

Identifikácia porúch vozoviek z výstupov zariadenia LineScan

Rozborová úloha

Zodpovedný riešiteľ: Mgr. Ondrej Svačina

október 2018



Identifikácia porúch vozoviek
z výstupov zariadenia LineScan

Obsah

1	Úvod.....	4
1.1	Skratky.....	4
1.2	Termíny a definície	5
2	Postupy a metódy identifikácie porúch vozoviek z vizuálnych záznamov	7
2.1	Zdroje vizuálnych záznamov	7
2.1.1	Snímkovanie v 2D.....	7
2.1.2	Snímkovanie v 3D.....	8
2.2	Spracovanie vizuálnych záznamov	10
2.3	Výstupné údaje	11
2.4	Zostava LineScan SSC	12
3	Softvérové prístupy k extrakcii informácií z vizuálnych záznamov.....	14
3.1	Tradičné prístupy s použitím filtrov.....	14
3.1.1	Prahovanie intenzity.....	14
3.1.2	Narastanie oblastí	15
3.1.3	Detekcia hrán.....	15
3.1.4	Matematická morfológia	15
3.2	Princípy s využitím strojového učenia sa.....	16
4	Experimentálne overenie neurónovej siete pre detekciu porúch povrchu vozovky	17
4.1	Úvod	17
4.2	Návrh typov rozpoznávaných porúch	17
4.3	Vstupné údaje	20
4.4	Údaje pre experimentálne overenie.....	20
4.5	Výstupné údaje	20
4.6	Návrh metódy.....	21
4.7	Dosiahnuté výsledky	21
5	Návrh metodiky vyhodnotenia vizuálnych záznamov zariadenia LineScan	23
5.1	Meranie.....	23
5.2	Rozsah merania.....	23
5.3	Vyhodnotenie a spracovanie merania	23
5.4	Navrhované výstupy.....	24
6	Záver	25
7	Odkazy	26

1 Úvod

Systém hospodárenia s vozovkami (SHV) predstavuje systém, účelom ktorého je zabezpečenie efektívneho využívania vozoviek cestných komunikácií za konkrétnych dopravno-prevádzkových a klimatických podmienok a materiálových, technologických a finančných možností [1].

Nevyhnutným vstupom do SHV je stav vozoviek – aktuálny v danom roku hodnotenia, ako aj stav minulý. Stav vozoviek je možné charakterizovať rôznymi veličinami prevádzkovej spôsobilosti alebo prevádzkovej výkonnosti. Prevádzková spôsobilosť vozovky predstavuje schopnosť vozovky plniť požadované prevádzkové funkcie a na Slovensku sa vyjadruje veličinami nerovnosti, drsnosti a stavu povrchu vozovky. Prevádzková výkonnosť vozovky je miera schopnosti vozovky odolávať namáhaniu do dosiahnutia medzného stavu únosnosti vyjadrená zvyškovým počtom opakovaných zaťažení návrhovou nápravou; na Slovensku sa počíta z meraní únosnosti rázovým deflektometrom.

Na zistenie stavu povrchu vozovky pre potreby SHV sa na Slovensku využíva v súčasnosti viacero spôsobov: orientačné zistenie zo záznamov hlavných prehliadok ciest [2], podrobných vizuálnych prehliadok vozoviek [3], rýchlych vizuálnych prehliadok zariadením Videocar [4] a meraní zariadením LineScan [5].

Hlavné prehliadky ciest sa realizujú raz ročne a poskytujú subjektívny pohľad správcu na stav povrchu vozovky. Podrobné vizuálne prehliadky (PVP) poskytujú detailný záznam o poruchách vozoviek, ale ide v princípe o pešie pochôdzky s manuálnym záznamom porúch, a preto sú nevhodné pre zisťovanie stavu vozoviek na úrovni cestnej siete. Navyše, podobne ako pri hlavných prehliadkach ciest, sú z povahy skôr subjektívne, hoci v menšej miere. Rýchle vizuálne prehliadky zariadením Videocar poskytujú len veľmi hrubý detail o poruchách (napr. trhliny sa rozlišujú len na pozdĺžne a priečne, pri priečných trhlínach sa zapisuje šírka len v troch stupňoch). Podobne, ako pri predchádzajúcich dvoch metódach, sú výsledky ovplyvnené subjektívnym pohľadom hodnotiteľa a navyše v súčasnosti tieto poruchy ani nevstupujú do informačného systému IS MCS SHV.

Zariadenie LineScan je schopné pri takmer bežnej cestovnej rýchlosti na väčšine cestných komunikácií (CK) zostaviť detailný fotografický záznam povrchu vozovky. Tento je možné neskôr v kancelárii analyzovať a extrahovať z neho údaje o poruchách vyskytujúcich sa na povrchu vozovky. Tento prístup sleduje aktuálny trend v diagnostike vozoviek, pri ktorom sa cestovnou rýchlosťou zbierajú automatizovane strojovým vybavením údaje a tieto sa neskôr spracovávajú v kancelárii. Takýto prístup je jednak bezpečnejší pre pracovníkov vykonávajúcich diagnostiku vozoviek, ako aj vodičov a minimálne ovplyvňuje plynulosť cestnej premávky.

Výrobca zariadenia LineScan dodáva softvér pre spracovanie fotografických záznamov, umožňujúci extrakciu trhlín a výpočet unifovaného indexu trhlín (UCI). Rozborová úloha z roku 2010 [6], ako aj súčasná aplikačná prax však ukazujú, že algoritmus tohto softvéru nie je dostatočne kvalitný pre potreby SHV. Za posledné roky však vývoj pri spracovaní obrazu a extrakcii údajov z neho išiel prudko dopredu, predovšetkým vďaka umelej inteligencii a hlbokým neurónovým sieťam. Táto rozborová úloha analyzuje možnosti extrakcie porúch z fotografických záznamov zariadenia LineScan a navrhuje najlepší smer pre ďalšie realizačné kroky k čo najviac automatizovanému systému detekcie porúch.

Rozborová úloha vznikla na objednávku Slovenskej správy ciest v rámci riešenia úloh RVT v roku 2018.

1.1 Skratky

Táto časť obsahuje abecedný zoznam všetkých skratiek použitých v dokumente.

Skratka	Popis
CK	cestná komunikácia (diaľnica, rýchlostná cesta, cesta I., II. alebo III. triedy)

CCD	charge-coupled device; zariadenie s viazanými nábojmi – typ kamerového digitálneho senzora
CNN	convolutional neural network – konvolučná neurónová sieť
CMOS	complementary metal-oxide-semiconductor; doplňujúci sa kov-oxid-polovodič – typ kamerového digitálneho senzora
GigE	gigabitový ethernet; v užšom význame protokol GigE Vision pre rýchly prenos obrazu na dlhšie vzdialenosti s využitím gigabitového ethernetu
IS MCS	Informačný systém modelu cestnej siete – hlavný informačný systém pre technickú evidenciu a správu cestných komunikácií na Slovensku; prevádzkuje ho SSC
IRI	international roughness index – štandardizovaný parameter pozdĺžnej nerovnosti vozoviek
LED	light-emitting diode (svetlo emitujúca dióda)
LCMS	laser crack measurement system – systém detekcie trhlin na báze 3D snímkovania povrchu vozovky laserovým lúčom
LRIS	laser road imaging systems – kamerové zostavy pre snímkovanie vozovky využívajúce laser na osvetlenie
MPD	mean profile depth – stredná hodnota hĺbky profilu. Parameter kvality makrotextúry meraný jednobodovými laserovými systémami.
MTD	mean texture depth – stredná hĺbka textúry. Parameter kvality makrotextúry meraný tradične pieskovou metódou.
NDS	Národná diaľničná spoločnosť, a.s.
PVP	Podrobná vizuálna prehliadka podľa TP 084
RGB	aditívny farebný model so základnými farbami červená (red), zelená (green) a modrá (blue). Farba je v ňom reprezentovaná ako usporiadaná trojica celých nezáporných čísel.
SSC	Slovenská správa ciest
SHV	Systém hospodárenia s vozovkami
TP	technické podmienky Ministerstva dopravy a výstavby SR
UCI	unified crack index – parameter vyjadrujúci plošné poškodenie povrchu vozovky trhlinami

1.2 Termíny a definície

Pri termínoch a definíciách, ktoré sú nižšie uvedené, je potenciálne riziko ich rôznej interpretácie. Pre každý termín je uvedené jeho podrobnejšie vysvetlenie.

