

Juhaňák, Libor

Dosavadní směry výzkumů a řešená témata

In: Juhaňák, Libor. *Analytika učení a data mining ve vzdělávání v kontextu systémů pro řízení výuky*. Vydání první Brno: Masarykova univerzita, 2023, pp. 59-88

ISBN 978-80-280-0184-1; ISBN 978-80-280-0185-8 (online ; pdf)

Stable URL (handle): <https://hdl.handle.net/11222.digilib/digilib.77694>

Access Date: 18. 02. 2024

Version: 20230228

Terms of use: Digital Library of the Faculty of Arts, Masaryk University provides access to digitized documents strictly for personal use, unless otherwise specified.

6 DOSAVADNÍ SMĚRY VÝZKUMŮ A ŘEŠENÁ TÉMATA

V této kapitole jsou představeny vybrané výzkumné směry a témata, kterým je v rámci analytiky učení a data miningu ve vzdělávání věnována hlavní výzkumná pozornost výzkumníků. Vzhledem k tomu, že je cílem této kapitoly podat obecný přehled o dění v jednotlivých řešených oblastech, neusiluje tato část o systematický přehled, nýbrž je zde zaměřena pozornost pouze na ty směry a ta témata, která lze v analytice učení a data miningu ve vzdělávání považovat za nejvíce akcentovaná či aktuální. Opírám se přitom jednak o řadu přehledově orientovaných publikací (především Baker & Inventado, 2014; Baker & Yacef, 2009; Bakhshinateg, Zaiane, ELAtia, & Ipperciel, 2018; Buckingham Shum & Ferguson, 2012; Dutt, Ismail, & Herawan, 2017; Lang, Siemens, Wise, & Gašević, 2017; Papamitsiou & Economides, 2014; Peña-Ayala, 2014b, 2017; Romero & Ventura, 2007, 2010, 2013; Siemens, 2013), jednak také zohledňuji témata, která se s vyšší frekvencí objevují v rámci mezinárodních konferencí zaměřených specificky na tyto oblasti³¹.

Zároveň není možné alespoň z části nezmínit i určitý vývoj, jímž obě oblasti v průběhu posledních let prošly. Vezmeme-li si za příklad analytiku učení, pak lze říci, že v počátcích bylo množství výzkumů a publikací spojeno spíše s vývojem konkrétních analytických či vizualizačních nástrojů. Teprve později se začala pozornost postupně přesouvat ke složitějším prediktivním nástrojům a obecně k hledání možných prediktorů (ne)úspěchu ve studiu. Současně si mnozí autoři začali uvědomovat širší souvislosti fenoménu učení s využitím moderních technologií, a proto se nyní snaží přesunout pozornost např. k jeho sociálním či emočním aspektům. Postupem času také sílí důraz na etické aspekty využívání analy-

31 V oblasti data miningu ve vzdělávání jde primárně o konferenci s názvem *International Conference on Educational Data Mining*, v rámci analytiky učení jde především o konferenci s názvem *International Learning Analytics and Knowledge Conference*.

tiky ve vzdělávání, kterým byla zpočátku věnována pouze sporadická pozornost. Obdobný vývoj je patrný i v oblasti data miningu ve vzdělávání. V následujících podkapitolách se tak alespoň dílčím způsobem snažím reflektovat a nastínit i dosavadní vývoj jednotlivých směrů a témat výzkumu. Zároveň podávám informaci o tom, nakolik je daná oblast relevantní spíše pro data mining ve vzdělávání, nebo naopak pro analytiku učení. Ovšem s ohledem na značný průnik mezi oběma oblastmi je třeba počítat s tím, že v řadě případů se jednotlivé směry výzkumů promítají více či méně do obou oblastí.

Dříve než přesunu pozornost přímo k jednotlivým výzkumným směrům, je nutné doplnit, že jak data mining ve vzdělávání, tak i analytika učení jsou orientovány výrazně prakticky či aplikačně. Tím je myšleno, že řada výzkumů v této oblasti je zároveň spojena s vývojem určitého analytického nástroje. Proto je v následující tabulce (viz tabulka 4) nejprve podán stručný přehled analytických a vizualizačních nástrojů či systémů, které jsou v tomto kontextu využívány a kterým je zároveň věnována určitá výzkumná pozornost. Na jednotlivé nástroje uvedené v tabulce je pak dále odkazováno v navazujících podkapitolách.

Některé další analytické nástroje a příklady využití analytických systémů na institucionální či národní úrovni zmiňuje Fergusonová et al. (2016). Přehled vybraných nástrojů z oblasti data miningu ve vzdělávání uvádí ve své studii i Romero a Ventura (2013) či Peña-Ayala (2014b). Přehled několika novějších spíše vizualizačních nástrojů v kontextu analytiky učení pak nabízí opět Peña-Ayala (2018).

Tabulka 4: Přehled vybraných analytických nástrojů a systémů a jejich stručný popis

Název nástroje	Využívaná data	Stručný popis nástroje	Související publikace
<i>AAT - Academic Analytics tool</i>	LMS/VLE	analýza chování studentů v rámci konkrétních výukových aktivit v kurzu	Graf, Ives, Rahman, & Ferri (2011)
<i>ASSISTments</i>	vlastní data	inteligentní tutorský systém	Heffernan & Heffernan (2014)
<i>AutoTutor</i>	vlastní data	inteligentní tutorský systém	D'Mello & Graesser (2012)
<i>CMA - Check My Activity</i>	LMS/VLE	vizualizace aktivity studentů v kurzu za účelem poskytnutí včasné zpětné vazby a srovnání se studijním pokrokem ostatních studentů v kurzu	Fritz (2011)
<i>Cognitive Tutor</i>	vlastní data	inteligentní tutorský systém	Koedinger & Corbett (2006)
<i>Coh-metrix</i>	vlastní data, texty studentů	analýza různých typů písemných prací studentů (eseje, seminární práce, příspěvky v diskuzních fórech apod.)	McNamara, Graesser, McCarthy, & Cai (2014)

Název nástroje	Využívaná data	Stručný popis nástroje	Související publikace
<i>Course Signals</i>	LMS/VLE	predikce úspěšnosti a identifikace rizikových studentů	Arnold & Pistilli (2012)
<i>EIWM - E-learning Web Miner</i>	LMS/VLE	analýza chování studentů v rámci konkrétních výukových aktivit v kurzu	García-Saiz & Zorilla Pantaleón (2011)
<i>eLAT - exploratory Learning Analytics Toolkit</i>	LMS/VLE	vizualizace aktivity studentů v kurzu	Dyckhoff, Zielke, Bultmann, Chatti, & Schroeder (2012)
<i>GLASS</i>	LMS/VLE	vizualizace aktivity studentů v kurzu	Leony, Pardo, de la Fuente Valentín, de Castro, & Kloos (2012)
<i>Meerkat-ED</i>	LMS/VLE	analýza sociální sítě a vizualizace aktivity studentů v diskuzních fórech	Rabbany, ElAtia, Takaffoli, & Zaiane (2014)
<i>NAT - Network Awareness Tool</i>	vlastní data	vizualizační nástroj na podporu informálního učení v organizacích	Schreurs & De Laat (2012)
<i>OpenEssayist</i>	vlastní data, texty studentů	poskytování automatizované zpětné vazby studentům na jejich písemné práce	Whitelock et al. (2015)
<i>OU Analyse</i>	LMS/VLE, SIS	predikce úspěšnosti a identifikace rizikových studentů	Kužilek et al. (2015)
<i>SAM - Student Activity Meter</i>	LMS/VLE	vizualizace aktivity studentů za účelem podpory reflexe vlastního učení	Govaerts, Verbert, Duval, & Pardo (2012)
<i>SNAPP - Social Networks Adapting Pedagogical Practice</i>	LMS/VLE	analýza sociální sítě a vizualizace aktivity studentů v diskuzních fórech	Dawson, Bakharia, & Heathcote (2010)
<i>StepUp!</i>	LMS/VLE	vizualizace aktivity studentů za účelem podpory reflexe vlastního učení	Santos et al. (2013)

6.1 Analytické nástroje pro sumarizaci a vizualizaci dat

Velké množství pozornosti bylo v rámci analytiky učení (zvláště pak v jejích raných fázích) i v rámci data miningu ve vzdělávání věnováno vývoji různých analytických či data miningových nástrojů pro sumarizaci a vizualizaci dat. V souvislosti s analytikou učení bývají tyto nástroje často označovány jako *learning analytics dashboards* a lze je charakterizovat tím, že využívají vizualizaci dat a relativně jednoduché statistiky či metriky (např. četnosti, průměry apod.) jakožto dvě hlavní analytické techniky. Primárním úkolem těchto nástrojů je sumarizování či vizualizace dat

z různých online výukových prostředí za účelem poskytnutí důležitých informací odpovídajícím zúčastněným stranám, případně i s možností hlubšího prozkoumávání relevantních aspektů týkajících se učení v online prostředí (Klerkx, Verbert, & Duval, 2017). Zvláště v ranějších fázích rozvoje analytiky učení a data miningu ve vzdělávání bylo přitom nejvíce pozornosti věnováno takovým nástrojům, které byly určeny pedagogům, tutorům či administrátorům online kurzů, přičemž jim měly pomáhat analyzovat aktivitu studentů v kurzech (Romero & Ventura, 2010).

Postupem času se však zaměření jednotlivých *learning analytics dashboards* rozšiřovalo a v současnosti existuje řada nástrojů různých typů určených pro různé zúčastněné strany. Existují tak např. nástroje jako *CMA*, *SAM* či *StepUp!*, které jsou určené pro studenty a jež mají podporovat jejich reflexi vlastního procesu učení. Tyto nástroje poskytují studentům informace např. o tom, kolik času tráví studiem různých materiálů, jak si vedou s ohledem na doporučený studijní plán či v porovnání s jinými studenty v kurzu apod. Na druhé straně jsou pak již zmiňované nástroje poskytující užitečné informace primárně učitelům, např.: *AAT*, *EIWM*, *eLAT* či *GLASS*. Jde o nástroje, které mají vyučujícím pomoci monitorovat chování studentů v online kurzech. To často činí prostřednictvím přehledné vizualizace aktivity studentů, příp. nabízejí možnost srovnávání různých skupin studentů apod. Lze rovněž nalézt nástroje jako *Cohere*, *NAT* či *SNAPP* zaměřující se na využití metod analýzy sociálních sítí. V tomto kontextu za explicitní zmínku stojí relativně komplexní nástroj *Meerkat-ED*, který je určený zejména výzkumníkům a který může být poměrně snadno použit pro analýzu interakce studentů v online diskuzních fórech v LMS.

Zájem o problematiku *learning analytics dashboards* pokračuje až do současnosti a lze předpokládat, že tento výzkumný směr bude relevantní i v následujících letech. Zároveň je zde ale patrný určitý posun pozornosti jednak směrem ke komplexnějším či specifičtěji zaměřeným analyticko-vizualizačním nástrojům, jednak směrem k výzkumu toho, jak se využívání určitého nástroje tohoto typu (ať již studenty, či učiteli) promítá do samotného učení a výuky v online prostředí. Výzkumníci z oblasti analytiky učení přitom vykazují větší zájem spíše o otázky související s vizualizací, způsobem prezentace dat a širším kontextem využívání těchto nástrojů v průběhu výuky (Klerkx, Verbert, & Duval, 2017; Wise & Vytasek, 2017). Naopak v oblasti data miningu ve vzdělávání je kladen větší důraz na zkoumání možností využití pokročilejších data miningových metod pro odhalování potenciálně zajímavých či užitečných informací v datech. Místo relativně jednoduchých statistik, vizualizací či reportů jsou tak využívány pokročilejší metody jako dolování asociačních pravidel, shlukování, klasifikace či dolování sekvencí (Romero & Ventura, 2010).

