
**ՏՐԱՄԱԲԱՆԱԿԱՆ ՌԵԳՐԵՍԻՎԱՆ ՈՐՊԵՍ
ՄԱՐՔԵԹԻՆԳԻ ԳՈՐԾԻՔ**

ՍԻՐԱՆՈՒՇ ՍԱՐԳՍՅԱՆ, ԱԼՎԱՐԴ ԽԱՌԱՏՅԱՆ, ԱՆՆԱ ՀՈՎԱԿԻՄՅԱՆ

Ժամանակակից աշխարհում հետզհետե մեծանում է մարքեթինգի դերը: Ապրանքների և ծառայությունների բազմազանությունը, ինչպես նաև օրեցօր աճող մրցակցությունը ֆիրմաներին թույլ չեն տալիս միայն բարձր որակի շնորհիվ ամրապնդել դիրքերը մրցակիցների նկատմամբ: Ճիշտ ընտրված մարքեթինգային քաղաքականությունը հնարավորություն է տալիս մեծացնելու ֆիրմայի ապրանքի կամ ծառայության ճանաչելիությունը շուկայում: Շատ ընկերություններ մեծ ծախսեր են կատարում շուկան հետազոտելու և հաճախորդների կարիքները բացահայտելու համար՝ նպատակ ունենալով պարզել ապրանքների և ծառայությունների այն հատկանիշները և գինը, որոնք կարող են գրավիչ լինել թիրախային շուկայում: Տեղեկատվական տեխնոլոգիաների արագ զարգացման շնորհիվ բիզնեսի համար նոր միջավայրի էլեկտրոնային առևտրի ներդրումը հնարավորություն է տալիս **կրճատելու մարքեթինգի ծախսերը:**

Էլեկտրոնային առևտրի ոլորտն այսօր արագ զարգանում է: Այն ունի մեծ ապագա, քանի որ էլեկտրոնային շուկաները բավականին արդյունավետ են գործում նոր ապրանքների ու ծառայությունների ստեղծման տեսանկյունից և անփոխարինելի են հաճախորդների ու գործընկերների որոնման հարցում: Այստեղ համագործակցող կողմերը չունեն բիզնես վարելու ժամանակային և տարածական որևէ սահմանափակում, և բացի այդ՝ գովազդային ծախսերի նվազեցման ու ապրանքների պահանջարկի աճի միջոցով հնարավոր է հասնել ընդհանուր ծախսերի կրճատման: Հայաստանի Հանրապետության համար էլեկտրոնային առևտրի զարգացումը խոստումնալից հեռանկարներ է բացում հայրենական արտադրության ապրանքները այլ երկրներ արտահանելու համար: Կրճատելով տրանսպորտի և այլ ծախսերը՝ էլեկտրոնային առևտուրը կարող է նաև խթանել ՀՀ մարզերի զարգացումը:

Հազարավոր ընկերություններ, կազմակերպություններ ավելի հաճախ են պաշտոնական կայքի միջոցով համացանցն օգտագործում որպես մարքեթինգի գործիք: Մոցիալական ցանցերում ամեն օր միլիոնավոր օգտատերեր կիսում են տպավորություններն ու մտքերն իրենց ընկերների և ծանոթների հետ: Սա հնարավորություն է տալիս ուսումնա-

սիրելու և վերլուծելու օգտատերերի կատարած գրառումները և մեկնաբանությունները, որոնց համար կիրառվող մեթոդների ամբողջությունն անվանում են տեքստի տոնայնության վերլուծություն (Sentiment Analysis)¹: Պարզելով տեքստերի զգայական նկարագիրը՝ օգտատերերի մեկնաբանությունների դրական կամ բացասական լինելը՝ ընկերությունը **շատ արագ և առանց լրացուցիչ ծախսերի** տեղեկություն է ստանում հաճախորդների պահանջմունքների փոփոխության մասին: Դա ազդակ է ստեղծելու նոր ապրանք կամ ծառայություն կամ ձևափոխելու եղանակ՝ համապատասխանեցնելով դրանք գնորդների ցանկություններին:

