


VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



**FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ
ÚSTAV TELEKOMUNIKACÍ**

**FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF TELECOMMUNICATIONS**

DETEKCE CHARAKTERISTICKÝCH BODŮ OBLIČEJE V TELERENTGENOVÉM SNÍMKU

DETECTION OF CHARACTERISTIC FACIAL FEATURES IN TELE-X-RAY IMAGE

DIPLOMOVÁ PRÁCE
MASTER'S THESIS


AUTOR PRÁCE
AUTHOR

Bc. MARTIN HRUŠKA

VEDOUCÍ PRÁCE
SUPERVISOR

doc. Ing. JIRÍ MIŠUREC, CSc.

BRNO 2011



VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

Ústav telekomunikací

Diplomová práce

magisterský navazující studijní obor
Telekomunikační a informační technika

Student: Bc. Martin Hruška
Ročník: 2

ID: 73023
Akademický rok: 2010/2011

NÁZEV TÉMATU:

Detekce charakteristických bodů obličeje v telerentgenovém snímku

POKYNY PRO VYPRACOVÁNÍ:

Proveďte rozbor telerentgenových snímků a rozeberte možnosti automatizovaného určení charakteristických bodů ve snímků, které jsou potřebné pro kefalometrické analýzy. Navrhněte algoritmovatelnou metodu pro stanovení těchto bodů. V práci uvažujte s jednou vhodně vybranou kefalometrickou analýzou, na které proveďte experimentální ověření navržené metody.

DOPORUČENÁ LITERATURA:

[1] ŘÍHA, K.: Pokročilé techniky zpracování obrazu. Elektronické texty VUT, Ústav telekomunikací FEKT VUT v Brně, 2007.

[2] GONZALEZ R. C., WOODS R. E.: Digital Image Processing, Prentice Hall, New Jersey, 2002.

Termín zadání: 7.2.2011

Termín odevzdání: 26.5.2011

Vedoucí práce: doc. Ing. Jirí Mišurec, CSc.

prof. Ing. Kamil Vrba, CSc.

Předseda oborové rady

UPOZORNĚNÍ:

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

Abstrakt

Popis telerentgenových snímků a charakteristických bodů na lebce pro kefalometrické analýzy. Teoretický rozbor digitálního obrazu a úpravy snímku před samotnou detekcí. Výběr možných metod pro stanovení charakteristických bodů na obličeji. Experimentální ověření hranových detektorů, Hu momentů s neuronovou sítí a Haarových vlnek s detektorem Viola-Jones.

Abstract

Description cephalometric images and the characteristic points on the skull for cephalometric analysis. Theoretical analysis of digital image editing and image before the actual detection. The range of possible methods for determining the characteristic points on the face. Experimental verification of edge detectors, Hu moments with neural networks and Haar wavelets with Viola-Jones detector.

Klíčová slova

Telerentgen, lebka, úpravy obrazu, detekce hran, Hu momenty, Haarovy vlnky, Adaboost, detektor Viola-Jones.

Key words

Cephalometric, skull, image editing, edge detection, Hu moments, Haar wavelets, Adaboost, detektor Viola-Jones.

Bibliografická citace

HRUŠKA, M. *Detekce charakteristických bodů obličeje v telerentgenovém snímku*. Brno: FEKT VUT v Brně, 2011. 50 stran. Vedoucí práce doc. Ing. Jiří Mišurec, CSc.

Prohlášení

Prohlašuji, že svou diplomovou práci na téma DETEKCE CHARAKTERISTICKÝCH BODŮ OBLIČEJE V TELERENTGENOVÉM SNÍMKU jsem vypracoval samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové 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

.....

podpis autora

Poděkování

Děkuji vedoucímu diplomové práce doc. Ing. Jiřímu Mišurcovi, CSc., za velmi užitečnou metodickou pomoc a cenné rady při zpracování diplomové práce. Dále Ing. Jiřímu Přinosilovi, Ph.D. za pomoc při zpracování diplomové práce.

V Brně dne

.....
(podpis autora)

Obsah

1 Úvod	6
1.1 Zařazení	6
1.2 Rozbor zadání	6
1.3 Diplomová práce	6
2 Biologický základ	7
2.1 Lebka	7
2.2 Zuby	9
2.3 Kraniometrie, kefalometrie	9
2.4 Kefalometrický snímek	10
2.5 Rentgenologie	13
2.6 Digitální RTG snímek	13
3 Digitální obraz	14
3.1 Obrazový bod	14
3.2 Snímání obrazu	14
3.3 Rozlišovací schopnost obrazu	15
3.4 Digitalizace	15
4 Popis objektů	17
4.1 Příprava pro popis	17
4.2 Příznakový vektor	17
4.3 Dělení příznaků	18
4.4 Geometrické momenty a momentové invarianty, Hu momenty	19
4.5 Haarovy vlnky	20
5 Klasifikátory	23
5.1 Lineární klasifikátor	24
5.2 Bayesův klasifikátor	25
5.3 Markovovy modely	26
5.4 Skryté Markovovy modely	27
5.5 AdaBoost	27
5.6 Neuronové sítě	28
5.6.1 Model neuronu	29
5.6.2 Proces učení neuronové sítě	30
5.6.3 Hopfieldova síť	31
6 Úpravy obrazu	33
6.1 Načtení snímku	33
6.2 Změny barev a velikosti	34
6.3 Ostření a redukce šumu	37
7 Detekce objektů	41
7.1 Detekce hran	41
7.2 Segmentace	43
7.3 Hu momenty	44
7.4 Detektor Viola-Jones	44
7.5 Integrální obraz	44
7.6 Detekce objektů	45
8 Závěr a další postup	47
8.1 Závěr	47
8.2 Další postup	47
9 Seznam literatury a použitých zdrojů	48
10 Seznam příloh	49

1 Úvod

1.1 Zařazení

Práce doplňuje stávající neautomatizované metody pro zpracování dat z telorentgenových snímků. Současné prostředky nepodporují úplně automatickou detekci charakteristických bodů ze snímku, která by pro uživatele jednoznačně a jednoduše provedla kefalometrickou analýzu. Práce v ortodoncii momentálně probíhá dvěma různými metodami.

Jedna metoda probíhá zcela manuálně výpočtem a měřením na telorentgenovém snímku. Ortodontista si pořídí telorentgenový snímek a vyznačí na snímku body, které potřebuje. Vyznačí si tkáň, nakreslí si osy a změří již konkrétní vzdálenosti. Tyto vzdálenosti porovnává se standardy a s rozdílem hodnot měření pak pracuje.

Druhá metoda (kefalo) je již poloautomatizovaná. Systém předpokládá znalost uživatele určit body na snímku. Ortodontista pak má na jedné straně model lebky a na druhé straně snímek, na který virtuálně ukazuje myš. Uživatel postupuje podle příkazů a vyhledává body. Systém následně sám vypočte vzdálenosti a vyhodnotí výsledky.

1.2 Rozbor zadání

Telorentgenové snímky lebky jsou jediné podklady k této práci. Na snímcích se mají vyhledat body pro kefalometrické analýzy. Pro technika je potřeba vytvořit jasnou a srozumitelnou představu, kde se body nalézají a jak se body nazývají. Snímky mají různou kvalitu, je potřeba snímky po převodu do počítače upravit. S upravenými snímky se provedou operace vedoucí k nalezení bodů. Rozeberou se metody vyhledávání v obrazu. Navrhne se algoritmizovatelná metoda pro detekci bodů a provede se ověření. Bude provedeno rozdělení na segmenty, vytvoření příznaků a klasifikace příznaků obrazu.

1.3 Diplomová práce

Celý projekt je rozčleněn do několika kapitol. V druhé kapitole je popsána lebka a body pro zkoumání. Třetí kapitola popisuje digitální obraz a práci s ním. Čtvrtá kapitola rozebírá příznaky použitelné pro klasifikaci. Klasifikátory používané při rozpoznávání obrazu jsou v páté kapitole. Šestá a sedmá kapitola již popisuje práci se snímkem a samotnou detekci. Následující kapitoly jsou věnovány závěru a citacím.

2 Biologický základ

V této kapitole je popis lebky a rentgenologie. Text obsahuje velké množství pojmů a cizích názvů. Tento styl je klíčový pro pochopení, rozmístění bodů, hledání bodů a jednodušší orientaci v problematice. Jsou uvedeny všechny kosti, které jsou vidět na snímku. Existuje spousta kefalometrických metod a každá metoda obsahuje jiný soubor bodů pro analýzu. Na Obr.1. a Obr.2. jsou vyznačeny nejčastěji používané body. V části rentgenologie je uveden popis rentgenu, podmínky pro zachycení co nejkvalitnějšího snímku a postup správného vyvolávání. Jedná se o nejdůležitější část této kapitoly. Kvalitní snímek je zásadní předpoklad pro zvýšení úspěšnosti vyhledávání bodů. Informace pro tuto kapitolu jsem načerpal z pramenů [5], [6], [7], [8] a [9].

2.1 Lebka

Na lebce rozlišujeme část obličejovou (splanchnocranium), která obklopuje začátek trávicí trubice a část mozkovou (neurocranium) chránící především mozek [6].

Obličejová část je tvořena kostmi párovými a kostmi nepárovými.

Párové kosti jsou:

- Kost patrová (os palatinum) – její lamela doplňuje zadní část tvrdého patra, má tvar písmene L.
- Kost lící (os zygomaticum) – spojením výběžku lící kosti s kostí spánkovou (os temporale) vzniká jáhmový oblouk, který dává tvar obličejí, tvoří část okraje očnice.
- Horní čelist (maxilla) – obsahuje zubní lůžka, je složena z těla a čtyř výběžků. V horní čelisti je uložena největší nosní dutina (sinus maxilaris).

Nepárová kost je:

- Dolní čelist (mandibula) – je složena ze dvou ramen a těla. Dolní čelist také obsahuje zubní lůžka, k lebce je připojena kloubně.

Dále do obličejové části řadíme také:

- Sluchové kůstky (ossicula auditu) – kladívko, kovádlínka, třmínek. Nacházejí se ve středoušní dutině.
- Jazyk (os hyoideum) – tvořena tělem a rohy, má tvar písmene U, tvoří závěs pro hrtan.

Mozková část má důležitou funkci. Chrání mozek a smyslové orgány před poškozením. Je jeho pevným obalem. Mozková část (neurocranium) je stejně jako obličejová část (splanchnocranium) tvořena z párových a nepárových kostí.

