

**IKKINCHI VA UNDAN YUQORI DARAJADAGI MANTIQIY  
TO'PLAMLAR ASOSIDA KO'P DARAJALI AXBOROT TIZIMLARIDA  
QAROR QABUL QILISH MODELLARI**

*Qodirov Dilmurod To'xtasinovich*

*Namangan muhandislik-texnologiya instituti*

*Rahimov Rustam G'ulomjonovich*

*Namangan muhandislik-texnologiya instituti*

*Djuraev Sherzod Sobirdjonovich*

*Namangan muhandislik-texnologiya instituti*

**Annotatsiya:** Mazkur maqolada ko'p darajali axborot tizimlarida qaror qabul qilishni optimallashtirish uchun ikkinchi va undan yuqori darajadagi mantiqiy to'plamlar nazariyasiga asoslangan matematik modellar taklif etiladi. Dinamik Bayesian tarmoqlar (DBN) murakkab tizimlarning vaqt o'tishi bilan o'zgaradigan ehtimolliklarini modellashtirishda qo'llanilib, qatlamlı DBNlarning ierarxik tuzilmasi orqali qaror qabul qilish jarayonlari samaradorligi tahlil qilingan. Real vaqt kuzatuvlari asosida ehtimolliklarni yangilash va kuzatuvlarning dolzarbligini oshirish yondashuvlari tizimning samaradorligini oshirish uchun qo'llaniladi. Maqola qaror qabul qilish tizimlarini rivojlantirish uchun algoritmlar va modellarni amaliyotda qo'llash yo'nalishlarini ko'rsatadi.

**Kalit so'zlar:** Ko'p darajali axborot tizimlari, Dinamik Bayesian tarmoqlar, qaror qabul qilish, real vaqt kuzatuvlari, matematik modellashtirish, ehtimollik taqsimotlari, qatlamlı DBN, ierarxik tuzilma, optimallashtirish.

**Kirish.** Ko'p darajali axborot tizimlarida qaror qabul qilish jarayonlari murakkab va ko'p qirrali bo'lib, ularni samarali boshqarish uchun matematik modellar zarur. Ushbu maqolada ikkinchi va undan yuqori darajadagi mantiqiy to'plamlar nazariyasini asosida ko'p darajali axborot tizimlarida qaror qabul qilish modellarini ishlab chiqish va ularning matematik asoslarini ko'rib chiqamiz.

**Dinamik Bayesian Tarmoqlar (Dynamic Bayesian Networks, DBNs)** — bu vaqt o'tishi bilan o'zgaradigan ehtimollik taqsimotlarini ifodalash uchun ishlataladigan probabilistik graf modellaridir. DBNs dinamik jarayonlarni modellashtirishda samarali vosita bo'lib, ular Markovlik xususiyatiga asoslangan.

DBN ning asosiy matematik ifodasi vaqtga bog'liq holda ehtimolliklarni qayta baholashga asoslanadi. Quyida DBN ning asosiy komponentlari va matematik ifodasi keltirilgan:

DBNning asosiy matematik modeli

DBN ning asosiy matematik ifodasi vaqt bo'yicha birlgiligidagi ehtimollik taqsimotini tasvirlaydi. Bu taqsimot quyidagicha ifodalanadi:

$$P(X_{1:T}, O_{1:T}) = P(X_1) \prod_{t=2}^T P(X_t | X_{t-1}) \prod_{t=1}^T P(O_t | X_t)$$

bu yerda:

- $P(X_1)$ : Boshlang'ich holatning ehtimollik taqsimoti.
- $P(X_t | X_{t-1})$ : Holatlar orasidagi o'tish ehtimoli.
- $P(O_t | X_t)$ : Har bir holatda kuzatuv ehtimoli.

DBNda Markov xususiyati

Dinamik Bayesian Tarmoqlarda **Birlamchi Markov xususiyati** qabul qilinadi:

$$P(X_t | X_{1:t-1}) = P(X_t | X_{t-1})$$

ya'ni, tizimning keljak holati faqat uning hozirgi holatiga bog'liq bo'ladi, o'tgan holatlarga emas.

