

EKONOMICKÁ UNIVERZITA V BRATISLAVE
FAKULTA HOSPODÁRSKEJ INFORMATIKY

Evidenčné číslo: 103004/I/2018/36103158106300420

BIG DATA VO VZDELÁVANÍ

(Diplomová práca)

2018

Bc. Hana Benedikovičová

EKONOMICKÁ UNIVERZITA V BRATISLAVE
FAKULTA HOSPODÁRSKEJ INFORMATIKY

BIG DATA VO VZDELÁVANÍ

(Diplomová práca)

Študijný program: Informačný manažment

Študijný odbor: Kvantitatívne metódy v ekonómii

Školiace pracovisko: Katedra aplikovanej informatiky

Vedúci záverečnej práce: doc. Ing. Martin Mišút, CSc.

Bratislava 2018

Bc. Hana Benedikovičová

Čestné vyhlásenie

Čestne vyhlasujem, že diplomovú prácu som vypracovala sama a že som uviedla všetku použitú literatúru.

Dátum:

.....

(podpis študenta)

Pod'akovanie

Touto cestou by som sa chcela pod'akovať vedúcemu diplomovej práce doc. Ing. Martinovi Mišútovi, CSc. za jeho ochotu, ústretovosť, cenné rady a pripomienky, ktoré napomohli k vypracovaniu tejto diplomovej práce.

ABSTRAKT

BENEDIKOVIČOVÁ, Hana: Big Data vo vzdelávaní. – Ekonomická univerzita v Bratislave. Fakulta hospodárskej informatiky; Katedra aplikovanej informatiky. – Vedúci záverečnej práce: doc. Ing. Martin Mišút, CSc. – Bratislava: FHI EU, 2018, 57 strán

Cieľom záverečnej práce bolo zanalyzovať situáciu v univerzitnom vzdelávaní s ohľadom na možnosti a potenciál využitia poznatkov, skrytých v doteraz nevyužívaných zdrojoch údajoch. Práca pozostáva zo 4 kapitol a obsahuje 4 obrázky, 2 tabuľky, 6 grafov. V prvej kapitole autor popisuje súčasný stav riešenia problematiky u nás a v zahraničí, predstavuje pojem Big Data vo vzdelávaní. V druhej kapitole predstavuje ciele práce. Tretia kapitola obsahuje metodiku práce a metódy skúmania danej problematiky. Posledná kapitola je zameraná na analýzu dát vo vysokoškolskom prostredí a pohľad na štatistiky neúspešnosti študentov. Výsledkom záverečnej práce je predstavenie návrhu ako efektívne spracovať všetky údaje, ktoré vznikajú popri štúdiu.

Kľúčové slová: Big data, vzdelávanie, dolovanie dát

ABSTRACT

Benedikovičová, Hana: Big Data in education. - University of Economics in Bratislava. Faculty of Economic Informatics; Department of Applied Informatics.- thesis supervisor: doc. Ing. Martin Mišút, CSc. - Bratislava: FHI EU, 2018, 57 pages

The objective of this thesis is to analyze the situation in university level education with regard to all kinds of possibilities and potential how to use knowledge that used to be hidden in unused data resources. The work consists of 4 chapters and contains 4 pictures, 2 tables and 6 graphs. The first chapter introduces to current ways of how to deal with the problematics of Big Data in education, both in our country and abroad. The second chapter describes main objectives. The third chapter covers methodology and research methods of the problematics. The last chapter focuses on data analysis at university level education and on statistics of unsuccessful students. The result of the thesis is stating a proposal on how to effectively process all data that are collected during educational process

Keywords: Big data, education, data mining

Obsah

Zoznam obrázkov	10
Zoznam tabuliek a grafov	10
Úvod	11
1 Súčasný stav riešenia problematiky doma a vo svete	12
1.1 Pojem Big Data	12
1.1.1 <i>Definícia</i>	13
1.1.2 <i>Charakteristika</i>	14
1.1.3 <i>Veľkosť/objem (volume)</i>	14
1.1.4 <i>Rýchlosť (velocity)</i>	15
1.1.5 <i>Rozmanitosť (variety)</i>	15
1.1.6 <i>Pravdivosť (veracity)</i>	16
1.1.7 <i>Hodnota (value)</i>	17
1.2. Big Data vo vzdelávaní.....	17
1.2.1 <i>Prínosy Big Data vo vzdelávaní</i>	18
1.2.1.1 <i>Spätná väzba</i>	19
1.2.1.2 <i>Motivácia</i>	20
1.2.1.3 <i>Individualizácia</i>	20
1.2.1.4 <i>Efektivita</i>	21
1.2.1.5 <i>Spolupráca a sledovanie</i>	21
1.2.1.6 <i>Pochopenie procesu učenia</i>	21
1.2.2 <i>Riziká Big Data vo vzdelávaní</i>	21
1.2.2.1 <i>Ochrana osobných údajov</i>	22
1.2.2.2 <i>Skreslenie získaných dát</i>	23
1.2.2.3 <i>Nesprávne dáta</i>	23
1.2.2.4 <i>Korelácia</i>	24
1.2.3 <i>Ako môžu univerzity využívať Big Data?</i>	25
1.2.3.1 <i>Prijímanie študentov</i>	25
1.2.3.2 <i>Zlepšenie výkonnosti a výsledkov študentov</i>	26
1.2.3.3 <i>Účinnosť učiteľa</i>	26
1.2.4 <i>Výsledok analýzy</i>	27
2 Cieľ práce	28
3 Metodika práce a metódy skúmania	28
4 Výsledky skúmania	29
4.1 Systém na riadenie výučby - LMS	29

4.1.1	<i>Prekážky a problémy v oblasti e-learningu</i>	30
4.2	Analýza dát vo vysokoškolskom vzdelávaní	31
4.2.1	<i>Analýza vzdelávania</i>	32
4.3	Zdroje Big Dat v e-learningu	35
4.3.1	<i>Využitie dát získaných z LMS</i>	37
4.4	Pohľad na úspešnosť/neúspešnosť študentov	38
4.4.1	<i>Pohľady do štatistík neúspešnosti študentov</i>	40
4.4.2	<i>Príčiny študijnej neúspešnosti</i>	46
4.5	Návrh riešenia	48
4.5.1	<i>Blackboard Analytics</i>	49
Záver	52
ZDROJE	54

Zoznam obrázkov

Obrázok 1: Veľkosť digitálneho vesmíru	13
Obrázok 2: Rast množstva údajov	16
Obrázok 3: Úrovne analytiky vo vzdelávaní	34
Obrázok 4: Úrovne zberu dát na univerzite	38

Zoznam tabuliek a grafov

Tabuľka 1: Úbytok počtu študentov od nástupu až po absolvovanie II. stupňa štúdia	40
Tabuľka 2: Rozdiel v počte zapísaných študentov a absolventov, celková úspešnosť absolventov I. a II. stupňa	41
Graf 1: Počet prijatých študentov vs. Absolventi I. stupňa štúdia	41
Graf 2: Celkový pohľad na úspešnosť absolventov I. stupňa štúdia	43
Graf 3: Prijatí študenti vs. absolventi II. stupňa štúdia	43
Graf 4: Absolventi I. stupňa vs. absolventi II. stupňa štúdia	44
Graf 5: počet študujúcich na dennom štúdiu vs. absolventi za daný rok v SR	45
Graf 6: Novoprijatí študenti a absolventi	45

Úvod

Výsledky informačnej spoločnosti sa už nedajú len tak prehliadnuť. Vo vreckách nosíme mobilné telefóny, v batohoch notebooky, vo firmách pracujú výkonné serverové systémy, používame inteligentné veci, jazdíme na inteligentných autách. Toto všetko sme už spozorovali. No menej nápadné, a napriek tomu tak rozsiahle, sú samotné dáta. Dnešný svet je zaplavený viac dátami ako kedykoľvek predtým a objem týchto dát narastá stále rýchlejšie. Zmenil sa pohľad na dáta samotné. Kvantita sa premenila na kvalitu.

Big Data symbolizujú určitý začiatok rozsiahlej transformácie. Tak ako nám ďalekohľad pomohol pochopiť a priblížiť vesmír, vďaka mikroskopu sme mohli spoznať mikróby, nové technológie na zhromažďovanie a analýzu Big Dat nám majú pomôcť porozumieť veľkému množstvu údajov, ktoré následne môžeme efektívne využiť.

Jednou z oblastí, kde by mohla byť analýza Big Dat veľkým prínosom, je určite vzdelávanie. Je doba, kedy absolvovať štúdium bez počítača, notebooku je nemožné. Každý študent počas svojho štúdia vyprodukuje veľmi veľa rôznych údajov.

Pre našu diplomovú prácu sme si zvolili túto tému, pretože využitie Big Dat vo vzdelávaní je pomerne zaujímavá téma, ktorá môže do budúcnosti priniesť zásadné zmeny v študijnom prostredí. Napriek tomu, že pojem Big Data je už celkom známy, táto problematika v oblasti vzdelávania je na Slovensku ešte len celkom na začiatku.

V prvej časti, teda analytickej časti našej práce, si definujeme a charakterizujeme, čo vlastne pojem Big Data je. Následne si priblížime ich význam a prínos do oblasti vzdelávania. Okrem iného uvedieme, že s príchodom, využitím a spracovaním Big Dat prichádzajú aj isté riziká. Na záver analytickej časti zhodnotíme, ako by mohli univerzity a vysoké školy efektívne využívať Big Data.

V druhej, návrhovej časti si priblížime, čo je najväčším zdrojom Big Dat vo vzdelávaní, objasníme si jednu z najdôležitejších procesov správneho a efektívneho využitia veľkého množstva dát vo vzdelávacom procese, a to analýzu dát. Značnú časť tvorí vyhodnotenie získaných štatistických údajov, ktoré poukazujú na početnosť neúspešných študentov. Na základe výsledkov získaných pri spracovaní štatistických údajov sa ďalej budeme zaoberať príčinami študijnej neúspešnosti. Slovensko je v porovnaní s inými krajinami sveta ešte len na začiatku cesty efektívneho využitia Big Dat. Preto na záver navrhujeme nástroj na účinné spracovanie Big Dat vo vzdelávaní.

1 Súčasný stav riešenia problematiky doma a vo svete

“Everything we do in the digital realm – from surfing the Web to sending an e-mail to conducting a credit card transaction to, yes, making a phone call – creates a data trail. And if that trail exists, chances are someone is using it – or will be soon enough.”

Douglas Rushkoff, americký spisovateľ a mediálny teoretik

Big Data priniesli veľa nových možností, ale nemali by sme zabúdať, že všetko nové, na oko lepšie, má určite v sebe aj tie menej dobré stránky na ktoré veľa krát zabúdame.

V tejto kapitole si priblížime, čo vlastne Big Data sú. Zdefinujeme si ich využitie, špecifikujeme prínosy, vymedzíme riziká a určíme možnosti využitia Big Data v univerzitnom a vysokoškolskom prostredí.

1.1 Pojem Big Data

“Big Data is not the answer, and it is not the question. It is an opportunity.”

Zozbierať veľké množstvo rôznych dát nie je v dnešnej dobe žiadny problém. O moc zložitejšie je ich zmysluplne spracovať. Každým dňom množstvo dát pribúda a bude ich čím ďalej, tým viac.

Pojem Big Data je v súčasnosti pomerne známy. No vieme vysvetliť, čo to je? Vieme si predstaviť aké množstvo dát to je?

- Množstvo informácií v digitálnom vesmíre by vyplnilo radu toľkých tabletov, ktoré by dosiahli až do 2/3 vzdialenosti na Mesiac (157 000 km / 253 704 kilometrov). Do roku 2020 bude týchto rád 6,6.
- Priemerná domácnosť v roku 2014 vytvárala dostatok údajov na vyplnenie 65 telefónov iPhone (32GB) ročne. V roku 2020 sa toto zvýši na 318 telefónov iPhone.
- Ak by bajt dát bol galón vody, len za 10 sekúnd by bolo dostatok údajov na vyplnenie priemerného domu. V roku 2020 to bude trvať len 2 sekundy. [1]

Nové štúdie IDC Digital Universe tvrdia [2], že sa realizuje len malá časť potenciálu Big Data na svete, aj keď sa množstvo užitočných údajov rozširuje. Big Data predstavujú tak veľké množstvo dát, že ich môžeme kľudne nazvať aj digitálny vesmír. Predpokladá sa, že tento digitálny vesmír bude do roku 2020 obsahovať takmer toľko digitálnych bitov, koľko je hviezd vo vesmíre. **Každé dva roky sa zdvojnásobuje veľkosť** a do roku 2020 digitálny vesmír, teda údaje, ktoré každoročne vytvárame a kopírujeme, dosiahne 44 zetabajtov alebo 44 miliárd gigabajtov.

Obrázok 1: Veľkosť digitálneho vesmíru



Zdroj: <https://www.emc.com/leadership/digital-universe/2014iview/executive-summary.htm>

Hovoríme o veľkostiach, ktoré si len ťažko vieme predstaviť. Pre aspoň malú predstavu uvádzame, že 40 zetabajtov sa rovná 1,7 MB nových informácií, ktoré vytvorí každý človek na tejto planéte, každú sekundu denne.

V súčasnosti pracuje na veľkých údajoch a pokročilých analytických nástrojoch až šesť miliónov vývojárov na celkom svete. Týchto šesť miliónov tvorí takmer tretinu všetkých vývojárov na svete. [2]

1.1.1 Definícia

Definovať pojem Big Data je asi to isté, ako keby ste mali definovať čo je vesmír. Je to niečo, čo nemôžeme vidieť pohromade, nevieme si predstaviť veľkosť. Asi nie nadarmo sa Big Datam pripisuje aj pojem digitálny vesmír.

Prvá zmienka s pojmom Big Data sa pripisuje dvom výskumníkom z NASA, Michael Cox a David Ellswort, ktorí v roku 1997 publikovali prácu s názvom „Application-

Controlled Demand Paging for Out-of-Core Visualization“. Počas výskumu boli natoľko pohltení dátami, že túto prekážku nazvali ako problém Big Dat. [3]

„Pojmom Big Data označujeme súbory dát, ktorých veľkosť je mimo schopnosť zachytávať, spravovať a spracovávať dáta bežne používanými softvérovými prostriedkami v rozumnom čase.“ [4]

Podľa Oxfordského slovníka sú definované Big Data ako:

„ Extrémne veľké množstvo dát, ktoré môže byť analyzované na výpočet odhalenia vzorov, trendov a asociácií, najmä týkajúcich sa ľudského správania a interakcií.“ [5]

1.1.2 Charakteristika

„Big Data are high volume, high velocity and high variety of information assets that require new form of processing to enable enhanced decision making insight discovery & process optimisation“

Tom White in Hadoop the Definitive Guide

Spoločnosť META Group (pozn. teraz Gartner) [29] v roku 2001 vytýčila tri všeobecne uznávané charakteristické vlastnosti Big Dat, ktoré sa stali zároveň aj definíciou. Objem, rýchlosť a rôznorodosť. Sú označované podľa začínajúcich písmen z anglického prekladu slov volume, velocity a variety, ktoré sa hromadne označujú ako 3V. Vzhľadom na to, že objem dát sa neustále zvyšuje, v súčasnosti je táto definícia nedostačujúca. Postupne pribudli ďalšie dve charakteristické vlastnosti Big Dat, a to: veracity a value, čo je v preklade pravdivosť a hodnota.

1.1.3. Veľkosť/objem (volume)

Ako tvrdí Rafal Lukawiecki [7], svetový odborník na dátovú analytiku, nikdy nejde len o samotné dáta. Ide o kombináciu daných dát a otázky, na ktoré nimi chceme odpovedať. Ide teda o otázky, na ktoré dokážeme odpovedať len za využitia veľmi moderných technológií, a pri využití starých technológií by sme na ne nedokázali odpovedať. Celá definícia veľkosti sa neustále mení. Čo bolo veľké dnes, nemusí byť považované za veľké zajtra. Preto definovať presnú hranicu, kedy sa z normálneho objemu stáva objem charakteristický pre Big Data, je zložité.

Podľa spoločnosti IBM [6] užívatelia serveru YouTube si každý mesiac prezrú viac ako 4 miliardy hodín videí. Sieť Twitter má v súčasnosti cez 400 miliónov užívateľov. Podľa spoločnosti Zephoria bolo na konci roka 2017 viac ako 2,13 miliardy registrovaných používateľov Facebooku, čo predstavuje medziročný nárast o 14%. Z toho 1,4 miliardy ľudí sa denne prihlási na Facebook, čiže sa považujú za denných používateľov. Každých 60 sekúnd sa na Facebook pridá 510 000 nových komentárov, aktualizuje sa 293 000 stavov a nahrá sa 136 000 fotografií.