Տեքստի տոնայնության վերլուծության տարածված եղանակներից են ուսուցչի օգնությամբ մեքենայական ուսուցման մեթոդները², որոնք կազմված են երկու հիմնական փուլից՝ սովորել ուսուցման համար նախատեսված տվյալների հիման վրա (կառուցել մոտարկող ֆունկցիա) և կատարել դասակարգում արդեն նոր կամ թեստային տվյալներով (փաստաթուղթը ներառել որևէ դասի մեջ՝ ելնելով դրա բովանդակությունից):

Մեքենայական ուսուցման նախնական փուլում առանձնացվում է փաստաթղթերի ենթաբազմություն, որը բաժանվում է երկու չհատվող հատվածի՝ ուսուցողական և թեստային: Ամեն մի թեստային փաստաթուղթ տրվում է դասակարգչին որպես մուտքային տվյալ, այնուհետև ստացված արդյունքը համեմատվում է իրական ֆունկցիայի արժեքի հետ: Որքան համընկնումները շատ լինեն, այնքան դասակարգիչը կհամարվի արդյունավետ: Քանի որ փաստաթղթերի ծավալները բավականին մեծ են, անհրաժեշտ է լինում դրանցից հեռացնել այն բառերը (թերմերը), որոնք զգայական նկարագիր չեն պարունակում (օժանդակ բայեր, կապեր, շաղկապներ և այլն): Նման կերպ փաստաթղթերը բերվում են միննույն ձևաչափի, այսինքն՝ ինդեքսավորվում են:

Հաջորդ փուլում փաստաթղթերը բերվում են այնպիսի ձևաչափի, որի դեպքում դասակարգման ալգորիթմները արդեն կարող են աշխատել, այսինքն՝ ներկայացվում են վեկտորային տեսքով: Ցանկացած փաստաթուղթ ներկայացվում է թերմերի բազմությամբ: Յուրաքանչյուր թերմի համար որոշվում է կշիռ փաստաթղթի նկատմամբ, ուստի ամեն մի փաստաթուղթ կարելի է ներկայացնել որպես կշիռների վեկտոր:

Գոյություն ունի տեքստի տոնայնության դասակարգման մեթոդի գնահատման երկու հիմնական մոտեցում՝ դասակարգման տարրեր եղանակների համեմատում և որևէ չափողականությամբ տվյալ ալգորիթմի գնահատում: Ամենատարածվածը F1 չափողականությունն է, ո-

¹ Տե՛ս **E. Divya**. Real Time Sentiment Classification Using Unsupervised Reviews // International Journal of Scientific & Engineering Research, Volume 5, Issue 3, March-2014, էջ 61-65:

² Տե՛ս **Daniel Jurafsky, James H. Martin**. Speech and Language Processing. An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition. Third Edition draft. New York. 2018, էջ 10-37:

որը ներառում է երկու հիմնական հասկացություն՝ ճշգրտություն և լրիվություն³: Այս մեծությունները հեշտ է ստանալ՝ օգտվելով սխալանքի մատրիցից, որը ներկայացված է գծապատկեր 1-ում:

Գծապատկեր 1

Սխալանքի մատրից

		<i>gold standard labels</i>		
		gold positive	gold negative	
<i>system output labels</i>	system positive	true positive	false positive	precision = $\frac{tp}{tp+fp}$
	system negative	false negative	true negative	
		recall = $\frac{tp}{tp+fn}$		accuracy = $\frac{tp+tn}{tp+fp+tn+fn}$

Սխալանքի մատրիցում օգտագործվում են հետևյալ փոփոխականները.

