# MOLIYAVIY YANGILIKLARNI KLASSIFIKATSIYALASHDA TRANSFORMER MODELLARNING QIYOSIY TAHLILI

**Abdullayev A. Sh.**
Abu Rayhon Beruniy nomidagi Urganch davlat universiteti,
Kompyuter injiniringi fakulteti

**ANNOTATSIYA.**

Ushbu maqolada moliyaviy yangiliklarni avtomatik klassifikatsiyalash masalasida qo‘llaniladigan transfer o‘rganish (transfer learning) va transformer arxitekturasiga asoslangan modellar qiyosiy tahlil qilinadi. Domenga moslashtirilgan FinBERT oilasi (Araci, Yang va Liu variantlari), FLANG, hamda yirik generativ modellar — BloombergGPT, FinGPT va FinMA — arxitekturasi, oldindan o‘qitish strategiyasi, hisoblash xarajati va aniqlik ko‘rsatkichlari bo‘yicha solishtiriladi. Tahlil natijalari shuni ko‘rsatadiki, klassifikatsiya kabi tor vazifalarda ixcham encoder modellar ko‘pincha o‘nlab milliard parametrli generativ modellardan kam emas, balki ulardan ustun natija beradi. Maqolada, shuningdek, kam resursli va ko‘p tilli sharoit, jumladan o‘zbek tilidagi moliyaviy matnlar uchun amaliy tavsiyalar keltirilgan.

**Kalit so‘zlar:** transfer o‘rganish, transformer, FinBERT, BloombergGPT, moliyaviy NLP, matn klassifikatsiyasi, domenga moslashtirish, kam resursli tillar.

## 1. Kirish

Moliyaviy bozorlar har soniyada katta hajmdagi matnli axborot — yangiliklar lentalari, kompaniya hisobotlari, regulyator e’lonlari va ijtimoiy tarmoq xabarlari — ishlab chiqaradi. Bu axborotni qo‘lda kuzatib borish imkonsiz bo‘lgani sababli, moliyaviy yangiliklarni avtomatik tarzda toifalarga ajratish (klassifikatsiyalash) tabiiy tilni qayta ishlash (Natural Language Processing, NLP) sohasining muhim amaliy vazifalaridan biriga aylangan. Klassifikatsiya bu yerda keng ma’noda tushuniladi: sentiment (ijobiy/neytral/salbiy), mavzuviy toifalash, narxga ta’sir qiluvchi va ta’sir qilmaydigan xabarlarni ajratish, hamda nomli ob’yektlarni aniqlash (NER) bilan bog‘liq tasniflash kabilar shu doiraga kiradi.

Moliyaviy matn umumiy maqsadli matndan jiddiy farq qiladi: unda soha terminologiyasi zich, ko‘p ma’nolilik yuqori, hamda “o‘sish”, “pasayish”, “risk” kabi so‘zlarning sentiment qiymati kontekstga bog‘liq. Loughran va McDonald [4] ko‘rsatib bergan klassik misol — umumiy lug‘atlarda salbiy hisoblangan ko‘plab so‘zlar moliyaviy hujjatlarda neytral ma’no tashishi — soha uchun maxsus yondashuv zarurligini asoslaydi. An’anaviy lug‘atga asoslangan usullar va statistik mashinaviy o‘qitish (masalan, SVM yoki LSTM) ushbu nozikliklarni yetarlicha qamrab ololmadi.

2018-yilda BERT [2] modelining paydo bo‘lishi NLP sohasida tub burilish yasadi: katta korpusda oldindan o‘qitilgan (pre-trained) modelni kichik belgilangan ma’lumotlar bilan moslashtirish (fine-tuning) orqali yuqori aniqlikka erishish mumkin bo‘ldi. Aynan shu transfer o‘rganish g‘oyasi moliyaviy NLP uchun hal qiluvchi ahamiyat kasb etdi, chunki sohada belgilangan (labelled) ma’lumotlar tanqis. Ushbu maqolaning maqsadi — moliyaviy yangiliklarni klassifikatsiyalashda qo‘llanilayotgan transfer/transformer modellarini tizimli ravishda qiyoslash, ularning kuchli va zaif tomonlarini ko‘rsatish hamda kam resursli tillar uchun amaliy xulosalar chiqarishdan iborat.