Objem sa vzťahuje na množstvo údajov, ktoré sa produkujú každú sekundu vo všetkých online kanáloch, vrátane platforiem sociálnych médií, z mobilných zariadení, prostredníctvom on-line transakcií a iných. [7]

1.1.4 Rýchlosť (velocity)

Počet e-mailov, príspevkov zo sociálnych médií, videoklipov a iných textových dokumentov pridaných za deň, presahuje niekoľko miliárd záznamov. Toto dané množstvo sa zvyšuje rýchlosťou blesku, keďže tablety a mobilné zariadenia nám dávajú väčší prístup k pridávaniu obsahu online. Rýchlosť v tomto prípade predstavuje takú rýchlosť, s akou sa v danom čase generujú, zbierajú a analyzujú nové údaje. Teda s akou rýchlosťou sa dáta tvoria a prechádzajú celým systémom. [6]

1.1.5 Rozmanitosť (variety)

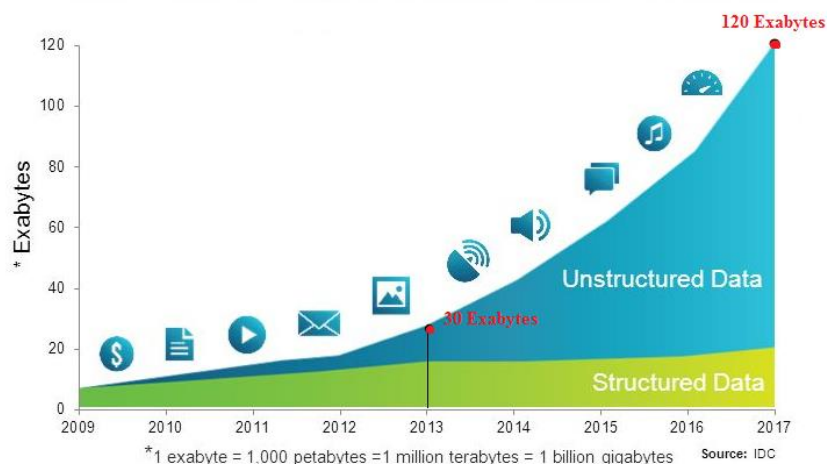
Tým, že sa internet a technológie neustále vyvíjajú, dáta sa môžu rýchlo stať zastaranými. Dnešné vyprodukované množstvo dát nie je ľahké zoradiť do nejakých tabuliek. Sú rôzneho charakteru a môžeme ich rozdeliť podľa štruktúry do troch kategórií [8]:

- Štruktúrované – sú to dáta, ktorých výhodou je oddelenie kontextu od formátu, vďaka čomu sú dáta jednoduché na pochopenie. Patria sem dáta, ktoré sú uložené v relačnej databáze, dokumentovej databáze, (napr. vo formáte XML, JSON,..) alebo aj ako tzv. dátové vety.
- Neštruktúrované – veľká časť všetkých dát je neštruktúrovaná. Odhaduje sa, že je to až 90 % . Pod týmto pojmom rozumieme súbory v rôznych formátoch ako napríklad Microsoft Word, PowerPoint prezentácie, PDF súbory a tiež sem patrí netextový obsah ako sú grafika, obrázky, audio a video súbory. Jeden záznam neštruktúrovaných dát je veľkosťou rozsiahlejší ako tradičné numerické dáta. Dáta

v tejto podobe je veľmi ťažké analyzovať a skladovať. Na ich spracovanie tradičné relačné databázové systémy nestačia. Ide o dáta ako sú emaily, obrázky, audio, video, dáta zo sociálnych sietí, textové súbory a pod. [9]

Obrázok 2: Rast množstva údajov

RAST ÚDAJOV



Zdroj. : Vlastné spracovanie podľa: <http://slideplayer.com/slide/10698448/>

Na obrázku môžeme vidieť rapidný nárast neštruktúrovaných dát v porovnaní so štruktúrovanými dátami za obdobie ôsmich rokov. Keď sa pozrieme na roky 2013 – 2017 môžeme spozorovať, že objem štruktúrovaných dát sa skoro vôbec nezmenil. Kde naopak pri neštruktúrovaných dátach môžeme spozorovať až trojnásobný nárast objemu dát.

- Semi – štruktúrované – môžeme tak nazvať dáta, ktoré patria medzi štruktúrované a neštruktúrované dáta. Zastupujú také dáta, ktoré nedodržiavajú striktnú schému z dôvodu častých zmien v ich štruktúre. Patria sem dáta v textovom formáte s rozpoznateľnou schémou.

1.1.6 Pravdivosť (veracity)

Pravdivosť údajov sa týka zaujatosti a abnormalít v údajoch. Sú to údaje, ktoré zmysluplne ukladajú a vyhodnocujú analyzovaný problém. Pravdivosť, resp. veracity, v analýze dát je veľkou výzvou pri porovnaní s objemom a rýchlosťou. Cieľom je udržať dáta čisté a zabráňovať hromadeniu „špinavých dát“ v systéme.

Pre rôznorodosť veľkých dát sú kvalita a presnosť menej kontrolované. Ako príklad môžeme uviesť príspevky na sieti Twitter alebo Instagram, inak nazvané aj hashtagmi. Sú to skratky, nápisy a hovorové prejavy. Význam slov je označený symbolom – tagom (#).

Tento symbol je dnes chápaný ako forma kľúčového slova. Aj s týmito typmi údajov nám v dnešnej dobe umožňujú pracovať veľké dátové a analytické technológie.

1.1.7. Hodnota (value)

Vďaka tejto vlastnosti môžeme zmeniť naše údaje na istú hodnotu. Pred využitím veľkých údajov je dôležité sa ich snažiť zhromaždiť. Ak vieme, ktoré údaje zhromaždiť a následne správne využiť, môžu nám priniesť hodnotu takmer v každej oblasti podnikania.

Môžu pomôcť spoločnostiam lepšie pochopiť zákazníkov. Ako napríklad odporúčania spoločnosti Amazon alebo Netflix. Spoločnosť Uber na základe údajov z aplikácií dokáže predpovedať dopyt, poslať najbližšieho vodiča k zákazníkovi. Taktiež môže zlepšiť našu zdravotnú starostlivosť. Vládne inštitúcie môžu predpovedať ohnisko chrípky a následne ho sledovať v reálnom čase. Môže pomôcť zlepšiť bezpečnosť. Vládne orgány činné v trestnom konaní používajú Big Data na vyriešenie teroristických útokov a zisťovanie počítačovej kriminality. Tiež pomáhajú vrcholovým športovcom zvyšovať ich výkon. Rôzne snímače v loptičkách, kamery na ihrisku a GPS trackery na oblečení umožňujú analyzovať a zlepšovať to, čo robia.

Všetky objemy rýchlo sa pohybujúcich dát rôznej rôznorodosti a pravdivosti sa musia zmeniť na hodnotu, čo v konečnom dôsledku znamená, že všetky Big Data, ktoré získame z rôznych výskumov a analýz, musia byť zhodnotené, teda musíme ich hodnotu k niečomu použiť a využiť. Preto je hodnota označovaná ako najdôležitejší ukazovateľ. [10]

1.2. Big Data vo vzdelávaní

Veľké údaje sú všade. Využívajú sa v zdravotníctve na predpovedanie epidémie, zlepšujú kvalitu života, pomáhajú liečiť a vyhýbať sa úmrtiam, ktorým sa dá predísť. Vládne agentúry využívajú analýzu rozsiahlych súborov údajov na boj proti podvodom a zneužívaniu. Národná bezpečnosť využíva riešenia GIS a dátové nástroje na podporu spravodajských informácií. Politický kandidáti dokonca využívajú analytikov pre určenie bodov vhodných pre výhru kampane tak, aby zvolené body boli v súlade s konkrétnymi záujmami voliča. Takto by sme mohli ďalej pokračovať. My sa budeme skôr zaujímať otázkou: Ako môžu pomôcť Big Data v oblasti vzdelávania?

Výraz Big Data vo vzdelávaní zahŕňa tri aspekty údajov vznikajúcich v procese vzdelávania. Objem, rýchlosť a rozmanitosť.

1. Objem – Big Data môžu poskytovať informácie o tisíckach študentov, ktorí absolvovali rovnaké štúdium, alebo mali rovnaké študijné skúsenosti. Môžu tiež pomôcť získať konkrétne informácie o jedinom študentovi. Big Data by mohli jedného dňa spájať údaje o štúdiu od stoviek vzdelávacích organizácií a tak poskytnúť globálny pohľad na vzdelávanie.
2. Rýchlosť – Údaje z rôznych vzdelávacích systémov by mali umožňovať študentom a organizáciám rýchly prístup k údajom aj v reálnom čase.
3. Rozmanitosť – Veľké dáta vznikajúce v procese učenia spájajú širšiu škálu informácií od študentov s rôznym pozadím. Umožňuje nám vidieť korelácie (väzby, závislosť) medzi výkonom a životným prostredím študenta.

1.2.1 Prínosy Big Dat vo vzdelávaní

Údaje poskytujú kľúč k dosiahnutiu lepších študijných výsledkov a pomáhajú pedagógom pochopiť otázku „prečo?“. Prečo študent absolvoval štúdium? Prečo študent zlyhal pri danej skúške? Prečo študent neovláda konkrétny pojem alebo zručnosť?

Údaje majú slúžiť aj k tomu, aby bol učiteľ schopný predísť zlyhaniu študenta, alebo aby mu naopak pomohol k úspešnému zvládnutiu štúdia. Medzi najväčšie prínosy Big Dat vo vzdelávaní patrí schopnosť analyzovať, sledovať a predpovedať výkonnosť študentov, zlepšiť absolvovanie a udržanie resp. zvyšovanie úrovne, ako aj zvolenie vhodnej stratégie výučby v správnom čase a fáze procesu vzdelávania.

Zvyšuje sa záujem inštitúcií vyššieho vzdelávania využívať Big Data na zlepšenie výkonnosti študentov a zvyšovanie efektívnosti učiteľov pri súčasnom znížení administratívneho zaťaženia. Údaje o výkonnosti študentov sa čoraz častejšie zaznamenávajú ako súčasť cvičenia a testovania v triede založenej na softvéroch a on-line aplikáciách. Tieto dáta môžu byť rozšírené o údaje o správaní, získané zo zdrojov, ako sú sociálne médiá, stretnutia študentov a profesorov, blogy, študentské prieskumy atď. K dispozícii je tiež množstvo verejných údajov, ako aj množstvo iniciatív otvorených údajov v inštitúciách vyššieho vzdelávania v celej krajine. Univerzity môžu porovnávať svoje výsledky študentov, profesorov a študijných programov oproti iným univerzitám, čo prináša nový pohľad na potenciál zlepšenia vzdelávacieho procesu. [11]

Big Data vo vysokoškolskom vzdelávaní sú uložené aj v databázových systémoch, ktoré uchovávajú veľké množstvo údajov o konkrétnych študentoch ako aj údaje o veľmi

špecifických transakciách a činnostiach týkajúcich sa vzdelávania a vyučovania. Keď študenti komunikujú so vzdelávacími technológiami, nechávajú za sebou dátové stopy, ktoré dokážu odhaliť ich pocity, sociálne súvislosti, zámery a ciele. Výskumníci môžu tieto údaje použiť na skúmanie modelov výkonnosti študentov v priebehu jedného semestra alebo aj jedného roka. [12]

Svetový inovačný samit o vzdelávaní (WISE) v roku 2013 prišiel s požiadavkou radikálnej zmeny. Vedúci pedagógovia, tvorcovia politik a vlády z viac ako 100 krajín sa zhromaždili v Katare, pričom sa vo väčšine zhodli, že spôsob akým by sa malo v dnešnej dobe vyučovať, nebude dostatočne pripravovať mladého človeka do jeho budúcnosti.

Môžeme spomenúť niekoľko spôsobov, akými sa očakáva, že Big Data pomôžu vzdelávaniu.

1.2.1.1 Spätná väzba

Big Data môžu byť informatívne z hľadiska spätnej väzby a kontextu. Keďže študenti nie sú veľakrát schopní zistiť, prečo zlyhajú, môže byť zaujímavé a užitočné, ak sa študent môže pozrieť nie len na seba, ale aj na iných ľudí, ktorí majú rovnaké skúsenosti. Môže im to pomôcť získať náhľad nad spôsobenou frustráciou, alebo naopak, spätná väzba by mohla byť použitá na opravu, aby mohol študent znovu uspieť.

Študent dostáva známky za splnenie úloh, aktivitu pri vyučovaní, skúšanie alebo písomné práce. V niektorých prípadoch stačí, keď nerobí žiadne problémy a následne je ohodnotený iba za účasť. V tomto prípade je teda spätná väzba iba jednosmerná, teda od učiteľov a školy k študentom. Nie je to práve najlepší systém. Je to niečo podobné, ako keby výrobca hodnotil svojich zákazníkov, a nie zákazníci kvalitu jeho produktu a spokojnosť s ním.

V systéme školstva odráža spätná väzba zatiaľ iba výsledky, a nie proces učenia, pretože by bolo náročné o ňom získať dáta. Napríklad ak nejaký študent čítal zadaný text niekoľkokrát za sebou, nevedeli sme zistiť, či to bolo preto, že by mu nerozumel, alebo preto, že sa mu páčil. Vďaka učebniciam, resp. skriptám na tabletoch alebo počítačoch bude možné spomínané údaje získať a využiť ich ako spätnú väzbu pre všetkých, ktorí sa na danom procese učenia zúčastňujú. Informácie získané za pomoci vyššie spomínaného procesu, bude potom možné použiť nielen k zlepšeniu podkladov pre výučbu, ale aj na prípravu nového materiálu presne podľa potrieb a znalostí študenta. Tento proces je označovaný ako

adaptabilná výučba, ktorá predstavuje začiatok novej éry personalizovaných učebných programov. [18]

1.2.1.2 Motivácia

Priebeh školského dňa a ani roka nezodpovedá potrebám súčasnej spoločnosti. Vyučovanie je presne nalinajkované, rozdelené do hodín podobajúcich sa pracovným smenám v továrni. Študenti sú zväčša zoskupení v triedach podľa dátumu narodenia a každý rok postupujú do vyššieho ročníka. V 19. a 20. storočí viedla demokratizácia spoločnosti k uniforme školstva, čo bola následne cena za všeobecný prístup k vzdelaniu, kde žiaci majú rovnaké podmienky, učebnice aj domáce úlohy.

Dnešná výučba je zameraná na priemer a zabúda zohľadňovať individuálne vlastnosti a schopnosti študentov. Všetci sa učia rovnakú látku, rovnakým tempom a v rovnaký čas. Je to síce vyhovujúce pre vyučujúcich a tiež pre školský, resp. vzdelávací systém, no nie však pre jednotlivých študentov.

Ak vo výučbe vysvetlíme použitie Big Dat v zrozumiteľnej podobe, študenti budú viac motivovaní tieto dáta aplikovať a používať, pretoževidia, aký dopad tieto dáta reálne majú. Big Data by mohli pomôcť súčasný školský systém zmeniť a podľa možností prispôsobiť schopnostiam jednotlivých študentov. Podľa Mayera Schönbergera a Cukiera možno plošným zhromažďovaním dát zlepšiť spätnú väzbu, individuálne schopnosti a predpovede súvisiace s vyučovaním.

1.2.1.3 Individualizácia

Pred dvesto rokmi boli deti z vyšších spoločenských tried vyučované na malých elitných internátoch alebo pomocou domácich učiteľov. Už pred začiatkom masového vzdelávania išlo o individuálny prístup, ktorého tempo sa určovalo podľa schopností študenta osvojiť si učebnú látku. Vo veľkých triedach nie je individuálny prístup možný, pričom práve on je tou najlepšou formou výučby.

Big Data umožňujú návrat k individualizovanému vyučovaniu, pretože vďaka nim je možné prispôsobiť učebný plán schopnostiam jednotlivých študentov. Vyučovací softvér sa neustále mení, a tým lepšie sa prispôsobuje schopnostiam študenta, čím viac dát má k dispozícii a môže ich využiť k spätnej väzbe. Študenti napríklad dostanú ťažké úlohy až potom, ako softvérový program vyhodnotí, že naozaj ovládajú základné znalosti.

Vďaka Big Datam bude možné analyzovať, čo pri výučbe funguje, či nefunguje, a to nielen vo všeobecnosti, ale podľa triedy alebo jednotlivého žiaka. Taktiež bude možné prispôsobiť učebný plán a vyučovaciu látku tak, aby zodpovedali jeho schopnostiam.

Big Data zmenia prístup k e-learningu (výučba online) a to tak, že umožnia vývojárom personalizovať kurzy takým spôsobom, aby ich prispôbili individuálnym potrebám študentov. Týmto spôsobom sa zdvihne úroveň a efektivita e-learningových kurzov. [18]

1.2.1.4 Efektivita

Big Data nám môžu ušetriť až hodiny času a úsilia najmä v prípade určovania našich osobných cieľov a stratégie, ako tieto ciele dosiahnuť. Napríklad niekto pracuje rok v práci "A", ale chce získať prácu "B". Môžeme sa spýtať, ako sa pripravovali a usilovali tí, čo sa o miesto v práci B usilovali skôr a nakoniec ju získali? Big Data nám s tým poradia a tiež nám ukážu, ktoré učebné programy boli najviac efektívne, alebo v akom období života sa práve nachádzali, keď sa o prácu "B" usilovali.

1.2.1.5 Spolupráca a sledovanie

Veľmi často sa musia zísť špecialisti z jednotlivých oddelení, aby zaistili správnu funkciu vzdelávacieho systému (LMS). To rozvíja spoluprácu medzi oddeleniami a odovzdávanie si myšlienok a poznatkov medzi sebou.

