

Rozpoznávání zájmových bodů a objektů na snímcích

Lačezar Ličev¹ a Štěpán Sojka²

Anotace

Recognition of points of concern leads to detection and consequent specification of values of coordinates X_i and Y_i . Result is data file of the coordinates. Problem domain is divided into two parts. The first one discusses processing of graphic information, while the second concentrates on searching of the point of concerns.

Key words: Objekt, objekty, proces, prezentace, segmentace obrazu, prahování, binární obraz, matematická morfologie, syntaktická analýza, příznaková analýza, atributy jasu, rozpoznávání, neuronová síť, zájmový bod, zájmový objekt, architektura.

1. Úvod

Rozpoznávání zájmových bodů na snímku slouží k nalezení a pak následně k určení hodnoty souřadnic X_i, Y_i . Výsledkem je datový soubor těchto hodnot. Na určování polohy jednotlivých bodů existuje celá řada algoritmů a metod. Příspěvek je rozdělen do třech částí. V první části se věnuji problematice matematických nástrojů, v druhé zpracování grafické informace a ve třetí popis modulů na rozpoznávání zájmových bodů a objektů.

2. Matematické nástroje analýzy snímku

2.1. Segmentace obrazu

Segmentace obrazu je nejdůležitějším a také nejsložitějším krokem v celém postupu vedoucím k analýze obsahu zpracovávaných obrazových dat. Snahou je rozčlenit obraz do částí, které mají úzkou souvislost s předměty či oblastmi reálného světa zachyceného na obraze. Výsledkem mají být obrazy reálných objektů, které jsou zachyceny v obraze.

Po provedení segmentace nastává další fáze, a to indexování oblastí. Indexování je důležité pro odlišení objektů od sebe a pro zjištění jejich počtu. Podrobnější popis je uveden v literatuře (Sojka E., 2000).

2.1.1. Prahování

Prahování je jedna z nejstarších a nejjednodušších metod segmentace obrazu a patří také k jedné z nejrychlejších.

Ve většině případů „vystupují“ objekty z pozadí, čímž je myšleno, že jasové (barevné) hodnoty prvků obrazové funkce (pixelů) objektů jsou odlišné od pozadí. Na tomto předpokladu je založena metoda prahování. Jejím principem je najít vhodný práh (hodnota jasu) t , který by „oddělil“ objekty od pozadí. Výsledkem tohoto procesu je obraz v binárním tvaru, ve kterém mají hodnotu 1 ty prvky obrazové funkce, které patří objektům a hodnotu 0 ty, které patří pozadí.

- Stanovení prahu metodou nejmenší chyby

Hodnotu prahu je většinou těžké vhodně stanovit. Proto byly odvozeny některé metody, které se touto problematikou zabývají. Stanovení prahu metodou nejmenší chyby je založeno na využití minimalizace pravděpodobnosti chybného zařazení prvků obrazové funkce (tzn. že prvek obrazové funkce objektu bude chybně vyhodnocen jako prvek obrazové funkce pozadí a naopak).

Protože se jedná o statistickou metodu, musíme nejdříve uvést následující předpoklady:

1 Doc. Ing. Lačezar Ličev, CSc., FEI VŠB TU Ostrava, tř. 17 listopadu 15

2 Bc. Štěpán Sojka, FEI VŠB TU Ostrava, tř. 17 listopadu 15

$$p(z) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-\frac{(z-\mu)^2}{2\sigma^2}\right] \quad (2.1)$$


kde $p(z)$ - normální rozložení hustoty pravděpodobnosti jasových úrovní pixelů objektu
 μ - střední hodnota
 σ - směrodatná odchylka

$$q(z) = \frac{1}{\tau\sqrt{2\pi}} \exp\left[-\frac{(z-\nu)^2}{2\tau^2}\right] \quad (2.2)$$

kde $q(z)$ - normální rozložení hustoty pravděpodobnosti jasových úrovní pixelů pozadí
 ν - střední hodnota
 τ - směrodatná odchylka

Uvedené předpoklady zavádějí normální rozložení hustoty pravděpodobnosti jasových úrovní pixelů objektů a pozadí. Zde se dopouštíme jisté nepřesnosti, protože hodnoty jasů pixelů jsou nespojitě a pouze na určitém rozsahu, který vyplývá ze zavedené implementace (ve většině případů 0-255).

