

UNIVERZA V LJUBLJANI
EKONOMSKA FAKULTETA

MAGISTRSKO DELO

**UPORABA METODE PODPORNIH VEKTORJEV ZA ZAZNAVANJE
PREUSMERJENIH LETOV**

Ljubljana, januar 2015

MIHA MIKEC

IZJAVA O AVTORSTVU

Spodaj podpisani(-a) Miha Mikec, študent Ekonomske fakultete Univerze v Ljubljani, izjavljam, da sem avtor zaključne magistrskega dela z naslovom Uporaba metode podpornih vektorjev za zaznavanje preusmerjenih letov, pripravljenega v sodelovanju s svetovalcem prof. dr. Petrom Trkmanom in sosvetovalcem prof. dr. Janom Mendlingom.

Izrecno izjavljam, da v skladu z določili Zakona o avtorski in sorodnih pravicah (Ur. l. RS, št. 21/1995 s spremembami) dovolim objavo magistrskega dela na fakultetnih spletnih straneh.

S svojim podpisom zagotavljam, da

- je predloženo besedilo rezultat izključno mojega lastnega raziskovalnega dela;
- je predloženo besedilo jezikovno korektno in tehnično pripravljeno v skladu z Navodili za izdelavo zaključnih nalog Ekonomske fakultete Univerze v Ljubljani, kar pomeni, da sem
 - poskrbel, da so dela in mnenja drugih avtorjev oziroma avtoric, ki jih uporabljam v magistrskem delu, citirana oziroma navedena v skladu z Navodili za izdelavo zaključnih nalog Ekonomske fakultete Univerze v Ljubljani, in
 - pridobil vsa dovoljenja za uporabo avtorskih del, ki so v celoti (v pisni ali grafični obliki) uporabljena v tekstu, in sem to v besedilu tudi jasno zapisal;
- se zavedam, da je plagiatorstvo – predstavljanje tujih del (v pisni ali grafični obliki) kot mojih lastnih – kaznivo po Kazenskem zakoniku (Ur. l. RS, št. 55/2008 s spremembami);
- se zavedam posledic, ki bi jih na osnovi predloženega magistrskega dela dokazano plagiatorstvo lahko predstavljalo za moj status na Ekonomski fakulteti Univerze v Ljubljani v skladu z relevantnim pravilnikom.

V Ljubljani, dne _____

Podpis avtorja: _____

KAZALO

UVOD	1
1 OZADJE.....	2
1.1 Zamude in preusmeritve tovora	3
1.2 Okoljski vpliv	4
1.3 Stroški prevoza	6
1.4 Letalski tovorni promet	8
1.4.1 Mednarodni letalski tovorni promet.....	8
1.4.2 Trend zračnega tovarnega prometa.....	10
1.4.3 Evropski letalski promet med letoma 2008 in 2013	11
1.4.4 Evropski letalski promet v prihodnosti	13
1.4.5 Zamude in preusmeritve poletov	14
2 DETEKCIJA PREUSMERJENEGA POLETA	15
2.1 Trajektorija poleta.....	16
2.2 Sledenje letala.....	17
2.3 Obstoječa raziskovalna dela	17
2.4 Projekt GET Service	18
2.5 Metoda podpornih vektorjev	20
2.5.1 Strojno učenje	21
2.5.2 Klasifikacija (uvrščanje)	21
2.5.3 Metoda podpornih vektorjev.....	22
2.5.4 Primeri uporabe.....	23
2.6 Primer predhodno opravljene študije za zaznavanje preusmerjenih poletov	24
2.6.1 Podatki	24
2.6.2 Pridobivanje podatkov	25
2.6.3 Vzorci preusmeritve.....	25
2.6.4 Zaznavanje nepravilnega vedenja	27
2.6.5 Predvidevanje preusmeritve.....	27
2.6.6 Podatki za testiranje	27
2.6.7 Optimizacija parametrov.....	28
2.6.8 Učinkovitost.....	30

2.6.9 Pridobitev odzivnosti/časovna pridobitev	31
3 VREDNOTENJE.....	32
3.1 Podatki o poletih.....	32
3.2 Treniranje/učenje SVM	35
3.2.1 Parametri za učenje SVM	36
3.2.2 Zaznavanje preusmerjenega poleta	36
3.2.3 Izbira trajektorij za učenje SVM.....	38
3.2.4 SVM, temelječ na evropskih poletih.....	39
3.2.5 SVM, temelječ na evropskih in ameriških poletih.....	41
3.3 Diskusija rezultatov	44
SKLEP.....	44
LITERATURA IN VIRI.....	47

KAZALO TABEL

Tabela 1: Predvidene spremembe v številu poletov	13
Tabela 2: Pravočasni, zamujeni, odpovedani in preusmerjeni poleti med letoma 2003 in 2014.	15
Tabela 3: Pravočasni, zamujeni, odpovedani in preusmerjeni poleti na letni ravni med letoma 2005 in 2014.....	15
Tabela 4: Rezultati treniranja SVM.	29
Tabela 5: Rezultati učenja SVM z 219 evropskimi trajektorijami.	40
Tabela 6: Klasifikacije 449 evropskih normalnih poletov.	40
Tabela 7: Klasifikacije 20 evropskih preusmerjenih poletov.....	41
Tabela 8: Klasifikacije 449 evropskih in 217 ameriških normalnih poletov.	41
Tabela 9: Klasifikacije 20 evropskih in 22 ameriških preusmerjenih poletov.	41
Tabela 10: Klasifikacija 449 normalnih evropskih poletov šestih različnih SVM.	42
Tabela 11: Klasifikacija 20 preusmerjenih evropskih poletov šestih različnih SVM.	42
Tabela 12: Rezultati 6 različnih SVM.....	43
Tabela 13: Klasifikacija 571 normalnih poletov sedmih različnih SVM.	43
Tabela 14: Klasifikacija 30 preusmerjenih poletov sedmih različnih SVM.	44
Tabela 15: Rezultati sedmih različnih SVM.	44

KAZALO SLIK

Slika 1: Izpusti CO ₂ iz različnih panog.	5
Slika 2: Izpusti CO ₂ glede na način transporta v letu 2000.....	5

Slika 3: Deleži števila praznih km v nekaterih evropskih državah.	7
Slika 4: Rast zračnega tovornega prometa med letoma 1979 in 2008.	9
Slika 5: Gibanje cen prevoza blaga z letali med letoma 1954 in 2004.	9
Slika 6: Primerjava gibanja prepeljanega tovora z letali in svetovna izmenjava blaga.	10
Slika 7: Primerjava gibanja prepeljanega tovora z letali in gibanje prepeljanih polprevodnikov z letali.	11
Slika 8: Dnevno število poletov po letalskih segmentih med letoma 2008 in 2013.	12
Slika 9: Gibanje števila poletov po letalskih segmentih med letoma 2008 in 2013 glede na prejšnje leto.	12
Slika 10: Primer dveh razredov, ločenih s hiperravninami.	23
Slika 11: Spremembe hitrosti pri normalnem in preusmerjenem poletu.	26
Slika 12: Razmerje med L in F-statistiko pri treniranju SVM.	30
Slika 13: Rezultati testiranja osmih različnih SVM.	31
Slika 14: Manjkajoče pozicije/zapisi poleta iz Moskve v Varšavo.	35
Slika 15: Primer intervala.	37
Slika 16: Postopek klasifikacije preusmerjenega poleta.	38
Slika 17: Primer nenormalnega nepreusmerjenega poleta iz Rima v Köbenhavn.	39

UVOD

V današnjem globalnem poslovanju se blago dnevno transportira po vsem svetu in prepotuje tudi več kot tisoč kilometrov (Freight Management and Operations, U.S. Department of transportation, 2014). Na tako dolgi poti lahko nastane marsikatera težava, ki povzroči zamudo blaga (zastoji na cesti zaradi prometne nesreče, nepredvidljive vremenske razmere, morebitna napaka voznika ipd.).

Zgodi se lahko tudi, da na prevzem blaga na nekem letališču čaka tovornjak. Zaradi neustreznih vremenskih razmer, stavke na letališču ali morebitne okvare na letalu lahko letalo ne pristane na predvidenem letališču, voznik tovornjaka pa je s tem najverjetneje seznanjen šele po pristanku. Če bi bila informacija o zamudi oziroma spremembi pristanka pravočasna, bi voznik prejel nov delovni nalog, obvestili pa bi tudi voznika drugega tovornjaka, da prevzame blago na primernem letališču. Sicer blago ne bo pravočasno prispelo na cilj, poleg tega lahko to za transportne/logistične službe pomeni finančno izgubo, za prebivalstvo pa nepotrebno onesnaževanje okolja.

Transport blaga po svetu se v zadnjem času povečuje (Eurostat, 2013), s tem pa tudi kilometri, ki jih opravijo letala, tovornjaki in druga prevozna sredstva. Mnoga od teh puščajo sledi na okolju, npr. onesnaženost zraka (McKinnon, 2007). Dodatno se onesnažuje okolje, ko se ta vozila prevažajo brez tovora. Poleg tega s tako imenovanimi praznimi kilometri (angl. *empty miles*) podjetja ustvarjajo dodatne stroške (Min, 2002). S povečevanjem transporta blaga je pričakovati, da se bo negativen vpliv na okolje povečeval, prav tako pa absolutno število letal, ki ne bodo pristala na sprva predvidenem letališču.

Delimo si isti planet, zato si z našim raziskovalnim delom prizadevamo, da bi pripomogli k zmanjšanju prevoženih praznih kilometrov in zmanjšanju nepotrebnega čakanja, saj bi med tem lahko opravili drugo delo.

Danes je na voljo več spletnih strani, na katerih lahko v realnem času spremljamo npr. polete nad Evropo. Ena takšnih je na <http://www.flightradar24.com/>. Pregled poletov je javno dostopen.

Za posamezne polete na spletni strani lahko dobimo informacije, od kod letalo prihaja in kam je namenjeno. Zaradi strogih varnostnih meril poteka podrobnejša komunikacija le med letali in letališči. Tovrstni podatki pa niso na voljo javnosti, vsaj dokler letalo ne pristane.

Cilj mojega raziskovalnega dela je, da bi s spremljanjem javno dostopnih podatkov in s pomočjo predhodno zgrajene odločitvene programske rešitve, o kateri bomo več pisali v nadaljevanju, dokazali, da lahko uspešno zaznavamo preusmerjene polete. To bi bilo uspešno, če bi med vsemi dejansko preusmerjenimi poleti zaznali vsaj 50 odstotkov takšnih, in to vsaj 30 minut pred pristankom. Pri nepreusmerjenih poletih pa, da bi bil delež morebitnih lažnih

alarmov o preusmeritvi pod pet odstotkov. Vse to, da bi še pred pristankom letala logistične službe prejele informacijo, ki bi jim koristila pri razporejanju dela in resursov.

Izdelava magistrske naloge je temeljila na treh fazah. V prvi sem se osredotočil na pregled obstoječe literature in podatkov, ki govorijo o ekonomskem in okoljskem vplivu tovarnega prometa. Glavni namen je bil ugotoviti, kakšen ekonomski in okoljski vpliv imajo obvozi, zamude in preusmeritve v cestnem, rečnem, železniškem ali letalskem tovarnem prometu.

V drugi fazi sem pregledal dosedanje delo na področju odkrivanja ali zaznavanja preusmeritev letal. Pri tem ni bilo pomembno, ali so bili pridobljeni podatki javne ali zasebne narave, in tudi ne, kako so se lotili zaznavanja preusmeritev. Poleg tega so me zanimali tudi končni rezultati opravljenih raziskav.

V zadnji, tretji fazi, sem se posvetil izdelavi programske rešitve, ki bi temeljila na javno dostopnih podatkih o poletih. Rešitev bi bila uspešna, če bi zaznala preusmerjene polete v več kot 50 odstotkih vsaj 30 minut pred pristankom. Še pred začetkom testiranja sem moral med vsemi podatki zbrati primerne za izdelavo rešitev. Nato sem se lotil testiranja in analiziranja pridobljenih rezultatov.

Poleg uvoda magistrsko delo sestavljajo še tri poglavja s podpoglavji in seznam literature.

V prvem poglavju želim prikazati predvsem, kako tovarni promet vedno bolj obremenjuje okolje in koliko stroškov za podjetja predstavlja prevoz tovora.

V drugem poglavju se bolj poglobim v sledenje poletov in detekcijo preusmeritev. Opišem, kako so se v preteklosti lotili obdelave podatkov o poletih in dosedanja dela pri detekciji. Predstavim tudi projekt GET Service, ki se loteva bolj zelenega in učinkovitejšega tovarnega prometa. Poleg tega opišem še metodo podpornih vektorjev, ki sem jo uporabil pri raziskovalnem delu, in predhodno opravljeno študijo o zaznavanju preusmerjenih poletov.

Tretje poglavje podrobneje opisuje moje raziskovalno delo, od pridobivanja podatkov, učenja SVM, testiranja in pridobljenih rezultatov.

1 OZADJE

Povpraševanje po kapacitetah za transport blaga se v globaliziranem svetu povečuje, kar je za evropski transportni ekosistem velik izziv (GET Service Project, 2014b). Povečevanje transportnih zmogljivosti se pozna pri transportni infrastrukturi, okolju in generalni populaciji.

Posebej problematičen je naraščajoč negativen vpliv transportnega sektorja na okolje, saj podatki kažejo, da v Evropi med vsemi sektorji najbolj onesnažuje ozračje, pri čemer to še povečuje (GET Service Project, 2014b). Izpusti CO₂ so se med letoma 1990 in 2007 v Evropi na področju transporta povečali za 29 odstotkov, leta 2000 pa je cestni transport prispeval 73 odstotkov vseh izpustov CO₂.

Trenutna infrastruktura je vedno bližje končni obremenitvi prometa, ki jo še lahko prenese. Širitev cest pri tem ne rešuje nujno problema cestnih zastojev, ki so iz leta v leto večji. Izboljšanje cestne infrastrukture pa prav tako ni rešitev za zmanjšanje izpustov CO₂, saj se s tem ne zmanjša število prevoženih kilometrov (GET Service Project, 2014b).

Obravnavanega problema se v tej magistrski nalogi v podobnem smislu nismo lotili prvi. Zaradi vplivov, ki jih imajo takšne ali drugačne prigode v prometu, bi si morali kot družba prizadevati za čim manj napak v celotnem procesu.

1.1 Zamude in preusmeritve tovara

Kadar blago ne pride pravočasno na cilj, to ne pomeni le, da bo končni potrošnik izdelek kupil z zamudo, ampak lahko prinese precej večje posledice. Motnja v prometu, ki traja npr. od enega dneva do tedna dni, lahko povzroči začasne ali kratkotrajne ekonomske izgube (Methodologies to Estimate the Economic Impacts of Disruptions to the Goods Movement System, 2014, str. 2). Če pa traja dlje časa, so ekonomske posledice lahko izjemno negativne, odvisno od prilagodljivosti industrije (Methodologies to Estimate the Economic Impacts of Disruptions to the Goods Movement System, 2014, str. 2). Tudi pri kratkotrajnih motnjah v dostavi blaga niso izključene dolgotrajne negativne ekonomske posledice.

Dalj časa trajajoče, geografsko obširnejše in številne prekinitve pri dostavi blaga bodo bolj verjetno pustile resne učinke na gospodarstvu. Po drugi strani pa bodo krajše in manj obsežne bolj verjetno povzročile le omejene gospodarske posledice (povišani transportni stroški in stroški zalog) (Methodologies to Estimate the Economic Impacts of Disruptions to the Goods Movement System, 2014, str. 2). Pri obsežnejših in dlje trajajočih motnjah bo najverjetneje prišlo do prekinitev pri proizvodnji oz. dostavi izdelkov. V takšnih primerih je izvoz na regionalni ali celo nacionalni ravni zmanjšan, kar lahko pomeni nižji BDP. Še vedno si podjetja lahko opomorejo, vendar so izgube neizogibne (Methodologies to Estimate the Economic Impacts of Disruptions to the Goods Movement System, 2014, str. 2).

Pri resnih posledicah je lahko prizadet širši del udeležencev znotraj oskrbovalne verige. Poleg ladijskih, železniških, cestnih in letalskih prevoznikov tudi javne agencije, lokalni sindikati, trgovci, ponudniki skladiščenja in distribucije ter posredno tudi veliko potrošnikov in gospodarskih organizacij (Methodologies to Estimate the Economic Impacts of Disruptions to the Goods Movement System, 2014, str. 2). V ekstremnih primerih, če proizvajalec, ki pričakuje blago, deluje po t. i. sistemu *just-in-time*, zamuda zanj pomeni zmanjšanje proizvodnje in izgubo v prodaji (Gong, Miao, Wang & Adams, 2014, str. 7).

