



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

CENTRUM SPORTOVNÍCH AKTIVIT

CENTRE OF SPORTS ACTIVITIES

ODHAD TEPOVÉ FREKVENCE ZE SIGNÁLŮ PPG

HEART RATE ESTIMATION FROM THE PPG SIGNALS

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Petr Šimčák

VEDOUCÍ PRÁCE

SUPERVISOR

doc. Ing. Jiří Kozumplík, CSc.

BRNO 2025

Bakalářská práce

bakalářský studijní program **Sportovní technologie**

Centrum sportovních aktivit

Student: Petr Šimčák

ID: 226320

Ročník: 3

Akademický rok: 2024/25

NÁZEV TÉMATU:

Odhad tepové frekvence ze signálů PPG

POKYNY PRO VYPRACOVÁNÍ:

1) Vypracujte stručný přehled metod odhadu tepové frekvence (TF) z fotoplethysmogramů (signálů PPG). 2) Navrhněte, realizujte a popište algoritmy pro detekci systolických maxim v signálech PPG. Algoritmy detekce a určení TF ověřte na databázi CapnoBase. 3) Dále ověřte algoritmy na databázi Brno University of Technology Smartphone PPG Database (BUT PPG). 4) Navrhněte automatické posouzení kvality testovaných signálů. 5) Získané výsledky vyhodnoťte a vypracujte studii shrnující výsledky práce.

DOPORUČENÁ LITERATURA:

- [1] VADREU S., MANIKANDAN M.S.: Use of Zero-Frequency Resonator for Automatically Detecting Systolic Peaks of Photoplethysmogram Signal. Healthcare Technology Letters, 2019, Vol. 6, Iss. 3, pp. 53–58.
- [2] PARK J., SEOK H.S., KIM S.-S., SHIN H.: Photoplethysmogram Analysis and Applications: An Integrative Review. Front. Physiol., 2022, 12:808451. pp. 1-23.

Termín zadání: 5.2.2025

Termín odevzdání: 31.5.2025

Vedoucí práce: doc. Ing. Jiří Kozumplík, CSc.

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 bakalářská práce se zabývá odhadem srdeční tepové frekvence (TF) ze signálů fotopletysmografie (PPG) a automatickým hodnocením kvality těchto signálů. Porovnávány jsou tři přístupy k odhadu TF: Elgendiho algoritmus, vlastní metoda detekce vrcholů a nově navržený přístup založený na Hjorthových deskriptorech. Dále je navržen klasifikační model využívající Shannonovu entropii a index spektrální čistoty pro hodnocení kvality signálu. Metody jsou testovány na dvou veřejných databázích: CapnoBase a BUT PPG. Výsledky ukazují vysokou přesnost detekčních metod u kvalitních signálů, zatímco metoda založená na Hjorthových parametrech dosahuje slibných výsledků zejména u krátkých úseků. Model pro klasifikaci kvality vykazuje dobrou výkonnost na spojené databázi ($AUC = 0,957$), avšak omezenou schopnost generalizace na jednotlivé databáze, takže je tento výsledek nutné brát s rezervou. Diskutována jsou omezení a možnosti budoucího rozšíření.

KLÍČOVÁ SLOVA

fotopletysmografie, tepová frekvence, PPG, odhad tepové frekvence, systolické vrcholy, algoritmy, CapnoBase, BUT PPG

ABSTRACT

This bachelor thesis addresses the problem of heart rate estimation from photoplethysmographic (PPG) signals and the automatic evaluation of signal quality. Three approaches to heart rate estimation are compared: Elgendi's algorithm, a custom peak detection method, and a novel approach based on Hjorth descriptors. Additionally, a machine learning model based on Shannon entropy and spectral power index is proposed to classify signal quality. Methods are evaluated on two public databases: CapnoBase and BUT PPG. The results show high accuracy of peak detection methods on clean signals, while the Hjorth-based method achieves promising results for short, high-quality segments. The signal quality classifier achieves good performance on combined data ($AUC = 0.957$), but limited generalization to individual databases so the results should be interpreted with caution. Limitations and potential improvements are discussed.

KEYWORDS

photoplethysmography, heart rate, PPG, heart rate estimation, systolic peaks, algorithms, CapnoBase, BUT PPG

ŠIMČÁK, Petr. *Odhad tepové frekvence ze signálů PPG*. Bakalářská práce. Brno: Vysoké učení technické v Brně, Centrum sportovních aktivit, Ústav biomedicínského inženýrství, 2025. Vedoucí práce: doc. Ing. Jiří Kozumplík, CSc.

Prohlášení autora o původnosti díla

Jméno a příjmení autora: Petr Šimčák
VUT ID autora: 226320
Typ práce: Bakalářská práce
Akademický rok: 2024/25
Téma závěrečné práce: Odhad tepové frekvence ze signálů PPG

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

Děkuji vedoucímu bakalářské práce doc. Ing. Jiřímu Kozumplíkovi, CSc. za trpělivost, hodnotné rady, laskavý přístup, konzultace, podklady k práci a odborné vedení.

Obsah

Úvod	19
1 Srdeční tep	21
1.1 Srdeční tepová frekvence	21
1.2 Faktory ovlivňující tepovou frekvenci	21
1.3 Měření srdečního tepu	22
2 Fotopletysmograf	23
2.1 Složení PPG signálu	23
3 Databáze	25
3.1 CapnoBase	25
3.2 BUT PPG	25
4 Elgendiho referenční algoritmus	27
4.1 Obecná struktura algoritmu	27
4.2 Předzpracování signálu	27
4.3 Určení bloků zájmů a nalezení vrcholů	29
5 Vlastní algoritmus založený na detekci systolických vrcholů	33
5.1 Předzpracování PPG signálu	33
5.2 Detekce vrcholů	35
5.3 Výpočet tepové frekvence	36
6 Využití Hjorthových deskriptorů na odhad TF a kvality signálů	39
6.1 Odhad TF pomocí Hjorthovy mobility	39
6.2 Hodnocení kvality PPG signálů	43
7 Výsledky	49
7.1 Výsledky pro databázi CapnoBase	49
7.2 Výsledky pro databázi BUT PPG	56
7.3 Výsledky automatického posouzení kvality	61
8 Diskuze	65
8.1 Interpretace výkonu metod odhadu TF pro CapnoBase	65
8.2 Interpretace výkonu metod odhadu TF pro BUT PPG	67
8.3 Výpočetní náročnost metod odhadu TF	68
8.4 Hodnocení automatického stanovení kvality signálů	70

Závěr	71
Literatura	73
Seznam symbolů a zkratk	77

Seznam obrázků

2.1	Snímání PPG signálu	23
2.2	Fiziologický popis PPG signálu	24
3.1	Získání PPG signálu pro databázi BUT PPG	26
4.1	Struktura Elgendiho algoritmu	27
4.2	Elgendiho předzpracování PPG signálu	28
4.3	Elgendiho zpracování pravidelného signálu	31
4.4	Elgendiho zpracování nepravidelného signálu	31
5.1	Vlastní amplitudová charakteristika Butterworthova filtru	34
5.2	Vlastní detekce vrcholů	35
5.3	Histogram IBI	37
5.4	Vlastní zpracování signálů	38
6.1	Schéma našeho algoritmu, který využívá Hjorthových deskriptorů . . .	39
6.2	Amplitudová charakteristika hornopropustného filtru	41
6.3	Porovnání původního, filtrovaného a autokorelovaného signálu	42
6.4	Důležitost příznaků pro klasifikaci kvality signálů pomocí náhodného lesa	46
6.5	Signál označený databází za kvalitní	47
6.6	Porovnání kvality dle Orphanidou a referenční anotace z databáze BUT PPG	48
7.1	Srovnání metod detekujících vrcholy pro minutové úseky	51
7.2	Srovnání metod detekujících vrcholy pro celý signál	51
7.3	Chybný odhad TF pomocí vlastní vrcholové detekce	52
7.4	Chybný odhad TF pomocí Hjorthových deskriptorů u nekvalitního signálu	52
7.5	Bland-Altmanova analýza pro metody detekujících vrcholy - CapnoBase	54
7.6	Bland-Altmanova analýza pro metodu využívající Hjorthovy deskrip- tory - CapnoBase	55
7.7	Porovnání TF pro jednotlivé kvalitní signály - BUT PPG	57
7.8	Bland-Altmanova analýza pro Elgendiho metodu - BUT PPG	58
7.9	Bland-Altmanova analýza pro naši metodu detekujících vrcholy - BUT PPG	59
7.10	Bland-Altmanova analýza pro metodu využívající Hjorthovy deskrip- tory - BUT PPG	60
7.11	ROC křivka pro automatické posouzení kvality signálů	61
7.12	Prostor příznaků pro BUT PPG a CapnoBase	62
7.13	Matice záměn pro automatické posouzení kvality signálů	63
8.1	Porovnání výkonu metod detekce vrcholů - CapnoBase	66

8.2	Největší odchylky u Hjorthovy metody 1 - BUT PPG	68
8.3	Největší odchylky u Hjorthovy metody 2 - BUT PPG	69

Seznam tabulek

7.1	Srovnání metod odhadu TF na databázi CapnoBase	50
7.2	Srovnání metod odhadu TF na databázi BUT PPG	56
7.3	Srovnání klasifikační přesnosti automatického hodnocení kvality . . .	63

Úvod

Tepová frekvence představuje jeden ze základních fyziologických parametrů, který poskytuje klíčové informace o aktuálním stavu kardiovaskulárního systému jedince. Její monitorování je široce využíváno nejen v klinické praxi, ale i ve sportovní medicíně, rehabilitaci či oblasti osobního zdraví. Zatímco elektrokardiografie (EKG) je zlatým standardem pro přesné měření tepové frekvence, její použití bývá spojeno s vyššími náklady a omezenou mobilitou.

V posledních letech proto nabývá na významu fotopletysmografie (PPG) jakožto neinvazivní optická metoda, která umožňuje kontinuální a uživatelsky přívětivé měření tepové frekvence. Princip PPG spočívá v detekci změn objemu krve v periferních tkáních na základě absorpce či odrazu světla. Díky své jednoduchosti a možnosti integrace do nositelných zařízení, jako jsou chytré hodinky či fitness náramky, umožňuje PPG dlouhodobé sledování srdeční aktivity v běžném životním prostředí.

Cílem této bakalářské práce je popsat metody odhadu tepové frekvence z PPG signálů a navrhnout vlastní algoritmy, které umožní spolehlivé stanovení tepové frekvence. Dalším cílem je ověřit možnost automatického hodnocení kvality PPG signálů na základě Shannonovy entropie a indexu spektrální čistoty (SPI), a následně klasifikovat segmenty signálu na použitelné a znehodnocené.

Zhodnocení navržených metod je provedeno na dvou veřejně dostupných databázích: CapnoBase a BUT PPG. Výsledky jsou porovnány pomocí standardních metrik výkonnosti, jako jsou citlivost, pozitivní prediktivní hodnota, střední absolutní chyba nebo ROC analýza.

V celé práci je dodržena citační norma ČSN ISO 690 [24, 23], přičemž veškeré zdroje jsou uváděny v jednotném stylu.

1 Srdeční tep

Srdeční tep, nazývaný též pulz, představuje jeden z nejzákladnějších zevních projevů srdeční činnosti. Jedná se o tlakovou vlnu, která vzniká při systole (stahu) srdce a šíří se krevním řečištěm do celého těla. Tuto tlakovou vlnu lze vnímat na povrchu těla (tzv. palpačně), konkrétně v místech, kde vedou tepny v relativně mělkých oblastech, a to na příklad na zápěstí (a. radialis) nebo na krku (a. carotis) [4, 18].

Význam srdečního tepu a jeho frekvence (počtu úderů za minutu) je zásadní v klinické praxi i ve výzkumu. Vzhledem k tomu, že tepová vlna vychází přímo z cyklické práce srdce, poskytuje nám relativně přesnou a snadno dostupnou informaci o srdeční aktivitě. Srdeční tep i jeho variabilita se dnes běžně využívají k orientačnímu posouzení kardiovaskulárního zdraví a k monitorování reakce kardiovaskulárního systému na různé podněty a zátěž [20].

