

VĚDECKÉ SPISY VYSOKÉHO UČENÍ TECHNICKÉHO V BRNĚ

Edice PhD Thesis, sv. 402

ISSN 1213-4198

thesis
?
IS

Ing. Ilona Kalová

Detekce a klasifikace vozidel

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
Fakulta elektrotechniky a komunikačních technologií
Ústav automatizace a měřicí techniky

Ing. Ilona Kalová

DETEKCE A KLASIFIKACE VOZIDEL

VEHICLES DETECTION AND CLASSIFICATION

ZKRÁCENÁ VERZE PH.D. THESIS

Obor: Elektrotechnika, elektronika, komunikační a řídicí technika
Školitel: Doc. Ing. Jozef Honec, CSc.
Oponenti: Doc. Ing. Ján Jadlovský, CSc., TU Košice
Doc. Ing. Eduard Sojka, CSc., FEI VŠB – TU Ostrava
Datum obhajoby: 10. 1. 2007

KLÍČOVÁ SLOVA

sběr dopravních dat, triangulační technika, zpracování obrazu, kamera, laser, výškový profil, klasifikace

KEYWORDS

traffic data collecting, triangulation technique, image processing, camera, laser, height profile, classification

MÍSTO ULOŽENÍ DISERTAČNÍ PRÁCE

Ústav automatizace a měřicí techniky, FEKT VUT v Brně

PODĚKOVÁNÍ

Na tomto místě bych chtěla poděkovat svému školiteli Doc.Ing. Jozefu Honcovi CSc. za přínosné rady udělené během konzultací a společnosti Camea spol. s r.o. za finanční i odbornou podporu při realizaci experimentálního zařízení. Tato práce byla také podporována Centrem aplikované kybernetiky, konkrétně projekty LN00B096 a 1M0567.

OBSAH

1 ÚVOD.....	5
2 CÍLE DISERTAČNÍ PRÁCE	5
3 SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY	7
4 APLIKAČNÍ ROZBOR TRIANGULAČNÍ TECHNIKY	8
4.1 Matematický model.....	9
4.2 Teoretický návrh opticko-mechanického uspořádání	10
4.3 Kalibrace	14
5 POPIS EXPERIMENTÁLNÍHO ŘEŠENÍ SYSTÉMU.....	16
5.1 Kamery.....	16
5.2 Lasery.....	16
5.3 Platforma pro upevnění kamery a laserů.....	17
5.4 Celkové uspořádání zařízení	17
6 PRIMÁRNÍ SIGNÁL A JEHO ZPRACOVÁNÍ	18
6.1 Primární data	18
6.2 Algoritmus pro detekci bodu v řádku	19
6.3 Detekce vozidla, práce s profilem.....	20
6.4 Určení rychlosti vozidla	21
7 KLASIFIKACE.....	21
7.1 Definice kategorií.....	22
7.2 Výběr příznaků.....	23
7.3 Trénovací množina.....	24
7.4 Umělá neuronová síť.....	25
7.5 Zhodnocení klasifikace	26
8 ZÁVĚR.....	26
9 POUŽITÉ ZDROJE.....	28
10 CURRICULUM VITAE	29
11 PUBLIKACE.....	29
12 ABSTRACT	30

1 ÚVOD

S trvalým nárůstem zatížení silniční sítě (počet vozidel se za posledních deset let zvýšil o 30 %), které přináší především zvýšení počtu dopravních nehod, poruch komunikace místním přetěžováním a znečištění ovzduší, se zvyšuje tlak na účelnou správu a organizaci průběhu dopravy. S tím spojené vyšší uplatňování telematiky pro kontrolu provozu a její řízení v silniční dopravě klade vyšší nároky na systémy určené pro sběr dopravních dat, automatickou analýzu stavu dopravy a rozpoznávání důležitých událostí v provozu. Na trhu se dnes v této oblasti nabízí mnoho v praxi ověřených, ale i inovativních systémů a metod. V národních i nadnárodních vývojových projektech jsou zkoumána a testována nová řešení.

Cílem moderních inteligentních dopravních systémů (ITS) je zajistit rychlý, účinný, ekonomický a v neposlední řadě bezpečný tok osob a zboží, proto je u těchto systémů velice důležitým požadavkem minimalizovat přerušení průběhu jízdy způsobené měřením. Dopravní systémy by také neměly v žádném případě jakkoli ohrozit bezpečnost účastníků silničního provozu. Měly by být schopny automaticky shromáždit informace z různých zdrojů a subsystémů, tyto informace společně zpracovat, vybrat, protřídit a podle priorit předkládat rozhodnutí. Dále by měly podporovat šíření a implementaci výsledných rozhodnutí a také poskytnout dostatečné prostředky ke kontrole dopadů těchto rozhodnutí.

Data, která je třeba sbírat, se týkají jednak hustoty dopravního toku – dopravní zatížení (vozidla/hod), okamžitá či průměrná rychlost v určitém úseku (km/hod), hustota vozidel (vozidla/km), rozestup vozidel, dále sledování důležitých událostí – dopravní nehody, zácpy, ale také porušování dopravních předpisů – průjezd křižovatkou na červenou, překročení povolené rychlosti, neoprávněný vjezd do daného prostoru atd. Pro určité aplikace je také velmi důležité znát základní charakteristiky vozidla – výška, délka, hmotnost, kategorie. Často jsou také v blízkosti komunikací sledovány meteorologické údaje – teplota, povětrnostní podmínky atd.

Údaje z automatického shromažďování dopravních informací se využívají v mnoha oblastech. Velmi důležité je sledování aktuální dopravní situace pro řízení dopravy a zabránění tak možným nehodám či zácpám, případně pro rychlejší odstraňování takto vzniklých situací (záchranná jednotka, odtahová služba, odklon dopravy atd.). Potřebné je také uplatnění při tvorbě dopravních statistik, které následně slouží pro dopravní plánování a kontrolu úspěšnosti zrealizovaných dopravních opatření (návrh potřebné kapacity komunikace, návrhy bezpečných křižovatek aj.). Neméně důležitá je také kontrola dopravy ve smyslu prosazování dopravních předpisů (zdokumentování přestupku pro potrestání viníků). Získaná data slouží pro tvorbu dopravních informací pro řidiče a dopravních prognóz. Dnes je také velmi aktuální výběr mýtného pro zpoplatnění některých úseků komunikací.

2 CÍLE DISERTAČNÍ PRÁCE

Skupina počítačového vidění na Ústavu automatizace a měřicí techniky (FEKT, VUT v Brně) se již řadu let úspěšně zabývá návrhem kamerových systémů a jejich nasazením do průmyslové praxe, a to i do dopravního průmyslu. Skupina navrhla ve spolupráci s firmou Camea a Ústavem kybernetiky na ČVUT řadu dopravních systémů, například pro detekci vozidel projíždějících na červenou, měření průměrné rychlosti v úseku nebo detekci krizových stavů atd. [1]. Má také zkušenosti s aplikacemi s použitím triangulační techniky,

například pro kontrolu svarů automobilových disků vyráběných společnostmi Hayes Lemmerz Autokola v Ostravě [10], [12], měření objemu vodivé pasty při výrobě tantalových kondenzátorů pro AVX Lanškroun [2] nebo pro pořizování 3D modelů klobouků pro firmu Tonak v Novém Jičíně [11]. Proto jsem se rozhodla využít získaných zkušeností v návrhu systému pro detekci a klasifikaci vozidel.

Cílem mé disertační práce tedy je teoreticky navrhnout, zrealizovat a otestovat systém, který bude schopen bez omezení rychlosti vozidla měřit některé jeho parametry a podle těchto parametrů vozidlo zařadit do příslušné třídy. Systém bude založen na dosud v této oblasti nepoužívané optické metodě měření - triangulační technice. Nejde však o zkonstruování finálního jednoúčelového zařízení, ale o ověření správnosti nového navrhovaného přístupu.

Cíle práce lze rozdělit do tří základních oblastí, které jsou dále složeny vždy z několika dílčích úloh:

- teoretický návrh a realizace prototypu - rozbor triangulační metody, sestavení matematického modelu, návrh uspořádání, volba vhodného hardware, realizace systému, testy, stanovení chyb měření a omezujících podmínek atd. (kapitola 4 a 5),
- software - návrh programového prostředí, návrh algoritmů zpracování obrazu a práce s profilem, časová i paměťová optimalizace algoritmů atd. (kapitola 6),
- klasifikace - volba příznaků charakterizujících vozidla, sestavení trénovací množiny vozidel a volba a nastavení klasifikátoru (kapitola 7).

Základní požadované funkce navrhovaného detekčního zařízení jsou:

- detekce vozidel,
- zaznamenání času průjezdu,
- měření výšky a délky vozidel,
- měření alespoň dvou výškových profilů vozidel,
- měření okamžité rychlosti vozidel,
- klasifikace vozidel do tříd,
- tvorba statistik provozu – vytíženost vozovky, rozestupy vozidel, četnost jednotlivých tříd, obsazenost jízdního pruhu atd.,
- odhad počtu náprav.

Z vymezených funkcí vyplývají typické aplikace, které se týkají především monitorování dopravní situace (sběr dat, statistiky dopravy), klasifikace vozidel pro výběr mýtného (třídy typu: vozidlo do 3,5 t, 3,5 – 12 t, nad 12 t nebo dle tvaru vozidla – osobní automobil, dodávka, nákladní vozidlo, autobus, kamión, atd.), kontroly vjezdu (dle výšky a typu vozidel), parkovací a vrátnicové systémy, měření rychlosti vozidel atd.

Využití triangulační techniky je v této oblasti velice výhodné, protože umožní změřit výškový profil vozidla při jeho pohybu. Profil je přitom nejlepším vstupem pro klasifikaci (viz kapitola 3). Jedinou v současnosti používanou technikou pro měření profilu vozidel je metoda založená na měření doby letu modulovaného světla (TOF), která však má několik nevýhod. Navrhovaný systém by měl přinést do této problematiky úplně nový přístup, který by měl odstranit některé nevýhody metody TOF. Navíc bude založen na podobné technologii jako kamerové systémy pro rozpoznání státní poznávací značky, proto jeho začlenění do komplexního řešení pro sběr silničních dat bude daleko snadnější.

K ověření očekávání vkládaných do tohoto přístupu bylo v rámci řešení disertační práce zrealizováno experimentální zařízení popsané teoreticky i konkrétně ve 4. až 7. kapitole. Testy byly prováděny nejdříve v Brně na ulici Božetěchova, dále pak na mostě nad komunikací Sportovní a později v Rudné u Prahy (dálnice D5, směr Praha).