Big Data nám pomôžu lepšie pochopiť reálne vzorce učenia u našich študentov a to tak, že ich budeme sledovať a monitorovať ich skúsenosti s e-learningovým kurzom. Z toho, čo študenti za sebou nechajú (digitálna stopa) môžeme sledovať ich cestu celým procesom učenia.

1.2.1.6 Pochopenie procesu učenia

Monitorovaním a analýzou dát v e-learningu môžeme napr. zistiť, ktorá časť úlohy alebo skúšky resp. testu bola jednoduchá, a ktorá naopak ťažká, kde sa študenti zasekli. Následne môžeme sledovať ďalšie časti procesu učenia, napr. ku ktorým častiam výučby, lekcii sa študenti vracali, ktoré časti odporúčali svojim spolužiakom, ktoré štýly učenia preferujú, alebo kedy počas dňa im ide učenie najlepšie. [13]

1.2.2 Riziká Big Data vo vzdelávaní

Ako sme vyššie spomínali, Big Data prinášajú do vzdelávania veľa pozitív. Nesmieme však zabudnúť na to, že všetko, čo môže viesť k veľkým benefitom, vedie takisto k rizikám. Big Data môžu v nesprávnych rukách viac poškodiť ako pomôcť. Bez ohľadu na

to, či úmyselne alebo neúmyselne, môže to narušiť celý vzdelávací systém. Možno vymedziť niektoré riziká a prekážky spojené s využitím veľkých dát vo vzdelávaní.

1.2.2.1 Ochrana osobných údajov

Viac ako dve storočia boli informácie a údaje o študentoch uchovávané v papierovej podobe, často v archívoch v školských alebo okresných úradoch. Počas tejto doby boli malé obavy z narušenia bezpečnosti, nesprávneho zdieľania údajov alebo problémov týkajúcich sa ochrany súkromia študentov. V posledných desaťročiach bola digitalizovaná prevažná väčšina osobných informácií pre študentov i zamestnancov.

Prvý zákon o rodinnom vzdelávaní a ochrane súkromia, ktorého cieľom bolo chrániť súkromie záznamov o vzdelaní študenta, bol schválený skôr, než ktokoľvek vedel, že úloha počítačov vo vzdelávacom procese bude taká dôležitá. V dnešnom vzdelávacom prostredí je prakticky nemožné sa do procesu učenia zapojiť bez prístupu k počítaču a internetu. Úlohy sa sťahujú a odosielať online. Materiály sú posielané e-mailom, testy sa robia online. V našom súčasnom prostredí sme do vzdelávacieho odvetvia priniesli bezdrôtové siete, sociálne médiá a všetky druhy mobilných a inteligentných zariadení. Naše potreby a vzory v oblasti využívania technológií sa zmenili, čo zvyšuje výzvy v oblasti bezpečnosti.

Univerzity, vysoké školy a iné vzdelávacie inštitúcie používajú rôzne typy študentských údajov. Patria tam finančné, osobné údaje a akademické informácie. Okrem toho sa univerzity zaoberajú výučbou a výskumom a všetkými technológiami a údajmi, ktoré sa jej týkajú. Mnohé z týchto informácií možno považovať za citlivé. Dôležité je vyriešiť otázku, kde budú všetky dáta o žiakoch a študentoch uložené, kto k nim bude mať prístup a či ich bude možné vymazať. Musíme zabezpečiť, aby isté citlivé dáta nebolo možné v budúcnosti dohľadať. Čo ak po mnohých rokoch bude možné nájsť informácie o tom, že napríklad daný študent na základnej škole navštevoval doučovanie pre zaostávajúcich a táto informácia sa sním dostane až na univerzitu? Jeho hodnotenie môže tiež ovplyvňovať počet zameškaných hodín, znížená známka zo správania, alebo návšteva školského psychológa, hoci toto obdobie má už dávno za sebou a jeho správanie sa už dávno zmenilo.

Všetko umiestnené na internete sa dá nájsť a použiť akýmkoľvek spôsobom, ktorý si hľadajúci vyberie. V tomto prípade sa nám ponúka len jediná otázka. Ako sa môžu vysoké školy a univerzity, ktoré sú plnohodnotnými účastníkmi online sveta, chrániť pred týmito silami? Rovnako ako ostatné sektory, aj univerzity pravdepodobne ovplyvnia mnohé zákony a nariadenia ako napríklad predpisy o ochrane osobných údajov. [14]

Situáciu by mohlo zlepšiť aplikované nariadenie o ochrane osobných údajov GDPR, ktoré nadobudlo platnosť 25.5.2018. GDPR je všeobecné nariadenie o ochrane osobných údajov (angl. General Data Protection Regulation) a nová revolučná legislatíva Európskej Únie, ktorá výrazne zvýši ochranu osobných údajov občanov. Bude sa týkať totiž skutočne každého, kto s osobnými údajmi pri svojom podnikaní či pôsobení pracuje. Občania EÚ tak opäť získajú kontrolu nad svojimi osobnými údajmi.

1.2.2.2 Skreslenie získaných dát

V skutočnosti môže byť výsledok analýzy veľkých dát značne skreslený. Môže byť dosť zložitá zahrnúť do výslednej analýzy podmienky na základe dát, v ktorých študenti realizujú online výučbové aktivity. To následne môže ovplyvniť napríklad aj výsledný profil študenta, ktorý je vytváraný automaticky na základe online sledovania jeho činnosti. Tu vzniká riziko, že takto vzniknutý skreslený obraz môže študenta poškodiť a následne sa sním ťahať po celý život. Po zhrnutí daných skutočností rozumieme pod rizikom skreslenia získaných dát nezahrnutie všetkých vplyvov pôsobiacich na žiaka v priebehu vzdelávacieho procesu.

S tým súvisí aj dehumanizácia, teda odosobnenie študenta. Analýza výučbových výsledkov založená na zbere veľkých dát vedie k odosobneniu tohto procesu. To, čo vždy bývalo vykonávané výhradne v rámci priameho kontaktu učiteľa so študentom, je dnes realizované strojmi, ktoré so živými ľuďmi zaobchádzajú ako s neživými objektami či dátami. [15]

1.2.2.3 Nesprávne dáta

Mnoho krajín sveta, patrí tam aj Slovensko, vykonáva tzv. plošné testovanie pomocou zhodných testov. Môžeme povedať, že toto testovanie rozhoduje istým spôsobom o živote skúšaného na základe jeho momentálneho výkonu. Mnoho odborníkov tieto postupy zásadne kritizuje. Je pravdou, že Big Data umožňujú nahradiť tieto rozhodujúce testy analýzou dlhodobej činnosti študenta, ale na druhej strane vedú tieto metódy k súťaženiu škôl v tom, kto dosiahne lepšie výsledky. Tým vzniká veľké riziko, že školy začnú učiť len to, čo sa testuje a ostatné výučbové ciele budú ignorovať. Najhoršie, čo sa môže prihodiť bude, ak sa aktéri procesu rozhodnú výsledky priamo falšovať.

Môžeme spomenúť napríklad škandalózne odhalenie v texaskom El Paso, kde sa chválili skvelými výsledkami študentov v kľúčových plošných testoch, ktoré sú v USA povinné. Škandalózne odhalenie sa dotýkalo 64 tisíc žiakov. Ukázalo sa, že riaditelia škôl

nielenže manipulovali s číslami, ale boli obvinení zo zámerného nepúšťania slabších žiakov k testom. Vyšetrovanie preukázalo existenciu prepracovaného programu skresľovania výsledkov testov tak, aby sa zlepšili výsledky miestnych škôl. Vďaka tomu mohli zainteresované školy získať ročné bonusy za splnenie cieľov federálneho programu. [16] Prípady, kedy sa učitelia snažili pomôcť študentom len preto, aby boli sami lepšie ohodnotení, žiaľ poznáme nie len z cudziny, ale dejú sa aj u nás.

Pod pojmom nesprávne údaje si môžeme predstaviť také dáta, ktoré sú zmanipulované, aby vytvorili lepší obraz o skúmanom ciele, napríklad škole alebo študentovi.

1.2.2.4 Korelácia

To, že medzi nejakými javmi existuje korelácia, teda možná súvislosť, nemusí nutne znamenať, že ich príčina je rovnaká. Použijeme jeden známy príklad korelácie medzi predajom zmrzliny a utopením. Keď stúpa množstvo predanej zmrzliny, stúpa aj počet prípadov utopenia. Dá sa povedať, že konzumácia zmrzliny spôsobuje, že sa ľudia utopia? Určite nie. Toto je jednoduchý príklad, v ktorom si určite vieme predstaviť, kde je chyba. Vieme si domyslieť, že prepojenie týchto dvoch zistení súvisí s nárastom teploty. Pri práci s Big Dátami je nutné značné overenie získaných výsledkov. Nemôžeme robiť okamžité závery. V tom prípade je potrebné príčinu javov, ktoré nás zaujímajú, dôkladne preveriť. [15]

Tiež sa môže stať, že závery nezodpovedajú dátam. To znamená, že dáta sú síce správne, ale závery analýz sú chybné. Ako príklad môžeme uviesť rebríček kvality škôl, ktorý je založený hlavne na úrovni vedeckej práce ich zamestnancov. Vyvodzovať z rebríčkov kvality škôl úroveň výučby je prinajmenšom zavádzajúce. [17]

Individualizácia potrieb a schopností ľudí môže byť najväčším dopadom Big Dat vo vzdelávaní. Obávame sa, že problémom môže byť nejednotnosť spoločnosti, kedy v dôsledku výberu informácií z internetu nastáva izolácia od ostatných ľudí podľa vlastných záujmov a prestáva byť zřejmé, či hodnoty a názory zodpovedajú väčšinovému názoru. Aj vo vzdelávaní môže nastať podobná situácia, kedy špeciálny učebný plán môže viesť k odlúčeniu od skupinovej skúsenosti v školskom systéme a tiež individualizovanému vzdelávaciemu programu, ktorý zamedzí zdieľať spoločné znalosti s ostatnými a spôsobí odtrhnutie od spoločnosti.

1.2.3 Ako môžu univerzity využívať Big Data?

„If we study learning as a data science, we can reverse engineer the human brain and tailor learning techniques to maximize the chances of student success. This is the biggest revolution that could happen in education, turning it into a data-driven science, and not such a medieval set of rumors professors tend to carry on.“

Sebastian Thrun

V posledných rokoch robia Big Data rozruch takmer v každom odvetví. Vysokoškolské vzdelávanie nie je výnimkou a aj v tejto oblasti má analýza Big Data čo ponúknuť. Inštitúcie vysokoškolského vzdelávania sa čoraz viac spájajú so svojimi študentami prostredníctvom internetu. Tak rastú príležitosti na zhromažďovanie a využívanie veľkých údajov v oblasti vzdelávania a pedagogickej inovácie. Údaje o výkonnosti študentov sa čím ďalej, tým častejšie zaznamenávajú prostredníctvom merania interakcií medzi online zdrojmi a virtuálnymi učebnými prostrediami (VLE). Tieto virtuálne učebné prostredia umožnili porovnávať úroveň angažovanosti s predchádzajúcimi rokmi a tiež proti iným univerzitám. Informácie ako sú napríklad počet strávených hodín vo VLE, počet odovzdaných zadaní, poskytuje reprezentáciu študentskej skúsenosti, ktorá je aj napriek jej obmedzeniam veľmi merateľná a porovnateľná. V kombinácii s inými informáciami, ako sú správanie na sociálnych sieťach, poznámky od učiteľov, z blogov a prieskumov, je možné nakresliť dosť jasný obraz o správaní študentov a celkovom výkone univerzity. Mnohé údaje sa však stále sledujú bez skutočného dôvodu.

Rozhodovanie ako najlepšie využiť údaje, ktoré zhromaždíme, je veľkou témou pre diskusiu. Analýza, ktorá používa údaje v prospech študentov a zlepšuje univerzitné služby sa vo všeobecnosti považuje za prijateľnú. Big Data dokážu poskytnúť potencionálnym študentom viac informácií pre lepšie rozhodnutia a lepšie zváženie možností ich budúcnosti. Univerzitám dopomôžu zlepšiť výkonnosť študentov a pomôžu pri náboře a následnom zotrvaní na danej univerzite. Rozoberieme si zopár konkrétnych prípadov, ako môžu univerzity najefektívnejšie využívať Big Data. [26]

1.2.3.1 Prijímanie študentov

Analýza Big Data nekončí po tom, ako študent podal svoju prihlášku. Big Data by mali vzdelávacím inštitúciám pomôcť pri rozhodovaní, ktorí študenti budú prijatí. Potrebné údaje by dokázali inštitúcie získať od súčasných a tiež bývalých študentov. Mohli by to byť napríklad historické výkony a demografické údaje, ktoré by boli použité na

vytvorenie profilov študentov. Analýza získaných údajov môže ukázať, ktorí kandidáti by s najväčšou pravdepodobnosťou uspeli na vysokej škole alebo univerzite a na druhej strane, ktorí by mohli byť náchylnejší k vypadnutiu alebo k neúspechu.

Zaujímavé je aj využitie informácií zo sociálnych médií, ktoré sa stalo v dnešnej dobe už bežnejším trendom. Týmto spôsobom sa školy pri náboře študentov môžu dozvedieť viac o konkrétnom študentovi. Nedávny prieskum Kaplan Test Prep zistil [27], že až 40% pracovníkov, ktorí prijímajú nových ľudí, v súčasnosti používa zdroje sociálnych médií, aby získali ďalšie informácie o žiadateľoch. Vo vyspelejších zahraničných univerzitách sa stáva tento proces čoraz populárnejší pri štipendijných fondoch, keďže organizácie sa snažia udeľovať peniaze len tým najslubnejším študentom.

1.2.3.2 Zlepšenie výkonnosti a výsledkov študentov

Hlavná myšlienka využitia Big Dat vo vzdelávacom systéme je zlepšiť študijné výsledky. V súčasnosti sú jediným spôsobom ako merať výkonnosť študentov spracované zadania a odpovede, resp. hodnotenia zo skúšok. Výsledky testov a akademická výkonnosť sa dajú ľahko sledovať a porovnávať s predchádzajúcim výkonom, ako aj so skúsenosťami podobných študentov. Ďalšie údaje, ako sú poznámky učiteľov a údaje o sociálnych médiách, môžu poskytnúť viac informácií o správaní študenta a upozorniť na akékoľvek významné zmeny jeho výkonnosti.

Počas svojho vzdelávacieho života každý študent vytvorí jedinečnú dátovú stopu. Analýza tejto dátovej stopy umožní v reálnom čase lepšie pochopiť a zhodnotiť individuálne správanie jednotlivých študentov a vytvoriť tak optimálne vzdelávacie prostredie pre každého.

1.2.3.3 Účinnosť učiteľa

Ako sme už spomínali v kapitole 1.2.1.1, študent dostáva isté hodnotenie za splnenie úloh, aktivitu pri vyučovaní, skúšanie alebo písomné práce. V tomto prípade je teda spätná väzba iba jednosmerná, teda od učiteľov a školy k študentom. Nie je to práve najlepší systém.

Študenti niekedy zaostávajú kvôli stresu, istým rodinným problémom alebo iným faktorom, ktoré sú mimo kontroly učiteľa. No jeden faktor, ktorý môže škola sledovať, je účinnosť učiteľa. Nie je to nevyhnutný spôsob ako udržať učiteľov zodpovedných za výkon študenta. Má skôr napomáhať učiteľom byť čo najúčinnjší. Sledovať, či majú kurzy, ktoré učiteľ vyučuje, vysokú angažovanosť od študentov. Tiež táto analýza môže odpovedať na

otázky ako sú napr.: Aké metódy a nástroje využívajú učitelia pri výučbe? Sú efektívne? Používa virtuálne učebné prostredie?

Stále sa zaoberáme využitím Big Dat v školstve, absolvovanie rôznych online a offline kurzov, k čomu priamoúmerne patrí aj využívanie IKT vo vzdelávaní. Sú na to pripravení aj naši, hlavne starší pedagógovia? V súčasnosti už nie je tak zvláštne a neobvyklé, keď študent disponuje lepšími technickými znalosťami ako jeho učiteľ. Ako sa vyjadrila Lukášová vo svojej publikácii. „Vzdelávanie učiteľov nie je ďaleko od toho, čo sa nazýva profesionalizácia bez profesionalizmu“ [28]. Preto by sme mali veľkú pozornosť venovať aj vzdelávaniu učiteľov.

1.2.4 Výsledok analýzy

V predchádzajúcich podkapitolách sme si priblížili a objasnili teoretické poznatky o Big Data. Definovali a charakterizovali sme si tento, už dosť používaný, no nie celkom známy pojem. Keďže naša práca je zameraná na konkrétne prostredie využitia Big Dat, druhú podkapitolu sme venovali rozanalyzovaniu Big Dat vo vzdelávaní. Zaoberali sme sa prínosmi, ktoré prináša využitie Big Dat vo všetkých druhoch vzdelávacích inštitúcií.

Problémy vznikajú všade, a preto sme museli upozorniť aj na riziká, ktoré môžu nastať pri práci s Big Datami.

