



UDK: 004.912(091)

**Botir ELOV,**

*ToshDO'TAU dotsenti, t.f.d*

*E-mail: elov@navoiy-uni.uz*

*ORCID: 0000-0001-5032-6648*

**Zilola XUSAINOVA,**

*ToshDO'TAU dotent v.b., PhD*

*E-pochta: xusainovazilola@navoiy-uni.uz*

*ORCID: 0000-0003-4357-7515*

*O'zMU professori v.b., f.f.d M.Abdurahmanova taqrizi asosida*

### FORMATION AND DEVELOPMENT STAGES OF THE NATURAL LANGUAGE PROCESSING (NLP) FIELD

Annotation

This article systematically analyzes the formation and development stages of the natural language processing field. The study covers the main evolutionary periods in NLP history, including rule-based and grammatical approaches, semantic and symbolic models, statistical methods, as well as deep learning and large pre-trained language models, based on scientific sources. In the literature review process, the initial ideas of machine translation, conceptual ontologies, corpus-based statistical models, and the formation of modern neural architectures are analyzed sequentially. Additionally, the contributions of the attention mechanism, Transformer architecture, and transfer learning approaches to the development of NLP are highlighted. The conducted analysis serves as an important scientific foundation for identifying the theoretical and methodological bases of modern NLP systems and for developing effective automatic text analysis models for low-resource languages, particularly the Uzbek language.

**Key words:** NLP history, machine translation, classical models, statistical models, deep learning, word embedding, seq2seq, attention mechanism, Transformer, pre-trained language models.

### ФОРМИРОВАНИЕ И ЭТАПЫ РАЗВИТИЯ ОБЛАСТИ ОБРАБОТКИ ЕСТЕСТВЕННОГО ЯЗЫКА (NLP)

Аннотация

В этой статье систематически анализируются формирование и этапы развития области обработки естественного языка. В исследовании на основе научных источников освещаются основные эволюционные периоды истории NLP, включая подходы на основе правил и грамматики, семантические и символические модели, статистические методы, а также глубокое обучение и крупные предобученные языковые модели. В процессе обзора литературы последовательно анализируются первоначальные идеи машинного перевода, концептуальные онтологии, статистические модели на основе корпусов и формирование современных нейронных архитектур. Кроме того, показан вклад механизма внимания, архитектуры Transformer и подходов transfer learning в развитие NLP. Проведенный анализ служит важной научной основой для определения теоретических и методологических основ современных систем NLP и для разработки эффективных моделей автоматического анализа текста для языков с низкими ресурсами, в частности узбекского языка.

**Ключевые слова:** история NLP, машинный перевод, классические модели, статистические модели, глубокое обучение, word embedding, seq2seq, механизм внимания, Transformer, предобученные языковые модели.

### TABIIY TILNI QAYTA ISHLASH (NLP) SOHASINING SHAKLLANISHI VA RIVOJLANISH BOSQICHLAR

Annotatsiya

Ushbu maqolada tabiiy tilni qayta ishlash sohasining shakllanishi va rivojlanish bosqichlari tizimli ravishda tahlil qilinadi. Tadqiqotda NLP tarixining asosiy evolyutsion davrlari, qoidalarga assolangan va grammatik yondashuvlar, semantik modellar, statistik usullar hamda chuqur o'rganish va katta oldindan o'rgatilgan til modellari bosqichlari ilmiy manbalar asosida yoritiladi. Adabiyotlar sharhi jarayonida mashina tarjimasining dastlabki g'oyalari, kontseptual ontologiyalar, korpusga asoslangan statistik modellar va zamonaviy neyron arxitekturalarning shakllanishi ketma-ketlikda tahlil qilinadi. Shuningdek, attention mexanizmi, Transformer arxitekturasi va transfer learning yondashuvlarining NLP rivojiga qo'shgan hissasi ko'rsatib beriladi. O'tkazilgan tahlil zamonaviy NLP tizimlarining nazariy va metodologik asoslarini aniqlash hamda kam resursli tillar, xususan o'zbek tili uchun samarali avtomatik matn tahlili modellarini ishlab chiqishda muhim ilmiy asos bo'lib xizmat qiladi.

**Kalit so'zlar:** NLP tarixi, mashina tarjima, klassik modellar, statistik modellar, chuqur o'rganish, word embedding, seq2seq, attention mexanizmi, Transformer, oldindan o'rgatilgan til modellari.

