




VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ
ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF BIOMEDICAL ENGINEERING

INTELIGENTNÍ KLASIFIKACE PŘÍZNAKŮ PRO PODPORU DIAGNOSTIKY GLAUKOMU

INTELLIGENT FEATURES CLASSIFICATION AIMED TO SUPPORT DIAGNOSIS OF GLAUCOMA

BAKALÁŘSKÁ PRÁCE
BACHELOR'S THESIS


AUTOR PRÁCE
AUTHOR

PAVEL VYKOUPILOV

VEDOUCÍ PRÁCE
SUPERVISOR

ING. JAN ODSTRČILÍK

BRNO 2012



**VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ**

**Fakulta elektrotechniky
a komunikačních technologií**

Ústav biomedicínského inženýrství

Bakalářská práce

bakalářský studijní obor
Biomedicínská technika a bioinformatika

Student: Pavel Vykoupil
Ročník: 3

ID: 125092
Akademický rok: 2011/2012

NÁZEV TÉMATU:

Inteligentní klasifikace příznaků pro podporu diagnostiky glaukomu

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s principem snímání očního pozadí pomocí fundus kamery a s vlastnostmi takto získaných obrazových dat. Zejména se zaměřte na obrazové struktury charakterizující nervová vlákna. 2) Provedte rešerši prací, zabývajících se analýzou fundus fotografií za účelem diagnostiky glaukomu a moderními přístupy redukce a klasifikace příznaků. 3) Vybrané metody implementujte v programovém prostředí MATLAB za účelem klasifikace stupně poškození vrstvy nervových vláken. 4) Výsledný klasifikátor otestujte na datech dostupných na UBMI. 5) Diskutujte dosažené výsledky a zhodnoťte účinnost a využitelnost aplikovaného řešení.

DOPORUČENÁ LITERATURA:

- [1] ODSTRČILÍK, J., et al. Retinal nerve fiber layer analysis via Markov random fields texture modeling, in Proc. European Sig. Proc. Conf. EUSIPCO 2010, 23-27 August 2010, Aalborg, Denmark, pp. 1650-1654.
[2] DUDA, O. R., et al. Pattern Classification, Wiley, New York 2001. ISBN 0471056693.

Termín zadání: 6.2.2012

Termín odevzdání: 25.5.2012

Vedoucí práce: Ing. Jan Odstrčilík
Konzultanti bakalářské práce:

prof. Ing. Ivo Provazník, Ph.D.
Předseda oborové rady

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. 121/2000Sb., včetně možných trestně právních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

Prohlášení

Prohlašuji, že bakalářskou práci na téma Inteligentní klasifikace příznaků pro podporu diagnostiky glaukomu jsem vypracoval samostatně pod vedením vedoucího bakalářské 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 bakalářské práce dále prohlašuji, že v souvislosti s vytvořením této práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení § 152 trestního zákona č. 140/1961 Sb.

V Brně dne 23. května 2012

.....
podpis autora

Poděkování

Děkuji vedoucímu bakalářské práce Ing. Janu Odstrčilíkovi za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé bakalářské práce.

V Brně dne 23. května 2012

.....
podpis autora

Abstrakt

Tato bakalářská práce se zabývá inteligentní klasifikací příznaků pro podporu diagnostiky glaukomu. První část práce se věnuje anatomii oka a onemocněním sítnice zvaném zelený zákal. V další části je stručně popsána texturní analýza a jak získáváme příznaky pro klasifikaci. V poslední části se zabývá samotnou klasifikací příznaků pomocí neuronových sítí a algoritmů HoKashyap a AdaBoost. Tato práce je tedy zaměřena na srovnání účinnosti těchto klasifikátorů na poli oční diagnostiky, čehož se i podařilo úspěšně dosáhnout.

Klíčová slova: klasifikace, příznaky, diagnostika, glaukom, texturní analýza, neuronové sítě, HoKashyap, AdaBoost.

Abstract

This bachelor thesis deals with intelligent features classification aimed to support diagnosis of glaucoma. First part focuses on eye anatomy and disease called glaucoma. In next part is briefly described texture analysis and how do we get attributes for classification. In last part it is dealt with attribute classification with the aid of neural networks and algorithm HoKashyap and AdaBoost. This thesis is therefore focused on comparing effectivity of these classifiers on the field of optical diagnostics which was managed successfully.

Keywords: classification, attributes, diagnostics, glaucoma, texture analysis, neural networks, HoKashyap, AdaBoost.

Obsah

1. Úvod.....	7
2. Anatomie oka	9
2.1. Cornea - rohovka	9
2.2. Iris - duhovka.....	10
2.3. Komorový úhel.....	10
2.4. Corpus ciliare – řasnaté těleso.....	11
2.5. Lens – čočka.....	11
2.6. Sclera – bělima	12
2.7. Choroidea – cévnatka	12
2.8. Retina – sítnice	12
2.8.1. Tunica conjunctiva - spojivka	14
2.8.2. Corpus vitreum – sklivec	14
2.8.3. Nitrooční tlak	14
3. Glaukom – zelený zákal	16
3.1. Co je to glaukom	16
3.2. Co je glaukomové poškození	16
3.3. Jaké jsou následky glaukomového poškození	17
3.4. Diagnostika glaukomu.....	18
4. Analyzovaná data	19
4.1. Fundus kamera	19
4.2. Obrazová data.....	19
4.3. Texturní analýza obrazových dat	22
4.4. Texturní příznaky analyzovaných dat	23
4.4.1. Testovací příznaky	23
4.4.2. Příznaky získané z obrazových dat od MUDr. Kuběny.....	24
4.4.3. Příznaky získané z obrazových dat databáze Erlangen.....	25
5. Rozhodovací systémy	26
5.1. Úvod.....	26
5.2. Neuronové sítě.....	26
6. Rozhodovací systémy založené na sboru.....	28
6.1. Úvod.....	28

6.2.	Diverzita: základní kámen sborových systémů	28
6.3.	Vytvoření sboru	29
6.3.1.	Boosting	29
6.4.	Adaboost.....	30
7.	Křížová validace	32
7.1.	Úvod.....	32
7.2.	Druhy křížové validace	32
7.2.1.	K-fold cross validation.....	32
7.2.2.	Repeated random subsampling	32
7.2.3.	Leave-one-out cross validation	33
8.	Klasifikace příznaků	34
8.1.	Úvod.....	34
8.2.	Chyby klasifikace	34
8.3.	Diskuse dosažených výsledků	38
9.	Realizované programové funkce.....	39
9.1.	Funkce Klasifikator.m	39
9.2.	Funkce RRSS.m	39
9.3.	Funkce K_Fold.m.....	39
9.4.	Funkce LOO.m.....	40
10.	Závěr	41

1. Úvod

Glaukomové onemocnění představuje jednu z nejčastějších příčin úplné sleposti ve vyspělých zemích. Glaukom postihuje vnitřní část oka, sítnici (*retinu*) [lat. *Rete*, síť] a je charakterizován změnami na ní, zejména v oblasti papily optického nervu (PON): zvětšení exkavace PON, krvácení PON, ztenčení neuro retinálního lemu a progresivní atrofie vrstvy nervových vláken (VNV). Tato ztráta VNV může být relativně dobře viditelná jako texturní změna na fundus fotografiích. Brzká detekce VNV ztráty tedy hraje zásadní roli v efektivní léčbě, jelikož retinální nervová vlákna nemohou být obnovena. Analýza retinálních snímků se tedy stala důležitou součástí při diagnostice glaukomu.

V dnešní době existuje několik diagnostických nástrojů pro snímání zadního segmentu oka používaných v oftalmologii. Nejstarším a nejrozšířenějším diagnostickým nástrojem je pravděpodobně klasický oftalmoskop, umožňující lékaři nahlédnout na zadní segment oka a poskytnout mu tak informaci o anatomii a fyziologii retinálních struktur daného pacienta, avšak bez možnosti jakéhokoli uložení obrazové informace. Možnost archivace diagnostických snímků s sebou přinesla až analogová fundus kamera na počátku 20. století [1], která umožnila snímat bílé světlo odražené od tkáně zadního segmentu oka a zaznamenávat tak fotografie sítnice na černobílý negativ.

S rozvojem informačních technologií pokročil i vývoj zobrazovacích systémů v oftalmologii. V dnešní době je většina oftalmologických pracovišť vybavena fundus kamerou. Kromě této kamery se však v oftalmologii využívá celá řada dalších systémů pro zobrazení a diagnostiku významných struktur zadního segmentu oka. Mezi tyto systémy patří např. ultrasonografie pro zobrazení různých tkání majících na svých rozhraních rozdílnou akustickou impedanci (více lze nalézt ve [2]).

Dalším zobrazovacím systémem používaným v očním lékařství je optická koherentní tomografie (OCT – Optical Coherence Tomography). Tato metoda nám umožňuje 3D zobrazení sítnice a její anatomické struktury. Oproti ultrazvukovému zobrazení využívá úzce koherentní svazek infračerveného záření (810 nm až 860 nm). Výhodou OCT je vyšší rozlišení než u ultrazvuku.