1.1 Srdeční tepová frekvence

Tepová frekvence (TF) je běžně užívanou veličinou pro základní posouzení srdeční činnosti. Je definována jako počet srdečních cyklů (systol a diastol) za jednu minutu. U zdravého dospělého jedince v klidovém stavu se nejčastěji pohybuje v rozmezí 60 až 90 úderů za minutu. Maximální rozsah TF lze vypočítat, když se vezme v potaz pohlaví, věk a váha [4]. Obecně jsou za hraniční považovány hodnoty 30 až 200 úderů za minutu [11]. Jsou ale přístupy, které doporučují počítat maximální TF přesněji, například pomocí vzorce $220 - (\text{věk} \cdot 0,7)$ [22]. Pro klidový stav jsou hodnoty pod 60 úderů za minutu označovány jako bradykardie, u 90 úderů za minutu pak hovoříme o tachykardii [4, 19].

Důležitým aspektem ovlivňujícím TF je i pravidelnost srdečního rytmu. Pravidelné intervaly mezi jednotlivými údery signalizují rovnoměrné srdeční stahy. Nepravidelnosti se označují jako arytmie, které mohou poukazovat na různá onemocnění, např. fibrilace síní či extrasystoly [4].

1.2 Faktory ovlivňující tepovou frekvenci

TF může kolísat v závislosti na mnoha faktorech, které lze rozdělit na vnitřní (endogenní) a vnější (exogenní). K vnitřním faktorům patří například momentální zdravotní stav, tělesná kondice, hormonální vlivy nebo genetické predispozice. Mezi vnější faktory lze řadit fyzickou aktivitu, působení stresu, emoční zátěž či užití stimulantů (např. kofein nebo nikotin) [20].

Významným determinantem srdečních pulzů je obecně fyzická aktivita - během cvičení či zvýšené tělesné námahy musí organismus zajistit vyšší přísun kyslíku a

živin do zatížených svalů, čehož dosahuje zrychlením srdeční aktivity. Podobně i stresové situace či emoční reakce vedou ke stimulaci sympatického nervového systému, jenž zvyšuje srdeční tep. Naopak parasympatický nervový systém v klidových stavech srdeční činnost brzdí [20].

1.3 Měření srdečního tepu

Existuje řada způsobů, jak TF měřit a kvantifikovat. Základní dělení vychází z rozlišení mezi manuálními a instrumentálními metodami.

Tradičním, jednoduchým a dostupným postupem manuálního měření je již zmíněné palpační měření tepu v kapitole 1. Při něm se prsty (typicky ukazovák a prostředník) přiloží na vhodnou tepnu, často vřetenní tepnu na zápěstí (a. radialis), a po stanovenou dobu se počítají úderů. Manuální metoda je i přes svoji jednoduchost relativně spolehlivá, avšak nemusí být ideální pro detekci nepravidelného rytmu, nebo může být chybová při nepozornosti vyšetřujícího [19].

Instrumentální metoda je taková, která využívá moderní přístroje, jako jsou fitness náramky, chytré hodinky či specializované pulzmetry, umožňující pohodlné, dlouhodobé a relativně přesné měření srdečního tepu. Často využívá principu fotopletysmografie (PPG), kdy senzor vyhodnocuje změny průtoku krve podle odrazivosti světla ve tkáni. Ve sportovním tréninku se uplatňují také hrudní pásy, které snímají EKG a monitorují tep spolehlivě i při vyšších zátěžích.


Výsledkem měření je tepová frekvence popsaná v podkapitole 1.1, vyjádřená v počtech úderů za minutu. Moderní přístroje nabízejí trvalé monitorování s automatickým záznamem tepové frekvence, což usnadňuje dlouhodobé sledování a vyhodnocování dat.

2 Fotopletysmograf

Fotopletysmografie (PPG) je neinvazivní optická metoda sloužící k monitorování změn objemu krve v mikrovaskulárním řečišti tkáně, obvykle na prstu, zápěstí či ušním lalůčku [21]. Zejména díky snadné integraci do nositelných zařízení (např. chytrých hodinek) a relativně nízkým nákladům na realizaci se PPG stává klíčovým nástrojem pro dlouhodobé sledování kardiovaskulárních parametrů, jako je tepová frekvence (TF), saturace krve kyslíkem (SpO_2) či hodnocení variability tepových intervalů [10]. První klinické využití PPG se datuje do 80. let 20. století, kdy byla technologie začleněna do pulzních oxymetrů, čímž zásadně změnila způsob měření saturace arteriální krve kyslíkem [7].

Na Obr. 2.1 jsou znázorněny dvě základní měřicí konfigurace. Transmisní režim (a), kde je zdroj světla a fotodetektor na opačných stranách tkáně (typicky při měření na prstu či ušním lalůčku) a reflexní režim (b), kde je umístěn zdroj světla i detektor na téže straně tkáně (používaný v běžných sportovních zařízeních, jakou jsou chytré hodinky). Tento režim je z morfologických důvodů náchylnější k chybám [16].

Metoda PPG je založena na měření intenzity světla, která se po interakci s tkání dostane k detektoru. Množství absorbovaného/odraženého světla závisí na aktuálním průtoku krve, který je modulován srdečními cykly [21].



Obr. 2.1: Transmisní režim (a) a reflexní režim (b), upraveno z [4].


2.1 Složení PPG signálu

Jak ukazuje Obr. 2.2, naměřený PPG signál zahrnuje *pulzní* složku, synchronizovanou se srdeční aktivitou, a stabilní *nepulzní* složku. *Pulzní* složka odráží perio-

dické změny objemu arteriální krve v rozsahu typického frekvenčního pásma srdeční činnosti (zhruba 0,5–3 Hz) a je klíčová pro přesnou detekci TF. *Nepulzní* složka představuje základní linii danou absorpcí tkáně a žilní krve; ovlivňuje ji například barva kůže, okolní osvětlení a anatomické poměry měřené oblasti [4, 21]. Je důležité si uvědomit, že PPG signál je inverzní k měřenému optickému signálu. Reprezentuje totiž objem krve v tkáni, nikoli množství světla dopadajícího na senzor, což je patrné i z Obr. 2.2.

Za počátek pulzu v PPG signálu se obvykle považuje nejnižší bod předcházející systolické fázi, který odpovídá minimálnímu objemu krve v měřené oblasti. Pro výpočet TF se využívají systolické vrcholy, tedy body s maximálním objemem krve, z nichž lze určit intervaly mezi srdečními údery a následně stanovit TF.

Po systolickém vrcholu přichází diastola, což je fáze srdečního cyklu, během které dochází k relaxaci srdečního svalu a plnění srdce krví. V průběhu diastoly bývá často patrný typický dikrotický zářez, který odráží elastické vlastnosti cévní stěny a uzávěr aortální chlopně. Jeho přítomnost a tvar mohou poskytovat užitečné informace o stavu kardiovaskulárního systému [10, 21].



Obr. 2.2: Princip získání PPG křivky a její popis. Upraveno z [21].

3 Databáze

V této práci jsme využívali dvě databáze fotoplety-smografických signálů: *CapnoBase* a *Brno University of Technology Smartphone PPG Database*, pro kterou budeme v této práci používat zkrácený název BUT PPG.

Na těchto databázích jsme testovali a porovnávali výsledky použitých algoritmů. U databáze *CapnoBase* jsme porovnávali naměřené systolické vrcholy s referenčními hodnotami a díky tomu jsme porovnávali i rozdíl v srdeční tepové frekvenci (TF). U databáze BUT PPG nebyly referenční hodnoty systolických vrcholů k dispozici, ale byly zde referenční hodnoty TF signálů, které jsme porovnávali s naměřenými výsledky.

3.1 CapnoBase

CapnoBase je veřejně dostupná databáze, která obsahuje osmiminutové záznamy od 42 dětských i dospělých pacientů, podstupujících plánované chirurgické zákroky včetně anestézie [3].

Součástí databáze jsou PPG, EKG a respirační signály, se vzorkovací frekvencí 300 Hz. Pro každý záznam jsou navíc ručně označeny systolické vrcholy v PPG, odvozené z EKG, což umožňuje přesné ověření správnosti detekce tepů. Autoři však nedoporučují databázi používat k trénování či doladování algoritmů [3]. Proto jsme ji použili pouze k testování použitých algoritmů a k porovnání výsledků s referenčními hodnotami.

Díky svým vlastnostem je *CapnoBase* vhodná k posouzení robustnosti a přesnosti metod v klinických situacích [8, 6].


3.2 BUT PPG

Databáze BUT PPG vznikla na Fakultě elektrotechniky a komunikačních technologií VUT za účelem zkoumání kvality PPG záznamů a odhadu TF. V nové rozšířené verzi obsahuje 3,888 desetisekundových měření od 50 dobrovolníků (25 žen a 25 mužů) ve věku 19 až 76 let, a to v klidu i při různých typech pohybových aktivit. Fotoplety-smografické záznamy byly pořízeny chytrými telefony *Xiaomi Mi9* a *Huawei P20 Pro* se vzorkovací frekvencí 30 Hz. Pro referenční EKG a akcelerometrická (ACC) data byl použit mobilní senzor *Bittium Faros 360 (nebo 180)* se vzorkovacími frekvencemi 1,000 Hz pro EKG a 100 Hz pro ACC [1, 2]. Surový PPG signál byl extrahován z červené složky nahraného videa (viz. Obr. 3.1).

Každý PPG záznam byl synchronizován s EKG a rozdělen do desetisekundových segmentů, které následně hodnotilo tři až pět expertů [2]. Pro označení kvality vycházeli výhradně z rozdílu mezi TF odhadnutou z PPG a referenční tepovou frekvencí z EKG. Pokud byla odchylka do pěti úderů za minutu, bylo dané měření označeno jako „dobré“ (1), jinak jako „špatné“ (0). Tato hranice vychází z mezinárodní normy IEC 60601-2-27 a v databázi BUT PPG je aplikována ještě přísněji [1].

Přibližně polovina záznamů vznikla přiložením prstu na zadní kameru a LED, druhá pak snímáním ucha v poloze připomínající telefonování. V novější části databáze se rozšiřuje množství subjektů i situací, včetně manipulací s osvětlením, vyšším tlakem prstu na čočku, mluvením či chůzí, a nově se přidávají i údaje o krevním tlaku, glykémii a saturaci krve kyslíkem.

Díky této variabilitě podmínek a bohatým anotacím je BUT PPG unikátním zdrojem pro testování robustnosti algoritmů detekce TF a pro posuzování použitelnosti krátkých PPG signálů z mobilního telefonu v reálné praxi.



Obr. 3.1: Záznam videa na kameru mobilního telefonu (a), jeden vybraný snímek ze záznamu (b), snímek rozložený na tři barevné složky (c), PPG signál vykreslený z červené složky (d), upraveno z [5].

Spojením klinicky orientované databáze CapnoBase a mobilně zaměřené BUT PPG vzniká možnost vzájemného porovnání a ověření přesnosti algoritmů, které musejí obstát v rozdílných kontextech: v relativně stabilním klinickém prostředí a v krátkých záznamech z chytrého telefonu.

4 Elgendiho referenční algoritmus


Tato kapitola popisuje, jak lze ve fotopletysmografickém (PPG) signálu nalézt systolické vrcholy s využitím Elgendiho algoritmu, který je implementován v knihovně NeuroKit2.

Tato knihovna reaguje na „krizi reprodukovatelnosti“, což je problém, kdy vědecké studie nelze opakovaně potvrdit kvůli nedostupnosti kódu a dat. Proto nabízí otevřený zdrojový kód, strukturovanou dokumentaci i podporu k začleňování funkcí přímo do výzkumných prací [13]. Zdrojový kód pro NeuroKit2 je dostupný na <https://github.com/neuropsychology/NeuroKit> a dokumentace na <https://neurokit2.readthedocs.io/>. Knihovnu je možné průběžně modifikovat a vyvíjet.

V kapitole 2 byly již podrobně shrnuty principy PPG, proto se zde zaměříme na samotnou detekci vrcholů a její realizaci.

4.1 Obecná struktura algoritmu


Algoritmus se skládá z několika kroků: *filtrace* pomocí pásmové propusti, *umocnění* signálu, vytvoření dvou *klouzavých průměrů* a dvou *prahů* (Obr. 4.1) [12]. Vstupem je surový fotopletysmografický záznam, zatímco výstupem jsou konkrétní časové pozice nalezených systolických vrcholů.



Obr. 4.1: Zjednodušené schéma Elgendiho algoritmu [12].

