

SPC v případě autokorelovaných dat

Jiří Michálek, Jan Král

OSSM, 21.6.2012

Pojem korelace

- Statistická vazba mezi veličinami
- Korelace vs. stochastická nezávislost
- Koeficient korelace = míra lineární vazby mezi veličinami
- Autokorelace = korelace mezi sousedícími daty v jedné časové řadě
- Autokorelační funkce, odhad autokorelace pořízený z dat

Předpoklady pro Shewhartovy diagramy

- Normálně rozdělený znak jakosti
- Sbíraná data z procesu jsou nezávislá jak mezi podskupinami, tak i uvnitř podskupin
- Parametr polohy a úroveň variability jsou konstantní
- Regulační meze jsou pak počítány na základě těchto předpokladů

Porušení předpokladů



- Závislost mezi daty v rámci podskupiny – může mít vliv na vyhodnocování průběhu diagramu, odhad směrodatné odchylky pro výpočet regulačních mezí
- Závislost mezi podskupinami – může podstatně ovlivnit výskyt falešných poplachů

Podezření na autokorelaci

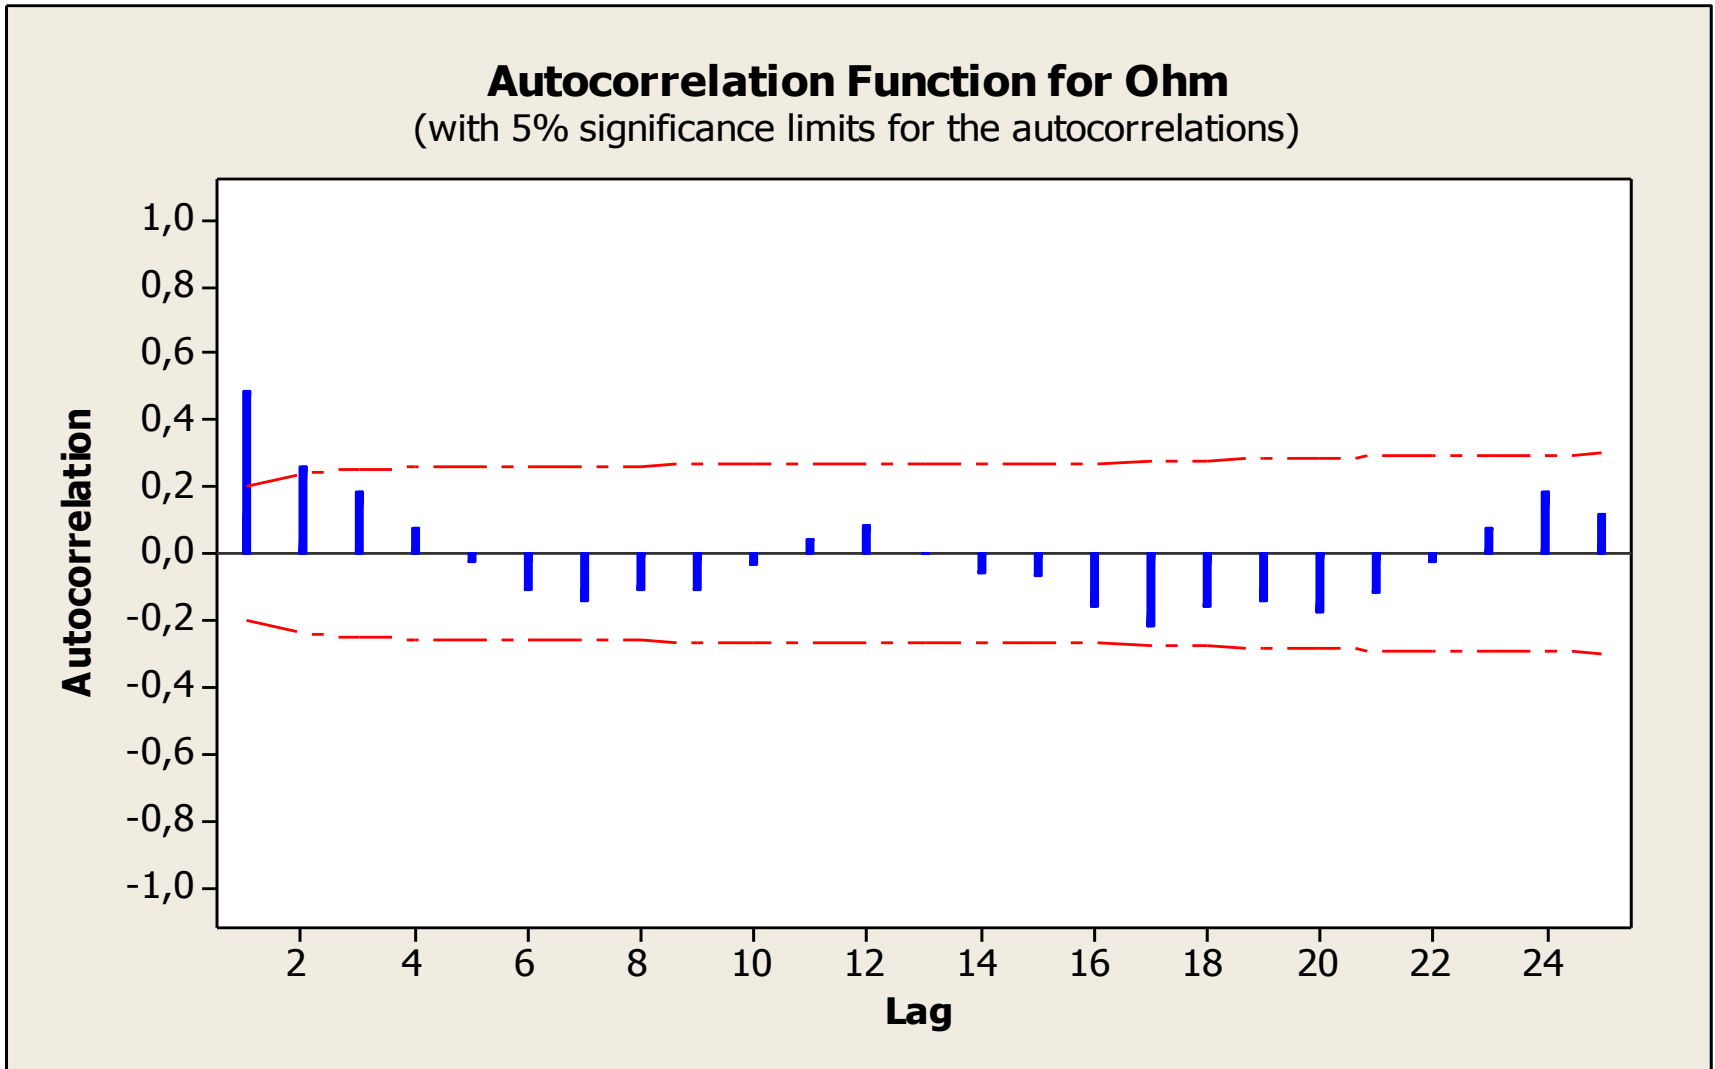
- Vysoká frekvence sběru dat, hlavně při automatickém odběru
- Fyzikální důvody – např. vliv teploty, vliv okolního prostředí
- Setrvačnost v datech vyvolaná např. způsobem měření, systematickými vlivy
- Záměrná manipulace s daty – opisování, falšování

Příklad regulačního diagramu

I-MR Chart of Ohm



Odhad autokorelační funkce



Co říká koeficient korelace?

