

2. Журавлев Ю.И., Камилов М.М., Туляганов Ш.Е. Алгоритмы вычисления оценок и их применение. Ташкент: Фан, 1974. -119с.
3. Kamilov M.M., Hudayberdiev M.X., Khamroev A.Sh. Methods of Computing Epsilon Thresholds in the Estimates' Calculation's Algorithms. International Conference "Problems of Cybernetics and Informatics" (PCI'2012), Volume III. September 12-14, 2012. – Baku, Azerbaijan. – Pp. 133-135.
- 4.Хамроев А.Ш. Алгоритм выбора оптимального метода вычисления значений е-порогов в алгоритмах вычисления оценок. Международный научно-технический журнал. Химическая технология. Контроль и управление. – Ташкент, 2012. – № 3. – С. 78-82.
- 5.Худайбердиев М.Х., Хамроев А.Х., Мамиева Д.З. Объектлар ҳакидаги ўқув ва назорат танланмаларини шакллантиришда баҳоларни хисоблаш алгоритми. Республика илмий-техник анжумани: “Аҳборот ва телекоммуникация технологиялари муаммолари”. - Тошкент, 2016 йил 10-11 март. – 185-187 бб.
6. Худайбердиев М.Х., Хамроев А.Ш. О взаимосвязы параметров в моделях алгоритмов вычисления оценок. Интеллектуальные системы (INTELS'-2014): Десятый международный симпозиум. 30 июня - 4 июля – Москва, 2014. – С. 49-52.
7. Хўжаев О.Қ., Абдуллаев Ф.О., Рахманова М.Р. “Методы определение веса документов в электронных ресурсах” // НАУКА И МИР Международный научный журнал, № 3 (19), 2015, Том 1 ISSN 2308-4804.
8. Хўжаев О.Қ. Абдуллаев Ф.О., Артиков М.Э., Бобожанов Б. “Применение нейронных сетей поисковых машинах типа электронного правительства”// НАУКА И МИР Международный научный журнал, № 3 (19), 2015, Том 1 ISSN 2308-4804.
- 9.<http://developer.yahoo.net/blogs/hadoop/2008/02/yahoo-worlds-largest-production-hadoop.html>
10. <https://blogs.bing.com/search/2009/06/01/user-needs-features-and-the-science-behind-bing>
- 11.[https://academy.yandex.ru/events/data\\_analysis/grant2009/](https://academy.yandex.ru/events/data_analysis/grant2009/)
12. Tie-Yan Liu (2009), Learning to Rank for Information Retrieval, Foundations and Trends in Information Retrieval: Vol. 3: No 3, cc. 225-331, ISBN 978-1-60198-244-5, DOI 10.1561/1500000016.
13. <http://www.MachineLearning.ru/wiki>

**Хўжаев Отабек Қадамбоевич**

Тошкент аҳборот технологиялари университети Урганч филиали “Аҳборот таълим технологиялари” кафедраси мудири

Эл. почта: [otabek.hujaev@gmail.com](mailto:otabek.hujaev@gmail.com)

**Эгамбердиев Нодир Абдуназарович**

Тошкент аҳборот технологиялари университети “Аҳборот технологияларининг дастурий таъминоти” кафедраси катта ўқитувчиси

Эл. почта: [nodir0188@mail.ru](mailto:nodir0188@mail.ru)

**O.Q. Xo'jayev, N.A. Egamberdiyev****Method of applying algorithm of calculating ranks for searching similar diagnosis on medical information systems**

This paper focuses on the problem of ranking, which is one of the issues of intelligent data analysis based on the medical information system database. Given commonly mathematical description of ranking task and analyzed RankBoost, RankSVM, IR-SVM algorithms for solving ranking task and also said its applications. In addition, the neuronal network, which is heuristic method, has been designed to solve the problem of ranking to the feed forward neural network model. And so on six stages calculating ranks algorithm for classification task is applied and is taken results for searching similar diagnosis in database of medical information system and redesigned in three stages. Taken results checked and compared algorithm accuracy on based database of medical information system. Given block-scheme of adopted variant of calculating ranks algorithm for solving ranking task.