Dále předpokládáme, že podíl bodů objektů na obraze je θ ($0 \leq \theta \leq 1$) a podíl bodů pozadí bude tedy $(1-\theta)$. Navíc předpokládáme, že pro střední hodnoty platí $\mu < \nu$. Hledanou hodnotu prahu označíme t .



Obr. č. 2.1

Normální rozložení hustot pravděpodobnosti pro objekty a pozadí s naznačeným prahem t , a pravděpodobnostmi $1-P(t)$ a $Q(t)$.

Zavedeme další pojmy:

$P(t)$ je pravděpodobnost, že bod objektu bude vyhodnocen správně jako bod objektu

$$P(t) = \int_{-\infty}^t p(z) dz \quad (2.3)$$

Pravděpodobnost jevu, že bod objektu bude vyhodnocen chybně jako bod pozadí, je $1-P(t)$ a $Q(t)$ je pravděpodobnost, že bod pozadí bude vyhodnocen chybně jako bod objektu

$$Q(t) = \int_{-\infty}^t q(z) dz \quad (2.4)$$

Pravděpodobnost jevu, že bod pozadí bude vyhodnocen správně jako bod pozadí, je $1-Q(t)$.

Celková pravděpodobnost chybné detekce je ε .

$$\varepsilon = \theta(1-P(t)) + (1-\theta)Q(t) \quad (2.5)$$

Snahou je dosáhnout co nejlepších výsledků segmentace, a proto musíme zajistit, aby chyba ε byla co možná nejmenší. Tato situace nastane v extrému, kterému odpovídá místo, kde je první derivace nulová.

$$\frac{\partial \varepsilon}{\partial t} = -\theta \frac{\partial P(t)}{\partial t} + (1-\theta) \frac{\partial Q(t)}{\partial t} = 0 \quad (2.6)$$

Po úpravě dostaneme vztah

$$(1-\theta)q(t) = \theta p(t) \quad (2.7)$$

Dalším dosazením (1.1) a (1.2) do (1.7) získáme po dalších úpravách a logaritmování

$$\ln(1-\theta) - \ln \tau - \frac{(t-\nu)^2}{2\tau^2} = \ln \theta - \ln \sigma - \frac{(t-\mu)^2}{2\sigma^2} \quad (2.8)$$

dalšími úpravami se dostáváme ke vztahu

$$t^2(\tau^2 - \sigma^2) + 2t(\sigma^2\nu - \tau^2\mu) + \tau^2\mu^2 - \sigma^2\nu^2 + 2\tau^2\sigma^2 \ln \frac{\sigma(1-\theta)}{\theta\tau} = 0 \quad (2.9)$$

Vyřešením této kvadratické rovnice určíme hledanou hodnotu prahu t . Aby rovnice měla řešení musíme splnit následující podmínky.

$$\begin{array}{ccc} \sigma \neq 0 & & \theta \neq 0 \\ & \text{a} & \\ \tau \neq 0 & & \theta \neq 1 \end{array} \quad (2.10)$$

Řešením rovnice (1.10) získáme hledanou hodnotu prahu metodou nejmenší chyby.

Metoda popsaná v této kapitole má však jednu velkou nevýhodu, a to, že musíme před začátkem výpočtu znát velmi mnoho informací o zpracovávaném obraze. Z tohoto důvodu uvedu vylepšení této metody (snížení počtu hodnot, které musíme znát).

- Iterační proces u metody nejmenší chyby

Vylepšení proti předchozí metodě spočívá v tom, že tato metoda nepředpokládá znalost poměrného zastoupení bodů objektů v obraze θ - tato hodnota se určí iteračním procesem. Musíme však znát hodnoty středních hodnot a směrodatných odchylek jasů pro objekty a pozadí.

Iterační proces pracuje stejně kvalitně jako metoda určení prahu pomocí nejmenší chyby.

- Prahování proměnným prahem

V případech, kdy je obraz sice kontrastní, avšak v různých svých částech má nerovnoměrnou úroveň jasu (např. vlivem nerovnoměrného osvětlení), nelze najít jedinou hodnotu prahu tak, aby vyhovovala pro všechny části obrazu. V takovém případě lze použít úspěšně metodu prahování s proměnným prahem.

Princip metody prahování proměnným prahem spočívá v rozdělení zdrojového obrazu na několik částí. V každé z těchto nově vzniklých částí se vypočte práh pouze pro danou oblast. Prah se vypočte jako průměr maximální a minimální hodnoty jasu v oblasti. Může ovšem také nastat situace pro některé oblasti, že rozdíl maximální a minimální hodnoty jasu bude malý. V takovéto oblasti by určení prahu nebylo přesné (v oblasti jsou pouze pixely pozadí nebo pixely objektu). V takovém případě se hodnota prahu stanovuje jako průměr prahů z okolních oblastí.

