

Diplomová práce



České
vysoké
učení technické
v Praze

F3

Fakulta elektrotechnická
Katedra teorie obvodů

Klasifikace krevní perfuze transplantované ledviny

Bc. Michaela Benešová

Vedoucí: doc. Ing. Radoslav Bortel, Ph.D.

Obor: Biomedicínské inženýrství

Studijní program: Biomedicínské inženýrství a informatika

Květen 2018

I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Benešová** Jméno: **Michaela** Osobní číslo: **419041**
Fakulta/ústav: **Fakulta elektrotechnická**
Zadávající katedra/ústav: **Katedra teorie obvodů**
Studijní program: **Biomedicínské inženýrství a informatika**
Studijní obor: **Biomedicínské inženýrství**

II. ÚDAJE K DIPLOMOVÉ PRÁCI

Název diplomové práce:

Klasifikace krevní perfuze transplantované ledviny

Název diplomové práce anglicky:

Classification of Blood Perfusion of Transplanted Kidney

Pokyny pro vypracování:

1. Posuďte možnosti klasifikace různých stavů krevní perfuze ledviny na základě měření reflektance/transmitance ve viditelné a blízké infračervené oblasti.
2. Proveďte klasifikaci krátkodobých signálů změřených při zaškrcování renální tepny a žíly na pokusném zvířeti.
3. Signály získané při zaškrcování renální tepny a žíly spojte s dlouhodobým záznamem na pokusném zvířeti a proveďte jejich klasifikaci.
4. Na základě získaných výsledků klasifikace, vyberte nejvhodnější klasifikátor a nejvhodnější vlnové délky pro měření. Rozsah průvodní zprávy: cca 40 stran.

Seznam doporučené literatury:

- [1] Duda, R.O., Hart, P.E., Stork, D.H.: Pattern Classification (2nd edition), Wiley-Interscience, 2000.
- [2] Heijden, F., Duin, R.P.W., Ridder, D., Tax, D.M.J.: Classification Parameter Estimation and State Estimation. Wiley, 2004.
- [3] Lee, J.A., Verleysen, M.: Nonlinear Dimensionality Reduction. Springer, 2007.

Jméno a pracoviště vedoucí(ho) diplomové práce:

doc. Ing. Radoslav Bortel, Ph.D., katedra teorie obvodů FEL

Jméno a pracoviště druhé(ho) vedoucí(ho) nebo konzultanta(ky) diplomové práce:

Datum zadání diplomové práce: **03.01.2018** Termín odevzdání diplomové práce: **25.05.2018**
Platnost zadání diplomové práce: **30.09.2019**

doc. Ing. Radoslav Bortel, Ph.D.
podpis vedoucí(ho) práce

prof. Ing. Pavel Sovka, CSc.
podpis vedoucí(ho) ústavu/katedry

prof. Ing. Pavel Ripka, CSc.
podpis děkana(ky)

III. PŘEVZETÍ ZADÁNÍ

Diplomantka bere na vědomí, že je povinna vypracovat diplomovou práci samostatně, bez cizí pomoci, s výjimkou poskytnutých konzultací. Seznam použité literatury, jiných pramenů a jmen konzultantů je třeba uvést v diplomové práci.

Datum převzetí zadání

Podpis studentky

Poděkování

Ráda bych touto cestou vyjádřila poděkování panu doc. Ing. Radoslavu Bortelovi, Ph.D. za jeho cenné rady a trpělivost při vedení mé diplomové práce.

Prohlášení

Prohlašuji, že jsem předloženou práci vypracovala samostatně a že jsem uvedla veškeré použité informační zdroje v souladu s Metodickým pokynem o dodržování etických principů při přípravě vysokoškolských závěrečných prací.

V Praze, 25. května 2018

Abstrakt

Diplomová práce se zabývá zpracováním a klasifikací signálů z měření reflektance transplantované ledviny ve viditelné a blízké infračervené oblasti. Cílem je rozlišit správně prokrvenou ledvinu od ledviny, u níž došlo k chybě perfuze, a zjistit, které kombinace vlnových délek jsou nejvhodnější pro klasifikaci. Pro klasifikaci byl použit kvadratický klasifikátor, klasifikátor k -NN a metoda Parzenových oken. Podle dosažených výsledků je nejvhodnější použít vlnové délky z červené a blízké infračervené oblasti (1050 nm, 850 nm, 740 nm a 660 nm).

Klíčová slova: transplantace ledviny, klasifikace, perfuze, zpracování signálu

Vedoucí: doc. Ing. Radoslav Bortel, Ph.D.

Abstract

This diploma thesis deals with the processing and classification of reflectance signals measured on a transplanted kidney in the visible and near infrared spectrum. The aim is to distinguish disruptions of blood perfusion, and to find the optimal combination of wavelength that is the most suitable for the classification. Tested classifiers were the quadratic classifier, k -nearest neighbor classifier and Parzen window classifier. According to the results, the best option is to combine wavelengths from red and near infrared spectrum (1050 nm, 850 nm, 740 nm and 660 nm).

Keywords: kidney transplantation, classification, perfusion, signal processing

Title translation: Classification of Blood Perfusion of Transplanted Kidney

Obsah

1 Úvod	1	3.5.1 Křížová validace	20
2 Analýza současného stavu	3	3.5.2 Monte Carlo křížová validace	20
3 Metody	7	3.6 Hodnocení úspěšnosti pro různé kombinace vlnových délek	21
3.1 Vstupní data	7	4 Výsledky	23
3.1.1 Měřicí systém	7	4.1 Zpracování statických signálů . .	23
3.1.2 Provedená měření	8	4.2 Zpracování kombinovaných signálů	26
3.1.3 Zpracovávané signály	9	4.2.1 Složky kombinovaných signálů	26
3.2 Zpracování statických signálů . .	10	4.2.2 Klasifikace	27
3.2.1 Předzpracování dat	10	4.2.3 Nastavení parametrů	28
3.2.2 Klasifikace	12	4.2.4 Vyhodnocení úspěšnosti při použití všech vlnových délek	29
3.3 Zpracování kombinovaných signálů	13	4.2.5 Vyhodnocení úspěšnosti pro různé kombinace vlnových délek .	29
3.3.1 Předzpracování dat	13	5 Diskuze	35
3.3.2 Vzorky odpovídající nesprávnému prokrvení	13	6 Závěr	37
3.3.3 Vzorky odpovídající správnému prokrvení	14	Literatura	39
3.3.4 Výsledné datasey	15	A Úspěšnost všech kombinací vlnových délek	43
3.4 Klasifikátory	16	B Obsah CD	51
3.4.1 Kvadratický klasifikátor	16		
3.4.2 Klasifikace podle nejbližších sousedů (k -NN)	17		
3.4.3 Parzenova okna	18		
3.5 Hodnocení úspěšnosti klasifikace	19		

Obrázky

3.1	Senzorický pás	7	4.8	Závislost úspěšnosti klasifikátoru k -NN na parametru k při použití všech vlnových délek	28
3.2	Fotografie senzorického pásu na ledvině	8	4.9	Závislost úspěšnosti metody Parzenových oken na parametru σ při použití všech vlnových délek	28
3.3	Ukázka úseku signálu s vysokým výkonem	10	4.10	Nejúspěšnější skupiny vlnových délek pro kvadratický klasifikátor a volný dataset	30
3.4	Úsek původního signálu (nahore) a signálu po předzpracování (dole)	12	4.11	Nejúspěšnější skupiny vlnových délek pro kvadratický klasifikátor a fixovaný dataset	30
3.5	Ukázka extrakce změny intenzity při zaškrcení žíly	14	4.12	Nejúspěšnější skupiny vlnových délek pro klasifikátor k -NN a volný dataset	31
3.6	Ukázka relativní změny intenzity při zaškrcení žíly	14	4.13	Nejúspěšnější skupiny vlnových délek pro klasifikátor k -NN a fixovaný dataset	31
3.7	Ukázka jednoho vzorku zaškrcení tepny (vlevo) a 17 kombinovaných vzorků vzniklých z tohoto vzorku (vpravo)	15	4.14	Nejúspěšnější skupiny vlnových délek pro Parzenova okna a volný dataset	32
3.8	Příklady jádrových funkcí	19	4.15	Nejúspěšnější skupiny vlnových délek pro Parzenova okna a fixovaný dataset	32
4.1	Klasifikace statického signálu kvadratickým klasifikátorem	24	A.1	Závislost úspěšnosti klasifikace na kombinaci vlnových délek pro kvadratický klasifikátor a volný dataset	44
4.2	Klasifikace statického signálu klasifikátorem k -NN ($k = 3$)	25	A.2	Závislost úspěšnosti klasifikace na kombinaci vlnových délek pro kvadratický klasifikátor a fixovaný dataset	45
4.3	Klasifikace statického signálu klasifikátorem Parzenova okna ($\sigma = 0,01$)	25	A.3	Závislost úspěšnosti klasifikace na kombinaci vlnových délek pro klasifikátor k -NN a volný dataset	46
4.4	Vzorky zaškrcení tepny	26			
4.5	Vzorky zaškrcení žíly	26			
4.6	Ukázka vzorků při správné funkci ledviny z volného senzorického pásu	27			
4.7	Ukázka vzorků při správné funkci ledviny z fixovaného senzorického pásu	27			

A.4 Závislost úspěšnosti klasifikace na kombinaci vlnových délek pro klasifikátor k -NN a fixovaný dataset	47
A.5 Závislost úspěšnosti klasifikace na kombinaci vlnových délek pro Parzenova okna a volný dataset...	48
A.6 Závislost úspěšnosti klasifikace na kombinaci vlnových délek pro Parzenova okna a fixovaný dataset	49

Tabulky

3.1 Klasifikační třídy, podbarvení buňky odpovídá barvě použité v obrázcích v sekci 4.1	12
4.1 Úspěšnost klasifikace datasetu ze statických signálů pro jednotlivé klasifikátory	23
4.2 Úspěšnost klasifikace volného datasetu pro jednotlivé klasifikátory	29
4.3 Úspěšnost klasifikace fixovaného datasetu pro jednotlivé klasifikátory	29
4.4 Nejvyšší dosažená úspěšnost klasifikace volného datasetu při použití čtyř vlnových délek pro jednotlivé klasifikátory	33
4.5 Nejvyšší dosažená úspěšnost klasifikace fixovaného datasetu při použití čtyř vlnových délek pro jednotlivé klasifikátory	34
4.6 Kombinace s nejnižším počtem vlnových délek při zachování minimální úspěšnosti klasifikace fixovaného datasetu 97 % pro jednotlivé klasifikátory	34

Kapitola 1

Úvod

Pacienti s chronickým onemocněním ledvin, kteří jsou ve stádiu, kdy je nutné nahrazovat funkci ledvin, mohou podstupovat hemodialýzu, peritoneální dialýzu nebo transplantaci ledviny. Transplantace je chirurgický zákrok, při kterém se do těla voperuje ledvina od živého nebo zemřelého (kadaverózního) dárce. Ve srovnání s ostatními metodami má transplantace nejlepší prognózu a je i ekonomicky nejvýhodnější [1].

V prvních dnech bezprostředně po operaci je klíčové udržet kvalitní a nepřerušovaný průtok krve transplantátem. Pokud není rychle zaznamenána a řešena chyba v prokrvení, může dojít k opožděnému rozvoji funkce transplantátu, omezení funkce nebo dokonce znemožnění funkce transplantátu [2].

V současné době se správná funkce transplantovaného orgánu v pooperačním období kontroluje prostřednictvím ultrazvukového vyšetření. Hlavní nevýhodou je, že poskytuje informaci o prokrvení pouze v době provedení vyšetření a průběžné monitorování není možné. Další limitací metody je, že interpretace ultrazvukového obrazu, a tedy i hodnocení stavu orgánu, závisí do jisté míry na zkušenostech obsluhy a jejím subjektivním posouzení.

