Slovenská technická univerzita v Bratislave
Fakulta informatiky a informačných technológií
Ilkovičova 2, 842 16, Bratislava 4

Moduly systému

Dokumentácia k tímovému projektu

Tímový projekt

Tím č. 21

Vedúci: Ing. Ivan Srba, PhD.

Členovia tímu:
- **Matej Groma**
- **Matej Horváth**
- **Peter Jurkáček**
- **Jozef Kamenský**
- **Adam Kňaze**
- **Kristína Macková**
- **Lenka Pejchalová**
- **Jakub Sedlář**

tim21.2018.fiit@gmail.com

Akademický rok: 2018/2019

Posledná zmena: 14. decembra 2018

Obsah

1 Úvod

V tomto dokumente uvádzame dokumentáciu k modulom ktoré vznikli ako riešenie projektu TrafficWatch. Dokument je rozdelený na sekcie pre každý modul, a pre modul uvádzame separátne ich analýzy, návrh a implementáciu. Rozsah týchto časti sa odvíja od charakteru modulu. Následne uvádzame spis o testovaní a kontinuálnom nasadení projektu.

2 Kamera

2.1 Analýza

2.1.1 Hardvér

Hardvér pre kamerový systém

Od spolupracujúcich firiem máme alokovaný neobmedzený budget, ktorý bude použitý na preplatenie nákladov na hardvér. Na zvolenú dosku bude potrebné pripojiť komunikačný modul a kameru. Hardvér je vhodné voliť tak, že sa budú neskôr môcť uchovávať vzorky videa. Napájanie hardvéru elektrickou sieťou nie je problémom.

Všeobecne sme zistili, že lacné dosky a dosky bez výkonnejšieho GPU sú výkonovo nedostatočné (kvôli potrebe akcelerácie neurónovej siete).

Po zvážení sme nakoniec zvolili nasledovný hardvér (vyznačený tučným, zvyšok tvoria alternatívy):

- **JETSON TX1 DEVELOPER KIT SE** – https://www.nvidia.co.uk/object/JetsonTX1DeveloperKitSE-cz.html?nvid=nv-int-jnt1drktsnt-21728
- Jetson TX2 – https://www.nvidia.co.uk/object/jetsontx2-edu-discount-cz.html
- **Huawei E5577C**, prípadne ľubovoľný LTE modem s Wi-Fi AP (alebo bez Wi-Fi AP ak vyskúšame a bude fungovať)
- **Logitech C920 PRO HD**, prípadne ľubovoľná kamera s aspoň 720p
- **USB micro B - USB A OTG** (napr. https://www.alza.sk/akasa-usb-micro-b-usb-a-otg-d4254841.htm)
- **SIM karta s dátami**

Požiadavky na HW akceleráciu

- TensorFlow - na GPU akceleráciu CUDA® Compute Capability >= 3.5 – Jetson TX1, Jetson TX2, inak nevhodné dedikované grafické karty
- Darknet neurónová sieť na YOLO – CUDA, Compute Capability neudávaná
- OpenCV – NVIDIA CUDA, Compute Capability prakticky ľubovoľná a OpenCL 1.2 (1.1 obmedzene)

Porovnanie použiteľného hardvéru

Nvidia JETSON TX1 DEVELOPER KIT SE

Ponuka pre ČR je 5868Kč. Jetsony TX1/TX2 robí Nvidia priamo pre AI na embedded systémoch, výhoda oproti ostatným možnostiam je GPU akcelerácia – oproti čisto CPU násobné zrýchlenie (5 až 10 krát). Aj čistý Tensorflow object detection model tu zaručene pobeží aspoň 15 FPS. TX1 by určite postačoval, dá sa neskôr optimalizovať nižšie, ale situácia že nevieme zrealizovať náš usecase lebo nemáme dosť dobrý HW by tu nehrozila. Procesor má až 10x väčší výkon ako populárne single board dosky. Problémom je len jeden USB port, riešenie je kúpiť OTG redukciu na druhý (https://www.alza.sk/akasa-usb-micro-b-usb-a-otg-d4254841.htm).

Starší model Jetson TK1 sa už nedá veľmi zohnať, neakceleruje TensorFlow a len kvôli CPU sa neoplatí kupovať.

LATTEPANDA

Výkon v benchmarku Geekbench je 3343 single-core a 6323 multi-core. Linux nemusí byť až tak dobre podporovaný. Neurónová sieť YOLO beží stále len na 0.62 FPS (https://www.youtube.com/watch?v=ic8zDDOIjbQ).

Firefly - AIO-3399J

Výhodou je slot na LTE modul. Výkon v benchmarku Geekbench je 1326 single-core a 2935 multi-core. Nevýhodou je slabá podora v Linuxe (ovládače).

MinnowBoard

Výkon v benchmarku Geekbench je 1004 single-core a 2874 multi-core.

HiKey 960

Výkon v benchmarku Geekbench je 1710 single-core a 4384 multi-core. Veľmi drahý.

ROCK64

Výkon v benchmarku Geekbench je 530 single-core a 1422 multi-core.

Intel Joule

Výkon v benchmarku Geekbench je 671 single-core a 2318 multi-core.

Porovnanie Nvidia TX1 vs LATTEPANDA (UP-board)

Problém bol nájsť benchmark na LATTEPANDA, výkon má porovnateľný s UP-board (rovnaký procesor a frekvencia), bol teda v benchmarkoch zastupovaný. Výsledky sú dostupné na https://openbenchmarking.org/result/1608034-HA-1603058GA17 a https://openbenchmarking.org/result/1703199-RI-ARMYARM4104 (iný benchmark, nezahŕňa Z8350). Niektoré výsledky má Intel Atom x5-Z8350 (LATTEPANDA) výrazne lepšie (pravdepodobne optimalizované v x86), inak sú výsledky lepšie pre Nvidia (tesne) alebo porovnateľné.

Zhodnotenie: ak bez GPU akcelerácie, tak výkonnejšie zariadenie (v rovnakej cenovej kategórií by sa asi dal už kúpiť aj TX1), GPU akceleráciu by sme mohli chcieť (veľmi slabý výkon YOLO na CPU).

Sieťové moduly

Existujú špecializované produkty pre rôzne scenáre (odpočty), komunikačný modul však v našom prípade musí byť schopný preniesť vlastnú správu kvôli flexibilite. Sigfox má nedostatočný počet správ, kity stoja od 20 . Lora je drahšia s cenou 78,65 za Orange Starter Kit. Technológia NB IoT je aj na slovensku, je skôr ale v testovacej prevádzke. Na začiatok na prototypovanie tak vyberáme LTE modem, neskôr budeme môcť produkt doplniť o IoT komunikačnú technológiu. Ako protokol použijeme MQTT, ktorý bol definovaný product ownermi.