2.1.2. Zpracování binárních obrazů

Binárním obrazem nazýváme takový obraz, v němž obrazová funkce v každém bodě (pixelu) nabývá jedné ze dvou možných hodnot. Binární obrazy jsou z pravidla výsledkem metod provádějících segmentace obrazu (v pixelech náležících objektů např. obrazová funkce nabývá hodnotu 1, pixelech pozadí nabývá hodnotu 0). Před tím, než jsou binární obrazy analyzovány, lze je zpracovat některým ze speciálních postupů.


- Matematická morfologie

Teorie matematické morfologie (Dougherty 1992, Serra J. 1982, 1988, Sojka 2000) je dosti obsáhlá. Základními operacemi matematické morfologie jsou **eroze** a **dilatace**. Tyto operace jsou definovány následujícími vztahy:

$$E = B \otimes S = \{x,y \mid S_{x,y} \subseteq B\} \quad (2.11)$$

$$D = B \oplus S = \{x,y \mid S_{x,y} \cap B \neq \emptyset\} \quad (1.12)$$

Erozi binárního obrazu (vztah 1.11) **B** za použití masky **S** vznikne obraz **E**, který je opět binární. Jednotlivé body binárního obrazu nesou hodnotu 0 nebo 1. V bodě o souřadnicích (x,y) je v obraze **E** hodnota 1, jestliže je v obraze **B** hodnota 1 alespoň na těch místech, je hodnota 1 v masce $S_{x,y}$. Jinak je v obraze **E** v bodě o souřadnicích (x,y) hodnota 0. Ve vztahu jsou obrazy formálně reprezentovány jako množiny – jedná se o množiny pixelů nesoucích hodnotu 1. Analogicky by bylo možné interpretovat také vztah 1.12. Grafická interpretace dilataci a erozi je následující:



Obr. č. 2.2 Dilatace a eroze

- Ztenčování

Cílem ztenčování je reprezentovat objekty jako lineární útvary. Ztenčování může být realizováno např. pomocí opakované eroze (tj. opakovaným odstraňováním krajních pixelů objektu). Postup provádění každého erozního kroku je přitom modifikován tak, aby nedošlo k porušení souvislosti objektu. Tutéž akci lze provést pomocí mat. morfologie nebo pomocí filtrace.

2.1.3. Metody rozpoznávání objektu s využitím neuronových sítí

V souladu se současným trendem aplikovat neuronové sítě jsem se rozhodl i já využít neuronovou síť jako rozpoznávací mechanismus pro modul rozpoznávání zájmových bodů.

a). Neuronové sítě:

- Třívrstvá síť s učením „Back Propagation“

Do vrstvy vstupních uzlů se zavádí jednotlivé složky vektoru příznaků, a proto je vstupních uzlů tolik, kolik je příznaků. Z výstupní vrstvy se odebírá identifikátor třídy. I když jsou možné i jiné způsoby, často se používá kódování 1 z n . V tomto případě je pak počet neuronů ve výstupní vrstvě roven počtu rozpoznávaných tříd. Počet neuronů ve střední skryté vrstvě (případně vrstvách) se zpravidla volí na základě zkušenosti.

- Kompetitivní síť a Kohonenovo učení

Kompetitivní síť je tvořena dvěma vrstvami neuronů, kde spodní reprezentuje vstupní jednotky, které jsou propojeny se všemi neurony vrstvy výstupní, ve které jsou opět všechny neurony vzájemně propojeny. Každý neuron výstupní vrstvy je napojen sám na sebe tzv. *sebeexcitující vazbou* a *inhibičními vazbami* k ostatním neuronům. Tento způsob propojení vede k posilování excitace neuronu, který byl na začátku excitován nejvíce. Nakonec je tento neuron vyexcitován na maximum a ostatní jsou úplně potlačeny (tento jev se nazývá *laterální, postranní inhibice*). Každý neuron pak reprezentuje nějaký objekt nebo třídu objektů ze vstupního prostoru.

b). Rozpoznávání objektu:

Abychom mohli objekty rozpoznávat, musíme je nejdříve popsat. Způsoby popisu je možno rozdělit na několik metod. Potom mluvíme o *syntaktické a příznakové analýze* obrazu.