V reakci na uvedené nedostatky ultrazvukového vyšetření pracuje tým složený z odborníků z Fakulty elektrotechnické Českého vysokého učení technického v Praze (FEL) a Institutu klinické a experimentální medicíny (IKEM) na vývoji senzoru, který bude schopen ledvinu monitorovat kontinuálně a vyhodnocení stavu bude automatizované. Měření je založeno na optické metodě a vychází z toho, že na základě reflektance ledviny je možné usuzovat její perfuzi. Zařízení je určeno pro monitorování v časném pooperačním období, které je z hlediska rozvoje chyby perfuze nejvíce kritické. Senzor je při transplantaci voperován do těla pacienta spolu s transplantátem a po překlenutí kritického období je senzor vyjmut [3].

Na pokusných zvířatech byla s prototypem senzoru provedena testovací měření. Získané signály je třeba vyhodnotit, což je úkolem této práce. Je třeba signály klasifikovat podle stavu prokrvení a za tímto účelem zvolit vhodnou

klasifikační metodu. Dále je nutné vybrat vhodné kombinace vlnových délek, při jejichž měření budou stavy dobře rozlišitelné a klasifikovatelné s co nejvyšší úspěšností.

Cílem práce je po zhodnocení možných přístupů vybrat vhodné klasifikační metody a provést klasifikaci. Nejprve by měly být klasifikovány signály získané z měření v anestezii, kdy byl eliminován pohyb pokusného zvířete. Dalším krokem je klasifikace signálů vzniklých kombinací signálů získaných z pohybujícího se zvířete a signálů z měření v anestezii. V kombinovaných signálech se projeví jak vlivy pohybu, tak změny perfuze. Dále je cílem zjistit, které kombinace vlnových délek vedou k nejvyšší úspěšnosti klasifikace.

Kapitola 2

Analýza současného stavu

K určení prokrvení v různých částech těla se využívají optické metody. Optické metody vychází z interakce elektromagnetického záření s analyzovanou látkou (tkání). Používá se záření v rozsahu viditelného světla s přesahem do infračervené a ultrafialové oblasti, tzn. přibližně 200 nm až 5000 nm [4]. Zaznamenává se intenzita záření, které se odrazilo od tkáně nebo prošlo skrz tkáň. Intenzita se mění v závislosti na úrovni prokrvení měřené tkáně. Kromě užitečné složky vycházející ze změn perfuze jsou ve výsledném signálu obsaženy i artefakty dané pohybem, dýcháním a mechanickým pohybem způsobeným pulzací celého organismu v průběhu srdečního cyklu. Při analýze je klíčové rozlišit změny v prokrvení i za přítomnosti rušení.

Metody pro určení prokrvení se liší podle způsobu vyhodnocení signálů. Fotopletysmografie (*photoplethysmography*, PPG) je založena na sledování objemových změn v tkáni. V průběhu každého srdečního cyklu je krev pumpována ze srdce do periferií. V důsledku toho v tkáních dochází ke kvaziperiodickým změnám objemu. Při prosvěcování tkáně je světlo utlumené jednotlivými složkami tkáně. Proměnný objem arteriální krve se projeví změnou intenzity detekovaného prošlého záření a tvoří střídavou (AC) složku získávaného signálu. Ostatní složky tkáně (kůže, kost, nepulsatilní krev) působí konstantní útlum a tvoří stejnosměrnou (DC) složku získávaného signálu. Podíl AC/DC se liší v závislosti na tom, jaká vlnová délka byla použita k prosvěcování [5]. Měření PPG není dostačující k určení perfuze, neboť i tkáň se sníženým prokrvením je ovlivňována tlakovými změnami vyvolanými srdcem.

Pulsní oxymetrie je založena na obdobném principu jako fotopletysmografie, ale k prosvěcování využívá dvou vlnových délek současně. Standardně se používají záření z červené oblasti (660 nm) a blízké infračervené oblasti (940 nm). Oxyhemoglobin (hemoglobin s navázaným kyslíkem) a deoxyhemoglobin (hemoglobin bez navázaného kyslíku) mají rozdílnou absorpční schopnost těchto vlnových délek. Z poměru AC/DC červeného záření a AC/DC infračerveného záření lze určit podíl zastoupení těchto frakcí hemoglobinu a z kalibrační křivky přístroje potom odvodit saturaci krve kyslíkem. Pulsní oxymetrie se v klinické praxi využívá k včasnému zachycení hypoxických stavů na jednotkách intenzivní

zákona odhadují koncentrace oxyhemoglobinu a deoxyhemoglobinu. Z podílu odhadnuté koncentrace oxyhemoglobinu k odhadnuté celkové koncentraci lze potom určit oxygenační index (úroveň oxygenace vyjádřená v procentech) [15].

Na principu měření celkové intenzity odraženého záření je založen také senzor vyvíjený ve spolupráci FEL a IKEM. Výhodou vyhodnocování celkové intenzity namísto pouze amplitudy pulzací je menší rušení způsobené pohybem. Cílem není kvantitativní určení úrovně saturace, ale správná detekce nastalé chyby v prokrvení.

Pro další fáze vývoje je nutné zjistit, jaký počet vlnových délek a jaké hodnoty vlnových délek jsou pro měření prokrvení nejvhodnější. Také zatím není stanoven vhodný způsob klasifikace měřených signálů. Aby mohly být vyřešeny výše uvedené otázky, byla provedena testovací měření. Na prasatech byla měřena intenzita záření odraženého od ledviny v různých perfuzních stavech. Pro měření bylo využito 7 vlnových délek.

Je třeba provést analýzu získaných signálů. Pro další vývoj senzoru je nutné navrhnout vhodnou metodu předzpracování a klasifikace dat. Dále je třeba určit, které kombinace z měřených vlnových délek jsou nejvhodnější z hlediska dosažení maximální úspěšnosti rozlišení správně a chybně prokrvené ledviny. Stanovené body analýzy jsou předmětem této práce.

Kapitola 3

Metody

Kapitola zahrnuje popis vzniku vstupních signálů, předzpracování signálů a metody klasifikace, které byly použity pro automatizované vyhodnocení prokrvení ledviny.

3.1 Vstupní data


V rámci této práce byly zpracovávány signály získané z experimentů prováděných v Institutu klinické a experimentální medicíny v Praze. Měření probíhalo na laboratorních prasatech. Na ledvinu byl připevněn sensorický pás se zdroji záření, jehož prostřednictvím byl získáván průběh intenzity odraženého záření v čase.

3.1.1 Měřicí systém

Měření je založeno na změně intenzity odraženého světla různých vlnových délek při změně perfuze ledviny. Pro získání signálu využívá měřicí systém sensorický pás s čtyřmi stejnými senzory. Sensor se skládá z sedmi zdrojů záření a detektoru odraženého záření. Sensorický pás je na obrázku 3.1. Každý sensor obsahuje zdroje záření o vlnových délkách 1050 nm, 940 nm, 850 nm, 740 nm, 660 nm, 560 nm a 465 nm. Vzorkovací frekvence signálu je 25 Hz. Při měření je sensorický pás v přímém kontaktu s povrchem ledviny, viz obrázek 3.2.



Obrázek 3.1: Sensorický pás



Obrázek 3.2: Fotografie senzorkého pásu na ledvině

3.1.2 Provedená měření

Cílem klasifikace je na pohybujícím se subjektu správně rozlišit funkční ledvinu od špatně prokrvené ledviny. Za tímto účelem je nutné zjistit, jak se signál mění v jednotlivých stavech. V ideálním případě by byly k dispozici záznamy volně se pohybujícího subjektu, u kterého by byly řízeně navozovány chyby prokrvení. Takový experiment však v praxi není možné provést, proto byl zisk signálů rozdělen na dvě fáze. V první fázi byl zjištěn vliv zaškrcení cévy na intenzitu záření a v druhé fázi bylo zaznamenáváno, jaké změny v intenzitě záření nastávají v důsledku pohybu. Pro klasifikaci byly oba typy signálů kombinovány, aby byla simulována chyba perfuze nastalá u pohybujícího se zvířete.

Byla provedena měření sledující vliv zaškrcení cévy na měřený signál. Při experimentu bylo prase v anestezii fixováno na operačním stole a byla mu zaškrcována a po několika minutách opět uvolňována renální tepna nebo žíla. Zároveň byl snímán signál ze senzorkého pásu umístěného na ledvině. Experimenty trvaly přibližně 45 minut a výsledné signály jsou opatřeny časovými značkami, které oddělují jednotlivé fáze. Vzhledem k tomu, že při snímání byl eliminován pohyb prasete, jsou záznamy tohoto typu dále v práci označovány jako statické signály/záznamy.

Dále byly získány záznamy monitorující odoperované prase po dobu několika hodin po zákroku. Prasata byla volně pohyblivá, proto jsou záznamy tohoto typu dále v práci označovány jako pohybové signály/záznamy. Pro lepší stabilitu byl v některých případech senzorký pás přišit k ledvině.

■ 3.1.3 Zpracovávané signály

Vstupem byly dvě sady dat. První sada sestává ze čtyř souborů. Každý soubor obsahuje statický záznam z jednoho experimentu. Druhá sada sestává se dvou souborů. Každý soubor obsahuje jeden pohybový záznam zvířete po operaci. První záznam je dlouhý přibližně 12 hodin a senzor nebyl na ledvině fixovaný, druhý záznam trvá přibližně 2 hodiny a obsahuje data získaná ze sensorického pásu, který byl na ledvině fixován přiřítím. Při zaznamenávání byla prasata volně pohyblivá a nenastaly u nich žádné komplikace.

Každý záznam obsahuje signály z jednoho sensorického pásu, tzn. ze čtyř senzorů po sedmi vlnových délkách, viz následující naznačení struktury.

- Soubor
 - Záznam ze sensorického pásu
 - Signál ze senzoru 1
 - Intenzita pro 1050 nm
 - Intenzita pro 940 nm
 - Intenzita pro 850 nm
 - Intenzita pro 740 nm
 - Intenzita pro 660 nm
 - Intenzita pro 560 nm
 - Intenzita pro 465 nm
 - Signál ze senzoru 2
 - Intenzita pro 1050 nm
 - ⋮
 - Intenzita pro 465 nm
 - Signál ze senzoru 3
 - Intenzita pro 1050 nm
 - ⋮
 - Intenzita pro 465 nm
 - Signál ze senzoru 4
 - Intenzita pro 1050 nm
 - ⋮
 - Intenzita pro 465 nm


3.2 Zpracování statických signálů

Klasifikátory byly nejdříve vyzkoušeny na vzorcích ze statických signálů. Cílem bylo otestovat základní funkci klasifikátorů a identifikovat možné problémy.

3.2.1 Předzpracování dat

Signál bylo nutné předzpracovat, odstranit irelevantní části a zachovat změny dané zaškrcením cév. Signály z jednotlivých senzorů v rámci jednoho senzorského pásu byly zpracovávány jednotlivě.

Signály obsahovaly oblasti s vysokým výkonem. Tyto úseky jsou projevem hrubého mechanického pohybu a vniku osvětlení do senzoru, ke kterému došlo při manipulaci se senzorem, například při kontrole správného upevnění. Pro klasifikaci nejsou přínosné, proto bylo třeba je detekovat a vyřadit z dalšího zpracování. Příklad takového úseku je na obrázku 3.3.



Obrázek 3.3: Ukázka úseku signálu s vysokým výkonem

Princip dalšího zpracování signálu spočívá ve výpočtu relativních změn v signále. Počítá se poměr aktuální intenzity ku předchozí hodnotě intenzity. Pro větší robustnost byly definovány délky dvou úseků a v rámci každého úseku byly počítány useknuté průměry.