3 SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY

Dnes používané systémy pro sběr dopravních dat lze rozdělit do dvou skupin. První je založena na komunikaci mezi jednotkou umístěnou ve vozidle (tzv. OBU – *On-Board Unit*) a systémem pro shromažďování a vyhodnocování dat. Komunikace probíhá na bázi mikrovlnného či infračerveného přenosu (DSRC - *Dedicated Short Range Communication*) nebo pomocí navigačního satelitního systému (GNSS/CN - *Global Navigation Satellite System/ Cellular Network*) [3], [4]. Systémy této skupiny se používají dnes hlavně u tzv. výkonového elektronického výběru mýtného (ETC – *Electronic Toll Collection*). Umožňují zpoplatnění uživatele dálniční komunikace podle skutečně ujeté vzdálenosti pohodlně bez nutnosti jakéhokoliv omezení jeho rychlosti nebo směru (*free-flow system*).

Tato skupina systémů předpokládá umístění OBU jednotky ve vozidle. Vozidlo bez jednotky nemůže být zachyceno, zároveň také může docházet např. k tzv. mýtným podvodům (úmyslná záměna OBU jednotky za jednotku s nižším tarifem). Z tohoto důvodu je třeba tyto systémy doplnit kontrolními místy. Ty mohou existovat v několika podobách. Buďto jako mobilní kontrolní vozidla, která se účastní běžné dopravy a jsou vybavena např. mikrovlnnými jednotkami a během jízdy ověřují OBU nebo jako stacionární kontroly, které jsou řešeny jako mýtné stanice (např. na hranicích) obsluhované operátorem nebo automatické kontrolní stanice.

Systémy patřící do druhé skupiny měří dopravní data mimo vozidlo [5]. Lze je použít právě pro automatickou následnou kontrolu, kdy jsou porovnávána naměřená data s daty z OBU jednotky (sesouhlasení např. registrační značky, přibližných rozměrů vozidla, počtu náprav atd.), ale mohou být aplikovány i samostatně pro sběr některých vybraných dopravních dat:

- indukční smyčky,
- piezoelektrické senzory, senzory s optickými vlákny,
- tenzometrické váhy,
- radary, mikrovlnné senzory,
- optické brány,
- laserové senzory – měření doby letu paprsku (TOF - *Time-of-Flight*),
- pasivní infračervené senzory,
- kamerové systémy.

Vedle těchto systémů se aplikují i další, využívající jiných principů např. hydraulické, akustické [6] či pneumatické senzory. Bohužel technický popis modernějších technologií je jen velmi málo publikovaný. Výrobci prezentují jen laický zevrubný popis ve svých reklamních prospektech. Konkrétní řešení je věcí výrobního tajemství jednotlivých firem.

Největší nároky vzhledem k definovaným požadavkům na navrhovaný systém vyžaduje klasifikace vozidel. Pro třídění vozidel lze použít všechny uvedené přístupy. Rozdíl je však v tom, na základě jakých údajů je vozidlo klasifikováno, s jakou spolehlivostí a do kolika tříd lze vozidla rozdělit.

U technik založených na infrastruktuře zabudované do vozovky (indukční smyčky, piezoelektrické senzory nebo tenzometrické váhy) se pro klasifikaci používají údaje o počtu náprav vozidla, celkové hmotnosti vozidla nebo hmotnosti jednotlivých náprav. I když se u nás dělí vozidla do tříd podle hmotnosti (do 3,5 t; 3,5 t až 12 t; nad 12 t), není možné nákladní automobil zařadit do nižší kategorie jen kvůli tomu, že právě nevezve žádný náklad a jeho aktuální hmotnost je tedy menší.

Radarové či mikrovlnné senzory mohou poskytovat údaj pouze o délce vozidla. Ta však ke spolehlivé klasifikaci také nestačí. Podobně jako pouhá informace o výšce vozidla, kterou lze měřit optickými branami.

Pro účely klasifikace lze aplikovat i kamerové systémy, které v sejmutých obrazech mohou detekovat vozidla i s koly a na základě projekce určit jejich délku i výšku, resp. celý profil. Avšak vzhledem ke složitosti scény (odlesky, jiná vozidla, okolní scéna, silniční infrastruktura atd.) je klasifikace značně náročná.


V tomto smyslu se jeví jako nejvhodnější systémy založené na měření doby letu modulovaného světla (TOF), jež měří celý profil vozidla. Je jisté, že právě tvar vozidel nejlépe může charakterizovat kategorii, do které má vozidlo patřit. Výhodou práce s profilem je i to, že díky měření průběhu výšky a apriorní znalosti možných tvarů vozidel lze jednoduše a spolehlivěji separovat jednotlivá vozidla. Analýzou signálu tak lze eliminovat chyby typu „rozpojení“ tažného vozidla a přívěsu nebo kabiny a návěsu atd., jež vedou k zásadní nepřesnosti určení délky, klasifikace a k poškození statistického souboru naměřených dat.

Metoda TOF má však také svá úskalí. Prvním nedostatkem je to, že systémy pracující s touto metodou jsou relativně pomalé. Např. doba odezvy u systémů nabízených firmou SICK [7] je 13,3 ms při skenování 100° po 1° (101 hodnot). Další nevýhodou metody je skutečnost, že pro zajištění měření jednoho profilu je zapotřebí vždy vysílač, přesná optika, přijímač a potřebná elektronika. Pro pokrytí jednoho jízdního pruhu by pak bylo třeba několik těchto drahých soustav. Proto se místo série snímačů používá u této metody postupné skenování prostoru [7], kdy vysílač s přijímačem a optikou jsou umístěny na rotačním kloubu nebo je do cesty laseru vloženo natáčející se zrcátko a měří se vzdálenost např. po 1° . Zajištění rotačního pohybu přináší jednak větší možnost poruchy, natáčení také ještě více prodlužuje dobu měření a navíc vzorky nejsou pořizovány pouze ve směru pohybu vozidla, ale „cik cak“ (každý další vzorek je od předchozího vzdálen nejen o dráhu, kterou vozidlo mezi tím urazilo, ale ještě o vzdálenost kolmou na směr pohybu danou změnou úhlu).

4 APLIKAČNÍ ROZBOR TRIANGULAČNÍ TECHNIKY

Princip navrhovaného systému je založen na využití optické aktivní triangulační techniky [8], [9], [15], [16], a to konkrétně její jednorozměrné varianty. Technika spočívá ve fotogrammetrické rekonstrukci snímaného objektu nasvícením jeho povrchu světelným zdrojem a současným snímáním CCD snímačem. Zdroj světla spolu se snímačem a osvětleným bodem na zkoumaném objektu tvoří tzv. triangulační trojúhelník. Spojnici b světelný zdroj - snímač nazýváme triangulační bází (základnou). Na straně zdroje je úhel α svíraný s triangulační bází neměnný, kdežto na straně snímače je úhel β určen proměnnou pozicí vysvíceného bodu CCD snímače. Z velikosti tohoto úhlu, na základě znalosti

triangulační báze a parametrů kamery a objektivu (velikost čipu c , ohnisková vzdálenost f , počet pixelů pxl) lze určit vzdálenost objektu l . Princip měření je znázorněn na Obr. 4.1.



Obr. 4.1 Princip měření

4.1 MATEMATICKÝ MODEL

Vztah mezi pozicí vysvíceného bodu na snímku z kamery a vzdáleností lze určit výpočtem na základě schéma Obr. 4.1. Pokud se odražený laserový paprsek promítne do pixelu k z celkového počtu pxl pixelů, pak velikost odpovídající projekce na čipu a [mm] lze určit pomocí vztahu:

$$a = \frac{c \cdot k}{pxl} \text{ [mm]} \quad (4.1)$$

Projekci a lze využít pro výpočet úhlu β :

$$\beta = \text{actg} \left(\frac{c/2 - a}{f} \right) + 90^\circ \text{ [}^\circ\text{]} \quad (4.2)$$

Kolmá vzdálenost l je pak určena na základě znalosti úhlů α , β a velikosti báze b :

$$l = \frac{b \cdot \sin \beta \cdot \sin \alpha}{\sin(180^\circ - (\alpha + \beta))} \text{ [mm]} \quad (4.3)$$

Z uvedených vztahů a ze schéma vyplývá, že pokud je měřený objekt blíže ke kameře a zdroji osvětlení (je vyšší), bude úhel β menší a tedy projekce a větší. To v praxi znamená, že odražený laserový paprsek se promítne na čip do pixelu více vpravo (ve smyslu Obr. 4.1). Tímto způsobem může být určena vzdálenost objektu jen z pozice světlého bodu ve snímku z kamery. Ze vztahů (4.1) až (4.3) lze odvodit, že přesnost měření (pixelové rozlišení, diskretizační chyba) poroste s velikostí báze b , kamerového rozlišení

pxl či ohniskové vzdálenosti objektivu f . Naopak, čím větší bude velikost čipu c (resp. velikost světlo-citlivých prvků) a samozřejmě měřená vzdálenost l , tím méně přesné výsledky získáme.

Vypočtená hodnota je však bohužel značně závislá na přesnosti změření všech potřebných údajů (především báze kamera - laser) a znalosti parametrů kamery (ohnisková vzdálenost, velikost čipu). I malá chyba na straně senzoru se díky relativně velké měřené vzdálenosti projeví velkou chybou na výstupu. Z tohoto důvodu byl matematický model použit hlavně pro návrh opticko-mechanického uspořádání (kap. 4.2) s ohledem na požadovanou přesnost, mechanické rozměry a další požadavky na systém, ale pro praktická měření byl použit vztah určený kalibrací systému (kap. 4.3).

4.2 TEORETICKÝ NÁVRH OPTICKO-MECHANICKÉHO USPOŘÁDÁNÍ

Celý návrh opticko-mechanického uspořádání byl řešen jako kompromis mezi požadavky na systém (přesnost, rozsah měření atd.) a jeho maximálními rozměry. Celé zařízení, ale především soustava kamera-lasery, je velice přesný optický systém. Změnou některých jeho parametrů, např. vlivem různého rozpínání materiálů, by hlavně při velkých rozměrech mohlo dojít k tomu, že lasery nebudou v jedné rovině s kamerou, a tedy, že se odražené paprsky laserů nebudou promítat do řádku kamery.

Výběr snímacího a digitalizačního zařízení


Princip triangulační techniky vyžaduje snímací zařízení a zdroj(e) světla. Jelikož lze při měření vozidel využít jejich translačního pohybu (skenování v jednom směru – změření výškového profilu), může být aplikována jednorozměrná varianta (1D triangulace) vyžadující pouze světelný paprsek. Pro svou směrovost a intenzitu byly jako zdroje světla vybrány lasery. Pro zaznamenání paprsku vystačí pouze jednorozměrný snímač - lineární CCD kamera (tím je získána vyšší vzorkovací frekvence oproti plošné kameře). Podrobnější informace o vybrané kameře a laserech i o dalších potřebných komponentech jsou uvedeny v páté kapitole.

Návrh počtu, pozic a orientace laserů

Jedním z nejdůležitějších parametrů ovlivňujících přesnost měření je velikost báze (vzdálenost kamery a laseru). Vzhledem k omezení velikosti navrhovaného zařízení (max. 400x400x300 mm) je maximální možná báze 250 mm.