V neposlednom rade sme sa zamerali na možnosti, ako efektívne využiť Big Data vo vzdelávaní, čo chceme následne v druhej časti našej diplomovej práce pretaviť na návrhy, ako efektívne a v rámci možností využiť zdroje údajov, ktoré na univerzite vo veľkom množstve produkujeme, no dostatočne nevyužívame.

2 Ciel' práce

Pred niekoľkými rokmi žiaci, študenti chodili do školy so zošitmi, výsledky mali zapísané v žiackych knižkách alebo indexoch a materiály mali výhradne len v knižnej podobe. S nástupom nových informačných technológií sa začali údaje o študentoch hromadiť. Množstvo údajov vzhľadom na stále novšie a novšie technológie narastá, no využitie týchto poznatkov bolo doteraz veľmi zložitú.

Preto hlavným cieľom našej práce je zanalyzovať situáciu v univerzitnom vzdelávaní s ohľadom na možnosti a potenciál využitia poznatkov, skrytých v doteraz nevyužívaných zdrojoch údajoch.

Čiastkovým cieľom bol pohľad na neúspešnosť študentov a následný návrh riešenia, ako by sa dali doteraz nevyužívané zdroje údajov vznikajúce vo vzdelávacom sektore využiť tak, aby sa predchádzalo predčasnému ukončeniu vysokoškolského štúdia.

3 Metodika práce a metódy skúmania

Pred vypracovaním našej diplomovej práce bolo nevyhnutné nastudovanie danej problematiky. Vzhľadom na nedostatok slovenskej literatúry sme väčšinou čerpali zo zahraničných zdrojov dostupných na internete a z vedeckých článkov.

V druhej časti práce sme vyhodnocovali získané údaje zo štatistík dostupných na internetovej stránke centra vedecko – technických informácií a na akademickom informačnom portáli AiS2. Zo získaných údajov sme za pomoci tabuľkového procesora Excel, zostrojili potrebné tabuľky použité v poslednej kapitole. Údaje z tabuliek sme si za pomoci kontingenčných grafov premietli do čitateľnejšej a zrozumiteľnejšej podoby.

Na základe analýzy získaných údajov sme došli k záveru, ktorý poukazuje na množstvo neúspešných študentov. Keďže cieľom bolo zhodnotiť možnosti a potenciál využitia poznatkov, skrytých v doteraz nevyužívaných zdrojoch údajoch, na záver sme navrhli riešenie, ako efektívne využiť všetky vyprodukované údaje, a tak obmedziť počet študentov, ktorí predčasne ukončia svoje štúdium.

Touto prácou by sme tiež chceli upozorniť na tému Big Data, ktorá je na školách vzhľadom na jej aktuálnosť veľmi málo diskutovanou témou.

4 Výsledky skúmania

V tejto časti našej práce popisujeme, čo je najväčším zdrojom všetkých údajov vo vzdelávaní a ako tieto údaje najlepšie využiť. Priblížime si jeden z najdôležitejších procesov pri využití množstva dát vo vzdelávacom procese a to analýzu dát. Následne si vyhodnotíme štatistické údaje, ktoré poukazujú na množstvo študentov, ktorí predčasne ukončia svoje štúdium. Zhodnotíme príčiny a poskytneme návrh riešenia.

4.1 Systém na riadenie výučby - LMS

Najväčším zdrojom Big Dat vo vzdelávaní sú určite systémy na riadenie výučby. Ako uvádza Wikipédia [30] „Systém na riadenie výučby je aplikácia na administratívu a organizáciu výuky v rámci e-vzdelávania. LMS sú aplikácie, ktoré v sebe integrujú spravidla najrôznejšie on-line nástroje pre komunikáciu a riadenie štúdia a zároveň sprístupňujú študentom učebné materiály či výukový obsah on-line alebo aj off-line.“

U nás, v prostredí verejného vysokého školstva sa môžeme s LMS, teda e-learningom stretávať zatiaľ iba v podpore jednotlivých predmetov. Zväčša ide iba o sprostredkovanie materiálov pre študentov online, alebo v niektorom z LMS. Asi už všetky vysoké školy ponúkajú e-learningové moduly, no zatiaľ ich môžeme definovať len ako doplnok klasických vzdelávacích foriem.

Na Slovensku je ponuka online kurzov obmedzená a predstavuje zväčša len ponuku kurzov, nie ucelených študijných programov. Preto môžeme tvrdiť, že e-vzdelávanie je na Slovensku nedostatočné. U nás je najpoužívanejším e-learningovým systémom Moodle.

Moodle je výučbové online prostredie, ktoré sa používa v mnohých vzdelávacích inštitúciách. Mal by poskytovať spoločný rámec pre všetky aktivity, ktoré poskytujú informačné a komunikačné technológie na elektronickú podporu výučby. Momentálne dostupné systémy poskytujú nástroje na:

- sprístupnenie výučbových materiálov študentom
- komunikáciu medzi študentmi a pedagógmi navzájom
- zadávanie úloh študentom a ich odovzdávanie
- testovanie získaných vedomostí [33]

Kultúra vzdelávania sa mení a aj sami študenti začínajú rozumieť, že nestačí počas štúdia iba sedieť v škole a počúvať, ale je potrebné sa aktívne zapájať do vzdelávacieho procesu a už priamo počas svojho štúdia nadobúdať aj zručnosti vďaka úlohám šitým na mieru a praktickým cvičeniam. Moodle obsahuje rôzne funkcie a pri práci s ním vzniká mnoho údajov, ktoré by sa dali následne spracovať, analyzovať a takto spracované údaje by nám poskytli informácie, ktoré by boli určite prínosom vo vzdelávaní, tak ako opisujeme v kapitole 1.2.1.

4.1.1 Prekážky a problémy v oblasti e-learningu

Všetky systémy na riadenie výučby, teda e-learning sú obrovským zdrojom údajov o každom študentovi, ktorý s daným systémom manipuluje. Aby sme mohli my študenti, ako aj škola, a v budúcnosti aj iné korporácie využívať roanalyzované údaje zo vzdelávacích systémov, museli by sme celoplošne zaviesť povinné vyučovanie cez e-learning v prvom rade na každej vysokej škole. A tu narážame na problém.

Jednoznačne môžeme potvrdiť, že e-learning na Slovensku nenapreduje takým tempom ako napríklad v USA. Vytvorenie e-learningových kurzov je pravdepodobne dlhodobá záležitosť a od vyučujúcich vyžaduje vysokú mieru IKT zručností. Tiež je nutné prispôbiť vzdelávanie kultúrnym zvyklostiam a požiadavkám študentov a aj učiteľov. Plnohodnotné e-learningové kurzy sú vo vysokoškolskom prostredí na Slovensku skôr raritou. Dovoľme si tvrdiť, že istou príčinou môže byť aj to, že vyučujúci momentálne neovládajú systémy spracovania obsahu na takej úrovni, že by boli samostatne schopní vypracovať online kurzy pre svojich študentov. Z vlastnej skúsenosti môžeme potvrdiť, že účinnosť e-learningových kurzov, resp. efektívne využitie Moodle na Slovensku, a aj na našej škole, je dosť mizerné. Nahratie učebnice alebo rôznych učebných materiálov na webstránku nie je e-learning, čomu mnoho vyučujúcich ešte stále nerozumie.

V slovenskom prostredí je e-learning zastrešovaný najmä pedagógmi, ktorí sa danej problematike venujú dobrovoľne vo svojom voľnom čase. Príčinou môže byť viacero aspektov, ktoré môžeme uviesť:

1. - nepochopenie alebo zlý výklad pojmu e-learning,
2. - odmietanie e-learningu ako alternatívnej formy vzdelávania,
3. - nedostatočné zručnosti pedagógov,
4. - neochota zdieľať verejne svoje študijné materiály,

5. - náročnosť vypracovania e-learningového kurzu,
6. - problém metodiky a chýbajúca podpora zo strany univerzity,
7. - nekoordinovaný prístup k tvorbe elektronických kurzov. [31]

Ako jeden z najväčších problémov môžeme uviesť fakt, že e-learning zväčša len kopíruje klasickú výuku. Skôr slúži len ako podpora priebežného vyučovania. Nie každý učiteľ je stotožnený napríklad s tým, že by sa mal prezentovať online. Totižto mnohým môžu chýbať skúsenosti s vystupovaním pred kamerou a tiež prax pri tvorbe zaujímavých a pútavých prezentácií, ktoré by inšpirovali masy študentov.

Problém využívania e-learningových kurzov na Slovensku nie je však problémom len samotných vysokých škôl. Je to globálny problém, ku ktorému sa Barbara Gindlová z Európskej kultúrnej spoločnosti vyjadrila takto: [32] „Dovolím si tvrdiť, že nie je ťažké získať finančné prostriedky na projekt, ktorého cieľom je vygenerovanie nového elektronického prostredia, vytvorenie e-learningového programu, založenie virtuálnej školy, akadémie či univerzity. Stačí byť šikovným projektovým inžinierom a využiť osvedčené modely. Zakúpiť alebo vygenerovať softvér, zaplatiť tvorcov obsahu, realizovať syntézu obsahu a formy, zakúpiť PC zostavy pripojené na internet, vyškoliť malú skupinu lektorov ďalšieho vzdelávania využívajúcich elektronický vzdelávací systém. Oveľa ťažšie je mať jasnú a dlhodobú stratégiu, čo bude s výsledkami, ktoré sa dosiahli vďaka peniazom získaným z grantu. Každý videl len množstvo prekážok. Kým sa to nestane ozajstnou prioritou, tak sa s tým nepohne, a zostane to iba na úrovni katedier“

E-learning môžeme brať ako veľkú príležitosť na zlepšenie a zefektívnenie vzdelávania na Slovensku a tiež ako zdroj všetkých Big Dat vo vzdelávaní.

4.2 Analýza dát vo vysokoškolskom vzdelávaní

Analýza dát je jedna z najdôležitejších procesov pri správnom a efektívnom využití množstva dát vo vzdelávacom procese.

Každá organizácia v každom odvetví disponuje bohatým množstvom informačných prostriedkov, z ktorých možno získať dáta. Platí to najmä pre vzdelávacie inštitúcie. Pokiaľ ide o vysokoškolské vzdelávanie, má nám analýza Big Data čo ponúknuť. Hlavným faktorom, ktorý radikálne zmenil spôsob vzdelávania, je technológia.

Príkladmi rôznych typov technológií používaných vo vzdelávaní sú mobilné zariadenia a prístroje, telekonferenčné a vzdialené prístupové systémy, vzdelávacie platformy, služby a iné, ktorými študenti, učitelia, akademická fakulta, hodnotiaci špecialisti, výskumníci a rozhodovací činitelia vo vzdelávaní komunikujú a používajú v snahe ovplyvniť a zlepšiť výučbu a učenie sa, ale aj reálne odrážať vo fáze učenia využívanie moderných technológií používaných v reálnych prostrediach. Interakcia s týmito technológiami generuje veľké množstvo údajov, ktoré sa pohybujú od individuálneho prístupu až po činnosť inštitucionálnej úrovne. Používanie moderných technológií vo výučbe by sa však nemalo zúžiť len na technické zariadenia, ale oveľa viac sa zameriavať napríklad na plošné zhromažďovanie dát a ich efektívne využitie.

Big Data nám poskytujú možnosť zahrnúť do výučby aj informácie, ktoré doposiaľ nie sú bežne dostupné. Hoci túto zmenu prináša technika, môžeme konštatovať, že táto zmena v spôsobe vyučovania nie je technická. Podstata tejto zmeny spočíva vo výbere zhromažďovaných dát a v ich spracovaní pre výučbu a získanie vedomostí.

Analýza obrovského množstva údajov zhromaždených vysokými školami a inštitúciami poskytuje kolektívne dátové vzory, z ktorých je ťažké predpovedať individuálne vzdelávacie záujmy a výber povolania. Analýza akademických údajov jednotlivých študentov na základnej úrovni určite pomôže pri vytváraní dátových vzorov študentov. Pomáha pri sledovaní ich zručností, záujmov, tvorivosti, talentu, schopnosti riskovať, rozhodovať sa, pri výbere správania a kariéry, ktoré ich sprevádzajú od začiatku školy. Určite zvyšuje mieru úspešnosti a zlepšuje kariérny graf študentov.

4.2.1 Analýza vzdelávania

Keďže každá činnosť v LMS je monitorovaná a uložená, môže sa získať prehľad o správaní študentov pri online štúdiu, čo sa dá využiť na zlepšenie učenia a výučby. Analýza údajov LMS sa často označuje ako analýza učenia (LA), definovaná ako "meranie, zhromažďovanie, analýza a oznamovanie údajov o študentoch a ich kontextoch na účely porozumenia a optimalizácie učenia a prostredia, v ktorom sa vyskytuje" [19]. Prostredníctvom LA môžeme odhaliť podobnosti v správaní (napr. spokojnosť užívateľa) alebo zistiť anomálie (napr. podvádžanie). Môže fungovať ako most medzi minulými a budúcimi operáciami vložením údajov o minulých udalostiach do LA s cieľom určiť pravdepodobné budúce výsledky.

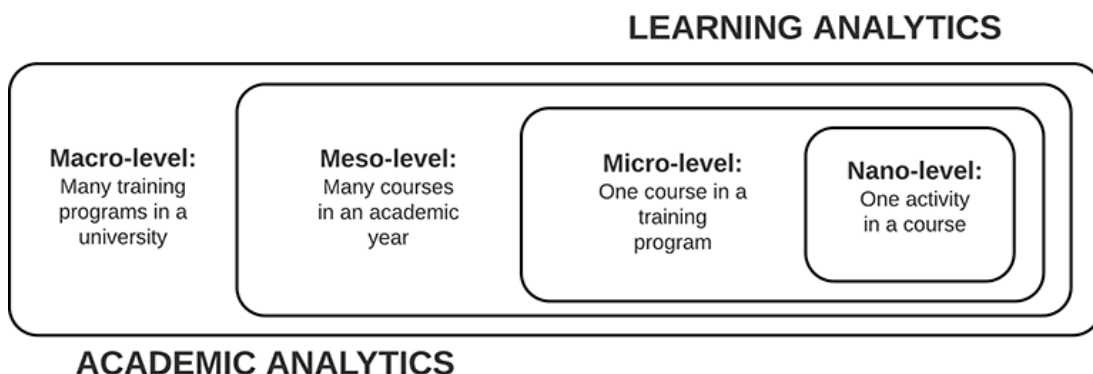
Učiteľia, zvyčajne na základe svojich skúseností používajú svoj vlastný vnútorný pocit na zhodnotenie správania študentov a podozrenia, že študent môže odstúpiť z kurzu alebo dokonca opustiť štúdium. To sa môže preukázať ako pravdivé, alebo nepravdivé, ale bez dôkazov existuje len nízka úroveň istoty v rozhodnutiach, ktoré sú založené len na skúsenostiach.

Techniky na dolovanie dát by mali byť uplatňované pri získavaní Big Dat vo vzdelávaní, a to tak, že budú použité pri analýze k rozpoznaní úrovni jednotlivých študentov. Teda pri zisťovaní, či výkonnosť študentov je dobrá alebo zlá. Následne by mali byť študenti informovaní o ich úrovniach. Týmto spôsobom by mohli byť študenti s možnými problémami identifikovaní včas, a tak vzdelávacie inštitúcie by mali čas čo najskôr zareagovať a podniknúť preventívne opatrenia. [22]

Analýza Big Data by mala pomôcť pri rôznych aktivitách vo vysokoškolskom vzdelávaní. Big Data spolu s analýzami pomáhajú vo vzdelávaní pri rozhodovaní a v alokovaní zdrojov a tak pomáhajú chrániť študentov pred neúspechom. Vytvárajú efektívne techniky a pretvárajú tradičný náhľad na učebné osnovy tak, že začínajú byť vnímané ako sieť vzťahov a prepojení medzi jednotlivými dátami, spojenými a získanými z LMS, sociálnych sietí, učebných aktivít a osnov. Konkrétnejšie, jednou z identifikovaných oblastí, v ktorých sú veľké údaje a analýza vhodne uplatniteľné na skúmanie a zlepšovanie vysokoškolského vzdelávania, je učebný plán a jeho obsah ako hlavná časť veľkých vzdelávacích údajov.

Pomocou analýzy sú rozhodnutia založené skôr na dôkazoch ako na predpokladoch. Analýza bola zaradená do piatich úrovní: kurz, oblasť/odbor, inštitúcia, región a národ. Môžu byť použité iné výrazy, ktoré sa pokúšajú konkrétnejšie definovať rôzne úrovne, a to; "Nanolevel" označuje aktivity v kurze; "mikroúroveň" poukazuje na celý kurz vzdelávacieho programu; "mesolevel" zahŕňa mnoho kurzov v konkrétnom akademickom roku; a nakoniec, "makroekonomická úroveň" sa týka mnohých študijných programov vo vzdelávacej inštitúcii. [20] Obrázok znázorňuje tieto štyri úrovne a vzťahy medzi nimi.

