

МРНТИ16.31.21

**А.Ә.Жаңабекова<sup>1</sup>, А.Қожахметова<sup>2</sup>**

<sup>1</sup>А.Байтұрсынұлы атындағы Тіл білімі институты Қолданбалы лингвистика  
бөлімінің менгерушісі, филология ғылымдарының докторы.

Алматы қаласы, Қазақстан

<sup>2</sup>А.Байтұрсынұлы атындағы Тіл білімі институты Қолданбалы лингвистика  
бөлімінің лаборанты, магистр. Алматы қаласы, Қазақстан

## **ЖАРТЫЛАЙ АВТОМАТТЫ МЕТАМӘТІНДІК БЕЛГІЛЕНИМДЕР ЕНГІЗУ БАҒДАРАЛАМАСЫНЫҢ ЖҰМЫС ІСТЕУ ТЕХНОЛОГИЯСЫ**

**Аннотация:** А.Байтұрсынұлы атындағы Тіл білімі институты Қолданбалы лингвистика бөлімі 2009 жылдан бастап «Қазақ тілінің ұлттық корпусын» жасау мәселесімен айналысып келеді. Бұл ретте қазақ тілінің 5 стилі бойынша бірнеше миллион сөзқолданыстан тұратын мәтіндер корпусқа салынып, әртүрлі лингвистикалық және экстралингвистикалық белгіленімдер өзірлемесі дайындалды. Корпусқа енгізілетін мәтіндер туралы ең бірінші экстралингвистикалық белгіленім қою қажет. Өйткені пайдалануға ең алдымен іздеғен материалының авторы, қандай мотін екені туралы ақпарат қажет. Мұндай ақпараттарды метамәтіндік белгіленім деп атайды.

Макалада А.Байтұрсынұлы атындағы Тіл білімі институты Қолданбалы лингвистика бөлімінде жасалған мәтіндер корпусына енгізілген 23 параметрден тұратын метамәтіндік белгіленімдер туралы баяндалады. Метамәтіндік белгіленімдердің түрлеріне арналғаннұсқаулықтар көрсетіледі. Сонымен қатар макалада метамәтіндік белгіленімге енгізу бағдарламасының жұмыс істеу технологиясы сипатталады және корпусқа енгізілгеннен кейінгі метамәтіндік белгіленім тerezесі көрсетіледі.

**Тірек сөздер:** корпус, аннотацияланған корпус, метамәтіндік белгіленім, тереze, іздеу.

**А.А. Жанабекова<sup>1</sup>, А. Кожахметова<sup>2</sup>**

1 заведующий отделом Прикладной лингвистики Института языкоznания имени  
А. Байтурсынова, док.филол.н., Алматы, Казахстан

2 лаборант отдела прикладной лингвистики Института языкоznания имени А.  
Байтурсынова, магистр, Алматы, Казахстан

## **ТЕХНОЛОГИЯ РАБОТЫ ПРОГРАММЫ ВНЕДРЕНИЯ ПОЛУАВТОМАТИЧЕСКИХ МЕТАТЕКСТОВЫХ РАЗМЕТОК**

**Аннотация.** Отдел прикладной лингвистики Института языкоznания им. А.Байтурсынова с 2009 года занимается вопросами создания «Национального корпуса казахского языка». При этом в корпус были помещены тексты на 5 стилях казахского языка, состоящие из нескольких миллионов словоупотреблений., подготовлены различные лингвистические и экстралингвистические обозначения.

О текстах, вводимых в корпус, необходимо поставить первую экстралингвистическую разметку. Потому что в первую очередь нужна информация об авторе материала, который ищут и информация о том, что это за текст. Такую информацию называют метатекстовой разметкой.

В статье описаны метатекстовые разметки, состоящие из 23 параметров, которые внедрены в корпус текстов, созданный в отделе Прикладной лингвистики Института языкоznания имени А.Байтұрсынова. Указываются инструкции для различных видов метатекстовых разметок. А также в статье описывается технология работы программы внедрения метатекстовых разметок и указывается окно метаразметки после внедрения в корпус.

**Ключевые слова:** корпус, аннотированный корпус, метатекстовая разметка, окно, поиск

A.A. Zhanabekova<sup>1</sup>, A. Kozhakhmetova<sup>2</sup>

<sup>1</sup>Head of the Department of Applied Linguistics, A. Baitursynuly Institute of the Linguistics, Doctor of Philology, Almaty, Kazakhstan

<sup>2</sup>Laboratory Assistant, Department of Applied Linguistics, A. Baitursynuly Institute of the Linguistics, Master, Almaty, Kazakhstan

## TECHNOLOGY OF WORK OF THE PROGRAM OF INTRODUCTION OF SEMI-AUTOMATIC META-LAYOUT

**Annotation.** Department of Applied Linguistics, A. Baitursynuly Institute of the Linguistics has been dealing with the creation of the «National Corpus of the Kazakh Language» since 2009. At the same time, according to 5 styles of the Kazakh language, texts have been formed into a corpus, consisting of several million word combinations, various linguistic and extralinguistic designations have been prepared. the first extralinguistic markup, because to use, first of all, you need information about which text is the author of the searching material. Such information is called metamatic quotation.