Pro splnění požadavku změření alespoň dvou výškových profilů vozidla jedoucího uvnitř jízdního pruhu jsou potřebné minimálně čtyři lasery. Všechny lasery musí být připevněny na stejné platformě jako kamera. Z konstrukčních důvodů (rozměry laserů a možnost manipulace s nimi) nemohou tedy mít stejnou vzdálenost od kamery. Navrhované báze jsou po řadě pro první až čtvrtý laser 150, 180, 220 a 250 mm.

Úhel jednotlivých laserů musí být zvolen tak, aby lasery rovnoměrně pokryly jízdní pruh, zároveň však musí v celém požadovaném měřeném rozsahu zůstat v zorném úhlu kamery. Dále je vhodné, aby se na řádku kamery nemohly jednotlivé lasery křížit, tedy tak, aby např. první laser odražený od pětimetrového objektu se promítl do pixelu ještě stále více vlevo než druhý laser odražený od země. Navrhované úhly jsou po řadě přibližně 75,6 °, 80,9 °, 86,2 °, 90,9 °. Laserové stopy jsou na zemi od sebe vzdáleny přibližně 700 mm.



Obr. 4.2 Návrh uspořádání – celá scéna a detail měřicího systému

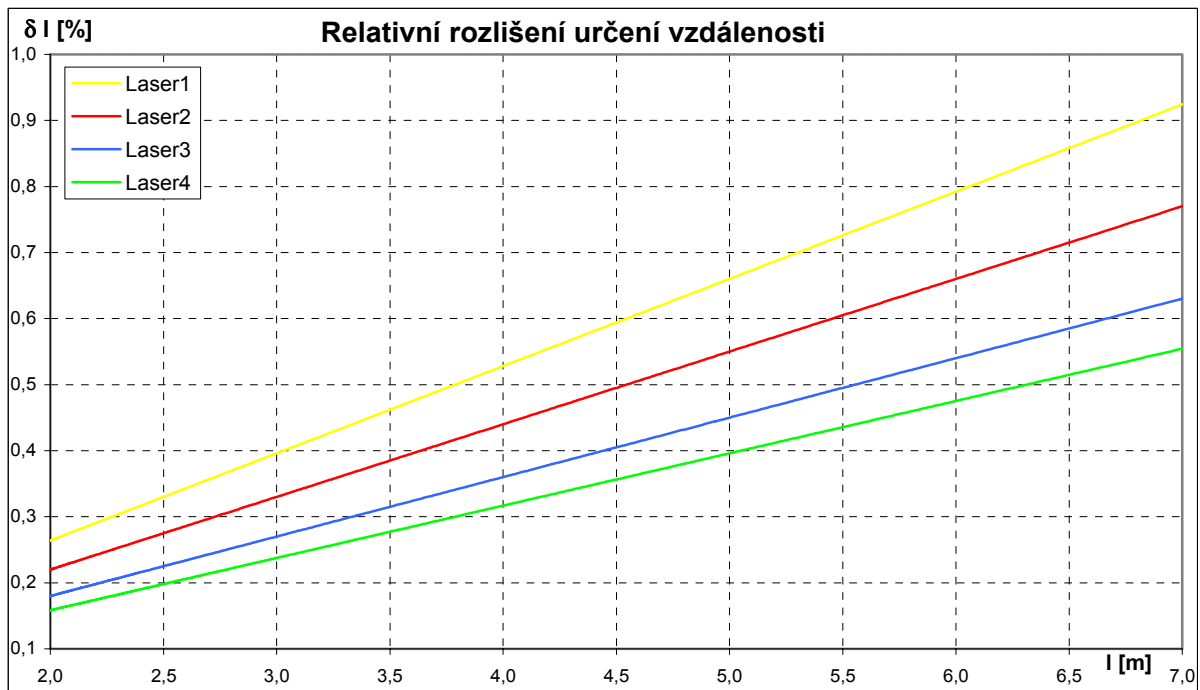
Umístění celého měřicího systému v rámci pruhu vozovky musí být voleno tak, aby vozidlo jedoucí i na okraji pruhu bylo změřeno vždy alespoň dvěma krajními lasery, proto byla navržena taková pozice systému, kdy optická osa kamery byla od levého pruhu vozovky vzdálena 2,2 m. Celou situaci naznačuje Obr. 4.2 (zorné pole kamery modře, lasery červeně, jízdní pruh zeleně).

Rozlišení výškového profilu

Jestliže vztah $l(k)$ mezi vzdáleností l a pozicí vysvíceného pixelu řádku kamery k je dán vztahy (4.1) až (4.3), lze pro navržený systém (Obr. 4.2) určit relativní rozlišení vzdálenosti jako:

$$\delta l(k) = \frac{l(k-0,5) - l(k+0,5)}{l(k)}, \quad (4.4)$$


kdy předpokládáme chybu určení pozice vysvíceného bodu \pm polovina pixelu. Graf závislosti rozlišení na vzdálenosti od měřicího systému pro jednotlivé lasery je na Obr. 4.5. Jak lze vidět, v celém měřicím rozsahu je chyba rozlišení menší než jedno procento i pro laser s nejmenší bází. Je třeba si však uvědomit, že toto je jen teoretická chyba. Ve skutečnosti je přesnost určení vzdálenosti nižší, protože je dále ovlivněná tloušťkou laserové stopy ve snímku, odlesky, složitostí scény atd.




Obr. 4.3 Relativní rozlišení určení vzdálenosti

Určení rychlosti vozidel

Vzorkovací frekvence navrhovaného systému je dána řádkovou frekvencí kamery. Jestliže s frekvencí jednoho řádku pořídíme jeden vzorek, získáme výškový profil, kde jednotlivé vzorky jsou od sebe vzdáleny časově - dobu jednoho řádku, ale není známa jejich prostorová vzdálenost. Pro určení vzdálenosti mezi pořizovanými vzorky a tedy i délky vozidla je třeba znát jeho rychlost. Okamžitou rychlost lze změřit použitím jiné technologie, např. radaru anebo vzájemným porovnáním nebo společným vyhodnocením dat ze dvou po sobě jdoucích měřících míst (dvě samostatné měřící jednotky umístěny za sebou, viz Obr. 4.4). Rychlost je pak určena na základě časového posunu mezi výškovým profilem změřeným v první měřící pozici a profilem změřeným v druhé pozici (Obr. 4.5).



Obr. 4.4 Dvě měřící soustavy



Obr. 4.5 Princip určení rychlosti z posunu profilů

Rychlost se určí jako:

$$v = \frac{d}{t_p} = \frac{d}{r_p \cdot t_{vz}}, \quad (4.5)$$

kde d je vzdálenost měřicích soustav (vzhledem k maximálním požadovaným rozměrům je navrhované $d = 250$ mm), t_p je časový posun profilů, r_p je počet vzorků posunu a t_{vz} je vzorkovací perioda.

Rozlišení rychlosti

Rozlišení rychlosti závisí na způsobu stanovení časového posunu mezi profily první a druhé soustavy. Pokud bude časový posun určen jen jednoduše tak, jak je to znázorněno na Obr. 4.5 z posunu začátku vozidla, získáme posun v řádu celých čísel. V tomto případě podobně jako při výpočtu chyby profilu, lze rozlišení určení časového posunu předpokládat $\pm 1/2$ doby jednoho vzorku, a tedy relativní rozlišení vypočítat jako:

$$\delta v(r_p) = \frac{v(r_p - 0,5r_p) - v(r_p + 0,5r_p)}{v(r_p)} \quad (4.6)$$

Při určení posunu tímto způsobem a při použití kamery s řádkovou periodou 433,6 μ s, svícením laseru ob jeden řádek (viz dále v kapitole 5) a vzdálenosti měřicích míst $d = 250$ mm je však rozlišení nedostačující (při rychlosti 200 km/hod je chyba dokonce téměř 20 %).

Posun musí být tedy určen přesněji. Lepších výsledků je možné docílit prací s celým profilem. Posun může být určen vzájemnou korelací obou signálů. Pokud navíc diskrétní vzorky budou proloženy vhodnou křivkou (stačí proložit pouze jeden profil), resp. dopočítány hodnoty mezi dvěma vzorky pro zvolený krok, může být tento krok libovolně

malý. Vzhledem k náročnosti výpočtu korelace a dopočítávání vzorků v celém rozsahu uvažovaných rychlostí a přes celý signál, je vhodné volit tento krok jako maximálně desetinu vzdálenosti vzorků (devět dopočítaných hodnot mezi vzorky). Tím získáme desetkrát lepší rozlišení.

Dalšího zpřesnění výsledků by bylo možné dosáhnout buď zvětšením vzdálenosti mezi měřicími soustavami nebo použitím rychlejší kamery (např. kamera s čipem ILX531 s řádková frekvence přibližně 7,77 kHz). Zvětšení vzdálenosti soustav by bylo možné řešit rozdělením soustav do dvou samostatných jednotek a umístěním na opačné strany portálu.

4.3 KALIBRACE

Určení kalibračního modelu

Jelikož nelze zaručit, že vyrobená konstrukce bude mít přesně navrhované parametry (úhly laserů, báze atd.), musí být zařízení navrženo tak, aby byla možnost některé tyto parametry doladit. Z těchto důvodů však nelze použít vztahy (4.1) až (4.3). Navíc je matematický model výpočetně náročný, proto byla pro definici vztahu „vysvícený bod na snímku - vzdálenost“ použita závislost získaná kalibrací.

Pro určení vhodného kalibračního modelu lze vyjít z modelu perspektivní kamery [9], jenž pomocí matice rozměru 3x4 představuje transformaci z 3D prostoru do 2D snímku. Jelikož navrhovaný systém používá 1D triangulační techniku, a tudíž se jedná o zobrazení z \mathfrak{R}^1 (vzdálenost l) do \mathfrak{R}^1 (pozice pixelu v řádku kamery k), lze tento model výrazně zjednodušit:

$$\begin{bmatrix} hk \\ h \end{bmatrix} = \begin{bmatrix} p_{11} & p_{12} \\ p_{21} & p_{22} \end{bmatrix} \cdot \begin{bmatrix} l \\ 1 \end{bmatrix} \quad (4.7)$$

Jelikož \mathbf{P} je čtvercová matice (tedy nedochází ke ztrátě informace), může být model navržen tak, aby řešil přímo zpětnou úlohu (transformaci \mathbf{T} - z pozice pixelu určit vzdálenost):

$$\begin{bmatrix} hl \\ h \end{bmatrix} = \begin{bmatrix} t_{11} & t_{12} \\ t_{21} & 1 \end{bmatrix} \cdot \begin{bmatrix} k \\ 1 \end{bmatrix} \quad (4.8)$$

Tento zápis lze vyjádřit maticově, ve formátu vhodném pro práci s celým souborem kalibračních dat o N bodech (jeden bod = dvojice souřadnic: pixelová pozice vysvíceného místa, odpovídající vzdálenost).

$$\mathbf{Bt} = \mathbf{L} \quad (4.9)$$

Matice \mathbf{B} je zde rozměru $N \times 3$, \mathbf{L} je sloupcový vektor $N \times 1$ a \mathbf{t} (rozměru 3×1) je sloupcový vektor neznámých koeficientů transformační matice \mathbf{T} . Na každém řádku je tedy zapsán jeden kalibrační bod:

$$\begin{bmatrix} k_1 & 1 & -l_1 \cdot k_1 \\ k_2 & 1 & -l_2 \cdot k_2 \\ \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot \\ k_N & 1 & -l_N \cdot k_N \end{bmatrix} \cdot \begin{bmatrix} t_{11} \\ t_{12} \\ t_{21} \end{bmatrix} = \begin{bmatrix} l_1 \\ l_2 \\ \cdot \\ \cdot \\ l_N \end{bmatrix} \quad (4.10)$$

Nyní lze pro výpočet koeficientů t_{11} , t_{12} a t_{21} použít metodu nejmenších čtverců:

$$t = B^+ L, \quad (4.11)$$

kdy matice B^+ je pseudo-inverzní k B a je dána jako:

$$B^+ = [B^T B]^{-1} B^T \quad (4.12)$$

Pro určení tří neznámých je zapotřebí nejméně tři vstupních kalibračních bodů, ale pro sestavení přesnějšího modelu je vhodné zařadit do souboru bodů více.