Syntaktická analýza obrazu používá k popisu objektu posloupností primitiv a jejich hierarchickou strukturou. Vytvořený popis se předkládá analyzátoru, který slouží k samotnému rozpoznávání. Analyzátor používá k rozpoznávání gramatiky. Gramatika musí být známa již před započítím rozpoznávání.

Příznaková analýza obrazu předpokládá, že máme k dispozici popis rozpoznávaného obrazu nebo jeho části ve formě vektorupříznaků $\mathbf{x} = (x_1, x_2, \dots, x_n)^T$. Tyto vektory pak předkládáme k dalšímu zpracování, např. klasifikátoru nebo neuronové síti. Proměnné x_i jsou příznakové proměnné a jejich hodnoty pak nazýváme příznaky. Každý příznakový vektor reprezentuje bod v n-rozměrném prostoru X^n , který je nazván příznakový prostor. Příznakový prostor je definován jako kartézský součin oborů hodnot všech uvažovaných příznakových proměnných. Tj. příznakový prostor X^n je tvořen všemi možnými vektory $\mathbf{x} = (x_1, x_2, \dots, x_n)^T$. V případě, že jsou všechny použité příznakové proměnné spojité, může být prostor X^n Euklidovský.

Protože každý obraz a objekty v něm obsažené mají jiné vlastnosti, velmi záleží na vhodné volbě množiny příznaků. V následujících částech popíšu vybrané příznaky.

Příznaky, které lze použít při rozpoznávání, mohou být např. plocha, momentové atributy, obvod, Eulerovo číslo, nekompaktnost, projekce výšky, šířky, výstřednost, podlouhlost apod. Ve své práci jsem se rozhodl pro implementaci atributu založené na Fourierově transformaci průběhu křivosti hranice objektu.

c). Výpočet Fourierovy transformace průběhu křivosti:

Základem pro výpočet právě popisovaných atributů je určení křivosti hranice objektu. Z diferenciální geometrie víme, že křivost jednoznačně určuje křivku (až na polohu). Tzv. přirozená rovnice křivky je: ${}^1k = {}^1k(s)$, kde ${}^1k(s)$ je průběh první křivosti (předpokládáme práci pouze s rovinnými křivkami).

Výpočet atributu založeného na Fourierově transformaci průběhu křivosti hranice se dá popsat následujícími kroky:

1. nalezení hranice objektu
2. proložení křivek (případně úseček) hranicí objektu
3. určení křivosti hranice objektu
4. Fourierova transformace křivosti hranice objektu

Výsledkem tohoto procesu je vektor obsahující všechny segmenty proložené hranice. Tento vektor dále slouží jako základ pro výpočet Fourierovy transformace.

d). Jasové atributy:

Výsledkem segmentace obrazu jsou extrahované oblasti. Právě k popisu těchto oblastí slouží atributy. Jasové atributy mají tu zvláštnost, že i když jsou tyto oblasti známy, jejich hodnoty jasů ukrývají jisté informace, které lze i dále využít. V následujících částech popíši jednotlivé jasové atributy, které lze implementovat.

• Střední hodnota jasu

Tento atribut udává střední hodnotu jasu na ploše objektu. Jsou dány dva objekty stejného tvaru, velikosti ale každý z nich má jinou úroveň jasu.

Oba dva tyto objekty jsou detekovány metodou segmentace jako testované oblasti. Střední hodnota jasu však tento problém řeší. Jednoznačně odliší tyto objekty od sebe.

$$\mu_b = \sum_{(b)} b \cdot p(b) \quad (2.13)$$

• Směrodatná odchylka jasu

Následující vztah popisuje výpočet atributu směrodatné odchylky jasu. Hodnota atributu udává rozptýlení hodnot jasu na ploše objektu. Využití tohoto atributu uvedu opět na příkladu. Máme dva testované objekty, které mají stejnou střední hodnotu jasu, ale u jednoho z nich jas kolísá a u druhého dosahuje skoro konstantní hodnoty. Použitím tohoto atributu je rozlišení těchto oblastí jasné a snadné.

$$\sigma_b^2 = \sum_{(b)} (b - \mu_b)^2 \cdot p(b) \quad (2.14)$$

Dále jsem implementoval jasové atributy, které jsou statistickými momenty vyšších řádů (šíkmost) a dále atributy počítající energii a entropii. Definici uvedených atributů je uvedena v následujících vztazích.

