

Korrelasjonsmodeller

Arne Bang Huseby

Standard normalfordelte variable

Gitt en vektor, \mathbf{X} , av n stokastiske variable X_1, \dots, X_n , der vi i første omgang antar at:

$$X_i \sim N(0, 1), \quad i = 1, \dots, n. \quad (1)$$

Vi skal nå se på ulike korrelasjonsmodeller for X_1, \dots, X_n , og hvordan disse kan representeres effektivt i forbindelse med simuleringer.

Vi ser først på det generelle tilfellet der C betegner korrelasjonsmatrisen for \mathbf{X} (som i dette tilfelle også er det samme som kovariansmatrisen siden alle varianser er lik 1). Anta så at C kan skrives på formen:

$$C = MM^T, \quad (2)$$

der $M = M^{n \times m}$ er en passende matrise. I så fall kan vektoren \mathbf{X} representeres som:

$$\mathbf{X} = M \cdot \mathbf{U} \quad (3)$$

der $\mathbf{U} = (U_1, \dots, U_m)$ er en vektor av m uavhengige standard normalfordelte stokastiske variable.

Dette følger fordi lineærtransformasjoner av multinormalfordelte variable er multinormalfordelte og fordi:

$$\begin{aligned}\text{Cov}(MU) &= E[(MU)(MU)^T] \quad (4) \\ &= ME[UU^T]M^T \\ &= MIM^T \\ &= MM^T = C,\end{aligned}$$

der vi har benyttet at kovariansmatrisen til en vektor \mathbf{Y} der $E\mathbf{Y} = \mathbf{0}$ er lik $E[\mathbf{Y} \cdot \mathbf{Y}^T]$.

Av spesiell interesse er den såkalte *Cholesky-dekomposisjonen*. Siden en korrelasjonsmatrise alltid er positivt definit (eller i det minste ikke-negativt definit), finnes det en nedre triangulær matrise $L = L^{n \times n}$ slik at:

$$C = L \cdot L^T \quad (5)$$

Vektoren \mathbf{X} kan dermed representeres som $\mathbf{X} = L \cdot \mathbf{U}$, der \mathbf{U} nå er en vektor av n uavhengige standard normalfordelte variable.

Bemerk at det alltid finnes en og bare en nedre triangulær $n \times n$ -matrise L som tilfredsstiller betingelsen (5).

For å vise entydighet, setter vi opp ligningene som følger av (5). La $C = \{c_{i,j}\}_{i,j=1}^n$. Elementene i matrisen $L = \{l_{i,j}\}_{i,j=1}^n$ må da tilfredsstille følgende ligninger:

$$l_{i,i} = [c_{i,i} - \sum_{k=1}^{i-1} l_{i,k}^2]^{1/2}, \quad (6)$$

$$l_{j,i} = \frac{1}{l_{i,i}} [c_{i,j} - \sum_{k=1}^{i-1} l_{i,k} l_{j,k}], \quad (7)$$

$$j = i + 1, i + 2, \dots, n,$$

der $i = 1, 2, \dots, n$.

Dersom ligningene (6) og (7) løses fortløpende for $i = 1, 2, \dots, n$, vil høyresidene av ligningene kun inneholde ledd som er bestemt tidligere i prosessen. Såsant vi har at:

$$c_{i,i} \geq \sum_{k=1}^{i-1} \ell_{i,k}^2, \quad i = 1, 2, \dots, n, \quad (8)$$

så vil ligningssettet dermed ha en entydig løsning.

Betingelsen (8) vil være oppfylt dersom matrisen C er ikke-negativt definit.

Det er en nær sammenheng mellom Cholesky-dekomposisjon og det å finne betingede fordelinger i multinormalfordelingen. For å se dette starter vi med å innføre vi følgende subvektorer:

$$\mathbf{X}_k = (X_1, \dots, X_k), \quad k = 1, \dots, n.$$

$$\mathbf{U}_k = (U_1, \dots, U_k), \quad k = 1, \dots, n.$$

Vi lar videre C_k betegne korrelasjonsmatrisen til subvektoren \mathbf{X}_k , $k = 1, \dots, n$.