V študiji, izdani leta 2012, so zapisali, da je pričakovati, da se bo tovarni promet v naslednjih 30 letih podvojil (Gong et al., 2014, str. 7). Dostava tovara v nedogovorjenem času prizadene proizvodnjo, vpliv pa ima tudi na logistične operacije. Poleg tega zamude tovara prinesejo tudi višje stroške. Stroški tovorjenja so od leta 1981, ko so znašali 228 milijard ameriških dolarjev (Gong et al., 2014, str. 9), do leta 2002 zrasli na 577 milijard ameriških dolarjev, kar obsega 45,1 oz. 63,4 odstotka vseh logističnih stroškov.

Poleg težko izmerljivih stroškov v morebitnem upadu produktivnosti ali prodaje, ki jih prinese dodatna zamujena ura tovornjaka s tovorom, lahko kot izmerljive stroške omenimo naslednje: približno 18,5 ameriškega dolarja za gorivo, 59,61 ameriškega dolarja pa je operativnih stroškov tovornjaka, kamor so vključeni tudi najem tovornjaka/prikolice, plačilo voznika ipd. (Gong et al., 2014, str. 12). Poleg tega se prevozne službe soočajo s problemom, da nezanesljivo načrtujejo prihodnje pošiljke, kar lahko vodi v zmanjšanje prostih resursov. Zaradi zadnjega se lahko zmanjša zmožnost ustreči več strankam, zaradi rednih nezanesljivih/nepravočasnih dobav pa lahko podjetja celo izgubijo stranke in s tem povezane prihodke (Gong et al., 2014, str. 13).

Zamujena dostava pošiljke blaga lahko povzroči, da bo drugo dostavno vozilo zamujalo pri naslednjih dostavah. To lahko privede do nezadovoljstva strank. Še ena od težav pa je, da lahko prevoznik krši pravila, povezana s številom ur za voznike, če želi v še razumnem času dostaviti blago (Gong et al., 2014, str. 13).


V študiji (Hummels, 2001) so ugotovili, da so uvozniki pripravljeni plačati 0,8 odstotka vrednosti pošiljke za vsak dan, prihranjen pri dostavi. To pomeni, da vsak dan zamude za uvoznika pomeni 0,8 odstotka dodatnih stroškov celotne vrednosti pošiljke.

1.2 Okoljski vpliv

Čeprav obstaja več toplogrednih plinov, je ogljikov dioksid (CO_2) znan kot tisti, ki najbolj negativno vpliva na naše okolje (Larsson & Kollberg, 2009, str. 1). Leta 2004 je obsegal 77 odstotkov vseh toplogrednih plinov, oddanih v okolje, od leta 1970 do 2004 pa so se njegovi izpusti povečali za približno 80 odstotkov (Intergovernmental Panel on Climate Change, 2007).

S slike 1 je razvidno, da poleg proizvodnje energije k izpustu CO_2 v okolje najbolj prispeva promet. V 27 evropskih državah se je delež izpustov CO_2 v prometni panogi med letoma 1995 in 2006 povečal za 19 odstotkov. S slike 1 je prav tako razvidno, da je večjemu delu panog uspelo zmanjšati te izpuste v primerjavi z letom 1995. Pri prometu pa je ravno nasprotno. Trend naraščanja izpustov CO_2 se nadaljuje kljub učinkovitejšim in čistejšim vozilom, saj k temu prispeva globalizacija (Larsson & Kollberg, 2009, str. 2). Kljub visoki rasti cen goriv se trend naraščanja izpustov CO_2 v prometu ni zmanjšal. Izpusti so se povečevali celo hitreje kot je rastla mednarodna trgovina in BDP (Larsson & Kollberg, 2009, str. 2).


Slika 1: Izpusti CO₂ iz različnih panog.



Vir: F. E. Larsson & D. Kollberg, *Overcoming the obstacles of intermodal transport*, 2009, str. 2.

V letu 2011 je k celotni količini izpusta CO₂ v ozračje promet prispeval 13,1 odstotka, vendar pa je zaradi rasti populacije in globalizacije pričakovati, da se bo ta delež povečeval (Laurson, Dislers & Keremet, 2011, str. 5). Stern (2006) z raziskovalnega inštituta klimatskih sprememb in okolja pravi, da je promet odgovoren za 14 odstotkov vseh toplogrednih plinov, izpuščenih v ozračje, pri čemer 76 odstotkov tega povzroči cestni promet, kot je razvidno s slike 2.

Slika 2: Izpusti CO₂ glede na način transporta v letu 2000.



Vir: N. Stern, *The economics of climate change*, 2006.

Že v osemdesetih letih prejšnjega stoletja je v zavest ljudi prišlo, da bo imelo povečanje proizvodnje vedno večji negativni vpliv na okolje in da bo treba nekaj storiti za njegovo trajnost. Okoljska trajnost stremi k temu, da bi zadovoljili današnje potrebe in s tem ne ogrozili možnosti prihodnjih generacij, da bi zadovoljevale svoje (Laurson et al., 2011, str. 6). Že pred več kot 15 leti se je začela povečevati ozaveščenost javnosti o okoljskih problemih in globalnem segrevanju. S tem so se pojavila pričakovanja, da bodo podjetja ukrepala in

ravnala drugače v proizvodnih procesih in dostavi, zaradi česar so bili vpeljeni različni vladni predpisi (Laurson et al., 2011, str. 6). Leta 1992 je Evropska unija predstavila prve smernice, s čimer so začeli upajati različne standarde za izboljšanje motorjev tovornjakov in avtobusov (Laurson et al., 2011, str. 6). Vse od takrat se standardi izboljšujejo in onesnaževanje se zmanjšuje (posameznega motorja).

Države, denimo Velika Britanija, so si zadale cilj, da bodo izpuste CO₂ zmanjšale za 80 odstotkov do leta 2050, tako bi bila njihova količina enaka kot leta 1900. Ker vlade kažejo več zanimanja za odnos med logistiko in okoljem, podjetja ne morejo več ignorirati okoljskih problemov, ki jih povzročajo s svojim delovanjem (Laurson et al., 2011, str. 7). V nasprotju s starimi članicami EU se na novo pridružene soočajo z novimi in strogimi standardi (Laurson et al., 2011, str. 7), ki jih morajo uvesti v razmeroma kratkem času. Zato so podjetja čedalje bolj prisiljena k temu, da prevzemajo odgovornost za vpliv na okolje.

V logističnih podjetjih, ki upajajo spremembe (nakup novih vozil, usposabljanje voznikov za bolj gospodarno vožnjo itd.), da bi manj onesnaževala, to kratkoročno poveča stroške. Toda tovrstni ukrepi lahko vodijo do boljšega ugleda in povečanja dobička (Laurson et al., 2011, str. 7).

1.3 Stroški prevoza

Glavni cilj prevoza tovora je povezati izvirno lokacijo blaga s strankami z najnižjimi možnimi transportnimi stroški in upoštevajočimi omejitvami, ki jih postavi stranka (Laurson et al., 2011, str. 11). Transport blaga je najdražji del logistike, ta pa je ena od aktivnosti v mednarodni trgovini, ki povzroča največ stroškov (Laurson et al., 2011, str. 11). Transport blaga pogosto zajema skoraj polovico vseh logističnih stroškov in transportni stroški so vedno največji strošek vseh distribucijskih stroškov. Te navedbe jasno kažejo na pomembnost in koristi ekonomičnega in učinkovitejšega transporta. Do tega je mogoče priti s trajnostnimi praksami in je to zato možno razumeti kot eno od spodbud, zakaj postati do okolja prijaznejši. Stroški logistike pa imajo na finančno uspešnost poleg neposrednega tudi posreden vpliv (Laurson et al., 2011, str. 12).


V eni od anket, ki je bila opravljena med logističnimi podjetji (Laurson et al., 2011, str. 34), so anketiranci lahko odgovorili, katere od navedenih praks njihovo podjetje uporablja, da bi zmanjšalo izpuste CO₂. Med vsemi jih je 16 odstotkov odgovorilo, da po raztovoru poberejo še nov tovor in ga nato peljejo, v smeri od koder so prišli. Tako želijo zmanjšati prevožene prazne kilometre.

Da pa uresničevanje dobrih praks za zmanjševanje izpustov CO₂ oz. varovanje okolja lahko vpliva na uspešnost logističnega podjetja, so pokazale tudi že nekatere ankete. Izkazalo se je, da je več kot 90 odstotkov podjetij že ovrednotilo ali pa še bodo svoje dobavitelje glede na skrb za trajnost okolja (Robinson, 2008) in da skoraj 80 odstotkov potrošnikov pred nakupom oceni nakup glede na okoljske prakse (Pedersen, 2009). Nekatera podjetja celo postavijo ultimat dobaviteljem v svoji dobavni verigi, da naj uporabljajo dobre prakse za varovanje

okolja, če želijo še naprej poslovati z njimi (Laurson et al., 2011, str. 35). To zahtevajo tudi zaradi tega, ker je kar 40 odstotkov potrošnikov pripravljenih plačati več za izdelke, prijazne do okolja; predvidevajo, da se bo ta delež še povečeval (Pedersen, 2009).

Po podatkih Eurostata se delež praznih kilometrov, prevoženih s tovornimi vozili, med evropskimi državami razlikuje. Tako naj bi v Latviji znašal 13 odstotkov, na Danskem 17, v Grčiji 35 in 38 na Irskem oz. 45 odstotkov na Cipru (Rizet, Cruz & Mbacké, 2012, str. 186). Na sliki 3 je prikazano spreminjanje deleža praznih kilometrov v nekaterih državah, pri čemer je razvidno, da je od 18 do 28 odstotkov. V Nemčiji se je ta delež zmanjšal, v Veliki Britaniji pa nekoliko povečal.

Slika 3: Deleži števila praznih km v nekaterih evropskih državah.



Vir: C. Rizet et al., *Reducing Freight Transport CO2 Emissions by Increasing the Load Factor*, 2012, str. 187.

Z anketiranjem prevoznikov na Tajskem so želeli ugotoviti, koliko praznih kilometrov prevozijo tovorna vozila na njihovem ozemlju (Peetijade & Bangviwat, 2012, str. 98). Pred tem lahko omenimo, da je bilo leta 2006 na Tajskem približno 690.000 tovornjakov, s katerimi so letno opravili okoli 71,74 milijona potovanj (navadno od A do B in nazaj v A) oziroma 12.415 milijonov kilometrov. Kar 33 milijonov potovanj ali 5586 milijonov kilometrov je bilo opravljenih brez tovora. Z deljenjem informacij med podjetji, bi se delež takšnih kilometrov lahko zelo zmanjšal. S skupnim načrtovanjem transportnih poti bi lahko privarčevali do 37 odstotkov distribucijskih stroškov (Peetijade & Bangviwat, 2012, str. 98).

V anketi so ugotovili, da so s tovornimi vozili anketiranih podjetij na teden opravili 245.118 povratnih (angl. *backhaul*) kilometrov. Od tega je bilo 210.193 takšnih, pri katerih so se od kraja, kjer so tovor oddali, do kraja, kjer so pot začeli, vračali brez tovora, in 34.925 takšnih s tovorom. Kilometrov, pri katerih je bilo ob vrnitvi tovorno vozilo brez tovora, je bilo torej kar 85,74 odstotka (Peetijade & Bangviwat, 2012, str. 101).

1.4 Letalski tovorni promet

Zračni tovorni promet omogoča prevoz tovora med državami na hiter in učinkovit način, ki ga z drugimi vrstami transporta ne moremo doseči, predvsem pri daljših razdaljah (Department for Transport, 2009, str. 2). Zaradi tega je letalski tovorni promet v prednosti, še posebej pri zelo časovno občutljivem blagu, kot so hitro pokvarljiva živila, zdravila, različni strojni deli ter izdelki z visoko vrednostjo, npr. visokotehnološki izdelki ali dragi kamni.


Poznamo dva različna modela letalskega transporta tovora (Department for Transport, 2009, str. 4). Prvega so sprejeli večji redni letalski prevozniki. Pri njem se na nekatera večja potniška letala, ki imajo dovolj kapacitete pod prostorom s potniki, naloži tovor. Manjša letala zaradi manj prostora ne sprejemajo dodatnih ali večjih pošilk. Podobno pa je z nizkocenovnimi letalskimi družbami, saj težijo k hitrim preobratom na letališčih, česar pa dodatno ravnanje z blagom ne omogoča (Department for Transport, 2009, str. 4). Nekatere letalske družbe, sicer znane po prevažanju potnikov, imajo tudi lastna tovorna letala, namenjena zgolj prevažanju tovora. Tudi za to imajo bolj ali manj redne linije, kjer se redno prevažata večji obseg blaga. Poleg tega lahko ponujajo tudi nekakšno kurirsko storitev, kjer se z blagom ravna podobno kot s potniško prtljago in zato ni opredeljeno kot tradicionalni tovor.

Drug način prevoza tovora z letali pa izvajajo specializirane prevozne družbe. Razvil se je v zadnjih 25 letih za ekspresno ali t. i. *next day* (naslednji dan) dostavo. Ti ponudniki prevoznih storitev ponujajo popolno dostavo blaga od izvira do cilja, za kar uporabljajo tovorna letala, lahko pa zakupijo tudi kapacitete na rednih potniških linijah drugih letalskih prevoznikov. Od celotnih kapacitet tovora, prepeljanega na t. i. ekspresen način, kar okoli 98 odstotkov vsega obsega prevoz med podjetji (angl. *business-to-business*) (Department for Transport, 2009, str. 5).

1.4.1 Mednarodni letalski tovorni promet

Na svetovni ravni se je v zadnjih 40 letih obseg zračnega tovrnega prometa zelo povečal. Slika 4 prikazuje vztrajno rast omenjenega transporta med letoma 1979 in 2008. Kljub svetovni gospodarski krizi, ki se je pojavila leta 2008, je pričakovati, da se bo po krajšem upadu tovrstnega prometa rast dolgoročno nadaljevala (Department for Transport, 2009, str. 5).


Slika 4: Rast zračnega tovarnega prometa med letoma 1979 in 2008.



Vir: Department for Transport, *The air freight end-to-end journey: An analysis of the end-to-end journey of air freight through UK international gateways*, 2009, str. 5.

Zaradi povečanja zračnega potniškega prometa in s tem kapacitet za prevoz blaga, ki jih ponujajo prevozniki na potniških letalih (po relativno nizkih cenah), je bila omogočena dodatna rast/povečanje zračnega prevoza tovora. Poleg tega sta liberalizacija svetovne trgovine in premik v njeni strukturi za manjše in lažje pošiljke razširila nabor/osnovo blaga. Na sliki 5 je prikazano, kako se je med letoma 1954 in 2004 cenil prevoz tovora z letalom.

Slika 5: Gibanje cen prevoza blaga z letali med letoma 1954 in 2004.



Vir: Department for Transport, *The air freight end-to-end journey: An analysis of the end-to-end journey of air freight through UK international gateways*, 2009, str. 6.

Kljub strmemu znižanju cen je tak način transporta še vedno dražji v primerjavi z drugimi (Department for Transport, 2009, str. 6), zato ga večinoma uporabljajo zgolj za posebne kategorije blaga. Denimo za blago z visoko vrednostjo (farmacevtski izdelki, umetniška dela in visokotehnološke naprave), ki je v večini primerov tudi lažje (gledano po teži); cena prevoza tako obsega manjši delež njegove celotne vrednosti. Sorazmeren delež stroškov


prevoza je zelo podoben pri zračnem in pomorskem prevozu, kar je približno pet odstotkov celotne vrednosti pošiljke (Department for Transport, 2009, str. 6). Zračni prevoz blaga je posebej primeren tudi za izdelke, kot so sadje ali ribe, pri čemer je pomembna hitrost dostave.

Prevoz z letalom je lahko posebna prednost tudi pri blagu, ki morda nima visoke denarne vrednosti, a je ključno za omogočanje nekaterih poslovnih procesov ali celo reševanje življenj (npr. nekateri strojni deli, zdravila, organi) (Brodnik, 2013).

1.4.2 Trend zračnega tovarnega prometa


S slik 6 in 7 je razvidno, kako je aktivnost v svetovnem zračnem tovarnem prometu močno povezana z gibanjem svetovne izmenjave. Pri tem je še posebej občutljiva za trende v panogah, ki večinoma uporabljajo zračni promet za transport tovora, kot so polprevodniki (glej sliko 7) in drugi izdelki z visoko dodano vrednostjo (Department for Transport, 2009, str. 7).

Slika 6: Primerjava gibanja prepeljanega tovora z letali in svetovna izmenjava blaga.



Vir: Department for Transport, *The air freight end-to-end journey: An analysis of the end-to-end journey of air freight through UK international gateways*, 2009, str. 7.

Slika 7: Primerjava gibanja prepeljanega tovora z letali in gibanje prepeljanih polprevodnikov z letali.



Vir: Department for Transport, *The air freight end-to-end journey: An analysis of the end-to-end journey of air freight through UK international gateways*, 2009, str. 7.

