

Analýza vývojových trendů a časových řad

1. Analýza vývojových trendů (AVT)

AVT = časové změny ukazatelů (nejen absolutních) = HORIZONTÁLNÍ ANALÝZA
(tzv. analýza po řádcích)

Trend může být reprezentativnější než vlastní hodnota ukazatele (srovnání), zvláště v přechodových stavech (zahájení činnosti, fúze atd.)

	Rok 0	Rok 1	Rok 2	Rok 3
U_1					
U_2	-20	80	40	50	horizontální analýza
U_{21}		5			
U_{22}		10			
U_{23}		15			
U_3		analýza komponent = vnitřní struktura ukazatele			
U_4				= vertikální analýza = procentní analýza	

Princip: minulé chování firmy je často dobrým indikátorem chování budoucího (PREDIKCE)

V každém případě je současný stav východiskem (základnou) budoucích aktivit, dokonce je může v jistém smyslu i předurčovat.

Predikovatelnost:

- náhlé změny se objevují jen zřídka (chování X výstupy)
- existují aspirace podniku do budoucna (cíle, záměry)
- jsou známy klíčové faktory (vnitřní i podstatného okolí) a jejich změny

Analýza trendu = kinematika ukazatele $\hat{=}$ technická analýza (Jak?)

Analýza vlivu faktorů = dynamika ukazatele $\hat{=}$ fundamentální analýza (Proč se ukazatele vyvíjí, jak se vyvíjí?)

Vertikální analýza se využívá k:

- identifikaci nejzávažnějších změn komponentů a tím i k identifikaci klíčových faktorů
- ke srovnání (mezipodnikovému)


2. Analýza časových řad

Časová řada = posloupnost údajů ekvivalentně rozložená v čase => JEDNODUCHOST ZPRACOVÁNÍ DAT

Dostatečný počet kvalitních (=srovnatelných) dat – průměr i rozptyl konstantní <= korelace a autokorelace => stovky (desítky) dat, či jejich dvojic

Zaměřeno na predikci.

Převažuje kinematický pohled, místo dynamických analýz



Cíl (zpracování časových řad)

- od kinematických metod k dynamice => PRINCIPÁLNÍ NÁSKOK FUNDAMENTÁLNÍCH ANALYTIKŮ
- od lineárních postupů k nelineárním
- od nerobustních modelů k robustním (vůči předpokladům i datům)

Úlohy analýzy časových řad

1. filtrace dat
2. odhad trendu (vyrovnání, regrese)
3. analýza složek
4. odhad korelace a autokorelace
5. modely časových řad (matematické) a jejich predikce

FILTRACE

Filtrace = takový odhad informační složky dat, který minimalizuje (potlačuje) vliv jejich rušivých složek

Lineární filtr

- každý element chyby má stejnou váhu
- minimalizuje rozptyl chyb výsledku

Gnostický filtr

- malé odchylky mají plnou váhu, velké mají tím menší váhu, čím jsou odlehlejší
- necitlivý vůči krátkodobým výkyvům
- maximalizuje se informace obsažená ve výsledku

ODHAD TRENDU

Princip: srovnání po sobě jdoucích hodnot ukazatele (starší U_1 a nová U_2) – růst, pokles

Změna $= U_2 - U_1$
Rychlost změny $= (U_2 - U_1) / \Delta T$] → NEVHODNÉ pro víceleté řady („svítí – nesvítí“)
↓
Vyrovnání dat jednoduchou hladkou funkcí = přímka (tzv. lineární regrese – metoda nejmenších čtverců)

2.3. ANALÝZA SLOŽEK ČASOVÉ ŘADY

Složky

- a) konstanta
 - b) lineární složka
 - c) kvadratická složka atd.
 - d) periodická složka
-] → lineární regrese – viz výše
] → vše směřuje k predikci

Metoda jejich určení – odečítání členů výchozí řady

Ad a) vytvoření rozdílové řady $U_i - U_{i-1} \Rightarrow$ odstraníme konstantní složku postupným opakováním tvorby rozdílové řady

Ad b) atd.

2.4 KORELACE A AUTOKORELACE

Koeficient korelace $= 1 \Leftrightarrow$ přímá úměra
 $= -1 \Leftrightarrow$ nepřímá úměra

Významnost korelačních koeficientů

- jejich číselnou hodnotu lze podrobit testu, zda jde o skutečnost či náhodnou závislost (hypotézy)
- vyžaduje to vysoký počet (stovky) srovnatelných dat (mimo jiné konstantní průměry a rozptyly)

Koeficient autokorelace (=závislost U_i na U_{i-d})

Autokorelace = vzájemná korelace řady s řadou zpožděnou (U_{i-d})

Soubor hodnot s autokorelačních koeficientů pro postupně narůstající zpoždění $d =$ autokorelační funkce

Pro stacionární řady (pouze!!!) - všechny statistické charakteristiky jsou konstantní

2.5 MODELÝ A PREDIKCE

- a) predikce konstantní (triviální predikce)

$$\hat{Y}(t+1) = Y(t) \quad \text{tzv. anglická predikce}$$

Invarianty: konstanta i trend, ale s posunem řady o jeden krok dopředu

b) lineární predikce (prodloužení)

$$\hat{Y}(t+1) = Y(t) + (Y(t) - Y(t-1)) = 2 * Y(t) - Y(t-1)$$

Invarianty: konstanta i trend

c) nerobustní matematické predikce

Box – Jenkinsův lineární model (ARMA = AutoRegresive Moving Average = AUTOREGRESNÍ MODEL S POHYBLIVÝM OKNEM)

$$X_i = \sum_{j=1}^{i-1} \times \zeta_{ij} + \sum_{k=1}^{i-1} \times \epsilon_k \rightarrow \text{Poruchy}$$

Pozn.: průměrný absolutní podíl predikovaných a skutečných hodnot metody ad c) může být horší než ad a)

d) robustní predikce (gnostická)

například jako lineární predikce robustně vyfiltrovaných dat