

Παράδειγμα

Sampling distribution: $y|\mathcal{G} \sim N(\cdot|\mathcal{G}, \sigma^2)$ με σ^2 γνωστό και διακριτό prior

$$\mathcal{G} \sim \begin{pmatrix} 1 & 2 & \dots & k \\ \pi_1 & \pi_2 & \dots & \pi_k \end{pmatrix} \text{ όπου } \pi_i = \pi(\mathcal{G}=i)$$

1. Να βρεθεί το marginal probability density του y (the prior predictive)
2. Να περιγραφεί το sampling scheme από την prior predictive.
3. Να βρεθεί η posterior για $k=2$, $\pi_1 = \pi_2 = 0.5$, $\sigma = 2$ και παρατήρηση $y=1$.

1. Το prior predictive είναι

$$\pi(y) = \sum_{\mathcal{G} \in \Theta} \pi(y, \mathcal{G}) = \sum_{i=1}^k \pi(\mathcal{G}=i) \pi(y|\mathcal{G}=i) = \sum_{i=1}^k \pi_i N(y|i, \sigma^2)$$

2. Το sampling scheme για $y \sim \pi(\cdot)$ είναι

$$\text{step 1: } \text{sample } u \sim U(\cdot|0,1)$$

$$\text{step 2: } \text{find } l \text{ such that } \pi_1 + \dots + \pi_{l-1} < u \leq \pi_1 + \dots + \pi_l \Rightarrow l \sim \begin{pmatrix} 1 & 2 & \dots & k \\ \pi_1 & \pi_2 & \dots & \pi_k \end{pmatrix}$$

$$\text{step 3: } \text{sample } \xi \sim N(\cdot|0,1) \Rightarrow y = l + \sigma\xi \sim N(\cdot|l, \sigma^2)$$

3. Η posterior του \mathcal{G} είναι

$$\pi(\mathcal{G}=i|y) = \frac{\pi(\mathcal{G}=i) \pi(y|\mathcal{G}=i)}{\pi(y)} = \frac{\pi_i N(y|i, \sigma^2)}{\sum_{i=1}^k \pi_i N(y|i, \sigma^2)}, \quad i=1,2$$

Για $k=2$, $\pi_1 = \pi_2 = 0.5$, $\sigma = 2$ και $y=1$, έχουμε

$$\pi(\mathcal{G}=1|y=1) = \frac{0.5N(1|1, 2^2)}{0.5N(1|1, 2^2) + 0.5N(1|2, 2^2)} = 0.53, \quad \pi(\mathcal{G}=2|y=1) = 0.47.$$

Sampling from mixture distributions

Μια mixture πυκνότητα είναι μια πυκνότητα που είναι κυρτός γραμμικός συνδυασμός από άλλες πυκνότητες.

- Το **discrete Gaussian mixture** είναι της μορφής

$$\pi^*(y) = p(y|\mu, \tau, \pi(\cdot)) = \sum_{i=1}^k \pi_i N(y|\mu_i, \tau_i^{-1}), \quad k \leq \infty.$$

Όπου $\mu = (\mu_1, \dots, \mu_k)$ οι μέσοι, $\tau = (\tau_1, \dots, \tau_k)$ τα **precisions** και

$$i \sim \pi(\cdot) = \begin{pmatrix} 1 & 2 & \dots & k \\ \pi_1 & \pi_2 & \dots & \pi_k \end{pmatrix} \text{ τα } \mathbf{mixing proportions} \text{ (the mixing measure is } \pi(\cdot) \text{)}$$

και $\sum_{i=1}^k \pi_i = 1$.

- Εάν τα mixing proportions δίνονται από κάποια πυκνότητα $\pi(\cdot)$

$$\pi^*(y) = p(y|\mu, \tau, \pi(\cdot)) = \int_{\Theta} \pi(\vartheta) N(y|\mu(\vartheta), \tau(\vartheta)^{-1}) d\vartheta$$

- Οι prior και posterior predictive distributions είναι mixtures της οικογένειας $\pi(Data|\vartheta)$ με την prior $\pi(\vartheta)$ και την posterior $\pi(\vartheta|Data)$ αντιστοίχως.

