

MODERNÍ OBRAZOVÉ METODY PRO SLEDOVÁNÍ A KONTROLU ŽELEZNIČNÍHO PŘEJEZDU

MODERN IMAGE METHODS FOR RAILWAY CROSSING MONITORING AND CHECKING

Zdeněk Šilar¹

Anotace: Obsahem tohoto článku je popis a porovnání zabezpečovacích zařízení používaných na železničních přejezdech v České republice a doporučení dalších moderních metod.

Klíčová slova: Zabezpečení železničních přejezdů, kamerové systémy, zpracování obrazové informace, předzpracování obrazu, segmentace obrazu, rozpoznávání obrazu

Summary: The content of this article is the description and comparison of security equipments used on railway crossings in the Czech Republic and recommendation of other modern methods.

Key words: Railway crossings security, camera systems, image processing and preprocessing, image segmentation, image recognition

1. ÚVOD

Počet nehod na železničních přejezdech stále přibývá. Většina nehod byla způsobena pouze a jen účastníky silničního provozu, a to nedovoleným vjezdem na železniční přejezd v důsledku porušení zákona č. 266/1994 Sb. o dráhách a zákona č. 361/2000 Sb. o provozu na pozemních komunikacích. Tento zákon jednoznačně stanovuje povinnosti řidičů při přejíždění železničních přejezdů. Přitom nejdůležitější je pravidlo, že vlak má vždy přednost a řidič se musí přesvědčit, zda může přejezd bezpečně přejet. Jednou z možností jak zabránit zvyšování nehodovosti je zlepšit stávající stav zabezpečení železničních přejezdů.

2. STÁVAJÍCÍ ZABEZPEČENÍ ŽELEZNIČNÍCH PŘEJEZDŮ

Z 8 389 železničních přejezdů (evidováno Správou železniční dopravní cesty (SŽDC) ke dni 31. 12. 2006 [1]) je 4 734 (56 %) nezabezpečených (řidiči jsou v jízdě omezeni pouze výstražným křížem, kde zabezpečení je nulové). „Nejlepší“ ochranu – automatické světelné zařízení (PZZS – přejezdové zabezpečovací zařízení světelné) a závory má pouze 988 přejezdů (12 %). Zbytek tvoří samotné PZZS (31 %). 1 % stále připadá na samotné mechanické závory.

Železniční přejezdy svou samotnou existencí ohrožují bezpečnost jak železniční, tak silniční dopravy. Proto je ze strany SŽDC stále vyvíjen tlak na snižování počtu málo

¹ Ing. Zdeněk Šilar, Univerzita Pardubice, Fakulta elektrotechniky a informatiky, Katedra informačních technologií, Studentská 95, 53210 Pardubice, Tel.: +420 46 603 6761, E-mail: zdenek.silar@upce.cz

frekventovaných železničních přejezdů, výstavbu koridorových tratí a modernizaci a zabezpečení ostatních železničních přejezdů pomocí moderních metod.

3. MODERNÍ METODY PRO ZABEZPEČENÍ ŽELEZNIČNÍCH PŘEJEZDŮ

V okamžiku, kdy výše uvedená zabezpečovací zařízení sice pracují správně, ale na kolejích se v kritickém okamžiku přesto nachází nežádoucí objekt (vozidlo, osoba), či jiný nedefinovaný objekt), nastávají problémy. K detekci nežádoucích objektů je v těchto případech možné využít dalších v současné době používaných technologií – metod.

3.1 Induktivní smyčky

Princip je založen na detekci magnetického materiálu v blízkosti smyčky v podobě změny indukovaného napětí. Smyčka je realizována drátem ukrytým pod vozovkou v prostoru přejezdu. Toto řešení je využíváno celkem málo a to hlavně z důvodu problematické údržby či odstraňování poruch, kdy je nutné provádět práce na vozovce. Další nevýhodou je detekce pouze magnetických materiálů – nelze tedy dobře detekovat hliníkové, plastové, dřevěné, či jiné objekty včetně osob a zvířat.

3.2 UWB radary

UWB (Ultra Wide Band) radary pracují se signálem, jehož šířka frekvenčního pásma s poklesem o 10 dB je větší než 500 MHz, nebo přesahuje 20 % rozsahu střední frekvence [2]. Detekce pomocí UWB radarů je možná na základě dvou principů:

- Přerušením vysílaného signálu
- Detekcí ve sledované oblasti přejezdu (vhodné pro UWB radary)

Detekce *přerušením vysílaného signálu* je založena na principu vysílání paprsku, který se odráží od odrazné plochy umístěné na protější straně přejezdu. Pokud je tento paprsek přerušen, dojde k poklesu výkonu odraženého paprsku a tím i k detekci objektu v přejezdu.

Detekce *ve sledované oblasti přejezdu* pracuje na principu sledování celé oblasti, kdy po vjezdu objektu do sledovaného prostoru dojde k odražení elektromagnetické vlny od objektu a tím k jeho detekci. Výhodou této metody je detekce objektu v jakémkoliv místě sledovaného prostoru a schopnost pracovat za jakéhokoliv počasí.