4.2 Předzpracování signálu

Pro samotnou detekci vrcholů připraví Elgendi [12] signál pomocí filtrace a umocnění kladných hodnot. Elgendi používá Butterworthův filtr druhého řádu, který je zpracován v přímém i reverzním směru (tzv. filtrace s nulovým fázovým posuvem), ale v knihovně NeuroKit2 je implementován filtr třetího řádu. My jsme se rozhodli přenastavit funkci v knihovně tak, aby odpovídala původnímu filtru druhého řádu, což je náš jediný zásah do kódu knihovny. Filtr je nastaven jako pásmová propust



Obr. 4.2: Filtrace PPG signálu pomocí Butterworthova filtru a umocnění.

s dolní a horní mezí 0,5 Hz a 8 Hz, který má potlačit ty složky signálu, které odpovídají šumu a kolísání nulové izolinie [12]. Na Obr. 4.2 je ukázka amplitudové charakteristiky filtru a porovnání původního a filtrovaného úseku signálu.

Po filtraci je kladná část signálu umocněna na druhou (4.1). To je provedeno s cílem zdůraznit rozdíly mezi systolicou vlnou a ostatními složkami, jako jsou diastolické zářezy nebo šum [12]. Výsledná hodnota $y[n]$ po umocnění je dána vztahem:

$$y[n] = \begin{cases} Z[n]^2, & \text{pokud } Z[n] > 0, \\ 0, & \text{pokud } Z[n] \leq 0. \end{cases} \quad (4.1)$$

kde $Z[n]$ představuje již vyfiltrovaný signál. Porovnání filtrovaného a umocněného signálu je ilustrováno na Obr. 4.2.

4.3 Určení bloků zájmů a nalezení vrcholů

Po úvodní filtraci a umocnění fotopletysmografického signálu vypočítává Elgendiho algoritmus dva klouzavé průměry (MA), které se od sebe liší v samotné šířce průměrujícího okna [12].

Kratší okno W_1 je nastaveno tak, aby sloužilo ke zdůraznění systolické špičky, zatímco delší okno W_2 je vybráno tak, aby zdůraznilo období celého srdečního cyklu. Tyto konstanty odpovídají šířkám oken v milisekundách, ve kterých se počítají klouzavé průměry (4.2) a (4.3). Vypočítání konkrétních velikostí oken bylo provedeno metodou „hrubé síly“ vhodných parametrů tak, že se vyzkoušely různé kombinace délek těchto a dalších a konstant. Jako nejlepší kombinace byla vybrána ta, po které dosahoval algoritmus nejvyššího skóre v citlivosti (Se) a pozitivní prediktivní hodnotě (PPV) na trénovací sadě dat [12]. Pro W_1 byla zvolena hodnota 111 (odpovídající milisekundám) a pro W_2 hodnota 667.

Výpočet klouzavých průměrů

Elgendi definuje umocněný a vyfiltrovaný PPG signál jako $y[n]$. Klouzavý průměr s kratším oknem MA_{peak} se pro každý bod n vypočítá rovnicí:

$$MA_{peak}[n] = \frac{1}{W_1} \left(y\left[n - \frac{W_1 - 1}{2}\right] + \dots + y[n] + \dots + y\left[n + \frac{W_1 - 1}{2}\right] \right), \quad (4.2)$$

kde je W_1 konstanta popsaná v podkapitole 4.3 [12]. Podobně se s delším oknem W_2 vypočítá MA_{beat} , který reprezentuje přibližnou délku jednoho srdečního cyklu:

$$MA_{beat}[n] = \frac{1}{W_2} \left(y\left[n - \frac{W_2 - 1}{2}\right] + \dots + y[n] + \dots + y\left[n + \frac{W_2 - 1}{2}\right] \right). \quad (4.3)$$

Výsledky výpočtů jsou zobrazeny na Obr. 4.3 a Obr. 4.4. Tyto klouzavé průměry slouží k vypočítání THR_1 a následných bloků zájmu, které vedou k určení systolických vrcholů.

Nastavení dvou dynamických prahů

Pro další zpracování Elgendi zvolí dvě prahové hodnoty. První dynamický práh THR_1 se vypočítá posunutím signálu MA_{beat} o konstantu β vynásobenou průměrnou hodnotou umocněného signálu $\bar{z}$ (4.4). Tuto průměrnou hodnotu vypočítá z celého umocněného signálu. β je jedním z parametrů, který byl nastaven metodou „hrubé síly“ a nejlepší výsledky vyšly, když byla β nastavena na hodnotu 2 [12].

$$THR_1[n] = MA_{beat}[n] + \beta \cdot \bar{z}. \quad (4.4)$$

První práh je vykreslen na Obr. 4.3 a Obr. 4.4 společně s klouzavými průměry a umocněným signálem. Z těchto obrázků je patrné, že parametry β ani $\bar{z}$ nemají na práh THR_1 příliš významný viditelný efekt, tudíž je křivka THR_1 velmi podobná křivce MA_{beat} .

Porovnáním $MA_{peak}[n]$ s $THR_1[n]$ získáme časové úseky (tzv. bloky zájmu), které odpovídají částem, kde je signál nad úrovní MA_{beat} .

Druhý práh THR_2 slouží k pročištění již stanovených bloků zájmů a je roven konstantě W_1 . Elgendi využívá tento práh pro eliminaci všech bloků, které jsou kratší než předem stanovená konstanta reprezentující očekávanou šířku systolické vlny [12].

Určení bloků zájmů


Porovnáním výše uvedeného klouzavého průměru MA_{peak} a prvního prahu (THR_1) jsou určeny bloky zájmu. Tyto bloky jsou definovány jako úseky n , kde je MA_{peak} větší než THR_1 a zároveň je jeho šířka větší než THR_2 (4.5) [12]. Bloky zájmu jsou zobrazeny jako šedé úseky na Obr. 4.3 a 4.4.

$$\{n : MA_{peak}[n] > THR_1[n] \wedge okno > THR_2\}. \quad (4.5)$$


Na Obr. 4.4 vidíme tři systolické vrcholy, které nebyly detekovány (kolem 74., 75. a 77. sekundy). U prvního z nich je patrné, že umocněný signál překračuje THR_1 , avšak blok je příliš krátký, a proto je vyřazen. Druhý a třetí vrchol mají ve filtrovaném signálu příliš nízkou amplitudu, což způsobuje, že po umocnění nejsou dostatečně výrazné.

Nalezení vrcholů

Samotné systolické vrcholy jsou určeny jako lokální maxima v oblastech bloků zájmu. Funkce `find_peaks` z knihovny `NeuroKit2` zpracovává jednodimenzionální signál a porovnáváním hodnot v každém bloku zájmu určuje lokální maxima [13].



Obr. 4.3: Nastavení bloků zájmu a určení systolických vrcholů pro pravidelný signál.



Obr. 4.4: Nastavení bloků zájmu a určení systolických vrcholů pro nepravidelný signál.

5 Vlastní algoritmus založený na detekci systolických vrcholů

V této kapitole se zaměříme na popis vlastního algoritmu pro detekci systolických vrcholů a odhad srdeční tepové frekvence z fotopletysmografických signálů.

Naším cílem je vytvořit jednoduchý a efektivní algoritmus, který poskytne spolehlivé výsledky pro různé typy PPG signálů.

5.1 Předzpracování PPG signálu

Načtení signálů

Jelikož pracujeme se dvěma databázemi - CapnoBase a BUT PPG, výstupem po načtení signálů jsou dvě odlišné knihovny, které zpracováváme samostatně později. Obě databáze mají odlišnou strukturu souborů a formát signálů, což vyžaduje samostatný přístup při jejich načítání.

Databáze CapnoBase obsahuje signály uložené v `.mat` souborech. Z každého souboru načítáme signál PPG, referenční systolické vrcholy a vzorkovací frekvenci [3]. Navíc si vygenerujeme referenční tepovou frekvenci (TF) z referenčních vrcholů, a to pomocí stejného algoritmu, který později použijeme pro výpočet TF z našich detekovaných vrcholů. Pro účely čitelnější vizualizace a zpracování ukládáme též identifikátor záznamu, což jsou první čtyři znaky názvu souboru.

Oproti tomu databáze BUT PPG používá formát WaveForm Database (WFDB) a obsahuje PPG záznamy v `.dat` a `.hea` souborech. Tato databáze původně obsahovala 48 záznamů, které byly později rozšířeny o dalších 3 840 záznamů. Při načítání bylo nutné zohlednit, že starší PPG signály byly uloženy v jednom kanálu, zatímco ostatní signály byly rozděleny do tří kanálů, odpovídajících třem různým barevným složkám signálu [2]. Z novějších záznamů jsme jako referenční PPG signál vybrali pouze červenou složku, která nejvíce odpovídá standardnímu PPG signálu.

Výsledkem načtení jsou dvě knihovny, které obsahují dostupná data z obou databází ve formátu vhodném pro další zpracování.

Rozdělení záznamů

Záznamy v databázi CapnoBase jsou dlouhé osm minut. Tuto délku jsme považovali za nevhodnou pro výpočet tepové frekvence, protože výsledná hodnota TF by mohla být zkreslená kratšími úseky se zvýšenou nebo sníženou TF. Mohlo by se tedy stát, že referenční a naše tepové frekvence by vykazovaly podobné výsledky, přestože by se v jednotlivých úsecích mohly výrazně lišit.


Proto jsme přistoupili k rozdělení každého dlouhého záznamu na kratší, minutové segmenty, které měly pětiprocentní překryv. Takový překryv byl zaveden proto, abychom testovali algoritmy na všech vrcholech v záznamu a nedošlo k vynechání některých vrcholů na začátku nebo na konci segmentu. Navíc takový překryv vyhovoval i proto, že počet oken popsanych v podkapitole 5.2 se rozšíří pouze o jeden. Rozdělený signál je znázorněn na Obr. 5.2. Výsledné, 63 sekund dlouhé úseky, byly dále považovány za samostatné signály, které byly zpracovány jednotlivě.

Filtrace

Po načtení a případném rozdělení záznamů následovalo filtrování signálu. Na filtraci jsme použili pásmový filtr čtvrtého řádu typu Butterworth, jehož parametry jsme nastavili s ohledem na fyziologické vlastnosti PPG signálu. Dolní mez frekvence byla nastavena na 0,5 Hz (30 úderů za minutu) a horní mez na 3,35 Hz (201 úderů za minutu). Amplitudová charakteristika filtru je znázorněna na Obr. 5.1.

Tento rozsah byl zvolen tak, aby odstranil velmi pomalé změny v signálu, například dechovou frekvenci. Zároveň tak, aby potlačil vysokofrekvenční šum, který by mohl negativně ovlivnit detekci vrcholů. V nastavení prahů vycházíme z obecných hraničních hodnot lidské tepové frekvence popsané v kapitole 1.1.

Samotný Butterworthův filtr byl zvolen pro jeho rovnost v propustném pásmu, takže amplitudová charakteristika filtru je hladká a nevykazuje vlnění, které je typické pro některé jiné typy filtrů. Čtvrtý řád zajišťuje dostatečný kompromis mezi strmostí přechodu a numerickou stabilitou filtru. Butterworthův filtr nemá nulovou fázovou charakteristiku, což znamená, že při jeho aplikaci dochází k fázovému posunu signálu. Proto jsme použili dopřednou a zpětnou filtraci.




Obr. 5.1: Amplitudová charakteristika Butterworthova filtru.

Výsledky filtrace a standardizace jsou zřetelné z Obr. 5.4. Po těchto krocích jsme získali očištěný a normalizovaný signál, připravený pro detekci systolických vrcholů.

5.2 Detekce vrcholů

Hledání vrcholů probíhá v pětisekundových oknech, která se překrývají o 50%. Nejprve analyzujeme prvních 5 sekund signálu, poté posuneme okno o 2,5 sekundy a analyzujeme dalších 5 sekund, přičemž prvních 2,5 sekund se překrývají s předchozím oknem. Tímto způsobem pokryjeme celý signál a zajistíme, že žádný vrchol nebude vynechán. Na jeden minutový signál obvykle připadá 23 oken, ale protože máme 5% překryv celého minutového záznamu, délka výsledného signálu je 63 sekund, a proto analyzujeme o jedno okno navíc. Vizualně je to znázorněno na Obr. 5.2.