DBNda kuzatuv ma'lumotlari asosida holat ehtimolini yangilash **Bayes qoidasi** asosida amalga oshiriladi:

1. **Prognoz qilish bosqichi qiyidagi ifoda bilan ifodalanadi:**

$$P(X_t | O_{1:t-1}) = \int P(X_t | X_{t-1}) P(X_{t-1} | O_{1:t-1}) dX_{t-1}$$

2. Matematik ifodada Yangilash bosqichi quyidaicha aniqlanadi

$$P(X_t | O_{1:t}) = \frac{P(O_t | X_t) P(X_t | O_{1:t-1})}{P(O_t | O_{1:t-1})}$$

bu yerda  $P(O_t | O_{1:t-1})$  — normallashtiruvchi koeffitsient:

$$P(O_t | O_{1:t-1}) = \int P(O_t | X_t) P(X_t | O_{1:t-1}) dX_t$$

DBN modellashtirish tizimlarda vaqt o'tishi bilan o'zgaruvchi ehtimolliklarni boshqarish va qaror qabul qilishda kuchli vosita hisoblanadi. Uning asosiy matematik ifodasi  $P(X_t | X_{1:t-1})$  va  $P(O_t | X_t)$  ehtimolliklarini baholashga asoslanadi va vaqt davomida Bayes qoidasi yordamida yangilanadi. Bu yondashuv murakkab tizimlarda qaror qabul qilishni optimallashtirishda samarali natijalar beradi.

Dinamik Bayesian Tarmoqlar (DBN) bo'yicha murakkab tizimlarda qaror qabul qilishni optimallashtirish uchun Qatlamlili (Layered) DBN tuzilmalardan foydalanish mumkin:

Qatlamlili Dinamik Bayesian Tarmoqlar (Layered DBNs) murakkab tizimlarni turli darajadagi qarorlar uchun modellashtirishga imkon beradi. Ushbu yondashuvda har bir qatlamlar tizimning ma'lum bir komponentini ifodalaydi va qatlamlar o'zaro bog'liq ehtimollik munosabatlari orqali bir-biriga ta'sir ko'rsatadi. Quyida qatlamlili DBNning asosiy matematik modeli keltiriladi.

Faraz qilaylik, tizim  $L$  qatlamdan iborat va har bir qatlamda vaqtga bog‘liq holatlar  $X_t^{(l)}$  va kuzatuvlar  $O_t^{(l)}$  mavjud. Bu yerda  $l$  qatlam indeksini bildiradi ( $l = 1, 2, \dots$ ).

Qatlamlararo bog‘liqlik quyidagicha ifodalanadi:

$$P(X_t^{(l)} | X_t^{(l-1)})$$

ya’ni,  $l$ -qatlamdagi holatlar  $l-1$ -qatlamdagi holatlarga bog‘liq. Har bir qatlam ichida vaqt davomida holatlar o‘zgaradi. Har bir qatlamda kuzatuvlar o‘zining holatlari bilan bog‘liq:

$$P(O_t^{(l)} | X_t^{(l-1)})$$

Shunday qilib qatlamli DBNning umumiy ehtimollik taqsimoti quyidagicha ifodalanadi:

$$P(X_{1:T}, O_{1:T}) = \prod_{t=1}^T \prod_{l=1}^L [P(X_t^{(l)} | X_{t-1}^{(l)}) P(X_t^{(l)} | X_t^{(l-1)}) P(O_t^{(l)} | X_t^{(l)})]$$

bu yerda:

- $P(X_t^{(l)} | X_{t-1}^{(l)})$  — vaqt bo‘yicha qatlam ichidagi o‘zgarish.
- $P(X_t^{(l)} | X_t^{(l-1)})$  — qatlamlararo bog‘liqlik.
- $P(O_t^{(l)} | X_t^{(l)})$  — kuzatuv va holatlarning ehtimoli.

Agar tizim faqat ikki qatlamdan iborat bo‘lsa ( $L = 2$ ), umumiy ehtimollik taqsimoti quyidagicha ifodalanadi:

$$\begin{aligned} & P(X_{1:T}, O_{1:T}) \\ &= \prod_{t=1}^T [P(X_t^{(1)} | X_{t-1}^{(1)}) P(O_t^{(1)} | X_t^{(1)}) P(X_t^{(2)} | X_{t-1}^{(2)}) P(X_t^{(2)} | X_t^{(1)}) P(O_t^{(2)} | X_t^{(2)})] \end{aligned}$$

Bu yerda:

- 1-qatlam tizimning pastki darajadagi xatti-harakatlarini modellashtiradi.
- 2-qatlam tizimning yuqori darajadagi qarorlarini modellashtiradi.