- ճիշտ դրական (True Positive-tp)՝ դրական դեպքերի քանակը, որոնք ճիշտ են դասակարգվել,
- սխալ դրական (False Positive-fp)՝ բացասական դեպքերի քանակը, որոնք սխալմամբ դասակարգվել են որպես դրական,
- ճիշտ բացասական (True Negative-tn)՝ բացասական դեպքերի քանակը, որոնք ճիշտ են դասակարգվել,
- սխալ բացասական (False Negative-fn)՝ դրական դեպքերի քանակը, որոնք սխալմամբ դասակարգվել են որպես բացասական:

Ճշտությունը (Accuracy) ցույց է տալիս, թե դիտարկված բոլոր օրինակների քանի տոկոսն է ճիշտ դասակարգվել.

$$\left(\text{Accuracy} = \frac{tp + tn}{tp + fp + tn + fn} \right):$$

Ճշգրտությունը (Precision) դրական/բացասական օրինակների համար ցույց է տալիս ճիշտ դրական/բացասական տոնայնությամբ դասակարգված օրինակների քանակի և համակարգի՝ դրական/բացասական դասակարգված օրինակների քանակի հարաբերակցությունը.

$$\left(\text{Precision} = \frac{tp}{tp + fp} \right):$$

Լրիվությունը (Recall) դրական/բացասական օրինակների համար

³ Տե՛ս **Leon Derczynski**. Complementarity, F-score, and NLP Evaluation. University of Sheffield S1 4DP, UK, 2013, էջ 3. http://www.derczynski.com/sheffield/papers/fl_compl_eval.pdf. **Матрица ошибок** (Confusion matrix) <http://ru.learnmachinelearning.wikia.com/wiki/>

ցույց է տալիս ճիշտ դրական/բացասական տոնայնությամբ դասակարգված օրինակների քանակի և բոլոր դրական/բացասական տոնայնությամբ օրինակների քանակի հարաբերակցությունը.

$$\text{Recall} = tp + fp \left(\text{Recall} = \frac{tn}{fp + tn} \right):$$

Այս երկու հատկությունների հարմոնիկ միջինով որոշվում է F_β չափողականությունը⁴.

$$F_\beta = (1 + \beta^2) * \frac{\text{precision} * \text{recall}}{(\beta^2 * \text{precision}) + \text{recall}}:$$

β պարամետրը ընտրվում է ճշգրտության և լրիվության գնահատականների հիման վրա: Եթե β -ն մեկ է, ապա կունենանք հավասար կախվածություն՝ F1:

Տնտեսագիտական խնդիրներում ընդունված է կիրառել տրամաբանական ռեգրեսիայի մեթոդը⁵, երբ անհրաժեշտ է գտնել որոշակի իրավիճակի հավանականությունը հատկանիշների (ռեգրեսորների) x_1, x_2, \dots, x_n բազմությունից: Կախյալ y փոփոխականն ընդունում է երկու արժեք՝ հիմնականում 1 կամ 0: Ենթադրում ենք, որ x_0 հատկանիշը հավասար է մեկի: $y = 1$ լինելու հավանականությունն է.

$$p\{y = 1|x\} = f(z), \quad (1)$$

որտեղ՝

$$z = w^T x = w_0 + w_1 x_1 + w_2 x_2 + \dots + w_n x_n: \quad (2)$$

x -ը և w -ն՝ համապատասխանաբար x_0, x_1, \dots, x_n անկախ փոփոխականների և w_0, w_1, \dots, w_n ռեգրեսիայի պարամետրերի (կշիռների) վեկտոր սյուններն են:

$f(z)$ -ը տրամաբանական ֆունկցիան է.

$$f(z) = \frac{1}{1 + e^{-z}}: \quad (3)$$

$y = 0$ լինելու հավանականությունն է.

$$P\{y = 0|x\} = 1 - f(z) = 1 - f(w^T x): \quad (4)$$

y -ի բաշխման ֆունկցիան տրված x -ի դեպքում տրվում է հետևյալ բանաձևով.

$$P\{y|x\} = f(w^T x)^y (1 - f(w^T x))^{1-y}, \quad y \in \{0, 1\}: \quad (5)$$

Տեքստի տոնայնության վերլուծության խնդրում w_1, w_2, \dots, w_n ռեգրեսիայի պարամետրերը գտնելու համար անհրաժեշտ է կազմել ուսուցման

