

Modeliranje koncentracije peludi ambrozije vektorskim autoregresivnim modelom

Knežević, Marinela

Master's thesis / Diplomski rad

2018

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Department of Mathematics / Sveučilište Josipa Jurja Strossmayera u Osijeku, Odjel za matematiku**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:126:981679>

Rights / Prava: [In copyright](#)/[Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-11-14**



mathos

Repository / Repozitorij:

[Repository of School of Applied Mathematics and Informatics](#)



Sveučilište J. J. Strossmayera u Osijeku
Odjel za matematiku

Marinela Knežević

**Modeliranje koncentracije peludi ambrozije
vektorskim autoregresivnim modelom**

Diplomski rad

Osijek, 2018.

Sveučilište J. J. Strossmayera u Osijeku
Odjel za matematiku

Marinela Knežević

**Modeliranje koncentracije peludi ambrozije
vektorskim autoregresivnim modelom**

Diplomski rad

Mentor: izv. prof. dr. sc. Nenad Šuvak

Osijek, 2018.

Sadržaj

Uvod	1
1 Osnovne analize vremenskih nizova	3
1. Općenito o vremenskom nizu i konceptu stacionarnosti	3
1.1 Vremenski niz	3
1.2 Stacionarni procesi	4
1.3 Nestacionarni procesi	7
2. Modeli stacionarnih vremenskih nizova	9
2.1 Linearan proces	9
2.2 Model pomičnih prosjeka	10
2.3 Autoregresivni model	11
2.4 Autoregresivni pomični prosjek	12
3. Modeli nestacionarnih vremenskih nizova	13
3.1 Diferenciranje i integrirani autoregresivni pomični prosjek	13
3.2 Sezonalni autoregresivni pomični prosjek	14
3.3 Sezonalni integrirani autoregresivni pomični prosjek	14
2 Višedimenzionalni vremenski nizovi	15
1. Višedimenzionalni vremenski nizovi	15
2. Vektorski autoregresivni modeli	18
2.1 Stabilnost	19

2.2	Stacionarnost	21
2.3	Grangerova uzročnost	28
2.4	Identifikacija modela	31
2.5	Dijagnostika modela	35
2.6	Predikcija	38
3	Vektorski autoregresivni model na stvarnim podacima	41
1.	Koraci u izgradnji modela	41
1.1	Deskriptivna analiza varijabli	42
1.2	Analiza uzročnosti	47
1.3	Odabir reda modela	48
2.	Adekvatnost modela	49
2.1	Reziduali	53
2.2	Stabilnost i stacionarnost	55
3.	Predikcija modela	55
	Literatura	59
	Sažetak	60
	Summary	61
	Životopis	62
	Dodatak	63

Uvod

Alergija je pretjerano izražena reakcija imunološkog sustava na tvari iz okoline koje su obično bezazlene i neopasne. Takve tvari nazivamo alergenima. Uobičajeni alergeni su različite tvari iz okoliša ili hrane, a najčešći su oni koji u tijelo ulaze dišnim sustavom iz zraka. Dodir osjetljivih osoba s takvim tvarima potiče otpuštanje upalnih tvari iz stanica (npr. sluznica vjeđa i dišnog sustava), što uzrokuje simptome alergije: curenje, začepjenost ili svrbež nosa, peckanje ili škakljanje u grlu, suženje ili svrbež te crvenilo i otekline oko očiju, otežano disanje, iznenadno kihanje, kašljanje, glavobolja i slično. Pelud je najčešći uzrok alergijskih bolesti dišnog sustava i jedan od najsnažnijih prirodnih alergena. U zraku ga je gotovo nemoguće izbjeći. Kada dođe u dodir s vlažnom sredinom poput sluznice našeg dišnog sustava, pelud otpušta niz kemijskih alergogenih spojeva (njih čak 52, prema [6]). Pojava alergija na pelud se podudara s cvatnjom biljaka koje stvaraju taj pelud, zbog čega je važno poznavati peludni kalendar koji daje podatke o sezoni cvjetanja biljaka koje izazivaju simptome alergije. Peludni kalendar je grafički prikaz peludnog spektra u zraku, a najčešće se izrađuje za razdoblje od godine dana. Izrađuje se zasebno za svako biogeografsko područje zbog različitosti biljnih vrsta i različitosti početaka cvatnje. Jako alergenu pelud ima drveće lijeske, johe i breze, od korovnih biljaka pelin i ambrozija te pripadnici porodice trava. Izrazito osjetljive osobe razviju simptome alergijske reakcije već pri niskoj razini peluda, većina osjetljivih osoba pri umjerenosti, dok pri visokim i vrlo visokim razinama sve osobe osjetljive na pelud razviju simptome alergijske reakcije. Procjenjuje se da u Republici Hrvatskoj 7-10 % stanovništva pati od peludne alergije.

Meteorološki uvjeti poput dnevne temperature, vlažnosti zraka, vjetra i padalina igraju veliku ulogu u koncentraciji peludi u smislu taloženja, prijenosa zrakom, ispiranja uslijed padalina i slično. U ovom diplomskom radu su korišteni podaci o koncentraciji peludi ambrozije u gradu Somboru, Republika Srbija, za razdoblje od siječnja 2008. do srpnja 2017. godine te podaci o meteorološkim uvjetima na mjernoj postaji u Rimskim Šančevima za isto vremensko razdoblje. Na osnovu danih podataka cilj je pronaći model koji dovoljno dobro prati kretanje tih pojava i predviđa njihove buduće vrijednosti, kako bi pojedincima koji pate od alergije olakšali taj period u godini. Primjena ovog ili sličnih modela za predikciju buduće dnevne koncentracije peludi podrazumijeva stalno pristizanje novih mjerenja, tj. novih podataka, i korekciju parametara modela u skladu s njima. U tom kontekstu ovaj se problem može svrstati u kategoriju problema iz popularnog "big data" područja.

U radu su najprije objašnjeni osnovni pojmovi analize vremenskih nizova koji će se koristiti u ostatku diplomskog rada. Model koji se pokazao prikladan za ovakav tip

podataka je vektorski autoregresivni model (VAR model) te su opisani rezultati koji su osnova za razumijevanje ovakve vrste modela. Na kraju je napravljena predikcija budućih koncentracija peludi te su dobivene vrijednosti podijeljene u kategorije - niska, umjerena, visoka i vrlo visoka koncentracija. Logičan nastavak ovog smjera modeliranja koncentracije peludi je implementacija VAR modela u domeni strojnog učenja (*engl. machine learning*), no to prelazi granice ovog diplomskog rada.

Poglavlje 1

Osnovne analize vremenskih nizova

1. Općenito o vremenskom nizu i konceptu stacionarnosti

1.1 Vremenski niz

Definicija 1.1. (Slučajni proces) *Slučajni proces* je familija $\{X_t, t \in T\}$, $T \subseteq \mathbb{R}$ slučajnih varijabli definiranih na istom vjerojatnosnom prostoru (Ω, \mathcal{F}, P) .

Dva bitna skupa koja karakteriziraju slučajni proces su:

- skup stanja - skup svih mogućih realizacija slučajnih varijabli X_t
- skup indeksa ili parametarski skup T

T može biti diskretan pa govorimo o slučajnom procesu u diskretnom vremenu, odnosno nizu slučajnih varijabli ili neprekidan pa govorimo o slučajnom procesu u neprekidnom vremenu.

Vremenski niz je niz podataka $x_{t_1}, x_{t_2}, \dots, x_{t_n}$ prikupljenih u uzastopnim vremenskim trenucima t_1, t_2, \dots, t_n . Svaki podatak vremenskog niza $x_{t_i}, i = 1, \dots, n$ smatramo realizacijom jedne slučajne varijable $X_{t_i}, i = 1, \dots, n$, odnosno, vremenski niz je realizacija slučajnog procesa $\{X_t, t \in T\}$, u trenucima iz $T_0, T_0 = \{t_1, t_2, \dots, t_n\}, T_0 \subseteq T$. Slučajni proces $\{X_t, t \in T\}$ zovemo model vremenskog niza. Svrha analize vremenskih nizova je modelirati i razumjeti stohastički mehanizam koji dovodi do realizacije kojom raspoložemo te predviđati buduće vrijednosti vremenskog niza.

1.2 Stacionarni procesi

Definicija 1.2. (Strogo stacionaran proces) *Slučajni proces* $\{X_t, t \in T\}$ je **strogo stacionaran (stacionaran u užem smislu)** ako za svaki $h > 0$ vrijedi:

$$(X_{t_1}, X_{t_2}, \dots, X_{t_n}) \stackrel{d}{=} (X_{t_1+h}, X_{t_2+h}, \dots, X_{t_n+h}), \forall t_1, \dots, t_n, n \in \mathbb{N}.$$

Posebno, $X_t \stackrel{d}{=} X_s, \forall s, t \in T$.

Promatrajmo nadalje diskretan T , pri čemu je $T = \mathbb{Z}$.

Definicija 1.3. Neka je $\{X_t, t \in \mathbb{Z}\}$ slučajni proces takav da je $E[X_t^2] < \infty, \forall t \in \mathbb{Z}$.

Funkcija očekivanja procesa $\{X_t, t \in \mathbb{Z}\}$ je $\mu: \mathbb{Z} \rightarrow \mathbb{R}, \mu(t) = E[X_t]$.

Funkcija autokovarijanci (ACVF) procesa $\{X_t, t \in \mathbb{Z}\}$ je $\gamma: \mathbb{Z}^2 \rightarrow \mathbb{R}$, definirana s

$$\gamma(t, s) = Cov(X_t, X_s) = E[(X_t - E[X_t])(X_s - E[X_s])] = E[X_t X_s] - E[X_t]E[X_s].$$

Autokorelacijska funkcija (ACRF) procesa $\{X_t, t \in \mathbb{Z}\}$ je $\rho: \mathbb{Z}^2 \rightarrow [-1, 1]$, definirana s

$$\rho(t, s) = Corr(X_t, X_s) = \frac{Cov(X_t, X_s)}{\sqrt{Var(X_t)Var(X_s)}} = \frac{\gamma(t, s)}{\sqrt{\gamma(t, t)\gamma(s, s)}}.$$

Definicija 1.4. (Slabo stacionaran proces) *Slučajni proces* $\{X_t, t \in \mathbb{Z}\}$ je **slabo stacionaran (stacionaran u širem smislu)** ako vrijedi:

(i) $E[X_t^2] < \infty, \forall t \in \mathbb{Z}$

(ii) $\mu(t) = c, \forall t \in \mathbb{Z}$, gdje je $c \in \mathbb{R}$ konstantno očekivanje

(iii) $\gamma(t, s) = \gamma(t+h, s+h), \forall t, s, h \in \mathbb{Z}$.

Uočimo, ako u (iii) stavimo $s = t$, dobivamo $\gamma(t, t) = \gamma(t+h, t+h)$, odnosno varijanca stacionarnog procesa je konstantna. Stavimo li u (iii) $h = -t$, onda vrijedi $\gamma(t, s) = \gamma(0, s-t), \forall t, s \in \mathbb{Z}$. Dakle, funkcija autokovarijanci ovisi samo o razlici $s - t$ pa je možemo promatrati kao funkciju jedne varijable: $\gamma(h) = \gamma(0, h) = Cov(X_t, X_{t+h})$. Ubuduće, stacionaran proces će podrazumijevati proces stacionaran u širem smislu.

Propozicija 1.1. (Svojstva funkcije autokovarijanci stacionarnog procesa) *Za funkciju autokovarijanci γ stacionarnog procesa $\{X_t, t \in \mathbb{Z}\}$ vrijedi:*

(i) $\gamma(0) \geq 0$

$$(ii) |\gamma(h)| \leq \gamma(0), \forall h \in \mathbb{Z}$$

$$(iii) \gamma(h) = \gamma(-h), \forall h \in \mathbb{Z}.$$

Analogno za autokorelacijsku funkciju stacionarnog procesa.

Propozicija 1.2. (Svojstva autokorelacijske funkcije stacionarnog procesa) *Za autokorelacijsku funkciju γ stacionarnog procesa $\{X_t, t \in \mathbb{Z}\}$ vrijedi:*

$$(i) \rho(0) = 1$$

$$(ii) |\rho(h)| \leq 1, \forall h \in \mathbb{Z}$$

$$(iii) \rho(h) = \rho(-h), \forall h \in \mathbb{Z}.$$

Navedena svojstva proizlaze iz samih definicija funkcija i dokazi se mogu vrlo lako pokazati.

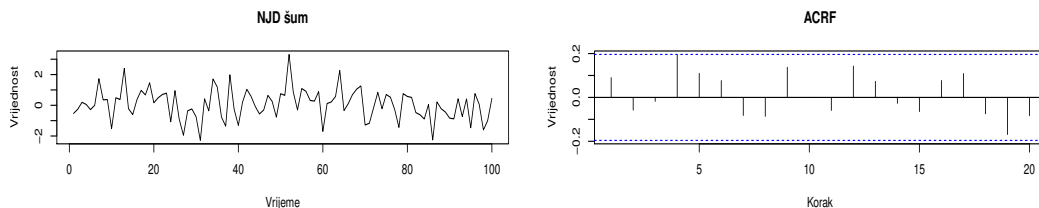
Neki od primjera stacionarnih procesa su niz nezavisnih jednako distribuiranih slučajnih varijabli, bijeli šum itd.

Definicija 1.5. (Nezavisni jednako distribuirani šum (NJD šum)) *Neka je $\{X_t, t \in \mathbb{Z}\}$ niz nezavisnih jednako distribuiranih slučajnih varijabli takvih da vrijedi:*

- $E[X_t^2] < \infty, \forall t \in \mathbb{Z}$
- $E[X_t] = 0, \forall t \in \mathbb{Z}$
- $Var(X_t) = \sigma^2, \forall t \in \mathbb{Z}.$

Tada je $\{X_t\}$ nezavisni jednako distribuirani šum, oznaka: $\{X_t\} \sim IID(0, \sigma^2)$.

Primjer 1.1. (NJD šum) *NJD šum takav da je $X_t \sim \mathcal{N}(0, 1)$.*



(a) Trajektorija

(b) Empirijska ACRF

Slika 1.1: NJD šum

Definicija 1.6. (Bijeli šum) Neka je $\{X_t, t \in \mathbb{Z}\}$ niz slučajnih varijabli takvih da vrijedi:

- $E[X_t^2] < \infty, \forall t \in \mathbb{Z}$
- $E[X_t] = 0, \forall t \in \mathbb{Z}$
- $Var(X_t) = \sigma^2, \forall t \in \mathbb{Z}$
- $Cov(X_t, X_s) = 0, \forall t \neq s.$

Tada je $\{X_t\}$ **bijeli šum**, oznaka: $\{X_t\} \sim \mathcal{WN}(0, \sigma^2).$

Uočimo da slučajne varijable ne moraju biti jednako distribuirane i nezavisne, bijeli šum je relaksacija NJD šuma.

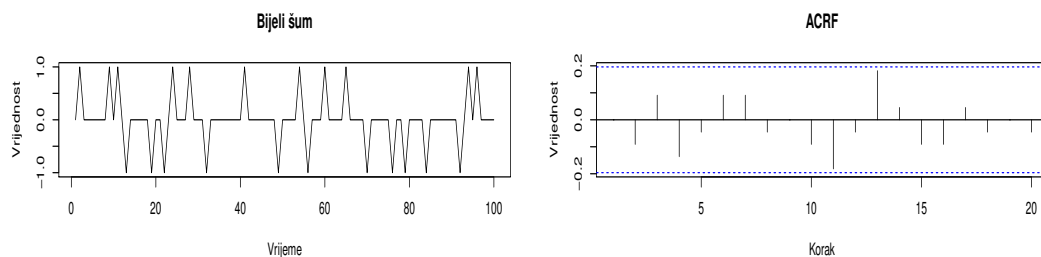
Primjer 1.2. (Bijeli šum) Neka su $\{Y_t, t \in \mathbb{Z}\}$ i $\{Z_t, t \in \mathbb{Z}\}$ nizovi nezavisnih jednako distribuiranih slučajnih varijabli takvi da je:

$$Y_t \sim \begin{pmatrix} 0 & 1 \\ \frac{1}{2} & \frac{1}{2} \end{pmatrix}$$

i

$$Z_t \sim \begin{pmatrix} -1 & 1 \\ \frac{1}{2} & \frac{1}{2} \end{pmatrix}$$

te međusobno nezavisni. Proces $\{X_t, t \in \mathbb{Z}\}$ definiran s $X_t = Y_t(1 - Y_t)Z_t$ je bijeli šum.



(a) Trajektorija

(b) Empirijska ACRF

Slika 1.2: Bijeli šum

1.3 Nestacionarni procesi

Ukoliko slučajni proces ne zadovoljava neku od pretpostavki iz Definicije 1.4., kažemo da proces nije stacionaran. Nestacionarnost može imati različite oblike, može naprimjer dolaziti od determinističkog trenda, od promjenjivosti varijance, od egzogenih šokova, iz sezonalnosti itd.

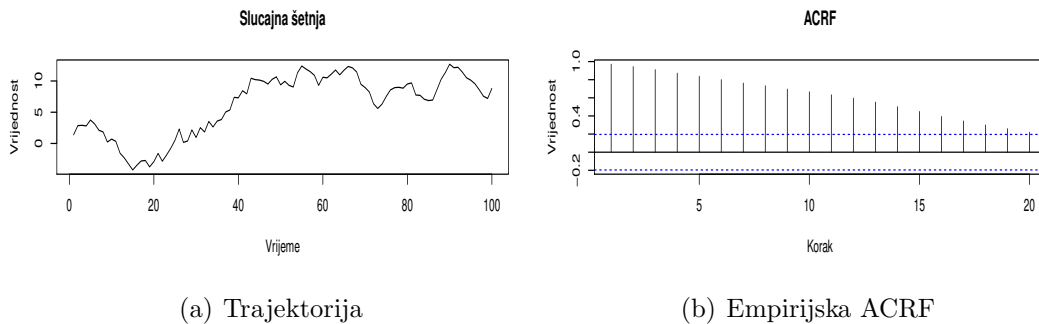
Definicija 1.7. (Slučajna šetnja) *Neka je $\{Y_t\} \sim IID(0, \sigma^2)$. **Slučajna šetnja** je proces $\{X_t, t \in \mathbb{N}_0\}$ definiran s:*

$$X_0 = 0, X_t = \sum_{i=1}^t Y_i, t \in \mathbb{N}.$$

Uočimo da proces nije stacionaran jer varijanca nije konstantna:

$$Var(Y_t) = Var\left(\sum_{i=1}^t Y_i\right) = tVar(Y_1) = t\sigma^2.$$

Primjer 1.3. (Slučajna šetnja) *Neka je $\{Y_t\} \sim IID(0, 1)$ iz standardne normalne distribucije te $\{X_t\}$ pripadajuća slučajna šetnja. Očigledna je promjenjivost varijance slučajne šetnje (Slika 1.3).*

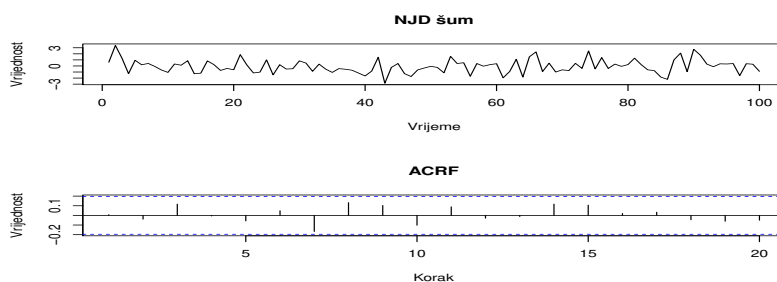


Slika 1.3: Slučajna šetnja

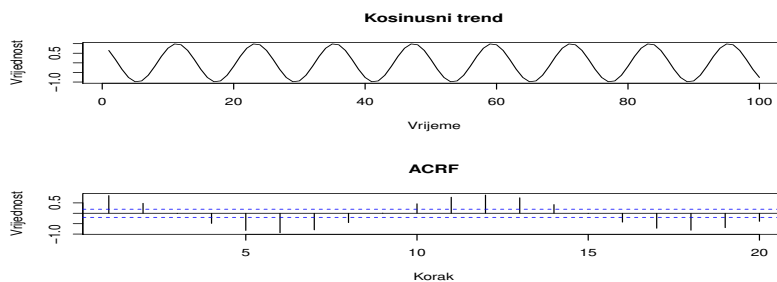
Definicija 1.8. (Proces s determinističkim trendom) *Kažemo da proces $\{X_t\}$ ima **deterministički trend** ako $\forall t \in \mathbb{Z}$ vrijedi $X_t = \mu_t + Y_t$, gdje je $\{Y_t\}$ stacionaran proces takav da je $E[Y_t] = 0$, a $\mu: \mathbb{Z} \rightarrow \mathbb{R}$ funkcija koja nije konstantna.*

$\{X_t\}$ nije stacionaran, ali $\{X_t - \mu_t\}$ je. Oblik funkcije μ obično procijenimo na osnovu podataka, a česti su linearni, polinomijalni, kosinunski trendovi itd.

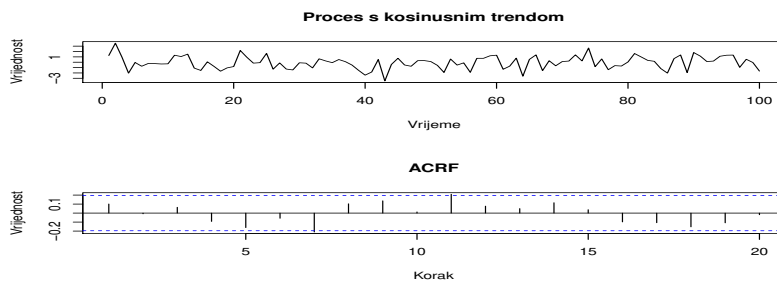
Primjer 1.4. (Kosinusni trend) U slučaju kosinusnog trenda, μ je općenito oblika: $\mu_t = \beta \cos(2\pi ft + \Phi)$, gdje je β amplituda, f period, i Φ faza. Primjera radi, neka je $Y_t \sim IID(0, 1)$ iz standardne normalne distribucije, $\mu_t = \cos(2\pi \frac{1}{12}t + \Phi)$ kosinusni trend tako da je faza slučajno odabran broj iz uniformne distribucije na intervalu $(0, 1)$, period je $1/12$, a amplituda je jednaka 1. Na taj način dobijemo sljedeći nestacionarni slučajni proces X_t .



