

AIG'15



Domov

Zbornik konference

Organizacijski odbor

Uvodna razmišljanja

Pokrovitelji

AIG / DAS

ZBORNIK devete konference

Avtomatizacija v industriji in gospodarstvu



Vabljen predavanja
Industrijski forum
Vodenje procesov
Pogoni, naprave in robotizacija
Študentska sekcija

CIP - Kataložni zapis o publikaciji
Univerzitetna knjižnica Maribor
62-5(082) (0.034.2)

KONFERENCA Avtomatizacija v industriji in gospodarstvu (9 ; 2015 ; Maribor)
Zbornik devete konference Avtomatizacija v industriji in
gospodarstvu, 9. in 10. april 2015, Maribor, Slovenija [Elektronski vir] /
organizatorji Društvo avtomatikov Slovenije ... [et al.] ; uredila Nenad
Muškinja, Milan Rotovnik. - Maribor : Društvo avtomatikov Slovenije, 2015

ISBN 978-961-93818-2-3

1. Muškinja, Nenad 2. Društvo avtomatikov Slovenije (Maribor)

ISBN 978-961-93818-2-3



METRONIK



TEHNOLOGIJA
VOĐENJA
PROCESOV

SIEMENS



YASKAWA

BECKHOFF



Univerza v Mariboru

Fakulteta za elektrotehniko,
računalništvo in informatiko



Napovedovanje koncentracije ozona s samorazvijajočim se modelom na podlagi Gaussovih procesov

Dejan Gradišar¹, Martin Stepančič^{1,2}, Marija Zlata Božnar⁴,
Primož Mlakar⁴, Boštjan Grašič⁴, Juš Kocijan^{1,3}

¹Institut Jožef Stefan, Jamova 39, Ljubljana

²Mednarodna podiplomska šola Jožefa Stefana, Jamova 39, Ljubljana

³Univerza v Novi Gorici, Nova Gorica

⁴MEIS, Mali vrh pri Šmarju 78, Šmarje-Sap

dejan.gradisar@ijs.si, martin.stepancic@ijs.si, marija.zlata.boznar@meis.si,
primoz.mlakar@meis.si, bostjan.grasic@meis.si, jus.kocijan@ijs.si

Online forecasting of the ozone concentration using evolving GP


The public warning system of ground level ozone is of high importance and for this we need a reliable modelling method for predicting it. A mobile weather station for on-line prediction of ground level ozone concentration represents a practical approach of monitoring the air quality. A nonparametric and probabilistic model is designed in order to adapt itself to the location of the weather station despite the limited availability of meteorological measurements and pollutant concentration measurements. The model is an evolving system from the Gaussian process modelling framework. It uses a vector of current and past measurements to predict a normally distributed random variable. The model may predict inaccurately in atypical weather and emission conditions, but it expresses its uncertainty measure within the predicted variance during the adaptation to new conditions. The choice of model inputs affects the model accuracy. A systematic approach is provided for selecting the most important measurements. The identified model is validated on measurements.

Kratek pregled prispevka

Osveščanje prebivalstva o koncentraciji talnega ozona je izrednega pomena, vendar zato potrebujemo zanesljiv model za njegovo napovedovanje. Premična vremenska postaja za sprotno napovedovanje koncentracije talnega ozona predstavlja praktičen pristop k spremljanju kakovosti ozračja. Za tovrstno napovedovanje smo zasnovali neparametrični verjetnostni model, ki se prilagaja legi vremenske postaje in upošteva omejen nabor meteoroloških meritev ter meritev koncentracij onesnaževal. Gre za samorazvijajoči se model na podlagi Gaussovih procesov. Uporablja meritve kot regresorje za napoved v obliki naključne spremenljivke z normalno porazdelitvijo. Ta model ne omogoča natančne napovedi koncentracije ozona v netipičnih vremenskih ali emisijskih razmerah, vendar lahko izraža negotovost s povečano varianco napovedi med prilagajanjem na nove razmere. Izbira regresorjev modela vpliva na natančnost napovedi, zato smo sistematično izbrali najvplivnejše regresorje. Kakovost napovedovanja smo preizkusili na merjenih podatkih.