**Kirish.** Tabiiy tilni qayta ishlash (Natural Language Processing, NLP) inson tilini kompyuter yordamida tahlil qilish, tushunish va qayta ishlashga qaratilgan fanlararo ilmiy yo'nalish bo'lib, u lingvistika, matematika, sun'iy intellekt va hisoblash texnologiyalari kesishmasida shakllangan. Liddy[1] ta'kidlaganidek, NLP tabiiy matnlarni turli lingvistik darajalarda leksik, morfologik, sintaktik, semantik va

pragmatik sathlarda modellashtirishga asoslangan hisoblash usullari majmuasini o'z ichiga oladi. Ushbu usullarning maqsadi turli vazifalar yoki ilovalarda insonga yaqin tilni qayta ishlashni ta'minlashdir. So'nggi yillarda NLP sohasiga nisbatan ko'proq qiziqish paydo bo'lgan bo'lsa-da, aslida bu yo'nalishda tadqiqotlar 1940-yillarning oxiridan boshlab bir necha o'n

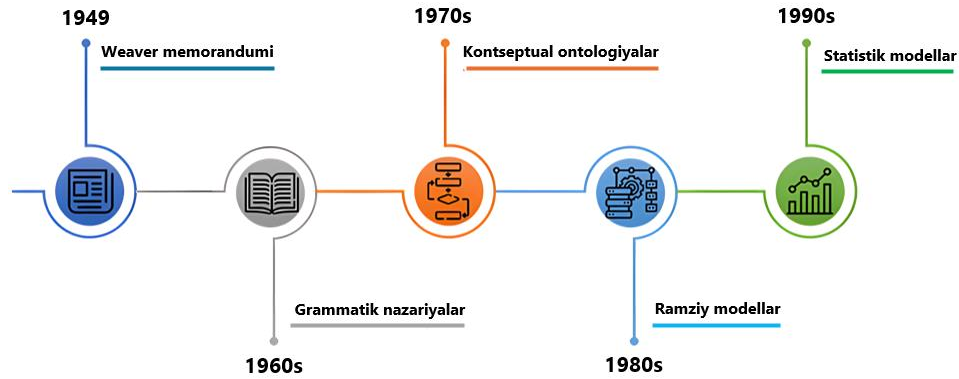
yilliklar davomida olib borilgan. NLPning tarixiy rivojlanishi shartli ravishda ikki asosiy bosqichga ajratiladi:

chuqur o'rganish davrigacha bo'lgan klassik bosqich  
chuqur o'rganish (deep learning) asosidagi zamonaviy bosqich

Chuqur o'rganish davrigacha bo'lgan klassik bosqich NLP sohasidagi dastlabki ilmiy g'oyalar XX asrning o'rtalariga to'g'ri keladi. 1949-yilda U.Weaver tomonidan ilgari surilgan mashina tarjimasini haqidagi memorandum tabiiy tilni avtomatik qayta ishlash g'oyasining boshlanishi sifatida

qaraladi. Ushbu davrda tadqiqotlar asosan qo'lda ishlab chiqilgan lingvistik qoidalar, lug'atlar va grammatik modellar asosida olib borildi.

1950–1960-yillarda generativ grammatika nazariyasining rivojlanishi tilni formal qoidalar orqali ifodalashga imkon yaratdi. Biroq ALPAC hisobotida mashina tarjimasining real amaliy natijalarga yetmaganligi tanqid qililib, ushbu yo'nalishga ajratilgan moliyalashtirish keskin kamaytirildi. Natijada NLP tadqiqotlari ma'lum muddat sekinlashdi.



1-rasm. Chuqur o'rganish davrigacha bo'lgan NLPning asosiy bosqichlari

Keyinchalik bu g'oya ko'plab loyihalarga turtki bo'ldi. Jumladan, IBM va Jorjtaun Universiteti hamkorligida o'tkazilgan Jorjtaun tajribasi (Georgetown experiment)[2] davomida 60 dan ortiq ruscha gaplarni ingliz tiliga mashina yordamida muvaffaqiyatli tarjima qilish namoyish etilgan edi. Tadqiqotchilar bunga qo'lda ishlab chiqilgan lingvistik qoidalar yordamida erishdilar. Biroq bu usul umumiy ma'noda tarjima vazifasini keng ko'lamda hal eta olmadi. Dastlabki mashina tarjimasini ishlanmalari juda sodda bo'lib, aksariyat tizimlar tarjima qilish uchun lug'at bo'yicha so'zlarni izlab topadi va tarjimadan so'ng so'zlarni yakuniy til grammatikasi qoidalariga muvofiq qayta tartiblashardi. Tabiiy tilga xos leksik noaniqlik, bir so'zning bir nechta ma'noga egaligi hisobga olinmaganligi bois bunday yondashuv qoniqsiz natijalarni berdi.