Vi blokkdeler så korrelasjonsmatrisen for \mathbf{X}_{k+1} som følger:

$$C_{k+1} = \left[\begin{array}{c|c} C_k & C_{k,k+1} \\ \hline C_{k+1,k} & 1 \end{array} \right], \quad (9)$$

der:

$$\begin{aligned} C_{k+1,k} &= C_{k,k+1}^T & (10) \\ &= (\text{Cov}(X_{k+1}, X_1), \dots, \text{Cov}(X_{k+1}, X_k)). \end{aligned}$$

Av elementære egenskaper ved multinormalfordelingen følger det nå at:

$$X_{k+1} | \mathbf{X}_k = \mathbf{x}_k \sim N(a_{k+1,k} \mathbf{x}_k, b_{k+1,k}), \quad (11)$$

der:

$$a_{k+1,k} = C_{k+1,k} C_k^{-1}, \quad (12)$$

og

$$b_{k+1,k} = (1 - C_{k+1,k} C_k^{-1} C_{k,k+1})^{1/2}. \quad (13)$$

Bemerk at uttrykket for $b_{k+1,k}$ alltid er veldefinert fordi $1 - C_{k+1,k}C_k^{-1}C_{k,k+1} \geq 0$. Dette følger fordi:

$$\begin{aligned}
 0 &\leq \text{Var}(X_{k+1} - C_{k+1,k}C_k^{-1}\mathbf{X}_k) \\
 &= 1 + C_{k+1,k}C_k^{-1}C_kC_k^{-1}C_{k,k+1} \\
 &\quad - 2\text{Cov}(X_{k+1}, C_{k+1,k}C_k^{-1}\mathbf{X}_k) \\
 &= 1 + C_{k+1,k}C_k^{-1}C_{k,k+1} \\
 &\quad - 2C_{k+1,k}C_k^{-1}C_{k,k+1} \\
 &= 1 - C_{k+1,k}C_k^{-1}C_{k,k+1}
 \end{aligned}$$

Basert på disse relasjonene kan vi nå konstruere en modell for \mathbf{X} som følger:

$$X_1 = U_1 \quad (14)$$

$$X_2 = a_{2,1}X_1 + b_{2,1}U_2$$

...

$$X_n = a_{n,n-1}X_{n-1} + b_{n,n-1}U_n$$

Bemerk at X_k kun avhenger av U_1, \dots, U_k for $k = 1, \dots, n$. Dette betyr at det finnes en triangulær matrise, L , slik at $\mathbf{X} = LU$. Ved entydigheten av Cholesky-dekomposisjonen, må denne dermed være lik L .

Vi kan også bruke (14) til å finne L rekursivt. La derfor L_k betegne Cholesky-dekomposisjonen av C_k . Dvs. vi har:

$$\mathbf{X}_k = L_k \mathbf{U}_k, \quad k = 1, \dots, n. \quad (15)$$

Siden $X_1 = U_1$, er selvsagt $L_1 = 1$. Anta så at vi har funnet L_k og skal finne L_{k+1} . De k første radene av L_{k+1} finner vi da umiddelbart ved å ta radene i L_k og føye til en null ytterst til høyre i hver rad. Den siste raden finnes til slutt av (14) ved å sette inn $\mathbf{X}_k = L_k \mathbf{U}_k$.


Skrevet ut ved hjelp av blokkdelte matriser får vi dermed følgende rekursjonsformel:

$$L_{k+1} = \left[\begin{array}{c|c} L_k & 0 \\ \hline a_{k+1,k}L_k & b_{k+1,k} \end{array} \right], \quad (16)$$

for $k = 2, \dots, n$.