⁴ Տե՛ս **Leon Derczynski**. Complementarity, F-score, and NLP Evaluation. University of Sheffield S1 4DP, UK, 2013, էջ 4. http://www.derczynski.com/sheffield/papers/fl_compl_eval.pdf

⁵ Տե՛ս **Daniel Jurafsky, James H. Martin**. նշվ. աշխ., էջ 82-101:

հավաքածու (training set), որը կազմված է անկախ փոփոխականների և դրանց համապատասխան y կախյալ փոփոխականների հավաքածուներից: Ձևականորեն դա $(x^{(1)}, y^{(1)}), \dots, (x^{(m)}, y^{(m)})$ զույգերի բազմությունն է, որտեղ $x^{(i)} \in R^n$ -ը անկախ փոփոխականների արժեքների վեկտորն է, իսկ $y^{(i)} \in \{1, 0\}$ -ն՝ դրանց համապատասխան y -ի արժեքները: Այդպիսի յուրաքանչյուր զույգ կոչվում է ուսուցման նմուշ:

Ուսուցման x օրինակների համար w կշիռներն ընտրվում են այնպես, որ դրանց համապատասխան y հավանականությունները լինեն մեծագույնը: Մուտքային x^j տվյալի համար w կշիռն ընտրվում է

$$\hat{w} = \arg_w \max \log[(P(y^j)) | x^j] \quad (6)$$

բանաձևով⁶, իսկ ուսուցման բոլոր օրինակների համար՝

$$\hat{w} = \arg_w \max \sum_j \log(P(y^j | x^j)) \quad (7)$$

բանաձևով: Մաքսիմալացվում է նպատակային L ֆունկցիան.

$$L(w) = \sum_j \log P(y^j | x^j): \quad (8)$$

$P(c|x)$ հավանականությունը, կախված հատկանիշներից, հաշվարկվում է

$$P(c|x) = \frac{\exp(\sum_{i=1}^N [(w_i f_i(c, x))])}{\sum_{c' \in C} \exp(\sum_{i=1}^N [(w_i f_i(c', x))])} \quad (9)$$

բանաձևով, որտեղ $f_i(c, x)$ -ը նշանակում է, որ դիտարկվում է x -ի f_i հատկանիշը c դասի համար: Ուստի փնտրում ենք այնպիսի w , որը կմաքսիմալացնի նպատակային L ֆունկցիան՝ կախված ուսուցողական տեքստերում եղած հատկանիշներից:

Մոդելում X օբյեկտը կարելի է դասել $y=1$ դասին, եթե մոդելի կանխատեսած հավանականությունը $P\{y=1|x\} > 0.5$ և $y=0$ դասին՝ հակառակ դեպքում: Նոր մուտքային տվյալների համար կատարվում է կանխատեսում՝ հիմնվելով նախկին մուտքային տվյալներից ստացված ռեգրեսիայի պարամետրերի վրա: Տրամաբանական ռեգրեսիան առաջարկում է հավանականային ֆունկցիա, ըստ որի՝ նոր մուտքային տվյալը պետք է պատկանի մեր ունեցած դասերից որևէ մեկին:

Տրամաբանական ռեգրեսիայի մոդելի աշխատանքում առանձնացվում են որոշ մասնավոր դեպքեր: Հնարավոր է, որ միայն մեկ դասում հանդիպելու պատճառով ռեգրեսորը լինի մեծ կշռով: Այս դեպքում այն իդեալական կերպով սովորում է ուսուցման օրինակների վրա, բայց թեստային տվյալների համար լավ արդյունքներ չի տալիս:

⁶ Տե՛ս Daniel Jurafsky, James H. Martin, նշվ. աշխ., էջ 93:

Այսինքն՝ ունենք գերուսուցման խնդիր⁷, որից խուսափելու համար օգտագործվում է կանոնակարգող անդամ: (7) բանաձևը կանոնակարգումից հետո կունենա հետևյալ տեսքը⁸.