The article considers metatext markings, consisting of 23 parameters, which are embedded in the corpus of texts created in the Department of Applied Linguistics of A. Baitursynuly Institute of the Linguistics. Instructions are provided for various types of metatext markup. Also, the article describes the technology of the program for the implementation of meta-text markup and indicates the window of meta-markup after the implementation in the corpus.

**Keywords:** корпус, annotated corpus, metatext markup, window, search

Корпұстар атқаратын функциясына қатысты түрлі шағынтоптарға (подкорпус) белінеді. Әсіреле лингвистикалық зерттеулер үшін лингвистикалық белгіленімдер қойылған аннотацияланған корпустар құрастыру ете маңызды әрі пайдалы. Осындай белгіленім қойылу-қойылмауына қарай корпустар белгіленім қойылған (аннотацияланған) және белгіленім қойылмаған (аннотацияланбаған) болып екіге белінеді. Белгіленім қойылған корпустар құрастыру лингвистикалық зерттеулер үшін маңызды болғанмен, ен алдымен корпусқа енгізілетін мөтіндерді сұрыптан өткізіп, олар туралы нақты ақпараттар беру кажет.

Корпұсқа қойылатын белгіленім түрлерін шартты түрде лингвистикалық және одан сырт түрі деп екіге бөліп қарастыруға болады. Белгіленімнің лингвистикалықтан сырт түріне мыналар жатады:

1) мәтінді форматтау ерекшеліктерін бейнелейтін белгіленім (такырыптар, абзаңтар, бос жер және т.б.);

2) автор мен мәтінге қатысты мәліметтерді бейнелейтін белгіленім. Сонымен бірге автор жайлы мәлімет тек оның аты-жөні ғана емес, оның жасын, жынысын, өмір сүрген жылдарын және т.б. болуы мүмкін. Ал мәтін туралы мәлімет, әдетте, такырыптан басқа оның қай тілде жазылғаны, жылы, баспа орны, аты және т.б. Мұндай ақпараттың корпуста орын алуды мәтіндер қорынан іздеу әрекетін тәпіштеп іздестіруге мүмкіндік жасайды және, сонымен бірге, олар тиісті құжатты теңестіру әрекеті үшін де қажетті құрал бола алады. Мұны кейде экстралингвистикалық белгіленімдер деп те агады, метамәтіндік белгіленім (метатекстовая разметка – метаразметка) деп те қолданылады. Лингвистикалық белгіленімдер ішкі белгіленім деп аталса, метамәтіндік белгіленімдерді сыртқы белгіленім деп бөлтіндер де бар. Олар: *мәтін және автор туралы ақпарат: автор, атауы, жынысы, шығқан жері, мәтіннің жанры, тақырыбы, стилі, көлемі т.б.* Оларды библиографиялық, типологиялық, тақырыптық, әлеуметтік, формальдық (мәтін, тарау, бөлім, абзац, сөйлем т.б.) және техникалық (орындаушылар, электрондық нұсқа алынған дерек-көз, өндөлген күні, кодтаған кезі т.б.) деп те бөледі.


Метамәтіндік белгіленімдер корпустың қай түріне болмасын енгізілуге тиісті маңызды ақпараттар болып табылады, сонымен қатар лингвистикалық белгіленімдер қойылатын корпустар құрастыру жұмысынан бұрын, корпұсқа әртүрлі стильдерден алынған мәтіндерді енгізу барысында атқарылады.

Зерттеу жұмыстарының белгілі бір жүйе бойынша жүргізілетіні белгілі. Өйткені тіл – қарым-қатынас құралы, қолданыс аясы өте кең күрделі жүйе болғандықтан, тілдік зерттеулер белгілі автор шығармалары бойынша немесе белгілі бір кезеңде жарық көрген көркем не баспасөз немесе тарихи ескерткіштер бойынша, сол сияқты белгілі бір жанр, стиль немесе белгілі бір тақырып, мәселе бойынша тарамтараң болып жіктеліп кете береді. Корпус жадына енгізілген мәтіндерді жүйелі құрылыммен беру метабелгіленімдер қоюдың теориялық және практикалық әдістәсілдерін менгергенде ғана мүмкін болады. Соңдықтан корпустың қайсібір түрінде болмасын, метабелгіленімдер қою мәселесі дұрыс жүргізілуі керек.

*Метабелгіленімдер* – ғылыми-зерттеу жұмыстарында белгілі бір кезеңге, стилге, авторға, тақырыпқа т.б. қатысты материалдар жинаудың таптырмас дереккөзі. Метабелгіленімдер қойылған корпустардан зерттеушілер өзіне қажетті стиль, кезең, автор т.б. ақпараттар бойынша мәліметтерді тез тауып алуына мүмкіндік алады. Ал бұл жетістік қазіргі дамыған еліміздің ғылыми-зерттеушілік әлеуетін, ғылым мен білімді жан-жақты дамытатын бірден-бір күш екендігі сөзсіз.