Agar yuqori darajadagi qatlam pastki qatlamlarning faqat statistik xulosalariga bog‘liq bo‘lsa:

$$P(X_t^{(l)} | X_t^{(l-1)}) = P(X_t^{(l)} | \text{Summary}X_t^{(l-1)})$$

bu yerda  $\text{Summary}X_t^{(l-1)}$  — pastki qatlamning asosiy statistik ko‘rsatkichlari.

Agar har bir qatlam bir nechta mustaqil komponentlardan tashkil topgan bo‘lsa:

$$P(X_t^{(l)}) = \prod_{i=1}^N P(X_t^{(l,i)})$$

bu yerda  $X_t^{(l,i)}$  —  $l$ -qatlamdagi  $i$ -komponentning holati.

Yuqoridagi yangiliklarni kuzatuvlar asosida ehtimollarni dinamik ravishda yangilash mumkin:

$$P(X_t^{(l)}|O_{1:t}) = \frac{P(O_t^{(l)}|X_t^{(l)}) P(X_t^{(l)}|O_{1:t-1})}{P(O_t^{(l)})}$$

Qatlamlı DBN murakkab tizimlarni modellashtirishda qaror qabul qilishni optimallashtiradi, chunki u har bir qatlama vaga bog'liq ehtimolliklarni baholash va qatlamlararo o'zaro bog'liqliklarni ifodalash imkonini beradi. Ushbu matematik model qaror qabul qilish tizimlarining iyerarxik tuzilmasini samarali tashkil etishda ishlataladi.

Real vaqt kuzatuvlarini integratsiyalash orqali **Dinamik Bayesian Tarmoqlar (DBNs)** asosida umumiyligida ehtimollik taqsimotini yaratish uchun tizim doimiy yangilanuvchi kuzatuv ma'lumotlarini hisobga olishi kerak. Quyida ushbu yondashuv asosida yangi model taqdim etilgan.

Faraz qilaylik, tizim vaqt davomida o'zgarib turadigan holatlar ( $X_t$ ) va kuzatuvlar ( $O_t$ ) bilan ifodalanadi. Tizim har bir qatlama uchun **real vaqt kuzatuvlarini** dinamik ravishda yangilaydi.

$$P(X_{1:T}, O_{1:T}) = P(X_1) \prod_{t=2}^T \prod_{l=1}^L [P(X_t^{(l)}|X_{t-1}^{(l)}) P(X_t^{(l)}|X_t^{(l-1)}) P(O_t^{(l)}|X_t^{(l)})]$$

Real vaqt ma'lumotlari kelib tushgan sari holat ehtimollari **Bayes qoidasi** asosida yangilanadi.

Agar t vaqt momentida yangi kuzatuv  $O_t^{(l)}$  mavjud bo'lsa, har bir qatlama uchun holat ehtimoli quyidagicha yangilanadi:

$$P(X_t^{(l)}|O_{1:t}) = \frac{P(O_t^{(l)}|X_t^{(l)}) P(X_t^{(l)}|O_{1:t-1})}{P(O_t^{(l)}|O_{1:t-1})}$$

Bu yerda:

•  $P(O_t^{(l)}|O_{1:t-1})$  — normallashtiruvchi koefitsient:

$$P(O_t^{(l)}|O_{1:t-1}) = \int P(O_t^{(l)}|X_t^{(l)}) P(X_t^{(l)}|O_{1:t-1}) dX_t^{(l)}$$

Agar  $t+1$  vaqt uchun kuzatuv hali kelmagan bo'lsa, prognoz holat ehtimoli hisoblanadi:

$$P(X_{t+1}^{(l)}|O_{1:t}) = \int P(O_{t+1}^{(l)}|X_t^{(l)}) P(X_t^{(l)}|O_{1:t}) dX_t^{(l)}$$

Real vaqt kuzatuvlarining ahamiyati vaqt o'tishi bilan o'zgaradi. Ushbu xususiyatni hisobga olish uchun vaga bog'liq og'irlilik funksiyasi  $\omega_t$  qo'shiladi:

$$P(O_t^{(l)}|X_t^{(l)}) = \omega_t P(O_t^{(l)}|X_t^{(l)})$$

Bu yerda  $\omega_t$  quyidagicha aniqlanadi:

$$\omega_t = e^{-\alpha(T-t)}$$

bu yerda  $\alpha$  vaqtga bog‘liq yomonlashuv koeffitsienti.