V data miningu ve vzdělávání je přitom věnována hlavní pozornost analytickým nástrojům určeným primárně pro učitele, tutorů a administrátory online kurzů či online vzdělávacích prostředí. Romero a Ventura (2010) dokonce v této souvislosti

hovoří o samostatném specifickém směru výzkumu, který se zaměřuje na zkoumání možností využití data miningových metod pro automatizované poskytování podpůrné zpětné vazby učitelům či instruktorům v kurzu. Naopak v oblasti analytiky učení je větší pozornost věnována analyticko-vizualizačním nástrojům určeným pro studenty. Přitom jsou akcentovány především možnosti využití těchto nástrojů pro podporu seberegulace a seberegulovaného učení (*self-regulated learning*). K dispozici jsou již i systematické přehledové studie zaměřující se přímo na *learning analytics dashboards* a mapující dosavadní výzkum v této oblasti (viz Bodily & Verbert, 2017; Matcha, Uzir, Gašević, & Pardo, 2019; Schwendimann et al., 2017).

6.2 Predikce úspěšnosti a identifikace rizikových studentů

Za druhý významný směr výzkumů v oblasti analytiky učení a data miningu ve vzdělávání lze považovat snahu o predikci (ne)úspěchu studentů v jejich studiu, resp. identifikaci tzv. rizikových studentů³². Obecným úkolem predikce je odhad hodnoty určité proměnné. V tomto případě jde nejčastěji o proměnnou, která se týká úspěšnosti či výkonu studenta a jež je obvykle vyjádřena v podobě známky či určitého skóru. Má-li tato proměnná kategorický charakter, např. binární indikátor typu prospěl/neprospěl či známka na škále A až F, jde o predikci klasifikačního typu. Má-li naopak daná proměnná charakter čísla, například při predikci výkonu studenta v závěrečném testu, jedná se o prediktivní úlohu regresního typu, u níž jsou používány jiné typy metod než v případě klasifikace (viz kapitolu 5.1 Prediktivní metody).

V obou případech je přitom cílem správně predikovat úspěšnost či výkon studenta co možná nejdříve v průběhu kurzu či studia, aby tak bylo možné včas identifikovat ty studenty, kterým hrozí, že nebudou schopni úspěšně absolvovat kurz či dokončit své studium. Výsledky takové predikce totiž mohou být použity při efektivnější intervenci a podpoře rizikových studentů (Clow, 2013). Při vývoji systémů zaměřených na tento typ predikce se pak často hovoří o tzv. systémech včasného varování (*early warning systems – EWS*), jejichž cílem je právě co možná nejvčasnější identifikace rizikových studentů. Tyto systémy jsou schopny upozornit vyučujícího na rizikové studenty a ten se následně může rozhodnout, jakým způsobem bude danou situaci řešit. Zbývá dodat, že predikci úspěšnosti či výkonu studenta lze považovat za jedno z nejstarších a zároveň nejčastěji řešených témat v oblasti data miningu ve vzdělávání i v analytice učení (srov. Bakhshinategh, Zaiane, ElAtia, & Ipperciel, 2018; Papamitsiou & Economides, 2014; Peña-Ayala, 2018; Romero & Ventura, 2010).

³² Za „rizikové“ studenty jsou v tomto kontextu považováni ti studenti, kterým z jakéhokoli důvodu hrozí, že nebudou schopni dokončit konkrétní kurz či studium obecně.

Jedním z prvních a pravděpodobně i nejčastěji zmiňovaným příkladem takového systému v odborné literatuře je nástroj *Course Signals* (viz tabulka 4), který byl vyvinut na *Purdue University*. Tento nástroj se zaměřuje na predikci (ne)úspěšnosti studentů v online kurzu, přičemž z pohledu uživatele se může zdát poměrně jednoduchým. Jeho základní funkcí je totiž pro každého studenta v kurzu zobrazit jednu z barev semaforu (červená, žlutá, zelená) na základě vypočtené pravděpodobnosti, zda daný student úspěšně absolvuje kurz. Červená barva značí vysokou pravděpodobnost, že student kurz nedokončí, žlutá značí možné problémy či zvýšené riziko nedokončení a zelená barva je určena pro studenty, u nichž je predikována vysoká pravděpodobnost úspěšného dokončení kurzu. Za touto jednoduchou vizualizací se však skrývá poměrně komplexní výpočet kombinující čtyři různé složky: 1) dosavadní výkon studenta v kurzu, 2) množství dosavadní interakce v rámci LMS ve srovnání s ostatními účastníky kurzu, 3) předchozí studijní úspěšnost a 4) další převážně demografické charakteristiky studenta jako věk, trvalý pobyt apod. Dosavadní výsledky pak naznačují, že využití tohoto nástroje přispívá nejen k vyšší úspěšnosti studentů v jednotlivých kurzech, ale také ke snížení počtu studentů, kteří studium na univerzitě ukončí neúspěšně (Arnold & Pistilli, 2012)³³.

Jak již bylo zmíněno, v případě predikce úspěšnosti a identifikace rizikových studentů jde o velmi významné téma v data miningu ve vzdělávání i v analytice učení. Lze se tak setkat s řadou studií věnujících se tomuto tématu, a to jak se studii staršího data (např. Lykourantzou, Giannoukos, Nikolopoulos, Mpardis, & Loumos, 2009; Macfadyen & Dawson, 2010), tak s výzkumy relativně aktuálními (např. Costa, Fonseca, Santana, de Araújo, & Rego, 2017; Howard, Meehan, & Parnell, 2018; Marbouti, Diefes-Dux, & Madhavan, 2016). Jednotlivé studie se liší mimo jiné použitými prediktivními technikami (vedle lineární a logistické regrese bývají využívány např. podpurné vektory, rozhodovací stromy, náhodný les, umělé neuronové sítě či naivní Bayesův klasifikátor), typy dat, které pro účely predikce využívají (nejčastěji data o aktivitě studentů v daném kurzu a data o předchozí úspěšnosti studentů ve studiu³⁴), či samotnou proměnnou, kterou se snaží predikovat (jak již bylo naznačeno výše, může jít o známku za kurz, skóre v závěrečném testu apod.).

Za zmínku stojí rovněž to, že této problematice je věnována pozornost i v českém kontextu. Již relativně dlouho se této problematice věnuje několik českých

33 V případě nástroje *Course Signals* nejsou upozorňováni pouze vyučující kurzu, nýbrž nástroj současně upozorňuje studenty, kterým posílá automaticky generovaný e-mail s varováním, že jim hrozí nedokončení kurzu. Studenti tak mohou po obdržení této informace okamžitě reagovat a podniknout kroky pro snížení rizika neúspěchu.

34 Najdou se ovšem i specificky zaměřené studie, které se záměrně snaží predikovat úspěšnost na základě omezené a specificky zaměřené sady dat. Např. Akçapınar, Hasnine, Majumdar, Flanagan a Ogata (2019) se zaměřují primárně na data týkající se toho, jak studenti využívají e-knihy. Saqr, Fors a Nouri (2018) věnují pozornost datům pocházejícím z online diskuzních fór apod.

výzkumníků, kteří se podíleli mimo jiné na vývoji nástroje *OU Analyse*, jenž byl vyvinut a je doposud rozvíjen v rámci *Knowledge Media Institute na Open University*. Tento nástroj kombinuje demografické údaje o studentech s daty o jejich aktivitě v LMS Moodle a pro identifikaci rizikových studentů využívá hlasování čtyř různých prediktivních modelů (Kužílek, Hlosta, Herrmannová, Zdráhal, & Wolff, 2015). V současnosti tento výzkum pokračuje přímo v České republice na Českém vysokém učení technickém v Praze, kde Kužílek řeší juniorský projekt podpořený Grantovou agenturou České republiky (GAČR) s názvem *Predictive modeling of student performance using learning resources* (číslo projektu: 18-04150Y). Problematicke se věnuje i několik výzkumníků na Fakultě informatiky Masarykovy univerzity (viz např. Bayer, Bydžovská, Géryk, Obšiač, & Popelínský, 2012; Bydžovská, 2016a; Bydžovská & Popelínský, 2013; Géryk & Popelínský, 2014).

6.3 Modelování studentů

Dalším významným směrem výzkumu v oblasti analytiky učení a obzvláště v data miningu ve vzdělávání je modelování studentů (*student modeling*). Jde o směr výzkumu, který může být chápán jako poměrně blízký výše zmiňované predikci úspěšnosti, což někteří autoři akcentují tím, že oba směry zařazují do jedné kategorie (např. Bakhshinategh, Zaiane, ElAtia, & Ipperciel, 2018). Jiní autoři (např. Papamitsiou & Economides, 2014; Romero & Ventura, 2010) však tyto oblasti oddělují, jelikož i přes občasné používání relativně blízkých analytických metod a technik mají oba směry zásadně odlišné cíle a způsoby praktického uplatnění. Předně, jak naznačuje samotné označení obou směrů výzkumu, je cílem predikce úspěšnosti získat předpověď či odhad toho, zda student úspěšně dokončí kurz, případně celé studium. Cílem je tedy na základě současných (respektive v současnosti dostupných) dat odhadnout, jaká je pravděpodobnost, že daný student bude na konci kurzu úspěšný. Oproti tomu modelování studentů se nesnaží predikovat budoucí stav, nýbrž se snaží modelovat stav současný. To znamená, že místo odhadování, zda student za několik měsíců úspěšně dokončí kurz, se při modelování studentů snažíme zjistit například současnou úroveň znalostí studenta v rámci studovaného obsahu.

S výše uvedenými odlišnými cíli pak souvisí i odlišné způsoby využívání. Zatímco predikce úspěšnosti studentů se v praxi využívá téměř výhradně v kontextu zmiňovaných systémů včasného varování (EWS), modelování studentů je využíváno především pro účely personalizace či adaptace. Najde tak praktické uplatnění například v inteligentních tutorských systémech (např. tutorské systémy *ASSISTments* a *Cognitive Tutor*, viz tabulka 4) či v různých typech adaptivních systémů (Baker & Inventado, 2014; Bakhshinategh, Zaiane, ElAtia, & Ipperciel, 2018; Peña-Ayala, 2014b).

Konkrétně lze modelování studentů chápat jako proces shromažďování relevantních informací s cílem odhadnout či odvodit určité aspekty či charakteristiky

studenta a následně je kvantitativně reprezentovat v podobně modelu, který může být využit pro automatizovanou adaptaci či personalizaci vzdělávacího obsahu či prostředí (srov. Chrysafiadi & Virvou, 2013; Peña-Ayala, 2014b; Sani, Bichi, & Ayuba, 2016). Mezi modelované aspekty či charakteristiky studentů patří například znalosti, resp. úroveň znalostí, dovednosti, chyby a miskoncepce, učební strategie či preference, chování studenta (např. při plnění určitého úkolu), afektivní stavy a emoce či různé kognitivní a meta-kognitivní faktory (Bousbia & Belamri, 2014). Z tohoto množství charakteristik se pozornost výzkumníků zaměřuje především na tři typy modelování studentů, které krátce představím a popíši v následujících podkapitolách. Konkrétně jde o modelování znalostí a dovedností studentů, modelování chování studentů a modelování emocí a afektivních stavů studentů (srov. Bakhshinategh, Zaiane, ElAtia, & Ipperciel, 2018; Papamitsiou & Economides, 2014; Peña-Ayala, 2014b).