Корпус мәтіндеріне метабелгіленімдер қою мәселесі А.Байтурсынұлы атындағы Тіл білімі институтының Қолданбалы лингвистика бөлімінде 2015-2017 жылдардағы грантық жоба бойынша зерттеліп келеді. Сонымен қатар 2016 жылы институт А.Фазылжановының жетекшілігімен «Қазақ тілінің ұлттық корпусын әзірлеу және жасау» атты мақсаттық жоба бойынша метабелгіленім әзірлемесін дайындағы. Метабелгіленім енгізушилер үшін арнайы нұсқаулық жасалды және тәмендегі тармақтарға негізделген әрбір стиль, корпус түрлеріне қойылатын

ұшықтар құрастырылды. Ұшық 23 тармактан тұрады. Латын қаріпті корпус құрастыру тапсырмасы кезінде де осы метабелгіленім әзірлемесін программаға енгізу жұмысы жалғасын тапты. Сөйтіп, жартылай автоматты метабелгіленім енгізу бағдарламасы жасалды. Төменде осы бағдарламаның жұмыс үстелі *1-суреттегі берілгенде*



*1-сурет.* Мәтіндерге метабелгіленім енгізуіндегі жартылай автоматты бағдарламасының жұмыс үстелі

Қайсыбір мәтін болмасын оның **авторы** болады. Олар: а) мәтіннің накты авторы болған жағдайда оның аты-жөні толық көрсетіледі; ә) мәтін авторлары бірнешеу болған жағдайда ұжымдық авторлардың аты-жөні беріледі. Олар мәселен ұжымдық монографиялар, бірлесіп жазылған мақалалар т.б.; б) жалпылама автор, мұндай мәтіндер жеке адамның емес, ұжымның, мекеменің атынан кететін мәтіндер (яғни құжаттар, хаттар т.б. мәтіндер); в) кейбір мәтіндер авторлары белгісіз де болуы мүмкін. Бұл әсіресе газет-журналдар мәтіндерінде көп кездеседі. Мұндай мәтіндер авторлары кейде шартты есімдермен де көрсетіледі. Авторы анық емес мәтіндердің метабелгіленімдерінде автор деген ұшық толтырылмай бос қалдырылады.

Автордың аты-жөнін беруде атын, экесінін атын, фамилиясын толық жазу керек пе, әлде аты мен экесінің атын қысқартып жазу керек пе дегенді де метабелгіленім жасауда алдымен шешіп алу қажет. Сонымен қатар оны фамилиядан бүрын беру немесесонынан беру жағы да метабелгіленім қоюдағы бірізділік үшін қажет. Мысалы: Автор: А.Қайырбекова; Автор: Қайырбекова А.; Автор: Айжан Қайырбекова т.б.

Кейбір мәтіндерде авторға қатысты мәлімет берілмейді. Айталық, фольклорлық шығармалар ауызша тарағандықтан, белгілі бір авторы жоқ. Мұндайда автор тұрағы ақпарат берілетін кесте бос қалдырылады немесе авторы белгісіз деген сияқты белгіленім қоюға болады.

Авторға қатысты кейде қосымша тармактар енгізуге тұра келеді. Мәселен, ертегілер ауызша тарағанмен, яғни авторы болмаганмен, ол ертегілерді жинақтап құрастырушы автор болады. Мұндайда метабелгіленімге «құрастырушы» деген ұшық енгізуге болады. Сонымен қатар авторға қатысты ақпарат мынадай жағдайда өзгеріске түседі. Бұл корпуска алынған мәтін аударма болған жағдайда кездеседі. Аударылған мәтінде түпнұсқадағы автормен қоса, оны аударған аудармашы аты туралы да ақпарат беру қажет.

Мәтін авторына қатысты тагы бір мәселе газет журналдарда берілген авторы жоқ хроникаларды беруде де туындаиды. Мұндайда кейде авторы регінде газет журнал редакторын алуға болады, яғни газет журналдағы мәтін авторы болмаган

жағдайда, газет редакторының аты және авторға қатысты мәліметтер (жыннысы, жасы) көрсетіледі.

Метабелгіленімдер үшшыктарында бір ғана авторға қатысты ақпаратты енгізуде әртүрлі стильдерге қатысты түрлі мәселе туындаиды.

Ал кейбір мәтіндерде авторды алу немесе аудармаши, құрастыруышыны алу мәселесін шешіп алу қажет. Кейбір аударма мәтіндерде авторды да, аудармашины да көрсетуге болады.


Метаразметканың авторға қатысты тағы бір түрі – автордың жас ерекшелігінің де көрсетілуі. Кейбір корпустарда автордың шығарманы жазған кездегі жас шамасы көрсетілсе (Британ, Чех), кейбір корпустарда автордың туған жылы, күні туралы накты, дәл мәліметтер беріледі немесе шамамен көрсетіледі (Орыс тілінің ұлттық корпусы). Яғни автордың туған жылы, күні туралы накты, дәл мәліметтер санмен беріледі. Ал автордың жасын анықтау қын болған жағдайда «белгісіз» екендігі туралы белгі койылады. Ал ұжымдық, жалпылама, белгісіз авторлар болған жағдайда жас ерекшелігі берілмейді немесе ұжымдық авторлар болған жағдайда «әртүрлі» деген белгіленім қоюға болады.