1 Uvod

Onesnaževanje ozračja je velik okoljski problem po svetu in tudi v Sloveniji (slika 1) [1]. Za nadzor trenutnega stanja onesnaženja uporabljamo podatke iz merilnih postaj in modelske prostorske izračune. Model pa potrebujemo tudi za napovedovanje stanja v prihodnosti. Izbira med fizikalnim in statističnim modelom je ključnega pomena za njegovo uporabo. Dober fizikalni model posnema dogajanje v naravi, vendar potrebujemo pravilno nastavitve parametrov in robnih vrednosti. Trenutni fizikalni modeli za napovedovanje onesnaženja so učinkoviti le za enostavnejše oblike zemeljskega površja. Kot alternativo pa lahko uporabljamo statistični model brez podrobnejšega fizikalnega ozadja. Naš cilj je predstaviti slednje za napovedovanje onesnaženja za točkovne lokacije.



Slika 1: Število dni s preseženo vrednostjo koncentracije ozona [1].

V prispevku bomo predstavili statistični verjetnostni model za napovedovanje koncentracije ozona na premični vremenski postaji. Ideja temelji na uporabi modela na podlagi Gaussovih procesov (GP). Metoda modeliranja je jedrna metoda in je primerna za identifikacijo nelinearnega sistema brez potrebe po podrobnejšem poznavanju fizikalnih lastnosti sistema. Postopek identifikacije pa lahko izvajamo tudi sprotno in s tem, npr. model prilagodimo na novo lego vremenske postaje. GP-model s sprotno identifikacijo je samorazvijajoč, saj se prilagaja novim

razmeram sprotno in napovedovanje lahko izvajamo kmalu po vzpostavitvi merilne postaje.

Opisano metodologijo modeliranja bomo uporabili in preizkusili za napovedovanje talnega ozona nad Novo Gorico (v nadaljevanju ozon). Tam je onesnaženje z ozonom večkrat problematično. Dobljene modele bomo ovrednotili z izmerjenimi podatki iz Nove Gorice. Novi modeli bodo lahko uporabljeni za pravočasno in učinkovito opozarjanje ter s tem boljšo zdravstveno preventivo in skladnost z direktivami EU.

Ker nas velikokrat zanima kakšna bo predvidena vsebnost ozona v ozračju za naslednji dan, smo se odločili za napovedovanje treh različnih dnevni vrednosti, in sicer:

- Maksimalno vrednost ozona v celotnem dnevu (Max),
- Povprečno vrednost vsebnosti ozona med 8. in 20. uro (8_20) in
- Povprečno vrednost vsebnosti ozona v celotnem dnevu (Avg).

V naslednjem poglavju se bomo osredotočili na postopek izbire vrednosti vhodnih veličin za model, ki jim pravimo regresorji, nato bomo predstavili identifikacijski postopek in vrednotenje modela na izmerjenih podatkih. V 3. poglavju bomo komentirali uporabnost predstavljene metode.

2 Postopek modeliranja in napovedovanja

Identifikacija je postopek s katerim iz danih podatkov oz. meritev naredimo model črne škatle. Natančnost modela je v veliki meri odvisna od kakovosti meritev, zato se bomo najprej posvetili zajemu in obdelavi podatkov in šele nato identifikacijskemu postopku.

2.1 Zajem in obdelava podatkov

Podatki za napovedovanje v tem prispevku so pridobljeni iz podatkovne baze zbranih meritev merilne postaje na področju Nove Gorice v sodelovanju s podjetjem MEIS d. o. o., ki je zagotovilo dostop do teh podatkov, ter podatkov meritev avtomatske merilne postaje

Bilje, ki so dostopni prek spletne strani Agencije Republike Slovenije za okolje ARSO.

Podatki obsegajo enourne in polurne meritve različnih okoljskih onesnaževal ter meteoroloških spremenljivk na obravnavanem območju za leto 2012 in leto 2013. Signale s polurnim časovnim intervalom smo pretvorili in povprečili na enourni interval.

