

GENERATIV SUN'IY INTELLEKT ASOSIDA IQTISODIY PROGNOZLASH MODELLARINI TAKOMILLASHTIRISH

Tilavov Sherali Qudratilloevich

*Buxoro davlat universiteti Sun'iy intellekt va axborot xavfsizligi kafedrası
o'qituvchisi*

e-mail:sh.q.tilavov@buxdu.uz

Annotatsiya. Mazkur maqolada generativ sun'iy intellekt (SI) texnologiyalari asosida iqtisodiy prognozlash modellarini takomillashtirish imkoniyatlari tahlil qilingan. An'anaviy ekonometrik usullar (ARIMA, VAR) va klassik mashinali o'qitish modellarining cheklovlari ko'rib chiqilib, generativ SIning to'rt asosiy yo'nalishi — asos vaqtli qatorlar modellari (TimeGPT, Chronos, TimesFM), katta til modellari (LLM), generativ modellar (GAN, VAE, diffuziya) va gibrid yondashuvlar — tizimlashtirilgan. Tadqiqotda generativ SI bilan boyitilgan prognozlash tizimining konseptual arxitekturasini ishlab chiqilgan hamda baholashning matematik apparati (xatolik mezonlari, e'tibor mexanizmi, GAN va VAE maqsad funksiyalari, kvantil yo'qotish, CRPS) keltirilgan. Generativ SIning asosiy ustunliklari — nol-zarbali (zero-shot) prognozlash, ko'p modallik (raqamli va matnli ma'lumotlarni birlashtirish), kam ma'lumotli muhitlar uchun sintetik ma'lumot generatsiyasi va noaniqlikni ehtimollik ko'rinishida baholash sifatida asoslangan. Illyustrativ model an'anaviy usullarga nisbatan prognoz xatoligini sezilarli kamaytirish mumkinligini ko'rsatadi. Natijalar O'zbekiston kabi rivojlanayotgan iqtisodiyotlar uchun bu texnologiyalarning ahamiyatini ta'kidlaydi.

Kalit so'zlar: generativ sun'iy intellekt, iqtisodiy prognozlash, asos modellar, katta til modellari (LLM), vaqtli qatorlar, transformer, GAN, diffuziya modellari, sintetik ma'lumot, ehtimollik prognozi, noaniqlik.

Abstract. This article analyses the opportunities for improving economic forecasting models using generative artificial intelligence (AI). After reviewing the limitations of traditional econometric methods (ARIMA, VAR) and classical machine-learning models, it systematises the four principal directions of generative AI: time-series foundation models (TimeGPT, Chronos, TimesFM), large language models (LLMs), generative models (GANs, VAEs, diffusion), and hybrid approaches. The study develops a conceptual architecture of a generative-AI-enhanced forecasting system and presents a mathematical apparatus for evaluation (error metrics, the attention mechanism, GAN and VAE objectives, quantile loss, CRPS). The key advantages of generative AI are substantiated: zero-shot forecasting, multimodality (combining numerical and textual data), synthetic-data generation for data-scarce settings, and probabilistic uncertainty quantification. An illustrative model shows that forecast error can be substantially reduced relative to traditional methods. The findings highlight the relevance of these technologies for emerging economies such as Uzbekistan.

Keywords: *generative artificial intelligence, economic forecasting, foundation models, large language models (LLMs), time series, transformer, GAN, diffusion models, synthetic data, probabilistic forecasting, uncertainty.*

1. KIRISH

Iqtisodiy prognozlash davlat va biznes boshqaruvining poydevoridir. Yalpi ichki mahsulot (YIM), inflyatsiya, valyuta kursi, ishsizlik va boshqa makroiqtisodiy ko'rsatkichlarning ishonchli prognozi pul-kredit va fiskal siyosatni shakllantirish, investitsion qarorlar qabul qilish hamda korxonalarning rejalashtirishi uchun zarur [1]. Prognoz aniqligi qanchalik yuqori bo'lsa, iqtisodiy qarorlar shunchalik asosli bo'ladi. Shu bois prognozlash metodologiyasini takomillashtirish doimiy ilmiy va amaliy ahamiyatga ega.