3.3 Kamerové systémy

V tomto případě je myšlen venkovní systém sestavený minimálně z jedné průmyslové kamery, který snímá určenou lokalitu a je připojen např. pomocí FireWire nebo GSM technologie k serverům, kde dojde k vyhodnocení obrazové informace.

Současné kamerové systémy se používají pro sledování a zabezpečení nejrůznějších objektů (pozemků, bank, muzeí, galerií, benzínových pump, parkovišť, letišť atd.) [3]. Velkou nevýhodou je, že tyto systémy jsou z větší části odkázány na lidský faktor. Navíc nepracují plně spolehlivě za jakéhokoliv počasí. To je právě nutné pro zabezpečení železničních přejezdů. Moderní možné řešení popisuje následující kapitola.

3.4 Metody pro zpracování obrazu

Obrazová informace dnes představuje jeden ze základních komunikačních a informačních kanálů a její zpracování se v současné době stává mocným a rychlým nástrojem. V našem případě se konkrétně jedná o rozšíření vhodného *kamerového systému* o počítačové zpracování obrazové situace, získané např. z oblasti železničního přejezdu, a o automatické vyhodnocení této situace. Pod pojmem *zpracování obrazové situace* se myslí rozpoznání nežádoucích objektů pomocí metod pro segmentaci a rozpoznávání obrazu pořízeného stacionární kamerou v oblasti železničního přejezdu.

Problematika zpracování obrazu je velmi rozsáhlá a lze ji rozdělit do následujících po sobě jdoucích kroků [4]:

- Snímání a digitalizace obrazu
- Předzpracování obrazu
- Segmentace obrazu
- Porozumění obsahu obrazové informace

V následujících kapitolách je popsán současný stav a možnosti v oblasti zpracování obrazové situace. Hlavní důraz je kladen na předzpracování obrazu, následnou segmentaci a rozpoznání obrazu.

4. SNÍMÁNÍ A DIGITALIZACE OBRAZU

Snímanou vstupní informací (z digitální kamery) může být jas nebo (při barevném snímání) RGB spektrální složky [5]. Vstupní analogový signál je popsán tzv. *obrazovou funkcí* dvou proměnných $z = f(x, y)$, kde funkční hodnota odpovídá např. jasu. Signál je potom vzorkován a kvantován – digitalizován pomocí CCD nebo CMOS snímačů a A/D převodníků přímo v digitální kameře. Výsledkem digitalizace je matice přirozených čísel (obrazových bodů - pixelů) reprezentující obraz.

5. PŘEDZPRACOVÁNÍ OBRAZU

Předzpracování obrazu je nezbytným krokem, pomocí něhož předejdeme negativním jevům, které by se projevily při dalším zpracování obrazu. Úkolem je získat kvalitní obraz pro následnou segmentaci. To znamená úplně odstranit nebo alespoň potlačit některé často se vyskytující degradace obrazu.

Deterministické chyby (viz dříve např. vady optiky) jsou eliminovány stále kvalitnější optikou případně odstraněny elektronikou kamery, která obsahuje korekční a filtrační obvody. Tzv. kvantizační chyba A/D převodníku (kvantizační šum) je v současné době do značné míry minimalizována použitím snímačů s vysokou citlivostí (zejména při nočním snímání). Data jsou komprimována pomocí diskrétní kosinové transformace (DCT) a uložena v plném rozlišení na kazetu nebo pevný disk. Odtud mohou být přenesena do počítače k dalšímu *předzpracování*.

Na výstupu z kamery stále není kvalitní a požadovaný obrazový signál. Ten je poškozen tentokrát *stochastickými jevy*. Jedná se zejména o náhodný aditivní šum, nerovnoměrné osvětlení, rozmazání snímků nebo jiná zkreslení vzniklá při snímání. K minimalizaci těchto

jevů a pro případné dodatečné úpravy obrazu (změny velikosti, rozlišení, barevné palety atd.) se používají různé typy softwarových filtrací a transformací. V následujících kapitolách budou popsány vybrané transformační metody, které již upraví obraz na požadovanou kvalitu potřebnou pro další zpracování *segmentačními metodami*. Pro zpřehlednění je možné transformace obrazu rozdělit do následujících skupin [4].

5.1 Geometrické transformace

Geometrické transformace obrazu popisují transformace souřadnic obrazových bodů, např. posunutí, změna měřítka, zkosení, rotace či složitější operace, které jsou potom realizovány skládáním výše popsaných základních transformací. Téměř u všech geometrických transformací dochází k degradaci obrazové informace. Se změnou měřítka se mění velikost obrazu a je tedy nutné znovu obraz převzorkovat. Navíc koeficienty změny měřítka mohou být reálná čísla. Je tedy třeba použít vhodné interpolační algoritmy (interpolace nejbližším sousedem, bilineární nebo bikubická interpolace, Parzenovo okno atd., jejichž součástí je *konvoluce*) pro přepočítání nových poloh pixelů. To se týká i rotací, kde se nově vypočítané polohy pixelů nemapují přesně do pozic pixelů v původní matici obrazu.