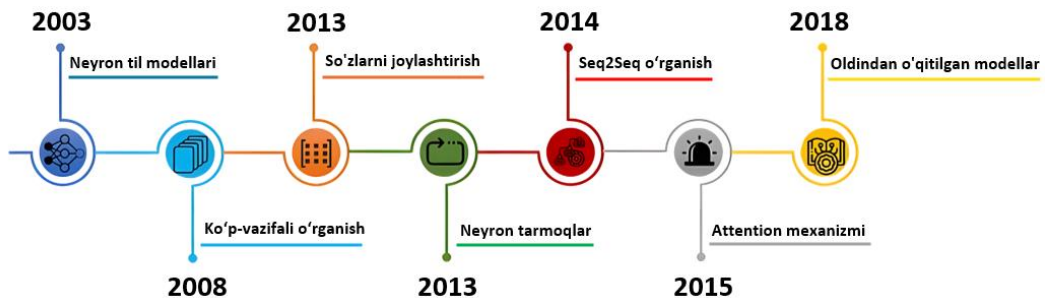
1950-yillarda tilning sintaktik nazariyasi va tahlil (parsing) algoritmlarining rivojlanishi tufayli tabiiy tilni qayta ishlashda burilish yasadi. O'sha paytda ko'plab mutaxassislar yaqin bir necha yil ichida avtomatik ravishda inson tarjimasidan sifat jihatidan qolishmaydigan yuqori sifatli to'liq mashina tarjimasini tizimlari yaratish mumkinligiga jiddiy ishonishgan. Ammo o'sha davrdagi til haqidagi mavjud bilimlar va kompyuter tizimlarining imkoniyatlaridan kelib chiqilganda, bu qarash mutlaqo haqiqatdan yiroq edi. 1966-yilda AQSH Milliy

Fanlar Akademiyasi qoshidagi ALPAC (Automatic Language Processing Advisory Committee) nomli qo'mita o'z hisobotini e'lon qildi. Ushbu hisobotda mashina tarjimasini yaqin kelajakda amalga oshiriladigan darajada emasligi xulosa qililib, tadqiqotchilar jamoasiga bu yo'nalishga ajratilgan mablag'larni to'xtatishni tavsiya qildi. Natijada bu xulosa nafaqat mashinada tarjima izlanishlarini, balki NLPning boshqa ko'plab qo'llanmalari bo'yicha ishlarni ham keskin sekinlashtirib yubordi.

1980-yillarga kelib NLPda bilimga asoslangan (knowledge-based) yondashuvlar ustunlik qila boshladi. Ushbu yondashuvlar qo'lda tuzilgan ontologiyalar, qoidalar va skriptlar asosida matnni tushunishga qaratilgan edi [3]. Biroq bunday tizimlar yuqori murakkablik, moslashuvchanlikning pastligi va ko'p mehnat talab etishi bilan cheklangan edi.

1990-yillarda esa NLPda tub burilish yuz berdi. Statistika va ehtimollikka asoslangan modellar keng qo'llanila boshlandi [4]. Statistika til modellari, yashirin Markov modellari, qaror daraxtlari va korpusga asoslangan yondashuvlar qo'lda yozilgan qoidalariga muqobil sifatida shakllandi. Bu davr NLPni empirik fan sifatida rivojlantirib, katta hajmdagi matn korpuslaridan foydalanish imkonini berdi.

Chuqur o'rganish (deep learning) asosidagi zamonaviy bosqich



2-rasm. Chuqur o'rganish davridagi NLPning asosiy bosqichlari

Bu davr 2003-yildan 2018-yilgacha bo'lgan muhim bosqichlarni, dastlabki neyron til modellaridan tortib oldindan

o'rgatilgan katta til modellari paydo bo'lishigacha qamrab oladi.