- **Šíkmost jasu**

$$s_b = \frac{1}{\sigma^3} = \sum_{(b)} (b - \mu_b)^3 \cdot p(b) \quad (2.15)$$

- **Energie jasu**

$$E_b = \sum_{(b)} [p(b)]^2 \quad (2.16)$$

- **Entropie jasu**

$$T_b = -\sum_{(b)} p(b) \log_2(p(b)) \quad (2.17)$$

2.2. Rozpoznávání zájmových bodů

Postup při rozpoznávání zájmových bodů můžeme rozdělit na:

- **Rozpoznávání zájmových bodů přímo ze světelné stopy**

Tento postup je vhodný v případě, kdy nelze měřený objekt dostatečně dobře separovat a proto je nutné postupovat opačně, tzn. určit zájmové body nebo body definující měřený objekt a potom z nich nadefinovat měřený objekt. K tomuto účelu je postupováno tak, že v místech, kde se bude nacházet předpokládaný zájmový bod určíme tzv. zájmovou oblast ve tvaru obdélníku pomocí standardních prostředků (použití myši, zvětšení snímku) anebo použijeme polohu zájmového bodu z předchozího snímku. Zájmovou oblast určujeme přidáním nebo odečtením určitého počtu pixelů po souřadnici x, y. Takto nadefinovaná zájmová oblast obsahuje světelnou stopu, která představuje množinu potenciálních zájmových bodů.


Dále je zpracován obraz zájmové oblasti. K tomu jsou použity prostředky popsané v předchozích kapitolách, tzn. výpočet prahu a prahování oblastí, zpracování binárního obrazu - erose světelné stopy, viz odd.1.5. Takto zpracovaná světelná stopa obsahuje body, které mají nejvyšší jas. Novým zájmovým bodem se stane ten hraniční bod ze světelné stopy, který je nejbližší k výchozímu bodu, z něhož byla vytvořena zájmová oblast, bod o souřadnici X0,Y0. Vizualizace procesu rozpoznávání je uvedena v 1.4 při zpracování důlních snímků. Budeme-li ale měřit objekty, které tvoří souvislou oblast, např. na rentgenových snímcích, postup je obdobný ale s tím rozdílem, že světelná stopa, která vzniká, tvoří souvislé pole.

- **Stanovení zájmových bodů pomocí neuronové sítě**


Tento způsob rozpoznání lze s úspěchem použít v případě, že měřený objekt lze dostatečně dobře separovat. Samotné stanovení zájmových bodů je provedeno tak, že nejdříve je objekt na snímku rozpoznán a potom jsou zpětně z hraničních bodů stanoveny jednotlivé zájmové body rozpoznávaného objektu. I zde musíme nejdříve provést zpracování obrazu. K tomu účelu použijeme prostředky popsané v předchozích kapitolách, tzn. výpočet prahu a prahování obrazu, zpracování binárního obrazu - ztenčení světelné stopy. Tento postup patří do příznakového rozpoznávání. Vstupní vrstva neuronové sítě je tvořena příznaky popisující rozpoznávaný objekt, viz kap. 1.3. Výstupní vrstvu tvoří neurony definující jednotlivé rozpoznávané objekty.

3. Vizualizace procesu určení zájmových bodů

Určení zájmového bodu po prahování a ztenčení zájmové oblasti, viz obr. 2.3a. Novým zájmovým bodem o souřadnici X_{ZB}, Y_{ZB} se stává ten bod, který je nejbližší k výchozímu bodu X_0, Y_0 , viz obr. č. 2.3b.



Obr. č. 2.3a



Obr. č. 2.3b

Obr. č. 2.3: Určení zájmové oblasti

3.1. Vizualizace procesu určení zájmových bodů modulem Fotom5 - 2008


Vizualizace určení zájmových:

Bod - Tento postup demonstruje vyhledávání nejjednoduššího objektu, a to bodu. Na obr. č. 4.13a vlevo je bod, který má stejné souřadnice, jako bod z předchozího měření, vyznačen červeně. Žlutě je vyznačena oblast, kde se bude nový bod vyhledávat. Na obrázku č. 4.13b vpravo je vyznačen nalezený bod – jde o nejbližší bílý bod v dané oblasti.




a) b)
Obr. č. 4.13: Vyhledávání objektu typu bod

Vrchol - je tvořen uspořádanou čtveřicí bodů, kde první dvojice bodů a druhá dvojice bodů definují přímky. Objekt vrchol se pak nachází v průsečíku těchto přímek. Při hledání nového vrcholu se postupně hledají nové body v okolí původních bodů, nový vrchol je pak vytvořen výše popsaným způsobem. Princip vyhledávání objektu typu vrchol je ilustrován na obr. č. 4.15.