(a) NJD šum



(b) Kosinusni trend



(c) Nestacionarni proces s kosinusnim trendom

Slika 1.4: Trajektorije i empirijske ACRF

2. Modeli stacionarnih vremenskih nizova

Pretpostavimo da podaci sugeriraju kako se radi o realizaciji stacionarnog procesa pa tražimo stacionaran slučajni proces za model tog vremenskog niza. Pretpostavit ćemo i da traženi model ima očekivanje 0. Opći okvir za proučavanje stacionarnih procesa nam daju linearni procesi.

2.1 Linearan proces

Definicija 1.9. (Linearan proces) *Kažemo da je $\{X_t, t \in \mathbb{Z}\}$ **linearan proces** ako se može prikazati kao:*

$$X_t = \sum_{j=-\infty}^{\infty} \psi_j Z_{t-j}, \forall t \in \mathbb{Z}, \quad (1.1)$$

gdje je $\{Z_t\} \sim \mathcal{WN}(0, \sigma^2)$ i $(\psi_j)_{j \in \mathbb{Z}}$ niz konstanti takav da je $\sum_{j=-\infty}^{\infty} |\psi_j| \leq \infty$.

Odnosno, proces je linearan ako se može zapisati kao linearna kombinacija prošlih, sadašnjih i budućih vrijednosti bijelog šuma.

Napomena 1.1.

(i) *Nekad ćemo pretpostaviti da je $\{Z_t\} \sim IID(0, \sigma^2)$ i reći da se radi o linearnom procesu uz NJD šum.*

(ii) *Desna strana izraza (1.1) je red slučajnih varijabli i shvaćamo ga kao $X_t = \lim_{n \rightarrow \infty} \sum_{j=-n}^n \psi_j Z_{t-j}$, gdje je limes u smislu gotovo sigurno ili L^2 smislu (vidi [2], Poglavlje 2.2).*

Definicija 1.10. (Operator pomaka unazad) *Za proces $\{X_t, t \in \mathbb{Z}\}$ **operator pomaka unazad** (engl. backward shift) je definiran s:*

$$BX_t = X_{t-1}.$$

Analogno, uzastopnom primjenom j puta, dobivamo

$$B^j X_t = B^{j-1} B X_t = B^{j-1} X_{t-1} = \dots = X_{t-j}.$$

Linearan proces (1.1) možemo zapisati kao:

$$X_t = \sum_{j=-\infty}^{\infty} \psi_j B^j Z_t = \psi(B) Z_t,$$

gdje je

$$\psi(B) = \sum_{j=-\infty}^{\infty} \psi_j B^j.$$

Definicija 1.11. (Linearan filter) Neka je $\{Y_t, t \in \mathbb{Z}\}$ slučajni proces i $\{\beta_j, j \in \mathbb{Z}\}$ niz koeficijena. Za slučajni proces $\{X_t, t \in \mathbb{Z}\}$ definiran s

$$X_t = \sum_{j=-\infty}^{\infty} \beta_j Y_{t-j}, t \in \mathbb{Z},$$

kažemo da je linearan filter procesa $\{Y_t\}$.

Propozicija 1.3. Neka je $\{Y_t\}$ stacionaran proces s očekivanjem 0 i funkcijom autokovarijanci γ_y . Ako je $\psi(B)$ linearan filter takav da je $\sum_{j=-\infty}^{\infty} |\psi_j| \leq \infty$, onda je proces

$$X_t = \psi(B)Y_t = \sum_{j=-\infty}^{\infty} \psi_j Y_{t-j}, t \in \mathbb{Z}$$

stacionaran s očekivanjem 0 i vrijedi:

$$\gamma_x(h) = \sum_{j=-\infty}^{\infty} \sum_{k=-\infty}^{\infty} \psi_j \psi_k \gamma_y(h+k-j), h \in \mathbb{Z}.$$

Specijalno, ako je $\{X_t\}$ linearan proces,

$$\gamma_x(h) = \sum_{j=-\infty}^{\infty} \psi_j \psi_{j+h} \sigma^2, h \in \mathbb{Z}.$$

Dakle, linearan filter stacionarnog proces je opet stacionaran proces. Dokaz vidljiv u [2], Propozicija 2.2.1.

2.2 Model pomičnih prosjeka

Prisjetimo se **Woldove dekompozicije** procesa: ako je $\{X_t, t \in \mathbb{Z}\}$ stacionaran nedeterministički proces, onda je on zbroj dva nekorelirana procesa, jednog determinističkog koji se može linearno izraziti iz proizvoljno daleke prošlosti procesa $\{X_t\}$ i jednog nedeterminističkog koji je linearna kombinacija sadašnjih i prošlih vrijednosti nekog bijelog šuma. Drugim riječima, $\{X_t\}$ se može prikazati u obliku:

$$X_t = \sum_{j=0}^{\infty} \psi_j Z_{t-j} + V_t, t \in \mathbb{Z},$$

gdje je:

- (i) $\psi_0 = 1, \sum_{j=0}^{\infty} \psi_j^2 < \infty$
- (ii) $\{Z_t\} \sim \mathcal{WN}(0, \sigma^2)$

- (iii) $Cov(Z_t, V_s) = 0, \forall s, t \in \mathbb{Z}$
- (iv) $Z_t = \Pi_t Z_t, \forall t \in \mathbb{Z}$, a Π_t je projekcija na $\{X_s, s \leq t\}$
- (v) $V_t = \Pi_s V_t, \forall s, t \in \mathbb{Z}$
- (vi) $\{V_t\}$ je deterministički proces.

Vidimo da je prvi član "približno" linearan proces jer ne vrijedi nužno $\sum_{j=0}^{\infty} |\psi_j| < \infty$. Dakle, iz Woldove dekompozicije slijedi da je, uz neke pretpostavke, stacionaran proces i linearan. Više o ovoj dekompoziciji u [3], Poglavlje 5.7.

Promatrajmo sad linearan proces $\{X_t\}$ kao u (1.1). $\{X_t\}$ se može zapisati i kao:

$$X_t = \sum_{j=-\infty}^{-1} \psi_j Z_{t-j} + \sum_{j=0}^{\infty} \psi_j Z_{t-j}.$$

Uočimo da je prvi član sume zapravo budućnost, a drugi sadašnjost i prošlost bijelog šuma. Za linearan proces za kojeg je $\psi_j = 0, j \leq -1$, kažemo da je **kauzalan** (neovisan o budućnosti). U Woldovoj dekompoziciji je nedeterministički dio kauzalan te stoga možemo promatrati samo linearne procese oblika:

$$X_t = \sum_{j=0}^{\infty} \psi_j Z_{t-j}, t \in \mathbb{Z}. \quad (1.2)$$

Umjesto (1.2), možemo promatrati linearne procese za koje je $\psi_j = 0, j > q, q \in \mathbb{N}$. To će biti upravo proces pomičnih prosjeka kojim se opisuju slučajni procesi koji generiraju vremenski niz čija je trenutna vrijednost povezana s greškama trenutnog i prethodnih razdoblja.

Definicija 1.12. (Proces pomičnih prosjeka) *Slučajni proces $\{X_t, t \in \mathbb{Z}\}$ je **proces pomičnih prosjeka reda $q \in \mathbb{N}$ ako je***

$$X_t = Z_t + \theta_1 Z_{t-1} + \dots + \theta_q Z_{t-q}, t \in \mathbb{Z},$$

gdje je $\{Z_t\} \sim \mathcal{WN}(0, \sigma^2), \theta_1, \dots, \theta_q \in \mathbb{R}, \theta_q \neq 0$. Oznaka: $\{X_t\} \sim MA(q)$.

2.3 Autoregresivni model

Ideja ovih modela jest sadašnju vrijednost procesa prikazati kao linearnu kombinaciju p prošlih vrijednosti uz šum.

Definicija 1.13. (Autoregresivni proces) *Slučajni proces* $\{X_t, t \in \mathbb{Z}\}$ je **autoregresivni proces reda** $p \in \mathbb{N}$ ako je stacionaran i ako je

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \cdots + \phi_p X_{t-p} + Z_t, t \in \mathbb{Z}, \quad (1.3)$$

gdje je $\{Z_t\} \sim \mathcal{WN}(0, \sigma^2)$ i $\phi_1, \phi_2, \dots, \phi_p \in \mathbb{R}, \phi_p \neq 0$. Oznaka: $\{X_t\} \sim AR(p)$.

Izraz (1.3) možemo zapisati kao $\phi(B)X_t = Z_t$, gdje je $\phi(z) = 1 - \phi_1 z - \phi_2 z^2 - \dots - \phi_p z^p, z \in \mathbb{C}$. Navedeni polinom se naziva i **karakteristični AR polinom**, a B je operator pomaka unazad.

2.4 Autoregresivni pomični prosjek

Ukoliko je sadašnja vrijednost procesa linearna kombinacija p prošlih vrijednosti procesa te sadašnje i q prošlih vrijednosti šuma, govorimo o autoregresivnom pomičnom prosjeku kao kombinaciji prethodna dva procesa.

Definicija 1.14. (Autoregresivni pomični prosjek) *Slučajni proces* $\{X_t, t \in \mathbb{Z}\}$ je **autoregresivni pomični prosjek reda** $(p, q), p, q \geq 0$ ako je stacionaran i ako je

$$X_t = \phi_1 X_{t-1} + \cdots + \phi_p X_{t-p} + Z_t + \theta_1 Z_{t-1} + \cdots + \theta_q Z_{t-q}, t \in \mathbb{Z}, \quad (1.4)$$

gdje je $\{Z_t\} \sim \mathcal{WN}(0, \sigma^2), \phi_1, \dots, \phi_p, \theta_1, \dots, \theta_q \in \mathbb{R}, \phi_p, \theta_q \neq 0$ i polinomi $\phi(z) = 1 - \phi_1 z - \phi_2 z^2 - \dots - \phi_p z^p$ i $\theta(z) = 1 + \theta_1 z + \theta_2 z^2 + \cdots + \theta_q z^q, z \in \mathbb{C}$ nemaju zajedničke nultočke. Oznaka: $\{X_t\} \sim ARMA(p, q)$.

Koristeći operator pomaka unazad, (1.4) možemo zapisati kao $\phi(B)X_t = \theta(B)Z_t$.

Nadalje, neka su $\alpha(B)$ i $\beta(B)$ linearni filteri, odnosno:

$$\alpha(B) = \sum_{j=-\infty}^{\infty} \alpha_j B^j, \sum_{j=-\infty}^{\infty} |\alpha_j| < \infty$$

i

$$\beta(B) = \sum_{j=-\infty}^{\infty} \beta_j B^j, \sum_{j=-\infty}^{\infty} |\beta_j| < \infty.$$

Kompozicija ovih operatora je linearni filter s koeficijentima ψ_j koji se odrede iz zahtjeva $\psi(z) = \alpha(z)\beta(z)$ i slijedi

$$\psi_j = \sum_{k=-\infty}^{\infty} \alpha_k \beta_{j-k}.$$

Teorem 1.1. *Stacionarno rješenje jednadžbe (1.4) postoji i jedinstveno je ako i samo ako $\phi(z) \neq 0, \forall z \in \mathbb{C}$ takav da je $|z| = 1$.*

Odnosno, stacionarno rješenje jednadžbe (1.4) postoji i jedinstveno je ako i samo ako AR polinom nema jedinični korijen.

3. Modeli nestacionarnih vremenskih nizova

Sjetimo se da smo spomenuli, ukoliko vremenski niz x_1, \dots, x_n sugerira da ga ima smisla modelirati nekim stacionarnim procesom, logično ga je pokušati modelirati nekim ARMA procesom. No, u praksi je dosta čest slučaj da podaci ne sugeriraju stacionarnost tako te ih je potrebno transformirati i doći do vremenskog niza čija trajektorija sugerira stacionarnost. Spomenuti su i neki najčešći oblici nestacionarnosti - deterministički trend i sezonalnost. U tu klasu treba dodati i procese sa stohastičkim trendom.

3.1 Diferenciranje i integrirani autoregresivni pomični prosjek

Definicija 1.15. (Operator diferenciranja) Za slučajni proces $\{X_t, t \in \mathbb{Z}\}$ **operator diferenciranja** Δ je definiran s: $\Delta X_t = X_t - X_{t-1} = (1 - B)X_t$.

Primjenom $d \in \mathbb{N}$ puta operator diferenciranja, dobivamo $\Delta^d X_t = (1 - B)^d X_t$.

Definicija 1.16. (Integrirani ARMA proces) Neka je $d \in \mathbb{N}_0$. Slučajni proces $\{X_t\}$ je **integrirani ARMA proces reda (p, d, q)** ako je $Y_t = \Delta^d X_t$ kauzalan ARMA(p, q) proces. Oznaka: $\{X_t\} \sim \text{ARIMA}(p, d, q)$.

Dakle, diferenciranjem d puta, dobijemo kauzalan ARMA proces. Koristeći standardne oznake, možemo pisati:

$$\phi(B)(1 - B)^d X_t = \theta(B)Z_t, Z_t \sim \mathcal{WN}(0, \sigma^2).$$

Uz oznaku $\tilde{\phi}(B) = \phi(B)(1 - B)^d$, dobivamo $\tilde{\phi}(B)X_t = \theta(B)Z_t$. Dakle, polinom $\tilde{\phi}(z) = \phi(z)(1 - z)^d$ ima jedinični korijen. Kažemo da proces $\{X_t\}$ ima **stohastički trend**.

Pitanje je za podatke vremenskog niza ima li pripadni model jedinični korijen? Treba li diferencirati? Ako treba, koliko puta? U tu svrhu koristimo **prošireni Dickey-Fuller test** (*engl. Augmented Dickey Fuller test*) - test jediničnog korijena (ADF test). Hipoteze su sljedeće:

$$\begin{aligned} \mathcal{H}_0: & \text{postoji jedinični korijen} \\ \mathcal{H}_1: & \text{ne postoji jedinični korijen.} \end{aligned}$$

Uočimo, \mathcal{H}_0 povlači da je proces nestacionaran, dok \mathcal{H}_1 ne povlači da je proces stacionaran. Proces i dalje može biti nestacionaran iako nema jediničnog korijena (tada je izvor nestacionarnosti nešto drugo). Dakle, ovaj test koristimo kad želimo zaključiti ima li smisla diferencirati vremenski niz.

3.2 Sezonalni autoregresivni pomični prosjek

Promatramo modele za podatke vremenskog niza koji pokazuju jasan sezonalni period s .

Definicija 1.17. (Sezonalni ARMA proces) *Za proces $\{X_t\}$ kažemo da je **sezonalni ARMA proces reda** $(\mathbf{p}, \mathbf{q}) \times (\mathbf{P}, \mathbf{Q})_s$, $p, q, P, Q \in \mathbb{N}_0$, $s \in \mathbb{N}$, ako je*

$$\phi(B)\Phi(B^s)X_t = \theta(B)\Theta(B^s)Z_t, t \in \mathbb{Z},$$

gdje je $\{Z_t\} \sim \mathcal{WN}(0, \sigma^2)$, s period, a

$$\phi(z) = 1 - \phi_1 z - \phi_2 z^2 - \dots - \phi_p z^p,$$

$$\Phi(z) = 1 - \varphi_1 z - \varphi_2 z^2 - \dots - \varphi_P z^P,$$

$$\theta(z) = 1 + \theta_1 z + \theta_2 z^2 + \dots + \theta_q z^q,$$

$$\Theta(z) = 1 + \vartheta_1 z + \vartheta_2 z^2 + \dots + \vartheta_Q z^Q.$$

Oznaka: $\{X_t\} \sim SARMA(p, q) \times (P, Q)_s$.

Uočimo da se radi o ARMA procesima, ali veći broj parametara je 0.

3.3 Sezonalni integrirani autoregresivni pomični prosjek

Definicija 1.18. (Operator sezonalnog diferenciranja) *Za proces $\{X_t\}$ **operator sezonalnog diferenciranja na koraku** $s \in \mathbb{N}$ definiran je s : $\Delta_s X_t = X_t - X_{t-s} = (1 - B^s)X_t$.*

Definicija 1.19. (Sezonalni ARIMA proces) *Neka su $d, D \in \mathbb{N}_0$. Kažemo da je $\{X_t\}$ **sezonalni ARIMA proces reda** $(\mathbf{p}, \mathbf{d}, \mathbf{q}) \times (\mathbf{P}, \mathbf{D}, \mathbf{Q})_s$ ako je $\Delta^d \Delta_s^D X_t$ stacionaran ARMA(p, q) \times (P, Q) proces. Oznaka: $\{X_t\} \sim SARIMA(p, d, q) \times (P, D, Q)_s$.*

Uz prijašnje oznake, vrijedi: $\phi(B)\Phi(B^s)(1 - B)^d(1 - B^s)^D X_t = \theta(B)\Theta(B^s)Z_t$.

Poglavlje 2

Višedimenzionalni vremenski nizovi

U prethodnim poglavljima smo razmatrali kako modelirati vremenski niz podataka nekim slučajnim procesom (modelom vremenskog niza). No, u praksi je prilično čest slučaj da raspolažemo s više vremenskih nizova i želimo ih modelirati istovremeno. Postoje generalizacije spomenutih modela koje svaki vremenski niz shvaćaju kao jednu komponentu višedimenzionalnog (vektorskog) niza.

Američki ekonomist Christopher Albert Sims je zaslužan za primjenu višedimenzionalnih vremenskih nizova i njihovu popularizaciju u makroekonomiji. Zajedno s Thomasom Sargentom je 2011. godine dobio Nobelovu nagradu za ekonomiju koja se dodjeljuje za iznimna postignuća i otkrića u tom području (vidljivo u [9]).

1. Višedimenzionalni vremenski nizovi

Napomena 2.1. U daljnjim razmatranjima ćemo radi jednostavnosti izostaviti notaciju podebljanim matematičkim slovima, kao npr. \mathbf{X}_t i pisat ćemo X_t , ali će iz konteksta biti jasno da se radi o vektoru.

Pretpostavimo da raspolažemo s $m \geq 2$ vremenskih nizova $x_{i1}, x_{i2}, \dots, x_{in}, i = 1, \dots, m$. Model za ovakve podatke je višedimenzionalni (vektorski) slučajni proces $\{X_t, t \in \mathbb{Z}\}$.

Definicija 2.1. (Vektorski slučajni proces) **Vektorski slučajni proces** je familija $\{X_t, t \in T\}, T \subseteq \mathbb{R}$ slučajnih vektora definiranih na istom vjerojatnosnom prostoru (Ω, \mathcal{F}, P) .

U fiksnom trenutku $t \in \{1, \dots, n\}$ imamo vektor $X_t = (X_{1,t}, X_{2,t}, \dots, X_{m,t})^T$. Za fiksni $i \in 1, \dots, m, \{X_{i,t}, t \in \mathbb{Z}\}$ je slučajni proces. Navedimo sad neka osnovna svojstva i osnovne funkcije za opisivanje ovakvih vremenskih nizova.

Definicija 2.2. Neka je $\{X_t, t \in \mathbb{Z}\}$ vektorski slučajni proces.

- **Funkcija očekivanja procesa** $\mu: \mathbb{Z} \rightarrow \mathbb{R}^m$:

$$\mu(t) = E[X_t] = \begin{pmatrix} E[X_{1,t}] \\ \vdots \\ E[X_{m,t}] \end{pmatrix}$$

- **Funkcija kovarijanci procesa** $\Gamma: \mathbb{Z}^2 \rightarrow \mathbb{R}^{m \times m}$:

$$\Gamma(t, s) = Cov(X_t, X_s) = \begin{pmatrix} \gamma_{11}(t, s) & \dots & \gamma_{1m}(t, s) \\ \vdots & \ddots & \vdots \\ \gamma_{m1}(t, s) & \dots & \gamma_{mm}(t, s) \end{pmatrix},$$

gdje je $\gamma_{ij}(t, s) = Cov(X_{i,t}, X_{j,s})$.

- **Autokorelacijska funkcija procesa** $R: \mathbb{Z}^2 \rightarrow \mathbb{R}^{m \times m}$:

$$R(t, s) = Corr(X_t, X_s) = \begin{pmatrix} \rho_{11}(t, s) & \dots & \rho_{1m}(t, s) \\ \vdots & \ddots & \vdots \\ \rho_{m1}(t, s) & \dots & \rho_{mm}(t, s) \end{pmatrix},$$

$$\text{gdje je } \rho_{ij}(t, s) = \frac{Cov(X_{i,t}, X_{j,s})}{\sqrt{Var(X_{i,t})Var(X_{j,s})}} = \frac{\gamma_{ij}(t, s)}{\sqrt{\gamma_{ii}(t, t)\gamma_{jj}(s, s)}}.$$

Napomena 2.2.

- Uočimo, za $i=j$ u definiciji matrice kovarijanci je γ_{ii} **funkcija autokovarijanci (ACVF) procesa** $\{X_{i,t}, t \in \mathbb{Z}\}$. Za $i \neq j$ je γ_{ij} **funkcija kroskovarijanci (CCVF) procesa** $\{X_{i,t}\}$ i $\{X_{j,t}\}$.
- Možemo pisati $\Gamma(t, s) = E[(X_t - \mu(t))(X_s - \mu(s))^T]$, pri čemu očekivanje matrice uzimamo po elementima.
- Uočimo, za $i=j$ u definiciji matrice korelacija je ρ_{ii} **autokorelacijska funkcija (ACRF) procesa** $\{X_{i,t}, t \in \mathbb{Z}\}$. Za $i \neq j$ je ρ_{ij} **kroskorelacijska funkcija (CCRF) procesa** $\{X_{i,t}\}$ i $\{X_{j,t}\}$.
- Matrica kovarijanci ne mora biti simetrična. Vrijedi: $\gamma_{ij}(t, s) = Cov(X_{i,t}, X_{j,s}) = Cov(X_{j,s}, X_{i,t}) = \gamma_{ji}(s, t)$. Posljedično isto vrijedi i za matricu korelacija.