Za napovedovanje maksimalne vsebnosti ozona za posamezen dan smo signale z enournim vzorčenjem pretvorili v signale z enodnevnim časovnim vzorčenjem, kjer vrednost na ta dan predstavlja največjo izmerjeno vrednost v tem dnevu. Izjema velja le za pretvorbo vrednosti smeri in hitrosti vetra, kjer smo upoštevali njuni vrednosti ob času največje vsebnosti ozona. Za napovedovanje 24 oz. 12 urnega povprečja, smo izračunali povprečne vrednosti za vse spremenljivke. Največje ter povprečne vrednosti smo izračunali le v primeru zadostnega števila podatkov v tekočem dnevu. V primeru, da v nekem dnevu primanjkuje več kot dve tretjini vrednosti signala, smo vrednost enodnevnega vzorca označili kot manjkajočo.

Napoved za naslednji dan lahko naredimo takoj, ko so na voljo dnevne vrednosti vplivnih parametrov, torej takoj po izteku prejšnjega dneva.

2.2 Izbira najvplivnejših parametrov

Izbira vhodnih regresorjev za napovedovanje vsebnosti ozona v ozračju je ključna za dobro napoved. Znano je, da je tvorjenje ozona v najnižji troposferi odvisno od različnih meteoroloških dejavnikov in je pod vplivom različnih onesnaževal.

Za izbiro regresorjev obstajajo določena priporočila posameznih vladnih organizacij in združenj, ki v svojih publikacijah in dokumentih opisujejo povezave med različnimi okoljskimi onesnaževali, meteorološkimi dejavniki ter ozonom. Dokument okoljske agencije ZDA (EPA) za kakovost zraka [1] podaja smernice za določanje možnih vplivnih spremenljivk za nastajanje ozona. Dokument podaja osnovne kemijske reakcije nastajanja ozona, pri čemer

kot vplivne spremenljivke navaja dušikove okside (NO_x), hlapne organske spojine (*Volatile Organic Compounds* – VOC) različnega izvora. Navaja tudi meteorološke vplive kot so sončno sevanje, temperatura, spreminjanje temperature z višino (temperaturni stolpec) ter površinski in višinski vetrovi (t.j. njihova hitrost in smer).

Medtem ko smernice navajajo okvirno izbiro vplivnih veličin, končna izbira regresorjev je odvisna od izbire metode modeliranja, metode izbire regresorjev, področja uporabe ter izbire in presoje raziskovalca.

Za izbiro najvplivnejših parametrov za napoved ozona, smo uporabili programsko orodje ProOpter.IVS [1]. Postopek je podrobno opisan v [5],[5]. Orodje omogoča analizo na podlagi podatkov iz preteklosti. Pri tem uporablja različne metode za izbiro regresorjev, ki so v literaturi razdeljene na filtrirne, ovojne in vgrajene metode. Za analizo vhodnih regresorjev za napovedovanje vsebnosti ozona v ozračju smo uporabili naslednje metode, ki so podprte z orodjem ProOpter.IVS:

- linearna korelacija,
- parcialna korelacijska analiza,
- korelacija razdalje,
- skupna informacija,
- parcialna skupna informacija,
- analiza variance (ANOVA),
- regularizacija nevronskega modela in občutljivostna analiza ter
- gradnja modela, linearnega v parametrih.


Z omenjenimi metodami smo analizirali vpliv vseh pridobljenih podatkov. Ker se koncentracija ozona spreminja s časom, moramo preveriti tudi regresorje vplivnih veličin, ki so zakasnjene za en, dva in tri dni.

Naš cilj je določiti izbor le tolikih regresorjev, kot je to res potrebno za posamezni model. Vsak dodatni regresor poveča zahtevnost identifikacije, saj zahteva sorazmerno večje število meritev.