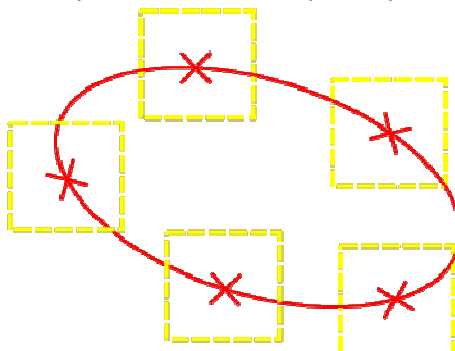
Obr. č. 4.15: Vyhledávání objektu typu vrchol

Kružnice - může být zadán libovolným počtem bodů, větším než tři. Při vyhledávání nové kružnice se postupuje tak, že se nové body hledají paprskovitě na přímkách, které spojují střed původní kružnice a jednotlivé body, kterými byla původní kružnice zadána. Po provedení této analýzy se provede aproximace kružnice pomocí metody nejmenších čtverců, vypočítá se nový střed a poloměr a tyto se zapíší do nového ftm souboru. Postup vyhledávání kružnice je označen na obrázku č. 4.16.




Obr. č. 4.16: Vyhledávání bodů kružnice

Elipsa - je zadána pěticí bodů. Při hledání nové elipsy se hledají nové body v okolí bodů, kterými byla zadána původní elipsa. Po provedení analýzy se spočítá obsah elipsy, její střed, natočení a délka poloos, které se opět zapíší do ftm souboru.



Obr. č. 4.17: Vyhledávání objektu typu elipsa

Polygon - může být zadán libovolným počtem bodů. Vyhledávání tohoto typu objektu se opět provádí paprskovitě po přímkách spojujících těžiště původního polygonu a body, kterými byl zadán. Po vyhledání nových bodů se vypočítá nové těžiště a obsah polygonu.

