

УДК 004.95

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

Қарор дараҳти алгоритмидан фойдаланиб матнларни таснифлаш

Аннотация. Таснифлаш объектни олдиндан маълум бўлган синклардан бирига тегишилигини аниклади. Матнларни таснифлаш компьютерли лингвистика масаласи бўлиб, бунда хужжатнинг мазмунига кўра уни олдиндан берилган бир неча рукилардан бирига тегишилигини аниклаш амалга оширилади. Хозирги кунда матнларни таснифлашнинг кўплаб усуллари ишлаб чиқилган. Масалан, машинали ўқитиши, карор дарахти, нейрон тўрлари, таянч векторлар ва бошқалар. Мазкур иш карор дарахти усулидан фойдаланган ҳолда таснифлаш механизмини куриш масаласи ечишга бағишланган бўлиб, унда ўзбек тилидаги матнлардан иборат хужжатларни таснифлаш учун қарор дарахти алгоритми атрибулгар кийматларини аниклаш (*Information Gain*, *Gain Ratio*, *Gini index*), карор дарахти алгоритмининг иш самарадорлигини ошириш ва тажрибавий тадқиқот натижаларини келтирилган.

Калим сўзлар. белги, матн, хужжат, тўплам, кисм тўплам, карор дарахти, усул, алгоритм, модел, атрибут, Джини индекси.

Кириш. Сүнгти йилларда матнли ахборотларнинг кескин ошиб бориши, маъноли ахборотларни ажратиб олиш, таҳлил килиш ва таснифлаш каби масалаларни тезкор ечимини талаб киласи. Айниқса, глобал тармок контент базасининг ривожланиши гипер тезликка эришганлиги, ахборот истеъмолига бўлган эҳтиёжнинг инсон кундалик эҳтиёжлари таркибий элементлари орасида лидерлик мақомига эга бўлганлиги ва ахборот ресурслари маконидан энг зарурларини ажратиб олиши масаласининг долзарблигини оширмоқда.

Маълумки, матнларни таснифлаш матнли маълумотларни олдиндан берилган синфларга тегишилигини назарда тутувчи маълумотларни тузилмалаштириш усулларидан бири хисобланади [1]. Матнли маълумотларни таснифлаш усуллари ахборотни кидириш ва матнларни ўқитиш билан боғлик. Мазкур икки ёндашувнинг умумий жиҳати хужжатни акс эттириш ва матнларни таснифлаш сифатини баҳолаш услубиятларида бўлиб, уларни факат ўзига хос бўлган кидирув механизмига эга эканлиги уларнинг фарқли жиҳати хисобланади [2].

Матнларни таснифлаш масаласи ечиш бўйича бир нечта илмий гурухлар фаолият олиб боришаётганига карамай, бу соҳадаги айрим саволлар хозиргача ўз счимини топигани йўқ. Баъзи бир усууларнинг аниқлиги априор бўлиб, йўл қўйилиши мумкин бўлган хатоликлар миқдори хамда матнли маълумот тузилмаси (синфлар сони, синфларнинг ҳажми ва бир жинслилиги, синфлараро «чегара»нинг аниқлилиги)га боғлиқdir. Матнли маълумотларга ишлов беришда бир қанча муаммолар юзага келади [3]. Масалан, таснифлаш учун фойдали бўлган информатив белгилар миқдорини аниқлаш, матнли маълумотларни қайта ишлаш ва таҳлил қилишга кетадиган ҳисоблаш вақтни минималлаштириш кабилар. Бундан ташқари, хосил қилинадиган «хужжат-атама» матрицаси ўта соддалаштирилган, атамаларнинг бошка хужжатларда учраши миқдори кўплиги ҳам турли муаммоларни келтириб чиқаради. Тартибланган ахборотлардан фарқли равишда тартибланмаган ахборот ягона матнли форматга эга бўлмайди, бу эса матнли маълумотга ишлов бериш ва таҳлил қилиш учун матнли хужжатларга ишлов беришининг комплекс моделини ишлаб чиқишини талаб қиласди [4-6]. Шунинг учун матнли хужжатларни таснифлаш масаласини ечишда комбинацияланган дастлабки ишлов бериш, ўкув танланма шакллантириш, синфларни самарали ташкил этиш ва таҳлил қилиш ёндашувларни биргаликда кўллаши мақсаддага мувофиқ ҳисобланади.