**Keywords:** *Ranking, RankBoost, RankSVM, IR-SVM, ListNet, ListMLE, feed forward neural network, algorithm of calculating ranks.*

УДК 621.396.41

**О.Ж. Бабомурадов, Н.С.Маматов, Л.Б. Бобоев, Б.И.Отахонова**

**МАТНЛАРГА ДАСТЛАБКИ ИШЛОВ БЕРИШ ВА ЭҲТИМОЛЛИ  
БАҲОЛАШ МОДЕЛЛАРИ АСОСИДА ТАСНИФЛАШ**

Мақолада турли табиий тилларда берилган матнли маълумотларни таснифлаш масаласи доирасида олиб борилган назарий ва амалий тадқиқот натижалари таҳлили келтирилган. Амалга оширилган манбалар таҳлили асосида тадқиқот учун устқурма ёндашувлар белгилаб олинган. Матнли электрон хужжатларни эҳтимолли баҳолаш моделлари асосида таснифлаш учун матнга дастлабки ишлов бериш орқали информатив белгилар фозосини хосил қилиш ёндашуви келтирилган. Матнли хужжатлардан ташкил топган модел масалани ечиш орқали Бернулли модели самарадорлиги баҳоланган ва тажрибавий тадқиқот натижалари ёрдамида асосланган.

**Калит сўзлар:** матнни хужжат, мантли маълумотга дастлабки ишлов бериш, таснифлаш, Байес эҳтимоллиги, Бернулли таҳсомоти, таҳлил, белгилар фазоси, лугат, ўқув танланма, сўзлар.

### Кириш

Турли табиий тилларда берилган матнларга дастлабки ишлов бериш ва таснифлаш учун зарур бўлган белгилар фазосини шакллантириш ҳозирги куннинг долзарб масалаларидан биридир.

Ахборот оқимининг тезкор ошиб бориши эса маълумотларга ишлов бериш ва таснифлашни автоматлаштиришда турли муаммоларни вужудга келтиради. Ҳозирги кунда ушбу муаммоларни бартараф этишининг кўплаб ёндашувлари ишлаб чиқилган.

Бу кўплаб ижтимоий-иқтисодий соҳаларнинг электрон матнли хужжатларига ишлов беришда намоён бўлади. Масалан электрон мурожаатларга автоматик ишлов бериш тизимиши ишлаб чиқиша, оммавий ва йўналтирилган электрон ахборот ресурсларини яратишда юзага келади.

Айни пайтда матнли маълумотларга ишлов беришнинг оммалашган тўрт алгоритми мавжуд. Мавжуд алгоритмлар интернет муҳитида матнли хужжатни қидириш, категориялаш, маршрутлаш ва фильтрлашни амалга оширади. Мазкур алгоритмларнинг батафсил таҳлили [1] ишда келтирилган.

Матнли маълумотларни таснифлашнинг содда ва самаралиси Байес таснифлагичи ҳисобланади.

Матнни категорияларга ажратишга йўналтирилган усуслар ҳам мавжуд. Улар категориялашни асосан статистик ва эвалуацион ёндашувлар асосида амалга оширади [2].

Матнларни лексик ва синтаксис хусусиятларига кўра мавзу ёки руҳн бўйича классификация ва кластеризациялаш усул ва алгоритмлари [3] ишда таклиф этилган.

Матнларни схематик ифодалаш орқали таснифлашни амалга оширувчи усул ва алгоритмларни ишлаб чиқиш билан Б.С.Хариш, Д.С.Гуру, С.Манжунатҳлар шугулланган.

Матнли хужжатларни таснифлашда кўпинча қисмий таснифлаш ёндашувлари кўлланилади. Бунда юқори натижага олиш учун чекли оптималлаштириш масаласини ечиш талаб этилади [5].