Primjer 2.1. (Matrica kovarijanci ne mora biti simetrična) Neka je $\{(X_t, Y_t)\}$ dvodimenzionalni vremenski niz takav da je $\{X_t\} \sim \mathcal{WN}(0, \sigma^2)$ i $Y_t = X_t + 0.8X_{t-1}$, odnosno $\{Y_t\} \sim MA(1)$ proces. Pogledajmo matricu kovarijanci:

$$\Gamma(t, s) = \begin{pmatrix} \gamma_{X,X}(t, s) & \gamma_{X,Y}(t, s) \\ \gamma_{Y,X}(t, s) & \gamma_{Y,Y}(t, s) \end{pmatrix}$$

Kako bismo pokazali da nije simetrična, ključni su elementi na sporednoj dijagonali, odnosno $\gamma_{X,Y}(t, s)$ i $\gamma_{Y,X}(t, s)$.

$$\begin{aligned} \gamma_{X,Y}(t, s) &= \text{Cov}(X_t, Y_s) \\ &= E[X_t Y_s] - E[X_t]E[Y_s] \\ &= E[X_t Y_s] \\ &= E[X_t(X_s + 0.8X_{s-1})] \\ &= E[X_t X_s] + 0.8E[X_t X_{s-1}] \\ &= \begin{cases} \sigma^2, & t = s \\ 0.8\sigma^2, & t = s - 1 \\ 0, & \text{inače} \end{cases} \end{aligned}$$

$$\begin{aligned} \gamma_{Y,X}(t, s) &= \text{Cov}(Y_t, X_s) \\ &= \vdots \\ &= E[X_t X_s] + 0.8E[X_{t-1} X_s] \\ &= \begin{cases} \sigma^2, & t = s \\ 0.8\sigma^2, & t - 1 = s \\ 0, & \text{inače} \end{cases} \end{aligned}$$

Iz nejednakosti $\gamma_{X,Y}(t, s)$ i $\gamma_{Y,X}(t, s)$ slijedi da matrica kovarijanci nije simetrična.

Definicija 2.3. (Stacionarnost) Višedimenzionalan proces $\{X_t, t \in \mathbb{Z}\}$ je **stacionaran** ako vrijedi:

(i) $E[X_{i,t}^2] < \infty, \forall t \in \mathbb{Z}, \forall i \in 1, \dots, m$

(ii) $\mu(t) = \mu \in \mathbb{R}^m, \forall t \in \mathbb{Z}$

(iii) $\Gamma(t, t+h)$ ne ovisi o $t, \forall h \in \mathbb{Z}$.

Budući da kod stacionarnih procesa $\Gamma(t, t+h)$ ne ovisi o t , a posljedično ni $R(t, t+h)$, ima smisla uvesti oznaku $\Gamma(h) := \Gamma(t, t+h)$ i $R(h) := R(t, t+h)$.

2. Vektorski autoregresivni modeli

U Poglavlju 1. smo spomenuli AR procese kao procese kod kojih trenutnu vrijednost modeliramo pomoću prošlih vrijednosti procesa i slučajne greške. Također, spomenuli smo da kod višedimenzionalnih vremenskih nizova u fiksnom trenutku $t = 1, \dots, n$ imamo vektor podataka $x_t = (x_{1,t}, x_{2,t}, \dots, x_{m,t})$. Cilj vektorskih autoregresivnih (VAR) modela je trenutnu vrijednost tog vektora modelirati preko prošlih vrijednosti tog vektora i greške, odnosno, svaku komponentu tog višedimenzionalnog vektora modelirati preko prošlih vrijednosti te, ali i ostalih komponenti vektora i greške.

VAR (*engl. vector autoregressive*) modeli su, dakle, dinamički modeli skupine vremenskih nizova, a rezultati dobiveni VAR modelom su osnova za razumijevanje i istraživanje međusobne ovisnosti skupa varijabli. Također se koriste u analizi Grangerove uzročnosti (*engl. Granger causality*) i inovacijskoj analizi (*engl. innovation analysis*). Za potrebe modela koji je rađen u okviru ovog diplomskog rada, definirat ćemo samo pojam Grangerove uzročnosti koji je korišten u izradi modela, a više o inovacijskoj analizi se može vidjeti u [4].

Opći oblik vektorskog autoregresivnog modela definiranog na temelju m varijabli s duljinom koraka p je:

$$X_t = \nu + A_1 X_{t-1} + \dots + A_p X_{t-p} + Z_t, t \in \mathbb{Z}, \quad (2.1)$$

gdje je $X_t = (X_{1,t}, \dots, X_{m,t})^T$ m -dimenzionalan slučajni vektor, $\nu = (\nu_1, \nu_2, \dots, \nu_m)^T$ je vektor konstantnih članova, A_i su kvadratne ($m \times m$) matrice koeficijenata i $Z_t = (Z_{1,t}, \dots, Z_{m,t})^T$ je m -dimenzionalan proces bijelog šuma, odnosno proces za kojeg vrijedi: $E[Z_t] = 0$, $E[Z_t Z_t^T] = \Sigma_Z$ i $E[Z_t Z_s^T] = 0$ (nul-matrica) $\forall s \neq t$. Za matricu kovarijanci Σ_Z se smatra da nije singularna, osim ako nije drugačije naglašeno. Uz ovakav korak p , proces (2.1) se naziva **vektorski autoregresivni model reda p** . Oznaka: $\{X_t\} \sim VAR(p)$.

2.1 Stabilnost

Razmotrimo sada VAR(1) model koji starta u trenutku $t=1$.

$$\begin{aligned}
 X_1 &= \nu + A_1 X_0 + Z_1 \\
 X_2 &= \nu + A_1 X_1 + Z_2 \\
 &= \nu + A_1(\nu + A_1 X_0 + Z_1) + Z_2 \\
 &= (I_m + A_1)\nu + A_1^2 X_0 + A_1 Z_1 + Z_2 \\
 &\vdots \\
 X_t &= (I_m + A_1 + \dots + A_1^{t-1})\nu + A_1^t X_0 + \sum_{i=0}^{t-1} A_1^i Z_{t-i} \\
 &\vdots
 \end{aligned}$$

Dakle, slučajni vektori X_1, \dots, X_t su jednoznačno određeni s X_0, Z_1, \dots, Z_t .

Ukoliko u zadnjem retku uvedemo oznaku $j = t - 1$, dobivamo:

$$X_t = (I_m + A_1 + \dots + A_1^j)\nu + A_1^{j+1} X_{t-j-1} + \sum_{i=0}^j A_1^i Z_{t-i}.$$

Ako su sve svojstvene vrijednosti matrice A_1 modula manjeg od jedan, onda je niz $A_1^i, i = 0, 1, \dots$ apsolutno sumabilan (vidi [4], Dodatak A, Poglavlje A.9.1). Dakle, prebrojiva suma $\sum_{i=0}^{\infty} A_1^i Z_{t-i}$ postoji u srednje kvadratnom smislu (vidi [4], Dodatak C, Propozicija C.9). Štoviše, $(I_m + A_1 + \dots + A_1^j)\nu \xrightarrow{j \rightarrow \infty} (I_m - A_1)^{-1}\nu$ (vidi [4], Dodatak A, Poglavlje A.9.1). Nadalje, A_1^{j+1} konvergira k nuli kad $j \rightarrow \infty$, tako da je u limesu izraz $A_1^{j+1} X_{t-j-1}$ jednak nuli.

Stoga, ako su sve svojstvene vrijednosti matrice A_1 modula manjeg od 1, smatramo da je dobro definiran slučajni proces

$$X_t = \mu + \sum_{i=0}^{\infty} A_1^i Z_{t-i}, \forall t \in \mathbb{Z},$$

gdje je $\mu := (I_m - A_1)^{-1}\nu$. Kao što smo rekli, distribucija vektora X_t je jedinstveno određena distribucijom procesa $\{Z_t\}$ i vrijedi:

$$E[X_t] = \mu, \forall t \in \mathbb{Z}$$

i

$$\begin{aligned}
\Gamma_X(h) &:= E[(X_t - \mu)(X_{t-h} - \mu)^T] \\
&= \lim_{n \rightarrow \infty} \sum_{i=0}^n \sum_{j=0}^n A_1^i E[Z_{t-i} Z_{t-h-j}^T] (A_1^j)^T \\
&= \lim_{n \rightarrow \infty} \sum_{i=0}^n A_1^{h+i} \Sigma_Z (A_1^i)^T \\
&= \sum_{i=0}^{\infty} A_1^{h+i} \Sigma_Z (A_1^i)^T,
\end{aligned}$$

zbog definicije matrice kovarijanci bijelog šuma Σ_Z .

Kažemo da je VAR(1) proces **stabilan** ako su sve svojstvene vrijednosti matrice A_1 modula manjeg od jedan. Taj uvjet je ekvivalentan uvjetu $\det(I_m - A_1 z) \neq 0, \forall |z| \leq 1$ (vidi [4], Dodatak A.6, Pravilo 7). Bitno je za naglasiti da se proces (2.1) može definirati i ako uvjet stabilnosti nije zadovoljen, ali mi ćemo se baviti stabilnim procesima u ostatku rada.

Prethodno razmatranje se može lako proširiti na VAR(p) procese, $p > 1$, budući da se svaki VAR(p) proces može zapisati u formi VAR(1) procesa. Konkretno, ako imamo VAR(p) proces kao u (2.1), onda je odgovarajući mp -dimenzionalan VAR(1) proces dan s:

$$X_t = \nu + \mathbf{A}X_{t-1} + Z_t, \quad (2.2)$$

gdje je:

$$\begin{aligned}
X_t &:= (X_t, X_{t-1}, \dots, X_{t-p+1})^T, (mp \times 1), \\
\nu &:= (\nu, 0, \dots, 0)^T, (mp \times 1), \\
\mathbf{A} &:= \begin{pmatrix} A_1 & A_2 & \dots & A_{p-1} & A_p \\ I_m & 0 & \dots & 0 & 0 \\ 0 & I_m & & 0 & 0 \\ \vdots & & \dots & \vdots & \vdots \\ 0 & 0 & \dots & I_m & 0 \end{pmatrix}, (mp \times mp), \\
Z_t &:= (Z_t, 0, \dots, 0)^T, (mp \times 1)
\end{aligned}$$

s dimenzijama navedenim u zagradi. Analogno kao u slučaju VAR(1) procesa, slijedi da je $\{X_t\}$ stabilan ako je

$$\det(I_{mp} - Az) = \det(I_{mp} - A_1 z - \dots - A_p z^p) \neq 0, \forall |z| \leq 1.$$

2.2 Stacionarnost

2.2.1 Stabilnost i stacionarnost

Zapišimo proces $\{X_t\}$ u MA reprezentaciji koristeći operator pomaka unazad:

$$X_t = \nu + (A_1B + \dots + A_pB^p)X_t + Z_t,$$

odnosno uz oznaku $A(B) := I_m - A_1B - \dots - A_pB^p$,

$$A(B)X_t = \nu + Z_t.$$

Neka je $\Phi(B) := \sum_{i=0}^{\infty} \Phi_i B^i$ operator takav da vrijedi $\Phi(B)A(B) = I_m$. Odnosno, operator $\Phi(B)$ je inverz operatora $A(B)$ pa se nekada i označava s $A(B)^{-1}$. Općenito, kažemo da je operator $A(B)$ invertibilan ako je $\det(A(z)) \neq 0, \forall |z| \leq 1$. Ako to vrijedi, koeficijenti matrice $\Phi(B) = A(B)^{-1}$ su apsolutno sumabilni te je proces $\Phi(B)Z_t$ dobro definiran što će nam poslužiti zbog sljedećeg zapisa:

$$\begin{aligned} X_t &= \Phi(B)\nu + \Phi(B)Z_t \\ &= \sum_{i=0}^{\infty} \Phi_i \nu + \sum_{i=0}^{\infty} \Phi_i Z_{t-i}. \end{aligned}$$

Sada je matrica kovarijanci procesa X_t dana s:

$$\begin{aligned} \Gamma_X(h) &= E \left[(X_t - \nu) (X_{t-h} - \nu)^T \right] \\ &= E \left[\left(\sum_{i=0}^{h-1} \Phi_i Z_{t-i} + \sum_{i=0}^{\infty} \Phi_{h+i} Z_{t-h-i} \right) \left(\sum_{i=0}^{\infty} \Phi_i Z_{t-h-i} \right)^T \right] \\ &= \sum_{i=0}^{\infty} \Phi_{h+i} \Sigma_Z \Phi_i^T. \end{aligned}$$

Ovaj rezultat je vrlo važan jer temeljem njega i Propozicije 1.3. slijedi sljedeća propozicija:

Propozicija 2.1. *Stabilan VAR(p) proces $\{X_t, t \in \mathbb{Z}\}$ je stacionaran.*

Dakle, stabilnost implicira stacionarnost te je to razlog zašto se u literaturi uvjet stabilnosti često referira kao i uvjet stacionarnosti. Pogledajmo funkcije autokovarijanci i autokorelacija stabilnog, pa time i stacionarnog VAR(p) procesa.

2.2.2 Funkcija autokovarijanci stabilnog VAR(p) procesa

Pretpostavimo da je $\{X_t\}$ stabilan i stacionaran VAR(p) proces:

$$X_t = \nu + A_1 X_{t-1} + \dots + A_p X_{t-p} + Z_t.$$

Ukoliko proces zapišemo u tzv. 'mean-adjusted' formi, dobivamo:

$$X_t - \mu = A_1(X_{t-1} - \mu) + \dots + A_p(X_{t-p} - \mu) + Z_t,$$

gdje je $\mu = E[X_t]$. Pomnožimo li sve s $(X_t - \mu)^T$ i uzmemo li očekivanje, korištenjem svojstva $\Gamma_X(-h) = \Gamma_X(h)^T$, za $h=0$ dobivamo:

$$\begin{aligned} \Gamma_X(0) &= A_1 \Gamma_X(-1) + \dots + A_p \Gamma_X(-p) + \Sigma_Z \\ &= A_1 \Gamma_X(1)^T + \dots + A_p \Gamma_X(p)^T + \Sigma_Z, \end{aligned}$$

dok za $h > 0$ dobivamo: $\Gamma_X(h) = A_1 \Gamma_X(h-1) + \dots + A_p \Gamma_X(h-p)$. Ove jednadžbe se obično zovu **Yule-Walkerove jednadžbe**.

2.2.3 Autokorelacijska funkcija stabilnog VAR(p) procesa

Uz iste oznake kao kod računanja funkcije autokovarijanci stabilnog VAR(p) procesa, autokorelacijske funkcije stabilnog VAR(p) procesa možemo dobiti na sljedeći način: $R_X(h) = D^{-1} \Gamma_X(h) D^{-1}$, gdje je D dijagonalna matrica sa standardnim devijacijama komponenta od X_t na glavnoj dijagonali. Odnosno, dijagonalni elementi matrice D su zapravo korijeni dijagonalnih elemenata matrice $\Gamma_X(0)$.

Uz oznaku $\gamma_{ij}(h) := Cov(X_{i,t}, X_{j,t-h})$ (odnosno $\gamma_{ij}(h)$ je ij -ti element od $\Gamma_X(h)$), dijagonalni elementi $\gamma_{11}(0), \dots, \gamma_{mm}(0)$ matrice $\Gamma_X(0)$ su varijance od $X_{1,t}, \dots, X_{m,t}$. Dakle,

$$D^{-1} = \begin{pmatrix} 1/\sqrt{\gamma_{11}(0)} & & 0 \\ & \ddots & \\ 0 & & 1/\sqrt{\gamma_{mm}(0)} \end{pmatrix},$$

i koeficijent korelacije između $X_{i,t}$ i $X_{j,t-h}$ je dan s: $\rho_{ij}(h) = \frac{\gamma_{ij}(h)}{\sqrt{\gamma_{ii}(0)\gamma_{jj}(0)}}$.

2.2.4 Procjena parametara metodom najmanjih kvadrata

Pretpostavimo da je $\{X_t, t \in \mathbb{Z}\}$ stabilan, pa time i stacionaran, VAR(p) proces uz oznake kao u (2.1). No, u prethodnim razmatranjima smo pretpostavljali da su koeficijenti ν, A_1, \dots, A_p i matrica kovarijanci Σ_Z poznati, no zapravo se u praksi oni procjenjuju na osnovi podataka vremenskog niza.

Napomena 2.3. *Notacija se u daljnjim razmatranjima ne razlikuje u slučaju slučajnog procesa i vremenskog niza kao realizacije slučajnog procesa. No, iz konteksta će biti jasno značenje.*

Procjena spomenutih parametara se može provoditi na više načina - npr., procjena metodom najmanjih kvadrata, procjena metodom najmanjih kvadrata sa 'mean-adjusted' podacima, Yule-Walker procjena i *maximum likelihood* procjena. No, za potrebe ovog diplomskog rada navodimo samo metodu koja je korištena i u modelu, a to je metoda najmanjih kvadrata. Diskutirat ćemo kako izgleda taj procjenitelj te spomenuti neka njegova svojstva. Detaljnije o preostalim metodama se može vidjeti u [4], Poglavlje 3.

2.2.5 Procjena matrice koeficijenata

Pretpostavimo kao i dosad da raspoložemo s m vremenskih nizova duljine T , ali i da za svaki vremenski niz imamo poznatih p prethodnih vrijednosti. Uvedimo sljedeće oznake:

$$\begin{aligned} X &:= (X_1, \dots, X_T), (m \times T) \\ B &:= (\nu, A_1, \dots, A_p), (m \times (mp + 1)) \\ Y_t &:= (1, X_t, \dots, X_{t-p+1})^T, ((mp + 1) \times 1) \\ Y &:= (Y_0, \dots, Y_{T-1}), ((mp + 1) \times T) \\ Z &:= (Z_1, \dots, Z_T), (m \times T), \end{aligned}$$

dimenzija navedenih u zagradi. Koristeći te oznake, VAR(p) model (2.1) možemo zapisati kao: $X = BY + Z$, odnosno kao $vec(X) = vec(BY) + vec(Z) = Y^T \otimes I_m vec(B) + vec(Z)$, gdje je \otimes Kroneckerov produkt, a vec operator slaganja stupaca (više u [4], Dodatak A).

Procjenitelja metodom najmanjih kvadrata možemo dobiti na sljedeći način: izraz

$$X_t = BY_{t-1} + Z_t$$

pomnožimo s Y_{t-1}^T i uzmemo očekivanje:

$$E[X_t Y_{t-1}^T] = BE[Y_{t-1} Y_{t-1}^T].$$

Procjenimo li $E[X_t Y_{t-1}^T]$ s

$$\frac{1}{T} \sum_{t=1}^T X_t Y_{t-1}^T = \frac{1}{T} X Y^T,$$

a $E[Y_{t-1}Y_{t-1}^T]$ s

$$\frac{1}{T} \sum_{t=1}^T Y_{t-1}Y_{t-1}^T = \frac{1}{T} YY^T,$$

dobivamo normalne jednadžbe

$$\frac{1}{T} XY^T = B \frac{1}{T} YY^T,$$

iz čega slijedi da je

$$\widehat{B} = XY^T(YY^T)^{-1}.$$

Spomenimo sad neke rezultate koji će nam trebati kasnije.

Definicija 2.4. (Standardni bijeli šum) *Bijeli šum $Z_t = (Z_{1,t}, \dots, Z_{m,t})^T$ se naziva standardni bijeli šum ako su Z_t neprekidni slučajni vektori takvi da vrijedi $E[Z_t] = 0$, $\Sigma_Z = E[Z_t Z_t^T]$ nije singularna, Z_t i Z_s su nezavisni za $t \neq s$ i za neku konačnu konstantu c vrijedi:*

$$E[|Z_{i,t}Z_{j,t}Z_{k,t}Z_{l,t}|] \leq c, \text{ za } i, j, k, l = 1, \dots, m \text{ i } \forall t.$$

Nadalje, označimo $\Gamma = p - \lim \frac{YY^T}{T}, T \rightarrow \infty$.

Lema 2.1. *Neka je $\{X_t\}$ stabilan, m -dimenzionalan $\text{VAR}(p)$ proces kao u (2.1) gdje su reziduali $\{Z_t\}$ standardni bijeli šum. Tada vrijedi:*

(i) Γ postoji i nije singularna

(ii) $\frac{1}{\sqrt{T}} \sum_{t=1}^T \text{vec}(Z_t Y_{t-1}^T) = \frac{1}{\sqrt{T}} \text{vec}(ZY^T) \xrightarrow{d} \mathcal{N}(0, \Gamma \otimes \Sigma_Z)$, za $T \rightarrow \infty$.

Dokaz. Vidi Fuller(1976, str. 340, tm. 8.2.3). □

Propozicija 2.2. (Asimptotska svojstva LS procjenitelja) *Neka je $\{X_t\}$ stabilan, m -dimenzionalan $\text{VAR}(p)$ proces kao u (2.1) gdje su reziduali $\{Z_t\}$ standardni bijeli šum i $\widehat{B} = XY^T(YY^T)^{-1}$ LS procjenitelj VAR koeficijenata B uz oznake kao u 2.2.5. Onda vrijedi:*

(i) \widehat{B} je konzistentan procjenitelj za B

(ii) $\sqrt{T} \text{vec}(\widehat{B} - B) \xrightarrow{d} \mathcal{N}(0, \Gamma^{-1} \otimes \Sigma_Z)$.

Dokaz. (i) Zapišimo \widehat{B} na sljedeći način

$$\begin{aligned}\widehat{B} &= XY^T(YY^T)^{-1} \\ &= (BY + Z)Y^T(YY^T)^{-1} \\ &= B + ZY^T(YY^T)^{-1}\end{aligned}$$

Sada vrijedi

$$p - \lim(\widehat{B} - B) = p - \lim\left(\frac{ZY^T}{T}\right)p - \lim\left(\frac{YY^T}{T}\right)^{-1} = 0$$

jer Lema 2.1.(ii) povlači da je $p - \lim\left(\frac{ZY^T}{T}\right) = 0$.