## 2. Moliyaviy matnni klassifikatsiyalashning o‘ziga xosligi

Moliyaviy klassifikatsiyaning murakkabligi bir nechta omil bilan izohlanadi. Birinchidan, domen tili: “bull”, “bear”, “short”, “hedge” kabi terminlar umumiy ma’nosidan tubdan farq qiladi. Ikkinchidan, sentimentning implitsit (yashirin) ifodalanishi: “kompaniya prognozdan past daromad e’lon qildi” jumlasi salbiy sentiment so‘zlarsiz ham salbiy. Uchinchidan, sinflar nomutanosibligi (class imbalance): neytral xabarlar ko‘pincha ustun bo‘lib, F1-me’yor (ayniqsa makro-F1) aniqlikdan ko‘ra adolatliroq baho beradi.

Soha uchun etalon (benchmark) ma’lumotlar to‘plamlari shu kontekstda shakllangan. Eng ko‘p ishlatiladigani — Financial PhraseBank [5], unda moliyaviy yangilik jumlalari uch sinfga (ijobiy/neytral/salbiy) ajratilgan. FiQA SA esa sentimentni regressiya (uzluksiz ball) sifatida baholaydi, Headline va FiNER-ORD kabi to‘plamlar esa sarlavhalarni tasniflash va nomli ob’yektlarni aniqlashga mo‘ljallangan. Aynan shu to‘plamlar quyida qiyoslanadigan modellarning umumiy “o‘lchov mezoni” bo‘lib xizmat qiladi.

## 3. Transfer o‘rganish va transformer arxitekturasi

Transfer o‘rganish — bitta vazifada (odatda katta korpusda oldindan o‘qitishda) olingan bilimni boshqa, ko‘pincha kam ma’lumotli vazifaga ko‘chirish g‘oyasidir. NLP da bu yondashuv ELMo va ULMFiT bilan boshlangan bo‘lsa-da, transformer arxitekturasi [8] uni sanoat darajasiga ko‘tardi. Transformer “e’tibor” (self-attention) mexanizmi orqali har bir so‘zning butun jumla kontekstidagi bog‘lanishini parallel hisoblaydi va shu bilan kontekstga sezgir vektor tasvirlarini hosil qiladi.

Moliyaviy NLP da transformer modellari ikki katta oilaga ajraladi. Birinchisi — encoder asosidagi modellar (BERT va uning variantlari): ular matnni ikki tomonlama (bidirectional) tahlil qiladi va klassifikatsiya, NER kabi “tushunish” vazifalariga juda mos. Ikkinchisi — decoder asosidagi generativ modellar (GPT oilasi, BloombergGPT): ular matn yaratish, savol-javob va few-shot o‘rganishga mo‘ljallangan. Quyidagi tahlilning markaziy savoli

— tor klassifikatsiya vazifasida qaysi oila samaraliroq degan masaladir.

## 4. Domenga moslashtirilgan modellar tahlili

### 4.1. FinBERT oilasi

FinBERT atamasi ostida bir nechta mustaqil model yashiringani ko‘p chalkashlikka sabab bo‘ladi. Birinchi va eng ko‘p iqtibos qilinadigani — Araci [1] ishi: u BERT modelini Reuters TRC2-financial korpusi asosida qo‘shimcha oldindan o‘qitib, so‘ngra Financial PhraseBank da fine-tuning qilgan. Ushbu yondashuv moliyaviy sentiment klassifikatsiyasida oldingi eng yaxshi natijani taxminan 14 foiz punktga oshirib, transfer o‘rganishning soha uchun samaradorligini amalda isbotladi.