Při klinickém vyšetření zadního segmentu oka, z pohledu diagnostiky glaukomu, dnes hraje stěžejní roli především analýza velikosti a tvaru optického disku a analýza tloušťky VNV. Na mnoha oftalmologických pracovištích se toto vyšetření stále opírá především o subjektivní vyhodnocení fotografií sítnice, pořízených fundus kamerou, zkušenými a trénovanými oftalmology.

Kvalitativní diagnostika oftalmologem je však časově náročná a především špatně reprodukovatelná [2]. Jelikož je však fundus kamera mnohem levnější než ostatní zobrazovací systémy v oftalmologii, využívá se dodnes. Automatická analýza obrazových dat z fundus kamery se proto dnes, díky dostupnosti kvalitnějších a věrohodnějších fotografií, dostává čím dál více do popředí zájmu a mnoho vědeckých, ale i klinických pracovišť, reflektuje snahu podpořit automatizovanou analýzou těchto dat diagnostiku glaukomu a jiných nemocí sítnice. Samotná klasifikace příznaků nám tedy umožňuje relativně rychlé a levné roztřídění dat do jednotlivých tříd.

Existuje několik sofistikovaných metod klasifikace příznaků získaných pomocí texturní analýzy fundus fotografií [3-6]. Jedním z posledních trendů na poli klasifikátorů je mimo jiné i algoritmus AdaBoost, představený v roce 1997 [7]. Cílem této práce je tedy testování těchto metod na obrazových datech, zhodnocení jejich účinnosti a využitelnosti při diagnostice glaukomu.

2. Anatomie oka


Anatomii oka a všechny jeho součásti zobrazuje Obrázek 1:



Obrázek 1: Anatomie oka, zdroj: [8]

2.1. Cornea - rohovka

Rohovka je průhledná, kopulovitě zakřivená vrstva pokrývající přední část oční koule. Rohovka má značnou optickou mohutnost, představuje zhruba dvě třetiny celkové optické mohutnosti oka (± 43 dioptrií) a společně s čočkou, která má ± 15 dioptrií, se podílí na lomu světla přicházejícího do oka. Protože rohovkou neprocházejí žádné krevní cévy, za normálních okolností je naprosto čirá a má lesklý povrch. Rohovka je také extrémně citlivá - obsahuje více nervových zakončení než kterákoli jiná oblast v lidském těle. Rohovka dospělého člověka je silná jen přibližně půl milimetru. Obrázek 2 znázorňuje rohovku.



Obrázek 2: Rohovka, zdroj: [8]


2.2.Iris - duhovka

Duhovka má tvar mezikruží se středovým otvorem, jímž je pupila – zornice. Duhovka spolu s čočkou odděluje přední a zadní komoru oční. Funkce duhovky je funkce clony, jako u fotografického objektivu: *rozvívá pupilu (mydriasa)* při nedostatku světla a při akomodaci oka na dálku; *svírá pupilu (miosa)* při dostatku světla a při akomodaci oka nablízko. Důležitým funkčním místem u duhovky je místo vstřebávání komorové tekutiny do cévního systému. Poruchy vstřebávání komorové tekutiny vedou ke zvýšení nitroočního tlaku (normální nitrooční tlak činí 10 – 20 mm Hg [9]), které vyvolává tzv. **zelený zákal (glaukom)**, při němž jsou tlakem z nitra oka utištěny a posléze zacházejí buňky sítnice[10].

2.3.Komorový úhel

Komorový úhel je místo v přední oční komoře, kde se spojuje rohovka s duhovkou. Skládá se z několika struktur, které vytvářejí drenážní systém odvádějící z oka nitrooční tekutinu. Pokud tento systém nefunguje správně, může dojít k hromadění tekutiny v oku a tím ke zvýšení nitroočního tlaku, který je nejvýznamnějším faktorem pro vznik glaukomu.

Nitrooční tekutina protéká ze zadní komory oční přes zornici do přední komory. Jelikož je teplota v zadní komoře za normálního stavu vyšší, je zaručena tepelná cirkulace tekutiny v přední komoře [9]. Cirkulaci nitrooční tekutiny znázorňuje Obrázek 3.



Obrázek 3: Komorový úhel a cirkulace nitrooční tekutiny, zdroj: [8]


2.4. Corpus ciliare – řasnaté těleso

Řasnaté těleso leží těsně za duhovkou. Z povrchu řasnatého tělíska vybíhají četná jemná vlákénka, na kterých je zavěšena oční čočka. Kyslík a výživné látky pro řasnaté tělísko jsou přiváděny cévami, které zároveň vyživují také duhovku.

Řasnaté tělísko plní v oku dvě důležité funkce. Za prvé je místem, kde se tvoří **nitrooční tekutina**, jež vyplňuje oční komory. Zvýšená tvorba nitrooční tekutiny nebo její zhoršený odtok z oka mají na svědomí zvýšení nitroočního tlaku, což může způsobit vznik **zeleného zákalu (glaukomu)**. Druhou důležitou funkcí řasnatého tělíska je zajišťování **akomodace** a tím také ostrého vidění do blízka i do dálky podle toho, jak je právě potřeba. Principem akomodace je změna zakřivení čočky, která je na řasnatém tělísku zavěšena. Změnou tvaru čočky a tím její tloušťky je ovlivněn lom paprsků, které vcházejí do oka.

Když se řasnaté tělísko kontrahuje, uvolní se vlákna, na kterých je zavěšena čočka, a té je tak umožněno se více vyklenout. V tomto vyklenutém tvaru je čočka zaostřena na vidění do blízka. Pokud se řasnaté tělísko uvolní, čočka se stává tenčí a umožní naopak ostrý pohled na více vzdálené předměty.

U starších lidí ztrácí řasnaté tělísko schopnost se kontrahovat a čočka se hůře vyklenuje, což způsobuje potíže se čtením a neostře vidění na krátkou vzdálenost. Tento stav se nazývá **presbyopie**. Obrázek 4 nám znázorňuje řasnaté tělísko.



Obrázek 4: Řasnaté tělísko, zdroj: [8]

2.5. Lens – čočka

Čočka je uložena za *pupilou - zornicí*, u dospělého člověka má průměr 9 - 10 mm; tloušťka čočky činí 3,7 mm, při akomodaci na blízko 4,4 mm. Její optická mohutnost je 10 – 17 dioptrií podle stávajícího stavu jejího vyklenutí, neboť základní vlastností čočky je schopnost měnit vyklenutí a tím i optickou mohutnost [10].


2.6.Sclera – bělima

Bělima má rozsah téměř 80% povrchu oční koule. Skládá se z hustého fibrilárního vaziva, jehož pruhy se ve všech směrech proplétají. Vzhledem připomíná šlachy a je mléčně bílá [4]. Sclera v přední části oka přechází v rohovku. Ta je na rozdíl od bělimy prostupná pro světelné paprsky. Bělima je velmi tuhá, a proto dobře chrání vnitřní struktury oka. Na bělimu se dále upíná šest okohybných svalů, které umožňují pohyb očního bulbu. Na zadní straně bulbu bělimou prostupuje zrakový nerv.

2.7.Choroidea – cévnatka

Cévnatka je další vrstva obalující oční kouli, která leží mezi bělimou a sítnicí. Je velmi hustě prostoupena krevními kapilárami, které vyživují oční struktury. Cévnatka je z přední strany napojena na řasnaté tělísko a na zadní straně se připojuje k okrajům zrakového nervu.

Obrázek 5 znázorňuje uložení jednotlivých vrstev, které tvoří oční bulbus.




Obrázek 5: Sítnice, cévnatka a bělima, zdroj: [8]

2.8.Retina – sítnice

Sítnice je součástí zadního neboli posteriorního segmentu oka, též nazývaného fundus. Obsahuje velké množství světločivných buněk. Mezi tyto buňky řadíme tyčinky (černobílé vidění) a čípky (barevné vidění). Vždy několik světločivných buněk připadá na jednu buňku gliovou, několik buněk gliových pak zase na jednu buňku nervovou, a jejich jednotlivá vlákna jdou rovnoběžně s

povrchem oční koule, k místu zvaném „**papila zrakového nervu**“ na zadním pólu oka, kde se ohýbají do pravého úhlu a společně tvoří zrakový nerv, vedoucí vzruch do centrálního nervového systému (CNS). Místo, kde jsou čípky nejvíce koncentrovány a tyčinek je tam relativně málo, se nazývá *macula lutea - žlutá skvrna* a je to místo nejostřejšího vidění. Je to část sítnice, na kterou se zobrazuje ta část zorného pole, na kterou právě zaostřujeme. V papile zrakového nervu existuje ještě tzv. slepá skvrna, kde se nachází pouze axony, a tato malá část sítnice tedy není schopna „vidět“. Tato malá oblast, na které není zachycena informace, je téměř nepostřehnutelná, protože mozek chybějící části celkového obrazu do jisté míry doplňuje. Slepé skvrny je však možné identifikovat při vyšetření zorného pole.