$$w = \arg \max_w \sum_j \log P(y^{(j)} | x^{(j)}) - \alpha R(w): \quad (10)$$

$R(w)$ ֆունկցիան օգտագործվում է մեծ կշիռները փոքրացնելու համար: Որպես R ֆունկցիա կարող է լինել $L2$ կանոնակարգումը, որը ցույց է տալիս էվկլիդեսյան հեռավորությունը.

$$R(w) = \|W\|_2^2 = \sum_{j=1}^N w_j^2: \quad (11)$$

Օգտվելով (11) բանաձևից՝ (10)-ը կստանա հետևյալ տեսքը.

$$w = \arg \max_w \sum_j \log P(y^{(j)} | x^{(j)}) - \alpha \sum_{j=1}^N w_j^2: \quad (12)$$

Մեկ այլ կանոնակարգում է $L1$ -ը, որը գծային ֆունկցիա է.

$$R(w) = \|W\|_1 = \sum_{i=1}^N |w_i|: \quad (13)$$

Կիրառելով $L1$ կանոնակարգումը՝ նպատակային ֆունկցիայի համար կստանանք

$$w = \arg \max_w \sum_j \log P(y^{(j)} | x^{(j)}) - \sum_{i=1}^N |w_i| \quad (14)$$

տեսքը: Այս երկու ֆունկցիաներն էլ հաճախ օգտագործվում են բնական լեզվի մշակման (NLP) խնդիրներում:

Ընկերության մարքեթինգային քաղաքականության մեջ տրամաբանական ռեգրեսիայի մոդելի կիրառման նպատակով մենք հավաքեցինք 500 հայերեն տեքստ `twitter.com` և 200 տեքստ `facebook.com` սոցիալական կայքերից և դրանց հիման վրա կառուցեցինք հայերեն տեքստերի համար մինչ այժմ գոյություն չունեցող կորպուսներ (`twitter-corpus.scv` և `facebook-corpus.scv`):

Մոդելի կիրառման համար անհրաժեշտ ծրագրերը գրեցինք Python ծրագրավորման լեզվով: Օգտագործեցինք `sklearn` գրադարանի `LogisticRegression` դասը: Սկզբում բեռնեցինք տեքստային տվյալները և դրանց համապատասխան տոնայնությունները, այնուհետև տեքստերից հեռացրեցինք սիմվոլները, հղումները և ոչ էական բառերը (`stop words`): Մուտքային տվյալները թվայնացրեցինք երկու եղանակով՝ `Bag`

⁷ Տե՛ս «Underfitting and Overfitting in Machine Learning» // <https://www.geeksforgeeks.org/underfitting-and-overfitting-in-machine-learning>

⁸ Տե՛ս **Daniel Jurafsky, James H. Martin**, նշվ. աշխ., էջ 97:

of words և Word2vec մոդելներով⁹: Oգտագործեցինք sktlearn CountVectorizer դասը, որի միջոցով մուտքային տվյալներից կառուցեցինք հատկանիշների բառարանը: Այնուհետև ստացվող տվյալները որպես մուտքային արժեք փոխանցեցինք LogisticRegression դասին: Այն ստեղծեց դասակարգող օբյեկտը, որը, ստանալով մուտքային գրառումների վեկտորական տեսքը և դրանց համապատասխան տոնայնությունները (դրական, բացասական), ուսուցանեց մոդելը:

Մուտքային տվյալը (x փաստաթուղթը) դրական (+) և բացասական (-) դասերում զետեղելու համար օգտագործեցինք մասնավորապես հետևյալ հատկանիշները.