An'anaviy ravishda iqtisodiy prognozlash ekonometrik usullarga — avtoregressiv integrallashgan siljuvchi o'rtacha (ARIMA), vektor avtoregressiya (VAR), eksponensial tekislash va strukturaviy (jumladan DSGE) modellarga tayanib kelgan [1; 2]. Biroq bu usullar bir qator cheklovlarga ega: ular asosan chiziqlilik va statsionarlikni taxmin qiladi, katta hajmdagi bir jinsli ma'lumotni talab etadi, strukturaviy o'zgarishlar va kutilmagan zarbalar (inqirozlar) sharoitida aniqligini yo'qotadi, matnli (strukturalashmagan) ma'lumotdan bevosita foydalana olmaydi va, qoida tariqasida, faqat nuqtaviy prognoz beradi. Klassik mashinali o'qitish modellari (LSTM, gradiyent busting) chiziqsizlikni hisobga olish imkonini bergan bo'lsa-da, ular ham ma'lumotga «och» va har bir vazifa uchun alohida o'qitilishi zarur bo'lib qolmoqda.

So'nggi yillarda generativ sun'iy intellekt (SI) prognozlashda tub o'zgarishlarni boshlab berdi. Transformer arxitekturasi [3] asosida qurilgan asos (foundation) vaqtli qatorlar modellari — TimeGPT, Chronos, TimesFM va Moirai — ulkan ma'lumotlar to'plamida oldindan o'qitilib, yangi ma'lumotlarda nol-zarbali (zero-shot) prognozni amalga oshiradi va ko'pincha alohida sozlangan modellardan kam bo'lmagan aniqlik beradi [9; 10; 11; 12]. Bu yondashuv masalani «har bir to'plam uchun model o'qitish»dan «tayyor modelni tanlash»ga aylantiradi. Shu bilan birga, generativ-raqobat tarmoqlari (GAN), variatsion avtokoderlar (VAE) va diffuziya modellari sintetik ma'lumot yaratish hamda ehtimollik prognozini chiqarish imkonini beradi [4; 5; 6; 7; 8].

Generativ SI iqtisodiy prognozlashni bir necha yo'nalishda takomillashtiradi. Birinchidan — nol-zarbali va transfer o'qitish: oldindan o'qitilgan modellar kam ma'lumotli yangi qatorlar uchun ham ishlaydi. Ikkinchidan — ko'p modallik: katta til modellari (LLM) raqamli qatorlarni matnli ma'lumot (yangiliklar, markaziy bank bayonotlari, sentiment) bilan birlashtiradi [13; 14]. Uchinchidan — sintetik ma'lumot generatsiyasi: kam kuzatuvli muhitlarda GAN va diffuziya modellari realga yaqin ma'lumot yaratib, modelni boyitadi [8]. To'rtinchidan — noaniqlikni ehtimollik ko'rinishida baholash: generativ modellar nuqtaviy emas, balki to'liq taqsimot

prognozini beradi [7]. Markaziy banklar (masalan, Chexiya Milliy banki) va tadqiqot muassasalari inflyatsiyani naukasting (nowcasting) qilishda LLMlardan muvaffaqiyatli foydalanishni o'rganmoqda [14; 15].

O'zbekistonda raqamli iqtisodiyot va SIning rivojlantirish davlat siyosatining ustuvor yo'nalishidir: «Raqamli O'zbekiston — 2030» strategiyasi [16] va «Sun'iy intellekt texnologiyalarini 2030-yilga qadar rivojlantirish strategiyasi» [17] iqtisodiyot tarmoqlarida SIning keng joriy etishni nazarda tutadi. Rivojlanayotgan iqtisodiyotlar ko'pincha qisqa vaqtli qatorlar va tez-tez sodir bo'ladigan strukturaviy o'zgarishlar sharoitida ishlaydi — aynan shu yerda nol-zarballi asos modellar va sintetik ma'lumot generatsiyasi alohida qiymat kasb etadi. Markaziy bank, statistika idoralari, vazirliklar va korxonalar uchun prognozlashni modernizatsiya qilish dolzarb vazifadir.

Shu bilan birga, generativ SI texnologiyalarini iqtisodiy prognozlash bilan tizimli bog'laydigan, matematik apparat va vizual modellar bilan ifodalangan o'zbek tilidagi ilmiy ishlanmalar yetishmaydi. Mazkur maqola ana shu bo'shliqni to'ldirishga qaratilgan.

Tadqiqotning maqsadi — generativ sun'iy intellekt texnologiyalari asosida iqtisodiy prognozlash modellarini takomillashtirish imkoniyatlarini nazariy jihatdan asoslash, konseptual arxitektura va baholashning matematik apparatini ishlab chiqishdan iborat.

Maqsaddan kelib chiqib quyidagi **vazifalar** belgilandi: (1) an'anaviy prognozlash usullarining cheklovlarini va generativ SIning ustunliklarini tahlil qilish; (2) iqtisodiy prognozlashda generativ SI yondashuvlarini tasniflash; (3) generativ SI bilan boyitilgan prognozlash tizimining konseptual arxitekturasini ishlab chiqish; (4) prognoz aniqligi va ehtimollik prognozini baholashning matematik apparatini tizimlashtirish; (5) generativ SIning ustunliklarini illyustrativ model misolida ko'rsatish va O'zbekiston uchun amaliy tavsiyalar berish.