Termín	Definícia
neurónová sieť	výpočtový model používaný pri strojom učení založený na vzájomne prepojených jednotkách (neurónoch) transformujúci postupných vstup na výstup postupným prechodom informácií po spojeniach medzi neurónmi a ich úpravou neurónmi
prevádzková spôsobilosť	schopnosť vozovky plniť požadované prevádzkové funkcie
prevádzková výkonnosť	schopnosť vozovky odolávať namáhaniu do dosiahnutia hraničného stavu únosnosti

trhlina	štrbina v materiáli vozovky na jej povrchu, typicky minimálnej šírky 1 mm a dĺžky 25 mm
strojové učenie sa	metóda umelej inteligencie založená na automatickom odvodzaní pravidiel medzi vstupmi a výstupmi počítačom zo vzorovej množiny údajov
umelá inteligencia	prístupy k riešeniu zložitých problémov vyžadujúcich vyššiu mieru intelektu počítačmi
výtlk	lokálny úbytok hmoty v krytovej vrstve na ohraničenej ploche

2 Postupy a metódy identifikácie porúch vozoviek z vizuálnych záznamov

2.1 Zdroje vizuálnych záznamov

2.1.1 Snímkovanie v 2D

Vzhľadom na to, že povrch vozovky je ľahko prístupný a z jeho porúch je možné odvodiť množstvo informácií o stave vozovky ako takej, snaha o identifikáciu porúch a ich spracovanie z povrchu vozovky siaha do dávnych dôb.

Prvé zariadenia vo svete používali klasické optické záznamové zariadenia využívajúce filmové fotoaparáty alebo kamery na klasický 35 mm film. Výhodou týchto systémov je pomerne veľká vernosť zachyteného obrazu (hoci dnešná digitálna technológia sa im už vyrovnáva), ale nevýhodou je komplikované spracovanie. Americký program dlhodobého sledovaných úsekov ešte v nedávnej dobe (2011) využíval záznam na 35 mm film snímaný v noci. Tento film sa následne opticky skenoval do výsledných digitálnych obrázkov v rozlíšení 2.048 pixelov na jeden jazdný pruh v 256 odtieňoch sivej farby (rovnaké rozlíšenie má momentálna sústava LineScan na SSC).

S príchodom analógovej televízie a videa sa začali tieto technológie rovnako používať pri zázname povrchu vozovky. Nahrávalo sa na bežne dostupné médiá, hlavne SuperVHS. Na efektívne spracovanie však bolo potrebné takéto záznamy rovnako skonvertovať do digitálnej podoby, avšak na rozdiel od konvertovaných 35 mm filmových záznamov, analógové video má nižšie rozlíšenie a analógovo-digitálna konverzia vnáša do neho veľa digitálneho šumu.

Dnes sa na bežné účely vizuálneho záznamu povrchu vozovky využívajú plne digitálne záznamové zariadenia. Dva najdôležitejšie prvky každej digitálnej kamery, ktoré aj najviac ovplyvňujú kvalitu záznamu, sú *digitálny senzor* a pred ním predradená *optická sústava*.

V komerčne dostupných kamerách dnes prevládajú dva typy digitálnych senzorov: *CCD* (charge-coupled device; zariadenie s viazanými nábojmi) a *CMOS* (complementary metal-oxide-semiconductor; doplňujúci sa kov-oxid-polovodič). Vo všeobecnosti sa dá povedať, že modernejšie CMOS senzory nahrádzajú staršie CCD.

Optické digitálne senzory môžu snímať obraz v zásade dvomi spôsobmi: *priestorovo* alebo *riadkovo*. Pri priestorovom snímaní (*area scan*) je senzor zostavený z matice svetlocitlivých bodov; sníma sa teda v rámci jednej expozície obraz vo forme obdĺžnika. Pri riadkovom snímaní (*line scan*) je jednou expozíciou zosnímaný obraz jedného riadku a priestorový snímok sa vytvára postupným snímaním predmetu riadok po riadku buď pohybom predmetu voči kamere alebo kamery voči predmetu.

Zostava LineScan SSC používa riadkovú kameru modelu Spyder3 radu 10 od kanadskej spoločnosti Teledyne DALSA so senzorom typu CCD a rozlíšením riadka 2.048 pixelov. Pri snímaní obrazu sa pohybuje kamera montovaná na vozidle voči vozovke.

Riadkové snímanie má voči priestorovému niekoľko výhod, predovšetkým je možné dosiahnuť vyššie rozlíšenie pri rozumných nákladoch, vyšší dynamický rozsah (pomer najjasnejšej a najtmavšej intenzity v obrázku), ostré obrazy pri snímaní pohybujúcich sa objektov a nie je potrebná náročná synchronizácia za sebou idúcich obdĺžnikových snímok pri vytváraní súvislého obrazového pásu.

Pri riadkovom snímaní musí byť použité kvalitné a uniformné osvetlenie a špeciálna širokouhlá optika. Osvetlenie by malo zohľadňovať, že širokouhlé objektívy väčšinou pohlcujú na krajoch viac prechádzajúcich svetelných lúčov ako v strede. Dostupnosť vhodného a kvalitného umelého osvetlenia je kľúčová podmienka na to, aby bol systém pri meraní nezávislý na ambientnom osvetlení a výsledný záznam nebol ovplyvnený slnkom a následnými neželanými tieňmi.

Ako osvetľovacie systémy sa pri 2D skenovaní vozoviek využíva buď tradičné plošné osvetlenie (najčastejšie vo forme vysokovýkonných halogénových lámp alebo LED systémov) alebo osvetlenie

laserovým lúčom vo forme priečného riadka (zostavy využívajúce laser na osvetlenie sa komerčne nazývajú aj *laser road imaging systems* – LRIS).

Optická sústava predstavuje šošovku alebo sériu šošoviek predradených pred digitálny senzor s prípadnou clonou. Najdôležitejšie charakteristiky sú ohnisková vzdialenosť a apertúra (ak je prítomná clona).

Čo sa týka farebnej hĺbky a dynamického rozsahu obrazu, takmer vždy sa na celom svete používa snímanie v odtieňoch šedej, väčšinou vo farebnej hĺbke 8 bitov (256 odtieňov sivej vrátane bielej a čiernej), čo sa zdá byť dostačujúce.

Pri rozpoznávaní trhlín je dôležitá informácia o ich šírke. Je zrejmé, že čím má riadková kamera vyššie horizontálne rozlíšenie, tým je schopná zosnímať trhliny s užšou šírkou pri pevnej šírke snímanej časti vozovky. Spodný limit sa dá spočítať jednoducho z informácie o šírke snímanej časti vozovky (l mm) a rozlíšenia (r px): $\frac{l}{r}$ mm/px. Vďaka použitej optike zostava LineScan SSC sníma 3.500 mm širokú časť vozovky pri horizontálnom rozlíšení 2.048 pixelov. Jeden pixel teda reálne nesie obrazovú informáciu o cca 1,71 mm širokej časti vozovky. Nie je preto fyzicky možné, aby trhliny so šírkou pod touto hranicou táto kamerová zostava zachytila v rozpoznateľnej podobe či už pre človeka alebo pre softvér.

Vzhľadom na to, že vo všeobecnosti sa pod trhlínami majú na mysli štrbiny v materiáli vozovky na jej povrchu so šírkou už 1 mm, je zrejmé, že súčasne používaná zostava SSC nedokáže zachytiť tak jemné trhliny, ktoré by bolo možné sanovať vo veľmi skorom štádiu vývoja. Nebráni to však širokej aplikácii súčasnej zostavy LineScan SSC za predpokladu dostatočne vyspelého automatického systému rozpoznávania trhlín. Práve naopak, na sieťovej úrovni by systém hospodárenia s vozovkami dostal veľmi potrebné dáta o výskyte trhlín na celej dĺžke cestnej siete.

Určite stojí za úvahu nahradenie súčasnej kamery s rozlíšením 2k novou kamerou s rozlíšením 4k alebo ešte vyšším. Súčasná zostava SSC využíva ešte model Spyder3 S3-10 (technológia CCD), ktoré sa vyrábali len vo variantoch 1k a 2k. Neskôr prišiel na trh modernizovaný Spyder3 S3-14 a S3-24, ktoré podporovali aj 4k rozlíšenie. Modely Spyder3 však už sú výrobcom deklarované ako zastaralé. V súčasnosti výrobca Teledyne DALSA ponúka dva modely riadkových kamier: lacnejší modelový rad Linea a drahší Piranha4, oba už založené na technológii CMOS. Piranha4 je dostupná len s dátovým rozhraním CameraLink, Linea s rozhraním CameraLink aj GigE. Keďže súčasná zostava SSC využíva GigE, použitie kamery z radu Piranha4 by znamenalo aj prebudovanie dátových rozhraní a kabeláže vo vozidle. Vhodná náhrada by mohla byť napr. Linea LA-GM-04K08A s rozlíšením 4k s frekvenciou 26.000 riadkov za sekundu v štandardnom móde alebo až 80.000 riadkov za sekundu v TurboDrive (súčasná kamera má snímacu frekvenciu len 18.500 riadkov za sekundu) alebo LA-GM-08K08A s rozlíšením až 8k (snímacia frekvencia 13.000 riadkov/s v štandardnom a 45.000 riadkov/s v TurboDrive režime); obe využívajú GigE rozhranie.