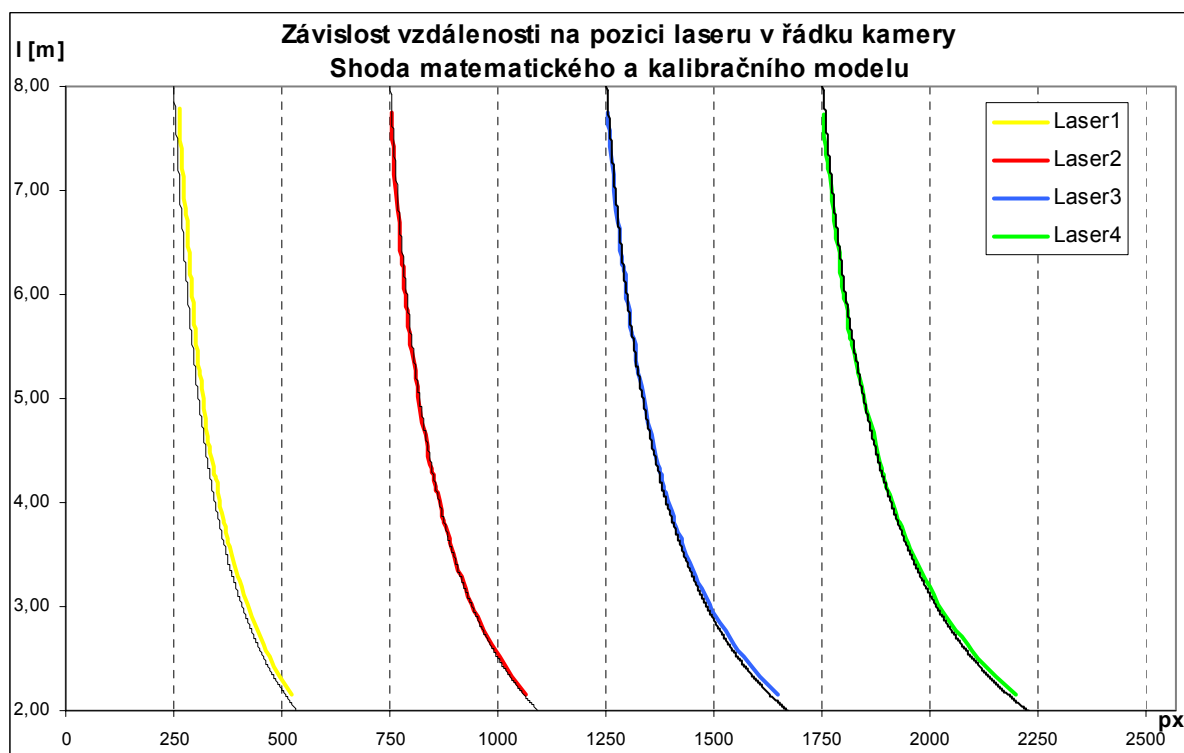
Praktická realizace kalibrace

Kalibrace zkonstruovaného zařízení byla provedena pro 45 hodnot vzdáleností v potřebném rozsahu 2–8 m. Pro každou vzdálenost byly na snímcích z obou kamer nalezeny pozice všech osmi laserů (dva systémy po čtyřech laserech). Soubor kalibračních dat pro každý laser byl použit pro výpočet neznámých koeficientů t_{11} , t_{12} a t_{21} podle vztahů (4.10) až (4.12).

Vzdálenost l se tedy určí z pixelové pozice k laseru (i) pomocí vztahu:

$$l = \frac{k \cdot t_{11}^{(i)} + t_{12}^{(i)}}{k \cdot t_{21}^{(i)} + 1}, \quad (4.13)$$

Graf na Obr. 4.6 znázorňuje rozložení laserů na řádku z kamery (2568 pxl) pro různé vzdálenosti. Barevně jsou vyznačeny závislosti určené kalibračními modely a černě je vždy naznačen odpovídající matematický model určený teoretickým návrhem popsáním v kapitole 4.1 a 4.2. Z grafu lze vidět, že se stopy laserů v měřeném rozsahu vzdáleností nepřekrývají a že čtvrtý laser má větší rozlišení než první (rozdílná báze).



Obr. 4.6 Srovnání kalibračního (barevně) a matematického (černě) modelu

5 POPIS EXPERIMENTÁLNÍHO ŘEŠENÍ SYSTÉMU

V této kapitole jsou detailněji popsány jednotlivé prvky (hardware) experimentálního měřicího zařízení, které bylo testováno v Rudné u Prahy na 4. km dálnice D5 (směr Praha).

5.1 KAMERY

Pro experimentální řešení byly použity dvě řádkové kamery vyráběné firmou CAMEA spol. s r. o. s černobilým čipem SONY ILX751. Čipy mají 2048 světlo-citlivých prvků, ale tento počet byl převzorkován na 2568 pixelů. Velikost pixelu je $14 \times 14 \mu\text{m}$. Perioda řádku je $433,6 \mu\text{s}$. Pracovní teplota se může pohybovat v rozsahu od -10 do $+55 \text{ }^\circ\text{C}$. Pro požadované parametry skeneru (přesnost, zorný úhel) byly zvoleny objektivy s ohniskovou vzdáleností 50 mm (Pentacoon MC 1.8/50).

Praxe ukázala, že rozsah všech možných slunečních podmínek (noc, den, intenzivní slunečný den, déšť atd.) a také různých barev a odrazivostí povrchů vozidel nelze obsáhnout pouze jednou expoziční dobou kamery a jedním neměnným clonovým číslem objektivu. Proto byl navržen kamerový program, který v cyklu tří řádků mění expoziční dobu (a také délku svícení laserů). Tedy vždy na prvním řádku cyklu trvá expozice polovinu řádku, na druhém jednu čtvrtinu a na třetím pouze osminu řádku a tento cyklus se vždy opakuje. Tím se dostatečně rozšířilo pásmo použitelnosti měřicího systému vzhledem k možným okolním podmínkám. I při nejnepríznivějších podmínkách je vždy alespoň jedna expozice ze tří použitelná a vzorky na ní mohou být kvalitně detekovány.

Pro další potlačení negativního vlivu okolního světla (slunce, reflektorů, pouličních lamp,...) a zvýšení kontrastu ve snímku mezi vysvíceným bodem a okolím je před kamerový čip vložen optický filtr (úzká pásmová propust - 10 nm), který má střed ve vlnové délce laseru.

K ověření správnosti detekce a klasifikace je použita plošná kamera, která pod úhlem (z rohu portálu) zaznamenává projíždějící vozidla. Pro zachycení co největší části vozidla, je použit objektiv s malou ohniskovou vzdáleností 4,5 mm.

5.2 LASERY

Aby bylo docíleno co největšího odstupů mezi signálem a šumem (světlo odraženého paprsku ku ostatnímu okolnímu světlu), jsou jako zdroje světla použity lasery. Lasery svítí velice směrově (na vzdálenosti 7 m je průměr vysvíceného bodu pouze cca 20 mm) a intenzivně (kontinuální výkon laserů je 5 mW). Vlnová délka použitých laserů je 650 nm.


Pro monitorování celého jízdního pruhu dostačují čtyři lasery (viz teoretický návrh v kapitole 4.2). Obecně však lze do jednoho řádku promítat s vhodným rozestupem i více laserů. Díky tomu stačí pro pokrytí celého pruhu a vytvoření 3D modelu vozidla pouze jedna přijímací jednotka (kamera) s jednou optikou a elektronikou a několik jednoduchých laserových diod, což je velká výhoda oproti metodě založené na měření doby letu.

Lasery jsou synchronizovány s kamerami deskou umístěnou uprostřed skříně skeneru (viz Obr. 5.2). U experimentálního řešení bylo použito řízení svitu laserů tak, aby na jednom řádku svítily vždy jen dva vzdálenější lasery současně (tzn. na jednom řádku svítí 1. a 3. laser, na následujícím řádku pak 2. a 4. laser atd.). Lasery svítí vždy jen po dobu expozice. Důvodem pro použití režimu svícení dvojice vzdálenějších laserů je snaha o dodržení hygienických norem, definujících maximální střední výkon laseru takový, aby nedocházelo k oslnění lidského zraku. Tento střední výkon by neměl přesáhnout 1 mW.

V režimu, kdy laser svítí v cyklu 1/2, 0, 1/8, 0, 1/4, 0 řádku (433,6 μ s) je střední výkon laserů přibližně 0,73 mW.

5.3 PLATFORMA PRO UPEVNĚNÍ KAMERY A LASERŮ

Aby byl zaručen stálý, neměnný vztah kamery a laserů, jsou tyto prvky upevněny na společnou duralovou platformu a pevně zafixovány (viz Obr. 5.1). Návrh měřicí soustavy a přesné rozměry jsou uvedeny v kapitole 4.2. Upevnění kamery i laserů má několik stupňů volnosti, aby bylo možné měřicí soustavu přesně nastavit. Po každé změně nastavení je třeba provést novou kalibraci soustavy.




Obr. 5.1 Opticko-mechanická soustava

5.4 CELKOVÉ USPOŘÁDÁNÍ ZAŘÍZENÍ

Obě osazené platformy jsou umístěny ve skříni o rozměrech 400x400x200 mm (viz Obr. 5.2). Platformy jsou od sebe vzdáleny 250 mm. Skříň má dva světelné skleněné průzory pro kamery a dva průzory pro čtveřice laserů.

Vedle těchto popsaných prvků obsahuje měřicí systém ještě desku pro synchronizaci a řízení kamer a laserů, desku pro usměrnění a stabilizaci napájecího napětí, topné tělísko pro vytápění skříně, napájecí kabely a koaxiální kabely vedoucí video signál.