Матнли хужжатларни таснифлаш масаласи.
Таснифлаш алгоритми бирор-бир $D = \{d_i\}$ хужжатлар түпламида амалга оширилаётган ва бу хужжатлар түплами

кесишмайдиган кисм түплам синфларга ажратылган бўлсин, яъни

$$C = \{C_i\}, \cup_{d \in C_i}^{\forall} d = D, C_i \cap C_j = 0, (i \neq j)$$

Тасніфалаш масаласи киругчы хужжатни мос синфга тегишилигини аниклаш ҳисобланади. Ҳар бир d элементга $d = \{X_i\}$ белгилар мажмуси мос күйилади ва тасніфлаш алгоритми ёрдамида матнли хужжатни олдиндан берилган синфларнинг бирига тегишилигини аникланади. Күйида күйилган масалани ечишнинг карор дараҳти усулига асосланган алгоритм баён этилган.

Қарор дараҳти алгоритми. Қарор дараҳти бу блок схемага ўхшаш тузилишида бўлиб, унда белги (ёки артгрибут) ички тугунни, шоҳ қарор қойдасини ва ҳар бир япроқ тугун натижасини ифодалайди [7]. Қарор дараҳтидаги энг юқори тугун илдиз тугун деб аталади. У атрибут қийматлари асосида ажратишни амалга ошириша қўлланилади. Бунда рекурсив ажратиш деб номланган усул орқали маълумотлар рекурсив ажратилади. Бундай блок-схемага ўхшаш структура қарор қабул килишида қўлланилади ва ушбу блок-схема диаграммаси визуализациялаш имконини бераб, у инсон дараражасида фикрлашни осонлаштиради. Шунинг учун қарор дараҳтлари тушунишда мураккабликюзага келмайди (1-расм).



1-расм. Қарор дараҳти алгоритми блок-схемасы

Қарор дараҳти алгоритми машинали ўқитишининг оқкути тури ҳисобланыб, у нейрон тўрлари каби қора кути алгоритмларидан фарқли равишда ички қарор қабул қилиш мантиғини ошкор киласди. Бунда ўқитиши вақти эса нейрон тўрларига нисбатан тезроқ амалга оширилади ва катта ўлчамли маълумотларни яхши аниқлик билан бошқариш имкониятига эгадир.


Қарор даражати алгоритмидә күйидаги күйидаги боскىчларда бажарылады:

1. Атрибут танлаш. Бунда ўлчовларидан фойдаланиб энг яхши атрибутлар танланади.

2. Атрибутни қарор тугуни сифатида белгилаш ва маълумотлар тўпламини кичик қисм тўпламларга ажратиш.

3. Юқоридаги жараёнлар кўйидаги ҳолатлардан бирига келгунинга қадар тақорлаш орқали дарахтни қуриш амалга оширилади:

- барча тўпламлар бир хил атрибуттага тегишли.
- бошқа атрибутлар йўқ.
- бошқа мисоллар йўқ.



2-расм. Қарор дарахти алгоритми

Атрибут танлаш ўлчовлари. Атрибут танлаш ўлчовлари маълумотларни ажратиш мезонини танлаш учун муҳим ҳисобланади. Бундан ташқари, ажратиш қоидалари сифатида ҳам танилган, чунки у бизни муайян тугундаги тўпламларни аниқлашга ёрдам беради. Атрибут танлаш мезонлари ҳар бир белгига рейтингни беришни таъминлайди. Энг яхши рейтингли атрибут эса ажратиш атрибути сифатида олинади. Ҳозирги кундаги фойдаланилаётган энг машҳур танлаш ўлчовлари Information Gain, Gain Ratio ва Gini Index ҳисобланади.

Information Gain. Шаннон энтропия контсепциясини кашф этган, бу контсепция орқали кириш тўпламининг тозалик даражасини ўлчанади. Физика ва математикада энтропия тизимдаги тасодифлик ёки аралашма деб аталади. Ахборот назариясида у мисоллар гуруҳидаги тозалик даражасини ифодалайди. Information Gain - бу энтропиянинг пасайиши. Information Gain берилган атрибут қийматларида маълумотлар тўпламини ажратишдан олдин ва кейинги энтропия орасидаги фарқни ҳисоблайди. ID3 (Iterative Dichotomiser) қарор дарахти алгоритми Information Gain усулидан фойдаланади.