Délka prvního úseku signálu t_1 , který představuje dlouhodobější stav, referenci, byla stanovena na 60 s. Délka druhého úseku postihujícího aktuální stav ledviny t_2 byla stanovena na 15 s. Mezi oběma úseky je pauza t_p dlouhá 30 s. Při vzorkovací frekvenci 25 Hz tomu odpovídají počty vzorků $n_1 = 1500$, $n_2 = 375$ a $n_p = 750$.

Signál $\mathbf{x}[n]$ ve vzorkovacím okamžiku n obsahuje intenzity M vlnových délek

$$\mathbf{x}[n] = [x_1[n], x_2[n], \dots, x_M[n]]^\top. \quad (3.1)$$

Relativně k vzorku n jsou definovány úseky I_1 a I_2 . Platí, že

$$I_1 = \left[n - \frac{n_p}{2} - 1, n - \frac{n_p}{2} - 2, \dots, n - \frac{n_p}{2} - n_1 \right], \quad (3.2)$$

$$I_2 = \left[n + \frac{n_p}{2} + 1, n + \frac{n_p}{2} + 2, \dots, n + \frac{n_p}{2} + n_2 \right]. \quad (3.3)$$

Následující postup je ukázán pro jednu vlnovou délku m . V části signálu daným indexy I_1 byl vypočítán useknutý průměr $\overline{p_{1,m}}[n]$. Nejprve bylo nutné vzorky z $\mathbf{x}_m[I_1]$ seřadit vzestupně podle velikosti. Pro vlnovou délku m dostaneme $x_{m(1)}, x_{m(2)}, \dots, x_{m(n_1)}$, číslo určuje pořadí. Je nutné určit, jaké procento nejextrémnějších hodnot p nebude zahrnuto do výpočtu. Bylo zvoleno $p = 10\%$, tzn. 5% nejvyšších a 5% nejnižších hodnot nepřispívá k výpočtu průměru. Pořadí prvního zahrnutého vzorku i_1 je $n_1 \cdot \frac{p}{2} + 1$, pořadí posledního vzorku i_2 je $n_1 - n_1 \cdot \frac{p}{2}$


$$\overline{p_{1,m}}[n] = \frac{\sum_{i=i_1}^{i_2} x_{m(i)}}{n_1 - n_1 \cdot p}. \quad (3.4)$$

Stejným způsobem byl vypočítán useknutý průměr $\overline{p_{2,m}}[n]$ v druhé oblasti dané indexy I_2 .

Následně byl vypočítán podíl $r_m[n]$

$$r_m[n] = \frac{\overline{p_{2,m}}[n]}{\overline{p_{1,m}}[n]}. \quad (3.5)$$

Postup byl stejný pro všechny vlnové délky. Vzorku $\mathbf{x}[n]$ po předzpracování odpovídá $\mathbf{r}[n] = [r_1[n], r_2[n], \dots, r_M[n]]^\top$. Ukázka výsledku předzpracování je na obrázku 3.4.



Obrázek 3.4: Úsek původního signálu (nahore) a signálu po předzpracování (dole)

3.2.2 Klasifikace

Byly definovány tři stavy, ve kterých se může ledvina nacházet. Jedná se o správné prokrvení, zaškrcení tepny a zaškrcení žíly. Každý vzorek byl přiřazen do jednoho z těchto stavů. Popsané stavy jsou shodné s třídami, do kterých probíhala klasifikace, značení viz tabulka 3.1.

Charakteristika	Zkratka
Správné prokrvení	F
Došlo k zaškrcení tepny	A
Došlo k zaškrcení žíly	V

Tabulka 3.1: Klasifikační třídy, podbarvení buňky odpovídá barvě použité v obrázcích v sekci 4.1

Byl vytvořen dataset obsahující vzorky z předzpracovaných statických signálů. Dataset obsahoval 1000 vzorků funkční ledviny, označovaných jako \mathbf{r}_F , 1000 vzorků z oblasti, kdy byla zaškrcena tepna, označovaných jako \mathbf{r}_A a 1000 vzorků z oblasti, kdy byla zaškrcena žíla, označovaných jako \mathbf{r}_V .

Vzhledem k tomu, že klasifikátor by měl být schopen zachytit okamžik zhoršení perfuze, nikoli nutně přetrvávající stav špatné perfuze, byly vzorky \mathbf{r}_A a \mathbf{r}_V vybírány z oblasti do jedné minuty od časové značky zaškrcení. Při klasifikaci byla data dělena do trénovací a testovací množiny v poměru 2:1, tzn. k natrénování bylo použito 2000 náhodně vybraných vzorků a zbývajících 1000 vzorků sloužilo k otestování klasifikátoru. Použité klasifikátory jsou popsány v sekci 3.4. Byla provedena Monte Carlo křížová validace s počtem opakování 50. Výsledky jsou uvedeny v sekci 4.1.

3.3 Zpracování kombinovaných signálů

Kombinované signály vznikaly se statických a pohybových signálů. Předpoklad je takový, že statické signály obsahují změny dané pouze rozdílným prokrvením, jelikož pohyb prasete byl eliminován. Zároveň je předpokládáno, že v pohybových signálech jsou obsaženy změny v intenzitě vyvolané pohybem, dýcháním a dalšími projevy prasete. V dlouhodobých signálech nebyly pozorovány žádné projevy, které by svědčily o špatném prokrvení. Cílem kombinování obou typů signálů bylo simulovat pohyblivé zvíře v pooperačním období, u kterého došlo k nežádoucímu ucpaní cévy. Přímé měření takových signálů není v praxi možné. Klasifikace kombinovaných signálů je hlavní částí této práce.

3.3.1 Předzpracování dat

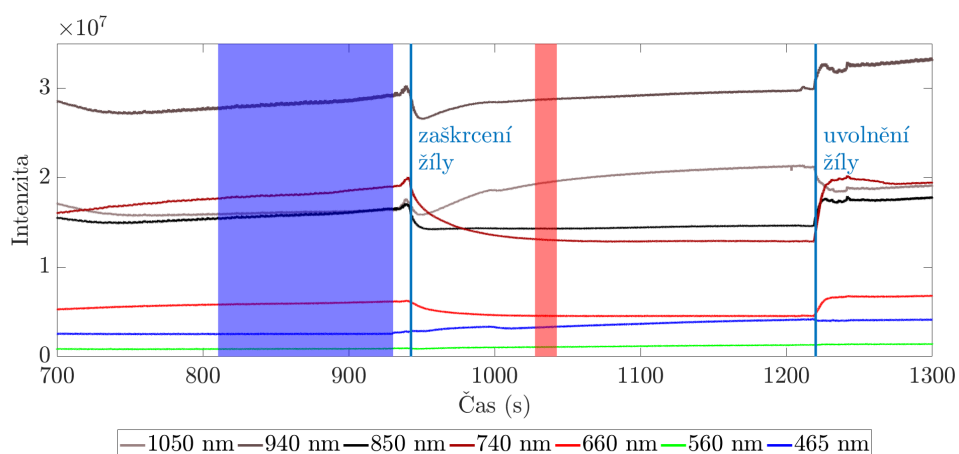
V následujících odstavcích budou popsány způsoby extrakce částí kombinovaného signálu, tzn. zisk vzorků při chybném prokrvení a zisk vzorků pohybujícího se zvířete se správně prokrvenou ledvinou. Dále bude popsán postup použitý pro kombinování těchto dvou typů vzorků. Výsledkem je dataset obsahující vzorky správného i chybného prokrvení ledviny pohybujícího se zvířete.

3.3.2 Vzorky odpovídající nesprávnému prokrvení


První částí kombinovaného signálu jsou změny nastalé po zaškrcení cévy. Změny byly extrahovány ze statických signálů podobným způsobem, jaký je popsán v sekci 3.2.1. Byla sledována změna signálu po zaškrcení vzhledem k stavu před zaškrcením. Na rozdíl od popsaného postupu však nebyla použita pevná délka pauzy t_p mezi úseky signálu I_1 a I_2 . K umístění jednotlivých úseků byly využity časové značky zaškrcení. Úsek I_1 končil 25 s (625 vzorků) před časovou značkou zaškrcení. Nacházel se tedy v oblasti normální funkce. Jeho délka t_1 byla 120 s, tzn. n_1 bylo 3000. Úsek I_2 se nacházel za časovou značkou zaškrcení, v jedné třetině mezi časovou značkou zaškrcení a uvolněním, viz obrázek 3.5. Délka úseku t_2 byla 15 s, tzn. n_2 bylo 375.

V úsecích I_1 a I_2 byla odhadnuta střední hodnota signálu podle vztahu (3.4). Následně byl vypočítán podíl odhadů středních hodnot podle vztahu (3.5).

Podíl vyjadřuje relativní změnu mezi dvěma sledovanými oblastmi. Pokud se mezi sledovanými úseky signál nezměnil, nezměnila se ani jeho střední hodnota a výsledný poměr bude roven jedné. Odchyšky od této hodnoty vyjadřují změnu způsobenou zaškrcením, viz obrázek 3.6.



Obrázek 3.5: Ukázka extrakce změny intenzity při zaškrcení žíly



Obrázek 3.6: Ukázka relativní změny intenzity při zaškrcení žíly

3.3.3 Vzorky odpovídající správnému prokrvení

Druhou částí kombinovaného signálu jsou vzorky odpovídající relativním změnám při správném prokrvení, tedy fyziologickém stavu. Byly získány z pohybových signálů. Náhodně bylo vybráno n_F pozic v signále ($n_F = 3000$). V okolí těchto pozic byly podle postupu popsáném v sekci 3.2.1 definovány

oblasti I_1 a I_2 . V úsecích signálu určených oblastmi I_1 a I_2 byl proveden výpočet podle vztahu (3.4) a vztahu (3.5). Dva dostupné pohybové signály byly zpracovávány zvlášť. Uvedeným způsobem bylo z každého signálu získáno n_F relativních změn aktuálního stavu vůči referenci, které nastaly v důsledku pohybu.


3.3.4 Výsledné datasety

Dalším krokem bylo zkombinování vzorků odpovídajících zaškrcení s vzorky odpovídajícími správnému prokrvení. Tímto způsobem byla simulována situace, kdy při pohybu prasete nastala nežádoucí změna perfuze.

Pro každý vzorek zaškrcení tepny \mathbf{r}_A bylo náhodně vybráno několik vzorků funkční ledviny. Vzorek funkční ledviny je označen \mathbf{r}_F . Kombinovaný vzorek zaškrcení tepny \mathbf{A} vznikl součinem částí po prvcích.

$$\mathbf{A} = \mathbf{r}_A \circ \mathbf{r}_F, \quad (3.6)$$

kde \circ je Hadamardův součin. Z každého vzorku zaškrcení tepny vzniklo několik kombinovaných vzorků, viz obrázek 3.7.



Obrázek 3.7: Ukázka jednoho vzorku zaškrcení tepny (vlevo) a 17 kombinovaných vzorků vzniklých z tohoto vzorku (vpravo)

Analogický postup byl aplikován pro tvorbu kombinovaných vzorků zaškrcení žíly \mathbf{V}

$$\mathbf{V} = \mathbf{r}_V \circ \mathbf{r}_F. \quad (3.7)$$

Počet kombinovaných vzorků vzniklých z jednoho vzorku zaškrčení byl zvolen tak, aby vznikl přibližně stejný počet kombinovaných vzorků zaškrčení žíly a tepny. Počet výsledných kombinovaných vzorků v jedné třídě byl stanoven na 500. Ze zbývajících vzorků funkční ledviny, které nebyly použity k tvorbě předchozích kombinovaných vzorků, bylo náhodně vybráno 500 vzorků. Ty byly ve výsledném datasetu použity beze změny jako vzorky funkční ledviny \mathbf{F} .