Kuzatuvlar turli aniqlik darajalariga ega bo‘lishi mumkin. Kuzatuvning ishonchlilagini  $c_t^l$  orqali modellashtirish mumkin:

$$P(O_t^{(l)}|X_t^{(l)}) = c_t^l P(O_t^{(l)}|X_t^{(l)})$$

Yuqoridagi qo‘sishimchalar bilan birgalikda real vaqt kuzatuvlarini hisobga oluvchi qatlamlı DBN umumiyyatini quyidagicha ko‘rinishga ega bo‘ladi:

$$P(X_{1:T}, O_{1:T}) = P(X_1) \prod_{t=2}^T \prod_{l=1}^L \left[ P(X_t^{(l)}|X_{t-1}^{(l)}) P(X_t^{(l)}|X_t^{(l-1)}) \omega_t^l c_t^l P(O_t^{(l)}|X_t^{(l)}) \right]$$

Ushbu yangi model real vaqt kuzatuvlarini dinamik ravishda hisobga oladi va murakkab tizimlarda qaror qabul qilish jarayonini samaraliroq qiladi. Model vaqtga bog‘liq ishonchlilik va kuzatuv sifatini baholashni hisobga olishi bilan ajralib turadi. Bu, ayniqsa, real vaqt tizimlari, masalan, boshqaruv tizimlari yoki monitoring jarayonlarida qo‘llash uchun mos keladi.

Vaqt bo‘yicha og‘irliklarni kiritish orqali umumiyyatini ehtimollik taqsimotini vaqt o‘tishi bilan kuzatuvlarning ahamiyatini moslashtiruvchi elementlar bilan boyitish mumkin. Ushbu yondashuv real vaqt kuzatuvlarining dolzarbligini oshiradi, chunki yaqinda kelgan kuzatuvlar ko‘proq ta’sir qiladi, uzoq vaqt avvalgi kuzatuvlar esa kamroq ahamiyatga ega bo‘ladi.

Qatlamlı Dinamik Bayesian Tarmoqning (DBN) real vaqt kuzatuvlarini integratsiya qiluvchi umumiyyatini ehtimollik taqsimotini, vaqt bo‘yicha og‘irliklarni ( $\omega_t$ ) hisobga olib, quyidagicha ko‘rinishga ega:

$$P(X_{1:T}, O_{1:T}) = P(X_1) \prod_{t=2}^T \prod_{l=1}^L \left[ P(X_t^{(l)}|X_{t-1}^{(l)}) P(X_t^{(l)}|X_t^{(l-1)}) \omega_t^l P(O_t^{(l)}|X_t^{(l)}) \right]$$

Yoki

$$\begin{aligned} P(X_{1:T}, O_{1:T}) \\ = P(X_1) \prod_{t=2}^T \prod_{l=1}^L \left[ P(X_t^{(l)}|X_{t-1}^{(l)}) P(X_t^{(l)}|X_t^{(l-1)}) \omega_t e^{-\alpha(T-t)} P(O_t^{(l)}|X_t^{(l)}) \right] \end{aligned}$$

Ushbu holatda real vaqt kuzatuvlari asosida ehtimolliklarni yangilash quyidagicha amalga oshiriladi:

$$P(X_t^{(l)}|O_{1:t}) = \frac{\omega_t e^{-\alpha(T-t)} P(O_t^{(l)}|X_t^{(l)}) P(X_t^{(l)}|O_{1:t-1})}{\int \omega_t e^{-\alpha(T-t)} P(O_t^{(l)}|X_t^{(l)}) P(X_t^{(l)}|O_{1:t-1}) dX_t^l}$$

Prognoz qilish

$$P(X_t^{(l)}|O_{1:t}) = \int P(X_{t+1}^{(l)}|X_t^{(l)}) P(X_t^{(l)}|O_{1:t}) dX_t^l$$

Vaqt bo'yicha og'irliklarni kiritish orqali DBN tizimlari murakkab muhitlarda samaraliroq ishlaydi. Bu yondashuv yangi kuzatuvlarni tezkor qabul qilish va ularga moslashishni ta'minlab, tizimning qaror qabul qilish qobiliyatini sezilarli darajada oshiradi.