Ал кейде қунделік, жеке хаттар сияқты жеке басқа тән мәтіндер авторлары белгілі болғанмен, олардың аты-жөндері берілмей, шартты атпен беріліп, бірақ жыннысы мен жасы көрсетіле береді. Автордың жас ерекшелігін көрсетуде оның жасын накты көрсетпей, туған күні, айы, жылын жазуға да болады. Мысалы: 18.09.1973.

Метабелгіленімдерде кейде авторлардың жыннысына қатысты да ақпарат беріледі. Автордың әйел адам екендігі немесе ер адам екендігі немесе жыннысы анық көрсетілмейі де мүмкін. Әдетте автордың жыннысы мәтін авторы біреу болған жағдайда көрсетіледі, ал ұжымдық мәтіндерде автордың жыннысы көрсетілмейді. Автордың жыннысы анық емес болған жағдайда, «белгісіз» деген белгіленім қойылады. Г.Қапан деген сияқты фамилия болғанда ер не әйел екенін белгілеу мүмкін емес, мұндайда белгісіз деген белгі койылады не үшшық бос қалдырылады.

«Жынныска» қатысты үшшыкты толтыруды мәтін авторының, аудармашиның, редактордың, құрастыруышының қайсысының жыннысын көрсетеміз деген мәселе туындаиды.

Метабелгіленім бағдарламасында мұндай белгіленімдерді жазып отыру қыннаның түспес үшін дайын форматтары тізімделеді. Белгілеуші солардың бірін тандейдаймыз. 2-сурет.



2-сурет. Жынныска қатысты үшшық

Башқұрт тілінің зерттеушісі З.А.Сиразитдинов автордың, информанттың ұлттында көрсеткен [1, 32 б.]. Ал орыс тілінің ұлттық корпусында ұлтқа қатысты белгіленім берілмейді.

Корпусқа енгізілген **мәтіннің атауы** да – негізгі метабелгіленімдердің бірі. Корпусқа енгізілген мәтіндердің атауының, яғни тақырыптарының бәрі болмауы мүмкін. Егер мәтінде тақырыптар атау берілсе, олар метабелгіленімдер жүйесіне салынады, ал тақырыптары берілмеген мәтіндердің атаулары көрсетілмейді. Бұлар әдетте газеттер мен журналдардағы бір рубрика ішінде берілетін қысқа мәтіндер, демек, корпусқа салынған мәтіндердің барлығы да табиғи тіл қолданысын сипаттайтындықтан, тақырыбы жок болса да алына береді, бірақ метабелгіленімдер жүйесінде көрсетілмейді немесе макала атауы жоқ жай хроникағана болған жағдайда «жоқ» деген белгіленім қойылады. Телеарна, радиодан алынған (ауызша не жазбаша) мәтін болса, телебағдарлама аты жазылады. Мәтін атауы дегендеге басын ашып алғын мәселе кітап, жинақ мәтіндеріне қатысты да туындаиды. Кітап, жинақ ішіндегі тақырыптар мәтін атауы ретінде беріле ме, әлде кітаптың, жинақтың аты мәтін атауы ретінде беріле ме? Метабелгіленімдер қоюда мәтін атауы ретінде кітап, жинақ ішіндегі тақырыпшалар алынады. Ал кітаптың, жинақтың сыртқы бетіндегі атауы метабелгіленімдер ішіндегі дереккөз (источник) деген ұшықта беріледі. Бұл әртурлі стиль мәтіндерінің бәріне ортақ ұстаным. Мәтін оқулық ішінен алынған тақырыптан алынса, тақырып атауы жазылады. Ал оқулық атауы дереккөзде көрсетіледі. Гылыми мәтіндер макала түрінде болса, макала аты жазылады.

Мәтін туралы метабелгіленімдердің бірі – мәтіннің жазылу уақыты. Әдетте мұндай белгіленімдер автордың шығарманы жазу барысында мәтіннің соңында калдырыған мәліметтерінен алынады. Көбінесе мәтіннің жазылу уақыты библиографиялық, өмірбаяндық зерттеулерден анықталады.

Мерзімі (жазылған уақыты): 26.01.2016 жыл

Ал мәтіннің жазылу уақыты туралы нақты ақпарат болмаған жағдайда оның мерзімі 5-10 жылды аралағында шамамен алынады.

Мерзімі (жазылған уақыты): шамамен 1998-2000 жылдар

Кейде мәтіндердің жазылу уақыты туралы нақты мәлімет болмаған жағдайда корпусқа салынған мерзімі алынады. Мәтіннің корпусқа салынған мерзімі жазу кей жағдайда метабелгіленімдер қатарында арнайы жеке ұшықта беріледі. Корпусқа енгізілу уақыты корпустың жасалу уақытымен бірдей болып келеді. Қазақ тілінің ұлттық корпусы қазіргі кездері ғана жасалып жатқандықтан, соңғы жылдар жазылады. Мысалы: 20.07.2016.

Мерзімге қатысты мәтіннің жазылған уақытынан басқа жарық көрген уақытын да метабелгіленімдердің арнайы ұшығында беруге болады. Орыс тілі корпусында «Дата публикации» деген атаумен арнайы ұшық берілген. Кейбір мәтіндер (шығарма, монография, оқулық т.б.) жазылған уақытында жарық көрсе, кейбірі кейін өндөліп қайта басылады. Бұл жерде кітаптың жарыққа шыққан, яғни қайта басылып шыққан уақыты көрсетіледі.