Obrázok 3: Úrovne analýzy vo vzdelávaní



Zdroj: <https://www.intechopen.com/books/big-data-on-real-world-applications/introduction-to-big-data-in-education-and-its-contribution-to-the-quality-improvement-processes>

Na obrázku môžeme vidieť rôzne úrovne analýzy vo vzdelávaní, ktoré sa prekrývajú a navzájom dopĺňajú. Napríklad výsledky akcií vykonaných na nanolevelovej úrovni môžu byť vstupom do iných úrovni mikro, meso a makro, zatiaľ čo ich kontrolujú a monitorujú. Aplikácia analytikov v tejto klasifikácii môže byť tiež orientovaná na rôzne zainteresované strany vrátane študentov, učiteľov, administrátorov, inštitúcií a výskumníkov. Môžu mať rôzne ciele, napríklad mentoring, monitoring, analýzu, predikciu, hodnotenie, spätnú väzbu, personalizáciu, odporúčanie a podporu pri rozhodovaní. [21]

Operácie na mikroúrovni a úrovni nanolevelu, ako sú napríklad výučba alebo učenie sa v kurze, sa odvolávajú na LA. Príklady týchto operácií vykonávajú učitelia, dizajnéri kurzov, študenti a programoví riaditelia. Nasledujúci scenár ukazuje praktické využitie LA v kruhu zlepšovania kvality kurzu.

V prípravnej fáze kurzu môžu inštruktori použiť nástroje mapovania kurikula¹, aby presne zistili skutočné medzery. Môžu tak rozpoznať, ktoré ciele učenia nie sú náležite riešené vyučovacími alebo vzdelávacími aktivitami. Potrebujú odporúčania pre nové, motivujúce výučbové aktivity, aby ich zahrnuli do svojho harmonogramu. Prostredníctvom dostupných nástrojov služby Analytics dokážu ďalej analyzovať triedu a predpovedať jej potreby, ako sú demografia študentov, výkonnosť, rôzne vzdelávacie prístupy, použitá

¹ Kurikulum – súhrnná informácia o vzdelávacích zámeroch hovorí komplexne o vyučovaní alebo o vzdelávacom procese a jeho dôležitých bodoch, o realizácii a výsledkoch. Prekračuje rámec učebných osnov a učebného plánu. Súčasťou kurikula sú informácie o učebných cieľoch, obsahu učiva, organizácii učiva, o vyučovacích a študijných metódach a prostriedkoch, o spôsobe kontroly a hodnotenia. Kurikulum odpovedá na otázky : koho, prečo, v čom, ako, kedy, za akých podmienok, s akými očakávaniami, budeme vzdelávať. [25]

technológia a skupinová dynamika. Tento typ údajov je spracovávaný množstvom algoritmov a prediktívnych modelov, ktoré môžu vyvinúť charakteristiky triedy [23].

Vizuálne nástroje sa môžu použiť v nasledujúcom kole, aby poskytli alternatívne návrhy na navrhovanie vhodných aktivít pre túto konkrétnu triedu a tiež ilustrovali účinky každej z možností. Vedúci kurzu môže kontrolovať aktivity a sledovať pokrok študentov počas priebežného kurzu. Môžu priblížiť a oddialiť celú triedu do jednej pracovnej skupiny alebo jedného študenta. Môžu navyše sledovať tok vytvorených sociálnych sietí. Môžu posúdiť celkový záväzok a identifikovať rizikových študentov. Vo veľkej miere používané platformy môžu tiež porovnať jednotlivé ukazovatele z iných tried, alebo ďalšie anonymné súbory v rámci rovnakého programu alebo z iného oddelenia, alebo dokonca v porovnaní s ostatnými dátami z prepojených programov v iných univerzitách [24]. Výsledky a získané skúsenosti možno využiť na vytvorenie databázy vedomostí zrejme v súvislosti s niekoľkými pedagogickými zásahmi. To môže podporiť vytváranie nových politík v celej organizácii a byť dôležitým prvkom rozvoja kvality a akademického výskumu.

4.3 Zdroje Big Dat v e-learningu

Big Data je všestranný termín, ktorý sa vzťahuje na veľké množstvo informácií v celom vzdelávacom procese. Otázka však môže byť, kde nájsť tieto cenné Big Data? Našťastie existuje niekoľko zdrojov, ktoré majú všetky informácie, ktoré potrebujeme na získanie Big Dat v e-learningu.

Nepochybne tam patria LMS – systémy riadenia vzdelávania, ktoré môžeme považovať za najsilnejší nástroj a zdroj Big Dat. Platformy LMS zvyčajne obsahujú podrobné správy a analýzy. Pri využívaní kurzov v e-learningu máme možnosť analyzovať všetky aspekty svojho kurzu. Od individuálnej výkonnosti a miery dokončenia kurzu jednotlivých študentov až po výsledné hodnotenia. Sú jednotlivé metriky LMS, ktoré by sa mali pravidelne kontrolovať.

- Online výkonnosť študenta – pomôže nám určiť jednotlivé oblasti vhodné na zlepšenie, ako aj silné a slabé stránky celkového dizajnu e-learningu. Ak by 75% študentov prihlásených do kurzu nebolo schopných dokončiť on-line simuláciu/test, je to príznak toho, že nemá dostačujúce informácie ani zručnosti. Ako učiteľ a tvorca kurzu by sme mali študentom poskytnúť buď

doplnkové vzdelávacie materiály, alebo prehodnotiť, resp. pozmeniť samotný kurz.

- Výsledky hodnotenia – tu sa môžeme spýtať otázku, sú študenti, ktorí absolvovali daný kurz naozaj schopní aplikovať to, čo sa naučili? Spomínajú si na kľúčové veci? Hodnotenia z LMS nám môžu pomôcť určiť, či študenti po absolvovaní kurzu posúvajú svoje poznatky z teórie do praxe.
- Online spätná väzba študenta – hodnotenie spokojnosti s kurzom môže učiteľovi pomôcť sa priblížiť študentom a poskytnúť im zaujímavý a lákavý pohľad na danú problematiku. Spätná väzba môže vypovedať o aké aktivity v rámci e-learningu majú študenti záujem a tiež môže byť nástrojom na sledovanie výkonnosti učiteľov. Vysoký podiel neúspešných študentov v e-learningu môže znamenať len jednu vec, a to neefektívne vzdelávanie pomocou e-learningu.

Ďalším zdrojom je určite štatistika sociálnych médií. Tieto médiá umožňujú študentom komunikovať online a tým uľahčujú spoluprácu v online vzdelávaní. Napríklad Facebook môže obsahovať ankety, ktoré uľahčujú proces spätnej väzby, môžeme sa tam dozvedieť o preferenciách, osobných názoroch a zvykoch študentov. Táto analýza dokáže zistiť odkiaľ pochádzajú online študenti, koľko času trávia na webe a aké zariadenia používajú. Napríklad služba Google Analytics umožňuje sledovať kedy študenti navštívia stránku a ktoré kľúčové slová používali pri vyhľadávaní.

Efektívny spôsob ako zhromaždiť Big Data je získať ich priamo od online študentov. Prieskumy, rozhovory, videokonferencie môžu pomôcť odhaliť pravdivý názor na e-learningový kurz. Dôležité je v tomto prípade sa zamerať na riziká a ciele učenia. Každý online kurz vyžaduje určitú prácu pri vytváraní. Otázky sa preto môžu zamerať na chybujúce prvky kurzu a tak otvoriť priestor pre návrhy. Ak študenti majú priestor pre svoj názor a zároveň vedia, že ich názor môže mať nejaký význam a bude vypočutý, dokáže to posilniť ich aktívnu účasť a motiváciu.

Medzi zdroje Big Dat vo vzdelávaní patrí aj analýza webových stránok. Webové stránky e-learningových kurzov, on-line fóra a blogy sú ďalšími zdrojmi Big Dat. Analýzu môžeme použiť na sledovanie návštevnosti stránok, angažovanosti a miery konverzie.

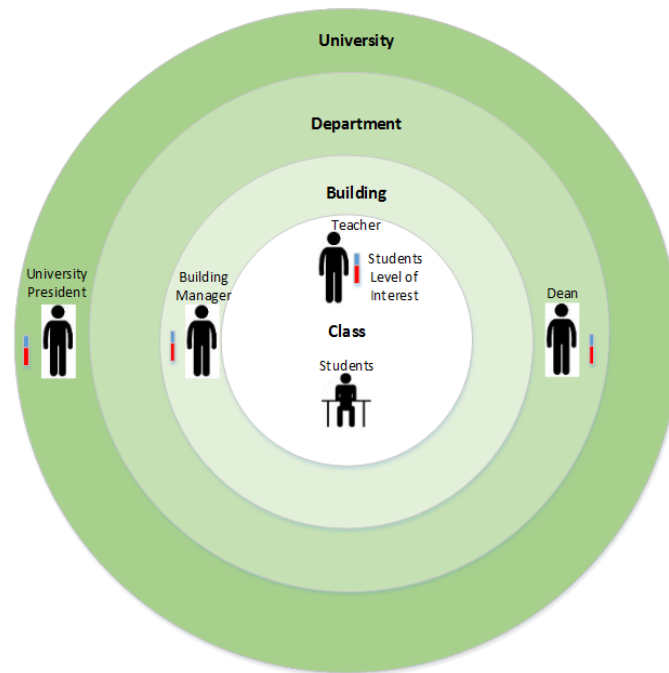
4.3.1 *Využitie dát získaných z LMS*

Študent pri práci s LMS zanecháva za sebou istú dátovú stopu. Jednou z dôležitých vecí je vedieť správne využiť získané dáta zo systému. LMS nie je len pomôcka pre študentov, ale umožňuje učiteľom poskytovať a spravovať získané zdroje/údaje relatívne jednoduchým a integrovaným spôsobom. Keďže každá činnosť v LMS je monitorovaná a uložená, môže sa získať prehľad o správaní študentov na internete, čo sa dá využiť na zlepšenie učenia a výučby.

Jednými z extrahovaných dát môže byť výkon a pokrok v online vzdelávaní. Na týchto získaných údajoch môžeme pozorovať výkonnosť a pokrok študentov. Tiež môžu tieto údaje priniesť prehľad o správaní, skúsenostiach a schopnostiach učenia. Tieto informácie sú použiteľné ako pre študentov, tak aj pre univerzitu. Jednotlivé fakulty porovnávajú dáta medzi jednotlivými učebňami a vedenie univerzity zase porovnáva výsledky všetkých fakúlt, ktoré spadajú pod akademickú obec. Viac univerzít potom môže porovnať dáta navzájom a vylepšovať tak kvalitu výučby pre budúcich aj existujúcich študentov.

Vďaka dátam získaným pomocou nových technológií, možno skvalitniť a zefektívniť nielen výučbu, ale celé pôsobenie vysokej školy. Z hľadiska univerzity môže byť úroveň záujmu študentov zhromažďovaná na úrovni triedy, oddelenia a univerzity, takže učiteľ môže v reálnom čase sledovať úroveň záujmu každého jednotlivca, ako aj celej triedy. Oddelenie môže zhromažďovať na úrovni oddelení a univerzita tak môže zbierať úroveň záujmu na univerzitnej úrovni. Na obrázku nižšie môžeme vidieť ako sa rozčleňuje zber a využitie dát v univerzitnom prostredí do jednotlivých úrovní.

Obrázok 4: Úrovne zberu dát na univerzite



Zdroj: <http://www.mcrlab.net/research/smart-education-in-a-smart-city/>

Dáta o vysokoškolskom vzdelávaní sú dnes zhromažďované samotnými vysokými školami a univerzitami, no môžeme tvrdiť, že až donedávna obsahovali len málo údajov o výsledkoch študentov alebo o študentoch, ktorí prišli z inej vysokej školy. Ak študent vystrieda viac vysokých škôl, spoľahlivý záznam o jeho skúsenostiach je v najlepšom prípade veľmi slabý.

Študent môže ťažiť z týchto dát napríklad tým, že zistí obľúbenosť predmetov z minulých rokov a následne mu tieto informácie pomôžu pri zápise do nasledujúcich semestrov. Zároveň študent získava aj spätnú väzbu na jeho výkony počas výučby a na základe týchto dát sa môže ďalej do budúcnosti zlepšovať. Tiež zistí, ktoré predmety boli pre neho zaujímavé, a ktorým nevenoval príliš pozornosti. Pre stredoškolských študentov sú tieto informácie dôležitým zdrojom pri rozhodovaní, ktorú univerzitu, fakultu a odbor zvoliť pri výbere vysokoškolského štúdia. [34]

4.4 Pohľad na úspešnosť/neúspešnosť študentov

Hneď na úvod si môžeme zdefinovať, koho budeme považovať za neúspešného študenta. Bude to taký študent, ktorý nespĺnil požiadavky stanovené študijným programom, na ktorý sa zapísal, za podmienok vymedzených v tomto programe.

Je takmer nemožné ohodnotiť výkon škôl. Prečo sa len určitý počet študentov dostane k štátniciam? Nechávajú školy prepadať svojich študentov a opakovať ročníky? Alebo na druhej strane pomáhajú niektoré školy svojim študentom prejsť celým stupňom vysokoškolského štúdia ľahším spôsobom? Toto zatiaľ nevieme nijako dokázať a ani vyvrátiť, keďže zbieranie dát na úrovni inštitúcií bohužiaľ znamená, že vieme len veľmi málo o programoch na jednotlivých školách, a o tom, ako školy dokážu študentov efektívne do viesť k znalostiam a zručnostiam, ktoré potrebujú k úspechu. To sťažuje študentom možnosť sa rozhodnúť, akú školu si pre svoje štúdium vybrať. Zatiaľ čo na niektorých školách existuje hodnotenie niektorých odborov, sú tieto hodnotenia založené na vstupných dátach a hovoria len málo o výstupoch študentov, ktoré môžu dosiahnuť. [35]

Úspešnosť vzdelávania na vysokých školách závisí od ich schopnosti odpovedať na naliehavé otázky. Prečo študenti odchádzajú? Ako môžeme zistiť jednotlivé rizikové úrovne študentov? Prečo študent zlyhal pri danej skúške? Prečo študent neovláda konkrétny pojem alebo zručnosť? Odpovede sa líšia vzhľadom na konkrétnu školu, ale všetky sú založené na údajoch. Na základe analýzy Big Dat získaných počas štúdia každého študenta by mala škola vedieť identifikovať rizikových študentov včas, navrhnúť opatrenia a predísť predčasnému ukončeniu štúdia.

Už pri pohľade na číselné údaje v Štatistických ročenkách školstva SR môžeme badať značný rozdiel medzi počtom študentov, ktorí sa na jednotlivých vysokých školách/fakultách zapísali do prvého ročníka a počtom študentov, ktorí úspešne doštudovali prvý stupeň bakalárskeho štúdia a následne aj druhý stupeň inžinierskeho resp. magisterskeho štúdia. Samozrejme, nemožno z týchto údajov odvodiť presný číselný úbytok, hlavne čo sa týka druhého stupňa štúdia, keďže je možnosť pokračovať v tomto štúdiu aj na inej škole. Na mnohých fakultách je rozdiel medzi prijatými študentami a tými, ktorí toto štúdium úspešne ukončili po piatich rokoch, dosť veľký na to, aby sme sa mohli zamýšľať nad jeho príčinami a dôsledkami. Bez zbytočného zveličovania môžeme povedať, že neúspešnosť študentov na slovenských verejných vysokých školách je nepriaznivým spoločenským javom. Nielen kvôli neúčelne vynaloženým finančným prostriedkom z verejných zdrojov, ale určite aj pre zúčastneného študenta. Dôsledkom môže byť málo vyhovujúca príprava na stredných školách, náročnosť štúdia, alebo aj postup pri prijímaní na štúdium.

Je dobré si uvedomiť, že ak hovoríme o neúspešnosti vysokoškolských študentov, táto neúspešnosť nie je iba ich produktom. Má na nej podiel aj kvalita a osobnostné vlastnosti vysokoškolských učiteľov a tiež materiálne a finančné podmienky práce vysokých škôl.

4.4.1 Pohľady do štatistík neúspešnosti študentov

V našej štúdií sme sa zamerali na študentov Ekonomickej univerzity v Bratislave a konkrétne len študentov Fakulty hospodárskej informatiky. Na začiatok si uvedieme tabuľky, ktoré sme si vytvorili na základe dostupných štatistík v štatistickej ročenke školstva, a tiež v našom akademickom informačnom systéme AiS2. Tento informačný portál nám poskytuje kompletné údaje o všetkých absolventoch na Ekonomickej univerzite.

Nižšie uvedená tabuľka dokumentuje, ako od roku 2009 až po rok 2017 klesal počet absolventov. V tejto tabuľke sme porovnávali aký bol počet študentov prijatých do prvého ročníka štúdia, následne koľko z týchto študentov úspešne absolvovalo prvý stupeň a posledný stĺpec tabuľky predstavuje študentov, ktorí úspešne skončili aj druhý stupeň štúdia a odišli s inžinierskym titulom.