Ikkinchi muhim variant — Yang va boshqalar [13] taklif qilgan FinBERT bo‘lib, u taxminan 4,9 milliard tokenli moliyaviy kommunikatsiya korpusida o‘qitilgan va uchta sentiment to‘plamida bazaviy BERT dan ustun chiqqan. Uchinchisi — Liu va boshqalar [3] ning ko‘p vazifali oldindan o‘qitishga asoslangan FinBERT moliyaviy matn qazib olish (text mining) uchun mo‘ljallangan. Ushbu variantlar nomi bir xil bo‘lsa-da, korpus, hajm va baholash protokoli bo‘yicha farq qiladi; shu sababli ilmiy ishlarda aniq iqtibos (qaysi FinBERT) ko‘rsatilishi shart.

### 4.2. FLANG

FLANG [6] — moliyaviy domen uchun BERT va ELECTRA negizida qurilgan model bo‘lib, asosiy yangiligi “afzal ko‘riluvchi token niqoblash” (preferential token masking) usulidir: oldindan o‘qitishda moliyaviy terminlar yuqori ehtimol bilan niqoblanadi, bu esa model e’tiborini soha leksikasiga yo‘naltiradi. FLANG mualliflari, shuningdek, FLUE (Financial Language Understanding Evaluation) etalon to‘plamini taqdim etishdi; u sentiment, sarlavha klassifikatsiyasi, NER va savol-javob kabi vazifalarni qamrab oladi va keyingi qiyosiy tadqiqotlar uchun standart o‘lchovga aylandi.

### 4.3. BloombergGPT va generativ modellar

BloombergGPT [9] — moliya uchun noldan o‘qitilgan birinchi yirik til modeli (LLM). U 50 milliard parametrga ega decoder-only transformer bo‘lib, Bloomberg ning xususiy ma’lumotlaridan tuzilgan taxminan 363 milliard tokenli FinPile korpusi hamda 345 milliard tokenli umumiy korpus aralashmasida o‘qitilgan. Model sentiment, NER va savol-javob kabi vazifalarda o‘xshash hajmdagi ochiq modellardan sezilarli ustunlikni namoyish etib, ayni paytda umumiy NLP etalonlarida ham raqobatbardosh bo‘lib qoldi.

Biroq generativ yondashuvning cheklovlari ham aniq. Bir qator mustaqil tadqiqotlar (masalan, korpus xilma-xilligi ta’sirini o‘rgangan ishlar) ko‘rsatdiki, FPB va NER vazifalarida bazaviy BERT, RoBERTa va ixtisoslashgan encoder modellar — parametrlari o‘nlab marta kam bo‘lishiga qaramay — in-context (few-shot) rejimda ishlagan

BloombergGPT dan ustun chiqishi mumkin. Bu klassifikatsiya kabi yaxshi belgilangan, tor vazifalarda fine-tuning qilingan ixcham modellar generativ LLM larning kontekst orqali o‘rganishidan ko‘ra ishonchliroq ekanini ko‘rsatadi.

FinGPT [12] muqobil yo‘lni tanladi: noldan o‘qitish o‘rniga ochiq LLM larni LoRA (Low-Rank Adaptation) usuli bilan moliyaviy ma’lumotlarda arzon va tez moslashtiradi. Baholashlar shuni ko‘rsatdiki, FinGPT ba’zi vazifalarda BloombergGPT dan ham ustun chiqib, hisoblash va xotira xarajatini bir necha barobar kamaytiradi. PIXIU/FinMA [10] esa instruksiyaga moslashtirilgan ochiq model va baholash to‘plamini birlashtirib, soha tadqiqotlari uchun ochiq infratuzilma yaratdi.