- Koeficient korelace je mezi -1 a 1
- Čím je koeficient korelace v absolutní hodnotě blíže k 1, tím je větší stochastická vazba mezi veličinami
- Čím je koeficient korelace v absolutní hodnotě blíže 0, tím je menší stochastická vazba mezi veličinami
- Pro hodnoty -1 a 1 stochastická vazba přechází dokonce ve funkční lineární vztah

Test korelace mezi 2 veličinami

- Data jsou spárována do dvojic
- Vypočte se odhad r koeficientu korelace
- Vypočte se statistika

$$t = r \sqrt{(n-2)} / \sqrt{(1-r^2)} ,$$

která za nulové hypotézy o nekorelovanosti má
přibližně t-rozdělení o $n-2$ stupňů volnosti
(n je počet dvojic)

Pozn. U normálně rozdělených veličin
nekorelovanost = nezávislost

Jak se s korelací vyrovnat?

- Pro praktické účely má cenu se zabývat korelací, pokud odhad koeficientu korelace má hodnotu nad 0,75 – 0,80
- Znaky kvality na jednom výrobku mohou být vzájemně korelovány – vylepšení jednoho znaku může vyvolat zhoršení jiného znaku
- Použití vícerozměrných regulačních diagramů – odhad korelační matice

Jak se s korelací vyrovnat?

- Při zjištěné silné korelaci uvnitř podskupin je nutno toto zohlednit při výpočtu regulačních mezí – zásadní roli hraje špatný odhad směrodatné odchylky na základě výběrového rozpětí či výběrové směrodatné odchylky počítaných uvnitř podskupin
Korelace může způsobit podhodnocení úrovně variability a toto může vést ke zvýšenému počtu falešných poplachů, protože regulační meze jsou pak blíže u sebe

Jak se s korelací vyrovnat?

- Zvláště je nutné si dát pozor u regulačního diagramu pro individuální data při sériové korelaci – odhad založený na klouzavém rozpětí opět může podhodnotit úroveň variability
- V tomto případě v praxi stačí se zaměřit pouze na autokorelaci 1.řádu a použít faktor $\sqrt{1 - r^2}$ pro úpravu regulačních mezí

Jak se s korelací vyrovnat?

- Pro výpočet klasických regulačních mezí nepoužijeme $Rbar$ či $sbar$, ale jejich hodnoty získané z dat podělíme právě faktorem $\sqrt{1 - r^2}$, čímž dosáhneme rozšíření regulačních mezí
- Pokud jsou mezi daty autokorelace vyšších řádů, je obvykle možno v praxi je ignorovat

Jak se vyrovnat s korelací?

- Komplikovanější přístup je založen na nalezení vhodného modelu pro sledovanou časovou řadu (AR, ARMA, ARIMA či další modely) a pracovat s rezidui získanými při použití vhodného modelu
- Obvykle se vyžaduje, aby rezidua byla vzájemně nekorelovaná se střední hodnotou nula a konstantní úrovní variability (či dokonce normálně rozdělená) a na jejich sledování pak lze použít klasické Shewhartovy regulační diagramy

Příklad na úpravu mezí

- Na následujícím diagramu je vidět, že první 3-4 zleva, které jsou mimo regulační meze, by mohly znamenat pouze falešný poplach
- Je nutné prošetřit autokorelaci a zjistíme, že korelační koeficient mezi sousedícími daty bude významný, jeho odhad je sice pouze 0,48, ale je mimo konfidenční meze

Příklad na úpravu mezí

- Původní meze pro individuální hodnoty:

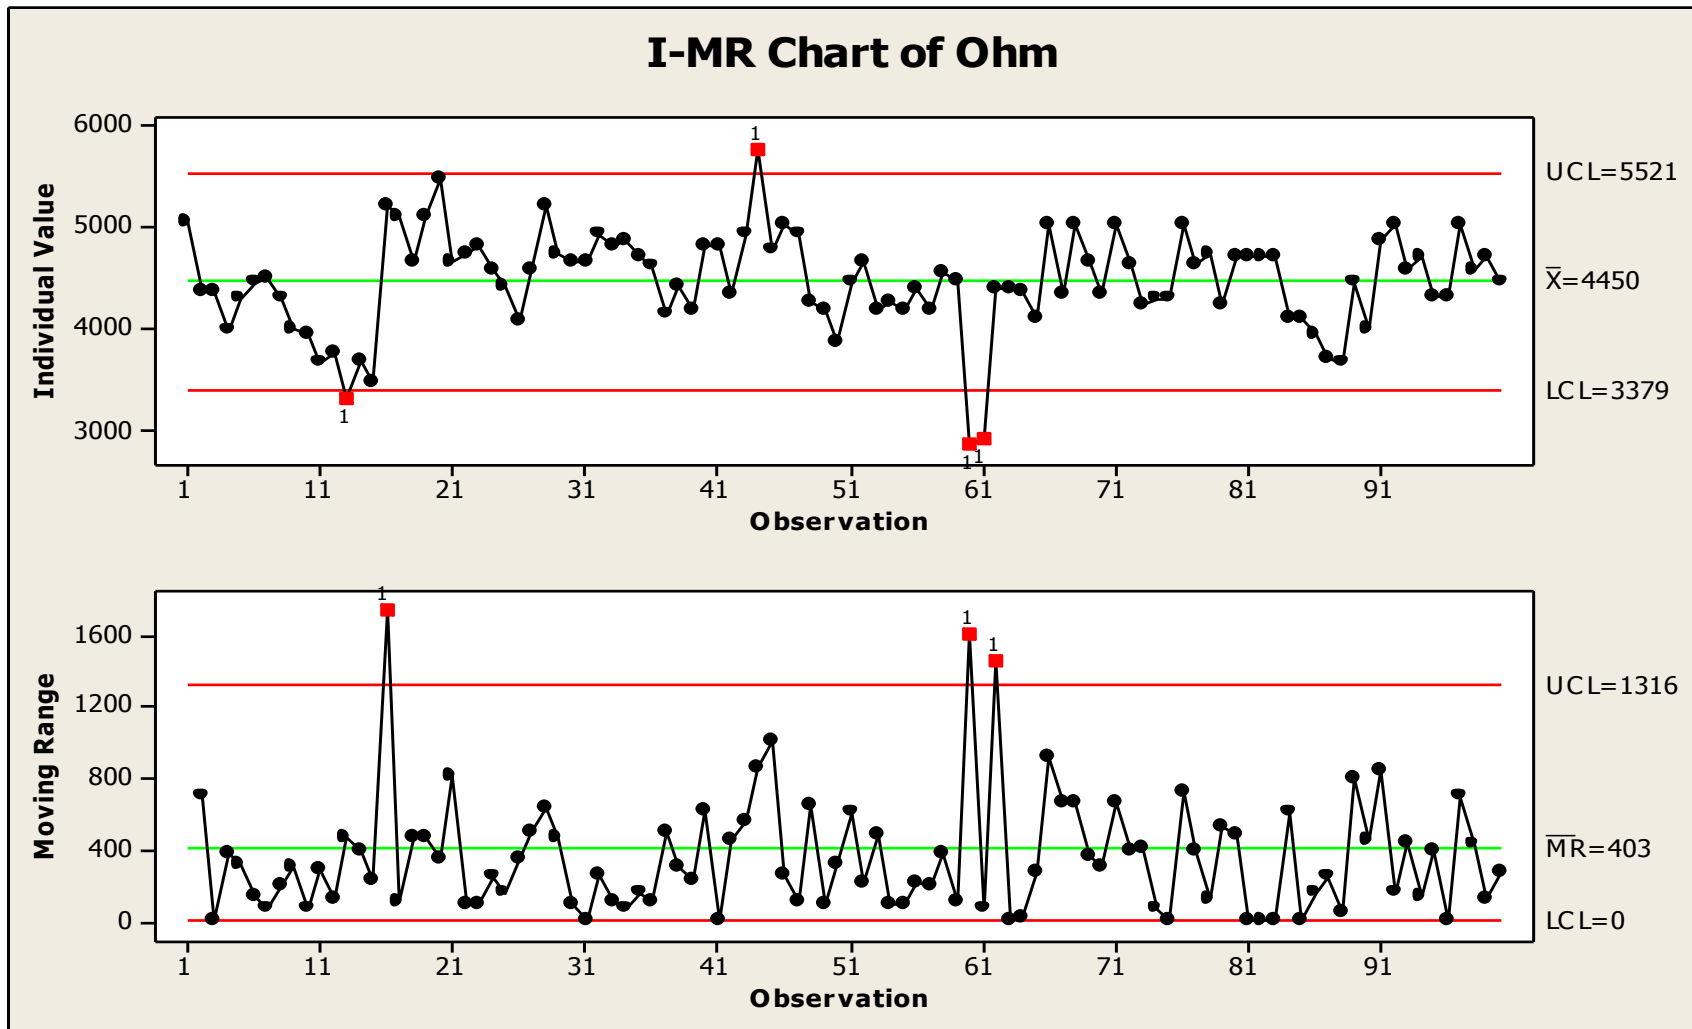
$$UCL = 5387, LCL = 3514$$

$$CL = 4450$$

Faktor opravy je při $r = 0,4845$ roven $0,8748$ a přepočtené meze jsou:

$$UCL = 5521, LCL = 3379$$