Na oslajeno rast zračnega tovarnega prometa od leta 2000 so med drugim vplivale motnje zlasti na severnoatlantskih linijah. Od leta 2001 so namreč po terorističnem napadu v New Yorku povečali zmogljivost in pogostost pomorskih transportnih storitev. Zaradi tega je od takrat vidno hitrejša naraščanje cen letalskega goriva v primerjavi z ladijskim (Department for Transport, 2009, str. 7).

1.4.3 Evropski letalski promet med letoma 2008 in 2013

V letu 2013 so malo več kot polovico (55 odstotkov) vseh poletov v evropskem zračnem prometu obsegali redni poleti, kar pomeni tri odstotne točke manj v primerjavi z letom 2008 (EUROCONTROL, 2014 b, str. 5). Nizkocenovni prevozi so obsegali dobro četrtino vseh poletov oz. šest odstotnih točk več v primerjavi z letom 2008. V kategorijah izredni poleti, poslovni in tovorni poleti je od leta 2008 do 2013 delež v vsaki upadel za odstotno točko.

Čeprav redni letalski prevozi zajemajo glavni del letalskega zračnega prometa v Evropi, se je njihov delež v omenjenem obdobju zmanjšal predvsem v korist nizkocenovnih letalskih prevozov. Gospodarska kriza, ki se je začela leta 2008, je tako kot na veliko drugih panog vplivala tudi na letalski promet (EUROCONTROL, 2014 b, str. 6). V zadnjem obdobju je bilo tudi precej politične nestabilnosti, posebej v severni Afriki in na Bližnjem vzhodu, kar je negativno vplivalo na letalstvo v Evropi (EUROCONTROL, 2014 b, str. 6).


V nasprotju z letom 2008 je bilo leta 2013 nekaj vidnejših sprememb v letalskem prometu, in sicer:

- število dnevni sporočil MVT (angl. *movement message*, tj. standardizirana oblika sporočila, poslanega od letala do letališča in drugih prejemnikov, ki vsebuje podatke o vzletu ali pristanku) se je zmanjšalo za šest odstotkov oz. s 27.500 na 25.800;

- število nizkocenovnih poletov se je povečalo za 18 odstotkov ali 1000 MVT dnevno več;
- število rednih poletov se je zmanjšalo za 11 odstotkov oziroma je dnevno 1700 MVT manj;
- v segmentu nerednih prevozov je vsak utrpel vsaj 10-odstotno znižanje, največ pa za 19 odstotkov.

Na slikah 8 in 9 je prikazan promet glede na letalski segment med letoma 2008 in 2013.

Slika 8: Dnevno število poletov po letalskih segmentih med letoma 2008 in 2013.



Vir: EUROCONTROL, Market Segments in European Air Traffic 2013, 2014, str. 6.

Slika 9: Gibanje števila poletov po letalskih segmentih med letoma 2008 in 2013 glede na prejšnje leto.



Vir: EUROCONTROL, Market Segments in European Air Traffic 2013, 2014, str. 6.

V opazovanem obdobju je bilo leto 2009 za evropski letalski promet najslabše, saj je ustavilo rast med letoma 2003 do 2008. V zadnjem obdobju je rast v povprečju znašala 3,6 odstotka. Kljub izbruhu vulkana na Islandiji aprila 2010, zaradi česar je bil večji del letalskega prometa ohromljen za več dni, je bilo v letih 2010 in 2011 zaznati rast v letalskem prometu. V letih 2012 in 2013 pa so znova zaznali upad, kar lahko pomeni, da so se posledice krize iz leta 2009 kazale tudi v minulih letih (EUROCONTROL, 2014 b, str. 6).

V nasprotju s skupnim številom poletov v opazovanem obdobju je bilo gibanje poletov v posameznih segmentih drugačno:

- z izjemo leta 2011 se je število rednih poletov iz leta v leto zniževalo;
- z izjemo leta 2011 se je vseh letih opazovanega obdobja število nizkocenovnih poletov povečevalo;
- poslovni in tovorni poleti, kategoriji, ki sta tradicionalno najbolj občutljivi za ekonomske spremembe, sta zaznali rast v letih 2010 in 2011 in upad v naslednjih dveh letih, z nekaj spremembami v povečanju leta 2013;
- pri izrednih poletih so od leta 2010 do 2013, z izjemo leta 2012, zaznali upad.

1.4.4 Evropski letalski promet v prihodnosti

Po nekaterih napovedih (EUROCONTROL, 2014 a, str. 39) je pričakovati, da bo leta 2020 v Evropi opravljenih približno 11,2 milijona letalskih poletov oz. 19 odstotkov več kot leta 2013. Za leto 2014 so v primerjavi z letom 2013 napovedali približno 1,2-odstotno povečanje, saj gospodarska rast (v Evropi) ostaja skromna in so evropski letalski prevozniki še vedno previdni pri dodajanju kapacitet v svojo prevozniško mrežo (EUROCONTROL, 2014 a, str. 39). Pričakujejo, da se bo letalski promet od leta 2015 povečal za približno 2,7 odstotka na letni ravni. Dosedanji rekord z 10,1 milijona poletov iz leta 2008 naj bi dosegli leta 2016. V tabeli 1 so prikazane predvidene spremembe v številu poletov na ozemlju Evrope.

Tabela 1: Predvidene spremembe v številu poletov.

ESRA08		2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020
IFR Sporočila o letalskih premikih (v tisočih)	V	-	-	-	-	9 669	10 015	10 442	10 826	11 208	11 618	12 072
	B	9 493	9 784	9 548	9 447	9 557	9 812	10 095	10 339	10 570	10 867	11 200
	N	-	-	-	-	9 438	9 582	9 682	9 780	9 891	10 030	10 179
Letna rast (glede na prejšnje leto)	V	-	-	-	-	2,3%	3,6%	4,3%	3,7%	3,5%	3,7%	3,9%
	B	0,8%	3,1%	-2,4%	-1,1%	1,2%	2,7%	2,9%	2,4%	2,2%	2,8%	3,1%
	N	-	-	-	-	-0,1%	1,5%	1,0%	1,0%	1,1%	1,4%	1,5%

Napovedi V - visoko B - bazno N - nizko

Vir: EUROCONTROL, EUROCONTROL Seven-Year Forecast February 2014, 2014, str. 39.

Pričakovati je, da bo rast približno 2,7 odstotka letno med letoma 2015 in 2017 ta nekoliko upadla v letu 2018, predvsem zaradi pomanjkanja zmogljivosti v evropskem letalskem omrežju oz. omejenih zmogljivostih evropskih letališč (EUROCONTROL, 2014 a, str. 42). Po predvideni gradnji novega letališča v Istanbulu leta 2019 se zaradi rahlega povečanja zmogljivosti letalskega omrežja pričakuje, da bo rast v letih 2019 in 2020 približno 2,8 odstotka na leto.

1.4.5 Zamude in preusmeritve poletov

Letno se z letali prevozi na milijone potnikov in tone tovora (Kara, Ferguson, Hoffman & Sherry, 2013). Zaradi zamud poletov naj bi tako samo v letu 2007 gospodarstvo ZDA izgubilo približno 31,2 milijarde ameriških dolarjev (Schumer, 2008).

Na spletni strani <http://www.transtats.bts.gov/> smo pridobili podatke o tem, koliko poletov okvirno je v ZDA priletelo z zamudo, bilo preusmerjenih ali odpovedanih. Natančnejših podatkov o številu preusmeritev na območju Evrope nam ni uspelo najti.

V tabeli 2 so podatki o poletih v ZDA, zajetih med junijem 2003 in avgustom 2014. Poleg števila letal, ki so pristala na predvidenem letališču pravočasno, je prikazano tudi število poletov z zamudo, odpovedjo ali preusmeritvijo na drugo letališče. Kot polet z zamudo je obravnavan tisti, ki se konča vsaj 15 minut pozneje, kot je predvideno (RITA, Bureau of Transportation Statistics, 2014). Pri podatku o številu (zapoznelih) minut so upoštevane le tiste pri poletih z zamudo. Zanj pa je lahko več vzrokov: okoliščine pri letalskem prevozniku (npr. vzdrževanje, čiščenje letala, težave z osebjem, nakladanje prtljage itd.), vreme (dejansko stanje ali napovedi), nacionalni sistem za letalstvo (obratovanje letališča, velik obseg prometa itd.), letalo, ki je prispelo z zamudo in tako povzročilo, da je tudi drugo letalo vzletelo z zamudo, kaj v zvezi z varnostjo (RITA, Bureau of Transportation Statistics, 2014).

Tabela 2: Pravočasni, zamujeni, odpovedani in preusmerjeni poleti med letoma 2003 in 2014.

Obdobje med junijem 2003 in avgustom 2014

	Število operacij	% vseh operacij	Zamujene minute	% od vseh zamujenih minut
Pravočasno	58 418 859	77,82%	N/A	N/A
Zamuda letalskega prevoznika	4 215 904	5,62%	236 789 852	28,62%
Zamuda zaradi vremena	562 364	0,75%	43 291 115	5,23%
Zamuda zaradi nacionalnega letalskega sistema	5 199 714	6,93%	233 746 983	28,26%
Zamuda zaradi varnosti	37 844	0,05%	1 400 931	0,17%
Zamuda letala	5 129 639	6,83%	311 997 681	37,72%
Odpovedani	1 332 038	1,77%	N/A	N/A
Preusmerjeni	168 422	0,22%	N/A	N/A
Skupno operacij	75 064 770	100,00%	827 226 562	100,00%

Vir: RITA, Bureau of Transportation Statistics, Airline On-Time Statistics and Delay Causes, 2014.

Tabela 3 prikazuje podrobnejše deleže oz. število letal, prispelih ob predvidenem času, z zamudo, preusmerjenih ali odpovedanih na letni ravni med letoma 2005 in 2014 (2014 do meseca avgusta).

Tabela 3: Pravočasni, zamujeni, odpovedani in preusmerjeni poleti na letni ravni med letoma 2005 in 2014.

leto	št. pravočasnih	pravočasnih (%)	št. z zamudo	z zamudo (%)	št. odpovedanih	odpovedanih (%)	št. preusmerjenih	skupno
2005	3 711 017	76,75%	1 018 293	21,06%	95 386	1,97%	10 453	4 835 149
2006	3 619 673	76,13%	1 050 452	22,09%	72 933	1,53%	11 254	4 754 312
2007	3 609 556	72,14%	1 262 229	25,23%	119 142	2,38%	12 821	5 003 748
2008	3 600 462	74,32%	1 129 500	23,32%	102 035	2,11%	12 388	4 844 385
2009	3 443 636	78,82%	850 217	19,46%	63 708	1,46%	11 264	4 368 825
2010	3 420 122	79,20%	806 854	18,69%	79 779	1,85%	11 355	4 318 110
2011	3 180 246	77,16%	829 249	20,12%	101 149	2,45%	10 844	4 121 488
2012	3 371 820	82,06%	680 977	16,57%	47 210	1,15%	9 078	4 109 085
2013	3 335 959	77,52%	888 495	20,65%	68 508	1,59%	10 335	4 303 297
2014	2 932 949	74,82%	872 245	22,25%	103 966	2,65%	10 914	3 920 074

Vir: RITA, Bureau of Transportation Statistics, On-Time Performance – Flight Delays at a Glance, 2014.

2 DETEKCIJA PREUSMERJENEGA POLETA

Povečevanje medcelinske trgovine/izmenjave blaga je vodilo tudi do opaznega povečanja večmodalnega (angl. *multi-modal*) transporta tovara. Ta zajema vsaj dva različna načina pri transportu tovara od izvora do cilja, ki morata biti usklajena (Van der Aa, Cabanillas, Di Ciccio, Mendling & Prescher, 2014, str. 1). Primer takšnega načina je, ko npr. prvi del poti

tovor prepeljemo z letalom, na letališču pa se ga natovori na tovornjak, ki ga nato prepelje do končnega cilja. Ali ko prvi del poti prepeljemo z ladjo, drugi pa s tovornjakom.

Težava, ki obstaja pri večmodalnem transportu, pa je njegova učinkovitost. Navadno za vsakega od načinov v tem transportu skrbi več različnih podjetij, ki pa si ne izmenjujejo informacij o stanju svojih vozil v realnem času (Van der Aa et al., 2014, str. 1). Takšne razmere otežujejo prilagajanje transportnih načrtov ob nepričakovanih dogodkih (Van der Aa et al., 2014, str. 1). S problemom učinkovitosti pri tem transportu se srečujemo še posebej pri t. i. proizvodnji *just-in-time*, kjer je kritična točnost/pravočasnost dobave. Pa tudi pri okoljevarstvu, saj ne želimo po nepotrebnem onesnaževati okolja (Van der Aa et al., 2014, str. 1). Če bi za celotno transportno verigo skrbel en upravitelj, bi bilo takšnih težav najverjetneje manj. V takšnih primerih bi bilo pravočasno zaznavanje preusmeritev ključnega pomena.

2.1 Trajektorija poleta

Da bi lahko zaznali preusmeritev letala, bi morali nepravilnosti ugotoviti že čez leto. Za to pa bi morali upoštevati različne dejavnike, ki bi jih pridobili iz trajektorije poleta. To je krivulja, ki jo opiše telo pri gibanju. V našem primeru bi lahko dejali, da letalo med poletom ustvari lastno trajektorijo.

Do danes je bilo že veliko dela vloženega v razvoj pristopov za računanje primernih trajektorij (tj. pot od izvora do kraja) poletov, pri čemer se upoštevajo številni dejavniki. V takšnem primeru bi upoštevali statične informacije poleta, kot so (Besada, Frontera, Crespo, Casado & Lopez-Leones, 2013):

- načrt poleta, kar vključuje začetno in končno geografsko točko, ter t. i. namen poleta (angl. *flight intent*), k čemur lahko štejemo pričakovano vedenje letala ali vmesne zahteve, kot je ustrezna višina letala v določenem časovnem obdobju;
- omejitve poleta, ki opisujejo napredne zahteve, npr. časovna omejitev;
- potencialna merila za optimizacijo v povezavi s cilji letalske družbe, kot je varčevanje z gorivom ali časom.

Pri nekaterih pristopih za ustvarjanje trajektorij so upoštevane tudi vremenske razmere. V nekaterih primerih (Pfeil & Balakrishnan, 2012) so se osredotočili zgolj na terminale zračnih prostorov (tj. območje v bližini letališča). V drugih študijah (Nilim, Ghaoui, Duong & Hansen, 2001; Pannequin, Bayen, Mitchell, Chung & Sastry, 2007; Kamgarpour, Dadok & Tomlin, 2010) pa so upoštevali tudi preletna območja poleta, ker se je izkazalo (Evans & Robinson, 2005), da nevihte blizu poti letala ali terminalnih zračnih prostorov povzročijo veliko večje zamude.

Druge dinamične informacije o poletu, ki bi jih bilo treba upoštevati, so še:

- dinamične omejitve poleta (angl. *aero dynamic constraints*), kot so hitrost, pospešek oz. obremenitev G);

- terminalske omejitve, kot sta smer, v kateri je končna pozicija (letališče oz. pristajalna steza), in trenutna usmerjenost letala;
- okoljske omejitve, npr. teren.

2.2 Sledenje letala

Za zaznavanje težav letala med poletom, ki lahko vodijo v preusmeritev, je natančno sledenje ključnega pomena (Van der Aa et al., 2014, str. 2). To pa je mogoče izvajati različno (Liao, Wang & Yang., 2002; Cabanillas, Di Ciccio, Mendling & Baumgrass, 2014). Ena od možnosti je, da bi zaznavanje letala s pomočjo radarja nadomestili z drugim sistemom, denimo s pasivnimi oddajniki, ki ne ustvarjajo elektromagnetnega valovanja in s tem ne obremenjujejo (angl. *clutter*) okolja z dodatnimi signali (Korona & Kokar, 1998). Ravno pri nadzoru poletov je prenasíčenost signalov eden od problemov, posebej v bližini letališč, kjer se število aktivnih letal opazno poveča (Hwang, Balakrishnan, Roy & Tomlin, 2004).

Z dodatnimi težavami bi se spopadali tudi, ko bi želeli grafično prikazati sledenje letal v bližini letališč (Van der Aa et al., 2014, str. 2).

2.3 Obstoječa raziskovalna dela

Raziskav z enakim namenom, pri katerih bi poskušali enako ali podobno kot mi zaznavati preusmeritev poletov, ni veliko. So se pa pri nekaterih ukvarjali s podatki o poletih, vendar je bil njihov namen drugačen. Obstajajo tudi raziskave, pri katerih so uporabljali podoben pristop k reševanju problemov kot mi (trajektorije) in imeli predvsem bolj celostne podatke (Van der Aa et al., 2014, str. 3). Vsekakor velja, da sta točnost in veljavnost pristopa močno odvisni od popolnosti podatkov.