Markov-kjeder

En vanlig brukt avhengighetsstruktur er Markov-kjeder, dvs. sekvenser av stokastiske variable der enhver variabel i sekvensen avhenger av de foregående kun via den forrige variabelen.



Influensdiagram for en Markov-kjede

Vi skal nå konstruere en enkel additiv Markovkjede. La U_1, \dots, U_n være n uavhengige standard normalfordelte stokastiske variable, og definer:

$$X_1 = U_1 \quad (17)$$

$$X_2 = aX_1 + bU_2$$

...

$$X_n = aX_{n-1} + bU_n$$

der konstantene a og b velges slik at kjeden får den ønskede korrelasjonsstruktur.

Variansene til variablene i Markov-kjeden blir nå gitt ved:

$$\text{Var}(X_1) = \text{Var}(U_1) \quad (18)$$

$$\text{Var}(X_k) = a^2 \text{Var}(X_{k-1}) + b^2 \text{Var}(U_k),$$
$$k = 2, \dots, n.$$

Vi krever så at alle variablene i kjeden skal ha varians lik 1. Dette leder til følgende betingelse på a og b :

$$a^2 + b^2 = 1. \quad (19)$$

Kovariansen mellom to påhverandre følgende ledd i kjeden blir gitt ved:

$$\begin{aligned}\text{Cov}(X_k, X_{k-1}) &= \text{Cov}(aX_{k-1} + bU_k, X_{k-1}) \\ &= a \text{Cov}(X_{k-1}, X_{k-1}) \\ &= a \text{Var}(X_{k-1}) \\ &= a.\end{aligned}\tag{20}$$

for $k = 2, 3, \dots, n$.

Vi krever videre at:

$$\text{Cov}(X_k, X_{k-1}) = \rho, \quad k = 2, 3, \dots, n. \quad (21)$$

Av dette, samt av (19), følger det dermed at:

$$a = \rho. \quad (22)$$

$$b = (1 - \rho^2)^{1/2} \quad (23)$$

Bemerk spesielt at både a og b er veldefinerte for alle mulige korrelasjonskoeffisienter, dvs. for alle ρ som er slik at:

$$-1 \leq \rho \leq 1. \quad (24)$$

Vi ser nå litt nærmere på korrelasjonsstrukturen i Markov-kjeden. Dersom $j < k$, har vi at:

$$\begin{aligned}\text{Cov}(X_k, X_j) &= \text{Cov}(aX_{k-1} + bU_k, X_j) \\ &= a \text{Cov}(X_{k-1}, X_j).\end{aligned}\tag{25}$$

Ved å gjenta denne operasjonen tilstrekkelig mange ganger, og til sist kombinere dette med (20), ser vi at vi får følgende sammenheng for alle $j < k$:

$$\text{Cov}(X_k, X_j) = a^{k-j}\tag{26}$$

Innsatt $a = \rho$ blir korrelasjonsmatrisen til \mathbf{X} dermed gitt ved:

$$C = \begin{bmatrix} 1 & \rho & \rho^2 & \dots & \rho^{n-1} \\ \rho & 1 & \rho & \dots & \rho^{n-2} \\ \rho^2 & \rho & 1 & \dots & \rho^{n-3} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ \rho^{n-1} & \rho^{n-2} & \rho^{n-3} & \dots & 1 \end{bmatrix} \quad (27)$$

Denne strukturen er den første av flere eksempler der korrelasjonen mellom to variable er avhengig av “avstanden” mellom variablene. I dette tilfellet er avstandsbegrepet knyttet til tidsavstand i kjeden.

Mer spesifikt kan vi innføre følgende avstandsmål mellom variablene:

$$d(X_i, X_j) = |i - j|, \quad i, j = 1, \dots, n. \quad (28)$$

Kovariansen mellom to variable kan da uttrykkes på formen:

$$\text{Cov}(X_i, X_j) = \rho^{d(X_i, X_j)}, \quad i, j = 1, \dots, n. \quad (29)$$

Siden alle avstander i dette tilfellet er heltall, så er (29) definert både for positive og negative verdier av ρ . Imidlertid gir nok avstandsfortolkningen mest mening når $0 < \rho < 1$. I dette tilfellet avtar korrelasjonen monotont med økende avstand.