Za vsak regresor smo z izbranimi metodami ocenili kakšna je njegova vplivnost. Ker te ocene nimajo enakega pomena, smo jih za lažjo primerjavo skalirali med 0 in 1, vendar se

moramo zavedati, da neposredna primerjava vrednosti različnih metod ni ustrezna.

Na sliki 2 so prikazani rezultati ocen regresorjev za napovedovanje značilke *Max*, združeni v kumulativen prikaz za vse metode. S primerjanjem mediane in srednje vrednosti lahko opazimo razpršenost ocen metod za posamezno vhodno spremenljivko. Na enak način so bili analizirani regresorji tudi za značilki *8_20* in *Avg*.



Slika 2: Razvrstitev vhodnih spremenljivk glede na kumulativne rezultate vseh metod za napovedovanje značilke *Max*.

V nadaljevanju smo za vse tri značilke izvedli podrobnejšo analizo. Tako smo za vsako metodo zgradili modele, ki so vsebovali prvih pet, deset, petnajst in dvajset vhodnih spremenljivk. Na ta način smo ovrednotili doprinos večjega števila regresorjev h kvaliteti napovedi modela. Modeli, ki jih uporabljamo za vrednotenje dobljenih razvrstitev regresorjev, temeljijo na Gaussovih procesih in so predstavljeni v poglavju 2.3. Razvrstitve smo ovrednotili na osnovi 10-kratnega križnega vrednotenja. Postopek je podrobno opisan v [4],[5]. Seznam regresorjev, ki najbolj vplivajo na posamezne značilke je podan v tabeli 1.

Tabela 1: Izbrani regresorji za posamezne značilke, kjer je *k* zaporedna vrednost vzorca.

Max	8_20	Avg
<i>O3(k-1)</i>	<i>O3(k-1)</i>	<i>O3(k-1)</i>
<i>GIsonSev(k-0)</i>	<i>GIsonSev(k-0)</i>	<i>VeterHit(k-0)</i>
<i>VeterHit(k-0)</i>	<i>VeterHit(k-0)</i>	<i>GIsonSev(k-0)</i>
<i>TempZr(k-0)</i>	<i>NO2(k-1)</i>	<i>TempZr(k-0)</i>
<i>TempZr(k-1)</i>	<i>TempZr(k-0)</i>	<i>RelVI(k-0)</i>

<i>DifSonSev(k-0)</i>	<i>TempZr(k-1)</i>	<i>TempZr(k-1)</i>
<i>RelVI(k-2)</i>	<i>RelVI(k-0)</i>	<i>O3(k-2)</i>
<i>VeterSmer(k-0)</i>	<i>Padav(k-0)</i>	<i>VeterSmer(k-2)</i>
<i>DifSonSev(k-1)</i>	<i>TempZr(k-3)</i>	<i>RelVI(k-1)</i>
<i>GIsonSev(k-3)</i>	<i>O3(k-2)</i>	<i>DifSonSev(k-0)</i>
	<i>RelVI(k-1)</i>	
	<i>VeterSmer(k-0)</i>	
	<i>VeterSmer(k-3)</i>	
	<i>Prah(k-2)</i>	
	<i>VeterSmer(k-1)</i>	

Izbira regresorjev za modeliranje je lahko odvisna od lokacije merilne postaje. Tako bo potrebno za neko drugo lokacijo izbor regresorjev ponoviti.

2.3 Sprotno modeliranje koncentracije ozona

Gaussov proces je definiran kot poljubna množica povezanih naključnih spremenljivk z normalno verjetnostno porazdelitvijo, ki imajo določeno srednjo vrednost in medsebojne kovariance na osnovi neke funkcije vhodnih spremenljivk. Ti dve funkciji sta srednja funkcija in kovariančna funkcija. Model na podlagi Gaussovega procesa pri nekaterih vhodnih spremenljivkah določa srednjo vrednost in varianco izhoda na podlagi srednje funkcije in kovariančne funkcije [6].