Матнларни таснифлашнинг яна бир самарали ёндашувида матнлар маркерланади. Бунда маркерланган ва маркерланмаган матнларни “Кутиш-максималлаш” комбинацияси ва Байес таснифлагичи ёрдамида таснифлаш амалга оширилади [6]. Маркерланмаган матнлардан фойдаланилганда таснифлаш хатолигини 30% дан ошиб кетиши [6] ишда кўрсатиб ўтилган. Бундан ташкари мазкур ишда матнларни тузилмавий белгилари асосида автоматлашган таснифлашни амалга оширилган бўлиб, унда 16 хужжатдаги 2000 та сўздан фойдаланилган.

Техник хужжатлардаги мураккаб ибораларни тузилмавий таҳлили табиий тилдаги каби таксономик тузилма асосида таҳлил қилинади ва

тегишлилик мезонлари ҳамда матннинг асосий элементлари иборалар ёрдамида таснифлаш амалга оширилади [7].

Таснифлаш масаласининг умумий аспектлари [8, 9] ишларда кўриб чиқилган ва норавшан тўпламлар назарияси ҳамда нейро-норавшан ёндашувлари ҳам таклиф этилган. Бу ёндашувларда “Юмшоқ модел”ли алгоритм асос сифатида олинган.

Куйида хужжатларга ишлов бериш ва таснифлашнинг кенг тарқалган Бернулли модели кўриб чиқилган.

Матнни таснифлашда кўпинча тил тузилмаси инобатга олинмайди ва аксарият ҳолларда хужжат сўзлари мажмуасидан фойдаланилади [10]. Албатта бу содда ёндашув, бироқ таснифлашда юқори натижалар беради. Ушбу ёндашувда дастлаб сўзлар алфавити шакллантирилади. Таснифлашда сўзларнинг тартиби инобатга олинмайди.

Фараз қиласи, бизга бирор бир тилнинг сўзлар тўплами  $V$  берилган бўлсин. Одатда  $V$  тўплам лугат деб аталади.  $V$  тўпламнинг куввати  $N(N=|V|)$  ундаги сўзлар сонига teng.  $V$  тўплам асосида  $S=(S_1, S_2, \dots, S_N)$  сўзлар вектори шакллантирилади.  $K=\bigcup_{i=1}^m K_i$  матнлар тўплами, яни сифлар бўлсин.

Бизга  $K_i$  синфга тегишли  $D_j$  матн берилган бўлсин ( $i=1, m; j=1, p$ ).  $D_j$  матнни  $K_i$  тўпламда ётиш эҳтимоллиги  $P(K_i | D_j)$  Байес формуласига кўра қуидагига teng:

$$P(K_i | D_j) = \frac{P(D_j | K_i)P(K_i)}{P(D_j)} \Rightarrow P(D_j | K_i)P(K_i) \quad (1)$$

Берилган  $D_j$  матн асосида  $G_j$  сўзлар тўплами шакллантирилади ва  $G_j$  тўпламга мос  $W_j=(w_{j1}, w_{j2}, \dots, w_{jr})$  сўзлар вектори ҳосил қилинади.

$S$  сўзлар вектори асосида  $N$  ўлчовли  $X_j^i$  буль вектори қуидагича шакллантирилади:

$$x_{jt} = \begin{cases} 1, & \text{агар } s_t = w_{je} & j = \overline{1, p}; \\ 0, & \text{акс холда} & t = \overline{1, N}; e = \overline{1, r}; \end{cases}$$

$K_i$  синфда  $s_t$  сўзнинг учраш эҳтимоллиги  $P(s_t | K_i)$  бўлса,  $s_t$  сўзнинг мазкур синфда учрамаслик эҳтимоллиги  $(1 - P(s_t | K_i))$  га teng бўлади. У холда (1) га кўра  $K_i$  синфга  $D_j$  матннинг

тегишлилик эҳтимоллиги, яъни  $S$  сўзларнинг  $K_i$  синфга тегишлилик эҳтимоллиги куйидагича аниқланади:

$$P(D_j | K_i) = P(S | K_i) = \prod_{t=1}^{|V|} [x_t P(s_t | K_i) + (1-x_t)(1-P(s_t | K_i))] \quad (2)$$