Мерзімі (жазылған уақыты): 1963 жыл

Жарық көрген уақыты: 1991 жыл


Метабелгіленімдердің бірі – корпусқа енгізілген мәтіндердің әрбіріндегі **сөз-қолданыс саны** туралы ақпарат. Корпусқа мәтін енгізуде стильдер арасалмағы негізінен тенгерімді болғанмен, кейбір жанрларға қатысты мәтіндер көлемі әртурлі

бөлшік келеді. Мысалы хабарландырулар, құттықтаулар, жаңалықтар т.б. ете қысқа, олардағы сөзқолданыс саны да он шақты сөзден тұруы мүмкін. Сондықтан корпуска енгізілген метабелгіленімдердегі мәтіндердегі сөзқолданыс саны оннан он мындаған сөзқолданысқа жетеді. Сөзқолданыс саны ете үлкен болып келетіндегі – көбінесе корпуска тұтастай енгізілген романдар немесе монографиялар сияқты көлемді еңбектер. Бірақ кейде мұндай шығармалар мен монографиялардың бәрі алынбай, белгілі бір тарауыға алынуды да кездеседі. Мәтіндердегі сөзқолданыс саны оларға берілген метабелгіленімдер жүйесінде корсетіледі. Жеке файлда тұрган әрбір мәтінді ашқанда компьютер экранының астынғы жағында сол мәтіндегі сез саны шығып тұрады, осы санды метабелгіленімге енгізу керек. Сөзқолданыс санын мәтінді енгізу барысында арнайы компьютерлік бағдарламалар арқылы анықтайды. Кейбір корпустарда мәтіндердегі сөйлемдер саны туралы да ақпараттар берілген.

Корпұстарда сөзқолданың терминінің орнына сөзформа деп колдану да кездеседі.

Метабелгіленімдердің енді бір түрі мәтіннің **қолданылу саласы** болып табылады, ол мәтіннің ең жалпы типологиялық сипаттамасы. Мәселен, Орыс тілінің ұлттық корпусында 8 функционалды қолданыс саласы көрсетілген. Олар: *оку-ғылыми, өндірістік-техникалық, ресми-іскери, публицистика, жарнама, діни, әдеби, түрмис-тың*.

Мәтіндерді белгілі бір **тақырыптық топтарға** бөліп беру де метаметіндік белгіленімдердің біріне жатады. Мысалы, қозамдық ғылымдар, физика, биология, саяхат, спорт, табигат, өнер, саясат т.б. Алайда бұлай тақырыптық топтарға бөлу кейде шартты болып келеді. Өйткені кейбір мәтіндер бірнеше тақырып аясында, бірнеше салаға қатысты карастырыла береді. Сондықтан белгілі бір мәтіннің тақырыптық топка қатысын көрсеткенде, олар бір салаға ғана емес, бірнеше салаға ортақ болып та келеді. Әлемдік корпустарда (Браун корпусы, Орыс тілінің ұлттық корпusesы т.б.) көркем әдебиеттерде көбінесе тақырыптық топ көрсетілмейді. Томендең **3-суретте** тақырыптар әртүрлі. Белгілеуші корпусқа енгізіліп отырган мәтіннің тақырыбын осының ішінен тандап алады.




3-сүрет. Мәтін тақырыбы ұяшығы

Метабелгіленімдердің енді бірі – **хронотоп**. Кейбір мәтіндердің тақырыптық топтар бойынша бөлу қындық тудыратындықтан, кейбір корпустарда мәтіннің жазылған уақыты мен жазылған жерін көрсету де қажет болған, яғни мәтіннің жазылған жері

мен белгілі бір кезенге қатысы көрсетіледі. Мысалы, Алматы, 1998 жыл немесе Ресей, 1945-50 жж. немесе Қазақстан, Қенес өкіметі жылдары т.б. Кейбір мәтіндерде мәтіндегі оқиғаның мерзімін, яғни хронотопын анықтау мүмкін болмайды. Оқиғага құрылмаған мәтіндер де болуы мүмкін. Мұндайда метабелгіленімдер тармактарындағы хронотоп үшіншін «бейтарап» деген белгі қоюға болады немесе мәтінде (көркем шығармада) суретtelген оқиғаның мерзімі мен орнын анықтау мүмкін болмagan жағдайда, «белгісіз» деген белгіленім қойылады.