Zařízení je umístěno na portále nad vozovkou kolmo na směr pohybu vozidel a sleduje část vozovky pod portálem. Výška portálu je cca 7 m. Pro sběr všech potřebných údajů o vozidle tedy není potřeba zasahovat přímo do vozovky (jako u indukčních smyček nebo piezoelektrických snímačů), což je vždy spojeno se složitou instalací a poškozením komunikace.



Obr. 5.2 Celkové uspořádání měřicího zařízení

6 PRIMÁRNÍ SIGNÁL A JEHO ZPRACOVÁNÍ

Celý systém zpracování snímků až po předání změřených údajů o vozidle byl řešen v prostředí Borland C++ Builder Professional verze 6. Při reálných měřeních (podzim-zima 2004/5) byla do tohoto prostředí implementována i jedna z prvních verzí klasifikátoru (neuronová síť s radiální bází). Později však byl klasifikátor řešen jako samostatná offline úloha v modelovacím prostředí Matlab 7.0.1 (viz kapitola 7).


6.1 PRIMÁRNÍ DATA

Jednotlivé řádky z kamery (2568 pixelů v 256 odstínech šedi) jsou skládány za sebe do pracovních bloků (snímků), které vstupují do algoritmů. Tato primární nezpracovaná obrazová data vypadají například jako na Obr. 6.1.

Systém je navržen tak, aby se stopy laserů nemohly ve snímku překrývat a navzájem se křížit. Proto může být snímek z hlediska zpracování rozdělen do čtyř částí vymezujících jednotlivé lasery a okrajů, které jsou z dalšího zpracování vyloučeny. Každému laseru je vymezena oblast 500 pixelů, a to po řadě od 250., 750., 1250. a 1750. pixelu (viz Obr. 6.3).

Pro měření profilů je nutné pro každý laser znát pixelovou pozici odpovídající vzdálenosti vozovky (země). Bylo by možné použít předem definovanou pozici, ale díky světelným a povětrnostním podmínkám se tato pozice v průběhu měření mírně mění, proto je třeba na začátku měření provést kalibraci vzhledem k zemi. Během měření se pro dosažení vysoké přesnosti tato kalibrace automaticky opakuje. To řeší i případy, kdy se na vozovce objeví nějaký statický předmět (kámen, krabice,...). Nutné je také ošetřit případy,

kdy se laserová stopa na snímku „ztratí“ a to ať z důvodu přerušení napájení, poruchy nebo změny jeho viditelnosti (zašpinění, zamlžení průhledového skla či změna kvality materiálu v místě odrazu laseru – sníh, voda, špína na zemi).




Obr. 6.1 Primární nezpracovaná obrazová data zachycující začátek vozidla

6.2 ALGORITMUS PRO DETEKCI BODU V ŘÁDKU

Primárním úkolem měření je správně najít vysvícený laserový bod ve snímku. Do algoritmu pro detekci bodu v řádku vstupuje vždy jen jeden řádek a to jen jeho část (500 pixelů) patřící danému laseru. Na každém řádku je tedy volán vždy dvakrát (pro první a třetí, resp. pro druhý a čtvrtý laser).

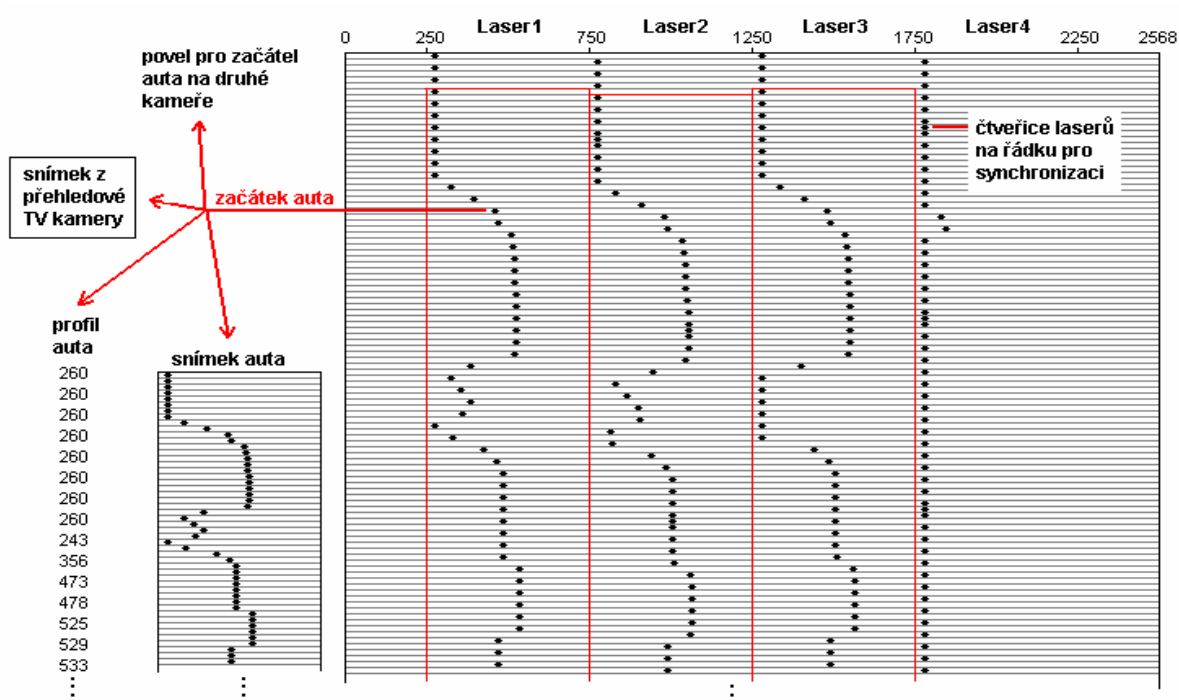
Výřez se nejdříve filtruje – ze tří po sobě jdoucích pixelů se určí průměr (vyhlazení drobného šumu kamery) a zároveň se stanoví střední a maximální hodnota na řádku. Pokud na řádku „nic není“ (rozdíl maxima a průměru je menší než hodnota 20) nebo je řádek příliš světlý (průměr je větší než 200), dále se nepokračuje a je vrácena neplatná hodnota. Jinak se hledá začátek a konec úseku, jehož jas je větší než průměrná hodnota maxima a průměru. Všechny tyto úseky kratší než 35 pixelů jsou zaznamenány do pole, kdy velmi blízké úseky (jejich středy jsou bližší než 15 pixelů) jsou sloučeny do jednoho. Pokud je v tomto poli na konci detekce více než jedna hodnota, je pro výsledek vybrána hodnota nejbližší předcházející změřené hodnotě. Příklad profilu cisterny s detekovanými vzorky je uveden na obrázku Obr. 6.2.



Obr. 6.2 Příklad snímku vozidla s detekovanými vzorky (pro lepší zobrazení natočen o 90 °)

6.3 DETEKCE VOZIDLA, PRÁCE S PROFILEM

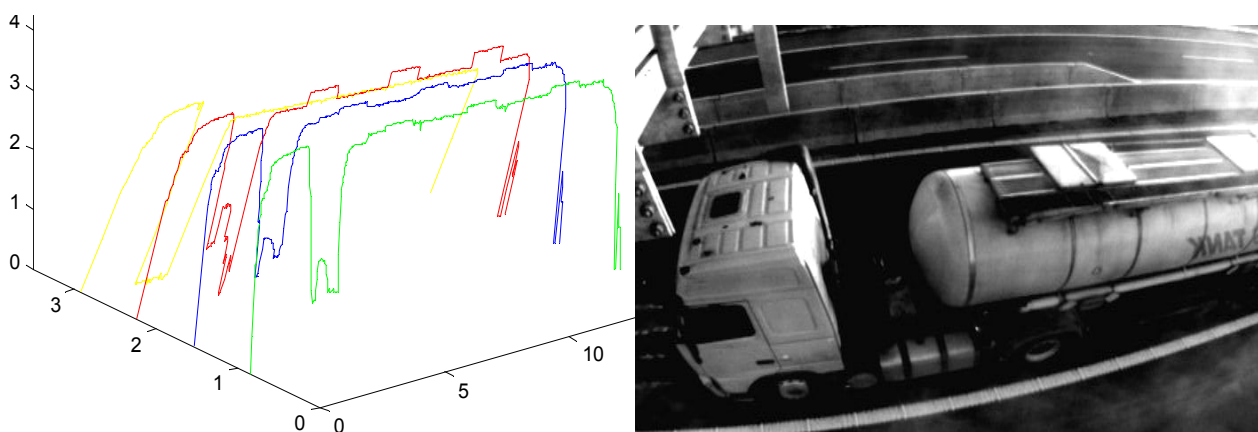
Naměřené vzorky jsou filtrovány (pro potlačení krátkých chyb profilu – odlesky, reflektory vozidel, odrazy od sněhových vloček atd.). Po filtraci jsou data pro každý laser postupně porovnávána s aktuálně nalezenou pixelovou pozicí země zvýšenou o určitý práh. Je-li pozice laserové stopy na první kameře větší než tato hodnota a je toto vyhodnoceno jako začátek vozidla, je uložen snímek z přehledové kamery. Dále je do pole profilu vozidla uloženo deset předchozích detekovaných a filtrovaných hodnot, aby mohl být později začátek rozpoznán přesněji a otevře se snímek, do kterého je opět uloženo posledních deset výřezů řádků daného laseru (viz Obr. 6.3). Tato funkce je volána pro první i druhou kameru (začátek vozidla na první kameře nastartuje ukládání i na druhé kameře).



Obr. 6.3 Činnosti prováděné při začátku vozidla

Další detekované vzorky jsou postupně ukládány do pole profilu vozidla a příslušné části řádků jsou zaznamenávány do snímku vozidla. Za každým koncem automobilu, jsou-li změřená data prohlášena za automobil (profil je dostatečně dlouhý, nebylo dosaženo maxima vzorků za vozidlem atd.), je předán celý profil a další potřebná data funkci, která pomocí přepočtových vztahů určených z kalibrace převede změřené pixelové hodnoty na výšku vozidla v metrech. Dále určí velikost posunu mezi kamerami a z něho pak rychlost vozidla a jeho délku. Z naměřeného profilu vybere jen tu část, která představuje profil vozidla (nalezne přesněji první a poslední vzorek vozidla). Dále zapíše do aktuální položky výsledkové struktury potřebná data (např. jméno odpovídajícího snímku z přehledové kamery, číslo laseru, rychlost vozidla atd.).

Není-li již žádný jiný laser aktivní (konec profilu na všech laserech), vyvolá se funkce, která vyhodnotí všechny dílčí výsledky a mezi nimi vybere ten nejvhodnější. Pro výběr nejvhodnějšího profilu je použita kombinace několika různých kritérií výběru např. podle kvality profilu, pozice laseru (např. při třech aktivních laserech je větší váha dána prostřednímu, také je „podpořen“ laser s vyšším indexem - větší přesnost díky větší bázi mezi laserem a kamerou) či podle délky profilu (pro ošetření případů více výsledků na jednom laseru - spojování přerušovaných profilů např. tažného vozidla a přívěsu a naopak rozdělení profilu, jsou-li změřena dvě vozidla jedoucí těsně za sebou).