Z histologického hlediska se tkáň retiny skládá z 10 retinálních vrstev [11] viz. Obrázek 6. Vnitřní hraniční membrána tvoří ochrannou vrstvu složenou z Müllerových buněk poskytující výživu a kyslík neuronům. Naopak nejzevnější retinální vrstva (před pigmentovým epitelem) obsahuje foto senzitivní receptory (až 132 mil.), na něž dopadá světlo přes ostatní retinální vrstvy, které jsou z pohledu absorpce světla transparentní. Odtud je světelná informace zpracována zpětně dalšími vrstvami a přenesena k vrstvě tvořené z gangliových buněk (cca 1 mil.). Výběžky nervových gangliových buněk obsahují axony (vlákna), tvořící vrstvu nervových vláken (VNV), a sbíhají se v terči zrakového nervu (papila). Terč zrakového nervu je také často označován pojmem optický disk (OD). Axony tvořící zrakový nerv (*n. opticus*) v místě OD opouštějí sítnici a vedou přímo do mozku. Terčem zrakového nervu procházejí rovněž zásobovací cévy, které tkáním sítnice zajišťují potřebné prokrvení a výživu.



Obrázek 6: Schematický řez retinální tkání, zdroj: [12]

2.8.1. Tunica conjunctiva - spojivka

Je to sliznice zadní plochy víček, která z nich přechází hlubokými záhyby – v úrovni kořene víčka na přední povrch skléry jako vrstevnatý dlaždicový epitel podložený vazivovou lamelou. Vazivo končí na okraji rohovky a povrchový epitel pak přechází v povrchový epitel rohovky [5]. Je vyživována velmi tenkými cévami, které jsou prostým okem takřka neviditelné. Spojivka vylučuje hlen, který pomáhá udržovat oko vlhké.

2.8.2. Corpus vitreum – sklivec

Sklivec je průhledná, dokonale čirá, světlolomná, bezbuněčná vodnatá hmota (98,6 % vody), která vyplňuje prostor uvnitř bulbu.

2.8.3. Nitrooční tlak

Nitrooční tlak je výsledkem poměru mezi tvorbou a odtokem nitrooční tekutiny, nebo jednodušeji řečeno tlak uvnitř oka. Normální hodnota nitroočního tlaku se pohybuje mezi 10 – 20 mm Hg (rtuťového sloupce) [9]. Tlak uvnitř oka se u zdravého člověka v průběhu dne moc nemění.

Vysoký nitrooční tlak způsobuje utlačování vlákna zrakového nervu a to hlavně v místě jeho výstupu z oka. Nervová vlákna jsou v tomto místě ohýbána do pravého úhlu (viz. Retina – sítnice) a

právě v tomto místě jsou nejvíce náchylná na změny nitroočního tlaku. Vznikají pak pro glaukom typické výpadky zorného pole. Citlivost vazivové i nervové tkáně je však k tlakovému působení velmi individuální.

3. Glaukom – zelený zákal

3.1. Co je to glaukom


Termín „glaukom“ zahrnuje spektrum nemocí. Bohužel tento termín není používán jednotně, což může být zavádějící zejména pro ty, kteří se s touto nemocí setkají poprvé. Některé knihy, zejména z kontinentální Evropy, definují glaukom jako skupinu stavů s jedním společným znakem – zvýšeným nitroočním tlakem (NT). Jiné články, především z anglicky mluvících zemí, definují glaukom jako výlučně takové stavy, kde dochází k poškození zrakového nervu a ztrátě vidění. V běžné oftalmologické praxi se ukázalo jako užitečné používat termínu glaukom jak u všech pacientů se zvýšeným nitroočním tlakem (ať už s nebo bez glaukomového poškození), tak u všech pacientů s glaukomovým poškozením (ať už s nebo bez vysokého NT) [13].

3.2. Co je glaukomové poškození

Vidění je proces probíhající v několika fázích: na oko dopadá světlo a sítnice toto světlo „transformuje“ na elektrické nervové impulzy, které je mozek schopen zpracovat. U glaukomu nervové buňky a nervová vlákna postupně odumírají. V důsledku toho se také postupně narušuje spojení mezi okem a mozkiem, které je pro vidění tak zásadní. Oko stále „vidí“ světlo, protože tyčinky a čípky ještě pracují, ale přenos zrakové informace do mozku je přerušen. To je podstata problému a je označována jako „glaukomové poškození“.

Ztráta nervových vláken je patrná především na terči zrakového nervu. Oční lékař může tento stav pomocí přístrojů (HRT, HRT II, HRT III, GDx, OCT) přímo pozorovat, a poškození tak určit [13].

Na následujících obrázcích (od MUDr. Tomáše Kuběny, viz. Kapitola 4.2) lze vidět glaukomové poškození.



Obrázek 7: Fundus snímek zdravého oka



Obrázek 8: Fundus snímek oka postiženého glaukomem. Oblast postižená glaukomem je vyznačená šipkami

3.3. Jaké jsou následky glaukomového poškození

V raných stádiích nemoci, kdy odumírají první nervové buňky a jejich „zakončení“, zrak mnohdy zůstává překvapivě nedotčený. S postupující chorobou se však v pacientově vidění objevují čím dál závažnější defekty. Oftalmolog je schopen tyto defekty odhalit, ačkoli sám pacient si jich často není vědom. Právě proto je glaukom nebezpečný – když si pacient ztrátu zorného pole uvědomí, je nemoc již v pokročilém stádiu. Pacient by se neměl nechat ukolébat tím, že zůstává ostrost zraku – ztráta zorného pole může být značná i při vysoké ostrosti vidění [13].

3.4.Diagnostika glaukomu

Diagnostika glaukomového poškození je dosti náročná, zvláště v raných stádiích nemoci. Je závislá zejména na analýze OD a zorného pole. Pro hodnocení postupu choroby je nejvýznamnější perimetrie (vyhodnocení zorného pole [14]). Oftalmolog také zkoumá rizikové faktory, například měří nitrooční tlak a kontroluje komorový úhel, aby stanovil míru a rizika uzávěru úhlu. Pokud existuje podezření, že v roli ve vývoji poškození hrají i poruchy perfúze, je důkladně vyšetřena cirkulace. Pokud je to možné, je kvantitativně stanovena. Vhodné metody jsou měření krevního tlaku, barevná Dopplerova sonografie a kapilární mikroskopie. Ačkoli i jiné testy jsou zajímavé, protože upozorňují na možné poškození, nejsou běžně prováděny, protože významně nepřispívají k diagnóze, ani k hodnocení vlastního postupu choroby. Další ztráta funkce se může projevit u adaptace na tmu, barevného vidění, kontrastní citlivosti nebo jako zesílené oslnění; může se také objevit v elektrofyziologických testech, jako ERG (Elektroretinografie), VEP (Vizuálně evokované potenciály)[13]. Další nedílnou součástí diagnostiky glaukomu je analýza fundus fotografií. Na těchto snímcích sledujeme množství gangliových buněk, jejich počet usuzujeme podle svazečků nervových vláken na sítnici a podle šíře neuro retinálního lemu terče zrakového nervu. Sledování změn vrstvy nervových vláken je citlivější pro včasné poznání glaukomu než sledování terče samotného. Vzhledem k variabilitě terče je obtížné stanovit jednotnou normu pro všechny lidi. Vrstva nervových vláken je však morfologicky téměř stejná u každého člověka. Dále hodnotíme velikost a barvu terče, rozsah a hloubku exkavace, průběh cév a nervových vláken.

Mezi více sofistikované zobrazovací modality využívané v oftalmologii, umožňující 3D zobrazení topografie a tloušťky zadního segmentu oka, můžeme uvést např. CSLO (Cofocal Scanning Laser Ophthalmoscopy), poprvé představený R. Webbem v roce 1987 [15]. Toto zařízení umožnilo zobrazení struktury sítnice pomocí fokusace laserového svazku do příslušných kofokálních rovin. Na základě této CSLO vznikla jedna z nejznámějších metod, a to skenovací laserový tomograf HRT (Heidelberg Retina Tomograph, Heidelberg Engineering, Heidelberg, Německo).

Další modalitou vzniklou na základě CSLO je zařízení s označením GDx (Laser Diagnostic Technologies, Inc., San Diego, California, USA), které je navrženo pro analýzu tloušťky VNV na sítnici [2].

Dále je v oftalmologii využívána optická koherentní tomografie (OCT). Funguje stejně jako ultrazvuk, avšak u OCT je nosičem informace úzce koherentní svazek infračerveného záření fokusovaný do různých vrstev sítnice. Výhodou této metody oproti ultrazvuku je schopnost zobrazit větší plochu s lepším axiálním rozlišením, cca 10-20 μm (ultrazvuk cca 150 μm)[16].

Jedním z nejjednodušších a nejlevnějších způsobů, jak získat snímky zadního segmentu oka, je pomocí digitální fundus kamery. Jak již bylo uvedeno v úvodu, je v dnešní době většina oftalmologických pracovišť vybavena fundus kamerou. Díky těmto vlastnostem se automatická analýza fundus snímků dostává stále více do popředí zájmu.

