

e-ISSN 3060-5059

DOI: 10.67227



IJTIMOYIY-GUMANITAR SOHADA ILMIY-INNOVATSION TADQIQOTLAR

ILMIY METODIK JURNAL

Scientific and Innovative Research in
Social and Humanitarian Studies

Vol. 3 • Issue 7

2026



Founded in 2024



publishscience.uz



publish_science_journal@mail.ru



PEER REVIEWED • OPEN ACCESS

LEKSIKOGRAFIK VA MORFOLOGIK RESURLARNI RAQAMLASHTIRISHDAGI METODIK TO'SIQLAR

Ibragimov Javlon Yormatovich

Axborot texnologiyalari va menejment universiteti, dotsent (PhD).

e-mail: ibragimovjavlon@mail.com ORCID: <https://orcid.org/0009-0005-6785-4910>

Annotatsiya.

Mazkur maqolada o'zbek tili uchun leksikografik va morfologik resurslarni raqamlashtirish jarayonida uchrayotgan metodik muammolar tahlil qilinadi. Tadqiqotda an'anaviy leksikografik manbalarni elektron muhitga moslashtirish, morfologik tahlilchilar yaratish, ma'lumotlarni formatlash va standartlashtirish, semantik modellashirish hamda teglash tizimlarini ishlab chiqish bilan bog'liq muammolar yoritilgan.

Kalit so'zlar: raqamli leksikografiya, morfologik tahlilchi, elektron lug'at, raqamlashtirish, semantik annotatsiya, teglash tizimi, NLP, korpus lingvistikasi, agglutinatativ til, lemmatizatsiya, ontologiya, morfologik modellashirish, raqamli resurslar, til texnologiyalari.

МЕТОДИЧЕСКИЕ БАРЬЕРЫ В ЦИФРОВИЗАЦИИ ЛЕКСИКОГРАФИЧЕСКИХ И MORFOLOGICHESKIX RESURSOV

Ibragimov Javlon Yormatovich

Университет информационных технологий и менеджмента, доцент (PhD).

Аннотация.

В данной статье анализируются методологические проблемы, возникающие в процессе оцифровки лексикографических и морфологических ресурсов узбекского языка. Исследование охватывает проблемы, связанные с адаптацией традиционных лексикографических ресурсов к электронной среде, созданием морфологических анализаторов, форматированием и стандартизацией данных, семантическим моделированием и разработкой систем тегирования.

Ключевые слова: цифровая лексикография, морфологический анализатор, электронный словарь, оцифровка, семантическая аннотация, система тегирования, НЛП, корпусная лингвистика, агглютинативный язык, лемматизация, онтология, морфологическое моделирование, цифровые ресурсы, языковые технологии.

METHODOLOGICAL BARRIERS IN THE DIGITALIZATION OF LEXICOGRAPHIC AND MORPHOLOGICAL RESOURCES

Ibragimov Javlon Yormatovich

University of Information Technologies and Management, Associate Professor (PhD).

Abstract.

This article analyzes the methodological challenges arising in the process of digitizing lexicographic and morphological resources of the Uzbek language. The study covers issues related to the adaptation of traditional lexicographic resources to the digital environment, the creation of morphological analyzers, data formatting and standardization, semantic modeling, and the development of tagging systems.

Keywords: digital lexicography, morphological analyzer, electronic dictionary, digitization, semantic annotation, tagging system, NLP, corpus linguistics, agglutinative language, lemmatization, ontology, morphological modeling, digital resources, language technologies.

Kirish. O'zbek tili uchun raqamlashtirish jarayonining eng og'ir va sekin rivojlanayotgan yo'nalishlaridan biri leksikografik hamda morfologik resurslarni zamonaviy formatda qayta yaratishdir. Chunki tilni raqamli maydonga olib chiqish uchun, avvalo, undagi barcha so'zlar, shakllar, grammatik belgilar va ma'no munosabatlarini aniq hamda izchil ifodalovchi elektron lug'atlar, morfologik tahlilchilar, ma'lumotlar bazalari va teglash (annotatsiya) tizimlari zarur. O'zbek tilshunosligida bu yo'nalishlar tarixan shakllana boshlagan bo'lsa-da, ularning hozirgi holati metodik jihatdan ancha

parchalanib ketgan. Mazkur parchalanishning ildizi metodika, yondashuv va tuzilma darajasida kuzatiladi.