$$f_1(c, x) = 1 \text{ if "լավ" } \in x \ \& \ c = + \text{ otherwise } 0,$$

$$f_2(c, x) = 1 \text{ if "վատ" } \in x \ \& \ c = - \text{ otherwise } 0,$$

$$f_3(c, x) = 1 \text{ if "հիանալի" } \in x \ \& \ c = - \text{ otherwise } 0:$$

Այս հատկանիշներից ամեն մեկին տվեցինք կշիռ, որը կարող է լինել դրական կամ բացասական: $w_1(c, x)$ -ը ցույց է տալիս «լավ» բառի կշիռը $c = +$ դասի համար, $w_2(c, x)$ -ը և $w_3(c, x)$ -ը՝ համապատասխանաբար «վատ» և «հիանալի» բառերի կշիռները դասի համար: $w_2(c, x)$ -ը կլինի դրական, քանի որ ժխտական բառերը տրամաբանորեն ավելի շատ կհանդիպեն բացասական իմաստ ունեցող տեքստերում: Բայց $w_3(c, x)$ -ը կլինի բացասական, քանի որ «հիանալի» բառը հիմնականում հանդիպում է դրական տոնայնությամբ տեքստերում: Ուսուցման յուրաքանչյուր նմուշի համար որոշեցինք դրանց հատկությունները և համապատասխան կշիռները:

Ուսուցման ավարտից հետո պատրաստի մոդելը փորձարկեցինք թեստային գրառումների վրա և թեստավորմամբ ստացանք հետևյալ ցուցանիշները.

$$\text{Accuracy} = 0.789, \text{ Precision} = 0.784, \text{ Recall} = 0.789, \text{ F1} = 0.785:$$

Սա նշանակում է, որ համակարգը ճիշտ է դասակարգել տվյալների 78.9 տոկոսը: Ճշգրիտ դրական (կամ բացասական) տոնայնությամբ օրինակների համար համակարգը որպես դրական (կամ բացասական) է դասակարգել օրինակների 78.4 տոկոսը: Իրականում դրական (կամ բացասական) դեպքերի մեջ որպես դրական (կամ բացասական) է դասակարգվել օրինակների 78.9 տոկոսը: Համակարգի F1 չափողականությունը 0.785 է :

Պարամետրերի հետագա կանոնակարգումների համար CountVectorizer դասը փոխարինեցինք TfidfVectorizer-ով, որն իրականացնում է TFIDF մշակված ալգորիթմը: Այս փոփոխություններից հետո

⁹ Տե՛ս «Testing word2vec on Armenian Wikipedia». <https://devhub.io/repos/YerevaNN-word2vec-armenian-wiki>

ստացանք հետևյալ արդյունքները.

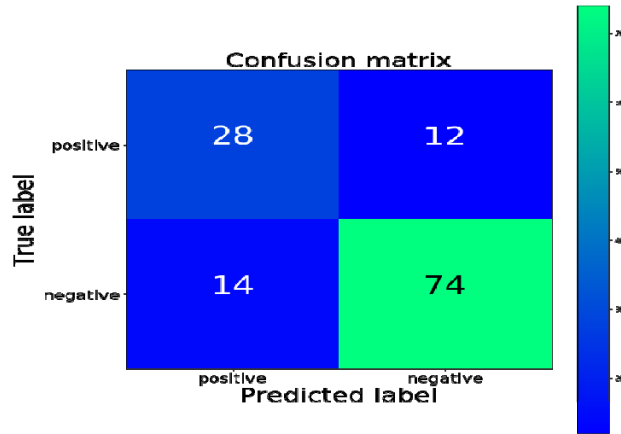
Accuracy = 0.773, Precision = 0.772, Recall = 0.773, F1 = 0.773:

Այսինքն՝ մոդելի աշխատանքի ճշգրտությունը 78.4-ից նվազեց՝ հասնելով 77.2 տոկոսի, լրիվությունը՝ 78.5-ից 77.3 տոկոսի, ճշտությունը՝ 78.9-ից 77.3 տոկոսի: F1 չափողականությունը վկայեց, որ TfidfVectorizer դասի օգտագործումը sklearn CountVectorizer դասի համեմատ տվել է պակաս որակյալ արդյունք: Հարկ է նշել, որ մուտքային տվյալները այս դեպքում թվայնացրել ենք Bag of words մեթոդով, իսկ հետո՝ թվայնացման համար օգտագործել Word2vec մեթոդը:

Bag of words մեթոդով փորձարկումից ստացված սխալների աղյուսակը ներկայացված է գծապատկեր 2-ում, համաձայն որի՝ իրական 40 դրական գրառումներից դրական են դասակարգվել 42-ը, իսկ 88 բացասական գրառումներից բացասական են կանխատեսվել 86-ը:

Գծապատկեր 2

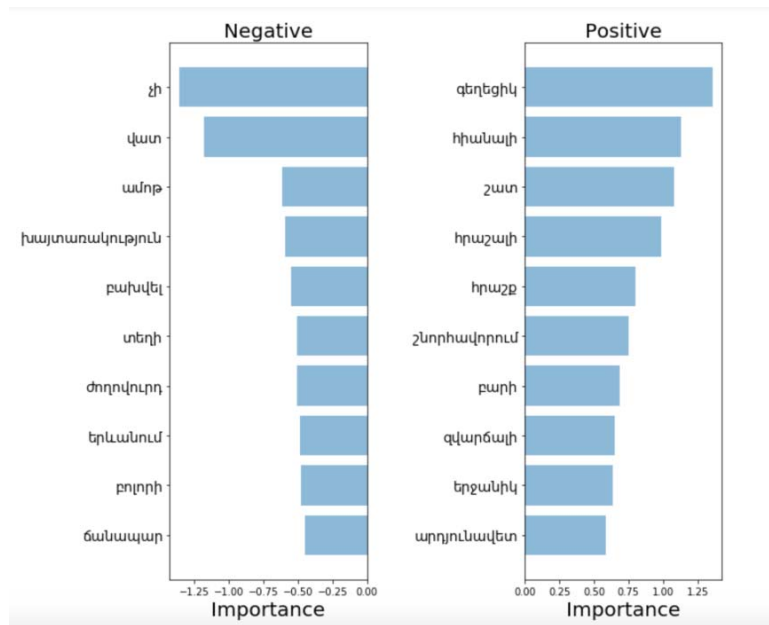
Տրամաբանական ռեգրեսիայի մոդելի սխալների աղյուսակը



Մոդելում ստացանք նաև բառերի կարևորության աստիճանի գնահատումը դրական կամ բացասական տոնայնություն ունեցող տեքստերում ըստ կշիռների: Գծապատկեր 3-ից երևում է, որ մոդելը կարողացել է բավական լավ առանձնացնել դրական և բացասական իմաստ ունեցող բառերը: Դրականներից ամենաբարձր կշիռն ունի «գեղեցիկ» բառը, այնուհետև՝ «հրաշալի» և «շատ» բառերը: Բացասական իմաստ ունեցողներից ամենամեծ կշիռն ունեն «չի» և «վատ» բառերը: Նշենք, որ իրականում որևէ զգայական նկարագիր չունեցող որոշ բառերի («տեղ», «ժողովուրդ») տրվել են բարձր (ցածր) կշիռներ¹⁰: Պատկերը կարող է փոխվել, եթե ուսուցման տվյալների քանակը շատացնենք:

¹⁰ Ծրագիրը պատահականության սկզբունքով ընտրել է տեքստ twitter.com և facebook.com սոցիալական կայքերից: Գծապատկեր 3-ում ներկայացված «տեղի», «ժողովուրդ» և այլ բառերը ծրագիրն առանձնացրել է այդ տեքստից:

Բառերի կարևորության աստիճանի գնահատումը տրամաբանական ռեգրեսիայի մոդելում



Մոդելում կիրառել ենք մուտքային տեքստերի ձևափոխման Word2vec և Bag of Words մեթոդները, որոնք օգտագործում են տեքստերի վեկտորացման տարբեր մեխանիզմներ: Տեքստերի ձևափոխման Word2vec մեխանիզմը կիրառելիս ռեգրեսիայի մոդելի իրականացման դեպքում ստացանք հետևյալ արդյունքները.

Accuracy = 0.812, Precision = 0.819, Recall = 0.812, F1 = 0.815:

Իսկ Bag of Words մեխանիզմը կիրառելիս ստացանք հետևյալ արդյունքները.