HUAWEI E3372

Mal by fungovať aj na Linuxe. Niektoré verzie aj emulujú ethernet cez usb (NAT), záleží od FW/distribútora (http://www.draisberghof.de/usb_modeswitch/bb/viewtopic.php?f=3&t=2261). Sú postupy, ako pridať ovládač (https://devtalk.nvidia.com/default/topic/1006033/jetson-tx2/lte-usb-module-on-tx2/, https://www.jetsonhacks.com/2018/04/21/build-kernel-and-modules-nvidia-jetson-tx1/). Cena je 44,49 . Podobný model E3372h má cenu 44,26 .

Alcatel Link Key 4G

Používa RNDIS (MS proprietárny, implikuje NAT) – predvolene bez ovládača, mal by sa dať pridať. Cena je 38,15 .

E5577C

Jedná sa o Wi-Fi modem, teda je isté, že bude fungovať. Cena je 68,05

Výber kamery

Kamera by mala mať podporu na Linuxe, dostupnosť v EÚ/Slovensko a podporu 1080p. Zatiaľ na prototypovanie si môžeme vystačiť z ľubovoľnou kamerou. Kameru je možné pripojiť aj cez špeciálny kamera modul (lepší výkon bez USB, znížené nároky na CPU), na prototypovanie je však vhodnejšia USB kamera (napr. kvôli dlhšiemu káblu alebo nižšej cene). Podporované formáty obrazu v prípade USB kamery môžu byť dôležité (môže byť väčšie zaťažovanie pri nekomprimovaných dátach). Aj menšie FPS kamery je dostatočné, pri 50 km/h rýchlosti auta je posun pri 12 FPS 1,67 m medzi snímkami. Záleží aj na tom, v akej výške bude kamera umiestnená. 640 x 480 (320 x 240) by malo byť dostatočné na rozpoznanie druhu vozidla (auto, nákladné, ...) podľa existujúcich komerčných riešení, máme sa však orientovať na väčšie rozlíšenie.

C920

Overená na TX1, cena je 72,90 . Obľúbená je na počítačové videnie (https://www.chiefdelphi.com/forums/showthread.php?t=154360, https://www.reddit.com/r/computervision/comments/7x59de/inexpensive_5075_camera_for_machine_vision/du6hbm9/, https://www.quora.com/Which-camera-would-be-the-best-low-cost-solution-for-small-OpenCV-projects-like-Face-Tracking-and-Object-Detection-etc). Má veľmi dobre manuálne nastaviteľné parametre (napr. zaostrenie), dala by sa tak nastaviť vzdialene cez konfiguráciu (https://www.kurokesu.com/main/2016/01/16/manual-usb-camera-settings-in-linux/). Je to 2. najpopulárnejší model (heuréka).

C922

Overená na TX1, cena je 85,90 . Na počítačové videnie je rovnako dobre použiteľná ako C920 (https://devtalk.nvidia.com/default/topic/1002483/jetson-tx1/reliable-usb-3-0-camera/). Je to 1. najpopulárnejší model (heuréka).

Iné vhodné kamery

Neboli porovnávané, keďže sú obsolete (napr. 720p modely), alebo sú to podobné Logitech kamery v rovnakej cenovej kategórií.

Iné poznámky k hardvéru

Nebudeme mať verejnú IP adresu cez modem (niektoré modemy priamo robia NAT) – potrebné je vyriešiť vzdialené pripojenie (zariadenie sa bude aktívne pripájať/udržiavať komunikačný kanál). Modem cez PCIe nie je vhodný, väčšina modulov je cez mini PCIe a adaptér je položka navyše k aj tak drahšiemu modulu. Potrebujeme LTE na prenos 1080p streamu. Wi-fi modem je isté riešenie z hľadiska spoľahlivosti a je jednoduchší na prototypovanie.

2.1.2 Komunikácia medzi kamerou a backendom

Voľba MQTT servera

V tabuľke 1 sú popísané použiteľné MQTT servery. Neuvádzané sú neudržiavané, uzatvorené, platené, prípadne inak nevyhovujúce. Definovanými požiadavkami boli:

- dá sa jednoducho spustiť standalone (až spadne server, nemusia sa stratiť správy)
- robí len to čo má (nie nejaký väčší framework alebo pre nás zbytočné funkcionality navyše)
- podporuje čo najviac MQTT funkcionality
- obstojný v benchmarkoch

Meno	Standalone	Zbytočnosti	Funkcionalita
ActiveMQ (Artemis)	áno	áno	áno
emitter	áno	nie	nie
HBMQTT	áno	nie	áno
Mongoose	nie	áno	nie
Moquette	áno	nie	nie
mosca	áno	áno	nie
Mosquitto	áno	nie	áno
tstack	áno	nie	nie
VerneMQ	áno	nie	áno

Tabuľka 1: Porovnanie MQTT serverov

Z trojice vhodných bol dalej kvôli slabému výkonu (https://github.com/home-assistant/home-assistant/issues/12117, https://community.home-assistant.io/t/hbmqtt-default-mqtt-broker-doesnt-support-heavy-flow-of-data/37333) vyradený HBMQTT. Zvolený bol najskôr VerneMQ, ktorý sa úspešne používa aj pri vyšších záťažiach. Tento sa však nepodarilo nastaviť (problémy so zabezpečením), prešli sme tak na Mosquitto.

Server beží na adresách tls://team21-18.studenti.fiit.stuba.sk:8883 (secure TCP) a

wss://team21-18.studenti.fiit.stuba.sk:8083 (secure websocket), na otestovanie je možné sa pripojiť napr. cez MQTTBox.

Voľba MQTT knižníc

Java

- Eclipse Paho Java
- XenQTT - neaktualizované od 2015
- MeQanTT - neaktualizované od 2012
- mqtt-client - neaktualizované od 2016
- Qatja - málo funkcionality

Zvolené Paho je udržiavané a nestane sa, že v budúcnosti bude potrebné vymeniť knižnicu kvôli nepodporovanej funkcionalite. MQTT knižnica bola zakomponovaná do build procesu servera.