Το sampling scheme για mixtures είναι:

$\begin{array}{l} \text{first sample } \vartheta \sim \pi(\cdot) \\ \text{then sample } y \vartheta \sim \pi(\cdot \vartheta) \end{array} \quad \begin{array}{l} \text{marginally} \\ \Rightarrow \end{array} \quad y \sim \pi^*(\cdot) = \int_{\Theta} \pi(\vartheta) \pi(\cdot \vartheta) d\vartheta$

Έτσι για να προσομοιώσουμε iid δείγμα $y_i \stackrel{iid}{\sim} \pi^*(\cdot), 1 \leq i \leq n$ θα πρέπει πρώτα να προσομοιώσουμε διάνυσμα $(\vartheta_1, \dots, \vartheta_n)$ με $\vartheta_i \stackrel{iid}{\sim} \pi(\cdot), 1 \leq i \leq n$ και μετά διάνυσμα (y_1, \dots, y_n) με $y_i|\vartheta_i \stackrel{iid}{\sim} \pi(\cdot|\vartheta_i), 1 \leq i \leq n$ τότε θα έχουμε ότι

$$y_i \stackrel{iid}{\sim} \int_{\Theta} \pi(\vartheta) \pi(\cdot|\vartheta) d\vartheta, 1 \leq i \leq n$$

Έστω ότι οι πραγματοποιήσεις της τυχαίας μεταβλητής \tilde{Y} είναι τα y στα αριστερά του sampling scheme και οι πραγματοποιήσεις της τυχαίας μεταβλητής Y^* είναι τα y στα δεξιά του sampling scheme θα δείξουμε ότι $\tilde{Y} \stackrel{d}{=} Y^*$

Η συνάρτηση κατανομής του \tilde{Y} είναι $F_{\tilde{Y}}(y) = P\{\tilde{Y} \leq y\}$, conditioning στο ϑ έχουμε

$$F_{\tilde{Y}}(y) = \int_{\Theta} P\{\tilde{Y} \leq y | \vartheta\} \pi(\vartheta) d\vartheta = \int_{\Theta} \left(\int_{-\infty}^y \pi(u | \vartheta) du \right) \pi(\vartheta) d\vartheta$$

$$= \int_{-\infty}^y \left(\int_{\Theta} \pi(\vartheta) \pi(u | \vartheta) d\vartheta \right) du = \int_{-\infty}^y \pi^*(u) du = P\{Y^* \leq y\} = F_{Y^*}(y)$$

δηλαδή έχουμε $F_{\tilde{Y}}(y) = F_{Y^*}(y) \Leftrightarrow \tilde{Y} \stackrel{d}{=} Y^*$.

Παράδειγμα

Έστω ότι $n = 70$ με διωνυμική παρατήρηση $x = 34$. Εάν οι πεποιθήσεις των ειδικών είναι $\mu = 0.4$ και $\sigma^2 = 0.02$ και επειδή οι παράμετροι της κατανομής $\vartheta \sim Be(\cdot | p, q)$ σαν συνάρτηση της μέσης τιμής και της διασποράς είναι

$$E(\vartheta) = \frac{p}{p+q} = \mu$$

$$Var(\vartheta) = \frac{pq}{(p+q)^2(p+q+1)} = \sigma^2$$

$$\Leftrightarrow \begin{cases} p = \frac{(1-\mu)\mu^2}{\sigma^2} - \mu \\ q = \frac{\mu(1-\mu)^2}{\sigma^2} - (1-\mu) \end{cases},$$

θα έχουμε $p = 4.4$ και $q = 6.6$.

Εάν θέλουμε να κάνουμε δειγματοληψία από την αργiori κατανομή πρόβλεψης (prior predictive) $\pi(y)$ του διωνυμικού μοντέλου $x | \vartheta = \sum_{i=1}^n y_i | \vartheta \sim Bin(\cdot | n, \vartheta)$, θα έχουμε:

for (i in $1:SS$) { $\vartheta_i \leftarrow beta(4.4, 6.6)$; $y_i \leftarrow binomial(70, \vartheta_i)$ }

όπου SS το μέγεθος του δείγματος (sample size). Δηλαδή $\{y_1, \dots, y_{SS}\}$ είναι ένα δείγμα μεγέθους SS από την κατανομή beta – binomial με παραμέτρους $(70, 4.4, 6.6)$

- Η κατανομή beta-binomial δίνεται από το mixture

$$\pi(y) = BB(y|n, p, q) = \int_0^1 Be(\vartheta|p, q) Bin(x|n, \vartheta) d\vartheta \propto \binom{n}{x} \Gamma(p+x) \Gamma(q+n-x),$$

με σταθερά κανονικοποίησης $c = \Gamma(p+q) \{ \Gamma(p) \Gamma(q) \Gamma(p+q+n) \}^{-1}$ και χώρο

καταστάσεων το $X(\Omega) = \{0, 1, \dots, n\}$.