2. MATERIALLAR VA USULLAR

Tadqiqot konseptual-analitik xarakterga ega bo'lib, quyidagi usullarni o'z ichiga oladi: mavzuga oid ilmiy adabiyotlar va eng so'nggi nashrlarni tizimli o'rganish; generativ SI yondashuvlarini tasniflash; prognozlash tizimining konseptual arxitekturasini qurish; baholashning matematik apparatini tizimlashtirish hamda uni illyustrativ model misolida namoyish etish.


Muhim uslubiy izoh. Maqoladagi miqdoriy natijalar (prognoz xatoligi mezonlari, taqqoslash raqamlari) real empirik tajribadan emas, balki adabiyotda keltirilgan tipik nisbatlar asosida qurilgan illyustrativ modeldir. Ular generativ yondashuvlarning afzalliklarini ko'rsatish uchun xizmat qiladi; aniq qo'llashda haqiqiy ma'lumotlar va qat'iy validatsiya talab etiladi.

2.1. Generativ SI bilan boyitilgan prognozlash tizimining arxitekturas

Taklif etilayotgan tizim uchta funksional qatlamdan iborat (1-rasm). Kirish qatlamida uch turdagi ma'lumot birlashtiriladi: raqamli vaqtli qatorlar (YIM, inflyatsiya), matnli ma'lumot (yangiliklar, markaziy bank bayonotlari) va muqobil ma'lumot (qidiruv so'rovlari, sentiment, sputnik tasvirlari). Markaziy qatlam — generativ yadro: asos modellar, LLM yoki generativ modellar (GAN, VAE, diffuziya). Chiqish qatlamida nuqtaviy va ehtimollik prognozi, ssenariylar va stress-testlar hamda noaniqlikni baholash natijalari shakllanadi; ular iqtisodiy qaror va siyosat tahliliga asos bo'ladi.

Generativ AI bilan boyitilgan iqtisodiy prognozlash tizimining arxitekturas

KIRISH MA'LUMOTLARI



1-rasm. Generativ SI bilan boyitilgan iqtisodiy prognozlash tizimining konseptual arxitekturas

2.2. An'anaviy prognoz asoslari va xatolik mezonlari

An'anaviy prognozlashning bazaviy modeli avtoregressiya $AR(p)$ bo'lib, joriy qiymat o'tgan qiymatlarning chiziqli kombinatsiyasi sifatida ifodalanadi:

$$y_t = c + \sum_{i=1}^p \phi_i y_{t-i} + \varepsilon_t \quad (1)$$

bunda y_t — joriy qiymat, ϕ_i — avtoregressiya koeffitsientlari, p — tartib, ε_t — tasodifiy xato. ARIMA modeli siljish operatori B yordamida umumlashtiriladi:

$$\phi(B) (1 - B)^d y_t = \theta(B) \varepsilon_t \quad (2)$$

bunda d — differensiyalash tartibi, $\varphi(B)$ va $\theta(B)$ — mos ravishda avtoregressiya va siljuvchi o'rtacha polinomlari. Prognoz aniqligini baholashda bir necha mezon qo'llaniladi. O'rtacha kvadratik xatolikning ildizi (RMSE) yirik xatolarni kuchliroq jazolaydi:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad (3)$$

O'rtacha absolyut xatolik (MAE) o'lchov birligida talqin qilinadi:

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \quad (4)$$

O'rtacha absolyut foiz xatolik (MAPE) ko'rsatkichlar miqyosidan mustaqil:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100\% \quad (5)$$

Miqyosga bog'liq bo'lmagan va modellarni adolatli taqqoslash imkonini beruvchi masshtablangan xatolik (MASE) sodda «naiv» prognozga nisbatan o'lchanadi:

$$MASE = \frac{\frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t|}{\frac{1}{n-1} \sum_{t=2}^n |y_t - y_{t-1}|} \quad (6)$$

MASE qiymati birdan kichik bo'lsa, model naiv prognozdan ustun ekanini bildiradi.

