

Bayesian state space model (BSSM)

Р. Махаммадиев, У. Джуманазаров, Ш. Маҳмудов,
С. Абдуғаниев

Ушбу мақоладаги қарашлар муаллифларнинг шахсий фикр ва мулоҳазалари бўлиб, Ўзбекистон Республикаси Марказий банкининг расмий позицияси билан мос келмаслиги мумкин. Ўзбекистон Республикаси Марказий банки мақола мазмунига жавобгарлик олмайди. Тақдим қилинган материалларни ҳар қандай услубда қайта ишлатиш фақатгина муаллифлар рухсати билан амалга оширилади.

Аннотация

Ушбу мақолада қисқа вақт қаторлари учун ишончлилик даражаси юқори бўлган параметрларни баҳолашда самарали ҳисобланган Bayesian state space model (BSSM) таҳлил қилинган. Жумладан, BSSM ишга тушириш, Variational Bayesian M-step (Maximisation), Variational Bayesian E-step (Expectation), логарифмик маргинал эҳтимоллик қуйи чегарасининг баҳосини ҳисоблаш, гиперпараметрларни янгилаш, логарифмик маргинал эҳтимолликнинг қуйи чегараси баҳоси қийматларини таққослаш босқичларида амалга оширилади. Мазкур мақола Ўзбекистон кўчмас мулк бозорида уй-жой нархларининг фундаментал қийматини баҳолаш аниқлигини оширишда моделлар қамровини кенгайтириш мақсадида тайёрланган.

Таянч сўзлар: ковариация матрицаси, маргинал эҳтимоллик, нисбий хатолик, приор тақсимот, постериор тақсимот, вақт қаторлари.

Bayesian state space model (BSSM)

Bayesian state space model (BSSM) қисқа вақт қаторлари учун юқори ишончилилик даражасига эга параметрларни баҳолашда state space model (SSM)¹га нисбатан самарали ҳисобланади. Хусусан, BSSM ноаниқликларни бошқариш ва параметрларни кузатилган маълумотларга мослаштириш имкониятларини тақдим этади. Қисқа вақт қаторларида маълумотларнинг динамик ўзгаришларини яхшироқ акс эттириш учун постериор тақсимотларни (posterior distribution)² тез янгилаш имкониятларини беради.

BSSM барча ноаниқ миқдорларни тасодифий ўзгарувчилар сифатида кўриб чиқади ва эҳтимоллик қонуниятларидан фойдаланади. Ушбу моделлар сигналларни филтрлаш ва башорат қилишда кенг қўлланилади. Моделдаги ноаниқликларни аниқлаш учун моделдаги барча параметрлар бўйича постериор тақсимотлар талаб қилинади. Жумладан, ушбу модел ўзаро боғлиқлик даражасини ифодаловчи кузатиш тенгламаси (observable or measurement equation) ҳамда динамик ҳолат ўзгарувчиларини ифодаловчи ўтиш тенгламасидан (transition equation) ташкил топган³:

$$\begin{aligned}y_t &= Cx_t + Du_t + v_t \\x_t &= Ax_{t-1} + Bu_t + w_t .\end{aligned}$$

Бу ерда,

y_t – кузатилиши мумкин бўлган эрксиз узгарувчилар вектори;

x_t – яширин ҳолат ўзгарувчилар вектори;

u_t – кузатилиши мумкин булган эркли ўзгарувчилар вектори;

A – $k \times k$ ўлчамли ҳолат динамик матрицаси;

C – $p \times k$ ўлчамли кузатиш матрицаси

B – $k \times d$ ўлчамли ҳолат кириш матрицаси;

D – $p \times d$ ўлчамли кузатиш кириш матрицаси;

$v_t \sim N(0, R)$ – тақсимотдан олинган кузатиш тенгламаси учун нисбий хатоликлар вектори;

¹ State space model (SSM) методологияси 2023 йил учун молиявий барқарорлик шарҳида келтирилган.

² Постериор тақсимот – маълумотлар кузатилгандан кейин параметрнинг янгиланган тақсимоти.

³ Beal, M. (2003). Variational Algorithms for Approximate Bayesian Inference. University of Cambridge.

$w_t \sim N(0, Q)$ – ҳолат тенгламаси учун нисбий хатоликлар вектори;
 A, B, C ва D матрицалар – номаълум коэффицентлар матрицалари;
 Q ва R – нисбий хатоликлар ковариация матрицалари.

Кузатиш майдонидаги силжишларни ҳолат кириш ва кириш кузатиш матрицаларининг параметрлари сифатида ўрганиш мумкин. Яширин ўзгарувчилар кузатилмаганлиги учун ҳолат тенгламаси учун нисбий хатоликлар ковариация матрицаси Q ни ҳолат динамик матрицаси A га киритиб юбориш мумкин. Натижада, яширин ҳолат шунга мос равишда ўзгаради. Маълумотлар кузатилганлиги сабабли кузатиш тенгламаси учун нисбий хатоликлар ковариация матрицаси R ни кузатиш матрицаси C га киритиб бўлмайди. Жумладан, диагонал деб қабул қилинган нисбий хатоликлар ковариацияси R , ρ аниқлик вектори орқали қуйидагича аниқланади:

$$R^{-1} = \text{diag}(\rho)$$

Бу ерда, R – нисбий хатоликлар ковариацияси, $\text{diag}(\rho)$ – диагоналидан бошқа барча элементларини нолга тенг бўлган матрица.