5.2 Transformace barev a jasů

Pod pojmem *transformace barev* rozumíme zejména snižování – redukci barev. Pokud omezíme počet barev, dojde automaticky ke ztrátě informace. Při snižování barev se původní barvy nahradí nejbližší barvou z použité barevné palety. Razantní redukce barev má za následek vznik barevných ploch s ostrými přechody. V takovém případě je možné použít techniku zvanou *dithering*, kdy se namísto jednolitě barevné plochy použijí střídající se různobarevné body tak, aby při běžném pohledu vznikl dojem požadovaného odstínu barvy.

Pod *transformací jasů* si můžeme představit zesvětlení nebo ztmavení obrazu (zvýšení nebo snížení výkonu obrazového signálu). Jedná se o aritmetické operace přičítání/odčítání a násobení/dělení (je progresivnější) obrazové matice konstantou. Transformace je stejná pro všechny pixely obrazu.

5.3 Diskrétní lineární integrální transformace

Tyto transformace se v současné době řadí mezi klasické techniky pro zpracování obrazu [6]. Jejich základní postupy vycházejí z teorie signálů. Existují dvě ekvivalentní cesty s použitím lineárních filtrů.

5.3.1 Filtrace ve frekvenční oblasti

Cesta filtrace ve frekvenční oblasti je názornější a pro její realizaci se používá celá řada transformací, z nichž nejznámější je, v oblasti zpracování jak signálů, tak i obrazu, *diskrétní Fourierova transformace*.

Dalšími transformacemi, které se při zpracování obrazu používají, jsou např. [4] *diskrétní kosinová transformace*, jejíž hlavní výhodou je reálné spektrum. Tato transformace se používá např. při ztrátové kompresi obrazu do JPEG formátu. Na rozdíl od Fourierovy

transformace jsou bázovými funkcemi „kosinusovky“. Koeficienty DCT lze potom vypočítat pomocí rychlé Fourierovy transformace FFT [6]. Také naprostá většina kodeků pro ukládání videesignálu pracuje s využitím DCT.

Další oblíbenou integrální transformací pro analýzu obrazu je „vlnková“ (*Wavelets*) transformace umožňující ze signálu získat jeho *časově-frekvenční popis*. Ideou „vlnkové“ transformace je dosáhnout optimálního poměru rozlišitelnosti v čase a frekvenci pomocí vhodné změny šířky "okna" (mateřské funkce) a typem a frekvencí použité bázové vlnky. V současnosti existuje kolem 400 používaných vlnek, které jsou vhodné pro různé úlohy [8]. Vlnkové transformace se v oblasti zpracování obrazu používá pro analýzu, kompresi dat (JPEG2000), potlačování šumu a pro popis obrysu objektů.

Dále jsou používány *Hadamardova*, *Haarova*, *Walshova* a případně další integrální transformace.

5.3.2 Filtrace v prostorové oblasti

Tyto filtrace zpracovávají obraz jako lineární kombinaci vstupního obrazu s koeficienty filtru. Konkrétně se jedná o aplikace tzv. *konvolučních filtrů*, které se používají jak v oblasti *lineárních* tak i *nelineárních transformací* pro úpravy obrazů [4].

V následujících kapitolách jsou uvedeny často používané metody a analogicky srovnány s filtry frekvenčními.

5.3.3 Filtrace šumu, vyhlazování obrazu

Velmi častým úkolem v oblasti zpracování obrazu je problematika odstranění šumu. Odstranění šumu může být realizováno např. konvolucí obrazu s vhodnou konvoluční maticí. Konvoluční maticí je nejčastěji filtr ve frekvenční oblasti typu *dolní propust*. Ta odstraňuje z obrazu složky vyšších prostorových frekvencí – tedy šum, ale bohužel i detaily (rozmazání, ztráta hran). Další možností, jak vyhladit obraz, je použít matici, v níž váhy pixelů odpovídají tzv. Gaussovu rozložení [6]. Výsledný efekt vyhlazení je na obr. 1.



Zdroj: [Autor]

Obr. 1 – Vyhlazování obrazu (Gaussian-Blur) programem *Filtry*

5.3.4 Zaostření obrazu

Principem zaostření je „mírné“ zvýraznění hran. Ve frekvenční oblasti se jedná o *horní propust*, která naopak odstraňuje z obrazu nižší kmitočty, což má za následek zaostření obrazu. Výsledek této filtrace je na obr. 2.



Zdroj: [Autor]

Obr. 2 – Zaostření obrazu (Sharpening) programem *Filtry*

5.4 Nelineární transformace

Lineární metody detekce hran (*ostření*) a vyhlazování (*rozmazávání* detailů - hran) jsou naneštěstí v protikladu. Proto byly navrženy a jsou dále rozvíjeny *nelineární metody*, které např. dobře vyhlazují, ale jsou stále šetrné k hranám. Původ těchto metod je v tzv. *robustní statistice*. Největším problémem lineárních metod (pracujících na principu aritmetického průměrování) při odstraňování šumu je tzv. „vychýlený“ odhad. Ten může vzniknout, když při měření více hodnot nastane při jednom měření hrubá chyba. Ta potom silně ovlivní i celý průměr měření. Cílem *nelineárních metod* je nalezení těchto „vychýlených“ hodnot a jejich vyloučení z dalších výpočtů. To je možné dosáhnout nasazením dalších, *vyhledávacích* algoritmů.