Accuracy = 0.789, Precision = 0.784, Recall = 0.789, F1 = 0.785:

Աղյուսակ 1

Տրամաբանական ռեգրեսիայի մոդելի կիրառման արդյունքները

Դասակարգիչ	Accuracy	Precision	Recall	F1 չափողակ.	Ուսուց. ժ. (վրկ.)
Bag of Words	0.773	0.772	0.773	0.773	0.005948
Word2vec	0.812	0.819	0.812	0.815	0.042347

Աղյուսակ 1-ում ներկայացված են տրամաբանական ռեգրեսիայի մոդելի կիրառման արդյունքները տվյալների վեկտորացման տարբեր մեթոդների դեպքում, որտեղ նշված են նաև մոդելի ուսուցման համար ծախսված ժամանակահատվածները: Աղյուսակը փաստում է, որ տվյալների ներկայացման Word2vec մեխանիզմն օգտագործելիս ստա-

ցել ենք ավելի լավ արդյունքներ, քան Bag of Words-ի:

Այսպիսով, տեքստի տոնայնության վերլուծությունը հնարավորություն է տալիս բարձրացնելու մարքեթինգային քաղաքականության արդյունավետությունը, որն իր հերթին կարող է նպաստել ընկերության վաճառքի ծավալների և շահույթի աճին: Մարքեթինգային քաղաքականության մեջ տրամաբանական ռեգրեսիայի մոդելի կիրառման արդյունքները վկայում են, որ համակարգը 80 տոկոս ճշտությամբ տալիս է տեքստերի զգայական նկարագիրը՝ օգտատերերի մեկնաբանությունների դրական կամ բացասական լինելը:

Նոր գրառումներ ներբեռնելու և կառուցված մոդելը իրականացնելու ծրագրային մեր մշակած մոդուլները տեղադրվել են github.com կայքում՝ <https://github.com/hripman/Armenian-corpus>:

Բանալի բառեր – *տրամաբանական ռեգրեսիա, ռեգրեսիայի պարամետրեր, տեքստի տոնայնության վերլուծություն, բնական լեզվի մշակում, ուսուցման հավաքածու, սխալանքի մատրից*

СИРАНУШ САРКИСЯН, АЛВАРД ХАРАТЯН, АННА ОВАКИМЯН – *Логистическая регрессия как инструмент маркетинга.* – Правильно выбранная маркетинговая политика – один из ключевых факторов роста прибыли. Сегодня тысячи компаний и организаций посредством своих официальных сайтов используют Интернет в маркетинговых целях. Анализ тональности сделанных пользователем записей позволяет быстро, без дополнительных затрат получать информацию о том, как меняются требования потребителей. Моделью логистической регрессии, представленной в работе, можно пользоваться как инструментом, повышающим эффективность маркетинговой политики.

Разработанные авторами программные модули для загрузки новых записей и осуществления встроеной модели размещены на сайте github.com <https://github.com/hripman/Armenian-corpus>.

Ключевые слова: *логистическая регрессия, параметры регрессии, анализ тональности текста, обработка естественного языка, обучающее множество, матрица ошибок*

SIRANUSH SARGSYAN, ANNA HOVAKIMYAN, ALVARD KHARATYAN – *Logistic Regression as a Marketing Tool.* – A properly selected marketing policy is one of the key factors in the growth of profitability of a firm. Thousands of companies and organizations today have their own official websites and can use the Internet for marketing purposes. With sentiment analysis, one can analyze user-generated records and quickly get information about the changing demands of customers without additional costs. The logistic regression model presented in the work can be used as a tool to increase the effectiveness of the firm's marketing policy.

We created software modules to download new records and to implement the built-in model that can be found on github.com (<https://github.com/hripman/Armenian-corpus>).

Key words: *logistic regression, regression parameters, text sentiment analysis, natural language processing, training set, confusion matrix*

Ներկայացվել է՝ 04.02.2019, գրախոսվել է՝ 22.02.2019, ընդունվել է տպագրության՝ 22.04.2019