Yuqoridagi modelning bat afsil ifodasida **prognoz qilish** komponentini samaraliroq qilish uchun real vaqt kuzatuvlarini va vaqt bo'yicha og'irliklarni kiritish orqali tizimning keyingi holatlarini aniqlash yanada optimallashtiriladi. Bu prognoz qilish jarayonida har bir vaqt momentidagi kuzatuvlarning dolzarbligini hisobga olib, tizimni dinamik boshqarish imkonini beradi.

Har bir qatlama ( $l$ ) uchun vaqt bo'yicha og'irliklar kiritilgan prognoz modeli quyidagicha aniqlanadi:

$$P(X_{t+1}^{(l)}|O_{1:t}) = \int P(X_{t+1}^{(l)}|X_t^{(l)}) \left( \underbrace{\prod_{i=1}^t \omega_i P(O_i^{(l)}|X_i^{(l)})}_{\text{Real vaqt kuzatuvlarining tizim holatlariga ta'siri}} \right) P(X_t^{(l)}|O_{1:t-1}) dX_t^l$$

Bu yerda:

- $P(X_{t+1}^{(l)}|X_t^{(l)})$ : Tizimning holatlar o'rta sidagi o'tish ehtimoli.
- $\prod_{i=1}^t \omega_i P(O_i^{(l)}|X_i^{(l)})$ : Real vaqt kuzatuvlarining tizim holatlariga ta'siri, bunda yaqinda kelgan kuzatuvlarning og'irligi kattaroq.
- $P(X_t^{(l)}|O_{1:t-1})$ : Oldingi vaqt momentidagi tizim holati ehtimoli.

**Yuqori darajadagi kuzatuvlar integratsiyasi:** Agar yuqori qatlama (masalan,  $l+1$ ) holatlari va kuzatuvlari mavjud bo'lsa, ular ham prognoz modeliga kiritilishi mumkin:

$$P(X_{t+1}^{(l)}|O_{1:t}) = \int P(X_{t+1}^{(l)}|X_t^{(l)}, X_t^{(l+1)}) P(X_t^{(l)}|O_{1:t-1}) P(O_t^{(l)}|X_t^{(l)}) dX_t^l$$

Prognoz qilishda bir nechta vaqt oralig'ini hisobga olish uchun modelni kengaytirish mumkin:

$$P(X_{t+1}^{(l)}|O_{1:t}) = \int \int P(X_{t+1}^{(l)}|X_t^{(l)}, X_{t-1}^{(l)}) P(X_t^{(l)}|O_{1:t-1}) P(X_{t-1}^{(l)}|O_{1:t-2}^{(l)}) dX_t^l dX_{t-1}^l$$

Tizimga vaqt bo'yicha og'irliklar  $\omega_t$  va kuzatuvning aniqligi (ishonchliligi)  $c_t$  ni birlashtirish mumkin:

$$P(X_{t+1}^{(l)}|O_{1:t}) = \int P(X_{t+1}^{(l)}|X_t^{(l)}) \underbrace{\prod_{i=1}^t \omega_i c_i P(O_i^{(l)}|X_i^{(l)})}_{\text{Tizimga vaqt bo'yicha og'irliklar } \omega_t \text{ va kuzatuvning aniqligi (ishonchliligi) } c_t \text{ ni birlashtirish}} P(X_t^{(l)}|O_{1:t-1}) dX_t^l$$

Ushbu model prognoz qilish jarayonini samarali qiladi, chunki u real vaqt kuzatuvlarining dolzarbligini hisobga oladi va vaqt bo'yicha og'irliklarni integratsiya qiladi. Modelning optimallashtirilgan shakli murakkab tizimlarda, xususan,

monitoring, boshqaruv va prognozlash kabi muhim sohalarda qo‘llanilishi mumkin. Bu yondashuv qaror qabul qilishni tezroq va aniqroq qilishga yordam beradi.

Kuzatuv va holatlarning ehtimollik taqsimotini boyitish orqali ularning o‘zaro ta’sirini optimallashtirish mumkin:

$$P(O_t^{(l)}|X_t^{(l)}) = f(X_t^{(l)}) + \varepsilon$$

bu yerda:

- $f(X_t^{(l)})$  va kuzatuv ( $O_t^{(l)}$ ) o‘rtasidagi bog‘liq funksional munosabat.
- $\varepsilon$ : Kuzatuvdagi shovqin yoki o‘lchovdagi xatolikni ifodalaydi.