5.4.1 Filtrace mediánem

Nejjednodušším a nejpoužívanějším způsobem použití nelineárních metod je *filtrace mediánem*. Tato metoda stanoví jas výsledného pixelu jako medián určený z hodnot v malém lokálním okolí (např. pomocí pomyslné matice 3x3 nebo 5x5) měřeného pixelu vstupního obrazu (v tomto případě se nejedná o konvoluci).

Na obr. 3 je výsledek filtrace mediánem² obrazu (nutně šedotónového) porušeného náhodným šumem typu *salt & pepper*.



Zdroj: [Autor]

Obr. 3 – Filtrace mediánem (originální obraz, uměle porušený, po filtraci)

6. SEGMENTACE OBRAZU

Jedná se o důležitý a také velmi složitý krok analýzy obrazu, který dokáže ve vhodně předzpracovaném obraze rozlišit a oddělit jednotlivé objekty, které „nás zajímají“. V našem

² Tento i další výsledky filtračních a segmentačních metod byly realizovány v programu Matlab.

případě se bude jednat o tzv. „nežádoucí objekty“ na železničním přejezdu. Informaci o rozdělení obrazu do jednotlivých segmentů využívají potom vyšší algoritmy zpracování obrazu, snažící se porozumět obsahu obrazu. Konkrétním úkolem může být detekce přítomnosti příslušného objektu nebo nalezení a klasifikace objektů v obraze.

V průběhu let bylo vypracováno a navrženo velké množství obecných segmentačních metod [7]. Pro přehlednost a podle obtížnosti a početní náročnosti můžeme rozdělit segmentační metody následovně (z důvodu velkého množství a rozsahu budou uvedeny a porovnány v současné době nejpoužívanější a nejznámější metody).

6.1 Nízkoúrovňové hranové detektory

I když jsou hranové detektory svou povahou lineární lokální filtry, můžeme je zahrnout mezi tzv. *nízkoúrovňové* segmentační techniky. Hranové detektory [4] patří do skupiny algoritmů pro detekci nespojitostí.

Hrany (hranice objektů) v obraze odpovídají prudkým změnám hodnot jasu. Tyto změny jasu se dají detekovat pomocí prvních a druhých derivací intenzity jasu. Nízkoúrovňové segmentační techniky (také nazývané *edge-based metody*) se tedy dále dají rozdělit do dvou skupin – metody využívající *první* nebo *druhou* derivaci hrany v diskretním obraze.

6.1.1 První derivace, gradient

Pro spojitou obrazovou funkci definujeme velikost gradientu a směr gradientu ψ (je kolmý na hranu) dle následujících vztahů:

$$|\nabla f(x, y)| = \sqrt{\left(\frac{\partial f}{\partial x}\right)^2 + \left(\frac{\partial f}{\partial y}\right)^2} \quad (1)$$

$$\psi = \arg\left(\frac{\partial f}{\partial x}, \frac{\partial f}{\partial y}\right) \quad (2)$$

V digitalizovaném obraze potom můžeme aproximovat parciální derivace *diferencemi*:

$$\Delta_j f(j, k) = f(j, k) - f(j - n, k) \quad (3)$$

$$\Delta_k f(j, k) = f(j, k) - f(j, k - n) \quad (4)$$

kde n je celé malé číslo, obvykle $n = 1$.

Tyto vztahy jsou při praktickém použití obvykle realizovány aplikací tzv. hranových operátorů - *konvolučních jader* – matic. Jednotlivé hranové detektory se pak liší jádrem konvolučního filtru, které udává, jaké body se pro výpočet gradientu použijí a jaké budou mít váhy. Vlastnosti filtru, jeho velikost a hodnoty významně ovlivňují výsledné vlastnosti hranového detektoru. Tzv. gradientní obraz tedy získáme konvolucí mezi originálním obrazem a jádrem filtru.

Nejběžnějšími jsou masky 3x3 a z nich jsou nejznámějšími operátory *Laplaceův* (je všesměrový, velmi citlivý na šum a více se uplatní při druhé derivaci), *Sobelův*, *Robinsonův*, *Kirschův* a operátor *Prewittové*, který podobně jako předchozí operátory odhaduje gradient

v okolí 3x3 pro osm směrů (osm konvolučních masek). Menší citlivost na šum mají potom jádra 5x5 a 7x7, které jsou ale výpočetně náročnější.

6.1.2 Druhá derivace, Laplaceův operátor

Při detekci hran pomocí *druhé derivace* se využívá detekce průchodu nulou. Jedním z operátorů využívajících druhou derivaci je tzv. všesměrový Laplaceán ∇^2 , který je výpočetně méně náročnější (absence odmocniny):

$$\nabla^2 f(x, y) = \frac{\partial^2 f(x, y)}{\partial x^2} + \frac{\partial^2 f(x, y)}{\partial y^2} \quad (5)$$

V diskrétním případě můžeme výše uvedený vztah aproximovat vztahem:

$$\nabla^2 f(j, k) \approx f(j+1, k) + f(j-1, k) + f(j, k+1) + f(j, k-1) \quad (6)$$

Druhá derivace představuje *rychlost* změny hodnot jasu a projeví se hlavně na strmých nebo izolovaných hranách nebo ji lze použít pro detekci izolovaných bodů. Laplaceův operátor je bohužel opět citlivý na šum. Jeho užití může způsobit nalezení dvojitého hran, není schopen určit směr hrany. Další nevýhodou metod druhé derivace detekujících průchod nulou je ztráta ostrých rohů a sklon vytvářet uzavřené smyčky hran.