Graf s upravenými mezemi



Použití modelu časové řady

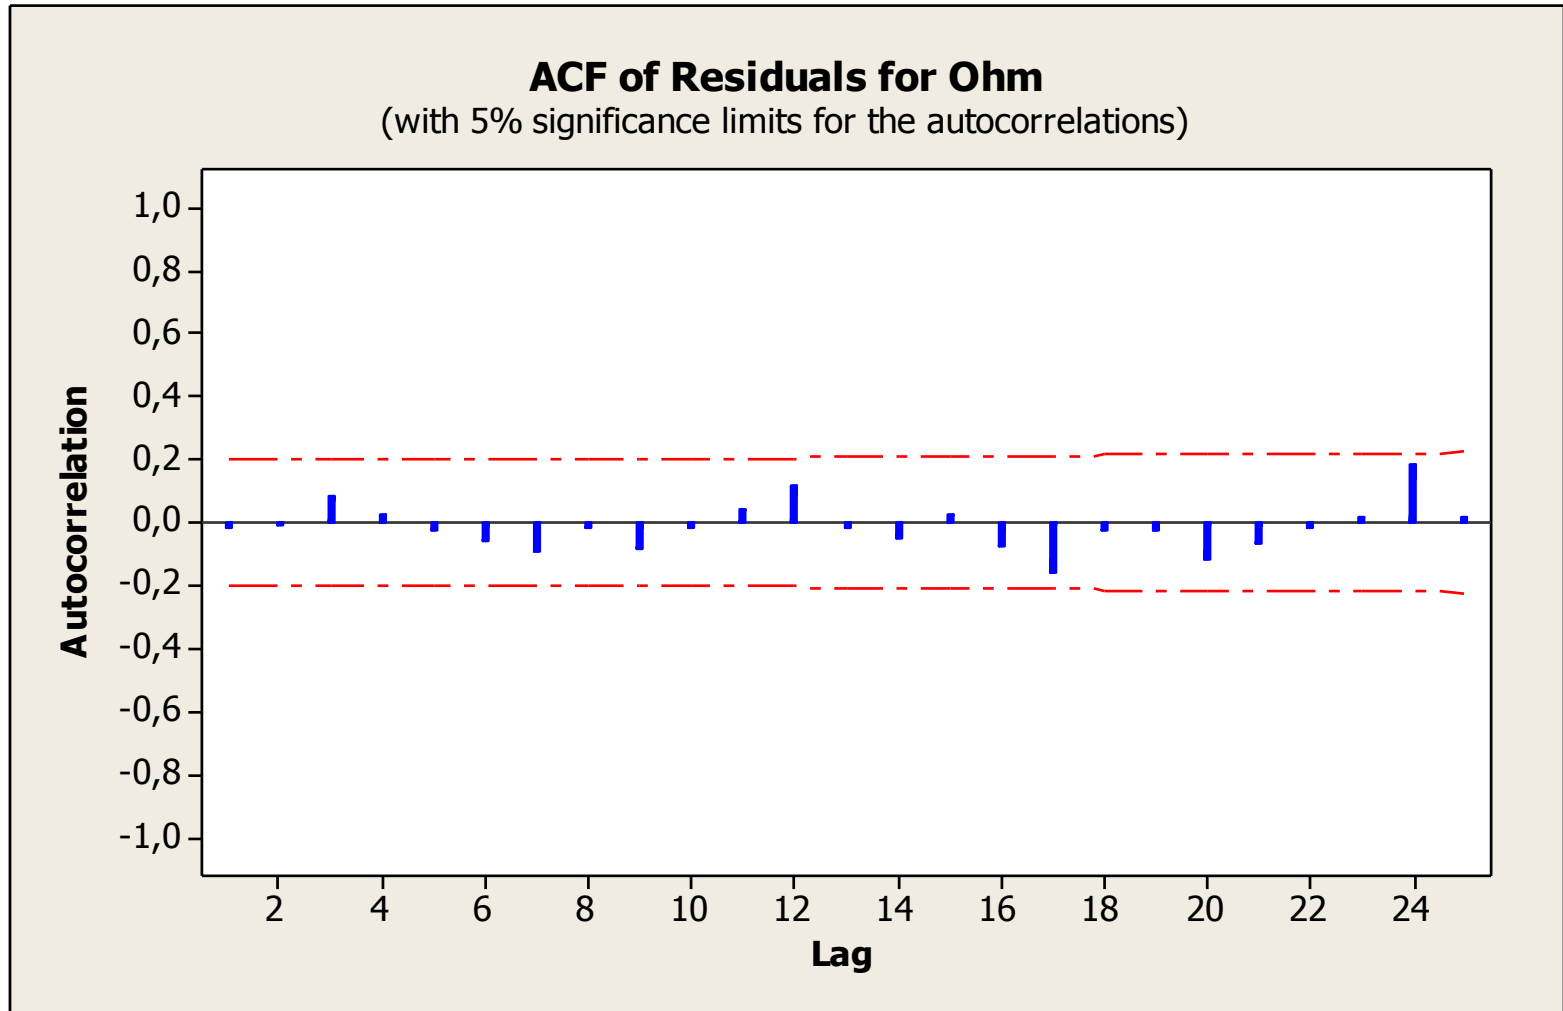
- Na základě odhadu autokorelační funkce budeme uvažovat model typu AR(1):