Iz toga slijedi konzistentnost procjenitelja \widehat{B} .

(ii) Označimo $\beta = \text{vec}(B^T)$. Analogno je dokazati da

$$\sqrt{T}\text{vec}(\widehat{\beta} - \beta) \xrightarrow{d} \mathcal{N}(0, \Gamma^{-1} \otimes \Sigma_Z).$$

Uz oznaku $z = \text{vec}(Z)$, vrijedi

$$\begin{aligned}\sqrt{T}\text{vec}(\widehat{\beta} - \beta) &= \sqrt{T}((YY^T)^{-1}Y \otimes I_m)z \\ &= \left(\left(\frac{1}{T}YY^T \right)^{-1} \otimes I_m \right) \frac{1}{\sqrt{T}}(Y \otimes I_m)z.\end{aligned}$$

Prema [4], Dodatak C, Propozicija C.2 (4), $\sqrt{T}\text{vec}(\widehat{\beta} - \beta)$ ima ista asimptotska svojstva kao

$$(p - \lim \left(\frac{1}{T}YY^T \right)^{-1} \otimes I_m) \frac{1}{\sqrt{T}}(Y \otimes I_m)z = (\Gamma^{-1} \otimes I_m) \frac{1}{\sqrt{T}}(Y \otimes I_m)z.$$

Prema Lemi 2.1. je asimptotska distribucija od $\sqrt{T}\text{vec}(\widehat{\beta} - \beta)$ normalna s matricom kovarijanci

$$(\Gamma^{-1} \otimes I_m)(\Gamma \otimes \Sigma_Z)(\Gamma^{-1} \otimes I_m) = \Gamma^{-1} \otimes \Sigma_Z.$$

□

Vidimo da su nam za procjenitelja matrice koeficijenata potrebne matrice Γ i Σ_Z . Konzistentan procjenitelj za Γ je iz Leme 2.1. upravo $\widehat{\Gamma} = \frac{YY^T}{T}$, dok nam još preostaje naći konzistentnog procjenitelja za matricu kovarijanci bijelog šuma Σ_Z .

2.2.6 Procjena matrice kovarijanci bijelog šuma

Budući da je $\Sigma_Z = E[Z_t Z_t^T]$, procjenitelja možemo naći na sljedeći način:

$$\begin{aligned}
\tilde{\Sigma}_Z &= 1/T \sum_{t=1}^T (\hat{Z}_t (\hat{Z}_t)^T) \\
&= \frac{1}{T} \hat{Z}_t (\hat{Z}_t)^T \\
&= \frac{1}{T} (X - \hat{B}Y)(X - \hat{B}Y)^T \\
&= \frac{1}{T} [(X - XY^T (YY^T)^{-1})Y][(X - XY^T (YY^T)^{-1})Y]^T \\
&= \frac{1}{T} X [I_T - Y^T (YY^T)^{-1}Y] [I_T - Y^T (YY^T)^{-1}Y]^T X^T \\
&= \frac{1}{T} X [I_T - Y^T (YY^T)^{-1}Y] X^T.
\end{aligned}$$

Navedeni se procjenitelj korigira stupnjevim slobode i dobivamo: $\hat{\Sigma}_Z = \frac{T}{T-mp-1} \tilde{\Sigma}_Z$. Procjenitelji su asimptotski ekvivalentni i u uvjetima Propozicije 2.2. su konzistentni.

Propozicija 2.3. (Asimptotska svojstva procjenitelja matrice kovarijanci WN) *Neka je $\{X_t\}$ stabilan, m -dimenzionalan VAR(p) proces kao u (2.1) s rezidualima koji su standardni bijeli šum i neka je \bar{B} procjenitelj matrice koeficijenata B takav da $\sqrt{T} \text{vec}(\bar{B} - B)$ konvergira po distribuciji. Nadalje, koristeći oznake kao u 2.2.5, pretpostavimo da je $\bar{\Sigma}_Z = (X - \bar{B}Y)(X - \bar{B}Y)^T / (T - c)$, gdje je c konstanta. Tada vrijedi:*

$$p - \lim \sqrt{T} (\bar{\Sigma}_Z - ZZ^T / T) = 0.$$

Dokaz. Vrijedi

$$\begin{aligned}
\frac{1}{T} (X - \bar{B}Y)(X - \bar{B}Y)^T &= (B - \bar{B}) \left(\frac{YY^T}{T} \right) (B - \bar{B})^T \\
&\quad + (B - \bar{B}) \frac{YZ^T}{T} + \frac{ZY^T}{T} (B - \bar{B})^T + \frac{ZZ^T}{T}.
\end{aligned}$$

Pod uvjetima propozicije je $p - \lim (B - \bar{B}) = 0$. Stoga, po Lemi 2.1. je

$$p - \lim (B - \bar{B}) Y Z^T / \sqrt{T} = 0$$

i

$$p - \lim \left((B - \bar{B}) \frac{YY^T}{T} \sqrt{T} (B - \bar{B})^{-1} \right) = 0.$$

Konačno,

$$p - \lim \sqrt{T} [(X - \bar{B}Y)(X - \bar{B}Y)^T / T - ZZ^T / T] = 0.$$

Budući da $T/(T - c) \rightarrow 1$, za $T \rightarrow \infty$, slijedi tvrdnja propozicije. □

Ova propozicija pokriva oba procjenitelja $\widehat{\Sigma}_Z$ i $\widetilde{\Sigma}_Z$.

Korolar 2.1. *Pod uvjetima Propozicije 2.3. vrijedi:*

$$p - \lim \widehat{\Sigma}_Z = p - \lim \widetilde{\Sigma}_Z = p - \lim ZZ^T/T = \Sigma_Z.$$

Dokaz. Zbog Propozicije 2.3., dovoljno je pokazati da vrijedi $p - \lim ZZ^T/T = \Sigma_Z$.

Budući da je

$$E \left[\frac{1}{T} ZZ^T \right] = \frac{1}{T} \sum_{t=1}^T E(Z_t Z_t^T) = \Sigma_Z$$

i

$$\text{Var} \left(\frac{1}{T} \text{vec}(ZZ^T) \right) = \frac{1}{T^2} \sum_{t=1}^T \text{Var}[\text{vec}(Z_t Z_t^T)] \leq \frac{T}{T^2} q \rightarrow 0, T \rightarrow \infty,$$

gdje je q konstanta koja je gornja granica za $\text{Var}[\text{vec}(Z_t Z_t^T)]$ i koja postoji jer su četvrti momenti od Z_t omeđeni prema Definiciji 2.4. \square

2.2.7 Procjena očekivanja

Prisjetimo se *mean-adjusted* forme modela iz 2.2.2.:

$$X_t - \mu = A_1(X_{t-1} - \mu) + \dots + A_p(X_{t-p} - \mu) + Z_t.$$

Često očekivanje procesa μ nije poznato te ga procjenjujemo aritmetičkom sredinom uzorka, odnosno:

$$\bar{X} = \frac{1}{T} \sum_{t=1}^T X_t.$$

Zapravo, koristeći *mean-adjusted* formu, \bar{X} možemo zapisati na sljedeći način:

$$\begin{aligned} \bar{X} &= \mu + A_1[\bar{X} + \frac{1}{T}(X_0 - X_T) - \mu] + \dots \\ &+ A_p[\bar{X} + \frac{1}{T}(X_{-p+1} + \dots + X_0 - X_{T-p+1} - \dots - X_T) - \mu] \\ &+ \frac{1}{T} \sum_{t=1}^T Z_T. \end{aligned}$$

Vrijedi i:

$$(I_m - A_1 - \dots - A_p)(\bar{X} - \mu) = \frac{1}{T} Y_T + \frac{1}{T} \sum_t^T Z_T, \quad (2.3)$$

gdje je $Y_T = \sum_{i=1}^p A_i [\sum_{j=0}^{i-1} (X_{0-j} - X_{T-j})]$.

Budući da je $\{X_t\}$ stabilan, vrijedi: $E[Y_T/\sqrt{T}] = 0$ i $\text{Var}(Y_T/\sqrt{T}) \rightarrow 0$, kad $T \rightarrow \infty$

odnosno Y_T/\sqrt{T} konvergira k nuli u srednje kvadratnom smislu. Stoga, ukoliko (2.3) pomnožimo s \sqrt{T} i primijenimo to svojstvo, dobivamo da $\sqrt{T}(I_m - A_1 - \dots - A_p)(\bar{X} - \mu)$ ima ista asimptotska distribucijska svojstva kao $\frac{1}{\sqrt{T}} \sum_t Z_T$ (više u [4], Dodatak A, Propozicija C.2). Budući da po centralnom graničnom teoremu vrijedi:

$$\frac{1}{\sqrt{T}} \sum_{t=1}^T Z_t \xrightarrow{d} \mathcal{N}(0, \Sigma_Z), T \rightarrow \infty$$

slijedi sljedeći rezultat:

Propozicija 2.4. (Asimptotska svojstva aritmetičke sredine prosjeka) *Ako je $\{X_t\}$ stabilan VAR(p) proces dan s (2.1) i reziduali $\{Z_t\}$ standardni bijeli šum, onda vrijedi:*

$$\sqrt{T}(\bar{X} - \mu) \xrightarrow{d} \mathcal{N}(0, \Sigma_{\bar{X}}),$$

gdje je

$$\Sigma_{\bar{X}} = (I_m - A_1 - \dots - A_p)^{-1} \Sigma_Z ((I_m - A_1 - \dots - A_p)^T)^{-1}.$$

Specijalno, $\bar{X} \xrightarrow{d} \mu$.

Dokaz. Dokaz slijedi iz zapisa koji prethode Propoziciji 2.4. i Propoziciji C.15 iz [4], Dodatak C. □

Alternativni procjenitelj očekivanja se može dobiti iz LS procjenitelja matrice koeficijena i sljedećeg je oblika: $\hat{\mu} = (I_m - \hat{A}_1 - \dots - \hat{A}_p)^{-1} \hat{v}$. Procjenitelj je također konzistentan i asimptotski normalan ([4], Propozicija C.15, Dodatak C).

2.3 Grangerova uzročnost

Granger je 1969. godine definirao koncept uzročnosti (kauzalnosti) koji je posljednjih godina postao prilično popularan. Ideja je da uzrok ne može doći nakon učinka (efekta). Da bismo formalizirali ideju, označimo s Ω_t skup informacija koji sadrži sve relevantne informacije u svemiru do trenutka t , uključujući i njega. Neka je $z_t(h|\Omega_t)$ optimalan h -prediktor procesa $\{z_t\}$ u odnosu na informacije u Ω_t . h -prediktor je prediktor koji radi predviđanje h koraka unaprijed, a optimalnost se promatra u odnosu na minimalnu srednje kvadratnu grešku (MSE). Odgovarajuća MSE predikcije neka bude označena sa $\Sigma_z(h|\Omega_t)$.

Kažemo da proces $\{\mathbf{x}_t\}$ **uzrokuje** $\{z_t\}$ u Grangerovom smislu ako vrijedi:

$$\Sigma_z(h|\Omega_t) < \Sigma_z(h|\Omega_t \setminus \{x_s | s \leq t\}), \text{ za barem jedan } h = 1, 2, \dots$$

$\Omega_t \setminus \{x_s | s \leq t\}$ je skup koji sadrži sve relevantne informacije iz svemira osim prošlih i sadašnjih vrijednosti procesa $\{x_t\}$.

Pojednostavljeno rečeno, ako $\{z_t\}$ može biti efikasnije predviđen na temelju informacija procesa $\{x_t\}$, onda kažemo da je $\{x_t\}$ Granger-kauzalan za $\{z_t\}$.

Proširimo ovu definiciju na slučaj kad je $\{z_t\}$ M -dimenzionalan, a $\{x_t\}$ N -dimenzionalan proces. Tada kažemo da $\{x_t\}$ je Granger-kauzalan za $\{z_t\}$ ako vrijedi:

$$\Sigma_z(h|\Omega_t) \leq \Sigma_z(h|\Omega_T \setminus \{x_s | s \leq t\}),$$

odnosno ako je razlika desne i lijeve matrice pozitivno semidefinitna. Budući da je i nul-matrica pozitivno semidefinitna, nužno je zahtijevati da te dvije matrice nisu jednake.

Inače, ako $\{x_t\}$ uzrokuje $\{z_t\}$ i $\{z_t\}$ uzrokuje $\{x_t\}$, kažemo da imamo povratni sustav (*engl. feedback system*).

2.3.1 Karakterizacija Grangerove uzročnosti VAR procesa

Podsjetimo se MA reprezentacije m -dimenzionalnog VAR procesa:

$$X_t = \mu + \sum_{i=0}^{\infty} (\Phi_i Z_{t-i}) = \mu + \Phi(B)Z_t, \quad (2.4)$$

gdje je $\Phi_0 = I_m$. Pretpostavimo sada da se $\{X_t\}$ sastoji od M -dimenzionalnog procesa $\{z_t\}$ i $(m-M)$ -dimenzionalnog procesa $\{x_t\}$ i da je MA reprezentacija particionirana:

$$X_t = \begin{pmatrix} z_t \\ x_t \end{pmatrix} = \begin{pmatrix} \mu_1 \\ \mu_2 \end{pmatrix} + \begin{pmatrix} \Phi_{11}(B) & \Phi_{12}(B) \\ \Phi_{21}(B) & \Phi_{22}(B) \end{pmatrix} \begin{pmatrix} Z_{1,t} \\ Z_{2,t} \end{pmatrix}. \quad (2.5)$$

Vrijedi:

$$z_t(1|\{X_s | s \leq t\}) = [I_M : 0]X_t(1) = \mu_1 + \sum_{i=1}^{\infty} \Phi_{11,i}Z_{1,t+1-i} + \sum_{i=1}^{\infty} \Phi_{12,i}Z_{2,t+1-i}, \quad (2.6)$$

te je stoga greška predikcije:

$$z_{t+1} - z_t(1|\{X_s | s \leq t\}) = Z_{1,t+1}.$$

z_t također ima MA reprezentaciju kao podproces stacionarnog procesa te vrijedi:

$$z_t = \mu_1 + \sum_{i=1}^{\infty} \Phi_{11,i}Z_{1,t-i} + \sum_{i=1}^{\infty} \Phi_{12,i}Z_{2,t-i} = \mu_1 + \sum_{i=0}^{\infty} F_i v_{t-i}, \quad (2.7)$$

gdje je $F_0 = I_M$.

Sada je 1-prediktor temeljem $\{z_t\}$

$$z_t(1|\{z_s|s \leq t\}) = \mu_1 + \sum_{i=1}^{\infty} F_i v_{t+1-i}, \quad (2.8)$$

a pripadajuća greška predikcije je

$$z_{t+1} - z_t(1|\{z_s|s \leq t\}) = v_{t+1}.$$

Prediktori (2.6) i (2.8) su jednaki ako i samo ako je $v_t = u_{1,t}, \forall t$, a jednakost tih prediktora povlači da $\{z_t\}$ ima i sljedeću MA reprezentaciju:

$$z_t = \mu_1 + \sum_{i=0}^{\infty} F_i u_{q,t-i}. \quad (2.9)$$

Zbog jedinstvenosti MA reprezentacije (2.7) i (2.9) mora biti jednako, a to povlači da je $F_i = \Phi_{11,i}$ i $\Phi_{12,i} = 0, \forall i = 1, 2, \dots$. Iz toga slijedi propozicija:

Propozicija 2.5. (Karakterizacija Grangerove neuzročnosti) *Neka je $\{X_t\}$ VAR(p) proces kao u (2.4) i (2.5) s kanonskim MA operatorom $\Phi(z)$. Tada vrijedi:*

$$z_t(1|\{X_s|s \leq t\}) = z_t(1|\{z_s|s \leq t\}) \Leftrightarrow \Phi_{12,i} = 0, \forall i = 1, 2, \dots$$

Ova propozicija daje nužan i dovoljan uvjet da x_t nije Granger-kauzalan za z_t i to za sve procese koji imaju MA reprezentaciju. Odnosno, ako imamo proces $\{X_t\}$ kao u (2.5), proces $\{x_t\}$ nije Granger-kauzalan za $\{z_t\}$ ako i samo ako su sve matrice koeficijenata uz $\{x_t\}$ u jednadžbi za $\{z_t\}$ jednake nul-matrici.

U pogledu stacionarnih, stabilnih VAR(p) modela imamo sljedeće:

$$X_t = \begin{pmatrix} z_t \\ x_t \end{pmatrix} = \begin{pmatrix} \nu_1 \\ \nu_2 \end{pmatrix} + \begin{pmatrix} A_{11,1} & A_{12,1} \\ A_{21,1} & A_{22,1} \end{pmatrix} \begin{pmatrix} z_{t-1} \\ x_{t-1} \end{pmatrix} + \dots + \begin{pmatrix} A_{11,p} & A_{12,p} \\ A_{21,p} & A_{22,p} \end{pmatrix} \begin{pmatrix} z_{t-p} \\ x_{t-p} \end{pmatrix} + \begin{pmatrix} Z_{1t} \\ Z_{2t} \end{pmatrix}. \quad (2.10)$$

Korolar 2.2. *Ako je X_t stabilan VAR(p) proces kao u (2.10) sa nesingularnom matricom kovarijanci bijelog šuma Σ_Z , onda vrijedi:*

$$z_t(h|\{X_s|s \leq t\}) = z_t(h|\{z_s|s \leq t\}), h = 1, 2, \dots \Leftrightarrow A_{12,i} = 0, \forall i = 1, \dots, p.$$

Alternativno,

$$x_t(h|\{X_s|s \leq t\}) = x_t(h|\{x_s|s \leq t\}), h = 1, 2, \dots \Leftrightarrow A_{21,i} = 0, \forall i = 1, \dots, p.$$

Ovaj korolar implicira da se neuzročnost može uočiti samo iz promatranja VAR reprezentacije procesa. Odnosno, ako imamo VAR proces kao u (2.10), proces $\{x_t\}$ nije Granger-kauzalan za $\{z_t\}$ ako su u jednadžbi za proces $\{z_t\}$ sve matrice koeficijenta uz proces $\{x_t\}$ jednake nul-matrici.

2.3.2 Waldov test Grangerove uzročnosti

Ukoliko u procijenjenom VAR(p) modelu želimo testirati Grangerovu uzročnost, potrebno je testirati ograničenja koeficijenata za što nam je potrebna Waldova statistika. Uz oznake kao u Poglavlju 2.2.5, neka je $\beta := \text{vec}(B)$ vektor dimenzija $((m^2p + m) \times 1)$. Testiramo hipoteze $\mathcal{H}_0 : C\beta = c$ i $\mathcal{H}_1 : C\beta \neq c$, gdje je C ($N \times (m^2p + m)$) matrica ranga N , a c je ($N \times 1$) vektor.

Pretpostavimo li da je

$$\sqrt{T}(\hat{\beta} - \beta) \xrightarrow{d} \mathcal{N}(0, \Gamma^{-1} \otimes \Sigma_Z), T \rightarrow \infty$$

kao u prethodnom potpoglavlju, dobivamo

$$\sqrt{T}(C\hat{\beta} - C\beta) \xrightarrow{d} \mathcal{N}(0, C(\Gamma^{-1} \otimes \Sigma_Z)C^T), T \rightarrow \infty$$

te je stoga

$$T(C\hat{\beta} - c)^T [C(\Gamma^{-1} \otimes \Sigma_Z)C^T]^{-1} (C\hat{\beta} - c) \xrightarrow{d} \chi^2(N), T \rightarrow \infty.$$

Ta statistika se zove **Waldova statistika**.

Zamijenimo li Γ i Σ_Z njihovim procjeniteljima $\hat{\Gamma} = YY^T/T$ i $\hat{\Sigma}_Z$, dobivamo statistiku:

$$\lambda_W = (C\hat{\beta} - c)^T [C((YY^T)^{-1} \otimes \hat{\Sigma}_Z)C^T]^{-1} (C\hat{\beta} - c)$$

koja u uvjetima istinitosti nul-hipoteze ima asimptotsku $\chi^2(N)$ distribuciju.

Moguća je sljedeća korekcija test statistike

$$\lambda_F = \lambda_W/N \approx F(N, mT - m^2p - m) \approx F(N, T - mp - 1).$$

Time smo dobili statistiku koja se može aproksimirati F-statistikom koja ima "lakše" repove od $\chi^2(N)$ distribucije.

2.4 Identifikacija modela

U prethodnim poglavljima smo pretpostavljali da imamo poznat red VAR modela p . U praksi je red obično nepoznat. Pod identifikacijom modela smatramo određivanje reda modela. Odabirom nepotrebno velikog reda p smanjujemo preciznost predikcije odgo-varajućeg procijenjenog VAR modela. Iz dosadašnjih razmatranja možemo zaključiti da ne postoji jedan točan red VAR modela. Primjerice, ako imamo proces:

$$X_t = \nu + A_1 X_{t-1} + \dots + A_p X_{t-p} + Z_t, t \in \mathbb{Z},$$

isto vrijedi i za proces

$$X_t = \nu + A_1 X_{t-1} + \cdots + A_p X_{t-p} + A_{p+1} X_{t-p-1} + Z_t, t \in \mathbb{Z}$$

uz uvjet $A_{p+1} = 0$. Odnosno, ako je $\{X_t\}$ VAR(p) proces, tada je on u ovom smislu i VAR($p+1$) proces jer nismo postavili nikakav uvjet koji isključuje jednakost matrice koeficijenata nul-matrici. Stoga je nužno da u ovom trenutku uvedemo uvjet za jedinstveni broj koji će biti red modela. U nastavku ćemo reći da je $\{X_t\}$ VAR(p) proces ako je $A_p \neq 0$ i $A_i = 0, \forall i > p$, tako da je p najmanji mogući red.