Келесі бір метабелгіленімдердің бір түрі – **мәтін типі**. Мұнда мәтіннің белгілі бір жанрға қатысы көрсетіледі. Мысалы: ғылыми стильдегі мәтін болса, мынадай типтері көрсетіледі; *мақала, монография, оқулық, реферат, оқу құралы, тезис, аңдатпа, түйіндеме, баяндама, пікір т.б.* Публицистикалық стиль бойынша публицистикалық мәтіннің белгілі бір жанрға (типке) қатысы көрсетіледі. құнделік, *репортаж, интервью, мақала, бас мақала, ақпараттық мақала, сұхбат, жарна- ма, хабарландыру, газети очерк, хроника т.б.* Ресми стиль мәтіндері болса, типтері көрсетіледі: *өтініш, арыз, сенімхат, қолхат, тусініктеме, малімдеме, анықтама, мінездеме, шақырухат, хабарландыру, жарнама, қатынасқағаз, акт т.б.* Ауызша жазылып алған мәтіндер немесе ауызша дискурстан алынып, қағазға түсірілген әртүрлі стильдегі мәтіндер бейтарап стиль ретінде танылады да, типтері былай беріледі: *жасаулықтар, сұхбат, әңгіме, комментарий, репортаж, реплика т.б.* Көркем әдебиет стилінде көркем мәтіннің белгілі бір типке қатысы көрсетіледі. Олар: *эпопея, новелла, повесть, роман т.б.* Көркем мәтін поэзия жанры болса, оның да типтері көрсетіледі. Олар: *өлең, баллада, поэма, арнау, жыр, айтыс, терме, ән, қара өлең т.б.* Төменде мәтін типтің ұяшығы берілген. **4-сурет**. Белгілеуші осы ұяшықтан енгізіліп отырған мәтіннің типтіне қарай қажетті белгіленімді таңдайды.



#### 4-сурет. Мәтін типі үяшығы

Жанр деген термин әдебиет саласында да езіндік мәнгө ие болғандықтан, онымен шағастырмас үшін корпус құрастыруда кейде оны «мәтін типі» деген терминнен де қолданады. Мәтін *стилін* көрсету арқылы мәтіннің тілдік формасы, жарыс мәтіннің лексикалық құрамы анықталады. Олар: әдеби, әдеби емес стиль, бейтарап стиль, реңсі стиль, арнайы (ғылыми) стиль т.б. Көркем прозада мынадай стильдер: бейтарап,


аймақтық, қарапайым, жеке-авторлық стильдерді беруге болады. Алайда мәтіндерге осылайша стилистикалық сипаттама жасау корпустарда көбінесе берілмейді. Оның орнына мәтін типі мен жанрына көбірек көңіл бөлінеді. Стильдерді метабелгіленім программасына енгізуде де белгілеуші осы төменде берілген *5-суреттегі* үшшыктан стильдердің бірін таңдайды.



*5-сурет.* Стильдер үшшығы

Метабелгіленімдердің келесі түрі – **аудиторияның жасын көрсету**. Мәтіннің кімге арналғанын білу мәтіннің мазмұны мен онда қолданылатын тілдік құралдар-ды да айқындаиды. Мәтіндерге мұндай жас ерекшелігіне қарай белгіленім қою балалар әдебиетін, белгілі бір жас кезеңдеріне арналған окулықтарды табуға мүм-кіндік береді. Балалар әдебиеттің 1-10 жас, жасөспірімдік кезең 11-17, жастар әдебиеті 18-34 жас аралығы болып келеді. Немесе тек үлкен адамдарға арналғаның көрсететін белгіленім қойылады. Кейде мәтіндер жас ерекшелігіне қатысты көрсетілмейді, яғни аудиториясы бейтарап болып келеді. Әсіресе ерессектерге ар-налған мәтіндерге белгіленім қойылмайды, аудиториясы бейтарап болып келеді. Мұндайда «бейтарап» деген белгіленім қойылады. Аудитория жасына қатысты белгіленім коюда да параметрлерді алдын ала ойластырып алу қажет. Төменде метабелгіленім енгізудің жартылай автоматты бағдарламасының аудиторияның жасына қатысты параметрлер үшшығы көрсетілген. *6-сурет*.

Метабелгіленімдердің келесі түрі – мәтіннің кімге, бұл жерде **аудиторияның білім дәрежесіне** қарайғы ерекшелігін көрсету. Бұл жерде мәтін аудиториясының жалпы білімі немесе арнайы білімі, соңдай-ақ жоғары білімі немесе білімнің төмендігі сияқты сипаттары негізге алынады. Себебі арнайы кәсіби салада жазылған мәтіндердің өзіне тән терминологиясы болады. Ешқандай кәсіби білімсіз жалпыға ортақ мәтіндер де болады. Соңдықтан аудиторияның білім дәрежесі ескеріліп, пайдаланушы органды қарастырылады. *а)* жоғары білімді ортага арналған, *ә)* кәсіби білімді қажет ететін, *б)* кәсіби білімі жоқ, жоғары білімі жоқ ортага арналған, *в)* бейтарап орта мәтіндері. Алайда корпустардың көпшілігінде аудиторияның білім дәрежесі көрсетіле бермейді. Ол бір жағы аудиторияның білім дәрежесін анықтаудың кейде кындық тудыруына байланысты.



6-сурет. Аудиторияның жасына қатысты ұяшығы

**Метабелгіленімдердің келесі түрі – мәтіндерді пайдаланушы ортанның саны, көлемі.** Кейбір мәтіндер жалпы көпшілікке арналып, яғни мындаған, миллиондаған адамға арналса, отыз шақты адамнан тұратын топқа немесе бір ғана адамға арналған болуы да мүмкін. Жалпы көпшілікке арналған мәтіндер көбінесе баспа беттерінен шыққан мәтіндер, электронды қарым-қатынасқа арналған мәтіндер болса, топқа арналған мәтіндер оку лекциялары, кеңсе құжаттары т.б., ал жеке аудиторияға арналған мәтіндер көбінесе жеке хаттар болып келеді.