2000-yillardan boshlab NLPda neyron tarmoqlar asosidagi modellar jadal rivojlana boshladi. Bu vazifa matnda oldingi so'zlar ketma-ketligidan foydalanib keyingi so'zni bashorat qilishni maqsad qilgan.

Bengio tomonidan taklif etilgan neyron til modeli va so'z embedding tushunchasi zamonaviy NLP uchun poydevor bo'ldi[5]. Keyinchalik Word2Vec modeli so'zlarning zich vektorli tasvirlarini samarali o'rganish imkonini yaratdi va semantik munosabatlarni vektorlar fazosida ifodalashni ta'minladi. U bitta yashirin qatlamli oldinga yo'naltirilgan neyron tarmoqdan iborat edi. Shuningdek, ular hozirda "word embedding" deb ataladigan, so'zning *Rd* o'lchovli sonli vektorida ifodalinishini ham birinchilardan bo'lib joriy etdilar. Ularning modelida kirish sifatida oldingi *n* ta so'zning modelning o'zi bilan birga o'rgatilgan maxsus jadvaldan topib olingan vektor tasvirlari kiritilgan. Ushbu vektorlar yashirin qatlamga uzatilgan va u yerda qayta ishlangach, natijaviy holat ketma-ketlikdagi navbatdagi so'zni bashorat qiluvchi softmax qatlamiga uzatilgan.

2013–2015-yillarda rekurrent neyron tarmoqlar (RNN), LSTM va CNN modellarining NLPga tatbiqi matni ketma-ketlik sifatida chuqur modellashtirishga olib keldi. Ayniqsa, ketma-ketlikdan ketma-ketlikka (sequence-to-sequence) arxitekturalar va diqqat (attention) mexanizmi mashina tarjimai va matn generatsiyasida sezilarli yutuqlarni ta'minladi[6]. Biroq, rekurrent modellar "katastrofik unutish" deb ataluvchi muammoga moyil bo'lib, vaqt o'tishi bilan uzoqdagi holatlarni "esdan chiqarib qo'yishi" mumkin edi[7]. Shuningdek, Bengio taklif qilgan modeldagi umumiy qurilish elementlari bugungi kunda ham aksariyat neyron til modellari va so'z embedding modellarda uchraydi.

2008-yilda Collobert va Weston neyron tarmoqlarda ko'p-vazifali o'rganish (multi-task learning) tamoyilini NLPga tatbiq etdilar[8]. Ular bir dona CNN konvolyutsion neyron tarmoq arxitekturasidan foydalandilar. Ushbu yagona tarmoqqa gapni kiritgan holda, bir vaqtning o'zida bir nechta tilni qayta ishlash vazifalarini bajarish, so'z turkumlarini teglash (POS-tagging), nomlangan obyektlarni aniqlash (NER-tagging) va semantik rollarni tayinlash mumkin bo'ldi. Barcha vazifalar bo'yicha tarmoq bir vaqtda o'qitilib, bu jarayonda lug'aviy ko'rsatkichlar jadvalining vaznlari, embedding jadvalining weight-sharing mexanizmidan foydalanildi. Bu esa turli modellar uchun so'zlarning embedding matritsasidagi umumiy past darajali xususiyatlaridan foydalanish imkonini berdi. Bundan tashqari, Collobert va Westoning mazkur tadqiqoti ko'p-vazifali o'rganish doirasidan tashqariga ham ta'sir ko'rsatdi. Ularning ishida so'z embeddinglarini oldindan o'rgatish (pre-training) va matni qayta ishlashda CNN arxitekturasidan foydalanish g'oyalari ilgari surildi.

Oldindan o'rgatilgan embeddinglarni modellarni boshlang'ich holatida foydalanish turli quyi vazifalarda natijalarni sezilarli yaxshilashini ko'rsatgan dalillar so'z embeddinglarini hozirgi NLPning ajralmas qismiga aylantirdi. So'nggi yillarda ko'plab yangi model va usullar paydo bo'lganiga qaramay, Word2Vec hali ham mashhur bo'lib, amaliyotda keng qo'llanilmoqda.