Matrisen C er opplagt positivt definit siden vi faktisk har vist at den er en virkelig korrelasjonsmatrise. Ved å ekspandere (17), ser vi at relasjonen mellom \mathbf{X} og \mathbf{U} i dette tilfellet blir på form:

$$\mathbf{X} = \begin{bmatrix} 1 & 0 & 0 & \dots & 0 \\ a & b & 0 & \dots & 0 \\ a^2 & ab & b & \dots & 0 \\ \vdots & \vdots & \vdots & \dots & \vdots \\ a^{n-1} & a^{n-2}b & a^{n-3}b & \dots & b \end{bmatrix} \mathbf{U}, \quad (30)$$

der den triangulære matrisen i dette uttrykket svarer til Cholesky-dekomposisjonen av C .

Stjerne-modeller

Den neste modellen vi skal se på, vil vi kalle en stjernemodell. En slik modell egner seg godt for å beskrive en situasjon der alle variablene avhenger av en felles bakenforliggende variabel, si U_0 .



Influensdiagram for en stjerne-modell

La denne gang $U = (U_0, U_1, \dots, U_n)$ være en vektor av $n + 1$ uavhengige standard normalfordelte stokastiske variable, og definer:

$$X_1 = a_1U_0 + b_1U_1 \quad (31)$$

$$X_2 = a_2U_0 + b_2U_2$$

...

$$X_n = a_nU_0 + b_nU_n$$

der konstantene $a_i, b_i, i = 1, \dots, n$ velges slik at modellen får den ønskede korrelasjonsstruktur.

Variansen til X_i 'ene blir dermed:

$$\text{Var}(X_i) = a_i^2 \text{Var}(U_0) + b_i^2 \text{Var}(U_i), \quad (32)$$

$$= a_i^2 + b_i^2$$

$$i = 1, \dots, n.$$

Som sist krever vi at alle X_i 'ene skal ha varians lik 1. Dvs. vi må ha at:

$$a_i^2 + b_i^2 = 1, \quad i = 1, \dots, n. \quad (33)$$

Kovariansen mellom to variable X_i og X_j blir:

$$\begin{aligned}\text{Cov}(X_i, X_j) &= \text{Cov}(a_i U_0 + b_i U_i, a_j U_0 + b_j U_j) \\ &= a_i a_j \text{Cov}(U_0, U_0) \\ &= a_i a_j \text{Var}(U_0) \\ &= a_i a_j\end{aligned}\tag{34}$$

for alle $i \neq j$.

Vi krever nå at kovariansene skal kunne skrives på følgende form:

$$\text{Cov}(X_i, X_j) = \rho_i \rho_j, \quad i \neq j. \quad (35)$$

Av dette, samt av (33), følger det dermed at:

$$a_i = \rho_i, \quad i = 1, \dots, n, \quad (36)$$

$$b_i = (1 - \rho_i^2)^{1/2}, \quad i = 1, \dots, n. \quad (37)$$

Også denne gang er a_i 'ene og b_i 'ene veldefinerte for alle mulige korrelasjonskoeffisienter, dvs. for alle ρ_i som er slik at:

$$-1 \leq \rho_i \leq 1. \quad (38)$$

Totalt får vi at korrelasjonsmatrisen til \mathbf{X} er gitt ved:

$$C = \begin{bmatrix} 1 & \rho_{1\rho_2} & \rho_{1\rho_3} & \cdots & \rho_{1\rho_n} \\ \rho_{2\rho_1} & 1 & \rho_{2\rho_3} & \cdots & \rho_{2\rho_n} \\ \rho_{3\rho_1} & \rho_{1\rho_3} & 1 & \cdots & \rho_{3\rho_n} \\ \vdots & \vdots & \vdots & \cdots & \vdots \\ \rho_{n\rho_1} & \rho_{n\rho_2} & \rho_{n\rho_3} & \cdots & 1 \end{bmatrix} \quad (39)$$

I likhet med Markov-modellen kan også denne strukturen gis en tolkning der korrelasjonen mellom to variable er avhengig av “avstanden” mellom variablene.