Метабелгіленімдердің келесі түрі – мәтін алынған дереккөздер болып табылады. Мәтін жинаудың түрлі әдіс-тәсілдері бар. Электронды кітапханалардан, интернетке салынған сайttардан, газет-журналдар, кітаптар шығарылатын баспалардан, жеке адамдардан атуға болады немесе колдап сканір жасалады немесе колдан теріледі. Жарық көрметен мәтіндер қолжазба ретінде көрсетіледі. Интернеттен алынған мәтіндерде сайт аты беріледі. Жарық көрген газет-журналдардың шыққан уақыты алынады.

Метабелгіленім параметрлерінің ішіндегі ең көлемді акпарат берілетіні де дереккөз ұяшығы болып табылады. Онда кітап, жинақ аты, жылы, баспасы, жарық көрген жері т.б сияқты толық акпарат беріледі. Мәселен, көркем шығарма мәтіні болса, дереккөзі ретінде ол туралы толық акпарат (жинақ (кітап) аты, жері, баспа, жылы) жазылады.

Дереккөзі: Әуезов М. Абай жолы. 2 том. – Алматы, Ғылым, 1947.

Мәтін монография (ғылыми, іскери т.б.) ішінен алынған болса, монография туралы толық акпарат (жері, баспа, жылы) беріледі.

Дереккөзі: Жаңабекова А. Функционалды грамматиканың метатілі. – Алматы, Даік-пресс, 2012. – 150 бет.

**Мәтіндер жарық көрген баспа атын да көрсету – метабелгіленімнің бір түрі.** Бұл әсіресе кітаптарға (монография, оқулық, оку құралы, шығарма т.б.) арналған. Баспа атына қатысты мәлімет кейбір корпустарда арнайы жеке ұяшықта берілмейді, дереккөздерінде басқа да акпараттармен бірге көрсетіледі.


Корпусқа енгізілген мәтіннің корпусқа енгізуге дейін қандай формада (электронды, кітап, газет-журнал, іскери құжат т.б.) болғанын көрсету де қажет. **Мұны тара-**

**лым типі** деп атайды. Мәтін газет-журналдан алынған болса, таралымы типі газет не журнал болады.

Таралым типі: газет/журнал

Мәтін интернет-басылым, блок, сайттардан алынған болса, таралымы типі интернет-ресурс болады.

Таралым типі: галамтор-ресурс. Төменде *7-суретте* таралым типінің түрлері ұяшықта көрсетілген.



7-сурет. Таралым типінің ұяшығы

Таралым типіне ұқсас метабелгіленімінің бірі – **мәтін көзі**. Корпусқа жинақталатын мәтіндер әртүрлі жолмен жинақталады. Мәтін (көркем шығарма, өлең, газет, журнал т.б.) интернеттөн алынған болса, дереккөзі ретінде «интернет» (галамтор) деген белгіленім қойылады.


Мәтін көзі: галамтор-ресурс

Мәтін (көркем шығарма, өлең, газет, журнал т.б.) баспадан алынған болса, дереккөзі ретінде «баспа аты» көрсетіледі.

Мәтін көзі: «Дайк пресс» баспасы

Баспадан алынған, бірақ баспа атын анықтау киындық тудырған жағдайда «баспа» деген белгіленім қойылады.

Мәтін көзі: баспа. Төменде *8-суретте* берілген.




8-сурет. Мәтін көзі ұяшығы

Корпұска енгізілетін мәтіндер әртүрлі пішінде (ауызша, жазбаша) болуы мүмкін. Мұны **мәтін формасы** деп атайды. Газет-журналдар, көркем шығарма, монография, оқулық т.б. мәтіндері жазбаша мәтіндер болғандықтан, «жазбаша» деген белгіленім қойылады.


### **Мәтін формасы:** жазбаша

Видео/аудиожазбалар болған жағдайда «ауызша» деген белгіленім қойылады. Мәтін формасы: ауызша. Мәтін формасы үяшығы **9-суретте**.



9-сурет. Мәтін формасы үяшығы

Мәтінді сипаттауда тағы бір берілетін ақпарат оның қандай **каріптермен** жазылғандығы туралы ақпарат. Қазақ тіліндегі мәтіндер тәте, латын, кирил әріптерімен жазылғандыктан, алынған мәтіннің графикасын көрсетіп отыру да қажеттік тұғызады. Алайда қазіргі мәтіндер негізінен кирил картпімен жазылған. Корпұска негізінен осы кирил картпімен алынған мәтіндер алынады. Ал тарихи корпустар үшін тәте, латын картпітерімен жазылған мәтіндерді де алу қажет. Төменде **10-суретте** мәтіннің графикасына қатысты үяшық көрсетілген.