Nepárové kosti jsou:

- Kost týlní (*os occipitale*) – obsahuje týlní otvor (*foramen magnum*). Kost týlní se kloubí s prvním krčným obratlem (*altas*).
- Kost klínová (*os sphenoidale*) – je složena z těla, malých křídel, velkých křídel a křídlových výběžků. Tělo kosti klínové vytváří tzv. turecké sedlo (*sella turcica*). V něm je umístěn podvěsek mozkový (*hypophysis*).
- Kost čichová (*os ethmoidale*) – je tvořena třemi částmi z nichž jedna, ploténka svislá (*lamina perpendicularis*), tvoří část nosní přepážky.
- Kost čelní (*os frontale*) – tvoří horní část očnic a je kostěným podkladem pro čelo. Nachází se v ní párová dutina čelní kosti (*sinus frontalis*).
- Kost slzní (*os lacrimale*) – kůstka tvořící vnitřní stěnu očnic.
- Kost radličná (*vomer*) – plochá kost tvořící nosní přepážku.

Z kostí párových jsou to:

- Kost spánková (*os temporale*) – složitá kost, ve které je uloženo střední ucho.
- Kost temenní (*os parietale*) – je čtverhranného tvaru, spojuje se s ostatními kostmi hlavními lebečními švy.
- Kost nosní (*os nasale*) – tvar nosních kostí určuje tvar hřbetu nosu. Jsou připojeny k čelní kosti.

Lebka obsahuje důležité prostory. V mozkové části to jsou:

- Dutina lebeční (*cavitas cranii*) – dutina v níž je uložen mozek.
- Klenba lebeční (*calvaria/calva*) – chrání lebeční dutinu.
- Spodina lebeční (*basis cranii*) – spodní část dutiny lebeční.

V obličejové části jsou to:

- Očnice (*orbity*) – dutiny pro oční bulvy.
- Kostěná nosní dutina (*Cavitas nasalis ossea*).
- Jámy spánkové (*fossae temporales*).
- *Fossae infratemporales* – dutiny do nichž pokračují jámy spánkové.
- *Fossae pterigopalatinae* – prostory do nichž pokračují *fossae infratemporales*.

Lebeční spoje:

- *Kraniovertebrální* – dva spoje. Spoj mezi lebkou a prvním krčným obratlem (*atlas*) a spoj mezi prvními dvěma krčnými obratli (*atlas* a *čepovec*).
- *Synchrodózy* (*synchondroses cranii*) – u dospělých jedinců se nacházejí na spodině lební.
- *Syndesmozy* (*syndesmoses cranii*) – jsou švy a vazy. Z vazů je to například *ligament pterigospinosum*. Švy jsou nepohyblivá spojení kostí. Je jimi spojena většina kostí lebky. Aby však při porodu nedošlo k fraktuře lebky, tvoří švy hlavičky dítěte tenká vrstva vaziva mezi kostmi, která růstem jedince vymizí (*osifikace = zkostnatění*).

Podle toho jak k sobě sousedící kosti přiléhají se rozdělují švy na 3 druhy:

- Šev pilovitý (*sutura serrata*) – okraje kostí tvoří zoubky, které do sebe přesně zapadají.
- Šev šupinovitý (*sutura squamosa*) – spojení kostí je jakoby šikmo seříznuté.
- Šev hladký (*futura plana*) – kostní okraje jsou úplně rovné.

Na lebce se nacházejí tyto švy:

- Korunový (sutura coronalis) – spojuje kost čelní a kost temenní.
- Šupinový (sutura squamosa) – spojuje temenní a spánkovou kost.
- Šípový (sutura sagittalis) – spojuje obě temenní kosti.
- Lambdový (sutura labdoidea) – spojuje temenní kost s týlní kostí.

2.2 Zuby

Zuby se nacházejí v dutině ústní a jsou vklíněny do horní a dolní čelisti [7]. Zubní vzorec stálého chrupu člověka je 2-1-2-3/2-1-2-3. Označuje počet řezáků (dentes incisivi), špičáků (dentes canini), třenových zubů (dentes praemolare) a stoliček (dentes molares) vždy v jedné polovině horní a dolní čelisti. Celkem má tedy úplný chrup dospělého člověka 32 zubů. Oproti tomu chrup mléčný obsahuje 20 zubů a zubní vzorec je 2-1-0-2/2-1-0-2.

2.3 Kranioetrie, kefalometrie

V kranioetrii provádíme měření přímo na lebce [5], [8]. Zjistíme tak její tvar a velikost. Toto měření má teoretický význam pro studium vývoje člověka. Praktický význam má pro posouzení řady anomálií lebky.

Kefalometrie je podobný typ měření jako kranioetrie. V kefalometrii se provádí měření na hlavě (lebce pokryté měkkými tkáněmi). K proměrování slouží body umístěné na kůži nebo na kosti.

Ortodoncie je obor stomatologie zabývající se příčinou, určením, léčbou a prevencí vzniku anomálií čelisti, chrupu a zubních oblouků. Ke správnému určení diagnózy a následné léčby se používá řada vyšetřovacích metod. Jsou to například anamnéza, aspekce, palpáce, měření chrupu, fotografie, rentgenové vyšetření.

Na kefalometrickém rentgenovém snímku lze spolehlivě proměřovat čelist, polohu řezáků a špičáků, struktury vzhledem k měkkým tkáním obličeje. Spolehlivost takové projekce je dána nejen fixací hlavy pacienta pomocí kefalostatu, ale také uchycením rentgenové lampy, stejnou polohou kazety s rentgenovým filtrem k hlavě pacienta a stejnou vzdáleností rentgenové lampy a hlavy pacienta. Pokud je rentgenový snímek kvalitní, jsou na něm zřetelné kostní tkáně, zuby včetně kořenů i měkké tkáně obličeje (čelo, nos, rty, brada). Vyhodnocení kefalometrického snímku se provádí pomocí přesně daných bodů, linií a úhlů.


2.4 Kefalometrický snímek

Nejvíce používanými body a liniemi v kefalometrii jsou:


- S Sella - střed tureckého sedla
- N Nasion - bod nacházející se v průsečíku švu spojujícího kost nosní a kost čelní s mediánní rovinou
- A Bod A - nazad nejvíce položený bod na profilové linii horního alveolárního výběžku
- B Bod B - nazad nejvíce položený bod na profilové linii dolního alveolárního výběžku
- Po Pogonion - bod který se nachází nejvíce vepředu na srůstu dolní čelisti
- Go Gonion - bod nacházející se na dolním okraji úhlu dolní čelisti
- Me Menton - nejnižší položený bod na srůstu dolní čelisti
- ML Mandibularni linie - protíná nejnižší položený bod na srůstu dolní čelisti a gonion
- FOL Funkční okluzální linie - probíhá místem, kde se dotýká nejvíce hrbolků horních a dolních třenových zubů a stoliček

Mimo těchto bodů se mohou využít i některé kranioметриcké body, kterými jsou například:

- Go Gonion - bod nacházející se na dolním okraji úhlu dolní čelisti
- G Glabella - bod na spodní straně čelní kosti (os frontale) v mediánní rovině mezi nadobočními oblouky
- Op Opisthocranium - nazad nejvíce vyčnívající místo na lebce v mediánní rovině, nacházející se na šupině týlní kosti
- Po Porion - bod na horním okraji zevního zvukovodu
- B Bregma - střeť šípového a věččitého švu na vrcholu lebky
- Eu Euryon - nejzevnější bod na kosti temenní, někdy na kosti spánkové, od mediánní roviny při pohledu na lebku zepředu
- Pt Pterion - bod kde se stýká korunový šev, šev mezi čelní a klínovou kostí a šev mezi kostí klínovou
- Zy Zygion - bod ležící nejlaterálněji na oblouku jařmové kosti
- L Lambda - místo, kde se protíná lambdový a šípový šev



Obr.1: Lebka zepředu.



Obr.2: Lebka z boku.

2.5 Rentgenologie

Dvěma základními metodami používanými v rentgenologii jsou skiaskopie – prosvěcování na prohlížecí štít, tzn. permanentní rentgenování a skiografie- zhotovení rentgenových snímků. Pro zhotovení rentgenového snímku se používají kazety, které jsou úměrné rentgenovým filmům. Rentgenové filmy jsou v rozměrech 13x18cm, 18x24cm, 24x30cm, 30x40cm. Při manuálním vyvolávání rentgenových snímků se musí dodržovat přesný postup, aby byla kvalita snímku co nejvyšší.

2.6 Digitální RTG snímek

Existují přístroje, které přímo exportují snímek v digitální podobě z rentgenu do počítače. Tato možnost je mnohem lepší pro detekci bodů, vnáší do obrazu pouze nepatrné množství aditivního šumu. Digitální systémy se v České republice stále rozšiřují a ulehčují práci při zhotovení snímku. Digitální snímek je nejlepší variantou pro použití při detekci bodů.

3 Digitální obraz

Podkladem pro tuto práci je telereografický snímek. Snímek se převede do digitální podoby. Jedná se o digitální obraz reprezentovaný sérií bodů – pixelů (angl. pixel = element) popsanými čísly. Tato i další kapitoly zavádějí pojmy a matematické nástroje, které jsou používány v analýze obrazu. Informace pro tuto kapitolu jsem načerpal z pramenů [1], [2], [3], [4].

3.1 Obrazový bod

Každý pixel obrazu je popsán právě tolika souřadnicemi, v jaké dimenzi se pohybuje. Obraz 2D je výsledkem perspektivní projekce intenzity 3D scény. Matematický model obrazu může být spojitá funkce. Práce se soustředí na 2D, tedy k popisu bodu je zapotřebí vždy dvou souřadnic. Funkce $f(x,y)$ je obvykle nazývána obrazová funkce. Celkově obraz obsahuje $x \times y$ bodů. Body jsou seřazeny do matice. Hodnoty x nabývají hodnot $1,2,3, \dots x$ a hodnoty y nabývají hodnot $1,2,3, \dots y$. Orientace je stejná, jako při kartézském souřadnicovém systému, kdy hodnoty x tvoří řádky a hodnoty y tvoří sloupce. K popisu bodu ve zpracování monochromatického obrazu stačí jedna informace prostřednictvím stupně šedi. Stupně šedi odpovídají jasů v obrazových bodech.