6.1.3 Operátor Laplacian of Gaussian (LoG)

Přes výše uvedené nevýhody můžeme Laplaceův operátor celkem úspěšně použít v kombinaci *Gaussova a Laplaceova operátoru (LoG)*. Potom filtrací Gausiánem umožníme malé rozmazání obrazu a pro následný odhad druhé derivace můžeme použít Laplaceán ∇^2 . Díky linearitě obou operací můžeme zaměnit pořadí konvoluce a derivace a odvodit tak výslednou funkci – konvoluční jádro dle vztahu:

$$\nabla^2 h(r) = -\frac{r^2 - 2\sigma^2}{2\pi\sigma^4} e^{-\frac{r^2}{2\sigma^2}} \quad (7)$$

kde $r^2 = x^2 + y^2$, r je tzv. Euklidovská vzdálenost od středu Gausiánu; σ je tzv. středně kvadratická odchylka, která udává, na jak velkém okolí filtr operuje a pomocí níž se určuje rozměr konvolučního jádra – čtvercové matice o rozměru n .

Na obr. 4 je použití LoG pro $\sigma = 2$, ($n = \text{ceil}(\sigma * 3) * 2 + 1 = 13$).



Obr. 4 – Hrana a její první a druhá derivace

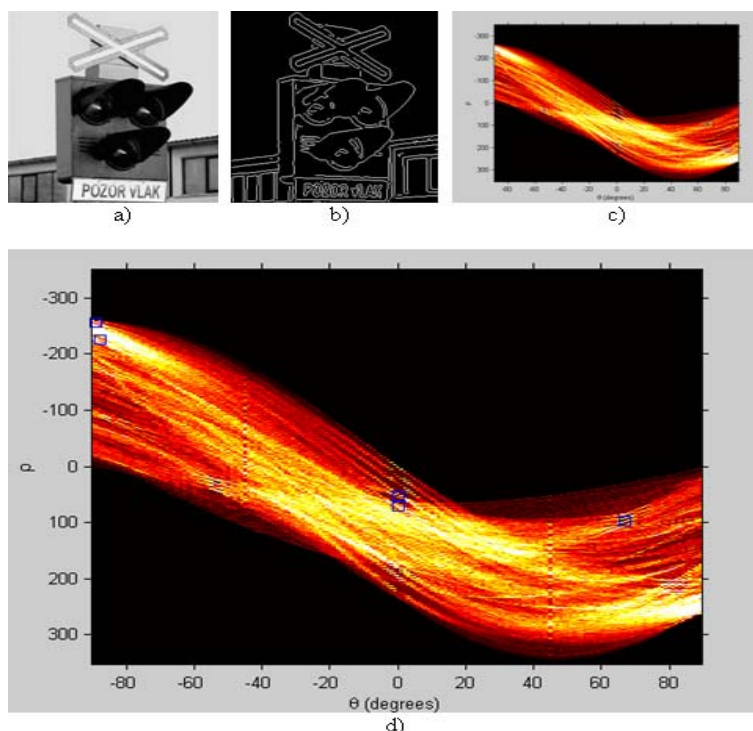
Zdroj: [Autor]

6.2 Houghova transformace

Úkolem Houghovy transformace je nalezení jakéhokoliv analyticky vyjádřitelného útvaru, např. rovinných přímek a kružnic, které je možné popsat parametricky, v obraze [9]. Principiálně se jedná o transformaci z kartézského souřadnicového systému do polárního. Vztah (8) je parametrickým vyjádřením přímky v rovině.

$$r = x \cos\theta + y \sin\theta \quad (8)$$

V praxi se úlohy řeší tak, že se originální obraz převede na „šedotónový“. Dále se na něj aplikuje např. *Cannyho detektor* (je kvalitnější než *Laplacian of Gaussian*). Na takto předzpracovaný a vyfiltrovaný obraz (pouze černobílý) se již může aplikovat HT (obr. 5).



Zdroj: [Autor]

Obr. 5 – Ukázka Houghovy transformace úseček

Obr. 5c) zobrazuje výsledek (tzv. *akumulátor*) HT (sinusovky a kosinusovky), obr. 5d) pomocí „čtverečků“ zobrazuje vyhledaná lokální maxima na souřadnicích (r, θ) . Dále by následovalo vyhledání příslušných přímek a jejich vyznačení, což je již snadno řešitelné pomocí numerických algoritmů.

Velkou výhodou této metody je její rychlost a robustnost, kdy segmentace není příliš citlivá na porušená data nebo šum. V současné době se HT často používá k vyhledávání jednoduchých tvarů – úseček nebo kružnic.

6.3 Techniky hledání oblastí (Region-Based)

Tyto metody detekují v obraze namísto hran tzv. homogenní oblasti - regiony. Každá oblast musí být spojitá a jednotlivé oblasti se nesmějí překrývat. Kritériem homogenity je např. úroveň šedi, barva, tvar, textura, model atd. Metody se používají v případech hodně „zašuměného“ obrazu, kdy hranové detektory selhávají.

