



Univerzita Komenského v Bratislave  
Fakulta matematiky, fyziky a informatiky



**Ivana Bartoková**

**Autoreferát dizertačnej práce**

Climatology of Fog in Coastal Desert Region and its Prediction by Model Based on Data Mining (Klimatológia hmly v regióne pobrežnej púšte a jej predpoveď modelom založeným na hĺbkovej analýze údajov)

**na získanie akademického titulu philosophiae doctor**

**v odbore doktorandského štúdia:**  
Meteorológia a klimatológia

**Miesto a dátum:** .....

**Dizertačná práca bola vypracovaná v externej forme doktorandského štúdia.**

**Predkladateľ:**           **Ivana Bartoková**  
MicroStep-MIS  
Čavojského 1  
841 04 Bratislava

**Školiteľ:**                 **Prof. RNDr. Milan Lapin, CSc.**

**11-55-9 Meteorológia a klimatológia**

**Predseda odborovej komisie:**  
Prof. RNDr. Milan Lapin, CSc.  
Fakulta matematiky, fyziky a informatiky  
Univerzita Komenského v Bratislave  
Mlynská dolina, 842 48 Bratislava

## Autoreferát

Predkladaná dizertačná práca sa zaoberá predpovedaním meteorologického fenoménu hmly v regióne pobrežnej púšte Dubaja modelom založeným na metóde hĺbkovej analýzy údajov. Práca je napísaná prevažne v anglickom jazyku po súhlase garanta.

V danej lokalite sa vyskytujú najmä radiačné hmly s vrcholom v skorých ranných hodinách počas dopravnej špičky, ktoré boli príčinou viacerých vážnych hromadných dopravných nehôd (napr. v roku 2008 Ghantoot incident, kde sa zrazilo viac ako 200 automobilov). Tento incident vyvolal záujem Dubajskej municipality o možnosti monitorovania a predpovedania hmly na Dubajských hlavných ťahoch. Výsledkom bolo vybudovanie monitorovacej siete 13 meteorologických staníc pozdĺž hlavných ciest a nasadenie fyzikálnych predpovedných modelov na hmlu 3D model WRF a 1D model PAFOG.

Úspešnosť predpovede hmly pomocou tohto prepojenia fyzikálnych modelov sa ukázala pozitívna najmä na 4 až 12 hodín dopredu, a signifikantná od 7 do 9 hodín, kde model dosahoval najlepšie výsledky  $POD = 92\%$  a  $FAR = 66\%$ . Tieto hodnoty predstavujú vo vedeckej modelárskej komunite úspech a boli publikované v *Boundary-Layer Meteorology*, 2012, Vol.145, 485-506.

Ďalším zlepšením predpovedania hmly v danom regióne je vytvorenie modelu na prvých 6 hodín predpovede fyzikálnych modelov založeného na hĺbkovej analýze údajov, ktorý zohľadní klimatologické fenomény typické pre tento región pobrežnej púšte, pomôže prekonať inicializačné chyby fyzikálnych modelov a výrazne zvýši úspešnosť predpovede hmly najmä v inkriminovanom čase najčastejšieho výskytu hmly v kombinácii s raňajšou dopravnou špičkou.

## Ciele

Očakávaným výsledkom tejto práce a teda jej hlavným cieľom bolo vytvoriť predpovedný model na hmlu v regióne pobrežnej púšte Dubaja založený na hĺbkovej analýze údajov, s vlastnosťami opísanými vyššie.

Tento hlavný cieľ si autorka rozdelila na niekoľko čiastkových cieľov:

- 1 Podrobná analýza klimatologickej situácie regiónu s dôrazom na činitele, ktoré sú pre vznik hmly všeobecne ale najmä v regióne pobrežnej púšte kľúčové.
- 2 Prehľad problematiky použitia metód hĺbkovej analýzy údajov na predpovedanie hmly vo svete.
- 3 Analýza možností použitia metód hĺbkovej analýzy údajov pre daný problém popísaný vyššie a výber najvhodnejšej metódy.