Конжугация (conjugate)⁴ учун аниқлик вектори ρ нинг ҳар бир ўлчами a ва b гиперпараметрлар билан тақсимланган Гамма тақсимот сифатида қабул қилинади. ρ нинг приор тақсимоти эса қуйидаги кўринишда бўлади:

$$p(\rho|a, b) = \prod_{s=1}^p \frac{b^a}{\Gamma(a)} \rho_s^{a-1} \exp\{-b\rho_s\} .$$

Параметрлар ва гиперпараметрлар қуйидаги кўринишдаги эҳтимолликлар билан боғланади:

$$\begin{aligned} p(a_{(j)}|\alpha) &= N(a_{(j)}|0, \text{diag}(\alpha)^{-1}) \\ p(b_{(j)}|\beta) &= N(b_{(j)}|0, \text{diag}(\beta)^{-1}) \\ & j = 1, 2, \dots, k \\ p(c_{(s)}|\rho_s, \gamma) &= N(c_{(s)}|0, \rho_s^{-1} \text{diag}(\gamma)^{-1}) \\ p(d_{(s)}|\rho_s, \delta) &= N(d_{(s)}|0, \rho_s^{-1} \text{diag}(\delta)^{-1}) \\ p(\rho_s|a, b) &= Ga(\rho_s|a, b) \end{aligned}$$

⁴ Конжугация – ҳисоб-китобларни энгиллаштириш учун олдинги ва кейинги тақсимотларни бир хил кўринишга келтириш.

$$s = 1, 2, \dots, p.$$

Бу ерда,

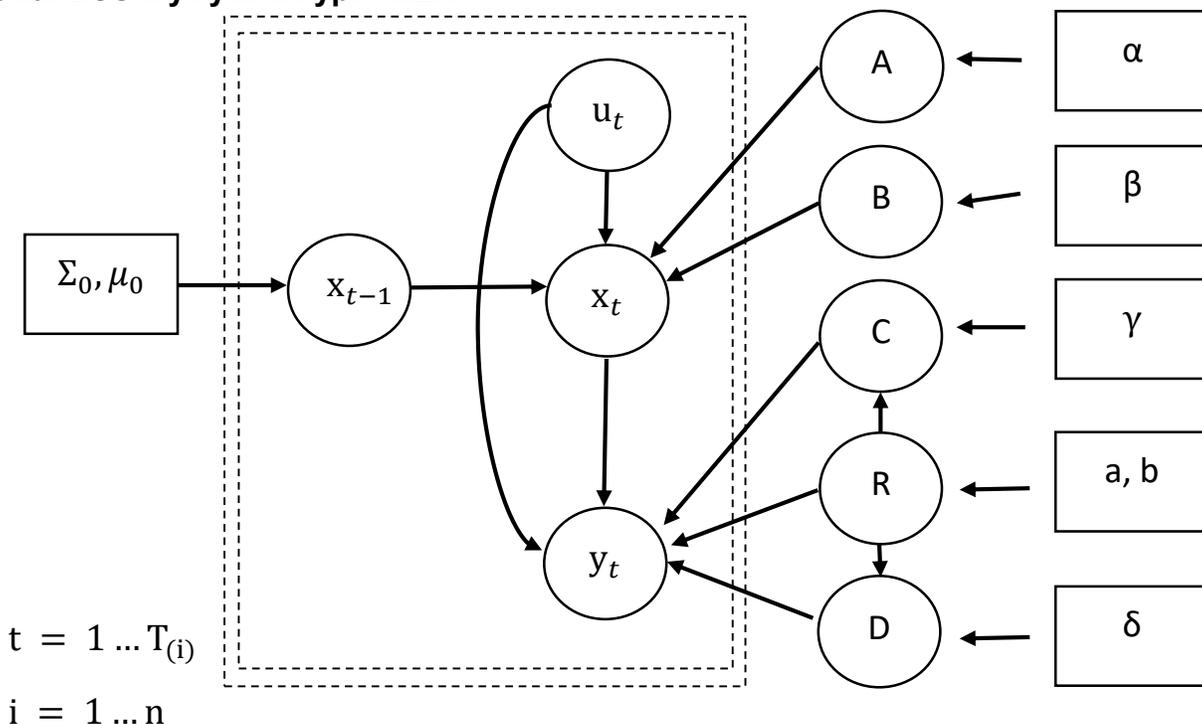
$a_{(j)}$ – A матрицанинг j устуни;

$b_{(j)}$ – B матрицанинг j устуни;

$c_{(s)}$ – C матрицанинг s устуни;

$d_{(s)}$ – D матрицанинг s устуни.

1-чизма. BSSM умумий кўриниши



Манба: Beal, M. (2003). Variational Algorithms for Approximate Bayesian Inference. University of Cambridge.

Шунингдек, A матрицанинг ҳар бир қатори бўйича ўртачаси нолга тенг бўлган дастлабки Гаусс тақсимоида аниқлик кўрсаткичи⁵ (precision) $diag(\alpha)$ га тенг. C матрицанинг ҳар бир қатори бўйича эса, ўртачаси нолга тенг бўлган дастлабки Гаусс тақсимоида аниқлик кўрсаткичи $diag(\rho_s \gamma)$ га тенг. $c_{(s)}$ аниқлик кўрсаткичининг шовқин чиқиш аниқлик кўрсаткичига боғлиқлиги ρ_s конжугация билан боғлиқ бўлади. Шунга ўхшаш устунларни киритиш билан боғлиқ B ва D матрицалар қаторига мос равишда яна иккита гиперпараметр вектори β ва δ киритилади. A ва B матрицаларнинг

⁵ Тақсимоиларда аниқлик кўрсаткичи дисперсиянинг тескарасига тенг, яъни ушбу аниқлик кўрсаткичи ҳамда дисперсияларнинг ўзаро кўпайтмаси бирга тенг.

қаторлардаги ковариациялари узгармайди. Бироқ, C ва D матрицалар қаторларидаги ковариациялар ρ_s нинг ҳисобига ўзгариши мумкин. Агар, A нинг j устуни нолга айланса $t - 1$ вақтидаги j устун t вақтидаги яширин узгарувчиларни топишда иштирок этмайди. Аммо, j яширин ўлчов ҳар бир вақт босқичида маълумотларда ковариация структурасини яратиш учун фойдаланилади.