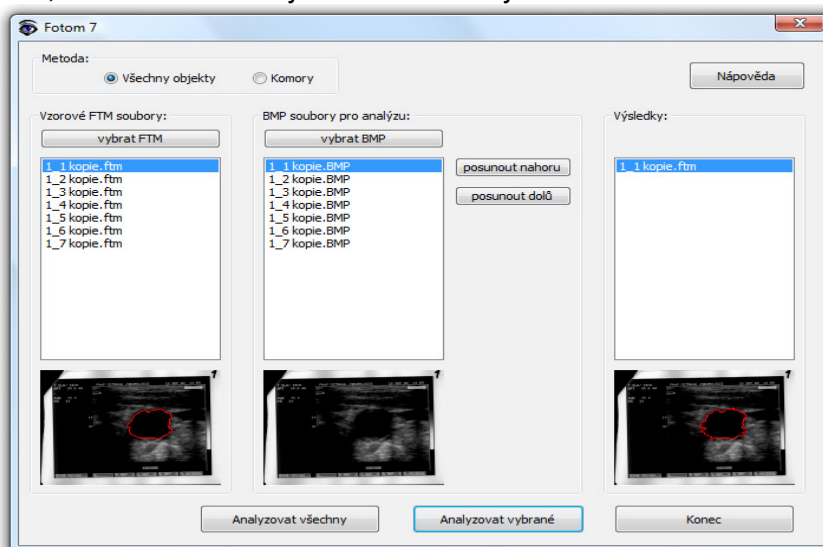


Obr. č. 4.18: Vyhledávání polygonu

3.2. Páce s modulem Fotom5 - 2008

- **Modul Fotom5.1 – 2008**

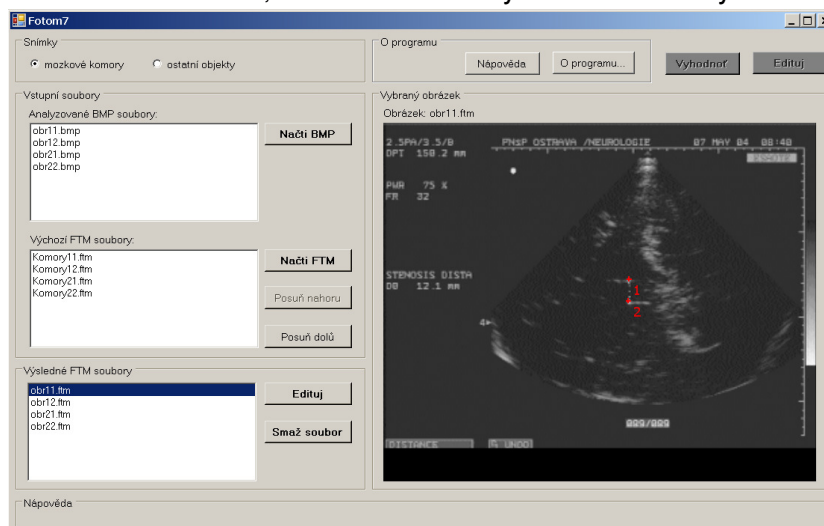
Modul je schopen automaticky detekovat objekty na ultrazvukových a jiných snímcích (Sojka Š. 2008). Automatické rozpoznávání vychází z předpokladu, že máme k dispozici informace o požadovaných objektech z předchozího měření. Po spuštění aplikace se zobrazí hlavní okno, které umožní uživateli vybrat typ snímků, se kterými bude pracovat. Dále musí zadat vstupní BMP soubor, který reprezentuje snímek, na kterém se bude vyhledávat a vstupní FTM soubor, ve kterém jsou uloženy informace o objektech z předchozího měření. Dále jsem v tomto hlavním okně realizovala náhled vybraného BMP snímku a objektů z vybraného FTM snímku tak, aby se uživatel mohl rozhodnout, které BMP snímky se hodí ke kterým FTM snímkům.



Obr. č. 3.1: Rozhrání modulu Fotom5.1

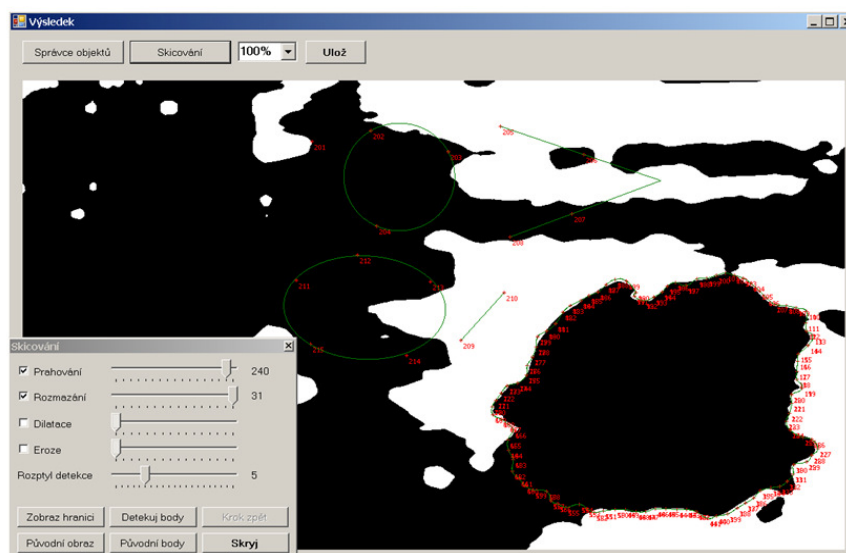
- **Modul Fotom5.2 – 2008**

Modul je také schopen automaticky detekovat objekty na ultrazvukových a jiných snímcích (Uhlářová, E. 2008). Automatické rozpoznávání vychází z předpokladu, že máme k dispozici informace o požadovaných objektech z předchozího měření. Po spuštění aplikace se zobrazí hlavní okno, které umožní uživateli vybrat typ snímků, se kterými bude pracovat. Dále musí zadat vstupní BMP soubor, který reprezentuje snímek, na kterém se bude vyhledávat a vstupní FTM soubor, ve kterém jsou uloženy informace o objektech z předchozího měření. Dále jsem v tomto hlavním okně realizovala náhled vybraného BMP snímku a objektů z vybraného FTM snímku tak, aby se uživatel mohl rozhodnout, které BMP snímky se hodí ke kterým FTM snímkům.



