

## 5 Penktoji paskaita. PROGNOZAVIMAS

Dinamikos eilutės sisteminei komponentei be pagrindinės trendo komponentės įtaką gali turėti ir kitos komponentės, tokios kaip:

- sezoniškumas – atspindi reguliarius nukrypimus nuo trendo,
- cikliškumas – matomi nukrypimai nuo trendo, kurie pasikartoja tam tikrais laiko intervalais,
- atsitiktinumumas – nenuspėjami laiko eilučių pokyčiai.

Tokiu būdu bendrasis dinamikos eilučių modelis galėtų būti užrašomas taip:

$$y = \Phi(f(t), s(t), c(t), \varepsilon(t)),$$

čia  $f(t)$  – pagrindinė (trendo) komponentė,  $s(t)$  – sezoninė komponentė,  $c(t)$  – cikliškumo komponentė,  $\varepsilon(t)$  – atsitiktiniai nuokrypiai.

Paprastai turima dinamikos eilutė išskaidoma į trendo, sezoniškumo, cikliškumo ir atsitiktinę komponentes. Turėdami visas modelio komponentes galime gana tiksliai prognozuoti mus dominančio dydžio kitimą netolimoje ateityje.

Kaip jau minėjome, sezoniškumas suprantamas kaip reguliarūs nuokrypiai nuo trendo. Norėdami nustatyti, ar duomenys yra įtakojami sezoniškumo komponentės galime nagrinėti skirtumus tarp trendo ir laiko eilutės reikšmių. Pastebėję, kad skirtumų svyravimai yra reguliarūs, galime teigti, kad sezoniškumas turi įtakos stebimiems duomenims.

Tais atvejais, kai skirtumai tarp trendo ir laiko eilutės reikšmių yra beveik vienodi, sakome, kad turime adityvųjį sezoniškumo modelį. Adityvusis dinamikos eilučių modelis užrašomas taip:

$$y = f(t) + s(t) + c(t) + \varepsilon(t).$$

Jei skirtumai turi tendenciją didėti arba mažėti, tai kalbame apie multiplikatyvųjį sezoniškumo modelį, kurio bendroji išraiška yra tokia:

$$y = f(t) \cdot s(t) \cdot c(t) \cdot \varepsilon(t).$$

Turėdami sezoninius svyravimus, galime įvertinti ryšio tarp besikartojančių duomenų stiprumą, t. y. apskaičiuoti autokoreliaciją. Autokoreliacijos funkcija nustato ryšį tarp duomenų visais laiko intervalais. Didžiausios autokoreliacijos koeficiento reikšmės parodo, kurie laiko intervalai yra stipriausiai susiję. Sezoniškumo indeksas rodo vidutinį sezoninį duomenų nuokrypį nuo slenkamųjų vidurkių kreivės.

Tuo atveju, kai proceso vidurkis ir autokoreliacijos funkcija kintant laikui nesikeičia, sakoma, kad turime stacionarųjį procesą. Stacionarusis procesas iš nestacionariojo gali būti gautas diferencijavimo metodu, t. y. panaikinus trendą. Vienas iš būdų tai padaryti: iš kiekvieno sekos nario atimti atitinkamą trendo reikšmę. Kitas būdas gauti stacionarųjį procesą yra apskaičiuoti pirmuosius skirtumus ir nagrinėti pirmųjų skirtumų seką. Jei po šio diferencijavimo dar negaunamas stacionarusis procesas, tai galima pereiti prie antųjų skirtumų ir t. t.

Kaip jau esame minėję, stacionariųjų eilučių atveju prognozuoti galima ir slenkamųjų vidurkių metodu.

Gan plačiai prognozėms taikomas ir eksponentinio glodinimo metodas, kai prognozuojama reikšmė apskaičiuojama pagal formulę:

$$\hat{y}_i = \alpha(y_{i-1} - \hat{y}_{i-1}) + \hat{y}_{i-1},$$

čia glodinimo konstanta  $0 < \alpha < 1$ , o  $\hat{y}_2 = y_1$ . Pradinę reikšmę eksponentiniam glodinimui taip pat galima parinkti lygią visų dinamikos eilutės reikšmių vidurkiui. Kai glodinimo konstanta artima 1, tai turime nedidelį duomenų glodinimą, o kai ji artima 0, tai glodinimas yra labai stiprus.

Kad ir kokį prognozavimo metodą taikytume visuomet turime vertinti prognozės paklaidą, t. y. skirtumą tarp laiko eilutės reikšmės ir prognozuotos reikšmės. Tokių skirtumų kvadratų vidutinė reikšmė išreiškia prognozės kvadratinę paklaidą. Kuo mažesnė paklaida, tuo geresnė prognozė.