6.3.1 Modelování znalostí a dovedností studentů

Oblast modelování znalostí a dovedností lze považovat za nejtypičtějšího zástupce modelování studentů. To je dáno mimo jiné poměrně dlouhou historií této oblasti, která v určitých ohledech sahá daleko za oblast data miningu ve vzdělávání či analytiku učení a má výrazné styčné plochy s problematikou testování (zvláště pak počítačového adaptivního testování) v rámci psychologického výzkumu. Současně se jedná o jednu z velmi živých (a dnes již poměrně obsáhlých) oblastí výzkumu v kontextu data miningu ve vzdělávání. To ostatně dokládá hned několik přehledových studií věnujících se tomuto tématu. Zvláštní pozornost si přitom zaslouží především studie Pelánka (2017), která se zaměřuje specificky na modelování znalostí a dovedností. Zmínit lze však i několik dalších, obecněji pojatých přehledů (např. Desmarais & Baker, 2012; Chrysafiadi & Virvou, 2013; Sani, Bichi, & Ayuba, 2016).

Modelování znalostí je přitom oproti ostatním typům modelování studentů asi nejužší spojeno s problematikou adaptivních systémů (viz níže kapitolu 6.4) a inteligentních tuteorských systémů, jako jsou výše zmíněné *ASSISTments* (Heffernan & Heffernan, 2014) či *Cognitive Tutor* (Koedinger & Corbett, 2006), v jejichž rámci nachází modelování znalostí své hlavní praktické uplatnění. A ačkoli nejrůznější adaptivní a inteligentní tuteorské systémy mohou stavět i na modelování chování či emocí a afektivních stavů studentů, model znalostí či dovedností studenta lze obecně považovat za jejich základní složku.

Za primární cíl modelování znalostí a dovedností můžeme stejně jako Pelánek (2017) považovat odhadování současného stavu znalostí či dovedností studentů spolu s predikcí jejich budoucího výkonu, a to na základě údajů o jejich dosavadních výkonech (tj. např. jak daný student odpovídal na dosavadní otázky). Samotné modelování znalostí či dovedností je relativně komplexním procesem, do něhož

vstupuje řada faktorů. Lze zmínit například znalostní doménu, ve které se pohybujeme (výuka jazyka, výuka programování apod.), typ znalosti či dovednosti, která má být modelována (např. učení se jednoduchým faktům versus učení se komplexním dovednostem), účel modelu, resp. způsob využití jeho výstupů (adaptace obsahu, vizualizace pokroku studenta v rámci dané znalostní domény atd.), či dostupná data, která mohou být využita pro účely modelování (srov. Pelánek, 2017). Všechny tyto faktory se přitom mohou odrážet v tom, jakou techniku či postup při modelování zvolíme. Pro účely základního přehledu je přitom užitečné provést obecné rozlišení na dva základní typy modelů, kterým zároveň odpovídají dvě různé formy adaptace a dva základní způsoby využití v rámci adaptivních, respektive tutorovacích systémů (srov. Desmarais & Baker, 2012; Pelánek, 2017; Essa, 2016). Jedná se o vnitřní kognitivní model a vnější kognitivní model.³⁵

V případě vnitřního kognitivního modelu se zaměřujeme na postup studenta při řešení jednoho konkrétního problému či jedné úlohy. V tomto smyslu se tedy pohybujeme „uvnitř“ konkrétní úlohy a nevěnujeme se otázkám souvisejícím s přecházením mezi různými úlohami. Zároveň nás v kontextu vnitřních kognitivních modelů zajímají složitější problémy, jejichž řešení sestává z posloupnosti většího množství kroků. Tento typ modelů je tak využíván spíše v systémech, které se zaměřují na výuku komplexnějších znalostí či dovedností. Takové adaptivní systémy pak pro každou úlohu obsahují nejen informaci o jejím správném řešení, ale také o správné posloupnosti kroků, která k takovému řešení vede. Daný adaptivní systém (obvykle systém typu ITS) pak sleduje aktivitu studenta při plnění úlohy a dokáže mu v průběhu jejího řešení poskytovat personalizovanou zpětnou vazbu (např. v podobě vysvětlení, proč je daný způsob řešení chybný, či v podobě nápovědy, jak správně postupovat při řešení problému). Proto se v souvislosti s vnitřním kognitivním modelem hovoří o mikroadaptaci, kdy adaptace systému probíhá nikoli na úrovni úloh (a tudíž obsahu jako takového), nýbrž na úrovni zpětné vazby v rámci dané úlohy.

Naopak v případě vnějšího kognitivního modelu nás tolik nezajímá, co se děje „uvnitř“ konkrétní úlohy, nýbrž věnujeme primární pozornost pořadí jednotlivých úloh, respektive tomu, jakou další úlohu dát studentovi k řešení. Adaptace tak v systémech tohoto typu probíhá na úrovni úloh, tj. každý uživatel dostává jiný obsah – buď dostává zcela jiné úlohy, anebo dostává z části stejné úlohy, ale ale v jiném, jemu uzpůsobeném pořadí. Proto se v tomto případě hovoří o makroadaptaci. Oproti vnitřním jsou ve vnějších kognitivních modelech využívány spíše úlohy

35 Toto či obdobné rozlišení je v literatuře činěno za pomoci různých pojmů (srov. Desmarais & Baker, 2012; Essa, 2016; Pelánek, 2017). Někteří autoři hovoří o vnitřní a vnější smyčce (*inner loop*, *outer loop*) v rámci modelování znalostí, jiní o mikroadaptaci a makroadaptaci (*micro-adaptation* a *macro-adaptation*, případně *microadaptivity* a *macroadaptivity*), další pak o přístupu založeném na analýze řešení problému (*problem solving and solution analysis*) a přístupu založeném na analýze řešení kurikula (*curriculum sequencing*). V této publikaci se přidržuji rozlišení, které používá např. Essa (2016), jenž v návaznosti na vnitřní a vnější smyčku hovoří o vnitřních a vnějších kognitivních modelech (*inner and outer cognitive models*).

jednoduchého charakteru (často v podobě výběru z možností), a vnější kognitivní modely jsou tak využívány především v adaptivních systémech zaměřujících se na výuku či procvičování faktických znalostí. Daný adaptivní systém pak v základní podobě funguje tak, že sleduje a vyhodnocuje, jak student odpovídal na předchozí úlohy (tj. zda odpověděl správně, či špatně). Na základě toho odhaduje úroveň znalostí studenta a nabízí mu další úlohu odpovídající úrovně náročnosti.

V rámci obou těchto typů modelů se v současnosti používají různé způsoby či techniky modelování znalostí a dovedností. V případě vnitřních kognitivních modelů patří mezi relativně často využívané přístupy například tzv. modelování založené na omezeních (*constraint-based modeling*) či modely založené na pravidlech, které Pelánek (2017) nazývá *model tracing models*. Jak již název napovídá, modely založené na pravidlech sestávají ze sady pravidel typu „jestliže-pak“, které specifikují možné postupy při řešení dané úlohy. Naproti tomu modely založené na omezeních se nesnaží přesně vymezit možné způsoby řešení, nýbrž sestávají ze sady omezení, jež musí studentovo řešení úlohy splnit. V případě vnějších kognitivních modelů pak patří mezi často zastoupené techniky např. modelování označované jako *performance factor analysis* či jiné formy logistických modelů. Obecně je však zřejmě nejvíce pozornosti (alespoň v kontextu data miningu ve vzdělávání) věnováno technice označované jako *bayesian knowledge tracing* (BKT), kterou již v roce 1994 představili Corbett a Anderson (1994). Od jejího představení pak řada autorů pracovala na různých způsobech obohacení, respektive rozšíření BKT. A to např. s ohledem na individualizaci BKT a na zahrnutí parametrů specifických pro jednotlivé studenty, v souvislosti s integrací obtížnosti položek do modelu, či s ohledem na odhadování počáteční pravděpodobnosti, že student již má danou znalost či dovednost (srov. Desmarais & Baker, 2012; Pelánek, 2017).

6.3.2 Modelování chování studentů

Druhou oblastí modelování studentů, která je významně zastoupena zvláště v kontextu data miningu ve vzdělávání, je modelování chování studentů. Oproti předchozí oblasti, zaměřující se na znalosti a dovednosti studentů, se zde výzkumníci věnují spíše tomu, jak se studenti chovají. Jde přitom primárně o chování související s učením³⁶, čili se obvykle zkoumá chování studentů v určitém online vzdělávacím prostředí, případně i specificky v průběhu konkrétní výukové aktivity jako např. při vyplňování testu, při práci na zadaném úkolu, při práci ve skupině apod. Předmětem modelování se pak stávají různé typy či rysy chování studentů v závislosti na konkrétním typu výukové aktivity. Například při vyplňování testu může

³⁶ Zvláště v angličtině též označované jako „učební chování“ (*learning behavior*). Odpovídajícím způsobem se pak hovoří též o modelování učebního chování (*learning behavior modeling*).

jít o identifikaci hádání či tipování odpovědí místo jejich korektního zodpovídání (tzv. *guessing behavior*). V případě práce na zadaném úkolu bývá věnována pozornost takovému chování, kdy student neví, jak úkol splnit či jak má dál postupovat, a tudíž vyžaduje či hledá nějakou pomoc (tzv. *help-seeking behavior*). U skupinové práce pak může být mapováno např. chování související s ochotou spolupracovat (*willingness to collaborate*) či mohou být modelovány různé způsoby participace jednotlivých studentů ve skupině (viz Baker & Inventado, 2014; Papamitsiou & Economides, 2014, 2016; Peña-Ayala, 2014b).

Napříč různými typy výukových aktivit je pak relativně častým zájmem výzkumníků modelování a identifikace takového chování, při kterém studenti aktivně plní zadaný úkol, soustředí se na něj a jsou jím zaujati, a kdy naopak zadaný úkol neplní a věnují se nějaké jiné aktivitě (tzv. *on-task vs. off-task behavior*, příp. *engagement vs. disengagement*). Pod takové „off-task“ chování mohou spadat situace od nesoustředěnosti či věnování se nesouvisející aktivitě až po situace, při kterých student svým „off-task“ chováním ruší ostatní studenty, a narušuje tak výukovou aktivitu jako celek (srov. např. Baker, 2007; Baker & Gowda, 2010; Baker, Goldstein, & Heffernan, 2011).

A právě problematiku modelování a detekce nežádoucího chování studentů lze považovat za specifickou podoblast modelování chování studentů, které je v tomto kontextu věnována poměrně velká výzkumná pozornost. Někteří autoři (např. Bakhshinategh, Zaiane, ElAtia, & Ipperciel, 2018; Romero & Ventura, 2010) ji dokonce vyjmenovávají jako samostatný směr výzkumu, v případě Romera a Ventury (2010) je dokonce na stejné úrovni jako výše představené modelování studentů či predikce úspěšnosti. S ohledem na to, že i v případě těchto výzkumů jde stále o modelování chování studentů (totiž nežádoucího chování), považuji za vhodnější chápat tyto výzkumy jako součást obecnějšího směru výzkumů zaměřených na modelování studentů, resp. jejich chování.