Raziskave s podobnim kontekstom – zaznavanje nepravilnosti na podlagi trajektorij – se dotikajo teme videonadzora (Owens & Hunter, 2000; Piciarelli, Micheloni & Foresti, 2008; Zhou, Yan & Huang, 2007), nekatere pa trajektorij v cestnem prometu (Chen et al., 2011; Zhang et al., 2011; Pang, Chawla, Liu & Zheng, 2013; Barria & Thajchayapong, 2011; Kong, Zhao, Wei & Liu, 2012; Dunne & Ghosh, 2013). Njihova skupna značilnost je, da so usmerjene na zemljepisno bolj omejeno območje (npr. območje, nadzorovano z eno samo kamero, ali eno mesto) (Van der Aa et al., 2014, str. 3). To jim omogoča, da se ciljno območje razdeli na mrežo celic, tako da se trajektorija lahko izrazi kot urejeno zaporedje prevoženih celic. S tem se kompleksnost problema zmanjša, medtem ko se v našem primeru osredotočamo na zračno območje nad ozemljem Evrope. Tak pristop bi bil tako lahko primeren tudi za druge dele sveta, ne samo za Evropo.

V eni od raziskav so se osredotočili na odkrivanje vzrokov preusmeritve na podlagi načrta poleta (Krozel, 2002). Skupaj z zadnjim primerom in še enim (Reynolds & Hansman, 2002) so uporabljali načrtovano/predvideno vedenje poletov, s čimer so lahko primerjali aktualno/realno trajektorijo. V obeh primerih se je pokazalo, da je bil glavni vzrok za preusmeritev, vreme (Van der Aa et al., 2014, str. 3).

Gariel, Srivastava & Feron (2011) so predstavili orodje AirTrajectoryMiner, namenjeno spremljanju (v realnem času) stanja zračnega prostora. V tem primeru so celoten načrt ustvarili oni, in sicer z združevanjem (angl. *clustering*) podobnih trajektorij poletov. Podobno kot mi ne primerjajo vnaprej predvidenih trajektorij poletov, ampak le končni cilj (letališče) poletov.

Z raziskavami so se lotili tudi odpravljanja drugačnih problemov. Eden takšnih je preprečevanje trčenj med letali ali odkrivanje posebnih vrst odstopanj. Šišlák, Volf & Pechoucek (2011) so se ukvarjali z reševanjem tega, kako zaznati konflikt med trajektorijama/potema dveh letal. Timar, Griffin, Borener & Knickerbocker (2012) so ocenjevali razmere za pojav in vplive ob obračanju letala. Takšni vzorci se pogosto pojavljajo v preobremenjenih zračnih prostorih, kadar mora letalo opraviti tak manevar, da odloži čas pristanka.

V našem primeru bi bilo zbiranje podatkov o vseh možnih letalskih poteh manj smiselno. Za primer lahko navedemo, da ima spletna stran www.flightradar24.com, ki ponuja aktualen vpogled v polete nad evropskim ozemljem, v svoji podatkovni bazi že več kot 100.000 različnih letalskih poti (Van der Aa et al., 2014, str. 3). Pri tem je treba poudariti, da to število poti ni končno. Eden od vzrokov, zakaj ne zbirati vseh možnih poti, je, da bi bila primerjava vsakega poleta z bazo podatkov vseh obstoječih poletov časovno potratna. Drugi pa, da sledi niso enake, zato primerjava z znanimi sledmi ne bi bila primerna. Zaradi tega želimo uporabiti čim bolj splošen pristop. Primer takšne rešitve bi bil program, ki bi uspešno zaznaval preusmerjene polete v evropskem zračnem prostoru ne glede na vreme, zračni prostor ipd.

Med bolj relevantnimi podatki v naši raziskavi bodo tako identifikacijska/unikatna številka poleta, letališče, s katerega letalo vzleta, in letališče, na katero je namenjeno. Z našim pristopom bi tako za določeno zemljepisno območje (npr. Evropo) potrebovali bistveno manj podatkov kot s pristopi, ki zahtevajo vse mogoče trajektorije, s katerimi nato primerjajo sled poleta, ki ga spremljajo.

2.4 Projekt GET Service

S projektom GET Service želijo izboljšati vzajemno delovanje informacijskega sistema, ki ga trenutno uporabljajo transportne službe. Dosedanji sistemi, ki večinoma delujejo le znotraj ene logistične službe, omogočajo da se prek računalnikov razporeja dela različnim voznikom. Tem naprave v tovornjakih prikazujejo naloge, poleg tega pa nekatere naprave omogočajo tudi pregled zastojev na cestah. V zadnjem času potekajo tudi testiranja, kjer naprave iz vozil posredujejo podatke druga drugi ali transportni infrastrukturi o npr. prometnih nesrečah ali delih na cestah (GET Service Project, 2014b). V okviru projekta GET Service pa želijo, da bi trenutni transportni sistem in sistem za načrtovanje poti pridobivala podatke iz različnih virov.

Štiri glavne funkcionalnosti projekta so (GET Service Project, 2014b):

- zbiranje aktualnih podatkov iz več virov, kar bi omogočilo izboljšanje algoritmov za načrtovanje. Bili bi natančnejši, kajti ti, ki so v uporabi zdaj, temeljijo na zgodovinskih podatkih ali ocenah potovalnih časov in izpustov CO₂ na izbranih poteh. Z zbranimi podatki iz več različnih virov pa bi bili izračuni predvidenih potovalnih časov in izpustov CO₂ natančnejši, ker bi se pri tem upoštevali teža tovora, moč motorja in aerodinamičnost vozila, ki bo tovor prevažalo, vremenske razmere in nekateri drugi dejavniki. S pomočjo vseh informacij bi z novim sistemom delali tudi t. i. napovedno načrtovanje, kar bi pomenilo, da bi bilo mogoče predvideti, ali bo npr. zastoj na poti že odpravljen, ko bo tovorno vozilo prišlo do tja.
- ponovno planiranje v realnem času. V praksi bi to pomenilo, da bi po pregledu vseh razpoložljivih sredstev za prevoz blaga, optimalnih poti glede na razmere in drugih dejavnikov izbrali čim boljšo možnost. Pri tem bi bilo možno tudi združevanje posameznih pošilk. Omogočeno bi bilo tudi opozarjanje ustvarjalca transportnih načrtov, če bi sistem odkril boljšo razporeditev nalogov ali sredstev. Sistem bi ugotavljal, ali je smotrneje pripraviti optimalnejši transportni načrt s prerazporeditvijo pošilk na nalogih prevoznikov.
- zmanjšanje števila prevoženih praznih kilometrov. Čeprav se ta termin uporablja za tovornjake, se pri projektu GET Service nanaša tudi na druga transportna sredstva. V Evropi je več kot 20 odstotkov kilometrov, prevoženih s tovornjaki, praznih (brez blaga). To pomeni, da se po nepotrebnem dodatno onesnažuje okolje in obremenjuje transportno infrastrukturo. Do tega pogosto prihaja zaradi premajhne obveščenosti, saj prevozne službe nimajo informacij o tem, da je v bližini, kjer bo njihov tovornjak oddal blago, blago za prevoz v smeri, kamor je ta namenjen. Tako se tovornjak vrača prazen. V sklopu projekta GET Service se tako želi zbirati in imeti vpogled v informacije večjega števila organizacij ter s tem zmanjšati število praznih kilometrov.
- uporaba različnih transportnih sredstev s ciljem doseči optimalno in trajnostno izkoriščenost sredstev. Pri tem se je treba zavedati, da bi si morala podjetja deliti informacije (znotraj projekta GET Service), ki pa so lahko občutljive narave ali strateškega pomena.

Z uspešnostjo projekta se pričakuje, da se bo število prevoženih praznih kilometrov zmanjšalo, kar danes velja kot potencialna rešitev pri zmanjšanju izpustov CO₂. Poleg tega bi bilo dobro, da bi evropski transportni sistem postal učinkovitejši, tako da bi uporabljali bolj optimizirane algoritme za načrtovanje transportnih poti. Marže v tem sektorju so zelo nizke, zato bi imele izboljšave v učinkovitosti močan vpliv na konkurenčnost prometne industrije kot celote. Želijo pa ustvariti tudi poslovne modele za to, kako bi rešitev GET Service lahko ponudili drugim kot produkt za npr. do okolja prijaznejše načrtovanje transporta (GET Service Project, 2014a).

Ublažitev negativnih učinkov lahko ponazorimo z naslednjim primerom: Tovornjak logističnega podjetja pričakuje letalo za prevzem blaga na letališču A. Ko bi prevzel tovor, bi ga dostavil do končne točke C. Vendar zaradi obilnega sneženja letalo, ki je bilo sprva

namenjeno na letališče A, iz kontrolnega stolpa ne dobi dovoljenja za pristanek. Zaradi tega je prisiljeno pristati na letališču B, kjer so vremenske razmere ugodnejše in prejme dovoljenje za pristanek.

Logistično podjetje, katerega tovornjak čaka na letališču A, je imelo rezerviran termin za prevzem blaga na letališču A, a zdaj mora poskrbeti za termin prevzema na letališču B. Poleg tega pa morajo, ker pa sta letališči A in B preveč oddaljeni ali pa nimajo razpoložljivih sredstev, najeti podizvajalca, ki bo poskrbel za prevzem tovora in dostavo na lokacijo C. Zdaj to urejanje večinoma poteka po telefonu in celoten proces lahko traja tudi do šest ur, kar povzroči zamude. Zaradi rešitve GET pa bi lahko podjetje hitreje našlo primernega prevoznika za prevzem in dostavo. Tako bi stranke in kupci pogosteje prejeli tovor pravočasno. Logistično podjetje bi s tem ponujalo višjo raven storitve, si zmanjšalo morebitne kazni in izboljšalo izrabo lastnih sredstev/resursov. Poleg tega bi imeli dodatne koristi tudi zunanji izvajalci, prijavljeni v bazo zunanjih izvajalcev logističnega podjetja. Vse to pa bi bilo tudi v dobro okolja, saj bi bilo prevoženih manj praznih kilometrov, boljše uporabljene kapacitete in manj izpustov emisij CO₂.

Da bi v takšnem primeru vse potekalo po načrtih in bi storitev GET delovala, bi moral GET obvestiti načrtovalca transporta/logističnega podjetja o preusmeritvi letala na letališče B. Takoj ko bi se začel proces ponovnega načrtovanja, bi GET poskusil najti tovornjak, primeren za prevzem tovora na letališču B; poskrbel bi tudi za rezervacijo novega tovornjaka. Po rezervaciji so načrtovalci in na novo najeti voznik tovornjaka o tem obveščeni.

S pomočjo sledenja tovora bi GET obveščal ključne udeležence v procesu o trenutnem položaju in predvidenem času dostave na cilj; pripravil bi tudi primerne dokumente.

Predvidimo, da v opisanem primeru letališče A predstavlja letališče v Amsterdamu (Nizozemska), B letališče v Bruslju (Belgija) ter končni cilj C skladišče v mestu Utrecht (Nizozemska). V takšnem primeru bi brez podpore GET logistično podjetje npr. poslalo čakajoči tovornjak z letališča v Amsterdamu na letališče v Bruselj, kjer bi prevzel tovor in ga dostavil v Utrecht. V primeru 40 ton težkega tovornjaka z 20-tonskim tovorom bi to pomenilo približno 250,4 kg izpustov CO₂, prevoženo razdaljo 365,7 km in približno 5,5 ure. Ob ustrezni uporabi GET pa bi lahko pričakovali, da bi tovornjak iz Bruslja v Utrecht pripeljal v približno 2,5 ure oz. prevozil 164 km in v zrak izpustil približno 124,9 kg CO₂. Kolikšna bi bila razlika v ceni, je težje oceniti, saj je odvisna od višine stroškov zunanjega izvajalca.

2.5 Metoda podpornih vektorjev

V okviru našega raziskovalnega dela smo se odločili, da bomo za predvidevanje preusmerjenih poletov uporabili algoritem strojnega učenja metode podpornih vektorjev (angl. *Support Vector Machine* ali SVM). V tem podpoglavju bomo zapisali več o tem, kaj je metoda podpornih vektorjev in kako deluje.

2.5.1 Strojno učenje

Ena od vej raziskav umetne inteligence je strojno učenje, ki se v zadnjem času vedno bolj uporablja na številnih področjih, kot so industrija, medicina, ekonomija, ekologija (Kononenko & Šikonja, 2010, str. 1). Uporablja se za analizo podatkov in odkrivanje zakonitosti v podatkovnih bazah, za avtomatsko generiranje baz znanja za ekspertne sisteme, za učenje načrtovanja, gradnjo numeričnih in kvalitativnih modelov, klasifikacijo besedil itd.

Temeljni princip strojnega učenja je avtomatsko opisovanje pojavov iz podatkov (Kononenko & Šikonja, 2010, str. 1). Rezultati, pridobljeni iz učenja, so relacije, funkcije, pravila, verjetnostne porazdelitve ipd. Predstavljeni so z različnimi formalizmi, kot so odločitvena pravila, nevronske mreže, odločitvena drevesa, regresijska drevesa itd. Modeli, ki so bili naučeni, poskušajo razlagati podatke, iz katerih so bili ustvarjeni. Te modele pa se nato lahko uporablja za odločanje pri opazovanju modeliranega procesa v prihodnosti (napovedovanje, diagnosticiranje, simulacije, preverjanje, nadzor itd.).

Poznamo različne metode strojnega učenja, ki jih delimo glede na način uporabe naučenega znanja, in sicer: kvalifikacije (uvrščanje), učenje asociacij in logičnih relacij, razvrščanje, regresija in učenje sistemov enačb (Kononenko & Šikonja, 2010, str. 2). Mi bomo opisali le metodo za klasifikacijo, saj metoda podpornih vektorjev spadajo pod njo.

2.5.2 Klasifikacija (uvrščanje)

Klasifikacija ali uvrščanje (angl. *classification*) je ena najpogostejših uporab strojnega učenja. Naloga klasifikatorja je za objekt (problem), opisan z množico atributov (značilk, lastnosti), določiti, kateremu izmed možnih razredov pripada (Kononenko & Šikonja, 2010, str. 2). Uporabljeni atributi so neodvisne diskretne ali zvezne spremenljivke, ki se uporabijo za opisovanje objektov. Razred pa je odvisna diskretna spremenljivka, ki ji je določena vrednost glede na vrednosti neodvisnih spremenljivk (Kononenko & Šikonja, 2010, str. 2).

Primer klasifikacijskega problema je postavljanje medicinske diagnoze. Pacient je opisan z zveznimi atributi, kot so spol, lokacija bolečine itd. Klasifikatorjeva naloga je, da postavi diagnozo, kar pomeni tudi, določiti enega od možnih razredov, npr. da je pacient zdrav, ima angino, pljučnico, je prehlajen itd.

Klasifikator mora imeti predstavljeno diskretno funkcijo, ki preslika prostor atributov v razred in ga nato lahko določi (Kononenko & Šikonja, 2010, str. 2). Funkcija je lahko naučena iz podatkov (primerov rešenih problemov v preteklosti) ali pa podana vnaprej. Pri medicinski diagnozi bi bila funkcija lahko sestavljena/naučena iz opisov pacientov z njihovimi diagnozami, zaradi katerih so se zdravili zadnjih nekaj let. Naloga učnega algoritma bi bila iz množice opisov pacientov z znanimi diagnozami zgraditi pravilo (izračuna funkcijo), ki bi ga nato lahko uporabili za diagnosticiranje novih pacientov (Kononenko & Šikonja, 2010, str. 2).

Klasifikatorje ločimo po načinu predstavitve klasifikatorjeve funkcije (Kononenko & Šikonja, 2010, str. 2). Med najpogostejše spadajo odločitvena pravila, odločitve drevesa, klasifikator z

najbližjimi sosedi, logistična regresija, naivni Bayesov klasifikator, Bayesove verjetnostne mreže, usmerjene (večnivojske) umetne nevronske mreže ter klasifikator po metodi podpornih vektorjev.


2.5.3 Metoda podpornih vektorjev

Metoda podpornih vektorjev ali SVM je računalniški algoritem (algoritem za strojno učenje), ki se uči na podanih primerih, da prihodnje primere kvalificira (Noble, 2006, str. 1565). SVM je bil razvit v devetdesetih letih 20. stoletja in velja za uspešno metodo za klasifikacijo in regresijo (Kononenko & Šikonja, 2010, str. 175). V nasprotju z algoritmi strojnega učenja, ki težijo k minimalnemu številu atributov, da lahko poiščejo ustrezno podmnožico pomembnih atributov, nad katerimi nato zgradijo model, metode SVM uporabijo vse razpoložljive attribute. Vključijo tudi manj pomembne in jih nato z linearno kombinacijo uporabijo za napovedovanje odvisne spremenljivke (Kononenko & Šikonja, 2010, str. 175).