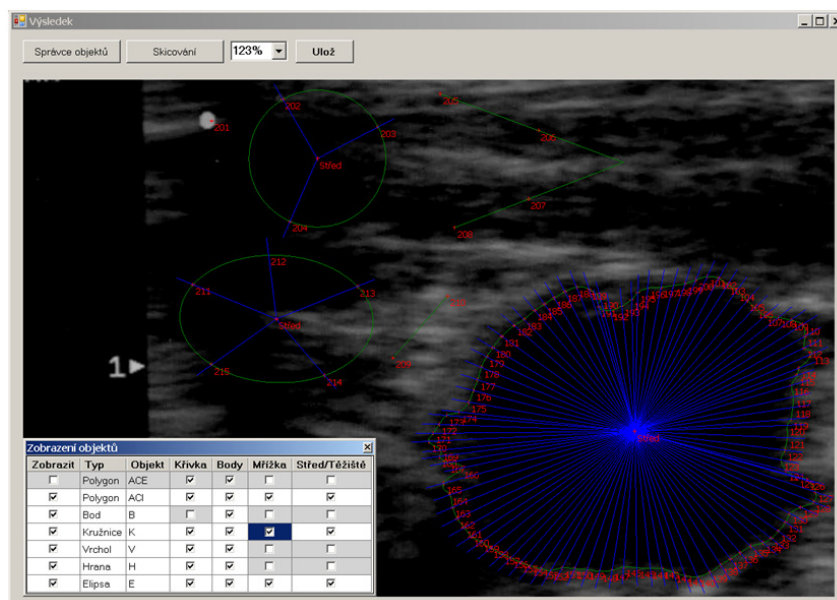
Obr. č. 3.1: Rozhraní modulu Fotom5.2

Další nástroj, který uživateli usnadňuje ruční detekci nových souřadnic bodů, je „Skicování“, které je rovněž spouštěno z editačního okna. Skicování implementuje nástroje potřebné k zpracování vstupního BMP snímku tak, aby pak bylo možné v něm detekovat objekty.



Obr. č. 3.2: Editace snímku.

Nový modul proto umožňuje úpravu výsledných objektů z nově vygenerovaného FTM snímku či poopravení výchozích FTM snímků tak, aby pomocí nich bylo vyhledávání realizovatelné. Tato úprava znamená měnit souřadnice jednotlivých bodů objektů. Změny je možno provést v editačním okně nového modulu.



Obr. č. 3.2: Editace bodů a objektů na snímku.

4. Závěr

Rozpoznávání zájmových bodů na snímku je činnost velmi důležitá, neboť na ni záleží efektivnost a rychlost zpracování fotografické informace. V předloženém příspěvku byly popsány metody a způsoby, jak rozpoznávat zájmové body nebo měření objekt a následně stanovení jejich souřadnic.

Výše uvedené metody a algoritmy jsou ověřeny. V současné době jsou tyto moduly součástí fotogrammetrického systému FOTOM 2008 vyvinutého na Katedře informatiky FEI VŠB TU v Ostravě.

Vývoj fotogrammetrického systému FOTOM 2008 přispívá k vyřešení konkrétních požadavků, kladených na jedno snímkovou fotogrammetrii jako ucelený systém na kvalitativně vyšší úrovni, než jsou stávající technické a softwarové prostředky.

Literatura

- Ličev, L. a Holuša T. 1998. Nové řešení důlní fotogrammetrie na PC, 2/1998, URGP Praha.
- Ličev, L. 1998. New approaches to mining photogrammetry using PC, 5 nacionalna konferencija Varna '98, MGU Sofia.
- Ličev, L. a Holuša T. 1999. Fotogrammetrické měření důlních jam, Konference GIS'99 VŠB TUO, HGF.
- Ličev, L.: Fotogrammetrie na PC, 4/1999, Acta montanistica slovaci, Košice.
- Ličev, L.: 2001. Razpoznavane na interisuvaštite točki i obekti na snimkaga. Konference SGEM'2001 Varna, MGU Sofie.
- Ličev, L.: 2001. Fotogrammetrični sistemi i vizualizacija na procesa na merene. Konference SGEM'2001 Varna, MGU Sofie.
- Serra, J. 1982. Image Analysis and Matematical Morphology, Vol. 1, Academic Press, New York
- Serra, J. 1988. Image Analysis and Matematical Morphology, Vol. 2, Academic Press, New York

Sojka, E. 1999. Digitální zpracování obrazu, skripta VŠB - TUO, FEI.

Sojka, Š. 2008. Počítačové zpracování snímků ultrazvuku mozkových komor, diplomový projekt, VŠB - TUO, FEI

Šmidrkal, J. 1985. Fotogrammetrie I,II,III - Teoretické základy, ČVUT Praha.

Uhlářová, E. 2008. Rozpoznávání objektů na snímcích ultrazvuku, diplomový projekt, VŠB - TUO, FEI.