BSSM олти босқичда амалга оширилади. Дастлабги босқич ишга тушириш босқичи ҳисобланиб, бу босқичда ёрдамчи яширин ҳолат ишга туширилади ҳамда параметрларнинг приор тақсимоти (prior distribution)⁶ киритилиб, логарифмик маргинал эҳтимоллик⁷ (marginal probability) Jensen тенгсизлиги (Jensen's inequality) ёрдамида баҳоланади. Иккинчи босқич Variational Bayesian M-step (Maximisation) босқичи ҳисобланади. Бу босқичда, параметрларнинг постериор тақсимотларининг оптимал шакли топилади ва табиий параметрлар вектори ҳисобланади. Бундан сўнг, Variational Bayesian E-step (Expectation) босқичида яширин ҳолат ўзгарувчилар векторининг тақсимотлари топилади. Тўртинчи босқичда логарифмик маргинал эҳтимолликнинг қуйи чегараси баҳоси яъни F нинг қиймати ҳисобланади. Бешинчи босқич гиперпараметрларни янгилаш босқичи ҳисобланиб, бунда логарифмик маргинал эҳтимолликнинг қуйи чегараси баҳосини ошириш учун гиперпараметрлар янгиланади. Якуний босқичда, логарифмик маргинал эҳтимолликнинг қуйи чегараси баҳоси олдинги қийматига нисбатан солиштирилиб, қуйи чегара баҳоси ортган ҳолатда Variational Bayesian M-step босқичи қайтадан амалга оширилади. Ушбу қуйи чегаранинг баҳоси олдинги қийматига нисбатан ортмай қолгунга қадар ҳисоблаш босқичлари давом эттирилади.

Ишга тушириш босқичи

Дастлаб $t = 0$ давр учун ёрдамчи яширин ҳолат x_0 ишга туширилади. Бунда, ёрдамчи яширин ҳолат x_0 Гаусс тақсимоти бўйича тақсимланиб, ёрдамчи яширин ҳолатнинг ўртача μ_0 ва ковариация Σ_0 қийматлари, шунингдек приор тақсимоти қуйидаги кўринишларда бўлади:

$$p(x_0 | \mu_0, \Sigma_0) = N(x_0 | \mu_0, \Sigma_0)$$

⁶ Приор тақсимот – параметрларнинг маълумотлари кузатилишидан олдинги тақсимоти.

⁷ Маргинал эҳтимоллик – бошқа ҳодисаларга боғлиқ бўлмаган бир ҳодисанинг содир бўлиш эҳтимоли.

$$\begin{aligned}\mu_0 &\sim N(\mu_0 | 0, b_{\mu_0} I) \\ \Sigma_0 &\sim \prod_{j=1}^k Ga(\Sigma_{0jj}^{-1} | a_{\Sigma_0}, b_{\Sigma_0})\end{aligned}$$

Бу ерда,

x_0 – ёрдамчи яширин ҳолат;

μ_0 – ёрдамчи яширин ҳолат ўртачаси;

Σ_0 – ёрдамчи яширин ҳолат ковариацияси.

Бунда, ҳолат динамик жараёни орқали x_1 нинг приори қуйидаги кўринишда бўлади:

$$\begin{aligned}p(x_1 | \mu_0, \Sigma_0, \theta) &= \int dx_0 p(x_0 | \mu_0, \Sigma_0) p(x_1 | x_0, \theta) \\ &= N(x_1 | A\mu_0 + Bu_1, A^T \Sigma_0 A + Q) .\end{aligned}$$

Соддалаштириш мақсадида параметрлар битта параметр векторига $\theta = (A, B, C, D, R)$ йиғилади. Шунингдек, A , B , C ва D матрицаларнинг гиперпараметрлари билан боғлиқлиги қуйидаги гиперприор тақсимот (hyperprior distribution) орқали берилади:

$$\begin{aligned}\alpha &\sim \prod_{j=1}^k Ga(\alpha_{(j)} | a_{(\alpha)}, b_{(\alpha)}) \\ \beta &\sim \prod_{c=1}^d Ga(\beta_{(c)} | a_{(\beta)}, b_{(\beta)}) \\ \gamma &\sim \prod_{j=1}^k Ga(\gamma_{(j)} | a_{(\gamma)}, b_{(\gamma)}) \\ \delta &\sim \prod_{c=1}^d Ga(\delta_{(c)} | a_{(\delta)}, b_{(\delta)})\end{aligned}$$

Маргинал эҳтимоллик қуйидаги кўринишда бўлади:

$$p(y_{1:T}) = \int dA dB dC dD d\rho dx_{0:T} p(A, B, C, D, \rho, x_{0:T}, y_{1:T})$$

Моделнинг параметрлари ўртасидаги баъзи бир шартли мустақиллик ҳисобига динамика ва чиқиш жараёнлари учун постериор тақсимотлар қандай постериор тақсимотларга ажралишини кўриш мумкин. Киришларни ҳисобга олган ҳолда параметрлар, яширин ўзгарувчилар ва кузатилган маълумотлар учун тўлиқ биргалиқдаги эҳтимоллик қуйидаги кўринишда бўлади:

$$\begin{aligned}p(A, B, C, D, \rho, x_{0:T}, y_{1:T} | u_{1:T}) &= \\ p(A | \alpha) p(B | \beta) p(\rho | a, b) p(C | \rho, \gamma) p(D | \rho, \delta) p(x_0 | \mu_0, \Sigma_0) \cdot\end{aligned}$$

$$\prod_{t=1}^T p(x_t | x_{t-1}, A, B, u_t) p(y_t | x_t, C, D, \rho, u_t)$$

Шундан кейин, киришларда $u_{1:T}$ боғлиқлик йўқотилади ва киришлар ёпиқ ҳолатда қолдирилади. Яширин ўзгарувчилар ва параметрларга боғлиқ $q(\theta, x)$ тақсимот киритилади. Jensen тенгсизлигини қўллаш орқали маргинал эҳтимолликнинг қуйи чегараси баҳоланади:

$$\ln p(y_{1:T}) = \ln \left(\int dA dB dC dD d\rho dx_{0:T} p(A, B, C, D, \rho, x_{0:T}, y_{1:T}) \right) \geq \int dA dB dC dD d\rho dx_{0:T} q(A, B, C, D, \rho, x_{0:T}) \ln \frac{p(A, B, C, D, \rho, x_{0:T}, y_{1:T})}{q(A, B, C, D, \rho, x_{0:T})} = F$$