For å se hvordan dette kan gjøres, antar vi at $0 < \rho_i \leq 1$, $i = 1, \dots, n$. La så ρ være et passende tall slik at $0 < \rho < 1$, og innfør så:

$$\alpha_i = \frac{\ln(\rho_i)}{\ln(\rho)}, \quad i = 1, \dots, n. \quad (40)$$

Vi har med andre ord at:

$$\rho_i = \rho^{\alpha_i}, \quad i = 1, \dots, n. \quad (41)$$

Størrelsen α_i kan nå fortolkes som “avstanden” fra X_i til sentrum av stjernen. Avstanden mellom to variable blir summen av deres respektive avstander inn til sentrum. Dvs.:

$$d(X_i, X_j) = \begin{cases} \alpha_i + \alpha_j & i \neq j \\ 0 & i = j \end{cases} \quad (42)$$

Med dette avstandsmålet får vi igjen at:

$$\text{Cov}(X_i, X_j) = \rho^{d(X_i, X_j)}, \quad i, j = 1, \dots, n. \quad (43)$$

En spesielt enkel situasjon oppstår når $\alpha_i = 1/2$, for $i = 1, \dots, n$. I dette tilfellet blir $d(X_i, X_j) = 1$ for alle $i \neq j$. Korrelasjonsmatrisen til \mathbf{X} blir dermed:

$$C = \begin{bmatrix} 1 & \rho & \rho & \cdots & \rho \\ \rho & 1 & \rho & \cdots & \rho \\ \rho & \rho & 1 & \cdots & \rho \\ \vdots & \vdots & \vdots & \cdots & \vdots \\ \rho & \rho & \rho & \cdots & 1 \end{bmatrix} \quad (44)$$

Bemerk at vi i denne situasjonen har at $a_i = \rho^{1/2}$ og at $b_i = (1 - \rho)^{1/2}$, $i = 1, \dots, n$.

Matrisen C er igjen opplagt positivt definit siden vi faktisk har vist at den er en virkelig korrelasjonsmatrise. Av (31), ser vi at relasjonen mellom \mathbf{X} og \mathbf{U} i dette tilfellet blir på form:

$$\mathbf{X} = \begin{bmatrix} a_1 & b_1 & 0 & \cdots & 0 \\ a_2 & 0 & b_2 & \cdots & 0 \\ \vdots & \vdots & \vdots & \cdots & \vdots \\ a_n & 0 & 0 & \cdots & b_n \end{bmatrix} \mathbf{U}. \quad (45)$$

Siden dimensjonen til \mathbf{U} (dvs. $n + 1$) i dette tilfellet er større enn dimensjonen til \mathbf{X} (dvs. n), blir matrisen over ikke triangulær.

Dette kan vi imidlertid få til ved å føye til en ekstra variabel X_0 i \mathbf{X} . Vi kan f.eks. la denne svare til sentrum av stjernen ved simpelthen å la $X_0 = U_0$. Med en slik utvidelse av \mathbf{X} , får vi at:

$$\mathbf{X} = \begin{bmatrix} 1 & 0 & 0 & \cdots & 0 \\ a_1 & b_1 & 0 & \cdots & 0 \\ a_2 & 0 & b_2 & \cdots & 0 \\ \vdots & \vdots & \vdots & \cdots & \vdots \\ a_n & 0 & 0 & \cdots & b_n \end{bmatrix} \mathbf{U}. \quad (46)$$

Denne matrisen er triangulær, og svarer til Cholesky-dekomposisjonen av korrelasjonsmatrisen for den utvidede versjonen av \mathbf{X} .