- 4 Príprava súborov podkladov na hĺbkovú analýzu údajov. Príprava podkladov je veľmi komplexná a časovo náročná fáza hĺbkovej analýzy údajov (často pohltí 60 až 70% celkového času).
- 5 Vytvorenie stabilného a robustného predpovedného modelu na hmlu použitím vybranej metódy hĺbkovej analýzy údajov na pripravených súboroch podkladov.
6. Verifikácia vytvoreného modelu

Vytvorený model bol podrobený verifikácii. Jeho úspešnosť bola vyjadrená štandardnými skóre založenými na výpočtoch z kontingenčnej tabuľky, bežne používanými v meteorologickej komunite:

$$\begin{pmatrix} a & b \\ c & d \end{pmatrix} = \begin{pmatrix} \text{correct} & \text{negatives} & \text{false} & \text{alarms} \\ & \text{misses} & & \text{hits} \end{pmatrix}$$

$$\text{Bias} = \frac{b + d}{c + d},$$

$$\text{POD} = \frac{d}{c + d},$$

$$\text{FAR} = \frac{b}{b + d},$$

$$\text{POFD} = \frac{b}{a + b},$$

$$\text{TSS} = \frac{ad - bc}{(a + b)(c + d)} = \text{POD} - \text{POFD},$$

$$\text{GSS} = \frac{ad - bc}{(ad - bc) + (a + b + c + d)(b + c)}$$

Zaujímavou bola otázka údajov, na ktorých sa verifikácia vykonávala. Štandardnými metódami verifikácie modelov vytvorených hĺbkovou analýzou údajov je 10-násobná krížová verifikácia alebo náhodné rozdelenie súboru dát na tréningovú (súbor údajov, na ktorých sa vykoná hĺbková analýza) a testovaciu (verifikačnú) množinu. Z meteorologického hľadiska bolo zaujímavé zistiť, či je možné na vytvorenie úspešného modelu použiť ako tréningovú množinu údaje z jednej stanice a verifikovať ho na údajoch z inej stanice v regióne. Z toho plynula otázka, či klimatológia vzniku hmly v danom regióne umožní vytvorenie jedného modelu, ktorý bude rovnako úspešne predpovedať hmlu pre všetky miesta z daného regiónu, z ktorých máme dostupné údaje, alebo bude nutné kvôli miestnym klimatologickým rozdielom vytvoriť model pre každú stanicu zvlášť. V ideálnom prípade, keďže sa ukázalo, že je možné model vytvorený na údajoch z jednej stanice použiť úspešne aj pre viaceré stanice,

bolo možné vytvoriť veľký súbor údajov z viacerých staníc a vytvoriť jeden robustný model založený na hĺbkovej analýze údajov z celého regiónu.

Ďalšou zaujímavou úlohou bola snaha o zlúčenie výhod predpovedania hmly fyzikálnymi modelmi a modelom založeným na hĺbkovej analýze údajov:

- Model založený na hĺbkovej analýze údajov predpovedá na kratší časový interval ako fyzikálne modely ale z väčšou úspešnosťou.
- Fyzikálne modely samotné ostali predpovedať s aktuálnou nižšou úspešnosťou, ale z väčším časovým predstihom pred výskytom hmly.
- Zlúčením modelov sa využijú prednosti oboch. O zlúčenie predností oboch modelovacích prístupov sa autorka pokúsila pridaním predpovedí fyzikálnych modelov ako prediktora do modelu založeného na hĺbkovej analýze údajov.

### **Zhrnutie dosiahnutých výsledkov**

Výsledkom danej práce je model na predpoveď hmly v regióne Dubaja, s vlastnosťami popísanými vyššie, vytvorený metódou hĺbkovej analýzy údajov. Z metód hĺbkovej analýzy údajov sa autorka rozhodla pre metódu rozhodovacích stromov pred neurónovými sieťami, pretože rozhodovacie stromy v modeli pozostávajú zo súboru meteorologicky zrozumiteľných pravidiel. Tento fakt umožňuje porovnať rozhodovací proces v modeli s expertízou a skúsenosťami meteorológov predpovedajúcich hmlu v danom regióne. Na druhej strane neurónové siete vnútri modelu predstavujú čiernu skrinku, takže možno interpretovať len výsledok modelu.