2.4.1 LR test statistika

Pretpostavimo da je poznata gornja granica M za mogući red VAR modela. Od različitih pristupa za određivanje reda, promatrat ćemo onaj koji se temelji na *likelihood ratio* statistici. Statistički test temeljen na LR statistici se bazira na usporedbi maksimuma logaritma funkcije vjerodostojnosti (*engl. log-likelihood*) restringiranog i nerestringiranog prostora parametara na temelju kojeg je definirana nul-hipoteza. Konkretno, LR statistika je oblika: $\lambda_{LR} = 2[\ln(l(\tilde{\delta}) - \ln(l(\tilde{\delta}_r))]$, gdje je $\tilde{\delta}$ nerestringirani ML procjenitelj za vektor parametara δ dobiven maksimiziranjem funkcije vjerodostojnosti nad cijelim prostorom parametara, a $\tilde{\delta}_r$ restringirani ML procjenitelj koji je dobiven maksimiziranjem funkcije vjerodostojnosti nad prostorom parametara s ispunjenim restrikcijama. λ_{LR} ima asimptotski $\chi^2(N)$ distribuciju, gdje je N broj linearnih restrikcija.

Najprije testiramo hipotezu $\mathcal{H}_0 : A_M = 0$. Ako se nul-hipoteza ne odbaci, testiramo dalje hipotezu $\mathcal{H}_0 : A_{M-1} = 0$ i tako sve dok ne dođemo do situacije da odbacimo nul-hipotezu. Pogledajmo shemu:

$$\begin{aligned} \mathcal{H}_0^1 : A_M = 0 & \quad ; \quad \mathcal{H}_1^1 : A_M \neq 0 \\ \mathcal{H}_0^2 : A_{M-1} = 0 & \quad ; \quad \mathcal{H}_1^2 : A - M - 1 \neq 0 | A_M = 0 \\ & \quad \quad \quad \vdots \quad \quad \quad \vdots \\ \mathcal{H}_0^M : A_1 = 0 & \quad ; \quad \mathcal{H}_1^M : A_1 \neq 0 | A_M = \cdots = A_2 = 0. \end{aligned}$$

Dakle, svaka nova nul-hipoteza se testira uvjetno na to da prethodna nije odbačena. LR statistika za testiranje i -te nul-hipoteze je dana s:

$$\lambda_{LR}(i) = T[\ln |\tilde{\Sigma}_Z(M-i)| - \ln |\tilde{\Sigma}_Z(M-i+1)|],$$

gdje $\tilde{\Sigma}_Z$ označava ML procjenitelja $\Sigma_Z(k)$ kad imamo VAR(k) model na uzorku veličine T i u tom slučaju vrijedi $\lambda_{LR}(i) \sim \chi^2(m^2)$, budući da je u svakoj \mathcal{H}_0^i m^2 parametara

postavljeno na nulu.

Bitno je za napomenuti da je razina značajnosti pojedinog testa različita od greške tipa I cijele procedure budući da odbacivanje \mathcal{H}_0^i znači da su odbačene i $\mathcal{H}_0^{i+1}, \dots, \mathcal{H}_0^M$. Ukoliko s D_j označimo događaj da je \mathcal{H}_0^j odbačena u j -tom testu kad je zapravo istinita, vjerojatnost greške tipa I za i -ti test u nizu je $\varepsilon_i = P(D_1 \cup D_2 \cup \dots \cup D_i)$, dok je $\gamma_j = P(D_j)$ razina značajnosti j -tog testa. Nadalje, može se pokazati da su za $l \neq j, l, j \leq i$ $\lambda_{LR}(l)$ i $\lambda_{LR}(j)$ asimptotski nezavisne statistike ako su $\mathcal{H}_0^1, \dots, \mathcal{H}_0^i$ istinite. Stoga su D_l i D_j nezavisni događaji za velike uzorke te vrijedi:

$$\begin{aligned} \varepsilon_i &= P(D_1 \cup D_2 \cup \dots \cup D_{i-1}) + P(D_i) - P((D_1 \cup D_2 \cup \dots \cup D_{i-1}) \cap D_i) \\ &= \varepsilon_{i-1} + \gamma_i - \varepsilon_{i-1}\gamma_i \\ &= \varepsilon_{i-1} + \gamma_i(1 - \varepsilon_{i-1}), \end{aligned}$$

$i = 2, 3 \dots, M$.

Za prvi test vrijedi $\gamma_i = \varepsilon_i$. Induktivno, vrijedi:

$$\varepsilon_i = 1 - (1 - \gamma_1) \dots (1 - \gamma_i), i = 1, 2, \dots, M.$$

2.4.2 Kriteriji za određivanje reda modela

Iako je izvođenje statističkih testova dobra strategija za detekciju parametara različitih od nule, takav pristup za specifične svrhe nije potpuno zadovoljavajuć. Primjerice, ako se VAR model koristi za predikciju, onda nismo posebno zainteresirani za pronalazak točnog reda modela. Više nas zanima model koji će biti dobar u smislu predikcije. Stoga ćemo u ovom poglavlju navesti kriterije koji se koriste za određivanje reda modela.

Ukoliko je cilj modela predviđanje, onda ima smisla odabrati takav red za kojeg je srednje kvadratna greška (*engl. mean squared error*) predikcije minimalna. Stoga Akaike (1969, 1971) predlaže da red modela odaberemo na temelju srednje kvadratne greške predikcije jedan korak unaprijed (vidljivo u [4], Poglavlje 3):

$$\Sigma_{\hat{X}}(1) = \frac{T + mr + 1}{t} \Sigma_Z,$$

gdje je r red modela procijenjen na podacima. Da bismo mogli ovo koristiti, Σ_Z zamijenimo procjenom matrice kovarijanci bijelog šuma $\hat{\Sigma}_Z$. Budući da je jednostavnije imati skalarni kriterij nego matricu, Akaike predlaže da se koristi LS procjenitelj s korekcijom stupnjeva slobode i uzme determinanta dobivene procjene matrice kovarijanci:

$$\Sigma_Z(r) = \frac{T}{T - mr - 1} \tilde{\Sigma}_Z(r).$$

Time dobivamo kriterij/mjeru **finalna prediktivna greška** (FPE) definiranu izrazom:

$$FPE(r) = \det \left(\frac{T + mr + 1}{T} \frac{T}{t - mr - 1} \tilde{\Sigma}_Z(r) \right) = \left(\frac{T + mr + 1}{T - mr - 1} \right)^m \det \left(\tilde{\Sigma}_Z(r) \right).$$

Na temelju ovog kriterija procjenu reda \hat{p} dobivamo kao $\arg \min_{r=0,1,\dots,M} FPE(r)$.

Akaike (1973, 1974) izvodi novi kriterij poznat kao **Akaike informacijski kriterij** (AIC) definiran s:

$$AIC(r) = \ln |\tilde{\Sigma}_Z(r)| + \frac{2rm^2}{T}.$$

Na temelju ovog kriterija procjenu reda \hat{p} dobivamo kao $\arg \min_{r=0,1,\dots,M} AIC(r)$.

Može se pokazati da vrijedi sljedeća veza između ova dva kriterija:

$$\ln FPE(r) = AIC(r) + 2m/T + \mathcal{O}(T^{-2}).$$

No, ovi procjenitelji nisu konzistentni (vidi [4] Poglavlje 4, Propozicija 4.2 i Korolar 4.2.1). Stoga, spomenimo dva procjenitelja koji su u posljednje vrijeme postali dosta popularni u primjeni, a konzistentni su. To su **Hannan-Quinn kriterij** (HQ) i **Schwarzov kriterij** (SC) definirani na sljedeći način:

$$HQ(r) = \ln |\tilde{\Sigma}_Z(r)| + \frac{2 \ln(\ln T)}{T} rm^2,$$

$$SC(r) = \ln |\tilde{\Sigma}_Z(r)| + \frac{\ln T}{T} rm^2.$$

Sljedeći rezultat uspoređuje ove kriterije.

Propozicija 2.6. (Usporedba AIC, HQ i SC kriterija za male uzorke) *Neka je $x_{-M+1}, \dots, x_0, x_1, \dots, x_T$ bilo koji m -dimenzionalan vremenski niz te neka je $VAR(r)$, $r = 0, 1, \dots, M$ model kojim modeliramo podatke x_1, \dots, x_T . Tada vrijede sljedeće relacije:*

$$\hat{p}(SC) \leq \hat{p}(AIC) \quad \forall T \geq 8,$$

$$\hat{p}(SC) \leq \hat{p}(HQ) \quad \forall T,$$

$$\hat{p}(HQ) \leq \hat{p}(AIC) \quad \forall T \geq 16.$$

Dakle, za manje uzorke AIC i FPE imaju bolja svojstva (izabiru dobar red češće) od HQ i SC kriterija, a također i minimiziraju varijancu greške predikcije i općenito daju bolje predikcije.

2.5 Dijagnostika modela

Pod dijagnostikom modela smatramo kritički analizirati model i odabrati najbolji među kandidatima. Dijagnostika se temelji na analizi reziduala. Poželjno svojstvo bi bilo da se reziduali ponašaju kao bijeli šum, no sve ovisi o svrsi modela. Ako je, na primjer, predikcija glavna svrha modela, to svojstvo nije toliko bitno ukoliko model dobro predviđa. No, ako je primjerice red modela određen nekom nestatističkom metodom (recimo na osnovu neke teorije), onda bi bilo poželjno imati neke statističke alate koji će analizirati svojstva reziduala te provjeriti ispravnost te odluke. Također, budući da različite procedure i kriteriji provjeravaju različite aspekte modela, poželjno bi bilo koristiti više statističkih alata te između više potencijalnih modela odabrati bolji, a te usporedbe se upravo vrše na osnovi analize reziduala i prediktivne sposobnosti modela.

2.5.1 Korelacija reziduala

Pretpostavimo da je $\{Z_t\}$ m -dimenzionalan bijeli šum s nesingularnom matricom kovarijanci Σ_Z . $\{Z_t\}$ može predstavljati na primjer rezidualne VAR(p) procesa. Matricu kovarijanci procesa $\{Z_t\}$ procjenjujemo s:

$$\hat{\Gamma}_Z(h) := \frac{1}{T} \sum_{t=h+1}^T Z_t Z_{t-h}^T.$$

U 2.2.3 smo naveli da korelacijsku matricu možemo dobiti iz matrice kovarijanci na sljedeći način: $R_Z(h) = D^{-1}\Gamma_Z(h)D^{-1}$, gdje je D dijagonalna matrica sa standardnim devijacijama komponenta od Z_t na glavnoj dijagonali, odnosno, dijagonalni elementi matrice D su zapravo korijeni dijagonalnih elemenata matrice $\Gamma_Z(0)$. Stoga, temeljem procjenitelja matrice kovarijanci definiramo i procjenitelja matrice korelacija: $\hat{R}_Z(h) = \hat{D}^{-1}\hat{\Gamma}_Z(h)\hat{D}^{-1}$.

Testovi koji se najčešće koriste za testiranje hipoteze o nekoreliranosti reziduala su **Portmanteau test** i **Lagrange Multiplier test** poznat kao **Breusch-Godfrey test**. Portmanteau test testira hipotezu o nekoreliranosti reziduala do koraka h :

$$\mathcal{H}_0 : \mathbf{R}_h = (R_1, \dots, R_h) = 0; \mathcal{H}_1 : \mathbf{R}_h \neq 0.$$

Test statistika:

$$Q_h := T \sum_{i=1}^h \text{tr}(\hat{R}_i^T \hat{R}_0^{-1} \hat{R}_i \hat{R}_0^{-1})$$

ima asimptotski $\chi^2(m^2(h-p))$ distribuciju. Ovi testovi se mogu koristiti za potrebe ispitivanja jesu li reziduali bijeli šum na način da se postavi niz hipoteza kao

u određivanju reda modela u 2.4.1 i, prema Lütkepohlu [4], prigodni su za velike korake h zbog asimptotskih svojstava.

Lagrangeov test je, s druge strane, prigodan za manje korake h jer je ideja da se postavi VAR model za vektor greške:

$$Z_t = D_1 Z_{t-1} + \dots + D_h Z_{t-h} + V_t,$$

gdje je V_t bijeli šum i on je jednak Z_t ako su reziduali nekorelirani. Dakle, hipoteze su:

$$\mathcal{H}_0 : D_1 = \dots = D_h = 0 \text{ i } \mathcal{H}_1 : D_j \neq 0 \text{ za barem jedan } j \in 1, \dots, h.$$

Test statistika $\chi_{LM}(h)$ se izvodi iz pomoćnog regresijskog modela i ima asimptotsku $\chi^2(hm^2)$ distribuciju. Radi jednostavnosti, ovdje ne navodimo spomenuti regresijski model i izvod test statistike, što je dostupno u [4], Poglavlje 4.4.4.

2.5.2 Normalnost reziduala

2.5.2.1 Normalnost bijelog šuma Svojstvo normalnosti reziduala je poželjno, ali nije i nužan uvjet prihvaćanja modela. Testovi se baziraju na trećem i četvrtom centralnom momentu normalne distribucije poznatima kao koeficijent asimetričnosti (*engl. skewness*) i koeficijent spljoštenosti (*engl. kurtosis*) redom. Prisjetimo se svojstva da ako je X slučajna varijabla sa standardnom normalnom distribucijom, onda vrijedi: $E[X^3] = 0$ i $E[X^4] = 3$.

Neka je $\{Z_t\}$ m -dimenzionalan Gaussov bijeli šum, odnosno vrijedi: $Z_t \sim \mathcal{N}(\mu_Z, \Sigma_Z)$ i neka je P matrica takva da vrijedi: $PP^T = \Sigma_Z$. Neka je

$$W_t = (W_{1,t}, \dots, W_{m,t})^T := P^{-1}(Z_t - \mu_Z) \sim \mathcal{N}(0, I_m),$$

odnosno, komponente od Z_t su nezavisne standardne normalne slučajne varijable pa vrijedi:

$$E[W_{1,t}^3, \dots, W_{m,t}^3]^T = 0, E[W_{1,t}^4, \dots, W_{m,t}^4]^T = [3, \dots, 3]^T = 3I_m. \quad (2.11)$$

Ovaj rezultat će se koristiti za testiranje normalnosti na temelju usporedbe trećeg i četvrtog momenta transformiranog procesa i teorijskih vrijednosti Gaussovog procesa. Pripadajući test je poznat kao **Jarque-Berra test**. Definirajmo:

$$\bar{Z} := \frac{1}{T} \sum_{t=1}^T (Z_t), S_Z := \frac{1}{T-1} \sum_{t=1}^T (Z_t - \bar{Z})(Z_t - \bar{Z})^T,$$

i neka je P_s matrica takva da vrijedi $P_s P_s^T = S_Z$ i $p - \lim(P_s - P) = 0$. Nadalje, neka je:

$$\begin{aligned}
v_t &:= (v_{1,t}, \dots, v_{m,t})^T = P_s^{-1}(Z_t - \bar{Z}), t = 1, \dots, T, \\
b_1 &:= (b_{1,1}, \dots, b_{m,1})^T, \text{ gdje je } b_{k,1} = \frac{1}{T} \sum_t (v_{k,t}^3), k = 1, \dots, m, \\
b_2 &:= (b_{1,2}, \dots, b_{m,2})^T, \text{ gdje je } b_{k,2} = \frac{1}{T} \sum_t (v_{k,t}^4), k = 1, \dots, m.
\end{aligned}$$

Dakle, b_1 i b_2 su procjenitelji vektora iz (2.11). Za asimptotsku distribuciju koeficijenata asimetričnosti i spljoštenosti vrijedi:

$$\sqrt{T} \begin{pmatrix} b_1 \\ b_2 - 3I_m \end{pmatrix} \xrightarrow{d} \mathcal{N} \left(0, \begin{pmatrix} 6I_m & 0 \\ 0 & 24I_m \end{pmatrix} \right), \text{ kad } T \rightarrow \infty.$$

Odnosno, b_1 i b_2 su asimptotski nezavisni i normalno distribuirani. Prethodni rezultat implicira sljedeće:

$$\lambda_s := T b_1 b_1^T / 6 \xrightarrow{d} \chi^2(m)$$

i

$$\lambda_k := T (b_2 - 3I_m)^T (b_2 - 3I_m) / 24 \xrightarrow{d} \chi^2(m).$$

λ_s statistika se koristi za testiranje hipoteza:

$$\mathcal{H}_0 : E[W_{1,t}^3, \dots, W_{m,t}^3]^T = 0; \mathcal{H}_1 : E[W_{1,t}^3, \dots, W_{m,t}^3]^T \neq 0,$$

a λ_k za testiranje:

$$\mathcal{H}_0 : E[W_{1,t}^4, \dots, W_{m,t}^4]^T = 3I_m; \mathcal{H}_1 : E[W_{1,t}^4, \dots, W_{m,t}^4]^T \neq 3I_m.$$

Konačno, statistika $\lambda_{s,k} := \lambda_s + \lambda_k \xrightarrow{d} \chi^2(2m)$ se može koristiti za testiranje obje hipoteze.

2.5.2.2 Normalnost VAR procesa Stabilan, stacionaran VAR(p) proces dan s

$$X_t - \mu = A_1(X_{t-1} - \mu) + \dots + A_p(X_{t-p} - \mu) + Z_t,$$

je normalno distribuiran ako i samo ako je proces bijelog šuma $\{Z_t\}$ normalno distribuiran. Stoga, normalnost procesa $\{X_t\}$ ispitujemo preko normalnosti $\{Z_t\}$. U primjeni se to ispituje zapravo preko procjene reziduala \hat{Z}_t . Može se pokazati kako procjenitelji koeficijenta spljoštenosti i asimetričnosti i u ovom slučaju imaju asimptotski normalnu distribuciju, odnosno vrijedi:

$$\sqrt{T} \begin{pmatrix} \hat{b}_1 \\ \hat{b}_2 - 3I_m \end{pmatrix} \xrightarrow{d} \mathcal{N} \left(0, \begin{pmatrix} 6I_m & 0 \\ 0 & 24I_m \end{pmatrix} \right).$$

(vidi [4], Poglavlje 4.5, Propozicija 4.10).

Iz toga računamo i vrijednosti test statistika:

$$\begin{aligned}\widehat{\lambda}_s &:= T\widehat{b}_1(\widehat{b}_1)^T/6 \xrightarrow{d} \chi^2(m), \\ \widehat{\lambda}_k &:= T(\widehat{b}_2 - 3I_m)^T(\widehat{b}_2 - 3I_m)/24 \xrightarrow{d} \chi^2(m), \\ \widehat{\lambda}_{s,k} &:= \widehat{\lambda}_s + \widehat{\lambda}_k \xrightarrow{d} \chi^2(2m).\end{aligned}$$

2.6 Predikcija

Nakon što smo kritički analizirali i usporedili modele te se odlučili za najprikladniji, možemo pomoću njega predviđati buduće vrijednosti varijabli modela. To je zapravo glavna svrha ove analize.

Pretpostavimo da u specifičnom trenutku t želimo predvidjeti buduće vrijednosti varijabli X_1, \dots, X_m . Neka je Ω_t skup svih dostupnih informacija u trenutku t . U slučaju VAR(p) procesa, Ω_t sadrži sadašnje i prošle vrijednosti varijabli sustava, odnosno: $\Omega_t = \{X_s | s \leq t\}$, gdje je $X_s = (X_{1,s}, \dots, X_{m,s})^T$. Sjetimo se, prediktor koji radi predviđanje h koraka unaprijed se naziva h -prediktor. Cilj je da prediktor minimizira očekivani gubitak. Funkcije gubitka mogu biti definirane na različite načine, ali u kontekstu VAR modela, najrašireniji su prediktori koji minimiziraju srednje kvadratnu grešku (MSE). Granger (1969) i Granger & Newbold (1986) su pokazali da minimalna MSE predikcije zapravo minimizira i široki rang drugih funkcija gubitaka. Osim toga, u slučaju nepristranih prediktora, MSE je varijanca greške predikcije što je korisno u određivanju intervala predikcije.

Neka je $\{X_t\}$ stabilan m -dimenzionalan VAR(p) proces kao u (2.1). Tada je prediktor koji minimizira MSE za period h **uvjetno očekivanje**:

$$E_t[X_{t+h}] := E[X_{t+h} | \Omega_t] = E[X_{t+h} | \{X_s | s \leq t\}]$$

i on minimizira MSE po svim komponentama od X_t .

Optimalnost uvjetnog očekivanja implicira i da je

$$E_t[X_{t+h}] = \nu + A_1 E_t[X_{t+h-1}] + \dots + A_p E_t[X_{t+h-p}] \quad (2.12)$$

optimalan h -prediktor VAR(p) procesa $\{X_t\}$ ako je $\{Z_t\}$ nezavisni bijeli šum, odnosno ako su Z_t i Z_s nezavisni za $s \neq t$ pa je stoga i $E_t[Z_{t+h}] = 0$ za $h > 0$.

Formula (2.12) se može rekursivno računati za h -prediktora počevši s $h=1$:

$$\begin{aligned}E_t[X_{t+1}] &= \nu + A_1 X_t + \dots + A_p X_{t-p+1} \\ E_t[X_{t+2}] &= \nu + A_1 E_t[X_{t+1}] + A_2 X_t + \dots + A_p X_{t-p+2} \\ &\vdots\end{aligned}$$

te na taj način dobijemo VAR(1) proces:

$$E_t[X_{t+h}] = (I_m + A_1 + \dots + A_1^{h-1})\nu + A_1^h X_t.$$

Uvjetno očekivanje ima sljedeća svojstva:

- nepristran je procjenitelj, odnosno vrijedi $E[X_{t+h} - E_t[X_{t+h}]] = 0$,
- ako je $\{Z_t\}$ nezavisni bijeli šum, $MSE[E_t[X_{t+h}]] = MSE[E_t[X_{t+h}|X_t, X_{t-1}, \dots]]$.