SVM je primeren za učenje na velikih množicah primerov, ki so opisani z velikim številom (manj) pomembnih atributov. Ključno je predvsem, kako bomo povezovali attribute, zaradi česar je njihova izbira manj pomembna, ker SVM z ustrezno kombinacijo izlušči želeno informacijo (Kononenko & Šikonja, 2010, str. 175). Čeprav metode dosegajo izjemno točnost napovedi, je njihova slaba stran, da je interpretacija naučenega težavna, prav tako razlaga posamezne odločitve (Kononenko & Šikonja, 2010, str. 175). Kadar se SVM uporabi za klasifikacije, je namenjen razločevanju dveh razredov. Pri več razredih je treba postopek ponoviti za vsakega, ki ga poskušamo ločiti od drugih (Kononenko & Šikonja, 2010, str. 175). Pri klasifikaciji nov primer klasificiramo v razred z najvišjo vrednostjo odločitvene funkcije (Kononenko & Šikonja, 2010, str. 175).

Osnovna ideja pri SVM je, da se v danem prostoru (originalnih ali transformiranih) atributov postavi optimalno hiperravnino (Kononenko & Šikonja, 2010, str. 175). Če so primeri linearno ločljivi, je možnih več hiperravnin, ki ločujejo razrede med seboj. Primer dveh hiperravnin lahko vidimo na sliki 10. Na njej so te hiperravnine premice, ki jasno ločujejo primere iz prvega razreda (označene s +) od primerov iz drugega razreda (označenih z o).

Slika 10: Primer dveh razredov, ločenih s hiperravninami.



Vir: I. Kononenko & M. Šikonja, *Inteligentni sistemi*, 2010, str. 176.

Kadar je hiperravnina optimalna, je enako in najbolj oddaljena od najbližjih primerov iz obeh razredov. Najbližjim primerom optimalne hiperravnine pravimo *podporni vektorji*, razdalji hiperravnine od podpornih vektorjev pa *rob* (angl. *margin*) (Kononenko & Šikonja, 2010, str. 175).

Pri metodi podpornih vektorjev je bistveno, da se poleg nje uporabi implicitne transformacije atributnega prostora v kompleksnejši atributni prostor. Pogosto se zgodi, da linearna hiperravnina v originalnem prostoru ne zadošča za sprejemljivo klasifikacijsko točnost. Če pa uporabimo nelinearno transformacijo, lahko prostor postane primeren za linearno hiperravnino. S tem ko uporabnik vnaprej izbere transformacijo, lahko z različnimi transformacijami rešujemo različne nelinearne probleme (Kononenko & Šikonja, 2010, str. 178).

Resnična moč metod SVM je v tem, da transformacij ni treba narediti eksplicitno kot pri drugih metodah strojnega učenja. Kadar se transformacijo naredi eksplicitno, dobimo veliko atributov (npr. pri produktih osnovnih atributov število atributov naraste polinomske, pri čemer je stopnja polinoma odvisna od dolžine produktov). Če pa je število atributov preveliko, kar je lahko težava, temu pravimo tudi prekletstvo dimenzionalnosti (angl. *curse of dimensionality*).

V nasprotju z drugimi metodami strojnega učenja je pri metodi podpornih vektorjev dovolj, da izračunamo skalarne produkte podpornih vektorjev z novim (testnim) primerom v transformiranem atributnem prostoru (Kononenko & Šikonja, 2010, str. 178).

2.5.4 Primeri uporabe

V praksi lahko metodo podpornih vektorjev uporabimo v številnih primerih. SVM bi lahko naučili, da bi prepoznal goljufanje pri uporabi kreditnih kartic, tako da bi mu pred tem predstavili npr. več sto tisoč primerov zlorabe. Ali pa bi ga naučili, da bi prepoznal ročno

napisane številke, tako da bi prej preučil veliko zbirko skeniranih slik ročno napisanih številk (ničel, enic, dvojek, trojk itd.).

Ne gre spregledati, da so SVM v številnih primerih uporabili na biološkem področju. Pogosta uporaba je samodejna klasifikacija profilov mikromrežno izraženih genov (angl. *classification of microarray gene expression profiles*). Teoretično lahko SVM preučí profil gena, izvirajočega iz vzorca tumorja ali periferne tekočine, in tako pomaga pri postavitvi diagnoze ali prognoze.

2.6 Primer predhodno opravljene študije za zaznavanje preusmerjenih poletov

V tem poglavju bomo predstavili študijo, ki je bila opravljena malo pred začetkom našega raziskovalnega dela. Njihovo raziskovalno delo je temeljilo na zaznavanju preusmeritve poletov s pomočjo SVM. Za namene raziskave so uporabili podatke, ki temeljijo na ameriških poletih.

2.6.1 Podatki

Na spletu lahko najdemo več ponudnikov, ki uporabnikom omogočajo vpogled v aktualno dogajanje v ozračju, denimo Flightstats, FlightRadar24 in FlightAware. Podatki so (delno) javno dostopni, pri čemer se je treba v nekaterih primerih registrirati (registracija je brezplačna). Za podaljšanje članstva je v nekaterih primerih potrebno doplačilo. Podatki, ki jih med drugim lahko dobimo, so informacije o položaju letala, in sicer:

- zemljepisna dolžina
- zemljepisna širina
- višina
- čas
- hitrost

Za zaznavanje letal skrbijo naprave z omejenim dosegom na površju Zemlje, in sicer sprejemajo podatke o njihovem položaju. Ker pa so zelo drage, niso enakomerno razporejene. Tako je mogoče, da letalo v določenem delu poleta ni v dosegu katere od naprav, s tem pa je podatek o položaju poleta izgubljen. To je pogosto, kadar je letalo nad večjim vodnim telesom (npr. oceanom). K nepopolnim podatkom o položajih letal pripomorejo tudi frekvenca oddajnika, vremenske razmere in okvare sprejemnika. Tako lahko dobimo sled s podatki o položaju v neenakomernih razmikih.

Pristop, ki so ga uporabili v tej raziskavi, takšne nepravilnosti popravi glede na čas med znanimi položaji letala (Van der Aa et al., 2014, str. 5).

2.6.2 Pridobivanje podatkov

Da so izpeljali pet ključnih podatkov, ki opisujejo vedenje letala skozi določeno časovno obdobje, so uporabili javno dostopne in znane položaje s spletne strani www.flightstats.com. Poleg tega so iz drugih virov pridobili še lokacijo letališča, s katerega je letalo vzletelo, in letališča, na katero je namenjeno. Pet ključnih podatkov za zaznavanje nepravilnosti v poletu oz. zaznavanje preusmeritve v tej študiji je:


- opravljena razdalja, ki jo je letalo opravilo do danega (opazovanega) trenutka. Pri tem celotna predvidena razdalja predstavlja razdaljo med letališčem, s katerega je letalo vzletelo, do letališča, na katero je namenjeno;
- razdalja, ki jo je letalo opravilo v opazovanem časovnem intervalu;
- povprečna hitrost v opazovanem časovnem intervalu;
- povprečna sprememba višine v opazovanem časovnem intervalu;
- odstopanje v smeri: odklon od povprečne usmeritve letala v primerjavi z usmeritvijo letala v prejšnjem intervalu, pri čemer usmeritev predstavlja pravo pot med dvema točkama.

2.6.3 Vzorci preusmeritve

S spremljanjem teh podatkov bi lahko zaznali nepravilnosti v predvidenem poletu. V raziskavi omenjajo, da je med naštetimi pomemben predvsem podatek o opravljeni razdalji, saj ta determinira fazo poleta, denimo vzletanje, sredina poleta ali pristajanje. To je pomembno predvsem zaradi tega, ker trajektorija prikazuje različno vedenje glede na fazo poleta.

Na sliki 11 modra črta prikazuje odstopanje v hitrosti pri pravilnem poletu (oz. kadar je polet opravljen, kot je bilo predvideno), zelena črta pa odstopanje v hitrosti pri preusmerjenem poletu. Abscisna os predstavlja opravljeno razdaljo letala, pri čemer je končna razdalja enaka razdalji med letališčem vzleta in letališčem pristanka v primeru pravilnega poleta.

Slika 11: Spremembe hitrosti pri normalnem in preusmerjenem poletu.



Vir: Van der Aa et al., *Detecting Flight Trajectory Anomalies and Predicting Diversions in Freight Transportation*, 2014, str. 6.

V osrednjem delu poleta razlike v hitrosti niso tako očitne kot proti koncu (blizu vrednosti 1,0 na abscisni osi), ko letalo pristaja in se temu primerno hitrost relativno hitro spreminja. Pri preusmerjenem poletu pa lahko opazimo, da so spremembe v prvi polovici (do približno vrednosti 0,5 na abscisni osi) podobne kot pri pravilnem poletu. Kmalu zatem pa so podobne kot pri koncu pravilnega poleta, le da so v primeru te razlike že kmalu po polovici poleta. Iz tega lahko sklepamo, da letalo ni pristalo na pričakovanem letališču, saj ni prepotovalo celotne razdalje med letališčema.

Drugi vzorci petih prej omenjenih ključnih podatkov o poletu, ki lahko kažejo, da je bilo letalo preusmerjeno, so:

- velika negativna sprememba v višini letala pri relativno večjem delu opravljene poti bi lahko nakazovala na predčasen pristanek;
- velika sprememba pri usmeritvi letala pri relativno večjem delu opravljene poti bi lahko nakazovala na oster, a nenačrtovan zavoj;
- nič ali zelo majhne (skoraj ničelne) spremembe pri hitrost, višini in usmeritvi letala pri pričakovani celotni opravljeni razdalji bi lahko nakazovale, da je letalo preletelo predvideno letališče in leti proti drugemu.

Pri tem je treba poudariti, da se argumentiranje posameznih vzorcev preusmeritve poleta lahko izkaže kot nepravilno. Vzorci, ki nam še niso znani, se lahko pozneje izkažejo kot vzorci, ki nakazujejo na preusmeritev. V študiji so zato, namesto da bi poskušali opisati nepravilnosti v poletih/podatkih v smislu objektivnih vzorcev, pripravili t. i. enorazredni klasifikator, ki je sposoben razlikovati med pravilnim/rednim in nepravilnim (angl. *anomalous*) vedenjem.

2.6.4 Zaznavanje nepravilnega vedenja

V okviru raziskave so se odločili, da bodo za zaznavanje nepravilnosti v poletu uporabili metodo podpornih vektorjev. SVM je namreč sposoben množico elementov (v njihovem primeru poletov) razdeliti na normalne in osamelce (angl. *outliers*). Dodati je treba, da je v nasprotju z nekaterimi drugimi metodami sposoben razločevati tudi v večdimenzionalnem prostoru (oz. med več spremenljivkami). Izbira spremenljivk močno vpliva na uspešnost SVM (Van der Aa et al., 2014, str. 6).

Z uporabo metode podpornih vektorjev so naučili enorazredni klasifikator, ki opisuje vedenje, najdeno med normalnimi poleti. Ko je takšen klasifikator zgrajen in predstavlja model normalnega vedenja, se ga lahko uporabi za odkrivanje nepravilnosti. V primeru poletov dobiva podatke o novem položaju letala in na podlagi prejšnjega položaja preveri, ali so v vedenju nepravilnosti ali ne.

2.6.5 Predvidevanje preusmeritve

Med normalnim poletom lahko nastanejo odstopanja npr. zaradi S-ovinka, ki ga letalo naredi zaradi preobremenjenega letališča. To še ne pomeni, da je ali bo takšen polet preusmerjen. Zaradi te in številnih drugih anomalij med normalnim poletom so se pri opravljanju raziskave odločili, da polet ne bo označen kot preusmerjen že pri prvi zaznani nepravilnosti. Takšno oznako bo dobil šele po določenem zaporednem številu zaznanih anomalij. Pri postavljanju takšne omejitve je omogočeno, da se nenormalno vedenje prikazuje določen čas, ne da bi se takoj sprožila napoved za preusmeritev. Poleg tega pa predhodno (ne)pravilno vedenje poleta ne vpliva na poznejšo klasifikacijo (Van der Aa et al., 2014, str. 6). To v praksi pomeni, da če zaporedno število intervalov neobičajnega vedenja ne doseže ali preseže postavljenega praga, ob katerem se sproži opozorilo za preusmerjen polet, ta ni označen kot preusmerjen. Če se po intervalu, ko je bilo zaznano odstopanje, opazi pravilnost v poletu, vsa do takrat zaznana odstopanja ne vplivajo na klasifikacijo.

2.6.6 Podatki za testiranje

Da so v sklopu raziskave lahko naučili SVM, so potrebovali množico trajektorij poletov. Pri iskanju čim boljše naučenega SVM, so uporabili tri različne skupine s trajektorijami poletov. Nobena trajektorija se v teh treh skupinah ni ponovila.

V prvo skupino (S1), ki so jo uporabili za treniranje SVM, so vključili 217 trajektorij poletov, ki so bili normalni oz. niso bili preusmerjeni. V drugo skupino (S2), namenjeno potrjevanju (angl. *validation*) naučenega SVM, so vključili 119 trajektorij. Od tega jih je bilo 98 normalnih, 21 pa preusmerjenih. To skupino so pri treniranju SVM uporabili za optimizacijo parametrov pri pristopu razvrščanja. V tretji skupini (S3) pa je bilo 192 trajektorij, in sicer 170 normalnih in 22 preusmerjenih. Uporabili so jo kot testno.

Pri kvantificiranju uspešnosti naučenega SVM so uporabili tri meritve: natančnost (angl. *precision*), priklic (angl. *recall*) in F-statistiko (angl. *F-score*). Njihov izračun lahko vidimo

na spodnjih enačbah (1, 2, 3). Spremenljivka *tp* ali resnično pozitivna (angl. *true positive*) predstavlja število poletov, ki jih je SVM pravilno napovedal kot preusmerjene. Tisti, ki jih je ravno tako kvalificiral kot preusmerjene, a v resnici to niso, so označeni s *fp* ali lažno pozitivni (angl. *false positive*). Pri klasifikaciji pa sta uporabljeni še dve spremenljivki: *tn* ali resnično negativna (angl. *true negative*) označuje polete, ki jih je SVM pravilno označil kot normalne; *fn* ali lažno negativna (angl. *false negative*) pa polete, napačno označene kot normalne.

$$\text{Natančnost} = \frac{tp}{tp+fp} \quad (1)$$

$$\text{Priklic} = \frac{tp}{tp+fn} \quad (2)$$

$$\text{F-statistika} = \frac{2 * \text{natančnost} * \text{priklic}}{\text{natančnost} + \text{priklic}} \quad (3)$$

Prikazane formule so uporabljene za izračun natančnosti (1), priklica (2) in F-statistike (3). Natančnost označuje razmerje med pravilno napovedanimi preusmerjenimi poleti in seštevkom pravilno napovedanih preusmerjenih z napačno napovedanimi preusmerjenimi poleti. Priklic (angl. *recall*) označuje delež resnično preusmerjenih, F-statistika (angl. *F-score*) pa je harmonična sredina natančnosti in priklica (Baeza-Yates & Ribeiro-Neto, 1999).

2.6.7 Optimizacija parametrov

V raziskavi so pri iskanju čim boljše naučenega SVM s skupino trajektorij S1 uporabljali skupino trajektorij S2, na kateri so potrjevali natančnost SVM. SVM so učili s štirimi parametri, njihove možne vrednosti pa so vnaprej definirali. Ti parametri z definiranimi vrednostmi so:

- $L \in \{3, \dots, 30\}$; dolžina intervala med dvema položajema letala;
- $\tau \in \{1, \dots, 15\}$; št. zaporednih intervalov, ko se sproži alarm za preusmeritev, ki določa, po koliko zaporedno zaznanih anomalijah v poletu naj se tega označi kot preusmerjenega;
- $v \in \{0,01, 0,02, \dots, 0,25\}$; vrednost, s katero določamo SVM, kako zelo naj dopušča odstopanja od osnovne skupine enega razreda. Za dobro klasifikacijo je treba izbrati pravilno vrednost te konstante. Od neke vrednosti naprej višja vrednost te konstante ne prinaša boljše klasifikacije, pač pa le po nepotrebnem upočasni proces učenja (Šmitran, 2010). Je vrednost, s katero se uglašuje (angl. *tunes*) število sprejemljivih osamelcev (v našem primeru preusmerjenih poletov);
- $\gamma \in \{2^{-10}, 2^{-9}, \dots, 2^3\}$; določa ukrivljenost meje, ki ločuje razrede ali normalne in preusmerjene polete (Šmitran, 2010).

Z definiranimi vrednostmi teh štirih parametrov so pri preverjanju uspešnosti naučenega SVM s skupino S2 preverjali vse možne kombinacije teh parametrov.