Вариацион яқинлашишнинг кейинги босқичи параметрлар ва яширин ўзгарувчилар тақсимоти $q(\cdot)$ учун маълум бир тахминий шаклларни қабул қилиш ҳисобланади. Биринчи навбатда, яширин ўзгарувчилар ва параметрлар шартли мустақиллик асосида ажратилади:

$$q(A, B, C, D, \rho, x_{0:T}) = q_\theta(A, B, C, D, \rho) q_x(x_{0:T}) \\ q(A, B, C, D, \rho, x_{0:T}) = q_{AB}(A, B) q_{CD\rho}(C, D, \rho) q_x(x_{0:T}) .$$

Логарифмик маргинал эҳтимоллик қуйи чегарасининг баҳосини соддалаштириш учун шартли эҳтимолликнинг қуйидаги хоссаларидан фойдаланилади:

$$q_{AB}(A, B) = q_B(B) q_A(A|B) \\ q_{CD\rho}(C, D, \rho) = q_\rho(\rho) q_D(D|\rho) q_C(C|D, \rho)$$

Логарифмик маргинал эҳтимоллик қуйи чегарасининг баҳоси F юқоридаги хоссалардан фойдаланиб қуйидаги йиғиндига келтирилади:

$$F = \int dB q_B(B) \ln \frac{p(B|\beta)}{q_B(B)} + \int dB q_B(B) \int dA q_A(A|B) \ln \frac{p(A|\alpha)}{q_A(A|B)} + \\ \int d\rho q_\rho(\rho) \ln \frac{p(\rho|a, b)}{q_\rho(\rho)} + \int d\rho q_\rho(\rho) \int dD q_D(D|\rho) \ln \frac{p(D|\rho, \delta)}{q_D(D|\rho)} + \\ \int d\rho q_\rho(\rho) \int dD q_D(D|\rho) \int dC q_C(C|\rho, D) \ln \frac{p(C|\rho, \gamma)}{q_C(C|\rho, D)} - \\ \int dx_{0:T} q_x(x_{0:T}) \ln q_x(x_{0:T}) + \int dB q_B(B) \int dA q_A(A|B) \int d\rho q_\rho(\rho) \cdot$$

$$\int dD q_D(D|\rho) \int dC q_C(C|\rho, D) \int dx_{0:T} q_x(x_{0:T}) \ln p(x_{0:T}, y_{1:T} | A, B, C, D, \rho) =$$

$$F(q_x(x_{0:T}), q_B(B), q_A(A|B), q_\rho(\rho), q_D(D|\rho), q_C(C|\rho, D))$$

$$H(q_x(x_{0:T})) = - \int dx_{0:T} q_x(x_{0:T}) \ln q_x(x_{0:T})$$

Логарифмик маргинал эҳтимоллик қуйи чегарасининг баҳоси гиперпараметрларга боғлиқ кўринишда бўлади. Ушбу тахминий постериор тақсимотларнинг оптимал шакллари параметрлар ва яширин ўзгарувчилар кетма-кетликлари бўйича ҳар бир тақсимотга нисбатан F дан олинган функционал хусусий ҳосилаларни нолга тенглаш ёрдамида аниқлаш мумкин.

Variational Bayesian M-step (Maximisation), VBM

Бу босқичда, Bayesian теоремасини қўллаш орқали параметрлар бўйича вариацион постериор тақсимотлар топилади ва булардан кутилган табиий параметрлар вектори ҳисобланади. Постериор тақсимот қуйидаги кўринишда факторларга ажратилади:

$$q_\theta(A, B, C, D, \rho) = \prod_{j=1}^k q(b_{(j)}) q(a_{(j)} | b_{(j)}) \prod_{s=1}^p q(\rho_s) \cdot$$

$$q(d_{(s)} | \rho_s) q(c_{(s)} | \rho_s, d_{(s)})$$

Бу ерда,

$b_{(j)}$ – B матрицанинг j устуни;

$a_{(j)}$ – A матрицанинг j устуни;

$d_{(s)}$ – D матрицанинг s устуни;

$c_{(s)}$ – C матрицанинг s устуни.

Ҳисоб-китобларда зарур бўладиган кириш ва чиқиш ўзгарувчилар векторларининг баъзи статистик маълумотлари қуйидагича киритилади:

$$\ddot{U} = \sum_{t=1}^T u_t u_t^T$$

$$U_y = \sum_{t=1}^T u_t y_t^T$$

$$\dot{Y} = \sum_{t=1}^T y_t y_t^T$$

Параметрларнинг постериор тақсимотини ва табиий параметрлар векторини ҳисоблашда қўлланиладиган етарли статистик маълумотлар қуйидаги тенгламалар ёрдамида топилади:

$$\begin{aligned}
W_A &= \sum_{t=1}^T \langle x_{t-1} x_{t-1}^T \rangle = \sum_{t=1}^T Y_{t-1,t-1} + \omega_{t-1} \omega_{t-1}^T \\
G_A &= \sum_{t=1}^T \langle x_{t-1} \rangle u_t^T = \sum_{t=1}^T \omega_{t-1} u_t^T \\
\tilde{M} &= \sum_{t=1}^T u_t \langle x_t^T \rangle = \sum_{t=1}^T u_t \omega_t^T \\
S_A &= \sum_{t=1}^T \langle x_{t-1} x_t^T \rangle = \sum_{t=1}^T Y_{t-1,t} + \omega_{t-1} \omega_t^T \\
W_C &= \sum_{t=1}^T \langle x_t x_t^T \rangle = \sum_{t=1}^T Y_{t,t} + \omega_t \omega_t^T \\
G_C &= \sum_{t=1}^T \langle x_t \rangle u_t^T = \sum_{t=1}^T \omega_t u_t^T \\
S_C &= \sum_{t=1}^T \langle x_t \rangle y_t^T = \sum_{t=1}^T \omega_t y_t^T .
\end{aligned}$$

