

ART ՆԵՅՐՈՆԱՅԻՆ ՑԱՆՑԻ ԿԻՐԱՌՄԱՆ ՀՆԱՐԱՎՈՐՈՒԹՅՈՒՆԸ
ՍՊԱՌՈՂՆԵՐԻ ԱՆՀԱՏԱԿԱՆԱՑՄԱՆ ՀԱՄԱԿԱՐԳԻ ԿԱՌՈՒՑՄԱՆ
ՀԱՄԱՐ

ՀՏԴ 004.8

DOI 10.56246/18294480-2022.12-02

ԽՈՒՐՇՈՒԴՅԱՆ ԱՐՄԵՆ

լոնդոնական գիտությունների թեկնածու, դոցենտ,
ԳՊՀ ինֆորմատիկայի և ֆիզիկամաթեմատիկական գիտությունների
ամբիոնի դասախոս
էլփոստ՝ armkhur@mail.ru

ՄԱՐԴՈՅԱՆ ՇՈՒՇԱՆ

ԳՊՀ բնագիտական ֆակուլտետի «Համակարգչային
ճարտարագիտություն» բաժնի
մագիստրատուրայի երկրորդ կուրսի ուսանողուհի
էլփոստ՝ mardoyan98@bk.ru

**Հոդվածում ներկայացված են սպառողների անհատականացման
կամ, ինչպես հաճախ անվանում են, առաջարկությունների տրման հա-
մակարգի նախագծման և մշակման արդյունքները: Անհատականացման
խնդրի լուծումը պահանջում է սպառողների որոշակի դասակարգում ըստ
տարբեր, հաճախ նախապես չկանխատեսված հատկանիշների հա-
մընկնման: Այդպիսի խմբավորումը անվանում են կլաստերացում: Սպա-
ռողներին համասեռ կլաստերների բաժանելու նպատակով նախագծվել
և կառուցվել է ադապտիվ ռեգոնանսի տեսության (ART) ներդրային
ցանց: Ցանցի ուսուցումը իրականացվել է Ս. Գրոսսբերգի և Գ. Կարպեն-
թերի ART1 ալգորիթմի օգտագործմամբ: Ուսուցումն իրականացվել է
սպառողների գնումների պատմության վեկտոր-հատկանիշների պայմա-
նական ընտրանքի կիրառմամբ: Որպես կլաստերների բաժանման մե-
թոդ՝ ընտրվել է գնումների նմանության համեմատման վրա հիմնված
«item-based» սկզբունքը, որը պատկանում է, այսպես կոչված, «կոլաբո-
րատիվ» զտման (ֆիլտրման) համակարգերի դասին: Ուսուցման փուլի
ավարտին պայմանական սպառողները բաժանվել են երեք համասեռ
դասերի (կլաստերների), որոնցից յուրաքանչյուրի համար կառուցվել է
վեկտոր-պրոֆոտիպ՝ հեղադա կիրառման հնարավորությամբ: Առաջար-**

կոլոնիաների տրաման նպատակով յուրաքանչյուր ստացված կլաստերի նկատմամբ օգտագործվել է գումարման վեկտորը, որի միջոցով կազմվել են ռեկոմենդացիաներ բոլոր սպառողների համար: Ստացված արդյունքների հիման վրա կարելի է եզրակացնել, որ ART1 ալգորիթմը, ապահովելով «կայունության-ճկունության» սկզբունքի կատարումը, թույլ է տալիս արդյունավետ իրականացնել սպառողների բաժանումը կլաստերների ըստ նախընտրությունների համընկնման սկզբունքի, իսկ գումարման վեկտորի կիրառումը՝ ստանալ առաջարկությունների տրաման ավարտուն համակարգ:

Բանալի բառեր՝ նեյրոնային ցանց, ադապտիվ ռեգոնանսի տեսություն, վեկտոր հարկանիշ, վեկտոր պրոյուկտիա, կլաստերացման ալգորիթմ, ART1 ալգորիթմ, ինքնակազմակերպող նեյրոնային ցանցեր:

Նախ ներկայացնենք անհատականացման խնդիրը ֆորմալ տեսքով: Դիցուք, ունենք սպառողների բազմություն $U = \{u_1, u_2, \dots, u_n\}$, օբյեկտների (օրինակ, ապրանքների) բազմություն $P = \{p_1, p_2, \dots, p_m\}$ և $n \times m$ վարկանիշային մատրից $R = (r_{ij})$, որտեղ $i \in 1 \dots n$, $j \in 1 \dots m$: Վարկանիշավորման հնարավոր արժեքները կարող են լինել սանդղակային, օրինակ, 1-ից (չի հավանել) մինչև 5-ը (շատ է հավանել) կամ բինար (գնել է / չի գնել)՝ արտահայտված որպես 1 և 0: Եթե i -րդ սպառողը որևէ կերպ չի վարկանիշավորել j ապրանքը, ապա համապատասխան r_{ij} վանդակը դատարկ կլինի: Օրինակ պատկեր 1-ում ներկայացված է բինար տեսքով լրացված վարկանիշների մատրիցան:

	Ապրանք1	Ապրանք2	Ապրանք3	Ապրանք4	Ապրանք5	Ապրանք6
Գնորդ 1	1	1	0	1	1	0
Գնորդ 2	1	0	1	1	1	0
Գնորդ 3	1	1	0	1	1	0
Գնորդ 4	0	0	1	1	0	0
Գնորդ 5	0	1	1	1	0	0

Պատկեր 1. Վարկանիշների մատրիցան բինար տեսքով:

Խնդիրը հետևյալն է՝ լավագույնս կանխատեսել, թե ինչ գնահատականներ պետք է լինեն r_{ij} -ը, վարկանիշային մատրիցայի դատարկ վանդակներ:

րում, այսինքն՝ հաշվարկել r_{ij} : Այնուհետև յուրաքանչյուր u_i սպառողի համար, հիմնվելով r_{ij} կանխատեսված արդյունքների վրա, մենք պետք է ձևավորենք N ապրանքների ցանկ, որոնք առավել շատ են համապատասխանում օգտատիրոջ նախընտրություններին և դեռ չեն գնահատվել սպառողի կողմից:

Ներկայումս գոյություն ունեն բազմաթիվ մոտեցումներ սպառողների անհատականացման (առաջարկությունների տրման) համակարգերի ստեղծման խնդիրը լուծելու ուղղությամբ: Հիմնական առաջարկող ալգորիթմները կարելի է բաժանել մի քանի խմբի, օրինակ, «կոլաբորատիվ» գտման (ֆիլտրման) համակարգեր, բովանդակության վրա հիմնված գտման համակարգեր, ինչպես նաև օգտվողի գիտելիքների վրա հիմնված և այլ համակարգեր:

Առավել հաճախ կիրառվում են, այսպես կոչված, «կոլաբորատիվ» գտման (ֆիլտրման) համակարգերը: Նման համակարգերի հիմնական գաղափարն այն է, որ եթե նախկինում սպառողներն ունեին նույն հետաքրքրությունները, ապա ապագայում նրանց նախասիրությունները նույնպես կհամընկնեն: Օրինակ, եթե սպառողները, որոնք գնահատել են երկու ապրանք, հավանել են երկուսն էլ, ապա այն սպառողներին, որոնք փորձել են միայն մեկը, կարելի է առաջարկել երկրորդը, որն ամենայն հավանականությամբ իրենց դուր կգա: Մեծ հաշվով բոլոր նոր զարգացումները, որոնք հիմնված են ինչպես բովանդակության, այնպես էլ օգտվողի գիտելիքների վրա, «կոլաբորատիվ» գտման մոտեցումների բարելավումն են:

Կամայական մեթոդաբանության կիրառումը պահանջում է սպառողների որոշակի դասակարգում ըստ տարբեր, հաճախ նախապես չկանխատեսված, հատկանիշների համընկնման: Այդպիսի խմբավորումը անվանում են կլաստերացում: Կլաստերացման ալգորիթմները մեթոդներ են, որոնց շնորհիվ տվյալները բաժանվում են և միավորվում ոչ մեծ խմբերի (կլաստերների) ըստ անալոգիայի սկզբունքի: Ըստ նույն սկզբունքի՝ իրականացվում է միմյանց չնմանվող տվյալների առանձնացումը, և այդ պատճառով էլ տվյալները կլաստերի բաժանման գլխավոր խնդիրը դասակարգումն է: Դասակարգումը օգտագործվում է շատ դեպքերում, սակայն նրա հիմնական նշանակումն է կլաստերների ուսումնասիրությունը՝ նրանց միջև եղած տարբերությունները բացահայտելու համար:

Արհեստական բանականության ընկալումը մոդելավորող համակարգերի կառուցման ժամանակ ամենաբարդ ու դժվար լուծելի խնդիրներից մեկը

Ս. Գրոսսբերգի կողմից ձևակերպված **կայունության-ճկունության դիլեման է[1]**: Կենդանի օրգանիզմների (առաջին հերթին՝ մարդու) արտաքին աշխարհի ընկալման բնույթը մշտապես կապված է երկընտրանքի լուծման հետ. Արդյո՞ք որոշակի կերպար «նոր» տեղեկատվություն է, և, հետևաբար, դրա արձագանքը պետք է լինի որոնողական-ճանաչողական, հիշողության մեջ այդ կերպարի պահպանման հետ, կամ այդ կերպարը «հին», արդեն ծանոթ պատկեր է, և այդ դեպքում օրգանիզմի արձագանքը պետք է համապատասխանի նախկինում կուտակված փորձին:

Նեյրոնային ցանցերը հիմնականում հարմարեցված չեն այդ խնդրի լուծմանը: Օրինակ՝ բազմաշերտ պերսեպտրոնները, որոնք ուսուցանվում են հակառակ տարածման կամ հակադարձ փոխազդեցության (հակադարձ կապի) մեթոդներով, հիշում են ուսուցման տեղեկատվության ամբողջ փաթեթը: Ընդ որում նախնական ուսումնական նմուշի պատկերները ուսուցման ընթացքում բազմիցս փոփոխվում են: Պերսեպտրոնը վերուսուցելու, մուտքում նոր կերպար առաջարկելով, հանգեցնում են սինապտիկ կապերի անվերահսկելի փոփոխությունների, ընդհանուր առմամբ, հիշողության կառուցվածքի նախորդ պատկերների ոչնչացմանը: Այսպիսով, պերսեպտրոնը չի կարողանում «հիշել» նոր տեղեկատվությունը, անհրաժեշտ է ցանցի ամբողջական վերանայում:

Նմանատիպ իրավիճակ է նաև Կոհոնենի [3] և Լիպպման-Հեմինգի ցանցերում, որոնք սովորում են ինքնակազմակերպման հիման վրա: Դասակարգման ժամանակ այդպիսի ցանցերը միշտ դրական արդյունք են տալիս: Սակայն նույնիսկ այդ տիպի նեյրոնային ցանցերը չեն կարողանում առանձնացնել նոր պատկերները աղավաղված «հին» պատկերների տարբերակներից:

Այդ թերությունից զուրկ է ադապտիվ ռեզոնանսի տեսության (Adaptive Resonance Theory) նեյրոնային ցանցը, որն իրենից ներկայացնում է վեկտորային դասակարգիչ: Մուտքային վեկտորը դասակարգվում է, կախված նրանից, թե նախապես հիշված որ վեկտորին է (այդ վեկտորները անվանվում են նախատիպեր) նմանեցվում: Այն դեպքում, երբ այն նման չէ և ոչ մի նախատիպի, ստեղծվում է նոր կլաստեր նոր վեկտորի պատկերը որպես նախատիպ պահպանելու միջոցով:


Իսկ եթե որոշվում է, որ մուտքի վեկտորը ըստ որոշակի չափանիշների նման է նախատիպերից որևէ մեկին, հիշված վեկտորը ձևափոխվում է (ուսուցանվում է) այնպես, որ ավելի շատ նմանվի մուտքային վեկտորին: Իհարկե, եթե նմանության աստիճանը բավարարում է որոշակի ընդունված

չափանիշի, ապա նախատիպը չի փոփոխվում: Այդպես լուծվում է նաև կա-
յունության-ճկունության երկրճնտրանքը:

ART ցանցերի ուսուցման առավել հայտնի ալգորիթներից է Ս. Գրոսս-
բերգի և Գ. Կարպենթերի ART1 ալգորիթը [2]: ART1 ալգորիթը աշխատում
է օբյեկտների հետ, որոնք անվանվանում են վեկտոր-հատկանիշներ (feature
vector): Հատկանիշների վեկտորը բինար կոդով ներկայացված արժեքների
խումբ է, որը ներկայացնում է ինֆորմացիայի որոշակի տիպ: Որպես վեկ-
տոր-հատկանիշի օրինակ կարող ենք վերցնել գնումների ընտրությունը:
Վեկտորի յուրաքանչյուր օբյեկտը ցույց է տալիս, թե արդյո՞ք սպառողը գնել
է որոշակի ապրանքը (եթե այո, ապա համապատասխան դիրքում արժեքը
հավասար է 1, եթե ոչ՝ 0): Սպառողը գնել է ապրանք 1 և ապրանք 4 (պատ-
կեր 2):

ապր. 1	ապր. 2	ապր. 3	ապր. 4	ապր. 5	ապր. 6	ապր. 7	ապր. 8	ապր. 9	ապր. 10	ապր. 11
1	0	0	1	0	0	0	0	0	0	0

Պատկեր 2. Սպառողի մասին տվալներ պարունակող վեկտոր-հատկանիշի
օրինակ:



Պատկեր 3. ART1 ալգորիթի աշխատանքի բլոկ-սխեման:

ART1 ալգորիթմի աշխատանքի բլոկ-սխեման ներկայացված է պատկեր 3-ում:

Ալգորիթմի գործարկման պահին դեռ գոյություն չունի ոչ մի վեկտոր-պրոտոտիպ, այդ պատճառով էլ ալգորիթմը կատարման սկզբում ստեղծվում է առաջին վեկտոր-պրոտոտիպը հենց առաջին վեկտոր հատկանիշից (հավասարում 1):

$$P_0 = E_0 \quad (1)$$

Այնուհետև համեմատում ենք բոլոր հաջորդ վեկտոր-հատկանիշները այդ վեկտոր պրոտոտիպի հետ: Ստուգվում է, թե որքան են նման վեկտոր-հատկանիշը և ընթացիկ վեկտոր-պրոտոտիպը: Բետա-պարամետրը, որն օգտագործվում է նմանության ստուգման հավասարման մեջ (հավասարում 2), «կապի փլուզման» պարամետրն է: Այն ընտրում է այն պրոտոտիպերը, որոնք ավելի շատ մեկեր ունեն այն պայմանով, որ վեկտոր-պրոտոտիպի բոլոր 1-երը առկա են նաև թեստավորվող վեկտոր-հատկանիշում:

$$\frac{||P_{inE}||}{\beta + ||P_i||} > ||E|| / (\beta + d) \quad (2)$$

Եթե նմանության թեստը անցել է հաջող, ապա իրականանում է հաջորդ թեստը, ստուգում ենք վեկտոր-հատկանիշը և վեկտոր-պրոտոտիպը ըստ ուշադրության պարամետրի (հավասարում 3): Տվյալ պարամետրի խնդիրը կլաստերի (այսինքն, համապատասխան պրոտոտիպի) չափսի գնահատումն է: Եթե պարամետրի նշանակությունը մեծ է, ձևավորվում են ավելի մեծ դասեր (տվյալների ավելի մեծ քանակով կլաստերներ): Արժեքը նվազելու դեպքում ստեղծվում են փոքրաքանակ տվյալներով կլաստերներ: Եթե ուշադրության պարամետրին վերագրված արժեքը բավականաչափ փոքր է ($< 0,1$), վեկտոր-հատկանիշները կլաստերում ընդգրկելու համար պետք է համապատասխանեն վեկտոր-պրոտոտիպին:

$$\frac{||P_{inE}||}{||E||} < \rho \quad (3)$$

Եվ վերջապես, եթե ուշադրության թեստը նույնպես հաջող է անցել, ալգորիթմը ավելացնում է ընթացիկ վեկտոր-հատկանիշը ընթացիկ վեկտոր-պրոտոտիպում (հավասարում 4):