Korrelasjonsmatrisen for den utvidede versjonen av \mathbf{X} blir:


$$C = \begin{bmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_n \\ \rho_1 & 1 & \rho_1\rho_2 & \cdots & \rho_1\rho_n \\ \rho_2 & \rho_2\rho_1 & 1 & \cdots & \rho_2\rho_n \\ \vdots & \vdots & \vdots & \cdots & \vdots \\ \rho_n & \rho_n\rho_1 & \rho_n\rho_2 & \cdots & 1 \end{bmatrix} \quad (47)$$

Bemerk at avstandstolkningen videreføres i den utvidede modellen ved at $d(X_0, X_i) = \alpha_i$, $i = 1, \dots, n$. Dermed holder det også at $\text{Cov}(X_i, X_j) = \rho^{d(X_i, X_j)}$, $i, j = 0, 1, \dots, n$.

Tre-modeller

Den neste modellen generaliserer både Markov-modellen og stjerne-modellen. Denne modellen kalles en tre-modell, fordi avhengighetsstrukturen grafisk kan illustreres som et (rettet) tre. En tre-modell har følgende viktige egenskaper:

- Modellen inneholder en “rot”-variabel som ikke har noen forgjengere
- Enhver annen variabel har nøyaktig én direkte forgjenger



Influensdiagram for en tre-modell

Vi starter med å definere begrepet *forgjenger* i en tre-modell. En variabel X_i sies å være en *forgjenger* til en annen variabel X_j hvis tre-modellen inneholder en *rettet sti* fra X_i til X_j . Spesielt sies X_i å være en *direkte forgjenger* til X_j dersom det eksisterer en *rettet sti* av lengde 1 fra X_i til X_j .

Indeksmengden av forgjengere til variabelen X_i betegnes med $P(i)$, mens indekssmengden av direkte forgjengere betegnes med $p(i)$. En variabel X_i sies å være en *rot* dersom $P(i) = p(i) = \emptyset$.

I en tre-modell skal det altså eksistere nøyaktig en variabel X_i som er slik at $P(i) = p(i) = \emptyset$. Videre skal $|p(j)|$ være lik 1 for alle de øvrige variablene. Dersom $p(j) = \{i\}$, vil vi for enkelhets skyld droppe mengdesymbolene, og i stedet skrive $p(j) = i$.

Vi antar at vi har indeksert variablene i tre-modellen, $\mathbf{X} = (X_1, \dots, X_n)$, på en slik måte at modellens eneste rotvariabel er X_1 , og slik at dersom $p(i) = \{j\}$, så er $j < i$. Av dette følger det også at mengden $P(i)$ kun består av indekser som er lavere enn i .

Som tidligere lar vi $U = (U_1, \dots, U_n)$ være en vektor av n uavhengige standard normalfordelte stokastiske variable, og definer:

$$X_1 = U_1 \quad (48)$$

$$X_2 = a_2 X_{p(2)} + b_2 U_2$$

...

$$X_n = a_n X_{p(n)} + b_n U_n$$

der konstantene $a_i, b_i, i = 2, \dots, n$ velges slik at modellen får den ønskede korrelasjonsstruktur.

Variansen til X_i 'ene blir dermed:

$$\text{Var}(X_i) = a_i^2 \text{Var}(X_{p(i)}) + b_i^2 \text{Var}(U_i), \quad (49)$$

$$i = i, \dots, n.$$

Som sist krever vi at alle X_i 'ene skal ha varians lik 1. Dette betyr at:

$$a_i^2 + b_i^2 = 1, \quad i = i, \dots, n. \quad (50)$$

Kovariansen mellom X_i og $X_{p(i)}$ blir:

$$\begin{aligned}\text{Cov}(X_i, X_{p(i)}) &= \text{Cov}(a_i X_{p(i)} + b_i U_i, X_{p(i)}) \\ &= a_i \text{Cov}(X_{p(i)}, X_{p(i)}) \\ &= a_i \text{Var}(X_{p(i)}) \\ &= a_i\end{aligned}\tag{51}$$

for alle $i > 1$.