A ва B учун постериор тақсимотлар қуйидаги тенгламалар билан аниқланади:

$$\begin{aligned}
q_B(B) &= \prod_{j=1}^k N(b_{(j)} | \Sigma_B \bar{b}_{(j)}, \Sigma_B) \\
q_A(A|B) &= \prod_{j=1}^k N(a_{(j)} | \Sigma_A [S_{A(j)} - G_A b_{(j)}], \Sigma_A) \\
\Sigma_A^{-1} &= \text{diag}(\alpha) + W_A \\
\Sigma_B^{-1} &= \text{diag}(\beta) + \ddot{U} - G_A^T \Sigma_A G_A \\
\bar{B} &= \hat{M}^T - S_A^T \Sigma_A G_A \\
q_A(A) &= \prod_{j=1}^k N(a_{(j)} | \Sigma_A [S_{A(j)} - G_A \Sigma_B \bar{b}_{(j)}], \tilde{\Sigma}_A) \\
\tilde{\Sigma}_A &= \Sigma_A + \Sigma_A G_A \Sigma_B G_A^T \Sigma_A
\end{aligned}$$

Бу ерда, $\bar{b}_{(j)}$ – \bar{B} матрицанинг j устунини, $S_{A(j)}$ – S_A матрицанинг j устунини билдиради.

Шунингдек, ρ , C ва D учун постериор тақсимотлар қуйидаги тенгламалар орқали топилади:

$$\begin{aligned}
q_\rho(\rho) &= \prod_{s=1}^p Ga(\rho_s | a + \frac{T}{2}, b + \frac{1}{2} G_{ss}) \\
q_D(D|\rho) &= \prod_{s=1}^p N(d_{(s)} | \Sigma_D \bar{d}_{(s)}, \rho_s^{-1} \Sigma_D) \\
q_C(C|D, \rho) &= \prod_{s=1}^p N(c_{(s)} | \Sigma_C [S_{C(s)} - G_C d_{(s)}], \rho_s^{-1} \Sigma_C) \\
\Sigma_C^{-1} &= \text{diag}(\gamma) + W_C \\
\Sigma_D^{-1} &= \text{diag}(\delta) + \ddot{U} - G_C^T \Sigma_C G_C \\
G &= \ddot{Y} - S_C^T \Sigma_C S_C - \bar{D} \Sigma_D \bar{D}^T \\
\bar{D} &= U_Y^T - S_C^T \Sigma_C G_C \\
q_C(C|\rho) &= \prod_{s=1}^p N(c_{(s)} | \Sigma_C [S_{C(s)} - G_C \Sigma_D \bar{d}_{(s)}], \rho_s^{-1} \hat{\Sigma}_C) \\
\hat{\Sigma}_C &= \Sigma_C + \Sigma_C G_C \Sigma_D G_C^T \Sigma_C
\end{aligned}$$

Бу ерда, $\bar{d}_{(s)}$ – \bar{D} матрицанинг s устунини, $S_{C(s)}$ – S_C матрицанинг s устунини билдиради.

Variational Bayesian M-step (Maximisation) босқичида кутилган табиий параметрлар вектори $\varphi(\theta)$ ҳисобланади. Кейинчалик улар тизимдаги яширин ҳолатлар бўйича $q_x(x_{0:T})$ тақсимотни кўрсатадиган Variational Bayesian E-step (Expectation) босқичида қўлланилади. Тегишли табиий параметрлар вектори эса қуйидаги кўринишда бўлади:

$$\begin{aligned} \varphi(\theta) &= \varphi(A, B, C, D, R) = [A, A^T A, B, A^T B, C^T R^{-1} C, \\ &R^{-1} C, C^T R^{-1} D, B^T B, R^{-1}, \ln|R^{-1}|, D^T R^{-1} D, R^{-1} D] . \\ \langle A \rangle &= [S_A - G_A \Sigma_B \bar{B}^T]^T \Sigma_A \\ \langle A^T A \rangle &= \langle A \rangle^T \langle A \rangle + k [\Sigma_A + \Sigma_A G_A \Sigma_B G_A^T \Sigma_A] \\ \langle B \rangle &= \bar{B} \Sigma_B \\ \langle A^T B \rangle &= \Sigma_A [S_A \langle B \rangle - G_A \{ \langle B \rangle^T \langle B \rangle + k \Sigma_B \}] \\ \langle B^T B \rangle &= \langle B \rangle^T \langle B \rangle + k \Sigma_B \\ \langle \rho_s \rangle &= \bar{\rho}_s = \frac{a_\rho + T/2}{b_\rho + G_{ss}/2} \\ \langle \ln \rho_s \rangle &= \overline{\ln \rho_s} = \Psi \left(a_\rho + \frac{T}{2} \right) - \ln \left(b_\rho + \frac{G_{ss}}{2} \right) \\ \langle R^{-1} \rangle &= \text{diag}(\bar{\rho}) \\ \langle C \rangle &= [S_C - G_C \Sigma_D \bar{D}^T]^T \Sigma_C \\ \langle D \rangle &= \bar{D} \Sigma_D \\ \langle C^T R^{-1} C \rangle &= \langle C \rangle^T \text{diag}(\bar{\rho}) \langle C \rangle + p [\Sigma_C + \Sigma_C G_C \Sigma_D G_C^T \Sigma_C] \\ \langle R^{-1} C \rangle &= \text{diag}(\bar{\rho}) \langle C \rangle \\ \langle C^T R^{-1} D \rangle &= \Sigma_C [S_C \text{diag}(\bar{\rho}) \langle D \rangle - G_C \langle D \rangle^T \text{diag}(\bar{\rho}) \langle D \rangle - p G_C \Sigma_D] \\ \langle R^{-1} D \rangle &= \text{diag}(\bar{\rho}) \langle D \rangle \\ \langle D^T R^{-1} D \rangle &= \langle D \rangle^T \text{diag}(\bar{\rho}) \langle D \rangle + p \Sigma_D . \end{aligned}$$

Бу ерда, $\langle \cdot \rangle$ – кейинги вариацияга нисбатан кутишни билдиради.