Vznikly dva datasety, které vstupovaly do klasifikátorů. Jeden dataset vycházel ze signálu z volného sensorického pásu, dále je označován jako volný dataset, druhý ze signálu z fixovaného sensorického pásu, dále je označován jako fixovaný dataset.

3.4 Klasifikátory

Pro klasifikaci byly využity tři klasifikátory: kvadratický klasifikátor, k -NN a Parzenova okna.

Klasifikace probíhala do tří tříd, odpovídajícím stavům v tabulce 3.1, tedy funkční ledvina, zaškrčená tepna a zaškrčená žíla.

V následujícím textu je použito značení \mathbf{y} pro vzorek z trénovací množiny (tzn. vzorek, u něž známe třídu). Značení \mathbf{x} je použito pro vzorek, u něž třída není známa a má být provedena jeho klasifikace.

3.4.1 Kvadratický klasifikátor

Kvadratický klasifikátor odděluje třídy kvadratickou plochou. Je zobecněním lineárního klasifikátoru, který používá roviny. Jedná se o parametrickou metodu, předpokládá, že vzorky každé třídy pochází z normálního rozdělení a odhaduje jeho parametry [16].

Vícerozměrné (M -rozměrné) normální rozdělení je určeno hustotou pravděpodobnosti $f(\mathbf{x})$

$$f(\mathbf{x}) = \frac{1}{\sqrt{(2\pi)^M |\mathbf{R}|}} e^{-\frac{1}{2}(\mathbf{x}-\boldsymbol{\mu})^\top \mathbf{R}^{-1}(\mathbf{x}-\boldsymbol{\mu})}, \quad (3.8)$$

kde $\boldsymbol{\mu}$ je vektor středních hodnot a \mathbf{R} je kovarianční matice.

Z trénovacích vzorků \mathbf{y} je třeba odhadnout pro každou třídu Y_k střední hodnotu $\boldsymbol{\mu}_k$ a kovarianční matici \mathbf{R}_k , které jsou definovány jako

$$\boldsymbol{\mu}_k = \mathbb{E}[\mathbf{y} | \mathbf{y} \in Y_k] \quad (3.9)$$

$$\mathbf{R}_k = \mathbb{E}[(\mathbf{y} - \boldsymbol{\mu}_k)(\mathbf{y} - \boldsymbol{\mu}_k)^\top | \mathbf{y} \in Y_k] \quad (3.10)$$

Odhad bývá realizován výpočtem průměrné hodnoty [16].

Diskriminační funkce $g_k(\mathbf{x})$ vyjadřuje míru příslušnosti vzorku \mathbf{x} do třídy Y_k a určí se jako

$$g_k(\mathbf{x}) = \ln p(\mathbf{x} | Y_k) + \ln(p(Y_k)), \quad (3.11)$$

kde $p(Y_k)$ je pravděpodobnost výskytu třídy Y_k . V připravených datasetech jsou všechny třídy stejně zastoupeny, tedy je možné tento člen zanedbat.

Za uvedeného předpokladu, že $p(\mathbf{x} | Y_k)$ pochází z vícerozměrného normálního rozdělení, získáme

$$g_k(\mathbf{x}) = -\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_k)^\top \mathbf{R}_k^{-1}(\mathbf{x} - \boldsymbol{\mu}_k) - \frac{M}{2} \ln 2\pi - \frac{1}{2} \ln |\mathbf{R}_k|. \quad (3.12)$$

Při klasifikaci jsou pro neznámý vzorek \mathbf{x} vypočítány hodnoty diskriminačních funkcí pro každou třídu a vzorek je přiřazen do třídy s největší hodnotou diskriminační funkce [16, str. 36].

■ 3.4.2 Klasifikace podle nejbližších sousedů (k -NN)

Neparametrické metody klasifikace nevyžadují předpoklad o pravděpodobnostním rozdělení dat. Jedním z typických zástupců těchto přístupů je metoda k -nejbližších sousedů, neboli k -nearest neighbors.

Z dostupných trénovacích dat, u nichž známe třídu (jedná se tedy o učení s učitelem) vytvoříme body v M -rozměrném prostoru, kde M je počet atributů v trénovacím souboru.

Klasifikace neznámého bodu probíhá na základě jeho nejbližších sousedů ve vytvořeném prostoru. K určení vzdálenosti je třeba zavést metriku. Často používanou metrikou je euklidovská vzdálenost d_e , která je definována mezi dvěma vektory $\mathbf{x} = (x_1, x_2, \dots, x_M)$ a $\mathbf{y} = (y_1, y_2, \dots, y_M)$ jako

$$d_e(\mathbf{x}, \mathbf{y}) = \sqrt{\sum_{i=1}^M (x_i - y_i)^2} \quad (3.13)$$

Parametrem metody je počet nejbližších sousedů k . Při klasifikaci se pro každý testovací bod najde k jeho nejbližších sousedů podle zvolené metriky a přiřadí se do té třídy, kterou má většina z k nejbližších sousedů [16, str. 174].

Optimální hodnota parametru k je vázána na konkrétní data, výběr bývá proveden podle toho, s jakou hodnotou parametru je v konkrétní úloze dosaženo nejvyšší úspěšnosti.

V rámci této práce byly při volbě parametru k vyzkoušeny všechny hodnoty k od 1 do 20 s krokem 1. Vždy byla provedena Monte Carlo křížová validace s počtem opakování 50. Výsledná hodnota k byla zvolena podle nejvyšší dosažené úspěšnosti. Průměrnou úspěšnost pro každou hodnotu k ukazuje obrázek 4.8 v sekci 4.2.3.

■ 3.4.3 Parzenova okna

Metoda Parzenových oken je dalším příkladem neparametrické metody klasifikace. Neznámý vzorek je přiřazen do třídy Y_k podle toho, jaká je největší posteriorní pravděpodobnost $p(Y_k|\mathbf{x})$

$$p(Y_k|\mathbf{x}) = \frac{p(\mathbf{x}|Y_k)p(Y_k)}{p(\mathbf{x})}. \quad (3.14)$$

Pravděpodobnost třídy $p(Y_k)$ je možné pro všechny třídy považovat za stejnou, protože v připravených datasetech jsou všechny třídy stejně zastoupeny. Při stejné pravděpodobnosti třídy nedochází k preferování početnější třídy při klasifikaci.

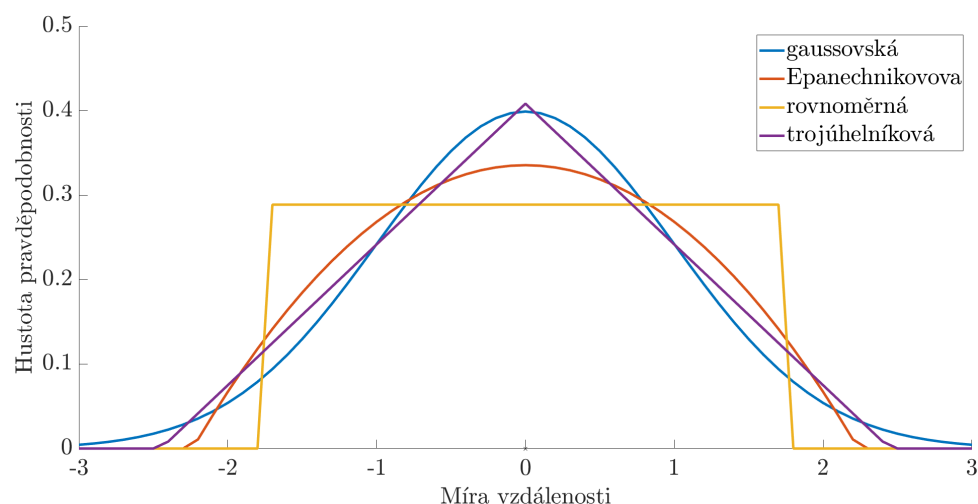
Metoda Parzenových oken slouží k odhadu podmíněné pravděpodobnosti $p(\mathbf{x}|Y_k)$ z trénovacích dat.

$$\hat{p}(\mathbf{x}|Y_k) = \frac{1}{\sum_{i=1}^N v_k^i} \sum_{i=1}^N K(\mathbf{x}, \mathbf{y}_i) v_k^i, \quad (3.15)$$

kde v_k^i nabývá hodnoty 1, pokud \mathbf{y}_i patří do třídy Y_k , v opačném případě má hodnotu 0. Odhad je tvořen superpozicí jádrových funkcí K vycentrovaných kolem jednotlivých bodů, které přísluší do třídy Y_k . Každá jádrová funkce

kolem trénovacího vzorku vyjadřuje jeho příspěvek k celkovému odhadu [17, str. 151].

Je možné zvolit různé typy jádrových funkcí, které svým tvarem ovlivňují výsledný odhad, viz obrázek 3.8. Dalším parametrem, kterým má vliv na odhad, je šířka okna. Při příliš malé šíři okna je výsledný odhad příliš zvlněný a projevuje se v něm každý vzorek jako vrchol, při velké šířce zase dojde ke „slévání“ jednotlivých shluků vzorků [18].



Obrázek 3.8: Příklady jádrových funkcí

V rámci této práce byla zvolena gaussovská jádrová funkce

$$K(\mathbf{x} - \mathbf{y}_i) = e^{-\frac{|\mathbf{x} - \mathbf{y}_i|^2}{2\sigma^2}}. \quad (3.16)$$

Šíře okna je ovlivňována pomocí parametru σ , tedy směrodatné odchylky jádra. Pro určení parametru σ gaussovského jádra Parzenových oken byly vyzkoušeny hodnoty σ v rozsahu 10^{-3} až 10^3 . Vždy byla provedena Monte Carlo křížová validace s počtem opakování 50. Výsledná hodnota σ byla zvolena podle nejvyšší dosažené úspěšnosti. Průměrnou úspěšnost pro každou hodnotu σ ukazuje obrázek 4.9 v sekci 4.2.3.

3.5 Hodnocení úspěšnosti klasifikace

Při hodnocení úspěšnosti klasifikace je pohlíženo na výsledky, kterých klasifikátor dosahuje na testovacích datech. Z toho se dá usuzovat, jaká bude úspěšnost na zcela neznámých nových datech.

Jako parametr pro porovnávání dosažených výsledků byla zvolena průměrná úspěšnost v klasifikaci jednotlivých tříd. U_F je úspěšnost klasifikace funkcí

ledviny, U_A je úspěšnost klasifikace zaškrvení tepny, U_V je úspěšnost klasifikace zaškrvení žíly. Úspěšnost v rámci jedné třídy je definována jako počet správně klasifikovaných vzorků dané třídy ku všem vzorkům dané třídy. Průměrná úspěšnost U_P je určena jako

$$U_P = \frac{U_F + U_A + U_V}{3}. \quad (3.17)$$

Primárně je klasifikace prováděna do tří tříd, viz tabulka 3.1 v sekci 3.2.2.

Ve výsledcích v sekci 4 jsou navíc prezentovány výsledky úspěšnosti při sloučení tříd A a V . Ucpání tepny a ucpání žíly jsou rozdílné jevy, mají však stejné důsledky. Pokud nastane chyba v prokrvení transplantátu, ať již z libovolné z těchto dvou příčin, musí být provedena reopreace. Záměna klasifikace mezi třídami A a V tedy není natolik závažná. Průměrná úspěšnost při klasifikaci do dvou tříd (funkční (F) a nefunkční ledvina (A nebo V)) je označována U_{P2} .

■ 3.5.1 Křížová validace

Křížová validace se používá v případech, kdy je třeba odhadnout úspěšnost klasifikátoru a nejsou dostupná validační data. Validační procedura spočívá v otestování klasifikátoru na datech, které nesloužily k jeho natrénování. Metody křížové validace jsou založeny na opakovaném provádění validační procedury s různým rozdělením vstupních dat na trénovací a testovací data. Cílem je dosažení spolehlivějších odhadů než při jednou náhodném rozdělení na trénovací a testovací množinu. Výsledky z jednotlivých iterací jsou sdruženy a je vytvořen odhad pravděpodobnosti úspěšné klasifikace.