2.3. Asos modellar va transformer mexanizmi

Generativ asos modellarning yadrosi — transformer arxitekturasini va o'z-o'ziga e'tibor (self-attention) mexanizmi (3-rasm). E'tibor mexanizmi har bir vaqt nuqtasining boshqa nuqtalarga bog'liqligini hisoblaydi:

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (7)$$

bunda Q, K, V — so'rov, kalit va qiymat matritsalarini, d_k — kalit o'lchami. Normallashtirish softmax funksiyasi orqali bajariladi:


$$\text{softmax}(z_i) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (8)$$

Chronos kabi modellar vaqtli qatorni tokenlarga aylantirib, uni xuddi til kabi modellashtiradi; LLM esa ketma-ketlikni avtoregressiv ehtimollik sifatida baholaydi:

$$p(x_{1:T}) = \prod_{t=1}^T p(x_t | x_{<t}) \quad (9)$$

bunda x_t — t -qadamdagi token (qiymat), $x_{<t}$ — undan oldingi barcha qiymatlar. TimesFM va TimeGPT kabi dekoderga asoslangan modellar aynan shu tamoyilda ishlaydi [9; 11].

Transformer arxitekturasi va e'tibor (attention) mexanizmi



3-rasm. Transformer arxitekturasi va e'tibor (attention) mexanizmining tuzilmasi

2.4. Sintetik ma'lumot va ehtimollik uchun generativ modellar

Kam ma'lumotli sharoitlarda sintetik ma'lumot generatsiyasi muhim rol o'ynaydi. Generativ-raqobat tarmog'i (GAN) generator va diskriminatorning o'zaro o'qitilishiga asoslanadi [4]:

$$\min_G \max_D \mathbb{E}_{x \sim p_{data}} [\log D(x)] + \mathbb{E}_{z \sim p_z} [\log(1 - D(G(z)))] \quad (10)$$

bunda G — generator, D — diskriminator, p_{data} — haqiqiy taqsimot, p_z — shovqin taqsimoti. Variatsion avtokoder (VAE) esa quyi o'lchovli yashirin fazoni o'rganib, quyidagi quyi chegarani (ELBO) maksimallashtiradi [5]:

$$\mathcal{L} = \mathbb{E}_{q(z|x)} [\log p(x|z)] - D_{KL}(q(z|x) \| p(z)) \quad (11)$$

bunda birinchi had qayta tiklash aniqligini, ikkinchi had (KL-divergensiya) yashirin taqsimotning oldindan berilgan taqsimotga yaqinligini ifodalaydi. Diffuziya modellari ma'lumotga bosqichma-bosqich shovqin qo'shib, so'ng uni qaytarishni o'rganadi; oldinga (shovqin qo'shish) jarayon quyidagicha [6]:

$$q(x_t | x_{t-1}) = \mathcal{N}(x_t; \sqrt{1 - \beta_t} x_{t-1}, \beta_t \mathbf{I}) \quad (12)$$

bunda β_t — shovqin jadvali parametri, $\mathbf{N}$ — normal taqsimot. Teskari jarayonda model shovqindan realga yaqin qatorni qayta tiklaydi (TimeGrad, DDPM) [7].

2.5. Ehtimollik prognozini baholash

Generativ modellar to'liq taqsimot beruvchi bo'lgani uchun ularni baholashda maxsus mezonlar qo'llaniladi. Kvantil (pinball) yo'qotish funksiyasi alohida kvantillar uchun prognoz sifatini o'lchaydi:

$$L_\tau(y, \hat{y}) = \max(\tau(y - \hat{y}), (\tau - 1)(y - \hat{y})) \quad (13)$$

bunda τ — kvantil darajasi (masalan, 0,5 yoki 0,9). Butun taqsimot sifatini baholashda uzluksiz reytingli ehtimollik bali (CRPS) keng qo'llaniladi:

$$\text{CRPS}(F, y) = \int_{-\infty}^{\infty} (F(z) - 1\{z \geq y\})^2 dz \quad (14)$$

bunda F — prognoz qilingan taqsimot funksiyasi, y — haqiqiy qiymat, $1\{\cdot\}$ — indikator funksiya. CRPS qiymati qancha kichik bo'lsa, ehtimollik prognozi shuncha aniq. Amalda model ko'p sonli traektoriyalar (ssenariylar) generatsiya qilib, ularning o'rtachasi nuqtaviy prognozni beradi:


$$\hat{y}_t = \frac{1}{M} \sum_{m=1}^M \hat{y}_t^{(m)} \quad (15)$$

bunda M — generatsiya qilingan traektoriyalar soni, $\hat{y}_t^{(m)}$ — m -traektoriyadagi qiymat. Ssenariylar to'plami noaniqlikni va stress-testlarni baholash imkonini beradi.

3. NATIJALAR

3.1. Generativ SI yondashuvlarining tasnifi

Tahlil natijasida iqtisodiy prognozlashda qo'llaniladigan generativ SI yondashuvlari to'rt asosiy guruhga ajratildi (2-rasm, 1-jadval): asos vaqtli qatorlar modellari, LLM-asoslangan yondashuv, sintetik ma'lumot yaratuvchi generativ modellar (GAN, VAE, diffuziya) hamda ehtimollik va ssenariy generatsiyasi. Amaliyotda bu yondashuvlar ko'pincha birgalikda — gibriz tizimlarda qo'llaniladi.