Εάν θέλουμε να κάνουμε δειγματοληψία από την a posteriori κατανομή πρόβλεψης (posterior predictive) $[\tilde{y}|x]$ για μια νέα παρατήρηση \tilde{y} (μια νέα δοκιμή Bernoulli) του διωνυμικού μοντέλου θα έχουμε:

$$\pi(\tilde{y}|x) = \int_{\Theta} \pi(\tilde{y}, \vartheta|x) d\vartheta = \int_{\Theta} \pi(\vartheta|x) \pi(\tilde{y}|\vartheta) d\vartheta = \int_0^1 Be(\vartheta|p+x, q-x+n) Bin(\tilde{y}|1, \vartheta) d\vartheta$$

με αποτέλεσμα

$$\begin{aligned} \pi(\tilde{y}|x) &= BB(\tilde{y}|1, p+x, q+n-x) = \binom{1}{\tilde{y}} \frac{B((p+x)+\tilde{y}, (q+n-x)-\tilde{y}+1)}{B(p+x, q+n-x)} \\ &= \left\{ \frac{\Gamma(p+x+\tilde{y}) \Gamma(q+n-x-\tilde{y}+1)}{\Gamma(p+q+n+1)} \right\} \left\{ \frac{\Gamma(p+q+n)}{\Gamma(p+x) \Gamma(q+n-x)} \right\}, \quad \tilde{y} \in \{0, 1\} \end{aligned}$$

και η posterior predictive είναι η δίτιμη τυχαία μεταβλητή

$$\tilde{y}|x \sim \begin{pmatrix} 0 & 1 \\ \frac{q+n-x}{p+q+n} & \frac{p+x}{p+q+n} \end{pmatrix},$$

επειδή

$$\begin{aligned} \pi(\tilde{y}=0|x) &= \left\{ \frac{\Gamma(p+x) \Gamma(q+n-x+1)}{\Gamma(p+q+n+1)} \right\} \left\{ \frac{\Gamma(p+q+n)}{\Gamma(p+x) \Gamma(q+n-x)} \right\} \\ &= \left\{ \frac{(q+n-x) \Gamma(q+n-x)}{(p+q+n) \Gamma(p+q+n)} \right\} \left\{ \frac{\Gamma(p+q+n)}{\Gamma(q+n-x)} \right\} = \frac{q+n-x}{p+q+n} \end{aligned}$$

$$\pi(\tilde{y} = 1|x) = 1 - \pi(\tilde{y} = 0|x) = \frac{p+x}{p+q+n}$$

for $i = 1$ to SS

$$[\mathcal{G}_i | x = 34] \leftarrow \text{beta}(4.4 + 34, 6.6 + 70 - 34)$$

$$[\tilde{y}_i | \mathcal{G}_i] \leftarrow \text{binomial}(1, \mathcal{G}_i)$$

next i

όπου SS το μέγεθος του δείγματος (sample size). Δηλαδή $\{y_1, \dots, y_{SS}\}$ είναι ένα δείγμα μεγέθους SS από την κατανομή beta – binomial με παραμέτρους $(70, 4.4, 6.6)$

Έστω ότι έχουμε παράγει δείγμα $\{y_1, \dots, y_{SS}\}$ μήκους SS από την κατανομή $[\tilde{y} | x = 34]$ τότε εάν κ είναι ο αριθμός των 0 και $SS - \kappa$ ο αριθμός των 1 θα πρέπει

$$\lim_{SS \rightarrow \infty} \frac{\kappa}{S} = \frac{q+n-x}{p+q+n} = \frac{42.6}{81}$$