Mavzuga oid adabiyotlarning tahlili (Literature review). Avvalo, o'zbek leksikografiyasi an'anaviy lug'at tuzish madaniyatiga ega. Bu lug'atlar ilmiy jihatdan yuksak darajada yaratilgan, lekin bosma shaklga mo'ljallangan edi. Bosma lug'atlar tizimi kompyuter tomonidan qayta ishlanishga mos emas: ularning ma'lumot tuzilmalari (makro- va mikrostruktura), belgilar, sarlavhalar, qisqartmalar, ko'rsatkichlar va izohlar o'rtasidagi bog'lanishlar formal emas, ya'ni strukturaviy kodlanmagan. Shuning uchun ularni elektron shaklga o'tkazish shunchaki skanerlash yoki PDF yaratish degani emas, balki ichki semantik modelini qayta qurish demakdir. Tilshunoslar L.L. Shestakova va A.S. Kulevalar ta'kidlaganidek: "Zamonaviy leksikografiyani raqamlashtirish va til materialini samarali lug'atlashtirish talablari leksikograflar vazifalarini ham o'zgartirdi" [1:94–113]. Aynan mana shu bosqichda metodik to'siqlar boshlanadi: eski lug'atlar semantik bog'lanishlarga, kompyuter esa formal strukturalarga tayanadi. Tilshunoslikda mavjud "ma'no", "so'z turi", "ko'chma ma'no", "uslubiy qatlam" kabi kategoriyalarni mashina uchun o'qiladigan formatga o'tkazishning yagona metodikasi hali-hanuz ishlab chiqilmagan.

Raqamli leksikografiya uchun asosiy metodik yondashuv – ma'lumotlarni belgilash va tipologik modellashtirish. Bunda har bir so'z uchun morfologik, sintaktik, semantik, uslubiy va etimologik atributlar aniqlanadi. Ammo o'zbek tilshunosligida bu atributlar to'liq formallashtirilmagan. Masalan, so'z turkumini belgilashda ayrim lug'atlarda "ot", "fe'l", "sifat" kabi kategoriyalar ishlatilsa, boshqalarida "predmet nomi", "harakat bildiruvchi so'z" kabi tabiiy tildagi tavsiflar keltiriladi. Bu mashina tili uchun mos emas, chunki dasturiy tizim sintaktik bir xillikka tayanadi. Shuning uchun o'zbek leksikografiyasi raqamli bosqichga o'tishda formal belgilash tizimini yaratish muammosi bilan to'qnash kelmoqda.

Tadqiqot metodologiyasi (Research Methodology). Ikkinchi metodik to'siq – ma'lumotlarni morfologik darajada tahlil qilish uchun zarur bo'lgan qo'shimcha vositalarning yetishmasligi. Har qanday raqamli til resursining asosi morfologik tahlilchidir. Ingliz, rus yoki turk tillarida bu tahlilchilar (lemmatizator, stemmer, tagger) allaqachon mukammal ishlab chiqilgan. O'zbek tili **agglutinativ** tuzilishga ega bo'lgani sababli morfologik modellashtirish yanada murakkab: bitta so'z o'nlab grammatik qo'shimchalar bilan turlanadi, morfemalar ketma-ketligi o'zgaruvchan. Masalan, "borolmaydiganlardansizmi" so'zining segmentatsiyasi juda ko'p qatlamli: o'zak + "qodirlik" affiksi + inkor + sifatdosh + ko'plik + kelishik + shaxs-son + so'roq yuklamasi. Bunday so'zlarni tahlil qilish uchun murakkab morfologik generatorlar kerak bo'ladi. Hozircha o'zbek tili uchun bunday tahlilchilar faqat tajriba darajasida mavjud va ularning aniqlik darajasi past. Chunki morfemalar to'plami to'liq raqamlashtirilmagan hamda grammatik kategoriyalar o'rtasidagi formal bog'lanishlar belgilab chiqilmagan.