$K_i$  синфга тегишли  $S_t$  сўз иштирок этган хужжатлар сони  $\eta_{K_i}(s_t)$  ва бу синфга тегишли хужжатлар сони  $N_{K_i}$  бўлсин. У ҳолда  $S_t$  сўзнинг эҳтимоллиги куйидагига teng бўлади:

$$\hat{P}(s_t | K_i) = \frac{\eta_{K_i}(s_t)}{N_{K_i}} \quad (3)$$

Агар ўқитишдаги барча хужжатлар сони  $N$  бўлса, у ҳолда  $K_i$  синфга тегишли хужжатлар эҳтимоллиги куйидагига teng бўлади:

$$\hat{P}(K_i) = \frac{N_{K_i}}{N} \quad (4)$$

Ўқитилувчи хужжатлар тўплами ва  $K_i$  синфга тегишли матнларни таснифлашнинг Бернулли модели куйидаги босқичларда амалга оширилади:

1.  $V$  лугат шакллантирилади.
2. Ўқитиш амалга оширилади.
3. Таснифлаш амалга оширилади.

Таснифланмаган  $D$  хужжатни бирор синфга тегишлилигини аниқлаш (1) ва (2) комбинацияси асосида куйидагича аниқланади:

$$P(K_i | S) \Rightarrow P(S | K_i)P(K_i) \Rightarrow P(K_i) \prod_{t=1}^{|V|} [x_t P(s_t | K_i) + (1-x_t)(1-P(s_t | K_i))] \quad (5)$$

**Модел масала.** Бизга  $K_1$  ва  $K_2$  синфга оид бўлган хужжатлар тўплами берилган бўлсин. Бунда  $K_1$  - спортга оид матнлар ва  $K_2$  - информатикага оид матнлар.  $D_j$  ни ( $j=1,11$ )  $K_1$  ёки  $K_2$  синфига тегишлилиги берилган бўлсин.

Дастлаб  $V$  тўплам (лугат) шакллантириб олиниади:

$$V = \{\text{гол, ўзгарувчанлик, устоз, тезлик, ҳимоя, ичимлик, майдон, бажарии}\}$$

Луғат элементлари асосида  $S = (\text{бажарии}, \text{гол}, \text{майдон}, \text{тезлик}, \text{ӯзгарувчанлик}, \text{устоз})$

ҳимоя) сўзлар вектори шакллантириб олиниади.  $D_j$  матн асосида  $W_j$  сўзлар вектори ҳосил қилинади ва  $X_j^i$  буль вектор шакллантирилади:

$$X_1^1 = (1, 0, 0, 0, 1, 1, 1, 1);$$

$$X_2^1 = (0, 0, 1, 0, 1, 1, 0, 0);$$

$$X_3^1 = (0, 1, 0, 1, 0, 1, 1, 0);$$

$$X_4^1 = (1, 0, 0, 1, 0, 1, 0, 1);$$

$$X_5^1 = (1, 0, 0, 0, 1, 0, 1, 1);$$

$$X_6^1 = (0, 0, 1, 1, 0, 0, 1, 1);$$

$$X_7^2 = (0, 1, 1, 0, 0, 0, 1, 0);$$

$$X_8^2 = (1, 1, 0, 1, 0, 0, 1, 1);$$

$$X_9^2 = (0, 1, 1, 0, 0, 1, 0, 0);$$

$$X_{10}^2 = (1, 0, 0, 0, 1, 1, 1, 1);$$

$$X_{11}^2 = (1, 0, 0, 0, 1, 1, 1, 1);$$

**Ечимни ҳосил қилиш.** Ўқитиш тўплами синклари  $K_1 \cup K_2$  деб оламиз. Бунда  $N = 11$ ;  $N_{K_1} = 6$ ,  $N_{K_2} = 5$ . (4) тенгламадан фойдаланиб куйидаги эҳтимоллик ҳисобланади:

$$\hat{P}(K_1) = \frac{6}{11}; \quad \hat{P}(K_2) = \frac{5}{11}$$

Бунда  $S_i$  сўзнинг  $K_1$  ёки  $K_2$  синфга кириш эҳтимоллигини ўкув танланмасидаги хужжатларни санаш  $\eta_k(s)$  ва (3) формуладан фойдаланиб, сўз эҳтимолий баҳолаш куйидагича амалга оширилади:

	$\eta_{K_1}(s)$	$\hat{P}(S   K_1)$	$\eta_{K_2}(s)$	$\hat{P}(S   K_2)$
$S_1$	3	3/6	1	1/5
$S_2$	1	1/6	3	4/5
$S_3$	2	2/6	3	3/5
$S_4$	3	3/6	1	1/5
$S_5$	3	3/6	1	1/5
$S_6$	4	4/6	1	2/5
$S_7$	4	4/6	3	3/5
$S_8$	4	4/6	1	1/5

Бизга  $Y_1$  ва  $Y_2$  матнлар берилган бўлсин.  $Y_1$  ва  $Y_2$  векторлар  $X$  вектор каби шакллантирилади.

$$1. \quad y_1 = (1, 0, 0, 1, 1, 1, 0, 1)$$

$$2. \quad y_2 = (0, 1, 1, 0, 1, 0, 1, 0)$$

Модел масала таснифланиши  $y_1$  ва  $y_2$  да хисоблаш жараёни қуидагича амалга оширилади:

$$1. \quad y_1 = (1, 0, 0, 1, 1, 1, 0, 1)$$

$$\hat{P}(K_1 | y_1) \Rightarrow$$

$$\hat{P}(K_1) \prod_{t=1}^8 [y_{1t} \hat{P}(s_t | K_1) + (1 - y_{1t})(1 - \hat{P}(s_t | K_1))] \Rightarrow$$

$$\frac{6}{11} \left( \frac{1}{2} \times \frac{5}{6} \times \frac{2}{3} \times \frac{1}{2} \times \frac{1}{2} \times \frac{2}{3} \times \frac{1}{3} \times \frac{2}{3} \right) = \frac{5}{891} \approx 5.6 \times 10^{-3}$$

$$\hat{P}(K_2 | y_1) \Rightarrow$$

$$\hat{P}(K_2) \prod_{t=1}^8 [y_{1t} \hat{P}(s_t | K_2) + (1 - y_{1t})(1 - \hat{P}(s_t | K_2))] \Rightarrow$$

$$\frac{5}{11} \left( \frac{1}{5} \times \frac{2}{5} \times \frac{2}{5} \times \frac{1}{5} \times \frac{1}{5} \times \frac{1}{5} \times \frac{2}{5} \times \frac{1}{5} \right) = \frac{8}{859375} \approx 9.3 \times 10^{-6}$$

**Хужжат** таснифланишида  
 $\hat{P}(K_1 | y_1) > \hat{P}(K_2 | y_1)$  бўлганлиги учун  $y_1 \in K_1$  бўлади.

$$2. \quad y_2 = (0, 1, 1, 0, 1, 0, 1, 0)$$

$$\hat{P}(K_1 | y_2) \Rightarrow$$

$$\hat{P}(K_1) \prod_{t=1}^8 [y_{2t} \hat{P}(s_t | K_1) + (1 - y_{2t})(1 - \hat{P}(s_t | K_1))] \Rightarrow$$

$$\frac{6}{11} \left( \frac{1}{2} \times \frac{1}{6} \times \frac{1}{3} \times \frac{1}{2} \times \frac{1}{2} \times \frac{1}{3} \times \frac{2}{3} \times \frac{1}{3} \right) = \frac{12}{42768} \approx 2.8 \times 10^{-4}$$

$$\hat{P}(K_2 | y_2) \Rightarrow$$

$$\hat{P}(K_2) \prod_{t=1}^8 [y_{2t} \hat{P}(s_t | K_2) + (1 - y_{2t})(1 - \hat{P}(s_t | K_2))] \Rightarrow$$

$$\frac{5}{11} \left( \frac{4}{5} \times \frac{3}{5} \times \frac{3}{5} \times \frac{4}{5} \times \frac{1}{5} \times \frac{4}{5} \times \frac{3}{5} \times \frac{4}{5} \right) = \frac{34560}{4296875} \approx 8.0 \times 10^{-5}$$

