

BAKALÁRSKA PRÁCA

Business Intelligence: Spracovanie podnikových dát

Business Intelligence: Business data processing

ŠTUDIJNÝ PROGRAM

Ekonomika a management

VEDÚCI PRÁCE

doc. Ing. Kubálek Tomáš CSc.

PAĽOVÁ

KATARÍNA

2022

I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Pařová** Jméno: **Katarína** Osobní číslo: **484935**
Fakulta/ústav: **Masarykův ústav vyšších studií**
Zadávající katedra/ústav: **Institut manažerských studií**
Studijní program: **Ekonomika a management**

II. ÚDAJE K BAKALÁŘSKÉ PRÁCI

Název bakalářské práce:

Business Intelligence - Spracovanie podnikových dát

Název bakalářské práce anglicky:

Business Intelligence - Business Data Processing

Pokyny pro vypracování:

Bakalářská práce má teoreticko-praktický charakter. Hlavním cílem teoretické části je popsat' oblast' business intelligence. Následně v praktické části je cílem vypracovat' přehlednou analýzu dat univerzity třetího věku operující se o znalosti získané v teoretické části.
Definujte základní pojmy, prvky a principy spadající pod oblast' business intelligence a stručně popište její vznik a historii. Popište základní kroky implementace business intelligence řešení v podnicích.
Získejte, zpracujte a analyzujte data univerzity třetího věku s využitím Power BI, vytvořte přehlednou zprávu a navrhněte doporučení pro management univerzity na základě výsledků dané analýzy.

Seznam doporučené literatury:

NOVOTNÝ, Ota, Jan POUR a David SLÁNSKÝ. Business intelligence: jak využít bohatství ve vašich datech. Praha: Grada, 2005. Management v informační společnosti. ISBN 80-247-1094-3.
OLSZAK, Celina M. Business Intelligence and Big Data: Drivers of Organizational Success. Auerbach Publications, 2020. ISBN 978-0367373948.
OLSZAK, Celina a Ewa ZIEMBA. Approach to Building and Implementing Business Intelligence Systems. Interdisciplinary Journal of Information, Knowledge, and Management. 2007/01/13, 2, 135-148. Dostupné z: doi:10.28945/105
POWER, Daniel J. A Brief History of Decision Support Systems. DSSResources [online]. March 10, 2007 [cit. 2021-08-05]. Dostupné z: <http://DSSResources.COM/history/dsshistory.html>

Jméno a pracoviště vedoucí(ho) bakalářské práce:

doc. Ing. Tomáš Kubálek, CSc., institut manažerských studií MÚ

Jméno a pracoviště druhé(ho) vedoucí(ho) nebo konzultanta(ky) bakalářské práce:

Datum zadání bakalářské práce: **05.01.2022**

Termín odevzdání bakalářské práce: **28.04.2022**

Platnost zadání bakalářské práce: _____

doc. Ing. Tomáš Kubálek, CSc.
podpis vedoucí(ho) práce

Ing. Dagmar Skokanová, Ph.D.
podpis vedoucí(ho) ústavu/katedry

prof. PhDr. Vladimíra Dvořáková, CSc.
podpis děkana(ky)

III. PŘEVZETÍ ZADÁNÍ

Studentka bere na vědomí, že je povinna vypracovat bakalářskou práci samostatně, bez cizí pomoci, s výjimkou poskytnutých konzultací. Seznam použité literatury, jiných pramenů a jmen konzultantů je třeba uvést v bakalářské práci.

Datum převzetí zadání

Podpis studentky

PAĽOVÁ, Katarína. *Business Intelligence: Spracovanie podnikových dát*. Praha: ČVUT 2022. Bakalárska práca. České vysoké učení technické v Praze, Masarykův ústav vyšších studií.



**MASARYKŮV ÚSTAV
VYŠŠÍCH STUDIÍ
ČVUT V PRAZE**

Prehlásenie

Prehlasujem, že som svoju bakalársku prácu vypracovala samostatne. Ďalej prehlasuje, že som všetky použité zdroje správne a úplne citovala a uvádzam ich v priloženom zozname použitej literatúry.

Nemám závažný dôvod proti sprístupneniu tejto záverečnej práce v súlade so zákonom č. 121/2000 Sb. O práve autorskom o právach souvisejících s právem autorským a o změně některých zákonů (autorský zákon) v platnom znení.

V Prahe dňa:

Podpis:

Pod'akovanie

Rada by som sa poďakovala vedúcemu bakalárskej práce, doc. Ing. Tomášovi Kubálkovi CSc., za odborné vedenie mojej práce a pravidelné konzultácie, ktoré mi umožnili prácu dokončiť. Rovnako tak by som sa chcela poďakovať pánovi Kubálkovi a VŠE za poskytnutie dát k analýze, bez ktorých by táto práca nemohla vzniknúť.

Napokon by som sa rada poďakovala mojej rodine a priateľom, ktorí mi poskytli morálnu podporu pri písaní práce. Špeciálne poďakovanie patrí mojej prvej manažérke a mentorke Eve Šundrica, vďaka ktorej som mala možnosť sa vôbec o tejto téme dozvedieť a získať tak inšpiráciu pre tému mojej bakalárskej práce.

Abstrakt

Cieľom tejto práce je opísať oblasť business intelligence a ukázať jej prínos pre organizácie a podniky na príklade Univerzity tretieho veku na Vysoké škole ekonomickej v Prahe. Dáta boli zbierané priamo od univerzity a ich následné spracovanie a analýza bola vykonaná s využitím nástroja Power BI. Hlavným výstupom analýzy bolo zistenie, že univerzita má stabilnú študentskú základňu, ktorá jej pomohla zmierniť prepád v počte študentov v dôsledku pandémie COVID-19. Tiež ukázala, že súbor študentov nevykazoval v skúmanom období veľké výkyvy, čo sa týka demografických charakteristík. Výsledky analýzy vyvolali ďalšie otázky, predovšetkým ohľadom preferencií študentov v otázkach spôsobu výuky a ponuky predmetov. Získaním odpovedí na tieto otázky môže univerzita v budúcnosti vylepšiť svoju ponuku, čím posilní lojalitu svojich stávajúcich študentov a zároveň zatriktívni štúdiu pre nových študentov. Vytvorením dátového modelu a jeho následným využitím pre analýzu sme ukázali ako môžu organizácie pracovať so svojimi dátami a vyvodit z nich uchopiteľné odporúčania pre optimalizovanie ich fungovania či pre ich udržateľný rast.

Kľúčové slová

Business intelligence, dátový sklad, ETL, Power BI, dáta, znalosť, informácie, podpora rozhodovania, dashboard, vizualizácia, management, prijímanie rozhodnutí, OLAP, univerzita tretieho veku, vzdelávanie

Abstract

This work aims to describe the field of business intelligence and show its benefits for organizations and companies. Data from the University of the Third Age at the University of Economics in Prague will be used as a practical example. Data was collected directly from the university, and the subsequent processing and analysis of the data were performed using the Power BI tool. The main output of the analysis was the finding that the university has a stable student base, which helped mitigate the drop in the number of students due to the COVID-19 pandemic. It also showed that the sample of students did not show large fluctuations in demographic characteristics during the study period. The analysis results raised further questions, especially regarding students' preferences in regards to the delivery methods and course offering. By obtaining answers to these questions, the university can improve its offer in the future, thus strengthening the loyalty of its current students and at the same time making studies more attractive for new students. By creating a data model and leveraging it for subsequent analysis, we have shown how organizations can work with their data to derive tangible recommendations and optimize its functioning or support sustainable growth.

Keywords

Business intelligence, data warehouse, ETL, Power BI, data, knowledge, information, decision support, dashboard, visualization, management, decision making, OLAP, University of the Third Age, education

Obsah

ÚVOD	5
1 ZÁKLADY BUSINESS INTELLIGENCE	8
1.1 DEFINÍCIA BI.....	8
1.2 HISTÓRIA BI	10
1.3 ZÁKLADNÉ PRVKY A PRINCÍPY BI.....	11
1.3.1 Vrstva umožňujúca získavanie, transformáciu a nahrávanie dát	11
1.3.2 Vrstva slúžiaca na uskladnenie získaných dát.....	11
1.3.3 Analytická vrstva.....	13
1.3.4 Vrstva pre prezentáciu analyzovaných dát	14
1.3.5 Vrstva know-how	14
1.4 TRH RIEŠENÍ BI.....	14
2 IMPLEMENTÁCIA BI SYSTÉMOV	16
2.1 DÔVODY PRE IMPLEMENTÁCIU BI	16
2.1.1 Oblasti využitia BI.....	17
2.2 FÁZY IMPLEMENTÁCIE.....	18
2.2.1 Tvorba BI.....	18
2.2.2 Užívanie či „Konzumácia“ BI	19
3 APLIKÁCIA BI NÁSTROJOV V PRAXI	22
3.1 CIEĽ	22
3.1.1 Cieľ práce	22
3.1.2 Čiastkové ciele.....	22
3.2 CHARAKTERISTIKA VYBRANEJ ORGANIZÁCIE	22
3.3 IMPLEMENTÁCIA RIEŠENIA	23
3.3.1 Analýza požiadavku a problematika organizácie.....	23
3.3.2 Výber BI nástroja.....	24
3.3.3 Návrh a tvorba BI riešenia.....	24
3.4 VÝSLEDKY ANALÝZY	32
3.4.1 Vyhodnotenie súboru študentov	32
3.4.2 Vyhodnotenie obľúbenosti predmetov.....	34
3.4.3 Vyhodnotenie kohortovej analýzy.....	36
3.4.4 Dopad pandémie.....	38
3.4.5 Odporúčania pre manažment	41
ZÁVER.....	42
ZOZNAM POUŽITEJ LITERATÚRY.....	44
ZOZNAM OBRÁZKOV	48

Úvod

Dáta sú v dnešnej dobe všade okolo nás, denne o nás firmy získavajú stovky dát, či už pri platbe kartou v supermarkete, alebo pri prezeraní reklamy na internete. Výzva, ktorej firmy čelia však je, ako tieto dáta spracovať a ako vôbec z nich vyťažiť informácie, ktoré budú jednoducho prístupné, dostatočne detailné, k dispozícii v ten správny čas a budú odpovedať požadovanej kvalite. Dôležitosť mať takéto informácie k dispozícii plynie hlavne z toho, že väčšina firiem a organizácií rozhoduje o svojich ďalších krokoch práve na základe týchto informácií, a preto v prípade, že by nespĺňali jednu z uvedených podmienok by sa spoločnosť vystavila riziku, že sa rozhodne nesprávne. Na druhej strane v prípade, že firma dokáže prijať správne rozhodnutie, ktoré je podložené informáciami získanými práve z dát včas, môže spoločnosť získať konkurenčnú výhodu nad zvyškom firiem na trhu. Relatívne nová oblasť, stavajúca na manažérskych systémoch na podporu rozhodovania, ktorá sa tejto problematike venuje, sa nazýva Business Intelligence.

Práve aktuálnosť tejto témy a jej veľký potenciál do budúcnosti bol jednou z hlavných motivácií pre písanie tejto práce, keďže autorka si mohla na vlastných skúsenostiach v pracovnom živote vyskúšať ako zavedenie riešení BI môže pomôcť firme nie len pri strategickom plánovaní, ale aj pri každodenných operatívnych činnostiach.

Hlavným cieľom tejto práce je nazbieranie teoretických poznatkov o tejto problematike a následné aplikovanie týchto poznatkov na analýze reálnych dát nami vybranej organizácie. Samozrejme popri uvedenom hlavnom ciele existujú aj čiastkové ciele, ktoré nám umožnia vidieť pridanú hodnotu BI riešení a to hlavne čiastkový cieľ poskytnutia praktických odporúčaní na základe analýzy dát z vytvoreného dátového modelu. Vzhľadom k tomu, že univerzita v dôsledku pandémie COVID-19 čelila veľkému odlivu študentov, bude nezanedbateľnú časť práce tvoriť aj dôkladnejší pohľad na dáta pred a počas pandémie COVID-19, kde sme sa pokúšali o potvrdenie či vyvrátenie niekoľkých tvrdení. Osobný vedľajší cieľ autorky je rovnako spopularizovať verejne dostupné nástroje BI, konkrétne Power BI, a dokázať tak, že v prípade, že má niekto, či už firma alebo individuum záujem preniknúť do tejto problematiky, nie je to problém.

Práca je rozdelená na dve časti, teoretickú a praktickú časť. Teoretická časť je ďalej rozdelená na dve kapitoly a praktická časť je tvorená samostatnou kapitolou. Prvá kapitola sa venuje predovšetkým základným informáciám o problematike business intelligence, pričom druhá kapitola sa zameriava na otázku implementácie BI riešení v organizáciách. Posledná kapitola popisuje aplikáciu teoretických poznatkov z predošlých kapitol, konkrétne spôsob získavania a spracovania získaných dát prostredníctvom nástroja s názvom Power BI. Táto časť tiež prezentuje analýzu týchto dát, ktorá vznikla za využitia vytvoreného dátového modelu. Prácu ukončuje niekoľko

doporučení pre management univerzity, ktoré budú tvoriť hlavný prínos tejto bakalárskej práce.

TEORETICKÁ ČASŤ

1 Základy business intelligence

V prvej kapitole si odpovieme na fundamentálne otázky k problematike Business Intelligence(BI), ako napríklad: Čo to vlastne BI je ? alebo Kde má BI svoje korene ? Rovnako tak v tejto kapitole predstavíme architektúru BI, teda z akých vrstiev sa skladá, spolu s definíciami prvkov, ktoré do jednotlivých vrstiev radíme. K záveru kapitoly uvidíme kľúčových užívateľov BI a dôvody, pre ktoré firmy vôbec o zriadení BI riešení uvažujú.