6.3.1 Metoda šíření oblasti (Region Growing)


Metoda šíření oblasti je teoreticky nejjednodušším postupem: sousední pixely s podobnou amplitudou jsou seskupovány k sobě a vytváří segmentovanou oblast. V praxi jsou ovšem pravidla řídicí seskupování o dost složitější. Při segmentaci jsou nejdříve vytvořeny atomické oblasti pomocí kvantizovaných hodnot pixelů. V následujícím kroku jsou odstraňovány slabé hrany mezi atomickými oblastmi, tj. oblasti jsou spojovány do větších celků, jsou-li splněna definovaná kritéria.

Jednotlivé metody se mohou lišit pravidly pro počáteční rozdělení oblastí i kritérii pro jejich následné spojování. Jedním z kritérií může být např. síla společné hranice mezi sousedními oblastmi. Je-li hranice slabá, může být tzv. rozpuštěna a oblasti se spojí. Pro testování síly hrany se používá tzv. super-grid, který navíc obsahuje informace o rozdílu hodnot sousedních pixelů.

6.3.2 Metoda dělení a spojování oblasti (Region Splitting and Merging)

Tato metoda *dělení a spojování* rozdělí původní celý obraz do samostatných oblastí (opak předchozí metody). Obraz je postupně rozdělován a nově vzniklé oblasti jsou testovány na podmínku homogennosti (např. stejná barva nebo odstín šedi). Pokud je podmínka splněna, oblasti se sloučí a dále se nedělí. Pokud podmínka splněna není, podoblasti se dělí dál.


Nejpoužívanějším způsobem je postupné dělení obrazu na čtverce (je výpočetně nejefektivnější) a následný popis pomocí struktury, která se nazývá čtyřstrom. Algoritmus se jmenuje *Quadtree Decomposition* a jeho princip je naznačen na obr 6.



Obr. 6 – Quadtree dekompozice

Zdroj: [Autor]

Na obr. 7 je ukázka reálné aplikace metody *Splitting and Merging*.



Obr. 7 – Aplikace Splitting and Merging

Zdroj: [Autor]

6.4 Statistické metody

Základem těchto segmentačních metod je statistická analýza obrazových dat - nejčastěji hodnot pixelů.

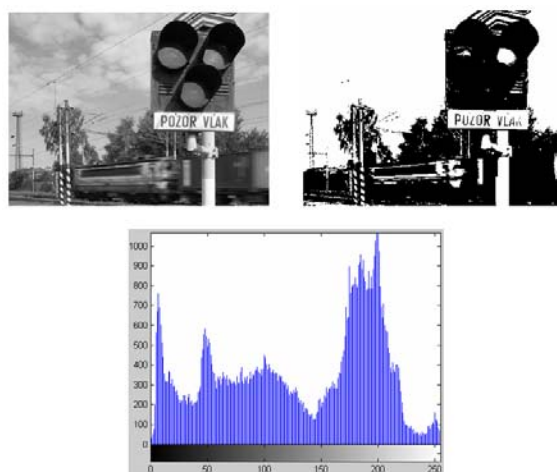
6.4.1 Prahování (Thresholding)

Jedná se o jednu z nejstarších, ale stále nejrychlejších segmentačních technik a používá se k převedení obrazu s více úrovněmi jasu (šedotónového) na obraz, ve kterém se vyskytují dvě i více (n) jasových úrovní. Bodům s hodnotou jasu větší než určitá hodnota (tzv. *prahová*) se přiřadí hodnota 1 (případně 255) a ostatním bodům je přiřazena 0. Prahování můžeme tedy definovat vztahem:

$$p(x,y) = \begin{cases} 1 & \text{pro } f(x,y) \geq T \\ 0 & \text{pro } f(x,y) < T \end{cases} \quad (9)$$

kde $p(x,y)$ je obrazová funkce vypočítaná prahováním původního obrazu.

Hodnoty prahu T je možné určit interaktivně (pokusně z histogramu) nebo pomocí některé z metod automatického určování prahu (např. pomocí *Otsuovy metody* [10] pro hledání lokálního minima v histogramu obrazu). Příklad originálního obrazu, jeho histogramu a prahovaného obrazu je na obr. 8.



Zdroj: [Autor]

Obr. 8 – Prahování pomocí histogramu

Prahování může být *globální* nebo *lokální*. U globálního prahování je hodnota prahu T konstantní pro celý analyzovaný obraz. Jde o jednoduché prahování a používá se v případech, kdy úroveň jasu pozadí je přibližně konstantní. V reálných případech však toto neplatí a použije se lokální prahování (někdy nazývané *adaptivní prahování*). Obraz je nejdříve rozdělen do několika částí. Pro každou část je potom nalezen práh (prahy jednotlivých oblastí mohou být interpolovány). Nakonec se provede prahování pro každou část s jejím konkrétním prahem. Toto prahování již poskytuje mnohem lepší výsledky.

Metody prahování jsou vhodné zejména pro obrazy, které obsahují plné objekty nad kontrastním pozadím. V případě použití prahování při detekci objektů na železničním přejezdu by mohlo dojít k selhání této metody, např. při nerovnoměrném osvětlení vozovky

(vlivem počasí a denního nebo nočního času) nebo nehomogenním povrchem přejezdu. Proto se tato segmentační metoda nejčastěji kombinuje s pokročilejšími technikami.

