Tiejun; AIHARA, Kazuyuki; NAKAMURA, Kazuyuki a NAKANO, Akimasa, 2018. Photoplethysmogram at green light: Where does chaos arise from? Online. Chaos, Solitons & Fractals. Roč. 116, s. 157-165. ISSN 09600779. Dostupné z: <https://doi.org/10.1016/j.chaos.2018.09.016>. [cit. 2023-12-01].
- [18] ZHONG, Yizhou; PAN, Yun; ZHANG, Ling a CHENG, Kwang-Ting, 2016. A wearable signal acquisition system for physiological signs including throat PPG. Online. In: 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). IEEE, s. 603-606. ISBN 978-1-4577-0220-4. Dostupné z: <https://doi.org/10.1109/EMBC.2016.7590774>. [cit. 2023-12-01].
- [19] KINNUNEN, Hannu; RANTANEN, Aleksii; KENTTÄ, Tuomas a KOSKIMÄKI, Heli, 2020. Feasible assessment of recovery and cardiovascular health: accuracy of nocturnal HR and HRV assessed via ring PPG in comparison to medical grade ECG. Online. Physiological Measurement. 2020-05-01, roč. 41, č. 4. ISSN 0967-3334. Dostupné z: <https://doi.org/10.1088/1361-6579/ab840a>. [cit. 2023-12-01].
- [20] CHARLTON, Peter H.; KYRIACOU, Panicos A.; MANT, Jonathan; MAROZAS, Vaidotas; CHOWIENCZYK, Phil et al., 2022. Wearable Photoplethysmography for Cardiovascular Monitoring. Online. Proceedings of

- the IEEE. Roč. 110, č. 3, s. 355-381. ISSN 0018-9219. Dostupné z: <https://doi.org/10.1109/JPROC.2022.3149785>. [cit. 2023-12-01].
- [21] XUAN, Yinan; BARRY, Colin; ANTIPA, Nick a WANG, Edward Jay, 2023. A calibration method for smartphone camera photoplethysmography. Online. *Frontiers in Digital Health*. 2023-11-24, roč. 5. ISSN 2673-253X. Dostupné z: <https://doi.org/10.3389/fdgth.2023.1301019>. [cit. 2024-04-05].
- [22] WANG, Wenjin; DEN BRINKER, Albertus C.; STUIJK, Sander a DE HAAN, Gerard, 2017. Algorithmic Principles of Remote PPG. Online. *IEEE Transactions on Biomedical Engineering*. Roč. 64, č. 7, s. 1479-1491. ISSN 0018-9294. Dostupné z: <https://doi.org/10.1109/TBME.2016.2609282>. [cit. 2024-01-31].
- [23] HERRANZ OLAZÁBAL, Jorge; WIERINGA, Fokko; HERMELING, Evelien a VAN HOOFF, Chris, 2022. Camera-Derived Photoplethysmography (rPPG) and Speckle Plethysmography (rSPG): Comparing Reflective and Transmissive Mode at Various Integration Times Using LEDs and Lasers. Online. *Sensors*. Roč. 22, č. 16. ISSN 1424-8220. Dostupné z: <https://doi.org/10.3390/s22166059>. [cit. 2024-01-31].
- [24] ORPHANIDOU, Christina, 2018. Signal Quality Assessment in Physiological Monitoring. Online. 1. *SpringerBriefs in Bioengineering*. Cham: Springer International Publishing. ISBN 978-3-319-68414-7. Dostupné z: <https://doi.org/10.1007/978-3-319-68415-4>. [cit. 2024-01-02].
- [25] ELGENDI, Mohamed, 2016. Optimal Signal Quality Index for Photoplethysmogram Signals. Online. *Bioengineering*. Roč. 3, č. 4, article 16, s. 2. ISSN 2306-5354. Dostupné z: <https://doi.org/10.3390/bioengineering3040021>. [cit. 2024-01-30].
- [26] ORPHANIDOU, Christina; BONNICI, Timothy; CHARLTON, Peter; CLIFTON, David; VALLANCE, David et al., 2014. Signal Quality Indices for the Electrocardiogram and Photoplethysmogram: Derivation and Applications to Wireless Monitoring. Online. *IEEE Journal of Biomedical and Health Informatics*. S. 1-1. ISSN 2168-2194. Dostupné z: <https://doi.org/10.1109/JBHI.2014.2338351>. [cit. 2024-01-03].
- [27] LE, Van-Khoa D.; HO, Hai Bich; KAROLCIK, Stefan; HERNANDEZ, Bernard; GREEFF, Heloise et al., 2022. Vital_sqi: A Python package for physiological signal quality control. Online. *Frontiers in Physiology*. 2022-11-11, roč. 13. ISSN 1664-042X. Dostupné z: <https://doi.org/10.3389/fphys.2022.1020458>. [cit. 2024-01-30].

