

Aplikace genetických algoritmů v procesu plánování výroby ve společnosti Mitas, a. s.

Roman Kasal, Petr Klímek, Jozef Říha, Pavel Stríž

Genetické algoritmy

Genetické algoritmy představují stochastickou prohledávací metodu, která je inspirována genetickými principy jako je přirozený výběr, křížení a mutace. I když se první pokusy o modelování evoluce na počítači objevily už v padesátých letech, za objevitele genetických algoritmů tak, jak je známe dnes, je považován John Holland, který položil základy této disciplíny v sedmdesátých letech.

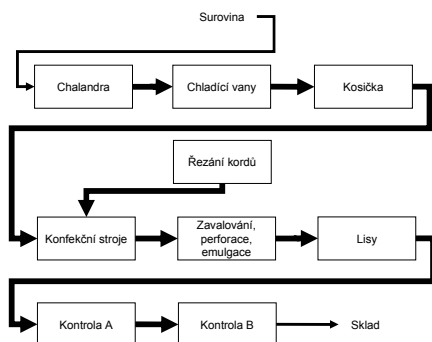
Aplikace genetických algoritmů

Pro aplikaci genetických algoritmů rozhodla složitost výrobního procesu produkce motopláštěů ve společnosti Mitas, a. s., kde tento proces dokáže optimalizovat snad jen řízená metoda pokus-omyl. Genetické algoritmy právě tuto metodu více než vylepšily a jsou snad jediným uvažovaným nástrojem pro řešení velmi složitých problémů s velkým množstvím proměnných.

Aplikace genetických algoritmů bude stručně popsána v pěti číslovaných krocích.

1. Sběr potřebných informací

Časově nejnáročnější část. Obrázek (1) schematicky ukazuje nejdůležitější cíl úkolu – popis provozu pro následné řešení genetickými algoritmy.



(1) Schéma provozu

2. Predikce množství produktů potřebného k výrobě

- regresní analýza se sezónní složkou
- harmonická analýza
- SARIMA modelování
- umělé neuronové sítě

3. Vytvoření matematického modelu provozu v úzkém místě

Model, jak můžeme shlédnout na obrázku (2), zahrnuje zejména:

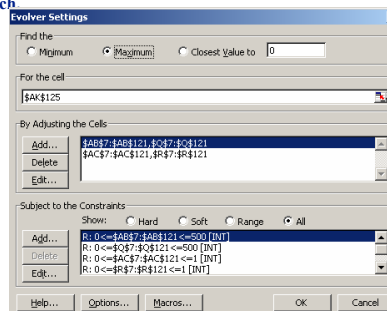
- množství, které je třeba vyrobit,
- skladové zásoby,
- čas lisování,
- atd.,
- dále nejdůležitější omezení spočívající v 22,5 hodinách provozu za den, které je nutné plně využít.

	A	C	D	P	Q	R	S	T	U	V	W	X	Y	Z	AA	AB	AC	AD	AE
1	1	počet lisů BOM 40"																	
2	5	počet lisů BOM 30"																	
3	15	počet lisů BOM 40"																	
4																			
5																			
6	č. výrobku	doba lisování	počet lisů	počet lisů	GA vyr.	GA ano/ne	nutná výroba	vyrobeno	potřeba	chybí	počet hodin na lis	počet hodin na lis	počet hodin na lis	celkem m	sklad	GA vyr.	GA ano/ne	nutná výroba	vyrobeno
7	21212	15,3	15	50	1	0	0	0	0	0	0	0	0	0	50	79	0	0	0
8	22021	15,3	5	0	27	0	0	0	0	0	0	0	0	0	0	26	0	0	0
11	22041	15,3	5		335	0	1	335	320	0	0	42,71	0	42,7	15	334	0	1	334
12	22043	22,3	5		50	0	0	0	0	0	0	0	0	0	0	2	0	0	0
13	22049	22,3	5		56	0	0	0	0	0	0	0	0	0	0	141	0	0	0
14	22051	15,3	5		314	0	1	314	300	0	0	40,04	0	40	14	367	0	1	367
40	24432	32,3	15		16	0	0	0	0	0	0	0	0	0	0	89	0	0	0
41	24532	15,3	15		403	0	1	403	400	0	51,4	0	0	51,4	3	398	0	1	398
42	24544	15,3	15		66	0	0	0	0	0	0	0	0	0	0	39	0	0	0
44	24643	22,3	15		500	0	1	500	500	0	92,9	0	0	92,9	0	500	0	1	500
45	24649	22,3	15		17	0	0	0	0	0	0	0	0	0	0	55	0	0	0
46	24796	22,3	15		160	0	1	160	150	0	29,7	0	0	29,7	30	141	0	1	141
79	25141	17,3	1		68	0	0	0	0	0	0	0	0	0	0	69	0	0	0
80	25250	17,3	1		156	0	1	156	156	0	0	0	0	22,49	22,5	1	156	0	1
91	24997	22,3	15		27	0	0	0	0	0	0	0	0	0	0	30	0	0	0
92	24134	32,3	15		71	0	0	0	0	0	0	0	0	0	0	5	0	0	0
93	24167	22,3	15		301	0	1	301	300	0	56,9	0	0	56,9	1	302	0	1	302
94	24403	32,3	15		300	0	1	300	300	0	80,8	0	0	80,8	0	302	0	1	302
116	52038	15,3	5		30	0	0	0	0	0	0	0	0	0	0	53	0	0	0
116	52010	15,3	5		205	0	1	205	150	0	26,14	0	0	26,1	55	181	0	1	181
117	61011	15,3	5		55	0	0	0	0	0	0	0	0	0	0	124	0	0	0
121	52020	17,3	1		12	0	0	0	0	0	0	0	0	0	0	27	0	0	0