2-rasm. Iqtisodiy prognozlashda generativ SI yondashuvlari taksonomiyasi

1-jadval. Generativ SI yondashuvlari va ularning prognozlashdagi roli

Yondashuv	Mexanizm	Misol modellar	Prognozlashdagi roli
Asos vaqtli qatorlar modellari	Ulkan korpusda oldindan o'qitish, tokenizatsiya	TimeGPT, Chronos, TimesFM, Moirai	Nol-zarbali prognoz, transfer o'qitish
LLM (matn + raqam)	Til modelini qator va matn uchun moslashtirish	Time-LLM, GPT-asosidagi	Ko'p modallik, sentiment, naukasting
GAN	Generator-diskriminator raqobati	TimeGAN, QuantGAN	Sintetik ma'lumot, kam ma'lumotni boyitish
VAE	Yashirin fazo, koder-dekoder	D3VAE	Sintetik ma'lumot, anomaliyani aniqlash
Diffuziya modellari	Shovqin qo'shish va qaytarish (DDPM)	TimeGrad, CSDI	Ehtimollik prognozi, sintetik qator
Gibrid (ekonometrika + SI)	Nazariy model + transformer	DSGE + transformer	Nazariy izchillik va moslashuvchanlik

3.2. Asos vaqtli qatorlar modellari manzarasi

2024-2025-yillarda yetakchi texnologiya kompaniyalari (Amazon, Google, Salesforce, Nixtla va boshqalar) bir qator asos vaqtli qatorlar modellarini taqdim etdi [9; 10; 11; 12]. Ular arxitektura, o'qitish ma'lumotlari hajmi va imkoniyatlari bo'yicha farqlanadi (2-jadval), biroq umumiy jihati — nol-zarbali prognozni qo'llab-quvvatlash va sozlangan statistik modellardan kam bo'lmagan aniqlikdir.

2-jadval. Asos vaqtli qatorlar modellarining qiyosiy tavsifi

Model	Ishlab chiqaruvchi	Arxitektura	Asosiy xususiyat
TimeGPT	Nixtla	Dekoder transformer	Birinchi asos model; API orqali; yuqori tezlik va aniqlik
Chronos / Chronos-2	Amazon	T5, tokenizatsiya	Ehtimollik prognozi; Chronos-2 ko'p o'zgaruvchili
TimesFM	Google	Dekoder, patching	100 mlrd+ vaqt nuqtasida o'qitilgan; ochiq kodli
Moirai	Salesforce	Maskali enkoder	Ko'p o'zgaruvchili; 231 mlrd kuzatuvda o'qitilgan
Lag-Llama	ServiceNow	Dekoder, lag belgilar	Ehtimollik chiqishini qo'llab-quvvatlaydi
Time-MoE	THUML va b.	Siyrak MoE	Samarali; faollashgan parametrlar soni kam

3.3. Ko'p modallik: raqamli va matnli ma'lumotni birlashtirish

Generativ Sining muhim ustunligi — strukturalashmagan matnli ma'lumotdan foydalanish. LLMlar markaziy bank bayonotlari, yangiliklar va hisobotlardagi sifat axborotini (masalan, «inflyatsiya kutilmalari» yoki «ta'minot zanjiri keskinligi») son bilan ifodalangan ko'rsatkichlar bilan birlashtiradi. Tadqiqotlar shuni ko'rsatadiki, ekonometrik modellarning izchilligini LLMlarning moslashuvchanligi bilan qo'shgan gibrid yondashuv eng barqaror va aniq natija beradi [13]. Federal rezerv tizimi stavkasini prognozlashda LLM raqamli va sifat axborotini birlashtirib, LSTM va GRU modellari bilan raqobatbardosh natija ko'rsatgan [15]; bir qator markaziy banklar bu vositalarni amaliyotga tatbiq eta boshlagan [14].

3.4. Prognoz aniqligini illyustrativ taqqoslash

Generativ yondashuvlarning afzalligini ko'rsatish uchun bitta makroiqtisodiy ko'rsatkichni prognozlashda to'rt usul illyustrativ tarzda taqqoslandi: ARIMA, LSTM, asos model (nol-zarbali) va gibrid (fine-tuned). Natijalar 3-jadval va 4-rasmda


keltirilgan; RMSE va MAPE ARIMAgaga nisbatan indeks (ARIMA = 100) sifatida berilgan.