- [28] SHIN, Hangsik, 2022. Deep convolutional neural network-based signal quality assessment for photoplethysmogram. Online. Computers in Biology and Medicine. Roč. 145. ISSN 00104825. Dostupné z: <https://doi.org/10.1016/j.complbiomed.2022.105430>. [cit. 2024-01-31].
- [29] CHRISTMANN, Andreas a STEINWART, Ingo, 2008. Support Vector Machines. Online. Information Science and Statistics. New York, NY: Springer New York. ISBN 978-0-387-77241-7. Dostupné z: <https://doi.org/10.1007/978-0-387-77242-4>. [cit. 2024-04-07].
- [30] PEDREGOSA, F. et al. Scikit-learn: Machine Learning in Python. Journal of Machine Learning Research. 2011, roč. 12, s. 2825-2830. Dostupné také z: <http://www.jmlr.org/papers/volume12/pedregosa11a/pedregosa11a.pdf>. [cit. 2024-04-07].
- [31] KNN Model-Based Approach in Classification, 2004. Newtownabbey, BT37 0QB, Northern Ireland, UK: School of Computing and Mathematics, University of Ulster. Dostupné také z: <https://shorturl.at/dorHT>. [cit. 2024-04-07].
- [32] ROH, Donggeun a SHIN, Hangsik, 2021. Recurrence Plot and Machine Learning for Signal Quality Assessment of Photoplethysmogram in Mobile Environment. Online. Sensors. Roč. 21, č. 6. ISSN 1424-8220. Dostupné z: <https://doi.org/10.3390/s21062188>. [cit. 2024-04-11].
- [33] NAEINI, Emad Kasaeyan; AZIMI, Iman; RAHMANI, Amir M.; LILJEBERG, Pasi a DUTT, Nikil, 2019. A Real-time PPG Quality Assessment Approach for Healthcare Internet-of-Things. Online. Procedia Computer Science. Roč. 151, s. 551-558. ISSN 18770509. Dostupné z: <https://doi.org/10.1016/j.procs.2019.04.074>. [cit. 2024-04-11].
- [34] GOODFELLOW, Ian; BENGIO, Yoshua Bengio a COURVILLE, Aaron, 2016. Deep Learning. Online. MIT Press. Dostupné z: <http://www.deeplearningbook.org>. [cit. 2024-04-11].
- [35] FAWCETT, Tom, 2006. An introduction to ROC analysis. Online. Pattern Recognition Letters. Roč. 27, č. 8, s. 861-874. ISSN 01678655. Dostupné z: <https://doi.org/10.1016/j.patrec.2005.10.010>. [cit. 2024-05-28].
- [36] ABOY, M.; MCNAMES, J.; THONG, T.; TSUNAMI, D.; ELLENBY, M.S. et al., 2005. An Automatic Beat Detection Algorithm for Pressure Signals. Online. IEEE Transactions on Biomedical Engineering. Roč. 52, č. 10, s. 1662-1670. ISSN 0018-9294. Dostupné z: <https://doi.org/10.1109/TBME.2005.855725>. [cit. 2024-04-13].

- [37] MAESTRE-RENDON, J. Rodolfo; RIVERA-ROMAN, Tomas A.; FERNANDEZ-JARAMILLO, Arturo A.; GUERRÓN PAREDES, Nancy E. a SERRANO OLMEDO, José Javier, 2020. A Non-Contact Photoplethysmography Technique for the Estimation of Heart Rate via Smartphone. Online. Applied Sciences. Roč. 10, č. 1. ISSN 2076-3417. Dostupné z: <https://doi.org/10.3390/app10010154>. [cit. 2024-04-19].
- [38] Discrete Fourier Transform - Frequencies, Lectures on matrix algebra, 2021. Online. TABOGA, Marco. StatLect. Dostupné z: <https://www.statlect.com/matrix-algebra/discrete-Fourier-transform-frequencies>. [cit. 2024-03-23].
- [39] VANDERPLAS, Jacob T., 2018. Understanding the Lomb–Scargle Periodogram. Online. The Astrophysical Journal Supplement Series. 2018-05-11, roč. 236, č. 1. ISSN 0067-0049. Dostupné z: <https://doi.org/10.3847/1538-4365/aab766>. [cit. 2024-05-26].
- [40] HOCKE, K. a KÄMPFER, N., 2009. Gap filling and noise reduction of unevenly sampled data by means of the Lomb-Scargle periodogram. Online. Atmospheric Chemistry and Physics. Roč. 9, č. 12, s. 4197-4206. ISSN 1680-7324. Dostupné z: <https://doi.org/10.5194/acp-9-4197-2009>. [cit. 2024-05-22].
- [41] ADINSTRUMENTS. Using the Lomb-Scargle Periodogram for HRV analysis. Online. Dostupné z: <https://www.adinstruments.com/blog/using-lomb-scargle-periodogram-hrv-analysis>. [cit. 2024-05-22].
- [42] NEMCOVA, Andrea; VARGOVA, Enikő; SMISEK, Radovan; MARSANOVA, Lucie; SMITAL, Lukas et al., 2021. Brno University of Technology Smartphone PPG Database (BUT PPG): Annotated Dataset for PPG Quality Assessment and Heart Rate Estimation. Online. BioMed Research International. 2021-9-6, roč. 2021, s. 1-6. ISSN 2314-6141. Dostupné z: <https://doi.org/10.1155/2021/3453007>. [cit. 2024-04-14].
- [43] KALIDAS, Vignesh a TAMIL, Lakshman, 2017. Real-time QRS detector using Stationary Wavelet Transform for Automated ECG Analysis. Online. In: 2017 IEEE 17th International Conference on Bioinformatics and Biotechnology (BIBE). IEEE, s. 457-461. ISBN 978-1-5386-1324-5. Dostupné z: <https://doi.org/10.1109/BIBE.2017.00-12>. [cit. 2024-04-14].
- [44] BITTIUM BIOSIGNALS LTD, 2019. Bittium Faros 180 Manual: Electrode Positioning And Lead Placement; Positioning Of The Fastfix Electrode. 800953 Version 2.0.0. Dostupné také