Barva je schopnost objektů odrážet elektromagnetické vlnění různých vlnových délek. Při zpracování obrazu se nepracuje se všemi vlnovými délkami. Rozsah se dělí na pásma, které se pak snímají dílčími senzory. Například u barevné televize se rozsah dělí na tři složky: červenou, zelenou a modrou. Mísením složek vzniká barevný obraz. S barevným multispektrálním obrazem pracovat nebudeme, ačkoliv v další kapitole se bude hovořit o barevném snímku, který je nutné převést do jeho monochromatické interpretace.

3.2 Snímání obrazu

Celkový proces jak získat informace, se kterými se dá dále pracovat vypadá obecně následovně. Na začátku se vybírá vhodný obraz nasnímaný zařízením. Signál se navzorkuje a kvantuje. Data se dále zpracovávají, dochází k zvýraznění obrazu, odstraňování šumu. Obraz je segmentován, aby se oddělila scéna od pozadí. Mezi finální kroky patří metody, které předcházejí výsledku (rozpoznávání, klasifikace, měření, komprese).

Aby byl obraz kvalitní musí se při snímání obrazu dodržovat určitá pravidla. Jas pixelu je závislý na několika faktorech: odrazivosti materiálu, struktuře materiálu, osvětlení scény, povrchu materiálu, zdroji světla. Zdrojů světla je celá řada (slunce, žárovka, zářivka, laser, LED dioda), na každý z nich je potřeba brát ohled. Jak na jejich orientaci, tak na vlnovou délku. Senzor, většinou kamera nebo fotoaparát, má před snímači předsazen objektiv. Objektiv zaostřuje na daný objekt, dokáže přiblížit, clona na objektivu filtruje světlo dopadající na senzory. Umístění a počet senzorů závisí na daném zařízení.

Znatelným zvýšením kvality je odstranění šumu. Rozeznávají se tyto typy:

- Bílý šum: vzniká při digitalizaci nebo přenosu, patří mezi nejhorší degradace obrazu. Má zastoupeny ve výkonovém spektru všechny kmitočty.
- Gaussův šum: mění hodnoty všech bodů na snímku, tzv. závislý šum.
- Aditivní šum: vzniká při přenosu nebo snímání obrazu.
- Šum „pepř a sůl“: šum vyvolaný prostředím, vzniká u binárních obrazů, s více jasovými úrovněmi.
- Neo kvantizační šum: vzniká, při nedostatečném vzorkování. Přes obraz se objevují vodorovné pruhy.

3.3 Rozlišovací schopnost obrazu

Kvalita obrazu je dána v poměru prostorové, časové, spektrální a radiometrické rozlišovací schopnosti. Jedná se o schopnost rozlišit dva body. Každý snímač má tuto vlastnost.

Prostorová rozlišovací schopnost – rozlišení. Určuje rozlišovací schopnost obrazu, skutečnou velikost pixelu. Jestli se bude zvyšovat skutečná velikost pixelů, bude se snižovat prostorové rozlišení. Rozlišení je dáno blízkostí vzorků obrazu v obrazové rovině.

Časová rozlišovací schopnost. Obraz získaný z různého období na stejném místě je jiný, než dříve. Jedná se o schopnost, jak často snímací zařízení podává snímky.

Spektrální rozlišovací schopnost definuje šířku intervalu vlnových délek elektromagnetického spektra. Výběr šířky pásem se vybírá tak, aby bylo možno co nejlépe pořídit identifikaci objektu.


Radiometrická rozlišovací schopnost udává počet rozlišitelných úrovní signálu (úrovně šedi). Určuje se silou signálu senzoru.

3.4 Digitalizace


Matice je nejvhodnější datovou strukturou použitelnou pro zpracování v počítači. Matice používá vhodné diskrétní datové struktury. Digitalizace je proces, který zaznamenává do řádků a sloupců obrazové informace. Informace získává ze snímačů, jako je například kamera, skener, jednoduše systému senzorů zachytávající obrazové informace. Pásmo je rozděleno do intervalů. Čím více řádků a sloupců obsahuje výsledná matice a čím větší je kvantizace, tím se tato interpretace více blíží originálu. Jde tedy o kvalitnější, hodnotnější a lépe rozpoznatelnější obrazy.

Systém odebrání vzorků závisí na hustotě digitálního vzorkování, na detailech obsažených v obrázku a geometrickém uspořádání odběru vzorků, tedy kvantování. Hodnoty obrazové funkce se převádějí do digitální formy. Digitalizace bere ohled na souřadnice bodů. Kvantizace nahrazuje spojitý signál diskrétní množinou kvantizačních hladin. Výsledkem jsou odstíny šedi, šedotónový obraz.


Základním předpokladem pro správné vzorkování je dodržet vzorkovací teorém. Shannonova věta říká, že vzorkovací frekvence musí být alespoň dvakrát větší než je nejvyšší frekvence v celém vzorkovaném signálu. Při zpracování obrazu musí být interval vzorkování menší nebo roven polovině rozměru nejmenších detailů v obraze. Když se zpracovává obraz, doporučuje se vzorkovat alespoň pětkrát častěji než říká Shannonova věta.



A



B




C

Obr.3.: Plošné uspořádání A, čtvercové, B, trojúhelníkové, C, hexagonální.

Po vzorkování obrazu se musí vybrat prostorové uspořádání bodů. Mezi možnosti, jak uspořádat body patří trojúhelníková, čtvercová nebo hexagonální mřížka. I přes problémy se vzdálenostmi a souvislostmi oblastí se nejvíce používá čtvercová mřížka.

4 Popis objektů

Příznaky obrazu slouží pro klasifikaci objektů. Příznaky se získají ze segmentů upraveného obrazu. Vhodný výběr příznaků určuje detekovatelnost hledaných objektů. Informace pro tuto kapitolu jsem načerpal z pramenů [3], [10].



Obr.4.: Řetězec detekce objektů.

Příznaky musí přesně vystihnout charakteristické rysy objektů. Mezi základní požadavky kladené na příznaky patří:

- Invariantnost – příznaky invariantní vůči změně jasu, kontrastu, translaci, rotaci a změně měřítka.
- Spolehlivost – podobnost příznaků pro tentýž objekt.
- Diskriminalita – různé hodnoty příznaků pro různé objekty.
- Efektivita výpočtu – jednoznačné výsledky při detekování.
- Časová invariantnost – příznaky invariantní vůči času při zpracování dynamických obrazů.

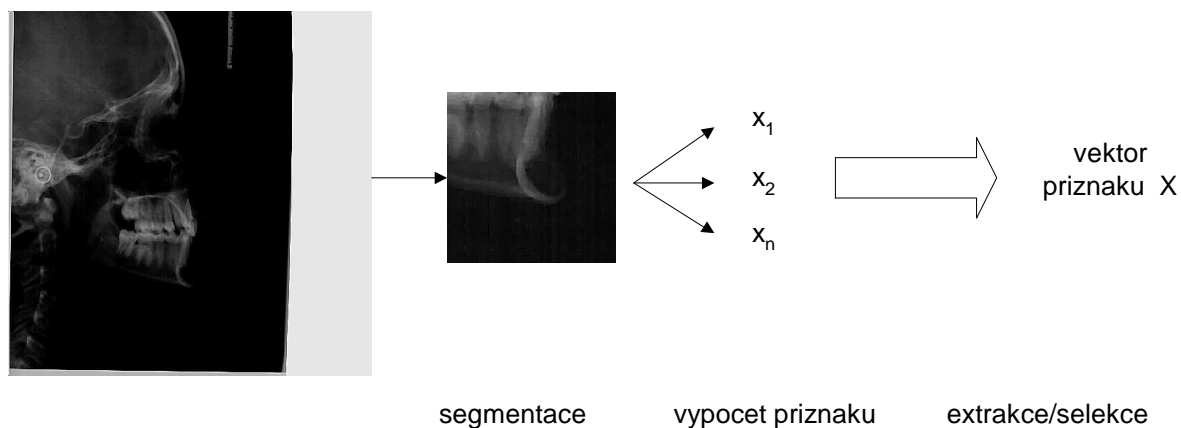
Nejdůležitějším rozhodnutím při rozpoznávání obrazu je správný výběr příznaků. Volba příznaků, které evidentně mohou fungovat na daném obrazu nemusí vykazovat po kvalifikaci vysokou pravděpodobnost rozpoznání objektu. Mnoho předmětů reálného světa nelze matematicky popsat a formálně všeobecně a přesně tak definovat předmět.

4.1 Příprava pro popis

Nasnímaný obraz se segmentuje, rozděluje se na menší části. Většinou je vhodné, aby se segmenty překrývaly. Nesegmentovaný binární obraz se prahuje, aby se oddělil objekt od pozadí. Používají se také hranové detektory k lepšímu určení hran objektů. (více v předchozí kapitole)

4.2 Příznakový vektor

Po segmentaci se aplikuje metoda, která je schopna ze segmentů obrazu vytvořit matematický soubor číselných charakteristik nebo soubor symbolů definované abecedy. Z vypočítaných příznaků je sestaven vektor příznaků X . Vektor většinou obsahuje vysoký počet odlišných příznaků bez ohledu na jejich rozlišovací schopnost.



Obr.5.: Výpočet příznakového vektoru.

Při výpočtu příznaků se většinou vytvoří obrovské množství příznaků. Aby se mohla množina příznaků redukovat, oddělí se množství příznaků:

- Extrakce příznaků – původní příznakový vektor se transformuje na vektor s nižším počtem příznaků s odlišným významem od původních členů. Známa je Karhunen-Loevova transformace (KLT).
- Selekcce příznaků – nový příznakový vektor se liší od původního nižším počtem příznaků a obsahuje prvky pouze s vyšší diskriminací. Význam nových příznaků se shoduje s původními příznaky, ale objekt ztrácí informace.

Každý člen příznakového vektoru X tvoří jednu část příznakového prostoru. Příznakový prostor je grafické vyjádření hodnot příznakových dat.