Na systéme MacOS sa vyskytli tradičné problémy – zlyhanie bezpečného pripojenia z dôvodu nerozpoznania dôveryhodnosti použitého certifikátu. Na vyriešenie vykonáme nasledovné príkazy, ktoré používaný certifikát pridajú napevno do keystore (po vymenení certifikátu je potrebné zopakovať):

```
openssl x509 -in <(openssl s_client -connect team21-18.studenti.fiit.stuba.sk
    :8883:443 -prexit 2>/dev/null) -out ~/certificate.crt
sudo keytool -importcert -file ~/certificate.crt -alias example -keystore

 $(/usr/libexec/java_home)/jre/lib/security/cacerts -storepass changeit
```

Python

- Eclipse Paho Python
- gmqtt
- Nyamuk - neaktualizované od 2016
- hbmqtt

Paho Python bol zvolený kvôli rovnakej knižnici použitej pre jazyk Java.

2.1.3 Zápisnica zo stretnutia s Martinom Tamajkom

Detekcia a rozpoznanie auta

základný postup: detekcia vozidla z opencv, pridanie marginu a rozpoznanie typu v neurónovej sieti

(dense) optical flow - zistenie smeru pohybu medzi obrázkami

konkrétne Gunnar Farneback's algorithm

ďalej je možné klastrovať na základe uhlových šípok, napr. pomocou DBSCAN

Background modeling/subtraction

odpočítanie pozadia medzi dvoma po sebe idúcimi snímkami, získanie tak masky pozadie/popredie

Kontúrová analýza

analýza, či je auto stále to isté medzi snímkami (sledovanie) - zobrať kontúru a porovnať ju s kontúrami z predošlých snímkov

porovnanie na základe vzdialenosti, alebo farby (lepšie, porovnanie histogramov)

Odstránenie šumu

- treshold
- mediánový filter
- zahodiť najmenšie kontúry

Zistenie typu vozidla

- neurónová sieť - napr. YOLO na rozpoznávanie objektov (https://pjreddie.com/darknet/yolo/, https://www.youtube.com/watch?v=g5BECgk9AEw, https://www.youtube.com/watch?v=PncSIx8AHTs, https://github.com/tejaslodaya/car-detection-yolo)
- pomocou detekcie ŠPZ - malo by byť dostupné API, ktoré vracia aj typ vozidla

Riešenia problému detekcie prekrývajúcich sa áut

Je to dosť závažný problém, mohli by sme chcieť ho riešiť.

Opatrenia:

- umiestnenie kamery zvislo dolu, minimalizujeme tak perspektívne skreslenie
- detekcia pruhov a obmedzenie kontúry na jeden pruh

Detekcia auta medzi kamerami

dôležité je zabezpečenie rovnakého nastavenia kamier (pohľad a i.)

Prístup 1: kľúčové body

opis auta pomocou bodov, pri ktorých je pravdepodobnosť, že budú rozpoznané aj na inom zábere

algoritmy SIFT (pomalý, lepší, lepšie na GPU), SURF, FAST

spárovanie kľúčových bodov

RANSAC - zrušenie falošných párovaní – https://vgg.fiit.stuba.sk/2013-07/object-recognition-ransac-verification/

Prístup 2: siamské neurónové siete

využíva dve rovnako nakonfigurované neurónové siete

na výstupe je, či je to rovnaký objekt

tzv. one-shot learning

Prístup 3: template matching

veľmi nefunguje (študenti testovali na cvičeniach)

Iné poznámky

prototypovanie v pythone, do produkcie C++

odporúčaná kombinácia prístupov, z viacerých výstupov rozhodnúť (hlasovanie):

- klasické opencv
- neurónové siete
- iné klasifikátory

"Rozhodnúť sa, čo je horšie - false positive alebo false negative? Môže mať vplyv napr. na rozhodnutie, ako spojiť rôzne paralelne použité algoritmy"

Odkazy

https://docs.google.com/document/d/1XSlcn4ZJxyspVy0X-_YLgvbUgA52AQibret-weNZE2g/edit

https://www.youtube.com/watch?v=inCUJ0JM5ng

https://github.com/topics/vehicle-counting

https://medium.com/machine-learning-world/tutorial-making-road-traffic-counting-app-based-on-computer-vision-and-opencv-166937911660

https://chatbotslife.com/vehicle-detection-and-tracking-using-computer-vision-baea4df65906

2.1.4 Softvérové vybavenie kamery

Modely a implementácie (Neurónové siete)

Detekcia objektov (aka objavenie a vyznačenie objektu na obrázku) neurónkami je výrazne náročnejšia úloha ako obyčajná klasifikácia. Samostatná kapitola je detekcia na videu realtime, ešte donedávne neexistoval model schopný túto úlohu splniť. Tri roky dozadu vznikli dva prístupy (modely), ktoré sa vyvíjajú a stále sú v zásade jediné dve možnost

Sú to:

- YOLO (you only look once) - https://pjreddie.com/darknet/yolo/
- SSD (single shot multibox detector) - https://towardsdatascience.com/understanding-ssd-multibox-real-time-object-detection-in-deep-learning-495ef744fab

Toľko modely, nás však zaujíma aj implementácia, chceli by sme niečo štandardné, odtestované, s dobrou podporou. Pri detekcií máme v podstate dve možnosti.

Štandardom pre YOLO je originálna implementácia od autora modelu vo frameworku darknet (jeho custom framework napísaný v C a CUDA) a spĺňa všetky vyššie podmienky. Nevýhodou je ten darknet, tažšie by sme v ňom implementovali prípadné modifikácie, na druhú stranu nič extra by sme nemali potrebovať. https://pjreddie.com/darknet/yolo/

V Tensorflowe máme od Googlu oficiálne Object Detection API, udržiavané repo ktorého najväčšia výhoda je množstvo predimplementovaných modelov na rôzne účely, okrem iného aj SSD (okrem iného aj mobilenet variáciu SSD (to je neurónkový model od Googlu špeciálne robený s tým aby rýchlo bežal na mobilných zariadeniach)).

Performance

Skúšal som niekoľko implementácií využívajúcich TF Object Detection API, plus som pozeral čo poskúšali iní.

- čisto CPU na mojej staršej i5ke som dal max 7 FPS, pekný výsledok ale nie dosť. https://github.com/datitran/object_detector_app
- s použitím GPU (NVIDIA computation capability len trochu menej ako Tegra X1 z Jetsonu) som na inej implementácií dostal 15 FPS čo už je použiteľná hodnota. Potvrdzuje to, že na na zariadení s GPU vieme použiť aj čisto neurónkový detekčný model.
- pohľadal som pár ľudí čo robili detekciu priamo na Jetsone TX1, SSD aj YOLO, reportujú od 10 do 20 FPS

Poučenie - čisto na CPU, čisto neurónkový detekčný realtime model nikdy nerozbeháme. S GPU áno viacerým sa to už experimentálne podarilo. Prakticky jediné embedded zariadenie ktoré to umožňuje je NVIDIA Jetson TX1/2

Presnosť

Jedna vec je, že máme model s dostatočným FPS, druhá vec je presnosť. V skúšaných modeloch ktoré mali dostatočné FPS bola kvalita detekcie vo všeobecnosti neuspokojivá. Samozrejme, model bude ešte možné dotrénovať (bude to nutné aby rozoznal triedy ktoré chceme) čím zlepšíme kvalitu, osobne však pochybujem že takto dosiahneme dostatočnú kvalitu. Ak má byť náš nástroj použiteľný musíme dosiahnúť aspoň nejakú minimálnu presnosť, a čisto neurónkový model na embedded zariadení bežiaci realtime to podľa mňa nedáva.