Vyššia frekvencia snímokovania znamená vyššiu maximálnu teoretickú rýchlosť vozidla pri meraní (frekvencia 18.500 riadkov za sekundu pri súčasnej optike a rozlíšení 2k predstavuje maximálne 113 km/h; pri predpoklade využitia rovnakej optiky by kamera s frekvenciou 26.000 riadkov za sekundu vedela merať až do rýchlosti 160 km/h).

Pri súčasnej optike rozlíšenie 4k dosiahne dvojnásobne lepšie detaily (veľkosť pixelu 0,85 mm) a pri 8k štvornásobne lepšie detaily (veľkosť pixelu 0,43 mm).

Zvýšenie rozlíšenia je možné dosiahnuť aj montážou dvoch riadkových kamier s novou optikou pri súčasnom potenciálnom rozšírení skenovacieho priestoru (napr. dve riadkové 2k kamery vedia pokryť šírku 3,5 m z vozovky pri skutočnej šírke pixela 0,85 mm a šírku 4 m z vozovky pri skutočnej šírke pixela 0,98 mm).


2.1.2 Snímkovanie v 3D

S príchodom laserových profilografů a prvotných neúspechoch automatizovanej detekcie porúch povrchu vozovky na fotografických (2D) snímkach sa začali vynárať úvahy o využití priečného

laserového snímkovania vozovky laserovými lúčmi, ktoré by vytvorili 3D záznam povrchu vozovky. Takéto systémy sa označujú ako LCMS – *laser crack measurement systems* (systémy laserového merania trhlín).

Najpoužívanejšie konfigurácie využívajú dva vysokovýkonné laserové projektory umiestnené vo vzájomnej vzdialenosti 2 m na krajoch konzoly v zadnej hornej časti nosného vozidla a kamerový detektor. Laserové projektory premietajú na vozovku úzke 1 mm široké čiary, ktoré sú snímané 3D kamerou. Typické vzorkovacie frekvencie sú 5.600 – 28.000 profilov/s, šírka záberu 4 m v rozlíšení 4k bodov v profile, priečne rozlíšenie (os x) 1 mm, pozdĺžne rozlíšenie (os y, rozstup profilov) 2,5 mm – 1 mm a hĺbkové rozlíšenie (os z) 0,1 – 0,5 mm, maximálna rýchlosť vozidla pri meraní do 100 km/h.

Na rozdiel od 2D snímkovania výstupom nie je matica farieb alebo intenzít jasu vo viditeľnom spektre, ale dve matice – matica hĺbky a matica odrazivosti. Obe sa dajú softvérovo skombinovať do 3D modelu povrchu vozovky:



Obrázok 1 Výstup z typického systému LCMS – hĺbka prevedená na odtiene šedej farby (vľavo), odrazivosť (v strede), zlúčený 3D obraz (vpravo). Prevzaté z [7].

Treba si ale uvedomiť, že nie je pravidlom, aby LCMS snímал súčasne fotografický záznam, takže niektoré prvky rozoznateľné podľa farby, ale s rovnakou alebo podobnou odrazivosťou laserového lúča, nemusia byť viditeľné vo výstupe LCMS.

Systém LCMS boli do súčasnosti použité v zhruba 35 krajinách. [7]

V súčasnosti najznámejší výrobca LCMS systému využíva na detekciu trhlín metódy filtrovania hĺbkových obrazcov založené na predpoklade, že trhlinka sa prejavuje náhlým a relatívne úzkym poklesom v priečnom reze. Problémom pri tomto prístupe sú vyjazdené koľaje a makrotextúra, ktoré tento vzorec môžu narušovať. Softvér pre detekciu preto pracuje s rôznymi parametrami, ktoré treba prispôbovať pre rôzne textúry a materiály povrchu vozovky. [8]

Okrem využitia hĺbkového atribútu by výhodou LCMS mohlo predstavovať súčasné vyhodnotenie makrotextúry povrchu, ktorá sa podľa súčasných štandardov meria jediným 32 kHz alebo 64 kHz laserom – výsledkom je teda záznam makrotextúry v jedinom bode priečneho prierezu vozovky. Keďže LCMS skenujú celú šírku jazdného pruhu, existuje potenciál na plošné meranie makrotextúry vozovky, čo by predstavovalo významný kvalitatívny dátový vstup do SHV. Plošný digitálny model dokonca umožňuje vypočítať nielen parameter MPD makrotextúry, ale aj parameter MTD tradičnej

pieskovej metódy. Na toto využitie by ale bolo vhodné urobiť porovnávacie merania LCMS, jednobodového laserového meracieho systému MPD (napr. súčasný Profilograph GE vo vlastníctve SSC) a manuálnej pieskovej metódy. Teoreticky by mohli kvantifikovať LCMS aj vypieranie povrchu, ale pre tento druh poruchy zatiaľ neboli ani zavedené štandardné parametre.

Okrem otvorených trhlín, na ktoré prvotne boli tieto systémy stavané a makrotextúry, existuje potenciál aj pre meranie priečnej nerovnosti, detekcie výtlkov a zaliatych trhlín. Kombináciou inerciálnej pohybovej jednotky (IMU) je možné týmito systémami merať pozdĺžnu nerovnosť vyjadrenú ako IRI a geometrický priebeh cesty.

Záver z rôznych štúdií automatickej detekcie trhlín z LCMS systémov zatiaľ neukazujú jednoznačne, že by tento problém bol uspokojivo vyriešený, čo sa týka úspešnosti a opakovateľnosti.

Priečne rozlíšenie bolo v súčasných LCMS dosiahnuté na úroveň 1 mm, čo pre detekciu 1 mm a submilimetrové trhliny je nedostačujúce. Reálne je možné uvažovať s detekciou trhlín od šírky cca 2 mm. Na druhej strane, riadkové 2D kamery dnes vedú snímkovať s vyšším ako 1 mm rozlíšením. Kombinácia týchto dvoch technológií by teda mohla byť výhodou.

Výhľadovo by bolo vhodné odskúšať technológiu LCMS aj v slovenských podmienkach, pričom je možné rozšíriť nami navrhovaný prístup detekcie porúch povrchu vozovky na báze konvolučných neurónových sietí o hĺbkový rozmer získaný z LCMS.

2.2 Spracovanie vizuálnych záznamov

Nasnímané obrazové záznamy je potrebné spracovať do formy potrebnej pre ďalšie procesy v rámci systému hospodárenia s vozovkami. Nevyhnutne to znamená vyextrahovať záujmové poruchy, predovšetkým trhliny a tieto štatisticky predspracovať.

Extrakcia porúch zo záznamu môže prebiehať v zásade:

- manuálne,
- automatizovane,
- plne automaticky.

Manuálna extrakcia znamená postupné prezeranie záznamu meter za metrom operátorom v špecializovanom softvéri a označovanie porúch v ňom.

Automatizovaná extrakcia predstavuje automatické predspracovanie záznamu softvérom, ktorý označí prvky v obraze, ktoré sú s najväčšou pravdepodobnosťou (v súlade v ňom naimplementovanými algoritmami) ako trhliny. Následne je ale nevyhnutné, aby operátor takto označené záznamy prešiel opätovne meter za metrom a prípadne chyby opravil.

Plne automatická extrakcia ponecháva operátorovi minimum prácností. Použitý softvér je schopný s vysokou spoľahlivosťou identifikovať poruchy, zvlášť trhliny, bez potreby rutinného prechádzania záznamov operátorom. Je však aj tu žiaduce, aby softvér umožnil prezeranie záznamu s označenými poruchami a prípadne korekcie operátorovi.

Pre úroveň cestnej siete je manuálna extrakcia vylúčená a automatizovaná nevhodná. Je potrebné, pochopiteľne, **využívať plne automatickú extrakciu s minimálnou intervenciou operátora.**

Softvér, ktorým v súčasnosti disponuje SSC, sa dá klasifikovať ako *automatizovaný softvér*. Pred spracovaním jednotlivých záznamov je jednak žiaduce upraviť nastavenia hodnotiaceho algoritmu podľa vlastností zoskenovaného záznamu a jednak nevykazuje prvky vysoko spoľahlivej detekcie (pozri aj [6]).