4.3 Dělení příznaků

Příznaky lze rozdělit podle mnoha kritérií:

- Doména popisované vlastnosti objektu může mít deskriptory:
 - Fotometrické – deskriptory odrážejí optické vlastnosti objektu (průměrná jasová úroveň, diference průměrné jasové úrovně objektu od průměrné jasové úrovně blízkého okolí, rozptyl jasových hodnot objektu).
 - Radiometrické – deskriptory odrážejí geometrické vlastnosti objektu (velikost, délka hlavní a vedlejší osy, obvod).
- Oblast výpočtu může mít deskriptory:
 - Založené na regionech – deskriptory vyžadují znalost jasových hodnot pixelů objektu.
 - Založené na hranicích – deskriptory vyžadují znalost hranice objektu určenou implicitně indexovaným seznamem pixelů objektu, nebo explicitně funkčním předpisem.
- Oblast popisu může mít deskriptory:
 - Globální deskriptory obrazu – je to lineární integrální transformace (fourierova transformace, diskrétní kosínová transformace, vlnková transformace). Objekt postrádá individuální znaky.
 - Globální deskriptory objektu – přiřazení jednoho příznaku celému objektu. Deskriptory jsou jednoduché (velikost, konvexnost, podlouhlost, geometrické momenty). Objekt vyžaduje přesnou segmentaci a odolnost vůči aditivnímu šumu.

- Lokální deskriptory objektu – jen z určité lokální části objektu je proveden výpočet příznaků. Obraz se nemusí segmentovat. Deskriptory využívají rohy, struktury, textury, přímost, zakřivení objektu. Lokální deskriptory nelze logicky žádným způsobem sestavit.

4.4 Geometrické momenty a momentové invarianty, Hu momenty

Podle tvaru objektů a jasových hodnot jeho pixelů probíhá výpočet geometrických momentů. Geometrické momenty jsou fotometrické příznaky založené na regionech. Pro každý objekt je možné sestavit nekonečně mnoho geometrických momentů. Aby byl objekt popsán co nejdokonaleji, je nutné pro jeho rekonstrukci použít co nejvíce momentů.

Vzorec základního geometrického momentu řádu $p+q$:

$$m_{pq} = \sum_Y \sum_X x^p y^q s(x, y). \quad (1)$$

Centralizované geometrické momenty se používají pro výpočet momentových invariantů segmentovaných objektů.

Vzorec pro výpočet vztahovaný k těžišti objektu:

$$\mu_{pq} = \sum_Y \sum_X (x - x_t)^p (y - y_t)^q s(x, y). \quad (2)$$

Z obrazových dat základních geometrických momentů nultého a prvního řádu se vypočte přímo těžiště objektu. Součet jasových hodnot segmentu je moment nultého stupně m_{00} . Jeho mocnina se používá jako normalizační konstanta pro ostatní momenty. Normalizované momenty prvního stupně určují hodnoty souřadnic těžiště objektu.

Vzorec pro výpočet souřadnice těžiště x_t :

$$x_t = \frac{\sum_Y \sum_X x \cdot s(x, y)}{\sum_Y \sum_X s(x, y)} = \frac{m_{10}}{m_{00}}. \quad (3)$$

Vzorec pro výpočet souřadnice těžiště y_t :

$$y_t = \frac{\sum_Y \sum_X y \cdot s(x, y)}{\sum_Y \sum_X s(x, y)} = \frac{m_{01}}{m_{00}}. \quad (4)$$

Kvůli úspěšné rekonstrukci se musí hodnoty geometrických momentů normalizovat vzhledem k velikosti objektů.

Vzorec pro výpočet geometrického momentu:

$$v_{pq} = \frac{m_{pq}}{m_{00}^{\frac{p+q}{2}+1}}. \quad (5)$$

Pro kompozici složitějších struktur zvaných momentové invarianty se používají základní i centrální geometrické momenty. Tyto momenty jsou deskriptory jasového rozložení hodnot objektů. Momenty nejsou nezávislé na obecné afinní transformaci.

Momentových invariant je obrovské množství pro celou řadu úloh. Velmi známá je sada momentových invariantů ϕ_1 až ϕ_7 nezávislých na translaci, rotaci a změnu měřítka.


Vzorci Hu momentů:

$$\begin{aligned} \phi_1 &= \mu_{20} - \mu_{02} \\ \phi_2 &= (\mu_{20} - \mu_{02})^2 + 4\mu_{11}^2 \\ \phi_3 &= (\mu_{30} - 3\mu_{12})^2 + (3\mu_{21} + \mu_{03})^2 \\ \phi_4 &= (\mu_{30} + \mu_{12})^2 + (\mu_{21} + \mu_{03})^2 \\ \phi_5 &= (\mu_{30} - 3\mu_{12})(\mu_{30} + \mu_{12}) \left[(\mu_{30} + \mu_{12})^2 - 3(\mu_{21} + \mu_{03})^2 \right] + \\ &+ (3\mu_{21} - \mu_{03})(\mu_{21} + \mu_{03}) \left[3(\mu_{30} + \mu_{12})^2 - (\mu_{21} + \mu_{03})^2 \right] \\ \phi_6 &= (\mu_{20} - \mu_{02}) \left[(\mu_{30} + \mu_{12})^2 - (\mu_{21} + \mu_{03})^2 \right] + \\ &+ 4\mu_{11}(\mu_{30} + \mu_{12})(\mu_{21} + \mu_{03}) \\ \phi_7 &= (3\mu_{21} - \mu_{03})(\mu_{30} + \mu_{12}) \left[(\mu_{30} + \mu_{12})^2 - 3(\mu_{21} + \mu_{03})^2 \right] - \\ &- (\mu_{30} - 3\mu_{12})(\mu_{21} + \mu_{03}) \left[3(\mu_{30} + \mu_{12})^2 - (\mu_{21} + \mu_{03})^2 \right] \end{aligned} \quad (6)$$

Při rozpoznávání objektů musí momentové invarianty splňovat podmínku vysoké diskriminality. Většinou se při rozpoznávání používají kombinace momentových invariantů s jednoduššími fotometrickými nebo radiometrickými deskriptory obrazu.


4.5 Haarovy vlnky

Využívají se jako jednoduché příznaky, které nejsou výpočetně náročné. Jedná se vůbec o první spojitost s vlnkovou transformací. Haarova vlnka je nespojitá, symetrická, ortogonální, dá se přirovnat k vlnce Daubechies prvního řádu. Průběh Haarovy vlnky se podobá skokové funkci.





Obr.6.: Průběh Haarovy vlnky.


Z definice Haarovy vlnky se vytvářejí Haar-like příznaky. Vypočítají se hranové, čárové a diagonální příznaky. Hodnota příznaku je rozdílem součtu pixelů obrazu světlé části a součtem pravé části.



hranove priznaky



carove priznaky



diagonalni priznak


Obr.7.: Haar-like příznaky.

Hranové příznaky tvoří dvě oblasti, čárové tři oblasti a diagonální příznak tvoří čtyři oblasti. Všechny příznaky se aplikují na celý obraz a to s různou velikostí jednotlivých oblastí. Výpočet probíhá od velikosti 1×1 až po velikost obrazu.

5 Klasifikátory

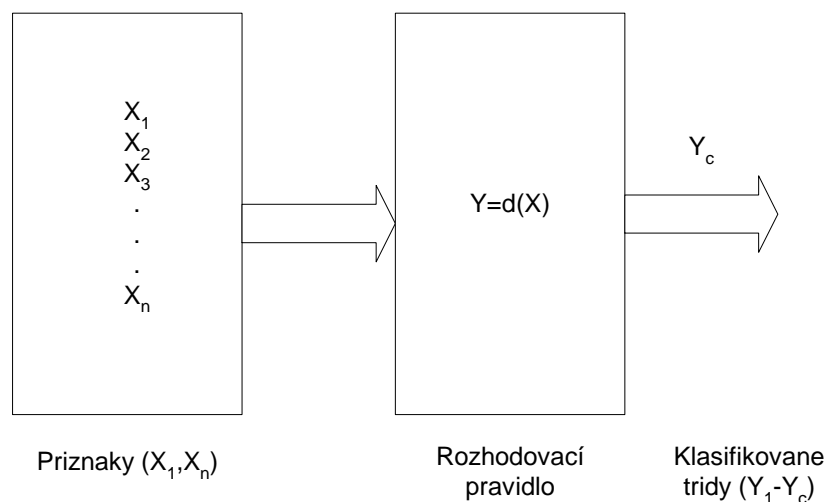
Budou popsány základní pojmy a některé klasifikační metody použitelné při rozpoznávání obrazu. . Informace pro tuto kapitolu jsem načerpal z pramenů [3], [10].

Nauka o získávání a zpracování znalostí je strojové učení – strojová klasifikace.



Obr.8.: Zpracování dat a strojová klasifikace.

Klasifikátor je algoritmus, který je schopen na základě znalostí rozdělit vstupní data s příznaky do předem zvolených skupin. Úspěšná klasifikace je podmíněna vhodnou volbou klasifikačního algoritmu.



Obr.9.: Klasifikátor – vstupy a výstupy.

Při strojovém učení se musí zvolit:

- Vhodné příznaky.
- Klasifikační metoda.
- Metoda učení, vyhodnocení chyb klasifikace.
- Interpretace výsledků učení.
- Implementace klasifikátoru do cílové matice.

Postup použití klasifikační metody:

- Učení – vytvoření znalostního modelu s ohledem na typ klasifikátoru.
- Ověřování – kontrola s jinými daty a určení přesnosti klasifikace.
- Klasifikace – normální provoz naučeného klasifikátoru.
- Určení přesnosti klasifikace – jedná se o procentuální poměr mezi počtem správně určených vzorků k počtu všech předložených vzorů k testování.

Kompletní model – na základě učení vzniká množina znalostí se všemi pozitivními případy (obsahuje i některé negativní případy).

Konzistentní model – na základě učení vzniká množina znalostí, kde není negativní případ (obsahuje i některé pozitivní případy).