Mezi metody křížové validace patří k -násobná křížová validace, leave-one-out křížová validace a Monte Carlo křížová validace. Jednotlivé metody se liší způsobem rozdělování na trénovací a testovací data [19].

■ 3.5.2 Monte Carlo křížová validace

V rámci práce byla využita Monte Carlo křížová validace (*Monte Carlo Cross Validation*, MCCV), neboli opakované náhodné vzorkování (*repeated random subsampling*). Při MCCV se z datasetu o velikosti N vzorků náhodně vybere n_t vzorů do trénovací množiny a slouží k natrénování modelu, zbylých $(N - n_t)$ vzorků se použije k validaci. Tento proces se opakuje i -krát, v každém běhu je náhodně vygenerována nová trénovací a testovací množina. Vzhledem k tomu, že jednotlivé výběry jsou náhodné, může dojít k tomu, že stejný vzorek (stejná skupina vzorků) se v testovací množině objeví opakovaně [19].

Výsledkem každého testování je průměrná úspěšnost U_P definovaná v sekci 3.5. Po proběhnutí celého procesu křížové validace je k dispozici i hodnot U_P . Celkovým výstupem reprezentujícím proces je průměr z těchto i hodnot.

■ 3.6 Hodnocení úspěšnosti pro různé kombinace vlnových délek

S rostoucím počtem měřených vlnových délek roste počet světelných zdrojů, a tím i velikost senzoru a množství zpracovávaných dat. Pokud by bylo měřeno méně vlnových délek, bylo by možné dosáhnout menších rozměrů senzoru a rychlejšího zpracování. Ve vstupních datech bylo měřeno sedm vlnových délek (1050 nm, 940 nm, 850 nm, 740 nm, 660 nm, 560 nm a 465 nm). Je možné z nich vytvořit 127 různých kombinací. Bylo analyzováno, které kombinace vlnových délek na vstupu klasifikátoru povedou k nejvyšší úspěšnosti klasifikace.

Ve vstupním datasetu byly vybrány pouze inzenzity vlnových délek z právě uvažované kombinace. Následná klasifikace probíhala podle stejného postupu jako při použití všech vlnových délek. Postupně byly vyzkoušeny všechny kombinace.

Byly získány průměrné úspěšnosti pro všech 127 kombinací. Za základě toho bylo hodnoceno, které kombinace vedou k nejvyšší úspěšnosti klasifikace a jaký je vhodný počet měřených vlnových délek. Při vyhodnocování bylo přihlíženo k tomu, že z hlediska akceptovatelné velikosti senzoru se podle lékařů jeví jako vhodné řešení použít čtyři vlnové délky.

Hodnocení probíhalo zvlášť pro volný dataset a zvlášť pro fixovaný dataset a bylo provedeno pro všechny tři vyzkoušené klasifikátory.

Kapitola 4

Výsledky

Kapitola shrnuje výsledky metod aplikovaných na data. První část kapitoly ukazuje výstupy pro klasifikaci statických signálů, druhá výsledky klasifikace dat vzniklých kombinací statických a pohybových signálů. Nejprve jsou prezentovány výsledky při použití všech vlnových délek, další část se zaměřuje na výběr nejvhodnějších kombinací vlnových délek.

4.1 Zpracování statických signálů

Klasifikace statických signálů byla provedena podle postupu popsaném v sekci 3.2.1. Výsledky pro klasifikaci datasetu vytvořeného ze statických signálů shrnuje tabulka 4.1.


		Úspěšnost (%)				
		U_F	U_A	U_V	U_P	U_{P2}
Klasifikátor	Kvadratický klasifikátor	96,7	96,8	95,5	96,0	96,0
	k -NN ($k = 3$)	98,4	99,9	99,0	99,1	99,2
	Parzenova okna ($\sigma = 0,01$)	99,1	99,9	99,6	99,5	99,4

Tabulka 4.1: Úspěšnost klasifikace datasetu ze statických signálů pro jednotlivé klasifikátory


Klasifikátory natrénované na části dat z připraveného datasetu byly dále otestovány na jednotlivých signálech. Výsledky jsou na obrázcích 4.1, 4.2 a 4.3. Klasifikace je zobrazena na původních signálech a je znázorněna podbarvením. Před klasifikací byly identifikovány oblasti s výrazným rušením a byly vyřazeny z klasifikace, tedy nejsou podbarveny.

Správnost klasifikace lze odvodit z časových značek. Klasifikátor by měl identifikovat a odlišit správnou perfuzi od okamžiku, kdy došlo ke zhoršení perfuze. Oblasti klasifikované jako zaškrcení by měly následovat po časových


značkách zaškrcení. Například po značce „zaškrcení žíly“ by měla následovat oblast signálu klasifikovaná jako zaškrcení žíly (tzn. V) a signál by měl být podbarven růžově. Klasifikovaná oblast nemusí pokrývat celý úsek mezi značkami „zaškrcení žíly“ a „uvolnění žíly“, protože cílem bylo detekovat prudkou změnu intenzity značící vznik zaškrcení a s tím spojenou změnu perfuze.



Obrázek 4.1: Klasifikace statického signálu kvadratickým klasifikátorem



Obrázek 4.2: Klasifikace statického signálu klasifikátorem k -NN ($k = 3$)



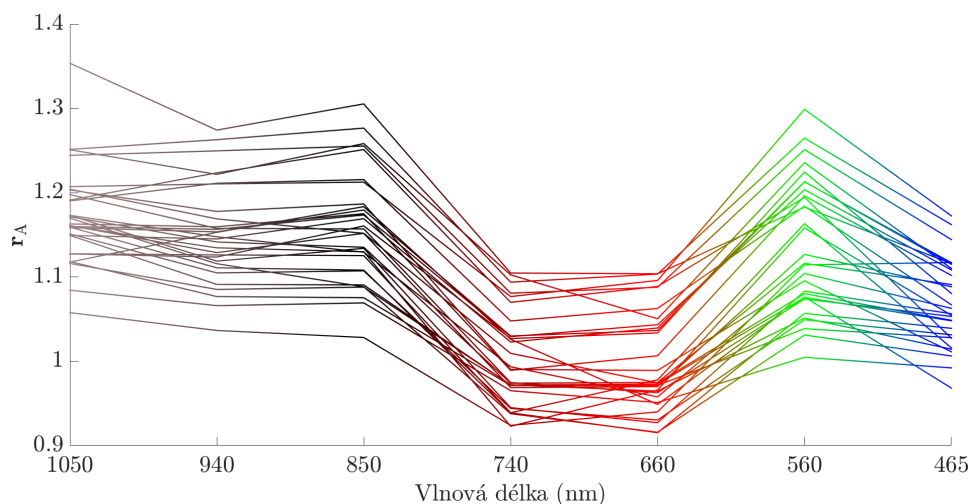
Obrázek 4.3: Klasifikace statického signálu klasifikátorem Parzenova okna ($\sigma = 0,01$)

4.2 Zpracování kombinovaných signálů

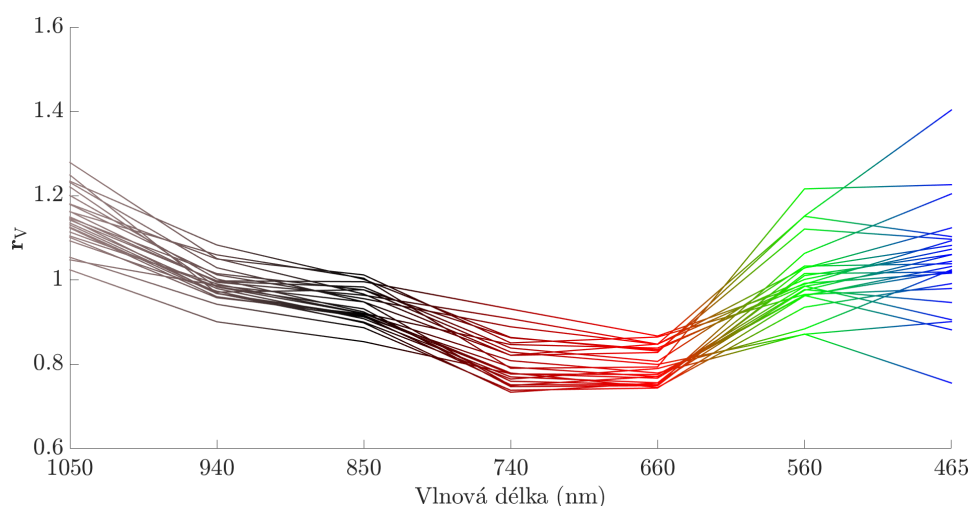
V následující části jsou prezentovány výsledky tvorby kombinovaných signálů, volby parametrů klasifikátorů a klasifikace kombinovaných signálů.

4.2.1 Složky kombinovaných signálů

Patologie byly extrahovány ze statických signálů podle postupu popsaném v sekci 3.3.2. Obrázek 4.4 ukazuje všechny získané vzorky odpovídající zaškrčení tepny. Celkem bylo extrahováno 30 vzorků. Obrázek 4.5 ukazuje všechny získané vzorky odpovídající zaškrčení žíly. Celkem bylo extrahováno 25 vzorků.

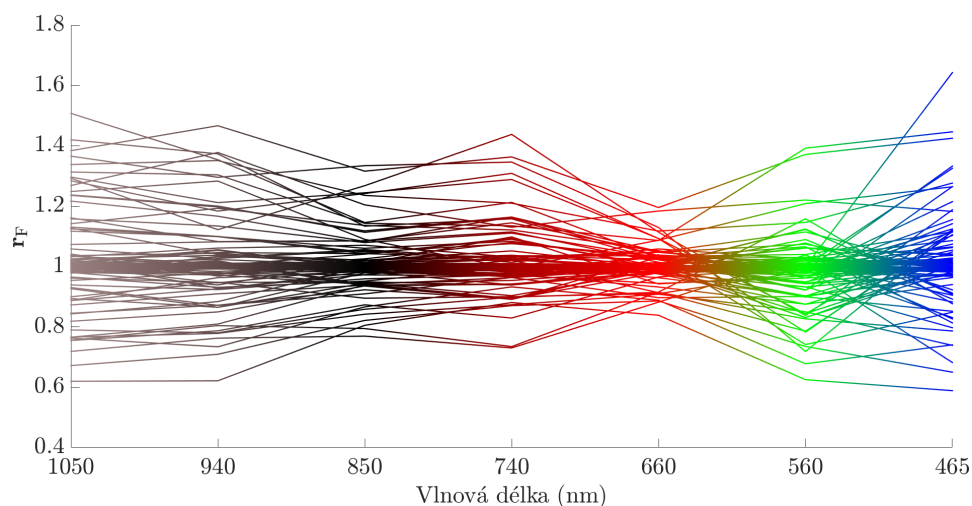


Obrázek 4.4: Vzorky zaškrčení tepny

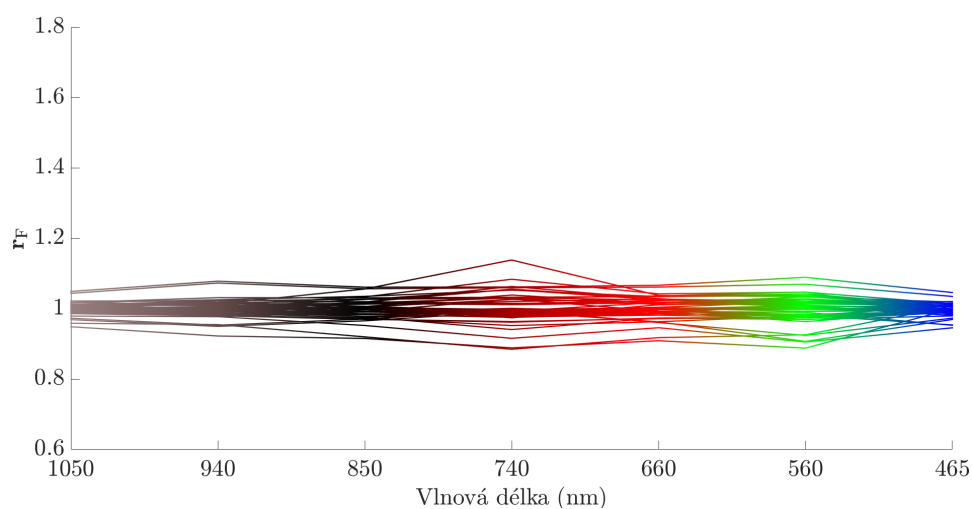


Obrázek 4.5: Vzorky zaškrčení žíly

Pohybové signály při volném a fixovaném senzoričném pásu byly zpracovávány zvlášť. Bylo získáno 3000 vzorků pro každou z uvedených variant. Obrázek 4.6 ukazuje část vzorků funkční ledviny pro volný senzoričký pás, obrázek 4.7 totéž pro fixovaný senzoričký pás.