2.3 Výstupné údaje

Pre ďalšie počítačové spracovanie je potrebné získať zo spracovaných údajov štruktúrované dáta vo forme lokalizácie poruchy, jej kvalitatívnej charakteristike (hlavne typ poruchy) a prípadne doplnkové kvantitatívne atribúty (napríklad dĺžka a šírka trhliny).

Pre hodnotenie na úrovni cestnej siete je potrebné údaje o jednotlivých poruchách zhrnúť do kvantitatívneho parametra (indexu), ktorý bude charakterizovať kvalitu cestnej siete (celej, ako aj na jej častiach) a bude slúžiť ako podklad pre rozhodovacie procesy, primárne pre zostavenie programu údržby, opráv a rekonštrukcií vozoviek.

Na Slovensku je na úrovni cestnej siete zavedených päť hlavných parametrov charakterizujúcich prevádzkovú spôsobilosť na základe stavu povrchu vozovky na úrovni cestnej siete:

- IRI pre pozdĺžnu nerovnosť,
- RUT pre priečnu nerovnosť,
- MPD pre drsnosť povrchu z hľadiska makrotextúry,
- Mu pre celkovú drsnosť na základe pozdĺžneho šmykového trenia,
- UCI pre stav porušenia povrchu trhlinami.

Na úrovni projektu sa využíva parameter IPSV v rôznych obmenách [3]. V zásade ide o váženú plochu porušenia vozovky z údajov podrobných vizuálnych prehliadok.

Ako bolo spomenuté vyššie, pre účely hodnotenia cestnej siete v rámci SHV sú hlavným predmetom riešenia trhliny, nakoľko predstavujú z kľúčových porúch povrchu vozovky jedinú kategóriu, ktorá nie je v súčasnosti uspokojivo meraná s dostatočným výkonom.

Pre trhliny bolo vo svete zavedených veľa rôznych parametrov a metodík ich vyhodnotenia, ako napríklad *cracking score*, *intensity*, *extent by severity class*, *extent by type and severity* a iné. Vo všetkých prípadoch ide v princípe o percentuálny výpočet plochy, na ktorej sa vyskytujú trhliny, rôzne vážený podľa závažnosti, rozsahu, šírky a podobne. Tieto indexy väčšinou vychádzajú z manuálnych prehliadok, na ktorý sa zvykovo eviduje typ poruchy, závažnosť (severity) a rozsah poruchy (extent).

Jeden z prvých indexov pre charakteristiku trhlín na sieťovej úrovni zaviedol H. Lee začiatkom 90. rokov najskôr pod názvom *štandardná hustota trhlín* (standard crack density). [9] Tento index bol zavedený ako reakcia na prvé pokusy s automatizovanou počítačovou detekciou trhlín, založených na prahovaní intenzít jasu. Počíta sa ako podiel počtu pixelov pozitívne identifikovaných ako trhlina voči všetkým pixelom záznamu. Jeho výhoda spočíva v tom, že kombinuje atribúty závažnosti a rozsahu trhlín, ktoré v tej dobe nebolo triviálne určiť počítačovým programom. Neskôr sa tento index začal označovať ako *unifikovaný index trhlín* (unified crack index, UCI), hoci v pôvodnom článku ho autor takto ešte neoznačuje. Neskôr popisuje spôsoby, ako skutočnú hodnotu UCI odhadnúť počítaním nie jednotlivých pixelov, ale počtu štvorcov v mriežke preloženej ponad obrazový záznam, pričom o označení štvorca ako poruchy rozhoduje počet pixelov identifikovaných ako poruchových v rámci neho. Tento spôsob má za cieľ eliminovať nedokonalosti algoritmu detekcie porúch pri vysokom šume [10]. Vďaka tomuto spôsobu je vypočítaný index relatívne stabilný. Pri detekcii trhlín sa využíva dynamická metóda prahovania intenzít, kde prah je funkcia priemerného jasu štvorca.

Neskôr Lee úvahou o súčtoch štvorcov označených ako poruchy v riadkoch a stĺpcoch začal klasifikovať trhliny ako priečne, pozdĺžne a sieťové. Toto rozšírenie UCI nazval *index typu trhlín* (crack type index, CTI). [11]

Ďalší index zaviedol Paterson pod názvom *univerzálny indikátor trhlín* (universal cracking indicator, CI), počítaný ako súčin rozsahu, intenzity a šírky trhliny pre všetky nájdené trhliny. Rozsah je daný ako percentuálna plocha, na ktorej sa nachádza trhlina voči celkovej posudzovanej ploche vozovky, intenzita je podiel celkovej dĺžky trhliny voči ploche $[m/m^2]$ a šírka je priemerná šírka otvorenia trhliny

[mm]. Výsledkom je nezáporné číslo. Je možné určovať špecializované CI pre konkrétne typy trhlín a za predpokladu, že určovať sa budú na danej ploche vždy dominantné trhliny, potom CI bude mať aditívnu vlastnosť (súčet hodnôt CI pre jednotlivé typy bude rovnaký ako CI pre všetky typy). [12]

V USA sa používa štandardná prax pre kvantifikáciu trhlín na povrchoch asfaltových vozoviek z obrazových záznamov využitím automatizovaných metód AASHTO PP 67-10. Prax špecifikuje minimálnu šírku trhlín 1 mm a minimálne kritéria kvality na metódu detekcie trhlín. Výstupné dáta sú poskytované v kroku 100 m. Trhliny sú reportované v piatich záujmových zónach priečného profilu vozovky (medzi okrajom a ľavou stopou, v ľavej stope vozidla, medzi stopami, v pravej stope a medzi pravou stopou a okrajom). Počíta sa rozsah (extent) trhlín ako súčet ich dĺžok a závažnosť (severity) ako priemerná šírka [mm] zvlášť pre priečne, pozdĺžne a ostatné trhliny. Prax priznáva, že metódy v čase jej tvorby sa ešte len rozvíjali (a rozvíjajú sa dodnes) a upozorňuje, že viaceré stanoviská môžu byť predmetom zmeny. Súčasne odporúča, aby detegované trhliny širšie ako 25 mm boli označené na manuálne prezretie, nakoľko pôjde s vysokou pravdepodobnosťou o zaliate trhliny, v ktorých môžu byť prítomné úzke trhliny, a sú tak kombináciou falošného pozitíva a falošného negatíva. [13]

Britská špecifikácia pre tzv. SCANNER prehliadky určuje štyri výstupné parametre pre trhliny: intenzitu trhlín na celej vozovke, intenzitu priečných trhlín, intenzitu rozpadu povrchu a intenzitu trhlín v ľavej a pravej stope. Pri výpočtoch sa používa štvorcová sieť so stranami štvorcov 200 mm. Intenzita trhlín na celej ploche je podiel štvorcov s trhlinami voči počtu všetkých štvorcov v kroku 10 m (podobne ako UCI). Intenzita priečných trhlín sa vyjadruje podielom počtu všetkých štvorcov v celom riadku s priečnymi trhlinami voči počtu všetkých riadkov; uvažuje sa pohyblivé okno o výške dvoch riadkov, pričom keď sa v okne nájde viac ako 20 % štvorcov s trhlinami, na všetky štvorce v okne sa hľadí ako na štvorce s priečnymi trhlinami. Intenzita rozpadu povrchu vozovky je podiel počtu štvorcov, v ktorých bola identifikovaná trhlina a súčasne v jeho susedných štvorcoch nie je nájdená trhlina a v susedných štvorcoch jeho susedoch je najviac jedna, voči počtu všetkých štvorcov. Intenzity trhlín v stopách sú počítané analogicky ako intenzita na celej ploche, pričom sa berú do úvahy len jazdné stopy ako pásy šírky 0,8 m, ktorých okraje bližšie od osi pruhu sú vzdialené od nej 0,6 m. [14]

2.4 Zostava LineScan SSC

SSC disponuje tzv. zostavou *LineScan SSC* s týmito súčastami:

- dvojnápravový prívesný vozík,
- čiernobiela riadková kamera DALSA Spyder3 SG-10-02k40-00-L s optikou 24 mm, riadkové rozlíšenie 2k, dátové rozhranie GigE (gigabitový ethernet),
- LED osvetľovacia sústava z 32 lúčov, pričom každá lampa sa skladá z 12 LED diód,
- senzor rýchlosti vozidla a odometer ako rotačný enkodér montovaný na zadný náboj kolesa vydávajúci 20.000 impulzov na jedno otočenie kolesa,
- GPS modul,
- serverový rack,
- gigabitový ethernet,
- notebook Dell N09X7301 pre riadenie merania,
- benzínový generátor pre napájanie meracej sústavy a meniče napätia,
- ťažné vozidlo.