$$X(i+1) = \mu + \alpha X(i) + e(i+1),$$

kde chyby jsou normálně rozdělené se střední hodnotou 0 a nezávislé, μ je aditivní konstanta



Vhodnost modelu posoudíme podle chování reziduí a průběh původního procesu pomocí regulačního diagramu pro rezidua

Použití modelu časové řady




Použití modelu časové řady

Summary for Res(Ohm)



95% Confidence Intervals



Anderson-Darling Normality Test

A-Squared	0,67
P-Value	0,079

Mean	-4,33
StDev	417,13
Variance	173996,21
Skewness	-0,02060
Kurtosis	1,77335
N	100

Minimum	-1597,99
1st Quartile	-296,75
Median	-60,62
3rd Quartile	224,53
Maximum	1232,80

95% Confidence Interval for Mean

-87,09	78,44
--------	-------


95% Confidence Interval for Median

-116,23	62,65
---------	-------

95% Confidence Interval for StDev

366,24	484,57
--------	--------

Použití modelu časové řady



Použití modelu časové řady

Nalezený model má tvar:

$$X(i+1) = 2262,73 + 0,4922X(i) + e(i+1),$$

kde rezidua jakožto odhady chyb mají rozdělení $N(\mu, \sigma^2)$.

$$\mu \approx -4,33 \quad \sigma \approx 417,13$$

Srovnání obou přístupů

Lze říci, že přístup založený na úpravě regulačních mezí se zdá přísnější, ale v žádném případě si oba přístupy neodporují a možné ovlivněné podskupiny označily podobně.

Je zřejmé, že přístup založený na úpravě mezí je daleko jednodušší, přístup založený na modelování časové řady vyžaduje již vhodný software.