4. Analyzovaná data

4.1. Fundus kamera

Fundus kamera je přístroj sloužící k zobrazení očního pozadí (fundu). Funguje na principu oftalmoskopie. Snímací kamera, v dnešní době CCD kamera, je připojena na mikroskop, který soustavou čoček a zrcadel fokusuje světelný paprsek na oční pozadí. Kamera potom snímá obraz očního pozadí. Obrázek 9 nám ukazuje fundus kameru Canon CR-1.



Obrázek 9: Fundus kamera Canon CR-1, zdroj: [17]

4.2. Obrazová data


V současné době je k dispozici sada RGB snímků sítnice z fundus kamery pocházející z oční ordinace MUDr. Tomáše Kuběny ve Zlíně a snímky z databáze Erlangen. Snímky od MUDr. Kuběny mají rozlišení 3504 × 2336 pixelů, byly pořízeny digitální fundus kamerou Canon CR-1 s vestavěným fotoaparátem CANON EOS-20D a zorným polem 60°. Všechny snímky jsou ve formátu JPEG. Jedna skupina snímků představuje „zdravé oči“ (15 snímků) zahrnující snímky sítnice zdravých pacientů a druhá skupina jsou „nemocné oči“ (18 snímků) zahrnující snímky sítnice očí pacientů, u kterých bylo diagnostikováno glaukomové poškození s výpadkem ve VNV.

Snímky v databázi Erlangen byly pořízeny na Oftalmologické klinice Univerzity Erlangen-Norimberk, Německo. Ke snímání byla použita fundus kamera CANON CR-1 s vestavěnou zrcadlovkou CANON EOS 40D. Snímky s rozlišením 3888 × 2592 pixelů jsou uloženy ve formátu


JPEG s minimální kompresí.

Na těchto snímcích byla provedena texturní analýza a její příznaky vstupují do samotné klasifikace.


Pro ukázkou jsou níže uvedeny jednotlivé barevné kanály (viz. Obrázek 8, Kapitola 3.2). Z těchto obrázků můžeme vidět, že textura VNV je dobře viditelná ze zelené a modré složky snímku. Nejlépe však můžeme vidět ztrátu VNV z průměru zelené a modré složky, kterou nám znázorňuje Obrázek 13.




Obrázek 10: Červená složka fundus snímku oka postiženého glaukomem



Obrázek 11: Zelená složka fundus snímku oka postiženého glaukomem




Obrázek 12: Modrá složka fundus snímku oka postiženého glaukomem



Obrázek 13: Průměr zelené a modré složky fundus snímku oka postiženého glaukomem

4.3. Texturní analýza obrazových dat

Jako texturu v našem případě bereme texturu nervových vláken, tzv. „žíhání“, na očním pozadí. Při texturní analýze snímků z databáze od MUDr. Kuběny byla pro extrakci příznaků použita metoda LBP (Local Binary Patterns) [18]. Pro analýzu snímku z databáze Erlangen byla použita metoda GMRF (Gaussian Markov Random Fields) [3, 19]. Pro názornost nám Obrázek 14 zobrazuje texturu VNV.




Obrázek 14: Vrstva nervových vláken. Modrá šipka ukazuje plochu, která obsahuje nervová vlákna. Červená šipka zobrazuje místo bez nervových vláken, zdroj: [20]


4.4. Texturní příznaky analyzovaných dat

4.4.1. Testovací příznaky

Nejprve byly použity testovací data z toolboxu v [21] (jmenovitě `test_data.mat` a `data_12.mat`), pro testování chování klasifikátorů na různém rozložení dat. Konkrétně 2x100 příznaků pro `test_data.mat` a 2x600 příznaků pro `data_12.mat`. Rozložení dat v dvojrozměrném prostoru můžeme vidět na obrázcích níže (viz. Obrázek 15 a Obrázek 16). Zároveň s rozložením dat v prostoru, je vyobrazeno rozložení příznaků pomocí tzv. boxplotu. Pomocí této funkce zobrazíme data do „krabic“ a vidíme jejich rozložení. Vzdálenost těchto boxů nám udává míru překrývání dat. Tzn., že pokud jsou tyto boxy dostatečně daleko od sebe (jeden z nich je nahoře, druhý dole a vice versa), jsou tato data dobře klasifikovatelná. Pokud by však byly na stejné úrovni, data se překrývají a bude je velmi obtížné, ne-li nemožné klasifikovat. Červená přímka nám udává medián, okraje boxu jsou 25 a 75 percentil a přímky vystupující z nich jsou extrémní hodnoty




Obrázek 15: Nepřekrývající se data z toolboxu (`test_data.mat`). Zobrazení v dvourozměrném příznakovém prostoru a rozložení pomocí boxplotu.



Obrázek 16: Překrývající se data z toolboxu (data_12.mat). Zobrazení v dvourozměrném příznakovém prostoru a zobrazení pomocí boxplotu.

4.4.2. Příznaky získané z obrazových dat od MUDr. Kuběny


Z obrazových dat od MUDr. Kuběny byly vytvořeny dvě sady příznaků, po pěti a sedmi příznacích v každém, vytvořené metodou LBP [18], které byly použity pro klasifikaci. V těchto setech je dále rozdělení na příznaky pro zdravou tkáň ve zdravém oku, nemocnou tkáň v nemocném oku a zdravou tkáň v nemocném oku (viz. Obrázek 17). Konkrétně 5x176 příznaků pro nemocnou tkáň a 5x227 příznaků pro zdravou tkáň.



Obrázek 17: Příznaky získané metodou LBP. Zobrazení v dvourozměrném příznakovém prostoru a zobrazení pomocí boxplotu.

4.4.3. Příznaky získané z obrazových dat databáze Erlangen

Z obrazových dat z databáze Erlangen, byly vytvořeny sady příznaků pomocí metody GMRF [3, 19] po třech, čtyřech a pěti příznacích v každém z nich (viz. Obrázek 18). V případě setu po třech bylo 3×39 příznaků pro nemocnou tkáň a 3×107 pro tkáň zdravou.



Obrázek 18: Příznaky získané metodou GMRF. Zobrazení v dvourozměrném příznakovém prostoru a pomocí boxplotu.

5. Rozhodovací systémy

5.1. Úvod

Jakmile tedy máme příznaky, resp. příznakové vektory, je potřeba je klasifikovat. K tomu nám slouží rozhodovací systémy, tedy klasifikátory. Pod pojmem klasifikace si představme zařazení vstupního (příznakového vektoru) do jedné z daných tříd (binárně – 0 nebo 1). Klasifikátory jsou tedy sítě, které rozpoznají vstupní vzor a zařadí ho do vybrané třídy. Na výstupu je tato třída zastoupena např. logickou jedničkou na příslušném výstupu, zatímco ostatní výstupy jsou nulové. Úlohou klasifikátorů je tedy zařadit vzor na základě podobnosti [22]. V této práci jsou použity tři klasifikátory pro posouzení jejich účinnosti a využitelnosti na poli diagnostiky glaukomu. Použité klasifikátory jsou jednoduchý perceptron, HoKashyap a algoritmus AdaBoost. Perceptron a HoKashyap patří mezi lineární klasifikátory. Tyto klasifikátory rozdělují příznaky pomocí jedné nadroviny (přímky) [21, 22]. Algoritmus AdaBoost [21, 23], patřící mezi expertní systémy založené na sboru, se využívá tam, kde jsou výsledky lineárního neuspokojivé, nebo není možné data rozdělit pomocí jedné nadroviny [22]. Jsou tedy srovnány účinnosti jednotlivých typů klasifikace na různém rozložení vstupních dat. Tato kapitola se věnuje klasifikátorům lineárním.


5.2. Neuronové sítě

Neuronové sítě jsou jednou z oblastí umělé inteligence, které se v posledních letech věnuje značná pozornost, protože mají mnoho zajímavých vlastností, které lze s úspěchem využít v řadě oborů. [22]

Neuronové sítě mají celou řadu zajímavých vlastností, především schopnost učit se, tj. měnit své parametry i strukturu, aby lépe vyhovovala zadaným požadavkům. Musí mít tedy zavedenou zpětnou vazbu, která jí říká, jak dobře splnila svůj úkol a podle toho pak změnila své parametry. Učení neuronové sítě může probíhat buď s učitelem, nebo bez něj. Je-li síť navržena tak, aby se mohla učit na příkladech, říkáme, že je to síť s učitelem. V opačném případě, kdy není učitel k dispozici, se musí síť učit z chyb, které udělala a snažit se vyhovět nějakému zadanému kritériu. V obou případech si neuronová síť snaží vytvořit svůj vlastní vnitřní model, který by napodoboval skutečný systém. Touto schopností přibývá neuronové síti další zajímavá vlastnost a to možnost predikce. [22]


Vznikne-li v klasickém počítačovém programu chyba, program se zpravidla „zhroutí“. Neuronové sítě však na chyby reagují jinak, drobné odchylky jejich funkci nenaruší a jsou vůči chybám relativně robustní. Jejich další výhodou je, že zpracovávají informaci paralelně a to zvyšuje jejich rychlost. Paralelní zpracování signálů je typickou vlastností neuronových sítí mozku. [22]

Nejjednodušším příkladem neuronových sítí je perceptron, tedy jeden neuron, který rozděluje vložené vstupy do dvou tříd tím, že jednomu výstupu přiřadí jedničku (např. zdravá, neporušená VNV) a druhému nulu (ztráta VNV). Na následujícím obrázku můžeme vidět funkci perceptronu. Vstupy jsou náhodné 4 hodnoty, které se poté klasifikovaly do dvou tříd.