Uchinchi metodik to'siq – leksikografik ma'lumotlarning formatlashdagi nomuvofiqliklar. O'zbek tilidagi elektron lug'atlar turli formatlarda ishlab chiqilmoqda: ba'zilar TXT yoki DOC fayllari shaklida, boshqalari XML, CSV yoki JSON formatida. Har bir format o'z standartiga ega, ammo umumiy qoidaning yo'qligi ularni bir tizimga keltirishni qiyinlashtiradi. Masalan, XML formatidagi lug'atda so'z "word" tegi ostida berilsa, JSON lug'atida u "lemma" sifatida ifodalanadi. Shuning uchun leksikografik ma'lumotlarning almashuviga xizmat qiluvchi yagona texnik standart ishlab chiqilmagan. Bu "O'zbek tilining raqamli leksik portal" kabi integratsion platformalarning kechikishiga sabab bo'lmoqda.

Yana bir muhim to'siq – mavjud leksik manbalarni raqamli semantizatsiya qilishdagi qiyinchiliklar. Har qanday raqamli lug'at faqat shaklni emas, ma'noni ham ifodalashi kerak. Ma'no kompyuter uchun aniq belgilar tizimiga aylantirilmaguncha "noaniq ma'lumot" hisoblanadi. Masalan, "yurak" so'zi o'zbek tilida "organ", "jasorat", "mehr" kabi bir nechta semantik sohaga kiradi. Bu ma'no qatlamlarini formal tarzda belgilash uchun semantik tarmoqlar (ontologiyalar) zarur, ammo hozircha o'zbek tili uchun bunday semantik modellar ishlab chiqilmagan. Bu metodik bo'shliq tufayli raqamli lug'atlar ko'p hollarda faqat "so'z – izoh" tarzida ishlaydi, lekin semantik tahlil, mashina tarjimai yoki intellektual qidiruv tizimlarida foydalanish uchun yetarli emas.

Metodik to'siqlarning yana bir muhim jihati tildagi variantlilikdir. O'zbek tilida ko'p yozuvli birliklar (lotin va kirill), dialektal so'zlar, uslubiy qatamlar hamda tarixiy va zamonaviy variantlar mavjud. Ularni leksikografik modellashtirishda yagona tamoyil yo'q. Elektron lug'atlardagi modellashtirishning turlichaligi borasida quyidagi fikrlarni keltirish o'rinli: "Ba'zi elektron lug'atlar qat'iy alifbo tartibiga asoslansa, boshqalari so'z chastotasi, korpusdagi real uchrashish soni yoki foydalanuvchi qidiruv statistikasiga ustunlik beradi. Yana bir guruh dasturchilar esa morfologik tahlil, so'z birikmalari yoki semantik yaqinlikni hisobga olib, dinamik va kontekstga bog'liq tartiblash usullarini qo'llaydi" [2:157]. Natijada bir xil so'z turli raqamli lug'atlarda keskin farqli o'rinlarda joylashishi bugungi kunda odatiy holga aylangan. Masalan, ayrim elektron lug'atlar "g'alaba" so'zini faqat adabiy shaklda beradi, boshqa lug'atlar esa "g'alaba" variantini ham alohida birlik sifatida kiritadi. Aslida raqamli leksikografiyada bunday holatlar "variantlararo bog'lanish" orqali belgilanadi, ya'ni har bir so'zning asosiy lemmatik shakli bo'ladi, qolganlari unga referens (havola) orqali ulanadi. O'zbek leksikografiyasida bu model hali qo'llanilmayapti, natijada lug'atlar hajman kattalashadi, lekin ichki aloqadorlik yo'qoladi.