**5. Modellarning qiyosiy tahlili**

Quyidagi jadvalda asosiy modellar arxitektura turi, oldindan o‘qitish korpusi, taxminiy hajmi va klassifikatsiya vazifasidagi amaliy mavqei bo‘yicha umumlashtirilgan. Aniq raqamli ko‘rsatkichlar baholash protokoli (fine-tuning yoki few-shot), ma’lumotlarning bo‘linishi va metrika tanloviga sezilarli bog‘liq bo‘lgani sababli, jadvalda mutlaq sonlar emas, balki nisbiy xususiyatlar keltirilgan.

| Model | Arxitektura | Oldindan o‘qitish korpusi | Hajmi | Klassifikatsiyada mavqei |
|---|---|---|---|---|
| FinBERT (Araci, 2019) | Encoder (BERT) | TRC2-financial + Financial PhraseBank | ~110M | Etalon baza, yuqori va barqaror |
| FinBERT (Yang, 2020) | Encoder (BERT) | ~4,9 mlrd token moliyaviy kommunikatsiya | ~110M | Sentimentda BERT dan ustun |
| FLANG-BERT / ELECTRA | Encoder | SEC, Reuters, Investopedia + token niqoblash | ~110M | FLUE etalonida kuchli |
| BloombergGPT (2023) | Decoder (LLM) | FinPile ~363 mlrd + ~345 mlrd umumiy | 50B | Ko‘p vazifali; few-shotda beqaror |
| FinGPT (2023) | Decoder + LoRA | Ochiq LLM ustiga moliyaviy fine-tuning | 7–13B | Arzon, moslashuvchan |

| Model | Arxitektura | Oldindan o‘qitish korpusi | Hajmi | Klassifikatsiyada mavqei |
|---|---|---|---|---|
| FinMA / PIXIU (2023) | Decoder (instruksiya) | Instruksiyaga moslashtirilgan moliyaviy korpus | 7–30B | Ochiq baholash uchun qulay |

*1-jadval. Moliyaviy klassifikatsiya modellarining qiyosiy xususiyatlari*

Jadvaldan uchta asosiy xulosa kelib chiqadi. Birinchidan, samaradorlik va xarajat o‘rtasidagi muvozanat: ixcham encoder modellar (taxminan 110 million parametr) klassifikatsiyada yirik LLM larga teng yoki ulardan yuqori natija berib, o‘qitish va joriy etish xarajatini keskin kamaytiradi. Ikkinchidan, vazifaga moslik: generativ modellarning afzalligi (matn yaratish, izohlash, few-shot) klassifikatsiyada to‘liq ochilmaydi, chunki bu vazifa “tushunish”ga, ya’ni encoder kuchli bo‘lgan sohaga tegishli. Uchinchidan, korpus muhimligi: model hajmidan ko‘ra, oldindan o‘qitish korpusining soha bilan mosligi va sifati ko‘pincha natijaga kuchliroq ta’sir ko‘rsatadi.

**6. Baholash etalonlari (benchmark)**

Modellarni adolatli qiyoslash uchun standart etalonlar zarur. FLUE [6] moliyaviy NLP uchun dastlabki yaxlit to‘plamni taqdim etgan bo‘lsa, FinBen [11] uni 24 ta vazifaga kengaytirib, klassifikatsiyadan tashqari bashoratlash, risk boshqaruvi va qaror qabul qilish kabi murakkab vazifalarni ham qamrab oldi. FinMTEB [7] esa vektor tasvirlash sifatini 64 ta to‘plam orqali baholaydi. Bunday etalonlar va ularga bog‘liq ochiq reyting jadvallari (Open Financial LLM Leaderboard) tadqiqot natijalarining takrorlanuvchanligini ta’minlaydi.

Shuni alohida ta’kidlash kerakki, etalon natijalarini taqqoslashda ma’lumotlar bo‘linishi (train/test split) va metrikaning bir xilligiga e’tibor berish lozim. Ko‘p sinfli vazifalarda makro-F1, nomutanosib to‘plamlarda esa vaznli F1 ko‘rsatkichi sof aniqlikdan adolatliroq baho beradi. Maqolalarda turli bo‘linish va metrikalar bo‘yicha keltirilgan raqamlarni to‘g‘ridan-to‘g‘ri solishtirish metodologik xatoga olib kelishi mumkin.

