

TMS125, Stokastiska Processer F2, VT 2005

KURSVÄRDERING PÅ KURSEMSIDAN!

<http://www.math.chalmers.se/Stat/Grundutb/Chalmers/TMS125/>

TENTA FACIT

- Kovariansen kan endast beskriva linjärt beroende mellan stokastiska variabler. Därför betyder inte that kovariansen är 0 att variabler är oberoende.
 - För normalfördelade (Gaussiska) stokastiska variabler mäter kovariansen all möjlig beroende. Således är väntesvärdes och kovariansfunktionen mest användbara för Gaussiska processer.
- Det finns många sätt att visa att det inte håller. Låt t. ex. $X(t)$ vara en Poissonprocess. Då gäller:

$$\begin{aligned}\mathbf{E}[Y(t + \tau) - Y(t)] &= \mathbf{E}[X(t + \tau)^2] - \mathbf{E}[X(t)^2] \\ &= V_X(t + \tau) + m_X(t + \tau)^2 - V_X(t) - m_X(t)^2 \\ &= \lambda(t + \tau) + \lambda^2(t + \tau)^2 - \lambda t - \lambda^2 t^2 \\ &= \lambda\tau + \lambda\tau^2 + 2\lambda t\tau\end{aligned}$$

Altså beror väntevärdet av $Y(t)$ s ökning på t , vilket motsäger att den har stationära ökningar.

- Det enklast exemplet är att ta $X(t) = \xi$ för alla $t \geq 0$, och låta ξ vara en normalfördelad stokastisk variabel. Den processen antar ett konstant normalfördelat värde.
 - $m_Y(t) = m_W(t + T) - m_W(t) = 0$ beror inte på t .

$$\begin{aligned}r_Y(t + \tau) &= \mathbf{Cov}[Y(t), Y(t + \tau)] \\ &= \mathbf{Cov}[W(t + T) - w(t), W(t + \tau + T) - w(t + \tau)] \\ &= \mathbf{Cov}[W(t + T), W(t + \tau + T)] - \mathbf{Cov}[W(t), W(t + \tau + T)] \\ &\quad - \mathbf{Cov}[W(t + T), W(t + \tau)] + \mathbf{Cov}[W(t), W(t + \tau)] \\ &= \sigma^2(t + T - t - \min(t + T, t + \tau) + t) \\ &= \sigma^2(T - \min(T, \tau)) \\ &= \begin{cases} 0 & \text{om } \tau \geq T \\ \sigma^2(T - \tau) & \text{annars.} \end{cases}\end{aligned}$$

Eftersom varken $m_Y(t)$ eller $r_Y(t, t + \tau)$ beror på t är $Y(t)$ svagt stationär. Eftersom skillnaden mellan två Gaussiska processer är en Gaussisk process, så är den även det. En svagt stationär Gaussisk process är stationär.

4. Det följer från direkt beräkning:

$$\begin{aligned}\mathbf{E}[(X(t)/t - \lambda)^2] &= t^{-2}\mathbf{E}[(X(t) - \lambda t)^2] \\ &= t^{-2}\mathbf{E}[(X(t) - \mathbf{E}[X])^2] \\ &= t^{-2}\mathbf{Var}[X(t)] \\ &= \lambda/t \rightarrow 0 \text{ då } t \rightarrow \infty\end{aligned}$$

5. (a) För att det ska vara en stokastisk matris måste alla element ligga i $[0, 1]$ och radsummorna vara 1. Det följer att $a \in [0, 0.5]$ och att $c = b = 1 - 2a$.
- (b) För att det ska finnas en unik stationär process måste kedjan vara irreducibel. Det är den endast om $a > 0$.
- (c) Den stationära fördelningen ges av $\pi = [\frac{1}{4}, \frac{1}{2}, \frac{1}{4}]$. Det gäller för att alla godtagbara värden av a , b , och c .
6. Egenskapen är att g måste ha vara en *injektiv* funktion. Det betyder att $g(x) = g(y)$ omm $x = y$. För en injektiv funktion har en invers defenierad på g s bildmängd. Det följer att:

$$\begin{aligned}&\mathbf{P}(Y_{n+1} = j | Y_n = i, Y_{n-1} = i_{n-1}, \dots, Y_0 = i_0) \\ &= \mathbf{P}(X_{n+1} = g^{-1}(j) | X_n = g^{-1}(j_n), X_{n-1} = g^{-1}(j_{n-1}), \dots, X_0 = g^{-1}(j_0)) \\ &= \mathbf{P}(X_{n+1} = g^{-1}(j) | X_n = g^{-1}(j_n)) \\ &= \mathbf{P}(Y_{n+1} = j | Y_n = i).\end{aligned}$$

Alltså uppfyller Y_n Markovegenskapen och är således en Markovkedja när g är injektiv.

För ett motexempel när g inte är injektiv, ta $S = \{1, 2, 3\}$ och låt X_n ha följande överångsmatris:

$$P = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \end{bmatrix}$$

och låt $g(1) = 1$, $g(2) = 2$, och $g(3) = 2$. Det är inte möjligt för X_n att återvända till tillstånd 1 om den var där för en tur sedan, alltså gäller $\mathbf{P}(Y_{n+1} = 1 | Y_n = 2, Y_{n-1} = 1) = 0$. Men å andra sidan gäller $\mathbf{P}(Y_{n+1} = 1 | Y_n = 2, Y_{n-1} = 2) = 1$. Detta motsäger Markovegenskapen.