Rozdělení klasifikátorů podle metod klasifikace:

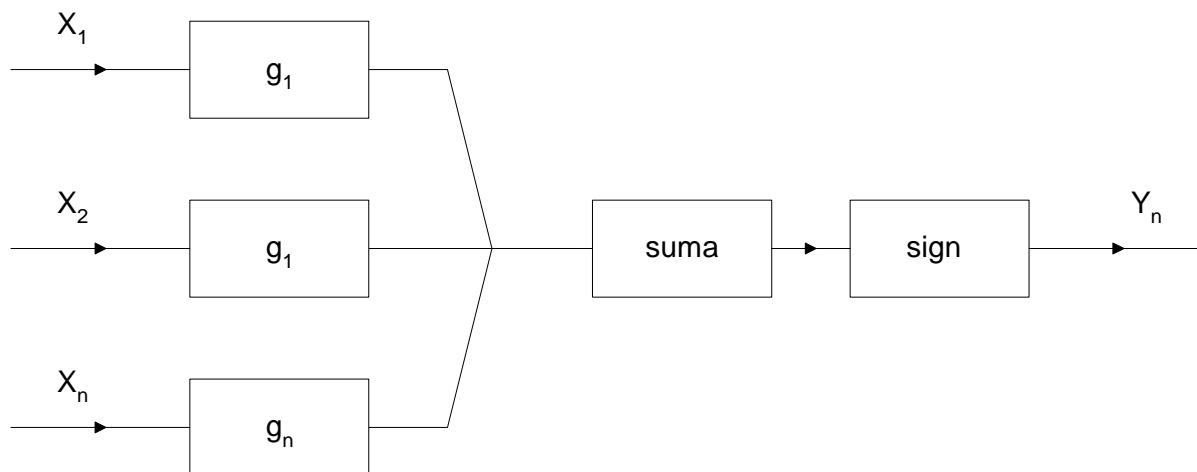
- Symbolické – metody jsou založeny na rozhodovacích stromech (např.: ID3).
- Sub-symbolické – metody založené na biologickém základě (např.: neuronové sítě, genetické algoritmy).
- Statistické – metody využívají regresní nebo jiné statistické metody (např.: Bayerův odhad).
- Paměťové – metody jsou založené na ukládání instancí (např.: IBL).

Rozdělení klasifikátorů podle charakteru učení:

- Dávkové – při učení se pracuje vždy s celou cvičnou množinou naráz (symbolická klasifikace).
- Inkrementální – při učení lze cvičné příklady dodávat postupně. Podle nich se naučená znalost postupně aktualizuje (statická klasifikace).
- Inkrementální se zapomínáním – jestliže je při učení některý významný atribut skryt nebo se v množině šíří šum, může být zapomínání části znalostí výhodné.

5.1 Lineární klasifikátor

Jednoduchou metodu klasifikace založenou na rozdělení množiny příznaků představuje lineární klasifikátor. Prostor je rozdělen po částech do lineárních úseků. Prostor má více úseků, množinu příznaků rozděluje nad-rovinami (nad-plochami).



Obr.10. Lineární klasifikátor.

Při učení klasifikátoru se vyberou konstanty g a parametry funkce sign . Podmínka separace:
 $s_r = g_1 X_1 + g_2 X_2 + \dots + g_n X_n$. (7)

Je-li tato podmínka splněna při nulové chybě klasifikátoru, jedná se o lineární separabilitu prostoru příznaků.

Při návrhu lineárního klasifikátoru se vybírá vhodný příznak. Při učení se vybírá nejlepší příznak pro celou třídu. Hledá se nejmenší vzdálenost neznámého vzoru od některého z příznaků. Vzor je následně přiřazen do nejbližší části.

Míra vzdálenosti:

$$\|V_s - X\| = \sqrt{(V_s - X)^T (V_s - X)}. \quad (8)$$

Kde V_s je poloha nejlepšího příznaku a X je poloha vzoru.

Minimální vzdálenost od některého vzoru:

$$\begin{aligned} \min \|V_s - X\|^2 &= \min (V_s^T V_s - 2V_s^T X + X^T X) = \\ &= X^T X - 2 \max (V_s^T X - \frac{1}{2} V_s^T V_s) \end{aligned} \quad (9)$$

5.2 Bayesův klasifikátor

Jedná se o statický klasifikátor s dávkovým i inkrementálním učením. Naučená znalost se podle pravděpodobnosti rozděluje do tříd. Třída s největší pravděpodobnosti je použita pro klasifikaci.

Při učení se pro třídy C_i , příznaky A_j a jejich hodnoty V_{jk} zaznamenává do tabulky, kolikrát se ve cvičné množině N_{ijk} vyskytl případ $A_j = V_{jk}$.

Při klasifikaci jsou ukládány hodnoty:

- T_i – počet jevů třídy C_i .
- T_{jk} – počet jevů $A_j=V_{jk}$.
- T – celkový počet jevů.

Na základě dílčích pravděpodobností $P(C_i/V_{jk})$, resp. $P(V_{jk}/C_i)$ se vypočítá pravděpodobnost nutná pro klasifikaci.

5.3 Markovovy modely


Pomocí pravděpodobnostního modelu se detekují a vyhodnocují změny stavu systému. Předpokládají se omezené podmínky změny stavu konečného stavového automatu.

Markovův předpoklad – pokud následující stav závisí pouze na současném stavu a nezávisí na stavech dřívějších, je v teorii pravděpodobnosti označen náhodný proces jako Markovův.

Markovův proces – stochastický proces s Markovovým předpokladem.


MM – Markovův model – je model s konečným počtem stavů, kdy přechod mezi stavy je vyjádřen pravděpodobnostmi. Existují modely s diskrétním a spojitým časem.

Ergodický model – všechny stavy mají mezi sebou přechody.



Obr.11.: Ergodický model.

Levo-pravý model – jedná se o jednodušší model, kdy nelze přecházet mezi všemi stavy v jednom směru.



Obr.12.: Levo-pravý model.

5.4 Skryté Markovovy modely

Jedná se o konečný stavový automat formálně zapsaný pěticí $\lambda = (N, M, A, B, \pi)$.

- N - Skryté stavy.
- M - Pozorovatelné stavy.
- A - Pravděpodobnosti přechodu mezi skrytými stavy.
- B - Pravděpodobnosti přechodů k pozorovatelným stavům.
- π - Počáteční pravděpodobnosti stavů.

5.5 AdaBoost

Jedná se o klasifikační algoritmus „Adaptive Boosting“. Základem je metoda strojového učení „boosting“. Metoda má za úkol zlepšit klasifikační přesnosti libovolného algoritmu strojového učení. Nad množinou špatných slabých klasifikátorů (žáků) je vytvořena nová silná množina silných klasifikátorů (učitelů). Slabé klasifikátory jsou výběrem vzorků ze základní množiny. Přesnost prvního klasifikátoru je nízká. Postupně jsou přidávány další klasifikátory a je vytvořena množina silných klasifikátorů. Tím roste celková přesnost v závislosti na počtu vzorků.

Adaboost tedy využívá slabých klasifikátorů k vytvoření silných klasifikátorů. Jedná se o jednoduchou metodu, která neklade žádné požadavky na klasifikátory. Metoda je náchylná na šum a přetrénování. Jedná se o jev kdy se algoritmus naučí trénovací data a nově přidané data spíše nezohledňuje.

Trénovací množina:

$$(x_1, y_1), \dots, (x_m, y_m); x_i \in X, y_i \in Y = \{-1, +1\}. \quad (10)$$

Algoritmus využívá slabých klasifikátorů h_i . Množina špatných žáků:

$$\begin{aligned} h_i &: X \rightarrow \{-1, +1\} \\ h_i &\in H \end{aligned} \quad (11)$$

Výsledný silný klasifikátor:

$$K(x) = \text{sign}\left(\sum_{i=1}^T \alpha_i h_i(x)\right). \quad (12)$$

Adaboost používá vážení trénovací množiny ze začátku rovnoměrně rozloženými váhami D_i .

Inicializace metody:

$$D_1(i) = \frac{1}{m}; i = 1, \dots, m$$

$$t = 1, \dots, T$$
(13)

Kde T je velikost trénovací množiny.

Vyhledání klasifikátoru:

$$h_t : X \rightarrow \{-1, +1\}$$

$$h_t \in H$$
(14)

Aby byla přesnost klasifikace vyšší, než kdyby se klasifikace prováděla náhodně, vybírá se klasifikátor s nejmenší chybou klasifikace:

$$h_t = \arg \min_{h_j \in H} \varepsilon_j$$
(15)

$$\varepsilon_j = \sum_{i=1}^m D_t(i) \text{bool}(y_i \neq h_j(x_i))$$
(16)

Pokud $\varepsilon_t > 0,5$ tak se učení ukončí, jinak následuje určení váhy klasifikátoru α_t

$$\alpha_t = \frac{1}{2} \ln \left(\frac{1 - \varepsilon_t}{\varepsilon_t} \right)$$
(17)

$$\alpha_t \in \mathfrak{R}$$

Váha špatně klasifikovaných měření se zvětší a dobře klasifikovaných se zmenší. S rostoucím počtem klasifikátorů metoda redukuje trénovací chybu. Je hledán klasifikátor, který bude lépe klasifikovat chybná měření.

Váhy trénovací množiny se přepočítají:


$$D_{t+1}(i) = \frac{D_t(i) e^{-\alpha_t y_i h_t(x_i)}}{Z_t}$$
(18)

$$Z_t = \sum_{i=1}^m D_t(i) e^{-\alpha_t y_i h_t(x_i)}$$
(19)

5.6 Neuronové sítě

Pro případy s neznámým rozložením nebo vysokým počtem příznaků se dá použít klasifikátor na bázi neuronové sítě. Klasifikátor je inspirován biologickými prvky. Jedná se o paralelně propojenou síť neuronů (pamětí). Axony (výstupy) a dendrity (vstupy) tvoří spojení neuronů. Klasifikace probíhá podle znalostí a zkušeností. Metoda klasifikace je pseudo-symbolická. Existuje několik typů neuronových sítí použitelných pro různé úlohy.

Definice: Umělá neuronová síť je paralelní distribuovaný systém výkonných prvků modelujících biologické neurony účelně uspořádaný tak, aby byl tento systém schopen požadovaného zpracování informací.

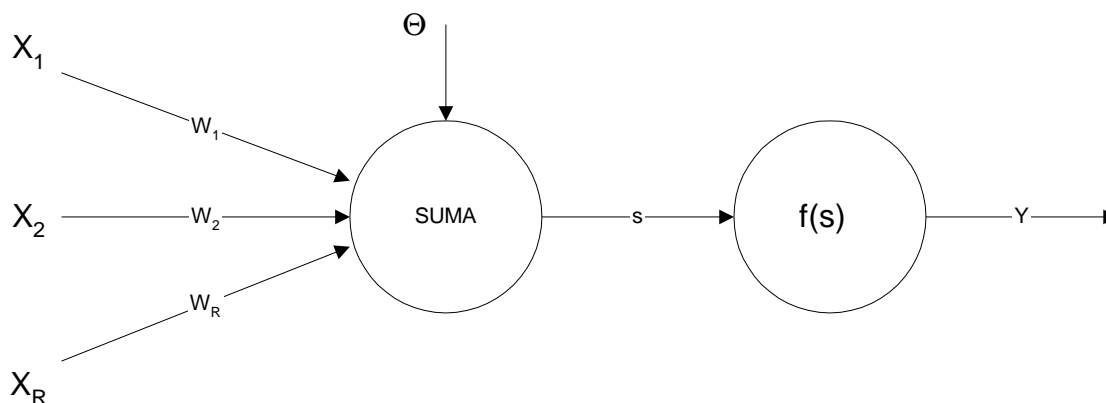


Obr.13: Transformační funkce umělé neuronové sítě.