V nasledujúcich odstavcoch autorka predstavuje výsledky modelu vytvoreného metódou rozhodovacích stromov na súboroch dát zo štyroch automatických meteorologických staníc z Dubajskej monitorovacej siete opísanej vyššie Al Faqaa (stanica F), Al Layan (stanica L), Um Al Momameneen (stanica M), Nazwa (stanica N). Tieto štyri stanice sú stanice s najvyšším počtom hmliel. Dáta z týchto staníc obsahujú namerané hodnoty dohľadnosti, teploty vzduchu, vlhkosti vzduchu, atmosférického tlaku, rýchlosti, smeru a nárazov vetra, teploty a vlhkosti pôdy v troch rôznych hĺbkach v dvojminútových intervaloch.

V nasledujúcej tabuľke sú prezentované výsledky modelu trénovaného na veľkom súbore dát vytvoreného zjednotením dát z týchto štyroch staníc (autorka v práci ukázala, že klimatológia hmly v danom regióne umožňuje, model vytvorený na dátach z ľubovoľnej z daných štyroch staníc, rovnako úspešne použiť na ľubovoľnej zo zvyšných troch staníc). Tento model bol verifikovaný na dátach z jednotlivých staníc ako aj 10-násobnou krížovou verifikáciou.

Výsledky modelu trénovaného na zjednotení dát štyroch staníc a testovaného voči dátam z jednotlivých staníc

Test. Dataset	Zeroes	F.Alarms	Bias	POD	FAR	POFD	TSS	GSS
	Misses	Hits						
Union	1263	22	0.79	0.65	0.17	0.02	0.63	0.54
	55	104						
F	324	1	0.63	0.60	0.05	0.00	0.60	0.56
	14	21						
L	289	13	0.91	0.68	0.25	0.04	0.64	0.50
	18	39						
M	329	6	0.93	0.73	0.21	0.02	0.71	0.58
	8	22						
N	321	2	0.65	0.59	0.08	0.01	0.58	0.53
	15	22						

Výsledky 10-násobnej krížovej verifikácie modelu trénovaného na zjednotení dát štyroch staníc

Unified model	Zeroes	F.Alarms	Bias	POD	FAR	POFD	TSS	GSS
	Misses	Hits						
10-cross fold	1268	17	0.70	0.59	0.15	0.01	0.58	0.50
	65	94						
90 % confidence intervals			0.12	0.05	0.05	0.007	0.04	0.04

Ako bolo spomenuté vyššie autorka sa pokúsila aj o spojenie oboch modelovacích prístupov. A to tak, že k meraným dátam zo stanice Al Layan skonštruovala ďalší a to binárny prediktor (1 - fyzikálne modely predpovedajú hmlu, 0 - fyzikálne modely nepredpovedajú hmlu). Z tabuľky nižšie je zjavné, že model vytvorený na dátach s pridaným prediktorom dosiahol najlepšie výsledky. Vo výstupe fyzikálnych modelov sú totiž zohľadnené aj vlastnosti atmosféry, ktoré neboli zaradené ako priamo merané prediktory (napr. vertikálny profil atmosféry).

Výsledky 10-násobnej krížovej verifikácie modelu trénovaného na dátach zo stanice Al Layan (L) bez použitia a s použitím binárneho prediktora vyjadrujúceho predpoveď fyzikálnych modelov WRF-PAFOG

L without PAFOG	Zeroes	F.Alarms	Bias	POD	FAR	POFD	TSS	GSS
	Misses	Hits						
10-cross fold	268	16	1.13	0.83	0.27	0.06	0.77	0.58
	9	43						
90 % confidence intervals			0.29	0.07	0.10	0.02	0.07	0.09
L with PAFOG	Zeroes	F.Alarms	Bias	POD	FAR	POFD	TSS	GSS
	Misses	Hits						
10-cross fold	273	11	1.10	0.88	0.19	0.04	0.85	0.69
	6	46						
90 % confidence intervals			0.19	0.08	0.09	0.02	0.08	0.10

Z výsledkov predloženej práce vyplýva, že najlepším prístupom k predpovedi hmly v danom regióne pobrežnej púšte je kombinácia fyzikálnych modelov WRF-PAFOG s modelom založeným na hĺbkovej analýze údajov. V prvých hodinách sa na predpoveď použije model založený na hĺbkovej analýze údajov a po tomto čase sa využijú výsledky fyzikálnych modelov WRF-PAFOG. Takýmto spôsobom sa skombinujú výhody oboch modelovacích prístupov v časových intervaloch , v ktorých dosahujú najlepšiu úspešnosť predpovede hmly.