Variational Bayesian E-step (Expectation), VBE

Яширин ҳолат ўзгарувчилари вектори $x_{0:T}$ нинг постериор тақсимоти вақт босқичлари бўйича биргаликда Гаусс тақсимоти каби бўлиб, яширин ўзгарувчилар векторининг логарифмик постериор тақсимоти қуйидаги кўринишда ифодаланadi:

$$\begin{aligned}\ln q_x(x_{0:T}) &= -\ln Z + \langle \ln p(A, B, C, D, \rho, x_{0:T}, y_{1:T}) \rangle \\ &= -\ln Z' + \langle \ln p(x_{0:T}, y_{1:T} | A, B, C, D, \rho) \rangle \\ Z' &= \int dx_{0:T} \exp \langle \ln p(x_{0:T}, y_{1:T} | A, B, C, D, \rho) \rangle.\end{aligned}$$

$$\ln Z' = \sum_{t=1}^T \ln \zeta_t'(y_t)$$

$$\begin{aligned}\ln \zeta_t'(y_t) &= -\frac{1}{2} [\langle \ln |2\pi R| \rangle - \ln |\Sigma_{t-1}^{-1} \Sigma_{t-1}^* \Sigma_t| + \mu_{t-1}^T \Sigma_{t-1}^{-1} \mu_{t-1} - \mu_t^T \Sigma_t^{-1} \mu_t \\ &\quad + y_t^T \langle R^{-1} \rangle y_t - 2y_t^T \langle R^{-1} D \rangle u_t + u_t^T \langle D^T R^{-1} D \rangle u_t \\ &\quad - (\Sigma_{t-1}^{-1} \mu_{t-1} - \langle A^T B \rangle u_t)^T \Sigma_{t-1}^* (\Sigma_{t-1}^{-1} \mu_{t-1} - \langle A^T B \rangle u_t)].\end{aligned}$$

Кузатилган маълумотлар берилган t вақтдаги яширин ҳолатга нисбатан $\alpha_t(x_t)$ t вақтгача ($t = \{1, 2, \dots, T\}$) постериор бўлади. Шу билан биргаликда, $\alpha_t(x_t)$ яширин ҳолатнинг филтёрланган ўртача μ_t ва ковариацияси Σ_t аниқланади:

$$\alpha_t(x_t) \equiv p(x_t | y_{1:t}).$$

Шунингдек, $\alpha_t(x_t)$ олдинги $\alpha_{t-1}(x_{t-1})$ билан рекурсияни қуйидаги кўринишда ҳосил қилади:

$$\begin{aligned}\alpha_t(x_t) &= \int dx_{t-1} \frac{p(x_{t-1} | y_{1:t-1}) p(x_t | x_{t-1}) p(y_t | x_t)}{p(y_t | y_{1:t-1})} \\ &= \frac{1}{\zeta_t(y_t)} \int dx_{t-1} \alpha_{t-1}(x_{t-1}) p(x_t | x_{t-1}) p(y_t | x_t) \\ &= \frac{1}{\zeta_t(y_t)} \int dx_{t-1} N(x_{t-1} | \mu_{t-1}, \Sigma_{t-1}) N(x_t | Ax_{t-1}, I) N(y_t | Cx_t, R) \\ &= N(x_t | \mu_t, \Sigma_t)\end{aligned}$$

Бу ерда, $\zeta_t(y_t) \equiv p(y_t | y_{1:t-1})$ белгилаш филтёрланган чиқиш эҳтимолини беради.

$$\begin{aligned}\Sigma_{t-1}^* &= (\Sigma_{t-1}^{-1} + A^T A)^{-1} \\ x_{t-1}^* &= \Sigma_{t-1}^* [\Sigma_{t-1}^{-1} \mu_{t-1} + A^T x_t] \\ \Sigma_t &= [I + C^T R^{-1} C - A \Sigma_{t-1}^* A^T]^{-1} \\ \mu_t &= \Sigma_t [C^T R^{-1} y_t + A \Sigma_{t-1}^* \Sigma_{t-1}^{-1} \mu_{t-1}].\end{aligned}$$

Ҳар бир босқичда $\alpha_t(x_t)$ нинг маҳражи сифатида олинган нормаллаштирувчи доимий $\zeta_t(y_t)$ маълумотларнинг эҳтимоллигини

ҳисоблашга ёрдам беради. Бунда, доимий маълумотлар эҳтимоллигини қуйидаги шаклда ёзиш мумкин:

$$\begin{aligned}
 p(y_{1:T}) &= p(y_1)p(y_2|y_1) \dots p(y_t|y_{1:t-1}) \dots p(y_T|y_{1:T-1}) = \\
 &= p(y_1) \prod_{t=2}^T p(y_t|y_{1:t-1}) = \prod_{t=1}^T \zeta_t(y_t) \\
 \zeta_t(y_t) &= N(y_t|\varpi_t, \xi_t) \\
 \xi_t &= (R^{-1} - R^{-1}C\Sigma_t C^T R^{-1})^{-1} \\
 \varpi_t &= \xi_t R^{-1} C \Sigma_t A \Sigma_{t-1}^* \Sigma_{t-1}^{-1} \mu_{t-1}.
 \end{aligned}$$