**7. Kam resursli va ko‘p tilli kontekst**

Yuqorida qaralgan modellarning aksariyati ingliz tiliga mo‘ljallangan. Boshqa tillar uchun ikki yo‘nalish rivojlangan: birinchisi — soha modelini noldan yoki davomli o‘qitish (masalan, nemis tili uchun German FinBERT, xitoy tili uchun Mengzi-fin va BBT-FinT5, yapon tili uchun JaFIn instruksiya to‘plami); ikkinchisi — ko‘p tilli bazaviy modellardan (mBERT, XLM-RoBERTa) transfer qilish. German FinBERT misoli ko‘rsatadiki, soha uchun maxsus oldindan o‘qitilgan model umumiy ko‘p tilli modeldan 1–2 foiz punktga

ustun chiqishi mumkin, ammo buning uchun yetarli korpus talab etiladi.

O‘zbek tili kabi kam resursli tillar uchun amaliy strategiya quyidagicha shakllanadi. Belgilangan ma’lumotlar tanqis bo‘lganda noldan model o‘qitish maqsadga muvofiq emas; aksincha, ko‘p tilli encoder (XLM-RoBERTa yoki mBERT) ni mavjud o‘zbekcha moliyaviy korpusda davomli oldindan o‘qitish (continued pre-training), so‘ngra kichik belgilangan to‘plamda fine-tuning qilish samaraliroqdir. Ma’lumot kamligini yengish uchun translatsiya orqali kengaytirish (masalan, inglizcha Financial PhraseBank ni tarjima qilish), distillyatsiya va sintetik ma’lumot yaratish kabi usullardan foydalanish mumkin. Bunda model qarorlarining tushunarliligini ta’minlash uchun LIME yoki SHAP kabi izohlash usullarini qo‘shish maqsadga muvofiq.

## 8. Muammolar va kelajak yo‘nalishlari

Birinchi muammo — ma’lumotlar tanqisligi va sifati: moliyaviy belgilangan to‘plamlar kam, qimmat va ko‘pincha bir tilga bog‘langan. Ikkinchisi — domenning vaqt bo‘yicha siljishi (temporal/concept drift): bozor leksikasi va kontekst tez o‘zgaradi, shu sababli statik korpusda o‘qitilgan model eskirishga moyil. Uchinchisi — tushuntirib berish (explainability): moliyaviy qarorlar yuqori javobgarlikka ega bo‘lgani uchun “qora quti” modellar amaliyotda cheklangan ishonchga ega; izohlanuvchi AI (XAI) usullari shu sababli zarur. To‘rtinchisi — gallyutsinatsiya va xolislik (bias): generativ LLM lar noto‘g‘ri faktlar yaratishi yoki ma’lumotdagi tizimli xolislikni kuchaytirishi mumkin.

Kelajak yo‘nalishlari sifatida quyidagilar ko‘rinadi: parametrlarni samarali moslashtirish (LoRA, adapterlar) orqali katta modellarni arzonlashtirish; ko‘p modal yondashuv (matn + sonli/tabular ma’lumot) bilan yangilik va bozor ko‘rsatkichlarini birga tahlil qilish; ko‘p tilli va kam resursli tillar uchun maxsus korpus va etalonlar yaratish; hamda retrieval-augmented generation (RAG) orqali modelni dolzarb manbalarga bog‘lab, gallyutsinatsiyani kamaytirish. Aynan shu yo‘nalishlar o‘zbek tilidagi moliyaviy NLP tadqiqotlari uchun ham istiqbolli zamin yaratadi.