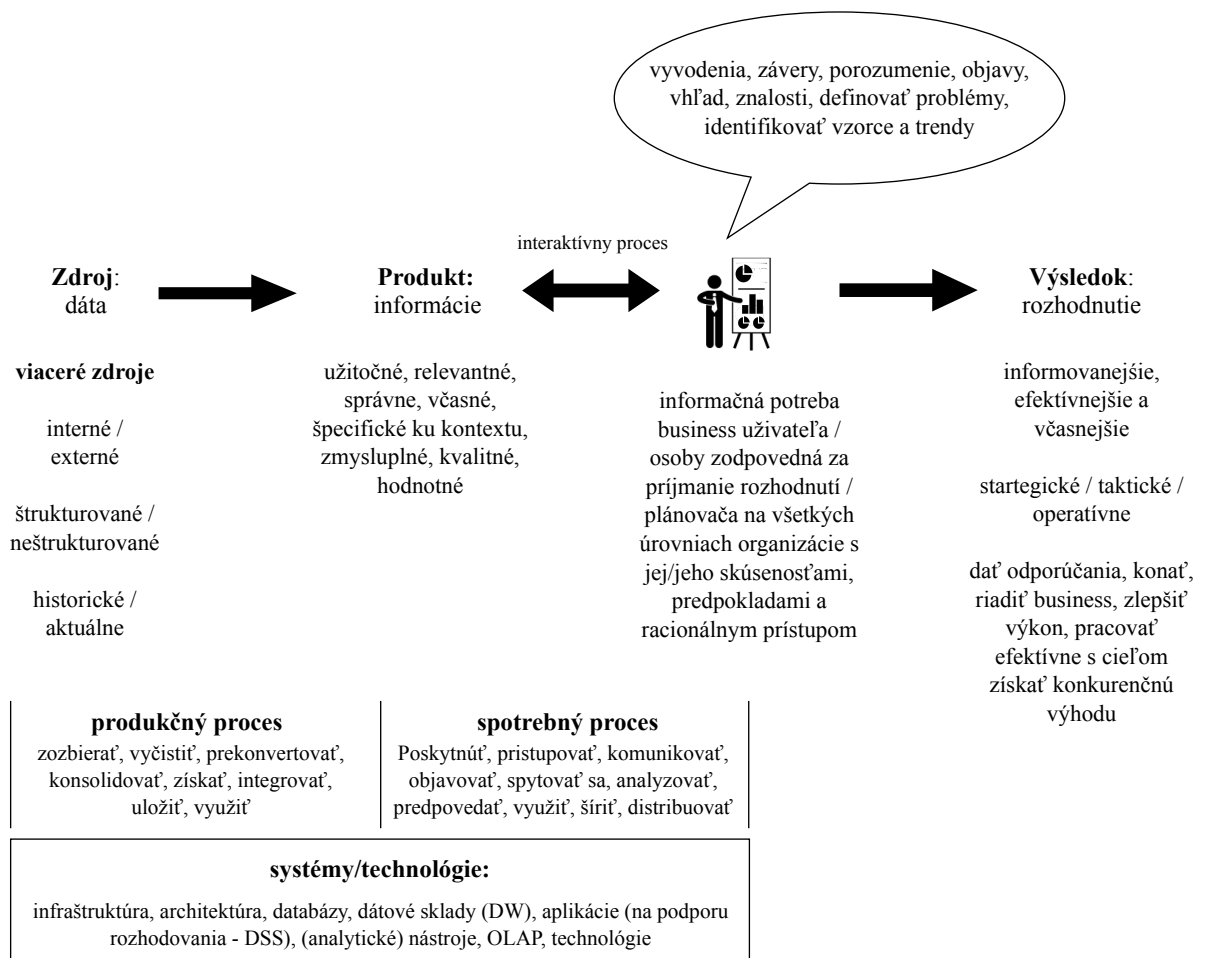
1.1 Definícia BI

Business intelligence je relatívne nový pojem, ktorý sa prvý krát vyskytol až v roku 1958 v článku Hansa Peter Luhna v časopise spoločnosti IBM [Tutunea a Rus, 2012]. Hoci v tejto publikácii nebol pojem definovaný ako jeden celok teda „business intelligence“, Luhn (1958) si dovoľil osobitne definovať pojem „business“ a „intelligence“. Slovo business definoval ako súbor aktivít v ľubovoľnej oblasti či už je to veda, obchod alebo vojenská obrana. Slovo intelligence vysvetlil pomocou definície zo slovníka Webster, kde „intelligence“ je definované ako schopnosť porozumieť vzťahom medzi prezentovanými faktami tak, aby viedli činnosti ktoré povedú k dosiahnutiu želaného cieľa [Woolf, 1981]. Bolo to až o 30 rokov neskôr, kedy sa dočkáme úplnej definície pojmu a to v podaní Howarda Dresnera, ktorý v roku 1989 popísal BI ako: „a set of concepts and methods to improve business decision making by using fact-based support systems“ [Power, 2007]. Čo by sme mohli voľne preložiť ako koncepty a metódy na vylepšenie business rozhodnutí založených na faktoch teda inak povedané na dátach.

Dnešná definícia tohto pojmu nie je ani zďaleka jednoznačná, žiadna štandardizovaná definícia totiž neexistuje [Novotný, Pour a Slanský, 2004]. Výskumníci v tejto oblasti pri svojich výskumoch totiž používajú definície, ktoré sa pozerajú na problematiku z rôznych uhlov pohľadu, a to tak, aby definícia čo najlepšie vyhovovala predmetu ich skúmania [Foley a Guillemette, 2010]. Vo všeobecnosti sa však v literatúre definície delia na dve skupiny, a to buď na tie manažérske orientované alebo technologicky orientované [Petrini a Pozzebon, 2004]. O zjednotenie týchto definícií sa pokúsili autori Shollo a Kautz (2010), ktorí vo svojom výskume analyzovali až 103 článkov z obdobia od 90. rokov až po rok 2010, aby prišli na to, čo to BI vlastne znamená a ako ho najlepšie zdefinovať. Došli k záveru, že každý autor definuje tento pojem inak, avšak niekoľko kľúčových slov ich spája, a to dáta, informácie, znalosti a rozhodnutia. Ako najdôležitejšie fázy identifikovali zber a úschovu dát, analýzu dát a informácií a ich využitie k prijímaniu rozhodnutí. Iný pohľad na problematiku prináša Pirrtimäki (2007), ktorý sa rovnako zaoberal tým čo to BI znamená a došiel k názoru, že novšie definície sa vo svojej podstate pridávajú tým starším až na to, že dnes ich ovplyvňuje rozvoj informačných technológií, ktoré rozšírili možnosti BI. Jeho záver bol, že na BI by sme sa

možno mali pozerat skôr ako na manažérsku filozofiu, ktorá môže fungovať vďaka technologickým riešeniam.

S týmto názorom sa zhoduje aj Ponelis a Britz (2012), ktorí sa vo svojom výskume, pokúšali o vytvorenie definičného rámca, ktorý by najlepšie zachytil podstatu BI. Ich výskum bol robený na vzorke 27 BI definícií v období od roku 2001 až 2011. Zaujímavé je, že skúmali definície od známych akademikov v tejto oblasti, ale rovnako tak aj od vývojárov BI softwaru či od ľudí z praxe, od čoho si slubovali zaistenie toho, že všetky pohľady na BI budú v ich navrhovanej definícii zastúpené. Aj preto budeme v tejto práci používať definičný rámec pochádzajúci z tejto štúdie.



Obrázok 1 Definičný rámec BI. [Ponelis a Britz, 2012]

Tento definičný rámec nekontradikuje ani jednej z vyššie spomenutých definícií, keďže vo svojej podstate ukazuje BI ako proces, ktorý podporuje rýchlejšie a informovanejšie prijímanie rozhodnutí na základe dát, ktoré boli prostredníctvom vhodných systémov a technológií transformované na informácie s ktorými môže manažér interaktívne pracovať.

V podkapitole 1.3 vysvetlíme niektoré z technologických pojmov z uvedeného definičného rámca.

1.2 História BI

Pojem BI bol v minulosti často zamieňaný aj s pojmi ako systém na podporu rozhodovania (DSS) či manažérsky informačný systém (MIS) [Thomsen, 2003]. Aj preto sa musíme pri skúmaní histórie BI pozrieť až do polovice 50. rokov kedy myšlienka využívania počítačov k uľahčeniu prijímania rozhodnutí vôbec vznikla. V tomto období sa tieto systémy využívali prevažne na opakované spracovanie dát, ktoré bolo napokon nahradené transakčným spracovaním dát a ich ukladaním [Ponelis a Britz, 2012]. V 70. rokoch rozvoj počítačových technológií a zníženie nákladov spojených s výrobou softwaru a hardwaru, umožnil vznik prvých manažérskych informačných systémov (MIS). Tieto systémy boli založené na princípe relačných databáz a umožňovali rôzne typy analýz či krátkodobých predpovedí [Olszak, 2020]. 80. roky priniesli prvý tabuľkový procesor, pre osobné počítače s názvom VisiCalc [Baker a Sugden, 2003] ale rovnako tak aj prvé systémy na podporu rozhodovania (DSS). Tieto systémy sa od MIS líšili hlavne tým, že fungovali na princípe modelov [Olszak, 2020], čo znamená, že systém dokáže vytvoriť matematický model, ktorý slúži k analýze predpokladaných dôsledkov určitého rozhodnutia či udalosti [Makowski, 1994]. Okrem vyššie spomínaného sa v 80. rokoch objavili aj prvé exekutívne informačné systémy (EIS), ktoré poskytovali dynamický a multidimenzionálny reporting, predpovede a mnoho ďalšieho [Turban et al., 2010]. V 90. rokoch sa EIS rozšírilo o nové technológie ako napríklad dátové sklady či OLAP [Power, 2007]. Práve opísané obdobie od začiatku 70. rokov až po začiatok 90. rokov by sme mohli považovať za éru BI 1.0 [Němec, 2012], ktorá sa vyznačovala prevažne štruktúrovanými dátami, ktoré boli často ukladané do relačných databáz (RDBMS) a analyzované s využitím metód pochádzajúcich zo 70. a 80. rokov ako napríklad data mining [Chen, Chiang a Storey, 2012].

Druhá generácia BI začala v 90. rokoch, a to definíciou tohto pojmu Howardom Dressnerom v roku 1989 [Němec, 2012]. Rok 1989 so sebou priniesol aj vznik internetu [W3C, 2021], ktorý je jednou z technológií, ktorá sa z BI 2.0 spája. Ďalšie z týchto technológií sú napríklad pokročilejšie dátové sklady či OLAP technológie [Olszak, 2020]. Hoci internet vznikol už v roku 1989, bolo to až v momente, kedy statické stránky na internete nahradil dynamický obsah založený na databázach, kedy sa aj BI začalo posúvať týmto smerom [Nelson, 2010].

Tretia generácia BI riešení a nástrojov je spájaná s pokrokmi v oblasti sieťových a mobilných zariadení [Chen, Chiang a Storey, 2012]. Rovnako tak sa BI 3.0 vyznačuje dôrazom na spoluprácu a jednoduchým prístupom k informáciám pre každého, kto má k nim oprávnenie. Takýto typ BI nazývame aj self-service BI [Němec, 2012].

Čo sa týka budúcnosti BI, výskum v tejto oblasti ide rýchlo napred. Ešte v článku z roku 2015 sa hovorí o cloudových BI riešeniach ako o budúcnosti Business Intelligence [Al-Aqrabi, 2015]. Dnes už sú však skutočnosťou, vďaka riešeniam ako napríklad Power BI Service od Microsoftu [Microsoft, 2021a].

O aktuálnych BI nástrojoch a riešeniach budeme bližšie informovať v podkapitole 1.4.

1.3 Základné prvky a princípy BI

V predchádzajúcich kapitolách sme si popísali čo si pod pojmom BI predstaviť ale aj z akých technológií vzniklo. Už pri definovaní sme spomenuli niektoré technické pojmy BI, no v tejto časti si ich rozdelíme do jednotlivých vrstiev BI architektúry a pozrieme sa bližšie na to, čo presne znamenajú. Rozdelenie jednotlivých prvkov je subjektívne a závisí od autora. V tejto práci budeme používať rozdelenie od autorov Novotný, Pour a Slanský (2004), ktorí kategorizovali prvky BI do nasledujúcich vrstiev.

1.3.1 Vrstva umožňujúca získavanie, transformáciu a nahrávanie dát

Táto vrstva v sebe zahŕňa dva dôležité typy systémov, a to ETL a EAI. Skratka ETL je zložená z troch slov a to extrakcia, transformácia a nahrávanie dát, pri čom skratka EAI označuje nástroje pre integráciu aplikácii [Novotný, Pour a Slanský, 2004].

ETL nástroje, u nás známe aj ako dátová pumpa [Novotný, Pour a Slanský, 2004], zabezpečujú tri základné funkcie. Extrakciu dát, pri ktorej sa dáta získavajú z rôznych zdrojov, od klasických databáz, textových súborov až po emaily. Transformácia získaných dát, je druhá a zároveň najkomplexnejšia funkcia ETL nástrojov. Počas tohto kroku sa všetky dáta musia zmeniť na jednotný formát a vyčistiť [Olszak, 2020]. Za čistenie považujeme proces pri ktorom sa pokúšame zvýšiť kvalitu dát prostredníctvom odstránenia nekonzistentných, nepresných či chýbajúcich hodnôt. Poslednou funkciou je nahrávanie dát do tabuliek dátového skladu, odkiaľ tieto dáta putujú do aplikácii či priamo k analytikom na ich analýzu [Vercellis, 2009].

EAI nástroje vznikli ako odpoveď na problém mnohých organizácií, ktoré si za roky svojej existencie vytvorili mnoho aplikácií na jedno použitie. Tieto aplikácie boli pre organizácie hodnotné, no fakt, že tieto aplikácie nevedeli využiť informácie z inej podobnej aplikácie ich hodnotu znižovala. Preto prišli nástroje EAI, ktoré vo svojej podstate umožňujú organizáciám zdieľanie dát a procesov bez nutnosti meniť už existujúce aplikácie či používané dátové štruktúry [Linthicum, 1999].

1.3.2 Vrstva slúžiaca na uskladnenie získaných dát

Druhá vrstva architektúry BI je venovaná priestorom pre ukladanie dát, kde sa počas poslednej fázy ETL nahrávajú extrahované a transformované dáta. Medzi tieto úložiská patria dočasné úložiská dát (DSA), operatívne úložiská dát (ODS), dátové sklady (DW) a dátové tržnice (DM) [Novotný, Pour a Slanský, 2004].

DSA (Data staging Areas) slúžia k uloženiu netransformovaných získaných dát po obmedzenú dobu. Nejedná sa o povinnú súčasť BI architektúry, ale sú užitočné v prípadoch, kedy chceme zo systémov presúvať dáta bez ovplyvnenia ich výkonu. Ale tiež nájdeme využitie u systémov, kde je potrebné dáta pretransformovať do databázového formátu predtým ako ich spracujeme [Novotný, Pour a Slanský, 2004].

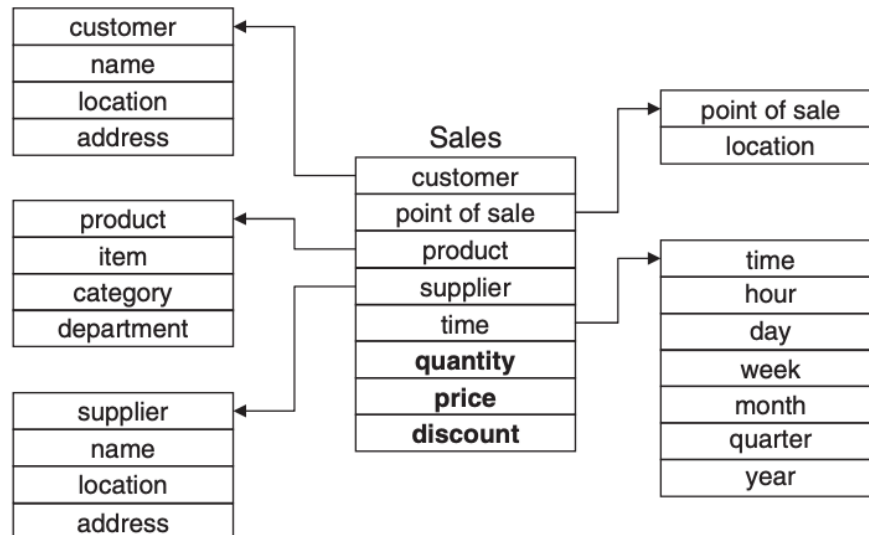
ODS (Operational Data Store) predstavujú typ databázy, ktorý sa využíva ako prechodné úložisko, predtým ako sa dáta uložia do dátového skladu. ODS by sme mohli prirovnávať ku krátkodobej pamäti na počítači, ktorej obsah sa operatívne mení [Thiesse, 2021].

DW (Data Warehouse) je podľa jedného zo zakladateľov tohto konceptu Billa Inmona (2005), súbor dát slúžiaci manažérom ako pomoc pri ich rozhodovacom procese. Medzi hlavné vlastnosti takéhoto dátového skladu patrí orientácia na hlavné subjekty v organizácii, ktorá sa odlišuje od klasických aplikácií, ktoré boli orientované na procesy. Druhou dôležitou vlastnosťou DW je ich integrovanosť, čo sa na uložených dátach prejavuje napríklad tým, že sa používa jednotné pomenovanie, jednotné premenné či rovnaké kódovanie. Ďalšou vlastnosťou je, že dáta v DW obsahujú časový údaj, táto vlastnosť vychádza z faktu, že DW obsahujú historické dáta a preto sa u nich vždy zaznamenáva aj informácia o čase, v ktorom sú dané informácie aktuálne. Poslednou vlastnosťou je stálosť dát v dátových skladoch, teda akonáhle sú dáta raz do DW uložené, mali by sa meniť jedine v prípade, pri nahrávaní v minulosti vznikla chyba.