Po končanem treniranju so za vsak par (L , τ) izbrali vrednosti ν in γ , pri katerih so bile najvišje vrednosti F-statistike. S spreminjanjem parametrov pri treniranju SVM so iskali takšno kombinacijo, pri kateri bi bila F-statistika čim višja, s tem da bi bil čas, potreben za opozorilo (tj. $L * \tau$) SVM, da je polet zaznan kot preusmerjen, čim krajši. V tabeli 4 so predstavljeni nekateri izmed najboljših rezultatov, ki so jih dobili po treniranju SVM. Opazimo lahko, da je v skoraj vseh primerih, razen pri $L = 25$, F-statistika relativno visoka (nad 0,8). Opaziti je, da F-statistika upada, s tem ko L narašča. Če pogledamo še sliko 12, pa lahko vidimo, da v večini primerov, ko L narašča, F-statistika upada. Glede na pridobljene rezultate pri učenju tako menijo, da je v njihovem primeru, če je L pod 10 minutami, najboljša izbira.

Tabela 4: Rezultati treniranja SVM.

L	τ	ν	γ	Natančnost	Priklj	F statistika
3	3	0,02	0,25	0,920	0,958	0,939
4	5	0,03	2,00	0,957	0,917	0,937
5	4	0,04	2,00	0,920	0,958	0,939
6	5	0,07	4,00	1,000	0,875	0,933
7	3	0,01	0,50	0,958	0,958	0,958
8	4	0,06	4,00	0,885	0,958	0,920
9	3	0,03	0,50	0,913	0,875	0,894
10	5	0,08	4,00	0,952	0,833	0,889
11	3	0,10	0,25	0,880	0,917	0,898
12	3	0,07	2,00	0,880	0,917	0,898
13	3	0,01	1,00	0,952	0,833	0,889
14	3	0,01	2,00	0,913	0,875	0,894
15	3	0,05	2,00	0,880	0,917	0,898
16	3	0,10	0,50	0,913	0,875	0,894
17	3	0,03	2,00	1,000	0,875	0,933
18	3	0,10	4,00	0,875	0,875	0,875
19	3	0,11	2,00	0,870	0,833	0,851
20	3	0,07	2,00	0,870	0,833	0,851
21	2	0,01	1,00	0,727	1,000	0,842
22	3	0,18	0,25	0,833	0,833	0,833
23	2	0,01	0,25	0,833	0,833	0,833
24	2	0,03	0,50	0,840	0,875	0,857
25	2	0,01	0,25	0,889	0,667	0,762
26	2	0,01	1,00	0,750	0,875	0,808
27	2	0,01	1,00	0,778	0,875	0,824
28	2	0,01	0,50	0,833	0,833	0,833
29	2	0,05	0,50	0,840	0,875	0,857
30	2	0,06	0,50	0,759	0,917	0,831

Vir: Van der Aa et al., *Detecting Flight Trajectory Anomalies and Predicting Diversions in Freight Transportation* 2014, str. 7.

Slika 12: Razmerje med L in F -statistiko pri treniranju SVM.




Vir: Van der Aa et al., *Detecting Flight Trajectory Anomalies and Predicting Diversions in Freight Transportation*, 2014, str. 8.

2.6.8 Učinkovitost

Po rezultatih učenja različnih SVM so v raziskavi želeli SVM testirati na podatkih/trajektorijah v skupini S3. Uporabili so parametre za učenje različnih SVM iz tabele 4, pri čemer so izbirali tiste, pri katerih je L znašal od 3 do 10. Na sliki 13 so prikazani rezultati (natančnost, priklic in F -statistika), ki so jih dobili pri kvalificiranju trajektorij iz skupine S3 z osmimi različno naučenimi SVM.

Slika 13: Rezultati testiranja osmih različnih SVM.



Vir: Van der Aa et al., *Detecting Flight Trajectory Anomalies and Predicting Diversions in Freight Transportation*, 2014, str. 8.

Najboljše rezultate, F-statistika (0,878), so dobili, ko je bil L 6 ali 7 minut, najboljšo natančnost (1,0), vendar relativno nizek priklic, pa pri L = 4. Odpoklic je bil pri teh osmih različnih SVM najvišji (0,864) pri L = 5. Med omenjenimi štirimi rezultati bi se lahko za najprimernejšega odločali po različnih kriterijih, saj bo v enem primeru (L = 7) morebitno pravilno zaznan preusmerjen polet v 21 minutah, kar je 9 minut prej, kot če bi za L izbrali 6 (in posledično temu primerno druge vrednosti parametrov za učenje SVM).

Preusmeritev v letalstvu je precej redek pojav, zato bi bilo vredno razmisliti o tem, da bi izbrali SVM, kjer je priklic čim višji, kar bi pomenilo, da bi manj normalnih poletov označil za preusmerjene in bi bilo tako manj lažnih opozoril.

2.6.9 Pridobitev odzivnosti/časovna pridobitev

Glavni cilj raziskave ni le zaznavanje preusmerjenih poletov, ampak tudi čim zgodnejše zaznavanje. Zato so se v raziskavi lotili še računanja, koliko časa bi glede na testne podatke pridobili za boljše razporejanje resursov (tovornih vozil).

Za računanje pridobljenih časov so med kvalificiranjem poletov uporabili trajektorije resnično preusmerjenih poletov iz skupin S2 in S3. Teh trajektorij je 43, med katerimi jih je SVM 39 označil kot preusmerjene. S takšnim pristopom so v povprečju za teh 39 poletov dobili signal, da je bil polet preusmerjen, 104 minute pred predvidenim časom pristanka oz. 64 minut pred dejanskim pristankom. Tako bi imele logistične službe na voljo več kot eno uro, da se v dani situaciji (preusmerjen polet) čim bolje odzovejo. To bi bila velika razlika v primerjavi z

okoliščinami, ko logistične službe izvedo, da je bil polet preusmerjen, šele dve uri po tem, ko je letalo že pristalo.

Povprečen pridobljeni čas 104 minute je čas, ki bi ga pri testiranju pridobila logistična služba, da odpove ali preusmeri cestno tovorno/prevozno sredstvo. Izračunali so ga kot razliko med uro/časom, ko je SVM polet označil kot preusmerjen, in predvidenim časom pristanka letala.

Povprečen pridobljeni čas 64 minut je čas pred pristankom za organizacijo tovarnega sredstva, ki bi prevzelo tovor na letališču, na katero je letalo preusmerjeno. Izračunali so ga kot razliko med uro/časom, ko je SVM polet označil kot preusmerjen, in časom/uro dejanskega pristanka na novem letališču.

3 VREDNOTENJE

V tem poglavju bom opisal podatke o poletih, ki sem jih pridobil za namene svojega raziskovalnega dela. Da sem jih lažje uporabljal, sem jih moral spremeniti v drugo obliko. Zato bom opisal tudi postopek spreminjanja in kaj sem moral narediti, da sem iz celotne množice dobil zase uporabne podatke. Pojasnil bom tudi, zakaj vsi niso bili primerni za raziskavo. Prav tako sem se lotil učenja SVM, nato pa še testiranja njegove učinkovitosti na testnih podatkih. Prikazal bom tudi rezultate različnih SVM.

3.1 Podatki o poletih

Spletni ponudnik FlightRadar24 (www.flightradar24.com) ponuja aktualni pregled letalskih poletov nad Evropo. Po dogovoru z lastniki spletne strani smo za namene raziskave pridobili nekatere podatke o poletih; shranjeni so bili v datotekah, zapisanih v obliki .JSON.

V takšni obliki so precej nepregledni in težko berljivi. Poleg tega bi moral za vse podatke o enem poletu preiskati več datotek, saj niso bili vsi shranjeni v svoji, ampak (lahko) v več različnih, skupaj s podatki preostalih poletov, ki so potekali ob istem času.

Struktura vsakega položaja poleta je bila sestavljena iz več podatkov, in sicer:

- oznaka letala
- zemljepisna širina, izražena v stopinjah
- zemljepisna dolžina, izražena v stopinjah
- višina, izražena v čevljih (angl. *feet*)
- hitrost, izražena v vozlih (angl. *knots*)
- oznaka radarja
- časovni žig zabeleženega položaja letala, izražen v sekundah od 00:00:00 01/01/1970 UTC/GMT
- izvor (angl. *origin*) ali mednarodna oznaka letališča, s katerega je letalo vzletelo
- destinacija (angl. *destination*) ali mednarodna oznaka letališča, na katero je letalo namenjeno

- številka poleta (angl. *flight number*)
- na tleh (angl. *onground*) označuje, ali je letalo na tleh ali v zraku

Poleg omenjenih lastnosti poleta so bile v obliki zapisa še nekatere druge, ki so za potrebe mojega raziskovalnega dela nepomembne.

Ker sem v nadaljevanju potreboval tudi podatka (zemljepisno širino in dolžino) o letališčih, sem uporabil že prej pripravljeno ločeno tabelo.

Pregled nad vsemi poleti v datotekah .JSON bi bil zamuden, zato so pripravili program, ki je prebral posamezne zapise o položajih poletov in jih zapisal v podatkovno bazo MySQL.

Po uspešnem prebiranju datotek in spreminjanju zapisov v podatkovno bazo sem kot rezultat dobil tabelo s stolpci/atributi, ki sem jih omenil v prejšnjem poglavju. Ko sem imel podatkovno bazo napolnjeno s podatki, sem imel z uporabo poizvedbenega jezika MySQL in programskega orodja MySQL Workbench boljši pregled nad podatki, kot če bi jih moral pregledovati v datotekah .JSON.

Tako sem lahko z nekaj osnovnega znanja poizvedbenega jezika izbral različne poglede na podatke. Ugotovil sem, da je prvi zapis pozicije nastal 10. julija 2013 ob 02:00:05, zadnji pa 16. julija 2013 ob 06:49:56. Znotraj tega obdobja sem lahko našel 152.212 različnih oznak poletov.

Vsak izmed poletov pa je imel različno število zapisanih položajev. Že pregledovanje toliko zapisov v tabeli je lahko nepregledno. Če pa pri tem upoštevam še, da je imel vsak izmed teh 152.212 zapisov še več lastnih, število vseh vrstic ali zapisov v tabeli preseže milijon.

Po kratkem pregledu podatkov sem opazil, da so v nekaterih zapisih manjkajoči podatki; nekateri za moje raziskovalno delo niso bili relevantni, drugi pač.

Da sem v nadaljevanju rezultate poizvedb lahko pripravil na zase enostavnejši način, sem naredil nekaj novih tabel, v katere sem vstavil pomembnejše podatke o poletih. V novo tabelo sem za vsak polet zapisal le eno vrstico/zapis z naslednjimi podatki/atributi/stolpci:

- unikatna številka iz glavne tabele prvega zapisa poleta
- unikatna številka iz glavne tabele zadnjega zapisa poleta
- začetna zabeležena višina letala
- končna zabeležena višina letala
- letališče, s katerega je letalo vzletelo
- letališče, na katero je bilo letalo namenjeno
- čas prvega zapisa/položaja poleta
- čas zadnjega zapisa/položaja poleta
- med vsemi zapisi položajev poleta najnižja zabeležena višina
- med vsemi zapisi položajev poleta najvišja zabeležena višina

- začetna zemljepisna širina
- končna zemljepisna širina
- začetna zemljepisna dolžina
- končna zemljepisna dolžina
- začetna hitrost letala
- končna hitrost letala

Po ponovnem in podrobnejšem pregledovanju podatkov sem ugotovil, da poleg nekaterih prej omenjenih vrednosti pri nekaterih poletih manjkajo zapisi položajev (v zadnjem delu poleta vključno s pristankom). Odkril sem tudi primere, ko je v eni od pozicij sredi poleta hitrost znašala 0 ali pa je bila vrednost višine 0. Ponekod je bil vmesen zemljepisni položaj letala veliko kilometrov oddaljen od smeri poleta. Med poleti so bili tudi takšni, kjer je letalo vzletelo in pristalo na predvidenem letališču, nato pa pod isto oznako leta nadaljevalo proti letališču, s katerega je pred tem vzletelo. Ali pa poleti (pod isto oznako), pri katerih je letalo na poti proti predvidenem letališču pristalo nekje drugje ter pot nadaljevalo in končalo na predvidenem letališču.

Zaradi teh napak sem se odločil, da ustvarim novo tabelo v podatkovni bazi. V njej sem zbral le podatke o poletih brez pomanjkljivosti. Pripravil sem takšen poizvedbeni stavek, ki sem ga pozneje uporabil za iskanje normalnih (nepreusmerjenih poletov) in preusmerjenih poletov za namene mojega raziskovalnega dela.


Za iskanje običajnih poletov sem v poizvedbeni stavek vključil pogoj, da začetni (zemljepisni) položaj letala v podatkih ni dlje kot miljo od letališča, s katerega je letalo vzletelo. Oddaljenost sem izračunal iz podatkov zemljepisne širine in dolžine letala in letališča. Podatke o zadnjih sem imel na voljo v tabeli. Prav tako sem primerjal zadnjo pozicijo letala z lokacijo letališča, na katero je bilo letalo namenjeno. Pri tem sem predvideval, da je letalo pristalo na tem letališču, če je bila oddaljenost pozicije letala in letališča manj kot miljo. Pri iskanju preusmerjenih poletov sem prvi kriterij ohranil, pri drugem pa dal pogoj, da sta letalo in letališče oddaljena več kot 10 milj.

Poleg tega sem pri iskanju normalnih in preusmerjenih poletov dodal še naslednje pogoje:

- razlika med najvišjo in najnižjo zabeleženo višino poleta je morala biti vsaj 914 metrov (oz. angl. 3000 *feet*);
- začetna hitrost poleta je morala znašati manj kot 74,08 km/h (oz. angl. 40 *knots*), pri čemer sem predvideval, da je bilo letalo na letališču pred vzletom;
- končna hitrost poleta je morala znašati manj kot 74,08 km/h (oz. angl. 40 *knots*), pri čemer sem predvideval, da je bilo letalo na letališču med pristajanjem oz. po njem;
- končna višina letala je morala znašati manj kot 12,19 metra (oz. angl. 40 *feet*).

Kljub filtriranju so ostali poleti z drugimi napakami v podatkih. Odkril sem primere, kjer je bila časovna razlika med dvema zaporednima zapisoma pozicije poleta tudi več kot 30 minut. To bi pomenilo, da pri sledenju takšnega poleta več kot 30 minut ne bi imeli podatkov o njegovem položaju. Primer poleta z manjkajočimi zapisi pozicij lahko vidimo na sliki 14.

Slika 14: Manjkajoče pozicije/zapisi poleta iz Moskve v Varšavo.



Vir: C. Di Ciccio, osebna komunikacija, 2014.

Zaradi omenjenih napak v podatkih sem pripravil dodatno funkcijo v poizvedbenem jeziku MySQL. Z njo sem preveril in pridobil najnižjo zabeleženo vrednost višine v 15 minutah od prve zaznane pozicije poleta in 15 minut pred zadnjo zaznano pozicijo leta. To funkcijo sem uporabil v postopku, ki je poleg prej omenjenih filtriranj pri iskanju normalnih in preusmerjenih poletov brez pomanjkljivih podatkov odstranil takšne, pri katerih se zapisana višina poleta 15 minut po začetku in 15 minut pred koncem ni spustila pod 3048 metrov (oz. angl. 10.000 feet).

Za ločevanje poletov z manjkajočimi zapisi o pozicijah več kot 30 minut med dvema zaporednima pozicijama sem pripravil dodaten postopek. V njem sem določil, da te polete vpiše v novo tabelo. Zato sem pozneje z razliko tabel dobil polete, ki niso imeli toliko pomanjkljivih podatkov.

Po končanem filtriranju sem dobil skupaj 6448 poletov, ki so ustrezali kriterijem za normalen polet, in 47 takšnih, ki so ustrezali kriterijem za preusmerjen polet.

3.2 Treniranje/učenje SVM

Po tem, ko sem dobil 6448 običajnih poletov in 47 preusmerjenih, sem za delo s SVM oz. učenje/treniranje tega pripravil ustrezno obliko zapisa poletov. Uporabil sem predhodno pripravljen program in mu za vnos podal seznam unikatnih oznak poletov iz podatkovne baze.

Program je za vsak polet posebej iz podatkovne baze pridobil vse pozicije in iz njih pripravil datoteko .XML.

Struktura generiranih datotek .XML je bila naslednja:

- mednarodna oznaka letališča, s katerega je letalo vzletelo, ter njegova zemljepisna dolžina in širina;
- mednarodna oznaka letališča, na katero je bilo letalo namenjeno, ter njegova zemljepisna dolžina in širina;
- številka poleta;
- pozicije poleta v časovnem zaporedju, pri čemer se je za vsak položaj iz podatkovne baze (oz. iz podatkov) poskušalo pridobiti podatek o zemljepisni širini in dolžini, datumu in času, hitrosti in višini.

Za učenje novega SVM sem dobil tudi datoteke .XML poletov, ki so jih uporabili pri učenju SVM v raziskavi, omenjeni v poglavju 2.6 (Van der Aa et al., 2014). Z uporabo teh trajektorij sem naučili SVM in ga nato uporabil za klasifikacijo trajektorij, ki sem jih pripravil.