Μαρκοβιανές διαδικασίες σε διακριτό χρόνο και συνεχή ή διακριτό χώρο καταστάσεων

Ο χώρος καταστάσεων (state space) $S = \bigcup_{n \in \mathbb{N}_0} X_n(\Omega)$, της διαδικασίας $\{X_n\}_{n \in \mathbb{N}_0}$, είναι ένα συνεχές σύνολο Borel του \mathbb{R}^d είτε κάποιο υποσύνολο του \mathbb{Z}^d και η ιδιότητα Markov δίνεται αθροιστικά

$$P\{X_{t+k} \leq y | X_t = x, X_{t-1} = x_{t-1}, \dots, X_0 = x_0\} = P\{X_{t+k} \leq y | X_t = x\}$$

$$= F_{X_{t+k}|X_t}(y|x) = P(t, x, t+k, (-\infty, y]), \quad k \geq 1$$

Δηλαδή η k -τάξης “τάση” μετάβασης από το $x \in S$ κατά την χρονική στιγμή t στο σύνολο $(-\infty, y]$ είναι $P(t, x, t+k, (-\infty, y])$. Εάν ισχύει ότι

$$P(t, x, t+k, (-\infty, y]) = P((t+k)-t, x, (-\infty, y]) = P(k, x, (-\infty, y])$$

λέμε ότι η διαδικασία είναι χρονικά ομογενείς (έχει στάσιμη πιθανότητα μετάβασης) γιατί η πιθανότητα μετάβασης δεν εξαρτάται από τον χρόνο t που γίνεται η μετάβαση, αλλά μόνο από το μήκος του χρονικού διαστήματος k . Στα παρακάτω απλοποιούμε τον συμβολισμό για $k=1$ με $P(y|x) = P(x, y) = P(1, x, (-\infty, y])$ και συμβολίζουμε

$$P(B|x) = P(x, B) = P(1, x, B), \quad \forall B \in \mathcal{B}(S)$$

Η πυκνότητα μετάβασης 1^{ης} τάξης ή απλά πυκνότητα μετάβασης $p(y|x) = p(x, y)$ (transition density) από το x στο y είναι

$$p(y|x)dy = P\{y < X_{t+1} \leq y+dy | X_t = x\} = P\{X_{t+1} \leq y+dy | X_t = x\} - P\{X_{t+1} \leq y | X_t = x\}$$

$$= P(x, y+dy) - P(x, y) = \left(\frac{\partial}{\partial y} P(x, y) \right) dy$$

δηλαδή έχουμε $p(y|x) = \frac{\partial}{\partial y} P(x, y) = f_{X_{t+1}|X_t}(y|x)$ για κάθε $t \in \mathbb{N}_0$.

Άλλοι συμβολισμοί είναι

$$p(y|x)dy = p(x, y)dy = p(x, dy) = p(x, (y, y+dy])$$

Για Markovian αλυσίδα διακριτού χρόνου θα χρησιμοποιούμε για την μετάβαση πρώτης τάξης τον συμβολισμό $p(y|x)$

Συμβολίζουμε την marginal της στοχαστικής διαδικασίας για χρόνο t με $\pi_t(\cdot)$

$$\pi_t(x) \equiv f_{X_t}(x) = \frac{1}{dx} P\{x < X_t \leq x+dx\}.$$

1. Ισχύει ότι

$$\pi_{t+1}(y) = \int_S p(y|x)\pi_t(x)dx.$$

Πράγματι

$$\begin{aligned}\pi_{t+1}(y) &= f_{X_{t+1}}(y) = \int_S f_{X_t, X_{t+1}}(x, y)dx = \int_S f_{X_t}(x) f_{X_{t+1}|X_t}(y|x)dx \\ &= \int_S p(y|x)\pi_t(x)dx\end{aligned}$$

2. Για το induced measure $\Pi_{t+1}(\cdot)$ της τυχαίας μεταβλητής X_{t+1} ισχύει

$$\begin{aligned}\Pi_{t+1}(B) &= P\{X_{t+1} \in B\} = \int_{y \in B} \pi_{t+1}(y)dy = \int_{y \in B} \int_{x \in S} p(y|x)\pi_t(x)dx dy \\ &= \int_{x \in S} \pi_t(x) \left\{ \int_{y \in B} p(y|x)dy \right\} dx = \int_{x \in S} \pi_t(x) p(B|x)dx\end{aligned}$$