Obrázek 19: Funkce perceptronu. Modré tečky představují binární jedničku, tedy „zdravé oko“, bílé potom binární nulu, tedy „nemocné oko“

Směrnice rovnice přímky ($y = kx + q$), kterou můžeme vidět na obrázku nahoře, odpovídá funkci f ve schématu perceptronu níže, kde k a q odpovídá vahám w , které se mění při každé iteraci. Hodnota k je směrnice přímky a q je úsek, kde přímka protíná osu y .



Obrázek 20: Schéma perceptronu

6. Rozhodovací systémy založené na sboru

6.1. Úvod

V předchozích kapitolách byly probrány jednoduché expertní systémy (např. perceptron). Tyto systémy jsou navrženy pro řešení komplexních problémů na základě určitých předem daných znalostí. V našem případě šlo o klasifikaci degradace VNV. Jednoduché expertní systémy nám mohou úspěšně klasifikovat dobře oddělené příznaky (viz. Obrázek 15). Při klasifikaci VNV máme většinou více než dva příznaky a dělicí linie mezi příznaky není přesně daná (viz. Obrázek 17). V těchto případech je vhodné využít některé sofistikovanější lineární klasifikátory, jako je HoKashyap [21, 24], nebo využít expertních systémů založených na sboru, mezi které patří námi použitý algoritmus AdaBoost [21, 23].

Aby námi vytvořený sbor dokázal úspěšně klasifikovat i složité problémy, je potřeba zajistit diverzitu mezi jednotlivými klasifikátory. Diverzitou a algoritmem AdaBoost se zabývají následující kapitoly.

6.2. Diverzita: základní kámen sborových systémů

Pokud bychom měli klasifikátor, který by měl perfektní výkon, nebylo by potřeba využívat sborové systémy. Ve skutečnosti však takový klasifikátor nelze vytvořit, kvůli náhodným hodnotám, šumu nebo překrývajícími se daty. Přinejlepším můžeme doufat, že bude klasifikátor úspěšný ve většině případů. Strategií sborových systémů je tedy vytvořit mnoho klasifikátorů, jejich výstupy vhodně skombinovat a zlepšit tím tak výkon sboru. Důležité však je, aby individuální klasifikátory chybovaly v různých případech. Pokud tedy každý klasifikátor dělá různé chyby, potom kombinací

těchto klasifikátorů můžeme redukovat celkovou chybu [23].

Diverzity klasifikátorů můžeme dosáhnout několika způsoby. Nejpopulárnější metodou je použití různých trénovacích data setů pro trénink individuálních klasifikátorů. Tyto data sety jsou většinou získávány pomocí resamplovacích technik jako jsou bagging nebo bootstrapping [25], kde jsou sub sety trénovacích dat vybírány náhodně, často s výměnou, z celého setu dat. Pokud jsou tyto sub sety vybrány bez výměny, nazývá se tato metoda jackknife nebo k-fold data split [23].

Dalším způsobem pro dosažení dostatečné diverzity je použití různých trénovacích parametrů pro různé klasifikátory. Například série vícevrstvých perceptronů u neuronových sítí může být trénována s různými vahami, počty vrstev atd. [23].

V neposlední řadě patří mezi tyto metody také tzv. boosting a konečně algoritmus AdaBoost [21, 23].

6.3. Vytvoření sboru

Jak již bylo uvedeno výše, při vytváření sboru je nejdůležitější diverzita jednotlivých klasifikátorů. Tím zajistíme obecný výkon sboru jako kombinace těchto klasifikátorů. Jednou z metod dosažení diverzity je metoda boosting [26].

6.3.1. Boosting

V roce 1990 Schapire dokázal, že weak learner, tedy algoritmus, který generuje klasifikátor, pracující jen nepatrně lépe než náhodný odhad, se může přeměnit na strong learner, který generuje klasifikátor úspěšně klasifikující všechna data, až na malé odchylky [26]. Formální definice weak a strong learner mohou být nalezeny v [26], kde Schapire také poskytuje elegantní algoritmus pro zesílení výkonu weak learneru na úroveň strong learneru. Odtud vznikl název metody boosting, neboli zesílení. Tento algoritmus je v dnešní době považován za jeden z nejvýznamnějších poznatků v historii strojového učení [23].

Stejně jako u metody bootstrapping, algoritmus boosting vytvoří sbor klasifikátorů na základě resamplovacích technik, které potom skombinuje pomocí hlasu většiny (majority vote). Zde však všechny podobnosti končí. U boosting algoritmu, vzorkování je strategicky směřováno tak, aby byla data pro každý další klasifikátor co nejvíce informativní. V podstatě algoritmus boosting vytvoří tři slabé klasifikátory. První klasifikátor C_1 je trénován subsetem S_1 náhodně vybraným ze setu S . Následně se vytvoří subset S_2 jako nejvíce informativní subset, daný klasifikátorem C_1 tak, že polovina subsetu S_2 je správně klasifikována klasifikátorem C_1 a druhá polovina je klasifikována špatně. Poté se klasifikátor C_2 natrénuje subsetem S_2 . Nakonec se vytvoří subset S_3 výběrem


případů, kde se klasifikátory C_1 a C_2 neshodly. Poslední klasifikátor C_3 je natrénován subsetem S_3 . Následná klasifikace testovacích dat probíhá potom tak, že náhodný vzorek x je klasifikován pomocí C_1 a C_2 . Pokud na výsledné třídě souhlasí, je tato třída finální. V případě kdy nesouhlasí, vybere se jako finální třída předpovězená klasifikátorem C_3 [23].

6.4. Adaboost

V roce 1997 Freund a Schapire představili algoritmus Adaptive Boosting neboli AdaBoost [7], který se těší velké pozornosti ve výpočetní inteligenci. AdaBoost je více obecná verze originálního boosting algoritmu a je více využíván díky schopnosti zvládat klasifikaci do více tříd a regresní problémy [23]. Při klasifikaci do více tříd rozděluje algoritmus AdaBoost vícetřídní problém na několik dvoutřídních [27]. Tento přístup však není zcela efektivní a v této době již existuje vylepšená verze algoritmu AdaBoost pro klasifikaci do více tříd, zvaný SAMME (Stagewise Additive Modeling using a Multi-class Exponential loss function) [28].

Algoritmus AdaBoost využívá jako weak learner rozhodovací model decision stump. Decision Stump je ve strojovém učení jednoúrovňový rozhodovací strom [29]. Je to tedy rozhodovací strom s jedním vnitřním uzlem (kořenem), který je připojen ke konečným uzlům (listům).

Schéma AdaBoostu je na obr. [24](#).



Obrázek 21: Schéma algoritmu AdaBoost, zdroj: [23]

Algoritmus Adaboost funguje tak, že z celkového setu dat D_t (celý set musí být jednotný, aby všechny instance měly stejnou šanci dostat se do prvního trénovacího subsetu) vybere subset S_t , poté natrénuje C_t (weak learner) pomocí S_t a získáme hypotézu h_t . Následně se spočítá a normalizuje chyba β a aktualizuje se distribuce dat. Aktualizace distribuce se provádí tak, že na začátku algoritmu mají všechny instance stejné váhy. Distribuční váhy těch instancí, které byly správně klasifikovány současnou hypotézou, jsou sníženy hodnotou β a váhy špatně klasifikovaných instancí jsou nezměněny. Poté, co se aktualizované váhy renormalizují, tak že D_{t+1} je vyhovující distribuce, váhy špatně klasifikovaných instancí jsou efektivně zvýšeny. Tím pádem, iterací za iterací, se AdaBoost zaměřuje na hůře klasifikovatelné instance [23]. Matematický popis algoritmu AdaBoost lze nalézt v [23].

7. Křížová validace

7.1. Úvod

Křížová validace je jeden z několika postupů odhadu, jak dobře bude model, tedy klasifikátor, který jsme natrénovali pomocí dat z trénovací množiny, pracovat na datech z testovací množiny. Je to tedy způsob získání objektivních, nezájatých odhadů predikce chyby [30]. Odhad přesnosti klasifikátorů je důležité nejen pro předpověď jejich budoucí predikční přesnosti, ale také pro výběr vyhovujícího klasifikátoru ze setu, popřípadě vhodnou kombinací klasifikátorů [31].

