

Մեծ տվյալները, մեքենայական ուսուցումը և դրանց կիրառությունները կենտրոնական բանկերում

Մարգարյան Ա. Հ.

Հայաստանի Պետական Տնտեսագիտական Համալսարան (Հայաստան, Երևան)
and.sargsyan@yahoo.com

Վճռորոշ բառեր՝ մեծ տվյալներ, արհեստական բանականություն, մեքենայական ուսուցում, կենտրոնական բանկեր

Большие данные, машинное обучение и их применение в центральных банках

Саргсян А. О.

Армянский государственный экономический университет (Армения, Ереван)
and.sargsyan@yahoo.com

Резюме: Развитие компьютерных технологий и снижение стоимости хранения данных привело к сбору и сохранению массовых электронных данных организациями. Трудно, а иногда и невозможно, проанализировать большие данные с помощью существующих традиционных методов. Для их анализа созданы новые статистические модели, которые строятся на основе данных и делают прогнозы. В статье описываются большие данные, машинное обучение, их применение и проблемы связанные с внедрением в центральных банках.

Ключевые слова: центральные банки, большие данные, искусственный интеллект, машинное обучение

Big Data, Machine Learning and their applications in Central Banks

Sargsyan A. H.

Armenian State University of Economics (Armenia, Yerevan)
and.sargsyan@yahoo.com

Abstract: The development of computer technology and the reduction of data storage cost resulted in the collection and maintenance of mass electronic data by organizations. It is difficult, sometimes impossible, to analyze big data through existing traditional methods. New statistical models have been developed which are built from the given data and make predictions about the future. The article describes big data and machine learning, their applications and challenges associated with the implementation in Central Banks.

Keywords: central banks, big data, artificial intelligence, machine learning

Համակարգչային տեխնիկայի զարգացումը և տվյալների պահպանման գնի իջեցումը հանգեցրին կազմակերպությունների կողմից հսկայածավալ էլեկտրոնային տվյալների հավաքագրման և պահպանման: Այդ ծավալի տվյալները գոյություն ունեցող ավանդական մեթոդներով վերլուծելը բարդ է, երբեմն էլ անհնար: Դրանց վերլուծման համար ստեղծվել են վիճակագրական նոր մոդելներ, որոնք կառուցվում են տրված տվյալների հիման վրա և կանխատեսումներ կատարում ապագայի վերաբերյալ: Հոդվածում ներկայացվում են մեծ տվյալների, մեքենայական ուսուցման սահմանումները, դրանց կիրառությունները և ներդրման հետ կապված մարտահրավերները կենտրոնական բանկերում:


Հաշվողական տեխնիկայի և ինտերնետի զարգացմանը զուգընթաց տարբեր աղբյուրներից գեներացվող և ստացվող տեղեկատվության ծավալը երկրաչափական պրոգրեսիայով

աճեց: Դա առաջացրեց անհրաժեշտություն՝ ստեղծելու նման տվյալների պահպանման և մշակման նոր մեխանիզմներ: Այդ մեխանիզմների ներդրումը այսօր գտնվում է խոշոր կազմակերպությունների, այդ թվում նաև Կենտրոնական բանկերի ուշադրության կենտրոնում: Կենտրոնական բանկերը, օգտագործելով մեծածավալ և տարբեր աղբյուրներից ստացվող տվյալները, փորձում են կատարել ավելի ճշգրիտ կանխատեսումներ և մշակել ավելի արդյունավետ դրամավարկային քաղաքականություն:

Մեծ են համարվում մեծածավալ, բարդ և արագ աճող տվյալները, որոնք պահանջում են առաջադեմ տեխնիկա և տեխնոլոգիա ինֆորմացիան հավաքագրելու, պահպանելու, բաշխելու, կառավարելու և վերլուծելու համար¹:

¹ St' u Demystifying Big Data: A Practical Guide To Transforming The Business of Government, 2012

Մեծ տվյալներ (Big data) տերմինը առաջին անգամ կիրառել է O'Reilly Media հրատարակչության մարքեթինգի բաժնի տնօրեն Ռոջեր Մագուլասը 2005 թվականին: Դա վերաբերում էր տվյալների այնպիսի մեծ բազմությանը, որը գրեթե անհնար էր կառավարել և մշակել օգտագործելով բիզնես վերլուծության գործիքները²: Չնայած նրան, որ մեծ տվյալներ հասկացությունը սկսել է շրջանառվել դեռևս 2005 թվականից, դրա նկատմամբ հետաքրքրությունը առավել մեծ տեմպով սկսել է աճել 2012 թվականից:



Գծապատկեր 1. “Big data” տերմինի որոնման թրենդը 2004-2018 թթ. ըստ Google Trends օնլայն գործիքի³

Մեծ տվյալները սովորաբար բնորոշվում են երեք առանցքներով (3V մոդել)⁴.