Ko želimo določiti verjetnostno porazdelitev neke spremenljivke z bayesovskim sklepanjem, upoštevamo našo predpostavko o porazdelitvi (npr. srednja vrednost in varianca) in množico meritev, da določimo novo srednjo vrednost in varianco spremenljivke. Podobno lahko z bayesovskim sklepanjem določamo stohastičen proces, ki je v našem primeru Gaussov proces. Najprej predpostavimo neko kovariančno funkcijo in srednjo funkcijo, nato pa ju z upoštevanjem meritev popravimo. Na novo izračunani srednja funkcija in kovariančna funkcija, novega Gaussovega procesa, določata srednjo vrednost in varianco koncentracije ozona pri danem regresorskem vektorju.

Za modeliranje za napovedovanje lahko uporabimo tak tip GP modela, ki ima regresorski vektor sestavljen iz zakasnenih meritev. Ker za napovedovanje koncentracije ozona uporabljamo tudi pretekle meritve iste veličine, imamo opravka z avtoregresijskim

modelom s posplošenim pogreškom (*Nonlinear autoregressive model with exogeneous input – NARX*) [7]. Regresorski vektor tako ponazarja stanje dinamičnega sistema v prejšnjem časovnem koraku.

Samorazvijajoči se GP model je samorazvijajoči se sistem (*Evolving System*) pri katerem izvajamo sprotno identifikacijo sistema [7][8]. Upošteva le podmnožico podatkov iz meritev, ki jo imenujemo aktivna učna množica. Ob vsakem časovnem koraku primerjamo napoved GP modela z meritvijo ozona. Če napaka presega neko vnaprej določeno mejo, trenutno meritev s pripadajočimi regresorji (t.i. vzorec) vnesemo v aktivno učno množico, model ponovno identificiramo. Če velikost aktivne učne množice presega dovoljeno, njej odstranimo tisti vzorec, ki predstavlja najbolj redundantno informacijo. Pomembnost posameznega vzorca je sestavljena iz produkta dveh faktorjev: prvi opisuje najmanjšo možno evklidsko razdaljo vzorca do drugih vzorcev, drugi faktor pa je funkcijska utež med 0 in 1 v odvisnosti od starosti posameznega vzorca. Bolj kot je vzorec star, manjša je utež. Tisti vzorec, ki je najbližji nekemu drugemu vzorcu glede na svojo starost, je izločen iz aktivne učne množice.

2.4 Validacija samorazvijajočega se GP-modela

Samorazvijajoči se GP-model smo uporabili za napovedovanje ozona pri vseh treh značilkah (*Max*, *8_20* in *Avg*). Kakovost napovedovanja smo ovrednotili z naslednjimi uveljavljenimi cenilkami:

Srednja standardna logaritmična izguba (*mean standardised log loss – MSSL*):

$$MSSL = \frac{1}{2N} \sum_{i=1}^N \left[\log(\sigma_i^2) + \frac{(E(\hat{y}_i) - y_i)^2}{\sigma_i^2} \right] - \frac{1}{2N} \sum_{i=1}^N \left[\log(\sigma_y^2) + \frac{(y_i - E(\mathbf{y}))^2}{\sigma_y^2} \right],$$

kjer je N število vseh podatkov, σ_i^2 varianca napovedi modela, σ_y^2 varianca izmerjenih vrednosti, y_i izmerjena vrednost, \hat{y}_i napovedana vrednost, $E(\hat{y}_i)$ srednja vrednost napovedanih

vrednosti ter $E(\mathbf{y})$ srednja vrednost izmerjenih vrednosti.

Srednja relativna kvadratna napaka (*mean-relative-square error – MRSE*):

$$MRSE = \sqrt{\frac{\sum_{i=1}^N (E(\hat{y}_i) - y_i)^2}{\sum_{i=1}^N y_i^2}},$$

Standardizirana srednja kvadratna napaka (*stand. mean-squared error – SMSE*):

$$SMSE = \frac{1}{N} \frac{\sum_{i=1}^N (E(\hat{y}_i) - y_i)^2}{\sigma_y^2},$$

Kazalnik uspešnosti (*success index – si*), ki ga je določila Evropska agencija za okolje [3] z vrednostjo praga $140 \mu\text{g}/\text{m}^3$:

$$si = \left(\frac{a}{m} + \frac{N + a - m - f}{N - m} - 1 \right) \cdot 100\%,$$

kjer a predstavlja število pravilno napovedanih dogodkov, ko je bila presežena dovoljena meja, m število merjenih dogodkov, ko je bila presežena dovoljena meja in f število napovedanih dogodkov, ko je bila presežena dovoljena meja. Večja vrednost kazalnika pomeni bolj zanesljiv model za napovedovanje prekomerne koncentracije.