7.2. Druhy křížové validace

První krok křížové validace obsahuje rozdělení setu dat do komplementárních subsetů. Druhým krokem je výběr jednoho subsetu, na kterém se provede trénování algoritmu (tzv. training set). Na zbytku dat se potom provádí validace (tzv. validation set nebo testing set). Pro zvýšení objektivnosti se provádí několik opakování, kdy se v každém cyklu vybere jiný subset na trénování.

Máme několik metod křížové validace, patří mezi ně K-fold cross validation, Repeated random subsampling validation a Leave-one-out cross validation.

7.2.1. K-fold cross validation

U metody K-fold cross validation je originální set dat náhodně rozdělen do k subsetů. Z těchto k subsetů je vybrán jeden jako validation set, tedy set pro testování a zbytek $k-1$ subsetů je použito pro trénink. Proces křížové validace je potom opakován k krát (počet přeložení), kde je každý z k subsetů použit právě jednou pro testování. Výhodou této metody oproti repeated random subsampling je ta, že všechny data jsou použity jak pro trénování, tak pro testování. V praxi se většinou využívá tzv. 10-fold cross validation, tedy $k=10$ [32], ale většinou zůstává k jako proměnný parametr [33].

7.2.2. Repeated random subsampling

Metoda Repeated random subsampling, také nazývána jako Monte Carlo cross validation [34], nebo repeated evaluation set [35], je založena na náhodném rozdělování dat do subsetů, kde je velikost těchto subsetů definovaná uživatelem [36]. Toto náhodné rozdělování může probíhat několikrát pro zvýšení objektivnosti. Výhodou této metody je (oproti K-fold cross validation), že poměr mezi sety training/validation není závislý na počtu iterací (foldů). Nevýhodou této metody je, že některá data nemusí být vybrána vůbec a některá zase vícekrát.

7.2.3. Leave-one-out cross validation

Jak už jméno napovídá, Leave-one-out cross validation funguje tak, že z celého setu dat vybere jeden vzorek pro validaci a zbytek pro trénování. Tato metoda je časově i výpočetně nejnáročnější, avšak udává nejlepší výsledky.

8. Klasifikace příznaků

8.1. Úvod

Tato kapitola je věnována samotné problematice klasifikace příznaků z jednotlivých setů (viz. Kapitola 4.4). V první části bylo testováno, jak si povedou tři různé klasifikátory na rozdílných vstupních datech, tedy překrývajících se a nepřekrývajících se (Obrázek 15, Obrázek 16). Aby byla zajištěna objektivita výsledku, byly využity tři metody křížové validace, o nichž je pojednáno v kapitole č. 7. Algoritmy pro klasifikaci byly jednoduchý perceptron (viz. Kapitola č. 5.2 a literatura [21]), algoritmus Ho-Kashyap [24], [21] a algoritmus AdaBoost (viz. Kapitola č. 6.4 a literatura [21], [26]).

V další části byly potom testovány reálné příznaky pořízené pomocí texturní analýzy z fundus snímku pacientů s glaukomem (viz. Kapitola 4.4). Nejprve jsou klasifikovány vždy dva příznaky, většinou první dva a následně všechny příznaky v setu.

8.2. Chyby klasifikace

Výstupní příznaky z texturní analýzy fundus snímku byly použity jako vstupy do jednotlivých klasifikátorů. Pro test klasifikační přesnosti byly použity tři metody křížové validace (viz. Křížová validace). Trénování a testování bylo provedeno 100 krát pro metodu Repeated random sub sampling, 50 přeložení pro metodu K-fold a podle počtu příznaků pro metodu Leave one out, a poté byly vypočítány minimální, průměrné a maximální chyby. Chyby jednotlivých klasifikátorů můžeme vidět v tabulkách níže.

Nepřekrývající se data (test_data.mat, zaokrouhleno na 2 desetinná místa)

Chyby pro metodu RRSS (Repeated random sub-sampling)			
Typ klasifikátoru	Minimální chyba	Průměrná chyba	Maximální chyba
AdaBoost	2,00	2,88	8,00
Ho-Kashyap	0,00	0,94	4,00
Perceptron*	0,00	0,88	4,00

Chyby pro metodu K-Fold**			
Typ klasifikátoru	Minimální chyba	Průměrná chyba	Maximální chyba
AdaBoost	1,02	1,55	4,08
Ho-Kashyap	0,00	0,00	0,00
Perceptron*	0,00	0,00	0,00

Chyby pro metodu LOO (Leave-one-out)			
Typ klasifikátoru	Minimální chyba	Průměrná chyba	Maximální chyba
AdaBoost	1,01	1,45	4,04
Ho-Kashyap	0,00	0,00	0,00
Perceptron*	0,00	0,00	0,00

Tabulka 1: Chyby nepřekrývajících se dat (test_dat.mat)

Překrývající se data (data_12.mat, zaokrouhleno na 2 desetinná místa)

Chyby pro metodu RRSS (Repeated random sub-sampling)			
Typ klasifikátoru	Minimální chyba	Průměrná chyba	Maximální chyba
AdaBoost	8,00	21,85	28,67
Ho-Kashyap	40,67	46,56	58,67
Perceptron*	32,34	48,89	62,00

Chyby pro metodu K-Fold**			
Typ klasifikátoru	Minimální chyba	Průměrná chyba	Maximální chyba
AdaBoost	19,38	23,41	26,02
Ho-Kashyap	41,67	41,67	41,67
Perceptron*	33,33	47,67	66,67

Chyby pro metodu LOO (Leave-one-out)			
Typ klasifikátoru	Minimální chyba	Průměrná chyba	Maximální chyba
AdaBoost	18,69	23,34	29,88
Ho-Kashyap	0,00	0,00	0,00
Perceptron*	0,00	43,83	100,00

* Pro 5000 iterací

** Pro 50 přeložení

Tabulka 2: Chyby překrývajících se dat (data_12.mat)

První dva příznaky ze setu reálných příznaků od MUDr. Kuběny (zaokrouhleno na 2 desetinná místa)

Chyby pro metodu RRSS (Repeated random sub-sampling)			
Typ klasifikátoru	Minimální chyba	Průměrná chyba	Maximální chyba
AdaBoost	0,50	0,77	3,47
Ho-Kashyap	0,00	0,00	0,00
Perceptron*	0,00	0,57	2,99

Chyby pro metodu K-Fold**			
Typ klasifikátoru	Minimální chyba	Průměrná chyba	Maximální chyba
AdaBoost	0,25	0,39	1,01
Ho-Kashyap	0,00	0,00	0,00
Perceptron*	0,00	0,00	0,00

Chyby pro metodu LOO (Leave-one-out)			
Typ klasifikátoru	Minimální chyba	Průměrná chyba	Maximální chyba
AdaBoost	0,25	0,40	2,23
Ho-Kashyap	0,00	0,00	0,00
Perceptron*	0,00	0,00	0,00

Tabulka 3: Chyby prvních dvou příznaků ze setu od MUDr. Kuběny

První dva příznaky ze setu reálných příznaků databáze Erlangen (zaokrouhleno na 2 desetinná místa)

Chyby pro metodu RRSS (Repeated random sub-sampling)			
Typ klasifikátoru	Minimální chyba	Průměrná chyba	Maximální chyba
AdaBoost	1,35	1,94	5,40
Ho-Kashyap	0,00	0,00	0,00
Perceptron*	0,00	0,00	0,00

Chyby pro metodu K-Fold**			
Typ klasifikátoru	Minimální chyba	Průměrná chyba	Maximální chyba
AdaBoost	0,69	1,09	3,47
Ho-Kashyap	0,00	0,00	0,00
Perceptron*	0,00	0,00	0,00

Chyby pro metodu LOO (Leave-one-out)			
Typ klasifikátoru	Minimální chyba	Průměrná chyba	Maximální chyba
AdaBoost	0,69	1,06	3,44
Ho-Kashyap	0,00	0,00	0,00
Perceptron*	0,00	0,00	0,00

* Pro 5000 iterací

** Pro 50 přeložení

Tabulka 4: Chyby prvních dvou příznaků ze setu databáze Erlangen

Všechny příznaky ze setu reálných příznaků od MUDr. Kuběny (zaokrouhleno na 2 desetinná místa)

Chyby pro metodu RRSS (Repeated random sub-sampling)			
Typ klasifikátoru	Minimální chyba	Průměrná chyba	Maximální chyba
AdaBoost	0,00	1,37	2,97
Ho-Kashyap	0,00	0,06	2,99
Perceptron*	1,49	16,76	56,21

Chyby pro metodu K-Fold**			
Typ klasifikátoru	Minimální chyba	Průměrná chyba	Maximální chyba
AdaBoost	0,25	0,39	1,01
Ho-Kashyap	0,00	0,00	0,00
Perceptron*	0,00	25,71	57,14

Chyby pro metodu LOO (Leave-one-out)			
Typ klasifikátoru	Minimální chyba	Průměrná chyba	Maximální chyba
AdaBoost	0,75	1,73	3,23
Ho-Kashyap	0,00	0,00	0,00
Perceptron*	0,00	16,12	100,00