Obr. 6.4 3D model cisterny a snímek z přehledové kamery

6.4 URČENÍ RYCHLOSTI VOZIDLA

Rychlost lze určit z časového posunu mezi profily stejného automobilu ze dvou za sebou umístěných kamer (vzdálenost 0,25 m). Posun je stanoven algoritmem, který nejdříve každý signál derivuje (nalezne význačné difference). Poté pro každou derivaci (špičku) z první kamery hledá odpovídající špičku na profilu z druhé kamery a vypočte průměr z určených jednotlivých posunů. Z nalezeného posunu r_p je pak vypočtena rychlost podle vztahu (4.5).

7 KLASIFIKACE

Aby bylo možné testovat kvalitu klasifikačního procesu, bylo třeba sestavit množinu testovacích vozidel. Z naměřených dat pořízených jednak v Brně na ulici Sportovní a jednak v Rudné u Prahy byla vybrána sada vozidel, která vstupuje do klasifikace (celkem 1268 vozidel). Dílčím vstupem je vždy výškový profil vozidla a jeho boční snímek.

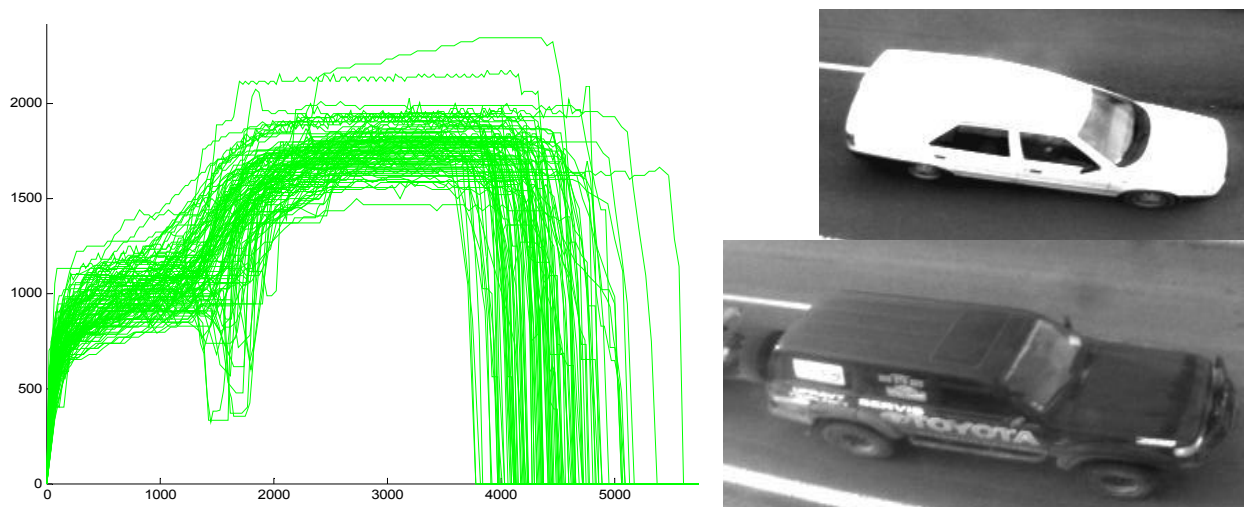
Před samotným návrhem celého rozhodovacího procesu pro konkrétní množinu dat je důležité si zodpovědět několik otázek týkajících se povahy zkoumaných dat a klasifikačních tříd a vyřešit několik dílčích úloh – definovat jednotlivé kategorie a vozidla roztrždit (kapitola 7.1); zvolit vhodné příznaky (kapitola 7.2); vybrat vozidla, která budou zařazena do trénovací množiny (kapitola 7.3); vybrat klasifikační metodu a nastavit klasifikátor (kapitola 7.4). Vzhledem k tomu, že jiné příznaky budou vhodné například pro rozhodovací strom a jiné pro neuronovou síť, je třeba mít již na začátku práce představu o řešení všech těchto dílčích úloh a postupně jen jednotlivé kroky dopracovávat.

7.1 DEFINICE KATEGORIÍ

V České republice se klasifikují vozidla podle několika kritérií, např. podle typu a účelu vozidla (L, M, N, ...) nebo se zařazují do hmotnostních kategorií. Pro bezpečný vjezd do tunelu nebo pod most je třeba znát maximální výšku vozidla a např. pro parkovací účely je potřeba informace o jeho délce. Kritérií pro třídění může být ještě více (počet náprav, počet dveří, světlá výška vozidla atd.). Je-li změřen výškový profil vozidla, může být toto vozidlo snadno zařazeno do výškové nebo délkové kategorie. S vhodnou trénovací množinou lze odhadnout i hmotnost vozidla a počet náprav. Kompletní výškový profil je však velice silný nástroj, který dává informaci především o tvaru vozidla, proto byly po úvaze vybrány kategorie, které se částečně drží třídění podle typu a účelu vozidla a částečně intuitivního třídění podle tvaru. Kategorie však mohou být voleny i jinak. Při jiné kategorizaci by bylo třeba znovu zvážit výběr příznaků a klasifikátor znovu naučit.

Vozidla byla podle bočního snímku a vykresleného výškového profilu zařazena do jedenácti tříd: 1. osobní vozidla, 2. rozměrná osobní vozidla, 3. dodávky, 4.-7. malá a velká nákladní vozidla s korbou a boxem, 8.-9. kamiony s korbou a boxem, 10. tahači, 11. autobusy. Klasifikuje se vždy jen první část vozidla, tzn. vozidlo bez případného přívěsu.

V úvahu musí být brán fakt, že nejsou dané přesné hranice mezi třídami. Jednotlivé kategorie se částečně překrývají, např. hranice mezi malými (kat. 1) a velkými osobními automobily (kat. 2) je velmi neostrá a vozidla byla často zařazena spíše intuitivně. Tento problém hraje velkou roli i při samotném hodnocení navržených klasifikátorů. Není jisté, zda bylo vozidlo již na začátku špatně zařazeno do příslušné kategorie nebo zda chyboval navržený klasifikátor.



Obr. 7.1 Příklad 2. kategorie (rozměrná osobní vozidla) – graf všech vozidel, typický malý a velký zástupce kategorie

7.2 VÝBĚR PŘÍZNAKŮ

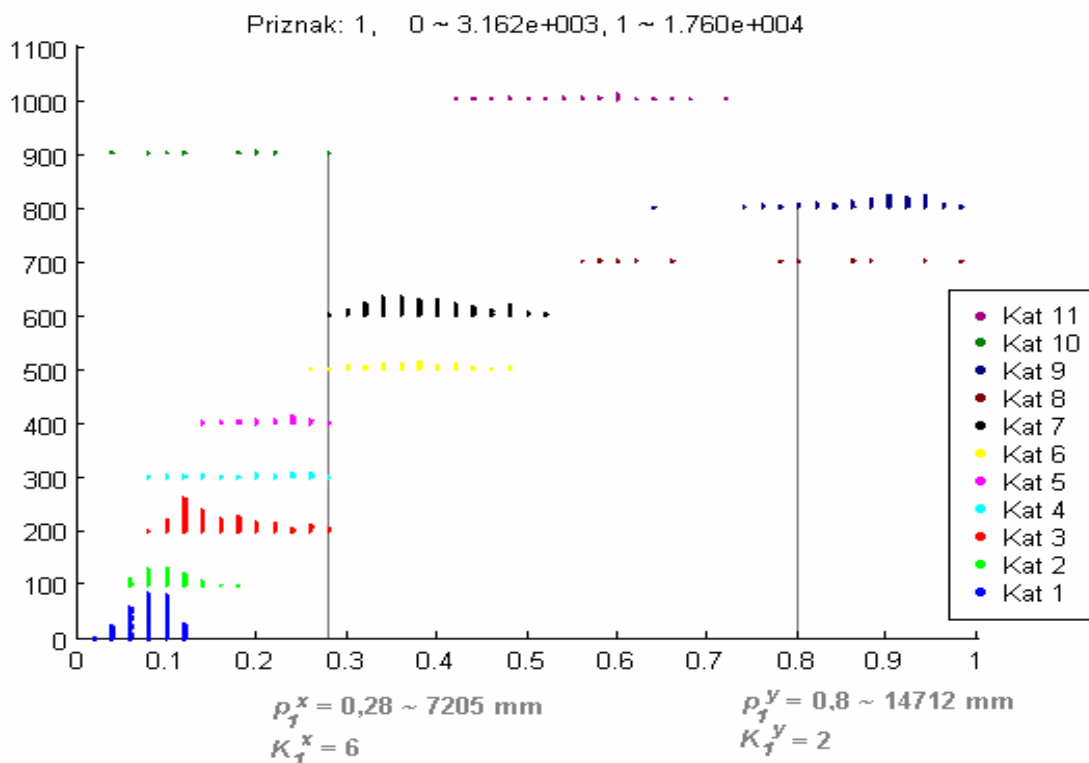
Vozidla by bylo možné klasifikovat na základě celého profilu (např. korelací se známými vzory), ale to by bylo výpočetně i paměťově náročné. Proto musí být vozidla popsána co nejmenším počtem příznaků, které je však budou stále dostatečně dobře charakterizovat. Kvalitu příznaků, resp. to, jaký význam budou jednotlivé zvolené příznaky mít pro celkovou kvalitu klasifikace, lze většinou jen velmi těžce určit. Obecně lze však říci, že pro výběr příznaků je zásadní jak je tento příznak „široký“ uvnitř jedné kategorie a jak se jednotlivé kategorie v rámci tohoto příznaku překrývají (minimální rozptyl hodnot příznaků uvnitř jedné třídy a maximální vzdálenosti mezi jednotlivými kategoriemi). Proto byl pro každý příznak a každou kategorii sestaven histogram (viz Obr. 7.2 – nanormované histogramy délky).

Pro posouzení kvality příznaků bylo navrženo kritérium vycházející ze sestavených histogramů a popsané následujícími vztahy:

$$K_d^v = \sum_{k=1}^{KAT} t^k \quad \text{pokud } \min(p_d^k) < p_d^v < \max(p_d^k) \text{ tak } t^k = 1, \quad (7.1)$$

$$\text{jinak } t^k = 0,$$

kde K_d^v je hodnota dílčího kritéria pro každé vozidlo v a příznak d , KAT je celkový počet kategorií (11), $\min(p_d^k)$ představuje minimální hodnotu příznaků d z kategorie k a podobně $\max(p_d^k)$ je maximální hodnota příznaků d z kategorie k . Kritérium v podstatě představuje test, do kolika kategorií je vozidlo v s hodnotou příznaku p_d zařazeno na základě vymezeného tolerančního pásma pro každou kategorii. Obr. 7.2 ukazuje hodnotu kritéria pro dvě ukázková vozidla – vozidlo x s hodnotou prvního příznaku $p_1^x = 0,28$ a vozidlo y s $p_1^y = 0,8$. Jak je vidět z obrázku, vozidlo x bude na základě tohoto příznaku klasifikováno do šesti tříd, kdežto vozidlo y jen do dvou tříd.