Pravdepodobne sa tým pádom nevyhneme nejakej kombinácií/spolupráci s tradičnými computer vision algoritmami (cez OpenCV).

Čo ďalej

Bez neurónok to nepôjde, chceme rozoznávať typy áut a to klasickými CV algoritmami (OpenCV) nedávame. Čisto neurónkami to tiež nepôjde, lebo naraz realtime aj kvalitu nezvládajú. Tu sú nejaké nápady:

- Nezávisle bežia OpenCV a TF modely, kde sa zhodnú je auto
  - ktovie či máme dosť výpočtovej kapacity na takéto srandy
- OpenCV detekuje možné autá, TF klasifikuje (nie detekuje) či naozaj
  - klasifikácia je rýchlejšia ako detekcia, vieme ju robiť rýchlo a kvalitne
  - Ak ale OpenCV auto nenájde už nám nič nepomôže
  - Ak OpenCV dá viac áut do jedného boxu musíme nejako vymyslieť splitovanie
- niečo iné?

OpenCV background substraction beží rýchlo a takmer nemá false negatives. Ak však auto zastane zmizne.

Datasety

Nech to bude akokoľvek, budeme musieť neurónku trénovať na nejakých dátach. Časom si môžme niečo oanotovať sami, ale to je veľa roboty. Čo existujúce som našiel:

- Detrarc challenge - anotovane data z cinskych ciest, zabery z dopravnych kamier http://detrac-db.rit.albany.edu/download
- Nvidia Ai city cahllenge - k dátam som sa zatiaľ nedokopal http://smart-city-sjsu.net/AICityChallenge/data.html
- Aicitychallenge - riešia rýchlosť, detekciu anomálií a znovuobjavenie auta, datasety nemusia byť verejne dostupné https://www.aicitychallenge.org/2018-data-sets/

Bonus, podľa všetkého sú nejaké datasety aj na znovuobjavenie, aka reidentifikáciu

https://github.com/knwng/awesome-vehicle-re-identification

2.1.5 OpenCV

Open Source Computer Vision Library - knižnica ponúkajúca optimalizované funkcie využívajúce metódy počítačového videnia.

Analyzované prístupy detekcie vozidiel pre náš projekt:

- **Haar** - otestované, tento prístup nie je vhodný z dôvodu časovej náročnosti algoritmu
- **HOG** - nepodarilo sa otestovať
- **MOG background subtraction + Kontúrová analýza** odporúčaný prístup, otestovaný, vhodný

Testovné kvality videozáznamu pri detekcii zvoleným algoritmom:

- Viac ako 720p - detekcia bola príliš pomalá
- 240p až 720p - detekcia v reálnom čase
- Zmena FPS neovplyvnila zásadným spôsobom úroveň detekcie (4 vs 15)

Pri akcelerácii OpenCV na GPU sa detekcia pravdepobodne zrýchly, testovanie prebiehalo na CPU.

Postrehy:

- Parametre do OpenCV funkcií (pre rôzne videá treba nastavit rôzne tresholdy)
- Spájanie detekovaných vozidiel do jedného detekovaného vozidla, ak sú blízko seba - riešiteľné uhlom, pod ktorým je umiestnená kamera a detekciou pruhov
- Detekované sú len pohybujúce sa vozidlá

2.2 Návrh

Kamera je zodpovedná za tvorbu videozáznamu a následne spracovanie tohto záznamu, teda detekovanie objektov, vyhodnotenie ich pohybu a odoslanie výsledkov na server.

Kamera je implementovaná primárne v jazyku Python, kvôli využitiu CUDA akcelerácie a optimalizácií sú časti implementované v C++.

2.2.1 Organizácia

- **trafficwatch** - Hlavný modul, z ktorého sa spúšťa celá camera app. Slúži na inicializáciu detekčných modulov, MQTT modulu a tiež modulu spravujúceho konfiguráciu. Niekoľko prvých snímkov je spracovaných výhradne na počiatočné natrénovanie algoritmu KNN. Následne sú v cykle spracúvané jednotlivé snímky vstupného videozáznamu (pomocou nainicializovaných modulov) a výsledky sú odosielané v podobe eventov na server.
- **detector** - Modul zabezpečujúci detekciu pohyblivých objektov. Pri vytvorení triedy VehicleDetector prebehne inicializácia detekčných parametrov z konfiguračného súboru. Tieto parametre je tiež možné za behu programu aktualizovať. Pri volaní triedy sa aktuálna snímka spracuje background-subtraction algoritmom (v našom prípade je to algoritmus KNN). Výsledkom je maska obsahujúca detekované pohybujúce sa objekty. Táto je následne očistená od šumu, vyhladená a odoslaná do metódy, ktorá implementuje OpenCV algoritmus na nájdenie kontúr. Výstupom je zoznam detekovaných objektov.
- **counter** - Modul zabezpečuje počítanie prejazdov áut cez zóny. Pri vytvorení triedy VehicleCounter prebehne inicializácia detekčných parametrov z konfiguračného súboru. Tieto parametre je tiež možné za behu programu aktualizovať. Pri volaní triedy je pre objekty detekované triedou VehicleDetector zapamätávaná ich poloha v jednotlivých snímkach, pričom množiny týchto polôh tvoria trajektórie jednotlivých detekovaných objektov. Na základe týchto trajektórií sú následne identifikované prejazdy, ktoré sú počítané.
- **visualizer** - Modul slúžiaci na zobrazenie priebehu detekcie vo vstupnom videozázname.Do každej snímky videozáznamu sú vyznačené detekované objekty, ich trajektórie, zóny a tiež počítadlo prechodov, ktoré je súhrnné pre všetky zóny.
- **config** - Modul obsahuje triedu ConfigManager, ktorá slúži na správu konfiguračných súborov. Sú podporované 3 typy konfiguračných súborov:
  - defaultný - obsahuje všetky parametre, ktoré je možné nastavovať a ich východzie hodnoty.
  - používateľský - hodnoty parametrov vložené do tohto konfiguračného súboru majú vyššiu prioritu ako východzie. Tento konfiguračný súbor má praktické využitie napr. pri vývoji, keďže pri experimentovaní so zmenami parametrov nie je potrebné prepisovať východzie hodnoty.
  - prijatý zo serveru - má najvyššiu prioritu. Hodnoty parametrov prijaté zo serveru prostredníctvom MQTT sú ukladané do tohto typu konfiguračného súboru
- **mqtt** - Modul spravujúci MQTT komunikáciu na kamere. Použitie MQTT modulu umožňuje pripojenie sa do komunikácie, posielanie správ a prijímanie správ.
- **utils** - Modul obsahuje pomocné funkcie používané pri detekcii objektov, počítaní prejazdov a vizualizácii v ostatných moduloch