Tabulka 5: Chyby všech příznaků ze setu od MUDr. Kuběny

Všechny příznaky ze setu reálných příznaků databáze Erlangen (zaokrouhleno na 2 desetinná místa)

Chyby pro metodu RRSS (Repeated random sub-sampling)			
Typ klasifikátoru	Minimální chyba	Průměrná chyba	Maximální chyba
AdaBoost	0,00	0,26	1,35
Ho-Kashyap	0,00	2,15	8,33
Perceptron*	0,00	10,26	72,22

Chyby pro metodu K-Fold**			
Typ klasifikátoru	Minimální chyba	Průměrná chyba	Maximální chyba
AdaBoost	0,69	0,13	0,69
Ho-Kashyap	0,00	0,00	0,00
Perceptron*	0,00	4,00	100,00

Chyby pro metodu LOO (Leave-one-out)			
Typ klasifikátoru	Minimální chyba	Průměrná chyba	Maximální chyba
AdaBoost	0,69	0,13	0,69
Ho-Kashyap	0,00	0,00	0,00
Perceptron*	0,00	14,38	100,00

* Pro 5000 iterací

** Pro 50 přeložení

Tabulka 6: Chyby všech příznaků ze setu databáze Erlangen

8.3.Diskuse dosažených výsledků

V tabulkách uvedených výše můžeme vidět výsledky klasifikace jednotlivých klasifikátorů v závislosti na vstupních datech. Pro zajištění objektivnosti a nezájatosti výsledků, byly použity tři metody křížové validace, a to jsou Repeated random sub sampling, K-fold a Leave one out.

Klasifikátorům byly nejprve předloženy testovací data z toolboxu u [21]. Na nepřekrývajících se datech si většina klasifikátorů vedla velice dobře s malými chybami. Tato data byly dobře klasifikovatelná, což ostatně můžeme vidět i na boxplotu u Obrázek 15. U překrývajících se dat, tedy špatně klasifikovatelných (viz. boxplot u Obrázek 16), si nejlépe vedl klasifikátor AdaBoost, který měl nejmenší chybu oproti ostatním.

Následně byly klasifikátorům předkládány reálné příznaky ze sady od MUDr. Kuběny a příznaky ze sady Erlangen. Nejprve se klasifikátorům předložily první dva příznaky z jednotlivých sad a poté všechny příznaky ze sady. U klasifikace dvou příznaků si klasifikátory Perceptron a HoKashyap vedly téměř bezchybně. Klasifikátor AdaBoost vždy chyboval alespoň v jednom případě, avšak tato chyba byla zanedbatelná.

Při klasifikaci všech příznaků ze sady si nejlépe vedli klasifikátory AdaBoost a HoKashyap. Jednoduchý perceptron nebyl schopen klasifikovat vícerozměrná data a maximální chyba byla vždy vyšší než 50% (viz. Tabulka 5 a Tabulka 6).

S ohledem na charakter vstupních dat se jeví jako nejefektivnější z testovaných klasifikátorů klasifikátor AdaBoost. I špatně klasifikovatelná data dokázal klasifikovat s poloviční chybou než ostatní klasifikátory. Pro snadno klasifikovatelná data je výhodnější použít jednoduchý perceptron nebo klasifikátor HoKashyap, které dokáží tato data klasifikovat bezchybně.

9. Realizované programové funkce

Algoritmy klasifikace popsané v předchozích kapitolách byly realizovány v programovém prostředí MATLAB. Jednotlivé funkce jsou okomentovány, a tudíž je jejich obsluha jednoduchá. Popis těchto funkcí, parametry nastavení včetně návodu na použití, jsou uvedeny v této kapitole.

9.1.Funkce Klasifikator.m

Funkce Klasifikátor.m je základní funkcí volající jak funkce pro křížovou validaci, tak funkce pro klasifikaci. Na začátku funkce je potřeba nastavit, která a kolik dat se použije ke klasifikaci. Pro výběr sady dat a počtu příznaků je potřeba nechtěná data nechat v komentáři a chtěná nechat v kódu.

```
function ERR=Klasifikator(typ_validace,metoda)
```

Výstupem funkce jsou chyby pro všechny průběhy křížové validace. Vstupem je typ_validace (tím je RRSS, K_Fold a LOO, viz. Nápověď funkce Klasifikator.m) a metoda klasifikace (těmi jsou AB, HK a PC viz. Nápověď funkce Klasifikátor.m). Na základě vybraného typu validace, tato funkce volá přes switch jednotlivé křížové validátory, kterým předává načtená data. Těmito funkcemi jsou funkce RRSS, K_Fold a LOO.

9.2.Funkce RRSS.m

Funkce realizující křížovou validaci repeated random sub sampling (viz. 7.2.2).

```
function [ERR]=RRSS(x,y, metoda)
```

Výstupem této funkce jsou chyby jednotlivých průběhů křížové validace. Vstupem je x a y , což jsou příznakové vektory předané hlavní funkcí a metoda klasifikace. Data byla rozdělena na 50% pro trénování a 50% pro testování v každém průběhu. Na základě výběru metody, funkce volá přes switch jednotlivé klasifikátory, které v každém průběhu klasifikují předložená data. Funkce pro klasifikaci jsou AB, HK a PC. Stejně takto volají klasifikátory i následující funkce křížové validace.

9.3.Funkce K_Fold.m

Funkce realizující křížovou validaci K_Fold (viz. 7.2.1)

```
function [ERR]=K_fold(x,y, metoda)
```

Stejně jako předchozí funkce, výstupem jsou chyby jednotlivých průběhů a vstupem načtená data. V této funkci jsou však data rozdělena na 50 stejných částí (50 přeložení).

9.4.Funkce LOO.m

Funkce realizující křížovou validaci Leave one out (viz. 7.2.3)

```
function [ERR]=leave_one_out(x,y, metoda)
```

Výstupem funkce jsou chyby jednotlivých průběhů a vstupem načtená data. Tato funkce je početně nejjednodušší, avšak při větším počtu dat je časově náročná.

Jako klasifikátory byly použity funkce z toolboxu u [21].

Výpočet chyby klasifikace pro různá vstupní data funguje tedy takto:

1. Ve funkci Klasifikátor.m vybereme, která data a kolik z nich bude určeno pro klasifikaci.
2. Do příkazového řádku zadáme příkaz ve formátu [ERR]=Klasifikator('RRSS','HK'); podle toho, kterou metodu křížové validace a který klasifikátor chceme použít.
3. Funkce Klasifikator.m načte data a předá je vybranému křížovému validátoru.
4. Vybraný křížový validátor rozdělí data na trénovací a testovací množiny a ty předá vybranému klasifikátoru.
5. Vybraný klasifikátor data klasifikuje a výsledky předá zpět křížovému validátoru, který spočítá chybu v každém průběhu a tu pak předá základní funkci.

10. Závěr

Tato práce se zabývá inteligentní klasifikací příznaků pomocí několika klasifikačních algoritmů. Mezi ně patří klasifikace pomocí jednoduchých neuronových sítí (Perceptron), lineární klasifikátor Ho-Kashyap a klasifikátor AdaBoost, patřící mezi rozhodovací sborové systémy. Pro klasifikaci byly použity příznaky extrahované ze snímků od MUDr. Kuběny a ze sady Erlangen pomocí metod LBP (Local Binary Pattern) a GMRF (Gaussian Markov Random Field) a testovací data z toolboxu.

Pro zajištění objektivnosti a nezájatosti výsledků byly použity tři metody křížové validace. Mezi tyto metody patří metoda Repeated random subsampling cross validation, K-Fold cross validation a Leave one out cross validation. Na výběru této metody příliš nezáleží, jelikož nám všechny tři metody udávaly, až na malé odchylky, podobné výsledky.

Podle výsledků chyb u jednotlivých vstupních dat se jeví jako nejlepší pro klasifikaci stupně degradace VNV klasifikátory HoKashyap a klasifikátor AdaBoost. Jednoduchý perceptron je vhodný pro klasifikaci jednoduchých dvourozměrných dat. Při vícerozměrných datech nám udával vysoké chyby klasifikace a je tedy pro tento typ klasifikace nevhodný.

V této práci jsou příznaky klasifikovány pomocí klasifikátorů do dvou tříd s různou účinností. Klasifikaci do více tříd tyto klasifikátory buď nezvládají, nebo je jejich postup neefektivní. V budoucnu by bylo možné pro více třídou klasifikaci použít např. algoritmus SAMME.