## Summary

The presented work deals with prediction of a fog phenomenon in the coastal desert region of Dubai Emirate with model based on datamining technique.

Almost all fog events in the studied region are of radiation origin culminating in the early morning hours of the traffic rush. Several fog events were cause of serious traffic incidents. Ghantoot incident in 2008 heightened interest of Dubai Municipality for possibilities to monitor and also forecast fog events. It resulted in the establishing of monitoring network of 13 automated weather stations along main Dubai highways and employment of physical models 3D Weather Research and Forecasting model (WRF) and 1D PAFOG model.

Prediction skills of coupled WRF and the PAFOG fog model were positive in forecast hours 4 to 12 hours, with maximum skill from 7 to 9 hours.

Further improvement of the fog prediction in the studied region is creation of the short-term model for the first hours of the physical models forecast based on the data mining techniques. Such a model can take into account typical climatological phenomena of the considered region, it will help overcome initialization errors of physical models and it will increase skill of fog prediction in the incriminated time of the morning rush hours in combination with maximum of fog occurrences.

The created model significantly improved the fog forecast skill for the first six hours of the physical models forecast.

From the findings of the present work, it can be concluded that the best approach for fog prediction in the studied coastal desert region combines a model based on the data mining approach with the WRF-PAFOG system. In the first forecast hours, the results from the data mining method could be used, while after this time the WRF-PAFOG model results could be utilized.



## Publikačná činnosť

### ADC Vedecké práce v zahraničných karentovaných časopisoch

Bartoková I, Bott A, Bartok J, Gera M, 2015: Fog Prediction for Road Traffic Safety in a Coastal Desert Region: Improvement of Nowcasting Skills by the Machine-Learning Approach. *Boundary-Layer Meteorology* 157, 501-516

### ADD Vedecké práce v domácich karentovaných časopisoch impaktovaných

Bartok J, Babič F, Bednár P, Paralič J, Kováč J, Bartoková I, Hluchý L, Gera M, 2012: Data mining for fog prediction and low clouds detection. *Computing and Informatics* 30, 1441-1464

Cited by:

Butka P, Pócs J, Pócsová J, 2015: Reduction of Concepts from Generalized One-Sided Concept Lattice Based on Subsets Quality Measure. In *New Research in Multimedia and Internet Systems*, Springer International Publishing, 101-111

Lukáčová A, Babič F, Paralič J, 2014: Building the prediction model from the aviation incident data. In *Applied Machine Intelligence and Informatics (SAMi)*, 2014 IEEE 12th International Symposium, 365-369, Herľany, 23.-25.1. 2014

Sugumar R., Rengarajan A, 2014: A Technique to Stock Market Prediction Using Fuzzy Clustering and Artificial Neural Networks. *Computing & Informatics*, 33, 992-1024

### ADE Vedecké práce v ostatných zahraničných časopisoch

Kováčik A, Bartoková I, Omelka J, Melicherová T, 2014: Radiačný environmentálny monitoring v reálnom čase a disperzné modelovanie. *Bezpečnosť jaderné energie* 23(1/2), 46-55

### ADN Vedecké práce v domácich časopisoch registrovaných v databázach Web of Science alebo SCOPUS

Bartoková I, Křocová M, Bartok J, 2014: Inhomogeneity introduced to the climate data series by instrumentation changes of the thermometer shields and rain gauges. *Contributions to Geophysics and Geodesy* 44, 25-40

Cited by:

Adham, MI, Shirazi SM, Othman F, Zardari NH, Yusop Z, Ismail Z, 2015: Soil erodibility for water pollution management of Melaka watershed in Peninsular Malaysia. *EnvironmentAsia*, 8 (2), 63-69

### AFG Abstrakty príspevkov zo zahraničných vedeckých konferencií

Hluchý L, Bartoková I, Bartok J, 2014: Increased computational requirement of meteorological and crisis applications. *EGI Community Forum 2014: Book of Abstracts of EGI Community Forum 2014, Conference - Helsinki, 19.-23.5.2014*

Nechaj P, Bartoková I, 2014: Verification of ECMWF, GFS and WRF forecast in coastal desert region of Middle East, *Book of abstracts of EGU General Assembly 2014 Vienna, 27.4.-2.5.2014*.