6.5 Hybridní metody

6.5.1 Neuronové sítě

Téměř všechny výše popsané segmentační metody jsou založeny na definovaných algoritmech, znalostech a zkušenostech, podle kterých tyto metody probíhají. Opakem těchto deterministických postupů jsou např. *neuronové sítě* (Neural Network – NN)], které využívají svou hlavní schopnost - učit se (tzv. *trénování*) a které se v současné době prosazují i na poli zpracování obrazové informace.

Aplikace neuronových sítí v oblasti zpracování obrazu je vzhledem k lineární separabilitě problému obrazového vyjádření objektů typickou a velmi vhodnou aplikací. Na rozdíl od deterministických postupů popsaných výše, je však výsledek vždy spojen s menší, či větší nejistotou, která je v systémech s NN inherentní a těžko predikovatelná.

Pro dosažení uspokojivých výsledků aplikace neuronových sítí je nutná dokonalá a rozsáhlá předpříprava dat, trénovacích, testovacích a validačních množin. Výsledek je také silně ovlivňován použitým typem neuronové sítě a použitým modelem neuronu [7].

6.5.2 Matematická morfologie

Morfologie je obecně nauka o tvarech [11]. V digitálním zpracování obrazu se jedná o matematický nástroj pro *předzpracování* obrazu, jeho *segmentaci* i *kvantitativní popis* nalezených objektů v obraze. Matematická morfologie (MM) tedy zasahuje téměř do všech etap zpracování obrazové informace.


MM obsahuje řadu operací pro zpracování digitálního obrazu (odstranění šumu, odstranění drobných artefaktů, zjednodušení tvaru, zdůraznění struktury, optimální rekonstrukce porušeného tvaru atd.). Tyto operace jsou hardwarově nenáročné a jsou snadno realizovatelné.

Morfologická operace-transformace je relace mezi obrazem X a tzv. strukturálním elementem B . Následují definice nejdůležitějších morfologických operací pro *binární obrazy* (černobílé, 2D prostor), které lze zobecnit i pro *šedotónové*.

Dilatace (vztah 10, obr. 9):

$$X \oplus B = \{p \in E^2, p = x + b, x \in X, b \in B\} \quad (10)$$

kde $p = x + b$ je tzv. Minkowského množinový součet (p je bod). Po dilataci jsou objekty zvětšeny, což znamená, že k objektu jsou přidány body dle velikosti a tvaru zvoleného elementu.




Zdroj: [Autor]

Obr. 9 – Morfologická dilatace

Eroze (vztah 11, obr. 10):

$$X \ominus B = \{p \in E^2, p + b \in X \text{ pro každé } b \in B\} \quad (11)$$




Zdroj: [Autor]

Obr. 10 – Morfologická eroze

Objekty se po provedení eroze zmenší. Složitější objekty tak budou rozděleny.

Obrys (obr. 11) – získáme odečtením erodovaného obrazu od původního.



Zdroj: [Autor]

Obr. 11 – Obrys pomocí eroze

Při znalosti dilatace a eroze lze potom odvodit i další používané transformace - *otevření* (eroze následovaná dilatací) a *uzavření* (dilatace následovaná erozí).

MM má v současné době na poli zpracování obrazu široké uplatnění, zejména v oblasti rozpoznávání znaků a dokumentů, v geologii, medicíně i dopravě.

7. POROZUMĚNÍ OBSAHU OBRAZOVÉ SITUACE

Porozumět obsahu obrazové situace je jedním z nejobtížnějších problémů počítačového vidění. Rozpoznávání objektů se studuje intenzivně během posledních čtyř dekad, a přesto jsou dnešní nejlepší systémy schopny rozpoznat pouze jednoduché objekty, a to za přesně definovaných podmínek.

7.1 Generování hypotéz

Generování hypotéz v systémech rozpoznávání a analýzy obrazu je obvykle realizováno např. paměťovým systémem vytvářejícím popisný vektor vlastností detekovaných objektů. Jednotlivé vlastnosti vektoru jsou při iteračních krocích stále obnovovány a postupně doplňovány. Vzniká tak ucelený obraz popisované scény. Celková informace je následně použita pro stanovení *hypotézy* o identitě, vzhledu a konfiguraci možného objektu. Existuje několik postupů – metod pro generování hypotéz [12].

7.1.1 Pravděpodobnostní atlas

Základem metody je využití tzv. atlasu, ve kterém jsou uloženy *nasegmentované* vzorové obrazy. Neznámý obraz je nejprve porovnán se všemi obrazy obsaženými v atlasu. Z atlasu je vybrán nejpodobnější obraz, který je pak geometricky transformován tak, aby shoda byla maximální. Segmentace ze vzorového obrazu je pak přenesena na neznámý obraz, který tak bude rozdělen na oblasti stejné jako vzor. Zřejmou výhodou tohoto postupu je vysoká přesnost segmentace, protože vzorový obraz je většinou nasegmentován odborníkem. Nevýhodou jsou ručně pořízená vzorová data. Další nevýhodou je nereálnost vytvořit atlas, který by obsahoval vzory pro všechny vstupní obrazy. Z tohoto důvodu je tato metoda vhodná pouze pro jednoduché objekty, které si stále zachovávají stejný tvar.