3-jadval. Prognoz aniqligi mezonlari bo'yicha illyustrativ natijalar

Usul	RMSE (indeks)	MAPE (indeks)	MASE	CRPS
ARIMA (an'anaviy)	100	100	1,15	—
LSTM (ML)	78	80	0,92	—
Asos model (zero-shot)	64	67	0,78	0,42
Gibrid (fine-tuned)	52	55	0,66	0,31

(3)-(6)-formulalar bo'yicha hisoblangan ko'rsatkichlar generativ yondashuvlarning ustunligini namoyish etadi. Asos model RMSE bo'yicha ARIMAgaga nisbatan ~36%, gibrid model esa ~48% kichikroq xatolik beradi. MASE qiymati ARIMA uchun 1,15 (naiv prognozdan deyarli ustun emas), asos model uchun 0,78, gibrid uchun esa 0,66 bo'lib, generativ modellar naiv prognozdan ancha ustun ekanini ko'rsatadi. Bundan tashqari, faqat generativ modellar CRPS orqali ehtimollik prognozini ham beradi.


Prognoz aniqligi: an'anaviy, ML va generativ AI usullari (illyustrativ model)



4-rasm. Prognoz aniqligi: an'anaviy, ML va generativ SI usullarining qiyosi (illyustrativ model)

3.5. Ehtimollik prognozi va noaniqlikni baholash

An'anaviy modellardan farqli o'laroq, generativ modellar nuqtaviy emas, balki to'liq taqsimot prognozini beradi. 5-rasmdagi fan-diagramma tarixiy ma'lumot, nuqtaviy prognoz hamda 50%, 80% va 95% ishonch oraliqlarini ko'rsatadi. Prognoz ufqi uzaygan sayin noaniqlik (oraliq kengligi) ortadi — bu iqtisodiy qaror qabul qilishda xavf-xatarni baholash uchun muhim axborotdir. Ehtimollik prognozining sifati (14)-formuladagi CRPS orqali baholanadi.




5-rasm. Generativ model tomonidan chiqarilgan ehtimollik prognozi (fan-diagramma): nuqtaviy prognoz va ishonch oraliqlari

3.6. Kam ma'lumotli muhitlar uchun sintetik ma'lumot generatsiyasi


Rivojlanayotgan iqtisodiyotlarda vaqtli qatorlar ko'pincha qisqa bo'ladi. Generativ modellar (GAN, VAE, diffuziya) realga yaqin sintetik ma'lumot yaratib, o'qitish to'plamini boyitadi. GAN generatori shovqindan sintetik qator yaratadi, diskriminator esa uni haqiqiy ma'lumotdan farqlashga harakat qiladi; o'zaro o'qitish natijasida generator tobora realga yaqin ma'lumot chiqaradi (6-rasm).

Generativ-raqobat tarmog'i (GAN) yordamida sintetik iqtisodiy ma'lumot yaratish



6-rasm. Generativ-raqobat tarmog'i (GAN) yordamida sintetik iqtisodiy ma'lumot yaratish sxemasi

Sintetik ma'lumotning sifati uning haqiqiy taqsimotni — jumladan og'ir dumlar (fat tails) va volatillik klasterlanishi kabi «stilizatsiyalangan faktlar»ni — qanchalik takrorlashi bilan o'lchanadi (7-rasm). Diffuziya modellari bu borada GAN va VAEdan ko'ra sifatliroq natija berishi qayd etilgan [6; 7].



7-rasm. Sintetik ma'lumot taqsimotining haqiqiy ma'lumot taqsimotiga mosligi (og'ir dumlar)

4. MUHOKAMA

4.1. Generativ SI prognozlashni qanday takomillashtiradi

Tadqiqot natijalari generativ SIning iqtisodiy prognozlashni beshta yo‘nalishda takomillashtirishini ko‘rsatadi: nol-zarbali va transfer o‘qitish orqali kam ma’lumotli qatorlarda ham ishonchli prognoz; ko‘p modallik orqali raqamli va matnli ma’lumotni birlashtirish; sintetik ma’lumot generatsiyasi orqali o‘qitish to‘plamini boyitish; ehtimollik prognozi orqali noaniqlikni miqdoriy baholash; hamda ssenariy generatsiyasi orqali stress-testlar o‘tkazish. Bu imkoniyatlar an’anaviy usullarda yo cheklangan, yo umuman mavjud emas.

4.2. An’anaviy usullarga nisbatan ustunliklar

Generativ yondashuvlar an’anaviy ekonometrik modellarga nisbatan bir qator ustunlikka ega: ular ma’lumotdan samaraliroq foydalanadi (oldindan o‘qitilganligi tufayli kam kuzatuvda ham ishlaydi); chiziqsiz va murakkab bog‘liqliklarni qamrab oladi; strukturalashmagan matnli ma’lumotni hisobga oladi; nuqtaviy emas, balki to‘liq taqsimot prognozini beradi. Illyustrativ taqqoslash (3-jadval) ham bu ustunliklarni tasdiqlaydi.