z: <https://www.manualslib.com/manual/3066640/Bittium-Faros-180.html?page=27#manual>

- [45] VIRTANEN, P. et al. SciPy 1.0: Fundamental Algorithms for Scientific Computing in Python. *Nature Methods*, 17(3), 261-272. Dostupné z: <https://doi.org/10.1038/s41592-019-0686-2>. [cit. 2024-05-23].
- [46] POH, Ming-Zher; MCDUFF, Daniel J. a PICARD, Rosalind W., 2010. Non-contact, automated cardiac pulse measurements using video imaging and blind source separation. Online. *Optics Express*. Roč. 18, č. 10, s. 10762-10774. ISSN 1094-4087. Dostupné z: <https://doi.org/10.1364/OE.18.010762>. [cit. 2024-05-23].
- [47] TARASSENKO, L; VILLARROEL, M; GUAZZI, A; JORGE, J; CLIFTON, D A et al., 2014. Non-contact video-based vital sign monitoring using ambient light and auto-regressive models. Online. *Physiological Measurement*. 2014-05-01, roč. 35, č. 5, s. 807-831. ISSN 0967-3334. Dostupné z: <https://doi.org/10.1088/0967-3334/35/5/807>. [cit. 2024-05-23].
- [48] TRIRONGJITMOAH, Suchin; PROMKING, Arphorn; KAEWDANG, Khanittha; PHANSIRI, Nisarut a TREEPRAPIN, Kriengsak, 2024. Assessing heart rate and blood pressure estimation from image photoplethysmography using a digital blood pressure meter. Online. *Heliyon*. Roč. 10, č. 5. ISSN 24058440. Dostupné z: <https://doi.org/10.1016/j.heliyon.2024.e27113>. [cit. 2024-05-23].

Seznam symbolů a zkratek

AC	Pulzující složka
AI	Umělá inteligence
AP	Akční potenciál
AR	Autoregresivní
AUC	Plocha pod křivkou
AV	Atrioventrikulární
CNN	Konvoluční neuronová síť
DC	Stejnoseměrná složka
DFT	Diskrétní Fourierova transformace
EKG	Elektrokardiografie
FFT	Rychlá Fourierova transformace
FN	Falešně negativní
FP	Falešně pozitivní
ICA	Analýza nezávislých komponent
KNN	K-nejbližších sousedů
LED	Světelná dioda
LSP	Lomb-Scargle periodogram
MAE	Průměrná absolutní chyba
PC	Hlavní komponenta
PCA	Analýza hlavních komponent
PPS	Převodní systém srdeční
PPG	Fotopletysmografický záznam (fotopletysmogram)
PP	Časová vzdálenost mezi dvěma peaky v PPG
rPPG	Vzdálená fotopletysmografie

ROC	Receiver operating characteristic
ROI	Oblast zájmu
RMSE	Odmocnina střední kvadratické chyby
SA	Sinoatriální
SNR	Poměr signálu k šumu
SVM	Metoda podpůrných vektorů
SWT	Stacionární vlnková transformace
TF	Tepová frekvence
TN	Skutečně negativní
TP	Skutečně pozitivní
ZCR	Počet průchodů nulou

A Obsah elektronické přílohy

- Skript main.py – Aplikace pro stanovení kvality a tepové frekvence z videa obličeje.
- Skript test_modelu.ipynb – Testování různých modelů a metod pro stanovení kvality a TF.
- knn_model.pkl – KNN model naučený na všech dostupných datech, uložený pomocí knihovny pickle.
- Skript testovani.py – Testování různých metod zpracování videosekvence.
- Skript synchronizace.py – Pro převzorkování a synchronizaci PPG a EKG záznamů.
- Skript features_to_df.ipynb – Výpočet příznaků ze záznamů.
- Skript raw_ppg_to_df.py – Zpracování videosekvence a uložení.