**Хужжат** таснифланишида  
 $\hat{P}(K_1 | y_2) < \hat{P}(K_2 | y_2)$  бўлганлиги учун  $y_2 \in K_2$  бўлади.

Тажриба учун синфлар сони 6 та бўлган 600 та объект ва объектни таснифловчи 169205 та белги(сўз)дан иборат бўлган матнлар тўплами олинди ва таснифлаш масаласи қуидагича хал этилди. Дастреб (1) ва (2) ифодалардан фойдаланиб сўзлар эҳтимоллиги хисобланди ва сўзлар тўплами хосил қилинди, яъни белгилар фазоси қисқартирилди. Амал бажарилиши оқидатида 169205 та сўздан 28343 та сўзли тўплам хосил қилинди, яъни белгилар фазоси 17% гача қисқартиришга эришилди. Бу ҳолатда таниб олиш аниқлиги 65% ни ташкил этди.

### Хулоса

Матнларга дастлабки ишлов беришнинг оммалашган усуслари таҳлил қилинди. Матнларни

синфлаштириш учун зарур бўган белгилар фазоси ва таснифлаш масаласининг математик кўйилиши шакллантирилди. Таниб олиш масаласи учун турли руқнлари матнлар тўплами шакллантирилиб, улар руқнлар бўйича синфларга ажратилди. Олинган натижалар матнларни классификациялашда танлаб олинган моделни ривожлантириш зарурлигини кўрсатди.

### Адабиётлар

1. Li Y.H., Jain A.K. Classification of text documents
2. Yiming Y., Thorsten J. Text categorization // (2008), Scholarpedia, 3(5):4242
3. Philipp P., Bonnie W. Stable classification of text genres // (2011) Association for Computational Linguistics Vol. 37, No 2.
4. Harish B.S., Guru D.S., Manjunath S. Representation and classification of text documents: A Brief Review // IJCA Special Issue on “Recent Trends in Image Processing and Pattern Recognition” RTIPPR, 2010., pp.110-119
5. Kamal N., Andrew K., Sebastian T., Tom M. Text classification from labeled and unlabeled documents using EM // Machine Learning, 1–34 Kluwer Academic Publishers, Boston.
6. Пустыльникова О., Мелер А. Автоматическая классификация текстов на основе их структурных признаков // Труды российской конференции молодых ученых по информационному поиску
7. Якимов В.Н., Мошков И.С. Структурный анализ сложных терминов в технических документах // Интеллектуальные системы в производстве. 2011. № 2 (18), стр.270-278
8. Акбаралиев Б.Б., Бобомуродов О.Ж. Об одном подходе к обработке данных в задачах распознавания образов // Узб. журн. «Проблемы информатики и энергетики». Тошкент, 2008. - №6. – С. 41-43.
9. Бобомуродов О.Ж., Хамроев А.Ш. Построение базы нечётких правил при формировании параметров модели в задачах распознавания образов // Материалы Всероссийской конференции с международным участием «Знания-Онтологии-Теории» (ЗОНТ-2011), 3-5 октября 2011г., Новосибирск, 2011. – С. 66-72.
10. Jonathan J., Webster, Chunyu K. Tokenization as the initial phase in NLP // In Proceedings of the 14th conference on Computational linguistics Vol. 4. Association for Computational Linguistics, 1106–1110.

### Бабомуродов Озод Жураевич

Т.ф.д., Мухаммад ал-Хоразмий номидаги ахборот технологиялари университети (ТАТУ) Ахборот технологиялари дастурий таъминоти (АТДТ) кафедраси мудири

Эл. почта: bobomurodov@edu.uz

**Маматов Нарзулла Солиджанович**

Т.ф.д., ТАТУ хузуридаги аҳборот – коммуникация технологиялари илмий – инновацион маркази катта илмий ходими

Эл. почта: m\_narzullo@mail.ru

**Бобоев Лочинбек Боймуротович**

ТАТУ АТДТ кафедраси асистенти  
Эл. почта: repytolochin@gmail.com

**Б.И.Отахонова**

ФарДУ, АТ кафедраси ўқитувчи  
Эл. почта: bahrixon@mail.ru  
Babomuradov O.J., Mamatov N.S., Boboev L.B.,  
B.I.Otahona