Doposud se nepodařilo vytvořit komplexní model mozku. Je k dispozici částečná topologie, přenosové funkce neuronů, vnitřní vazby, způsoby učení, pamatování. Při rozpoznávání, podobnému jako je u mozku, se potřebuje mnohem větší výpočetní a paměťová kapacita, než jaká je k dispozici. Nelze tedy pro rozpoznávání užít neuronovou síť jakou používá lidský mozek.

5.6.1 Model neuronu

Nejčastěji se používá aproximace biologického neuronu. Původní model neuronu navrhl McCulloch a Pitts.



Obr.14.: Model neuronu.

Při zpracování vstupních dat se počítá vážený součet vstupů vztažený k prahové hodnotě Θ .

Vážený součet vstupů:

$$s = \sum_{i=1}^R X(i)W(i) - \Theta. \tag{20}$$

Míru aktivace přenosové funkce určuje práh neuronu Θ . Zavádí se jako nultý prvek vstupního vektoru $X(0)$ s váhou $W(0)$.

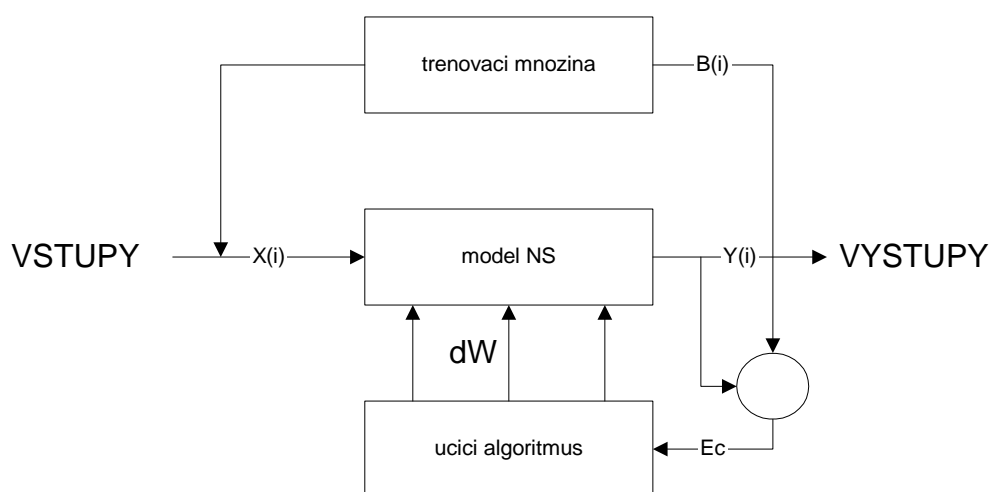
Přenosová funkce výstupu:

$$Y = f(s) = f\left(\sum_{i=1}^R X(i)W(i) - \Theta\right). \tag{21}$$

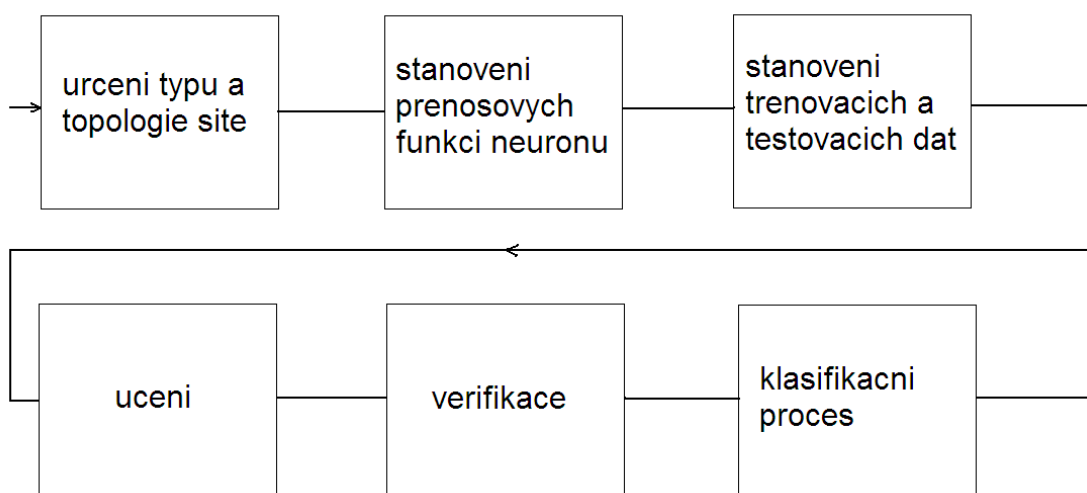
Každý neuron může mít vlastní typ přenosové funkce, ale většinou jsou přenosové funkce pro všechny neurony ve vrstvě stejné. Chování neuronové sítě popisuje průběh přenosové funkce. Je základním prvkem při nastavení neuronové sítě.

5.6.2 Proces učení neuronové sítě

Na základě učících vzorů se postupně samočinně neuronová síť učí znalost klasifikátoru. Trénovací množinu tvoří příznaky, které popisují objekt v obraze. Při trénování musí informace obsažené v obrazech trénovací množiny platit pro celý prostor obrazu.



Obr.15.: Učení znalostí klasifikátoru.



Obr.16.: Fáze klasifikace.

Celková chyba sítě při učení musí být minimální. Optimalizační kritérium stanovuje chybovou funkci E_C a hledá extrém funkce.

Optimalizační kritérium:

$$w_i^{k-1} \rightarrow w_i^{k-1} + \Delta w_i^k : \min \mapsto E_c = \frac{1}{2} \sum_{i=1}^P \sum_{s=1}^S (Y(i,s) - B(i,s))^2 \quad (22)$$

w_i^{k-1} - Váha i -tého neuronu v $k-1$ kroku.


E_c - Chybová funkce výstupu sítě.

S - Počet výstupních neuronů.

P - Počet předkládaných vzorů v jedné epoše učení.

5.6.3 Hopfieldova síť

Hopfieldova síť má jednorázové nastavení. Vstupy a výstupy sítě jsou binární nebo bipolární. Kapacita paměti je menší než 15% počtu neuronů. Obrazy předložených vzorů jsou uloženy ve vahách sítě. Klasifikátor je na bázi asociativní paměti. Klasifikátor aktivuje jeden výstup a ostatní jsou v nule.



Obr.:17 Hopfieldova síť.

Informace na výstupu Hopfieldovy sítě:

$$\sum_{i=1}^N (a_i w_i + c_i) > \Theta_i \quad (23)$$

Paměti:

- Klasické lineární paměti - k vyhledání informace v paměti je potřeba adresy.
- Asociativní paměti – informace se získá na základě znalosti, lineární kombinace vstupu.
- Auto-asociativní paměti – vstupní i výstupní informace je podobná. Používá se pro rozpoznání poškozených vzorů.
- Hetero-asociativní paměti – vstupní i výstupní informace jsou různé. Informace závisí na lineární kombinaci vstupů.

6 Úpravy obrazu

V ideálním případě by snímek neobsahoval šum. Na snímku by byly jasně rozpoznatelné všechny kosti ve vysokém poměru černá – bílá. Obrázek by neobsahoval cizí předměty, jako je pravítko, které na většině pořízených snímků nalezneme. Nebo by bylo pravítko alespoň jednoznačně rozpoznatelné. Obrázek by měl stejnou velikost, měl by stejné rozlišení. Umístění hlavy na snímku by bylo vždy na stejném místě, nechyběla by temenní, ani týlní část, respektive by bylo ořezání vždy stejné. Snímky mají různý jas i kontrast. Existuje spousta dalších idealizací, které by vedly k jednoznačné práci se snímkem.

Vzhledem k tomu, že existuje různá kvalita snímku a různé zobrazení hlavy (výřez) je práce se snímky složitá. Musí se tedy najít cesta, která povede k detekci co nejvíce bodů. Série úprav, která se provede, může vést k nalezení jen určitých bodů. Série jiných úprav povede k nalezení jiných bodů.

Matlab má ve své knihovně dostačující množství instrukcí pro úpravu obrazu. Postupně budou popsány úpravy obrazu a jejich reprezentace v programu matlab i výstupy provedených příkazů.

6.1 Načtení snímku

Dentista nebo ortodontista si pořídí snímek. Je několik možností, jak snímek převést do počítače. Snímek se dá naskenovat, vyfotografovat digitálním fotoaparátem. V ordinaci se snímek umístí na negatoskop. Pokud není lepší možnost, dá se použít jako zdroj světla svit monitoru s bílým pozadím.

Skener při snímání zbarvuje snímek a přidává šum, tím značně znehodnocuje kvalitu. Fotografování vykazuje soudkovitost a zabarvení, ale šum je nižší než při použití skeneru. Šum se musí eliminovat a barevný snímek převést zpět do stupňů šedi. Soudkovitost momentálně není podstatná. Tato fáze společně s pečlivým vyhotovením snímku bude značně ovlivňovat úspěšnost vyhledávání bodů.

Většinou je vhodné zavřít všechny otevřené výstupní zobrazení příkazem „close all“. Pro vymazání všech proměnných a funkcí z paměti se použije příkaz „clear all“. Pracovní prostor zůstane prázdný. „Clc“ vymaže všechny vstupní a výstupní informace z displeje příkazového okna a tím zajistí aktuální informace při spuštění skriptu.

Nejprve se načte snímek příkazem „imread“. „Imread“ načte obrázek ve stupních šedi nebo ve formátu „rgb“. Soubor se načte buď z pracovního adresáře nebo ze zadané cesty. Funkce vrátí obrazová data v poli, pokud je obraz ve stupni šedi, bude dvou-dimenzionální pole. Jestli je obraz barevný, vrátí tří-dimenzionální pole. Funkce dokáže přečíst grafické soubory s různými formáty.



Obr.18.: Neskenovaný snímek.

6.2 Změny barev a velikosti

Pro další úpravy je nutné mít snímek pouze v odstínech šedi. Snímek se převádí na černobílý. V matlabu se pro tento požadavek použije funkce „rgb2gray“. Funkce převede barevný snímek do odstínů šedi odstraněním odstínů sytosti informací při zachování jasů.