Jak již napovídá samotné označení této oblasti, jde zde o modelování a identifikaci takových situací, při kterých v průběhu určité vzdělávací aktivity dochází k chování, jež je v rozporu s cílem či smyslem dané výukové aktivity. Například v průběhu vyplňování online testu může jít o již zmiňované hádání či tipování, případně o různé formy podvádění. V inteligentních tutorských systémech pak může jít např. o zneužívání pomoci, resp. nápovědy, kdy student okamžitě či opakovaně požaduje poskytnutí nápovědy, aniž by se nejprve sám pokusil úlohu vyřešit. Obecně se tyto jevy označují anglickým souslovím *gaming the system*, které lze přeložit jako „obcházení systému“³⁷. Tímto pojmem se má na mysli takové chování,

37 Považuji za vhodné upozornit, že tento typ chování nelze zcela ztotožňovat s podváděním v běžném slova smyslu. Zatímco v případě podvádění jde obvykle o provádění něčeho, co je explicitně zakázané (tj. např. u závěrečného testu je zakázané opisovat, ale já přesto opisuji), v případě chování typu *gaming the system* jde o využívání takových vlastností systému, které nejsou explicitně zakázané (např. výše zmiňované zneužívání nápovědy).

při kterém student záměrně využívá vlastností daného výukového systému k tomu, aby získal správné odpovědi či dosáhl úspěšného řešení úkolu, aniž by reálně znal správnou odpověď či uměl zadaný úkol vyřešit. Důvodem zájmu o modelování tohoto typu chování je především to, že souvisí s horším učením se prostřednictvím online výukových systémů typu ITS, čímž snižuje jejich potenciální přínos (Baker, 2007; Baker, Martin, & Rossi, 2017).

6.3.3 Modelování emocí a afektivních stavů

Třetí významnou oblastí v rámci modelování studentů, která stojí za explicitní zmínku, je oblast zaměřující se na modelování emocí a afektivních stavů³⁸ studentů v průběhu učení. Výzkumníci v této oblasti vychází z přesvědčení, že emoce či obecně afektivní stavy se vesměs vždy určitým způsobem promítají do kognitivních procesů, a tudíž hrají významnou roli i v kontextu učení a vzdělávání. A ačkoli tyto afektivní stavy nemusí být daným subjektem v danou chvíli vědomě reflektovány, vždy nějakým způsobem ovlivňují poznávací proces a proces učení (D’Mello & Graesser, 2015; D’Mello, 2017). Hlavní pozornost je přitom věnována právě těm afektivním stavům a emocím, které studenti prožívají či mohou prožívat v průběhu učení. Pekrun a Stephens (2012) hovoří o tzv. akademických emocích (*academic emotions*), přičemž je dále rozdělují na emoce související s dosahováním úspěchu (*achievement emotions*), emoce související s tématem či obsahem učení (*topic emotions*), emoce související se sociálním kontextem učení (*social emotions*) a epistemické emoce (*epistemic emotions*) související s procesem poznávání³⁹. D’Mello a Graesser (2015) místo o akademických emocích hovoří o tzv. na učení zaměřených afektivních stavech (*learning-centered affective states*), což však lze chápat jako vesměs synonymní pojem. Konkrétně se přitom v realizovaných výzkumech z oblasti analytiky učení a data miningu ve vzdělávání setkáme především s následujícími afektivními či kognitivně-afektivními stavy (srov. Baker, D’Mello, Rodrigo, & Graesser, 2010; Bosch & D’Mello, 2017; D’Mello & Graesser, 2011; D’Mello, Craig, Witherspoon, McDaniel, & Graesser, 2008):

38 Zde je nutné upozornit na poměrně odlišné chápání tohoto pojmu v českém prostředí. Jak upozorňují např. Poláčková Šolcová a Trnka (2015), v českém odborném i laickém pojetí je pojem afekt obvykle chápán jako užší pojem, který je podřazený pojmu emoce. Emoce pak bývají děleny na afekty, nálady a vášně. V zahraničním kontextu je však situace jiná. Zde je obvykle pojem afekt (resp. afektivní stavy či jevy) považován za obecnější a emoce jsou pouze jedním z různých typů afektivních stavů. Z tohoto pojetí pak vychází i oblast modelování emocí a afektivních stavů (srov. např. D’Mello & Graesser, 2015; D’Mello, 2017), a tudíž se ho přidržuji i v této publikaci.

39 Vzhledem ke zmiňované souvislosti s procesem poznávání se pro tuto kategorii používá rovněž označení kognitivně-afektivní stavy (*cognitive-affective states*), viz např. Baker, D’Mello, Rodrigo a Graesser (2010) či D’Mello a Graesser (2011).

- frustrace (*frustration*),
- nuda (*boredom*),
- potěšení (*delight*),
- překvapení (*surprise*),
- úzkost (*anxiety*),
- vztek (*anger*),
- zaujetí či koncentrace (*engagement, flow, concentration*),
- zmatení (*confusion*),
- znechucení (*disgust*),
- zvědavost (*curiosity*).

Problematika modelování emocí a afektivních stavů je přitom akcentována spíše v rámci data miningu ve vzdělávání, kde čerpá především z širších oblastí označovaných jako afektivní věda, resp. vědy (*affective science*)⁴⁰, a zvláště z počítačového zpracování emocí (*affective computing*). V posledních letech však začíná být problematice emocí věnována pozornost i v kontextu analytiky učení, kde se hovoří o emoční analytice učení (*emotional learning analytics*), afektivní analytice učení (*affective learning analytics*) či jednoduše o analytice emocí (srov. D’Mello, 2017; Williamson, 2017).

Podobně jako v ostatních oblastech modelování studentů se i u modelování afektivních stavů nachází uplatnění především v inteligentních tutorských systémech. Zde se pro účely modelování afektivních stavů využívají především logy či tzv. *click-stream data*, tj. taková data, která zachycují téměř veškerou interakci studenta s daným vzdělávacím systémem. Určitá část výzkumníků – ačkoli výrazně menší – se problematice detekce emocí a afektivních stavů věnuje i v souvislosti se systémy typu LMS či specificky v rámci kurzů typu MOOC (např. Aung & Myo, 2017; Wen, Yang, & Rosé, 2014; Yang, Kraut, & Rosé, 2016). Co se týče analyzovaných dat, jde v případě LMS a MOOC především o analýzu textových dat pocházejících z online diskuzních fór a o využití analýzy sentimentu (*sentiment analysis*) jakožto metody analýzy těchto dat. Specifickou kategorií dat, která se rovněž využívají k detekci emocí a afektivních stavů, představují data zachycující určité tělesné signály (např. výraz tváře, postoj apod.). V případě tohoto typu dat se pak oblast modelování afektivních stavů do značné míry prolíná s oblastí označovanou jako multimodální analytika učení (viz kapitolu 6.6).

Co se týče praktické aplikace výsledků výzkumu z oblasti modelování emocí a afektivních stavů studentů, lze spolu s D’Mellem a Graesserem (2015) hovořit o specifické kategorii vzdělávacích technologií či systémů označovaných jako *affect-*

40 Označení *afektivní věda/y* je relativně nové. Jak zmiňují Poláčková Šolcová a Trnka (2015), mezinárodní Společnost pro afektivní vědu (*The Society for Affective Science*) byla založena teprve v roce 2013. Výzkum afektivních stavů samozřejmě existoval i dříve, teprve v posledních letech se však zdá, že sílí snaha výzkumníků zabývajících se afektivními stavy o to, aby tato oblast byla rozpoznávána a vnímána jako svébytná (podobně jako je tomu u kognitivní vědy, resp. kognitivních věd).

-aware learning technologies (AALT). Jde o takové vzdělávací technologie, které jsou schopny nějakým způsobem identifikovat a zohledňovat afektivní stavy svých uživatelů. D’Mello a Graesser přitom rozlišují dva základní typy těchto technologií: reaktivní systémy a proaktivní systémy. Reaktivními systémy jsou myšleny takové systémy, jež jsou schopny detekovat afektivní stavy studentů a následně na ně nějakým způsobem reagovat. Relativně častým úkolem je přitom identifikace „negativních“ afektivních stavů, jako jsou frustrace či nuda, a následné reakce např. v podobě poskytnutí pomoci či vysvětlení vedoucího k řešení daného problému. Příkladem takového systému je upravená verze inteligentního tuteurského systému *AutoTutor* obohacená o detekci nudy, zmatení a frustrace (viz D’Mello & Graesser, 2012). Proaktivní systémy se pak místo reagování na emoce či afektivní stavy studentů snaží naopak určité emoce či afektivní stavy ve studentech vyvolávat. V tomto případě jde nejčastěji o využívání různých herních prvků za účelem zvyšování zaujetí (*engagement, flow*) či motivovanosti při plnění určitého úkolu (D’Mello & Graesser, 2015). Existují ovšem i pokusy se systémy snažícími se záměrně zvyšovat např. zmatení studentů (*confusion*). Ukazuje se totiž, že při využívání inteligentních tuteurských systémů může zmatení pozitivně souviset s učením a se studijními výsledky. Proto tyto proaktivní systémy v určitých momentech ve studentech strategicky navozují zmatení s cílem podpořit hlubší učení (D’Mello, Lehman, Pekrun, & Graesser, 2014).

6.4 Adaptivní a doporučovací systémy

Další oblastí výzkumu v rámci data miningu ve vzdělávání a v menší míře i analytiky učení jsou adaptivní systémy (*adaptive systems*) a doporučovací systémy (*recommender systems*). Tato oblast přitom poměrně silně souvisí s modelováním studentů, jelikož pro tvorbu personalizovaných doporučení je obvykle potřeba pracovat s určitým modelem studenta či uživatele, pro kterého jsou daná doporučení určena. Přesto je oblast adaptivních či doporučovacích systémů řadou autorů (např. Bakhshinategh, Zaiane, ElAtia, & Ipperciel, 2018; Papamitsiou & Economides, 2014; Romero & Ventura, 2010) vnímána jako do značné míry svébytná a odlišná od modelování studentů. Za hlavní rozdíl lze přitom považovat odlišný primární cíl obou oblastí. Zatímco hlavním cílem modelování studentů je tvorba modelu, který pokud možno věrně zachycuje znalosti, chování či afektivní stavy studentů, v případě adaptivních a doporučovacích systémů je primárním cílem zajištění toho, aby studentům bylo poskytnuto relevantní doporučení, či aby se jim systém odpovídajícím způsobem přizpůsobil. Ačkoli se tedy obě oblasti do značné míry překrývají, zároveň se odlišují v tom, na co je kladen hlavní důraz (tvorba modelu versus zajištění personalizace/doporučení).

Zároveň je třeba provést základní rozlišení mezi adaptivními a doporučovacími systémy. Přestože jsou oba typy systémů obdobné v tom, že pracují s personalizací či přizpůsobením se uživateli, je mezi nimi jeden zásadní rozdíl. Zatímco adaptivní výukové systémy (mezi které se běžně řadí i systémy typu ITS) obvykle uživateli přímo zobrazují personalizovaný obsah a uživatel nemá možnost zvolit si, aby mu byl zobrazován obsah nepřizpůsobovaný, v případě doporučovacích systémů jde obvykle pouze o personalizované doporučení, kterým se student případně nemusí řídit. Příkladem adaptivního systému může být procvičovací systém sestávající ze sady různě obtížných úloh, jež studentovi prezentuje takové úlohy, které nejlépe odpovídají jeho současné úrovni znalostí. Každému studentovi tedy budou úlohy prezentovány v jiném pořadí podle toho, jak odpovídal na předchozí úlohy. Pro studenta přitom neexistuje možnost postupovat úlohami v nepřizpůsobeném pořadí. Naopak příkladem doporučovacího systému může být systém, který studentovi doporučí kurzy k dalšímu studiu na základě informací o tom, které kurzy student již absolvoval (či na základě jiných kritérií). Takové doporučení může studentovi pomoci se rozhodnout, je ale zcela na studentu samotném, jaký další kurz ke studiu si zvolí a zda se vůbec bude řídit daným doporučením.

V rámci adaptivních systémů lze pak učinit základní rozlišení na adaptivní výukové systémy (*adaptive learning systems*) na jedné straně a na adaptivní testování (*adaptive testing*), častěji označované jako počítačové adaptivní testování (*computerized adaptive testing* – CAT), na straně druhé. A jak již naznačuje samotné označení obou typů adaptivních systémů, liší se primárně účelem, k němuž jsou využívány. V prvním případě jde o podporu výuky, resp. učení, zatímco v druhém případě jde spíše o testování, resp. měření znalostí.