Ukoliko $\{Z_t\}$ nije nezavisni bijeli šum, $E_t[Z_{t+h}]$ ne mora biti jednako nuli. Bez tog svojstva možemo pronaći manje ambicioznog prediktora koji minimizira MSE među linearnim funkcijama od X_t, X_{t-1}, \dots . Razmotrimo VAR(1) proces:

$$X_t = A_1 X_{t-1} + Z_t.$$

Kao u (2.2) vrijedi:

$$X_{t+h} = A_1^h X_t + \sum_{i=0}^{h-1} A_1^i Z_{t+h-i}.$$

Stoga za prediktora

$$X_t(h) = B_0 X_t + B_1 X_{t-1} + \dots,$$

gdje su $B_i (m \times m)$ matrice koeficijenata, dobijemo grešku predikcije:

$$X_{t+h} - X_t(h) = \sum_{i=0}^{h-1} A_1^i Z_{t+h-i} + (A_1^h - B_0)X_t - \sum_{i=1}^{\infty} B_i X_{t-i}.$$

Koristeći činjenicu da su Z_{t+j} i X_{t-i} za $j > 0$ i $i \geq 0$, dobijemo:

$$\begin{aligned} MSE|X_t(h) &= E \left[\left(\sum_{i=0}^{h-1} A_1^i Z_{t+h-i} \right) \left(\sum_{i=0}^{h-1} A_1^i Z_{t+h-i} \right)^T \right] \\ &+ E \left[\left[(A_1^h - B_0)X_t - \sum_{i=1}^{\infty} B_i X_{t-i} \right] \left[(A_1^h - B_0)X_t - \sum_{i=1}^{\infty} B_i X_{t-i} \right]^T \right]. \end{aligned}$$

Minimalna vrijednost MSE se postiže za $B_0 = A_1^h$ i $B_i = 0$ pa je optimalni prediktor

$$X_t(h) = A_1^h X_t = A_1 X_t(h-1)$$

i naziva se **prediktor minimalne MSE među linearnim funkcijama**. Pripadna greška predikcije je:

$$\sum_{i=0}^{h-1} A_1^i Z_{t+h-i}.$$

Budući da smo pokazali u (2.2) da se VAR(p) proces može zapisati u obliku VAR(1) procesa, ovaj rezultat se može poopćiti i na VAR(p) procese te vrijedi:

$$X_t(h) = \nu + A_1 X_t(h-1) + \dots + A_p X_t(h-p).$$

Sada kada smo vidjeli kako općenito izgleda predviđanje kod VAR procesa, pogledajmo kako ono izgleda na procijenjenim modelima.

2.6.1 Predviđanje s procijenjenim modelima

Ukoliko u formulu za $X_t(h)$ uvrstimo procjene za koeficijente ν, A_1, \dots i A_p , dobivamo procjenu za h -prediktora:

$$\hat{X}_t(h) = \hat{\nu} + \hat{A}_1 \hat{X}_t(h-1) + \dots + \hat{A}_p \hat{X}_t(h-p),$$

gdje je je $\hat{X}_t(j) = X_{t+j}$ za $j \leq 0$.

Greška predikcije je:

$$\begin{aligned} X_{t+h} - \hat{X}_t(h) &= [X_{t+h} - X_t(h)] + [X_t(h) - \hat{X}_t(h)] \\ &= \sum_{i=0}^{h-1} \Phi_i Z_{t+h-i} + [X_t(h) - \hat{X}_t(h)], \end{aligned}$$

gdje su Φ_i matrice koeficijenata MA reprezentacije procesa $\{X_t\}$ (vidljivo u 2.2.1) Vrijedi: $E[X_{t+h} - \hat{X}_t(h)] = 0$, dakle predviđanje je nepristrano čak i ako su koeficijenti procijenjeni.

Poglavlje 3

Vektorski autoregresivni model na stvarnim podacima

Sada kada smo napravili kratki uvod u teoriju koja stoji iza VAR modela, pogledajmo kako je izgledala primjena te vrste modela na stvarne podatke. Podaci koji su korišteni za modeliranje su meteorološki podaci i koncentracija peludi ambrozije u gradu Somboru, Republika Srbija za period od siječnja 2008. godine zaključno s lipnjem 2017. godine. Podaci o koncentraciji peludi su izvorno bili podaci s dvosatnim razmakom, dakle mjereno u 2 h, 4 h, 6 h, itd., odnosno 12 podataka za svaki dan. Cilj ovog modela je pokušati prognozirati dnevnu koncentraciju peludi. Budući da je prepostavka da bi osobe koje pate od alergije trebao zanimati 'najgori' slučaj, modelirali smo maksimalnu dnevnu koncentraciju.

Meteorološki podaci kojima raspolažemo su minimalna, prosječna i maksimalna temperatura, vjetar, padaline te vlažnost zraka i prikupljeni su s mjerne postaje Rimski Šančevi. Za vjetar, padaline i vlažnost zraka raspolažemo dnevnim prosjecima. Teorijski se smatra da je temperatura najznačajniji čimbenik, padaline i vlažnost su bitne zbog taloženja i ispiranja peludi, a vjetar zbog prijenosa zrakom. U ovom radu je analizom Grangerove uzročnosti donešena odluka o izboru prediktora za model.

1. Koraci u izgradnji modela

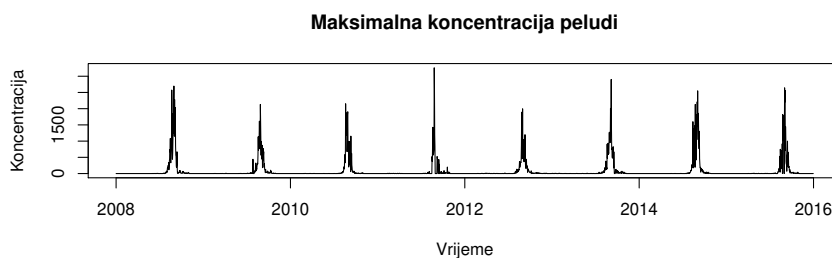
Na početku raspolažemo s 3466 dnevnih vrijednosti svake od navedenih varijabli. Od toga je odvojen dio podataka za modeliranje, a dio za validaciju dobivenog modela. Podaci od početka 2008. do kraja 2015. godine (njih 2920) su ostavljeni za modeliranje, a podaci od početka 2016. do srpnja 2017. (njih 546) su ostavljeni za validaciju. Daljnji postupak je rađen u programskom paketu R, verzija 3.4.4., a korištena je razina značajnosti 0.05 u svim statističkim testovima u nastavku.

1.1 Deskriptivna analiza varijabli

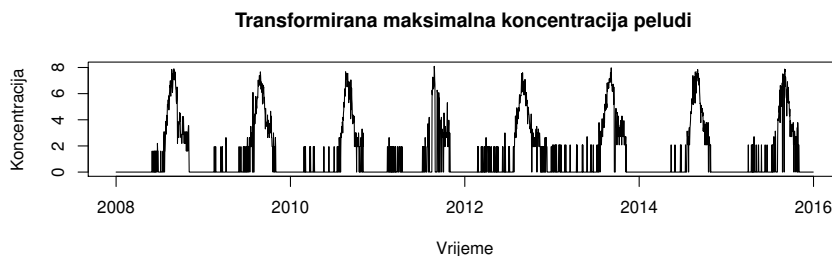
Pogledajmo najprije grafičke prikaze pojedinih varijabli, a potom ćemo analizirati svojstva svih varijabli zajedno.

1.1.1 Pelud


Koncentracija peludi se mjeri brojem zrnaca po kubnom metru zraka. Maksimalna koncentracija peludi izgleda vrlo nestacionarno te smo ju stoga transformirali funkcijom $x \mapsto \ln(1 + x)$ i kao takvu ćemo je modelirati.



(a) Originalna koncentracija peludi



(b) Transformirana koncentracija peludi



(c) Empirijska ACRF transformirane koncentracije peludi

Slika 3.1: Trajektorije i empirijska ACRF


Pelud	Min.	Donji kvartil	Prosjek	Gornji kvartil	Max.	Varijanca
Vrijednosti	0	0	0	2.08	8.09	4.39

Tablica 3.1: Numeričke karakteristike transformirane koncentracije peludi

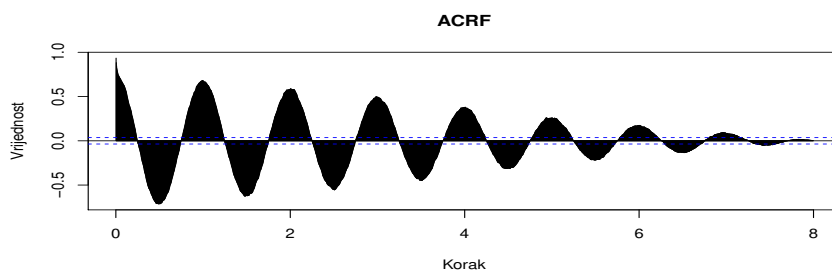
Sezona cvjetanja ambrozije je okvirno od početka lipnja do kraja listopada s maksimalnim koncentracijama obično u kolovozu i rujnu. Bitno je za napomenuti i da u danima kad nije mjerena koncentracija peludi (jer nije bila sezona) imamo nedostajuću vrijednost za koncentraciju, ali je ona iz jasnih razloga postavljena na 0.

1.1.2 Temperatura

U podacima je bilo 10-ak dana gdje nismo imali navedenu temperaturu te je ona procjenjena prosjekom temperature od prethodnog i budućeg dana.

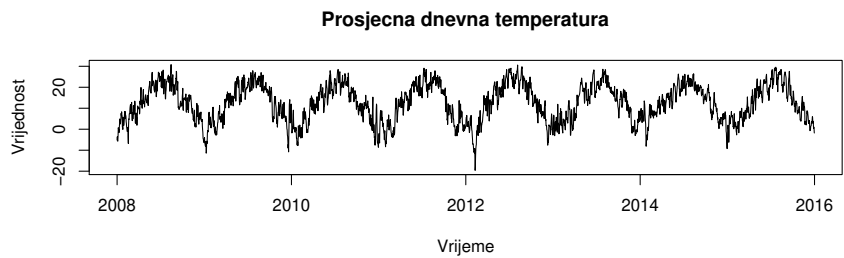


(a) Trajektorija




(b) Empirijska ACRF

Slika 3.2: Minimalna temperatura

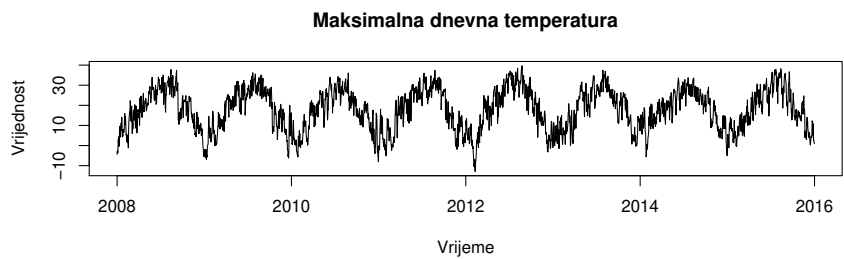


(a) Trajektorija




(b) Empirijska ACRF

Slika 3.3: Prosječna temperatura



(a) Trajektorija



(b) Empirijska ACRF

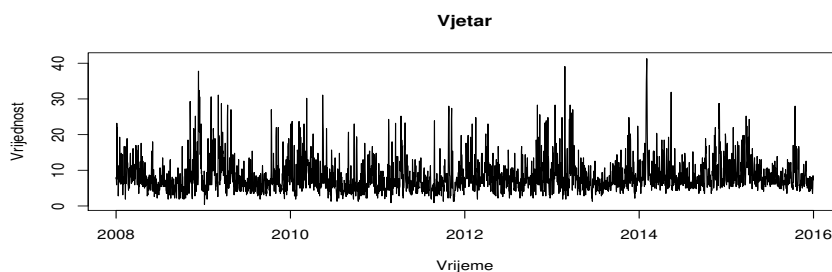
Slika 3.4: Maksimalna temperatura

Temperatura	Min.	Donji kvartil	Prosjek	Gornji kvartil	Max.	Varijanca
Minimalna	-28.7	1.6	8	13.9	23	58.8
Prosječna	-19.6	5.5	13.1	19.7	30.8	78.22
Maksimalna	-12.9	9.9	18.8	26.3	39.7	105.28

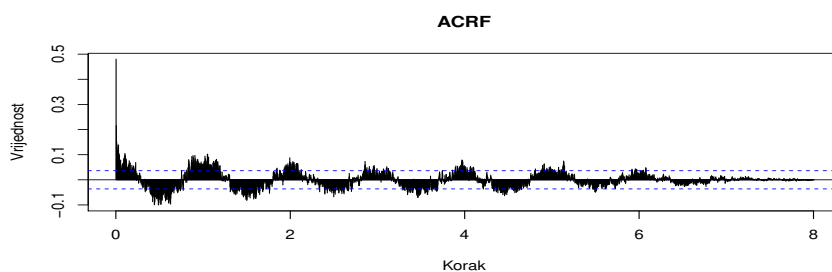
Tablica 3.2: Numeričke karakteristike temperatura

1.1.3 Vjetar

Brzina vjetra je mjerena u m/s .



(a) Trajektorija



(b) Empirijska ACRF

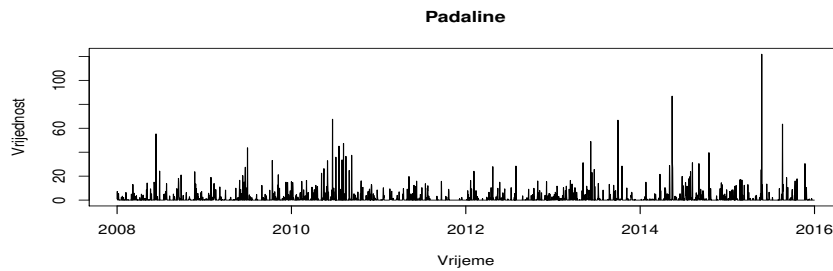
Slika 3.5: Vjetar

Vjetar	Min.	Donji kvartil	Prosjek	Gornji kvartil	Max.	Varijanca
Vrijednosti	0.4	5.4	7.2	10.4	41.3	23.2

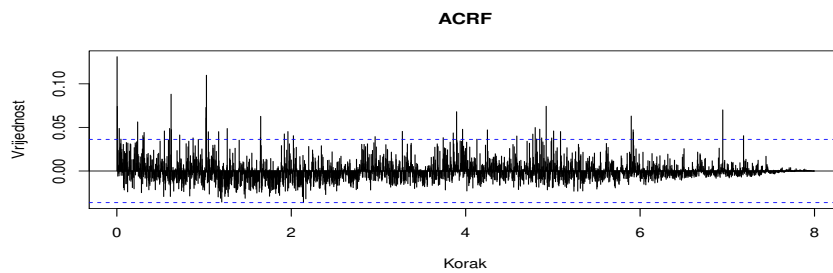
Tablica 3.3: Numeričke karakteristike vjetra

1.1.4 Padaline

Količina padalina se mjeri u mm što predstavlja njihovu količinu u l/m^2 .



(a) Trajektorija



(b) Empirijska ACRF

Slika 3.6: Padaline

Padaline	Min.	Donji kvartil	Prosjek	Gornji kvartil	Max.	Varijanca
Vrijednosti	0	0	0	0.7	121.9	32.9

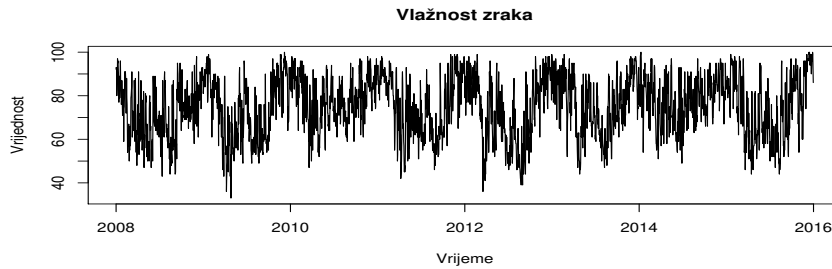
Tablica 3.4: Numeričke karakteristike padalina

1.1.5 Vlažnost zraka

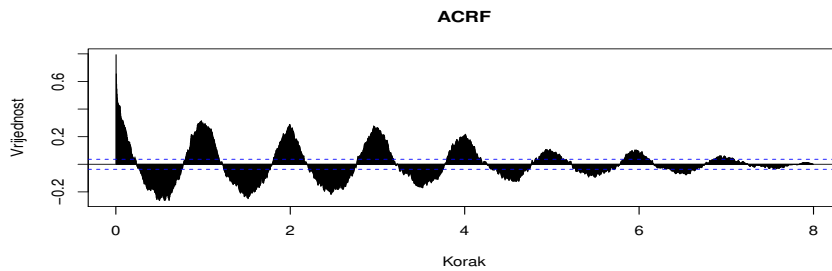
Relativna vlažnost zraka je mjerena u postotcima od 1 do 100%.

Vlažnost	Min.	Donji kvartil	Prosjek	Gornji kvartil	Max.	Varijanca
Vrijednosti	33	64	75.5	86	100	190.1

Tablica 3.5: Numeričke karakteristike vlažnosti zraka



(a) Trajektorija



(b) Empirijska ACRF

Slika 3.7: Vlažnost zraka

Uočimo da neke varijable pokazuju jasnu sezonalnost na godišnjoj razini koju bismo trebali obuhvatiti modelom. Prisutna je nestacionarnost, što je vidljivo i iz funkcija autokorelacija uzorka. Korišten je ADF test o postojanju jediničnog korijena (funkcija *adf.test()* iz paketa *'tseries'*) kako bismo donijeli odluku treba li dani vremenski niz diferencirati ili ne. Na razini značajnosti 0.05 je za svaku varijablu odbačena nul-hipoteza u korist alternativne hipoteze te nema potrebe diferencirati dane vremenske nizove. Sjetimo se, to i dalje ne znači da su nizovi stacionarni, nego samo da nemaju jedinični korijen. Dobivene p-vrijednosti ovog testa su navedene u sljedećoj tablici.

	Min. t.	Pros. t.	Maks. t.	Vjetar	Padaline	Vlažnost
p-vrijednosti	0.01	0.01989	0.01	0.01	0.01	0.01

Tablica 3.6: p-vrijednosti dobivene testiranjem jediničnog korijena

1.2 Analiza uzročnosti

Pri izradi modela, jedan od najvažnijih koraka je odabir prediktora koje ćemo staviti u model. U tu svrhu, možemo se poslužiti različitim metodama koje će nešto sugerirati. Naravno, ukoliko je moguće, poželjno je isprobati više različitih modela i odlučiti se za

najprikladniji. Upravo tako je i u ovom slučaju odabran model. Naime, jedan od važnih kriterija odabira modela je jednostavnost. Stoga, nakon isprobanih više mogućnosti, odlučili smo se za model koji je bio "jednako dobar" kao ostali, ali je najjednostavniji. Sjetimo se, za vremenski niz $\{X_t\}$ kažemo da uzrokuje $\{Y_t\}$ u smislu Grangera ako se buduće vrijednosti $\{Y_t\}$ mogu predvidjeti s većom preciznošću na osnovu prethodnih vrijednosti $\{X_t\}$ nego bez njih. Iako VAR model radi predikcije svih varijabli sustava, varijabla koja je nama od interesa je transformirana maksimalna koncentracija peludi. Stoga je provedena analiza Grangerove uzročnosti u smislu samo te varijable, odnosno, provjeravali smo koja od ostalih varijabli uzrokuje nju u smislu Grangera. U tu svrhu je korištena funkcija *causality()* iz paketa 'vars'. Nul-hipoteza jest da vremenski niz $\{X_t\}$ ne uzrokuje $\{Y_t\}$ u smislu Grangera, a alternativna da uzrokuje. Dobivene p-vrijednosti ovog testa su navedene u sljedećoj tablici.

	Min. t.	Pros. t.	Maks. t.	Vjetar	Padaline	Vlažnost
p-vrijednosti	0.1003	0.03642	0.05851	0.6265	0.2451	0.05849

Tablica 3.7: p-vrijednosti dobivene testiranjem Grangerove uzročnosti

Kao što vidimo, pokazala se značajno jedino prosječna temperatura, dok za maksimalnu temperaturu i vlažnost zraka ne odbacujemo nul-hipotezu, ali vidimo da je *p*-vrijednost malo veća od 0.05. S obzirom da je suviše uvrštavati obje dnevne temperature u model, odlučili smo se za jednu za koju mislimo da nosi najviše informacija (ujedno uočimo i da je *p*-vrijednost najmanja), a to je prosječna dnevna temperatura. Model koji je napravljen na temelju tog rezultata, a koji sadrži samo dvije varijable - transformiranu koncentraciju peludi i prosječnu temperaturu nije dovoljno dobro pratio kretanje podataka. Potom je u model dodana i vlažnost zraka, što je značajno popravilo model. Konačno, opredijelili smo se za ta tri prediktora.

1.3 Odabir reda modela

Nakon što smo se odabrali prediktore koje ćemo staviti u model, potrebno je odrediti red modela, odnosno odabrati broj prethodnih dana koje ćemo koristiti za predviđanje budućih vrijednosti varijabli modela. Spomenuli smo da odluku o tome možemo donijeti korištenjem LR test statistike, ali i optimiziranjem kriterija FPE, AIC, HQ i SC, što je preporučljivo ukoliko je svrha modela predviđanje. U tu svrhu je korištena funkcija *VARselect()* iz paketa 'vars' koja sugerira red modela prema svakom od tih kriterija. Potrebno je kao argument dati i maksimalan broj koraka, što je stavljeno na 30 dana. Dobiveni rezultati su prikazani u Tablici 3.8. Odlučili smo se za korak 16.

Kriterij	FPE	AIC	HQ	SC
Red	16	16	7	4

Tablica 3.8: Sugerirani red modela prema pojedinom kriteriju

2. Adekvatnost modela

Sada kada smo se odlučili koje varijable uzeti i kad smo odabrali red modela, imamo sve potrebno za izgraditi model. U tu svrhu koristimo funkciju $VAR()$ iz paketa 'vars'. U pozivu ove funkcije smo uvrstili i primjećenu godišnju sezonalnost podataka tako što smo kao argument dodali $season = 365$, a to rezultira dodavanjem u model 364 *dummy* varijabli oblika:

$$sd_i(x) = \begin{cases} 1, & x = i \\ 0, & x \neq i \end{cases}, i = 1, \dots, 364.$$

Na ovaj način dobijemo model za svaku od varijabli iz modela. Ukoliko je s sezona, u model se dodaje $s-1$ *dummy* varijabli kako matrica regresora ne bila singularna, budući da imamo i vektor konstantnih članova u modelu. U sljedećim tablicama su navedeni koeficijenti uz svakog prediktora i za svaki pojedini model, ali je radi preglednosti izostavljeno 364 koeficijenata uz *dummy* varijable za svaki od modela (isti su navedeni u Dodatku).