2.3 Implementácia

Zo serveru je pomocou aktualizácie konfiguračného súboru možné nastavovať tieto parametre:

- **video_source** - cesta k súboru s videom, na ktorom bude program spúšťať detekciu vozidiel
- **bg_sub_history** - počet framov, ktoré sa uchovávajú pre výpočet background modelu algoritmom MOG2. Čím je číslo menšie, tým ľahšie sa objekty stávajú súčasťou pozadia a nie sú detekované ako pohybujúce sa.
- **detector_min_contour_width** - minimálna šírka detekovanej kontúry.

- **detector__min__contour__height** - minimálna výška detekovanej kontúry. Spolu s minimálnou šírkou detekovanej kontúry určujú, akú minimálnu veľkosť na obraze musí mať objekt aby bol detekciou označený za pohybujúce sa vozidlo. Ak je napr. kamera ďalej od vozovky, treba tieto parametre zmenšiť, keďže vozidlá sa budú na obraze javiť ako menšie.
- **zones** - oblasti, v ktorých je detekovaný prejazd počítaných vozidiel. Každá oblasť ma svoje ID a je definovaná poľom vrcholov (dvojice X a Y súradníc), ktoré v obraze túto oblasť tvoria.
- **transit__table** - slovník obsahujúci dvojice ID a typov prejazdov.
- **counter__path__size** - počet bodov zobrazovanej trasy vozidla. Čím viac bodov, tým budú zobrazované trasy dlhšie.
- **counter__max__dst** - maximálna vzdialenosť novopridávaného bodu trasy od existujúcej trasy. Ak je príliš veľká, bude trasa nepresná - bude obsahovať vzdialené body, ktoré do nej nepatria. Ak je príliš malá, relevantné body nebudú do trasy pridané

3 Backend

3.1 Analýza

3.1.1 Databáza

Klasické SQL databázy nepripadajú do úvahy, porovnávali sme hlavne NoSQL databázy a rôzne rozšírenia SQL databáz:

1. TimescaleDB
2. InfluxDB
3. CrateDB
4. MongoDB
5. Apache Cassandra

Na internete nie sú k dipozícii presné benchmarky, väčšinou sa dajú nájsť len články/blogy, často propagujúce konkrétnu technológiu. Z dostupných zdrojov sa ako najlepšia javí TimescaleDB, knižnica rozširujúca PostgreSQL.

Dôvody a výhody:

1. Benchmarkovo poráža všetky ostatné - hlavne pri náročných dopytoch typu GROUP BY + ORDER BY + LIMIT
2. SQL syntax - jednoduchá a rozšírená
3. Rozšírenie PostgreSQL, ktorý je rokmi overený, otestovaný, dobrá kompatibilita
4. Škálovateľnosť - https://docs.timescale.com/v0.12/faqscaling
5. Hypertables
6. Indexy na časových údajoch
7. Custom funkcie na prácu s časom, napr. time_bucket()

Porovnanie manažérov závislostí

Pre jednoduchšiu prácu s externými knižnicami je vhodné použiť manažéra závislostí (angl. depenency manager). Zamerali sme sa dva populárne nástroje, Maven a Gradle.

3.1.2 Maven

- založené na XML
- jednoduchá validácia, v skriptoch (zvyčajne) nevznikajú bugy
- lepšia podpora pluginov, menej problémov pri používaní, viac dostupných pluginov
- lepší tooling pre písanie skriptov

3.1.3 Gradle

- vlastný jazyk založený na Groovy
- oveľa kratšie súbory
- plnohodnotný jazyk, dá sa v ňom nakódiť čokoľvek, častejšie môžu vzniknúť bugy
- ťažšie na naučenie sa
- podporuje inkrementálny build
- rýchlejšie buildy

3.1.4 Záver

Gradle je silnejší nástroj, dá s as ním toho viac robiť, ale je ťažší na naučenie, je tiež rýchlejší, obzvlášť pri veľkých projektoch. Maven je jednoduchší, je ťažšie na tom niečo pokaziť, lepšia podpora toolov a pluginov.

Pre naše účely bola rozhodujúca rýchlosť, nakoľko žiadne zložité skripty alebo pluginy sme používať neplánovali. Rozhodli sme sa preto pre Gradle.

3.2 Návrh

Backend (alebo server) je implementovaný v jazyku Java. Je realizovaný frameworkom Spring Web MVC.

3.2.1 Architektúra

Pre backend sme zvolili architektonický štýl MVC. Controller pozostáva z REST API, pristupuje k entitám, ktoré zodpovedajú entitám v databáze.

3.2.2 Organizácia

Projekt je organizovaný do nasledujúcich balíkov:

- **controller** - obsahuje REST API pre aplikáciu
- **entity** - objekty, ktoré predstavujú dátové modely
- **service** - služby pre kamery a frontend, obsahuje logiku systému
- **storage** - logika spojená s prístupom do databázy (rozšírenie JPA)
- **util** - pre všeobecné pomocné funkcionality (logger, exceptions)

3.3 Implementácia

Dokumentácia pre implementáciu backendu bola automaticky vygenerovaná nástrojom Javadoc a konvertovaná do PDF nástrojom HTMLDOC. Dokumentácia pre API rozhrania bola vygenerovaná nástrojom Swagger. Výstupy týchto nástrojov sú priložené v samostatných dokumentoch.

4 Frontend

4.1 Analýza

4.1.1 Mapové riešenia

V rámci analýzy sme porovnávali 2 mapové riešnia - Google Maps a HERE Maps. Google Maps
API:

1. JavaScript
2. Android SDK
3. iOS SDK

Ponúkané služby, ktoré môžme využiť:

1. Heatmapy
2. Custom štýlovanie
3. Traffic Layer

Možnosti vykresľovania:

1. markers, popups, info panels
2. polylines, polygons, circles, rectangles
3. používateľom zadané/editované body a oblasti(polygons, rectangles...)