Obrázok 2 Detail osvetľovacej LED rampy



Obrázok 3 Interiér príviesného vozíka s rackom, záznamovým zariadením a elektroinštaláciou

3 Softvérové prístupy k extrakcii informácií z vizuálnych záznamov

3.1 Tradičné prístupy s použitím filtrov

Ako už bolo spomenuté aj v úvode, najväčší záujem pri spracovaní vizuálnych záznamov povrchu vozovky predstavujú trhliny a je preto prirodzené, že drvivá väčšina súčasných komerčných softvérov v tejto oblasti sa venuje práve nim.

Konceptuálne sa dajú popísať tradičné prístupy automatizovaného rozpoznávania trhlín z obrazového záznamu takto:


1. dekompresia primárneho komprimovaného vstupu do matice,
2. aplikácia špecifických filtrov na odstránenie pozadia a prvkov, ktoré pravdepodobne nie sú trhliny,
3. odstraňovanie šumu a naopak, spájanie výsledných identifikovaných trhlín. Tento krok už väčšinou prebieha v jednobitovej hĺbke (pixel buď je pozitívne identifikovaný ako súčasť trhliny alebo nie).

Na výslednej matici sa potom urobí tradičná geometrická analýza, ak je potrebné identifikovať bližšie povahu trhliny (pričná, pozdĺžna, sieťová a pod.).

3.1.1 Prahovanie intenzity

Metóda prahovania intenzity (intensity thresholding) patrí medzi najstaršie metódy detekcie trhlín v obrazových záznamoch. Spolieha sa výlučne na fotometrické hypotézy a síce, že pixely trhlín sú tmavšie ako zvyšné pixely a distribúcie úrovne sivej farby v trhlíne a nepoškodenom povrchu vozovky sú nezávislé.

Princíp tejto metódy spočíva v hľadaní pixelov, ktorých intenzita leží v nejakom vopred určenom intervale. Tento interval môže byť určený buď globálne, väčšinou empiricky analýzou histogramu, alebo sa môže počítať lokálne pre každý pixel na základe intenzít susediacich pixelov (adaptívne prahovanie) v snahe prispôsobiť sa lokálnym variáciám intenzít. [15]



Obrázok 4 Vľavo histogram s bimodálnou charakteristikou s prítomnými trhlínami; vpravo unimodálny histogram obrázku bez trhlín. Obrázok prebratý z [16].

Metódu prahovania intenzít využíva aj súčasný softvér pre spracovanie záznamov LineScan od jeho výrobcu.

Výhodou týchto metód je, že sú jednoduché a ich spracovanie je relatívne rýchle. Výsledky sú však nespoľahlivé a vo všeobecnosti tieto metódy trpia veľkým množstvom falošných pozitív, čo vyplýva z faktu, že dané fotogrametrické hypotézy nie sú vo väčšine prípadov pravdivé. [17] Veľký problém pre tieto metódy predstavujú objekty s podobnými fotogrametrickými vlastnosťami ako trhliny, napr. poškodené vodorovné dopravné značenie, trávnaté nespevnené krajnice, zaliate trhliny, nečistoty na ceste a pod.

3.1.2 Narastanie oblastí

Algoritmus narastania oblastí (*region growing*) segmentuje obrazec do disjunktných súvislých oblastí na základe naplnenia nejakej vlastnosti. Prebieha v dvoch krokoch: najprv sa identifikujú štartovacie body (tzv. semienka), ku ktorým sú iteratívne pridávané ďalšie pixely, pokiaľ spĺňajú dané podmienky. Takto vznikne množina oblastí, ktoré reprezentujú záujmové prvky v obraze, napr. trhliny.

V princípe pre rast oblastí sa využíva metóda analogická k prahovaniu intenzít – v najjednoduchšom prípade ide o pridávanie pixelov k štartovacím bodom, ktorých intenzita sa nelíši od intenzity štartovacieho bodu o nejakú prahovú hodnotu.

Je zrejmé, že táto metóda dedí mnohé z ťažkostí jednoduchého prahovania intenzít.

3.1.3 Detekcia hrán

V odvetví počítačového spracovania obrazov existuje veľké množstvo samostatných algoritmov pre detekciu hrán, keďže znalosť o hranách je základným vstupom pre ďalšie komplikovanejšie algoritmy. Vzhľadom na to, že trhliny a poruchy vo všeobecnosti voči svojmu okoliu sú vymedzené prirodzenými hranami, skúšala sa aplikácia detektorov hrán aj v oblasti detekcie porúch povrchu vozovky.

Vo všeobecnosti sa dá povedať, že všetky tieto algoritmy zdieľajú mnohé z nevýhod predchádzajúcich prístupov. Sú citlivé na šum, detegujú veľa falošných pozitív a používajú parametre, ktoré treba väčšinou upravovať pre konkrétne vstupy.



Obrázok 5 Príklad aplikácie Cannyho detektoru hrán. Obrázok vľavo je záznam trhliny; v strede je výsledok Cannyho detektora s parametrom prahu 0,4; vpravo s parametrom prahu 0,5. Prevzaté z [18].

3.1.4 Matematická morfológia

Nejednoznačnosť, šum a ďalšie problémy predchádzajúcich metód sa snažia pridaním predpokladov o geometrickej povahe trhlín odstrániť metódy využívajúce matematickú morfológiu. Typické vlastnosti vo forme predpokladov, ktoré sa využívajú, sú linearita v jednom principiálnom smere a spojitosť trhlín (trhliny sú viac-menej úzke súvislé objekty), spoločne s fotogrametrickým predpokladom nižšej intenzity pixelov trhlín ako zvyšku obrazu.

Metódy matematickej morfológie aplikujú sériu morfologických operácií na vstupný obraz, na ktorý sa pozerajú v binárnej morfológii (čierno-bielej) ako na množinu súradníc pixelov majúcich čiernu farbu alebo v prípade šedo-tónovej morfológie ako na funkcie mapujúce súradnicový priestor obrazu

na rozšírenú množinu reálnych čísel. Základné morfologické operácie sú dilatácia, erózia, otvorenie a uzavretie. Morfologické operácie upravujú vstupný obraz postupnou transformáciou jednotlivých častí vstupného obrazca s daným tzv. štruktúrnym elementom. Väčšinou používané štruktúrne elementy pri detekcii trhlín sú disk, úsečka a štvorec.

Je zrejmé, že tieto metódy sú šité na konkrétne typy porúch, sú tak málo flexibilné a navyše väčšina implementácií vyžaduje aj nastavenie niekoľkých parametrov závislých od vstupných dát.

3.2 Princípy s využitím strojového učenia sa

Úplne nové prístupy sa začali skúšať s rozvojom tzv. druhej vlny umelej inteligencie. Umelá inteligencia sa dá charakterizovať ako snaha automatizovať úlohy vykazujúce intelekt, ktoré zvyčajne vykonávajú ľudia. *Strojové učenie* sa (machine learning) predstavuje veľkú časť spektra umelej inteligencie, ktorá sa snaží počítačom automaticky odvádzať pravidlá transformujúce požadované vstupy na výstupy na základe množstva príkladov vzťahov medzi vstupmi a výstupmi (fáza učenia sa). Strojové učenie sa teda predstavuje zásadný posun od tzv. klasického (imperatívneho) programovania, ktorého podstatou je, že programátor inštruuje počítač, čo má robiť, teda ako má transformovať vstupy na výstupy.

Podstatná časť výskumu strojového učenia sa sústreďuje na jej oblasť zvanú *hlboké učenie* sa (deep learning), podstatou ktorej je aplikácia kaskády mnohých vrstiev učiacich sa rôzne úrovne abstrakcie konceptov v riešenej doméne. Vo veľkej väčšine prípadov sa realizuje hlboké učenie neurónovou sieťou; hovoríme potom o *hlbokej neurónovej sieti* (deep neural network). Špeciálne v oblasti spracovania obrazov sa uplatňujú varianty *konvolučnej neurónovej siete* (convolutional neural network, CNN). Tieto siete sa sami učia kaskády filtrov, ktoré extrahujú prechodom siete od vstupov až po výstupy stále zložitejšie a konkrétnejšie koncepty. Ako sa ukazuje v iných oblastiach (napr. rozpoznávanie písaného písma, klasifikácia objektov z obrázkov a pod.), konvolučné neurónové siete sú schopné prekonať mnohé z prekážok, s ktorými si tradičné prístupy nevedia poradiť.