Kuzatuv va holatlar o‘rtasidagi bog‘liqni optimallashtirish uchun kuzatuvlardagi shovqin ta’sirini kamaytirish muhimdir. Bu quyidagicha amalga oshiriladi:

**Filtrlash algoritmlari:** Kuzatuvlardagi shovqinni minimallashtirish uchun Kalman filtri, Particle filtri yoki boshqa ehtimollik asosidagi filtrlash usullaridan foydalanish mumkin.

$$P(O_t^{(l)}|X_t^{(l)}) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(O_t^{(l)} - f(X_t^{(l)}))^2}{2\sigma^2}\right)$$

bu yerda  $\sigma^2$  kuzatuvlardagi shovqin dispersiyasidir.

Bir xil holat ( $X_t$ ) bir nechta kuzatuv ( $O_{t1}, O_{t2}, \dots$ ) orqali kuzatilishi mumkin. Bunday holatlarda kuzatuvlar o‘rtasidagi bog‘liqlikni qo‘shib, optimallashtirishga erishiladi:

$$P(O_t|X_t) = \prod_{k=1}^K P(O_t^k|X_t)$$

bu yerda  $K$  — kuzatuvlarning umumiy soni.

Ushbu holatda matematik model quyidagicha ko’rinishda bo’ladi:

$$P(O_t^{(l)}|X_t^{(l)}) = \prod_{k=1}^K \frac{1}{\sqrt{2\pi\sigma_k^2}} \exp\left(-\frac{(O_t^{(l,k)} - f_k(X_t^{(l)}))^2}{2\sigma_k^2}\right)$$

Kuzatuvalar vaqt davomida dinamik xususiyatlarga ega bo‘lishi mumkin. Buni hisobga olish uchun:

$$P(O_t^{(l)}|X_t^{(l)}) = g(X_t^{(l)}, t)$$

bu yerda  $g$  vaqtga bog‘liq funksiyani ifodalaydi.

Kuzatuvalar vaqt davomida dinamik xususiyatlarga ega model quyidagicha ko’rinishga ega bo’ladi.

$$P(O_t^{(l)}|X_t^{(l)}) = \frac{1}{\sqrt{2\pi\sigma^2(t)}} \exp\left(-\frac{(O_t^{(l,k)} - f_k(X_t^{(l)}, t))^2}{2\sigma^2(t)}\right)$$

Holat va kuzatuvlar vaqtga bog‘liq ravishda bog‘lanadi:

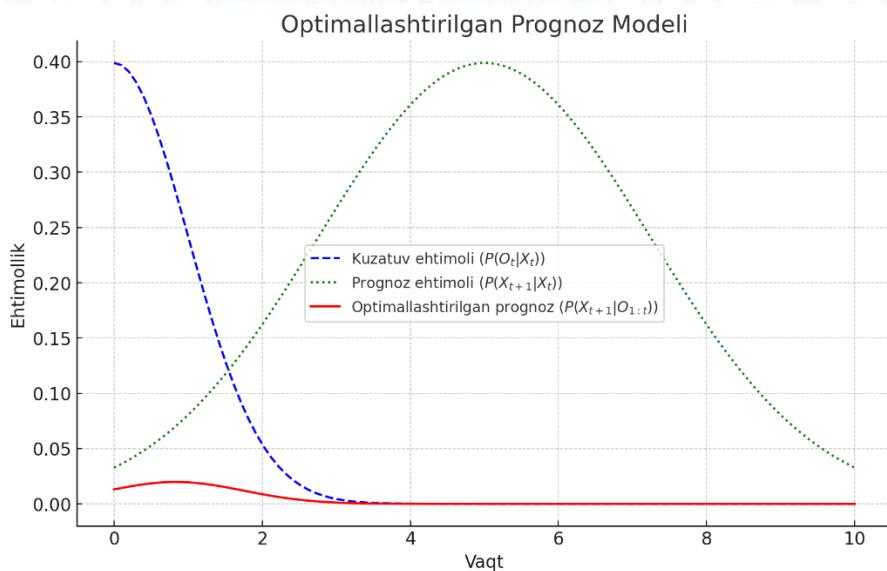
$$P(O_t^{(l)}|X_t^{(l)}) = \int P(O_t^{(l)}|X_t^{(l)}, \tau) P(\tau|t) d\tau$$

bu yerda  $\tau$  — vaqt o‘lchovi.