Pricing:

- nutný API klúč (účet a aktívny billing)
- platba za každý prístup
- kredit v hodnote 200$ zadarmo každý mesiac - up to 28,000 loads(dynamic maps)
- 0.007$ za každý load naviac (7$ za 1000 loadov) do 100 000 loadov, 5.6$ do 500 000 loadov... potom custom plány

Podpora prehliadačov:

1. Microsoft Edge
2. IE 10 a 11
3. Firefox
4. Chrome
5. Safari

HERE Maps
Ponúkané služby, ktoré môžme využiť:

1. Map Satellite Tiles
2. Custom Location Extension - Store, manage and retrieve custom POIs and polygons
3. Platform Data Extension - Get additional HERE Map Content, including height and slope values, curvature, speed limits and traffic lights

Možnosti vykresľovania:

1. Markers - normal a DOM
2. Polylines
3. Polygons, Circles, Rectangles

Pricing (mesačne):

1. FREEMIUM - free, 250k tranzakcií + 5k aktívnych userov,
2. PRO - 449$, 1M tranzakcií + 5k aktívnych userov
3. CUSTOM - dá sa dohodnúť custom plán

Podpora prehliadačov:

1. Internet Explorer 10+
2. Firefox (latest)
3. Google Chrome (latest)
4. Apple Safari 6+
5. Internet Explorer 9

Rozhodnutie V službách veľký rozdiel nie je - obidve riešenia poskytujú potrebnú funkcionalitu, HERE Maps ale ponúkajú aj služby navyše (napríklad vytváranie vlastných bodov či vrstiev mapy). Obidve riešenia majú určitý druh free plánu, ktorý nám pri vývoji postačí. Čo sa týka podpory, obidve riešenia poskytujú integráciu formou Javascriptovej knižnice.
Pri riešení HERE Maps sa ale javia pricing plány ako výhodnejšie. Preto sme sa rozhodli využiť na vizualizáciu získaných informácií HERE Maps.

4.1.2 Frontendové frameworky

Angular
Výhody:

- dobrá dokumentácia
- RXJS, HttpClient
- two-way data binding
- dependency injection
- TypeScript

Nevýhody:

- problémy s migráciou (release každých 6 mesiacov)
- strmá krivka učenia
- TypeScript

ReactJS
Výhody:

- ľahký na naučenie
- flexibilita
- virtual DOM
- Downward data binding
- 100% open source
- ľahká migrácia

Nevýhody:

- problémy s dokumentáciou - product owneri nám pomôžu
- príliš voľnosti
- potrebný dlhý čas na tzv. "master"level

VueJS
Výhody:

- detailná dokumentácia
- prispôsobivosť
- integrácia
- škálovateľnosť
- veľkosť

Nevýhody:

- malé zastúpenie na trhu
- over flexibility
- problém s dokumentáciou v angličtine

Kvôli jednoduchosti učenia a preferencii product ownerov sme sa rozhodli frontend vyvíjať v Reacte. Umožní nám rýchlo začať vyvíjať webové rozhranie a prípadné problémy môžme riešiť aj s product ownermi, ktorí nám sľúbili pomoc.

4.1.3 Porovnanie Metronic vs. AdminLTE

Metronic
Výhody:

- má vysoké rozlíšenie
- má veľké množstvo widgetov, diagramov, atď.

Nevýhody:

- nie je priamo integrovateľný s React-om
- spoplatnený (35$), neponúka žiadne voľné šablóny

Podpora prehliadačov:

1. Internet Explorer 10+
2. Firefox (latest)
3. Google Chrome (latest)
4. Apple Safari 6+
5. Microsoft Edge (latest)
6. Opera (latest)

Kompatibilita:

1. AngularJS 2
2. Bootstrap 4.x
3. Bootstrap 3.x

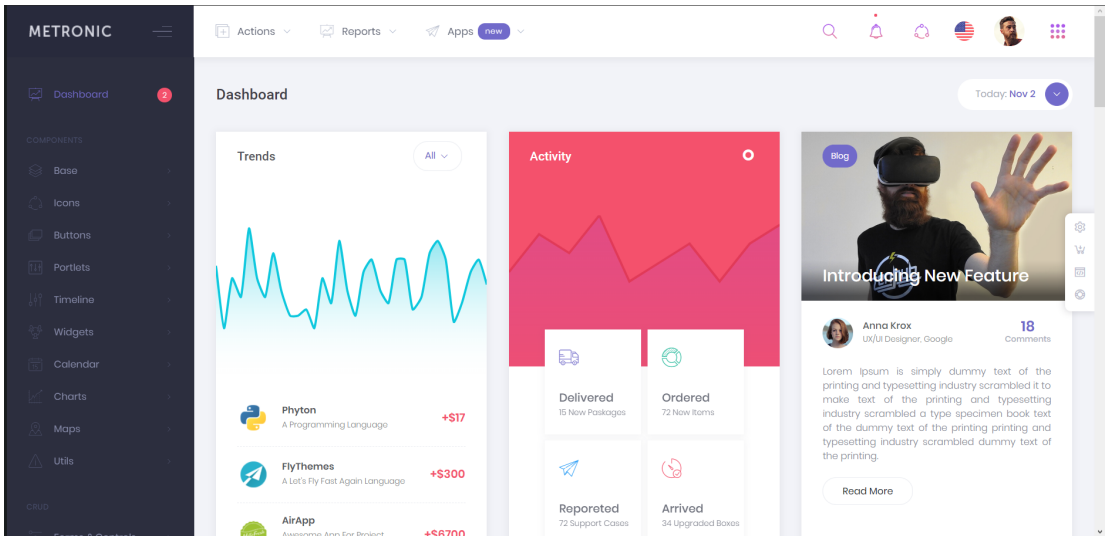

Obr. 1: Metronic.