2013-yil, shuningdek, NLPda neyron tarmoq modellarining ommaviy ravishda joriy etila boshlagan yili bo'ldi, xususan rekurrent neyron tarmoqlar, konvolyutsion neyron tarmoqlar (CNN) va rekursiv neyron tarmoqlar[9] keng qo'llanila boshlandi. Arxitektura xususiyatlari tufayli RNNlar kiritilayotgan ma'lumotlar ketma-ketligi bilan ishlashda juda qulay edi. Biroq oddiy RNNlar tez orada klassik LSTM modellariga yo'l berdi, chunki LSTMlar RNNlarda kuzatilgan yo'qoluvchi va portlovchi gradient muammolariga ancha chidamlir oq ekanini ko'rsatdi. Shu bilan birga, o'sha paytda kompyuter tasviri sohasida keng qo'llanila boshlagan CNNlar

NLPga ham tatbiq etila boshlandi. Matnli ketma-ketliklarini qayta ishlashda CNNning afzalligi shundaki, RNNlardan farqli ravishda unda har bir pozitsiyadagi holat faqatgina mahalliy kontekstga bog'liq bo'ladi va butun oldingi ketma-ketlik holatlarini to'liq hisobga olmaydi.

Rekursiv neyron tarmoqlar inson tilining iyerarxik tuzilishiga asoslangan g'oyalardan ilhomlanib yaratilgan: so'zlar birikib gaplarni, gaplar esa o'z navbatida maxsus hosil qilish qoidalari (production rules) orqali rekursiv tarzda murakkabroq tuzilmalarga birlashadi. Ushbu yondashuv asosida rekursiv neyron tarmoqlar jumalarni oddiy ketma-ketlik sifatida emas, balki daraxtsimon tuzilma sifatida ko'rib chiqadi. Ayrim tadqiqotlar hatto RNN va LSTMlarni ham ana shunday iyerarxik tuzilmalarda qo'llash mumkinligini ko'rsatdi [10].

2014-yilda Sutskever va hammualliflar ketma-ketlikdan ketma-ketlikka o'rganish (sequence-to-sequence learning) arxitekturasini taklif etdilar[11]. Bu bir ketma-ketlikni (gapni) boshqa bir ketma-ketlikka (tarjima jumlasiga) to'liq oxirigacha xaritalashga imkon beruvchi umumiy yondashuvdir. Ularning usulida enkoder neyron tarmoq kirish jumlasini belgi ketma-ketligi sifatida qayta ishlaydi va uni vektorli tasvirga siqadi. So'ng dekoder neyron tarmoq enkoderning yakuniy holati va har bir bosqichda avvalgi bosqichda chiqarilgan belgi asosida chiqish ketma-ketligini belgima-belgi generatsiya qiladi.

Mashina tarjimai ketma-ketlikdan ketma-ketlikka o'rganish arxitekturasini qo'llash uchun ayniqsa qulay vazifa bo'lib chiqdi. Taraqqiyot shu darajada katta bo'ldiki, Google kompaniyasi 2016-yilda Google Translate tizimidagi avvalgi yirik ibora-asosli (phrase-based) mashina tarjimai modellari o'rnini neyron ketma-ketlikdan ketma-ketlikka modelga to'liq o'tkazayotganini rasman e'lon qildi.

So'nggi yillarda esa Transformer arxitekturasini va oldindan o'rgatilgan yirik til modellari (BERT, GPT, ELMO) NLPda yangi bosqichni boshlab berdi. Ushbu modellar katta hajmdagi korpuslarda o'qitilib, keyinchalik aniq vazifalarga moslashtiriladi. Natijada, kam resursli tillar, jumladan o'zbek tili uchun ham yuqori samarador NLP tizimlarini yaratish imkoniyati paydo bo'ldi.

2015-yilda Bahdanau neyron mashinada tarjima arxitekturasidagi muhim kashfiyot diqqat mexanizmini (attention) joriy etdi[6]. Bu yangilik NMT modellarining klassik gap-asosli tarjima tizimlaridan ustun kelishini ta'minlagan asosiy g'oya edi. Diqqat mexanizmi ketma-ketlikdan ketma-ketlikka o'rganishdagi eng katta cheklovni bartaraf etadi, ya'ni manba jumlaning butun ma'nosini bitta fikserlangan o'lchamli vektorga siqish zaruriyatini yo'qotadi. Buning o'rniga, dekoder neyron tarmoq o'z jarayonida qayta-qayta manba jumlaning yashirin holatlariga murojaat qilishi mumkin bo'ladi. U enkoder ishlab chiqqan ichki tasvirlardan og'irlikli o'rtacha hisoblab, har bir bosqichda qo'shimcha kirish sifatida foydalanadi.