### AFH Abstrakty príspevkov z domácich vedeckých konferencií

Poturnaj K, Maláč J, Kováčik A, Bartoková I., Bartok J, Spál M, 2014: Metóda

rozpoznávanie rádionuklidov v prostredí. Zborník abstraktov: ACP 2014: Analytická chémia v praxi stav a perspektívy 2014 Bratislava, 1.-4.6.2014

Kováčik A, Bartoková I, Omelka J, Melicherová T, 2014: Radiation environmental real-time monitoring and dispersion modelling. Book of abstracts: Days of Radiation Protection 2014 Poprad, 10.-14.11.2014

**BEE Odborné práce v zahraničných zborníkoch (konferenčných aj nekonferenčných)**

Bartok J, Bartoková I, Kľocová M, Mazúrek D, 2014: Sophisticated metadata in database system for climatology, meteorology and environmental sciences. Book of abstracts: TECO 2014: WMO Technical Conference on Meteorological and Environmental Instruments and Methods of Observation - St. Petersburg, 7.-9.7.2014.

**BEF Odborné práce v domácich zborníkoch (konferenčných aj nekonferenčných)**

Jaroš B, Bartok J, Bartoková I, 2014: ARWIS - informačný systém o počasí na letisku, Zborník abstraktov: Letiskové vozovky 2014: medzinárodná konferencia Štrbské Pleso, 19.-20.5.2014.

**BFA Abstrakty odborných prác zo zahraničných podujatí (konferencie...)**

Povinec P, Hirose K, Igarashi Z, Ioannidou A, Ješkovský M, Kováčik A, Lujaniene G, Mietelski, J. W, Pham J, Sýkora I, Bartok J, Bartoková I, 2015: Sources of recent radionuclide variations in the atmosphere. Book of abstracts: ENVIRA 2015: Environmental Radioactivity: International Conference - Thessaloniki, 21.-25.9.2015.

**BFB Abstrakty odborných prác z domácich podujatí (konferencie...)**

Bartoková I, 2013: Simulácia radiačnej nehody v prostredí OpenStreetMap a GIS. Zborník abstraktov: Enviro-i-Fórum 2013: Odborné fórum o environmentálnej informatike - Zvolen, 14.-15.5.2013.

## Zoznam použitej literatúry

- [1] Almazroui, M. et al., 2007: Climate Change Signals in Saudi Arabia Using Surface Temperature. Project Number 305/428 supported from King Abdelaziz University, Kingdom of Saudi Arabia.
- [2] De Pauw, E., 2002: An Agroecological Exploration of the Arabian Peninsula. ICARDA, Aleppo, Syria. pp. 77.
- [3] Fisher, M., Membery, D. A., 1998: Climate. In Vegetation of the Arabian Peninsula, Ghazanfar SA, Fisher M(eds). Kluwer Academic Press: Netherlands; 5–38.
- [4] Ghazanfar, S. A. and Fisher, M., 1998: Vegetation of the Arabian Peninsula. Kluwer Academic, pp.364
- [5] H.M. Hasanean, Middle East Meteorology, Meteorology Department, Faculty of Meteorology, Environment and Arid Land Agriculture, King Abdulaziz University, 76 pp.
- [6] <https://services.dubaiairports.ae/DubaiMet/Default.aspx>, 28.12.2013 [online]
- [7] Saha, S. et al., 2006: The NCEP climate forecast system. J Climate 19:3483–3517, DOI 10.1175/JCLI3812.1
- [8] <http://glossary.ametsoc.org/wiki/Fog>, 02.01.2014 [online]
- [9] Bartok, J., Bott, A., Gera, M., 2012: Fog prediction for road traffic safety in a coastal desert region. Boundary-Layer Meteorology 145(3):485 - 506, DOI 10.1007/s10546-012-9750-5, URL <http://dx.doi.org/10.1007/s10546-012-9750-5>
- [10] Physick, William L., Deborah J. Abbs, 1992: Flow and Plume Dispersion in a Coastal Valley. J. Appl. Meteor., 31, 64–73
- [11] Neumann, J., 1951: Land breezes and nocturnal thunderstorms. J Meteorol 8:60–67
- [12] Pielke R (1984) Mesoscale Meteorological Modeling. Academic Press, Orlando, pp. 612
- [13] Simpson, J., 2007: Sea Breeze and Local Wind. Cambridge University Press, pp. 234
- [14] Steedman, R. A., Ashour, Y., 1976: Sea breezes over north-west Arabia 28:299–731 306, DOI 10.1111/j.2153-3490.1976.tb00679.x
- [15] <http://www.wrf-model.org/index.php>, 23.12.2013 [online]
- [16] Mellor, G. L., Yamada, T., 1974: A hierarchy of turbulence closure models for planetary boundary layers. J. Atmos. Sci. 31: 1791 – 1806
- [17] Mellor, G. L., Yamada, T., 1982: Development of a turbulence closure model for geophysical fluid problems. Rev. Geophys. Space Phys. 20: 851- 875