Obr. 7.2 Histogramy délky jednotlivých kategorií (barevně odlišeny)

Celková hodnota kritéria pro jeden příznak d a pro všechna vozidla ($AUT = 1268$) je:

$$K_d = \frac{1}{AUT} \sum_{v=1}^{AUT} K_d^v, \quad (7.2)$$

Pomocí tohoto principu a obecné znalosti o tvarech vozidel bylo vybráno 16 „nejnadějnějších“ příznaků, které by měly mít největší přínos pro správnou klasifikaci. Ještě důležitější než hodnota kritéria jednotlivých příznaků je však hodnota kombinace několika příznaků (důležitější je, jak pracuje příznak v kombinaci s ostatními než kvalita jednoho konkrétního příznaku). Hodnota kritéria pro daný výběr příznaků se vypočte jako:

$$K = \frac{1}{AUT} \sum_{v=1}^{AUT} K_{komb}^v, \quad (7.3)$$

kde K_{komb}^v představuje pro dané vozidlo v počet kategorií, do kterých toto vozidlo patří na základě všech svých aktuálně vybraných příznaků.

Jako nejlepší vzhledem k hodnotě kritéria a počtu příznaků se jeví kombinace osmi příznaků, pro které $K = 1,1822$. Další zvyšování počtu atributů již neznamená zásadní snížení hodnoty kritéria, ale vede k vyšší časové náročnosti výpočtů (pořízení příznaku, učení, klasifikační proces). Vybrané příznaky tedy jsou: délka, průměrná výška první desetiny vozidla, průměrná výška celého vozidla, poloha těžiště, obsazenost (poměr obsahu plochy pod profilem ku obdélníku opsanému křivce), obsazenost poslední desetiny vozidla, obsah, směrodatná odchylka.

Všechny příznaky lze určit během jednoho průchodu změřeným profilem vozidla. Žádný příznak nevyžaduje žádnou časově náročnější operaci. Jelikož se většinou pracuje s průměrnými hodnotami, nejsou příznaky příliš ovlivňovány drobnými chybami měření jednotlivých vzorků profilu.

7.3 TRÉNOVACÍ MNOŽINA

Další důležitou součástí návrhu klasifikačního postupu je naplnění trénovací množiny. Otázkou je, jak mnoho trénovacích vzorů je zapotřebí a jaká je nejlepší strategie pro jejich výběr. Tento problém byl vyřešen použitím algoritmu, který v podstatě počítá Euklidovskou vzdálenost mezi právě analyzovaným vozidlem a všemi vozidly dané třídy, která již byla do trénovací množiny zařazena. Pokud je i nejbližší vozidlo stále vzdálenější než určitá mez, je toto vozidlo přidáno do množiny.

Tímto postupem je zajištěno to, že trénovací množina má minimální počet prvků, které však vždy dobře reprezentují příslušnou kategorii. V množině jsou tak zaznamenána jednak všechna atypická vozidla a na druhou stranu i běžná, často se vyskytující vozidla, která jsou však vždy zastoupena pouze jedním zástupcem. Tabulka 7.1 ukazuje počty vozidel zařazených do testovací a do trénovací množiny. Z tabulky lze vidět, že pro trénování je použita zhruba jen pětina všech vozidel.

kategorie	1	2	3	4	5	6	7	8	9	10	11	Σ
vozidel v kategorii	291	110	239	52	49	83	245	18	132	12	37	1268
počet trén. vzorů	21	23	46	26	25	42	33	9	18	6	11	260


Tab. 7.1 Počet trénovacích vzorů vzhledem k celkovému počtu vozidel v kategoriích

7.4 UMĚLÁ NEURONOVÁ SÍŤ

V rámci návrhu optimálního klasifikačního postupu bylo testováno několik klasifikačních metod – rozhodovací stromy, fuzzy logika, různé neuronové sítě, metoda k -nejbližšího souseda, ale i prostá korelace signálů a jiné. V porovnání klasifikátorů hraje významnou úlohu nejen výsledná úspěšnost klasifikace, ale i například časová a paměťová náročnost přípravy dat a samozřejmě i samotné klasifikace. Podstatná je i forma získaných výstupů klasifikátoru či citlivost na drobné chyby vstupů atd. Po přihlednutí k těmto kritériím byla pro klasifikaci vybrána neuronová síť.

Bylo vyzkoušeno několik druhů sítí s různými konfiguracemi. Každá testovaná síť byla učena na trénovací množinu tvořenou 260 vozidly vybranými pomocí algoritmu popsáno v předcházející kapitole, kdy každé vozidlo je určeno osmi příznaky (viz kapitola 7.2). Po naučení byla vždy síť simulována na celou sadu vozidel a byla vyhodnocena úspěšnost dané sítě. Tímto způsobem byla vybrána konfigurace, která se v průměru učila nejlépe.

Použita tedy je dopředná třívrstvá síť se zpětným šířením chyby (*multiple feed-forward layers backpropagation*) s počty neuronů 8 - počet příznaků, 27 a 11 – počet kategorií (viz Obr. 7.3).



Obr. 7.3 Použitá třívrstvá neuronová síť

Přenosová funkce jednotlivých neuronů byla nastavena jako tangenciální sigmoida (*transfer function* – TANSIG). Jako typ učení byl použit algoritmus backpropagation s modifikací Levenberg-Marquardt (*training function* – TRAINLM). Jako chybová funkce byla použita metoda minimalizace kvadrátů odchylek (*performance function* - MSE).

Naučená síť byla testována na celé množině všech 1268 vozidel. Jako výsledná výstupní kategorie je pro každé vozidlo vybrána ta, která dosahuje maximální hodnoty výstupu. Tato síť stanovená kategorie byla porovnána s žádanou a bylo určeno, zda bylo vozidlo správně klasifikováno či nikoliv. Pro každou kategorii byla vypočtena celková procentuální úspěšnost klasifikace do této třídy a byla také určena celková úspěšnost klasifikace pro všechna vozidla. Výsledky dosažené popsanou sítí jsou shrnuty v následující tabulce.

kategorie	1	2	3	4	5	6	7	8	9	10	11	Σ
vozidel v kategorii	291	110	239	52	49	83	245	18	132	12	37	1268
úspěšnost klasifikace	99,66	97,27	97,91	98,08	100	98,80	99,18	100	100	100	100	98,97

Tab. 7.1 Procentuální úspěšnost klasifikace

V rámci testů byly vyzkoušeny i jiné kombinace příznaků, ty ale dosahovaly průměrně nižší úspěšnosti klasifikace. Tím byla ověřena správnost zvoleného principu výběru příznaků (viz kapitola 7.2). Testovány byly i jinak sestavené trénovací množiny (než je popsáno v kapitole 7.3), např. náhodný výběr, ruční výběr typických představitelů kategorií nebo prostý výběr například první pětiny vozidel z každé kategorie. I zde se ukázalo, že způsob výběru vozidel, na která se bude neuronová síť učit, byl dobře zvolen a dosahuje ve srovnání s jinou strategií výběru (přibližně stejného počtu trénovacích vzorů) nejlepších výsledků.

7.5 ZHODNOCENÍ KLASIFIKACE

Navrhovaný klasifikační postup není zcela jistě jediný možný přístup k tomuto problému a také pravděpodobně není nejlepší. Možností jak tuto úlohu třídění vozidel řešit je celá řada a některé z nich byly i ověřeny. Cílem této části návrhu systému bylo především ověřit, že profil vozidla může vést k úspěšné klasifikaci a kompletně navrhnout jeden z možných postupů návrhu klasifikátoru tak, aby tento postup mohl být použit i v případě změny definic jednotlivých kategorií podle požadavků případného zákazníka.

Klasifikátor (případně již samotné zpracování profilu) může vedle třídění do několika kategorií zjišťovat i další údaje o vozidle. Na základě profilů bylo např. u vozidel zjišťováno, zda měly přívěs. Dále by bylo možné odhadovat, zda vozidlo s korbou veze náklad či nikoliv. Vhodně zvolenými kategoriemi lze také odhadnout počet náprav vozidla nebo jeho hmotnost.

Obecně by bylo vhodné použít pro klasifikaci dva nezávislé principy, které by se navzájem potvrzovaly (např. kombinace s metodou k -nejbližšího souseda či rozhodovacím stromem). Lze také využít čelní snímky pořízené systémem pro určení státní poznávací značky (čelní masky např. osobního automobilu, nákladního vozidla nebo kamionu se výrazně liší tvarem i velikostí).

8 ZÁVĚR

Důležitost sběru, záznamu a následné analýzy silničních dat pro současnou dopravu je bezesporná. Pořízená data se uplatňují při plánování infrastruktury, monitorování dopravy, při jejím řízení, řešení krizových stavů, trestání přestupků. Vedou tak např. ke snížení počtu dopravních nehod, návrhu bezpečných a svou kapacitou dostačujících komunikací, větší plynulosti dopravy, spravedlivějšímu výkonovému zpoplatnění komunikací a k dalším příjemnějším pohybům na našich silnicích. Metodou, která dokáže v současné době zjistit o vozidle nejvíce informací, je metoda založená na měření doby letu paprsku (TOF).

Nový přístup do této problematiky přináší aktivní triangulační technika, která, jak ukázal sestavený prototyp a provedené testy, může metodě TOF cenově i svou funkčností úspěšně konkurovat. Je to alternativní metoda, která je plně realizovatelná. Její výhodou oproti metodě založené na měření doby letu je nižší cena. Na základě postupů a výsledků měření lze totiž předpokládat, že je možná konstrukce jednoúčelového zařízení, jehož cena by se při sériové výrobě mohla pohybovat kolem 20 tis. Kč (oproti skenerům např. od firmy SICK za nejméně 100 tis. Kč). Další výhodou je také vzorkovací frekvence nového přístupu, která je dána řádkovou frekvencí použitých kamer (běžně i 40 kHz). Přitom do jednoho řádku lze promítat i více laserových paprsků, a tedy je možné pokrýt jeden jízdní

pruh pouze jednou přijímací optikou a elektronikou. S tímto souvisí i další výhody spočívající v tom, že není třeba zajišťovat natáčení skenovacího zařízení (jako u metody TOF). Výhodou je i použití stejné technologie, jaká se využívá pro rozpoznání státní poznávací značky. Oba systémy jsou založeny na analýze kamerových snímků a mohou tak velice dobře spolupracovat.

Obsahově je tato práce pojata jako široké komplexní téma skládající se z řady dílčích problémů řešených samostatně (např. hardwarové pořízení dat nebo třídění vozidel apod.). Každý takto řešený problém přispívá svojí měrou k ucelenosti práce, která v konečné podobě především předkládá výsledky dokazující úspěšnost triangulační techniky v této oblasti.