(2) Matematický model provozu

4. Využití genetických algoritmů při řešení maximalizace produkce – Evolver

K řešení problému byl velmi nápomocen již vyvinutý software Evolver od společnosti Palisade, který je určen k produktu Microsoft Excel. Dle vložených proměnných nástroj zvláště u každého výrobku řeší, zda má být vyroben a v jakém množství, a to pro každý den ze 14 plánovaných.



(3) Jednoduchý princip použití programu

Evolver během několika vteřin využil kapacity všech lisů a následně již jen optimalizoval výrobu tak, aby maximalizoval výstup s penalizací přechodu z jedné receptury na novou mezi jednotlivými dny.

5. Problém obchodního cestujícího

Problém obchodního cestujícího je sice označen jako NP problém, ale algoritmus je samozřejmě možné propůjčit i například problémům typu stanovení vhodného pořadí receptur do výroby s neukončenou Hamiltonovou kružnicí při penalizaci z přechodu mezi výrobky, kde například penalizace přechodu z výrobku A na výrobek B může být odlišná pro opačné pořadí (přechod z výrobku B na výrobek A), což je přesně náš případ. Konečnou se toto specifikum může objevit i v realitě u problému obchodního cestujícího z důvodu jednosměrných ulic. Úkol byl řešen v Matlabu.

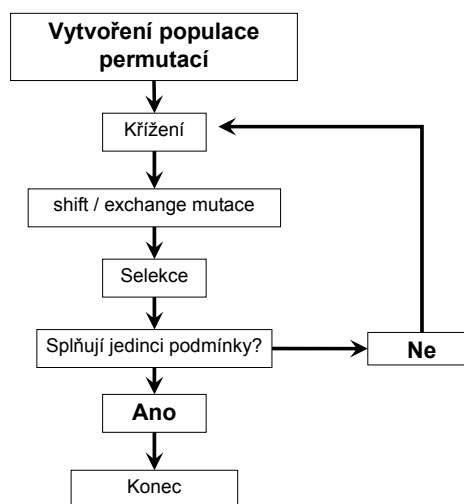


Diagram aplikace genetických algoritmů v problému obchodního cestujícího

Výsledná hodnota 167 minut při výměně 105 receptur, tzn. 104 změn, je v porovnání s počáteční náhodnou permutací pořadí receptur (1162 minut) velmi dobrý výsledek. Řešení představuje sedmínásobně lepší využití času.

Závěr

Genetické algoritmy se opravdu jeví jako prozatím nejlepší nástroj k výpočtu složitých problémů, které nelze řešit analyticky. Správné algoritmování problému a využití vhodné perturbační metody může ušetřit velmi mnoho času při řešení, což se ostatně potvrdilo.