Kazalnik učinkovitosti (*performance index – p⁶*) [10]:

$$p^6 = \frac{1}{N} \sum_{i=1}^N J_i^6,$$

kjer J_i^6 predstavlja stroškovno funkcijo, ki je enaka 1 v primeru pravilne napovedi visoke vsebnosti ozona pri istočasni meritvi visoke vsebnosti ozona in absolutni napaki manjši od $20 \mu\text{g}/\text{m}^3$ ali relativni napaki manjši od 20%.

Cenilke torej povedo kako uspešni smo lahko pri napovedovanju. Ker ocenjujemo modele, ki se prilagajajo sprotno, smo vrednotili napovedi šele po preteku 200 dni, ko predpostavljamo, da je model zadosti naučen. Napovedovanje se prične prej, in sicer že po preteku 50 dni.

2.4.1 Napovedovanje največje vsebnosti ozona


Za zagotavljanje zdravja in varnosti prebivalstva je najbolj pomembno pravilno napovedovanje preseženih vsebnosti ozona. O nevarnosti presežene vrednosti vsebnosti ozona mora biti prebivalstvo pravočasno obveščeno.

Natančnost napovedi modela, ki vsebuje regresorje v tabeli 1, smo ocenili na podlagi

cenilk $MSLL = -1.074$, $MRSE = 0.145$, $SMSE = 0.115$, $SI = 78.250$ in $P6 = 0.933$.


Na sliki 3 je prikazana primerjava napovedi.

Slika 4 bolj nazorno pokaže ujemanje napovedanih in izmerjenih vrednosti, kjer opazimo rahlo odstopanje.



Slika 3: Časovni potek dejanske (temna) in napovedane (svetla) maksimalne vrednosti ozona.

največje dnevne vsebnosti ozona in izmerjenih dejanskih vrednosti največje dnevne vsebnosti. Iz slike lahko razberemo, da napoved modela dokaj dobro napove dejansko vrednost.




Slika 4: Prikaz dejanske in napovedane maksimalne vrednosti ozona

2.4.2 Napovedovanje povprečne celodnevne vsebnosti ozona


V nadaljevanju smo določili model, ki napoveduje povprečne celodnevne vsebnosti ozona. Za določitev najboljšega modela GP smo opazovali vrednosti cenilk $MSLL$, $SMSE$ in $MRSE$. Natančnost napovedi modela, ki vsebuje regresorje v tabeli 1, smo ocenili na podlagi cenilk $MSLL = -0.379$, $MRSE = 0.209$ in $SMSE = 0.180$.

Na sliki 5 je prikazana primerjava napovedane in izmerjene povprečne celodnevne vrednosti ozona. Povprečne vrednosti so razumljivo nekoliko nižje, tudi tu pa lahko razberemo dobro ujemanje napovedi modela in dejanske vrednosti.



Slika 5: Časovni potek dejanske (temna) in napovedane (svetla) povprečne vrednosti ozona.

Da je ujemanje dejanske in napovedane vrednosti zadovoljivo potrjuje tudi primerjava na sliki 6.




Slika 6: Prikaz dejanske in napovedane povprečne vrednosti ozona.


2.4.3 Napovedovanje povprečne vsebnosti ozona med 8. in 20. uro

Dvanajsturna povprečna vsebnost ozona med 8. in 20. uro v dnevu nam podaja dnevno obremenitev, ki jo predstavlja ozon za človeka oz. okolje. Vsebnosti po zakonodaji ni potrebno meriti in spremljati. Natančnost napovedi modela, ki vsebuje regresorje v tabeli 1, smo ocenili na podlagi cenilk $MSLL = -1.252$, $MRSE = 0.148$ in $SMSE = 0.082$.