AdminLTE
Výhody:

- má vysoké rozlíšenie
- má veľké množstvo widgetov, diagramov, atď.
- ponúka aj šablóny zadarmo (študentská MIT licencia)

Podpora prehliadačov:

1. Internet Explorer 9+
2. Firefox (latest)
3. Google Chrome (latest)
4. Apple Safari 6+
5. Microsoft Edge (latest)
6. Opera (latest)

Kompatibilita:

1. React
2. Laravel
3. AngularJS 2
4. Bootstrap 3.x+

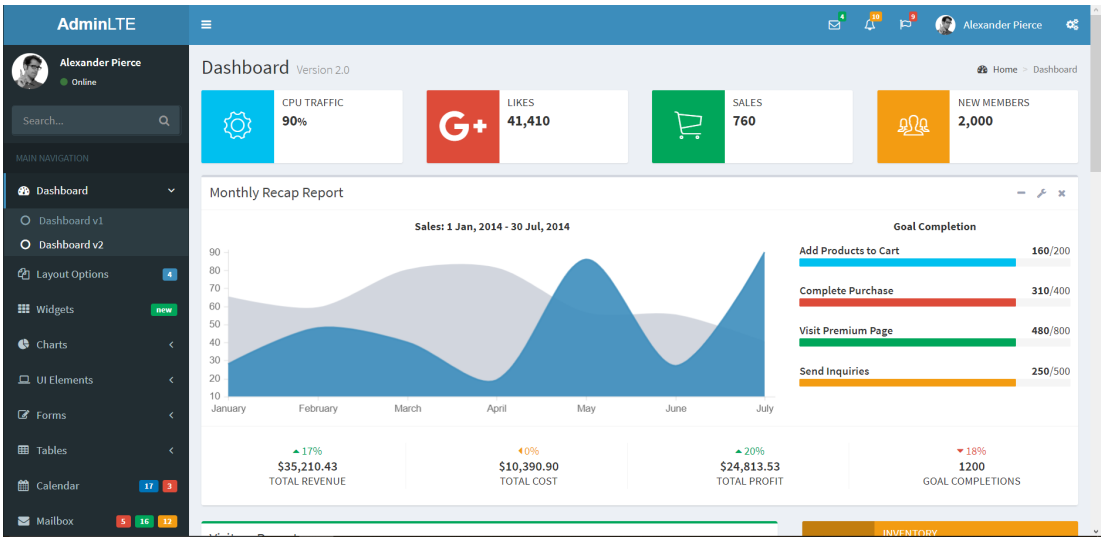

Obr. 2: AdminLTE.

Vzhľadom na fakt, že Metronic nemá priamu integráciu s Reactom, rozhodli sme sa použiť AdminLTE, ktorý ponúka podobnú funkcionalitu aj v šablónach, ktoré sú zadarmo.

4.2 Implementácia

4.2.1 Obrazovky

V tejto časti predstavíme obrazovky webovej stránky nášho projektu : 3, 4, 5, 6.

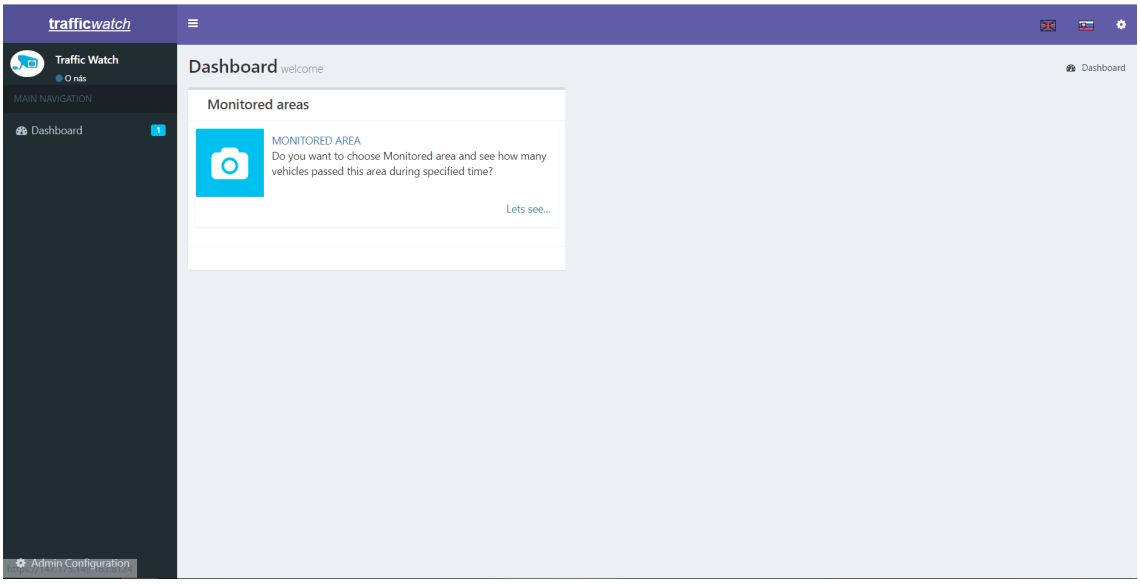

Obr. 3: Dashboard pre web projektu. Odtiaľto sa bude dať prekliknúť na ostatné štatistiky.

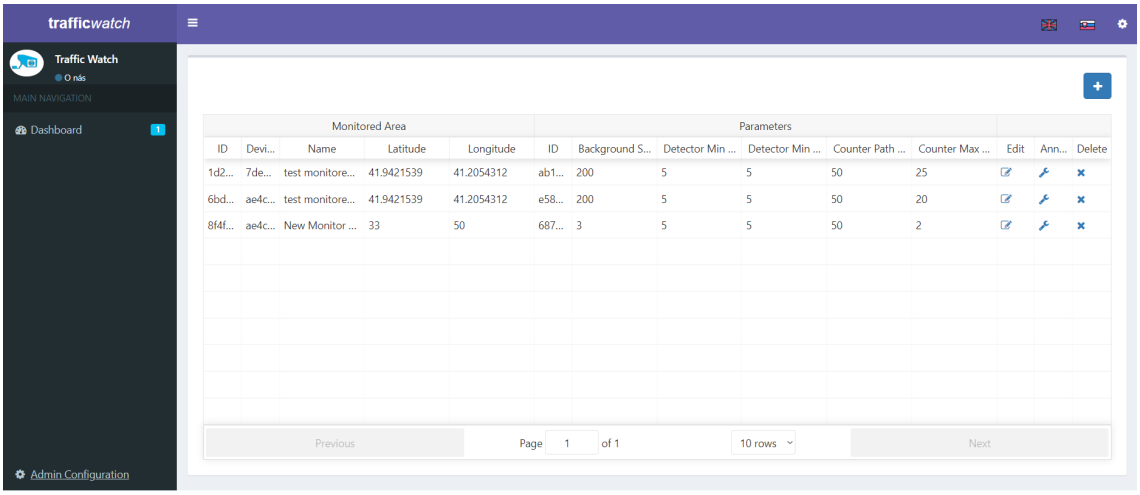

Obr. 4: Komponent pre konfiguráciu sledovaných oblastí, umožňuje oblasti pridávať, editovať, anotovať a vymazávať.