Pri hodnotení úspešnosti CNN pri detekcii a klasifikácii nás zaujímajú väčšinou dve metriky: *precision* a *recall*. Precision (zhodnosť) udáva úspešnosť triedenia, teda koľko percent z nájdených objektov bolo úspešne zatriedených do správnej triedy; recall udáva úspešnosť detekcie, teda koľko percent objektov nachádzajúcich sa na obrázku bolo nájdených a následne úspešne zatriedených.

$$\text{zhodnosť (precision)} = \frac{\text{skutočné pozitíva (true positive)}}{\text{skutočné pozitíva (true positive)} + \text{chybné pozitíva (false positive)}}$$

$$\text{recall} = \frac{\text{skutočné pozitíva (true positive)}}{\text{skutočné pozitíva (true positive)} + \text{chybné negatíva (false negative)}}$$

Konvolučné neurónové siete sú zaležitostou prakticky len pár rokov. Aj prvé aplikácie pre problém detekcie porúch povrchu vozovky začali okolo roku 2016. Medzi prvými bola aplikácia CNN na problém detekcie trhlín z obrázkov z low-cost smartfónu s rozlíšením 3264×2448 pixelov. [19] Použitá CNN má iba 4 vrstvy a pracuje nad štvorcami 99×99 pixelov v RGB. Už takáto jednoduchá sieť dosahuje precision 87 % (teda z 87 % z toho, čo označila CNN ako trhlina, boli skutočne trhliny) a recall 93 % (teda zo všetkých ozaj prítomných trhlín ich našla CNN 93 %), čo sú výsledky lepšie ako väčšina tradičných metód. Nasledovali ďalšie práce, väčšinou zvyšujúce počet vrstiev a dosahujúce ešte lepšie výsledky.

Experimentálne metódy, ako sú popísané ďalej, sú postavené práve na strojovom učení sa s využitím CNN.

4 Experimentálne overenie neurónovej siete pre detekciu porúch povrchu vozovky

4.1 Úvod

V posledných rokoch sa v technologických riešeniach firiem rozšírilo používanie strojového učenia sa, predovšetkým pri riešení mnohých ťažkých problémov súvisiacich so spracovaním obrazu.

Hlavným komponentom týchto riešení je neurónová sieť, ktorá sa dokáže naučiť priradenie medzi obrazmi a ich ohodnotením iba na základe príkladov týchto ohodnotení. Tieto ohodnotenia môžu byť rôzne, napríklad: rozhodnutie, či sa na danej časti povrchu vozovky vyskytuje trhlina alebo aká je percentuálna plocha časti vozovky obsahujúca trhliny. Pre robustné a presné predikcie použitím neurónových sietí je základným predpokladom, že máme k dispozícii dostatok ohodnotených príkladov (tzv. tréningových dát). Zabezpečenie dostatku ohodnotených príkladov býva veľmi často hlavná komplikácia, čo platí aj pre náš prípad – máme síce k dispozícii dostatok príkladov obrázkov vozovky, ale chýbajú nám k nim ohodnotenia.

Na získanie ohodnotení potrebujeme ručne prejsť niekoľko obrázkov vozoviek a označiť na nich poruchy. Keďže táto činnosť je časovo náročná, v našom prístupe sa snažíme jej čas minimalizovať pomocou ďalšej metódy strojového učenia, nazývanej *aktívne učenie*.

Metódy strojového učenia majú veľa praktických výhod, medzi inými:


- sami sa učia - netreba im nastavovať veľa parametrov,
- sú omnoho robustnejšie voči šumu ako tradičné metódy,
- ak bola porucha náhodou zle predikovaná, vedú sa poučiť zo spätnej väzby.




4.2 Návrh typov rozpoznávaných porúch



V rámci riešenia RÚ bol definovaný katalóg porúch povrchu vozovky, ktorých detekcia a extrakcia z vizuálnych záznamov zo zariadenia LineScan má byť predmetom riešenia. Jednotlivé typy porúch vychádzajú zo štandardnej typizácie porúch vozoviek (vrátane katalógu porúch asfaltových vozoviek používaného na Slovensku [20]), potrieb SHV, predovšetkým na sieťovej úrovni a teoretických možností zvoleného prístupu. Prične a pozdĺžne nerovnosti, rovnako ani poruchy implikujúce zníženie drsnosti povrchu vozovky, nie sú predmetom riešenia, nakoľko sú obťažne detekovateľné z čisto vizuálneho záznamu a súčasne existujú na Slovensku zariadenia na meranie korešpondujúcich parametrov s výkonom použiteľným na sieťovej úrovni (Profilograph GE, Skiddometer BV11).

Cieľom riešenia je vybrané typy porúch (predovšetkým trhliny) popísať aj kvantitatívne, minimálne kvantitatívnou klasifikáciou (napr. či je detegovaná trhlina úzka alebo široká pri hranici 5 mm).

Navrhovaný katalóg typov rozpoznávaných porúch:

Kód	Porucha	Popis	Príklady
1	Priečna trhlina	Trhlina kolmá na os vozovky. Cieľová aspoň kvantitatívna klasifikácia úzka (šírka ≤ 5 mm) a široká (> 5 mm).	

2	Pozdĺžna trhlina	Trhlina rovnobežná s osou vozovky. Cieľová aspoň kvantitatívna klasifikácia úzka (šírka ≤ 5 mm) a široká (> 5 mm).	
3A	Rozvetvená trhlina alebo diagonálna trhlina	Trhliny, ktoré nie sú jednoducho rovnobežné alebo kolmé na os vozovky, ale netvoria sieťovú/mozaikovú ani blokovú štruktúru.	
3B	Sieťová alebo mozaiková trhlina	Krátke, nepravidelné trhliny spojené do štruktúry siete trhlín. Veľkosť ôk je typicky cca 10-40 cm.	
3C	Blokové trhliny	Sieť trhlín vytvárajúcich pravidelnú pravouhlú štruktúru. Veľkosť ôk je typicky > 40 cm.	

5	Výtlk	Lokálny úbytok hmoty v krytovej vrstve na ohraničenej ploche.	
6A	Poruchy pri inž. sieťach	Trhliny a deformácie v okolí kontrolných šácht, kanalizačných šácht a vpustí a pod.	
6B	Poruchy pri most. záveroch	Trhliny a deformácie v okolí mostných záverov.	
7	Lokálna oprava/rozkopávka	Lokálne opravy povrchu, rozkopávky, prekopávky, ... Vyznačujú sa väčšinou pravidelnými okrajmi a rozdielom kontrastu medzi vnútrom a okolím na malej, lokalizovanej ploche, typicky v rádoch do jednotiek m ² .	
8	Rozpad povrchu vozovky	Súvislá dezintegrácia a strata konštrukčného materiálu vozovky; súvislá kombinácia sieťových alebo mozaikových trhlin a výtlkov.	

9	Iné	Akékoľvek iné potenciálne rozpoznané poruchy na základe lokálnej nehomogenity v obraze.
---	-----	---

4.3 Vstupné údaje

Rozlišujeme vstupné údaje potrebné pri príprave neurónovej siete (trénovaní a validácii) a vstupné údaje potrebné pre produkčnú prevádzku (teda vstupy, ktoré má neurónová sieť spracovať a vyhodnotiť).

Čo sa týka prvej množiny, tak na vstupe vychádzame z predpokladu, že máme prístup k veľkej databáze obrázkov povrchu vozoviek, v ktorých je viacero príkladov každého druhu hľadanej poruchy. Tento predpoklad je nutný, keďže metódy sa učia priamo z príkladov, vedia správne predikovať len to, čo v príkladoch videli.

V ideálnom prípade by sme na vstupe chceli databázu ohodnotených príkladov, na ktorých sa bude vedieť natrénovať neurónová sieť. V prípade, že takáto databáza nie je k dispozícii, budeme predpokladať, že máme k dispozícii niekoľko hodín času experta, ktorý vie presne rozoznávať jednotlivé poruchy na cestách. Tento expert bude požadovaný o vytvorenie ohodnotených dát pomocou nami vytvoreného softvéru, ktoré budú použité na tréning záverečného modelu.

Pri produkčnej prevádzke sa v zásade očakávajú ako vstup do neurónovej siete obrázky z vizuálneho záznamu povrchu vozovky zo zariadenia LineScan v niektorom štandardnom formáte (BMP, JPG). Tento dátový vstup poskytne produkčná aplikácia (LineScan Pro), ktorú bude obsluhovať používateľ zodpovedný za vyhodnotenie (pozri kap. 5).

4.4 Údaje pre experimentálne overenie

Údaje pre experimentálne overenie pochádzali z meraní SSC.

Okrem existujúcich meraní bolo vykonané špeciálne meranie zariadením LineScan dňa 31. 5. 2018 s požiadavkou na získanie vzorky dát povrchov vozoviek so značnou prítomnosťou rôznych porúch pre účely tréningu neurónovej siete. Meranie bolo vykonané na cestách v Bratislave. V rámci merania boli prejdené úseky s úplným rozpadom krytu, ako aj úseky s novopoloženým asfaltovým kobercom. Taktiež z hľadiska vodorovného dopravného značenia boli prejdené úseky s prítomným značením, ako aj úseky bez značenia. Z hľadiska druhu povrchu vozovky bola väčšina meraných úsekov s asfaltovým povrchom, ale zaznamenaná bola aj vzorka dát z betónového povrchu parkoviska a autobusových zastávok.