Pri tem je treba povedati, da so trajektorije poletov, ki sem jih pridobil iz omenjene raziskave, iz severnoameriškega zračnega prostora. V moji raziskavi pa izhajajo iz poletov iz evropskega zračnega prostora.

Prvotno sem se sicer lotil učenja SVM s trajektorijami evropskih poletov, vendar rezultati niso bili obetavni. Zaradi tega sem nadaljeval učenje SVM z amerišskimi poleti.

3.2.1 Parametri za učenje SVM

Pri učenju dobro naučenega SVM je pomembna kombinacija vrednosti štirih parametrov in trajektorij normalnih poletov.

Parametri (enaki kot v raziskavi, opisani v poglavju 2.6.7) in njihove vrednosti, uporabljeni za učenje SVM v sklopu moje raziskave, so bili:

- $L \in \{2, \dots, 13\}$
- $\tau \in \{1, \dots, 14\}$
- $v \in \{0,01, 0,02, \dots, 0,24\}$
- $\gamma \in \{0, 0,001, 0,002, 0,004, 0,008, \dots, 0,5, 1,0, 2,0, 4,0\}$

Za iskanje najboljših kombinacij vrednosti parametrov sem uporabil enak program, kot so ga v raziskavi, opisani v poglavju 2.6. Programu je bilo treba podati naslov na računalniku, na katerem sem hranil tri skupine trajektorij in vrednosti omenjenih štirih parametrov.

3.2.2 Zaznavanje preusmerjenega poleta

V okviru mojega raziskovalnega dela je SVM pri ocenjevanju in klasifikaciji trajektorije (ali gre za preusmerjen polet) upošteval štiri različne vrednosti.

SVM med vsemi pozicijami trajektorije ne upošteva vsake, ampak od prve izbrane pozicije vzame (prvo) naslednjo, ki je od nje oddaljena toliko minut, kolikor znaša parameter L (interval) pri učenju SVM. Primer intervala je prikazan na sliki 15.

Slika 15: Primer intervala.




Vir: A. Curik, C. Di Ciccio, M. Gutjahr, J. Mendling & J. Simecka, Combining Event Processing and Support Vector Machines for Automated Flight Diversion Predictions, 2014.

Pri klasificiranju, ali gre za preusmeritev, je SVM med dvema zaporednima položajema upošteval:

- razdaljo, ki jo je letalo opravilo do opazovanega trenutka, pri čemer je celotna predvidena razdalja razdalja med letališčem, s katerega je letalo vzletelo, in letališčem, na katero je namenjeno;
- razdaljo, ki jo je letalo opravilo v opazovanem časovnem intervalu, oz. pridobljeno razdaljo;
- spremembo hitrosti v opazovanem časovnem intervalu;
- spremembo višine v opazovanem časovnem intervalu.

Primer sprožitve alarma za preusmerjen polet je prikazan na sliki 16.

Slika 16: Postopek klasifikacije preusmerjenega poleta.




Vir: A. Curik, C. Di Ciccio, M. Gutjahr, J. Mendling & J. Simecka, *Combining Event Processing and Support Vector Machines for Automated Flight Diversion Predictions*, 2014.

Parameter τ je pri klasifikaciji preusmerjenega poleta prav tako pomemben, saj določa, po koliko zaporednih zaznanih nepravilnostih SVM polet klasificira kot preusmerjen. Kot tak je označen samo, kadar zaporedno število zaznanih nepravilnosti doseže prag.

3.2.3 Izbira trajektorij za učenje SVM

Pri učenju SVM je bilo treba podati množico trajektorij normalnih poletov, pri čemer pa število trajektorij ne igra ključne vloge pri tem, kako dobro bo SVM naučen. Po številnih manj uspešnih učenjih z naključno izbranimi trajektorijami iz nabora 6.448 normalnih poletov, sem nekaj poletov preveril. Za pregledovanje trajektorij so mi za vsako pripravili sliko s sledjo poleta. Na njej sta bili označeni letališče vzleta in letališče predvidenega pristanka. Polete z nenavadnimi vzorci sem odstranil iz nabora. Na sliki 17 lahko vidimo primer sledi poleta, ki sicer ni bil preusmerjen, sem pa ocenil, da ni povsem normalen zaradi nenavadnega zavoja na poti.

Slika 17: Primer nenormalnega nepreusmerjenega poleta iz Rima v København.



Vir: C. Di Ciccio, osebna komunikacija, 2014.

Po nekaj več kot 1.400 pregledanih sledih sem uporabil 1.395 trajektorij, za katere sem presodil, da po sledi sodeč niso posebej nenavadne. V naslednjem koraku sem uporabil SVM, naučen s trajektorijami ameriških poletov, in mu podal 1.395 trajektorij evropskih poletov za klasifikacijo (normalni ali preusmerjeni). Za nepreusmerjene jih je bilo označenih 749.

Med temi 749 sem nato izbiral trajektorije za učenje novega SVM z evropskimi poleti; trajektorij preusmerjenih letov sem imel še vedno le 47.

Za preizkušanje ustreznosti kombinacij parametrov smo za potrjevanje (angl. *validation*) uporabili dodatni skupini trajektorij. Pomembno je bilo, da se nobena izmed trajektorij ni ponovila v kateri od drugih (dveh) skupin, uporabljenih pri učenju in preizkušanju SVM, ter da je ena skupina vsebovala le trajektorije normalnih poletov, druga pa le trajektorije preusmerjenih letov.

3.2.4 SVM, temelječ na evropskih poletih

Pri iskanju čim boljše naučenega SVM sem uporabil omenjen program (v poglavju 2.6), v katerem sem moral vnaprej določiti vrednosti štirih parametrov za učenje SVM in tri skupine trajektorij. Za skupino, s katero se je učilo SVM, sem naključno med 749 izbral 219 trajektorij. Za skupino normalnih poletov za potrjevanje pa sem med preostalimi naključno izbral 81 trajektorij. Med 47 preusmerjenimi poleti sem jih naključno izbral 27 za tretjo skupino trajektorij, ki je prav tako služila potrjevanju.

Iz skupine normalnih in preusmerjenih poletov nekaterih nisem izbral, da sem jih pozneje lahko uporabil za testiranje SVM.

Po končanem učenju SVM z vsemi možnimi kombinacijami štirih parametrov sem dobil rezultate. Nekatere teoretično najbolj obetavne kombinacije z izbranimi 219 trajektorijami so prikazane v tabeli 5.

Tabela 5: Rezultati učenja SVM z 219 evropskimi trajektorijami.

L	τ	ν	γ	Natančnost	Priklic	F statistika
5	4	0.11	2	1	0,889	0,941
2	8	0.19	4	0,926	0,926	0,926
2	8	0.17	2	0,96	0,889	0,923
6	3	0.01	2	0,96	0,889	0,923
2	9	0.17	4	1	0,852	0,92
4	3	0.04	0	1	0,852	0,92
5	4	0.09	2	1	0,852	0,92
2	8	0.21	4	0,893	0,926	0,909

Nato sem s šestimi naučenimi SVM testiral klasificiranje dveh skupin trajektorij. V prvi je bilo 449 trajektorij normalnih poletov, v drugi pa 20 trajektorij preusmerjenih poletov. V tabeli 6 je prikazano, kako je šest različnih SVM klasificiralo skupino normalnih poletov.

Tabela 6: Klasifikacije 449 evropskih normalnih poletov.

tn	fp	Natančnost	Priklic	F statistika
438	11	0,577	0,75	0,652
432	17	0,469	0,75	0,577
430	19	0,457	0,8	0,582
412	37	0,302	0,8	0,438
409	40	0,298	0,85	0,442
417	32	0,319	0,75	0,448

Pri računanju natančnosti, priklica in F-statistike testiranja SVM sem upošteval, da spremenljivka tp v enačbah (1; 2; 3) predstavlja število pravilno označenih preusmerjenih poletov. Spremenljivka fp označuje število napačno označenih poletov za preusmerjene, fn pa število poletov, ki niso bili označeni kot preusmerjeni, a to v resnici so.

V tabeli 7 je zapisano, kako je šest različnih SVM (enakih kot v tabeli 6) klasificiralo skupino preusmerjenih poletov. Prikazani so tudi povprečni časi zaznave preusmeritve pred pristankom.

Tabela 7: Klasifikacije 20 evropskih preusmerjenih poletov.

fn	tp	Povp. min	Natančnost	Priklic	F statistika
5	15	67	0,577	0,75	0,652
5	15	67	0,469	0,75	0,577
4	16	63,5	0,457	0,8	0,582
4	16	62,3	0,302	0,8	0,438
3	17	61,1	0,298	0,85	0,442
5	15	67	0,319	0,75	0,448

Za tem sem skupinama normalnih in preusmerjenih evropskih poletov dodal še nekaj ameriških: 217 normalnih v skupino 449 evropskih normalnih in 22 preusmerjenih v skupino 20 evropskih preusmerjenih. Rezultati klasifikacije novih skupin so vidni v tabeli 8 in 9.

Tabela 8: Klasifikacije 449 evropskih in 217 ameriških normalnih poletov.

tn	fp	Natančnost	Priklic	F statistika
594	72	0,333	0,857	0,480
582	84	0,300	0,857	0,444
566	100	0,270	0,881	0,413
582	84	0,306	0,881	0,454
571	95	0,286	0,905	0,434
559	107	0,246	0,833	0,380

Tabela 9: Klasifikacije 20 evropskih in 22 ameriških preusmerjenih poletov.

fn	tp	Povp. min	Natančnost	Priklic	F statistika
6	36	120,5	0,333	0,857	0,480
6	36	120,5	0,300	0,857	0,444
5	37	117,6	0,270	0,881	0,413
5	37	78,5	0,306	0,881	0,454
4	38	77,9	0,286	0,905	0,434
7	35	133,8	0,246	0,833	0,380

3.2.5 SVM, temelječ na evropskih in ameriških poletih

Po učenju SVM s trajektorijami evropskih poletov sem se lotil še učenja s skupino trajektorij evropskih in ameriških poletov. Poročam lahko o dveh različnih, po mojem mnenju uspešnih učenjih.

V prvem primeru sem v skupino za učenje vključil 436 trajektorij (219 evropskih in 217 ameriških), v skupino normalnih trajektorij za potrjevanje 181 (81 evropskih in 100

ameriških), v skupino preusmerjenih trajektorij za potrjevanje pa 49 trajektorij (27 evropskih in 22 ameriških).

V fazo testiranja sem vključil enak nabor (449 normalnih in 20 preusmerjenih) trajektorij evropskih poletov kot pri testiranju, omenjenem v prejšnjem (3.2.4) poglavju. V tabeli 10 je prikazano število normalnih poletov, ki jih je šest različnih SVM označilo kot normalne ali preusmerjene.

Tabela 10: Klasifikacija 449 normalnih evropskih poletov šestih različnih SVM.

L	τ	ν	γ	tn	fp
5	4	0,08	2	446	3
3	6	0,01	4	442	7
3	6	0,05	4	440	9
4	4	0,05	2	433	16
4	3	0,02	1	437	12
5	4	0,07	2	446	3

Tabela 11 prikazuje, koliko poletov so enako naučeni SVM kot v primeru, prikazanem v tabeli 10, zaznali kot preusmerjene med vsemi 20 dejansko preusmerjenimi. V tej tabeli je prikazano tudi, povprečno koliko minut pred pristankom preusmerjenih poletov je bila preusmeritev zaznana.

Tabela 11: Klasifikacija 20 preusmerjenih evropskih poletov šestih različnih SVM.

L	τ	ν	γ	fn	tp	Povp. min
5	4	0,08	2	7	13	50
3	6	0,01	4	5	15	57
3	6	0,05	4	5	15	55
4	4	0,05	2	4	16	51
4	3	0,02	1	6	14	55
5	4	0,07	2	9	11	56

Tabela 12 pa prikazuje rezultate testiranja šestih različnih SVM.

Tabela 12: Rezultati 6 različnih SVM.

L	τ	ν	γ	Natančnost	Priklic	F statistika
5	4	0,08	2	0,813	0,65	0,722
3	6	0,01	4	0,682	0,75	0,714
3	6	0,05	4	0,625	0,75	0,682
4	4	0,05	2	0,5	0,8	0,615
4	3	0,02	1	0,538	0,7	0,609
5	4	0,07	2	0,786	0,55	0,647

Pri drugem uspešnem učenju SVM z evropskimi in ameriškimi poleti pa sem za treniranje uporabil 354 (219 evropskih in 135 ameriških) poletov. V dve skupini za potrjevanje pa sem vključil 141 (81 evropskih in 60 ameriških) normalnih in 39 (27 evropskih in 12 ameriških) preusmerjenih poletov.

V dveh skupinah trajektorij za testiranje SVM sem uporabil skupaj 571 (449 evropskih in 122 ameriških) normalnih in 30 (20 evropskih in 10 ameriških) trajektorij preusmerjenih poletov. Podobno kot v prejšnjih primerih so v tabeli 13, 14 in 15 prikazani nekateri med boljšimi rezultati testiranja. V tabeli 14 so prikazani tudi povprečni časi zaznave preusmeritve pred pristankom.

Tabela 13: Klasifikacija 571 normalnih poletov sedmih različnih SVM.

L	τ	ν	γ	tn	fp
3	6	0,01	4	561	10
3	6	0,05	4	562	9
3	6	0,06	4	557	14
4	4	0,01	2	557	14
3	6	0,04	4	562	9
3	6	0,07	2	559	12
5	4	0,09	2	560	11

Tabela 14: Klasifikacija 30 preusmerjenih poletov sedmih različnih SVM.

L	τ	ν	γ	fn	tp	Povp. min
3	6	0,01	4	8	22	86
3	6	0,05	4	7	23	84
3	6	0,06	4	6	24	82
4	4	0,01	2	7	23	90
3	6	0,04	4	8	22	85
3	6	0,07	2	6	24	82
5	4	0,09	2	6	24	85

Tabela 15: Rezultati sedmih različnih SVM.

L	τ	ν	γ	Natančnost	Priklic	F statistika
3	6	0,01	4	0,688	0,733	0,710
3	6	0,05	4	0,719	0,767	0,742
3	6	0,06	4	0,632	0,8	0,706
4	4	0,01	2	0,622	0,767	0,687
3	6	0,04	4	0,710	0,733	0,721
3	6	0,07	2	0,667	0,8	0,727
5	4	0,09	2	0,686	0,8	0,738

3.3 Diskusija rezultatov

V poglavjih 3.2.4 in 3.2.5 smo prikazali, da nam je uspelo naučiti različne SVM z različnimi nabori podatkov (trajektorij). S temi SVM nam je nato v nekaterih primerih uspelo zaznati več kot 50 odstotkov preusmerjenih poletov. Pri tem je bil povprečen čas zaznave tudi več kot 60 minut pred pristankom pri evropskih poletih in celo več kot 100 minut pri kombinaciji z ameriški. Poleg tega ni bilo sproženih veliko lažnih alarmov pri neusmerjenih poletih.

Uspešno smo naučili tudi SVM za klasificiranje evropskih in ameriških poletov hkrati. Menimo, da bi, če bi imeli na voljo več trajektorij preusmerjenih poletov, lahko naučili SVM, da bi bil sposoben zaznati še več preusmerjenih poletov, pri čemer bi delež klasifikacije normalnih poletov pri dejansko normalnih ostal velik. Čeprav smo dokazali, da lahko naučimo SVM uspešnega klasificiranja evropskih in ameriških poletov, mislimo, da bi bilo smotrneje uporabiti ločene SVM za klasificiranje celinskih poletov.

Pri vseh prikazanih različno naučenih SVM smo opazili, da od prve zaznave nepravilnosti do klasifikacije za preusmerjen polet mine od 12 do 20 minut.

SKLEP

V tej magistrski nalogi sem opisal predvsem, kako cestni tovorni promet onesnažuje naše ozračje, in vse kaže, da bo izpustov CO₂ zaradi tega čedalje več. Delež kilometrov,

opravljenih s tovornjaki, ki ne prevažajo blaga, ni zanemarljiv in izpuste CO₂ bi lahko znižali tudi tako, da bi zmanjšali število t. i. praznih kilometrov.

Eden od načinov bi bil omogočiti logističnim službam posreden vpogled v dogajanje v letalskem prometu. S pomočjo ustrezne programske rešitve bi jih lahko opozorili, da bo določeno letalo pristalo na nepredvidenem letališču ali z daljšo zamudo. Ko bi bile o tem obveščene npr. 60 minut pred pristankom, bi lahko optimalneje razpolagale s svojimi resursi ter poskrbele za gospodarnejše poslovanje in bolj ekološko ravnanje.