## 9. Xulosa

Moliyaviy yangiliklarni klassifikatsiyalashda transfer o‘rganish va transformer arxitekturasi hal qiluvchi rol o‘ynaydi. Qiyosiy tahlil shuni ko‘rsatdiki, klassifikatsiya kabi tor va yaxshi belgilangan vazifalarda domenga moslashtirilgan ixcham encoder modellar (FinBERT oilasi, FLANG) samaradorlik–xarajat muvozanati bo‘yicha eng oqilona tanlov bo‘lib qolmoqda; yirik generativ modellar (BloombergGPT, FinGPT) esa ko‘p vazifali, generativ va few-shot stsenariylarda ustunlik beradi. Model hajmini oshirish har doim ham aniqlikni oshirmaydi — bunda korpusning soha bilan mosligi va baholash metodologiyasining to‘g‘riligi ko‘proq ahamiyatga ega.

O‘zbek tili kabi kam resursli tillar uchun eng amaliy yo‘l — ko‘p tilli encoder modellardan transfer qilish, soha korpusida davomli oldindan o‘qitish hamda izohlanuvchanlikni ta’minlash. Bu yo‘nalishdagi keyingi tadqiqotlar o‘zbekcha moliyaviy etalon to‘plamlarni yaratish va modellarni shu to‘plamlarda tizimli baholashga qaratilishi maqsadga muvofiq.

**Foydalanilgan adabiyotlar**


1. Araci, D. (2019). FinBERT: Financial Sentiment Analysis with Pre-trained Language Models. arXiv:1908.10063. https://arxiv.org/abs/1908.10063
2. Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. NAACL-HLT. https://arxiv.org/abs/1810.04805
3. Liu, Z., Huang, D., Huang, K., Li, Z., & Zhao, J. (2020). FinBERT: A Pre-trained Financial Language Representation Model for Financial Text Mining. IJCAI-20, 4513–4519. https://doi.org/10.24963/ijcai.2020/622
4. Loughran, T., & McDonald, B. (2011). When Is a Liability Not a Liability? Textual Analysis, Dictionaries, and 10-Ks. The Journal of Finance, 66(1), 35–65. https://doi.org/10.1111/j.1540-6261.2010.01625.x
5. Malo, P., Sinha, A., Korhonen, P., Wallenius, J., & Takala, P. (2014). Good Debt or Bad Debt: Detecting Semantic Orientations in Economic Texts. JASIST, 65(4), 782–796. https://doi.org/10.1002/asi.23062
6. Shah, R., Chawla, K., Eidnani, D., Shah, A., Du, W., Chava, S., Raman, N., Smiley, C., Chen, J., & Yang, D. (2022). When FLUE Meets FLANG: Benchmarks and Large Pretrained Language Model for Financial Domain. EMNLP, 2322–2335. https://aclanthology.org/2022.emnlp-main.148/
7. Tang, Y., & Yang, Y. (2025). FinMTEB: Finance Massive Text Embedding Benchmark. arXiv:2502.10990. https://arxiv.org/abs/2502.10990
8. Vaswani, A., Shazeer, N., Parmar, N., et al. (2017). Attention Is All You Need. NeurIPS. https://arxiv.org/abs/1706.03762
9. Wu, S., Irsoy, O., Lu, S., et al. (2023). BloombergGPT: A Large Language Model for Finance. arXiv:2303.17564. https://arxiv.org/abs/2303.17564
10. Xie, Q., Han, W., Zhang, X., Lai, Y., Peng, M., Lopez-Lira, A., & Huang, J. (2023). PIXIU: A Large Language Model, Instruction Data and Evaluation Benchmark for Finance. NeurIPS Datasets and Benchmarks. https://arxiv.org/abs/2306.05443
11. Xie, Q., Han, W., Chen, Z., et al. (2024). FinBen: A Holistic Financial Benchmark for Large Language Models. NeurIPS Datasets and Benchmarks. https://arxiv.org/abs/2402.12659

12. Yang, H., Liu, X.-Y., & Wang, C. D. (2023). FinGPT: Open-Source Financial Large Language Models. FinLLM at IJCAI. arXiv:2306.06031. https://arxiv.org/abs/2306.06031
13. Yang, Y., Uy, M. C. S., & Huang, A. (2020). FinBERT: A Pretrained Language Model for Financial Communications. arXiv:2006.08097. https://arxiv.org/abs/2006.08097