V rámci řešení práce byly splněny všechny hlavní cíle stanovené ve druhé kapitole. Nejdříve byl proveden teoretický rozbor aplikace triangulační techniky pro sběr silničních dat. Z dostupného hardware byly vybrány jednotlivé komponenty potřebné pro tuto techniku měření a na základě rozboru bylo navrženo opticko-mechanické uspořádání těchto základních komponent (kamer a zdrojů světla vůči sobě a vzhledem k měřeným objektům). Dále byla vypočtena chyba měření. Další krok spočíval v realizaci experimentálního měřicího zařízení dle návrhu a ve vyřešení postupu jeho kalibrace.

Takto sestavené zařízení bylo umístěno na portál nad vozovkou a byla pořízena sada vzorků snímků vozidel. K tomu posloužilo vyvinuté programové prostředí (jádro převzato z aplikací řešených firmou Camea a vhodně upraveno pro tuto aplikaci) doplněné o základní prvotní algoritmy vedoucí k obrazovému zaznamenání projíždějícího vozidla na třech kamerách (dvě lineární měřicí a jedna plošná přehledová kamera). Na získané sadě snímků byly dále laděny algoritmy (detekce laseru na řádku, detekce začátku a konce vozidla, filtrace profilu, výběr nejvhodnějšího profilu atd.). Zaznamenaná vozidla také posloužila k sestavení testovací množiny vozidel pro návrh postupu klasifikace (volba příznaků, naplnění trénovací množiny, volba metody klasifikace a nastavení klasifikátoru).

Takto byl vytvořen systém, který je schopen změřit řadu parametrů vozidla (především délku, výšku, výškový profil a rychlost) a vozidlo správně zařadit do příslušné kategorie. Systém je založen na dosud v této oblasti neaplikované technice. Neomezuje rychlost a plynulost provozu (nevyžaduje žádné zpomalení vozidel) a neohrožuje bezpečnost účastníků silničního provozu (bezkontaktní měření, svícení laserů pod hygienickými limity). Zařízení lze dále vylepšovat a doplňovat o další funkce, a tím rozšiřovat možnosti jeho použití.

Navržený systém může být použit pro měření základních parametrů projíždějících vozidel (výška a délka). Jelikož systém umožňuje měřit i okamžitou rychlost vozidel, mohl by být aplikován i k tomuto účelu. Podstatným přínosem, který odlišuje navržený systém od jednoduchých optických bran, smyčkových senzorů či od radarů, je však možnost získat celý výškový profil (popřípadě několika profilů) vozidla. Tento parametr výrazně rozšiřuje možnosti nasazení systému, a to především využitím změřeného profilu pro klasifikaci vozidel do několika kategorií respektujících tvar vozidel. Nabízí se možnosti uplatnění při monitorování dopravní situace a při tvorbě dopravních statistik vztažených ke kategorii vozidel. Komplexní a velice přínosný nástroj může vzniknout spojením se systémem pro čtení SPZ. Příkladem použití může být kontrolní systém při elektronickém výběru mýtného.

9 POUŽITÉ ZDROJE

- [1] CAMEA s.r.o. UNICAM vizuální systémy pro monitorování dopravy [online]. c2004, poslední revize březen 2005 [cit. 2005-04-01]. <<http://www.camea.cz/cz/products/unicam>>.
- [2] HONEC, P., PETYOVSÝ, P., RICHTER, M., GREBENÍČEK, F., VALACH, S. 3D Object Surface Reconstruction. In *13th International Conference of Process Control*. Bratislava: Slovak University of Technology, 2001, pp. 94-95.
- [3] PŘIBYL, P., MICHALÍK, J. Elektronické platby mýtného: komunikace a interoperabilita. In *Automatizace*, duben 2005, ročník 48, číslo 4, str. 251 - 254. ISSN 0005-125X.
- [4] PLIŠKA, Z. Elektronický výběr poplatků. In *Automa* [online]. rok 2003, číslo 12. [cit. 2005-04-11], str. 37. <<http://www.automa.cz/automa/2003/au120337.htm>>.
- [5] MENCL, J. Systémy a metody pro zjišťování údajů o dopravě a pro automatické rozpoznávání událostí: co nabízí trh? [online]. c2003, poslední revize prosinec 2003 [cit. 2005-04-11]. <www.datis.cdail.cz/EDICE/Telema/IDS2004/ids4_04.pdf>.
- [6] INTERNATIONAL ROAD DYNAMICS. Sensors & Accessories [online]. c2005 [cit. 2005-03-25]. <<http://products.irdinc.com/html/sensor/index.htm>>.
- [7] SICK AG. Laser Measurement systems – technical description [online]. c2003, last rev. June 2003 [cit.2005-04-20]. <<http://www.sick.com/saqqara/IM0012759.PDF>>.
- [8] HAUBECKER, H., GEIBLER, P. *Handbook of Computer Vision and Applications: Volume 1, Sensors and Imaging*. San Diego: Academic press, 1999. 657 pages. ISBN 0-12-379771-3
- [9] VERNON, D. *Machine Vision*. New York: Prentice Hall, 1991. 255 p. ISBN 0-13-543398-3.

10 CURRICULUM VITAE

Jméno: Ing. Ilona Kalová
Narozena: 20.9.1978 v Uherském Hradišti
Kontakt: xkalov00@stud.feec.vutbr.cz
ÚAMT, FEKT VUT v Brně, Kolejní 2606/4, 612 00 Brno
Tel: +420 5 4114 3647, Fax: +420 5 4114 1123

Vzdělání

- 2003-** **VUT v Brně**, Fakulta elektrotechniky a komunikačních technologií, Ústav automatizace a měřicí techniky
Doktorský studijní program Elektrotechnika, elektronika, komunikační a řídicí technika, obor Kybernetika, automatizace a měření
Státní doktorská zkouška: 24.6.2005
- 1998-2003** **VUT v Brně**, Fakulta elektrotechniky a komunikačních technologií, Ústav automatizace a měřicí techniky
Magisterské studium oboru Kybernetika, automatizace a měření
Diplomová práce: Kontrola kvality svarů automobilových disků
- 1990-1998** **Gymnázium Zlín**, osmiletý studijní program

Praxe

- 2004-** **Centrum aplikované kybernetiky**, výzkumný pracovník
- 2001-2004** **CAMEA spol. s r.o.**, technický pracovník

Oblasti zájmu

Počítačové vidění a zpracování obrazu
Počítačová grafika
Rekonstrukce 3D objektů optickými metodami

11 PUBLIKACE

- [10] KALOVÁ, I. Kontrola kvality svarů automobilových disků. Diplomová práce na ústavu AMT, FEKT, VUT v Brně, vedoucí práce Doc. Ing. Jozef Honec CSc., 2003.
- [11] KALOVÁ, I. Rekonstrukce povrchu prostorových objektů. Semestrální práce 1 na ústavu AMT, FEKT, VUT v Brně, vedoucí práce Doc. Ing. Jozef Honec CSc., 2002.
- [12] KALOVÁ, I., RICHTER, M. Inspection of Welding Seams. In *15th International DAAAM Symposium*. Vienna: DAAAM International, 2004, p. 197 – 198. ISBN 3-901509-42-9.
- [13] KALOVÁ, I. Quality Inspection of Passenger Car Wheels. In *Proceedings of the 10th Conference STUDENT EEICT 2004*. Brno: Ing. Zdeněk Novotný CSc., 2004, s. 376 - 380, ISBN 80-214-2636-5.
- [14] KALOVÁ, I. Quality Inspection of Passenger Car Wheel. In *STUDENT EEICT 2004*. Bratislava: Vydavateľstvo STU, 2004, s. 100 – 103. ISBN 80-227-2057-7.

- [15] KALOVÁ, I., HORÁK, K. Optické metody měření 3D objektů. In *Elektrorevue - Internetový časopis* [online]. 2005/23. 12 str. <<http://www.elektrorevue.cz>>.
- [16] KALOVÁ, I., LISZTWAN, M. Active Triangulation Technique. In *5th International Conference of PhD Students*. Miskolc: University of Miskolc, 2005, p. 99 – 104. ISBN 963 661 673 6.
- [17] KALOVÁ, I., LISZTWAN, M. Industrial Applications of Triangulation Technique. In *Proceedings of IFAC Workshop on Programmable Devices and Embedded Systems - PDeS 2006*. Brno: Brno University of Technology, 2006, p. 258 – 263. ISBN 80-214-3130-X.
- [18] KALOVÁ, I., LISZTWAN, M. Image processing in traffic applications. In *Proceedings of GVIP 2005*. Cairo, EG: , 2005, p. 6 – 11.
- [19] KALOVÁ, I., HONEC, P. Přístupy k řešení systémů počítačového vidění v průmyslu. In *Automatizace*, 2005, roč. 48, č. 11, s. 680 - 683. ISSN 0005-125X.
- [20] KALOVÁ, I., HONEC, P. Počítačové vidění v průmyslu a dopravě. In *Automatizace*, 2005, roč. 48, č. 12, s. 756 - 761. ISSN 0005-125X.
- [21] LISZTWAN, M., KALOVÁ, I. Not Straight Line Enhancement and Detection In *Proceedings of the 16th International DAAAM Symposium*. Vienna: DAAAM International, 2005, p. 227 - 228, ISBN 3-901509-46-1.
- [22] HORÁK, K., KALOVÁ, I. Řízení expoziční doby CCD kamery. In *ELEKTROREVUE*. 2006, roč. 2006, č. 2006/19. ISSN 1213-1539.
- [23] BRADÁČ, Z., KALOVÁ, I., VALACH, S., ŽALUD, L., RICHTER, M. Kamerový systém pro zkušebnu zdrojů ionizujícího záření. (výzkumná zpráva)
- [24] HORÁK, K., PETYOVSKÝ, P., RICHTER, M., KALOVÁ, I. Praktické programování v cpp. (elektronické texty)

12 ABSTRACT

The aim of this thesis was to devise a system for automatic collection of traffic data based on active triangulation measuring technique. The system enables measuring of the vehicle length, height profile and velocity without constraint of its speed (free-flow system) and without necessity to put some device into the vehicle. The vehicles are classified into defined categories according to the profiles.

Theoretical analysis of triangulation technique, design of optic-mechanical configuration of all basic components and error computation were accomplished. On the next step hardware was selected and adapted and experimental measuring device was put into practice according to the design. Procedure of calibration was solved. This device was situated on a portal above the road and set of vehicles samples was acquired. Arranged software with basic primal algorithms was used for image record of passing cars. Hereafter the extension algorithms were debugged on this set (laser detection on image row, vehicle start and end detection, profile filtration, best profile selection etc.). Registered vehicles were used for composition of test series for design of classification procedure (attributes choice, generation of training set, classification method choice and classifier setting).

Designed system can be used e.g. for monitoring of traffic situation (data collection, traffic statistics), vehicles classification for toll collecting or in systems for entry check (according to height and vehicle type) or for vehicles velocity measuring.