Vi krever nå at kovariansen mellom en variabel og dens direkte forgjenger skal være:

$$\text{Cov}(X_i, X_{p(i)}) = \rho_i, \quad i = 1, \dots, n. \quad (52)$$

Av dette, samt av (50), følger det dermed at:

$$a_i = \rho_i, \quad i = 1, \dots, n, \quad (53)$$

$$b_i = (1 - \rho_i^2)^{1/2}, \quad i = 1, \dots, n. \quad (54)$$

Vi bemerker at også denne gang er a_i 'ene og b_i 'ene veldefinerte for alle mulige korrelasjonskoeffisienter.

Vi skal nå se på hvordan vi i tre-modellen kan beregne $\text{Cov}(X_j, X_i)$ for et vilkårlig variabelpar. For å få til dette, ser vi på to tilfeller:

- Tilfelle 1: $j \in P(i)$
- Tilfelle 2: $j \notin P(i)$

Tilfelle 1. $j \in P(i)$. La indeksmengden til den rettede stien fra X_j til X_i være $\{i_0, \dots, i_s\}$, der $i_0 = j$ og $i_s = i$. Vi har da ved (48) at:

$$\begin{aligned} \text{Cov}(X_j, X_i) &= \text{Cov}(X_j, a_i X_{p(i)} + b_i U_i) \\ &= \text{Cov}(X_j, a_i X_{i_{s-1}} + b_i U_i) \\ &= a_i \text{Cov}(X_j, X_{i_{s-1}}) \end{aligned} \quad (55)$$

Gjentagelse av dette argumentet samt antagelsen om at alle X_i 'ene har varians lik 1, gir til slutt at:

$$\text{Cov}(X_j, X_i) = a_{i_1} a_{i_2} \cdots a_{i_s}. \quad (56)$$

Tilfelle 2. $j \notin P(i)$. Vi velger i dette tilfellet k som den høyeste index i $P(j) \cap P(i)$. Pr. definisjon vil det da finnes en rettet sti fra X_k til X_j og en rettet sti fra X_k til X_i . Vi antar at indeksmengdene for disse to stiene er henholdsvis $\{j_0, \dots, j_s\}$ og $\{i_0, \dots, i_t\}$, der $j_0 = i_0 = k$, og der $j_s = j$ og $i_t = i$. Ved et tilsvarende argument som over kan det da vises at:

$$\text{Cov}(X_j, X_i) = a_{j_1} a_{j_2} \cdots a_{j_s} a_{i_1} a_{i_2} \cdots a_{i_t}. \quad (57)$$

På samme måte som tidligere kan også denne modellen gis en avstandstolkning. For å se dette, antar vi igjen at $0 < \rho_i \leq 1$, $i = 1, \dots, n$, lar så ρ være et passende tall slik at $0 < \rho < 1$, og innfører så:

$$\alpha_i = \frac{\ln(\rho_i)}{\ln(\rho)}, \quad i = 1, \dots, n. \quad (58)$$

eller ekvivalent:

$$\rho_i = \rho^{\alpha_i}, \quad i = 1, \dots, n. \quad (59)$$

Størrelsen α_i fortolkes som avstanden fra X_i til $X_{p(i)}$. Avstanden mellom to variable blir summen av deres respektive avstander inn den av variablenes felles forgjenger som har høyest index.

Med dette avstandsmålet får vi igjen at:

$$\text{Cov}(X_i, X_j) = \rho^{d(X_i, X_j)}, \quad i, j = 1, \dots, n. \quad (60)$$