- [18] Zdunkowski, W. G., Panhans, W.G., Welch, R. M., Korb, G. J., 1982: A radiation scheme for circulation and climate models. *Beitr. Phys. Atmos.* 55: 215 – 238
- [19] Nickerson, E. C., Richard, E., Rosset, R., Smith, D. R., 1986: The numerical simulation of clouds, rain, and airflow over the Vosges and Black Forest mountains: a meso-h model with parameterized microphysics. *Mon. Weather Rev.* 114: 398 – 414
- [20] Chaumerliac, N., Richard, E., Pinty, J. P., 1987: Sulfur scavenging in a mesoscale model with quasi-spectral microphysics: two-dimensional results for continental and maritime clouds. *J. Geophys. Res.* 92: 3114 – 3126
- [21] Sakakibara, H., 1979: A scheme for stable numerical computation of the condensation process with large time steps. *J. Meteorol. Soc. Jpn.* 57: 349 – 353
- [22] Siebert, J., Bott, A., Zdunkowski, W., 1992a: Influence of a vegetation-soil model on the simulation of radiation fog. *Beitr. Phys. Atmos.* 65: 93 - 106
- [23] Siebert, J., Sievers, U., Zdunkowski, W., 1992b: A one-dimensional simulation of the interaction between land surface processes and the atmosphere. *Boundary - Layer Meteorol.* 59: 1 – 34
- [24] Bartok, J., Babič, F., Bednár, P., Paralič, J., Kováč, J., Bartoková, I., Hluchý, L., Gera, M., 2012: Data mining for fog prediction and low clouds detection. *Computing and Informatics* 30:1441-1464, ISSN 1335-9150
- [25] Muller, M. D., Masbou, M., Bott, A., 2010: Three-dimensional fog forecasting in 709 complex terrain. *Q J R Meteorol Soc* 136:2189–2202, DOI 10.1002/qj.705
- [26] Fabian, D., de Dear, R., 2006: Application of Artificial Neural Network Forecasts to Predict Fog at Canberra International Airport, <https://www.cfa.harvard.edu/~wsoon/GreenArmstrong07-d/Fabbianetal07-ForecastFogCanberraAirport.pdf>
- [27] Nugroho, A. S., 2000: Fog Forecasting Using Self Growing Neural Network 'CombNET-II: A Solution for Imbalanced Training Sets: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.18.7997&rep=rep1&type=pdf>
- [28] Zazzaro, G., Pisano, F. M., Mercogliano, P., 2010: Data Mining to Classify Fog Events by Applying Cost-Sensitive Classifier. *International Conference on Complex, Intelligent and Software Intensive Systems*, pp. 1093-1098
- [29] Weymouth, G. T. et al., 2007: Dealing with uncertainty in fog forecasting for major airports in Australia. 4<sup>th</sup> Conference on Fog, Fog Collection and Dew, La Serena, Chile, pp. 73-76