Tahlil va natijalar (Analysis and results). Morfologik resurslar yaratishda etiketlash (tagging) tizimining nomuvofiqligi ham mavjud. O'zbek matnlari uchun bir nechta tahlilchi mavjud, ammo ularning tag tizimi turlicha: biri "NOUN, VERB, ADJ" shaklida inglizcha, boshqasi esa "ot, fe'l, sifat" tarzida o'zbekcha, uchinchi qisqartma ("n, v, a") shaklida belgilaydi. Bu korpuslarni taqqoslashni qiyinlashtiradi. Har bir tahlilchi o'z belgilash tizimiga ega bo'lgani uchun o'zbek tili uchun yagona morfologik tegset (tagset) zarur. Ingliz tilida bu tizim "Penn Treebank" asosida ishlab chiqilgan, turk tilida "ITU Morphological Tagset", rus tilida "Universal Dependencies" tizimi bilan uyg'unlashtirilgan. O'zbek tili uchun hali bu turdagi standart to'liq ishlab chiqilmagan. Bu holat morfologik tahlilchilarni mashina o'rganish modellariga integratsiya qilishni qiyinlashtiradi.

Metodik jihatdan yana bir muhim masala leksik birliklarning semantik toifalanishidir. Raqamli leksikografiyada

so'zlar faqat grammatik belgilarga ko'ra emas, semantik maydonlarga ko'ra ham tartiblanadi. Masalan, "inson tanasi", "tabiat", "iqtisod", "ta'lim" kabi sohalar bo'yicha tasnif tuziladi. O'zbek tilida bu bo'linish an'anaviy lug'atlarda mavjud bo'lgan, lekin raqamli lug'atlar uchun bu tasnif formal ontologiya shaklida qayta ishlab chiqilishi kerak. Buning uchun semantik belgilash (semantic annotation) metodikasi talab etiladi. Hozircha o'zbek tilida bu metodika tajriba bosqichida bo'lib, ko'p hollarda xorijiy model (masalan, WordNet) asosida sinovdan o'tkazilmoqda, lekin milliy semantik maydonlar o'ziga xosligi bilan bu modelga to'liq mos kelmaydi.

Metodik to'siqlarning yana biri – lingvistik ma'lumotlarni texnik formatga o'tkazish jarayonida nazariyani yo'qotish xavfi. Ba'zan raqamlashtirish jarayoni shunchalik texniklashib ketadiki, tilshunoslik mohiyati yo'qoladi. Lug'atlar raqamli "obyektlar"ga aylanadi, ammo ularning orqasidagi ilmiy konsepsiya, semantik tahlil chuqurligi, uslubiy qatamlar yo'qolib ketadi. Shuning uchun raqamli leksikografiyada metodika ikki yo'nalishda muvozanatda yurishi kerak: bir tomondan texnik standartlarga rioya etish, ikkinchi tomondan tilshunoslikning ilmiy aniqqligini saqlab qolish. Hozircha bu muvozanat o'zbek amaliyotida yetarli emas.

Raqamli morfologik resurslarni yaratish uchun yana bir zarur metodik yo'nalish mashina o'rganish modellarni lingvistik ma'lumotlar bilan boyitishdir. Dastlabki tahlilchilar, odatda, qoidaga asoslangan (rule-based) bo'ladi, lekin bugungi NLP jarayoni statistik va neyron modellarni talab qiladi. Bunday modellarni o'qitish uchun katta hajmdagi to'g'ri teglangan matn korpuslari kerak. O'zbek tilida bunday korpuslar juda cheklangan, ayrimlari ilmiy ishlanmalar doirasida yopiq holda saqlanmoqda. Bu mashina o'rganish metodlarini keng qo'llashni cheklaydi. Metodik yechim sifatida ochiq korpuslar, "crowdsourcing" asosida belgilash hamda xalqaro teglar tizimiga moslashtirish zarur.