Citace a seznam literatury

- [1] M. E. Tyler, P. J. Saine, T. J. Bennet, *Practical retinal photography and digital imaging techniques* 2003: Butterworth-Heinemann. ISBN 0-7506-7371-0
- [2] T. A. Ciulla, C. D. Regillo, A. H. Harris, *Retina and optic nerve imaging* 2003: Lippincott Williams and Wilkins, Philadelphia. ISBN 0-7817-3433-9
- [3] J. Odstrčilík, et al., *Retinal nerve fiber layer analysis via Markov random fields texture modeling*. Proc. European Sig. Proc. Conf. EUSPICO Aalborg, Denmark, 2010: p. 23-27
- [4] A. Tuulonen, et al., *Digital imaging and microtexture analysis of the nerve fibre layer*. Journal of Glaucoma, 2000. **vol. 9**: p. pp. 5-9
- [5] A. M. Oliva, D. Richards, W. Saxon, *Search for Color Dependent Nerve-Fibre-Layer Thinning in Glaucoma: A Pilot Study*, in ARVO 20072007: Fort Lauderdale, USA
- [6] J. Gazárek, J. Jan, R. Kolář. *Detection of Neural Fibre Layer in Retinal Images via Textural Analysis*. in Proc. BIOSIGNAL' 08. 2008. Brno, Czech Rep.
- [7] Y. Freund, R. E. Schapire, *Decision-theoretic generalization of on-line learning and an application to boosting*. Journal of Computer and System Sciences, 1997. **vol. 55**(no. 1): p. 119-139
- [8] Zelený Zákal [online]. Dostupný z www: <http://www.zeleny-zakal.cz/>.
- [9] P. Rozsival, et al., *Oční lékařství* 2006: Praha: Galén. 373 stran
- [10] R. Čihák, *Anatomie 3*. 2 ed 2000, Praha: Grada. 673 stran. ISBN 978-80-247-1132-4
- [11] P. M. Dodson, *Diabetic Retinopathy*. Oxford University Press 2008. ISBN 978-0-19-954496-7
- [12] H., Kolb, *The Organization of the Retina and Visual System* [online]. Dostupný z www: <http://webvision.med.utah.edu/imageswv/schem.jpeg>.
- [13] J. Flammer, *Glaukom*. 1 ed 2003, Praha: TRITON. 417 stran. ISBN 8072543512
- [14] J. Otradovec, *Klinická neurooftalmologie* 2003, Praha: Grada Publishing 504.80-247-0280-0
- [15] R. Webb, G. Hughes, F. Delori, *Cofocal scanning laser ophthalmoscopy*. Applied Optics, 1987. **vol. 26**: p. pp. 1492-1499
- [16] W. Drexler, J. G. Fujimoto, *State-of-the-art retinal optical coherence tomography*. Progress in Retinal and Eye Research 27, 2008
- [17] *Fundus Kamera CR-1-Mark II* [online]. Dostupné z www: http://www.canon-europe.com/Images/product_CR-1-markII-200_tcm13-697080.jpg.
- [18] M. Petrou, *Dealing with Texture* 2006, London: Wiley. ISBN 9780470026281
- [19] Li, S. Z., *Markov Random Field Modeling in Image Analysis* 2009. ISBN 10:1848002785
- [20] T., Kuběna, *Oční ordinace MUDr. Tomáš Kuběna, s.r.o.* 2011-11-7 Textura VNV [online] Dostupné z www: <http://www.kubena.cz/photos/lekar-papila-39.jpg>.
- [21] R. O. Duda, P. E Hart, D. G Stork, *Pattern classification*. 2 ed 2000: Wiley. 738 stran. ISBN 0471056693
- [22] J. Kozumplík, I. Provazník, *Umělá inteligence v medicíně* 2007, Brno: FEKT VUT
- [23] R. Polikar, *Ensemble Based Systems in Decision Making*. IEEE Circuits and Systems Magazine, 2006. **vol. 6**(no. 3): p. pp. 21-45

- [24] Y. C. Ho, R. L. Kashyap, *An Algorithm for linear inequalities and its applications*. IEEE Transactions on Electronic Computers, 1965. **EC-14**: p. 683-688
- [25] B. Efron, R. Tibshirani, *An Introduction to the Bootstrap*1993: Boca Raton, FL: Chapman & Hall/CRC.ISBN 0-412-04231-2
- [26] R. E. Schapire, *The strength of weak learnability*. Machine Learning, 1990. **Vol. 5**(no. 2): p. 197-227
- [27] E. Allwein, R. E. Schapire, and Y. Singer, *Reducing Multiclass to Binary: A Unifying Approach for Margin Classifiers*. Journal of Machine Learning Research, 2000. **vol. 1**: p. pp. 113-141
- [28] J. Zhu, H. Zou, S. Rosset and T. Hastie, *Multi-class AdaBoost*. Distribution 1001, 2009: p. pp. 0-20
- [29] W. Iba, P. Langley, *Induction of One-Level Decision Trees*. Proceedings of the Ninth International Conference on Machine Learning, Aberdeen, Scotland, 1-3 July 1992, 1992: p. 233-240
- [30] B. Efron, G. Gong, *A Leisurely Look at the Bootstrap, the Jackknife, and Cross-Validation*, 1983
- [31] D. H. Wolpert, *Stacked generalization*. Neural Networks 51992
- [32] G. J. McLachlan, Kim-Anh Do, C. Ambroise, *Analyzing microarray gene expression data*2004: Wiley-Interscience; 1 edition (August 4, 2004). 368 stran.978-0471226161
- [33] S. Geisser, *Predictive Inference*1993: New York: Chapman and Hall. 264.ISBN 0-412-03471-9
- [34] R. R. Picard, R. D. Cook, *Cross-validation of regression models*. J. Am. Stat. Assoc. Vol. 79. 1984
- [35] M. Forina, G. Drava, R. Boggia, S. Lanteri, P. Conti, *Validation procedures in near-infrared spectrometry*1994: Anal. Chim. Acta. 295
- [36] M. Baroni, S. Clementi, G. Cruciani, G. Constantino and D. Riganelli, *Predictive ability of regression models*. J. Chemometrics, 1992. **Vol. 6**(Issue 6): p. 347-356.DOI: 10.1002/cem.1180060605

Seznam tabulek:

Tabulka 1: Chyby nepřekrývajících se dat (test_dat.mat).....	35
Tabulka 2: Chyby překrývajících se dat (data_12.mat)	35
Tabulka 3: Chyby prvních dvou příznaků ze setu od MUDr. Kuběny	36
Tabulka 4: Chyby prvních dvou příznaků ze setu databáze Erlangen	36
Tabulka 5: Chyby všech příznaků ze setu od MUDr. Kuběny	37
Tabulka 6: Chyby všech příznaků ze setu databáze Erlangen	37

Seznam obrázků:

Obrázek 1: Anatomie oka, zdroj: [8]	9
Obrázek 2: Rohovka, zdroj: [8].....	9
Obrázek 3: Komorový úhel a cirkulace nitrooční tekutiny, zdroj: [8].....	10
Obrázek 4: Řasnaté tělísko, zdroj: [8].....	11
Obrázek 5: Sítnice, cévnatka a bělima, zdroj: [8]	12
Obrázek 6: Schematický řez retinální tkání, zdroj: [12]	14
Obrázek 7: Fundus snímek zdravého oka	17
Obrázek 8: Fundus snímek oka postiženého glaukomem. Oblast postižená glaukomem je vyznačená šipkami	17
Obrázek 9: Fundus kamera Canon CR-1, zdroj: [17]	19
Obrázek 10: Červená složka fundus snímku oka postiženého glaukomem	21
Obrázek 11: Zelená složka fundus snímku oka postiženého glaukomem	21
Obrázek 12: Modrá složka fundus snímku oka postiženého glaukomem.....	21
Obrázek 13: Průměr zelené a modré složky fundus snímku oka postiženého glaukomem	22
Obrázek 14: Vrstva nervových vláken. Modrá šipka ukazuje plochu, která obsahuje nervová vlákna. Červená šipka zobrazuje místo bez nervových vláken, zdroj: [20]	22
Obrázek 15: Nepřekrývající se data z toolboxu (test_data.mat). Zobrazení v dvourozměrném příznakovém prostoru a rozložení pomocí boxplotu.....	23
Obrázek 16: Překrývající se data z toolboxu (data_12.mat). Zobrazení v dvourozměrném příznakovém prostoru a zobrazení pomocí boxplotu.	24
Obrázek 17: Příznaky získané metodou LBP. Zobrazení v dvourozměrném příznakovém prostoru a zobrazení pomocí boxplotu.	24
Obrázek 18: Příznaky získané metodou GMRF. Zobrazení v dvourozměrném příznakovém prostoru a pomocí boxplotu.....	25
Obrázek 21: Funkce perceptronu. Modré tečky představují binární jedničku, tedy „zdravé oko“, bílé potom binární nulu, tedy „nemocné oko“	27
Obrázek 22: Schéma perceptronu	28
Obrázek 25: Schéma algoritmu AdaBoost, zdroj: [23].....	31

Seznam zkratk:

PON	Papila optického nervu
VNV	Vrstva nervových vláken
OCT	Optická koherentní tomografie
CNS	Centrální nervový systém
OD	Optický disk
NT	Nitrooční tlak
HRT	Heidelberský retinální tomograf
CCD	Charge-coupled device (zařízení s vázanými náboji)
LBP	Local Binnary Patterns
GMRF	Gaussian Markov Random Field
SAMME	Stagewise Additive Modeling using a Multi-Class Exponential loss function