Ушбу тақсимот ёрдамида кетма-кетликда олдинги кузатувларни ҳисобга олган ҳолда, ҳар бир кузатув y_t эҳтимоллиги кузатилади ва маълумотлар келиши билан ҳар бир вақт босқичида прогнозли ўртача ва дисперсия олинади. Бироқ, бу тақсимот яширин ҳолат кетма-кетлиги текислангандан сунг ўзгаради. Барча маълумотлар берилган яширин ҳолат устидан постериор бўлиши учун яширин ҳолат текисланган баҳоси γ аниқланади. Шу билан биргаликда, $\gamma_t(x_t) = p(x_t|y_{1:T})$ яширин ҳолатнинг текисланган баҳоси қуйидагича ифодаланади:

$$\begin{aligned}
 \gamma_t(x_t) &= p(x_t|y_{1:T}) = \int dx_{t+1} p(x_t, x_{t+1}|y_{1:T}) \\
 &= \int dx_{t+1} p(x_t|x_{t+1}, y_{1:T}) p(x_{t+1}|y_{1:T}) \\
 &= \int dx_{t+1} p(x_t|x_{t+1}, y_{1:t}) p(x_{t+1}|y_{1:T}) \\
 &= \int dx_{t+1} \frac{p(x_t|y_{1:t}) p(x_{t+1}|x_t)}{\int dx'_t p(x'_t|y_{1:t}) p(x_{t+1}|x'_t)} p(x_{t+1}|y_{1:T}) \\
 &= \int dx_{t+1} \left[\frac{\alpha_t(x_t) p(x_{t+1}|x_t)}{\int dx'_t \alpha_t(x'_t) p(x_{t+1}|x'_t)} \right] \gamma_{t+1}(x_{t+1}) \\
 \gamma_t(x_t) &= N(x_t|\omega_t, Y_{tt}) \\
 K_t &= (Y_{t+1,t+1}^{-1} + A \Sigma_t^* A^T)^{-1} \\
 Y_{tt} &= [\Sigma_t^{*-1} - A^T K_t A]^{-1} \\
 \omega_t &= Y_{tt} [\Sigma_t^{-1} \mu_t + A^T K_t (Y_{t+1,t+1}^{-1} \omega_{t+1} - A \Sigma_t^* \Sigma_t^{-1} \mu_t)].
 \end{aligned}$$

Бунда, t , y_t вақтидаги маълумотлар филтрлангандан сунг яширин ўзгарувчилар ўрнига $\alpha_t(x_t)$ дан фойдаланилади.

Турли вақт нуқталаридаги ҳолатларни баҳолаш учун параллел рекурсия $\beta_t(x_t) = p(y_{t+1:T}|x_t)$ ҳисобланади:

$$\beta_{t-1}(x_{t-1}) = \int dx_t p(x_t | x_{t-1}) p(y_t | x_t) p(y_{t+1:T} | x_t) = \int dx_t p(x_t | x_{t-1}) p(y_t | x_t) \beta_t(x_t) \propto N(x_{t-1} | \eta_{t-1}, \Psi_{t-1}).$$

$\beta_T(x_T) = 1$ якуний шартни қаноатлантириш учун $\Psi_T^{-1} = 0$ кўринишида ифодаланади. Рекурсия $t = T$ дан $t = 1$ гача давом этади. Бу рекурсиянинг охири босқичида, ёрдамчи яширин ҳолат ўзгарувчиси x_0 га боғлиқ бўлган барча маълумотларнинг эҳтимоллиги аниқланади:

$$\begin{aligned} \Psi_t^* &= (I + C^T R^{-1} C + \Psi_t^{-1})^{-1} \\ \Psi_{t-1} &= [A^T A - A^T \Psi_t^* A]^{-1} \\ \eta_{t-1} &= \Psi_{t-1} A^T \Psi_t^* [C^T R^{-1} y_t + \Psi_t^{-1} \eta_t]. \end{aligned}$$

Юқоридаги формулалардан фойдаланиб, $t = 0$ дан $t = T$ гача $\{\eta_t, \Psi_t\}_{t=0}^T$ лар ҳисобланилади.

Variational Bayesian ёндашувида маргиналлари кетма-кет ўтиш билан осонгина олиш мумкин эмас ва улар ўрнига α ва β маълумотлар қуйидаги тарзда бирлаштириш орқали ҳисобланади. Хусусан, $t = \{0, 1, 2, \dots, T - 1\}$ учун $\omega_t, \Upsilon_{t,t}$ ларни қуйидагича ҳисобланади:

$$\begin{aligned} p(x_t | y_{1:T}) &\propto p(x_t | y_{1:t}) p(y_{t+1:T} | x_t) = \\ \alpha_t(x_t) \beta_t(x_t) &= N(x_t | \omega_t, \Upsilon_{tt}) \\ \Upsilon_{t,t} &= [\Sigma_t^{-1} + \Psi_t^{-1}]^{-1} \\ \omega_t &= \Upsilon_{t,t} [\Sigma_t^{-1} \mu_t + \Psi_t^{-1} \eta_t]. \end{aligned}$$

$t = \{0, 1, 2, \dots, T - 1\}$ учун барча кузатувларни ҳисобга олган ҳолда яширин ўзгарувчилар векторининг ўзаро ковариацияси $\Upsilon_{t,t+1}$ эса, қуйидагича аниқланади:

$$\Upsilon_{t,t+1} = \Sigma_t^* A^T \Upsilon_{t+1,t+1}.$$

Логарифмик маргинал эҳтимоллик қуйи чегарасининг баҳосини ҳисоблаш

Логарифмик маргинал эҳтимолликни тўғридан-тўғри ҳисоблаш мураккаблиги сабабли, унинг қуйи чегарасини баҳолаб логарифмик маргинал эҳтимоллик қуйи чегарасининг баҳоси сифатида F олинади.

Логарифмик маргинал эҳтимоллик қуйи чегарасининг баҳоси ҳам мураккаб функция бўлганлиги учун бир нечта босқичдан ўтиш орқали, логарифмик маргинал эҳтимоллик қуйи чегарасининг баҳоси соддароқ кўринишдаги йиғиндига келтирилади.

KL (Kullback-Leibler) бир хил ўзгарувчилар бўйича икки нормал ёки икки гамма тақсимот орасидаги фарқ ҳисобланиб, J ва K ўзгарувчилар жуфтлиги учун қуйидаги тенгликлардан фойдаланилади:

$$KL(J) = \int dJ q(J) \ln \frac{q(J)}{p(J)}$$

$$KL(J|K) = \int dJ q(J|K) \ln \frac{q(J|K)}{p(J|K)}$$

$$\langle KL(J|K) \rangle_{q(K)} = \int dK q(K) KL(J|K)$$

Бу ерда,

$KL(J)$ – KL фарқи,

$KL(J|K)$ – шартли KL ,

$\langle KL(J|K) \rangle_{q(K)}$ – кутилган шартли KL .