Korak	Prosječna temp.	Vlažnost zraka	Transf. konc. peludi
1	0.9726*	0.0021	-0.0034
2	-0.2292*	-0.0078	-0.0789
3	0.0383	0.0034	-0.0203
4	0.0603*	0.0067	0.0062
5	-0.0410	-0.0041	-0.0366
6	0.0568*	0.0077	0.0637
7	-0.0247	-0.0018	0.0853
8	0.0155	0.0097	-0.0858
9	-0.0087	0.0030	-0.0089
10	-0.0034	-0.0010	0.01791
11	0.0050	-0.0003	-0.0053
12	0.0014	0.0107	0.0102
13	-0.0289	-0.0110	-0.0245
14	0.0208	0.0021	-0.0210
15	0.0009	0.0010	-0.0987
16	0.0160	0.0051	0.1443*

Tablica 3.9: Procijenjeni koeficijenti uz svakog prediktora za prosječnu dnevnu temperaturu za svaki korak $i = 1, \dots, 16$, * - značajni na nivou značajnosti 0.05


Korak	Prosječna temp.	Vlažnost zraka	Transf. konc. peludi
1	1.673e-01*	6.879e-01*	-1.366e-01
2	3.520e-02	-7.616e-03	4.277e-01*
3	1.102e-02	1.484e-02	-1.189e-01
4	-1.831e-01	3.864e-02	-3.504e-01
5	1.498e-01	2.143e-02	2.184e-01
6	-1.611e-02	-3.714e-03	-1.864e-01
7	-7.045e-02	5.393e-03	-2.039e-01
8	3.979e-02	1.309e-02	1.444e-01
9	5.325e-03	-9.496e-05	1.0519e-01
10	-8.812e-03	3.597e-02	-8.429e-02
11	6.484e-02	2.856e-02	6.247e-02
12	-2.199e-02	-1.811e-02	9.673e-02
13	1.074e-01	2.598e-02	6.027e-01*
14	1.223e-01	6.674e-02*	2.723e-02
15	-1.135e-01	-1.885e-02	8.226e-02
16	-1.389e-03	4.294e-02*	-3.025e-01

Tablica 3.10: Procijenjeni koeficijenti uz svakog prediktora za vlažnost zraka za svaki korak $i = 1, \dots, 16$, * - značajni na nivou značajnosti 0.05


Korak	Prosječna temp.	Vlažnost zraka	Transf. konc. peludi
1	1.018e-02	-2.472e-04	3.672e-01*
2	-1.349e-03	-9.117e-04	1.419e-01*
3	3.375e-03	3.817e-03	6.133e-02*
4	3.842e-03	-6.578e-04	2.866e-02
5	-3.039e-03	2.220e-03	-3.661e-06
6	-9.050e-03	1.478e-03	6.545e-02*
7	1.912e-03	8.000e-04	7.622e-02*
8	6.304e-04	-2.990e-03	-3.004841e-02
9	5.325e-03	4.039e-03	1.980e-03
10	-1.502e-02	-6.374e-03*	-2.150e-02
11	9.013e-03	1.544e-04	-2.171e-02
12	7.893e-03	4.325e-03	3.335e-02
13	-2.757e-02*	-3.807e-03	-3.755e-02*
14	2.621e-02*	1.422e-03	2.908e-02
15	-4.955e-03	2.653e-03	3.832e-02*
16	-5.783e-03	-2.19e-03	2.867e-02

Tablica 3.11: Procijenjeni koeficijenti uz svakog prediktora za transformiranu koncentraciju peludi za svaki korak $i = 1, \dots, 16$, * - značajni na nivou značajnosti 0.05

Pogledajmo usklađenost procijenjenih i pravih vrijednosti za varijablu od interesa - transformiranu koncentraciju peludi, a time i originalnu koncentraciju peludi, ukoliko vratimo transformaciju inverznom funkcijom $x \mapsto (e^x - 1)$.



Slika 3.8: Trajektorije procijenjene i stvarne transformirane koncentracije peludi po godinama



Slika 3.9: Trajektorije procijenjene i stvarne originalne koncentracije peludi po godinama

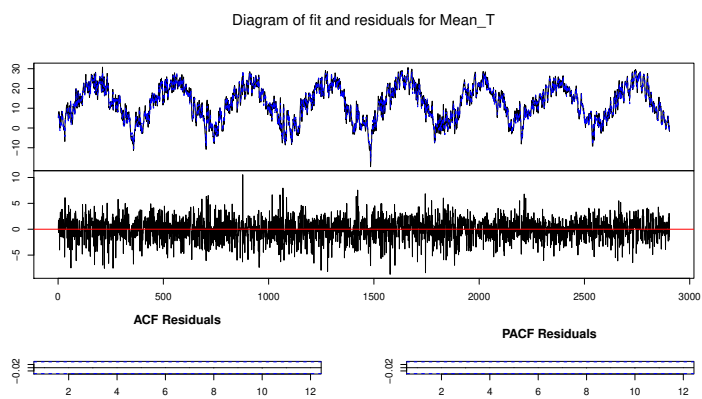
Poželjeno je da je što veći udio ukupne varijabilnosti podataka objašnjen modelom, što je u ovom slučaju u redu budući da je korigirani koeficijent determinacije \tilde{R}^2 u modelu za prosječnu temperaturu 0.977, u modelu za vlažnost zraka 0.9887, a u modelu za transformiranu koncentraciju peludi 0.8969. Spomenuli smo da je poželjno da je model stabilan, da su greške nekorelirane i normalno distribuirane te da je varijanca konstanta. Potrebno je provjeriti ta svojstva. Greške su slučajne varijable, a reziduali, kao procjene greške, podaci na temelju kojih provjeravamo te pretpostavke.

2.1 Reziduali

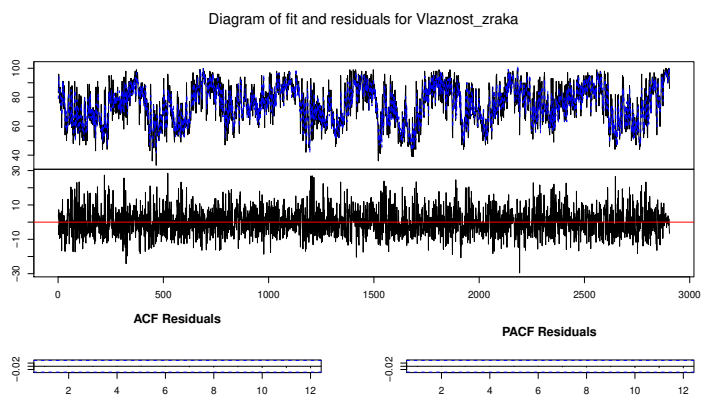
Za rezidualne smo rekli da normalnost nije nužno, ali je poželjno svojstvo prihvaćanja modela. Ispitali smo ju pomoću funkcije *normality.test()* iz paketa 'vars' koja računa vrijednosti test statistika i pripadne p-vrijednosti multivarijatnog Jarque-Berra testa i testova asimetričnosti i spljoštenosti. Korištene su i funkcije *serial.test()* za Portmanteauov test serijske koreliranosti i funkcija *arch.test()* iz istog paketa za provjeru prisutnosti uvjetne heteroskedastičnosti koju naslućujemo iz grafičkih prikaza (drugi prikaz na svakoj od Slika 3.10). Dobiveno je sljedeće:

Test	Skewness	Kurtosis	Jarque Berra test	Serial test	Arch test
p-vrijednost	< 2.2e-16	< 2.2e-16	< 2.2e-16	< 2.2e-16	< 2.2e-16

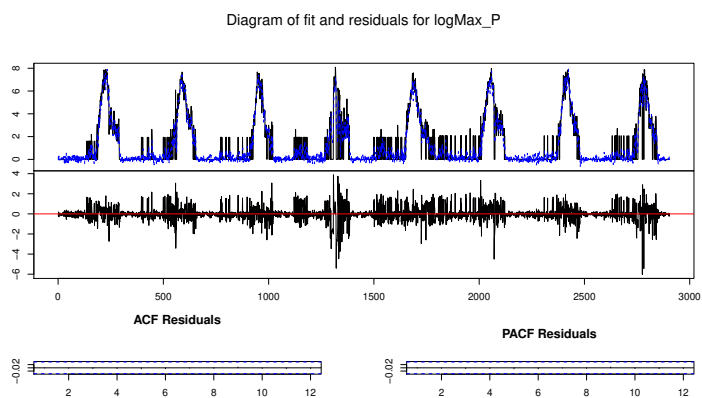
Dakle, odbacujemo sve nul-hipoteze i možemo reći da reziduali ne dolaze iz normalne distribucije te da je prisutna uvjetna heteroskedastičnost i serijska korelacija. Ta svojstva nam govore da se ne trebamo pouzdati u rezultate dobivene modelom u smislu pouzdanih intervala, interpretacije koeficijenata i slično. Ukoliko je svrha modela interpretacija, trebali bismo posegnuti za korekcijom modela kako bismo imali ispunjene pretpostavke na rezidualne i kako bismo se mogli pouzdati u dobivene rezultate, no ukoliko je svrha modela predikcija, možemo pogledati koliko model dobro predviđa buduće vrijednosti ovisnih varijabli modela i ukoliko je to zadovoljavajuće, model se može koristiti u te svrhe. Na sljedećim prikazima vidimo prave i temeljem ovog modela procijenjene vrijednosti transformirane maksimalne koncentracije peludi, prosječne dnevne temperature i vlažnosti zraka te pripadajuće rezidualne. Vidimo da model dosta dobro prati izmjerene (stvarne) vrijednosti svih tih varijabli.



(a) Prosječna dnevna temperatura



(b) Vlažnost zraka



(c) Transformirana koncentracija peludi

Slika 3.10: Modeli

2.2 Stabilnost i stacionarnost


Stabilnost smo provjerili tako što smo pogledali svojstvene vrijednosti matrice koeficijenata i svi su modula manjih od jedan. Svojstvene vrijednosti matrice koeficijenata su prikazane u Tablici 3.12. Kako smo pokazali da stabilnost modela povlači i stacionarnost, ovaj model je stacionaran.

Svojstvene vrijednosti matrice koeficijenata					
0.9998606	0.9357207	0.8895893	0.8895893	0.8700376	0.8594369
0.8594369	0.8581790	0.8581790	0.8568425	0.8568425	0.8563004
0.8563004	0.8501665	0.8501665	0.8479065	0.8479065	0.8472676
0.8472676	0.8452040	0.8452040	0.8450405	0.8450405	0.8372544
0.8372544	0.8371385	0.8371385	0.8314723	0.8314723	0.8291664
0.8291664	0.8121786	0.8121786	0.8120374	0.8120374	0.8034546
0.8034546	0.8026833	0.8026833	0.8018929	0.8018929	0.7972833
0.7972833	0.7718810	0.7718810	0.7242792	0.7242792	0.2817423

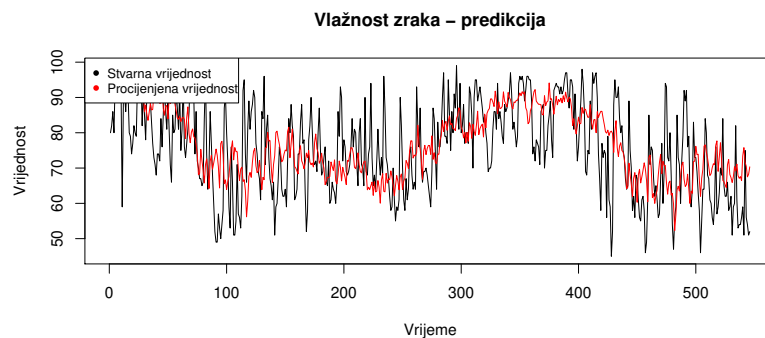
Tablica 3.12: Svojstvene vrijednosti matrice koeficijenata

3. Predikcija modela

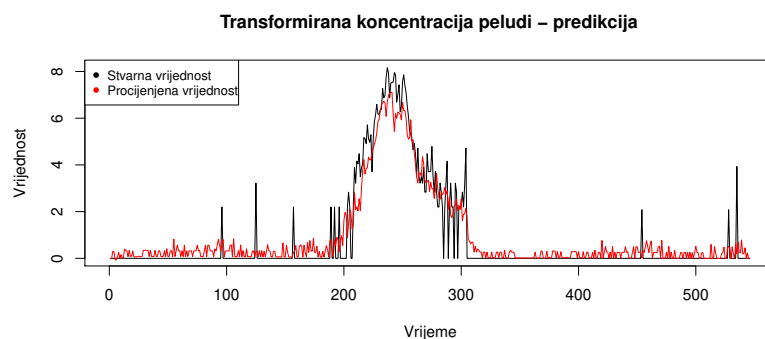
Iako naš model ne ispunjava bitne pretpostavke, pogledajmo ima li barem dobru prediktivnu moć. Koristeći funkciju *forecast()* iz istoimenog paketa smo napravili predikciju za 2016. godinu i prvu polovicu 2017. godine (ukupno 546 dana). Na sljedećim prikazima vidimo predikciju svake varijable modela.



(a) Prosječna dnevna temperatura



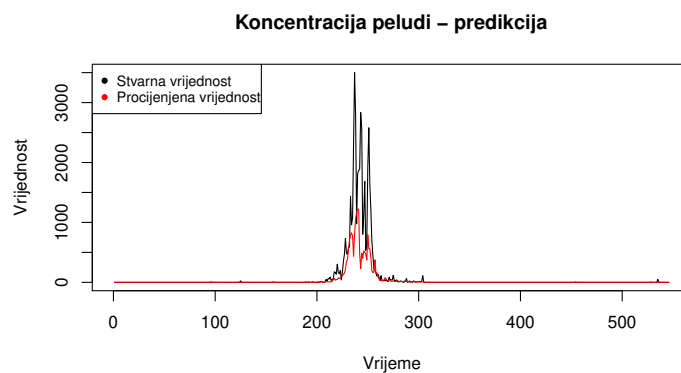
(b) Vlažnost zraka



(c) Transformirana koncentracija peludi

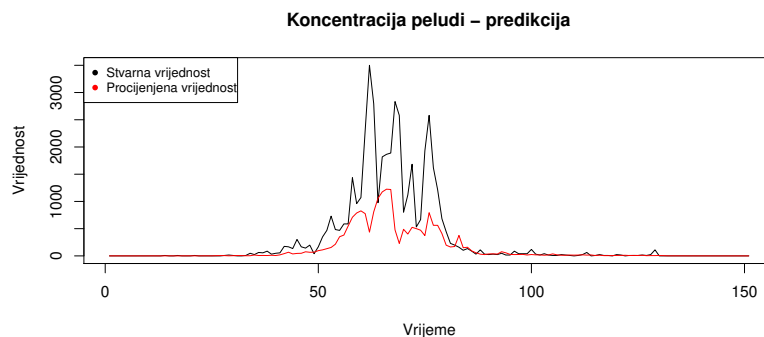
Slika 3.11: Trajektorije predikcije

Što se tiče predikcije originalne maksimalne dnevne koncentracije peludi, dobivene predviđene vrijednosti transformirane koncentracije su vraćene nazad inverznom funkcijom $x \mapsto (e^x - 1)$.



Slika 3.12: Trajektorija predikcije originalne koncentracije peludi

Istaknimo period oko sezone:



Slika 3.13: Trajektorija predikcije originalne koncentracije peludi - sezona

Vidljivo je da model ne predviđa dobro vrhunce koncentracije. No, prosječnoj osobi broj zrnaca peludi ne znači puno nego ju zanima kakva je općenito razina koncentracije peludi u zraku. Stoga je cilj modela predviđanje pripadnosti maksimalne dnevne koncentracije peludi unaprijed definiranim kategorijama. Dobivene vrijednosti su stoga podijeljene u kategorije prema sljedećoj tablici:

Koncentracija	Niska	Umjerena	Visoka	Vrlo visoka
Vrijednosti	[0, 10]	(10, 50]	(50, 500]	≥ 500

Tablica 3.13: Kategorizacija koncentracije peludi

Navedena kategorizacija je preuzeta s web stranice Nastavnog zavoda za javno zdravstvo "Dr. Andrija Štampar" ([7]), a tumačenje je sljedeće: kod niske koncentracije peludi samo vrlo osjetljive osobe na pelud mogu razviti simptome alergijske reakcije, kod umjerene koncentracije peludi 50% osjetljivih ljudi na pelud razviti će simptome alergijske reakcije, kod visoke koncentracije peludi većina osjetljivih osoba, a kod vrlo visoke koncentracije peludi gotovo sve osjetljive osobe na pelud razvit će simptome alergijske reakcije. U sljedećoj tablici je prikazano koliko je dana pojedine kategorije u stvarnim i predviđenim vrijednostima.

Koncentracija	Niska	Umjerena	Visoka	Vrlo visoka
Predviđene vrijednosti	467	35	29	15
Stvarne vrijednosti	463	31	27	25

Tablica 3.14: Podjela predviđenih i stvarnih koncentracija peludi u kategorije

Od 546 dana je:

- ispravno procijenjeno 502 (92.49%)
- neispravno procijenjeno 41 (7.51%), a od toga
 - precijenjeno 10 dana (1.83%) (predvidjeli smo koncentraciju više kategorije)
 - podcijenjeno 31 dan (5.68%) (predvidjeli smo koncentraciju niže kategorije).

Za osobe koje pate od alergija bitnije je biti pripravan, pa čak i ako koncentracija ne bude visoka koliko je predviđeno, tako da je onih 1.83% modelom netočno kategoriziranih dana manji "problem" nego 5.68% dana u kojima je modelom predviđena niža koncentracija nego stvarna. U čak 10 dana (1.83%) s vrlo visokom koncentracijom peludi je modelom predviđena visoka koncentracija, no u tom slučaju je vjerojatno većina osoba već i pripravna. Samo su 3 dana (0.54%) u kojima se modelom previđena kategorija koncentracije od stvarne koncentracije razlikovala za dvije kategorije, dok se u ostalim netočno kategoriziranim danima radilo o razlici za jednu kategoriju. Uzevši u obzir to i stopu ispravnih pogodaka od 92.49%, mogli bismo reći da model dobro predviđa buduće vrijednosti te da je njegova svrha kao takva ispunjena. Model je moguće i korigirati ukoliko bi se radila iterativna korekcija greške te potom nova procjena parametara modela.

Literatura

- [1] V. Bahovec, N. Erjavec, *Uvod u ekonometrijsku analizu*, Element, Zagreb, 2009.
- [2] P.J. Brockwell, R.A. Davis, *Introduction to Time Series and Forecasting*, Springer, New York, 2002.
- [3] P.J. Brockwell, R.A. Davis, *Time Series: Theory and Methods*, Springer, New York, 1991.
- [4] H. Lütkepohl, *New Introduction to Multiple Time Series Analysis*, Springer, Berlin, 2005.
- [5] Ž. Salinger, *Modeliranje stope nezaposlenosti i inflacije mjerene indeksom potrošačkih cijena u Republici Hrvatskoj*, Sveučilište J.J. Strossmayera u Osijeku, Odjel za matematiku, Diplomski rad, 2014.
URL: <http://www.mathos.unios.hr/~mdjumic/uploads/diplomski/SAL24.pdf>
- [6] *Hrvatski zavod za javno zdravstvo*,
URL: <https://www.hzjz.hr/sluzba-zdravstvena-ekologija/alergije-kad-preburno-reagira-imunosni-sustav/>
- [7] *Nastavni zavod za javno zdravstvo "Dr. Andrija Štampar"*,
URL: <http://www.stampar.hr/hr/alergijski-semafor-peludna-prognoza-i-peludni-kalendar>
- [8] *Wikipedia*,
URL: https://en.wikipedia.org/wiki/Christopher_A._Sims

Sažetak

U ovom radu su predstavljeni osnovni pojmovi, svojstva i rezultati analize vremenskih nizova. Navedeni su modeli za stacionarne i nestacionarne jednodimenzionalne vremenske nizove - procesi pomičnih prosjeka (MA), autoregresivni procesi (AR), autoregresivni (integrirani) procesi pomičnih prosjeka (ARMA i ARIMA) te sezonalni autoregresivni (integrirani) procesi pomičnih prosjeka (SARMA i SARIMA). Pokazani su i neki primjeri takvih procesa. Od modela za višedimenzionalne vremenske nizove je opisan vektorski autoregresivni proces (VAR). Navedene su metode procjene parametara i određivanja reda modela i analizirana je uzročnost u smislu Grangera. Opisana je i dijagnostika modela koja se zasniva na analizi reziduala te je opisana predikcija pomoću odabranog modela.

Na temelju podataka o koncentraciji peludi u Somboru i meteoroloških podataka s mjerne postaje Rimski Šančevi je napravljen vektorski autoregresivni model s ciljem predviđanja maksimalne dnevne koncentracije peludi. Za potrebe modela su odabrane i varijable vlažnost zraka i prosječna dnevna temperatura, a red modela je 16, što znači da za predikciju maksimalne koncentracije peludi pojedinog dana koristimo vrijednosti koncentracije peludi, vlažnosti zraka i prosječne temperature prethodnih 16 dana. Dobivene vrijednosti su podijeljene u sljedeće kategorije - niska, umjerena, visoka i vrlo visoka koncentracija. S obzirom na nezadovoljene pretpostavke o svojstvima reziduala, model se ne može koristiti u svrhu interpretacije, no za predikciju se pokazao točnim u 92.49 % promatranih dana. Navedena je i mogućnost poboljšanja korištenog modela.

Ključne riječi: vremenski niz, stacionarnost, MA, AR, ARMA, ARIMA, SARMA, SARIMA, VAR, alergija, pelud, ambrozija, koncentracija

Modelling of ambrosia pollen concentration with the vector autoregressive model

Summary

This graduate thesis presents basic terms, properties and results of time series analysis. Models of stationarity and non-stationarity univariate time series are described – moving average processes (MA), autoregressive processes (AR), autoregressive (integrated) moving average processes (ARMA and ARIMA) and seasonal autoregressive (integrated) moving average processes (SARMA and SARIMA). Some examples of these processes are also shown. Out of many multivariate time series models, the vector autoregressive process (VAR) is described. Methods of parameter estimation and order determination are shown and Granger causality is analysed. The diagnostic of models based on the residual analysis and the prediction by the chosen model are also described.