Diqqat mexanizmi kirishdagi muayyan qismlarga e'tibor qaratish talab qilinadigan istalgan vazifada qo'l kelishi mumkin. Hozirgi vaqtda u tuzilma bo'yicha tahlil (constituency parsing), matni tushunish (reading comprehension) va bir necha namunadan o'rganish (one-shot learning) kabi NLP masalalarida muvaffaqiyatli qo'llanildi. Yaqinda diqqat mexanizmining yangi turi – o'z-o'ziga diqqat (self-attention) paydo bo'ldi va u Transformer arxitekturasining markaziy qismiga aylandi. Qisqasi, self-attention gap yoki paragrafdagi boshqa so'zlarni hisobga olgan holda har bir so'zning kontekstga sezgirroq tasvirini hosil qilishga xizmat qiladi.

NLP sohasidagi so'nggi yirik innovatsiya, shubhasiz, katta oldindan o'rgatilgan til modellari (pre-trained language models) bo'ldi. Ular dastlab 2015-yilda taklif etilgan bo'lsa-da,

faqat yaqindagina juda xilma-xil vazifalarda ilgari erishilgan eng yuqori natijalardan sezilarli darajada ustunlik berishini namoyish etdi. Oldindan o'rgatilgan til modelidan olingan til tasvirlarini maqsadli model uchun xususiyat sifatida ishlatish yoki oldindan o'rgatilgan til modelini maqsadli vazifa ma'lumotlarida moslashtirib o'qitish (fine-tuning) yo'li bilan foydalanish mumkin[12]. Bu yondashuvlar modeli kam

hajmdagi teglangan ma'lumotlar bilan yuqori samaradorlikka erishishini ko'rsatib berdi.

Ushbu oldindan o'rgatilgan yirik til modellarning eng katta afzalligi shundaki, ular katta hajmdagi teglanmagan matn korpuslaridan so'zlarning ifodaviy tasvirlarini mustaqil ravishda o'rganishga qodir.

1-jadval. NLP sohasining shakllanishi va rivojlanish bosqichlari

Davr	Bosqich nomi	Izoh (ilmiy tavsif)
1949	Weaver memorandum (Mashina tarjimasining boshlanishi)	U. Weaver tomonidan mashina tarjima g'oyasi ilgari surilib, tabiiy tillarni kompyuter yordamida qayta ishlash konseptual asoslari yaratildi. Ushbu bosqichda NLP qoidalarga asoslangan va qo'lda tuzilgan lingvistik modellar asosida rivojlandi.
1960-yillar	Grammatik nazariyalar	Generativ grammatika (N. Chomsky) asosida tilning formal sintaktik modellashtirilishi amalga oshirildi. Biroq leksik noaniqlik va kontekstga sezgirlik muammolari yetarli darajada hal etilmadi.
1970-yillar	Kontseptual ontologiyalar	Til ma'nosini va qoidalarni modellashtirishga yo'naltirilgan yondashuvlar (case grammar, conceptual dependency) shakllandi. NLP semantik tahlil bosqichiga o'ta boshladi.
1980-yillar	Ramziy modellar	Qoidalarga asoslangan tizimlar, skriptlar va ontologiyalar yordamida matn tushunish modellarini yaratish yo'lga qo'yildi.
1990-yillar	Statistik modellar	Korpusga asoslangan ehtimollik yondashuvlari (n-gram, HMM) joriy etilib, NLP empirik fan sifatida rivojlandi. Qo'lda yozilgan qoidalardan bosqichma-bosqich voz kechila boshlandi.
2003	Neuron til modellari	Bengio va hammualliflar tomonidan neyron ehtimollik til modeli taklif etilib, so'z embeddinglari tushunchasi NLPga kiritildi. Bu chuqur o'rganishga o'tish uchun asos bo'ldi.
2008	Ko'p-vazifali o'rganish (Multi-task Learning)	Bitta neyron model orqali bir nechta NLP vazifalarini parallel o'rganish konsepsiyasi joriy etildi va modellar umumiyashuv qobiliyatini oshirdi.
2013	Word Embeddings (Word2Vec)	So'zlarning semantik va sintaktik munosabatlarini vektor fazosida ifodalash imkoniyati yaratildi. NLP amaliyotida sifat jihatidan yangi bosqich boshlandi.
2013	Neuron tarmoqlar (RNN, LSTM, CNN)	Ketma-ketliklarni chuqur modellashtirish orqali kontekstga sezgir NLP tizimlari ishlab chiqildi. Matn tushunish va generatsiya qilish sifati sezilarli oshdi.
2014	Seq2Seq o'rganish	Ketma-ketlikdan ketma-ketlikka xaritalash paradigmasi shakllandi va mashina tarjima hamda matn generatsiyasi vazifalarida keng qo'llanila boshlandi.
2015	Attention mexanizmi	Modelning muhim kontekst qismlariga e'tibor qaratish mexanizmi joriy etilib, NLP tizimlarining aniqligi va tushunish qobiliyati sezilarli darajada yaxshilandi.
2018-hozirgacha	Oldindan o'rgatilgan yirik til modellari	Transformer arxitekturasi asosidagi BERT, GPT, ELMO kabi modellar paydo bo'lib, NLPda transfer learning va fine-tuning paradigmasi ustuvor bo'ldi. Kam resursli tillar uchun ham yuqori samaradorlik ta'minlandi.