- [30] Ebecken, F. F., 1998: Fog Formation Prediction In Coastal Regions Using Data Mining Techniques. International conference on environmental coastal regions No.2, Cancun, Mexico, pp. 165-174
- [31] Viademonte, S., Burstein, F., Dahni, R., Williams, S., 2001: Discovering Knowledge from Meteorological Databases: A Meteorological Aviation Forecast Study. Third International Conference on Data Warehousing and Knowledge Discovery (DaWaK). Conference proceedings, LNCS 2114, pp. 61-70. Munich, Germany
- [32] Beckenkamp, F., Pree, W., Feldens, M. A., 1998: Optimizations of the Combinatorial Neural Model. In Proceedings of 5th Brazilian Symposium on Neural Networks (SBRN'98), Belo Horizonte, Brazil, pp. 155-164
- [33] Acosta, G., Tosini, M., 2001: A Firmware Digital Neural Network for Climate Prediction Applications. Proceedings of IEEE International Symposium on Intelligent Control 2001, Mexico City, Mexico, ISBN 0-7803-6722-7
- [34] Koskela, T., Lehtokangas, M., Saarinen, J., Kaski, K., 1996: Time Series Prediction With Multilayer Perceptron, FIR and Elman Neural Networks. Proceedings of the World Congress on Neural Networks 1996, INNS Press, San Diego, USA, pp. 491-496
- [35] Rehm, F., 2004: Prediction of Aircraft Delay at Frankfurt Airport as a Function of Weather. Presentation from German Aerospace Center, Germany, 69 pp
- [36] Jan, Z., Abrar, M., Bashir, S., Mirza, A. M., 2009: Seasonal to Inter-annual Climate Prediction Using Data Mining KNN Technique. Wireless Networks, Information Processing and Systems. Vol. 20, pp. 40-51
- [37] Tan, P. N., Steinbach, M., Kumar, V., 2006: Introduction to Data Mining. Addison-Wesley, Boston, MA, 769 pp
- [38] Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., Wirth, R., 2000: CRISP-DM 1.0 Step-by-step data mining guide. Tech. rep., The CRISP-DM consortium
- [39] World Meteorological Organization, 2009: Manual on Codes. International Codes. Volume I.1. Part A – Alphanumeric Codes. WMO-No. 306. Secretariat of the World Meteorological Organization, Geneva, Switzerland, 506 p.
- [40] Breiman, L., 1984: Classification and regression trees. Chapman & Hall/CRC, London, 368 pp
- [41] Quinlan, J. R., 1987: Rule induction with statistical data - a comparison with multiple regression. Journal of the Operational Research Society 38:347-352
- [42] Mitchell, T.M., 1997: Machine Learning. McGraw-Hill, Inc., New York, NY, 432pp