$$P_i = P_{inE} \quad (1.3.4)$$

Այդ գործընթացը միավորում է հատկանիշների վեկտորը և վեկտոր-պրոտոտիպը «եվ» օպերացիայի միջոցով: Եվ եթե ճշտության թեստը (կամ նմանության թեստը) անցած չէ, ստուգվում է հաջորդ վեկտոր-պրոտոտիպը: Եթե բոլոր վեկտոր-պրոտոտիպերը ստուգված են, և վեկտոր-հատկանիշը չի

ընդգրկվել որևէ կլաստերում, այդ վեկտորից ստեղծվում է նոր վեկտոր-պրոտոտիպ: Դա հանգեցնում է նոր կլաստերի ձևավորմանը:

ART1 ալգորիթմի աշխատանքային պարամետրերի ցուցակը ներկայացված է աղյուսակ 1-ում:

Աղյուսակ 1.


ART1 ալգորիթմի աշխատանքային պարամետրերի ցուցակը:

Պարամետրերը	Նկարագրությունը
σ	Բիթային «եվ» վեկտորը
$ \sigma $	σ վեկտորի 1 տարրերի քանակն է (վեկտոր-հատկանիշի արժեքը)
N	Կլաստերների մեծագույն քանակը (պրոտոտիպների քանակը)
ρ	Չափի պարամետր (ուշադրության) ()
ρ	Վեկտոր-նախատիպ (պրոտոտիպ)
E	Վեկտոր հատկանիշ
d	Վեկտորի չափը (երկարությունը)
β	Բետտա-պարամետր

Ի սկզբանե ART ալգորիթմը ստեղծվել է երկչափ պատկերների ճանաչման նպատակով և անհատականացման խնդրի լուծման առաջին փուլում, կիրառվում է սպառողներին ըստ կատարած գնումների պատմության կազմած բինար արժեքներով վեկտորները կլաստերների բաժանելու համար:

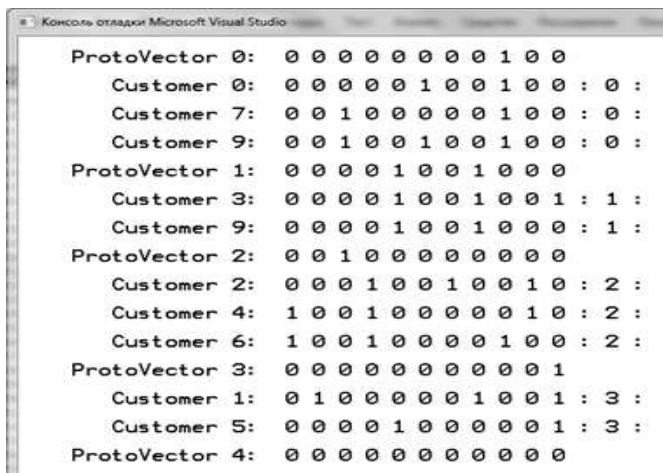
Երկրորդ փուլում վերլուծվում է այն գնորդի հատկանիշների վեկտորը, որին պետք է տրվի առաջարկություն: Այդ նպատակը իրականացնելու համար կիրառվել է նոր տարր, որը ներառված չէ ART1 ալգորիթմի մեջ. այսպես կոչված՝ գումարման վեկտորը (Sum vector): Գումարման վեկտորը իրենից ներկայացնում է տվյալ կլաստերի վեկտոր-հատկանիշների սյունակների արժեքների գումարը:

Առաջարկությունների ներկայացման գործընթացը դիտարկենք պարզ օրինակով: Ենթադրենք այն հաճախորդը, որին պետք է տրվի առաջարկություն, ներկայացված է հատկանիշների 1-ին վեկտորով, որն ընդգրկված է A կլաստերում: Հատկանիշների վեկտորի բովանդակությունը համապատասխանում է պատկեր 4-ում ներկայացված օրինակին (հաճախորդների գնումների պատմությունը):