$$Info(D) = \sum_{i=1}^m p_i \log_2 p_i$$

бу ерда p_i D тўпламнинг C_i синфда тегишилилек эҳтимоли.

$$Info_A(D) = \sum_{j=1}^V \frac{|D_j|}{|D|} Info(D_j)$$

$$Gain(A) = Info(D) - Info_A(D)$$

бу ерда, $Info(D)$ ифода D тўплам қисм тўплами синф ёрлигини аниқлашдаги ахборотнинг ўртача миқдори, $|D_j|/|D|$ ифода j - қисм вазни, $Info_A(D)$ А томонидан ажратишга асосланган D тўплам қисм тўпламини таснифлаш учун талаб килинадиган ва кутилган ахборот.

Энг юқори ахборот фойдасига эга атрибут A , яъни $Gain(A)$, N тугунда ажратиладиган атрибут сифатида олинади.

Gain Ratio. C4.5, ID3 тизимини такомиллаштирилган бўлиб, Gain Ratio деб номланган. Одатда мазкур усулиниң кенгайтирилган кўринишини кўлланилади. Gain ratio усулидан ахборотни ажратишда фойдаланиб, унда information gain усулини

нормаллаштириш орқали юзага келадиган ҳатоликини аниқлайди.

$$SplitInfo_A(D) = -\sum_{j=1}^V \frac{|D_j|}{|D|} \times \log_2 \left(\frac{|D_j|}{|D|} \right)$$

бу ерда, $|D_j|/|D|$ ифода j - қисм вазни, V A атрибутдаги дискрет қийматлар сони.

Gain ratio кўйидаги формула орқали ҳисобланади:

$$GainRatio(A) = \frac{Gain(A)}{SplitInfo_A(D)}$$

Юқори gain ratio қийматига эга атрибут ажратиш атрибути сифатида танланади.

Gini index. Бошқа бир қарор дарахти алгоритми CART (Classification and Regression Tree) ажратиш нуқталарини яратиш учун Gini index усулидан фойдаланади.

$$Gini(D) = 1 - \sum_{i=1}^m p_i^2$$

бу ерда D тўплам ичидағи қисм тўплам p_i - C_i синфа тегишилилек эҳтимоли.

Gini индекси ҳар бир атрибутнинг бинарликка тешириш орқали ҳар бир бўлакни ноаниқ оғирликлари ийғиндисини ҳисоблайди. Агар D маълумотнинг A атрибутдаги бинарлиги D_1 ва D_2 бўлса, у ҳолда D нинг Gini индекси кўйидагича ҳисобланади:

$$Gini_A(D) = \frac{|D_1|}{|D|} Gini(D_1) + \frac{|D_2|}{|D|} Gini(D_2)$$

Агар дискрет қийматли атрибутлар бўлса, танланган атрибут минимал Gini индекс берувчи қисм тўпламни таъминласа, у ҳолда у ажратувчи атрибут сифатида олинади. Агар атрибутлар давомий қийматли бўлса, кўйидаги стратегия бўйиса ҳисобланади.

$$\Delta Gini(A) = Gini(D) - Gini_A(D)$$

Бунда минимал Gini индексига эга бўлган атрибут ажратувчи атрибут сифатида олинади ва қарор дарахти таснифлагичини қуриш кўйидаги босқичларда амалга оширилади.

- Маълумотларни юклаш.
- Белгиларни танлаш.
- Маълумотларни бўлаклаш.
- Моделни куриш.
- Модел аниқлигини ўлчаш.
- Қарор дарахтини чизиш.

```

from sklearn.datasets import load_files
uzo = load_files('.\\uzo')
categories = uzo.target_names
print(categories)
['Жамият', 'Иқтисодиёт', 'Маданият', 'Спорт', 'Технологиялар', 'Фан']
  
```

```

from sklearn.feature_extraction.text import CountVectorizer
count_vect = CountVectorizer()
print(count_vect)

CountVectorizer(analyzer='word', binary=False, decode_error='strict',
               dtype=<class 'numpy.int64'>, encoding='utf-8', input='content',
               lowercase=True, max_df=1.0, max_features=None, min_df=1,
               ngram_range=(1, 1), preprocessor=None, stop_words=None,
               strip_accents=None, token_pattern='(?u)\\b\\w+\\b',
               tokenizer=None, vocabulary=None)
  