Tabuľka 1: Úbytok počtu študentov od nástupu až po absolvovanie II. stupňa štúdia

Rok nástupu	Počet prijatých študentov	Rok absolvovania I. stupňa štúdia	Počet absolventov I. stupňa	Rok absolvovania II. stupňa štúdia	Počet absolventov II. stupňa
2004	465	2007	339	2009	327
2005	370	2008	270	2010	262
2006	757	2009	488	2011	445
2007	462	2010	359	2012	342
2008	509	2011	345	2013	293
2009	359	2012	306	2014	307
2010	329	2013	234	2015	230
2011	301	2014	218	2016	244
2012	270	2015	192	2017	220

Zdroj: vlastné spracovanie podľa: ais2, CVTI SR

V nasledujúcej tabuľke č.2 znázorňujeme aký bol rozdiel v počte študentov zapísaných do 1. ročníka a počet absolventov štúdia I. a II. stupňa. Posledné dva stĺpce tabuľky znázorňujú úspešnosť absolventov I. a II. stupňa štúdia vzhľadom na počet prijatých študentov na začiatku absolventského štúdia.

Tabuľka 2: Rozdiel v počte zapísaných študentov a absolventov, celková úspešnosť absolventov I. a II. stupňa

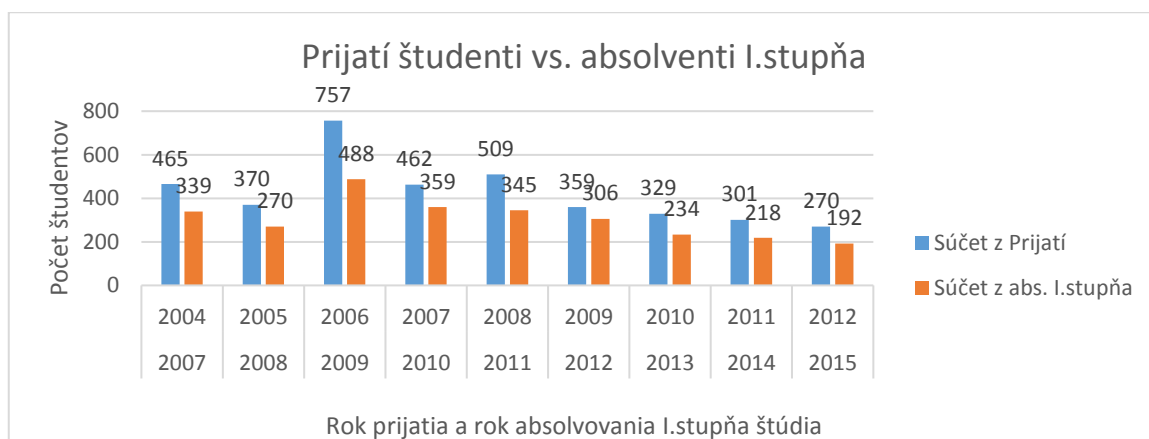
Rok nástupu	Počet prijatých študentov	Rozdiel v počte študentov zapísaných do 1. ročníka a úspešných absolventov I. stupňa	Rozdiel v počte študentov zapísaných do 1. ročníka a úspešných absolventov II. stupňa	% úspešnosť absolventov I. stupňa	% úspešnosť absolventov II. stupňa
2004	465	126	138	73%	70%
2005	370	100	108	73%	71%
2006	757	269	312	64%	59%
2007	462	103	120	78%	74%
2008	509	164	216	68%	58%
2009	359	53	52	85%	86%
2010	329	95	99	71%	70%
2011	301	83	57	72%	81%
2012	270	78	50	71%	81%

Zdroj: vlastné spracovanie podľa CVTI SR a AiS2

Vyššie sme si uviedli tabuľky s údajmi, ktoré sme získali z dostupných zdrojov a v nasledujúcom grafe č.1 znázorníme rozdiel medzi počtom prijatých študentov na I. stupni vysokoškolského štúdia na Fakulte hospodárskej informatiky a počtom tých študentov, ktorí po troch rokoch štúdia úspešne ukončili I. stupeň.

Budeme predpokladať, že úspešné absolvovanie tohto štúdia bude trvať 3 roky, ako je stanovené pre Bakalárske štúdium na Fakulte hospodárskej informatiky. Musíme však podotknúť, že študenti, ktorí sú zapísaní v tomto období, nemusia študovať len spomínané 3 roky. Podľa dostupných štatistík však nevieme určiť, či v týchto štatistikách nie sú započítaní aj študenti, ktorí opakujú ročník, alebo prestúpili z inej školy, resp. fakulty.

Graf 1: Počet prijatých študentov vs. Absolventi I. stupňa štúdia



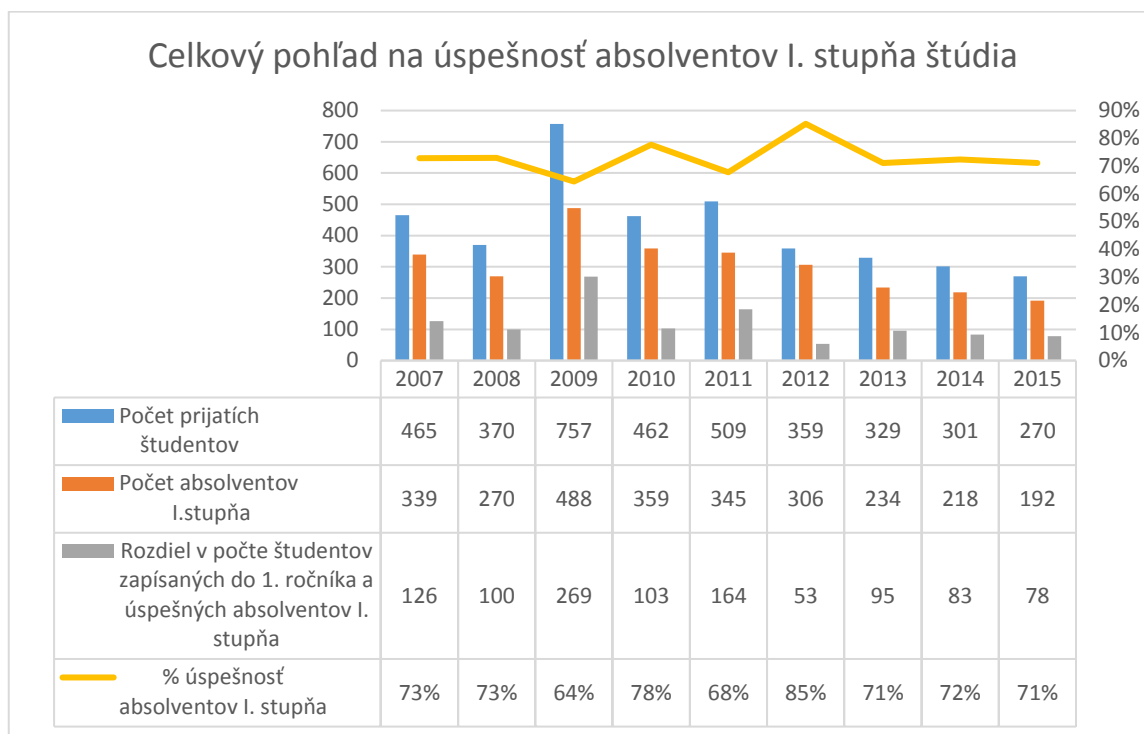
Zdroj: vlastné spracovanie podľa CVTI SR a AiS2

Na grafe môžeme vidieť, že v každom roku bol počet absolventov nižší ako počet tých študentov, ktorí nastúpili na začiatku štúdia. Teda jedná sa o tých istých študentov. Najväčší rozdiel medzi prijatými a absolventami bol v roku 2006-2009. Tento jav mohol vzniknúť aj na základe skutočnosti, že v akademickom roku 2005/2006 došlo v systéme štúdia na Ekonomickej univerzite v Bratislave k zásadným zmenám. Toto štúdium sa stalo 3-stupňové. Prvý stupeň predstavuje bakalárske štúdium, ktorého štandardná dĺžka je tri roky. Druhý stupeň tvorí inžinierske štúdium a jeho štandardná dĺžka je dva roky.

Ak sa pozrieme na ostatné roky, vo všetkých prípadoch vidíme, že počet študentov klesol, a isté percento študentov úspešne nedokončilo ani I. stupeň štúdia. Na nasledujúcom grafe môžeme vidieť celkový pohľad na priebeh I. stupňa štúdia. Graf nám zobrazuje počet prijatých študentov, počet absolventov bakalárskeho stupňa a počet študentov, ktorí nedokončili bakalárske štúdium. Rok prezentuje, kedy sa študenti stali úspešnými absolventami. Žltá čiara naznačuje percentuálnu úspešnosť v priebehu nastúpenia na štúdium až po dokončenie bakalárskeho štúdia, čiže tri roky. Jedná sa o študentov, ktorí nastúpili na štúdium v rokoch 2004 až 2012 a absolventami sa stali v rokoch 2007-2015.

Tabuľka pod grafom poukazuje na presné hodnoty prijatých študentov, absolventov, počet tých, ktorí predčasne skončili a celkovú percentuálnu úspešnosť absolventov I. stupňa štúdia. Z grafu môžeme zhodnotiť, že napriek tomu, že sa jedná o bakalárske štúdium, teda I. stupeň, podiel neúspešných študentov je dosť veľký. Najväčší rozdiel medzi počtom prijatých a absolventov bol v roku 2009 a 2011. Najväčšiu úspešnosť mali študenti, ktorí nastúpili na štúdium v roku 2009, čiže úspešnými absolventami bakalárskeho štúdia sa stali v roku 2012. Ako môžeme z grafu vidieť, nevieme určiť presné stanovisko, či celková úspešnosť absolventov, klesá alebo vzrastá. Môžeme však potvrdiť, že najväčšie výkyvy boli medzi rokmi 2008 až 2013. V tomto období úspešnosť absolventov trikrát klesla a dvakrát stúpila. Od roku 2013 sa úspešnosť drží približne na rovnakej úrovni.

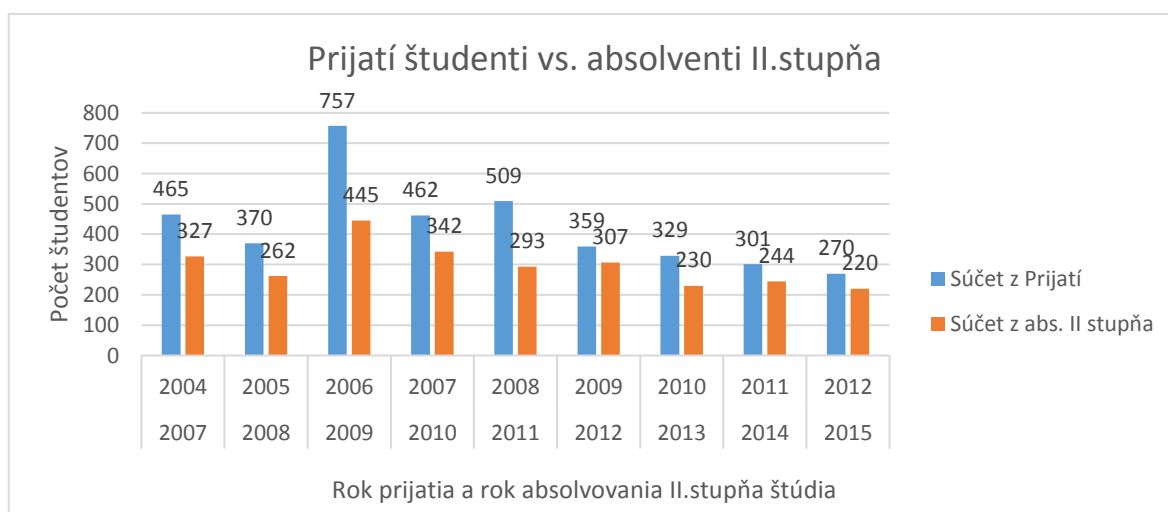
Graf 2: Celkový pohľad na úspešnosť absolventov I. stupňa štúdia



Zdroj: vlastné spracovanie podľa CVTI SR a AiS2

V grafe č.3 vidíme porovnanie medzi študentami, ktorí nastúpili na štúdium, a počtom študentov, ktorí úspešne dokončili aj druhý stupeň, v tomto prípade inžinierske štúdium. Aj tu je počet absolventov v každom roku nižší ako počet tých, ktorí začínali na začiatku inžinierskeho štúdia.

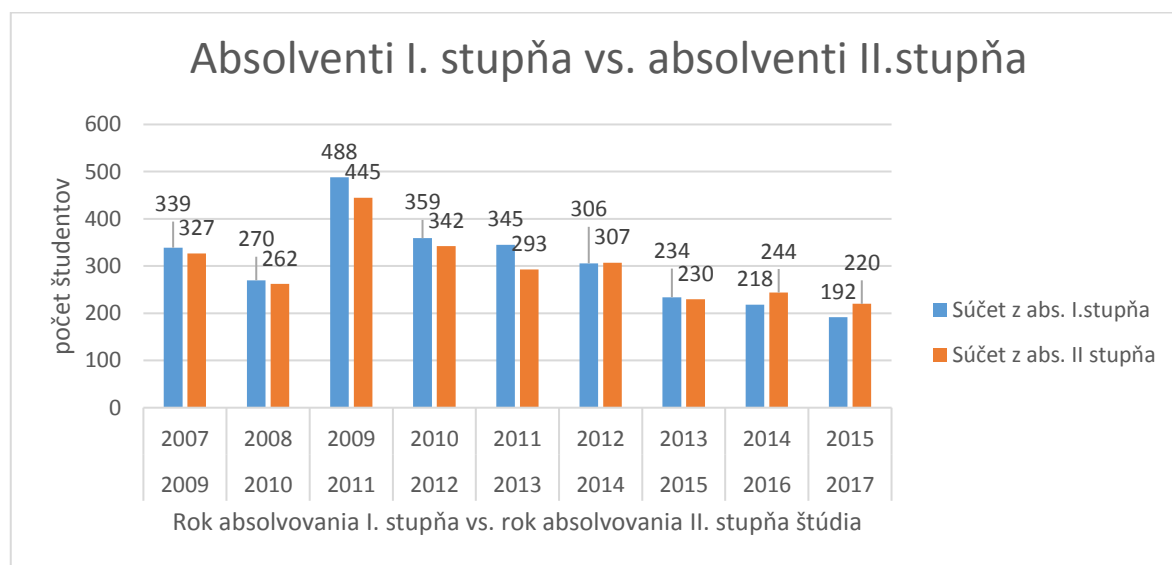
Graf 3: Prijatí študenti vs. absolventi II. stupňa štúdia



Zdroj: vlastné spracovanie podľa CVTI SR a AiS2

V nasledujúcom grafe č.4 si porovnáme absolventov I. stupňa a absolventov II. stupňa štúdia. V tomto prípade nie sú rozdiely tak veľké ako v predchádzajúcich grafoch. Napriek tomu môžeme aj v tomto prípade zhodnotiť, že neúspešnosť študentov pretrváva aj v II. stupni štúdia. Avšak podľa grafu vidíme že počet absolventov II. stupňa malo oproti počtu absolventov I. stupňa klesajúca tendenciu až do roku 2012/2014. Už v tomto roku bol rozdiel veľmi zanedbateľný a predstavoval len jedného absolventa. V roku 2016 a 2017 dosiahlo inžiniersky titul viac študentov ako na bakalárskom stupni.

Graf 4: Absolventi I. stupňa vs. absolventi II. stupňa štúdia

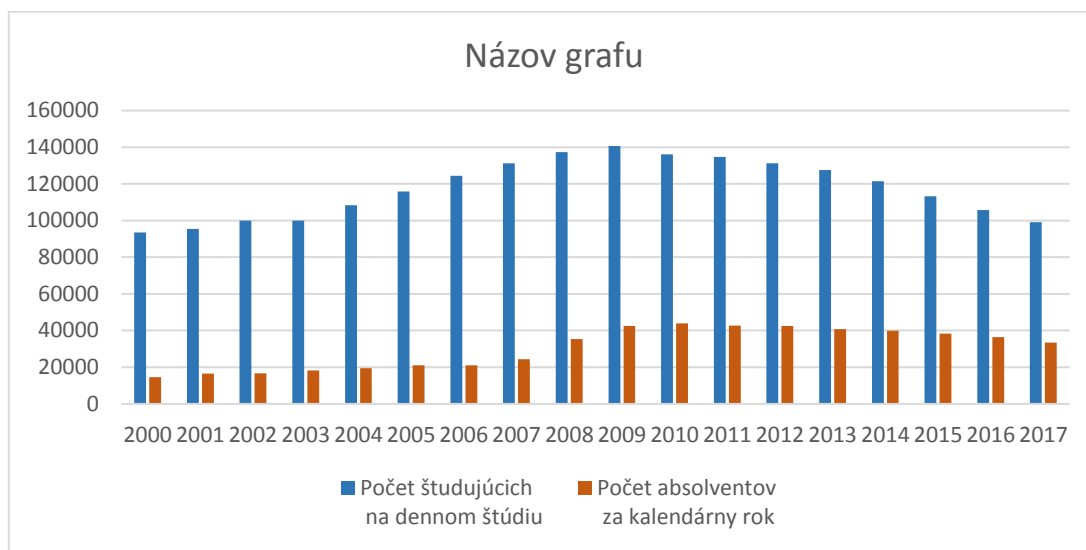


Zdroj: vlastné spracovanie podľa CVTI SR a AiS2

Tak isto v tomto prípade musíme brať do úvahy, že bakalársky titul si študent môže spraviť na jednej škole, a pokračovať na inžinierskom stupni štúdia môže následne aj na inej škole. Z tohto dôvodu prichádzame k záveru, že vzhľadom na tieto skutočnosti, nevieme odhadnúť presný počet úspešných absolventov na našej fakulte v porovnaní s počtom študentov, ktorí nastúpili na univerzitu na začiatku inžinierskeho štúdia. Medzi ďalšie faktory, ktoré spôsobujú nepresnosti v získaných údajoch môžu byť študenti opakujúci ročník. Pravdaže dôvodom na opakovanie ročníka nemusí byť iba neprospech. Určite časť týchto študentov opakuje štúdium napríklad pre chorobu, materstvo alebo štúdium v zahraničí.