Z našim raziskovalnim delom sem pokazal, da je možno naučiti SVM, ki bi v večini primerov dejansko preusmerjenih poletov na preusmeritev v povprečju opozoril tudi prej kot 60 minut pred pristankom letala. SVM z višjo natančnostjo mi je uspelo naučiti s kombinacijo evropskih in ameriških poletov. Pri takšnih SVM je bila pri testiranju napaka pri lažnih zaznavah preusmeritev manjša od pet odstotkov. Pri klasifikaciji evropskih poletov je bil povprečen čas zaznave preusmeritve poleta več kot 50 minut pred pristankom, pri klasifikaciji evropskih in ameriških poletov skupaj pa več kot 80 minut. Dosežene natančnosti in omenjeni povprečni časi zaznave preusmeritve pred pristankom pri testiranju kažejo, da bi z dodatnim delom lahko pripravili programsko rešitev, primerno za praktično uporabo. Zavedati se moramo, da stoodstotna natančnost pri napovedovanju preusmeritve poletov s povprečnimi časi zaznave, kot sem jih dosegel v raziskavi, ni mogoča.

Omeniti je treba, da sem imel v sklopu našega raziskovalnega dela na voljo podatke evropskih poletov zgolj šest dni. Menim, da bi za boljše naučene SVM potrebovali večji izbor poletov, med katerimi bi bili tudi takšni, opravljeni v različnih razmerah. Pri tem mislim na vremenske razmere (zima, nevihte ipd.) in obdobje večjega števila migracij (prazniki, počitnice ipd.). Poleg tega sem imel na voljo podatke poletov nad Evropo in manjši delež poletov nad Severno Ameriko. Ni pričakovati, da bi SVM, naučen s takšnimi podatki, enako uspešno klasificiral polete nad drugim zemljepisnim območjem. Predvsem zaradi tega, ker so drugod morda zaradi specifičnosti terena potrebni ali zahtevani drugačni letalski manevri.

V raziskovalnem delu smo vsakokrat, ko smo želeli, da SVM klasificira polete, poganjali za to pripravljen program. Poleg tega sem uporabljal datoteke, ki so že vsebovale celotno trajektorijo poleta. Moje raziskovalno delo bi zato lahko nadaljevali s pripravo programov, s katerimi bi simulirali pridobivanje pozicij poletov. Pri tem bi se sproti poganjal program za klasifikacijo poletov ob določenem časovnem intervalu. Ob morebitni zaznavi preusmeritve bi uporabnika na to opozoril. Ker pa ni vedno težava le v preusmerjenih poletih, pač pa tudi v takšnih z daljšo zamudo, bi se na podlagi koordinat letala in predvidenega uradnega časa pristanka lahko izračunalo približno zamudo. Ob daljši zamudi bi takšno informacijo logistična podjetja izkoristila za optimalnejše razporeditev resursov.

SVM, programi in podatki, uporabljeni v moji raziskavi, niso dovolj, da bi jih logistične službe lahko uporabljale v praksi in bi lahko pričakovali pozitivne učinke. Menim pa, da sem pokazal, da bi bilo mogoče z uporabo SVM, primerne programa in primernimi podatki pripraviti programsko rešitev, ki bi logističnim službam pomagala pri optimalnejšem delu. S

tem bi lahko zmanjšali število praznih kilometrov, izpuste CO₂, nepotrebne ure čakanja na pristanek letala na nepravem letališču ali ob nepravem času ter tako znižali stroške logističnih podjetij.

LITERATURA IN VIRI

1. Baeza-Yates, R. & Ribeiro-Neto, B. (1999). *Modern information retrieval*. ACM press New York, 463(1).
2. Barria, J. A., & Thajchayapong, S. (2011). Detection and Classification of Traffic Anomalies Using Microscopic Traffic Variables. *IEEE Transactions on Intelligent Transportation Systems*, 12(3), 695–704.
3. Besada, J. A., Frontera, G., Crespo, J., Casado, E., & Lopez-Leones, J. (2013). Automated Aircraft Trajectory Prediction Based on Formal Intent-Related Language Processing. *IEEE Transactions on Intelligent Transportation Systems*, 14(3), 1067–1082.
4. Brodnik, Š. (2013). *Izbor optimalnega transporta za dobavo zdravil v Mongolijo - Primer podjetja Lek* (magistrsko delo). Ljubljana: Ekonomska fakulteta.
5. Bureau of Transportation Statistics. (b.l.). Airline On-Time Performance and Causes of Flight Delays. Najdeno dne 11. oktobra 2014 na spletnem naslovu http://www.rita.dot.gov/bts/help_with_data/aviation/index.html#q2
6. Cabanillas, C., Di Ciccio, C., Mendling, J., & Baumgrass, A. (2014). Predictive Task Monitoring for Business Processes. *Business Process Management*, Springer Berlin Heidelberg, 8659, 424–432.
7. Chen, C., Zhang, D., Castro, P. S., Li, N., Sun, L. & Li, S. (2011). Real-time detection of anomalous taxi trajectories from GPS traces. *Mobile and Ubiquitous Systems: Computing, Networking, and Services*, Springer Berlin Heidelberg, 63–74.
8. Curik, A., Di Ciccio, C., Gutjahr, M., Mendling, J., & Simecka, J. (2014). Combining Event Processing and Support Vector Machines for Automated Flight Diversion Predictions. *Proceedings on Inter-Organizational Process Modeling and Event Processing in Business Process Management*: Dunaj, Avstrija: CEUR Workshop Proceedings.
9. Department for Transport (2009). *The air freight end-to-end journey: An analysis of the end-to-end journey of air freight through UK international gateways*. London, Velika Britanija: Department for Transport.
10. Dunne, S., & Ghosh, B. (2013). Weather Adaptive Traffic Prediction Using Neurowavelet Models. *IEEE Transactions on Intelligent Transportation Systems*, 14(1), 370–379.
11. Congressional Budget Office (2006). The Economic Costs of Disruptions in Container Shipments. Najdeno 9. oktobra 2014 na spletnem naslovu http://www.cbo.gov/sites/default/files/03-29-container_shipments.pdf
12. EUROCONTROL. (2014 a). EUROCONTROL Seven-Year Forecast February 2014: Flight Movements and Service Units 2014–2020. Najdeno 11. oktobra 2014 na spletnem naslovu <http://www.eurocontrol.int/sites/default/files/content/documents/official-documents/forecasts/seven-year-flights-service-units-forecast-2014-2020-feb2014.pdf>
13. EUROCONTROL. (2014 b). Market Segments in European Air Traffic 2013. Najdeno 11. oktobra 2014 na spletnem naslovu

<http://www.eurocontrol.int/sites/default/files/content/documents/official-documents/facts-and-figures/statfor/Doc534%20MarketSegments2013%20v1.0.pdf>

14. Eurostat. (2013). *Freight transport statistics*. Najdeno 9. novembra 2014 na spletnem naslovu http://epp.eurostat.ec.europa.eu/statistics_explained/index.php/Freight_transport_statistics#Main_statistical_findings
15. Evans, J., & Robinson, M. (2005). Assessment of Aviation Delay Reduction Benefits for Nowcasts and Short Term Forecasts. *World Weather Research Symposium on Nowcasting and Very Short Term Forecasts*. Toulouse.
16. Freight Management and Operations, U.S. Department of transportation. (2014). Freight Facts and Figures 2013. Najdeno 16. novembra 2014 na spletnem naslovu http://www.ops.fhwa.dot.gov/Freight/freight_analysis/nat_freight_stats/docs/13factsfigures/pdfs/fff2013_highres.pdf
17. Gariel, M., Srivastava, A. N., & Feron, E. (2011). Trajectory Clustering and an Application to Airspace Monitoring. *IEEE Transactions on Intelligent Transportation Systems*, 12(4), 1511–1524.
18. Georgia Tech Research Corporation. (2012). Methodologies to Estimate the Economic Impacts of Disruptions to the Goods Movement System. Najdeno 9. novembra 2014 na spletnem naslovu http://onlinepubs.trb.org/onlinepubs/nchrp/nchrp_rpt_732.pdf.
19. GET Service Project. (b. l.). Expected Impact. Najdeno 30. septembra 2014 na spletnem naslovu <http://getservice-project.eu/default.aspx?id=939&nt=18&lang=1>
20. GET Service Project. (b.l.). Societal needs. Najdeno 30. septembra 2014 na spletnem naslovu <http://getservice-project.eu/en/project/about-the-project/societal-needs>
21. Gong, Q., Miao, Q., Wang, B. X., & Adams, T. M. (2012). Assessing public benefits and costs of freight transportation projects: Measuring shippers' value of delay on freight system. Najdeno 9. oktobra 2013 na spletnem naslovu http://utcm.tamu.edu/publications/final_reports/Wang_11-00-65.pdf
22. Hummels, D. (2001). Time as a Trade Barrier. *Center for Global Trade Analysis, Department of Agricultural Economics, Purdue University*. Najdeno 31. oktobra 2014 na spletnem naslovu www.mgmt.purdue.edu/faculty/hummelsd/research/time3b.pdf
23. Hwang, I., Balakrishnan, H., Roy, K., & Tomlin, C. (2004). Multiple-target tracking and identity management in clutter, with application to aircraft tracking. *American Control Conference*, 4, 3422–3428.
24. Intergovernmental Panel on Climate Change. (2007). Climate Change: The physical science basis. Najdeno 30. septembra 2014 na spletnem naslovu http://www.ipcc.ch/pdf/assessment-report/ar4/wg1/ar4_wg1_full_report.pdf.
25. Kamgarpour, M., Dadok, V., & Tomlin, C. (2010). Trajectory generation for aircraft subject to dynamic weather uncertainty. *Decision and Control (CDC), 49th IEEE Conference 2010* (str. 2063–2068). Atlanta: Tempo, R.

26. Kara, A. Q., Ferguson, J., Hoffman, K., & Sherry, L. (2013). *Estimating Domestic U.S. Airline Cost of Delay based on European Model*. Fairfax, Virginia: George Mason University.
27. Kong, Q.-J., Zhao, Q., Wei, C., & Liu, Y. (2012). Efficient Traffic State Estimation for Large-Scale Urban Road Networks. *IEEE Transactions on Intelligent Transportation Systems*, 14(1), 398–407.
28. Kononenko, I., & Šikonja, M. (2010). *Inteligentni sistemi* (1. izd. ed.). Ljubljana: Založba FE in FRI.
29. Korona, Z., & Kokar, M. M. (1995). A Fusion and Learning Algorithm for Landing Aircraft Tracking: Compensating for Exhaust Plume Disturbance. *IEEE Transactions on Aerospace and Electronic Systems*, 31, 1210–1215.
30. Krozel, J. (2002). Intelligent Tracking of Aircraft in the National Airspace System. *AIAA Guidance, Navigation and Control Conference*. (str. 2132–2140). Monterey, California: The American Institute of Aeronautics and Astronautics.
31. Larsson, F. E., & Kollberg, D. (2009). *Overcoming the obstacles of intermodal transport* (magistrsko delo). Lund: Faculty of Engineering, Lund University.
32. Laurson, G., Dislers, K., & Keremet, M. (2011). *CO₂ Emission Reduction Practices of Road Freight Transportation* (diplomsko delo). Jönköping: Jönköping International Business School.
33. Liao, F., Wang, J. L., & Yang, G.-H. (2002). Reliable robust flight tracking control: an LMI approach. *Control Systems Technology, IEEE Transactions*, 10(1), 76–89.
34. McKinnon, A. (2007). CO₂ Emissions from Freight Transport: An Analysis of UK Data. Najdeno 9. novembra 2014 na spletnem naslovu http://www.greenlogistics.org/SiteResources/d82cc048-4b92-4c2a-a014-af1eea7d76d0_CO2%20Emissions%20from%20Freight%20Transport%20-%20An%20Analysis%20of%20UK%20Data.pdf
35. Min, H. (2002). The Impact of Lumper Costs, Empty Miles, and Shipment Size on the Profitability of Motor Carriers: A Case Study. *Journal of Transportation Management*, 13(1), 1–7.
36. Nilim, A., Ghaoui, L. E., Duong, V., & Hansen, M. (2001). Trajectory-based air traffic management under weather uncertainty. *Proceedings of the 4th USA/Europe Air Traffic Management Research and Development Seminar* (str. 64–72). Santa Fe, New Mexico: Federal Aviation Administration & EUROCONTROL.
37. Noble, W. (2006). What is a support vector machine? *Nature Biotechnology*, 24, 1565–1567.
38. Owens, J., & Hunter, A. (2000). Application of the self-organising map to trajectory classification. *Visual Surveillance, 2000. Proceedings. Third IEEE International Workshop on. IEEE* (str. 77–83). Dublin: Institute of Electrical and Electronics Engineers.
39. Pang, L. X., Chawla, S., Liu, W., & Zheng, Y. (2013). On Detection of Emerging Anomalous Traffic Patterns Using GPS Data. *Data & Knowledge Engineering*, 87, 367–373.

40. Pannequin, J., Bayen, A., Mitchell, I., Chung, H., & Sastry, S. (2007). Multiple aircraft deconflicted path planning with weather avoidance constraints. *AIAA Guidance, Navigation and Control Conference*. South Carolina: American Institute of Aeronautics and Astronautics
41. Pedersen, A. K. (2009). A More Sustainable Global Supply Chain. *Supply Chain Management Review*, 6–7.
42. Peetijade, C., & Bangviwat, A. (2012). The Challenges of Manufacturers' Empty Truck Runs in Bangkok. *2012 International Conference on Economics, Business and Marketing Management*, 29. Najdeno 15. oktobra 2014 na spletnem naslovu <http://www.ipedr.com/vol29/18-CEBMM2012-Q00035.pdf>
43. Pfeil, D. M., & Balakrishnan, H. (2012). Identification of Robust Terminal-Area Routes in Convective Weather. *Transportation Science*, 46(1), 56–73.
44. Piciarelli, C., Micheloni, C., & Foresti, G. L. (2008). Trajectory-based anomalous event detection. Circuits and Systems for Video Technology. *Circuits and Systems for Video Technology, IEEE Transactions*, 18(11), 1544–1554.
45. Reynolds, T. G., & Hansman, R. J. (2002). Conformance Monitoring Approaches in Current and Future Air Traffic Control Environments. *21st Digital Avionics Systems Conference* (str. 7C1-1–7C1-12). Irvine, California: American Institute of Aeronautics and Astronautics.
46. RITA, Bureau of Transportation Statistics. (b.l.). Airline On-Time Statistics and Delay Causes. Najdeno 11. oktobra 2014 na spletnem naslovu http://www.transtats.bts.gov/OT_Delay/ot_delaycause1.asp?display=data&pn=1
47. RITA, Bureau of Transportation Statistics. (b.l.). On-Time Performance - Flight Delays at a Glance. Najdeno 11. oktobra 2014 na spletnem naslovu http://www.transtats.bts.gov/HomeDrillChart.asp?URL_SelectYear=2014&URL_SelectMonth=8&URL_Time=1&URL_Selection=1
48. Rizet, C., Cruz, C., & Mbacké, M. (2012). Reducing Freight Transport CO₂ Emissions by Increasing the Load Factor. *Procedia – Social and Behavioral Sciences*, 48, 184–195.
49. Robinson, D. R. (2008). The greening of supply chains. *Supply Chain Management Review*. 61–64.
50. Schumer, C. E. (2008). *Flight Delays Cost Passengers, Airlines and the U. S. Economy Billions*. Texas: US Joint Economic Committee.
51. Stern, N. (2006), *The economics of climate change*. London: HM treasury London.
52. Šišlák, D., Volf, P., & Pechouček, M. (2011). Agent-Based Cooperative Decentralized Airplane-Collision Avoidance. *Intelligent Transportation Systems, IEEE Transactions*, 12(1), 36–46.
53. Šmitran, D. (2010). *Napovedovanje branosti spletnih novic s tehniko podpornih vektorjev* (diplomsko delo). Ljubljana: Fakulteta za računalništvo in informatiko.
54. Timar, S. D., Griffin, K., Borener, S., & Knickerbocker, C. (2012). Analysis of s-turn approaches at John F. Kennedy airport. *Digital Avionics Systems Conference* (str. 3C1-1 – 3C1-12). Williamsburg, Virginia: Institute of Electrical and Electronics Engineers.

55. Transportation Research Part C: Emerging Technologies. (2013). 33, 311–323.
56. Van der Aa, H., Cabanillas, C., Di Ciccio, C., Mendling, J., & Prescher, J. (2014). Detecting Flight Trajectory Anomalies and Predicting Diversions in Freight Transportation (Tehnično poročilo). Dunaj: Dunajska univerza za ekonomijo in gospodarstvo.
57. Zhang, D., Li, N., Zhou, Z.-H., Chen, C., Sun, L., & Li, S. (2011). iBAT: detecting anomalous taxi trajectories from GPS traces. *Proceedings of the 13th international conference on Ubiquitous computing* (str. 99–108). Peking: Landay, J., & Shi., Y.
58. Zhou, Y., Yan, S. & Huang, T. S. (2007). Detecting anomaly in videos from trajectory similarity analysis. *2007 IEEE International Conference on Multimedia and Expo. IEEE* (str. 1087–1090). Peking: Zhuang, X., & Gao, W.