DM (Data mart) by sme si mohli predstaviť ako malé dátové sklady, kde každé DM obsahuje dáta, ktoré sa viažu k nejakému konkrétnemu oddeleniu v organizácii napríklad marketing či financie [Olszak, 2020]. Hlavnou výhodou takýchto menších skladov je, že umožňujú rýchlejšiu návratnosť investícií a zníženie nákladov či rizík spojených z ich implementáciou [Novotný, Pour a Slanský, 2004].

Multidimenzionalita a dátové kocky. V tejto časti by bolo dobré si ozrejmiť aj princíp na ktorom sú DW a DM vystavané. DW a DM fungujú na multidimenzionálnej architektúre, vďaka ktorej sú schopné spracovať aj komplexné príkazy veľmi rýchlo. Vo vnútri samotného úložiska je táto architektúra väčšinou vystavaná v hviezdicovom formáte, ktorý obsahuje dva typy tabuliek, tie ktoré predstavujú dimenzie a tie ktoré obsahujú fakty. Tabuľka predstavujúca jednu dimenziu sa väčšinou viaže k objektu v organizácii okolo ktorej sa točí business, napríklad produkt, čas alebo poloha. Tieto tabuľky sú zväčša usporiadané hierarchicky. Ako príklady môžeme uviesť napríklad tabuľku času ktorá bude obsahovať stĺpce ako deň, mesiac a rok, či tabuľku polohy, ktorej záznamy budú rozdelené hierarchicky podľa ulice, smerovacieho čísla a krajiny. Vedľa dimenzionálnych tabuliek, v DW a DM nájdeme aj tzv. fact tables, ktoré najčastejšie obsahujú dáta pochádzajúce z transakcií. Buď sú to atribúty, ktoré umožňujú prepojenie s dimenzionálnou tabuľkou alebo jednotlivé hodnoty atribútov, ktoré sa neskôr pomocou OLAP príkazov analyzujú. Najlepšie pochopiteľné je to na príklade,

kde tabuľka obsahujúca informácie o jednotlivých predajoch bude predstavovať faktovú tabuľku, ktorá bude v sebe odkazovať na dimenzionálne tabuľky ako sú napríklad zákazníci, produkty alebo čas [Vercellis, 2009]. Ako ilustráciu uvádzame príklad jednoduchej hviezdicovej schémy.



Obrázok 2 Hviezdicové schéma [Vercellis, 2009]

1.3.3 Analytická vrstva

Do vrstvy analytických komponentov BI zaradujeme technológie ako OLAP databázy, dolovanie z dát (Data Mining) či reporting [Novotný, Pour a Slanský, 2004]. Tieto technológie umožňujú užívateľom analyzovať či modelovať problémy v organizácii a zdieľať informácie uložené v dátových skladoch [Olszak a Ziemba, 2007].

OLAP (Online Analytical Processing) je databázová technológia, ktorá je založená na princípe multidimensionalita, čo znamená že je zložená z tabuliek s viacerými dimenziami, ktoré sa dajú rýchlo meniť. Zmena týchto dimenzií umožňuje užívateľom pohľad na modelovanú realitu z viacerých uhlov [Novotný, Pour a Slanský, 2004].

Data Mining je opakujúci sa proces pri ktorom sa analyzujú veľké databázy s cieľom získať informácie či znalosti, ktoré by mohli byť užitočné v rámci procesu rozhodovania či riešenia problémov [Vercellis, 2009]. Dolovanie dát funguje na technikách s matematickým a štatistickým základom, ako napríklad rozhodovacie stromy, neurónové siete, genetické algoritmy či clustering [Novotný, Pour a Slanský, 2004].

Reporting je proces, ktorý umožňuje užívateľom prístup do systému v ktorom máme uložené dáta a vytvárať z nich vlastné reporty [Tripathi a Bagga, 2020]. Reporting obecné delíme na dva typy a to buď štandardný reporting, pri ktorom sú v pravidelných časových intervaloch spúšťané vopred pripravené dotazy (queries) alebo ad hoc

reporting, kedy sa užívateľ, väčšinou jednorazovo, dotazuje na databázu [Novotný, Pour a Slanský, 2004].

1.3.4 Vrstva pre prezentáciu analyzovaných dát

Jedná sa o vrstvu, ktorá zabezpečuje komunikáciu jednotlivých BI riešení s koncovými užívateľmi v organizácii. Do tejto vrstvy zaradíme portálové aplikácie založené na webovej technológii, EIS a iné aplikácie slúžiace na analýzu [Novotný, Pour a Slanský, 2004].

EIS (Executive information system) je nástroj, ktorý dokáže manažérom sprostredkovať on-line prístup k užitočným informáciám vo formáte, v ktorom sa ľahko orientuje. Sprostredkované informácie by mali byť manažérom v čas k dispozícii, mali by byť presné a mali by ponúknuť také informácie na základe, ktorých bude môcť vrcholový management podniknúť konkrétne kroky [Kelly, 1994]. Ako je z tejto vyššie spomenutej definície zjavné, EIS boli pôvodne určené predovšetkým pre vrcholový management, dnes už je však tento typ aplikácií viac orientovaný k strednému či nižšiemu managementu. Narozdiel od reportingových aplikácií, EIS nepristupujú priamo do dátového skladu ale vytvárajú si mnohodimenzionálnu sémantickú vrstvu, ktorá umožňuje používateľom prístup k dátam [Novotný, Pour a Slanský, 2004].

1.3.5 Vrstva know-how


Vrstva znalostí z danej sféry, ktorá sa prispôsobuje podľa situácie v danej spoločnosti, kde je BI implementované. Táto vrstva je nevyhnutnou súčasťou BI a predstavuje kombináciu znalosti toho čo BI technológie dokážu, aké BI riešenia sú najvhodnejšie v danom obore a znalosť toho ako funguje prostredie, v ktorom má byť BI implementované [Novotný, Pour a Slanský, 2004].

1.4 Trh riešení BI

V roku 2019 dosahoval trh s BI nástrojmi a analytickým softwarom veľkosť 14 908 miliónov USD. Predpokladá sa že do roku 2024 tento trh narastie až o 18% a dosiahne veľkosť 17 600 miliónov USD [Statista, 2020]. V tejto podkapitole si predstavíme niektoré z týchto nástrojov a s funkciami, ktorými disponujú.

Spoločnosť Gartner, ktorej zamestnanec Howard Dressner ako prvý definoval celý pojem BI [Ponelis a Britz, 2012], každoročne vyhodnocuje tzv. „Magic quadrant“, kde umiestňuje jednotlivých poskytovateľov BI riešení na trhu v závislosti od ich vízie a od ich schopnosti prinášať výsledky. V rámci vízie hodnotí aspekty ako napríklad dokáže poskytovateľ pochopiť potreby zákazníka, aká je jeho marketingová či produktová stratégia a mnoho iného. V kategórie schopnosti prinášania výsledkov sa Gartner

pozerá na aspekty ako kvalita či funkcie daných riešení, finančné zdravie spoločnosti či zákaznícka podpora [Gartner, 2019]. Poskytovateľov softwaru ďalej rozdeľuje do štyroch kvadrantov, a to na lídrov, vizionárov, niche hráčov a tzv. challengers. Medzi lídrov roku 2021 sa zaradili spoločnosti ako Microsoft, Tableau či Qlik (Obr. 3).



Obrázok 3 "Magic Quadrant" pre BI a Analytické platformy [Climber, 2021]

Základom pri výbere správneho BI nástroja je, aby si spoločnosť uvedomila, ktoré vlastnosti od daného nástroja vlastne očakáva, aký náročný je na používanie, akú podporu pre užívateľov poskytuje, ako rieši bezpečnostné otázky a napokon, aká je cena daného nástroja. Potrebuje organizácia základné funkcie alebo potrebuje pokročilé funkcie, ktoré nájdeme len u malej časti nástrojov? Podľa výskumu autorov Pribisalić, Jugo a Ipšić z roku 2019, ktorí analyzovali podrobne až 20 rôznych BI nástrojov dostupných na trhu, viac ako 90% riešení na trhu obsahuje základné funkcie ako dátová analýza, ad-hoc analýza, dashboardy, ad-hoc reporty, KPI, výkonnostné metriky a ad-hoc dopytovacie (query) nástroje. V tejto práci budeme používať riešenie od Microsoftu s názvom Power BI, ktoré podľa spomínaného výskumu patrilo

k nástrojom, ktoré obsahovali najviac funkcií, či už základných ale aj pokročilých. Jediná funkcionálna ktorá absentovala bol tzv. Edge Computing a NLP (Natural language processing), kde edge computing znamená to, že sa dáta spracúvajú priamo na zariadení alebo v jeho blízkosti [Krishnasamy, Varrette a Mucciardi, 2020] NLP je zase vlastnosť, ktorá umožňuje užívateľom komunikovať s daným nástrojom v hovorenej alebo textovej forme, bez toho aby ju museli prevádzať do reči, ktorej rozumie počítač [IBM, 2020]. Druhú spomínanú funkciu už dnes Power BI poskytuje a to vo forme tzv. Q&A, kde má užívateľ možnosť opýtať sa otázku v textovej forme a Power BI sa pokúsi nájsť odpoveď [Microsoft, 2021b].

2 Implementácia BI systémov

V prvej kapitole sme sa zoznámili so základnými informáciami o BI vrátane definície tohto pojmu. Rovnako tak sme si prešli históriou tejto oblasti, zosumarizovali sme aké prvky si môžeme pod týmto pojmom predstaviť a pozreli sme sa na to aké riešenia momentálne trh ponúka. V druhej kapitole sa bližšie pozrieme na implementačnú časť. V prvom rade identifikujeme aké sú vôbec dôvody spoločností pre implementáciu BI, v akých oblastiach môže BI nájsť svoje uplatnenie a kapitolu zakončíme predstavením jednotlivých fáz implementácie BI systémov.

2.1 Dôvody pre implementáciu BI

V roku 2021 firmy v priemere utratili za BI riešenia 5.9 EUR/zamestnanec, v porovnaní s rokom 2016 kedy to bolo len 4.50 EUR/zamestnanec, čo predstavuje nárast o viac ako 31 % za posledných 5 rokov [Statista, n.d.]. Preto sa teraz pozrieme na to, prečo sú firmy ochotné takúto čiastku do BI investovať.

Hlavným cieľom BI je vylepšovanie kvality informácií a zrýchlenie ich dostupnosti pre širokú škálu užívateľov. Vzhľadom k tomu, že informácie sú často považované za druhý najdôležitejší zdroj firmy hneď po svojich zamestnancoch, môže firmám implementácia BI zvýšiť ich výkonnosť. Za týmto zvýšením výkonnosti môže byť napríklad fakt, že BI urýchľuje prijímanie rozhodnutí, čo firme umožňuje reagovať na informácie rýchlejšie ako konkurencia. Na druhej strane môže zavedenie BI viesť k lepšiemu zákazníckemu servisu, vďaka rýchlejšej a vhodnejšej odpovedi na ich problémy [Ranjan, 2009].

Medzi prípady firiem, ktorým sa podarilo vyťažiť maximálny potenciál z BI patrí napríklad spoločnosť Western Digital, ktorá sa zaoberá výrobou pevných diskov. BI využila k lepšiemu riadeniu zásob, zásobovania, produktového cyklu a zákazníckych vzťahov, vďaka čomu sa jej podarilo znížiť prevádzkové náklady až na polovicu [Williams a Williams, 2007].

2.1.1 Oblasti využitia BI

Pre lepšiu predstavu toho, na aké otázky môžu firmy nájsť odpovede prostredníctvom BI si uvedieme hlavné aplikačné oblasti BI.

Prvou oblasťou, kde si BI nájde uplatnenie sú financie, ktoré disponujú veľkým množstvom historických dát o rozpočtoch, prognózach, tržbách, nákladoch či zisku. Rovnako tak informácie o faktúrach, nákupoch, nákladoch spojených s kvalitatívnymi problémami atď. Skúmanie týchto dát s využitím BI technológií môže viesť napríklad k zlepšeniu kvality rozpočtov a prognóz, identifikácii nákladov, ktoré by bolo možné znížiť zmenou dodávateľa, či odstránením problémov s kvalitou produktov [Williams a Williams, 2007].

Ďalšou oblasťou je dozaista marketing, ktorý je dnes podporovaný hlavne aplikáciami tzv. Customer Intelligence¹. Stále však existujú aj dedikované BI aplikácie zamerané iba na podporu marketingu. V tejto oblasti sa BI využíva napríklad pri analýze portfólia produktov a služieb, čo umožňuje analyzovať ziskovosť a nákladovosť týchto produktov, potenciál týchto produktov v rôznych zákazníckych segmentoch alebo vzťah zákazníkov k výrobkom konkurencie. Ďalej sa BI využíva pri tvorbe zákazníckych segmentov, správe marketingových kampaní a iných marketingových činnostiach [Novotný, Pour a Slanský, 2004].

Tretou oblasťou využitia BI je tzv. supply chain management. Autori Novotný, Pour a Slanský (2004) túto kategóriu rozdelili na oblasti výroby, logistiky a riadenia vzťahu s dodávateľmi, čo môžeme podľa Michigan State University (2020) zaradiť práve pod pojem supply chain management hoci ho sami autori nepoužili. Preto sa pozrieme na túto oblasť ako celok. V tejto oblasti sa stretne napríklad s dátami o zásobách, objednávkach, dodávateľoch, kapacite výroby, odstávkach strojov atď. S využitím BI môžu organizácie optimalizovať výkon a zásobovanie, získať informácie o vadách pri výrobe či dodávkach, zaviesť preventívne opatrenia k zníženiu odstávok strojov a ďalšie [Williams a Williams, 2007].

Poslednou oblasťou, ktorú spomenieme sú ľudské zdroje, kde sa BI využíva hlavne na analýzu pracovnej sily podľa rôznych ukazovateľov, ako vzdelanie či skúsenosti, analýzu nákladov spojených s touto pracovnou silou ale rovnako je využívané aj pri výbere či motivácii zamestnancov [Novotný, Pour a Slanský, 2004].

¹ Súbor aplikácií, ktorých hlavným cieľom je poznávanie zákazníka, jeho hodnoty, preferencií ale aj identifikácia rizika či pravdepodobnosti, že zákazník prejde ku konkurencii [Novotný, Pour a Slanský, 2004].

2.2 Fázy Implementácie

Stavbu BI systémov a riešení by sme mohli rozdeliť do dvoch veľkých iteratívnych častí, a to na tvorbu BI a jeho užívanie. Dôležitá je práve iteratívna povaha prezentovaného implementačného cyklu. Čo znamená že je nevyhnutné aby aj po zavedení daného systému boli kontinuálne analyzované informačné potreby podniku, prehodnocované existujúce riešenia a uvažovalo sa nad ich možnými zmenami či vylepšeniami [Olszak a Zemba, 2007].

2.2.1 Tvorba BI

Tvorba BI je časť, ktorá si vyžaduje počas životného cyklu BI najväčšie množstvo pracovnej sily a finančných prostriedkov. Rovnako tak sa jedná o tú časovo najnáročnejšiu fázu [Olszak a Zemba, 2007].

Stratégia vývoja BI systému

Ako prvý krok je dôležité aby si firma ujasnila celkovú víziu a to, prečo chce vlastne systém BI implementovať. Inak povedané, aké benefity od tejto implementácie očakáva ale rovnako tak aj limitácie či skutočnosti, ktoré by mohli využívanie týchto nástrojov ohroziť. V tejto fáze musí organizácia tiež identifikovať aké sú jej informačné potreby či to, kto bude v budúcnosti BI riešenie využívať [Olszak, 2020]. Pri tomto kroku je dôležité aby sa organizácia rozhodla aj o tom či bude BI implementovať iba na jednom oddelení alebo sa bude jednať o komplexný systém, ktorý bude využívaný pri viacerých aktivitách organizácie. Toto rozhodnutie bude mať dopad napríklad pri rozhodovaní, či sa firma rozhodne budovať DM pre jednotlivé oddelenia alebo zvolí prístup vytvorenia integrovaného DW, ktorý bude slúžiť naprieč všetkými oddeleniami. Obidva prístupy majú svoje pre a proti. Prvá možnosť, využitie dátových trhov (DM), je považovaná za menej náročný projekt s rýchlejšími výsledkami. Tento prístup však so sebou prináša riziko, že sa môže firma neskôr stretnúť s problémami pri snahe spojiť spomínané DM do jedného integrovaného dátového skladu (DW). Vo všeobecnosti sa počas tejto fázy nedívame na to aké zdroje dát máme k dispozícii ale skôr na to, čo firma potrebuje [Olszak a Zemba, 2007].