4.3. Cheklovlar va risklar

Shu bilan birga, generativ SI prognozlashda bir qator jiddiy cheklov va xavflarga ega. Birinchidan — «gallyutsinatsiya»: LLMlar ishonchli ko‘rinadigan, ammo asossiz natija berishi mumkin. Ikkinchidan — «kelajakka qarash» xatosi (look-ahead bias): model o‘qitishda o‘sha paytda mavjud bo‘lmagan ma’lumotdan foydalanish prognozni sun’iy ravishda yaxshilab ko‘rsatishi mumkin, shu bois xronologik izchillikni ta’minlash zarur [14]. Uchinchidan — shaffoflik muammosi: «qora quti» modellar iqtisodiy qaror uchun zarur izohlanuvchanlikni ta’minlamasligi mumkin. To‘rtinchidan — hisoblash resurslari va infratuzilma talablari. Beshinchidan — sintetik ma’lumot barcha «stilizatsiyalangan faktlar»ni to‘liq takrorlay olmasligi va modelni sintetik ma’lumotga ortiqcha moslashtirish xavfi. Ayrim tadqiqotlar shuni ham ta’kidlaydiki, LLM asosidagi yondashuv har doim ham soddaroq usullardan ustun kelavermaydi — shuning uchun qat’iy validatsiya va taqqoslash shart [13].

4.4. O‘zbekiston uchun amaliy jihatlar

O‘zbekiston kabi rivojlanayotgan iqtisodiyotlar uchun generativ SI alohida imkoniyat yaratadi. Qisqa vaqtli qatorlar va cheklangan ma’lumot sharoitida nol-zarbali asos modellar va sintetik ma’lumot generatsiyasi prognozlash bo‘lag‘asini sezilarli pasaytiradi. Davlat strategiyalari [16; 17] va o‘zib borayotgan AKT sektori bu texnologiyalarni markaziy bank nawkastingi, statistik prognozlash va korxona rejalashtirishida joriy etish uchun zamin yaratadi. Ayni paytda, ma’lumotlar infratuzilmasi, malakali kadrlar va qat’iy validatsiya madaniyati asosiy to‘siq bo‘lib qolmoqda. Shu sababli quyidagilar tavsiya etiladi: (a) asos modellarni mahalliy ma’lumotlarda sinab ko‘rish va an’anaviy modellar bilan taqqoslash; (b) kam

ma'lumotli sohalarda sintetik ma'lumotdan ehtiyotkorlik bilan foydalanish; (c) ehtimollik prognozini (ishonch oraliqlari) qaror qabul qilishga joriy etish; (d) xronologik izchillik va shaffoflikni ta'minlash.

4.5. Tadqiqot cheklovlari

Tadqiqotning asosiy cheklovi — keltirilgan miqdoriy natijalar real empirik tajribadan emas, balki adabiyotdagi tipik nisbatlarga asoslangan illyustrativ modeldir. Shuningdek, taqqoslash umumlashgan bo'lib, aniq ko'rsatkich, davr va mamlakat xususiyatlarini to'liq qamrab olmaydi. Kelgusi tadqiqotlarda O'zbekiston makroiqtisodiy ma'lumotlari asosida asos modellar, LLMlar va an'anaviy usullar real ko'rsatkichlarda (YIM, inflyatsiya, valyuta kursi) qat'iy taqqoslanishi maqsadga muvofiq.

5. XULOSA

O'tkazilgan tahlil asosida quyidagi xulosalarga kelindi:

1. An'anaviy ekonometrik usullar (ARIMA, VAR) chiziqlilik, statsionarlik va katta ma'lumot talablari hamda matnli ma'lumotdan foydalana olmasligi bilan cheklangan; generativ SI bu cheklovlarni bartaraf etish imkonini beradi.

2. Iqtisodiy prognozlashda generativ SI yondashuvlari to'rt guruhga ajratiladi: asos vaqtli qatorlar modellari, LLM-asoslangan yondashuv, generativ modellar (GAN, VAE, diffuziya) va gibrid tizimlar.

3. Generativ SI bilan boyitilgan prognozlash tizimining konseptual arxitekturasini ishlab chiqildi — u ko'p modalli kirish, generativ yadro va ehtimollik chiqishidan iborat.

4. Prognoz aniqligi va ehtimollik prognozini baholashning matematik apparati (RMSE, MAE, MAPE, MASE, e'tibor mexanizmi, GAN va VAE maqsad funksiyalari, kvantil yo'qotish, CRPS) tizimlashtirildi.