7.1.2 Znalostní metody

Základem těchto metod je opět velmi kvalitní segmentace obrazu. Klíčové vlastnosti jednotlivých segmentů jsou vyextrahovány z obrazu a uloženy v podobě vektoru do paměti. Vzniká tak tzv. trénovací množina vzorů, která se použije pro porovnání s objekty (segmenty) v novém obraze. Tyto úvahy vedou ke vzniku *expertních systémů* pro rozpoznávání definovaných objektů v obraze. Nevýhodou všech metod založených na znalostech je opět velká variabilita objektů, kdy je v současné době přesná segmentace velmi obtížná. Velkou roli v této oblasti hrají neuronové sítě, genetické algoritmy a další statistické a pravděpodobnostní metody.

7.2 Verifikace hypotéz

Hypotézu nemůžeme nikdy dokázat, jen ji můžeme verifikovat a potvrdit její platnost (nebo neplatnost) testováním. Jen samotná testovací data však nestačí pro vytvoření hypotézy ani pro ladění jejích parametrů. Správným řešením je vytvořit tři disjunktní množiny dat – trénovací, testovací a validační. Validační množina je pak použita pro ověření (či vyvrácení) navržené hypotézy/metody, resp. pro stanovení pravděpodobnosti úspěšnosti výsledku.

Výstupem navržené hypotézy bude část obrazu, ve kterém bude možné s určitou pravděpodobností očekávat výskyt definovaného nežádoucího objektu nacházejícího se v oblasti železničního přejezdu. Pomocí výše navržených postupů bude potom třeba vyřešit následující případy:

- v obraze se nachází jeden nebo více nežádoucích objektů
- v obraze se nachází jiný objekt
- v obraze se nenachází žádný objekt

Tyto případy je nutné navíc řešit s ohledem na denní dobu, roční období a změnu počasí.

8. ZÁVĚR

Článek popisuje stav a prostředky pro zabezpečení železničních přejezdů v České republice. Dále jsou uvedena moderní řešení, jako jsou indukční smyčky, UWB radary a kamerové systémy a navrženo řešení – aplikace metod pro zpracování obrazové informace. Další kapitoly jsou věnovány jednotlivým etapám zpracování obrazu. Velká část práce je o etapě předzpracování obrazu, která stále více nabývá na významu. Mít dobře předzpracovanou obrazovou informaci znamená polovinu úspěchu. Závěrečná část práce je věnována segmentaci obrazu. Jsou v ní popsány významné a používané segmentační metody určené pro separaci obrazu. Poslední kapitola je o porozumění obsahu obrazové informace, tato problematika je v současné době v popředí zájmu vědeckého zkoumání, zejména v oblasti umělé inteligence.

POUŽITÁ LITERATURA

- [1] *Železniční přejezdy Správy železniční dopravní cesty, s. o.* [online]. c2006 [cit. 2009-10-13]. Dostupné z <<http://www.szdc.cz/o-nas/zeleznice-cr/zeleznici-prejezdy-szdc.pdf>>.
- [2] *Detekce vozidel na přejezdu pomocí UWB radarů – možné řešení* [online]. c2006 [cit. 2009-10-14]. Dostupné z <http://www.cd.cz/static/old/NEW/TCD2007/7_13rada.htm>.
- [3] Chue J., Cheng J., *Visual Monitoring – Based Railway Grade Crossing Surveillance System*, Congress on Image and Signal Processing, Vol. 2, 2008.
- [4] Hlaváč, V.; Sedláček, M. *Zpracování signálů a obrazů*, ČVUT Praha, 2005.
- [5] *Elcom a. s. Divize Virtuální instrumentace* [online]. c2009 [cit. 2009-9-9]. Dostupné z <<http://www.elcom.cz/virtualni-instrumentace/produkty/basler/>>.
- [6] Castleman K. R. *Digital Image Processing*, Prentice-Hall, New Jersey, USA, 1996.
- [7] Getz N. *A Fast Discrete Periodic Wavelet Transform*, College of Engineering, University of California, Berkeley.
- [8] Shapiro G., Stockman G. *Computer Vision*, Prentice Hall, New Jersey, USA, 2001.
- [9] Dobeš M. *Zpracování obrazu a algoritmy v C#*, nakladatelství BEN, Praha, 2008.
- [10] Otsu N., *A Threshold Selection Method from Gray-Level Histograms*, *IEEE Transactions on Systems, Man and Cybernetics*, vol. 9, 1979.
- [11] Serra, J. *Image Analysis and Mathematical Morphology*, Academic Press, London, 1982.
- [12] Hájek P., Havránek T., Chytil M., K. *Metoda GUHA. Automatická Tvorba Hypotéz*, Academia, Praha, 1983.

Recenzenti: prof. Ing. Vladimír Schejbal, CSc.
Univerzita Pardubice, DFJP, Katedra elektrotechniky, elektroniky
a zabezpečovací techniky
Ing. Martin Kendra, PhD.
Žilinská univerzita v Žiline, FPEDaS, Katedra železničnej dopravy