Optimallashtirishni hisobga olib, kuzatuv va holatlarning bog‘liqligini yangi prognoz modeliga quyidagicha kiritamiz:

$$P(X_{t+1}^{(l)}|O_{1:t}) = \int P(X_{t+1}^{(l)}|X_t^{(l)}) \underbrace{\prod_{i=1}^t \omega_i \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(O_t^{(l)} - f_k(X_t^{(l)}))^2}{2\sigma^2}\right)}_{P(X_t^{(l)}|O_{1:t-1})} dX_t^{(l)}$$

Kuzatuv va holatlarning o‘zaro bog‘liqligini optimallashtirish prognoz qilish aniqligini oshiradi. Ushbu yondashuv real vaqt tizimlarida, monitoring jarayonlarida va murakkab tizimlarda qaror qabul qilishni samarali qilish uchun muhimdir. Modelga shovqinni boshqarish, vaqtga bog‘liq xususiyatlarni qo‘sish va kuzatuvlarni optimallashtirilgan usulda kiritish orqali aniq va tezkor natijalar olinadi 1-rasm.



Yuqoridaǵi grafikda optimallashtirilgan prognoz modelining asosiy komponentlari tasvirlangan:

- Kuzatuv ehtimoli** ( $P(O_t|X_t)$ ) — kuzatuv va holatlarning o‘zaro bog‘liqligini ko‘rsatadi (moviy, chiziqli grafik).
- Prognoz ehtimoli** ( $P(X_{t+1}|X_t)$ ) — tizimning keyingi holatiga o‘tish ehtimoli (yashil, nuqtali grafik).

3. **Optimallashtirilgan prognoz** ( $P(X_{t+1}|O_{1:t})$ ) — kuzatuvlar va prognozlarning kombinatsiyasi (qizil grafik).

Bu grafik kuzatuv va holatlarning birgalikda tahlilini vizual ko'rsatib, optimallashtirilgan prognozlashning samaradorligini namoyish etadi.

### Xulosa

Ushbu maqolada ko‘p darajali axborot tizimlarida qaror qabul qilishni samarali boshqarish uchun ikkinchi va undan yuqori darajadagi mantiqiy to‘plamlar nazariyasiga asoslangan matematik modellar ishlab chiqildi. Dinamik Bayesian tarmoqlar (DBN) orqali murakkab tizimlarning vaqt o‘tishi bilan o‘zgaruvchi ehtimolliklarini modellashtirish imkoniyatlari ko‘rsatildi. Qatlamlı DBNlar yordamida qaror qabul qilish tizimining ierarxik tuzilmasini tashkil etish va real vaqt kuzatuvlari orqali ehtimolliklarni dinamik ravishda yangilash mexanizmlari tahlil qilindi.

Taklif etilgan modellar real vaqt tizimlarida kuzatuvlar dolzarbligini oshirish, ehtimollik taqsimotlarini aniqlashtirish va qaror qabul qilish jarayonini optimallashtirishga yordam beradi. Mazkur yondashuvlar nazariy va amaliy jihatdan qaror qabul qilish tizimlarning samaradorligini oshirishda muhim ahamiyatga ega bo‘lib, monitoring, boshqaruv va prognozlash jarayonlarida qo‘llanilishi mumkin. Natijalar murakkab axborot tizimlarida qaror qabul qilishni tezkor va aniq amalga oshirish imkonini beradi.

### Foydalanilgan adabiyot:

1. Абубов, С. Т. (2006). *Интеллектуальные системы управления*. Алматы: КазНТУ.
2. Глушков, В. М. (1987). *Введение в кибернетику*. Москва: Наука.
3. Дьяконов, В. П. (2006). *MATLAB 7. Спутник инженера*. Москва: Горячая линия – Телеком.
4. Каримов, Б. Ж., & Абдурахмонов, Х. А. (2010). *Моделирование и управление сложными системами*. Ташкент: Ўзбекистон Миллий Энциклопедияси.
5. Мухамедъяров, Р. К. (2012). *Теория вероятностей и математическая статистика в инженерии*. Санкт-Петербург: Лань.
6. Турсунов, Э. А. (2018). *Автоматлаштирилган бошқарув тизимлари: назарий асослари ва амалий масалалари*. Тошкент: ТАТУ нашриёти.
7. Хайтов, Н. Х. (2014). *Ахборот технологиялари ва бошқарув тизимлари*. Тошкент: Ўзбекистон Миллий Энциклопедияси.
8. Чернов, А. А. (2019). *Байесовские сети и их применение в моделировании сложных систем*. Москва: УРСС.