Պատկեր 4. Գումարման վեկտորը:

Կիրառելով գումարման վեկտորը՝ առաջին հերթին անհրաժեշտ է որոշել այն ապրանքները, որոնք ներառված են տվյալ կլաստերում (այսինքն՝ համապատասխան դիրքում 0 գրանցված չէ): Այնուհետև ալգորիթմը գումարման վեկտորում գտնում է ամենամեծ արժեքը, որը համապատասխանում է հաճախորդի հատկանիշների վեկտորի 0 արժեքով օբյեկտին: Դա այն ապրանքն է, որը ձեռք չի բերվել գնորդի կողմից, բայց առավել գրավիչ է կլաստերում ընդգրկված սպառողների համար: Նման տեղեկատվությունն ընկած է առաջարկությունների հիմքում: Ենթադրությունը (կամ վիճակագրական կանխատեսումը) հետևյալն է. A կլաստերի հաճախորդների



Պատկեր 5. Կլաստերի քարտեզագրումը:

66%-ը արդեն գնել է այս ապրանքը (օրինակում՝ ապրանք համար երեքը), իսկ դա նշանակում է, որ մեծ հավանականությամբ այս հաճախորդը նույնպես կցանկանա այն գնել:

Կլաստերացման ալգորիթմի և անհատականացման խնդրի լուծման համար կազմել ենք ծրագիր ծրագրավորման C++ լեզվով, որի աշխատունակությունը ստուգել ենք 10 վեկտոր-հատկանիշների պայմանական բազմության օրինակով: ART1 ալգորիթմի կիրառության արդյունքում ստացված հատկանիշների վեկտորները բաժանվել են կլաստերների: Միևնույն ժամանակ վեկտոր-պրոտոտիպերից յուրաքանչյուրը ցուցադրվում է կլաստերի հատկանիշների վեկտորների հետ միասին: Սկզբնական տվյալների հիման վրա ստեղծվել է ընդամենը երեք կլաստեր, չնայած մատչելի էին հինգը (պատկեր 5):

Պատկեր 6-ում ներկայացված է անհատականացման խնդրի լուծման արդյունքները վերը ներկայացված վեկտոր-հատկանիշների պայմանական համախմբի համար: Վերին մասում տեսնում ենք ART1 ալգորիթմի աշխատանքի արդյունքը, իսկ ստորին մասում գումարման ֆունկցիայի միջոցով ստացված գնորդներին տրվող առաջարկությունները :

For Customer 0, The best recommendation is 2
(Snickers Owned by 2 out of 3 members of trixs cluste Already owns:
Kit - Kat Heath Bar

For Customer 1, The best recommendation is 4
(Pen) Owned by 1 out of 2 members of this cluste Already owns:
Paper Pencil Binder

For Customer 2, The best recommendation is 0
(Hammer) Owned by 2 out of 3 members of this cluster Already owns:
Screwdriver Wrench Tape - Measure

For Customer 3, No recommendation can be made.
Already be y Already owns:
Pen Pencil Binder

Պատկեր 6. գնորդներին տրվող առաջարկությունները:

Օգտագործված գրականության ցանկ

1. Grossberg S. Classical and instrumental learning by neural networks. Progress in theoretical biology, vol. 3, pp. 51-141. New York: Academic Press. 1974.
2. Carpenter G., Grossberg S. A Massively Parallel Architecture for a Self-



Organizing Neural Pattern Recognition Machine // Computer Vision, Graphics and Image Processing, 37: 54-115, 1987.

3. T.Kohonen. Self-Organizing Maps. Berlin, Springer- Verlag, 2001, 501

4. Melville P., Mooney R.J., Nagarajan R. Content-boosted collaborative filtering for improved recommendations // in Proceedings of the National Conference on Artificial Intelligence - 2002 - C. 187-192.

5. Geyer-Schulz A., Hahshler M., Comparing two recommender algorithms with the help of recommendations by peers // in Proceedings of the WEBKDD 2002 - Mining Web Data for Discovering Usage Patterns and Profiles - 2003 - C. 137-158.