Identifikácia a príprava dát

V druhom kroku je nutné identifikovať relevantné dáta, ktoré budú analyzované v BI systémoch. Tieto dáta môžu pochádzať z rôznych zdrojov, či už sú to interné zdroje firmy alebo externé zdroje od zákazníkov a dodávateľov. V prípade, že sa počas tohto kroku stane, že spoločnosť zistí, že množstvo údajov, ktoré potrebuje nie sú dostupné, môže sa pokúsiť o ich získanie z internetových zdrojov. Po identifikácii sa odporúča overiť si, či sú získané dáta spoľahlivé, aktuálne, presné a konzistentné, ale tiež aj zistiť či budú dáta v BI systéme pribúdať systematicky, s minimálnym omeškaním alebo

periodicky. Nakoniec netreba zabudnúť na to pripraviť transformáciu, ktorá bude využitá k spracovaniu dát predtým ako sa budú ďalej analyzovať [Olszak a Zemba, 2007].

Výber konkrétneho BI riešenia

Tretí krok pozostáva z výberu tých správnych BI nástrojov pre konkrétnu organizáciu. Organizácia by mala zvážiť hlavne nasledujúce kritéria pri výbere BI riešenia: funkcionality, komplexitu či kompatibilitu. Nemala by však zabudnúť na to, že potreby firiem, čo sa informácii týka, sa budú časom vyvíjať, a preto je nutné aby nástroje napĺňali firemné očakávania aj niekoľko rokov po ich implementácii [Olszak a Zemba, 2007]. Prehľad niekoľkých BI nástrojov a ich funkcií sme uviedli na konci prvej kapitoly.

Design a implementácia BI systému

Časová náročnosť tejto etapy je závislá hlavne na komplexite žiadaného systému, ale aj toho koľko užívateľov bude dané riešenie užívať. Počas tejto etapy sa nenavrhuje len samotná personalizovaná aplikácia, ale rovnako aj dátové sklady (DW), dátové trhy (DM), reporty, dashboardy a užívateľské rozhranie [Olszak, 2020]. Pri tvorbe dátového skladu netreba zabudnúť aj na vytvorenie mechanizmu na nahrávanie dát, ktorý by mal užívateľom umožniť nahrávať dáta prírastkovým spôsobom, teda vždy len dáta, ktoré v sklade predtým nahrané neboli. Vytvorený dátový sklad bude slúžiť ako hlavný podklad pre reporting. Nakoniec je potrebné venovať dostatok času vytvoreniu rozhrania pre užívateľov, keďže práve vrstva pre prezentáciu dát je veľmi dôležitým prvkom BI systémov [Olszak a Zemba, 2007].

Identifikácia novo vzniknutých informačných požiadaviek

BI systém vytvorený v predošlom kroku ponúka nový pohľad na informácie, kompetencie v organizácii či na obchodné vzťahy a to ako spolu súvisia. Tento fakt má za následok, že počas tejto fázy vzniká nový spôsob riadenia informácii. Zároveň tak organizácie zistia aké nové informácie potrebujú do systému ešte pridať. Objavenie informačných potrieb organizácie, by mali tvoriť základ pre zhodnotenie súčasného riešenia, možností jeho vylepšenia a budúcich zmien tohto systému [Olszak, 2020].

2.2.2 Užívanie či „Konzumácia“ BI

Po dlhej fáze konštrukcie celého BI ekosystému v organizácii, je na čase začať tento systém využívať. Užívatelia zohrávajú kľúčovú rolu práve v tejto časti, pretože BI systémy budú v organizácii úspešné len za určitých podmienok. Je nevyhnutné aby sa užívatelia venovali identifikácii znalostí a ich následnej implementácii pri modelovaní. Ďalej musia sledovať a prípadne upravovať vytvorené dátové úložiská. Samozrejme sa musia podieľať pri tvorbe vlastných analýz či reportov, a naučiť sa ako ich správne interpretovať a ako sa pýtať tie správne otázky. Nakoniec by mali dospieť k naplneniu

samotného cieľa BI, a to k pravidelnému zlepšovaniu spôsobu akým sa v organizácii prijímajú rozhodnutia.

Týmto sa avšak proces nekončí, keďže ako sme uvideli na začiatku tento proces je iteratívny a teda by sa mal opakovať na pravidelnej báze [Olszak a Zemba, 2007].

PRAKTICKÁ ČASŤ

3 Aplikácia BI nástrojov v praxi

V tejto časti práce sa budeme venovať praktickému využitiu poznatkov získaných v teoretickej časti práce formou vytvorenia dátového modelu s využitím nástroja BI. Tiež pripomenieme cieľ práce a s ním súvisiace čiastkové ciele. Následne opíšeme postup akým dátový model vznikol a ako bol využitý k analýze a k napĺňaniu týchto vopred vytýčených cieľov.

3.1 Cieľ

V nasledujúcich podkapitolách zopakujeme hlavný cieľ práce deklarovaný v úvode, a ďalej ho rozvetvíme do čiastkových cieľov, ktoré umožňujú naplnenie hlavného cieľa.

3.1.1 Cieľ práce

Ako hlavný cieľ bakalárskej práce sme si zadefinovali opísať oblasť business intelligence a ukázať jej prínos pre organizácie a podniky. Konkrétne sme sa venovali sfére školstva a to Univerzite tretieho veku na Vysokej škole ekonomickej v Prahe v období rokov 2006 - 2021.

3.1.2 Čiastkové ciele

Čiastkové ciele vyplývajúce z hlavného cieľa sú nasledovné:

1. štúdium dostupnej literatúry k danej problematike umožňujúce vypracovanie teoretickej časti práce,
2. identifikácia dostupných dát organizácie a ich následné získanie,
3. spracovanie získaných dát do formy ucelenej zostavy v Power BI,
4. vyhodnotenie zistených skutočností a následné vyvodenie odporúčaní pre management univerzity.

3.2 Charakteristika vybranej organizácie

Budeme sa zaoberať akademickou organizáciou, Vysokou školou ekonomicou v Prahe (VŠE), konkrétne Univerzitou tretieho veku (U3V). V Českej Republike sa VŠE považuje za najväčšiu verejnú vysokú školu ekonomickú s pomerne dlhou tradíciou, keďže vznikla už v roku 1953, a dnes sa pýši až šiestimi fakultami [Vysoká škola ekonomická v Praze, 2021].

U3V ako program celoživotného vzdelávania umožňuje každý semester ľuďom v dôchodkovom veku navštevovať okolo 80 predmetov po dobu 13 týždňov [Kubálek, 2018]. Jedná sa o symbolicky spoplatnené štúdium, pri čom študenti nezískavajú nakonci štúdia známky ale len informáciu o tom, či získali zápočet alebo nie. Zápočet je udelený na základe dochádzky, ktorá musí byť aspoň 60 % z prvých 10 týždňov výuky. Až do vypuknutia pandémie COVID-19 prebiehala výuka čiste prezenčnou formou, avšak v priebehu pandémie ponúkla univerzita študentom možnosť navštevovať hodiny online. Dnes už dokonca ponúka množstvo svojich kurzov aj formou hybridnej výuky.

3.3 Implementácia riešenia

Postup implementácie sa bude približne pridržovať krokov opísaných v kapitole 2.2, ale s niektorými modifikáciami, ktoré bolo nutné urobiť z dôvodu, že v našom prípade sa nejedná o tvorbu firemného BI systému ale o ukážku ako už existujúce BI nástroje môžu slúžiť firmám či organizáciám k vyťaženiu maximálneho potenciálu z ich existujúcich dát.

Hlavnou zmenou bude nahradenie kroku *návrh stratégie* za *analýzu požiadavku a problematiky organizácie* vzhľadom k tomu, že budeme BI nástroje využívať k analýze časti dát organizácie a nevytvárať systém určený pre dlhodobý BI reporting.

3.3.1 Analýza požiadavku a problematika organizácie

Dátový model z dát U3V už bol v minulosti v Power BI vytvorený, bolo tomu však predovšetkým pre potrebu školení o nástroji Power BI. Vzhľadom k tomu, že slúžil hlavne pre potreby školenia, nebol tento model úplne komplexný a neprepájal jednotlivé dátové zdroje. Tento model sa venoval dátam prevažne izolovaným spôsobom, to znamená, že sa napríklad pozeral samostatne na študentov a samostatne na rozloženie predmetov. Toto bolo spôsobené predovšetkým skutočnosťou, že škola nedisponuje jednou tabuľkou, kde by boli súčasne zobrazené podrobné dáta o študentoch, o tom aké predmety majú zapísané a ešte aj detaily o týchto predmetoch. Rovnako tak tento model sledoval kratšie časové obdobie, nie tak ako je tomu v našom prípade.

Z týchto skutočností plynuli aj hlavné motivácie pre vytvorenie dátového modelu prezentovaného v praktickej časti tejto práce. A to prepojiť všetky dostupné informácie o študentoch a ich predmetoch, obohatiť ich o nové detaily tam, kde to je možné. a sledovať ako sa situácia vyvíjala v dlhšom časovom horizonte. Samozrejme v dôsledku výskytu pandémie vznikla aj nová motivácia, a to pozrieť sa na to, či nám dáta umožnia sledovať posun v správaní študentov v dôsledku pandémie COVID-19. Všetky tieto motivácie samozrejme smerujú k tomu priniesť organizácii nový pohľad

na jej už existujúce dáta a ukázať ich možný prínos, čo je nakoniec aj hlavným cieľom tejto práce a požiadavkou, ktorú sa budeme snažiť v tejto práci vyriešiť.

3.3.2 Výber BI nástroja

Tak ako bolo uvedené v časti 1.4, ponuka BI nástrojov je veľmi široká a výber vhodného riešenia závisí vo veľkej miere na firemných požiadavkách. Pre túto prácu budeme používať nástroj od spoločnosti Microsoft s názvom Power BI, a to hneď s niekoľkými dôvodmi. V prvom rade tento nástroj disponuje širokou škálou základných ale aj pokročilých funkcií. No čo je možno ešte dôležitejšie je, že je ľahko prístupný vzhľadom k tomu, že jeho desktopová verzia je dostupná zadarmo [Microsoft, 2022a]. Navyše balík služieb Microsoft Office 365 mal v máji 2021 najvyšší podiel na trhu s kancelárskym softwarom pre zvýšenie produktivity, až 47,5 % [Statista, 2021]. Teda môžeme predpokladať, že Power BI je jedným z najpoužívanejších BI nástrojov v organizáciách. Nezanedbateľným dôvodom je aj fakt, že naša skúmaná organizácia využíva skupinu produktov od Microsoftu a v minulosti už analyzovala dáta s využitím Power BI, čo prispelo k výberu práve tohto riešenia.

3.3.3 Návrh a tvorba BI riešenia

Získavanie dát

Vo všeobecnosti dáta pre náš model pochádzajú zo školskej databázy VŠE, z webových stránok VŠE alebo z diskusií s akademickým riaditeľom programu, Tomášom Kubálkom. V prvom prípade sme dáta získavali dvoma spôsobmi:

- sťahovaním zo školského systému InSIS
- vyžiadanim skrytých dát z InSISu, vďaka exportu od databázového administrátora VŠE

Priamym stiahnutím z databázy, bolo možné získať demografické dáta o študentoch a semester, v ktorom boli zapísaní. Pri sťahovaní sme stiahli najdetailnejší pohľad no aj napriek tomu sme sa stretli s problémom, že niektorí študenti nemali uvedené všetky informácie, napríklad dátum narodenia. Tento fakt a ďalšie limitácie budú opísané nižšie. Od administrátora sme následne čerpali dáta o zapísaných predmetoch, pri čom integrujúcim údajom medzi vyššie uvedenými zdrojmi dát bol identifikátor študenta, ktorý nám umožnil tieto dáta prepojiť, a tým ponúknuť obohatený pohľad na tieto dáta.

Z ostatných zdrojov boli čerpané doplňujúce informácie o predmetoch či o kontexte v akom celý program prebieha.

Dôležité je spomenúť aj limitácie dát, hlavne čo sa týka ich neúplnosti. V súbore študentov evidujeme 5,13% nevyplnených miest bydliska, čo činí 194 študentov z 3 781 študentov. U dátumu narodenia je to asi 0,5% z celkového súboru. Tiež je dôležité spomenúť, že kategorizovanie predmetov nie je stopercentné, keďže predmety si naprieč ročníkmi nezachovávajú jednoznačné identifikátory. Vzhľadom k tomu, že prechádzanie všetkých predmetov a ich charakterizovanie by pri veľkosti súboru nebolo možné, bolo zavedené kategorizovanie na základe identu predmetu. Nanešťastie toto delenie nie je stopercentné a môžu nastať prípady, kedy predmet s identom patriacim do skupiny telovýchovných predmetov bude v skutočnosti výtvarným predmetom. Táto situácia by mala však nastať iba v ojedinelých prípadoch, takže sme sa rozhodli túto aj predchádzajúce limitácie prijať.

Nahrávanie a úprava dát

Power BI, konkrétnejšie nástroj Power Query, umožňuje desiatky možností nahrávania súborov a ich následných úprav. Nahratie jednoduchého Excelu, nahranie celej zložky až po napojenie sa na rôzne typy databáz [Microsoft, 2022b]. Pre prípady vytvárania pomocných tabuliek, napr. dátumovej dimenzionálnej tabuľky je možno využiť aj tzv. blank query. Kde s využitím funkcií vytvoríte dátumovú tabuľku bez existujúceho zdroju dát ale ju môžete vytvoriť po jednotlivých stĺpcoch, riadkoch a hodnotách. V našom prípade budeme používať kombináciu týchto dvoch prístupov, pri čom pre tabuľky *Študenti* a *Študenti_predmety* použijeme metódu načítania dát zo zložky, u tabuľky *Dátum* zase použijeme funkcie k naplneniu tabuľky podľa požadovaného časového rozmedzia. U ostatných tabuliek sa jedná, buď o odvodené tabuľky z predchádzajúcich tabuliek, alebo o tabuľky vytvorené vo vnútri Power BI bez externého zdroju, napr. tabuľka *Tituly*.

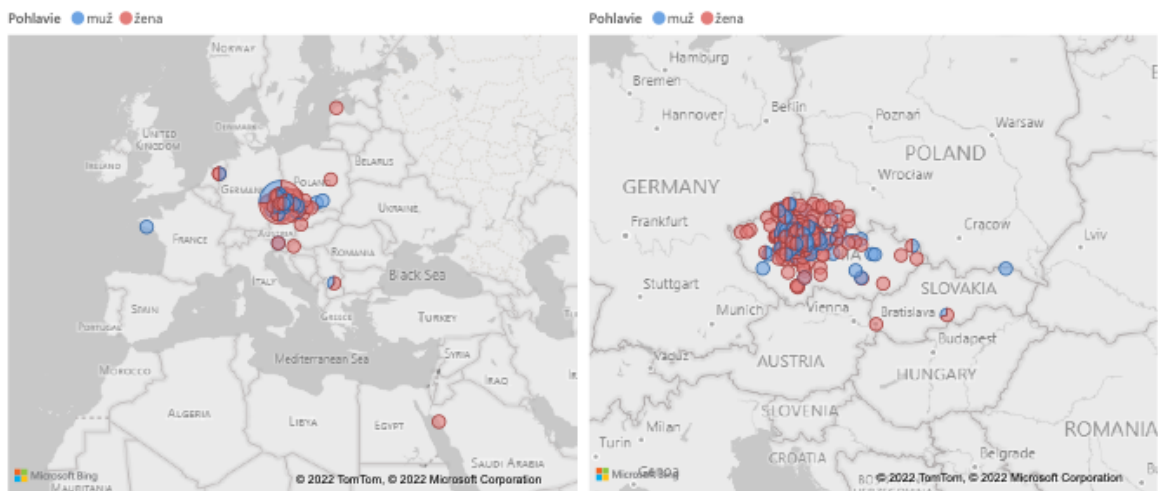
Po nahratí dát prichádza čas na úprava dát. Vzhľadom k tomu, že celý proces úpravy dát je pomerne komplexný a obsahuje množstvo krokov, ktoré nie sú priamo relevantné k analýze, si dovoľíme stručne opísať každú tabuľku a spomenúť len úpravy dát, ktoré boli kľúčové pri analýze či pri tvorbe jednotlivých grafov.

Tabuľka *Študenti*

Tabuľka *Študenti* obsahuje exporty zoznamov študentov po jednotlivých semestroch. Každý študent má pridelené unikátne ID, ktoré slúži ako primárny kľúč v tabuľke, inak povedané jedinečný identifikátor, ktorý nám umožní prepojenie s ostatnými tabuľkami. Vzhľadom k tomu, že študent, ktorý študoval na U3V niekoľko semestrov by sa takto v tabuľke nachádzal niekoľkokrát, to však nie je žiadúce. Preto boli dáta zoradené tak, aby navrchu boli najnovšie dáta (hlavne bydlisko či emailová adresa), čo nám následne umožnilo využitím funkcie odstrániť duplicity, ponechať len tie najaktuálnejšie dáta pre každého študenta.

Druhou dôležitou úpravou v tejto tabuľke, bolo vytvorenie stĺpca *Obec* (upravená). Nutnosť tohto stĺpca vyplýva z toho, že dáta vo svojej surovej podobe obsahujú stĺpec

Okres a stĺpec Mesto. Pri pokuse o namapovanie stĺpca Mesto sme prišli na to, že niektoré obce boli nesprávne priradené do iných krajín, a preto nám neposkytovali správny pohľad na dáta. Na vyriešenie tohto problému sa ponúkajú dve možnosti riešenia, a to buď manuálne prejsť všetky obce, ktoré sa javia ako nesprávne alebo celý proces zautomatizovať. Ak chceme model do budúcnosti updatovať o nové dáta, je proces automatizácie rozhodne výhodnejší, keďže pri manuálnej úprave by sme museli vždy pri pridaní nových dát skontrolovať či netreba niektoré obce znovu upraviť. Aby sme sa tomuto vyhli využili sme stĺpec Okres, ten totiž ako sa ukázalo, v kombinácii so stĺpcom Mesto, dokázali identifikovať miesto bydliska študentov jednoznačne.



Obrázok 4 Porovnanie neupravenej obce (vľavo) a obce po úpravách (vpravo)

Tabuľka *Tituly*

Tabuľka *Tituly* je tzv. dimenzionálna tabuľka a slúži len na to aby sme vedeli identifikovať, aký stupeň vzdelania každý študent dosiahol. Študenti U3V disponujú širokou škálou titulov preto sme sa rozhodli o ich zoskupenie do 3 stupňov, pri čom, u študentov ktorí žiadnym titulom nedisponujú sa predpokladá, že majú ukončené stredoškolské vzdelanie.

1 – bakalárske

2 – magisterské, inžinierske, doktorské (napr. Mgr., PhDr., Ing., MUDr., MVDr....)

3 – doktorandské, postgraduálne (napr. PhD., CSc., MBA)

Tabuľka *Študenti__tituly*

Tabuľka *Študenti__tituly* má rovnaký zdroj dát ako tabuľka *Študenti* s tým rozdielom, že sa využíva k tomu aby sme vytiahli všetky tituly, ktoré jednotliví študenti uvideli pri prihlasovaní do U3V. Tituly sú v tomto prípade spojené s celým menom študenta, a preto ich bolo nutné extrahovať, vďaka uniformnej štruktúre stačilo extrahovať text za čiarkou, ktorá nasleduje za každým priezviskom. Problém nastal až v prípade, že

študent disponuje viacerými titulmi, v tom prípade bolo nutné tieto tituly od seba ešte oddeliť a to najprv tituly, ktoré boli oddelené čiarkou a následne tituly, ktoré boli od seba separované len medzerou.

Po získaní zoznamu jednotlivých titulov boli zistené nekonzistencie v ich pomenovaní. Jednalo sa hlavne o rozdiely vo veľkosti písmen alebo umiestnení bodiek v skratkách. Tento problém bolo nutné riešiť približne desiatkou manuálnych úprav, ktoré názvy zjednotili a umožnili ich následné prepojenie s tabuľkou *Tituly*.

Tabuľka *Dátum*

Tabuľka *Dátum* predstavuje ďalšieho zástupcu tzv. dimenzionálnej tabuľky, ktorá nám neskôr pri analýze umožní dívať sa na dáta z pohľadu času, napr. podľa semestrov. Vytvorená je na základe vstavaných funkcií, kde sme si zadefinovali počiatočný dátum tak, aby nám pokryl prvý semester a koncový dátum, ktorý bude v našom prípade vždy deň v ktorom prebehne refresh dát. Power Query následne vytvorí list dní v zadanom rozmedzí, ktoré sa následne pretransformujú do tabuľky s jedným stĺpcom. K takto vytvorenej tabuľke už môžeme pridávať stĺpce podľa potreby. V našom prípade sú to napríklad rok, mesiac, akademický rok či semester. Pre určenie semestru sú hraničné dátumy 1.9 – začiatok zimného semestru a 1.2 – začiatok letného semestru.

Tabuľka *Predmety*

Tabuľka *Predmety* obsahuje zoznam všetkých predmetov, ktoré si študenti môžu zapísať, tento súbor stavia na súbore vytvorenom pre predošlú analýzu U3V s využitím Power BI a dopĺňa ho o nové predmety, ktoré sa predtým v tabuľke nenachádzali. Predmety sú označované tzv. identami (ID__predmet), ktoré sa až na pár výnimiek držia štruktúry UXXX, kde XXX sú čísla, ktoré identifikujú kategóriu predmetu.

001-035	spoločensko-vedné predmety
036-049	jazykové predmety
050-089	informatické predmety
090-091 a 097-099	telovýchovné predmety
092-096	výtvarné predmety
101-	doplnkové predmety

Tabuľka *Študenti__predmety*

Tabuľka *Študenti__predmety* obsahuje informácie o tom, aké predmety si jednotliví študenti v každom semestri zapísali. Jedná sa o faktovú tabuľku, teda tabuľku obsahujúcu transakčné dáta, na ktorú sa napájajú dimenzionálne tabuľky opísané vyššie. K tomuto napojeniu slúžia stĺpce ID__student, ID__predmet a Datum.

ID__student ani ID__predmet si nevyžadovalo úpravu, v zdrojových dátach figurovali od začiatku, avšak stĺpec Dátum musel byť umelo vytvorený.

Zdrojové dáta disponovali stĺpcom Semester a rok (napr. LS 2013/2014), bohužiaľ sa tento stĺpec nedal použiť na prepojenie s dátumov tabuľkou, keďže tabuľka *Dátum* obsahuje ako primárny kľúč celý dátum. Ponúkala by sa možnosť zmeniť primárny kľúč na kombináciu semestru a roku, avšak to by nám znemožnilo využívať niektoré časové funkcie neskôr pri analýze. Preto sme sa rozhodli umelo vytvoriť stĺpec Dátum, kde letný semester sa vyznačuje vždy dátumom 1.2. + druhý rok z dvojice 20xx/20xx a zimný semester sa vyznačuje dátumom 1.9 + prvý rok z dvojice 20xx/20xx.

Ďalším dôležitým stĺpcom, ktorý bol dopočítaný bol stĺpec Aktuálny vek. Pôvodne sme uvažovali o výpočte veku v tabuľke študenti, teda aby vek každého študenta bol zafixovaný a počítal sa ako rozdiel dátumu pri aktualizovaní tabuliek a dátumom narodenia študenta. Avšak pri bližšej analýze sme dospeli k tomu, že tento pohľad skresľuje evolúciu vekovej distribúcie. Pretože napríklad študent, ktorý začal študovať v roku 2006 ako 80 ročný sa pri tomto výpočte v analýze javil ako 95 ročný, čo neodpovedá realite. Preto bol nutný dynamický prístup, ktorý počíta vek študenta v každom semestri. Toho bolo dosiahnuté tak, že sme od stĺpca Dátum v tabuľke *Študenti__predmety* odčítali stĺpec Dátum narodenia, ktorý sme na tabuľku naviazali vďaka funkcii Related. Výsledok sme si ponechali v dňoch aby sme si mohli po vydelení 365,25 vybrať ako chceme zaokrúhliť vzniknutý vek. V našom prípade sme samozrejme zaokrúhľovali nadol.

Posledný dôležitý údaj, ktorým táto tabuľka disponuje je výsledok. Ten môže nadobúdať tri hodnoty: Z – zápočet udelený, NZ – zápočet neudelený alebo O – ospravedlnené.

Grafy a popis zostavy

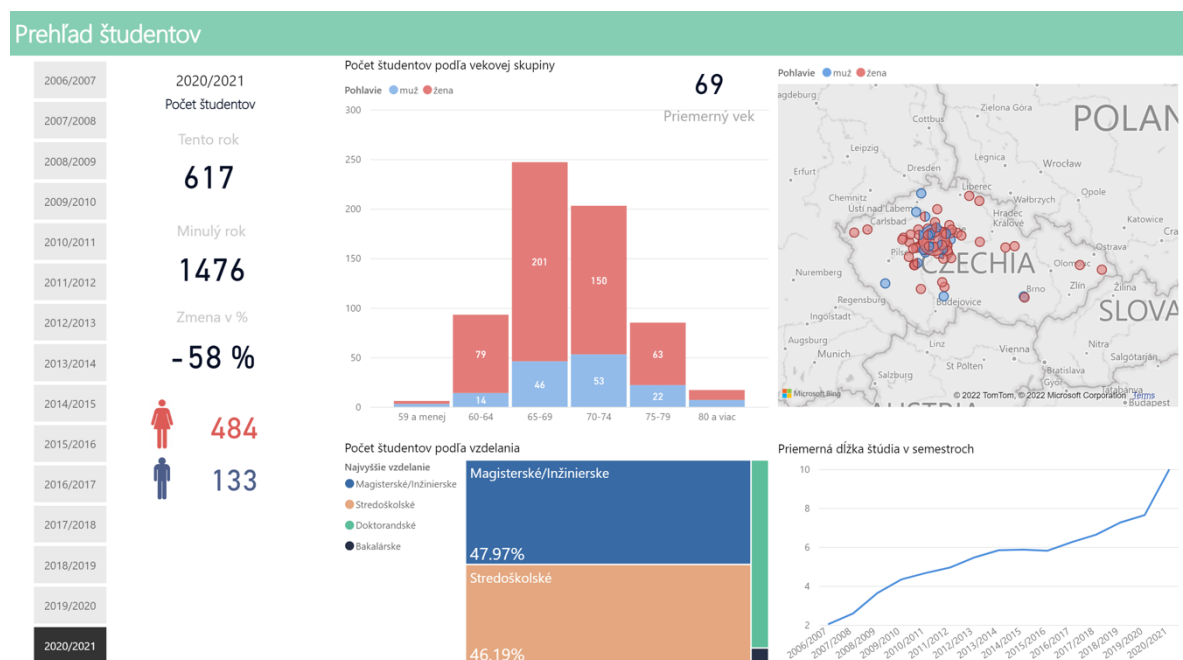
Celý model v Power BI pozostáva z troch hlavných stránok, ktoré by mali univerzite slúžiť ako rýchly prehľad toho, čo sa každý semester deje. Prvá stránka sa venuje študentom, po nej nasleduje stránka zaoberajúca sa predmetmi a napokon je jedna stránka venovaná tzv. kohortovej analýze. Mimo týchto troch stránok obsahuje zostava ešte 4 skryté dopĺňujúce stránky, ktoré slúžili čisto pre potreby analýz pre túto prácu keďže sa venujú hlavne dlhodobým evolúciám jednotlivých sledovaných charakteristík či porovnanie situácie pred a počas pandémie COVID-19.

Študenti

Stránka študenti ponúka celkový prehľad študentskej základne v každom ak. roku. Prehľad umožňuje pohľad na rozloženie študentov podľa pohlavia, podľa najvyššieho dosiahnutého vzdelania, lokality či podľa veku. Stránka tiež obsahuje základne metriky, ako počet študentov v konkrétnom ak. roku, pri čom ukazuje aj porovnanie s minulým rokom a jeho percentuálnu zmenu.

Čo sa týka vekovej distribúcie, sme študentov rozdelili do 6 vekových skupín, ktoré od seba vždy delí 5 rokov. Výnimkou sú okrajové skupiny 59 a menej a 80 a viac. Tieto skupiny by sme mohli nazvať záchytnými, keďže v sebe zahŕňajú niekoľko menších skupín, ktoré by samostatne kvôli nízkej početnosti tvorili len veľmi malé percento zo všetkých hodnôt. Tiež nám to umožňuje vyhnúť sa výnimočným prípadom alebo odchýlkam v dátach. Zvažované bolo aj použitie funkcie skupín v Power BI, avšak táto funkcia momentálne neumožňuje zoskupovanie týchto okrajových hodnôt. Každopádne nám toto rozdelenie slúžilo ako odrazový mostík pri výbere, ktoré vekové skupiny zoskupiť, a ktoré ponechať samostatné.

Posledným dôležitým grafom na tejto stránke je líniový graf ukazujúci vývoj priemernej dĺžky štúdia v čase. Tento graf umožňuje zistiť vernosť študentov, keďže rastúci trend, ako je tomu v našom prípade naznačuje, že študovať ostávajú práve študenti, ktorí študovali aj v predchádzajúcich semestroch. Táto skutočnosť pre univerzitu znamená, že nie je odkázaná na prítok nových študentov ale môže sa spoľahnúť na svoju stabilnú bázu vracajúcich sa študentov.




Obrázok 5 Prehľad študentov

Predmety

Stránka s prehľadom predmetov rozširuje pohľad na množstvo udelených zápočtov z predchádzajúcej stránky, pri čom na tejto stránke je možné sledovať ako sa množstvo udelených zápočtov vyvíjalo v priebehu akademických rokov. Možné je využiť aj interakcie s ostatnými grafmi čo nám umožní získať pohľad na to ako to vyzerá v jednotlivých kategóriách predmetov.

Ďalej sa na tejto stránke nachádzajú dve tabuľky ponúkajúce prehľad piatich najnavštevovanejších a najmenej navštevovaných predmetov. Na tieto tabuľky sa

opäť vzťahujú akékoľvek filtre, takže je možné sledovať ako na tom boli predmety v jednotlivých obdobiach či kategóriách. Ako posledný graf tu nájdeme distribúciu jednotlivých kategórií z celkového počtu zapísaných predmetov. Tento graf nám rovnako ukazuje aký je priemerný počet predmetov na študenta, teda to koľko predmetov si jeden študent v priemere každý semester zapíše.



Obrázok 6 Prehľad predmetov

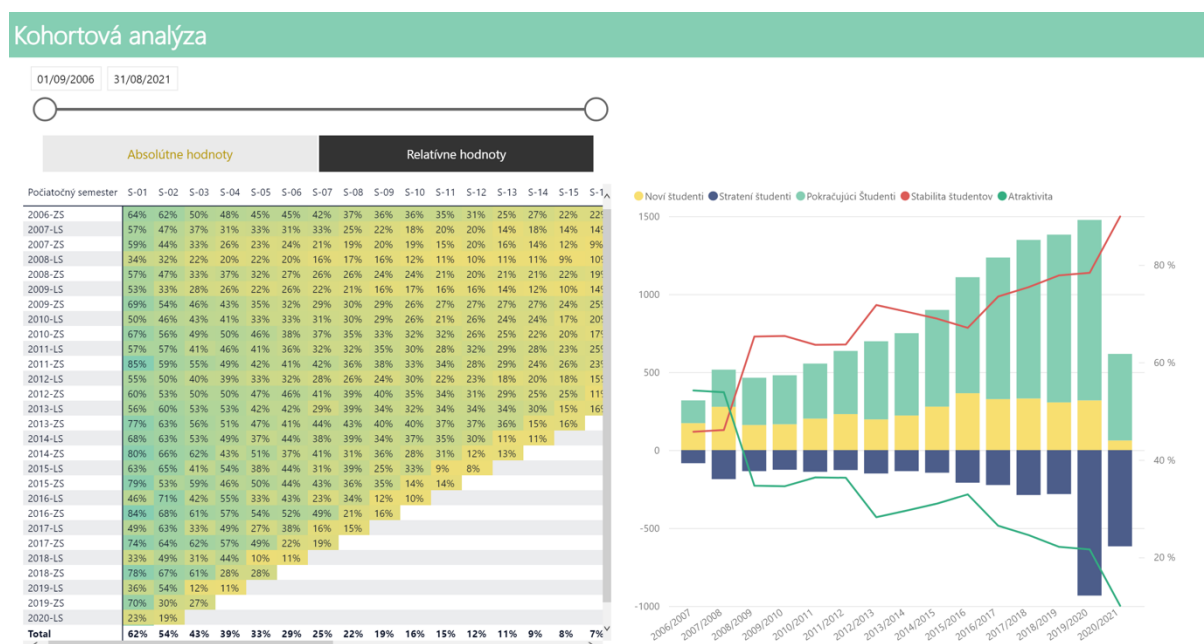
Kohortová analýza

Predtým ako popíšeme túto stránku, je potrebné si vysvetliť, čo to vlastne kohortová analýza znamená. Kohortovú analýzu by sme mohli opísať ako druh kvantitatívneho výskumu, ktorý študuje tzv. kohorty a to aký vplyv majú na určité premenné. Kde kohortu si môžeme predstaviť ako skupinu ľudí, ktorí majú niečo spoločné, napríklad istú skúsenosť počas určitého obdobia [Glenn, 2005]. V našom prípade bude jednu kohortu spájať skutočnosť, že začali študovať v rovnakom semestri konkrétneho akademického roku. Táto stránka obsahuje jednu tabuľku typu matica a jeden kombinovaný graf.

Tabuľka na tejto stránke nám ukazuje správanie jednotlivých kohort, kde v riadkoch vidíme počiatočný semester, teda semester, kedy sa študent prvýkrát zapísal, alebo lepšie povedané prvý záznam, ktorý o tomto študentovi máme. Informáciu o prvom semestri sme získali ako tzv. počítaný stĺpec, kde sme zobrali postupne každé ID študenta, prešli sme všetky jeho záznamy a našli najskorší dátum pomocou funkcie MIN(). Na druhej strane v stĺpcoch vidíme pokračujúci semester teda napr. S-10 označuje 10. nasledujúci semester po nástupe konkrétneho študenta. To o aké číslo pokračujúceho semestra sa jedná je počítané ako rozdiel medzi číslom prvého semestra daného študenta a číslom aktuálneho semestra. Na základe týchto informácií môžeme potom napríklad prvú bunku tabuľky prečítať takto: 64% študentov

zo všetkých študentov, ktorí nastúpili v zimnom semestri 2006 pokračovalo aj v nasledujúcom semestri. Tabuľka ponúka aj možnosť pozrieť sa na to koľko percent študentov z danej kohorty postúpilo do ďalšieho semestru prepnutím prepínača nad tabuľkou. Pri využití farebnej škály môžeme vidieť ako s každým pokračujúcim semestrom klesá množstvo pôvodných študentov, ktorí pokračujú. Podrobnejšie sa na výsledky pozrieme v časti 3.3.

Graf v pravej časti stránky nám ukazuje jednotlivé akademické roky na ose x, osa y na ľavej strane ukazuje počet študentov a tá na pravej strane slúži pre dve rozdielne metriky. Jednou z nich je stabilita študentov, teda koľko percent z celkových študentov v danom ak. Roku tvorili pokračujúci študenti a atraktivita, ktorá ukazuje presne opačný jav, teda koľko percent zo všetkých študentov tvorili noví študenti. V každom stĺpci grafu môžeme vidieť koľko študentov v danom roku bolo nových, teda nikdy predtým neštudovali na U3V, koľko študentov už v minulosti študovali a napokon počet študentov, ktorí už v žiadnom akademickom roku nepokračovali v štúdiu. To znamená, že aj v prípade, že by študent neštudoval jeden semester ale znova by sa vrátil, bude v semestri, kedy sa vráti vedený ako pokračujúci študent a nie ako nový študent. Červená čiara v grafe zachytáva stabilitu študentov, ktorá umožňuje sledovať či v priebehu existencie U3V dochádza k tomu, že sú študenti lojálnejší teda, že väčšie percento z celkových študentov tvoria práve študenti, ktorí už niekedy na U3V študovali. Úplne zrkadlový je vývoj tyrkysovej čiary na grafe, ktorý zachytáva atraktivitu štúdia pre nových študentov, teda aké percento z celkových študentov tvoria práve noví študenti. Samozrejme nie je možné maximalizovať obidve tieto veličiny naraz, keďže sú si protichodné. V tomto prípade závisí výber na cieľoch či prioritách konkrétnej organizácie.



Obrázok 7 Kohortová analýza


3.4 Výsledky analýzy

V predchádzajúcej časti sme si predstavili metodológiu akou sme vytvorili zo surových dát nástroj, ktorý nám v nasledujúcej sekcii umožní vyvodiť závery o skúmanom súbore ale aj o odporúčaníach, ktoré môžu univerzite pomôcť v budúcom rozvoji U3V.

3.4.1 Vyhodnotenie súboru študentov

Počas skúmaného obdobia navštívilo U3V 3 781 študentov, z toho 2 811 žien a 970 mužov. S výnimkou akademického roku 2008/2009 a 2020/2021 platí, že celkový počet študentov vždy oproti predchádzajúcemu roku vzrástol. Pri pohľade na demografickú stránku dát o študentoch sledujeme, že súbor študentov je naprieč akademickými rokmi konzistentný. To znamená, že nezaznamenávame veľké výkyvy čo sa týka rozloženia pohlaví, veku či vzdelania študentov v jednotlivých akademických rokoch.


Evolúcia distribúcie pohlavia študentov



Obrázok 8 Evolúcia vekovej distribúcie študentov


Ako môžeme vidieť na obr.8, percentuálne zastúpenie žien v jednotlivých akademických rokoch sa pohybovalo medzi 73%-78%, pri čom pozorujeme mierne rastúci trend naprieč rokmi.

Čo sa týka dosiahnutého vzdelania obecné platí, že najmenšie percento naprieč všetkými akademickými rokmi tvorili študenti s dosiahnutým bakalárskym vzdelaním. Nasledovali ich študenti s dosiahnutým doktorandským vzdelaním, pri čom ich percentuálne zastúpenie oscillovalo medzi 4 a 5 percentami. Nezastúpenejšie boli kategórie študentov s ukončeným magisterským či inžinierskym štúdiom a stredoškolským štúdiom. Výnimkou bol ak. rok 2020/2021, kde platilo, že najväčší podiel predstavovali práve študenti s ukončeným magisterským vzdelaním.



Obrázok 9 Evolúcia distribúcie vzdelania študentov


Ďalšou dimenziou, ktorou sa budeme zaoberať je vek. Priemerný vek celého skúmaného súboru je 68 rokov. Táto hodnota sa v skúmanom období pohybovala v rozmedzí 66 až 69 rokov, čo môžeme považovať za relatívne stabilné. Medzi ak. rokmi 2006/2007 a 2015/2016 pozorujeme kolísanie tejto hodnoty, avšak od ak. roku 2015/2016 má táto hodnota stúpajúci trend, čo odpovedá aj všeobecnému trendu starnutia obyvateľstva [OECD, 2019].



Obrázok 10 Evolúcia priemerného veku

Tento trend potvrdzuje aj pohľad na evolúciu vekovej distribúcie študentov, kde môžeme na obrázku č.11 vidieť ako sa každým rokom zvyšuje zastúpenie tmavších farieb, teda starších študentov na celkovom súbore študentov. Vo všeobecnosti však môžeme konštatovať že najväčšie množstvo študentov pochádza zo skupiny študentov vo veku 60 až 74 rokov. Pri čom s výnimkou ak. rokov 2007/2008 a 2008/2009 je najviac zastúpenou skupinou, veková skupina 65-69 rokov. Zaujímavým trendom, ktorý môže byť vysvetlený vyšším vekom odchodu do dôchodku je, že každým rokom sa znižuje percento študentov majúcich menej ako 60 rokov. Podobne tomu bolo aj u kategórie nad 75 rokov kde až do ak. roku 2015/2016 pozorujeme pokles na celkovej populácii študentov, avšak v posledných rokoch sledujeme rastúci trend. V ak. roku 2015/2016 percento študentov nad 75 rokov dosahovalo len 9,86% no

v ak. roku 2020/2021 toto číslo vzrástlo o 5,81 percentuálnych bodov až na hodnotu 15,67%, čo prvý krát predbehlo vekovú skupinu pod 65 rokov.



Obrázok 11 Evolúcia vekovej distribúcie študentov


Nakoniec sa pozrieme na bydlisko študentov, ktoré sa sústreďujú prevažne na územie Českej republiky, avšak nájdeme tu aj niekoľko študentov zo Slovenska. Jedná sa však iba o 12 študentov, čo pri veľkosti súboru 3 781 študentov predstavuje zanedbateľné množstvo. Dokonca v poslednom akademickom roku v našom súbore, teda v roku 2020/2021 nepochádzal ani jeden študent zo Slovenska. Čo sa týka rozdelenia študentov naprieč ČR, najväčšie množstvo študentov sa sústreďuje v Prahe, až tri štvrtiny (75,64%), čo je logické vzhľadom k umiestneniu VŠE. V prípade, že nezapočítame študentov, ktorí bydlisko nevyplnili, tak sa v Prahe sústreďuje ešte väčší podiel študentov, takmer 80% študentov (79,73%).

3.4.2 Vyhodnotenie oblúbenosti predmetov

Počas skúmaného obdobia evidujeme celkovo rastúci trend v počte zapísaných predmetov s výnimkou akademického roku 2020/2021, kedy nastal výrazný pokles v počte zapísaných predmetov v dôsledku pandémie. Pokiaľ by sme výber predmetov zúžili len na tie, ktoré skončili úspešným zápočtom, tak by sme tento pokles videli už rok predtým, kedy tak ako uvedieme v časti 3.4.3. boli vidieť prvé efekty pandémie. Zaujímavý je však aj ak. rok 2007/2008 kedy evidujeme najvyšší počet zapísaných predmetov ukončených bez získania zápočtu a to nie len v relatívnych hodnotách ale aj v absolútnych. Na zistenie dôvodov by bol nutný historický kvalitatívny výskum ohľadom konkrétnych dôvodov, prečo študenti nedosiahli týchto zápočtov.

Výsledky štúdia

Výsledok sloвне ● bez zápočtu ● nedostavil sa ● ospravedlnené ● zápočet




Obrázok 12 Výsledky štúdia

Dôležitou metrikou je aj priemerný počet predmetov na študenta. Hodnota tohto ukazovateľa v skúmanom období kolísala medzi 2,37 až 3,10 z čoho vidíme, že väčšina študentov si zapisuje 2 - 3 predmety za semester. Svoje minimum táto metrika dosiahla v prvom akademickom roku, z obdobia, ktoré sme skúmali, pri čom na toto minimum sa už v ďalších obdobiach nevrátila. V nasledujúcich obdobiach bolo minimum už 2,77, teda študenti si zapisovali v priemere väčšie množstvo predmetov. Existujú dve jednoduché vysvetlenia tohto fenoménu; a to zvyšujúci sa počet ponúkaných predmetov, ktorý takmer každý rok narastá a rovnako tak aj pribúdajúce kategórie predmetov. Práve v ak. roku 2010/2011 vidíme zavedenie jazykových predmetov, ktoré mohlo prispieť k tomu, že práve v tomto roku dosiahla hodnota priemerného počtu predmetov svoje maximum. Naopak zavedenie výtvarných predmetov v ak. roku 2011/2012 nevedlo k nárastu, skôr k miernemu poklesu z hodnoty 3,10 na 3,08.

Počet študentov a Priemerný počet predmetov na študenta

Kategória ● doplnkové ● informatický ● jazykový ● spoločensko-vedný ● telovýchovný ● výtvarný ● Priemerný počet predmetov na študenta




Obrázok 13 Počet študentov a priemerný počet predmetov na študenta

Pri pohľade na to ako sa menila skladba zapísaných predmetov v jednotlivých rokoch, je zaujímavé sledovať klesajúce zastúpenie informatických predmetov, ktoré až do ak.

roku 2012/2013 predstavovali skupinu najviac zapisovaných predmetov. Avšak so zavedením jazykových predmetov môžeme sledovať, ako sú infromatické predmety vytlačané narastajúcim percentom zapisovaných jazykových predmetov, ktoré od roku 2014/2015 prevýšili percento zapisovaných infromatických predmetov. Spoločensko-vedné predmety sa počas rokov stabilne držali v hodnotách od 32-44%, pri čom signifikantný nárast vidíme práve medzi akademickými rokmi 2019/2020 a 2020/2021, kde boli študenti pravdepodobne nútení viac využiť ponuku týchto predmetov v dôsledku zníženého počtu telovýchovných a výtvarných predmetov.

Počet študentov a Priemerný počet predmetov na študenta



Obrázok 14 Distribúcia zapísaných predmetov

3.4.3 Vyhodnotenie kohortovej analýzy


Tak ako sme spomenuli v časti 3.3.3. pri opisovaní karty Kohortová analýza, graf kohortovej analýzy nám umožňuje sledovať chovanie študentov podľa toho v akom semestri začali študovať. Vo všeobecnosti môžeme povedať, že do druhého semestru sa rozhodne pokračovať 62% študentov. Aj tretí semester môžeme považovať za relatívne úspešný, keďže do neho postúpi až 54%. Do 4. nadväzného semestru klesá percento pokračujúcich študentov pomerne strmým spôsobom, postupne spomaľuje a od 14. nadväzujúceho semestru sa pohybuje percento pokračujúcich študentov pod 10%.

Počiatočný semester	S-01	S-02	S-03	S-04	S-05	S-06	S-07	S-08	S-09	S-10	S-11	S-12	S-13	S-14	S-15	S-16	S-17	S-18	S-19	S-20	S-21	S-22	S-23	S-24	S-25	S-26	S-27	S-28	S-29
2006-ZS	64%	62%	50%	48%	45%	45%	42%	37%	36%	36%	35%	31%	25%	27%	22%	22%	24%	18%	20%	18%	15%	16%	16%	16%	15%	13%	9%	2%	3%
2007-LS	57%	47%	37%	31%	33%	31%	33%	25%	22%	18%	20%	20%	14%	18%	14%	14%	12%	14%	10%	10%	12%	12%	12%	10%	8%	10%	4%	6%	
2007-ZS	59%	44%	33%	26%	23%	24%	21%	19%	20%	19%	15%	20%	16%	14%	12%	9%	12%	9%	11%	9%	7%	7%	6%	5%	4%	1%	1%		
2008-LS	34%	32%	22%	20%	22%	20%	16%	17%	16%	12%	11%	10%	11%	11%	9%	10%	10%	9%	9%	10%	9%	8%	8%	7%	2%	4%			
2008-ZS	57%	47%	33%	37%	32%	27%	26%	26%	24%	24%	21%	20%	21%	21%	22%	19%	21%	21%	17%	16%	16%	16%	15%	9%	8%				
2009-LS	53%	33%	28%	26%	22%	26%	22%	21%	16%	17%	16%	16%	14%	12%	10%	14%	17%	14%	12%	10%	7%	10%	5%						
2009-ZS	69%	54%	46%	43%	35%	32%	29%	30%	29%	26%	27%	27%	27%	27%	24%	25%	21%	21%	22%	18%	20%	11%	7%						
2010-LS	50%	46%	43%	41%	33%	33%	31%	30%	29%	26%	21%	26%	24%	24%	17%	20%	19%	21%	19%	20%	13%	11%							
2010-ZS	67%	56%	49%	50%	46%	38%	37%	35%	33%	32%	32%	26%	25%	22%	20%	17%	19%	17%	18%	12%	11%								
2011-LS	57%	57%	41%	46%	41%	36%	32%	32%	35%	30%	28%	32%	29%	28%	23%	25%	23%	25%	13%	12%									
2011-ZS	85%	59%	55%	49%	42%	41%	42%	36%	38%	33%	34%	28%	29%	24%	26%	23%	25%	15%	16%										
2012-LS	55%	50%	40%	39%	33%	32%	28%	26%	24%	30%	22%	23%	18%	20%	18%	15%	11%	10%											
2012-ZS	60%	53%	50%	50%	47%	46%	41%	39%	40%	35%	34%	31%	29%	25%	25%	11%	12%												
2013-LS	56%	60%	53%	53%	42%	42%	29%	39%	34%	32%	34%	34%	34%	30%	15%	16%													
2013-ZS	77%	63%	56%	51%	47%	41%	44%	43%	40%	40%	37%	37%	36%	15%	16%														
2014-LS	68%	63%	53%	49%	37%	44%	38%	39%	34%	37%	35%	30%	11%	11%															
2014-ZS	80%	66%	62%	43%	51%	37%	41%	31%	36%	28%	31%	12%	13%																
2015-LS	63%	65%	41%	54%	38%	44%	31%	39%	25%	33%	9%	8%																	
2015-ZS	79%	53%	59%	46%	50%	44%	43%	36%	35%	14%	14%																		
2016-LS	46%	71%	42%	55%	33%	43%	23%	34%	12%	10%																			
2016-ZS	84%	68%	61%	57%	54%	52%	49%	21%	16%																				
2017-LS	49%	63%	33%	49%	27%	38%	16%	15%																					
2017-ZS	74%	64%	62%	57%	49%	22%	19%																						
2018-LS	33%	49%	31%	44%	10%	11%																							
2018-ZS	78%	67%	61%	28%	28%																								
2019-LS	36%	54%	12%	11%																									
2019-ZS	70%	30%	27%																										
2020-LS	23%	19%																											
2020-ZS	75%																												
Total	62%	54%	43%	39%	33%	29%	25%	22%	19%	16%	15%	12%	11%	9%	8%	7%	6%	5%	5%	4%	3%	2%	2%	1%	1%	1%	1%	1%	

Obrázok 15 Kohortová analýza

Prvý stĺpec v obrázku č.15 nám tiež ukazuje, že v prípade, že študent začne študovať v letnom semestri je menšia pravdepodobnosť, že bude pokračovať po prázdninách aj v zimnom semestri.

V druhej časti kohortovej analýzy, môžeme vidieť, že počet nových študentov sa v priebehu skúmaného obdobia držal pri stabilných počtoch, no v ten istý moment treba poznamenať, že počet pokračujúcich študentov každým rokom s výnimkou ak. rokov 2007/2008 a 2020/2021 nad proporčne stúpala a tým pádom percento nových študentov na celkovom počte študentov postupne klesá. Túto skutočnosť ukazuje krivka stabilita študentov, ktorá vykazuje rastúci trend a je zrkadlovým obrazom krivky atraktivity. Je potrebné zmieniť že počet stratených študentov v roku 2020/2021 nemá žiadnu výpovednú hodnotu, vzhľadom k tomu, že nemáme informáciu o ďalšom semestri a teda to dáva falošný dojem, že žiadny študent nepokračoval do ďalšieho semestra aj keď to bez dát nemôžeme vedieť.



Obrázok 16 Stabilita študentov a atraktivita pre nových študentov

Zaujímavý bol akademický rok 2007/2008 a rok 2006/2007 kedy počet nových študentov prevýšil počet pokračujúcich študentov, avšak tento fakt môže byť zapríčinený tým, že sa jedná o prvé roky v našich dátach čo by mohlo viesť k tomu, že medzi novými študentami sa ocitnú aj študenti, ktorý na U3V študovali v skorších semestroch, ktoré nie sú v našom dátovom modeli.

3.4.4 Dopad pandémie

Pandémia COVID-19 zasiahla všetky oblasti života, vrátane školstva, avšak U3V predstavuje veľmi špecifický segment oblasti vzdelávania, keďže tento stupeň vzdelávania je navštevovaný jednou s najohrozenejších skupín obyvateľstva. Pred začiatkom analýzy dát sme vyslovili niekoľko tvrdení, ktoré chceme potvrdiť alebo vyvrátiť s využitím vystavaného dátového modelu. Jednalo sa o nasledovné otázky:

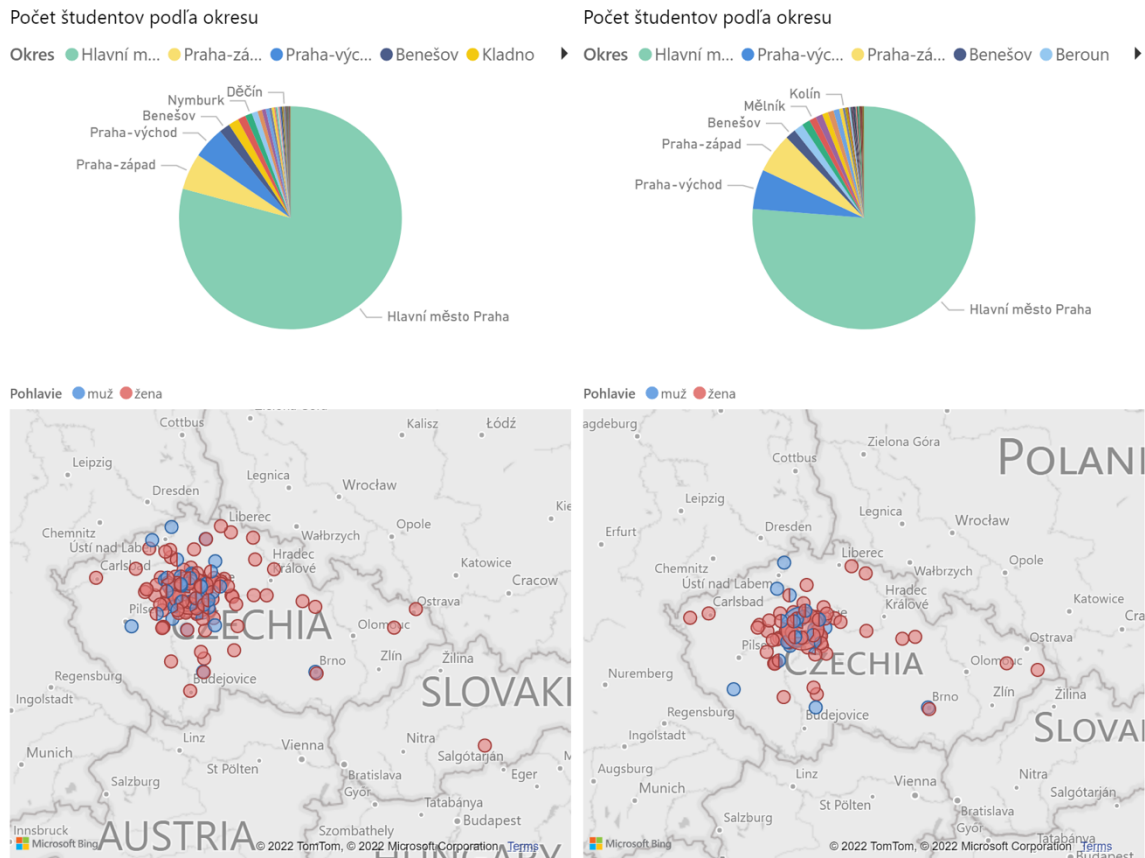
1. Pandémia COVID-19 bude mať menší dopad na pokračujúcich študentov, teda študentov, ktorí študovali na U3V aj pred pandémiou ako na nových študentov.
2. V dôsledku zavedenia hybridnej a distančnej výuky v ak. roku 2020/2021 dôjde k zvýšeniu percenta študentov dochádzajúcich za štúdiom mimo hlavného mesta Prahy.
3. Najväčší pokles v zapísaných predmetoch nastane u kategórie telovýchovných predmetov.

Celkovo v dátach vidíme pokles záujmu študentov o návštevu U3V, kde v ak.roku 2019/2020 navštevovalo U3V 1476 študentov, no v ak. roku 2020/2021 študovalo len 617 študentov, čo predstavuje medziročný pokles o 58%. Počas skúmaného obdobia sa jedná o najväčší pokles v návštevnosti univerzity. Rovnako tak sa jedná o rok, kedy univerzita prilákala najmenšie množstvo nových študentov, jednalo sa iba o 62 študentov, čo predstavuje len niečo cez 10% z celkového množstva študentov v danom akademickom roku. Len rok predtým tvorili noví študenti až 21,6% zo všetkých študentov, čo s výnimkou roku 2008/2009 predstavuje najvýraznejší pokles atraktivity U3V pre nových študentov. Toto zistenie potvrdzuje naše prvé tvrdenie a to, že pandémia bude mať menší vplyv na pokračujúcich študentov ako na tých, ktorí na U3V nikdy neštudovali. Tiež to poukazuje na skutočnosť, ktorá je aplikovateľná naprieč rôznymi odvetvami a to, že počas krízového obdobia je dôležitá práve základňa verných vracajúcich sa zákazníkov.

Dopady pandémie sme však zaznamenali už pred ak. rokom 2020/2021 a to v ak. roku 2019/2020 kedy evidujeme veľké množstvo predmetov, ktoré boli ukončené spôsobom „ospravedlnené“. Až 34,8%, čo predstavuje 1397 predmetov. Všetky tieto predmety pochádzajú z letného semestra 2020, teda obdobia, kedy pandémia prepukla na území ČR. Pre kontext rok predtým, kedy bol celkový počet zapísaných predmetov nižší len o 255 predmetov nezaznamenal ani jeden predmet ukončenie týmto spôsobom. V ak. roku 2020/2021 vidíme ešte mierne zvýšený počet týchto ospravedlnených predmetov avšak ich pomer je neporovnateľne nižší ako v predchádzajúcom roku a to len 1,4%.

Ako reakciu na pandémiu COVID-19 bola U3V nútená zaviesť hybridnú, poprípade čisto online výuku. Zavedenie takéhoto spôsobu výuky môže niektorých študentov odradiť, pretože preferujú prezenčnú výuku, no na druhej strane to môže byť lákavá možnosť pre študentov bývajúcich vo väčších vzdialenostiach od Prahy, ktorí by neboli ochotní alebo vôbec nemajú možnosť do školy niekoľkokrát týždeň osobne dochádzať. Vzhľadom k tomu, že univerzita neuskutočnila prieskum medzi študentami ohľadom toho, aký spôsob výuky preferujú sme sa rozhodli zamerať na potvrdenie druhého zmieneného výroku. Keďže medzi ak. rokmi 2019/2020 a 2020/2021 došlo k výraznému prepadu množstva študentov, nebolo možné porovnávať absolútne hodnoty, avšak pohľad na relatívne hodnoty nám potvrdzuje naše tvrdenie, že nové spôsoby výuky zvýšia percento študentov dochádzajúcich mimo Hlavného mesta

Praha. Ak odignorujeme študentov, ktorí svoje bydlisko nevyplnili tak dostávame nasledujúce výsledky. V akademickom roku 2019/2020 tvorili študenti z Hlavného mesta Praha 79,2%, v porovnaní s rokom 2020/2021 kedy to bolo 76,27%. Tento pokles nie je výrazný a je veľmi pravdepodobné, že pri štatistickom vyhodnotení by táto zmena nebola štatisticky významná.



Obrázok 17 Porovnanie distribúcie študentov z hľadiska bydliska pred a počas pandémie COVID-19

Posledným aspektom, na ktorý sa pozrieme bude akou zmenou si prešla skladba predmetov v dôsledku pandémie. Celkovo môžeme povedať že počas pandémie stúpol priemerný počet predmetov na študenta z 2,72 na 3,06, čo sa takmer približuje k maximu z ak. Roku 2010/2011, kedy táto veličina dosiahla hodnotu 3,10. Čo sa týka jednotlivých kategórií predmetov, ako sme očakávali, najväčší pokles nastal v kategóriách telovýchovných a výtvarných predmetov. Pravdepodobne z dôvodu, že ich výučba je technicky obťažnejšie zvládnuteľná pri online či hybridnom móde výučby. Konkrétne to bolo o viac ako 6,18 percentuálnych bodov u telovýchovných predmetov a 5,89 percentuálnych bodov u výtvarných predmetov. Teda sme potvrdili aj naše tretie tvrdenie o tom, že pandémia bude mať najväčší negatívny dopad práve na kategóriu telovýchovných predmetov. Na druhej strane, najväčší nárast sme zaznamenali u spoločensko-vedných predmetov, kde došlo k nárastu z 36% v ak. roku 2019/2020 na 44% v roku 2020/2021.

3.4.5 Odporúčania pre manažment

Uskutočnená analýza ponúka prvotný pohľad na správanie študentov U3V, no pre univerzitu by mala predstavovať len odrazový mostík k ďalším analýzám, ktoré pomôžu objasniť javy, ktoré dáta ukazujú. Vzhľadom k tomu, že historické dáta už dokáže univerzita len veľmi ťažko obohatiť, by sa mala univerzita zamerať na získavanie dát, ktoré jej umožnia v budúcnosti zlepšovať spokojnosť študentov a v ten istý čas udržateľne rásť. V dôsledku pandémie COVID-19 univerzita zaznamenala veľký pokles v počte študentov aj napriek tomu, že zaviedla nové spôsoby výučby. V dobe písania tejto práce nebol uskutočnený formálny prieskum preferencií študentov, ktorý by umožnil zistiť, aká ponuka predmetov a aká forma výučby je pre študentov optimálna. Preto odporúčame univerzite takýto prieskum vykonať, pri čom zamerať by sa mala aj na študentov, ktorí aktuálne na univerzite neštudujú ale v minulosti študovali. To jej umožní vylepšiť ponuku predmetov, aby si udržala stávajúcich študentov, ale tiež aby získala späť časť stratených študentov. Rovnako tak by mala univerzita optimalizovať svoju propagáciu, a so zavedením online štúdia, viac propagovať program univerzity vo vzdialenejších častiach republiky, poprípade na Slovensku, čím by opäť univerzita mohla rozšíriť základňu svojich študentov. Koniec koncov ide o vytvorenie rovnováhy medzi schopnosťou univerzity udržať si stávajúcich študentov ale zároveň prilákať nových.

Na základe kohortovej analýzy bližšie opísanej v časti 3.4.3. tiež odporúčame univerzite zamerať sa na lepšiu propagáciu nadväzného štúdia po skončení letného semestra. Napríklad formou emailovej komunikácie alebo kratších kurzov v priebehu leta aby sa univerzite podarilo vylepšiť percento pokračujúcich študentov, ktorí začali so štúdiom práve počas letného štúdia.

Čo sa týka rozloženia predmetov, odporúčame univerzite prehodnotiť ponuku predmetov či už na základe dodatočného prieskumu ako sme spomenuli vyššie ale rovnako tak aj z historických dát, ktoré sú k dispozícii vo vytvorenom modeli. Jedná sa napríklad o zníženie počtu informatických predmetov a o ich nahradenie spoločensko-vednými či jazykovými predmetmi. Toto odporúčenie vychádza predovšetkým zo skutočnosti, že aj pri relatívne vysokom množstve informatických predmetov, ich podiel na celkových zapísaných predmetoch stále klesá.

Záver

Hlavným cieľom tejto práce bolo načerpať teoretické informácie o oblasti Business Intelligence a ukázať ako aplikácia týchto poznatkov v organizácii dokáže byť prínosná pre podniky a iné organizácie. Teoretický základ práce bol čerpaný z odbornej literatúry, prevažne zahraničnej, vzhľadom k tomu, že daná problematika nie je v Českej Republike ani na Slovensku veľmi rozšírená. Na demonštráciu prínosu využitia BI v organizáciách sme sa rozhodli vytvoriť dátový model pre univerzitu tretieho veku na Vysokej škole Economickej v Prahe, ktorý umožnil uskutočniť analýzu dát. Dáta sme čerpali priamo od univerzity, pri čom za výskumné obdobie sme zvolili roky 2006-2021. Vzhľadom k tomu, že sme chceli pri analýze vždy sledovať len kompletne akademické roky, teda tie, u ktorých máme dáta o letnom aj zimnom semestri sme sa rozhodli zimný semester 2021 nezahrnúť do našej analýzy.

Vzhľadom k tomu, že vytvorený dátový model je možné aktualizovať s novými dátami, ho môže univerzita využiť na monitorovanie situácie aj v budúcich semestroch. Pre potreby tejto práce bol dátový model využitý prevažne k analýze historických dát, ktoré nám poskytli pohľad na to akým spôsobom sa v skúmanom období vyvíjalo zloženie študentov na U3V. Hlavným záverom z tejto analýzy bol poznatok, že súbor študentov bol počas rokov relatívne konzistentný. Hlavne čo sa týka zloženia pohlaví či dosiahnutého vzdelania. Pri vekovej distribúcii bol sledovaný mierny nárast priemerného veku študentov, ktorý je len odrazom celosvetového starnutia obyvateľstva. Zvýšená pozornosť bola venovaná posledným dvom akademickým rokom, ktoré boli poznačené pandemiou COVID-19. Nie len že univerzita už v letnom semestri 2020 zachytila bezprecedentné percento predmetov ukončených spôsobom „ospravedlnené“, v nasledujúcom akademickom roku došlo k najvýraznejšiemu poklesu študentov za existenciu univerzity. Vďaka využitiu kohortovej analýzy sme však mali možnosť vidieť, že univerzitu v týchto nestálych časoch podržali jej verní študenti, o čom vypovedá aj fakt, že takmer v každom akademickom roku dochádzalo k zvyšovaniu percenta pokračujúcich študentov.

Výzva, ktorej bude univerzita v najbližších rokoch čeliť, je predovšetkým nájsť optimálne riešenie, ktoré umožní udržanie lojálnych študentov bez ujmy na získavaní nových študentov. Preto by sa mala univerzita na základe našich odporúčaní pokúsiť o uskutočnenie prieskumu na základe, ktorého by dokázala priniesť študentom predmety, o ktoré majú záujem a vyučovať ich spôsobom, ktorý bude pre študentov najatraktívnejší.

Vykonaná analýza a z nej vyvedené závery či odporúčania ukazujú veľký potenciál BI riešení v riadení organizácií, hlavne pokiaľ ide o informované prijímanie rozhodnutí. O tom, že riešenia podobné tomu prezentovanému v tejto práci predstavujú prínos pre organizácie v dlhodobom plánovaní vypovedá aj skúsenosť autorky, ktorá podobný model v roku 2020 vytvorila aj pre komerčnú spoločnosť s hlavným cieľom

zvyšovania zisku. Pri čom pri vykonaní prieskumu medzi užívateľmi tohto riešenia po jeho zavedení, užívatelia deklarovali, že mesačne ušetria až päť hodín svojho pracovného času. Zvyšovanie efektivity práce môže samozrejme prispieť aj k inkrementálnemu nárastu zisku spoločnosti. Navyše bol tento model využívaný naprieč celou organizáciou, teda na všetkých úrovniach managementu, čo len potvrdzuje dôležitosť a aktuálnosť témy tejto práce.

Zoznam použitej literatúry

- AL-AQRABI, Hussain, Lu LIU, Richard HILL a Nick ANTONOPOULOS. Cloud BI: Future of business intelligence in the Cloud: Future of business intelligence in the Cloud. *Journal of Computer and System Sciences*. 2015, **81**(1), 85-96. ISSN 0022-0000. Dostupné z: doi:<https://doi.org/10.1016/j.jcss.2014.06.013>
- BAKER, John a Stephen SUGDEN. Spreadsheets in Education –The First 25 Years. *Spreadsheets in Education (eJSiE)* [online]. 2003, **1**(1), 18-43 [cit. 2022-08]. ISSN 1448-6156. Dostupné z: <http://web.boun.edu.tr/topcu/Spreadsheets%20in%20Education.pdf>
- Business Intelligence Software. In: *Statista* [online]. Graf, n.d.. [cit. 22-08-2021]. Dostupné z: <https://www.statista.com/outlook/tmo/software/enterprise-software-/business-intelligence-software/worldwide?currency=EUR#revenue>
- CHEN, CHIANG a STOREY. Business Intelligence and Analytics: From Big Data to Big Impact. *MIS Quarterly* [online]. 2012, **36**(4) [cit. 2021-08-05]. ISSN 02767783. Dostupné z: doi:10.2307/41703503
- Comparing Power BI Desktop and the Power BI service. *Microsoft* [online]. 11.1.2021a [cit. 2021-08-05]. Dostupné z: <https://docs.microsoft.com/en-us/power-bi/fundamentals/service-service-vs-desktop>
- Facts about W3C: History. *W3C* [online]. © 2021 [cit. 2021-08-05]. Dostupné z: <https://www.w3.org/Consortium/facts#history>
- FOLEY, Éric a Manon G. GUILLEMETTE. What is Business Intelligence? *International Journal of Business Intelligence Research* [online]. 2010, **1**(4), 1-28 [cit. 2021-08-05]. ISSN 1947-3591. Dostupné z: doi:10.4018/jbir.2010100101
- GARTNER. *How Markets and Vendors Are Evaluated in Gartner Magic Quadrants* [online]. 2019 [cit. 2021-8-22]. Dostupné z: <https://www.gartner.com/en/documents/3956304/how-markets-and-vendors-are-evaluated-in-gartner-magic-q>
- GLENN, Norval D. *Cohort analysis*. 2nd ed. Sage, 2005. ISBN 0-7619-2215-6.
- INMON, William H. *Building the Data Warehouse*. 4th edition. New York, United States: John Wiley, 2005. ISBN 978-0-764-59944-6.
- Introduction: Use natural language to explore data with Power BI Q&A. *Microsoft* [online]. 08/05/2021b [cit. 2021-8-28]. Dostupné z: <https://docs.microsoft.com/en-us/power-bi/natural-language/q-and-a-intro>
- Is Logistics the Same as Supply Chain Management? *Michigan State University* [online]. Michigan, 2020 [cit. 2021-8-25]. Dostupné z: <https://www.michiganstateuniversityonline.com/resources/supply-chain/is-logistics-the-same-as-supply-chain-management/>
- KELLY, Floyd. *Implementing an Executive Information System* [online]. 1994. [cit. 2021-11-06]. Dostupné z: <http://dssresources.com/papers/features/kelly11072002.html>
- KRISHNASAMY, Ezhilmathi, Sebastien VARRETTE a Michael MUCCIARDI. *Edge Computing: An Overview of Framework and Applications* [online]. Bruxelles, Belgium: PRACE, December 2020 [cit. 2021-8-28]. Dostupné z: <https://prace-ri.eu/wp-content/uploads/Edge-Computing-An-Overview-of-Framework-and-Applications.pdf>

KUBÁLEK, T. Proč studovat na U3V VŠE. In: *u3v.vse.cz* [online]. Praha: 1. 10. 2018 [cit. 2022-06-01]. Dostupné z: <https://u3v.vse.cz/predstaveni-u3v/proc-studovat-na-u3v/>

LINTHICUM, David S. *Enterprise Application Integration*. Addison-Wesley Professional, 1999. ISBN 978-0-201-61583-8.

LUHN, H. P. A Business Intelligence System. *IBM Journal of Research and Development*. 1958, 2(4), 314-319. ISSN 0018-8646. Dostupné z: doi:10.1147/rd.24.0314

Magic Quadrant for Analytics and Business Intelligence Platforms. In: *Climber* [online]. Climber © 2022 [cit. 2022-04-06]. Dostupné z: <https://www.climber.eu/qlik-a-leader-in-the-2021-gartner-magic-quadrant/>

MAKOWSKI, Marek. *Design and Implementation of Model-based Decision Support Systems*. Laxenburg, Austria: IIASA, 1994. Dostupné také z: <http://pure.iiasa.ac.at/id/eprint/4125/>

Market share of major office productivity software worldwide as of May 2021. In: *Statista* [online]. Graf, Máj, 2021. [cit. 6.1.2022]. Dostupné z: <https://www.statista.com/statistics/983299/worldwide-market-share-of-office-productivity-software/>

Natural Language Processing (NLP). *IBM* [online]. 2/7/2020 [cit. 2021-08-28]. Dostupné z: <https://www.ibm.com/cloud/learn/natural-language-processing>

NELSON, Gregory S. Business Intelligence 2.0: Are we there yet? In: *SAS Global Forum* [online]. 2010 [cit. 2021-08-05]. Dostupné z: <https://support.sas.com/resources/papers/proceedings10/040-2010.pdf>

NĚMEC, Radek. The application of business intelligence 3.0 concept in the management of small and medium enterprises. In: *Information Technology for Practice 2012* [online]. Ostrava, 2012, s. 84-89 [cit. 2021-11-06]. Dostupné z: <http://www.cssi-morava.cz/new/doc/IT2012/sbornik.pdf>

NOVOTNÝ, Ota, Jan POUR a David SLÁNSKÝ. *Business intelligence: jak využít bohatství ve vašich datech*. Praha: Grada, 2004. ISBN 80-247-1094-3.

OECD. *Working Better with Age: Ageing and Employment Policies*. Paris: OECD Publishing, 2019. Dostupné z: doi:10.1787/c4d4f66a-en

OLSZAK, Celina a Ewa ZIEMBA. Approach to Building and Implementing Business Intelligence Systems. *Interdisciplinary Journal of Information, Knowledge, and Management* [online]. 2007, 2, 135-148 [cit. 2021-11-06]. Dostupné z: doi:10.28945/105

OLSZAK, Celina M. *Business Intelligence and Big Data: Drivers of Organizational Success*. Auerbach Publications, 2020. ISBN 978-0367373948.

O VŠE. In: *Vysoká škola ekonomická v Praze* [online]. Praha: 2. 6. 2021 [cit. 2022-23-01]. Dostupné z: <https://www.vse.cz/informace-o-vse/profil-skoly/vysoka-skola-ekonomicka-v-praze/>

PETRINI, Maira a Marlei POZZEBON. What role is "business intelligence" playing in developing countries? A picture of Brazilian companies. *Cahier du GReSI*. 2004/08/01, 4(16). ISSN 0832-7203. Dostupné z: doi:10.4018/978-1-59904-283-1.ch013

- PIRTTIMÄKI, V. Conceptual analysis of business intelligence. *SA Journal of Information Management* [online]. 2007/11/03, 9(2) [cit. 2022-28-08]. Dostupné z: doi:10.4102/sajim.v9i2.24
- PONELIS, Shana a Johannes BRITZ. A Descriptive Framework of Business Intelligence Derived from Definitions by Academics, Practitioners and Vendors. *Mousaion* [online]. 2012, 30(1), 103-119 [cit. 2022-28-08]. ISSN 0027-2639. Dostupné z: <https://search.ebscohost.com/login.aspx?direct=true&db=lxh&AN=97849296&site=ehost-live&scope=site>
- Power BI data sources . *Microsoft* [online]. 12.10.2022b [cit. 2022-10-1]. Dostupné z: <https://docs.microsoft.com/en-us/power-bi/connect-data/power-bi-data-sources>
- Power BI Pricing. *Microsoft* [online]. © 2022a [cit. 2022-6-1]. Dostupné z: <https://powerbi.microsoft.com/en-us/pricing/>
- POWER, Daniel J. A Brief History of Decision Support Systems. *DSSResources* [online]. March 10, 2007 [cit. 2021-8-5]. Dostupné z: <http://DSSResources.COM/history/dsshistory.html>
- PRIBISALIĆ, Marko, Igor JUGO a Sanda MARTINČIĆ-IPŠIĆ. Selecting a Business Intelligence Solution that is Fit for Business Requirements. In: *Bled Econference Humanizing Technology For A Sustainable Society* [online]. Bled, Slovenia, July 2019 [cit. 2021-28-08]. Dostupné z: doi:10.18690/978-961-286-280-0.24
- RANJAN, Jayanthi. Business Intelligence: Concepts, components, techniques and benefits. *Journal of Theoretical and Applied Information Technology* [online]. 2009, 9(1), 60-70 [cit. 2022-08]. ISSN 1992-8645. Dostupné z: <https://www.jatit.org/volumes/research-papers/Vol9No1/9Vol9No1.pdf>
- SHOLLO, Arisa a Karlheinz KAUTZ. Towards an Understanding of Business Intelligence. *ACIS 2010 Proceedings*. 2010, 86. Dostupné také z: <https://aisel.aisnet.org/acis2010/86>
- Size of the business intelligence and analytics software application market worldwide, from 2019 to 2024. Graf, November, 2020. In: *Statista* [online]. [cit. 24-3-2021]. Dostupné z: <https://www.statista.com/statistics/590054/worldwide-business-analytics-software-vendor-market/>
- THIESSE, Frédéric. Business Intelligence Concepts and Architectures [prednáška]. Online: *Julius-Maximilian University Würzburg*, 19.7.2021.
- THOMSEN, Erik. *BI's Promised Land* [online]. INTELLIGENT ENTREPRISE. 2003. [cit. 2022-28-08]. Dostupné z: http://providersedge.com/docs/km_articles/BI-s_Promised_Land.pdf
- TURBAN, Efraim, Ramesh SHARDA, Dursun DELEN a David KING. *Business Intelligence: A Managerial Approach*. 2nd ed. Upper Saddle River, NJ: Prentice Hall, 2010. ISBN 978-0136100669.
- TUTUNEA, Mihaela Filofteia a Rozalia Veronica RUS. Business Intelligence Solutions for SME's. *Procedia Economics and Finance* [online]. 2012, 3, 865-870 [cit. 2022-28-08]. ISSN 2212-5671. Dostupné z: doi:10.1016/S2212-5671(12)00242-0

VERCELLIS, Carlo. *Business Intelligence: Data Mining and Optimization for Decision Making*. Wiley, 2009. ISBN 978-0-470-51138-1.

WILLIAMS, Steve a Nancy WILLIAMS. *The Profit Impact of Business Intelligence*. Morgan Kaufmann, 2007. ISBN 978-01-2372-499-1.

WOOLF, H. B. *Webster's New Collegiate Dictionary*, G&C Merriam Co. 981. Springfield, MA I, 1981.

Zoznam obrázkov

Obrázok 1 Definičný rámec BI.....	9
Obrázok 2 Hviezdicové schéma	13
Obrázok 3 "Magic Quadrant" pre BI a Analytické platformy	15
Obrázok 4 Porovnanie neupravenej obce (vľavo) a obce po úpravách (vpravo)	26
Obrázok 5 Prehľad študentov	29
Obrázok 6 Prehľad predmetov	30
Obrázok 7 Kohortová analýza	31
Obrázok 8 Evolúcia vekovej distribúcie študentov	32
Obrázok 9 Evolúcia distribúcie vzdelania študentov	33
Obrázok 10 Evolúcia priemerného veku	33
Obrázok 11 Evolúcia vekovej distribúcie študentov	34
Obrázok 12 Výsledky štúdia	35
Obrázok 13 Počet študentov a priemerný počet predmetov na študenta	35
Obrázok 14 Distribúcia zapísaných predmetov	36
Obrázok 15 Kohortová analýza	37
Obrázok 16 Stabilita študentov a atraktivita pre nových študentov	38
Obrázok 17 Porovnanie distribúcie študentov z hľadiska bydliska pred a počas pandémie COVID-19	40