Δηλαδή

$$\Pi_{t+1}(B) = \int_S p(B|x)\Pi_t(dx)$$

Εάν υποθέσουμε ότι υπάρχει μέτρο $\Pi(\cdot)$ (η στάσιμη κατανομή) τέτοιο ώστε

$\lim_{t \rightarrow \infty} \Pi_t(B) = \Pi(B)$ αυτό θα πρέπει να ικανοποιεί την εξίσωση

$$\Pi(B) = \int_S p(B|x)\Pi(dx)$$

πού είναι η εξίσωση του αναλλοίωτου μέτρου που ορίζεται από τη αναδρομική σχέση

$\Pi_{t+1}(B) = \int_S p(B|x)\Pi_t(dx)$. Η αναλλοίωτη πυκνότητα $\pi(\cdot)$ (invariant density –

stationary distribution) τότε θα ικανοποιεί την εξίσωση

$$\pi(y) = \int_S p(y|x)\pi(x)dx$$

Πράγματι θέτοντας $B = (y, y + dy]$ στην εξίσωση $\Pi(B) = \int_S p(B|x)\Pi(dx)$ παίρνουμε

$$\pi(y)dy = \Pi((y, y+dy]) = \int_{x \in S} p((y, y+dy]|x)\Pi((x, x+dx]) = \int_{x \in S} \{p(y|x)dy\}\{\pi(x)dx\}.$$

Το σχήμα δειγματοληψίας

Για την Markovian διαδικασία $X_n \sim MC(p(\cdot|\cdot), \pi_0(\cdot))$ για $n \in \mathbb{N}_0$ και $S \in \mathcal{B}(\mathbb{R})$ όπου $p(\cdot|\cdot)$ η στάσιμη πυκνότητα μετάβασης και $\pi_0(\cdot)$ η αρχική πυκνότητα, επειδή $\pi_{n+1}(y) = \int_S p(y|x)\pi_n(x)dx$ θα χρησιμοποιήσουμε το σχήμα δειγματοληψίας για mixtures

$$\begin{array}{l} x_0 \sim \pi_0(\cdot) \\ x_i | x_{i-1} \sim p(\cdot|x_{i-1}), i \geq 1 \end{array} \quad \begin{array}{l} \text{then marginally} \\ \Rightarrow \end{array} \quad x_i \sim \pi_i(\cdot) = \int_S p(\cdot|x)\pi_{i-1}(x)dx, i \geq 1.$$

Σχηματικά

$$\begin{array}{l} x_0 \sim \pi_0(\cdot) \\ x_1 | x_0 \sim p(\cdot|x_0) \end{array} \quad \begin{array}{l} \text{marginally} \\ \Rightarrow \end{array} \quad \begin{array}{l} x_1 \sim \pi_1(\cdot) \\ x_2 | x_1 \sim p(\cdot|x_1) \end{array} \quad \begin{array}{l} \text{marginally} \\ \Rightarrow \end{array} \quad \begin{array}{l} x_2 \sim \pi_2(\cdot) \\ x_3 | x_2 \sim p(\cdot|x_2) \end{array} \quad \begin{array}{l} \text{marginally} \\ \Rightarrow \end{array} \quad \dots$$

με αποτέλεσμα (x_0, x_1, x_2, \dots) να είναι μια ω -τροχιά της διαδικασίας $X_n \sim MC(p(\cdot|\cdot), \pi_0(\cdot))$.

Εάν ο χώρος καταστάσεων είναι διακριτός, δηλαδή $X_n \sim MC(\mathbb{P}, \pi_0)$ για $n \in \mathbb{N}_0$ και $S \subseteq \mathbb{Z}$ όπου $\mathbb{P} = [p(j|i)]_{j,i \in S}$ με $\sum_{j \in S} p(j|i) = 1$ ο πίνακας μετάβασης 1^{ης} τάξης (η στάσιμη πιθανότητα μετάβασης) και $\pi_0 = [P\{X_0 = j\}]_{j \in S}$ η αρχική μάζα πιθανότητας, επειδή

$$\pi_n(j) = P\{X_n = j\} = (\mathbb{P}\pi_{n-1})_j = \sum_{i \in S} p(j|i)\pi_{n-1}(i)$$

θα έχουμε

$$\begin{array}{l} x_0 \sim \pi_0(\cdot) \\ x_i | x_{i-1} \sim [p(\cdot|x_{i-1})] = \mathbb{P}_{x_{i-1}}, i \geq 1 \end{array} \quad \begin{array}{l} \text{marginally} \\ \Rightarrow \end{array} \quad x_i \sim \pi_i(\cdot) = \sum_{s \in S} p(\cdot|s)\pi_{i-1}(s), i \geq 1$$

όπου $\mathbb{P}_{x_{i-1}}$ η $x_{i-1} \in S$ στήλη του \mathbb{P} .