Obr.19.:Obrázek převedený do odstínů šedi.

Na obrázku nejsou vidět konkrétní rozdíly, ale existují snímky, kde se při skenování objeví barvy a ty je právě potřeba převést do stupňů šedi.

Zobrazení obrázku se provede po zadání příkazu „imshow“. Upřesněním příkazu „imshow“ se zobrazí obrázek ve stupních šedi, v barvě a zobrazuje binární obrazy. Aby se obrázky zobrazily zvlášť, předchází příkaz „figure“ s požadovaným pořadovým číslem. Možností, jak zobrazit výsledky a jak je seskupit je spousta.

Snímek se postupně ukládá, aby byla později vidět jeho změna příkazem „imwrite“. „Imwrite“ podporuje různé formáty a obraz uloží do stupňů šedi nebo barevného pole.

Pro hledání bodů na obrázku vyžaduje klasifikace přibližně konstantní velikost všech obrázků. Pro zjištění výšky a šířky obrazu slouží příkaz „imfinfo“. „Imfinfo“ zobrazí i další informace (viz. Tab.1.). Před samotnou klasifikací se snímek rozdělí na spoustu výřezů. Počet výřezů udává právě výška a šířka obrazu.

Filename:	'origo.bmp'
FileModDate:	'06-Oct-2010 10:24:47'
FileSize:	2878902
Format:	'bmp'
FormatVersion:	'Version 3 (Microsoft Windows 3.x)'
Width:	1008
Height:	952
BitDepth:	24
ColorType:	'truecolor'
FormatSignature:	'BM'
NumColormapEntries:	0
Colormap:	[]
RedMask:	[]
GreenMask:	[]
BlueMask:	[]
ImageDataOffset:	54
BitmapHeaderSize:	40
NumPlanes:	1
CompressionType:	'none'
BitmapSize:	2878848
HorzResolution:	0
VertResolution:	0
NumColorsUsed:	0
NumImportantColors:	0

Tab.1.: Informace o obrázku.

Aby měly všechny obrázky stejnou velikost musí se obrázku upravit velikost funkcí „imresize“. „Imresize“ vrací obraz, který bude mít požadovanou velikost (byla zvolena šířka 480 bodů a výpočet výšky v poměru). Při změně velikosti se měří velikost pomocí interpolace určitým způsobem. Jsou tři možnosti: podle „nejbližšího souseda“, bilineární a bikubická. Byla vybrána metoda „nejbližšího souseda“, jelikož se jeví nejostřejší a nejvíce se podobá originálu.

Při úpravě velikosti se musí akceptovat poměr stran. Musí se tedy zmenšovat o určitý díl. Zjistí se počet vertikálních a horizontálních bodů a postupně se obrázek zmenšuje než klesne šířka obrazových bodů pod 500. Při zmenšování se vhodně použije funkce „round“ na zaokrouhlování. „Round“ zaokrouhlí na nejbližší celé číslo.



Obr.20.: Zmenšený obrázek.

Obrázek se zmenšuje kvůli zobrazení na běžných monitorech a práci s menším (přesně daným) počtem bodů. Matlab jinak výstup dokáže zmenšit podle velikosti monitoru.

6.3 Ostření a redukce šumu

Testovací snímek je velmi zašuměný, nebyly dodrženy pravidla pro rentgenování. Je nutné provést úpravy vedoucí k zvýšení kvality. Matlab již má implementovány nástroje pro práci s obrázkem.

Nejprve se z obrázku odstraní vertikální pruhy a zvýší se kontrast. V matlabu se pro tuto situaci zadá příkaz „`imadjust`“. „`imadjust`“ dokáže vhodným výběrem omezujících hodnot ztmavit (zesvětlit) nebo upravit kontrast snímku. Pro tento obrázek ze zkušební sady bylo provedeno ztmavení a zvýšení kontrastu. Ve výsledku pak chybí zmíněné pruhy, které vznikly skenováním obrázku.

Pro zvýšení kontrastu pomocí ekvalizace histogramu lze použít funkci „`histeq`“. „`Histeq`“ zvyšuje kontrast obrazu tím, že změní hodnoty v intenzitě obrazu tak, aby histogram výsledného obrázku přibližně odpovídal zadanému histogramu. Tato funkce se nepodařila vhodně implementovat.



Obr.21:Odstranění pruhů.

Další důležitou úpravou je snížit hluk. V matlabu se použije funkce „medfilt2“. „Medfilt2“ provede dvojdimenzionální střední filtraci. Jedná se o nelineární operaci často používanou ve zpracování obrazu snížit „sůl a pepř“ hluk. Střední filtrace je účinnější než konvoluce, kdy je cílem snížení hluku.



Obr.22.:Odstranění šumu.

Po odstranění šumu je nutné obraz zaostřit. V matlabu se použije funkce „fspecial“ a „imfilter“. „Fspecial“ vytváří speciální 2-D filtry uvedeného typu. Funkce vrací srovnávací jádro, které je vhodnou formou pro použití s „imfilter“. Pro ostření je nutné použít jako typ „unsharp“ kontrastní filtr.

„Imfilter“ pro multi dimenzionální filtraci obrazu. Filtry multidimenzionálního pole rozostřeného obrazu s filtrem kontrastního filtru vytváří podle zvoleného typu zaostřený obraz. V tomto případě se volí typ „replicate“, kdy jsou vybrány nejbližší pole z hraničních hodnot.



Obr.23.:Zaostření obrazu.

7 Detekce objektů

Tato kapitola popisuje rozbor možných metod detekce hran, použití Hu momentů s neuronovou sítí a Haarových vlnek s algoritmem Adaboost vedoucích k detekci bodů. Bude provedeno rozdělení na segmenty, vytvoření příznaků a klasifikace příznaků obrazu. Informace pro tuto kapitolu jsem načerpal z pramenů [3], [10].

7.1 Detekce hran


Kdyby se jednalo o ideální obraz, bylo by nejjednodušší použít hranové detektory, které najdou hrany v obrázku ve stupních šedi. Metody by jasně vykreslily kosti i kůži a identifikace bodů pro ortodontisty by byla mnohem jednodušší.

Detekce hran patří mezi základní operace s obrazem. Každý obraz obsahuje šum. Na rentgenovém snímku se nachází pouze šum, nejsou tam skoro žádné jasně rozpoznatelné hrany a detektor generuje falešné hrany. Před detekcí je nutné tedy obraz upravit, detektory reagují na změnu jasové funkce.

Hranový detektor vytvoří z šedotónového obrazu podle určitých pravidel systém linií na základě rozdílů stupňů šedi. V matlabu se použije funkce „edge“. Tato funkce podporuje 6 metod. Byly vybrány dvě metody a to Laplace – Gaussova a Cannyho metoda.

Metoda Sobel, Prewitt a Roberts najde hrany pomocí aproximace na derivát. Vrací hrany na těch místech, kde je sklon I maximální. Nejjednodušší je metoda Roberts, používá matici 2×2 bodů. Aby se našla absolutní velikost gradientu v každém bodě a orientace, výstupy se kombinují. Obě matice jsou na obraz aplikovány odděleně.

Laplace - Gaussova metoda najde hrany tak, že hledá místa křížení s nulou po filtraci s Laplace - Gaussova filtrem. Metoda najde hrany tak, že hledá křížení s nulou po filtraci a s filtrem, který se zadá.



Obr.24.: Laplace - Gaussova metoda detekce hran.

Metoda Canny najde hrany tak, že hledá lokální maxima gradientu. Gradient se počítá podle derivátu Gaussova filtru. Tato metoda používá dva prahy, rozlišuje silné a slabé hrany, a slabé hrany zahrnuje ve výstupu pouze tehdy, pokud jsou připojeny k pevné hraně. Tato metoda je odolnější vůči šumu než ostatní a více pravděpodobná k odhalení slabé hrany.



Obr.25.: Cannyho metoda detekce hran.

7.2 Segmentace

Aby se mohly pomocí Hu momentů detekovat body, musí se obrázek rozdělit. Nejprve se již upravený snímek načte („imread“). Kdyby bylo potřeba, tak se dají pomocí funkce „size“ určit rozměry obrazu. „Size“ vrací dimenzi pole, v tomto případě počet řádků a počet sloupců.

Při navrhování se musí určit několik zásadních podmínek. Velmi důležitá je velikost okna, kterým se bude prohlížet snímek. Jak je již napsáno obrázek má velikost kolem 500 obrazových řádků a 500 obrazových sloupců. Zvolila se velikost okna 100×100 bodů. Musí se určit o kolik se bude posouvat okno při příštím běhu. Zvolila se velikost 20 bodů. Při těchto podmínkách je výsledkem kolem 400 obrázků, které budou sloužit pro detekci.

Když se rozděluje kefalometrický snímek, není nutné do oblasti zájmu zahrnout okrajové body. Při psaní programu se nesmí okno dostat mimo snímek. Velikost okna musí být dělitelná beze zbytku velikostí posunutí běhu. Obrázky vzniklé výřezem je nutné indexovat a je vhodné je uložit do samostatné složky.

7.3 Hu momenty

Teoretický základ a rovnice se kterými metoda pracuje jsou popsány v kapitole 4.4. Hu momenty pracují s geometrickými momenty podle regionu. Celkem se jedná o výpočet sedmi rovnic. Šest rovnic popisuje tvar regionu, jsou invariantní vůči posunu. Sedmá rovnice rozlišuje zrcadlově otočené obrazy.

Nejprve se musí vstupní obraz přetypovat, v Matlabu funkcí „double“. Dále se pomocí funkce „zeros“ připraví výstupní matice. Během procházení cyklu se pro všechny segmenty obrazu vypočtou Hu momenty. Výpočet probíhá několika fázemi: normalizací, centralizací a výpočtem momentů. Výsledky se ukládají do matice a do textového souboru pro pozdější využití.

Prostřednictvím neuronové sítě se provede klasifikace. Matlab má implementovanou utilitu „nntool“. Zde probíhá natrénování sady segmentů s příznaky s vektorem jedniček a nul. Učící algoritmus vytvoří síť.

7.4 Detektor Viola-Jones

Pro samotnou detekci se používá detektor Viola-Jones. Poprvé byl představen v roce 2001. Detektor pracuje s obrazy v odstínech šedi. Detektor tvoří tři základní části: integrální obraz, Haarova vlnka a klasifikační algoritmus Adaboost. Detektor je velmi rychlý, spolehlivý a nezávislý na osvětlení. Detektor se využívá k detekci obličejů a k podobným úlohám.