Globálny pohľad na počet študujúcich na dennom štúdiu a absolventov dennej formy nám poskytuje nasledujúci graf č. 5.

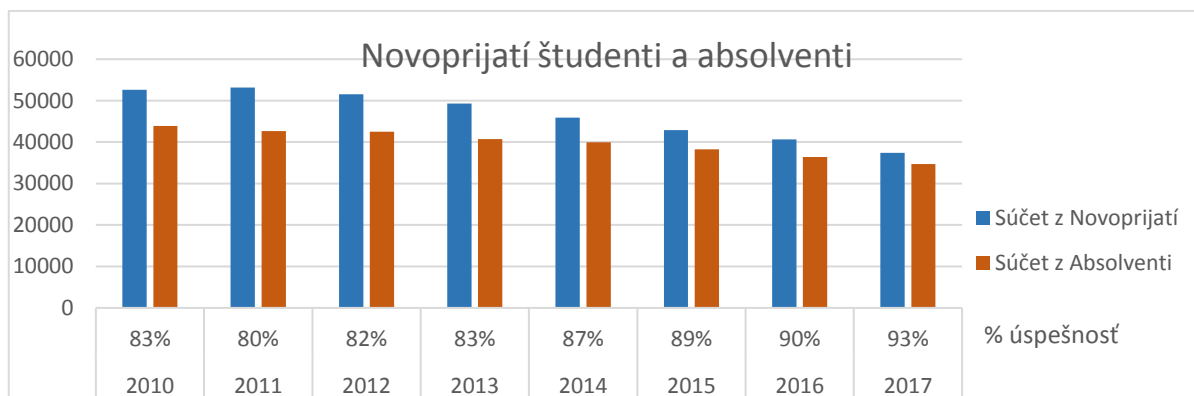
Graf 4: počet študujúcich na dennom štúdiu vs. absolventi za daný rok v SR



Zdroj: vlastné spracovanie podľa CVTI SR

Ako môžeme vidieť na grafe č.5, počet študentov lineárne rástol až do roku 2009. O počte absolventov môžeme povedať to isté. Prelomovým bol rok 2009. V nasledujúcom grafe si bližšie definujeme počet novoprijatých študentov a absolventov dennej formy vysokoškolského štúdia na Slovensku medzi rokmi 2010 až 2017.

Graf 5: Novoprijatí študenti a absolventi



Zdroj: vlastné spracovanie podľa CVTI SR a AiS2

Počet novoprijatých študentov na denné štúdium do roku 2009 rástol. V ďalšom období klesol päťpercentným medziročným tempom z 52,6 tisíc na súčasných 37,4 tisíc. Taktiež počet absolventov dennej formy vykazoval do roku 2010 rastúci trend. V nasledujúcej klesajúcej fáze sa znížil z 43,9 tisíc na súčasných 34,7 tisíc. Napriek klesajúcej tendencii ako u novoprijatých tak aj u absolventov, môžeme vidieť, že celková

úspešnosť má rastúcu tendenciu. Avšak, toto sa týka celkového pohľadu na všetky vysoké školy na Slovensku.

4.4.2 Príčiny študijnej neúspešnosti

„Mal som príležitosť analyzovať činnosť niekoľko tisíc mužov a žien, z nich 98% patrilo do kategórie neúspešných“

Napoleon Hill

Ak je tak veľké percento ľudí, ktorí nedosiahnu nejaký trvalejší a väčší úspech, nech už je to v čomkoľvek, môžeme sa spýtať, čo teda robia tí úspešní? Dá sa úspech napodobniť? Určite v istom slova zmysle áno. Je však potrebné pre to aj niečo robiť.

Keď by sme mali skúsiť odpovedať na otázky. Prečo je študent neúspešný? Prečo predčasne skončí svoje štúdium? Naše odpovede by sa asi líšili vzhľadom od školy, od daného študenta, od študijného programu, od vyučujúceho, ale v každom prípade by mali byť naše odpovede založené na údajoch.

Dovoľme si tvrdiť, že úroveň vysokých škôl na Slovensku dosť upadá. Viaceré vysoké školy pri prijímaní študentov nerobia výber, ale skôr nábor. Počas prvých dvoch rokov štúdia bakalárskych študijných programov takmer tretina študentov zanechá štúdium alebo ich z neho vylúčia. Uberá to aj na vážnosti vysokoškolského diplomu. Pod ukončenie vysokoškolského štúdia, už na jeho začiatku, sa nezvykne podpísať jediná príčina ani jediný zdroj viacerých príčin. Kombinujú sa príčiny subjektívne s objektívnymi. Pravdaže, s neúspešným štúdiom (predčasným odchodom z vysokoškolského štúdia) sa stretávame aj vo vyšších ročníkoch. V porovnaní s 1. ročníkom tu však odchádza len veľmi malá časť študentov a ich neúspech spravidla súvisí s nezvládnutím „zlomovej“ skúšky. Zaradenie takejto skúšky na niektorých fakultách do 3. alebo dokonca 4. ročníka je nedobré pre študenta i verejné financie, ktoré sa do jeho nedokončeného štúdia investovali.

Pohnútky a dôvody, pre ktoré sa rozhodne absolvent strednej školy uchádzať o vysokoškolské štúdium, sa stávajú dôležitým faktorom jeho vzťahu k štúdiu, môžu mu pomáhať prekonávať ťažkosti, alebo, na druhej strane, oslabovať jeho vôľu študovať úspešne. Istou príčinou neúspešnosti študentov môže byť nevyhranenosť záujmov. Ak hovoríme o motivácii študovať na vysokej škole a o voľbe fakulty (študijného programu), nemôžeme obísť fakt, že jestvuje nemalá časť absolventov stredných škôl, ktorých prvoradým cieľom je stať sa vysokoškolákom.

Ďalším dôležitým faktorom je vedomostná pripravenosť na vysokoškolské štúdium, teda predovšetkým rozsah a úroveň (kvantita a kvalita) vstupných vedomostí a zbehlostí, ktoré určujú hranice úspešnosti vysokoškolského štúdia. Už po mnohé roky vysoké školy konštatujú, že vedomostná pripravenosť absolventov stredných škôl na vysokoškolské štúdium sa zhoršuje. Hoci nejestvujú celoslovenské merania porovnávajúce vývoj rozsahu a úrovne vedomostí absolventov stredných škôl, je dosť indícií na to, aby sme tvrdenia vysokých škôl nespochybňovali. Nároky v celoslovenskom meraní „monitor“ nebývajú veľké a napriek tomu sa ich výsledkami chváliť nemožno. Pri hodnotení kvality prijímaných absolventov stredných škôl netreba zabúdať ani na to, že stovky absolventov stredných škôl odchádzajú študovať do zahraničia. Väčšinu z nich iste tvoria tí, ktorí patrili na strednej škole medzi lepších žiakov.

Ďalším významným faktorom, určujúcim úspešnosť/neúspešnosť vysokoškolského štúdia v jeho začiatkoch, je prechod zo stredoškolského spôsobu štúdia na vysokoškolský, prechod od zmeny štýlu a náročnosti prezentácie študijného obsahu, až po zmeny v kontrole a hodnotení študijných výsledkov. Podľa našich poznatkov, žiaľbohu, v 1. ročníku odchádzajú zo školy aj schopní študenti len preto, že si uvedomujú svoje nedostatky.

Jedným z dôvodov vedúcich k ukončeniu alebo prerušeniu štúdia môže byť aj nedostatok financií. Nie všetci študenti sú podporovaní rodičmi a hlavne tí, ktorí pochádzajú zo vzdialenejších miest musia riešiť aj otázky bývania. Z vlastnej skúsenosti môžeme potvrdiť, že skoro každý vysokoškolský študent počas absolvovania štúdia aj pracuje. V druhom stupni štúdia nájdeme aj veľké percento takých študentov, ktorí už pracujú na 100% úväzok. Tým pádom, ide škola pre týchto študentov bokom, a veľa krát pri ponuke dobrej pracovnej pozície školu ukončia.

Pedagogická vzdelanosť a osobnostné vlastnosti učiteľov sú ďalším z významných faktorov limitujúcich úspešnosť/neúspešnosť štúdia. Tak ako je rozdielna vedomostná úroveň študentov, tak rozdielna je aj pedagogická úroveň vysokoškolských učiteľov.

Dôvody, prečo študent predčasne ukončí svoje vysokoškolské štúdium nemusia byť vždy dôsledkom jeho študijného neúspechu. Preto môžeme vymenovať zopár príčin, ktoré môžu viesť študentov k prerušeniu štúdia, k predčasnému ukončeniu štúdia, rozloženiu štúdia na dlhšie časové obdobie alebo zmene dennej formy na externú. Môžu byť nimi:

- a) odchod na inú fakultu so zmenou študijného programu
- b) odchod na štúdium do zahraničia

- c) získanie lukratívneho zamestnania
- d) zdravotné problémy alebo problémy v rodine
- e) objektívne príčiny ako nedostatok financií na štúdium
- f) rezignácia, strata dôvery vo vlastné schopnosti

Ak by sme chceli zjednodušene odpovedať na otázku, kto má na to, aby úspešne absolvoval vysokoškolské štúdium, mohli by sme povedať, že ten, kto je vedomostne dobre pripravený študovať program, ktorý si vybral, nechýba mu vôľa, má dobrých učiteľov i potrebné materiálne a finančné zázemie a občas šťastie na skúškach. [37]

4.5 Návrh riešenia

Veľká časť vysokoškolských študentov nie je celkom stotožnená so svojim vysokoškolským zameraním. Až počas štúdia si uvedomia, že cesta, ktorou sa vydali nezodpovedá ich cieľom, teda nevyhovuje ich zručnostiam a záujmom, ktoré budú nasledovať po absolvovaní štúdia. Tento problém dokážeme vyriešiť vytvorením a analýzou dátových modelov akademickej cesty pre jednotlivého študenta. Prostredníctvom toho môže študent počas svojej akademickej cesty interpretovať a analyzovať vlastné súbory údajov o svojich záujmoch, zručnostiach, tvorivosti, analytickom prístupe, schopnostiach prijímať riziká, talente a správaní.

Integráciou umelej inteligencie bude možné ľahko získať zmysluplné poznatky o budúcej kariérnej voľbe študenta, o najvhodnejších inštitúciách blízkych pre jeho odvetvie. Rovnako je užitočné a efektívne, aby učители, pedagógovia, inštitúcie a tvorcovia politiky pochopili, analyzovali a prijali potrebné opatrenia. Pri analýze týchto údajov môžu následne inštitúcie prísť s väčším počtom miest, pripraviť a spravovať zdroje s cieľom poskytnúť študentom lepšie príležitosti.

V blízkej budúcnosti by bola navrhnutá cloudová platforma na vytváranie, správu a analýzu údajov študentov počas ich akademickej cesty a ich implementácia na celom svete. Bolo by zodpovednosťou inštitúcií poskytovať údaje o svojich študentoch. Tieto veľmi citlivé a zmysluplné údaje môžu byť analyzované na rôznych úrovniach a užitočné pre študentov, členov fakulty, inštitúcie, tvorcov politik atď. Študenti by mohli kontrolovať analýzu svojich údajov a prísť s lepším výberom kariéry. Učители by využívali tieto údaje na zlepšenie vzdelávacieho výstupu študentov. Zhromažďovanie údajov a vyhľadávanie údajov by inštitúcie používali na pochopenie zmysluplných vzorov, výberu povolania, správania, pridelovania zdrojov a riadenia.

Hoci mnohé z cieľov vzdelávacieho zážitku nemožno ľahko merať, výskum a analýza náročné na údaje vo vysokoškolskom vzdelávaní, nám môžu pomôcť zlepšiť, kontrolovať a pochopiť tie ciele, ktoré je možné merať. Rozsah a hĺbka dostupných údajov má potenciál zásadne zlepšiť vzdelávanie. Veríme, že to, čo sa deje s výskumom a analýzou náročnou na údaje, je dnes porovnateľné s vynálezmi mikroskopu a teleskopu. Obe tieto zariadenia odhalili nové typy údajov, ktoré boli vždy prítomné, ale nikdy neboli prístupné. Teraz máme ekvivalent mikroskopu a teleskopu na pochopenie výučby a učenia sa silnými spôsobmi.

Máme potenciál posúdiť študentov spôsobom, ktorý môže zlepšiť hĺbku, frekvenciu a čas odozvy, prípadne rozšíriť rozsah, akým môžu študenti a učitelia sledovať vzdelávanie vrátane hodnotenia zručností na vyššej úrovni a dokazovať spätnú väzbu založenú na týchto hodnoteniach. Avšak nástroje na pochopenie týchto údajov sú u nás stále v plienkach. Veľkou výzvou pri výskume a analýze náročnej na údaje vo vysokoškolskom vzdelávaní je nájsť prostriedky získané z veľmi bohatých dátových súborov, ktoré sa dnes vytvárajú. [37]

4.5.1 Blackboard Analytics

Jedným z riešení, ktoré univerzity a vysoké školy v Európe používajú, a ktoré by mohli byť dobrým nástrojom na využitie všetkých Big Dat vo vysokoškolskom vzdelávaní aj u nás, je Blackboard Analytics.

Blackboard Analytics je kompletný rad dátových a analytických produktov navrhnutých s cieľom pomôcť vysokým školám a univerzitám optimalizovať celkový študentský zážitok z výučby. Tento produkt je najsilnejší, najpružnejší a najkomplexnejší nástroj na analýzu vzdelávania na dnešnom trhu. Je navrhnutý tak, že slúži ako študentom, učiteľom, tak aj celej škole. Určite môžeme tvrdiť, že je špecifický svojim dizajnom. Dobre navrhnuté vzdelávacie prostredie môže zvýšiť angažovanosť študentov, znížiť zbytočné kognitívne zaťaženie a povzbudiť sebareflexiu, ale môže byť ťažké vedieť, čo funguje najlepšie, v akom kontexte a pre koho. Blackboard Analytics sa skladá z viacerých modulov.

Blackboard Analytics for Learn zlepšuje efektívnosť podávania správ, podporuje rozvoj fakúlt a tiež samo regulované vzdelávanie. Krokom k úspechu je určite optimalizovanie vzdelávania online. Tak isto ako aj iné fakulty vo svete aj tá naša sa snaží používať LMS rôznymi spôsobmi. Dôležité je však objaviť správne nástroje a vzory pre študentov podľa konkrétnej školy, odboru, programu a kurzu. Vysoké školy a univerzity

trávia veľa času pri rozvoji fakulty, ale pravdepodobne nemajú dobrý spôsob, ako merať istý vplyv. S programom Analytics for Learn môžu vývojári fakulty prezentovať učiteľom dôkazy o tom, čo funguje, a mať prístup k informáciám, ktoré potrebujú na neustále zlepšovanie výučby. Výskum zistil, že dashboardy² orientované na študentov majú významný vplyv na výkonnosť študenta. Služba Analytics for Learn obsahuje integrovaný informačný panel, ktorý umožňuje študentom sledovať svoju činnosť v porovnaní s ostatnými.

Blackboard Predict je rýchlo nasadené riešenie LMS, ktoré využíva údaje a pokročilú analýzu na identifikáciu rizikových študentov, čo umožňuje včasnú osobnú a škálovateľnú intervenciu. Zvyšuje zadržanie študentov a zabezpečuje poradenstvo pri riešení rôznych problémov. Tento prediktívny model využíva rozsiahle údaje z univerzitného LMS na posúdenie rizikových študentov spôsobom, ktorý je prispôsobený konkrétnej vysokej škole alebo univerzite. Jednoduché, ľahko interpretovateľné vizualizácie a upozornenia pomáhajú učiteľom pochopiť, ktorí študenti sú ohrození. Študentom orientované dashboardy informujú samotných študentov o pokroku v akademickom štúdiu a poskytujú mu relevantnú spätnú väzbu, ktorá im pomáha vytrvať na ceste štúdiom a snaží sa ho motivovať.

Tak ako Blackboard Analytics dokáže zlepšovať výsledky študentov, tak aj Blackboard Intelligence dokáže zlepšiť inštitucionálnu výkonnosť. Poskytujú vysokým školám a univerzitám komplexné riešenie na ukladanie dát a podávanie správ na podporu riadenia zápisu, uchovávanie, finančnej pomoci, strategického financovania, ľudských zdrojov a pokroku.

Vysoké školy a univerzity sú zložité inštitúcie, v ktorých úspech každej časti závisí od výkonnosti každého jedného. Na urýchlenie tempa vysokokvalitného vysokoškolského vzdelávania potrebujú inštitúcie spôsob, ako získať novú perspektívu, ktorá minimalizuje zložitosť a povrchové akcieschopné poznatky z masy údajov, ktoré už majú. Blackboard Intelligence je kompletná sada dátového manažmentu, ovládacieho panelu výkonnosti a reportovacích riešení, ktoré pomôžu pochopiť a optimalizovať všetky dimenzie vysokej školy alebo univerzity. Manažment študentov a finančná pomoc integrujú údaje z viacerých

² Dashboard - z anglického prekladu "nástenka", sa využíva v prípade produktov, ktoré majú za cieľ integrovať informácie z viacerých zložiek do jednotného zobrazenia. Vo svete internetu je používaná najčastejšie ako označenie miesta v užívateľskom rozhraní, na ktorom sa zobrazujú kľúčové informácie, najnovšie aktualizácie, správy a upozornenia. [39]

zdrojov, aby poskytli informácie o každom aspekte životného cyklu študentov. S bohatými údajmi o skúsenostiach so študentmi pri prechode do konkrétnej inštitúcie môžeme zvýšiť zápis, znížiť náklady na študentov, zlepšiť výsledky vzdelávania a zvýšiť mieru absolvovania.

Keďže aj naša škola využíva LMS Moodle, preto jedným z najzaujímavejších riešení, ktoré Blackboard Analytics ponúka je X-Ray Learning Analytics. Optimalizuje hodnotenia, zvyšuje angažovanosť študentov, podporuje kritické myslenie a objavuje trendy v priebehu kurzov. X-Ray Learning Analytics poskytuje hlboký pohľad na správanie sa študentov a určuje trendy, ktoré ovplyvňujú dosiahnuté výsledky v rámci Moodle. Pozitívna vzdelávacia skúsenosť je výsledkom vysokokvalitného vzdelávania, excelentnosti pri navrhovaní kurzu a angažovanosti s ostatnými študentmi v rámci učiacej sa komunity. Učitelia často nezistia, že študenti sú dezorientovaní v téme alebo zápasia so študijnými materiálmi, kým nie je príliš neskoro na to, aby to zmenili. X-Ray Learning Analytics pomáha zvýšiť angažovanosť študentov, zobrazuje trendy v aktivitách na úrovni jednotlivca a kurzu, aby pomohla učiteľovi zistiť, ako študenti reagujú a vytvárajú aktivity, ktoré im umožňujú zapájať sa. Tiež podporuje kritické myslenie a originalitu.

Blackboard Analytics je efektívny nástroj, ktorého poslaním je pomôcť vysokým školám a univerzitám získať hodnotu z dát, ktoré dnes v takom obrovskom množstve produkujeme. Tento nástroj by mohol byť istým riešením ako efektívne využiť Big Data vo vzdelávaní. Ale ako sami dobre vieme, takéto veľké zmeny sa nedajú robiť zo dňa na deň ani z roka na rok. Otázkou je, či naozaj chceme prejsť na úplné zdigitalizovanie školstva. Každý má na to asi svoj názor.

Záver

Svet technológií sa za uplynulé desaťročia zmenil na nepoznanie, čo výrazne ovplyvnilo aj prácu učiteľa a vybavenie škôl. Aktívny učiteľ tak môže poskytnúť študentom okrem klasických študijných materiálov aj elektronické, Facebook, resp. svoj blog. V čom je zásadná zmena?

- Veľa študentov uprednostňuje čítanie elektronických materiálov,
- nesledujú učiteľa pri chemickom pokuse na hodine, ani ho sami nerobia, pozerajú video na internete s rovnakým alebo oveľa náročnejším pokusom,
- používajú v učebniach dataprojektory a interaktívnu tabuľu a okrem nej majú k dispozícii informácie v elektronickej forme,
- hotové poznatky, ktoré predtým prezentoval učiteľ, postupne získavajú z dostupných informačných zdrojov, na základe ktorých si osvojujú nové vedomosti,
- niektoré písomky a testy nepíšu na papier, ale vyplňajú elektronický test alebo v reálnom čase riešia elektronické zadania.

Napriek technike, ktorú majú dnes učelia a študenti k dispozícii sa ďalšia výrazná zmena vo vyučovaní neuskutočnila a pri osvojovaní si poznatkov často robia tie isté chyby ako ich otcovia alebo dedovia pred mnohými rokmi. Jednou z príčin je nedostatok metodických materiálov, náročnosť príprav, obľúbené stereotypy, nedostatočná vonkajšia a vnútorná motivácia, ako aj slabá zručnosť učiteľov efektívne využívať technológie a nedostatok informácií o možnostiach ich využitia.

Existuje veľa príležitostí pre univerzity a vysoké školy, aby využili Big Data na zlepšenie spokojnosti a výkonnosti študentov a učiteľov. A hoci medzi univerzitami existuje súťaž pri nábere študentov, všetci môžu mať prospech zo zdieľania údajov, analýzy a osvedčených postupov v oblastiach, ako je efektívnosť študentov, udržanie študentov, zadržiavanie dobrých učiteľov. Vo svete, kde má vzdelanie najväčší potenciál viesť k zlepšeniu kvality života, sú pre vzdelávacie inštitúcie nespočetné možnosti spolupracovať a zvyšovať šťastie študentov, učiteľov a spoločnosti ako celku.

Zavedenie efektívnych nástrojov pre analýzu a spracovanie Big Dat, ktorými už teraz vo veľkom množstve disponujeme, by bolo pravdepodobne obrovským prínosom pre všetkých študentov hlavne v oblasti sebaopozorovania a výhľadov do budúcnosti.

Dovolíme si však položiť otázku. Dokáže nás, študentov, e-learning, online kurzy, videá, naučiť toľko ako zaujímavý prejav učiteľa, ktorý sa vyzná v danej problematike a ktorý to robí s radosťou, ochotou a s cieľom študentov naozaj niečo naučiť?

Sú Big Data naozaj to, čo chceme aby bolo už navždy súčasťou nášho života?

Richard Brautinfan, americký autor básní napísal jednu veľmi zaujímavú báseň. [40]

**Na všetko dohliadajú
stroje láskyplnej milosti**

Rád si predstavujem (a čím
skôr to bude, tým lepšie!)
Kybernetickú krajinu,
kde cicavce a počítače
spoločne žijú v naprogramovanej
vzájomnej harmónii,
ako priesračná voda
pod jasnou oblohou.

Rád si predstavujem
(hneď teraz, prosím!)
Kybernetický les
plný sosien a elektroniky,
kde sa jeleň pokojne prechádza
okolo počítačov,
ako keby to boli
rozkvitajúce kvety.

Rád si predstavujem
(musí sa to stať!)
Kybernetický svet,
kde nikto nepracuje
a žijeme späť v prírode
spoločne s našimi zvieracími
bratmi a sestrami
všetci pod dohľadom
strojov láskyplné milosti.

ZDROJE

- [1] Hopkinton, Mass, *Digital Universe Invaded By Sensors*, 2014, [cit. 14.3.2018]. Dostupné na: <https://www.emc.com/about/news/press/2014/20140409-01.htm>
- [2] The Digital Universe of Opportunities: *Rich Data and the Increasing Value of the Internet of Things*, 2014, [cit. 14.3.2018]. Dostupné na: <https://www.emc.com/leadership/digital-universe/2014iview/executive-summary.htm>
- [3] BUYYA, Rajkumar, Rodrigo N. CALHEIROS a Amir Vahid DASTJERDI, *ed. Big data: principles and paradigms*. Cambridge, 2016. ISBN 978-0-12-805394-2
- [4] Svetlana Sicular, *Gartner's Big Data Definition Consists of Three Parts, Not to Be Confused with Three "V"s*, 2013, [cit. 15.3.2018] Dostupné na: <https://www.forbes.com/sites/gartnergroup/2013/03/27/gartners-big-data-definition-consists-of-three-parts-not-to-be-confused-with-three-vs/#5b2d03c042f6>
- [5] Big data - *definition of big data in English* | Oxford Dictionaries. [cit. 2018-03-18]. Dostupné na: https://en.oxforddictionaries.com/definition/big_data)
- [6] Zephoria, *The Top 20 Valuable Facebook Statistics*, 2018, [cit. 15.3.2018]. Dostupné na: <https://zephoria.com/top-15-valuable-facebook-statistics/>)
- [7] Šmídová Veronika, *Big Data nejsou jen buzzword, přináší reálný užitek, říká světový odborník*, 2014, [cit. 15.3.2018] Dostupné na: <https://byznys.ihned.cz/podnikani/inspirace-technologie/c1-63229170-big-data-nejsou-jen-buzzword-prinasi-realny-uzitek-rika-svetovy-odbornik>)
- [8] HOLUBOVÁ Irena, KOSEK Jiří, MINAŘÍK Karel a NOVÁK David. *Big Data a NoSQL databáze*. Praha: Grada, 2015. Profesionál. ISBN 978-80-247-5466-6
- [9] The Digital Universe of Opportunities: *Rich Data and the Increasing Value of the Internet of Things*. IDC, 2014 [cit. 2018-03-18]. Dostupné na: <https://www.emc.com/leadership/digital-universe/2014iview/executive-summary.htm>)
- [10] Marr Bernard, *Why only one of the 5 Vs of big data really matters*, 2015, [cit. 18.3.2018] Dostupné na: <http://www.ibmbigdatahub.com/blog/why-only-one-5-vs-big-data-really-matters>

- [11] Schmarzo Bill, *What Universities Can Learn from Big Data – Higher Education Analytics*, 2014. [cit. 18.3.2018]. Dostupné na: https://infocus.dellemc.com/william_schmarzo/what-universities-can-learn-from-big-data-higher-education-analytics/
- [12] Daniel Ben, *Big Data and analytics in higher education: Opportunities and challenges*, 2014, [cit.18.3.2018] Dostupné na: <https://onlinelibrary.wiley.com/doi/full/10.1111/bjet.12230>
- [13] Briggs Saga, *Big Data in Education: Big Potential or Big Mistake?*, 2014, [cit. 18.3.2018]. Dostupné na: <https://www.opencolleges.edu.au/informed/features/big-data-big-potential-or-big-mistake/>
- [14] Herath Teju, *Big Data and Big Risks: Protecting Higher Education from Cyberattack*, 2017, [cit. 19.3.2018]. Dostupné na: https://evollution.com/technology/security_compliance/big-data-and-big-risks-protecting-higher-education-from-cyberattack/
- [15] Brdička Bořivoj, *Sú veľká dáta veľkým potenciálom alebo veľkou chybov?* 2014, [cit. 19.3.2018]. Dostupné na: <https://spomocnik.rvp.cz/clanek/18645/JSOU-VELKA-DATA-VELKYM-POTENCIALEM-NEBO-VELKOU-CHYBOU.html>
- [16] Traxlerová Petra, *Škandální odhalení v El Paso. Kam zmizeli žáci během zkoušek?*, 2013 [cit. 26.3.2018]. Dostupné na: <https://spomocnik.rvp.cz/clanek/17449/>
- [17] Šiškovič Matej, Játi Milan, *Čo skutočne merajú medzinárodné rebríčky vysokých škôl*, 2015, [cit. 26.3.2018], Dostupné na: <https://www.minedu.sk/data/att/7887.pdf>
- [18] Pietraš Petr, *Jak zlepšit' výuku? Také plošným shromažďováním dat.*, 2015, [cit.26.3.2018] Dostupné na: http://ceskapozice.lidovky.cz/jak-zlepsit-vyuku-take-plosnym-shromazdovanim-dat-f85-/recenze.aspx?c=A150317_103602_pozice-recenze_lub
- [19] Siemens G. 1st International Conference on Learning Analytics and Knowledge. *Connecting the technical, pedagogical, and social dimensions of learning analytics*, 2011, [cit. 28.3.2018] Dostupné na: <https://tekri.athabasca.ca/analytics/>
- [20] Mendez G, Ochoa X, Chiluíza K, de Wever B. *Curricular design analysis: a data-driven perspective. Journal of Learning Analytics*. 2014;1(3):84–119

- [21] Campbell JP, DeBlois PB, Oblinger DG. *Academic analytics. EDUCAUSE Review*. 2007;42(10):40–57
- [22] Tanes Z, Arnold KE, King AS, Remnet MA. *Using signals for appropriate feedback: perceptions and practices. Computers & Education*. 2011;57(4):2414–22
- [23] Mazza R. *Visualization in educational environments*. In: Romero C, Ventura S, Pechenizkiy M, Baker RSJD. editors. *Handbook of Educational Data Mining. 1st ed. Chapman & Hall/CRC Data Mining and Knowledge Discovery Series*, London. 2010. pp. 9–27
- [24] Siemens G, Gasevic D, Haythornthwaite C, Dawson S, Shum SB, Ferguson R, Duval E, Verbert K, Baker RS. *Open Learning Analytics: an integrated & modularized platform. Proposal to design, implement and evaluate an open platform to integrate heterogeneous learning analytics techniques*, 2011, [cit. 28.3.2018] Dostupné na: <http://classroom-aid.com/wp-content/uploads/2014/04/OpenLearningAnalytics.pdf>
- [25] prispievatelia Wikipédie. *Kurikulum. Wikipédia, Slobodná encyklopédia*; 2017, [cit. 4.4.2018]. Dostupné na: [//sk.wikipedia.org/w/index.php?title=Kurikulum&oldid=6516703](http://sk.wikipedia.org/w/index.php?title=Kurikulum&oldid=6516703).
- [26] Baker Nick, *How can higher education benefit from Big data*, 2017, [cit. 4.4.2018]. Dostupné na: <http://www.qs.com/how-can-higher-education-benefit-from-big-data/>
- [27] Short - Davis Heather, *School of Big Data: How Analytics Benefits Higher Education*, 2016, [cit. 4.4.2018]. Dostupné na: <https://www.linkedin.com/pulse/school-big-data-how-analytics-benefits-higher-heather-short-davis>
- [28] LUKÁŠOVÁ– KANTORKOVÁ, H. 2003. *Učiteľská profesie v primárnom vzdelávaní pedagogická príprava učiteľů (teorie, výzkum, praxe)*. Ostrava : PF OU, 2003.
- [29] Rijmenam van Mark, *Why the 3V's are not sufficient to describe Big Data*, 2017, [cit. 6.4.2018]. Dostupné na: <https://datafloq.com/read/3vs-sufficient-describe-big-data/166>
- [30] prispievatelia Wikipédie, *Systém na riadenie výučby, Wikipédia, Slobodná encyklopédia*, 2013, [cit. 10.4.2018] Dostupné na: https://sk.wikipedia.org/w/index.php?title=%C5%A0peci%C3%A1lne:Citova%C5%A5&page=Syst%C3%A9m_na_riadenie_v%C3%BDu%C4%8Dby&id=5349570
- [31] GYÁRFÁŠ, F. *E-learning vo vysokoškolskej realite*, 2007, [cit. 13.4.2018]. Dostupné na: http://www.vudu.exs.sk/Dokument/Elearning_vo_vysokoskolskej_realite.pdf

- [32] Rusinková Jana, *Využívanie e-learningu na Slovensku a v Spojených štátoch Amerických: 3.časť*, 2015, [cit. 13.8.2018]. Dostupné na: <https://ikaros.cz/vyuzivanie-e-learningu-na-slovensku-a-v-spojonych-statoch-americkyh-3-cast>
- [33] Grondžák Karol, *Nový modul v LMS Moodle*, 2007, [cit. 13.4.2018]. Dostupné na: http://itlib.cvtisr.sk/archiv/2007/3/novy-modul-v-lms-moodle.html?page_id=1368
- [34] Smart education in a smart city, MCRLab, [cit. 13.4.2018]. Dostupné na: <http://www.mcrlab.net/research/smart-education-in-a-smart-city/>
- [35] Dunagan Alana, *Higher ed outcomes, Lots of questions, few good answers*, 2018, [cit. 16.4.2018]. Dostupné na: https://www.christenseninstitute.org/blog/lots-of-questions-few-good-answers/?sft_topics=higher-education
- [36] TASR, *Počet študentov vysokých škôl medziročne klesol*, 2017, [cit. 20.4.2018]. Dostupné na: <http://www.teraz.sk/slovensko/pocet-studentov-vysokych-skol-medzirocne/283768-clanok.html>
- [37] Smida Jozef, *Príčiny študijnej neúspešnosti v 1. ročníku vysokoškolského štúdia*, 2005, [cit. 21.4.2018]. Dostupné na: http://web.uips.sk/download/vs/Priciny_neuspesnosti_2005.pdf
- [38] Dede Chris, Ho Andrew, *Big Data Analysis in Higher Education: Promises and Pitfalls*, 2016, [cit. 22.4.2018]. Dostupné na: <https://er.educause.edu/articles/2016/8/big-data-analysis-in-higher-education-promises-and-pitfalls>
- [39] IT slovník, *Dashboard*, , [cit. 23.4.2018]. Dostupné na: <https://it-slovník.cz/pojem/dashboard>
- [40] Brdlička Bořivoj, *Dohlížejí na vše stroje láskyplné milosti?*, 2011, [cit. 24.4.2018]. Dostupné na: <https://spomocnik.rvp.cz/clanek/12961/>