- ծավալ (volume)
- արագություն (velocity)
- բազմազանություն (variety)

Ծավալը նշանակում է, որ այդ տվյալները վերաբերում են հսկայածավալ ինֆորմացիայի վերլուծությանը՝ սովորաբար սկսած 10 և ավելի տերաբայթից: IBM-ի հետազոտությունները ցույց են տալիս, որ աշխարհի բոլոր տվյալների 90%-ը ստեղծվում են նախորդող 2 տարիների ընթացքում⁵: Այսինքն՝ ունենք տվյալների ծավալի երկրաչափական պրոգրեսիայով աճ, և աճի տեմպը միայն ավելի է արագանում:

Արագությունը արտացոլում է տվյալների ստեղծման և փոփոխման տեմպը: Օրինակ՝ ֆոնդային բորսաներում արժեթղթերի առք ու վաճառքի գների փոփոխությունը, սոցիալական մեդիայում կատարվող հրապարակումների քանակը միավոր ժամանակում և այլն:

Բազմազանությունը նկարագրում է այն փաստը, որ մեծ տվյալները գալիս են շատ և տարբեր աղբյուրներից, տարբեր ֆորմատներով, որոնք կարող են լինել թե՛ կառուցվածքային, թե՛ ոչ կառուցվածքային: Կառուցվածքային տվյալները ունենում են հստակ սահմանված կառուցվածք, ինչը հնարավորություն է տալիս արագ որոնում կատարել և վերլուծություն իրականացնել: Կառուցվածքային տվյալները հիմնականում պահվում են ռեյա-ցիոն տվյալների բազայում: Ոչ կառուցվածքային տվյալները մնացած բոլոր տվյալներն են, որոնք չունեն հստակ մոդել կամ սխեմա (տեքստային ֆայլեր, սոցիալական մեդիայի տվյալներ, էլեկտրոնային հաղորդագրություններ և այլն): Տարբեր ուսումնասիրություններում նշվում է, որ կազմակերպություններում տվյալների մոտ 80-85%-ը ոչ կառուցվածքային են: Ոչ կառուցվածքային տվյալների ճիշտ վերլուծության միջոցով հնարավոր է քաղել արժեքավոր ինֆորմացիա, որը կնպաստի ճիշտ որոշումների կայացմանը⁶:

3V մոդելը առաջարկվել էր Դագ Լեյնիի կողմից 2001 թվականին: Այսօր 3V-երին միացել են ևս 6-ը՝ արժանահավատություն (Veracity), արժեք (Value), հիմնավորվածություն (Validity), փոփոխականություն (Variability), վիրտուալ (Virtual), վիզուալիզացիա (Visualization)⁷:

Մեծ տվյալները կարելի է օգտագործել արհեստական բանականությամբ օժտված ծրագրեր մշակելու համար, որոնք կարող են լուծել բարդ խնդիրներ: Արհեստական բանականության ուսումնասիրության առարկան խելացի մեքենաների և ծրագրերի մշակումն է⁸:

Արհեստական բանականության հիմնական

² Տե՛ս Gali Halevi, Henk Moed. 2012. The evolution of big data as a research and scientific topic: Overview of the literature

³ Գծապատկերը կառուցվել է հեղինակի կողմից Google Trends օնլայն գործիքի տվյալների հիման վրա

⁴ Տե՛ս Doug Laney, “3D Data Management: Controlling Data Volume, Velocity, and Variety”, Gartner, file No. 949. 6 February 2001

⁵ Տե՛ս Performance and Capacity Implications for Big Data, 2014

⁶ Տե՛ս Ise Anderson Orobor, 2016. Integration and Analysis of Unstructured Data for Decision Making: Text Analytics Approach

⁷ Տե՛ս Ripon Patgiri, Arif Ahmed. 2016. Big Data: The V’s of the Game Changer Paradigm.