Pro obraz o velikosti 19×19 se vypočte zhruba 64 000 hodnot příznaků. Právě tyto příznaky jsou použity pro klasifikaci v algoritmu Adaboost. Ze všech příznaků se vybere jen určité malé množství příznaků a stejný počet natrénovaných slabých klasifikátorů. Při samotné detekci je pak použito toto malé množství příznaků.

7.5 Integrální obraz

Aby se pro každou hodnotu příznaku nemusel počítat součet hodnot pixelů, převádí se vstupní obraz do reprezentace integrálního obrazu. Výpočet integrálního obrazu je efektivnější a rychlejší. Každý bod integrálního obrazu odpovídá sumě předcházejících bodů.

Vzorec pro výpočet integrálního obrazu:

$$\begin{aligned} s(x, y) &= s(x, y-1) + I(x, y), \\ I_{\text{int}}(x, y) &= I_{\text{int}}(x-1, z + s(x, y)) \end{aligned} \quad (24)$$


$s(x, y)$ je kumulovaný součet hodnot v řádku obrazu

$I(x, y)$ jsou hodnoty intenzit jednotlivých pixelů vstupního obrazu

$I_{\text{int}}(x, y)$ jsou jednotlivé hodnoty integrálního obrazu

$$s(x, 0) = 0, I_{\text{int}}(0, y) = 0$$

Pro výpočet libovolného obdélníku v obraze postačí dvě operace sčítání a jedna operace odečítání. Výpočet je tak mnohem jednodušší.



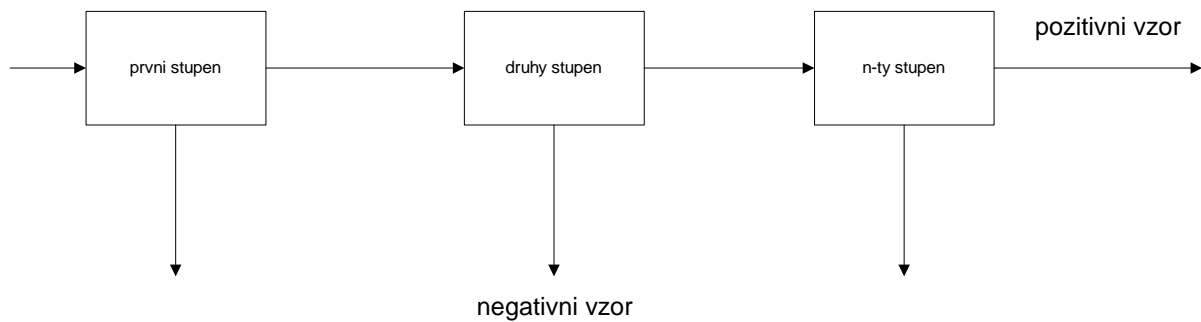
Obr.26.: Výpočet obdélníku integrálního obrazu.

7.6 Detekce objektů

Před samotnou detekcí je potřeba vytvořit trénovací množinu obrazů s pozitivními vzory objektu a negativními vzory pozadí. Byl vytvořen textový soubor s hodnotami pixelů segmentu obrazu obsahující hledaný objekt a 20 segmentů pozadí pro všechny snímky. Všechny vzory musí mít stejnou velikost. S tímto textovým souborem je natrénován klasifikační algoritmus Adaboost.


Obraz je zpracováván po částech. Okno o velikosti 19×19 se posouvá v horizontálním i vertikálním směru o určitý krok. Vybrané příznaky tohoto okna jsou použity pro klasifikaci a je rozhodnuto, zda toto okno hledaný objekt zahrnuje.

Prohledávání obrovským množstvím oken je výpočetně náročné. Je nutné výpočetní náročnost i dobu redukovat. Dochází ke snížení doby, kterou algoritmus věnuje prohledávání obrazu kaskádovým zapojením klasifikátorů. Většina segmentů obrazu neobsahuje hledaný objekt. Velmi málo příznaků postačuje k vytvoření klasifikátoru, který umí vybrat téměř všechny hledané objekty a negativní objekty eliminuje. V každém stupni kaskády se zavrhne vysoký počet negativních případů a do dalšího stupně postupují jen pozitivní případy.



Obr.27.: Schéma kaskádového zapojení klasifikátorů.

Textovému souboru se na začátek přidává informace o počtu segmentů a rozměru okna. Spuštěním souboru „Viola.exe“ detektor provede na základě textového souboru s hodnotami pixelů a vektorem jedniček a nul s informací o umístění hledaného objektu extrakce příznaků a naučení dané situace.



Obr.28.: Vstupní snímek a nalezený objekt.

Při detekci se načtou potřebné proměnné, provede se úprava neznámého snímku a provede se klasifikace. Algoritmus sestaví mapu jedniček a nul, které reprezentují umístění hledané oblasti, ve které se hledaný bod nalézá. Pomocí funkce „bwlabel“ a „imfeature“ algoritmus vypíše název segmentu s hledaným bodem.

8 Závěr a další postup

8.1 Závěr

V druhé kapitole je proveden rozbor telerentgenových snímků. Jsou popsány charakteristické body pro detekci v kefalometrii. Body jsou vyznačeny na lebce pro lepší orientaci. Úspěšnost nalezení bodů se zvyšuje dodržáním postupů při rentgenování. Při přenosu informace do počítače se vnáší do obrazu šum při skenování. Skener znehodnocuje snímek. Při fotografování sice není šum tak znatelný, ale obraz vykazuje soudkovitost. Soudkovitost práce zatím neřeší, není tak kritická. Tomu se dá jednoduše předejít použitím digitálního rentgenu, který zhotoví digitální obraz a pošle ho k dalšímu zpracování přímo do počítače.

V šesté kapitole je uveden postup, jak zvýšit kvalitu snímku, snížit šum, odstranit cizí předměty a postup načítání, ukládání a zobrazování. Nejasné, rozmazané a zašuměné hrany budou způsobovat nepřesnosti při měření na kefalometrickém snímku.

Jednou z možností, jak určit body je vykreslit hrany na lebce. Tato metoda se s úspěchem používá k rozpoznávání obrazu. 2-D zobrazení lebky obsahuje velké množství hran, ze kterého se nedají jednoznačně na různých telerentgenových snímcích určit charakteristické body pro kefalometrickou analýzu.

Jednou z možností, jak vyhledávat body na rentgenovém snímku jsou Hu momenty. V diplomové práci se nepodařilo prostřednictvím této metody nalézt charakteristické body.

Vzhledem k tomu, že existuje různá kvalita snímku a různé zobrazení hlavy (výřez) je práce se snímky složitá. Musí se tedy najít cesta, která povede k detekci co nejvíce bodů. Série úprav, která se provede, může vést k nalezení jen určitých bodů. Série jiných úprav povede k nalezení jiných bodů.

Momentálně, tedy i s malým počtem snímků, funguje využití detektoru Viola-Jones na většinu charakteristických bodů. Detektor spolehlivě najde hledaný segment. S jistým výsledkem se dá počítat až s mnohem větším počtem snímků.

Praktická část je naprogramovaná v prostředí Matlab. Program se spouští zadáním *priprava.m*, pak *Viola.exe* a nakonec *detekce.m*. V současné době má Matlab ve své knihovně dostačující množství instrukcí pro úpravu obrazu a vykazuje jednodušší práci než programovací jazyk C (C++) s knihovnou OpenCV.

8.2 Další postup

Jedná se o rozsáhlý a složitý projekt. Hlavním problémem je momentálně nedostatek snímků. Pro další práci je nejvhodnější získat výstupy z digitálního rentgenu a provést ověření s větším počtem vzorků. Momentálně se trend tímto směrem vyvíjí. Dále pak zjistit u ortodontisty normy, konkrétní body a vzdálenosti mezi nimi. S největší pravděpodobností se bude muset s každým segmentem pracovat individuálně. Pro každý segment se provede jiná posloupnost kroků v závislosti na tom, jaká struktura kosti se na segmentu bude nalézat.

9 Seznam literatury a použitých zdrojů

- [1] ŘÍHA, K. *Pokročilé techniky zpracování obrazu*. Elektronické texty VUT, Ústav telekomunikací FEKT VUT v Brně, 2007.
- [2] GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing*, Prentice Hall, New Jersey, 2002.
- [3] HORÁK, K.; KALOVÁ, I.; PETROVSKÝ, P.; RICHTER, M. *Počítačové vidění* Elektronické texty VUT, FEKT VUT v Brně, 2008.
- [4] SONKA, M.; HLAVAC, V.; BOYLE, R. *Image Processing, Analysis, and Machine Vision*, International Student Edition, Third Edition, Thomson, 2008
- [5] DOKLÁDAL, M.; PÁČ, L. *Anatomie člověka I. Pohybový systém*, Skripta lékařské fakulty, Brno, 1991.
- [6] ČIHÁK, R. *Anatomie I*, Druhé, upravené a doplněné vydání, strana 133 – 214, Grada
- [7] DOKLÁDAL, M. *Anatomie zubů a chrupu*, Lékařská fakulta Masarykovy univerzity v Brně, Brno, 1994
- [8] KAMÍNEK, M.; ŠTEFKOVÁ, M. *Ortodoncie I*, Lékařská fakulta Univerzity Palackého v Olomouci, Olomouc 2001
- [9] POPELKA, I. *Rentgenologie* [online], [cit. 2010-12-1]. Dostupný z WWW: <http://ivanpopelka.cz/maturitni-okruhy/rentgenologie/>.
- [10] PŘINOSIL, J.; KROLIKOWSKI, M. *Využití detektoru Viola-Jones pro lokalizaci obličejů a očí v barevných obrazech*, Článek VUT, Ústav telekomunikací FEKT VUT v Brně 2008
- [11] SMITH, S.; HUTTON, J.; MOORE, T.; NEWMAN, D. *Gait Recognition*, Electronics and Computer Science University of Southampton [online], [cit. 2011-2-1]. Dostupný z WWW: <http://users.ecs.soton.ac.uk/drn/ug/compvision/gait/Matlab/index.html>
- [12] PŘINOSIL, J. *Analýza emocionálních stavů na základě obrazových předloh*, VUT, Ústav telekomunikací FEKT VUT v Brně 2008.

10 Seznam příloh

Informace pro praktickou část jsem načerpal z pramenů [11], [12].

Příloha 1: CD s programem.