Napaka napovedi je prikazana na sliki 8, kjer lahko opazimo, da se napoved dovolj dobro ujema z dejanskimi vrednostmi.



Slika 7: Časovni potek dejanske (temna) in napovedane (svetla) povprečne vrednosti ozona (8:00-20:00).



Slika 8: Prikaz dejanske in napovedane povprečne vrednosti ozona (8:00-20:00).

3 Zaključek

V prispevku smo predstavili metodo za sprotno napovedovanje koncentracije ozona, ki je lahko primerna za uporabo na prečni merilni postaji.

Na slikah 3, 5 in 7 smo prikazali napovedi samorazvijajočega se GP modela, ki ga ročno vzpostavimo ob 50. dnevu poteka. Na podlagi rezultatov vrednotenja lahko sklepamo, da se samorazvijajoči se GP model kmalu po 50 dnevu izkaže za praktičnega, ker ne zahteva obsežno število podatkov za napovedovanje.

S predlagano metodo modeliranja, meteorološkimi meritvami in meritvami koncentracij smo dosegli zadostne pogoje za izvedljivost sistema za zgodnje opozarjanje previsoke koncentracije koncentracije ozona.

Opisano metodo modeliranja za napovedovanje lahko uporabimo ne samo za napovedovanje preseženih vrednosti ozona, ampak tudi za napovedovanje vrednosti veličin v energetiki, ekonomiji, prometu itd.

4 Zahvala

Raziskavo je sofinancirala Agencija za raziskovalno dejavnost Republike Slovenije v

okviru projekta L2-5475 – Razvoj in izvedba metode za sprotno modeliranje in napovedovanje onesnaženja zraka.

5 Literatura

- [1] European Environment Agency, Air pollution by ozone across Europe during summer 2013, EEA Technical report, 3, 2014. Web: <http://www.eea.europa.eu/publications/air-pollution-by-ozone-across-1>
- [2] Environmental Protection Agency. Guideline for developing an ozone forecasting program. EPA-454/R-99-009, 1999.
- [3] M. Glavan, D. Gradišar, M. Atanasijević-Kunc, S. Strmčnik, G. Mušič. Input variable selection for model-based production control and optimisation. *The international journal of advanced manufacturing technology*, 68 (9-12), 2013.
- [4] M. Hančič. Vrednotenje metod za iskanje najvplivnejših vhodnih spremenljivk pri napovedovanju vsebnosti ozona v zraku, Magistrsko delo, Fakultet za elektrotehniko, Ljubljana, 2014.
- [5] J. Kocijan, M. Hančič, D. Petelin, M.Z. Božnar, P. Mlakar. Regressor selection for ozone prediction. Poslano v objavo, 2015.
- [6] C.E. Rasmussen, C.K.I. Williams. *Gaussian processes for machine learning*. MIT Press, Cambridge, MA, London, 2006.
- [7] D. Petelin, J. Kocijan, A. Grancharova. On-line Gaussian process model for the prediction of the ozone concentration in the air. *Simulation Modelling Practice and Theory*, Vol. 33, str. 68-80, 2013.
- [8] D. Petelin, J. Kocijan. Evolving Gaussian process models for predicting chaotic time-series. *Evolving and Adaptive Intelligent Systems (EAIS), 2014 IEEE Conference on*, str.1-8,2014.
- [9] R.M. van Aalst, F.A.A.M. de Leeuw, *National ozone forecasting system and international data exchange in northwest Europe*, European topic centre on air quality, Tech. Rep. 9, European Environment Agency, 1998.
- [10] P. Mlakar, Determination of features for air pollution forecasting models, in: H. Adeli (Ed.), *Proceedings of Intelligent Information Systems IIS97*, Grand Bahama Island, Bahamas, IEEE Computer Society, Los Alamitos, 350–354, 1997.