10-сурет. Мәтін графикасы үяшығы

Корпустарды іштей стиль бойынша, формасы бойынша т.б. критерийлер бойынша шағын корпустарға бөлуге болады. Осыған орай метабелгіленімдер үяшығында алынған мәтіннің негізінен қандай корпұска жататыны жайлы ақпарат беріледі. Мұндай шағын корпустарды орыс тілінде «подкорпус» терминімен атайды. Қазақ тілінде **субкорпус** ретінде көрсетуге болады. Олар: газет мәтіндері

субкорпсусы, ауызша субкорпус, мультимедиялық субкорпсус, көркем мәтіндер субкорпсусы, поэтикалық мәтіндер субкорпсусы, ресми мәтіндер субкорпсусы, т.б. Орыс тілінде осы шағын корпустардың жиынтығын «негізгі корпсус» деп атайды. Ал осы субкорпустардың барлық жиынтығын «Ұлттық корпсус» деп атайды.

Публицистикалық стиль корпсусына жазбаша және ауызша формадагы газет-журнал және радио/теледидар мәтіндері кіреді. Газет-журналдан алынған мәтін болса, газет мәтіндері корпсусына жататындығы көрсетіледі.

Субкорпсус: газет мәтіндері

Радио/теледидардан алынған аудиожазбалар болса, ауызша корпсусқа жататындығы көрсетіледі.

Субкорпсус: ауызша

Теледидардан алынған видеожазбалар болса, мультимедиялық корпсусқа жататындығы көрсетіледі;

Субкорпсус: мультимедиялық

Көркемсөз стилінде жазылған мәтіндер дегенге көбінесе проза/драма жанры енеді;

Субкорпсус: көркем мәтіндер

Поэзия жанры «Корпсус поэтических текстов» деген атаумен жеке субкорпсус болады.

Субкорпсус: поэтикалық мәтіндер

Оқулықтардан алынған мәтіндер болса, оқыту корпсусы ретінде жазуға болады.

Субкорпсус: оқыту

Ғылыми стилде жазылған мәтіндерді субкорпсус ретінде шығаруға болады.


Субкорпсус: ғылыми-техникалық корпсус

Ісқағаздар, ресми стиль мәтіндері «ресми мәтіндер субкорпсусы» ретінде дербес корпсус бола алады.

Субкорпсус: ресми мәтіндер


Негізгі корпуста жоғарыда аталған субкорпустардың барлығы қамтылады. Негізгі корпсусқа катысты белгіленім жеке субкорпустар жасалып біткеннен кейін, яғни негізгі корпсусқа біріктірілгеннен кейін қойылады.

Субкорпсус: негізгі корпсус. Тәменде метабелгіленім енгізу бағдарламасынан субкорпустардың түрлері көрсетілген ұяшық берілген. **11 - сурет.**




Орыс тілінің ұлттық корпусында метабелгіленім енгізуші адамның аты да үшіншікта (разметчик) берілген. Қазақ тілінің ұлттық корпусын жасауда да **белгілеуші** адам туралы ақпарат беруге болады.

Жоғарыда аталаған метабелгіленім түрлері бойынша корпусқа енгізілетін мәтіндерге белгілеуші (разметчик) метабелгіленімдерді осы жартылай автоматты метабелгіленім қою бағдарламасы арқылы енгізеді. Бұл үшін алдымен электронды мәтіндердегі әр шығарманы жеке файлға сактап, оларды авторы бойынша жеке папкаға жинаймыз, яғни Word файлдарды бір папкаға, ал XML файлдарды жеке папкаға сактаймыз. Мәтіннің авторы, жазылған уақыты, алынған дереккөзі, стилі т.б. 23 параметр бойынша мәліметтер метабелгіленім бағдарламасына толтырылады. Сосын «Загрузить DOCX file» деген нұсқаулық арқылы электронды мәтінді жүктеп, «Сохранить XML file» нұсқаулығы арқылы метабелгіленімді сактаймыз. **12-сүретте** метабелгіленімдер мен мәтіндерді программаға (корпусқа) жүктеу жолы көрсетілген үшіншік берілген.




*12-сүрет. Метабелгіленімдер мен мәтіндерді программаға (корпусқа) жүктеу жолы*

Төмендегі **13-сүретте** 23 параметр бойынша метабелгіленім толық енгізілген және сол мәтін бірге тіркеліп сакталған үшіншік берілген. Осы процесс орындалғаннан кейін метабелгіленім қойылған мәтіндер корпусқа еніп отырады.



*13-сүрет. Метабелгіленім толық енгізілген және сол мәтін бірге тіркеліп сакталған үшіншік*

Қазіргі кезде осы 23 параметрмен Қолданбалы лингвистика бөлімінде мәтіндер корпусы (14-сурет) жұмыс жасайды.



*14-сурет. А.Байтұрсынұлы атындағы Тіл білімі институты Қолданбалы лингвистика бөлімінің мәтіндер корпусындағы метабелгіленім терезесі*

Сонымен, корпус жасауда метабелгіленімдерді енгізу қажеттігі дау тудырмайды. Олар корпусты пайдаланушыға, әсіресе тілші-зерттеушілерге кез келген қажетті акпаратын тез әрі онай тауып алуға мүмкіндік береді.

### ӘДЕБИЕТТЕР ТІЗІМІ:

- [1] Сиразитдинов З.А., Бускунбаева Л.А., Ишмухаметова А.Ш., Ибрагимова А.Д. Информационные системы и базы данных башкирского языка. – Уфа: Книжная палата РБ, 2013. – 116 с.