Παράδειγμα: Στάσιμη κατανομή και δειγματοληψία από $AR(1)$

Έστω στοχαστική διαδικασία $\{X_n\}_{n \in \mathbb{N}_0}$ που ικανοποιεί την αναδρομική σχέση

$$X_{n+1} = \beta X_n + \varepsilon_{n+1} \text{ με } \varepsilon_n \stackrel{iid}{\sim} N(0, \sigma^2), n \in \mathbb{N}_0 \text{ και } S = \mathbb{R}. \text{ Τότε}$$

$$[X_{n+1} | X_n = x] \stackrel{d}{=} \beta x + \varepsilon_{n+1} \sim N(\beta x, \sigma^2) \Rightarrow p(y | x) = N(y | \beta x, \sigma^2)$$

Έστω αρχική πυκνότητα $\pi_0(y) = N(y | 0, 1)$ τότε

$$\pi_1(y) = \int_{\mathbb{R}} N(y | \beta x, \sigma^2) N(x | 0, 1) dx \neq N(y | 0, \sigma^2(1 + \beta^2))$$

$$\pi_2(y) = \int_{\mathbb{R}} N(y | \beta x, \sigma^2) N(x | 0, \sigma^2(1 + \beta^2)) dx \neq N(y | 0, \sigma^2(1 + \beta^2 + \beta^4))$$

δηλαδή

$$\pi_n(y) = \int_{\mathbb{R}} N(y | \beta x, \sigma^2) N(x | 0, \sigma^2 \sum_{j=0}^{n-1} \beta^{2j}) dx \neq N(x | 0, \sigma^2 \sum_{j=0}^n \beta^{2j})$$

και γίνεται εμφανές από το παραπάνω “pattern” ότι εάν υπάρχει stationary distribution, θα υπάρχει για $|\beta| < 1$ και θα είναι η κατανομή:

$$\pi(x) = N\left(x | 0, \frac{\sigma^2}{1 - \beta^2}\right), |\beta| < 1.$$

Δεν είναι δύσκολο να δείξουμε ότι για $|\beta| < 1$ ισχύει:

$$\int_{\mathbb{R}} N\left(x | 0, \frac{\sigma^2}{1 - \beta^2}\right) N(y | \beta x, \sigma^2) dx = N\left(y | 0, \frac{\sigma^2}{1 - \beta^2}\right)$$

Το ergodic theorem μας λει ότι κάτω από συγκεκριμένες συνθήκες (irreducibility και ergodicity) το $\pi(\cdot)$ είναι το μοναδικό stationary distribution και έχουμε σύγκλιση σε αυτό για οποιαδήποτε αρχική πυκνότητα $\pi_0(\cdot)$ με support $S = \mathbb{R}$.

Εφαρμόζοντας το εργοδικό θεώρημα μπορούμε να υπολογίσουμε ολοκληρώματα της μορφής $\int_{\mathbb{R}} g(x) \Pi(dx)$ πιο συγκεκριμένα, εάν $X \sim \Pi(\cdot)$

$$\mathbb{E}[g(X)] = \int_{\mathbb{R}} g(x)\pi(x)dx = \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=0}^{n-1} g(x_i) \approx \frac{1}{N} \sum_{i=b+1}^{b+N} g(x_i),$$

όπου b το burn-in period και $\{x_0, x_1, \dots, x_b, x_{b+1}, \dots, x_{b+N}\}$ τροχιά μεγάλου μήκους από την στοχαστική διαδικασία $\{X_n\}_{n \in \mathbb{N}_0}$ με αυθαίρετη αρχική τιμή $x_0 \in S$.

Τα σημεία της τροχιάς της στοχαστικής διαδικασίας τα παίρνουμε εφαρμόζοντας δειγματοληψία από την κατανομή $p(x, \cdot)$. Για παράδειγμα για την $AR(1)$ θα έχουμε:

$$\begin{aligned} x_1 | x_0 &\sim p(\cdot | x_0) = \beta x_0 + \sigma N(\cdot | 0, 1) \\ x_2 | x_1 &\sim p(\cdot | x_1) = \beta x_1 + \sigma N(\cdot | 0, 1) \\ &\vdots \\ x_n | x_{n-1} &\sim p(\cdot | x_{n-1}) = \beta x_{n-1} + \sigma N(\cdot | 0, 1) \\ &\vdots \end{aligned}$$