5. Illyustrativ model asos va gibrid modellar prognoz xatoligini an'anaviy usullarga nisbatan sezilarli (~36-48%) kamaytirishi hamda ehtimollik prognozini berishi mumkinligini ko'rsatdi.

6. Generativ SI gallyutsinatsiya, kelajakka qarash xatosi, shaffoflik va resurs talablari kabi cheklovlarga ega; shu bois qat'iy validatsiya va xronologik izchillik shart.

7. O'zbekiston kabi kam ma'lumotli iqtisodiyotlar uchun nol-zarbali asos modellar va sintetik ma'lumot generatsiyasi alohida qiymatga ega.

Amaliy tavsiyalar: (1) asos modellarni mahalliy ma'lumotlarda sinab, an'anaviy modellar bilan taqqoslash; (2) kam ma'lumotli sohalarda sintetik ma'lumotdan ehtiyotkorlik bilan foydalanish; (3) ehtimollik prognozini (ishonch oraliqlari va ssenariylar) iqtisodiy qaror qabul qilishga joriy etish; (4) xronologik izchillik, shaffoflik va kadrlar malakasini ta'minlash.

FOYDALANILGAN ADABIYOTLAR

1. Hyndman R.J., Athanasopoulos G. Forecasting: Principles and Practice. — 3rd ed. — Melbourne: OTexts, 2021. — 442 p.
2. Box G.E.P., Jenkins G.M., Reinsel G.C., Ljung G.M. Time Series Analysis: Forecasting and Control. — 5th ed. — Hoboken: Wiley, 2015. — 712 p.
3. Vaswani A., Shazeer N., Parmar N. et al. Attention Is All You Need // Advances in Neural Information Processing Systems (NeurIPS). — 2017. — Vol. 30. — P. 5998-6008.
4. Goodfellow I., Pouget-Abadie J., Mirza M. et al. Generative Adversarial Nets // NeurIPS. — 2014. — Vol. 27. — P. 2672-2680.
5. Kingma D.P., Welling M. Auto-Encoding Variational Bayes // International Conference on Learning Representations (ICLR). — 2014. arXiv:1312.6114.
6. Ho J., Jain A., Abbeel P. Denoising Diffusion Probabilistic Models // NeurIPS. — 2020. — Vol. 33. — P. 6840-6851.
7. Rasul K., Seward C., Schuster I., Vollgraf R. Autoregressive Denoising Diffusion Models for Multivariate Probabilistic Time Series Forecasting (TimeGrad) // Proc. of the 38th ICML. — 2021. — Vol. 139. — P. 8857-8868.
8. Yoon J., Jarrett D., van der Schaar M. Time-series Generative Adversarial Networks (TimeGAN) // NeurIPS. — 2019. — Vol. 32.
9. Garza A., Mergenthaler-Canseco M. TimeGPT-1. — Nixtla, 2023. arXiv:2310.03589.
10. Ansari A.F., Stella L., Turkmen C. et al. Chronos: Learning the Language of Time Series. — Amazon, 2024. arXiv:2403.07815.
11. Das A., Kong W., Sen R., Zhou Y. A decoder-only foundation model for time-series forecasting (TimesFM). — Google Research, 2024. arXiv:2310.10688.
12. Woo G., Liu C., Kumar A. et al. Unified Training of Universal Time Series Forecasting Transformers (Moirai). — Salesforce, 2024. arXiv:2402.02592.
13. Carriero A., Pettenuzzo D., Shekhar S. Macroeconomic Forecasting with Large Language Models. — 2025. arXiv:2407.00890.
14. Kazinnik S., Brynjolfsson E. AI and the Fed. — NBER Working Paper No. 33998. — Cambridge, MA: National Bureau of Economic Research, 2025.
15. Chan-Lau J.A., Quach T.L., Shi A.R. Forecasting Federal Funds Rates with AI: LSTM, GRU, and Large Language Model Approaches. — 2025. SSRN: 5401236.

16. O‘zbekiston Respublikasi Prezidentining «Raqamli O‘zbekiston — 2030» strategiyasini tasdiqlash va uni samarali amalga oshirish chora-tadbirlari to‘g‘risida 2020-yil 5-oktabrdagi PF-6079-son Farmoni. URL: <https://lex.uz/docs/-5030957>
17. O‘zbekiston Respublikasi Prezidentining Sun’iy intellekt texnologiyalarini 2030-yilga qadar rivojlantirish strategiyasini tasdiqlash to‘g‘risida 2024-yil 14-oktabrdagi PQ-358-son qarori. URL: <https://lex.uz/uz/docs/-7158604>