**Text preprocessing and classification problem on the basis of probabilistic estimation models**

УДК 621.396.41

**М.Б. Зайнутдинова, Ш.Б. Сайфуллаев, Н.Ф. Ахмедова**

**КАТТА ҲАЖМЛИ МАЪЛУМОТЛАРНИ ҚАЙТА ИШЛОВЧИ АҲБОРОТ ТИЗИМИ ЁРДАМИДА КЎҚРАК БЕЗИ САРАТОНИНИ АНИҚЛАШ**

Мақолада кўқрак бези саратонини хавфли риск гурухини шаклланишини ва индивидуал риск факторларини аниқлаш ҳамда таҳлил бўйича аҳборот тизимини ишлаб чиқиши натижалари келтирилган. Кўқрак бези саратони риски мавжуд энг аҳамиятли факторларнинг ўрнатиш имконини берувчи илк натижалар олинган.

**Калит сўзлар:** кўқрак бези саратони, аҳборот тизими, хавфли риск гурухи, риск факторлари, башорат жадвали, анкета статистика, онкология.

Онкология соҳасининг муаммоларидан бири Ўзбекистон аёлларининг кўқрак бези саратони (КБС) касаллиги билан касалланган орасида юкори позиция эгаллаб турувчи кўқрак бези саратони касаллигини профилактикаси хисобланади [6]. Шу сабабли бу кассалликни профилактика режасида касалликнинг ривожланишига таъсир қилувчи факторлар комплексини аниқлаш асосида КБС хавфли риск ва индивидуал риск гурухларини шаклланишини баҳолаш билан “соғлом” аёллар контингенти орасида касалликнинг эрта

This paper analysis results of theoretical and practical research of classification of textual data presented in various natural languages. Approaches to research have been determined based on the analysis of the sources. Approaches to the formation of informative features by preprocessing of the text are given for the classification of textual electronic documents based on probability models. The model of the textual documentation was evaluated by Bernoulli effectiveness and based on the results of the experimental research.

**Keywords:** text documents, preprocessing text data, classification, Bayes probability, Bernoulli distribution, analysis, feature space, vocabulary, train data, words.

Эл. почта: repytolochin@gmail.com

боскичларида кўқрак безини хосиласини аниқлаш долзарб хисобланади. Этиологик факторларнинг аниқлаш усусларини бири соғликка зарар етказмасдан туриб ахоли контингентини кенг қамраб олувчи, худудий хусусиятларни хисобга оладиган, амалга оширишда содда бўлган чукур изланиш учун бирламчи танлов ўтказиш имконини берувчи анкеталаштириш усули хисобланади. Катта хажмдаги анкета сўрови маълумотлар массивини қайта ишлаш учун компьютер технологияларидан фойдаланиш истиқболли хисобланади.

1- жадвал

**Республика вилоятлари бўйича КБС билан касалланиш даражаси**

Вилоятлар	100 000 аҳолига интен-сив кўрсат-кич	100 000 аҳолига (дунё) стандартлаштирилган кўрсаткич		
		Умумий	Шахар	Кишлоқ
		M±m	M±m	M±m
Қорақалпоғистон Республикаси	5,6	8,2±1,7	15,2±5.7	5,6±1.1
Андижон	7,7	9,5±1,3	12,8±2.1	10,1±2.3
Бухоро	8,1	11±1,2	13,9±3.4	10,6±0.3
Жиззах	6,3	10,2±1,7	7±3.1	9,6±2.4
Қашқадарё	5,7	7,5±0,6	9,2±0,6	7,5±0,7
Навоий	7,4	12,3±4,2	9±3.8	12,2±1.6
Наманган	6,0	8,2±1,7	7,8±2.8	9,3±1.6
Самарқанд	6,3	8,1±1,0	14,1±1.1	7,2±0.8
Сирдарё	6,6	12,2±5,6	14,7±3.1	7,5±2,8