Kontakty

Roman Kasal
Petr Klímek
Jozef Říha
Pavel Stríž

kasal@fame.utb.cz
klimek@fame.utb.cz
riha@fame.utb.cz
striz@fame.utb.cz


Ústav informatiky a statistiky
FAME UTB Zlín
Mostní 5139
Zlín 760 01



CHANGE POINT ANALYSIS OF ATMOSPHERIC RADIATION PROFILES

LUBOŠ PRCHAL

lubos.prchal@st.cuni.cz
Department of Statistics and Probability, Charles University, Prague



SUMMARY

The poster presents a statistical analysis of the dependence of atmospheric radioactivity on the altitude. As a theoretical model explaining the physical background of this process is not known, two parametric regression models based on Richards growth curve are proposed. We discuss several computational challenges coming from the parameter estimating procedure and we focus on the choice of software suitable for calculations. The second part is devoted to the statistical analysis of changes in variance of our measurements. It appears that the random terms cannot be modelled by a series of i.i.d. random variables. On the contrary, the functional model consisting of three segments with two unknown change points seems to be much more appropriate. Assuming normal distribution of the error terms we propose test statistic for the detection of the linear trend in the variance and show its limit distribution. To complete the work, we estimate the change points and the variance parameters using several methods and study their properties.

I METEOROLOGICAL EXPERIMENT

Analyzed data come from Prague-Libuš upper air meteorological station of the Czech Hydrometeorological Institute, where every month the vertical profiles of beta and gamma radioactivity are measured by the radioactivity sonde system. The radioactivity sensor consisting of two Geiger-Müller gamma and beta tubes is a part of meteorological balloons which ascends from the earth's surface up to 35 km and detects short current pulses coming from the interaction between the radiation and the tube wall material.

After several "re-calculations" the complicated measurement process results into the data pairs $(x_i, y_i)_{i=1}^n$, where x represents the altitude and y the average number of pulses per second in the fixed altitude x . Let us note that y is proportional to the radiation intensity.

II APPLIED REGRESSION MODELS

The first aim of the analysis was to suggest a parametric regression model $Y_i = m(X_i) + \varepsilon_i$, where $m(\cdot)$ represents mean amount of radiation and ε_i a random "error" term. As described by Hlubinka (2004), the models $m(\cdot)$ are based on Richards growth curve $R(x)$ and its derivative $r(x)$. Unfortunately, Richards curve itself does not describe properly the measurements in low atmospheric layers. That's why we propose two extended additive models. The first model consists of $r(x)$ and a simple linear function, meanwhile the second model of $r(x)$ and logistic growth curve being of the form

$$m_1(x) = r(x) + cx + k;$$
$$m_2(x) = r(x) + c \left(1 + \exp\{-f(x-g)\} \right) + k.$$

III COMPUTATIONAL CHALLENGES

We used the classical Least Squares method to estimate the unknown parameters of suggested models $m_1(x)$ and $m_2(x)$. Although the principle seems to be quite simple, the minimization procedure must be performed numerically resulting in several difficult computational problems and challenges.

SETTING UP THE INITIAL PARAMETERS

Numerical methods need initial parameters estimators to start the procedure with. The key to set up appropriate initial parameters is to understand their interpretation. The choice of starting points resulting from the analysis of the parameters is described in detail by Hlubinka (2004).


NUMERICAL NON-STABILITY

The numerical stability of the minimization procedure is influenced by several factors. Because of the analytic form of $r(x)$ one must pay attention on representation of small numbers, exclude non-sense values of parameters and think about appropriate data scaling.


CHOICE OF SOFTWARE

Almost every statistical or mathematical software offers some implementation of numerical methods suitable for the Least Squares minimization. However, not all implementations are able to solve our, quite complicated, problem with 6 (or 8) parameters to be estimated. Notice that we wish not only to obtain the reasonable fit of the data, but we require that the estimated submodels (e.g. $r(x)$ and the logistic curve) and their parameters are interpretable. To obtain the best possible parameterization we applied the optimization procedure implemented in several software packages. Finally, we decided for Matlab, Release 13, and its lsqcurvefit function.



Methods implemented in R and S Plus softwares do not converge at all, even if the initial parameters are set up to the "optimal" solution provided by Matlab.



Mathematica 5 offers, as default, one extremely rapid function (FindFit). However, it sometimes results into non-sense and uninterpretable parameterizations as shown in the figure.



Matlab, Release 13, contains two suitable functions. Presented results were obtained by more sophisticated lsqcurvefit function from the Optimization Toolbox (right figure), while the simpler nlinfit function from the Statistics Toolbox convergates into uninterpretable parameterizations (left figure).



IV ANALYSIS OF VARIABILITY

Radioactivity measurements evidently show heteroscedasticity. The goal was to suggest a suitable parametric model, estimate its parameters and study its properties.