THE POSSIBILITY OF USING ART NEURAL NETWORK TO BUILD A CONSUMER PERSONALIZATION SYSTEM

KHURSHUDYAN ARMEN

*Candidate of Economics, Associate Professor,
Lecturer at the Chair of Informatics and Physical-Mathematical Sciences, GSU
e-mail: armkhur@mail.ru*

MARDOYAN SHUSHAN

*2nd-year Master Student of the Department of Computer Engineering,
the Faculty of Natural Sciences, GSU
e-mail: mardoyan98@bk.ru*

The article presents the results of designing and developing a consumer personalization system, which is often called a recommendation system. To solve the problem of personalization, it is necessary to divide consumers into classes, according to the coincidence of various, often unpredictable parameters. This classification is called clustering. In order to group clients into homogeneous clusters, a neural network of the adaptive resonance theory was designed and built. The ART1 algorithm developed by S. Grossberg and G. Carpenter was used to train the network. The training was conducted using a conditional sample of vectors-features of the purchase history of a group of consumers. As a method of splitting into clusters, the “item-based” principle based on the comparison of the similarity of purchases, which belongs to the class of collaborative filtering methods, was used. After the completion of the training phase, the consumers were divided into three homogeneous clusters, for each of which a prototype vector was created with the possibility of further training. To issue recommendations for each cluster, a



summing vector was applied, with the help of which recommendations were created for all consumers. Based on the results obtained, it can be concluded that by providing a solution to the stability-flexibility dilemma, the ART1 algorithm makes it possible to effectively divide consumers into clusters based on the principle of similarity of preferences, and the use of the summing vector allows creating an integral system for issuing recommendations.

Keywords: *neural network, adaptive resonance theory, feature vector, prototype vector, sum vector, clustering algorithms, algorithm ART1, self-organizing neural nets..*

ВОЗМОЖНОСТЬ ПРИМЕНЕНИЯ НЕЙРОННОЙ СЕТИ ART ДЛЯ ПОСТРОЕНИЯ СИСТЕМЫ ПЕРСОНАЛИЗАЦИИ ПОТРЕБИТЕЛЕЙ

ХУРШУДЯН АРМЕН

*Кандидат экономических наук,
доцент кафедры информатики и физикоматематических наук
электронная почта: armkhur@mail.ru*

МАРДОЯН ШУШАН

*Студентка второго курса магистратуры отделения
«Компьютерная инженерия»
электронная почта: mardoyan98@bk.ru*

В статье представлены результаты проектирования и разработки системы персонализации потребителей, которую часто называют системой выдачи рекомендаций. Для решения задачи персонализации требуется разбиение потребителей на классы, по совпадению различных, часто заранее непредсказуемых параметров. Такую классификацию называют кластеризацией. С целью группировки клиентов в однородные кластеры была спроектирована и построена нейронная сеть теории адаптивного резонанса. Для обучения сети использован алгоритм ART1, разработанный С. Гроссбергом и Г. Карпентером. Обучение проводилось с применением условной выборки векторов-признаков истории покупок группы потребителей. В качестве метода разбиения на кластеры применен осованный на сравнении схожести покупок принцип «item-based», относящийся к классу методов колаборативной фильтрации. После завершения этапа обучения потребители были разделены на три однородных кластера, для каждого из которых был создан вектор-прототип, с возможностью дальнейшего обучения. Для выдачи рекомендаций к каждому кластеру был применен сумми-



рующий вектор, с помощью которого были созданы рекомендации для всех потребителей. На основании полученных результатов можно сделать вывод: обеспечивая решение дилеммы "стабильности-гибкости", алгоритм ART1 позволяет эффективно осуществлять разделение потребителей на кластеры, исходя из принципа схожести предпочтений, а применение суммирующего вектора позволяет создать целостную систему выдачи рекомендаций.

Ключевые слова: *нейросеть, теория адаптивного резонанса, вектор признаков, вектор прототип, вектор суммирования, алгоритмы кластеризации, алгоритм ART1, самоорганизующиеся нейронные сети.*

Հոդվածը ներկայացվել է խմբագրական խորհուրդ 13.04.2022թ.:

Հոդվածը գրախոսվել է 16.04.2022թ.: