

## Daty řízený proces vzdělávání



**Článek se věnuje problematice využití dat ve školství, a to především z hlediska návrhu informačních systémů a jejich pedagogických a etických aspektů. Diskutována je problematika big data v edukačním procesu a vzdělávací politice, otázka adaptabilního vzdělávání a možnosti, které přináší. Důraz je kladen na propojení pedagogiky a informační vědy.**

### Úvod

Vztah mezi informační vědou a pedagogikou není zdaleka jednoznačný a obě vědecké disciplíny od sebe není možné snadno oddělit. Informační vzdělávání, které se v informační vědě formuje a dodnes má zázemí především v knihovnách, plynule přechází do pedagogiky a o jeho místě v ní jen málokdo pochybuje. Opačný proces je pak možné sledovat u využívání dat a dokumentů k řízení výuky a snaze o její evaluaci a efektivitu, které spíše patří do informační vědy než do pedagogiky či didaktiky. Toto dichotomické přeskupování pozic je pro rozvoj obou disciplín nesporně přínosné a zajímavé.

V tomto článku bychom se tak rádi podívali na oblast, která z pedagogiky vychází a jejíž výsledky se v ní projevují, ale současně je úzce navázána na vědu informační, totiž na problematiku daty řízeného školství a vzdělávání. Problematika big data jako trendu, který přetváří řadu oblastí lidského života, se výrazně promítá také ve vzdělávání, a to od procesu učení jednotlivce po tvorbu vzdělávacích politik. S tím souvisí nárůst významu informačních systémů, které tuto formu edukace umožňují a aktivně podporují.

### Big data ve školství

Dnes neexistuje žádná všeobecně přijímaná definice toho, co to big data jsou. Obecně se má za to, že jde o taková data, která není možné dostatečně efektivně zpracovat běžnými konzervativními způsoby. Důvodem může být jejich objem, nehomogenní struktura nebo potřeba s nimi pracovat v reálném čase. Ve školství se můžeme setkat především s prvními dvěma problémy. V kontextu vzdělávacích politik je objem dat mimořádně velký a jakákoli jejich redukce snižuje relevanci získaných výsledků.

Zajímavější je ale struktura dat. Triviálně se lze setkat s přesvědčením, že jde buď o data z Learning Management Systém (LMS) školy (například Moodle), nebo (v horším případě) o ta, která pochází z testování žáků. Na základě dat z testů či jiného zjišťování mezi nimi (dle paradigmatu akčního výzkumu) je třeba upravovat výuku takovým způsobem, aby byla co možná nejefektivnější.

Zde narážíme na zásadní problém – jde jen o malou část informací o skutečném chování či myšlení žáka a možnosti, jak na základě nich zlepšit výuku, jsou spíše malé. Nejsou v nich obsažena data od školních psychologů nebo z volnočasových aktivit, které navštěvuje, výpůjčky z knihoven, digitální stopy, jeho zájmy nebo práci v hodině. Současně je třeba říci, že školství zažívá v posledních letech (také u nás) silný posun od kognivistického ke konstruktivistickému pojetí, ve kterém se do popředí dostávají také soft skills a klíčové kompetence, nikoli pouze znalosti a dovednosti, které lze triviálně snadno testovat.

Martin Weller z Open University říká, že je „velký rozdíl mezi analýzou dat pro studenta a o studentovi“<sup>1</sup>. Naším ideálním cílem by mělo být, aby student dostal informace pro své vlastní rozhodování a podporu učitele<sup>2</sup>. Na druhou stranu se zde otevírá otázka, jak relevantní jsou takto neúplná data pro efektivní rozhodování, zda se nevytrácí cit a zkušenost pedagoga ve prospěch algoritmů a především je zde velký problém v ochraně soukromí.

Je zjevné, že čím více informací o studentovi budeme mít k dispozici, tím lépe jsme schopni hodnotit jeho vzdělávací progres a nabídnout mu kvalitní systém vzdělávání se. Na druhé straně zde platíme soukromím, což je v západním civilizačním okruhu důležitá hodnota. Kdykoli bylo v rámci myšlenek „velkého dobra“ omezeno, skončilo to „velkou totalitou“. Internet a služby na něm jej ale stále více proměňují na komoditu, kterou lidé platí za dobré služby – jejich provozovatel nebo třetí strana pak může lépe cílit reklamu a tím generovat zisk. Prodej soukromí tak není ničím, co by zde neexistovalo a nebylo relevantní o tom diskutovat.

Na druhou stranu by škola (nebo jiná vzdělávací instituce, neboť jde o téma zajímavé také – především – pro celoživotní a firemní vzdělávání) zřejmě neměla do soukromí žáků či studentů zasahovat více, než je nezbytně nutné. Situace, kdy jsou data o studentech poskytovány třetím osobám, z důvodů lepšího zpracování dat nebo úspor, jsou dle našeho soudu zcela nepřijatelné, neboť obsahuje velký potenciál zneužití.

Big data ve školství přináší také další rizika:<sup>3</sup>

- Ochrana soukromí je netriviálním etickým, ale také legislativním problémem. Jestliže bude analýze podrobeno chování studenta a jeho učební výsledky, je možné či přijatelné do tohoto výsledku zahrnout například data z pedago-

<sup>1</sup> WELLER, Martin. *5 things I think about Learning Analytics*.

<sup>2</sup> BRDIČKA, Bořivoj. *Daty řízené školství, politika a technologie*.

<sup>3</sup> BRDIČKA, Bořivoj. *Jsou velká data velkým potenciálem nebo velkou chybou?*

gicko-psychologických poraden, od výchovných poradců, data volně přístupná na internetu nebo veškeré údaje zpracovávány například v rámci školních Google Apps? Kde leží hranice mezi dobrem žáka a totalitním omezováním jeho svobody a soukromí?

- Jestliže analýza dat nereflktuje offline činnosti, jako je zájmová a spolková činnost žáka nebo studium knih, práci v klasické hodině atp., může docházet k výraznému zkreslení výsledků. Jestliže je rozhodovací proces učení nastaven jen automaticky, může vést paradoxně k horším výsledkům vzdělávání než při neimplementaci konceptu daty řízeného školství.
- Může docházet ke ztrátě sociálního a lidského kontaktu mezi žákem a učitelem. Tato ztráta může mít negativní vliv na socializaci, ale také na motivaci studentů nebo možnost jej pro dané téma dostatečně nadchnout čistě lidským přístupem. Data z MOOC kurzů, kde tento kontakt v podstatě není, hovoří o tom, že úspěšnost absolvování je do 10-15 % což je podstatně méně než v případě klasické výuky.
- Může dojít k poškození či chybě dat tam, kde existuje jasná motivace pro jejich vylepšování. Jsou-li žáci hodnoceni podle činnosti v LMS, může nastat situace, že část domácí práce za ně bude dělat někdo jiný, v případě hodnocení škol podle sumativních výsledků žáků k jejich úmyslnému zkreslování atp.
- Ne každá statistická korelace ukazuje na kauzální vztahy nebo na ně odkazuje správně, což v případě big data nemusí být snadné zjistit<sup>4</sup>. Špatná interpretace spolu s určitou dehumanizací může mít pro vzdělávání fatální následky.

Vzhledem k rozvoji nejrůznějších školských politik existuje netriviální tlak na hodnocení škol nebo celých systémů a právě daty řízené školství k tomu poskytuje na první pohled jednoduchý, rychlý a objektivní nástroj. Jeho využívání je sice možné a žádoucí, ale současně musí být realizováno takovým způsobem, který povede k tomu, aby se studenti a žáci učili pro svoji osobní potřebu a rozvoj, nikoli pro zvládnutí testů. Manipulace s daty nebo vhodné přizpůsobení systému „vzdělávání“<sup>5</sup> úspěšnému absolvování testů není obtížné a pro vzdělávání jako takové má vážné konsekvence.

Přesto se domníváme, že neexistuje jiná cesta, než s daty řízeným edukačním procesem pracovat, neboť k lepším výsledkům skutečně vést může, a především s rozvojem role celoživotního a neformálního vzdělávání si lze komplexní propojený systém spojující digitální portfolio studenta a jeho vzdělávací aktivity představit velice dobře.

## Adaptabilní učební systémy jako příklad dobré praxe

Ač z výše uvedeného mohl vzniknout dojem, že velká data jsou především problémem, se kterým se musí školství nějak vypořádat, jsem přesvědčen, že tomu tak není. Jde především o velkou výzvu a šanci změnit způsob vzdělávání. Nikoli v tom ohledu, že informační systém nahradí učitele, ale naopak v tom, že mu pomůže lépe vzdělávat každého jednotlivce.

Jedním z klíčových problémů vzdělávání je jeho masovost. Nejde zde jen o (lidové) ztěžování, že učitelé předčítají učebnice nebo je jejich výklad jinak nezajímavý, ale především o samotný fakt, že výuka má – ve velké většině – frontální charakter. Takto koncipovaná hodina, jestliže je pravidlem, neumožňuje respektovat potřeby vzdělávání každého jednotlivce, jeho styl učení, tempo, kterým je zvyklý pracovat, zájmy nebo předchozí i současné znalosti a dovednosti. Výsledkem jsou jak problémy s inkluzivním vzděláváním (které kompenzují asistenti), tak především s nadanými studenty, kterým se věnuje jen málokdo. Masovost školství vede ke vzdělávání průměrného studenta k průměrným znalostem.

Tím, že je nadání a zájem žáků rozprostřen mezi předměty různě, většinou dochází k tomu, že jeden nebo dva předměty studenta baví, část je mu lhostejných a v části se nudí nebo o ně neprojevuje žádný zájem. Je zřejmé, že cesta k individualizovanému vzdělávání, které by lépe pracovalo s každým jednotlivcem, je něčím, co není možné přehlížet, neboť jde jak o antropologický či etický imperativ, tak o naprostou nezbytnost v kontextu konkurenceschopnosti ekonomiky.

Salman Khan, který stojí za Khan Academy, jednoho z největších vzdělávacích projektů současnosti, poukazuje ještě na jeden vážný problém. Škola nijak nemonitoruje, zda jsou znalosti homogenní a kvalitní v celém rozsahu, což ilustruje na příkladu jízdy na kole. Není možné někoho naučit něco na trojku nebo čtverku. To je jako říci, že když někdo umí řídit kolo na známku „dobře“, znamená to, že sice umí rozjet a zatáčet, ale že brzdit neumí. Proto je třeba měnit školu tak, aby byla dokonale uzpůsobená na to, čas studentů využít k tomu, aby se naučili věci skutečně dobře a pořádně. Data ale lze ve školství používat také dalšími způsoby<sup>6</sup>.

Zřejmě nejznámějším a nejdostupnějším příkladem toho, jak lze začít s využíváním dat ve vzdělávání v moderní, pro studenty i pedagoga přínosné podobě, je opět Khan Academy. Na panelu, který má každý student k dispozici, vidí, jaká cvičení již má za sebou, která jsou ještě dostupná nebo jaký je doporučený průchod kurzem. Při spuštění cvičení může pracovat jak s jednoduchou nápovědou, tak také s videem, které podrobně vyloží celou problematiku. Samozřejmostí jsou pak pokročilé statistiky toho, jak je úspěšný, co už bezpečně ovládá a co musí ještě zlepšit.

Tato data jsou pak dostupná také učitelům, který s nimi může pracovat a individuálně podle nich jednotlivci maximálně pomoci. V této souvislosti se hovoří o převrácené třídě. Výklad je realizován primárně formou videa, které si může student pouštět opakovaně, ve vlastním tempu a libovolně se k němu vracet. Na učitelé je pak především vysvětlení nejasností, práce s chybou, pomoc při řešení úloh či demonstrace, což jsou oblasti, které studenti dříve spíše řešili doma než ve škole.

<sup>3</sup> Často se udává příklad, že množství prodané zmrzliny koreluje s počtem utopených osob. Kauzální příčina mezi nimi není, neboť tou je zvýšená teplota vzduchu.

<sup>5</sup> Slovo vzdělávání je zde v uvozovkách, neboť o pravé vzdělávání se v tomto kontextu již nejedná.

<sup>6</sup> BRDIČKA, Bořivoj. Skutečné možnosti využití daty řízeného školství; BRDIČKA, Bořivoj. Daty řízené školství, politika a technologie.

Jde o první krok, který by měl zajistit přechod od masového učení k adaptabilnímu. V zásadě je možné pracovat se čtyřmi úrovněmi přizpůsobení se potřebám jednotlivého studenta:<sup>7</sup>

1. Masové vzdělávání se konkrétním potřebám nijak nepřizpůsobuje, studijní skupinu či třídu vnímá jako masu, sleduje jen sumativní hodnocení, cílem je optimální prospěch celku.
2. Diferencované učení respektuje již existenci různých cest vedoucích ke společnému cíli. Student si může zvolit pořadí výkladu, posloupnosti příkladů, které chce řešit.
3. Personalizované učení vychází z myšlenky, že na základě pretestu vytvoříme studentovi množinu učebních materiálů či aktivit, které má zvládnout. Typicky jde o omezení materiálů, které jsou pro studenta nepotřebné, neboť jejich obsah již dobře zná, nebo naopak omezení pokročilých materiálů studentům, kteří nemají potřebné znalosti pro jejich pochopení. Může také pracovat s materiály či příklady podle zájmů či aktivit konkrétního studenta.
4. Adaptivní učení, které pružně reaguje na potřeby a výsledky žáka v průběhu vzdělávání. Příkladem může být průběžné opakování zlomků v případě, že studentovi v daném testu nejdu, atp. Intenzivně se hovoří o možnosti kombinování s počítačovým zpracováním emocí, které by umožňovalo měnit předměty či metody podle aktuální únavy či psychického stavu studenta.

Díky adaptivnímu učení, které by mělo být cílem všech inovací v oblasti LMS systémů a reforem procesu vzdělávání vůbec, lze učení dokonale individualizovat takovým způsobem, aby žák měl z dané oblasti úplné a robustní znalosti, nikoli pouze formální povědomí. Díky těmto systémům si student sám může měnit tempo a styl výkladu podle toho, jaké má schopnost a zájmy tak, aby se na konci procesu naučil to, co má. Takový koncept přirozeně vede k lepším vzdělávacím výsledkům a již zmíněnému konceptu převrácené třídy<sup>8</sup>.

Dokument Data-Driven Improvement and Accountability<sup>9</sup> hodnotí přínos testování a sběru dat pro efektivitu a kvalitu vzdělávání. V něm formulují dvanáct doporučení, které mají učitelům pomoci v tom, jak dobře nastavit testy či informační systémy, aby měřili to, co skutečně mají:

1. Měřit to, co je skutečně důležité, nikoli pouze to, co je snadno změřitelné. Diskomfort v podobě složitějších testů nebo psaní modulů do LMS se jednoznačně vyplatí.
2. Vytvořit metriku, která bude odrážet hodnoty a cíle, které ve výuce vnímáme jako důležité, nikoli jen ty snadno identifikovatelné.
3. Definovat a integrovat elementy inovací, tak, aby nepůsobily kontradikčně.
4. Pracovat jen s kvalitními a validními daty.
5. Testovat uvážlivě a s rozmyslem. Cílem testů není získat kompletní informaci o všem, ale relevantní data k inovacím.
6. Podporovat a šířit ochotu inovovat a měřit efektivitu vzdělávání.
7. Systematicky provádět evoluční změny, které umožní měřit pokroky či zlepšení.
8. Snažit se umenšit propast mezi nejhoršími a nejlepšími studenty.
9. Podporovat a rozvíjet učící se komunity.
10. Podporovat vertikální rozdělení zodpovědnosti za vyučovaný obsah i výsledky vzdělávání, vtáhnout do tohoto procesu také studenty.
11. Určovat trendy a vést vzdělávání za svým cílem, nikoli být prostým vykonavatelem doporučení statistiky či metriky.
12. Vytvořit standard, který povede ke kodifikaci a přenositelnosti výsledků měření.

Těchto dvanáct bodů, které vycházejí z myšlenek akčního výzkumu, je jistě během implementace daty řízeného vzdělávání nutné reflektovat. Dovolím si připojit ještě jeden bod – učitelé by měli mít dobré znalosti matematiky, statistiky a metodologie, aby uměli s daty dobře pracovat, provádět si vlastní zpracování a analýzy, kterými budou zjišťovat to, co je pro ně v daný okamžik důležité.

## Závěr

Rozhodovat se podle dostupných dat není ničím novým či inovativním. Ve firemním prostředí je dlouhodobě prosazován koncept business intelligence<sup>10</sup>, který má za cíl podpořit rozhodování manažerů reálnými a kvalitními daty. To v sobě jistě skrývá řadu rizik, z nichž nejmarkantnější je tupý inženýrský přístup, kdy vlastní osobnost a zkušenost manažera nehraje žádnou roli a dochází k řízení firmy jen na základě dat. Taková organizace nemá žádnou vlastní vizi či kulturu a je dříve nebo později určena k zániku. Na situaci, kdy budeme moci hovořit o school intelligence, tedy o rozhodovacím procesu, který bude pomáhat řediteli či učitelům řídit celé vzdělávání na základě dat, si budeme muset zřejmě ještě nějaký čas počkat. Tak jako v případě firem, také školám mohou data pomoci být podstatně lepší než bez nich, ale tím se nijak neumenšuje role pedagoga.

<sup>7</sup> HILL, Phil. *Differentiated, Personalized & Adaptive Learning: some clarity for EDUCAUSE*. 2013.

<sup>8</sup> HAMDAN, Noora; MCKNIGHT, Patrick; MCKNIGHT, Katherine. et al. *A Review of Flipped Learning*. 2013.

<sup>9</sup> HARGREAVES, Andy; BRAUN, Henry. *Data-Driven Improvement and Accountability*.

<sup>10</sup> Podrobněji viz například LIAUTAUD, Bernard; HAMMOND, Mark. *e-Business intelligence: turning information into knowledge into profit*.

Informační věda má v této oblasti velice dobrou pozici, kterou může zásadním způsobem přispívat k rozvoji vzdělávání a budování funkčních LMS. Předně jde o metadatový popis jednotlivých učebních objektů a repozitářů, které jsou nezbytné proto, aby student mohl dostávat takový vzdělávací obsah a formu, jakou právě potřebuje. Bude nutné se zásadním způsobem zamyslet nad tím, zda obyčejný popis pomocí Marc21 či Dublin Code<sup>11</sup> skutečně odpovídá tomu, co potřebují moderní systémy. Velký vliv by měla mít na návrh těchto informačních systémů, na studium informačního chování a prostředí nebo na samotnou analýzu dat. Daty řízené vzdělávání je tak velkou výzvou, které je vhodné věnovat patřičný prostor v oborovém vědeckém bádání.

## Literatura

BRDIČKA, Bořivoj. Daty řízené školství, politika a technologie. *Metodický portál: Články* [online]. 24. 05. 2010, [cit. 2014-04-24]. Dostupný z <http://spomocnik.rvp.cz/clanek/10813/DATY-RIZENE-SKOLSTVI-POLITIKA-A-TECHNOLOGIE.html>. ISSN 1802-4785.

BRDIČKA, Bořivoj. Jsou velká data velkým potenciálem nebo velkou chybou?. *Metodický portál: Články* [online]. 31. 03. 2014, [cit. 2014-04-22]. Dostupný z <http://spomocnik.rvp.cz/clanek/18645/JSOU-VELKA-DATA-VELKYM-POTENCIALEM-NEBO-VELKOU-CHYBOU.html>. ISSN 1802-4785.

BRDIČKA, Bořivoj. Skutečné možnosti využití daty řízeného školství. *Metodický portál: Články* [online]. 12. 09. 2011, [cit. 2014-04-24]. Dostupný z <http://spomocnik.rvp.cz/clanek/13511/SKUTECNE-MOZNOSTI-VYUZITI-DATY-RIZENHO-SKOLSTVI.html>. ISSN 1802-4785.

HAMDAN, Noora; MCKNIGHT, Patrick; MCKNIGHT, Katherine. et al. *A Review of Flipped Learning*. 2013. [cit. 2013-8-14]. Dostupný z [http://flippedlearning.org/cms/lib07/VA01923112/Centricity/Domain/41/LitReview\\_FlippedLearning.pdf](http://flippedlearning.org/cms/lib07/VA01923112/Centricity/Domain/41/LitReview_FlippedLearning.pdf).

HARGREAVES, Andy; BRAUN, Henry. Data-Driven Improvement and Accountability. *Boston College: National Education Policy Center*. Retrieved October, 2013, 24: 2013.

HILL, Phil. *Differentiated, Personalized & Adaptive Learning: some clarity for EDUCAUSE*. 2013. [cit. 2014-3-30]. Dostupný z <http://mfeldstein.com/differentiated-personalized-adaptive-learning-clarity-educause/>.

CHANDLER, Adam; FOLEY, Dan; HAFEZ, Alaaeldin M. Mapping and Converting Essential Federal Geographic Data Committee (FGDC) Metadata into MARC21 and Dublin Core. *D-Lib magazine*, 2000, 6.1: 1082-9873.

LIAUTAUD, Bernard; HAMMOND, Mark. *e-Business intelligence: turning information into knowledge into profit*. McGraw-Hill, Inc., 2000.

WELLER, Martin. *5 things I think about Learning Analytics*. 2011. [cit. 2013-07-10]. Dostupný z [http://nogoodreason.typepad.co.uk/no\\_good\\_reason/2011/03/5-things-i-think-about-learning-analytics-.html](http://nogoodreason.typepad.co.uk/no_good_reason/2011/03/5-things-i-think-about-learning-analytics-.html)

*Příspěvek byl napsán v rámci řešení operačního programu Vzdělávání pro konkurenceschopnost: Centrum informačního vzdělávání: rozvoj informační gramotnosti na MU (CEINVE), Reg. č.: CZ.1.07/2.2.00/28.0241.*

**Mgr. Michal Černý**  
mcerny@phil.muni.cz  
(Masarykova univerzita, Brno) ■



<sup>11</sup> CHANDLER, Adam; FOLEY, Dan; HAFEZ, Alaaeldin M. Mapping and Converting Essential Federal Geographic Data Committee (FGDC) Metadata into MARC21 and Dublin Core