Бу тенгликлардан фойдаланган ҳолда, F ни қуйидаги кўринишда қайта ифодалаш мумкин:

$$F = -KL(B) - \langle KL(A|B) \rangle_{q(B)} - KL(\rho) - \langle KL(D|\rho) \rangle_{q(\rho)} -$$

$$\langle KL(C|\rho, D) \rangle_{q(\rho, D)} + H(q_x(x_{0:T})) +$$

$$\langle \ln p(x_{1:T}, y_{1:T} | A, B, C, D, \rho) \rangle_{q(A, B, C, D, \rho) q(x_{1:T})} \cdot$$

$$H(q_x(x_{0:T})) = - \int dx_{0:T} q_x(x_{0:T}) \ln q_x(x_{0:T}) =$$

$$- \int dx_{0:T} q_x(x_{0:T}) [-\ln Z' + \langle \ln p(x_{0:T}, y_{1:T} | A, B, C, D, \rho, \mu_0, \Sigma_0) \rangle_{q_{\theta}(A, B, C, D, \rho)}]$$

$$= \ln Z' - \langle \ln p(x_{0:T}, y_{1:T} | A, B, C, D, \rho, \mu_0, \Sigma_0) \rangle_{q_{\theta}(A, B, C, D, \rho) q_x(x_{0:T})}$$

$H(q_x(x_{0:T}))$ дан фойдаланган ҳолда F нинг тенгламаси қуйидаги содда кўринишга келтирилади. Бу эса, F ни ҳисоблашда қулайлик яратади:

$$F = -KL(B) - \langle KL(A|B) \rangle_{q(B)} - KL(\rho) - \langle KL(D|\rho) \rangle_{q(\rho)} -$$

$$\langle KL(C|\rho, D) \rangle_{q(\rho, D)} + \ln Z'.$$

Гиперпараметрларни янгилаш

Гиперпараметрлар $\alpha, \beta, \gamma, \delta, a, b$, шунингдек Σ_0 ва μ_0 кўринишидаги олдинги гиперпараметрлар маргинал эҳтимоллик буйича пастки чегара баҳосини максимал даражага кўтариш учун янгиланади. Бунда, гиперпараметрлар қуйидагича янгиланади:

$$\begin{aligned}\alpha_j^{-1} &\leftarrow \frac{1}{k} [k\Sigma_A + \Sigma_A [S_A S_A^T - 2G_A \langle B \rangle^T S_A^T + \\ &G_A \{k\Sigma_B + \langle B \rangle^T \langle B \rangle\} G_A^T] \Sigma_A]_{jj} \\ \beta_j^{-1} &\leftarrow \frac{1}{k} [k\Sigma_B + \langle B \rangle^T \langle B \rangle]_{jj} \\ \gamma_j^{-1} &\leftarrow \frac{1}{p} [p\Sigma_C + \Sigma_C [S_C \text{diag}(\bar{\rho}) S_C^T - 2S_C \text{diag}(\bar{\rho}) \langle D \rangle G_C^T + pG_C \Sigma_D G_C' + \\ &G_C \langle D \rangle^T \text{diag}(\bar{\rho}) \langle D \rangle G_C^T] \Sigma_C]_{jj} \\ \delta_j^{-1} &\leftarrow \frac{1}{p} [p\Sigma_D + \langle D \rangle^T \text{diag}(\bar{\rho}) \langle D \rangle]_{jj}\end{aligned}$$

Бу ерда, $[\cdot]_{jj}$ – $[\cdot]$ матрицанинг (j, j) элементини билдиради.

Олдинги приор тақсимот остидаги яширин ҳолат кетма-кетлигининг эҳтимолини максимал даражада ошириш учун, ёрдамчи яширин ҳолатнинг гиперпараметрлари x_0 нинг текисланган баҳосининг тақсимланишига мувофиқ ўрнатилади:

$$\begin{aligned}\Sigma_0 &\leftarrow Y_{0,0} \\ \mu_0 &\leftarrow \omega_0\end{aligned}$$

Чиқиш шовқини бўйича приор тақсимотни бошқарувчи гиперпараметрлар a ва b эса $R = \text{diag}(\rho)$ тенгламанинг белгиланган нуқталарига ўрнатилади:

$$\begin{aligned}\Psi(a) &= \ln b + \frac{1}{p} \sum_{s=1}^p \overline{\ln \rho_s} \\ \frac{1}{b} &= \frac{1}{pa} \sum_{s=1}^p \bar{\rho}_s\end{aligned}$$

Логарифмик маргинал эҳтимолликнинг қуйи чегараси баҳоси қийматларини таққослаш

Логарифмик маргинал эҳтимолликнинг қуйи чегараси баҳоси аниқлангандан сўнг, яқуний босқичда ушбу баҳонинг бир давр олдинги қиймати билан ўзаро солиштирилади. Агар, қуйи чегара баҳоси бир давр олдинги қийматига нисбатан ортган бўлса, Variational Bayesian M-step босқичидан бошлаб қайтадан ҳисоб-китоблар амалга оширилади. Ушбу такрорланиш қуйи чегара баҳоси ортмай қолгунга қадар давом этади. Бунда, логарифмик маргинал эҳтимолликнинг қуйи чегараси баҳоси олдинги қиймати билан солиштирилган ҳолатда улар орасида фарқ бўлмаса, логарифмик маргинал эҳтимолликнинг қуйи чегараси баҳоси оптимал қийматга эришган ҳисобланади. Бу даврга келиб, гиперпараметрлар орқали параметрлар ҳам ўзининг оптимал қийматига эришади. Аниқланган параметрлар ва мавҳум ўзгарувчилардан келиб чиқиб, кузатилиши мумкин бўлган эрксиз ўзгарувчи Y баҳоланади.