O'zbek tili uchun leksikografik va morfologik resurslarni raqamlashtirishdagi to'siqlar, ko'rinishidan texnikdek tuyulsa-da, aslida metodik tafakkurning zamon bilan moslashmaganidan dalolat beradi. Bunday murakkabliklar barcha xalqlar tilshunosligi, xususan, leksikografiyasida kuzatilgan [3:59–97]. Tilshunoslikdagi an'anaviy metodlar raqamli tahlil uchun qayta talqin qilinmasa, har bir yangi loyiha o'tgan asrning mexanik takrori bo'lib qolaveradi. Demak, yangi metodika faqat yangi dastur emas, tilni formal, matematik va semantik jihatdan qayta o'ylash madaniyatidir. Shu yondashuvga o'zbek leksikografiyasini raqamli avlod uchun tayyorlay oladi.

Tadqiqot natijalari shuni ko'rsatadiki, o'zbek tili uchun leksikografik va morfologik resurslarni raqamlashtirish jarayoni nafaqat texnik, balki metodologik va nazariy muammolar bilan ham chambarchas bog'liqdir. Mavjud lug'atlar, grammatik tavsiflar va leksik manbalar asosan bosma shaklda yaratilganligi sababli, ularni zamonaviy raqamli muhitga moslashtirish murakkab jarayon hisoblanadi. Elektron resurslarni yaratishda formal modellashtirish, ma'lumotlarni standartlashtirish va mashina tomonidan qayta ishlanadigan formatlarga o'tkazish dolzarb vazifalardan biri bo'lib qolmoqda.

Tahlillar shuni ko'rsatdiki, o'zbek tilshunosligida morfologik tahlil, semantik belgilash, elektron lug'atlarni integratsiyalash, teglash tizimlarini standartlashtirish va ontologik modellashtirish bo'yicha yagona metodik yondashuv hali to'liq shakllanmagan. Ayniqsa, o'zbek tilining agglutinatib tabiati, ko'p qatlamli morfologik tuzilishi va variantlilik xususiyatlari mavjud raqamli vositalarni yaratishda qo'shimcha murakkabliklarni yuzaga keltirmoqda.

Shuningdek, elektron lug'atlar va morfologik resurslarning turli texnik formatlarda yaratilishi, yagona tegset tizimining mavjud emasligi hamda ochiq va katta hajmdagi annotatsiyalangan korpuslarning yetishmasligi raqamli til texnologiyalarining rivojlanishini sekinlashtirmoqda. Bu esa mashina tarjimai, avtomatik matn tahlili, nutq texnologiyalari va sun'iy intellekt asosidagi lingvistik tizimlarning samaradorligiga salbiy ta'sir ko'rsatmoqda.

Xulosa va takliflar (Conclusion/Recommendations). Xulosa qilib aytganda, o'zbek tilining raqamli leksikografiyasi va morfologik resurslarini rivojlantirish uchun an'anaviy tilshunoslik yutuqlarini zamonaviy kompyuter lingvistikasi metodlari bilan uyg'unlashtirish zarur. Buning uchun yagona standartlar tizimini yaratish, milliy morfologik tegsetni ishlab chiqish, ochiq korpuslar bazasini kengaytirish, semantik modellashtirish metodikasini takomillashtirish hamda tilshunoslar va dasturchilar o'rtasidagi hamkorlikni kuchaytirish muhim ahamiyat kasb etadi. Ana shunday kompleks yondashuvga o'zbek tilining raqamli infratuzilmasini mustahkamlash va uni zamonaviy sun'iy intellekt hamda til texnologiyalari rivojiga moslashtirish imkonini beradi.

FOYDALANILGAN ADABIYOTLAR

1. Шестакова Л. Л., Кулева А. С. Авторская лексикография в электронно-цифровую эпоху // *Terra Linguistica*. – 2023. – Vol. 14. – No. 3. – P. 94–113.
2. Fuertes-Olivera P., Bergenholtz H. *e-Lexicography: The Internet, Digital Initiatives and Lexicography*. – London: A&C Black, 2011. – 341 p.
3. Маник С. А. Цифровая лексикография: к вопросу о конце или перспективах // *Язык в эпоху цифровых трансформаций и развития искусственного интеллекта: сб. науч. ст. по итогам Междунар. науч. конф. (Минск, 23–24 октября 2024 г.)*. – Минск, 2024. – С. 59–67.