Pro celý signál jsme nastavili dva prahy. První prahová hodnota odpovídala minimální výšce vrcholu, který považujeme za platný. Tato hodnota byla empiricky nastavena na 0,3 a měla za cíl odlišit skutečné vrcholy od diastolických zářezů a šumu. Druhá prahová hodnota odpovídala minimálnímu časovému intervalu mezi dvěma po sobě jdoucími vrcholy. Byla nastavena na počet vzorků odpovídající dvěma stům tepům za minutu.



Obr. 5.2: Druhá minuta záznamu s vizualizací oken a s překryvem.

V každém okně jsme provedli standardizaci a normalizaci signálu do rozsahu od -1 do 1 , abychom zajistili, že nastavené prahy budou co nejpřesněji odpovídat předpokládaným systolickým a diastolickým fázím PPG křivky. Tyto kroky jsou důležité, protože maximální hodnoty systolické vlny se mohou v průběhu času měnit, jak je patrné z Obr. 5.2, což by vedlo k falešně negativním výsledkům.

Samotná detekce vrcholů je realizována jednoduchým algoritmem hledajícím lokální maxima. Funguje tak, že každý vzorek v okně je porovnán se svým předchozím a následujícím sousedem. Pokud je jeho hodnota větší než hodnota obou sousedů a současně překračuje oba zadané prahy, je tento vzorek označen jako systolický vrchol.

V závěru se odstraní případné duplicitní detekce, které vznikly vlivem překrývání oken. Vrchol detekovaný na stejném časovém vzorku ve dvou sousedních oknech je ponechán pouze jednou. Tento krok je důležitý zejména pro budoucí hodnocení algoritmu, kde pracujeme nejen s informací o pozici vrcholů, ale také s jejich počtem v jednotlivých úsecích. Duplicitní detekce by vedly ke zkreslení metrik a nesprávné interpretaci výsledků.

Posledním krokem je zpětná kontrola minimální vzdálenosti mezi detekovanými vrcholy. Bez této kontroly by se mohlo stát, že bychom detekovali vrchol na konci prvního okna a u dalšího okna bychom detekovali nový vrchol příliš blízko, protože si nové okno nepamatuje pozici posledního, předchozího vrcholu. Příklad takové chyby je zobrazen na Obr. 5.4, ve druhém okně.

5.3 Výpočet tepové frekvence

Základní veličinou pro tento výpočet je interval mezi dvěma po sobě následujícími vrcholy, označovaný jako tepový interval IBI (z anglického „Inter-Beat Interval“). Ten jsme vypočítali tak, že jsme vzali rozdíl mezi časem detekce aktuálního vrcholu a časem detekce předchozího vrcholu:


$$IBI_i = t_i - t_{i-1}. \quad (5.1)$$

Výsledkem je sekvence hodnot, které odpovídají časovým intervalům mezi jednotlivými systolickými vrcholy.


Z těchto intervalů jsme odvodili tepovou frekvenci pomocí vztahu popsaném rovnicí (5.2).

$$TF = \frac{60}{IBI_{median}} \quad (5.2)$$

Po volbě mezi průměrem, mediánem a modem jsme se rozhodli pro medián. Na rozdíl od modové a průměrné hodnoty byl medián nejméně citlivý na extrémní hodnoty. Na Obr. 5.3 vidíme, jak se může lišit průměr, modus a medián u signálů z našich databází.



Obr. 5.3: Stanovení TF z IBI pomocí průměru, mediánu a modu.



Obr. 5.4: Ukázky zpracování signálů.


6 Využití Hjorthových deskriptorů na odhad TF a kvality signálů

V této kapitole je popsán alternativní přístup k odhadu srdeční tepové frekvence (TF) z fotopletysmografického signálu (PPG), využívající Hjorthovy deskriptory. Na rozdíl od standardních metod [4, 6, 13], které se opírají o detekci jednotlivých systolických vrcholů a výpočet IBI, využívá tento přístup frekvenční vlastnosti analyzovaného signálu. To je výhodou v případech, kdy je signál poškozen šumem, artefakty, nebo když je kladen důraz na výpočetní náročnost a rychlost algoritmu.

V podkapitole 6.2 je popsán způsob využití Hjorthových deskriptorů pro odhad kvality signálu pomocí metody náhodného lesa (RF).

Hjorthovy deskriptory představují trojici příznaků určených z časového průběhu signálu, původně zavedených Hjorthem v roce 1970 pro kvantitativní popis elektroencefalografických (EEG) signálů [14, 15]. Jedná se o *aktivitu* (H_0), *mobilitu* (H_1) a *komplexitu* (H_2), které odrážejí střední výkon, střední úhlovou frekvenci a šířku pásma. Jejich výpočet vychází čistě z časové domény a nevyžaduje Fourierovu transformaci.

V dostupné literatuře jsme nenašli studie, které by Hjorthovy deskriptory využívaly k odhadu TF z PPG signálu. Proto v této práci navrhujeme a realizujeme nový přístup založený na Hjorthově mobilitě (H_1). Tu počítáme na filtrovaných a několika-násobně autokorelovaných signálech. Struktura navrženého algoritmu je znázorněna na Obr. 6.1.



Obr. 6.1: Blokové schéma našeho využití Hjorthových deskriptorů.

6.1 Odhad TF pomocí Hjorthovy mobility

Jak již bylo uvedeno, Hjorthova mobilita (H_1) představuje odhad střední (resp. dominantní) frekvence signálu v časové oblasti, a to bez nutnosti výpočtu Fourierovy

transformace.

Načtení signálů z databází probíhá stejným způsobem jako u našeho prvního algoritmu, popsaného v podkapitole 5.1. Odlišný přístup jsme však zvolili při dělení signálů. Zatímco v předchozím algoritmu jsme signály z CapnoBase databáze dělili na minutové úseky, zde si můžeme ve vstupu funkce zvolit libovolný počet úseků, na které signál rozdělíme. Maximální počet těchto úseků odpovídá situaci, kdy jeden úsek trvá 10 s. Pokud zbyde po rozdělení signálu část, která je kratší než délka jednoho úseku, tak ji dále nezpracováváme. Je proto důležité zvolit takové dělení, které minimalizuje délku zahozených úseků. Alternativou by bylo upravit algoritmus tak, aby zbylé části zpracoval samostatně, nebo je přiřadil k předchozímu úseku. Tím bychom však porovnávali signály různých délek, což by mohlo výsledky zkreslit.

Předzpracování

U analyzovaných signálů jsme provedli standardizaci. Nejprve jsme odstranili stejnosměrnou (DC) složku signálu, tedy jeho střední hodnotu μ . Tento krok slouží k centrování signálu kolem nuly, čímž omezíme vliv DC složky na výpočet rozptylu signálu. Ve druhém kroku standardizace jsme dělili signál zbavený hodnoty μ jeho směrodatnou odchylkou σ . Rovnice pro standardizaci signálu je následující:


$$x[n] = \frac{x[n] - \mu}{\sigma}. \quad (6.1)$$

Následně byl signál filtrován Butterworthovým hornopropustným filtrem čtvrtého řádu s mezní frekvencí 0,5 Hz v obou směrech. Jeho amplitudová charakteristika i její druhá mocnina jsou zobrazeny na Obr. 6.2. Cílem této filtrace bylo potlačení respirační složky, přičemž prahová frekvence byla zvolena na základě předpokládané minimální hodnoty TF, jak je uvedeno v podkapitole 1.1.

Získaný signál byl dále sedmkrát za sebou autokorelován. Autokorelace je operace, při které se signál koreluje sám se sebou při různých časových posunech. Sedminásobná iterace byla zvolena na základě empirického pozorování výsledků na desetisekundových signálech z databáze CapnoBase. Cílem opakované autokorelace je zvýraznění dominantní periodické složky signálu. Klasická autokorelační funkce diskrétního signálu $x[n]$ je definovaná jako:

$$r_x[m] = \sum_{n=0}^{N-m-1} x[n] \cdot x[n+m], \quad (6.2)$$

kde N je délka signálu a m je zpoždění. Výpočet probíhal ve frekvenční oblasti pomocí rychlé Fourierovy transformace, čímž se snížila výpočetní náročnost na $O(i \cdot N \log N)$, kde i je počet iterací autokorelace. Bez použití FFT by byla složitost $O(N^2)$.



Obr. 6.2: Amplitudová charakteristika hornopropustného filtru.

Po každé iteraci autokorelace byl signál převeden do rozsahu $\langle -1, 1 \rangle$ pomocí normalizace podle maximální absolutní hodnoty:


$$\hat{x}[n] = \frac{x[n]}{\max |x[n]|}. \quad (6.3)$$

Tato normalizace byla nezbytná, protože iterovaná autokorelace způsobuje exponenciální nárůst hodnot, což by vedlo k numerické nestabilitě a zkreslení výpočtu Hjorthových deskriptorů.

Opakovanou autokorelací dochází ke zvýšení spektrální ostrosti pro dominantní frekvenční složku, což jsme vyhodnotili jako žádoucí pro náš účel.

Porovnání spektra signálu před a po iterované autokorelaci je znázorněno na Obr. 6.3. Horní část grafu zobrazuje časové průběhy původního, filtrovaného a autokorelovaného signálu, spodní část pak odpovídající spektra získaná pomocí rychlé Fourierovy transformace. Amplitudové spektrum bylo vypočteno výhradně pro účely vizualizace a nefiguruje v samotném výpočtu Hjorthových deskriptorů. Pro účely porovnání byla všechna spektra převedena na relativní jednotky pomocí normalizace vůči maximální hodnotě amplitudy daného signálu.

U běžných PPG signálu odpovídají periodické složky systolickým fázím, diastolickým fázím a respiračním složkám. Pro potlačení respiračních složek jsme použili hornopropustný filtr a pro potlačení složek diastolických fází jsme použili sedm iterací autokorelace.



Obr. 6.3: Porovnání původního, filtrovaného a autokorelovaného signálu.

Výpočet TF z mobility

Po předzpracování signálu jsme vypočítali Hjorthovu mobilitu. Ta je definována [14, 17] jako druhá odmocnina poměru rozptylu první derivace signálu ku rozptylu signálu samotného:

$$H_1 = \sqrt{\frac{\text{var}(x[n] - x[n-1])}{\text{var}(x[n])}} = \sqrt{\frac{\text{var}(x')}{\text{var}(x)}} = \frac{\sigma_{x'}}{\sigma_x}. \quad (6.4)$$

Jelikož pracujeme v diskrétním prostředí, je derivace aproximována první diferencí.

Rozptyl signálu x je dán vztahem:

$$\text{var}(x) = \frac{1}{N} \sum_{n=0}^{N-1} (x[n] - \mu)^2, \quad (6.5)$$

kde N je délka okna a μ je střední hodnota signálu.

Podobně je definován i rozptyl první derivace signálu x' , přičemž první diferenci nelze definovat pro vzorek $n = 0$, takže součet začíná až od $n = 1$:

$$\text{var}(x') = \frac{1}{N-1} \sum_{n=1}^{N-1} (x'[n] - \mu')^2. \quad (6.6)$$

Z hodnoty H_1 jsme následně odvodili dominantní frekvenci f_{dom} [Hz], kterou jsme vynásobili šedesáti, abychom dostali odpovídající hodnotu TF v tepech za minutu:

$$\text{TF}_{\text{Hjorth}} = 60 \cdot f_{dom} = \frac{60 \cdot H_1}{2\pi}. \quad (6.7)$$

Hodnota dominantní frekvence je graficky znázorněna i písemně zmíněna na Obr. 6.3 společně s odpovídající tepovou frekvencí a referenční hodnotou TF z databáze.

Přestože mají klasické metody detekce vrcholů [12] lineární průchod signálem s asymptotickou složitostí $O(N)$, jejich praktická složitost může být vyšší kvůli víceprůchodovým algoritmům, adaptivním prahům, filtrováním nebo nastavováním bloků zájmu (popsané v podkapitole 4.3).

Naopak výpočet Hjorthovy mobility má sice po i iteracích autokorelace (prováděné pomocí FFT) složitost $O(i \cdot N \log N)$, avšak díky své jednoduchosti a absenci větvení může být v praxi rychlejší.

Výsledky odhadu TF na základě Hjorthovy mobility jsou popsány v kapitole 7, přičemž porovnání rychlosti exekuce algoritmů je uvedeno v Tab. 7.1 a Tab. 7.2.