Obrázek 4.6: Ukázka vzorků při správné funkci ledviny z volného senzoričkého pásu



Obrázek 4.7: Ukázka vzorků při správné funkci ledviny z fixovaného senzoričkého pásu


4.2.2 Klasifikace

Vstupní množina obsahovala 1500 vzorků. Dětila se na trénovací množinu a testovací množinu v poměru 2:1. Pro každý klasifikátor a dataset byla provedena Monte Carlo křížová validace s počtem opakování 50.

4.2.3 Nastavení parametrů


Metoda k -NN a metoda Parzenových oken vyžadují určení parametrů, které byly voleny vzhledem k maximalizaci úspěšnosti klasifikace kombinovaných datasetů při použití všech vlnových délek.

Na základě postupu uvedeného v sekci 3.4.2 bylo zvoleno $k = 3$, protože při tomto nastavení u obou datasetů dosahoval klasifikátor nejvyšší průměrné úspěšnosti.



Obrázek 4.8: Závislost úspěšnosti klasifikátoru k -NN na parametru k při použití všech vlnových délek

Na základě postupu uvedeného v sekci 3.4.3 byla zvolena hodnota $\sigma = 10^{-2}$. U obou datasetů bylo při tomto nastavení dosaženo nejvyšší průměrné úspěšnosti.



Obrázek 4.9: Závislost úspěšnosti metody Parzenových oken na parametru σ při použití všech vlnových délek

4.2.4 Vyhodnocení úspěšnosti při použití všech vlnových délek

V první fázi byl proces klasifikace proveden pro vstupní data obsahující všech sedm vlnových délek. Výsledky pro volný dataset shrnuje tabulka 4.2, výsledky pro fixovaný dataset jsou v tabulce 4.3.

		Úspěšnost (%)				
		U_F	U_A	U_V	U_P	U_{P2}
Klasifikátor	Kvadratický klasifikátor	97,0	99,1	96,6	97,6	98,5
	k -NN ($k = 3$)	94,1	94,5	95,5	94,7	95,4
	Parzenova okna ($\sigma = 0,01$)	95,7	94,1	95,4	95,1	96,3

Tabulka 4.2: Úspěšnost klasifikace volného datasetu pro jednotlivé klasifikátory

		Úspěšnost (%)				
		U_F	U_A	U_V	U_P	U_{P2}
Klasifikátor	Kvadratický klasifikátor	99,8	97,8	99,8	99,1	99,9
	k -NN ($k = 3$)	99,9	99,3	97,1	98,8	99,9
	Parzenova okna ($\sigma = 0,01$)	99,9	99,5	97,8	99,1	99,9


Tabulka 4.3: Úspěšnost klasifikace fixovaného datasetu pro jednotlivé klasifikátory

4.2.5 Vyhodnocení úspěšnosti pro různé kombinace vlnových délek

Zkoumání vlivu kombinace vlnových délek na úspěšnost klasifikace bylo provedeno pro každý klasifikátor zvlášť. V následující sekci jsou prezentovány tři kombinace s nejlepšími výsledky v rámci kombinací se stejným počtem vlnových délek. Skupiny se stejným počtem vlnových délek (dvojice, trojice atd.) jsou odděleny svislými čarami a v dolní části grafu jsou označeny číslem definujícím počet vlnových délek ve skupině. Nejprve jsou zobrazeny výsledky pro volný dataset a následně pro fixovaný dataset. Úspěšnosti U_P pro všechny kombinace vlnových délek jsou uvedeny v příloze A.

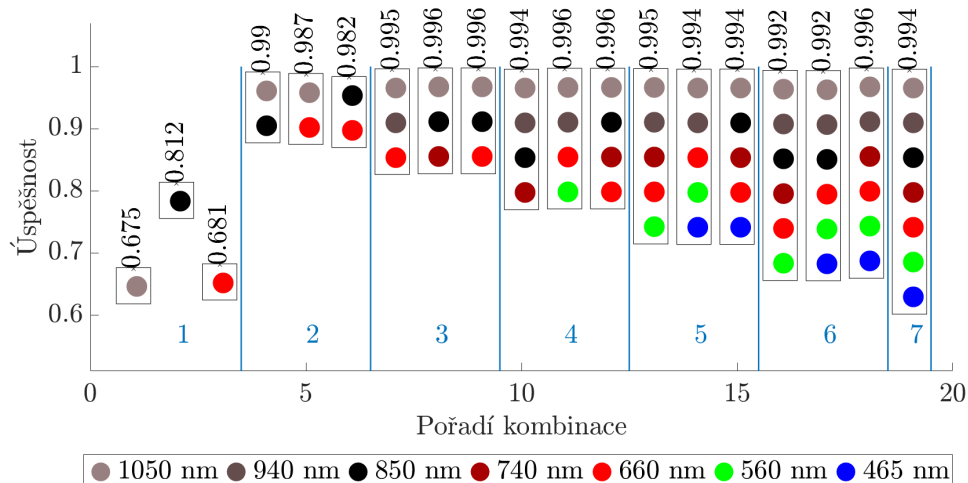
Kvadratický klasifikátor

U kvadratického klasifikátoru dosahují jednotlivě nejlepších výsledků vlnové délky 660 nm, 740 nm a 850 nm. Hodnoty 660 nm a 850 nm se také vyskytují téměř ve všech dalších nejlépe hodnocených skupinách, viz obrázek 4.10.



Obrázek 4.10: Nejúspěšnější skupiny vlnových délek pro kvadratický klasifikátor a volný dataset

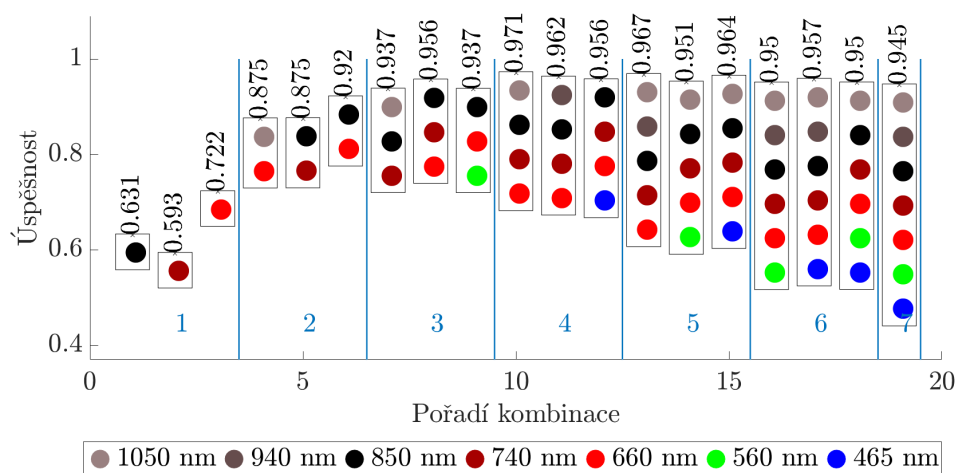
U fixovaného datasetu byla nejlepší vlnová délka 850 nm, která samostatně dosahuje přesnosti přes 80 %, viz obrázek 4.11. Je patrné, že při použití dvou vhodných vlnových délek (z červené a infračervené oblasti) je již dosaženo úspěšnosti přes 98 % a přidávání dalších vlnových délek již přispívá pouze velmi málo.




Obrázek 4.11: Nejúspěšnější skupiny vlnových délek pro kvadratický klasifikátor a fixovaný dataset

■ k -NN

U klasifikátoru k -NN se u volného datasetu v nejlépe hodnocených kombinacích objevují rovněž vlnové délky 660 nm, 740 nm a 850 nm. Nejlepšího výsledku bylo dosaženo pro kombinaci 1050 nm, 850 nm, 740 nm a 660 nm, viz obrázek 4.12. U fixovaného datasetu je situace obdobná, viz obrázek 4.13.




Obrázek 4.12: Nejúspěšnější skupiny vlnových délek pro klasifikátor k -NN a volný dataset




Obrázek 4.13: Nejúspěšnější skupiny vlnových délek pro klasifikátor k -NN a fixovaný dataset

Parzenova okna

Při použití Parzenových oken je patrný velký rozdíl v případě, kdy je ve vstupních datech pouze jedna vlnová délka, a v případě, kdy jsou použity dvě a více vlnových délek. Jednotlivě nedosáhne žádná vlnová délka vyšší úspěšnosti než 35 %, ale kombinace červené a infračervené již dosahují úspěšnosti 87 % pro volný dataset (obrázek 4.14) a 98 % pro fixovaný dataset (obrázek 4.15).



Obrázek 4.14: Nejúspěšnější skupiny vlnových délek pro Parzenova okna a volný dataset



Obrázek 4.15: Nejúspěšnější skupiny vlnových délek pro Parzenova okna a fixovaný dataset

Souhrn

Při vyhodnocování nejvhodnějších kombinací vlnových délek bylo přihlíženo k tomu, že podle lékařů se jeví jako příhodné řešení použít čtyři vlnové délky. Důvodem je přijatelná velikost sensorického pásu při tomto počtu světelných zdrojů. Byly tedy vyhodnoceny kombinace, které v rámci všech čtveřic vedly k nejvyšší úspěšnosti klasifikace. Výsledky pro volný dataset shrnuje tabulka 4.4. U volného datasetu dosahovaly uvedené čtveřice zároveň nejvyšší úspěšnosti ze všech kombinací.

		Úspěšnost (%)					Vlnové délky (nm)
		U_F	U_A	U_V	U_P	U_{P2}	
Klasifikátor	Kvadratický klasifikátor						1050
		97,8	99,2	97,2	98,1	99,1	850
							740
							660
	k -NN ($k = 3$)						1050
		97,1	96,7	97,5	97,1	97,9	850
							740
							660
	Parzenova okna ($\sigma = 0,01$)						1050
		97,8	97,2	97,3	97,4	97,8	850
							740
							660

Tabulka 4.4: Nejvyšší dosažená úspěšnost klasifikace volného datasetu při použití čtyř vlnových délek pro jednotlivé klasifikátory

Nejúspěšnější čtveřice vlnových délek pro fixovaný dataset jsou uvedeny v tabulce 4.5. U fixovaného datasetu byly rozdíly v úspěšnosti při použití kombinací složených z dvou a více vlnových délek velmi malé. Při stanovení minimální úspěšnosti 97 % bylo sledováno, jaký nejmenší počet vlnových délek je dostačující k dosažení definované úspěšnosti. Výsledky shrnuje tabulka 4.6. Při aplikaci stejné podmínky minimální úspěšnosti na klasifikaci volného datasetu jsou výsledky stejné jako v tabulce 4.4. Pro dosažení úspěšnosti alespoň 97 % je pro volný dataset třeba alespoň čtyř vhodně zvolených vlnových délek.