PARAMETRIC MODEL


It appears that the errors ε_i cannot be modelled by a series of i.i.d. random variables. To gain an idea about a suitable parametric model for the variance, we fitted squared errors using a kernel estimator as shown in the figure. Based on this estimation, the parametric functional model for $\sigma^2(x_i) = \text{var } Y_i$ in the form of

$$\sigma^2(x) = \sigma^2 + \delta^2 \left[\frac{x - x_s}{x_t - x_s} I(x \in (x_s, x_t)) + I(x \in (x_t, \infty)) \right]$$

seems to be much more appropriate. Having two unknown real parameters $\sigma^2 > 0$ and $\delta \geq 0$ it consists of three segments and may change its behavior in two unknown altitudes (two unknown change points x_s and x_t).

CHANGE POINT DETECTION

A natural question appears: Is the variance constant or not? More precisely, the question is how to perform a statistical test of the hypothesis of a constant variance against the alternative of two unknown change points. Assuming independent $Y_i \sim N(m(x_i), \sigma^2(x_i))$ and being inspired by Gupta and Ramanayake (2001), we propose a test statistic and show its limit distribution. Main ideas and key steps are summarized in the box below. The formal, very long and tedious proof is available on request.



1 TRANSFORMATION

Assuming independent and normal U_i we get

$$W_j = \frac{\sigma_{2j-1}^2 U_{2j-1}^2 + U_{2j}^2}{\sigma_{2j}^2} \sim \text{Exp}(\sigma_{2j-1}^{-2})$$

2 MAXIMUM LIKELIHOOD APPROACH

For fixed change points s and t we have ML ratio

$$l_n(\sigma^2, \delta^2) = \prod_{j=1}^{n/2} \frac{f_n(W_j)}{J_n(W_j)}$$

Using the sum-type principle, for unknown s, t we obtain the test statistic in the form of

$$T = \text{const.} \cdot \frac{\sum \gamma_j W_j}{\sum W_j}$$

3 MOMENTS OF T

To calculate moments of T denote

$$Z_j = W_j \left(\sum_{k=1}^{n/2} W_k \right)^{-1}$$

The vector $(Z_1, Z_2, \dots, Z_{n/2})'$ has $n/2 - 1$ dimensional Dirichlet distribution with all parameters equal 1. Moments of T can be easily calculated using moments of Z for fixed n .

4 LIMIT DISTRIBUTION

The test statistic has asymptotic normal distribution, i.e.


$$V = \frac{T - ET}{\sqrt{\text{var } T}} \sim N(0, 1)$$

and $n = 100$ is enough to use its asymptotic properties.



ESTIMATORS

As expected, we rejected the null hypothesis for all data sets. To complete the study we have to estimate the change points and the parameters σ^2 and δ^2 of the segmented model. We suggested estimators based on the Least Squares method, Weighted Least Squares method and the L_1 approach using Iteratively Weighted Least Squares method and the linear programming. L_1 approach seems to be satisfactory for the change points estimations, on the contrary LS and WLS methods are much more appropriate for estimating the variance parameters.

The optimal estimator combines the L_1 -estimator for change points with the WLS-estimator of variance parameters σ^2 and δ^2 .



Warning !!! As shown in the figures, the change points estimators based on the Least Squares methods (blue line) are extremely sensitive to the "outliers". On the contrary, L_1 approach (red line) provides much more stable estimations.



V FUTURE PLANS

The presented work should be understood as the first step in analyzing atmospheric radiation. However, a lot of interesting statistical and meteorological questions still remain without satisfactory answers. Among them, we would like to focus mainly on the following:

- how to detect a seasonality in our measurements when considered as functional data;
- how to estimate quantiles of the radiation in different altitudes to be able to set up an alarm system;
- how to improve numerical methods to obtain more stable parameterizations of proposed models.

Acknowledgement. Author would like to express his thanks to Prof. Jaromír Antoš for his generous support, valuable comments and help. The poster was supported by grants GACR 201/03/0945 and MSM 11320008.

[1] Gupta A.K. & Ramanayake A. (2001). Change points with linear trend for the exponential distribution. J. Statist. Plann. Inference 93, 181–195.
[2] Hlubinka D. (2004). Growth curve approach to profiles of atmospheric radiation. Compstat 2004, Physica-Verlag, Heidelberg, 1181–1192.
[3] Prchal L. (2004). Nonparametric estimators for the functional data analysis (in Czech). Master thesis, MFF UK, Praha.