6.2 Hodnocení kvality PPG signálů

Tato podkapitola popisuje metodu automatického hodnocení kvality PPG signálů pomocí Hjorthových deskriptorů s využitím klasifikátoru typu náhodný les (RF). Cílem této analýzy je ověřit, zda kombinace indexu spektrální čistoty (SPI) a Shannonovy entropie, postačuje k automatické binární klasifikaci PPG signálů na základě jejich kvality definované referenčním algoritmem od Orphanidou z knihovny NeuroKit2 [13].

Segmentace a předzpracování signálů

Klasifikátor byl trénován na signálech ze dvou databází: CapnoBase a BUT PPG, jejichž záznamy se liší délkou, jak podrobněji popisujeme v kapitole 3.

Pro zajištění srovnatelnosti Hjorthových deskriptorů mezi oběma databázemi byly signály z CapnoBase rozděleny na nepřekrývající se segmenty o délce 10 s, což odpovídá délce jednotlivých záznamů v databázi BUT PPG. Tato segmentace zároveň přispívá ke konzistenci vstupních dat a zvyšuje přesnost rozhodování jednotlivých stromů klasifikátoru.

Následně byly signály z CapnoBase převzorkovány na vzorkovací frekvenci 30 Hz, aby odpovídaly frekvenci signálů z databáze BUT PPG. Převzorkování bylo realizováno pomocí funkce `resample` z knihovny `scipy`, která implementuje Fourierovu interpolaci. Jelikož tato metoda neobsahuje předběžnou dolnofrekvenční filtraci, mohlo by při přítomnosti vyšších frekvenčních složek dojít k aliasingu.

Abychom tomuto jevu předešli, aplikovali jsme před převzorkováním dolnoproustný filtr typu Butterworth čtvrtého řádu s mezní frekvencí 14 Hz. Tím jsme

potlačili složky nad polovinou cílové vzorkovací frekvence a zachovali pouze spektrum relevantní pro analýzu srdeční činnosti.

Po sjednocení délky a vzorkovací frekvence byly všechny signály standardizovány (6.1). V souladu s postupem uvedeným v podkapitole 6.1 jsme dále odstranili nízkofrekvenční složky pod 0,5 Hz. Zde jsme navíc potlačili i složky nad 3,35 Hz (201 tepů za minutu), čímž jsme omezili spektrum pouze na fyziologicky očekávané rozsahy srdeční frekvence.

Výpočet příznaků pro náhodný les

Prvním příznakem je index spektrální čistoty (SPI), který je definován jako převrácená hodnota komplexity:

$$SPI = \frac{1}{H_2} = \frac{\sigma_{x'}^2}{\sigma_{x''} \cdot \sigma_x} [-]. \quad (6.8)$$

Hjorthova komplexita (H_2) kvantifikuje míru toho, jak se signál v čase odchyluje od harmonického průběhu. Je definována jako poměr mobility (6.4) první derivace signálu ku mobilitě samotného signálu [14, 17]:

$$H_2 = \sqrt{\frac{H_1(x')}{H_1(x)}} = \sqrt{\frac{\text{var}(x'')/\text{var}(x')}{\text{var}(x')/\text{var}(x)}} = \frac{\sigma_{x''} \cdot \sigma_x}{\sigma_{x'}^2} [-], \quad (6.9)$$

kde x , x' , x'' jsou signál, jeho první derivace a jeho druhá derivace. σ_x označuje směrodatnou odchylku. Pro čistě harmonický signál, jako je sinusoida, by vycházelo $H_2 = 1$. S rostoucím podílem vyšších frekvenčních složek se však signál stává proměnlivějším, a tím roste hodnota H_2 . To znamená, že SPI, definovaná jako obrácená hodnota komplexity, bude klesat s rostoucí nepravidelností signálu.

Druhým příznakem je Shannonova entropie, která měří míru neuspořádanosti signálu na základě jeho rozdělení hodnot. Jde o metriku založenou na teorii informace, jež vyjadřuje očekávané množství informace potřebné k popisu jedné hodnoty ze signálu:

$$S = - \sum_{i=1}^N p_i \cdot \log_2(p_i) [\text{bit}], \quad (6.10)$$

kde p_i je pravděpodobnost, že hodnota signálu spadá do i -tého intervalu histogramu a N je celkový počet binů.

Pro výpočet histogramu byl signál nejprve normalizován do intervalu $< 0, 1 >$ a následně rozdělen do $N = 30$ stejně širokých binů. Tento počet byl zvolen empiricky jako kompromis mezi rozlišením a stabilitou odhadu, při vědomí, že konstantní délka signálu je 10 s a vzorkovací frekvenci 30 Hz.

Shannonova entropie nabývá nízkých hodnot u pravidelných signálů s úzkým rozdělením (např. téměř periodická sinusoida), zatímco chaotické nebo arteficiální

signály, jejichž hodnoty se rozprostírají napříč celým intervalem, vykazují vyšší entropii.

Oba příznaky jsou standardizovány pomocí funkce `StandardScaler`, aby byl zajištěn jejich jednotný váhový vliv při klasifikaci.

Náhodný les

Pro odhad kvality signálů jsme použili již zmíněný klasifikátor náhodný les (RF), který tvoří sadu rozhodovacích stromů a kombinuje jejich výstupy hlasováním. Na rozdíl od lineárních modelů dokáže zachytit i nelineární vztahy mezi příznaky.

Použili jsme implementaci `RandomForestClassifier` z knihovny `scikit-learn` s výchozími parametry: `n_estimators = 100` (počet stromů), `max_depth = 5` (maximální hloubka stromu) a `max_features = sqrt` (pro každý uzel se testuje náhodně vybraná odmocnina z celkového počtu příznaků). Optimalizace těchto parametrů byla provedena pomocí metody `GridSearchCV` ze stejné knihovny, která systematicky vybírá nejlepší kombinace z námi předdefinovaných hodnot parametrů. Pro zajištění deterministického chování jsme parametr náhodné inicializace nastavili na hodnotu `random_state = 42`.

Rozdělení datasetu do trénovací a testovací množiny proběhlo v poměru 60 % ku 40 %, přičemž jsme použili stratifikaci, abychom zachovali poměr tříd (kvalitní/nekvalitní signály). Jelikož datová sada vykazovala nevyváženost tříd, aktivovali jsme parametr `class_weight='balanced'`, který upravuje váhy jednotlivých tříd podle jejich četnosti. To zajišťuje, že model nebude preferovat většinovou třídu, ať už kvalitní nebo nekvalitní.


Jednou z výhod RF je možnost kvantifikovat důležitost jednotlivých příznaků na základě jejich vlivu na rozhodování stromů, což přispívá k interpretovatelnosti modelu a transparentnosti výsledků, jak je zobrazeno na Obr. 6.4.

Výkonnost modelu jsme hodnotili pomocí pětinasobného křížového ověření, což umožňuje stabilní odhad generalizační chyby bez závislosti na konkrétním rozdělení dat. Jako hlavní metriku jsme zvolili F_1 skóre, které je definované jako harmonický průměr mezi přesností (PPV) a citlivostí (Se).

Výstupem modelu je pravděpodobnostní binární skóre kvality signálů. To lze chápat jako hlasování lesa o každém testovaném signálu, zda je daný signál kvalitní nebo ne.

Referenční hodnota kvality

Databáze BUT PPG [1, 2] poskytuje binární anotace kvality signálů založené na schopnosti odhadnout tepovou frekvenci z PPG. Segment je označen jako kvalitní, pokud alespoň tři z pěti expertů určili TF s absolutní chybou do 5 tepů za minutu



Obr. 6.4: Důležitost příznaků pro klasifikaci kvality signálů pomocí náhodného lesa.

vůči referenci z EKG. Tato anotace však vychází z lidského úsudku a konkrétní implementace referenčního algoritmu, což omezuje její objektivitu a opakovatelnost.

Proto jsme se rozhodli použít alternativní metodu hodnocení kvality signálů založenou na práci Orphanidou et al. [9] a její implementaci v knihovně **NeuroKit2** [13]. Zvolený algoritmus posuzuje kvalitu signálu na základě tzv. adaptivního porovnávání tvaru pulzních vln.

V první fázi algoritmus aplikuje heuristická pravidla, která ověřují, zda se inter-beat intervaly a srdeční frekvence nachází ve fyziologicky věrohodném rozmezí. Pokud tyto pravidla nejsou splněny, je segment automaticky označen jako nekvalitní. Ve druhé fázi se detekují jednotlivé pulzy v signálu, vytvoří se průměrná šablona pulzní vlny a následně se spočítá korelační koeficient mezi touto šablonou a každým detekovaným pulzem. Průměrná korelace slouží jako měřítko morfologické pravidelnosti a stability v čase.


Výstupem je spojitě skóre kvality pro každý pulz v rozsahu $< 0, 1 >$, kde vyšší hodnoty značí vyšší míru podobnosti mezi pulzy. Pro účely binární klasifikace jsme vypočítali průměrné skóre z výstupního řetězce hodnot a následně jsme zvolili prahovou hodnotu 0,9, což odpovídá vysoké kvalitě signálu. Tato metoda je plně automatická, replikovatelná a vhodná pro trénování algoritmů založených na strojovém učení.

Obr. 6.6 ukazuje rozptyl skóre kvality dle Orphanidou pro celou BUT PPG databázi a jejich vztah k binární anotaci. Je patrné, že se hodnoty kvalit neshodují. Např. Obr. 6.5 zobrazuje jeden ze signálů, který byl experty označen jako kvalitní,


ale hodnota kvality dle Orphanidou je přibližně 0,59. Chyba referenčního odhadu TF je u tohoto signálu 26 tepů za minutu.

Z těchto důvodů považujeme skóre podle Orphanidou za vhodnější základ pro trénink modelu automatického hodnocení kvality PPG signálu.

Úspěšnost algoritmů odhadujících TF budeme hodnotit pomocí obou referenčních hodnot kvality. Výsledky těchto algoritmů budou popsány v kapitole 7.



Obr. 6.5: Příklad signálu označeného jako kvalitní, přestože obsahuje silné artefakty a vykazuje vysokou chybu odhadu TF.



Obr. 6.6: Porovnání kvality dle Orphanidou a referenční anotace z databáze BUT PPG.

7 Výsledky

Tato kapitola obsahuje výsledky odhadu tepové frekvence z fotopletysmografických signálů pomocí tří různých metod: referenčního Elgendiho algoritmu, vlastního algoritmu založeného na detekci systolických vrcholů a nově navržené metody využívající Hjorthovy deskriptory.

Výsledky jsou vyhodnoceny samostatně pro obě použité databáze: CapnoBase a Brno University of Technology Smartphone PPG Database. Výsledky automatického posouzení kvality signálů jsou shrnuty v podkapitole 7.3.

7.1 Výsledky pro databázi CapnoBase

U této databáze máme k dispozici referenční hodnoty systolických vrcholů, a proto můžeme použít statistické metody pro vyhodnocení kvality detekce, jako je citlivost (Se), pozitivní prediktivní hodnota (PPV) a F1 skóre. Citlivost vyjadřuje procento vrcholů, které použitý algoritmus správně rozpoznal z celkového počtu *referenčních* vrcholů:

$$Se = \frac{TP}{TP + FN} \cdot 100\%. \quad (7.1)$$

Vyšší citlivost znamená nižší riziko, že algoritmus opomene detekovat skutečný vrchol.

Pozitivní prediktivní hodnota vyjadřuje procento vrcholů, které vybraný algoritmus určil správně z celkového počtu *detekovaných* vrcholů:

$$PPV = \frac{TP}{TP + FP} \cdot 100\%. \quad (7.2)$$

Vyšší hodnota PPV znamená, že algoritmus detekuje méně falešných vrcholů.

F1 skóre je harmonický průměr citlivosti a PPV vyjádřen v procentech:

$$F1 = 2 \cdot \frac{Se \cdot PPV}{Se + PPV} \cdot 100\%. \quad (7.3)$$

Tyto metriky počítáme pouze pro Elgendiho algoritmus a vlastní algoritmus detekce vrcholů, kvůli povaze algoritmu využívajícího Hjorthovu mobilitu, který neprovádí detekci vrcholů, ale přímo odhaduje tepovou frekvenci. Když jsme je ale počítali, nastavili jsme toleranční pásmo pro výpočet matice záměn na $\pm 0,1$ s, které nám definuje, jak daleko od referenčního vrcholu se může detekovaný vrchol nacházet, aby byl považován za správně detekovaný. V Tab. 7.1 jsou hodnoty Se a PPV vypočítány ze součtu všech TP, FP a FN. F1 skóre je pak vypočítáno z těchto hodnot.

Dále jsme vyhodnotili průměrnou absolutní chybu (MAE) mezi referenční a odhadovanou tepovou frekvencí dle rovnice (7.4).

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |TF_{i,ref} - TF_{i,est}|. \quad (7.4)$$

Jako dodatečné kritérium jsme stanovili poměr mezi dobře a špatně odhadnutými signály. Za dobře odhadnuté byly považovány signály s MAE menší než 5 bpm, což odpovídá prahové hodnotě dle mezinárodního standardu IEC 60601-2-27 a metodice databáze BUT PPG [1]. V tabuce používáme označení „d:š“ pro poměr „dobře:špatně“ odhadnutých signálů.

Poslední sledovanou metrikou byla výpočetní náročnost jednotlivých algoritmů, vyjádřená jako celkový čas potřebný ke zpracování celé databáze CapnoBase. Výpočty probíhaly na platformě Apple M1. Hodnoty jsou orientační a slouží pouze k vzájemnému srovnání mezi algoritmy. Vzhledem k rozdílným charakteristikám databází (odlišná vzorkovací frekvence, délka i počet signálů, datový formát) nejsou časy mezi CapnoBase a BUT PPG přímo srovnatelné.


Metriky přesnosti pro všechny tři algoritmy jsou uvedeny v Tab. 7.1, a to vždy pro různé délky vstupního signálu.

Tab. 7.1: Srovnání metod odhadu TF.


Metoda (délka [s])	Se [%]	PPV [%]	F1 [%]	MAE [bpm]	Poměr [d:š]	Čas [s]
Elgendi (480)	99,81	99,89	99,85	0,31	42:0	1,37
Elgendi (62,5)	99,23	99,88	99,55	0,35	336:0	1,65
Vlastní vrcholová detekce (480)	99,34	99,91	99,63	0,31	42:0	2,4
Vlastní vrcholová detekce (62,5)	98,49	99,91	99,20	0,37	336:0	2,7
Hjorth (480)	—	—	—	1,52	40:2	2,6
Hjorth (60)	—	—	—	0,80	332:4	2,7
Hjorth (10)	—	—	—	0,61	2015:1	14,5

Na Obr. 7.1 a Obr. 7.2 je znázorněno srovnání citlivosti a přesnosti mezi vlastní metodou detekce vrcholů a referenční Elgendiho metodou. První obrázek zobrazuje výsledky pro minutové úseky (přeneji 62,5 s), zatímco druhý shrnuje výstupy pro celé osmiminutové záznamy. Nejnižší hodnotu citlivosti vykazuje náš algoritmus ve druhé minutě signálu 0115, což odpovídá případu zobrazenému na Obr. 7.3.

Je důležité poznamenat, že zobrazené hodnoty Se a PPV se v grafech liší od hodnot uvedených v Tab. 7.1. V tabulce jsou hodnoty vypočteny jako agregovaná




Obr. 7.1: Srovnání metod detekující vrcholy pro minutové úseky.



Obr. 7.2: Srovnání metod detekující vrcholy celý signál.


hodnota pro celou databázi (tj. globální součet všech TP, FP a FN). Na druhou stranu, v grafech jsou vypočítané hodnoty Se a PPV individuálně, a z těch je následně vypočítán a vykreslen průměr. Tento přístup lépe odpovídá srovnání výkonnosti napříč jednotlivými záznamy, zatímco tabulková metrika lépe charakterizuje celkový výkon algoritmů.

Bland-Altmanovy grafy znázorněné na Obr. 7.5 porovnávají rozdíl mezi odha-




Obr. 7.3: Chybný odhad TF pomocí vlastní vrcholové detekce.

dovanou a referenční tepovou frekvencí pro obě metody detekce vrcholů. Výsledky jsou rozděleny nejen podle použité metody (vlastní versus Elgendi), ale také podle délky analyzovaných úseků – zvlášť pro celé osmiminutové signály a zvlášť pro jejich 62,5 s dlouhé úseky. V grafech jsou vyznačeny průměrné odchylky (ME) jako zelená přerušovaná čára, zatímco hranice shody, definované jako $\pm 1,96 \cdot SD$, jsou znázorněny červenými přerušovanými čarami. Tato rozdílová analýza umožňuje posoudit, jak výrazně se odhady liší od referenčních hodnot, a zda je chyba závislá na velikosti tepové frekvence.




Obr. 7.4: Chybný odhad TF pomocí Hjorthových deskriptorů u nekvalitního signálu.

Obr. 7.6 zachycuje výsledky Bland-Altmanovy analýzy pro metodu využívající Hjorthovy deskriptory. Grafy jsou opět rozděleny dle délky analyzovaných úseků: horní pro celé signály, prostřední pro minutové segmenty a spodní pro desetisekundové úseky. V posledním grafu byly zahrnuty pouze signály označené jako kvalitní, čímž byl vyloučen jeden extrémně odlehlý případ (signál 0147, 25. minuta), který by vzhledem ke své vysoké chybě narušil škálu zobrazení. Tento úsek je detailně zachycen na Obr. 7.4, kde je patrná výrazná deformace signálu a posun dominantní frekvence. Společně s ním bylo vyloučeno dalších 15 signálů.



Obr. 7.5: Bland-Altmanova analýza pro metody detekující vrcholy.



Obr. 7.6: Bland-Altmanova analýza pro metodu využívající Hjorthovy deskriptory.

7.2 Výsledky pro databázi BUT PPG

Databáze BUT PPG neobsahuje referenční anotace systolických vrcholů, a není proto možné vyhodnotit metriky citlivosti (Se), přesnosti (PPV) ani F1 skóre. Pro posouzení výkonu jednotlivých algoritmů při odhadu tepové frekvence jsme proto použili průměrnou absolutní chybu (MAE) definovanou rovnicí (7.4). Za správně odhadnuté byly považovány ty signály, u nichž byla MAE menší než 5 bpm, tedy ve shodě s prahovou hodnotou použitou již v předchozí podkapitole a doporučenou dle normy IEC 60601-2-27.

Jelikož se v databázi nachází značný počet nekvalitních signálů, byly výsledky interpretovány s ohledem na kvalitu vstupních dat. K tomu byly využity dvě hodnoty: původní, referenční skóre R-SQI, přítomné v metadatech databáze, a dále skóre O-SQI získané pomocí algoritmu podle Orphanidou, detailněji popisovaného v podkapitole 6.2. Obě hodnoty umožňují binárně rozdělit signály na kvalitní a nekvalitní, což následně slouží k oddělenému hodnocení přesnosti odhadů TF.

Souhrnné výsledky pro všechny tři metody odhadu TF jsou uvedeny v Tab. 7.2. Výsledky jsou prezentovány ve třech scénářích: pro celou databázi, pro signály označené jako kvalitní na základě R-SQI a pro kvalitní signály dle O-SQI. Podobně jako u vyhodnocení databáze CapnoBase jsou kromě hodnoty MAE uvedeny také poměry dobře a špatně ([d:š]) odhadnutých tepových frekvencí a orientační výpočetní čas algoritmů.


Tab. 7.2: Srovnání metod odhadu TF.

	celá databáze		R-SQI		O-SQI		
Metoda	MAE [bpm]	Poměr [d:š]	MAE [bpm]	Poměr [d:š]	MAE [bpm]	Poměr [d:š]	Čas [s]
Elgendi	18,84	875:2.797	6,73	511:299	7,82	177:90	49,46
Vlastní vrcholová detekce	20,54	875:2.797	7,80	507:303	7,12	183:84	45,48
Hjorth	31,22	624:3.048	12,98	497:313	8,05	182:85	79,27


Rozdíl mezi referenční a odhadovanou TF na databázi BUT PPG znázorňují Bland-Altmanovy grafy na Obr. 7.8, Obr. 7.9 a Obr. 7.10, a to zvlášť pro všechny tři zkoumané metody: Elgendiho algoritmus, vlastní metodu detekce vrcholů a metodu využívající Hjorthovy deskriptory. Každý z grafů je rozdělen podle způsobu hodnocení kvality signálu: celá databáze, signály označené jako kvalitní dle R-SQI a signály označené jako kvalitní podle O-SQI. V grafech je vykreslena střední odchylka

(ME) a hranice shody $\pm 1,96$ směrodatné odchylky (SD), což odpovídá 95% limitům shody.


Pro bližší pohled na konkrétní hodnoty odhadované a referenční TF byl zkonstruován graf na Obr. 7.7, který zobrazuje výstup Hjorthovy metody pro podmnožinu signálů označených jako kvalitní pomocí O-SQL. Horní panel zobrazuje obě časové řady — referenční a odhadovanou TF — pro každý signál, zatímco dolní panel ukazuje absolutní hodnotu rozdílu mezi nimi. Přerušovaná čára vyjadřuje průměrnou absolutní chybu (MAE) spočtenou na této množině.




Obr. 7.7: Porovnání TF pro jednotlivé signály s vysokým O-SQL skóre.



Obr. 7.8: Bland-Altmanova analýza pro Elgendiho metodu.



Obr. 7.9: Bland-Altmanova analýza pro naši metodu detekující vrcholy.




Obr. 7.10: Bland-Altmanova analýza pro metodu využívající Hjorthovy deskriptory.

7.3 Výsledky automatického posouzení kvality


K automatickému hodnocení kvality PPG signálů jsme využili model náhodného lesa (RF), který jako vstupní příznaky využívá Shannonovu entropii a spektrální index výkonu (SPI). Model byl trénován na kombinovaných datech z databází CapnoBase a BUT PPG, zpracované podle metodiky popsané v podkapitole 6.2. Za referenční hodnotu kvality jsme zvolili skóre podle metody Orphanidou (O-SQI), u které jsme vypočítali průměrnou hodnotu výstupního řetězce O-SQI a nastavili prahovou hodnotu na 0,9. Podrobněji je metoda popsána v podkapitole 6.2.

Na Obr. 7.11 je vykreslena ROC křivka vyhodnoceného klasifikačního modelu. Na ose x je míra falešně pozitivních případů (FPR), zatímco osa y zobrazuje míru skutečně pozitivních případů (TPR, též Se). Plocha pod křivkou (AUC) dosahuje hodnoty 0,957.



Obr. 7.11: ROC křivka pro automatické posouzení kvality signálů.

Obr. 7.12 zobrazuje prostor příznaků modelu ve dvou rozměrech: Shannonova entropie a SPI. Data jsou barevně odlišena podle binárního označení kvality dle Orphanidou a tvarově odlišena podle databáze, ze které pocházejí.



Obr. 7.12: Prostor příznaků pro BUT PPG a CapnoBase s přiblížením na přechodovou část.

Souhrnné metriky přesnosti klasifikace pro jednotlivé třídy (kvalitní vs. nekvalitní) a databáze uvádíme v Tab. 7.3. Pro každou skupinu jsou uvedeny hodnoty citlivosti (Se), pozitivní prediktivní hodnoty (PPV), F1 skóre a počet signálů (podpora), které byly použity k vyhodnocení metrik na testovací množině. Tyto metriky byly vypočteny zvlášť pro každou třídu a databázi na základě stejných trénovaných modelů, přičemž třída 0 odpovídá nekvalitním a třída 1 kvalitním signálům.


Tab. 7.3: Souhrnné metriky přesnosti klasifikace automatického posouzení kvality signálů pro jednotlivé databáze a třídy.

Databáze	Třída	Se [%]	PPV [%]	F1 [%]	Podpora
Všechny	0	89,77	91,99	90,86	1.368
	1	88,22	85,12	86,64	908
CapnoBase	0	0,00	0,00	0,00	3
	1	90,78	99,59	94,98	803
BUT PPG	0	89,96	97,38	93,53	1.365
	1	68,57	34,45	45,86	105

Hodnoty v tabulce nejsou odvozeny z křížového ověření modelu, ale z testovací množiny, která byla vytvořena z dat, jež nebyla použita při trénování modelu. Výsledky křížového ověření modelu na všech signálech jsou vůči testovací množině skeptičtější o 1,1 %.

Výslednou klasifikaci modelu ilustruje matice záměn na Obr. 7.13, kde jsou znázorněny výsledky pro celou testovací množinu, a dále odděleně pro databáze CapnoBase a BUT PPG.

Hodnoty v maticích odpovídají počtům případů rozdělených podle skutečné a predikované třídy: levý horní čtverec (TN), pravý horní čtverec (FP), levý dolní čtverec (FN), pravý dolní čtverec (TP).



Obr. 7.13: Matice záměn pro automatické posouzení kvality signálů.

Na základě těchto matic byla vypočtena klasifikační úspěšnost (Acc) i metriky pro jednotlivé třídy, které jsou shrnuty v Tab. 7.3. Klasifikační přesnost se počítá jako podíl správně klasifikovaných signálů z celkového počtu signálů v testovací množině.

$$\text{Acc} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \cdot 100\% \quad (7.5)$$

Výsledky pro celou testovací množinu dosahují klasifikační úspěšnosti 89,15 %. Pro databázi BUT PPG je klasifikační úspěšnost 88,44 %, zatímco pro databázi CapnoBase dosahuje 90,45 %.

8 Diskuze

Tato kapitola se věnuje interpretaci dosažených výsledků při odhadu srdeční tepové frekvence (TF) ze signálu PPG pomocí tří odlišných metod: Elgendiho algoritmu, vlastního algoritmu detekce vrcholů a přístupu založeného na Hjorthových deskriptorech. Uvedené metody byly testovány na dvou databázích: CapnoBase a BUT PPG.

Samostatně je diskutováno také automatické hodnocení kvality signálu na základě Shannonovy entropie a indexu spektrální čistoty (SPI).

8.1 Interpretace výkonu metod odhadu TF pro CapnoBase


Na databázi CapnoBase dosahují obě metody detekce vrcholů (Elgendi a vlastní algoritmus) vysoké hodnoty Se i PPV, což se projevuje velmi nízkou průměrnou absolutní chybou ($MAE \approx 0,34$ bpm). Srovnání metod na Obr. 7.1 a Obr. 7.2 ukazuje, že vlastní algoritmus vykazuje mírně nižších hodnot Se, tedy detekuje méně skutečných vrcholů, avšak zároveň dosahuje o něco vyšší hodnoty PPV, což naznačuje nižší podíl falešně pozitivních detekcí.

Nejnižší hodnota Se pro vlastní detekci byla zaznamenána ve druhé minutě signálu 0115, kde silná respirační složka výrazně ovlivnila rozsah systolické vlny (viz Obr. 7.3). Prahová hodnota, kterou jsme při konstrukci algoritmu zvolili, nebyla adaptabilní a v tomto případě byla nastavena na příliš vysokou hodnotu, takže náš algoritmus detekoval méně vrcholů, než bylo žádoucí. Možnost opravy by bylo zvýšit spodní mezní frekvenci použitého filtru, čímž bychom utlumili respirační složku signálu.

Naproti tomu u signálu 0312 (Obr. 8.1) dosáhl náš algoritmus vyššího PPV díky konzervativnějšímu nastavení prahu, které umožnilo vyloučení falešných maxim.

Vzhledem k velmi podobnému skóre F1 lze obě detekční metody považovat za srovnatelně výkonné. U všech signálů (osmiminutových i minutových) splňují požadavek mezinárodní normy IEC 60601-2-27, která stanovuje maximální odchylku od referenční TF ± 5 bpm.

Metoda založená na Hjorthových deskriptorech vykazuje pro celou délku signálů vyšší průměrnou chybu ($MAE = 1,52$ bpm), její výkonnost se však výrazně zlepšuje s kratšími segmenty. Při analýze desetisekundových úseků dosahuje průměrné chyby pouze 0,61 bpm, což je velmi slibný výsledek. Oproti metodám detekce vrcholů, jejichž přesnost je víceméně konstantní, je zde patrná závislost na délce segmentu, což by v praktických aplikacích vyžadovalo optimalizaci délky vstupního signálu.



Obr. 8.1: Porovnání výkonu metod detekce vrcholů - CapnoBase.

Vedle MAE byla hodnocena i úspěšnost metody z hlediska podílu segmentů, které splňují požadavky normy IEC. Výsledky jsou v tomto ohledu horší než u detekčních algoritmů, nicméně pro krátké a kvalitní segmenty dosahuje Hjorthova metoda velmi dobrých výsledků. Zejména u desetisekundových segmentů byla identifikována pouze jediná instance nesplňující kritérium odchylky, přičemž šlo o signál výrazně zatížený artefakty a vyhodnocený jako nekvalitní na základě metriky O-SQI (viz Obr. 7.4).

Lze tedy konstatovat, že pro krátké, kvalitní segmenty signálů z databáze CapnoBase dosahuje metoda založená na Hjorthových parametrech 100% úspěšnosti v rámci požadavků IEC 60601-2-27.

Pro posouzení systematických odchylek mezi odhadem a referencí byla provedena Bland-Altmanova analýza (Obr. 7.5 a Obr. 7.6). U obou detekčních metod je patrná

slabá závislost chyby na velikosti průměrné TF (s rostoucí TF narůstá rozptyl i výskyt extrémních chybových hodnot). U Hjorthovy metody jsou hranice shod širší, a tedy i variabilita odhadu vyšší, nicméně průměrná chyba je srovnatelná. Tato metoda navíc nevykazuje výraznou závislost na velikosti TF, což by mohlo být výhodné při odhadu v dynamicky proměnných podmínkách.

Použití Hjorthovy mobility pro odhad TF představuje inovativní přístup, který se ukázal jako slibný zejména v případech krátkých a kvalitních úseků signálu.

8.2 Interpretace výkonu metod odhadu TF pro BUT PPG


Vzhledem k absenci referenčních anotací systolických vrcholů v databázi BUT PPG bylo hodnocení výkonu metod omezeno na metriky založené na odhadu srdeční tepové frekvence (TF). Konkrétně byla použita průměrná absolutní chyba (MAE), přičemž za přijatelnou byla považována hodnota menší než 5 bpm v souladu s normou IEC 60601-2-27.

Jak ukazuje Tab. 7.2, všechny tři hodnocené metody vykazují na této databázi nižší přesnost než na CapnoBase, což lze přičíst přítomnosti většího množství signálů nízké kvality. Elgendiho algoritmus dosahuje MAE 18,84 bpm, vlastní metoda 20,54 bpm a metoda využívající Hjorthovy deskriptory 31,22 bpm.

Po separaci kvalitních signálů pomocí referenčního skóre R-SQI a skóre O-SQI došlo u všech metod k výraznému zlepšení přesnosti. Zatímco výkonnost detekčních metod se mezi oběma kritérii kvality příliš neliší, u Hjorthovy metody je zlepšení po aplikaci O-SQI výraznější než po aplikaci R-SQI. Tato skutečnost naznačuje, že detekční algoritmy jsou obecně odolnější vůči zhoršené kvalitě signálu, zatímco metoda využívající Hjorthovu mobilitu je na kvalitu vstupu výrazně citlivější.

Bland-Altmanovy grafy (Obr. 7.8 až 7.10) dále ukazují, že selekce kvalitních signálů výrazně redukuje rozptyl rozdílů mezi odhadovanou a referenční TF, přičemž největší variabilita se projevuje u Hjorthovy metody na celé databázi. Zde se vyskytují i extrémní chybové hodnoty, zejména u signálů s vyšší průměrnou TF, které metoda systematicky podhodnocuje ($ME < 0$). V ojedinělých případech však dochází k opačnému efektu, kdy metoda významně přestřeluje, což vede k extrémně vysokým chybám. Tato odlehlá pozorování jsou vizualizována v horní části grafu na Obr. 7.10.

Graf na Obr. 7.7 dokumentuje chování Hjorthovy metody na podmnožině signálů označených jako kvalitní dle O-SQI. Horní panel ukazuje, že metoda má obecně tendenci TF podhodnocovat, zatímco dolní panel ukazuje, že většina odhadů se pohybuje v přijatelném rozmezí, a pouze menší část vykazuje výraznou odchylku.




Obr. 8.2: Největší odchylky u Hjorthovy metody 1.

Výsledná průměrná absolutní chyba 8,05 bpm je tedy tvořena několika odlehlými signály s velmi vysokou chybou, přesahující 60 bpm, jak ilustrují Obr. 8.2 a Obr. 8.3.

Souhrnně lze říci, že metoda založená na Hjorthově mobilitě vykazuje na kvalitních segmentech (dle O-SQI) srovnatelný výkon s algoritmy detekce vrcholů. Bez předchozí selekce kvality však její výstupy vykazují vysoký rozptyl a systematickou chybu, což výrazně omezuje její využitelnost v praxi. Detekční algoritmy vykazují vyšší robustnost vůči artefaktům, přičemž Elgendiho algoritmus mírně překonává vlastní přístup z hlediska konzistence odhadu.

8.3 Výpočetní náročnost metod odhadu TF

Z hlediska výpočetní náročnosti byly všechny testované metody dostatečně rychlé pro potenciální nasazení v reálném čase. Nejrychlejší z nich byl Elgendiho algoritmus. V případě implementace v knihovně `NeuroKit2` bylo však nutné deaktivovat



Obr. 8.3: Největší odchylky u Hjorthovy metody 2.

defaultní výpočet kvality signálu, neboť ten výrazně prodlužoval celkový čas zpracování.

Vlastní metoda detekce vrcholů a Hjorthova metoda byla mírně pomalejší, ale stále plně použitelná v praxi.

Větší rozdíly se daly vypořádat na BUT PPG databázi. O pár sekund nejrychlejší byl vlastní algoritmus detekce vrcholů, následovaný Elgendiho algoritmem. Hjorthova metoda byla nejpomalejší, což může být způsobeno vyšší asymptotickou složitostí výpočtu.

8.4 Hodnocení automatického stanovení kvality signálů

Pro automatické hodnocení kvality PPG signálů byl použit klasifikátor náhodného lesa trénovaný na dvojici příznaků: Shannonově entropii a spektrálním indexu výkonu (SPI). Na sloučené databázi CapnoBase a BUT PPG dosáhl model vysoké klasifikační schopnosti s hodnotou plochy pod ROC křivkou (AUC) rovnou 0,957 (viz Obr. 7.11). ROC křivka ukazuje výraznou separaci mezi třídami, přičemž vyšší hodnoty SPI a nižší Shannonova entropie korelují s vyšší kvalitou signálu, což potvrzuje informační přínos obou příznaků.

Ve scatterplotu (Obr. 7.12) je patrná tendence k oddělení tříd, avšak bez jednoznačně definované rozhodovací hranice. Nejvyšší klasifikační přesnosti bylo dosaženo při tréninku na kombinované databázi, zatímco výkon na jednotlivých databázích odděleně byl výrazně nižší. Zhoršení výkonu pravděpodobně souvisí s výraznou nevyvážeností tříd a rozdílným poměrem kvalitních a nekvalitních signálů mezi oběma databázemi.

Zejména na databázi BUT PPG vykazoval klasifikátor sníženou schopnost identifikovat kvalitní signály, což lze přičíst větší variabilitě dat, přítomnosti artefaktů odlišného charakteru a rozdílné morfologii signálů. Výsledky tedy ukazují, že i přes vysoký výkon na spojené databázi není možné s dostatečnou jistotou tvrdit, že model bude spolehlivě fungovat na dosud neznámých datech. Je možné, že model se částečně naučil rozlišovat mezi konkrétními databázemi, nikoli mezi kvalitou signálu jako takovou.

Zvýšení klasifikační výkonnosti by mohlo být dosaženo jednak rozšířením množiny vstupních příznaků (například o další spektrální, morfologické či nelineární charakteristiky), jednak použitím rozsáhlejších, vyváženějších a více heterogenních trénovacích dat, která by reprezentovala širší spektrum typů PPG signálů.

Závěr

Tato bakalářská práce se zabývala problematikou odhadu srdeční tepové frekvence (TF) a hodnocení kvality signálu z fotopletysmografických (PPG) dat. Byly porovnány tři odlišné přístupy k odhadu TF: Elgendiho algoritmus, vlastní metoda detekce vrcholů a nově navržený přístup založený na Hjorthových deskriptorech. Současně byl představen model pro automatické hodnocení kvality PPG signálů na základě Shannonovy entropie a spektrálního indexu výkonu (SPI).

Výsledky ukazují, že obě metody detekce vrcholů dosahují vysoké přesnosti na databázi CapnoBase, přičemž Elgendiho algoritmus vykazuje o něco konzistentnější výkon i na méně kvalitních datech. Vlastní algoritmus poskytuje srovnatelné výsledky, přičemž v některých případech dosahuje vyšší přesnosti při zachování nízké výpočetní náročnosti.

Naopak metoda založená na Hjorthových parametrech nevychází z detekce jednotlivých pulzů, ale analyzuje celkovou periodičnost signálu. Tento přístup se ukázal jako robustní zejména pro krátké segmenty kvalitních signálů, u nichž dosahuje velmi nízké chyby odhadu TF. Bez předchozí selekce kvalitních segmentů však výkonnost metody výrazně klesá a objevují se extrémní odchylky.

Automatické hodnocení kvality signálu pomocí Shannonovy entropie a SPI potvrdilo, že tyto dva příznaky nesou dostatek informace pro binární klasifikaci signálu. Přestože model náhodného lesa dosáhl vysoké přesnosti na sloučené databázi, jeho výkonnost se při samostatném testování na jednotlivých databázích snížila. Tato skutečnost ukazuje na omezenou schopnost generalizace a poukazuje na nutnost tréninku na vyvážených a heterogenních datech.

V rámci budoucího výzkumu by bylo vhodné zaměřit se na rozšíření množiny příznaků, začlenění adaptivních metod zpracování signálu a testování na větším množství nezávislých databází.

Literatura

- [1] NEMCOVA, A., VARGOVA, E., SMISEK, R., MARSANOVA, L., SMITAL, L., VITEK, M. a JAKOVLJEVIC, M. Brno University of Technology Smartphone PPG Database (BUT PPG): Annotated Dataset for PPG Quality Assessment and Heart Rate Estimation. *BioMed Research International* [online]. 2021-09-06, 2021, 1-6 [cit. 2024-05-23]. ISSN 2314-6141. Dostupné z: <https://doi.org/10.1155/2021/3453007>
- [2] NEMCOVA, A., SMISEK, R., VARGOVA, E., MARŠÁNOVÁ, L., VITEK, M., SMITAL, L., FILIPENSKA, M., SIKOROVA, P. a GÁLÍK, P. Brno University of Technology Smartphone PPG Database (BUT PPG) (version 2.0.0). PhysioNet. 2024 [cit. 2025-03-23]. Dostupné z: <https://doi.org/10.13026/tn53-8153>
- [3] KARLEN, W. CapnoBase IEEE TBME Respiratory Rate Benchmark. *Borealis* [online]. 2021 [cit. 2024-05-23]. Dostupné z: <https://doi.org/10.5683/SP2/NLB8IT>
- [4] VARGOVÁ, E. Stanovení kvality a odhad tepové frekvence ze signálu PPG [online]. Brno, 2021. Bakalářská práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. [cit. 2022-11-15]. Vedoucí práce NĚMCOVÁ, A. Dostupné z: <https://www.vutbr.cz/studenti/zav-prace/detail/134388>.
- [5] SIDDIQUI, S. A., Y. ZHANG, Z. FENG a A. KOS. A Pulse Rate Estimation Algorithm Using PPG and Smartphone Camera. *Journal of Medical Systems* [online]. 2016, 40(5) [cit. 2024-05-20]. ISSN 0148-5598. Dostupné z: <https://doi.org/10.1007/s10916-016-0485-6>
- [6] CHARLTON, P. H., KOTZEN, K., MEJÍA-MEJÍA, E., ... a KYRIACOU, P. A. Detecting beats in the photoplethysmogram: benchmarking open-source algorithms. *Physiological Measurement* [online]. 2022-08-19, 43(8) [cit. 2024-05-20]. ISSN 0967-3334. Dostupné z: <https://doi.org/10.1088/1361-6579/ac826d>
- [7] CHARLTON, P. H., ALLEN, J., BAILÓN, R., ... a ZHU, T. The 2023 wearable photoplethysmography roadmap. *Physiological Measurement* [online]. 2023-11-29, 44(11) [cit. 2024-05-20]. ISSN 0967-3334. Dostupné z: <https://doi.org/10.1088/1361-6579/acead2>
- [8] KARLEN, W., S. RAMAN, J. M. ANSERMINO a G. A. DUMONT. Multiparameter respiratory rate estimation from the photoplethysmogram. *IEEE*

- Transactions on Biomedical Engineering* [online]. 2013, 60(7), 1946-1953 [cit. 2024-04-16]. ISSN 0018-9294. Dostupné z: <https://doi.org/10.1109/TBME.2013.2246160>
- [9] ORPHANIDOU, C., BONNICI, T., CHARLTON, P., ... a TARASSENKO, L. Signal-quality indices for the electrocardiogram and photoplethysmogram: derivation and applications to wireless monitoring. *IEEE Journal of Biomedical and Health Informatics* [online]. 2015, (3), 832-838 [cit. 2025-04-20]. ISSN 2168-2208. Dostupné z: <https://doi.org/10.1109/JBHI.2014.2338351>
- [10] ORPHANIDOU, C. *Signal Quality Assessment in Physiological Monitoring* [online]. Cham: Springer International Publishing, 2018 [cit. 2024-05-20]. SpringerBriefs in Bioengineering. ISBN 978-3-319-68414-7. Dostupné z: <https://doi.org/10.1007/978-3-319-68415-4>
- [11] GODA, M. Á., CHARLTON, P. H. a BEHAR, J. A. pyPPG: a python toolbox for comprehensive photoplethysmography signal analysis. *Physiological Measurement* [online]. 2024-04-08, 45(4) [cit. 2024-05-20]. ISSN 0967-3334. Dostupné z: <https://doi.org/10.1088/1361-6579/ad33a2>
- [12] ELGENDI, M., NORTON, I., BREARLEY, M., ABBOTT, D., SCHUURMANS, D. a BONDARENKO, V. E. Systolic peak detection in acceleration photoplethysmograms measured from emergency responders in tropical conditions. *PLoS ONE* [online]. 2013-10-22, 8(10) [cit. 2024-05-20]. ISSN 1932-6203. Dostupné z: <https://doi.org/10.1371/journal.pone.0076585>
- [13] MAKOWSKI, D., PHAM, T., LAU, Z. J., ... a CHEN, S. A. NeuroKit2: A Python toolbox for neurophysiological signal processing. *Behavior Research Methods* [online]. 2021, 53, 1689-1696 [cit. 2024-05-20]. ISSN 1554-3528. Dostupné z: <https://doi.org/10.3758/s13428-020-01516-y>
- [14] HJORTH, Bo. EEG analysis based on time domain properties. *Electroencephalography and Clinical Neurophysiology* [online]. 1970, 29, 306-310 [cit. 2025-04-23]. Dostupné z: [https://doi.org/10.1016/0013-4694\(70\)90143-4](https://doi.org/10.1016/0013-4694(70)90143-4)
- [15] HJORTH, Bo. The physical significance of time domain descriptors in EEG analysis. *Electroencephalography and Clinical Neurophysiology* [online]. 1973, 34(3), 321-325 [cit. 2025-04-14]. ISSN 0013-4694. Dostupné z: [https://doi.org/10.1016/0013-4694\(73\)90260-5](https://doi.org/10.1016/0013-4694(73)90260-5)
- [16] PERALTA, E., LAZARO, J., GIL, E., BAILÓN, R. a MAROZAS, V. Robust pulse rate variability analysis from reflection and transmission photoplethysmographic signals. *Computing in Cardiology (CinC)* [online]. 2017-09-14, 1-4

- [cit. 2025-04-10]. ISSN 2325-887X. Dostupné z: <https://doi.org/10.22489/CinC.2017.205-286>
- [17] KAUSHIK, G., GAUR, P., SHARMA, R. R. a PACHORI, R. B. EEG signal based seizure detection focused on Hjorth parameters from tunable-Q wavelet sub-bands. *Biomedical Signal Processing and Control* [online]. 2022, 76 [cit. 2024-04-20]. ISSN 1746-8094. Dostupné z: <https://doi.org/10.1016/j.bspc.2022.103645>
- [18] MOUREK, J. *Fyziologie: učebnice pro studenty zdravotnických oborů*. 2. doplněné vydání. Praha: Grada. Sestra (Grada), 2012. [cit. 2024-04-19]. ISBN 978-80-247-3918-2.
- [19] SOUČEK, M., SVAČINA, P. a kolektiv. *Vnitřní lékařství v kostce*. Praha: Grada Publishing, 2019. [cit. 2024-04-19]. ISBN 978-80-271-2289-9.
- [20] GONZAGA, L. A., VANDERLEI, L. C. M., GOMES, R. L. a VALENTI, V. E. Caffeine affects autonomic control of heart rate and blood pressure recovery after aerobic exercise in young adults: a crossover study. *Scientific Reports* [online]. 2017, 7(1) [cit. 2024-05-15]. ISSN 2045-2322. Dostupné z: <https://doi.org/10.1038/s41598-017-14540-4>
- [21] PARK, J., SEOK, H. S., KIM, S. S. a SHIN, H. Photoplethysmogram analysis and applications: an integrative review. *Frontiers in Physiology* [online]. 2022-03-01, 12 [cit. 2022-12-18]. ISSN 1664-042X. Dostupné z: <https://doi.org/10.3389/fphys.2021.808451>
- [22] POVEA, C. E. a CABRERA, A. Practical usefulness of heart rate monitoring in physical exercise. *Revista Colombiana de Cardiología* [online]. 2018, 25(3), e9-e13 [cit. 2024-05-15]. ISSN 01205633. Dostupné z: <https://doi.org/10.1016/j.rccar.2018.05.004>
- [23] ÚŘAD PRO TECHNICKOU NORMALIZACI, METROLOGII A STÁTNÍ ZKUŠEBNICTVÍ. ČSN ISO 690:2022 (01 0197), *Informace a dokumentace – Pravidla pro bibliografické odkazy a citace informačních zdrojů*. Čtvrté vydání. Praha, 2022.
- [24] FARKAŠOVÁ, B.; GARAMSZEGI T.; JANSOVÁ L.; KONEČNÝ L.; KRČÁL M. et al. *Výklad normy ČSN ISO 690:2022 (01 0197) účinné od 1. 12. 2022*. Online. První vydání. 2023. Dostupné z: <https://www.citace.com/Vyklad-CSN-ISO-690-2022.pdf>.

Seznam symbolů a zkratek

Acc	Klasifikační úspěšnost
ACC	Akcelerometr
AUC	Plocha pod křivkou
bpm	Tepy za minutu
BUT PPG	Brno University of Technology Smartphone PPG Database
CESA	Centrum sportovních aktivit
DC	Stejnoseměrná složka
EEG	Elektroencefalogram
EKG	Elektrokardiogram
FEKT	Fakulta elektrotechniky a komunikačních technologií
FFT	Rychlá Fourierova transformace
FN	Falešně negativní
FP	Falešně pozitivní
FPR	Falešně pozitivní míra
F1	F1 skóre
Hz	Hertz
H_0	Aktivita
H_1	Mobilita
H_2	Komplexita
IBI	Tepový interval
LED	Elektroluminiscenční dioda
MA	Klouzavý průměr
MA_{beat}	Klouzavý průměr pro zvýraznění tepu
MA_{peak}	Klouzavý průměr pro zvýraznění vrcholu

MAE	Průměrná absolutní chyba
ME	Průměrná chyba
min	Minuta
ms	Milisekunda
MTF	Maximální tepová frekvence
O-SQI	Index kvality signálu dle Orphanidou a kol.
PPG	Fotopletysmograf
PPV	Pozitivní prediktivní hodnota
RF	Náhodný les
RMSE	Průměrná kvadratická chyba
ROC	Křivka správnosti detekce
R-SQI	Referenční index kvality signálu
s	Sekunda
SD	Standardní odchylka
Se	Citlivost
SPI	Index spektrální čistoty
TF	Tepová frekvence
THR_1	Práh 1
THR_2	Práh 2
TN	Pravdivě negativní
TP	Pravdivě pozitivní
TPR	Pravdivě pozitivní míra
var	Rozptyl
VUT	Vysoké učení technické v Brně
WFDB	WaveForm Database