Na záznamoch sa sporadicky objavovali jednotlivé vypadnuté riadky (prítomné ako horizontálna čiara čiernych pixelov). Niektoré záznamy vykazovali súvislé jasové zmeny vo vertikálnych pásoch a prítomné pozorovateľné tieň z okolitých objektov, čo môže indikovať výpadky v osvetľovacej sústave. Jednoznačné príčiny ešte bude potrebné presne dohľadať, nakoľko môžu negatívne ovplyvňovať výkon neurónovej siete. V každom prípade odporúčame procesom kontroly kvality pred meraním a počas merania identifikovať problémy v zariadení LineScan.

4.5 Výstupné údaje

Výstupom z neurónovej siete sú označené časti (typicky štvorce) vstupných vizuálnych záznamov s priradenou klasifikáciou zodpovedajúcou typu poruchy podľa katalógu.

Klasifikácia časti znamená, že na danej časti vstupného záznamu sa podľa neurónovej siete nachádza porucha daného typu.

Pokiaľ výstupné časti budú rádovo väčšie ako sú rozmery porúch, musia byť kvantitatívne charakteristiky súčasťou výstupu neurónovej siete (napr. namiesto trieda „pričná trhlina“ budú existovať dve triedy „pričná trhlina – úzka“ a „pričná trhlina – široká“). V prípade, že rozmery výstupných častí budú zodpovedať približne veľkosti porúch, nie je potrebné požadovať kvantitatívne charakteristiky z neurónovej siete, nakoľko môžu byť dopočítané mimo nej. Pre prípad trhlín, ktorých os ale prebieha typicky cez jeden alebo pár pixelov, to ale znamená, že neurónová sieť musí vedieť rozpoznať trhliny na úrovni pixelov alebo jej blízkej.

4.6 Návrh metódy

Navrhované riešenie pozostáva z dvoch hlavných častí: *ohodnocovania dát* a *učenia neurónovej siete*.

Prvá časť sa zameriava na získanie dostatku ohodnotených dát, aby sa neurónová sieť vedela v druhom kroku naučiť rozpoznávať poruchy vozovky. Ak by sme časti vozovky ohodnocovali postupne (alebo v náhodnom poradí), tento proces by mohol trvať aj niekoľko desiatok hodín, čo je pre experimentálne riešenie veľa. Z tohto dôvodu sme do nášho riešenia zakomponovali prvky aktívneho učenia, ktoré predkladá obrázky na ohodnocovanie, ktoré sú v istom zmysle zaujímavé. Hlavná myšlienka aktívneho učenia spočíva v tom, že navrhuje také obrázky, u ktorých si je najmenej isté ohodnotením na základe ohodnotenia všetkých doterajších obrázkov. Neistota sa meria pomocou modelu XGBoost, čo je modernou verziou náhodných lesov (angl. *random forest*). Tento model okrem iného aj sám predikuje poruchy a dá sa použiť aj ako konečný model. Je v ňom ale uprednostňovaná rýchlosť pred presnosťou, preto tento prístup neodporúčame. Použitím týchto techník sa potrebná doba ohodnocovania skráti len na niekoľko hodín. Samotné ohodnocovanie dát prebieha pomocou proprietárneho softvéru vyvinutého pre tento účel.

V druhej časti sa ohodnotené dáta použijú na naučenie neurónovej siete rozpoznávať stav povrchu vozovky. Tento model by mal vedieť predikovať, či je na danom výseku cesty porucha, akého je druhu, ako aj odhadovať plochu zasiahnutú danou poruchou. Na takéto problémy sú vhodné techniky na segmentáciu obrazu, ako je napríklad Mask R-CNN. Segmentačné modely vedia určiť o každom pixeli obrazu, či patrí do nejakej triedy. Pomocou takejto segmentácie vieme odpovedať na všetky potrebné otázky o kvalite povrchu vozovky.

4.7 Dosiahnuté výsledky

V súčasnosti je vyvinutý softvér na ohodnocovanie dát. V rámci neho sa dá ohodnotiť dostatok dát pre neurónovú sieť a zároveň poskytuje základný predikčný model založený na modeli XGBoost. Predikuje poruchy na úrovni výrezov a nie pre každý pixel, čo je hlavný rozdiel medzi ním a druhou časťou založenou na neurónovej sieti.

Annotate

Image: 8460/39426 Annotation id: 0

n next or proposed
p previous or proposed
b browse mode
v view mode

u update model
e evaluate image
t change model type

ctrl+z undo
c clear all annotations
d brush-rubber
shift+whl set brush size

1 previous class
2 next class

s save
r fit image to window
h toggle help
q quit

Status: ORIGINAL

Browse: Proposed
View: Grid
Model: Classification

5 Návrh metodiky vyhodnotenia vizuálnych záznamov zariadenia LineScan

5.1 Meranie

Nepredpokladáme zásadné zmeny v procese samotného merania.

V prípade výmeny kamery za kameru s vyšším rozlíšením však bude takmer istá nutná úprava softvéru pre meranie od spoločnosti Greenwood a môžu byť upravované podmienky merania, predovšetkým s ohľadom na najvyššiu povolenú rýchlosť meracej sústavy.

5.2 Rozsah merania

Meranie zariadením LineScan je vhodné pre získavanie údajov o stave povrchu vozovky na úrovni cestnej siete pre potreby SHV.

Súčasný TP pre meranie a vyhodnocovanie záznamom z merania LineScan [5] nešpecifikujú pre úroveň cestnej siete frekvenciu a rozsah merania. Tieto údaje by bolo potrebné špecifikovať v rámci revízie TP. Navrhovaná frekvencia pre potreby SHV na úrovni cestnej siete:

Kategória CK	Približný počet pruhokm (stav k 2018)	Frekvencia	Ročný počet pruhokm na meranie
diaľnice, rýchlostné cesty	3100	1 × ročne	3100
cesty I. triedy	6620	2/3 ročne	4413
cesty II. triedy	7220	½ ročne	3610
cesty III. triedy	20720	¼ ročne	5180
<i>spolu</i>	16 940		16 303

Táto požiadavka znamená pre úroveň cestnej siete pri pesimistickej rýchlosti 60 km/h počas merania a čistom čase merania 5 hodín na jeden pracovný deň (zvyšok času na prestávky, prípravy meraní, náhla nepriaznivá zmena počasia a presuny) cca 54 pracovných dní ročne, čo je približne 45 % z počtu 125 pracovných dní kalendárneho roka potenciálne vhodných pre meranie z hľadiska počasia (6 mesiacov). Zvyšný čas môžu pokryť požiadavky na merania pre projektovú úroveň, dlhodobé sledované úseky, iné požiadavky na merania, servis zariadenia, letné dovolenky a neplánované výpadky. Po prvom roku odporúčame vyhodnotiť splnenie plánu meraní na úrovni cestnej siete a vykonať prípadné korektúry.

V tomto návrhu je zaradené cesty III. triedy v pláne ¼ siete ročne. Na cestách III. triedy v súčasnosti nie je vykonávaná žiadna systematická strojová diagnostika vozoviek, preto by bolo vhodné ju doplniť aspoň stavom povrchu vozovky.

Frekvencie meraní by bolo vhodné ešte zvýšiť, čo je možné výhľadovo realizovať napríklad dokúpením ďalšej diagnostickej zostavy LineScan alebo LCMS systému.

5.3 Vyhodnotenie a spracovanie merania

Pre účely vyhodnotenia a spracovania meraní musí byť následne vytvorená nová softvérová aplikácia. Táto aplikácia pokryje nosnú časť procesu. Aplikácia bude pracovať na vstupe priamo s natívnymi súborami zariadenia LineScan (pg2). Používateľ si v nej bude môcť prezrieť vizuálny záznam aj s trasou, aplikovať detekciu a extrakciu porúch z neurónovej siete, v prípade potreby manuálne výsledok skorigovať, pričom korekcie sa môžu použiť na budúce spresnenie výsledkov neurónovej siete. Aplikácia súčasne štatisticky spracuje výsledky do formy ukazovateľov stavu

povrchu vozovky, ktoré používateľovi zobrazí. Ako posledný krok umožní aplikácia priamy export výsledkov meraní, vrátane vizuálneho záznamu, do databáz IS MCS na ďalšie spracovanie v rámci SHV.