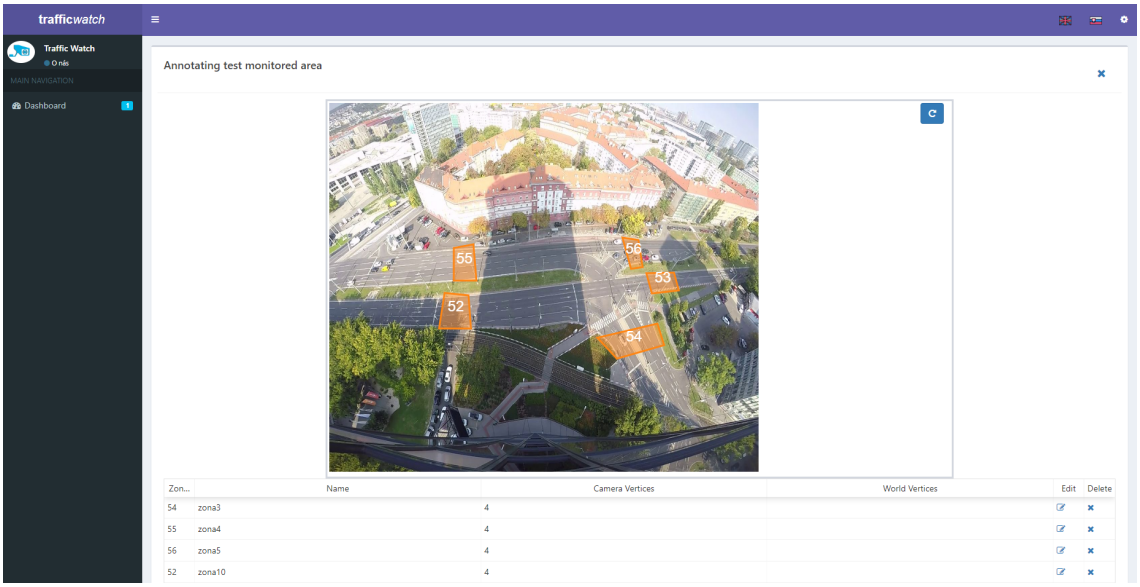

Obr. 5: Tento komponent slúži na konfiguráciu zón pre sledované oblasti, dostaneme sa sem kliknutím na ikonku "konfigurovať"(kľúč) v riadku tabulky sledovaných oblastí.

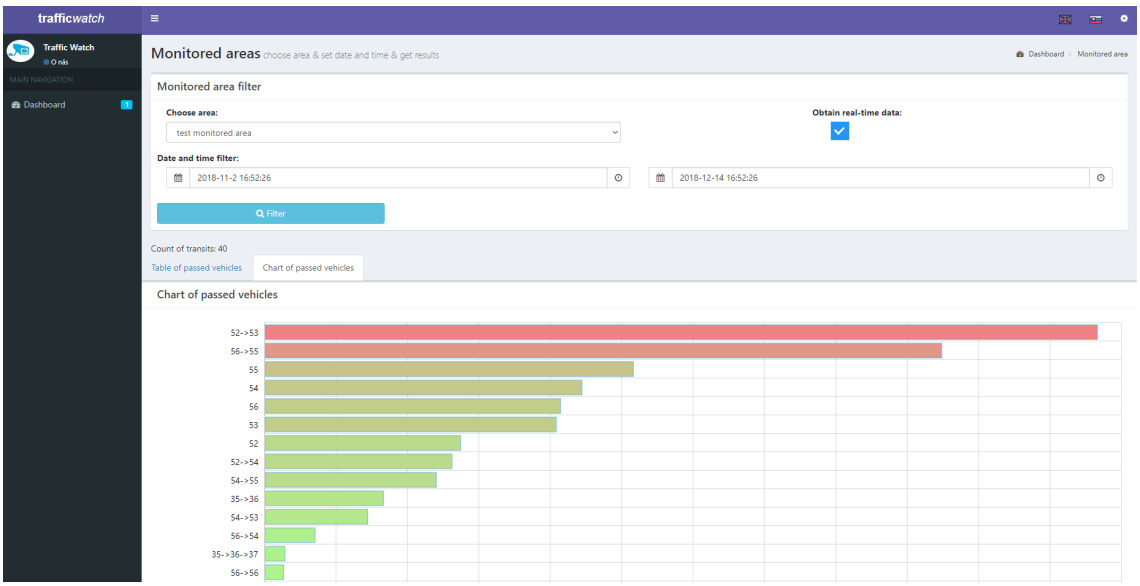

Obr. 6: Štatistiky aut ktoré prešli cez zóny sa zobrazujú v tabuľke a aj v grafoch. Tieto grafy sú prvou z plánovaných vizualizácií dát.

4.2.2 Lokalizácia

Na lokalizáciu bola integrovaná knižnica react-i18next (zvolená kvôli univerzálnosti knižnice i18next v prostredí webových aplikácií v rámci rozvoja schopností členov tímu do budúcnosti). Jazyky sú načítavané dynamicky (XHR) na základe voľby používateľa podľa pridaného selektora jazyka, prípadne predvolene podľa nakonfigurovanej autodetekcie podľa jazykového nastavenia webového prehliadača. Ďalej bol integrovaný nástroj i18next-scanner na automatickú extrakciu kľúčov z kódu pomocou príkazu npm run translations pre jednoduchšiu lokalizáciu. V rámci CI bola implementovaná kontrola, či je každý textový reťazec (kľúč) preložený.

5 Testovanie

Zo všetkých modulov systému sú zatiaľ testami pokryté len niektoré moduly na strane serveru. Na strane kamere o testoch zatiaľ neuvažujeme. V neskorších fázach riešenia projektu sa zavedú automatické testy pre frontend, napr. pomocou nástroja Selenium.

5.1 Testovanie backendu

Na strane serveru sú dostupné jednotkové testy, ktoré sa zameriavajú na overenie správnosti fungovanie CRUD operácií nad entitami z modelu údajov.
Pri testovaní používame knižnicu JUnit, ktorú sme spojili s knižnicou DBUnit.
Každý test si pred spustením inicializuje testovaciu databázu a naplní ju údajmi zo zadaného XML súboru. Po úspešnom alebo neúspešnom vykonaní testu sa dáta z databázy odstránia. Výsledkom sú testy, ktoré sú samostatne spustiteľné a nezáleží na poradí ich vykonávania.

6 Continuous integration

Po troch žiadostiach na Github a Travis bola schválená študentská organizácia s prístupom k Travis CI. VCS bolo následne premigrované z Bitbucketu na Github. Repozitár servera bol obohatený o Travis skript, ktorý automaticky nakonfiguruje systém s ohľadom na podmienky spustenia testov (databáza) a vykoná testovanie. CI bolo integrované do Githubu, merge pull requestu nie je možné vykonať, pokiaľ daná vetva neprešla úspešne testami. Github a Travis boli integrované do Slacku.