Based on the data of pollen concentration in Sombor and the meteorological data from the measuring station Rimski Šančevi, a vector autoregressive model is made with the aim of predicting the maximum daily pollen concentration. For the needs of the model, the chosen variables are also air humidity and average daily temperature and the order of the model is 16, meaning that for the prediction of the maximum pollen concentration of a single day, we use the values of pollen concentration, air humidity and average temperature of the previous 16 days. The obtained values are divided into the following categories - low, moderate, high and very high concentrations. Since the assumptions on model residuals are not satisfied, the model can not be used for the purpose of interpretation, but for prediction purposes it would be accurate for 92.49 % of observed days. Possible correction of the used model is also mentioned.

Keywords: time series, stationarity, MA, AR, ARMA, ARIMA, SARMA, SARIMA, VAR, allergy, pollen, ambrosia, concentration

Životopis

Rođena sam 24. siječnja 1994. godine u Osijeku u Republici Hrvatskoj. Pohađala sam OŠ "Tenja" u Tenji (2000.-2008. godine) te potom i I. gimnaziju u Osijeku (2008.-2012. godine). Tijekom osnovnoškolskog i srednjoškolskog obrazovanja sam sudjelovala na natjecanjima iz matematike i hrvatskog jezika.

2012. godine upisujem Preddiplomski studij matematike na Odjelu za matematiku u Osijeku te 2015. godine stječem naziv *prvostupnice matematike* uz završni rad *Vigenèreova i Playfairova šifra* pod mentorstvom doc.dr.sc. Mirele Jukić Bokun. U jesen iste godine upisujem Diplomski studij matematike, smjer Financijska matematika i statistika na Odjelu za matematiku. Istaknula bih obavljanje stručne prakse u tvrtci Farmeron d.o.o. gdje sam zajedno s mentorima radila na problemima modeliranja podataka iz područja mliječne industrije.

Dodatak

U sljedećoj tablici su prikazani procijenjeni koeficijenti uz *dummy* varijable u modelima za prosječnu dnevnu temperaturu, prosječnu dnevnu vlažnost zraka i transformiranu maksimalnu dnevnu koncentraciju peludi.

Dummy varijabla	Prosječna temperatura	Vlažnost zraka	Transf. konc. peludi
sd1	0.55303	0.06544	0.02359
sd2	2.05683	-0.05822	0.04394
sd3	1.42657	-0.24830	0.27550
sd4	1.65356	-2.84600	0.19860
sd5	0.92578	-1.85000	-0.14380
sd6	0.62096	4.47900	-0.08916
sd7	0.61358	-1.48400	0.02699
sd8	1.92830	1.77200	0.31980
sd9	1.47284	1.68000	-0.12820
sd10	0.61775	5.86200	-0.01568
sd11	2.5433915*	-2.51300	-0.05248
sd12	-0.46681	1.17000	-0.00648
sd13	1.29746	-1.04500	0.27530
sd14	2.5205626*	-2.21700	0.17720
sd15	1.30794	2.26600	0.08166
sd16	0.57019	1.58500	-0.14330
sd17	2.24069	-2.01400	0.20420
sd18	2.24318	2.27300	-0.14340
sd19	1.50935	-0.28370	-0.07359
sd20	2.9084479*	0.57420	0.19540
sd21	1.18923	-1.00600	-0.12800
sd22	-0.01193	1.24800	-0.11160
sd23	0.63914	-1.45500	-0.05749
sd24	-0.18448	3.01300	0.01860
sd25	-1.40705	-0.53650	-0.00222
sd26	0.44074	-0.67950	0.07252
sd27	1.39297	1.90700	0.05808
sd28	-0.87625	-0.27090	0.07190
sd29	1.05951	-2.24700	0.26550
sd30	1.92909	-5.40800	0.22500
sd31	0.10502	-0.15190	0.13880
sd32	0.91910	-4.90900	0.10900
sd33	1.61242	-3.90000	0.17390
sd34	0.48623	-0.15840	-0.14300
sd35	1.79273	0.92840	0.19710
sd36	1.69650	-1.93400	-0.10780
sd37	1.79333	-0.41430	0.00473
sd38	0.85528	3.34700	-0.06222
sd39	-0.00551	-0.49850	0.26440
sd40	-0.51508	1.89900	-0.03856
sd41	1.10646	0.92400	-0.05875
sd42	2.27017	-0.03957	0.26480
sd43	0.80623	-0.60170	0.20870
sd44	0.40232	-0.30280	-0.13660
sd45	0.83338	3.63100	-0.05030
sd46	2.07913	-3.00800	-0.02268
sd47	1.44562	-1.90200	0.19620
sd48	0.60582	1.41800	-0.05144
sd49	2.23240	-0.11240	0.29290
sd50	2.8449018*	-3.71200	-0.16940

Dummy varijabla	Prosječna temperatura	Vlažnost zraka	Transf. konc. peludi
sd51	0.19073	4.21000	-0.06436
sd52	1.99327	-1.63800	0.26760
sd53	1.32184	1.70600	0.14200
sd54	2.3901837*	1.41000	-0.17200
sd55	2.9059376*	-0.35780	0.73590
sd56	1.70475	-2.17200	-0.31970
sd57	1.88124	-2.49700	0.06316
sd58	1.02308	-3.03400	0.28430
sd59	1.86481	-1.82200	0.01545
sd60	2.9767707*	-1.27900	0.04377
sd61	2.26385	-3.139	-0.22690
sd62	1.21765	-1.44700	0.17780
sd63	0.61825	-1.74600	-0.08432
sd64	1.17673	-2.28900	0.38150
sd65	2.5344631*	-7.08300	-0.16050
sd66	0.69991	2.04500	0.19300
sd67	1.65550	0.87120	-0.09617
sd68	2.8208705*	-8.991*	0.28850
sd69	2.22801	-5.77200	0.08572
sd70	2.3033382*	-1.75100	0.09788
sd71	2.05514	-2.68000	-0.14770
sd72	2.6065446*	-4.62100	0.19490
sd73	2.9374012*	-3.57600	0.12190
sd74	1.30348	-5.47500	0.12190
sd75	3.2208386*	-6.51100	0.34210
sd76	3.1770394*	-9.961*	-0.04846
sd77	2.21784	-6.47400	0.14030
sd78	1.18869	0.60620	-0.14030
sd79	2.4586295*	-6.38800	-0.07178
sd80	3.743296*	-6.68600	0.02136
sd81	2.8984091*	-9.212*	0.26670
sd82	2.5535951*	-1.71200	0.40870
sd83	1.98885	-3.66600	-0.14140
sd84	2.6405517*	-7.49500	0.41960
sd85	3.765049*	-9.713*	0.32920
sd86	2.12063	0.98990	0.07419
sd87	3.7935549*	-2.91300	0.05941
sd88	4.0685481*	-7.30800	0.13740
sd89	3.3742804*	-2.92300	-0.16830
sd90	3.3299849*	-2.51600	0.27540
sd91	1.39994	-0.78980	0.04407
sd92	3.4634142*	-3.74700	0.35830
sd93	3.5663516*	-6.303	0.55910
sd94	4.4011919*	-10.57*	0.14810
sd95	2.3707421*	5.72300	-0.03475
sd96	1.7195582	-2.03300	0.35930
sd97	4.7510066*	-5.55000	0.48380
sd98	2.6016395*	-11.31*	-0.40270
sd99	2.944545*	-5.41400	0.05013
sd100	3.1429276*	-9.168*	0.10400
sd101	4.5924729*	-4.50300	0.10660
sd102	4.3332413*	-5.11400	0.04431
sd103	1.45427	-2.07700	0.38700
sd104	3.1286727*	-0.42570	0.25840
sd105	2.8029789*	-1.15500	-0.15210
sd106	4.1125574*	-8.603*	0.71570
sd107	2.8922276*	-1.19000	-0.24960
sd108	4.1141384*	-4.78200	-0.17050
sd109	3.2044936*	-4.28600	-0.11900
sd110	4.6998969*	-8.636*	0.18960
sd111	4.5908535*	-9.347*	-0.17100
sd112	2.4003023*	-3.71800	0.42830
sd113	3.7325638*	-5.01400	-0.23470

Dummy varijabla	Prosječna temperatura	Vlažnost zraka	Transf. konc. peludi
sd114	4.7361092*	-9.348*	0.27890
sd115	3.7031065*	-6.59900	-0.05617
sd116	3.7331706*	-10.02*	-0.06823
sd117	4.9891416*	-15.45*	0.39650
sd118	3.5242857*	-5.70200	-0.17610
sd119	3.2301889*	-2.90700	-0.04107
sd120	4.9089237*	-5.37000	0.03891
sd121	4.7508327*	-7.26000	0.03768
sd122	3.4590799*	-2.47500	0.27110
sd123	4.2333026*	-3.16200	0.27590
sd124	2.985531*	-3.66800	-0.09454
sd125	4.5371441*	-9.225*	0.22010
sd126	3.6647452*	-7.63100	0.18510
sd127	4.2664034*	-5.83800	-0.10550
sd128	3.1264281*	-3.30800	0.19450
sd129	4.9195571*	-9.244*	-0.11160
sd130	5.0912264*	-10.9*	0.29050
sd131	3.7945768*	-4.36000	-0.09813
sd132	3.8924093*	-7.89300	0.22290
sd133	1.725459	1.88800	-0.01201
sd134	4.2932576*	-4.09300	0.26550
sd135	3.4408805*	-0.16710	0.48600
sd136	3.2471967*	-5.62200	0.13200
sd137	4.7087822*	-4.61500	0.10310
sd138	5.3151641*	-12.02*	-0.13350
sd139	5.031173*	-12.03*	-0.07755
sd140	4.3947768*	-4.00200	0.15860
sd141	4.0241577*	-4.63900	0.10140
sd142	4.1133331*	0.77200	-0.17570
sd143	3.3723822*	-3.70400	-0.02734
sd144	4.6755008*	-5.80300	0.03940
sd145	4.4193085*	-6.59500	0.10310
sd146	3.7271046*	-7.73700	-0.03296
sd147	4.7079303*	9.349*	0.00582
sd148	2.8105809*	-7.35	0.59330
sd149	3.0898293*	-5.85600	-0.28570
sd150	4.6714972*	-6.03100	-0.03899
sd151	3.2702503*	-6.83200	0.52070
sd152	4.0509368*	-0.99810	0.06182
sd153	3.9179625*	-4.51900	-0.05143
sd154	5.1756883*	-13.15*	-0.03433
sd155	3.586544*	-3.33900	-0.06578
sd156	4.5038363*	-2.98200	-0.00816
sd157	5.2365065*	-10.5*	0.19130
sd158	5.1588839*	-12.4*	0.11830
sd159	5.4419153*	-9.829*	0.33930
sd160	5.4570777*	-10.57*	-0.19150
sd161	4.6558676*	-10.58*	-0.09063
sd162	2.33132	-2.60100	0.38100
sd163	5.3574718*	-5.37800	0.41430
sd164	4.1922541*	-10.74*	0.20090
sd165	4.3593888*	-8.711*	-0.29260
sd166	4.9133605*	-10.95*	0.43930
sd167	4.7715645*	-7.63600	0.02528
sd168	4.2817155*	-5.76900	-0.23180
sd169	4.7081293*	-9.342*	0.55090
sd170	3.9602209*	-6.07200	-0.03457
sd171	4.7112879*	-11.15*	0.52520
sd172	4.5223008*	-9.863*	-0.02869
sd173	4.695978*	-8.455*	0.05408
sd174	5.2188657*	-9.835*	0.63960
sd175	2.7719736*	-1.44900	-0.21430
sd176	2.9395157*	-4.39500	0.03202
sd177	4.3298901*	-9.683*	0.33410
sd178	4.6543566*	-7.36500	-0.28590

Dummy varijabla	Prosječna temperatura	Vlažnost zraka	Transf. konc. peludi
sd179	4.494896*	-11.19*	0.20480
sd180	5.605587*	-7.95300	-0.11080
sd181	4.467572*	-6.38300	-0.12540
sd182	4.2669051*	-10.94*	0.23050
sd183	5.4018438*	-10.14*	-0.13960
sd184	4.7201316*	-14.14*	0.21920
sd185	4.6980838*	-9.631*	0.39120
sd186	5.0355103*	-9.703*	0.11560
sd187	5.7001817*	-10.21*	-0.14620
sd188	5.358987*	-9.355*	0.57970
sd189	4.4160544*	-5.524	0.42770
sd190	3.5314515*	-9.648*	-0.09263
sd191	5.2811483*	-9.853*	-0.23260
sd192	4.1190639*	-5.92100	0.59750
sd193	5.3104792*	-13.61*	0.24160
sd194	5.994053*	-11.48*	0.56200
sd195	4.6272218*	-7.57600	0.21690
sd196	4.4335663*	-5.61700	-0.19580
sd197	5.0605773*	-10.54*	0.47840
sd198	5.9051955*	-11.7*	0.56220
sd199	4.5275683*	-6.14600	0.03187
sd200	5.1017971*	-10.77*	1.177*
sd201	5.4224487*	-10.4*	1.113*
sd202	3.9197028*	-12.1*	0.78080
sd203	4.5899625*	-4.08600	-0.22020
sd204	5.2196278*	-7.38400	0.67410
sd205	4.5252626*	-5.52400	1.232*
sd206	3.4177369*	-6.04900	0.73610
sd207	4.5172734*	-7.42900	-0.00790
sd208	5.0410897*	-8.13800	0.32250
sd209	5.8417632*	-11.12*	1.797*
sd210	5.6091904*	-9.836*	0.59320
sd211	4.1427633*	-8.43000	0.75590
sd212	3.798872*	-5.76000	0.42020
sd213	6.2226794*	-11.51*	1.133*
sd214	6.2979502*	-11.57*	0.52540
sd215	5.5764893*	-10.9*	1.423*
sd216	4.3140915*	-7.41500	1.778*
sd217	4.9124985*	-8.558*	1.946*
sd218	5.1487976*	-9.436*	0.9936*
sd219	5.0672347*	-12.67*	1.316*
sd220	6.145216*	-14.63*	1.305*
sd221	3.2662396*	-11.04*	1.659*
sd222	4.6693939*	-12.91*	1.342*
sd223	4.4074205*	-10.59*	1.233*
sd224	5.7566792*	-9.932*	1.559*
sd225	6.8774856*	-14.01*	1.587*
sd226	3.8017368*	-8.64200	1.753*
sd227	5.822527*	-13.86*	1.722*
sd228	4.1616446*	-12.39*	1.912*
sd229	4.0081626*	-9.014*	2.22*
sd230	5.8981977*	-13.23*	2.091*
sd231	5.6648002*	-15.62*	2.201*
sd232	5.0971983*	-6.12200	2.228*
sd233	4.4332927*	-8.88500	2.158*
sd234	6.039444*	-14.9*	2.109*
sd235	5.2284492*	-10.71*	1.894*
sd236	4.6765262*	-5.79800	1.263*
sd237	5.0531638*	-12.52*	2.151*
sd238	5.6580092*	-8.71100	2.197*
sd239	5.5996565*	-10.5*	2.053*
sd240	3.6681217*	-8.56200	2.112*
sd241	4.091476*	-10.86*	1.945*
sd242	4.8836295*	-12.29*	1.077*
sd243	5.4314947*	-14.41*	0.69850

Dummy varijabla	Prosječna temperatura	Vlažnost zraka	Transf. konc. peludi
sd244	4.7946713*	-9.251*	1.714*
sd245	4.5506798*	-8.05700	1.355*
sd246	5.4836372*	-12.77*	1.665*
sd247	5.770089*	-13.49*	1.452*
sd248	3.0474271*	-8.27800	1.447*
sd249	4.1054727*	-10.15*	1.371*
sd250	4.0354031*	-14.69*	2.201*
sd251	4.4692746*	-8.45800	1.555*
sd252	4.5715225*	-11.02*	1.62*
sd253	4.8997202*	-5.86000	1.198*
sd254	4.9741089*	-9.345*	0.59450
sd255	4.722033*	-10.28*	0.77290
sd256	3.2846848*	-3.65800	0.939*
sd257	3.391702*	-4.13800	1.833*
sd258	4.8043167*	-6.52600	0.70170
sd259	4.8653843*	-12.4*	1.016*
sd260	4.0248478*	-7.86400	0.55220
sd261	4.0236155*	-9.035*	0.37000
sd262	4.1012511*	-7.59200	0.03340
sd263	1.2624224	-0.28460	0.04039
sd264	3.6405701*	-10.63*	0.69460
sd265	3.8534036*	-8.48000	0.72510
sd266	4.2726686*	-11.08*	0.55280
sd267	4.6113981*	-15.27*	1.499*
sd268	2.6235387*	-3.03500	0.9469*
sd269	4.1526701*	-6.94100	0.2486
sd270	3.8901685*	-11*	0.48480
sd271	3.0313661*	-6.13400	0.59180
sd272	2.8286947*	-7.33800	0.69360
sd273	3.2893836*	-7.21200	0.17670
sd274	4.4013294*	-9.14*	0.72470
sd275	2.4846377*	-1.69400	0.45960
sd276	3.0274774*	-12.52*	0.61400
sd277	2.7839939*	-5.68400	0.27580
sd278	3.0992352*	-9.639*	0.77770
sd279	4.5320482*	-9.07*	1.511*
sd280	3.6943668*	-6.18800	0.52370
sd281	1.73442	-7.69600	0.22310
sd282	3.4958367*	-2.90700	0.38370
sd283	3.3413756*	-3.48300	0.75670
sd284	3.2201853*	-0.50770	0.62220
sd285	3.6571644*	-7.38900	0.73200
sd286	2.14493	-2.18200	0.831*
sd287	2.886248*	-3.60800	0.55570
sd288	3.2819864*	-6.94000	0.77690
sd289	2.18945	-1.93400	-0.05981
sd290	1.49883	-1.69000	0.77140
sd291	3.2075354*	-5.54900	-0.11310
sd292	3.256502*	-3.60100	0.08227
sd293	2.5210561*	-6.08000	0.34580
sd294	3.1061112*	-4.65600	0.62360
sd295	2.4654283*	-4.68300	0.61430
sd296	2.9455285*	-1.63800	0.846*
sd297	2.7727654*	-3.59700	0.26590
sd298	2.6344468*	-2.32900	0.67110
sd299	1.8086039	-4.08500	0.39700
sd300	2.486751*	-8.296*	0.9032*
sd301	2.04685	-5.66400	-0.20140
sd302	2.4152296*	-7.05200	0.28530
sd303	1.70206	-4.02800	0.37330
sd304	1.95924	-7.07900	0.66860
sd305	3.0424146*	-2.70300	0.20330
sd306	2.3623564*	-7.19100	-0.61310
sd307	1.62320	-0.66440	-0.22800
sd308	3.4447788*	-4.94200	-0.15460

Dummy varijabla	Prosječna temperatura	Vlažnost zraka	Transf. konc. peludi
sd309	4.3941554*	-7.71600	0.02558
sd310	1.37592	-1.59500	-0.08546
sd311	3.3637228*	-6.51800	-0.45990
sd312	4.0157783*	-6.08900	-0.00974
sd313	1.7861004	-2.27100	-0.19720
sd314	1.78113	-0.25330	-0.03545
sd315	2.3666757*	-9.023*	0.01784
sd316	1.37097	-1.75800	-0.16270
sd317	2.4529829*	-3.44300	-0.08244
sd318	1.32571	-3.05600	-0.19470
sd319	2.5671258*	-6.10400	0.02603
sd320	1.70609	3.04100	-0.00812
sd321	2.4929594*	-5.89600	-0.18550
sd322	1.32509	0.48870	0.20330
sd323	1.87429	-1.14800	-0.18800
sd324	2.08498	-1.40900	-0.01292
sd325	1.75595	1.27600	-0.00192
sd326	-0.20812	-0.44590	0.17350
sd327	1.66734	-1.34900	-0.05145
sd328	0.80264	-1.88000	-0.01604
sd329	0.53229	3.95600	-0.06679
sd330	1.91538	-2.40600	0.34560
sd331	1.19233	-3.86000	0.16400
sd332	1.47300	1.97200	-0.14510
sd333	2.22699	-2.83200	0.23060
sd334	1.46533	-1.28700	0.14920
sd335	2.19836	-0.64390	-0.14250
sd336	0.80759	2.65900	-0.05390
sd337	2.10225	-1.99800	0.30020
sd338	1.50542	-1.28400	-0.13910
sd339	1.45119	-2.22200	-0.07309
sd340	1.02096	2.97300	-0.00183
sd341	1.08454	-0.89910	0.19970
sd342	2.2958846*	-0.59500	0.24900
sd343	-0.45444	-2.65300	0.10110
sd344	0.96581	-1.90000	0.08237
sd345	0.34854	0.90670	0.10350
sd346	1.14584	-0.65960	-0.10210
sd347	0.30355	0.01450	-0.04324
sd348	0.98148	0.08719	-0.00109
sd349	1.37951	1.03700	-0.04640
sd350	1.00546	0.79550	0.03611
sd351	0.23816	-0.58490	-0.01246
sd352	0.64063	1.36100	0.03016
sd353	0.78203	0.29050	0.01211
sd354	1.07861	1.10100	0.01638
sd355	1.40899	-4.02200	0.05756
sd356	2.9939957*	-1.87300	-0.02130
sd357	3.2422659*	-4.69300	-0.04836
sd358	1.3319516	-2.11300	-0.04558
sd359	1.19507	0.98690	-0.04262
sd360	0.08464	0.23600	-0.03482
sd361	-0.64808	2.85100	-0.01132
sd362	0.73832	2.88000	0.06366
sd363	-1.26559	2.09000	0.32010
sd364	0.98722	-1.38900	-0.01344

Tablica : Procijenjeni koeficijenti uz *dummy* varijable u modelima za prosječnu dnevnu temperaturu, prosječnu dnevnu vlažnost zraka i transformiranu maksimalnu dnevnu koncentraciju peludi, * - značajni na nivou značajnosti 0.05