⁸ Տե՛ս Mubashir Hussain, Dr. Manhas, 2016. Artificial intelligence for big data: potential and relevance. International Academy of Engineering and Medical Research, Volume-1, ISSUE-1

մեթոդներից է մեքենայական ուսուցումը: Այդ տերմինը ներմուծել է Արթուր Սամուելը 1959 թվականին, իսկ Թոմ Միտչելը սովել է մեքենայական ուսուցման ալգորիթմի հետևյալ ֆորմալ սահմանումը. «Կասենք, որ համակարգչային ծրագիրը սովորում է՝ ելնելով E փորձից, հաշվի առնելով T խնդիրը և ունենալով ինչ որ P էֆեկտիվության գործակից, այնպես որ նրա էֆեկտիվությունը T խնդրի համար, որը չափվում է P էֆեկտիվության գործակցով, բարելավվում է E փորձի ընթացքում»^{9, 10}:

Մեքենայական ուսուցման հիմնական մեթոդները կարելի է խմբավորել հետևյալ երկու դասերում.

- սուպերվիզորով ուսուցման մեթոդներ
- առանց սուպերվիզորի ուսուցման մեթոդներ


Սուպերվիզորով ուսուցման մեթոդները իրենց հերթին լինում են ռեգրեսիոն և դասակարգման համար նախատեսված: Ռեգրեսիոն մեթոդներով կարելի է լուծել օրինակ անշարժ գույքի գների կանխատեսման խնդիրը, իսկ դասակարգման մեթոդներով՝ կանխատեսել վարկառուի սնանկացումը:

Առանց սուպերվիզորի ուսուցման մեթոդները հնարավորություն են տալիս իրականացնել ոչ կառուցվածքային տվյալների վերլուծություն: Դրանց միջոցով հնարավոր է տվյալների մեջ գտնել օրինաչափություններ, իրականացնել տվյալների կլաստերիզացիա, ինչպես նաև իջեցնել տվյալների չափողականությունը վիզուալիզացիայի նպատակով:

Վերը նշված մեթոդները ներկայումս լայն կիրառություններ ունեն տնտեսության այն ոլորտներում, որտեղ գեներացվում են մեծ քանակությամբ տվյալներ: Կենտրոնական բանկերի համար դրանք նույնպես հետաքրքրություն են ներկայացնում, քանի որ տնտեսական շատ երևույթներ հնարավոր է ուսումնասիրել և բացատրել մեծածավալ տվյալների ուսումնասիրման միջոցով, իսկ մեքենայական ուսուցումը տալիս է գործիքներ՝ անհրաժեշտ օրինաչափությունները գտնելու համար: Մասնավորապես, կենտրոնական բանկերում մեծ

տվյալների հավաքագրումը և մեքենայական ուսուցման մեթոդների օգնությամբ վերլուծությունը կարող են հնարավորություն տալ իրականացնել երկրի մակրոտնտեսական ցուցանիշների առավել ճշգրիտ կանխատեսումներ և վարել ավելի արդյունավետ դրամավարկային քաղաքականություն: Բացի այդ՝ կենտրոնական բանկերը մեծ տվյալների վերլուծությունը կարող են կիրառել բանկերի իրացվելիությունը և վճարունակությունը գնահատելու, փողերի լվացման և վճարահաշվարկային համակարգերում զեղծարարությունների դեմ պայքարելու համար:

Ըստ Central Banking հրատարակչության և BearingPoint խորհրդատվական ընկերության՝ համատեղ հետազոտության արդյունքների՝ հետազոտությանը մասնակցած աշխարհի 52 կենտրոնական բանկերի 56%-ը աշխատում է մեծ տվյալներ ներառող պրոյեկտի վրա: Հարցվածների 55%-ը մեծ տվյալների վերլուծությունը օգտագործում է երկարաժամկետ և կարճաժամկետ կանխատեսումների համար, 42%-ը՝ սթրես թեստավորման, 32%-ը՝ փողերի լվացման դեմ պայքարի, իսկ 30%-ը՝ զեղծարարությունների բացահայտման և կանխատեսման համար¹¹:



Գծապատկեր 2. Central Banking-ի կողմից ԿԲ-երի միջև անցկացված հարցման արդյունքները մեծ տվյալների կիրառման ոլորտների վերաբերյալ¹²

Թերևս կենտրոնական բանկերի համար մեծ տվյալների վերլուծության գլխավոր մարտահրավերներից են հանդիսանում, նախ և

⁹ Sté u Mitchell, T. (1997). Machine Learning. McGraw Hill. p. 2.
¹⁰ Sté u Arthur Samuel, 1959. "Some Studies in Machine Learning Using the Game of Checkers". IBM Journal of Research and Development. 3 (3): 210-229

¹¹ Sté u Emma Glass, Big data in central banks: 2018 survey results
¹² Գծապատկերը կազմվել է Big data in central banks, 2018 հարցման տվյալների հիման վրա

առաջ, գոյություն ունեցող տվյալների որակը (հատկապես զարգացող երկրների համար), քանի որ դրանք հաճախ մեծ ծավալի աղմուկ են պարունակում, իսկ մյուս կողմից՝ հսկայածավալ տվյալների մշակման դժվարությունը և համապատասխան մասնագետների ներգրավումը: Կենտրոնական բանկերը տվյալների որակին առնչվող խնդիրները կարող են լուծել այլընտրանքային աղբյուրներից տվյալների ձեռքբերմամբ, իսկ մասնագետների բացակայությունը՝ իրենց աշխատակիցների վերապատրաստման միջոցով:

Այսպիսով՝ մեծ տվյալների վերլուծությունը հնարավոր է դառնում մեքենայական ուսուցման մեթոդների կատարելագործման և հաշվողական հզորությունների ավելացման միջոցով: Հետազոտությունը ցույց է տալիս, որ Կենտրոնական բանկերը հետաքրքրված են այդ մեթոդներով իրենց առջև դրված խնդիրների լուծմամբ: Դա պայմանավորված է ինչպես տարբեր աղբյուրներից ստացվող տվյալների ծավալի աճով, այնպես էլ հաշվողական տեխնիկայի զարգացմամբ: Մասնավորապես՝ Կենտրոնական բանկերում մեքենայական ուսուցման մեթոդները կիրառվում են կամ կարող են կիրառվել մակրոտնտեսական ցուցանիշների կանխատեսման, զեղծարարությունների և փողերի լվացման դեմ պայքարի, ռիսկերի կառավարման և իրականացված քաղաքականության ազդեցության գնահատման համար: Մեծ տվյալների վերլուծությունը մեծ

հավանականությամբ կշարունակի գտնվել կենտրոնական բանկերի ուշադրության կենտրոնում և ձևափոխել նրանց կողմից ֆինանսական, տնտեսական վերլուծությունների իրականացման և որոշումների կայացման մեխանիզմները:

Օգտագործված գրականության ցանկ

1. Demystifying Big Data: A Practical Guide To Transforming The Business of Government (2012)
2. Glass, E. (2018). Big data in central banks: 2018 survey results
3. Halevi, G., Moed H. (2012). The evolution of big data as a research and scientific topic: Overview of the literature
4. Hussain M, Dr. Manhas (2016). Artificial intelligence for big data: potential and relevance. International Academy of Engineering and Medical Research, Volume-1, ISSUE-1
5. Jewell, D., Barros, R. D., Diederichs, S., Duijvestijn, L. M., Hammersley, M., Hazra, A. and Zolotow, C. (2014). Performance and Capacity Implications for Big Data, IBM Redbooks
6. Laney, D. (2001, February). 3D Data Management: Controlling Data Volume, Velocity, and Variety, Gartner, file No. 949
7. Mitchell T. (1997). Machine Learning. McGraw Hill. p. 2.
8. Orobor, I. A. (2016). Integration and Analysis of Unstructured Data for Decision Making: Text Analytics Approach
9. Patgiri R., Ahmed A. (2016). Big Data: The V's of the Game Changer Paradigm.
10. Samuel, A. (1959). Some Studies in Machine Learning Using the Game of Checkers. IBM Journal of Research and Development, 3 (3), 210–229