		Úspěšnost (%)					Vlnové délky (nm)
		U_F	U_A	U_V	U_P	U_{P2}	
Klasifikátor	Kvadratický klasifikátor						1050
							850
		99,8	99,4	99,5	99,6	99,8	740
							660
	k -NN ($k = 3$)						1050
							940
		99,9	99,7	99,7	99,8	99,9	850
							660
	Parzenova okna ($\sigma = 0,01$)						1050
						940	
99,9		99,8	99,2	99,7	99,9	850	
						740	

Tabulka 4.5: Nejvyšší dosažená úspěšnost klasifikace fixovaného datasetu při použití čtyř vlnových délek pro jednotlivé klasifikátory

		Úspěšnost (%)					Vlnové délky (nm)
		U_F	U_A	U_V	U_P	U_{P2}	
Klasifikátor	Kvadratický klasifikátor						1050
		97,5	99,4	99,9	99,0	99,3	850
	k -NN ($k = 3$)						850
		99,9	98,3	98,5	98,9	99,0	660
	Parzenova okna ($\sigma = 0,01$)						850
		99,9	98,3	98,2	98,9	99,1	660

Tabulka 4.6: Kombinace s nejnižším počtem vlnových délek při zachování minimální úspěšnosti klasifikace fixovaného datasetu 97 % pro jednotlivé klasifikátory

Kapitola 5

Diskuze

Hlavní úlohou monitorování prokrvení transplantované ledviny je včasné odhalení zaškrcení některé z cév. Algoritmus předzpracování byl navržen tak, aby porovnával referenci určenou odhadem střední hodnoty v delším časovém okně s aktuálním stavem ledviny. Tímto způsobem jsou zdůrazněny prudké změny, které jsou dány právě změnou prokrvení. Jak je vidět na obrázcích v sekci 4.1, všechny klasifikátory byly schopny správně detekovat vznik zaškrcení ve statických signálech.

Již ve fázi předzpracování pohybových signálů se ukázalo, že signály z fixovaného senzoričského pásu mají jiný rozptyl než signály z volného senzoričského pásu. Aby mohl být kvantifikován vliv fixace na kvalitu klasifikace, byly signály zpracovávány odděleně. Při klasifikaci datasetu vycházejícího ze signálů z fixovaného senzoričského pásu bylo ve všech případech dosaženo vyšší úspěšnosti než při klasifikaci datasetu z volného senzoričského pásu. Při použití všech vlnových délek dosahovaly klasifikátory u volného datasetu úspěšnosti kolem 95 %, u fixovaného datasetu se úspěšnost pohybovala kolem 99 %. Při klasifikaci pouze do dvou tříd (funkční ledvina a zaškrcení cévy) je dosažená úspěšnost klasifikace ještě vyšší.

Po vyzkoušení všech kombinací vlnových délek lze říci, že nejúspěšnější byly kombinace vlnových délek z rozmezí 660 nm až 1050 nm, tedy z červené a infračervené oblasti. Pro dosažení maximální úspěšnosti je třeba dodržet, aby byly ve vstupních datech zástupci z červené i infračervené oblasti. Kombinace dvou vlnových délek pouze z červené oblasti (660 nm a 740 nm) nepřinášely uspokojivé výsledky. Za neúspěšné lze také považovat kombinace modré (465 nm), zelené (560 nm) a infračervených vlnových délek. Při redukci počtu vlnových délek na čtyři se dle dosažených výsledků jako nejvhodnější kombinace jeví 1050 nm, 850 nm, 740 nm a 660 nm.

Při fixaci senzoričského pásu by bylo při zachování úspěšnosti klasifikace přes 97 % možné použít jen dvojici vlnových délek z červené a infračervené oblasti (1050 nm a 660 nm, 850 nm a 660 nm), případně pouze z infračervené oblasti (1050 nm a 850 nm).

Rozdíly mezi výsledky jednotlivých klasifikátorů byly ve všech případech velmi malé. Vzhledem k nižší výpočetní náročnosti by bylo vhodné zvolit kvadratický klasifikátor.

Kapitola 6

Závěr

Práce se zabývá klasifikací signálu, který se mění v závislosti na prokrvení transplantované ledviny. Úkolem klasifikace bylo rozlišit fyziologický stav od patologií – zaškrcení tepny a zaškrcení žíly.

Byly navrženy a otestovány tři klasifikátory – kvadratický klasifikátor, k -NN a Parzenova okna. Klasifikace probíhala na vzorcích, které vznikly kombinací statických a pohybových signálů.

Bylo prokázáno, že fixace senzorického pásu vede k vyšší přesnosti klasifikace. Při vhodném výběru vlnových délek je možné úspěšnost klasifikace u volného senzorického pásu zvýšit v řádu procent.

Na základě hodnocení úspěšnosti pro různé kombinace vlnových délek bylo zjištěno, že nejvhodnější je použít kombinace červeného a blízkého infračerveného záření. U volného senzoru je pro dosažení úspěšnosti přes 97 % dostačující použít kombinaci čtyř vlnových délek. U fixovaného senzoru bylo možné s úspěšností přes 97 % odlišit jednotlivé třídy za použití pouze dvou vlnových délek. Rozdíly mezi výsledky jednotlivých klasifikátorů byly minimální.



Literatura

- [1] VACHEK, Jan, Oskar ZAKIYANOV a Vladimír TESAŘ. Chronické onemocnění ledvin. *Interní medicína pro praxi*. 2012, **14**(3), 107-110.
- [2] PHELAN, Paul, Colm MAGEE, Patrick O'KELLY, Frank J. O'BRIEN, Dilly LITTLE a Peter CONLON. Immediate re-transplantation following early kidney transplant thrombosis. *Nephrology*. 2011, **16**(6), 607-611. DOI: 10.1111/j.1440-1797.2011.01483.x.
- [3] BORTEL Radoslav et al. Systém monitorování krevního zásobování transplantovaného orgánu. Užitečný vzor. Úřad průmyslového vlastnictví, CZ 31012 U1, 2017.
- [4] KASPRZAK, Jan, Dariusz SAMSEL, Aleksandra BORKOWSKA a Mariusz KECIK. Optical Diagnostic in Medicine - Needs and Possibilities. *Acta Physica Polonica A*. 2011, **120**(4), 678-685. DOI: 10.12693/APhysPolA.120.678.
- [5] KAMSHILIN, Alexei A. a Nikita B. MARGARYANTS. Origin of Photoplethysmographic Waveform at Green Light. *Physics Procedia* [online]. 2017, **86**(4), 72-80. DOI: 10.1016/j.phpro.2017.01.024.
- [6] ABAY, Tomas Ysehak a Panayiotis A. KYRIACOU. Reflectance Photoplethysmography as Noninvasive Monitoring of Tissue Blood Perfusion. *IEEE Transactions on Biomedical Engineering*. 2015, **62**(9), 2187-2195. DOI: 10.1109/TBME.2015.2417863.
- [7] CHAN, Edward D., Michael M. CHAN a Mallory M. CHAN. Pulse oximetry: Understanding its basic principles facilitates appreciation of its limitations. *Respiratory Medicine*. 2013, **107**(6), 789-799. DOI: 10.1016/j.rmed.2013.02.004.
- [8] AKL, Tony J., Mark A. WILSON, Milton N. ERICSON a Gerard L. COTÉ. Intestinal perfusion monitoring using photoplethysmography. *Journal of Biomedical Optics*. 2013, **18**(8), 087005:1-12. DOI: 10.1117/1.JBO.18.8.087005.

- [9] MANZKE, Bernd, Johannes SCHWIDER, Norbert O. LUTTER, Kai ENGELHARDT a Wilhelm STORK. Multiwavelength pulse oximetry in the measurement of hemoglobin fractions. *Proc. SPIE 2676. Biomedical Sensing, Imaging, and Tracking Technologies I*. 1996, 2676. 332-340. DOI: 10.1117/12.238813
- [10] SHAH, Nitin, Hamsa B. RAGASWAMY, Kavitha GOVINDUGARI a Laverne ESTANOL. Performance of three new-generation pulse oximeters during motion and low perfusion in volunteers. *Journal of Clinical Anesthesia*. **24**(5), 385-391. DOI: 10.1016/j.jclinane.2011.10.012.
- [11] ZHENG, Jia, Sijung HU, Vicente AZORIN-PERIS, Angelos ECHIADIS a Vassilios CHOULIARAS. A remote approach to measure blood perfusion from the human face. *Proc. of SPIE 7169 Advanced Biomedical and Clinical Diagnostic Systems VII*. 2009, 7169. DOI: 10.1117/12.807354.
- [12] SCHEEREN, Thomas, Patrick SCHOBER a Lothar SCHWARTE. Monitoring tissue oxygenation by near infrared spectroscopy (NIRS): background and current applications. *Journal of Clinical Monitoring and Computing*. 2012, **26**(4), 279-287. DOI: 10.1007/s10877-012-9348-y.
- [13] NIOKA, Shoko, Ryotaro KIME, Ulas SUNAR, Joohee IM, Meltem IZZETOGLU, Jun ZHANG, Burak ALACAM a Britton CHANCE. A novel method to measure regional muscle blood flow continuously using NIRS kinetics information. *Dynamic Medicine*. 2006, **5**(1), 5-17. DOI: 10.1186/1476-5918-5-5.
- [14] SOOD, Beena G., Kathleen MCLAUGHLIN a Josef CORTEZ. Near-infrared spectroscopy: Applications in neonates. *Seminars in Fetal and Neonatal Medicine*. 2015, **20**(3), 164-172. DOI: 10.1016/j.siny.2015.03.008.
- [15] ABAY, Tomas a Panayiotis KYRIACOU. Investigation of photoplethysmography and Near Infrared Spectroscopy for the assessment of tissue blood perfusion. *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE*, 2014. 5361-5364. DOI: 10.1109/EMBC.2014.6944837.
- [16] DUDA, Richard O., Peter E. HART a David G. STORK. *Pattern Classification*. 2nd ed. New York: Wiley-Interscience, 2000. ISBN 0471056693.
- [17] VAN DER HEIJDEN, Ferdi, Robert P. W. DUIN, Dick DE RIDDER a David M. J. TAX. *Classification, parameter estimation and state estimation - an engineering approach using Matlab*. John Wiley, 2004. ISBN 9780470090152.


- [18] MUSSA, Hamse Y., John B.O. MITCHELL a Avid M. AFZAL. The Parzen Window method: In terms of two vectors and one matrix. *Pattern Recognition Letters*. 2015, **63**, 30-35. DOI: 10.1016/j.patrec.2015.06.002.
- [19] FORINA, Michele, Giuliana DRAVA, Raffaella BOGGIA, Silvia LANTERI a Paolo CONTI. Validation procedures in near-infrared spectrometry. *Analytica Chimica Acta*. 1994, **295**(1-2), 109-118. DOI: 10.1016/0003-2670(94)80340-4.



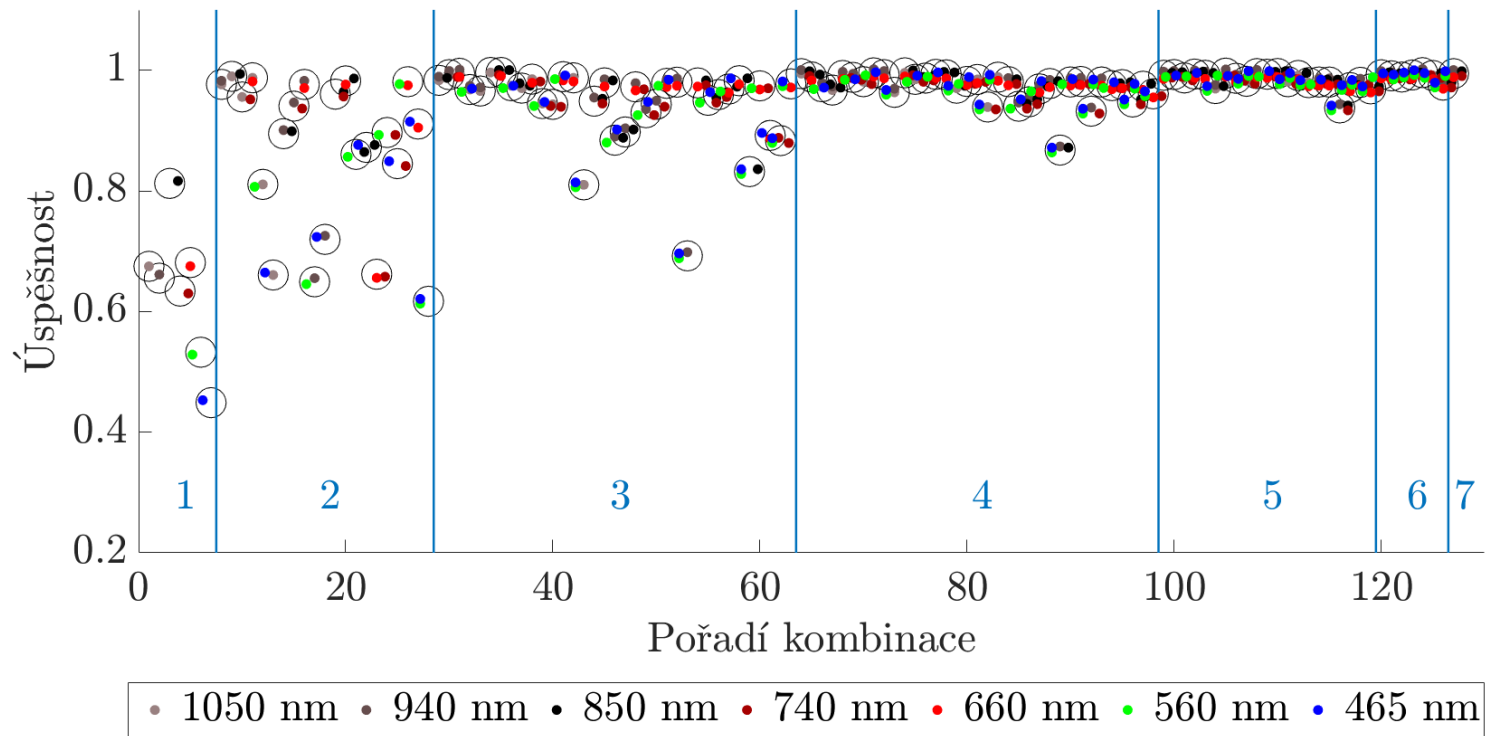
Příloha A

Úspěšnost všech kombinací vlnových délek

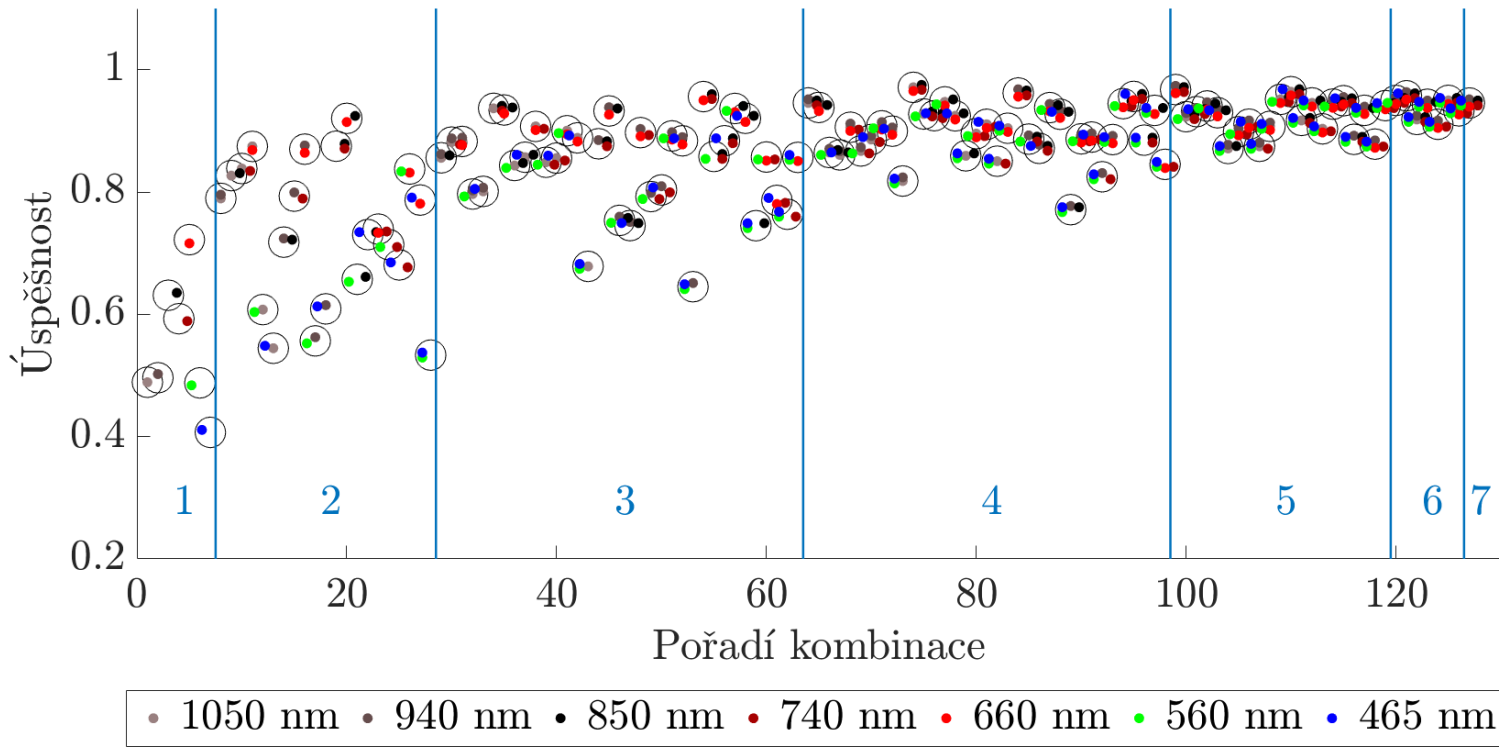
V příloze jsou uvedeny výsledky úspěšnosti pro všechny kombinace vlnových délek. Jednotlivé vlnové délky jsou znázorněny barevnými body, uvnitř kružnice se nachází vlnové délky patřící do stejné kombinace. Kombinace jsou uspořádány vzestupně podle počtu vlnových délek. Výsledky jsou zobrazeny postupně pro kvadratický klasifikátor, k -NN a Pazenova okna, vždy nejprve pro volný dataset a následně pro fixovaný dataset.



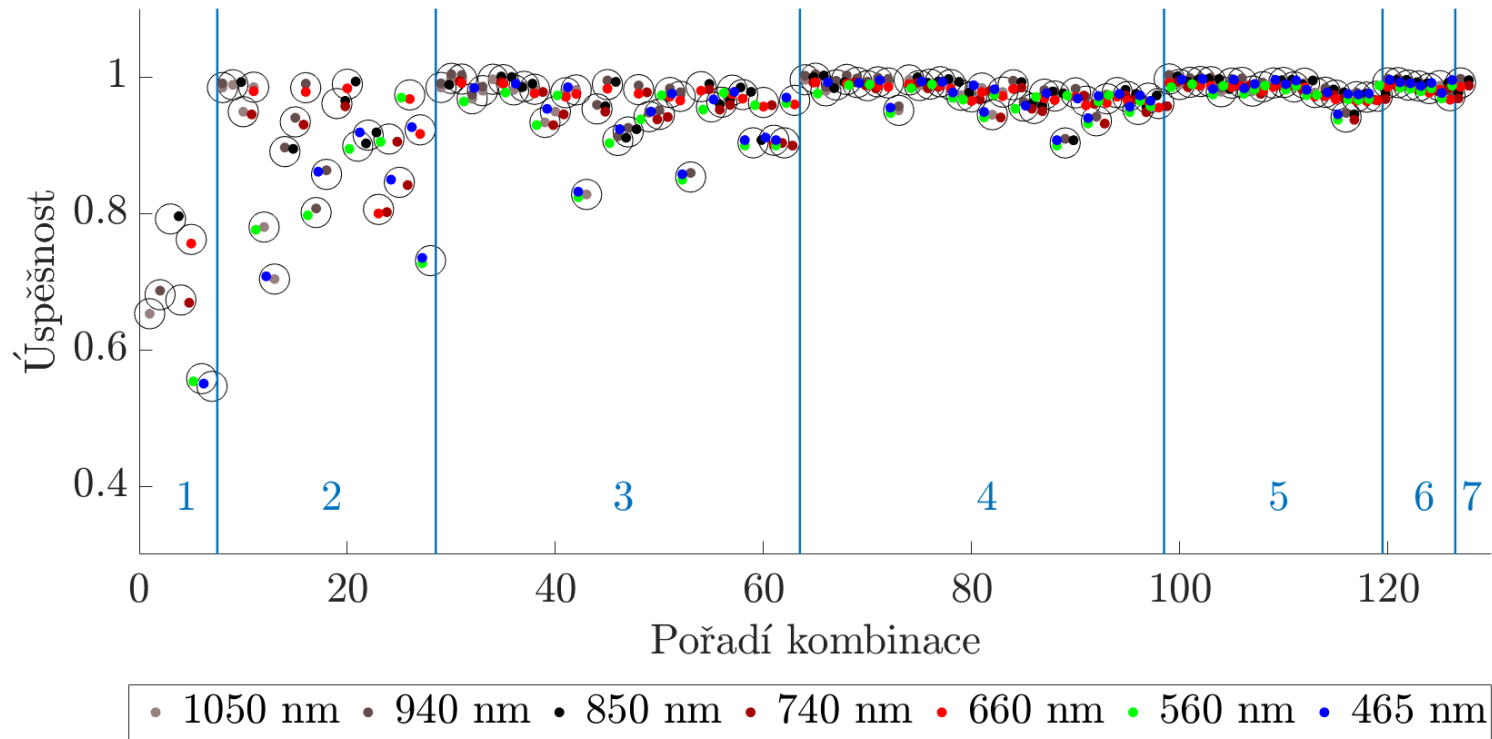
Obrázek A.1: Závislost úspěšnosti klasifikace na kombinaci vlnových délek pro kvadratický klasifikátor a volný dataset




Obrázek A.2: Závislost úspěšnosti klasifikace na kombinaci vlnových délek pro kvadratický klasifikátor a fixovaný dataset




Obrázek A.3: Závislost úspěšnosti klasifikace na kombinaci vlnových délek pro klasifikátor k -NN a volný dataset



Obrázek A.4: Závislost úspěšnosti klasifikace na kombinaci vlnových délek pro klasifikátor k -NN a fixovaný dataset



Obrázek A.5: Závislost úspěšnosti klasifikace na kombinaci vlnových délek pro Parzenova okna a volný dataset



Obrázek A.6: Závislost úspěšnosti klasifikace na kombinaci vlnových délek pro Parzenova okna a fixovaný dataset



Příloha B

Obsah CD

```
|_ diplomova_prace.pdf  
|_ zdrojove_kody  
  |_ data
```