```

```

from sklearn import tree
from sklearn.model_selection import cross_val_score

X = count_vect.fit_transform(uzo.data)
y = uzo.target

clf = tree.DecisionTreeClassifier(criterion="gini")
scores = cross_val_score(clf, X, y, cv=5)

print("Aniqlik: %.2f (+/- %.2f)" % (scores.mean(), scores.std() * 2))
Aniqlik: 0.64 (+/- 0.16)
  
```

Хулоса

Тадқиқот натижалари баъзи усуулар аниқлигини априор эканлигини кўрсатди. Бу йўл кўйилиши мумкин бўлган хатоликлар миқдори ҳамда матнли маълумот тузилмаси (синфлар сони, синфларнинг ҳажми ва бир жинслилиги, синфлараро «чегара»нинг аниқлилиги)га боғлиқдир. Матнли маълумотларга ишлов беришда бир қанча муаммолар юзага келади ва бу муаммоларнинг айримлари қарор дарахти усулидан фойдаланган ҳолда таснифлаш механизмини қуриш масаласи ечиш орқали ҳал этилади. Ўтказилган тажрибаларда ўзбек тилидаги матнлардан иборат ҳужжатларни таснифлаш қарор дарахти алгоритми атрибуталар кийматларини аниқлаш (Information Gain, Gain Ratio, Gini index) орқали амалга оширилди. Бунда маълумотлар Ўзбекистон Миллый ахборот агентлиги давлат расмий ахборот манбаидан олинган олтига категорияга тегишли бўлган 600 та янгилик олинган бўлиб, қарор дарахти алгоритми асосланган дастур ишлаб чиқилди ва таснифлаш аниқлиги 64% ташкил этди.

Фойдаланилган адабиётлар

- [1] W. Buntine. A theory of classification rules. 1992.
- [2] S.Murthy. Automatic construction of decision trees from data: A Multi-disciplinary survey.1997.
- [3] J. Ross Quinlan. C4.5: Programs for Machine learning. Morgan Kaufmann Publishers 1993.
- [4] Machine Learning, Neural and Statistical Classification. Editors D. Mitchie et.al. 1994.
- [5] К. Шенон. Работы по теории информации и кибернетике. М. Иностранный Использованная литература, 1963.
- [6] С.А. Айвазян, В.С. Мхитарян Прикладная статистика и основы эконометрики, М. Юнити, 1998.
- [7] Brett Lantz. Machine Learning with R. Packt Publishing, Birmingham - Mumbai, 2013.

Бабомурадов Озод Жўраевич - – техника фанлари доктори, Мухаммад ал-Хоразмий номидаги Тошкент ахборот технологиялари университети АТДТ кафедраси мудири.

Тел.: (+99897) 403-76-11 Факс: (0371) 237 62 48

E-mail: ozod_b_76@mail.ru

Маматов Нарзилло Солиджонович – техника фанлари доктори, Мухаммад ал-Хоразмий номидаги Тошкент ахборот технологиялари университети хузуридаги Ахборот-коммуникация технологиялари илмий-инновацион маркази етакчи илмий ходими.

Тел.: (+99897) 403-56-22 Факс: (0371) 237 62 48

E-mail: m_narzullo@mail.ru

Бобоев Лочинбек Боймуротович – Мухаммад ал-Хоразмий номидаги Тошкент ахборот технологиялари университети хузуридаги Ахборот-коммуникация технологиялари илмий-инновацион маркази таянч докторанти.

Тел.: (+99890) 115-10-10 Факс: (0371) 237 62 48

E-mail: replaytolochin@gmail.com

Отахонова Бахрихон Ибрагимовна– Мухаммад ал-Хоразмий номидаги Тошкент ахборот технологиялари университети таянч докторанти.

Тел.: (+99891) 659-44-89 Факс: (0371) 238 65 07

E-mail: bahrixon@mail.ru

Babomuradov O.J., Mamatov N.S., Boboyev L.B.,
Otaxonova B.I.

Classification of texts using decision trees algorithms

Annotation. The classification determines whether the object belongs to one of the previously known classes. Classification of texts is a matter of computer linguistics, to determine whether the document refers to one of the few chapters previously given. Currently, many ways of classifying texts have been developed. For example, machine learning, decision tree, neural nets, base vectors, and more. The present work is devoted to solving the problem of constructing a classification mechanism using the decision tree method.

Keywords: character, text, document, collection, partition, decision tree, method, algorithm, model, attribute, Gini index.