Jak upozorňují např. Jelínek, Květon a Vobořil (2011) či Žitný (2014), adaptivní testování jako takové má poměrně dlouhou historii. Výraznější rozvoj však začal až s rozšířením počítačů a výpočetních technologií. V současnosti lze oblast počítačového adaptivního testování považovat za jedno z velkých a moderních témat psychologického testování a testování obecně. V rámci data miningu ve vzdělávání a analytiky učení se výzkumníci obvykle zaměřují specificky na využití data miningových metod⁴¹ pro účely adaptivního testování (např. Ivančević, Knežević, Pušić, & Luković, 2014) nebo na využití adaptivního testování pro formativní hodnocení (např. Baneres, Elena Rodríguez, Guerrero-Roldán, & Baró, 2016; Vie, Popineau, Bruillard, & Bourda, 2017). Přesto je větší pozornost v analytice učení a data miningu ve vzdělávání věnována adaptivním výukovým systémům než adaptivnímu testování. Relativně významnou stopu v této oblasti zanechává i česká skupina *Adaptive Learning* fungující na Fakultě informatiky Masarykovy univerzity, která se

41 Na rozdíl od psychometrie a psychologického testování, kde se v souvislosti s adaptivním testováním využívá a rozvíjí především teorie odpovědi na položku (IRT).

zaměřuje mimo jiné právě na adaptivní procvičovací systémy (viz např. Papoušek, Stanislav, & Pelánek, 2016; Pelánek, 2016, 2017).

Co se týče doporučovacích systémů, vynecháme-li základní rozlišení na personalizované a nepersonalizované doporučování, které ve své disertační práci zmiňuje Bydžovská (2016b)⁴², lze doporučovací systémy rozdělit do několika základních kategorií na základě toho, jakým způsobem jsou doporučení tvořena. V data miningu ve vzdělávání a v analytice učení jsou přitom nejčastěji zmiňovány dvě základní kategorie (srov. např. Bydžovská, 2016b; Fazeli, Drachslar, Brouns, & Sloep, 2014; Manouselis, Drachslar, Verbert, & Duval, 2013):

- Na obsahu založené doporučování (*content-based recommendation*) spočívá v tom, že je uživateli doporučován takový obsah, jenž je v nějakém ohledu podobný tomu, který uživatel preferoval v minulosti. V případě systému doporučujícího kurzy by tak mohlo jít o doporučování takových kurzů, jež jsou tematicky podobné těm, které student již absolvoval. Systémy tohoto typu jsou tak obvykle tvořeny třemi částmi (viz Bydžovská, 2016b). První část zajišťuje porozumění obsahu potenciálních položek k doporučení. Budeme-li tedy pokračovat ve výše nastíněném příkladu, pak v této části jde o to, aby doporučovací systém věděl, jakému tématu se věnují všechny kurzy, které mohou být uživatelům potenciálně nabízeny. Druhá část vytváří modely či profily jednotlivých uživatelů. To znamená, že u každého uživatele sbírá informace o tom, která témata ho zajímají. Třetí část pak tvoří samotná doporučení na základě porovnání profilu uživatele s popisem nabízených položek. Dochází tedy ke srovnání tematického zájmu konkrétního uživatele s tematickou nabídkou kurzů, přičemž se hledají nejlepší shody.
- Kolaborativní doporučování (*collaborative recommendation*) označované také jako kolaborativní filtrování (*collaborative filtering*) funguje tak, že je uživateli doporučován takový obsah, který je preferován uživateli, jež mu jsou v nějakém ohledu podobní. V případě systému doporučujícího kurzy by tak určitému studentovi byly doporučovány např. takové kurzy, které jsou pozitivně hodnoceny studenty, jež mají obdobné zájmy jako student, pro kterého je doporučení tvořeno. Romero a Ventura (2010) zmiňují několik způsobů využití kolaborativního filtrování ve vzdělávání, například kontextově-relevantní doporučování vhodných učebních objektů, doporučování odkazů na rozšiřující studijní materiály či doporučování obsahu, který by se měl student naučit před tím, než se přesune ke studiu další části kurzu.

Vedle dvou výše představených typů pak někteří autoři zmiňují ještě další možné typy doporučovacích systémů. Např. Manouselis et al. (2013) zmiňují doporučování na základě demografických údajů (*demographic recommendation*), dopo-

42 Za nepersonalizované doporučovací systémy lze považovat jednoduché systémy, které doporučují stejné položky všem uživatelům. Příkladem by mohl být systém, který by všem uživatelům doporučoval např. nejlépe hodnocené kurzy či nejnovější kurzy.

ručování na základě užítka či užitečnosti (*utility-based recommendation*) a doporučování na základě znalostí (*knowledge-based recommendation*). Bydžovská (2016b) pak doplňuje ještě hybridní doporučovací systémy, které spočívají v kombinaci několika výše uvedených metod.

6.5 Sociální analytika učení

Sociální analytiku učení (*social learning analytics*)⁴³ lze chápat jako specifickou podoblast analytiky učení, jež se do určité míry vymezuje vůči přístupům a výzkumům, které se orientují především na jedince (tj. zvláště směry zaměřující se na predikci úspěšnosti, identifikaci rizikových studentů či modelování studentů). Za původní proponenty tohoto směru výzkumu lze považovat Buckingham Shuma a Fergusonovou (srov. Buckingham Shum & Ferguson, 2012; Ferguson & Buckingham Shum, 2012), pro které je sociální analytika učení specifickou podmnožinou analytiky učení v tom smyslu, že vychází z pojetí učení jako sociálního procesu. Podle těchto autorů nemůže být učení dostatečně pochopeno, dokud se budeme soustředit pouze na studenty jakožto jednotlivce a nebudeme brát zřetel na důležité sociální aspekty jako interakce, spolupráce, skupinové procesy apod. Siemens (2012) se přidává k těmto hlasům, když zdůrazňuje nutnost přesunu pozornosti výzkumníků od pouhé identifikace rizikových studentů směrem k jiným přístupům a metodám. Identifikace rizikových studentů sice dle Siemense je a zůstane důležitým tématem na poli analytiky učení, zároveň však podle něj tvoří pouze relativně malou část toho, čím vším může analytika přispět ke zlepšení vzdělání (Siemens, 2012).

Hlavní charakteristikou sociální analytiky učení, kterou se dle uvedených autorů odlišuje od ostatních výzkumných směrů v této oblasti, jsou pak především analytické metody a techniky, pomocí nichž se snaží zachycovat sociální aspekty učení. Fergusonová a Buckingham Shum (2012) v souvislosti se sociální analytikou učení zmiňují pět hlavních skupin metod či metodologických okruhů (přestože si nedělají nároky na úplnost tohoto výčtu):

1. Analytika sociálních sítí (*social network analytics*).
2. Analytika diskurzu (*discourse analytics*).
3. Analytika obsahu (*content analytics*).
4. Analytika dispozic (*disposition analytics*).
5. Analytika kontextu (*context analytics*).

Stěžejní roli v dosavadních výzkumech spadajících pod sociální analytiku učení hraje využívání metod analýzy sociálních sítí (SNA) a automatizovaného zpracová-

43 Přikláním se k používání jednotného překladu v podobě „sociální analytika učení“, přestože anglické sousloví „social learning analytics“ by v některých kontextech zřejmě bylo možné chápat a do češtiny překládat rovněž jako „analytika sociálního učení“.

ní přirozeného jazyka (NLP). Tato dominance se následně odrazila i v obsahové náplni stěžejní publikace *Handbook of Learning Analytics* (Lang, Siemens, Wise, & Gašević, 2017), která vyšla o několik let později od publikování výše uvedené pěti-
ce metod a ve které se v sekci technik a přístupů analytiky učení objevují jako samostatné kapitoly pouze analytika diskurzu (*discourse analytics*) a analytika obsahu (*content analytics*), jež jsou obě do značné míry založené na automatizované analýze textových dat.⁴⁴ Mimo tyto dvě kapitoly se pak v této přehledové publikaci objevuje rovněž kapitola s názvem *Natural Language Processing and Learning Analytics* (McNamara et al., 2017), což dále podtrhuje důraz kladený na metody zpracování přirozeného jazyka. Ostatně výzkumníci pohybující se spíše v oblasti data miningu ve vzdělávání (např. Baker & Inventado, 2014) často považují právě důraz na metody automatizované analýzy textových dat či metody analýzy diskurzu za jednu z hlavních charakteristik, ve kterých se analytika učení odlišuje od data miningu ve vzdělávání.

S ohledem na výše uvedené se v následujících podkapitolách zaměřuji podrobněji na tři nejčastěji uváděné a v rámci sociální analytiky učení nejvíce zastoupené oblasti: analytiku sociálních sítí (kterou chápu jako aplikaci analýzy sociálních sítí v kontextu analytiky učení), analytiku obsahu a analytiku diskurzu.

6.5.1 Analytika sociálních sítí

Jak jsem naznačil výše, označení analytika sociálních sítí (*social network analytics*) se od svého zavedení v roce 2012 (viz Ferguson & Buckingham Shum, 2012) příliš nerozšířilo. A to patrně především kvůli tomu, že se jím odkazovalo na využití metody analýzy sociálních sítí (SNA) v kontextu analytiky učení. Pojem analýza sociálních sítí přitom byl již tou dobou mnohem rozšířenější, takže se nelze příliš divit, že se většina výzkumníků přiklání spíše k využívání tohoto pojmu. Proto i v této kapitole používám primárně pojem analýza sociálních sítí místo analytika sociálních sítí⁴⁵.

Analýzu sociálních sítí (SNA) můžeme chápat jako soubor metod a technik sloužících k průzkumu různých typů sociálních sítí (viz kapitolu 5.5). Za sociální síť lze přitom považovat nejen online sociální síť jako Facebook či Twitter, ale

44 Chybějící kapitolu, která by se věnovala specificky analytice sociálních sítí (*social network analytics*), lze vysvětlit zřejmě především tím, že se toto označení v odborné komunitě příliš neujalo. Důvodem je nejspíš přílišná podobnost označení *social network analytics* s již existujícím a dlouhodobě používaným *social network analysis*. Označení *social network analysis* přitom není běžně chápáno jakožto označení specifického metodologického okruhu v rámci sociální analytiky učení, nýbrž jde o označení pro širokou oblast analytických metod používaných i v řadě dalších disciplín (viz kapitolu 5.5).

45 Pokud bychom chtěli mezi oběma pojmy striktně odlišovat, pak pojem „analýza sociálních sítí“ bude označovat specifickou metodu, resp. skupinu metod, zatímco „analytika sociálních sítí“ bude sloužit k označení dílčí oblasti analytiky učení, která se zaměřuje právě na využití metod analýzy sociálních sítí.

také např. sociální vztahy mezi studenty ve třídě či diskuzi studentů v online výukovém prostředí apod. Analýza sociálních sítí bývá využívána jak v kvantitativně, tak i v kvalitativně orientovaných výzkumech, přestože výrazně silnější zastoupení má ve výzkumech kvantitativního charakteru.

V současnosti je pak analýza sociálních sítí natolik obsáhlým souborem metod, že ji lze jen stěží představit na ploše několika odstavců. Zmíním proto jen tři základní body. Vedle využití SNA pro analýzu určité sítě či skupiny osob lze tyto metody využít rovněž v případech, kdy je pozornost zaměřována na konkrétní osobu. V těchto případech se pak obvykle hovoří o osobních či egocentrických (*egocentric*) sítích, resp. egocentrické analýze sociálních sítí. Mimo mapování sociální sítě v určitém okamžiku (tj. ve statické podobě) nabízí analýza sociálních sítí rovněž metody a techniky věnující se dynamickým sítím (*dynamic social network*), tj. takovým sítím, které se v čase mění. V neposlední řadě se pak techniky analýzy sociálních sítí využívají i při analýze textových dat a v rámci dolování textů. Jde například o sítě spoluvýskytů slov v analyzovaných textech (*term co-occurrence networks*). V kontextu systémů typu LMS lze taková data extrahovat a následně analyzovat například pomocí výše zmiňovaného nástroje *Meerkat-ED* (Rabbany, ELAtia, Takaffoli, & Zaiane, 2014). Zároveň je třeba dodat, že v takovém případě se už dostáváme spíše do oblasti analytiky obsahu či analytiky diskurzu, kde jsou rovněž využívány metody a techniky analýzy sociálních sítí.

Co se pak týče výzkumů využívajících metod analýzy sociálních sítí, lze uvést například případovou studii Brookse, Greera a Gutwina (2014), kteří použili SNA k mapování aktivity studentů v online diskuzních fórech. Gašević, Zouaq a Janzen (2013) pak hledali s pomocí SNA vztah mezi sociálním kapitálem studentů a jejich studijními výsledky, zatímco Joksimović et al. (2016) se zaměřili na souvislost mezi mírou centrality studentů v síti a jejich studijními výsledky. Jiný zajímavý příspěvek k metodologii SNA přidávají Kim a Lee (2012), kteří zkoumají možnosti multidimenzionálního přístupu pro analýzu vztahů mezi jednotlivci v průběhu online interakce. Hecking, Ziebarth a Hoppe (2014) se pak s pomocí SNA snaží identifikovat různé způsoby využívání studijních materiálů v online kurzech. Za zmínku stojí rovněž práce de Laata a Schreurse (2013), kteří SNA spolu s dalšími metodami sociální analytiky učení využili v kontextu neformálního profesního rozvoje. Obdobným směrem se vydávají i Abu Khousa a Atif (2018), jež se věnují analýze sociálních sítí při výzkumu kariérního rozvoje.

Za specifický způsob využití SNA v kontextu pedagogického výzkumu, který však již směřuje mimo oblast analytiky učení, lze považovat studii, v níž jsem analyzoval sociální sítě publikujících autorů, výzkumných institucí a odborných časopisů v pedagogických vědách v České republice (Juhaňák, 2017).

6.5.2 Analytika obsahu

Analytika obsahu či obsahová analytika (*content analytics*) může být chápána jako zastřešující termín pro sadu metod a metodologických přístupů v rámci analytiky učení, které se zaměřují specificky na analýzu učebního obsahu (*learning content*). Pokud bychom chtěli poskytnout přesnější definici analytiky obsahu, můžeme se místo staršího vymezení (viz Buckingham Shum & Ferguson, 2012; Ferguson & Buckingham Shum, 2012) přiklonit spíše k novějšímu a širšímu pojetí Kovanoviće et al. (2017, s. 76), kteří obsahovou analytiku chápou jako:

Automatizované metody zkoumání, evaluace, indexování, filtrování, doporučování a vizualizace různých forem digitálního učebního obsahu, bez ohledu na jeho producenta (např. instruktor, student) s cílem přispět k porozumění učebním aktivitám a ke zlepšení vzdělávací praxe a výzkumu.

Oproti zaměření pozornosti na studenta a na jeho znalosti, chování či afektivní stavy se analytika obsahu zaměřuje především na analýzu různých učebních zdrojů a produktů učení. Učebním zdrojem (*learning resource*) se myslí především nej-různější online studijní materiály, elektronické učebnice apod., zatímco učebními produkty (*products of learning*) jsou především odevzdávané úkoly studentů, seminární práce, zprávy v diskuzních fórech apod. A ačkoli učební zdroje i produkty učení mohou existovat v různých formátech (audio, video, text, animace apod.), dosavadní pozornost výzkumníků se v této oblasti zaměřuje především na textové učební zdroje a produkty.

V rámci analytiky obsahu učebních zdrojů lze přitom spolu s Kovanovićem et al. (2017) rozlišit tři základní dílčí oblasti, kterým výzkumníci věnují pozornost. V prvním případě má obsahová analytika velmi blízko k doporučovacímu systému (viz předchozí kapitola 6.4), kdy je cílem studentům na základě analýzy obsahu učebních zdrojů automaticky nabízet a doporučovat relevantní učební materiály. Druhým tématem obsahové analytiky učebních zdrojů je automatizovaná organizace či klasifikace výukových materiálů či obecně učebních objektů (*learning objects*). Zde se využívají metody jako automatická extrakce klíčových slov, kolaborativní tagování, shlukování či automatizované anotování. Hlavním cílem je přitom automatizovaně získat metadata o učebních zdrojích, pomocí nichž by pak bylo možné je vhodným způsobem uspořádat a popsat, aby se v nich studenti mohli efektivně orientovat. Se stále větším rozšířením multimediálních výukových materiálů se v obsahové analytice postupně začíná věnovat pozornost i těmto typům učebních zdrojů. Např. Brooks, Johnston, Thompson a Greer (2013) se zaměřují na techniky automatické detekce a kategorizace důležitých pasáží ve videozáznamech přednášek, aby tak studentům umožnili lépe se v těchto videozáznamech pohybovat a využívat je pro své učení. Třetí důležitá oblast analytiky obsahu učeb-

ních zdrojů se zaměřuje na hodnocení kvality či náročnosti obsahu výukových materiálů. V tomto kontextu byl využit např. nástroj *Coh-metrix* (McNamara, Graesser, McCarthy & Cai 2014), který se jinak používá především pro analýzu a hodnocení studentských písemných prací.

V rámci analytiky obsahu učebních produktů je stěžejní oblastí zájmu využití obsahové analýzy pro automatizované poskytování zpětné vazby na písemné práce studentů a automatizované hodnocení písemných prací studentů (*automated essay scoring – AES*). Pro tyto účely je využíván např. již zmiňovaný nástroj *Coh-metrix* (McNamara, Graesser, McCarthy & Cai 2014), který za využití techniky latentní sémantické analýzy (*latent semantic analysis – LSA*) umožňuje hodnotit např. soudržnost (koherenci) či informativnost analyzovaných textů studentů. Jiným příkladem nástroje obdobného typu je *OpenEssayist* (Whitelock et al., 2015), který se zaměřuje spíše na poskytování automatizované zpětné vazby studentům v průběhu tvorby jejich písemných prací. K tomu využívá mimo jiné vizualizaci v podobě sítí spoluvýskytů slov, které byly zmíněné výše.

6.5.3 Analytika diskurzu

Analytika diskurzu podobně jako analytika obsahu poměrně výrazně čerpá z technik a metod zpracování přirozeného jazyka. Díky tomu také oblast analytiky diskurzu sdílí mnohé charakteristiky s výše popsanou analytikou obsahu. Určitým rozdílem je však to, že v rámci analytiky diskurzu je věnována hlavní pozornost souvislostem mezi interakcí a komunikací studentů v přirozeném jazyce a jejich učním. Často se proto v analytice diskurzu věnuje pozornost právě takovým textovým datům, která zachycují určitý dialog či nějakou formu interakce mezi studenty (Ferguson & Buckingham Shum, 2012). Nejčastěji jde o analýzy komunikace studentů v online diskuzních fórech, chatech a jiných nástrojích na synchronní či asynchronní online komunikaci. Může jít ale také o analýzy obsahu výukových blogů či wiki nástrojů, jejichž součástí obvykle bývají nástroje na komentování či diskutování. Někteří výzkumníci rovněž věnují pozornost analýzám a automatickému zpracování odpovědí studentů na (kratší) otevřené otázky (Rosé, 2017).

Za typický příklad využití analytiky diskurzu lze považovat analýzu komunikace v diskuzních fórech v rámci masových otevřených online kurzů (MOOC). Tyto kurzy totiž běžně obsahují tisíce až desetitisíce studentů, a tudíž v nich vzniká obrovské množství diskuzních příspěvků, se kterými vyučující či tutoři kurzu nemohou pracovat běžným způsobem (tzn. číst všechny příspěvky a odpovídat na ně). Výzkumníci v oblasti analytiky diskurzu se tak věnují různým možnostem analýz těchto rozsáhlých diskuzí, jejichž výstupy by mohly vyučujícím a tutorům poskytnout lepší vhled do dění v diskuzních fórech. Mezi nejčastější typy analýz přitom patří analýza sentimentu umožňující identifikovat pozitivní a negativní emoce

vycházející z diskuzních příspěvků. Časté je rovněž tzv. modelování tématu (*topic modelling*), resp. identifikace či objevování tématu (*topic discovery*), které umožňuje automaticky identifikovat hlavní témata vyskytující se v diskuzích studentů v online kurzu. Na základě těchto technik tak mohou být automatizovaně identifikována hlavní témata, problémy či otázky, které studenti v online diskuzním fóru zmiňují a na jejichž řešení či zodpovězení se lektori a tutoři online kurzu mohou zaměřit. Příkladem může být systém *FAQtor*, na jehož vývoji pracují Bihani, Ullman a Paepcke (2018). Ten je schopen analyzovat obsah diskuzních příspěvků ve fóru a následně automaticky generovat seznam tzv. často kladených dotazů (*frequently asked question – FAQ*).

6.6 Multimodální analytika učení

Podobně jako se výše představená oblast sociální analytiky učení do jisté míry vymezovala vůči jiným přístupům v rámci analytiky učení a data miningu ve vzdělávání, tak i oblast multimodální analytiky učení (*multimodal learning analytics*) vzniká v určitém ohledu jako vymezení se vůči převažující výzkumné praxi analytiky učení a data miningu ve vzdělávání. Jak shrnuje Ochoa (2017), tyto oblasti již od svého vzniku zaměřovaly pozornost především na studium aktivit studentů v různých typech online výukových systémů jako např. LMS či ITS. Výrazně méně pozornosti však bylo v těchto oblastech věnováno jiným prostředím a kontextům, kde dochází k učení (semináře, přednášky, studijní skupiny apod.). Toto nerovnoměrné rozložení pozornosti samozřejmě pramení z faktu, že online výuková prostředí obvykle automaticky sbírají velká množství relativně podrobných dat a činí tato data pro výzkumníky v oblasti data miningu ve vzdělávání a analytiky učení poměrně snadno dostupná. Naopak v tradičních či „offline“ učebních kontextech, tj. tam, kde se aktivita studentů neodehrává skrze počítač, není aktivita studentů nijak automatizovaně zaznamenávána, což klade výrazně větší nároky na sběr dat.

Ochoa (2017) ovšem zároveň upozorňuje, že tento sklon výzkumníků k využívání primárně dat z online výukových systémů může produkovat tzv. efekt pouličního osvětlení (*streetlight effect*), resp. princip opilcova hledání (*the principle of the drunkard's search*). Tato metaforická označení se používají v souvislosti se zkreslením (*bias*), které vzniká proto, že výzkumníci při svém výzkumu častěji zaměřují pozornost tam, kde vidí větší šanci získání pozitivních výsledků, nebo tam, kde lze výzkum (např. pozorování, experiment apod.) provádět snadněji (Freedman, 2010).⁴⁶ Multimodální analytika učení se snaží reagovat právě na tento potenciální

46 Označení „princip opilcova hledání“ souvisí se známým vtípem, který se běžně využívá k ilustraci tohoto typu zkreslení: Pozdě v noci narazí policista na opilého muže, který pod pouliční lampu něco hledá. Opilý muž policistovi řekne, že hledá svoji peněženku. Když se policista zeptá, jestli si je muž jistý, že ji ztratil právě tam, opilec mu odpoví, že ji nejspíš ztratil na druhé straně ulice. Zmatený policista

problém a vymezuje se vůči těm přístupům, které se upínají pouze k analýze dat z online výukových systémů. Tím totiž takové přístupy ignorují řadu dalších informací, jež však mohou být zcela zásadní i pro vysvětlování chování studentů právě v online výukových systémech (příkladem mohou být situace, kdy se studenti tváří zmateně či zívají nudou při řešení úkolu v online výukovém systému).

Hlavním cílem multimodální analytiky učení je tedy právě ona kombinace různých zdrojů, dat či modalit, které mohou poskytovat důležité informace pro porozumění učení v daném kontextu (Ochoa, 2017). Pokud bychom měli podat konkrétní definici multimodální analytiky učení, pak lze využít vymezení, které nabízí Blikstein a Worsley (2016, s. 233), pojímající multimodální analytiku učení jako:

(...) soubor [analytických] technik zaměřujících se na využití vícečetných zdrojů dat (video, logy, text, artefakty, audio, gesta, biosenzory) za účelem zkoumání učení v realistických, ekologicky validních, sociálních výukových prostředcích kombinujících různé druhy médií.

Pojem multimodality přitom vychází primárně z teorie komunikace, kde odkazuje k tomu, že komunikace a výměna informací může probíhat v různých módech (textový, řečový, vizuální apod.). Jak ale upozorňuje Jewittová (2012), tento pojem přejali i výzkumníci v pedagogice, zvláště pak v kontextu e-learningu a technologií ve vzdělávání, jelikož multimodalita je charakteristická i pro samotné učení (student si může číst knihu, poslouchat přednášku, sledovat výukové video, dělat cvičení v LMS atd.). Multimodální analytika učení pak usiluje o rozvoj metod a technik pro sběr, analýzu a kombinaci dat o učení probíhajícím prostřednictvím různorodých modů.

Na základě analýzy dosavadních empirických studií v oblasti multimodální analytiky učení lze říci, že výzkumníci doposud věnují pozornost především následujícím pěti modalitám, resp. datům, které je zachycují: audio, video, biofyzilogické údaje, sledování pohybu očí (*eye tracking*) a logy zaznamenávající interakci v online výukových systémech (Worsley, 2018). Mimo tyto nejčastěji řešené modalitty však výzkumníci v této oblasti věnují pozornost i dalším modům. S oporou o přehledové publikace, které nabízí např. Blikstein a Worsley (2016) či Ochoa (2017), lze výzkum v oblasti multimodální analytiky učení shrnout do následujících kategorií:

- Analýza textů (*text analysis*). V tomto bodě se multimodální analytika učení vesměs překrývá s analytikou obsahu či s analytikou diskurzu. A podobně jako v uvedených oblastech jsou i v kontextu analýzy textů používané především metody a techniky z oblastí jako dolování textu a zpracování přirozeného jazyka. V multimodální analytice učení však analýza textů není

se zeptá: „Proč tedy peněženku hledáte zde?“, načež opilec vysvětluje: „Protože tady jde lépe vidět.“ (viz Freedman, 2010).

dominantním prvkem, jak tomu je například u analýzy obsahu. Roli zde samozřejmě opět sehrává to, že textová data jsou ve vzdělávání (ať již online či offline) rozšířena velmi výrazně, a zároveň je jejich sběr po technické stránce relativně jednoduchý.

- Analýza promluv (*speech analysis*). Jde asi o nejčastěji zastoupenou kategorii v kontextu multimodální analytiky učení. Analýza promluv zároveň z části sdílí cíle a metody analýzy textů. Audiozáznamy promluv se totiž obvykle používají jedním ze dvou základních způsobů. V prvním případě je pozornost věnována tomu, co je v rámci promluvy sdělováno. Zde je pak audiozáznam využit k získání textového přepisu promluvy, obvykle za využití technik automatizovaného rozpoznávání řeči (*speech recognition*), a následně se s datovým materiálem pracuje obdobně jako v rámci analýzy textů. Druhý přístup k analýze promluv se pak zaměřuje především na to, jak bylo něco řečeno, tzn. na různé prozodické vlastnosti řeči jako jsou intonace, důraz, tempo, rytmus apod. Z těchto charakteristik pak lze získávat doplňující informace o záměrech či interních stavech mluvčích (např. nervozita apod.).
- Analýza rukopisu a skic (*handwriting analysis, sketch analysis*). Třetí oblast, která je do značné míry blízká předchozím dvěma, a tedy zprostředkovaně i analytice obsahu, je analýza rukopisu, resp. písemných záznamů, případně analýza skic, kreseb apod. Podobně jako v případě promluvy pak může být věnována pozornost jednak tomu, co je psáno či kresleno, jednak také tomu, jakým způsobem (rychlost psaní, tempo, tlak na pero apod.). Sběr tohoto typu dat se stal snadnějším poté, co se staly běžnými technologie jako digitální pero či tablet se stylusem.
- Analýza pohledu a sledování pohybu očí (*gaze analysis, eye tracking*). Monitorování toho, kam se studenti dívají, může poskytovat především informaci o tom, čemu právě věnují pozornost. Technologii pro sledování pohybu očí je v současnosti věnována značná pozornost i daleko za rámec pedagogických věd. Přestože jsou k dispozici různé typy přístrojů od těch, které využívají statické monitory, až po ty, které pracují s mobilními brýlemi, výraznější využívání těchto přístrojů v přirozeném učebním kontextu je stále poměrně problematické (ať již z důvodu stále relativně velkých finančních nákladů, nebo z důvodu jejich možné rušivosti v přirozeném prostředí). Z těchto důvodů se pro analýzu pohledu v multimodální analytice učení poměrně často využívá i videozáznam pomocí běžné kamery (či sady kamer) zachycující hlavu, resp. obličej studentů. Za využití kombinace metod pro zpracování obrazu, spolu s informací o relativní poloze studentů a kamery, lze pak s určitou přesností usuzovat na směr pohledu studentů a zjišťovat tak např. to, zda věnují vizuální pozornost vyučujícímu, resp. zda jej mají v zorném poli (viz Raca & Dillenbourg, 2013).

- Řeč těla (mimika, gestika, posturika atd.). Další oblast, jíž je v kontextu multimodální analytiky učení věnována pozornost, souvisí s tzv. řečí těla, tj. sledováním výrazů tváře, gest, postoje, pohybu, držení těla apod. Podobně jako v případě eye trackingu lze i v tomto případě využít řadu různých přístrojů či senzorů, které s pomocí akcelerometru dokáží poměrně přesně sledovat pozici a pohyb jednotlivých částí těla, ke kterým jsou připojeny. Avšak vzhledem k jejich invazivnosti bývá i zde často využíván spíše běžný videozáznam a jeho následná analýza. Např. Raca, Tormey a Dillenbourg (2014) využili videozáznam třídy zachycující pohyby horní poloviny těla studentů k měření jejich pozornosti. Zajímavým příkladem výzkumu kombinujícího data ze senzorů pohybu s videozáznamem je práce Echeverría et al. (2014), kteří využili data ze zařízení Kinect spolu s videozáznamem horní poloviny těla pro predikci úrovně prezentačních dovedností studentů.
- Sledování biofyzilogických ukazatelů. Do této kategorie spadá využívání jakýchkoli přístrojů, které umožňují měřit a monitorovat nejrůznější biofyzilogické či neurofyzilogické procesy v lidském těle. Blikstein a Worsley (2016) uvádí jako nejběžnější příklady v kontextu pedagogického výzkumu měření srdečního tepu, měření dilatace zornic, měření elektrodermální aktivity, resp. kožní vodivosti, a měření elektrické aktivity mozku pomocí EEG. Tato data pak obvykle slouží pro účely identifikace různých kognitivních či afektivních stavů (např. radost, úzkost, zaujetí úkolem nebo rozptýlenost apod.) či měření jejich intenzity v průběhu učení nebo při řešení nějakého úkolu (např. míra kognitivní zátěže, intenzita prožívání pozitivních či negativních emocí apod.).
- Analýza afektivních stavů (*affective state analysis*). Blikstein a Worsley (2016) zmiňují jako samostatnou oblast multimodální analytiky učení i analýzu afektivních stavů. Tu však lze do značné míry vnímat jako překrývající se s oblastí modelování emocí a afektivních stavů, která byla představena výše v souvislosti s modelováním studentů (viz kapitolu 6.3.3). Za určitý rozdíl je snad možné vnímat to, že zatímco v případě modelování emocí a afektivních stavů studentů je obvykle věnována větší pozornost modelování těchto stavů při využívání online výukového systému (typicky ITS), přičemž jako data slouží především videozáznamy obličeje studenta při používání daného systému, v případě analýzy afektivních stavů v kontextu multimodální analytiky učení je věnována pozornost afektivním stavům i v jiných vzdělávacích kontextech, kde jsou pak pro sběr dat využívány například i různé biofyzilogické senzory.

Za do určité míry separátní a současně multimodální analytikou všeprostopující téma výzkumu je pak možné považovat otázky týkající se kombinace a integrace záznamů výše nastíněných modalit a různých typů dat do jednoho smysluplného celku. Ať již pro účely konkrétní analýzy, nebo obecně za účelem komplexnějšího porozumění učení (Blikstein & Worsley, 2016; Ochoa, 2017; Worsley, 2018).

6.7 Etické aspekty analytiky učení a data miningu ve vzdělávání

Jako poslední z témat výzkumu v oblasti analytiky učení a data miningu ve vzdělávání je možné uvést problematiku etických aspektů souvisejících s aplikací analytických a data miningových metod a nástrojů ve vzdělávání. Této oblasti se přitom začala věnovat větší pozornost až se vznikem analytiky učení (tj. kolem roku 2012) a i nadále je tato problematika řešena spíše v souvislosti s analytikou učení než s data miningem ve vzdělávání. Určitou roli v tomto ohledu zřejmě sehrává i to, že analytika učení má silnější kořeny v sociálních a humanitních vědách, zatímco data mining ve vzdělávání je více technickou disciplínou. Z raných publikací, které se etických aspektů dotýkají nebo se na ně přímo zaměřují, lze pak uvést především práce Dringuse (2012), Fergusonové (2012a), Grellera a Drachslera (2012), Siemense (2012) či Sladeové a Prinslooa (2013). Tyto autory a jejich publikace lze považovat za první iniciátory odborné diskuze věnující se tématu etických aspektů analytiky učení.

Zároveň, jak se postupně analytika učení dostávala do stále širšího povědomí a jak na řadě univerzit začaly být využívány různé analytické nástroje, přibývaly do diskuze etických aspektů další publikace řešící otázky, kterým doposud nebyla věnována patřičná pozornost. Velmi užitečným materiálem se v tomto ohledu ukázal být přehled literatury, který podal Sclater (2014). V něm identifikoval 15 řešených oblastí a v nich celkem 93 otázek, jež si pokládají autoři věnující se etickým aspektům v souvislosti s analytikou učení. Lze zmínit například otázky jako: Kdo má vlastnit data, která jsou automaticky generována a následně uchovávána při používání různých vzdělávacích systémů? Má mít student možnost zakázat sběr a analýzu dat o své osobě? Kdo má mít přístup ke studentským datům? Má univerzita právo poskytovat data o studentech třetím subjektům? Sclaterův (2014) přehled literatury pak byl využit při tvorbě kodexu praxe analytiky učení (*code of practice for learning analytics*), na jehož tvorbě se sám Sclater významně podílel (Sclater 2016).

Mimo práci Sclatera je pak téma etických i legislativních aspektů analytiky učení stále více rozvíjeno i dalšími autory v této oblasti (např. Krumm, Means, & Bienkowski, 2018; Pardo & Siemens, 2014; Prinsloo & Slade, 2017). Za poměrně zásadní příspěvek do odborné diskuze věnující se této problematice pak lze považovat speciální číslo časopisu *Educational Technology Research and Development* s názvem *Exploring the Relationship of Ethics and Privacy in Learning Analytics and Design*, které se věnovalo právě tomuto tématu (viz tabulka 2). Zároveň je v této odborné diskusi patrný určitý posun od spíše základních a jednodušších (a spíše legislativních) otázek, týkajících se např. informovanosti uživatelů či ochrany osobních údajů, ke stále komplexnějším a náročnějším etickým otázkám, týkajícím se například diskriminace a dalších nepříznivých důsledků, které může využívaní analytiky a data miningu ve vzdělávání přinášet. V následujících bodech pak

podávám základní přehled témat, jež jsou v oblasti etických a legislativních aspektů analytiky učení řešena:

- Informovanost, transparentnost a souhlas. Již Sladeová a Prinsloo (2013) poukazovali na to, že mnoho studentů v současnosti zřejmě ani neví, jaká data o nich škola či univerzita sbírá, a jak je případně analyzuje. Nabízí se tedy otázka, jestli by v oblasti analytiky učení neměla existovat povinnost informovat studenty o tom, jaká data jsou o nich sbírána. Zároveň je otázkou, zda by mělo být povinné od studentů získávat informovaný souhlas, jako je tomu zvykem v jiných oblastech či u jiných typů výzkumů. Zde ovšem záleží na vymezení a pojetí analytiky učení. Budeme-li analytiku učení chápat jako běžnou oblast výzkumu, pak lze pouze aplikovat etické standardy používané v jiných disciplínách (např. etická komise apod.). Analytiku učení však můžeme chápat také jako specifickou oblast výzkumu, která vyžaduje specifické či nové mechanismy dohledu. Případně může být analytika učení vnímána nikoli jako oblast výzkumu nýbrž jako oblast vzdělávací praxe, což by s sebou neslo opět jiné důsledky (srov. Willis III, Slade, & Prinsloo, 2016). V každém případě je ale důležitost informovanosti a souhlasu (primárně) studentů stejně jako celkové transparentnosti způsobu aplikace analytiky učení relativně všeobecně přijímána (srov. např. Pardo & Siemens, 2014; Prinsloo & Slade, 2017; Sclater, 2016, 2017). Přesto i v této oblasti zůstávají další otázky k řešení. Mají být například studenti informováni pouze o tom, jaká data jsou o nich sbírána, nebo mají být informováni i o dalších souvislostech (např. pro jaké účely jsou data sbírána, jakým způsobem jsou data ukládána, zpracovávána, analyzována apod.)? A pokud ano, do jaké míry podrobnosti (např. mají vědět i o konkrétních algoritmech, které jsou při analýze použity)?
- Ochrana osobních údajů. S výše uvedeným souvisí i problematika ochrany osobních údajů, která je v současnosti již do určité míry řešena i legislativně. Např. v kontextu Evropské unie vzbudilo značnou pozornost tzv. obecné nařízení o ochraně osobních údajů (*general data protection regulation*), známé od zkratkou GDPR, na které musely reagovat i univerzity či vysoké školy využívající aplikace a systémy na bázi analytiky a data miningu. Ostatně i systém Moodle, jemuž se věnují realizované analýzy prezentované v této publikaci, nabízí od verze 3.5 speciální modul přinášející novou funkcionalitu tak, aby mohlo být využívání systému v souladu s požadavky GDPR. Zde je však třeba si uvědomit, že existující nařízení a dostupná funkcionalita na straně daného systému jsou jedna věc, avšak konkrétní aplikace ochrany osobních údajů v rámci instituce je věc druhá. Zároveň je třeba odlišovat osobní údaje v legislativním smyslu a osobní či citlivé údaje na základě toho, jak je vnímají sami studenti. Ifenthaler a Schumacher (2016) například ve svém výzkumu ukazují, že studenti jsou poměrně často ochotni pro účely

analytického systému sdílet data o svém univerzitním studiu (např. zapsané kurzy, výsledky v testech apod.), ale již jsou méně ochotni sdílet data považující za osobní (např. příjem, bydliště, ale i v pedagogickém výzkumu poměrně běžně zjišťované údaje jako rodinný stav či vzdělání rodičů). Dále nejsou příliš ochotni sdílet data týkající se jejich chování v online vzdělávacím systému (např. časy přístupů, počet stažení apod.) nebo data produkovaná mimo vzdělávací systém (např. data ze sociálních sítí).

- Možnost neúčasti (princip opt-out)⁴⁷. V souvislosti s informovaností, a zvláště se souhlasem si pak někteří výzkumníci (např. Pardo & Siemens, 2014; Sclater, 2017) pokládají otázku, zda mají mít studenti možnost odmítnout, aby o nich byla určitá data sbírána, analyzována a používána např. pro predikci úspěšnosti či poskytnutí doporučení. Samotný smysl poskytování souhlasu se sběrem dat totiž spočívá právě v tom, že student má reálnou možnost souhlas neposkytnout. Většina běžných aplikací či služeb vyžadujících souhlas (např. pro přístup k určitým datům) přitom funguje tak, že pokud uživatel souhlas neudělí, pak danou aplikaci či službu vůbec nemůže využívat. Tento režim je ale jen obtížně přenositelný do oblasti vzdělávání, jelikož by vedl k nemožnosti nadále pokračovat ve vzdělávání. Těžko si lze například představit situaci, kdy by univerzita využívala nějaký online vzdělávací systém (např. Moodle), který o svých uživateliích běžně sbírá řadu údajů, a zároveň by studentům umožňovala odmítnout tento systém využívat. Navíc využívání principu opt-out má vliv i na ty studenty, kteří chtějí poskytovat svá data a využívat možností určitého analytického systému z těchto dat pramenící (např. v případě systému včasného varování). Lze si tak představit situaci, kdy velké množství studentů odmítne poskytnout data, což následně povede k méně reprezentativnímu vzorku, a tudíž k horším predikcím v rámci systému včasného varování. Sclater (2017) uvádí, že odmítnutí účasti (tj. princip opt-out) lze vnímat také jako sobecký čin, který znemožňuje ostatním využívat službu či funkcionalitu, kterou by využívat chtěli. Můžeme se tak dostat až k etickým otázkám týkajícím se toho, kdy užitek pro skupinu lidí převáží právo jednotlivce na odmítnutí účasti, což se běžně řeší např. v oblasti medicíny a medicínského výzkumu (Pardo & Siemens, 2014; Slade & Prinsloo, 2013).
- Validita dat a z nich vyvozovaných predikcí. Další oblast etických otázek souvisí s validitou sbíraných dat a z nich generovaných predikcí či doporučení.

⁴⁷ Principem „opt-out“ se má na mysli mechanismus, který uživateli umožňuje odstoupit od účasti (např. v určitém sběru dat či jejich analýze). Jde tedy o situaci, kdy jsou o studentovi automaticky sbírána data pro účely nějakého analytického systému, ale studentovi je zároveň dána možnost říci, že nechce, aby o něm tato data byla nadále sbírána. Opačným principem je pak princip „opt-in“, u kterého nedochází k žádnému sběru dat o studentovi, dokud se sám student nepřihlásí k tomu, že chce, aby o něm byla daná data pro dané účely sbírána.

Na jedné straně univerzity v současnosti tak jako tak automaticky sbírají velké množství dat o studentech a jejich učení, takže lze argumentovat, že je ne-li neetické, pak přinejmenším nezodpovědné, nevyužívat je pro dosahování vzdělávacích cílů studentů (Slade & Prinsloo, 2013; Sclater, 2017). Na druhé straně mohou být tato data zkreslená či jiným způsobem problematická, případně mohou být nevhodným způsobem analyzovaná. Tím může docházet k nevalidním predikcím či doporučením, které v důsledku mohou studentům škodit místo pomáhat. Zároveň, jak upozorňuje např. Sclater (2017), může v řadě případů docházet k tomu, že je velmi obtížné vůbec zhodnotit validitu vyvozovaných predikcí. Zvláště pak v případech, kdy univerzity využívají proprietární řešení dodávané externím poskytovatelem, a tudíž nemají přesnou představu o tom, jak jsou predikce generovány.

- Manipulace analytických metrik studenty. S validitou dat a predikcí a s výše nastíněnými otázkami informovanosti a transparency pak úzce souvisí problémy týkající se záměrné manipulace studentů s určitými daty či analytickými metrikami (srov. Sclater, 2017). Tím, že studenti ví, že jsou data o jejich chování sbírána a analyzována, mohou se je snažit ovlivňovat ve svůj prospěch. Čím více je daný analytický systém transparentní, tím snáze může být ovlivnitelný. Objevuje se tak etické dilema, kdy na jedné straně stojí informovanost studentů a transparentnost analytického řešení, a na druhé straně větší možnosti studentů takové transparentní řešení manipulovat, a tím znehodnotit jeho výstupy.
- Nepříznivé dopady analytiky a data miningu ve vzdělávání. Mimo záměrnou manipulaci pak může informovanost studentů o používaném analytickém systému vést k dalším nepříznivým důsledkům. Například může povědomí studentů o tom, že je jejich chování v online vzdělávacím systému monitorováno, vést k nežádoucí změně jejich chování v tomto systému, případně k vyhýbání se používání systému jako takového. Jiným příkladem nepříznivého dopadu, který vedle Sclatera (2017) zmiňují např. Lawson, Beer, Rossi, Moore a Fleming (2016), je demotivace některých studentů spojená s identifikací rizikových studentů a systémy včasného varování. Zatímco někteří studenti mohou být motivováni k intenzivnější práci poté, co jsou upozorněni, že jim hrozí nedokončení kurzu, jiní studenti mohou motivaci k další práci naopak ztratit. Případně mohou ztratit sebevědomí, že by kurz mohli úspěšně ukončit, a tudíž se o to raději přestanou snažit. V důsledku tak může prediktivní systém vést k přesnému opaku, než bylo jeho původním záměrem (tj. pomáhat studentům, kterým hrozí neúspěch). V souvislosti s adaptivními a doporučovacími systémy pak Sclater (2017) zmiňuje potenciální nepříznivý dopad v tom, že mohou vést ke ztrátě autonomie studentů v procesu jejich vlastního učení. Student tak může pouze slepě sledovat nejrůznější návrhy či doporučení (např. na kurzy či

studijní materiály, které má dále studovat), místo aby se sám rozhodoval a volil si vlastní cestu na základě vlastních studijních cílů. V širším kontextu a v rámci dlouhodobých efektů pak lze u doporučovacích systémů upozornit rovněž na problém tzv. informačních bublin (*filter bubbles*)⁴⁸. Ty mohou ve vzdělávacím kontextu vznikat například v situacích, kdy doporučovací systém funguje na principu podobnosti a doporučuje studentům ke studiu podobné studijní materiály či kurzy, anebo takové materiály, které studovali jemu podobní studenti apod. Případně může doporučovací systém fungovat tak, že bude doporučovat takové studijní materiály, jež vedou k rychlému či snadnému ukončení kurzu. Ve všech těchto příkladech pak může v konečném důsledku docházet k tomu, že student bude uzavřen do informační bubliny podobných či povrchních informací, místo aby se setkával s diverzitou a rozšiřoval si své znalosti a obzory (Bozdag, 2013; Pariser, 2011).

48 Někteří autoři v českém kontextu používají doslovnější překlady jako „filtrovaná bublina“ či „filtrační bublina“. Ovšem vzhledem k tomu, že podstata *filter bubbles* spočívá ve filtrování informací, jež se k subjektu dostanou, přikláním se k označení „informační bublina“, které se v českém jazyce jeví jako přiléhavější. Ke stejnému překladu se přiklání i další autoři, např. Rathouz (2017).