Tahlil shuni ko'rsatadiki, NLP sohasining rivojlanishi ramziy modellardan statistik yondashuvlarga, undan esa chuqur o'rganish va yirik til modellariga evolyutsion tarzda o'tgan.

**Xulosa.** Adabiyotlar sharhi natijalaridan tabiiy tilni qayta ishlash sohasining rivojlanishi izchil evolyutsion xarakterga ega ekanligini, dastlab qo'lda ishlab chiqilgan lingvistik qoidalar va grammatik modellar asosida boshlanganligini ko'rishimiz mumkin. Keyinchalik semantik yondashuvlar til ma'nosini chuqur modellashtirishga imkon

yaratib, ularning masshtablash va moslashuvchanlik imkoniyatlari cheklanganligi aniqlandi.

So'nggi yillarda chuqur o'rganish va oldindan o'rgatilgan til modellari NLP rivojida sifat jihatidan yangi bosqichni boshlab berdi. Transformer arxitekturasi va attention mexanizmi asosidagi modellar kontekstga sezgir, yuqori aniqlikka ega va ko'p vazifali NLP tizimlarini yaratish imkonini berdi. Ushbu yondashuvlar, ayniqsa, teglangan ma'lumotlar hajmi cheklangan kam resursli tillar uchun amaliy ahamiyat kasb etadi.

#### ADABIYOTLAR

- Liddy E.D. Natural Language Processing // Encyclopedia of Library and Information Science. – New York: Marcel Dekker, 2001. – P. 2126–2136.
- Thistlethwaite F., Dostert L. The Great Experiment: Machine Translation. – Washington, DC, 1955. – 98 p.
- Charniak E. Passing markers: A theory of contextual influence in language comprehension // Cognitive Science. – 1983. – Vol. 7, No. 3. – P. 171–190.
- Brown P.F. et. al. Word-sense disambiguation using statistical methods // Proceedings of the 29th Annual Meeting of the Association for Computational Linguistics. – 1991. – P. 264–270.
- Bengio Y. et. al. A neural probabilistic language model // Journal of Machine Learning Research. – 2003. – Vol. 3. – P. 1137–1155.
- Bahdanau D. et. al. Neural machine translation by jointly learning to align and translate // arXiv preprint. – 2014. – arXiv:1409.0473.
- Daniluk M. et. al. Frustratingly short attention spans in neural language modeling // arXiv preprint. – 2017. – arXiv:1702.04521.
- Collobert R., Weston J. A unified architecture for natural language processing // Proceedings of the 25th International Conference on Machine Learning (ICML). – 2008. – P. 160–167.
- Socher R. et. al. Recursive deep models for semantic compositionality over a sentiment treebank // Proceedings of EMNLP 2013. – P. 1631–1642.
- Tai K.S. et. al. Improved semantic representations from tree-structured LSTM networks // arXiv preprint. – 2015. – arXiv:1503.00075.
- Sutskever I. et. al. Sequence to sequence learning with neural networks // Advances in Neural Information Processing Systems. Vol. 27. 2014. – P. 3104–3112.
- Devlin J. et. al. BERT: Pre-training of deep bidirectional transformers for language understanding // Proceedings of NAACL-HLT 2019. – P. 4171–4186.