- [43] Marzban, C., 1998: Scalar measures of performance in rare-event situations. *Wea Forecasting* 13:753-763
- [44] Mehrotra, K., Mohan, C.K., Ranka, S. 1997: *Elements of Artificial Neural Networks*. The MIT Press, Cambridge, MA, 334 pp
- [45] Fabbian, D., de Dear, R., Lelleyett, S. 2007: Application of artificial neural network forecasts to predict fog at Canberra international airport. *Wea Forecasting* 22:372-381, DOI 10.1175/WAF980.1
- [46] Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., Witten, I. H. 2009: The WEKA data mining software: An update. *SIGKDD Explor Newsl* 11(1):10-18, DOI 10.1145/1656274.1656278, URL <http://doi.acm.org/10.1145/1656274.1656278>
- [47] Quinlan, J. R., 1993: *C4.5: Programs for Machine Learning*. Morgan Kaufmann Publishers Inc., San Francisco, CA, 302 pp
- [48] Breiman, L., 2001: Random forests. *Machine learning* 45(1):5-32
- [49] Hastie, T., Tibshirani, R. et al., 1998: Classification by pairwise coupling. *The annals of statistics* 26(2):451-471
- [50] Schoelkopf, B., Burges, C. J. C., Smola, A.J., 1999: *Advances in kernel methods support vector learning*. MIT Press, Cambridge, MA, 376 pp
- [51] Keerthi, S. S., Shevade, S. K., Bhattacharyya, C., Murthy, K. R. K., 2001: Improvements to Platt's SMO algorithm for SVM classier design. *Neural Computation* 13(3):637-649
- [52] Gardner, M. W., Dorling, S. R., 1998: Artificial neural networks (the multilayer perceptron) - a review of applications in the atmospheric sciences. *Atmos Environ* 32:2627-2636
- [53] Wilks, D., 2006: *Statistical methods in the atmospheric sciences*, vol 91, 2<sup>nd</sup> edn. International Geophysics Series, Academic Press, New York, NY, 627 pp
- [54] Murphy, A. H., 1996: The Finley affair: a signal event in the history of forecast verification. *Wea. Forecasting*, 11, 3-20
- [55] Murphy, A. H., 1991: Forecast verification: Its complexity and dimensionality. *Mon. Wea. Rev.*, 119, 1590-1601
- [56] Murphy, A. H., 1993: What is a good forecast? An essay on the nature of goodness in weather forecasting. *Wae. Forecasting*, 8, 281-293
- [57] Donaldson, R. J., Dyer, R. M. and Krauss, M. J., 1975: An objective evaluator of techniques for predicting severe weather events. *Preprints, Ninth Conf. on Severe Local Storms*, Norman, OK, Amer. Meteor. Soc., 321-326

- [58] Doswell, C. A., III, R. Davies-Jones, and D. Keller, 1990: On summary measures of skill in rare event forecasting based on contingency tables. *Wea. Forecasting*, 5, 576–585
- [59] Gandin, L. S., and A. Murphy, 1992: Equitable skill scores for categorical forecasts. *Mon. Wea. Rev.*, 120, 361–370.
- [60] Murphy, A. H. and Winkler R. L., 1987: A general framework for forecast verification. *Mon. Wea. Rev.*, 115, 1330–1338
- [61] Kohavi., R, John, G. H., 1997: Wrappers for feature subset selection. *Artificial Intelligence* 97(1-2):273-324
- [62] Marzban, C., G. J. Stumpf, 1998: A neural network for damaging wind prediction, *Weather and Forecasting*, Vol. 13, No.1, 151-163
- [63] Lakshmanan, V., Elmore, K. L., Richman, M. B., 2010: Reaching scientific consensus through a Almazroui, M. A., Al Khalaf, A. K., Abdel Basset H .M., and Hasanean H. M., 2009: Detecting competition. *Bulletin of the American Meteorological Society* 91(10):1423-1427
- [64] World Meteorological Organization, 2001: Guide on the Global Data-Processing System. WMO-No. 305. Secretariat of the World Meteorological Organization, Geneva, Switzerland, 204 p.
- [65] Bartokova, I., Bott, A., Bartok, J., and Gera, M., 2015: Fog prediction for road traffic safety in a coastal desert region: Improvement of nowcasting skills by the machine-learning approach. *Boundary-Layer Meteorol.*, 157, p. 501-516. DOI 10.1007/s10546-015-0069-x.
- [66] Membery, D.A, 1983: Low-Level winds during the Gulf Shamal, *Weather* Vol 38: pp. 18-24
- [67] Rokach, L. and Maimon, O., 2014: Splitting Criteria. *Data Mining with Decision Trees*, pp. 61-68. doi: 10.1142/9789814590082\_0005
- [68] Rokach, L. and Maimon, O., 2014: Decision Forests. *Data Mining with Decision Trees*, pp. 99-149. doi: 10.1142/9789814590082\_0009
- [69] Nowozin, S., 2012: Improved information gain estimates for decision tree induction. *Proceedings of the 29th International Conference on Machine Learning (ICML 2012)*, Edinburgh, Scotland, UK, pp. 391-396
- [70] Gultepe, I., Zhou, B., Milbrandt, J., Bott, A., Li, Y., Heymsfield, A. J., Ferrier, B., Ware, R., Pavolonis, M., Kuhn, T., Gurka, J., Liu, P. and Cermak, J., 2015: A review on ice fog measurements and modeling. *Atmos. Research*, 151, 2-19.