5.4 Navrhované výstupy

Aplikácia bude exportovať nasledovné výstupy:

- UCI (kombinovaný index pre všetky typy trhlín) v kroku 1 m a 20 m,
- UCI_{lc} , UCI_{pc} , UCI_{dc} , UCI_{ac} , UCI_{bc} – špecializovaný index trhlín pre pozdĺžne trhliny, priečne trhliny, rozvetvené/diagonálne trhliny, sieťové trhliny a blokové trhliny v kroku 20 m; pozdĺžne trhliny a priečne trhliny zvlášť pre úzke a široké,
- index plošného porušenia povrchu výtlkmi v kroku 20 m,
- index plošného narušenia homogenity povrchu lokálnymi vysprávkami a opravami v kroku 20 m,
- index plošného rozpadu povrchu vozovkami v kroku 20 m,
- počty objektov inžinierskych sietí a mostných záverov s poruchami okolo nich v kroku 20 m,
- zachytený obrazový záznam a obrazový záznam prekrytý vrstvou identifikovaných porúch,
- hodnoty istoty identifikovaných porúch pre ďalšiu analýzu.

6 Záver

Cieľom tejto rozborovej úlohy bolo poskytnúť prehľad možností spracovania vizuálnych záznamov zo zariadenia LineScan s dôrazom na realizovaný technologický progres v oblasti počítačového spracovania obrazu a navrhnúť ďalšie kroky smerom k automatizácii vyhodnotenia týchto záznamov.

Experimentálne bolo overené, že prístup s aplikáciou umelej inteligencie využitím neurónových sietí je schodný a dosahuje dostatočnú presnosť pri súčasnej konfigurácii meracej zostavy.

V texte je uvedených niekoľko odporúčaní, ktoré si dovoľujeme zosumarizovať:

- overenie možností technologického upgradu kamery a optickej sústavy LineScanu (zvýšenie riadkového rozlíšenia na aspoň 4k),
- overenie možnosti rozšíriť záznamy o hĺbkový rozmer, prípadne odrazivosť laserového lúča (3D záznamy),
- rozpracovať softvérovú aplikáciu pre detekciu porúch neurónovými sieťami a spracovanie záznamov,
- zaviesť systematizované meranie zariadením LineScan na úrovni cestnej siete pre potreby SHV,
- aktualizovať metodickú a softvérovú časť SHV tak, aby využívala výstupy zo zariadenia LineScan na úrovni cestnej siete (zostavovanie plánu údržby, opráv a rekonštrukcií vozoviek),
- nákup samostatného ťažného vozidla pre zariadenie LineScan,
- v nadväznosti na prijaté predchádzajúce závery aktualizovať TP 053 Metodika merania a vyhodnocovania stavu povrchu vozovky pomocou zariadenia LineScan. Hodnotenie stavu povrchu vozovky kamerovým systémom LineScan.

7 Odkazy

- [1] TP 024: Systém hospodárenia s vozovkami, MDPT SR, 2006.
- [2] TP 071: Prehliadky, údržba a oprava cestných komunikácií. Diaľnice, rýchlostné cesty a cesty., Bratislava: MDVRR SR, 2013.
- [3] TP 084: Vykonávanie a vyhodnocovanie podrobných vizuálnych prehliadok asfaltových vozoviek, MDVRR SR, 2014.
- [4] TP 005: Rýchle vizuálne prehliadky zariadením VIDEOCAR. Vykonávanie a vyhodnocovanie, Bratislava: SSC, 2002.
- [5] TP 053: Metodika merania a vyhodnocovania stavu povrchu vozovky pomocou zariadenia LineScan. Hodnotenie stavu povrchu vozovky kamerovým systémom LineScan, MDVRR SR, 2011.
- [6] Žilinská univerzita v Žiline, „Rozborová úloha - Metodika merania a vyhodnocovania stavu povrchu vozovky pomocou zariadenia LineScan - 1. etapa a Hodnotenie stavu povrchu vozovky kamerovým systémom LineScan - 2. etapa,“ Žilina, 2010.
- [7] J. Laurent, J. F. Hébert a T. Mario, „Using full lane 3D road texture data for the automated detection of sealed cracks, bleeding and raveling [Využitie 3D údajov o textúry cesty v plnej šírke pruhu pre automatizovanú detekciu utesnených trhlín, potenia a vypierania povrchu],“ Pavemetrics Systems Inc., 2017.
- [8] J. Laurent, J. F. Hébert, D. Lefebvre a Y. Savard, „Using 3D Laser Profiling Sensors for the Automated Measurement of Road Surface Conditions [Využitie 3D laser profilových senzorov pre automatizované meranie stavu povrchu ciest],“ rev. 7th RILEM International Conference on Cracking in Pavements, Delft, 2012.
- [9] H. Lee, „Standardization of distress measurements for the network-level pavement management system [Štandardizácia zberu porúch pre systém hospodárenia s vozovkami na úrovni cestnej siete],“ STP1121 Pavement Management Implementation, pp. 424-435, 1991.
- [10] S. Jitprasithsiri, H. Lee, R. Sorcic a J. Richard, „Development of Digital Image-Processing Algorithm To Compute Unified Crack Index for Salt Lake City [Vývoj algoritmu digitálneho spracovania obrázkov na výpočet unifikovaného indexu trhlín pre Salt Lake City],“ Transportation Research Record: Journal of the Transportation Research Board, zv. 1526, pp. 142-148, 1994.
- [11] H. D. Lee a J. Kim, „Development of a Crack Type Index [Vývoj indexu typu trhlín],“ Transportation Research Record: Journal of the Transportation Research Board, zv. 1940, p. 99–109, 2005.
- [12] W. D. Paterson, „Proposal of Universal Cracking Indicator for Pavements [Návrh univerzálneho indikátora trhlín],“ TRANSPORTATION RESEARCH RECORD, pp. 69-75, 1994.

- [13] AASHTO, „Standard practice for Quantifying cracks in asphalt pavement surfaces from collected images utilizing automated methods. AASHTO PP 67-10 [Štandardná prax pre kvantifikáciu trhlín v asfaltových vozovkách z pozberaných obrázkov využitím automat. metód],“ rev. *Standard specifications for transporation materials and methods of sampling and testing*, 2011.
- [14] UK Roads Board, „Cracking Parameters [Parametre trhlín],“ rev. *SCANNER surveys for Local Roads - User Guide and Specification, volume 5: Technical Requirements for SCANNER Survey Parameters and Accreditation*, 2009.
- [15] D. Darwin, M. N. Abou-Zeid a K. W. Ketcham, „Automated crack identification for cement paste,“ *Cement and Concrete Research*, 1995.
- [16] H. Oliveira a P. L. Correia, „Automatic road crack segmentation using entropy and image dynamic thresholding [Automatická segmentácia trhlín vozoviek využitím entropie a dynamického prahovania obrazu],“ *17th European Signal Processing Conference (EUSIPCO 2009)*, 2009.
- [17] S. Chambon a J.-M. Moliard, „Automatic Road Pavement Assessment with Image Processing: Review and Comparison [Automatické vyhodnotenie cestných vozoviek využitím spracovania obrazu: prehľad a porovnanie],“ *International Journal of Geophysics*, 2011.
- [18] A. Ouyang, C. Luo a C. Zhou, „Surface Distresses Detection of Pavement Based on Digital Image Processing [Detekcia porúch povrchu vozoviek založená na spracovaní digitálneho obrazu],“ rev. *4th Conference on Computer and Computing Technologies in Agriculture (CCTA)*, Nanchang, China, 2010.
- [19] L. Zhang, Y. D. Zhang a Y. J. Zhu, „Road crack detection using deep convolutional neural network [Detekcia trhlín vozoviek s využitím hlbokých konvolučných sietí],“ 2016.
- [20] Slovenská správa ciest, TP 083: Katalóg porúch asfaltových vozoviek, Bratislava: Ministerstvo dopravy, výstavby a regionálneho rozvoja SR, 2014.
- [21] K. Gopalakrishnan, „Deep Learning in Data-Driven Pavement Image Analysis and Automated Distress Detection: A Review [Hlboké učenie v dátovej analýze obrázkov vozoviek a automatizovaná detekcia porúch],“ *Data*, 2018.
- [22] K. C. P. Wang a O. Smadi, „Automated Imaging Technologies for Pavement Distress Surveys [Automatizované obrazové technológie pre prehliadky porúch vozoviek],“ Washington, Transporation Research Board, 2011.
- [23] A. J. Acosta, L. J. Figueroa a R. L. Mullen, „Low-cost Video Image Processing System for Evaluating Pavement Surface Distress [Nízko-nákladové systémy pre spracovanie video obrazu pre vyhodnotenie porúch povrchu vozoviek],“ *Transportation Research Record*, 1992.