

Česká zemědělská univerzita v Praze

Provozně ekonomická fakulta

Katedra systémového inženýrství



Disertační práce

Měření efektivnosti znalostí

Autorka disertační práce: Ing. Tereza Horáková

Školitel: doc. Ing. Milan Houška, Ph.D.

Poděkování

Ráda bych touto cestou poděkovala školiteli doc. Ing. Milanu Houškovi, Ph.D. za odborné vedení při zpracování disertační práce. Dále mu děkuji za spolupráci na publikační činnosti, konzultace a cenné rady v průběhu celého doktorského studia.

Souhrn

Znalosti vždy měly velký význam ve všech sférách lidské činnosti. V rámci pedagogiky se klade důraz na správné a efektivní předávání znalostí. Předávat znalosti lze prostřednictvím mnoha způsobů, jedním z možných nástrojů jsou i vzdělávací texty a učebnice. Práce je založena na produktovém přístupu ke znalostem, tj. nahlíží na znalost jako na objekt. Hlavním cílem disertační práce je zhodnotit vliv struktury vzdělávacích textů na efektivnost transferu explicitních znalostí. Předmětem výzkumu jsou znalostně strukturované texty, které mohou být vytvořeny na základě metod pro reprezentaci znalostí, tzv. znalostních jednotek a produkčních pravidel. Výzkumem se ověřuje předpoklad, že znalostně strukturovaný text vykazuje oproti textům bez záměrného strukturování kvalitativně vyšší úroveň, protože obsahuje koncentrované znalosti.

Disertační práce se skládá ze dvou hlavních částí, literární rešerše a výzkumné části disertační práce. Literární rešerše představuje teoretický přehled stavu poznání v oblasti znalostního inženýrství. Výzkumná část práce se skládá ze tří oblastí. V první oblasti výzkumné části práce jsou popsána východiska, tj. je definován pojem znalostně strukturovaný text a dále je navržena metodika jeho tvorby. Druhá oblast výzkumné části práce je aplikační a sleduje efektivnost transferu znalostí prostřednictvím vzdělávacích textů různých struktur, a to pomocí 3 odlišných experimentů. První experiment má za cíl popsat specifika znalostně strukturovaných textů prostřednictvím kvantitativních charakteristik. Druhý experiment má za cíl stanovit vliv struktury vzdělávacího textu na výsledky učení a zjistit, zda jsou uživatelé vzdělávacích textů schopni subjektivně rozlišit znalostně strukturované vzdělávací texty od textů bez záměrné orientace na znalosti. Třetí experiment má za úkol postihnout rozdíly v mozkové činnosti při práci s běžnými a znalostně strukturovanými texty, a to jak ve fázi učení, tak ve fázi vybavování znalostí. Z výsledků práce vyplývá, že znalostně strukturovaný text se statisticky významně liší od běžně strukturovaného textu z hlediska didaktických charakteristik textu. Znalostně strukturovaný text vykazuje statisticky významnou vyšší úspěšnost transferu znalostí v rámci práce se znalostně a běžně strukturovanými texty. Uživatelé subjektivně nevnímají rozdíly ve struktuře u znalostně a běžně strukturovaných textů. Závěrem jsou shrnuty dosažené výsledky a představeny příležitosti pro navazující budoucí výzkum.

Klíčová slova

Znalost, znalostní inženýrství, znalostní jednotka, znalostně strukturovaný text, vzdělávací text, transfer znalostí.

Summary

Knowledge has always been of great importance in all spheres of human activity. Within pedagogy, the emphasis is placed on the correct and effective transfer of knowledge. The transfer of knowledge can be done in many ways, one of the possible tools are some educational texts and textbooks. The work is based on product access to knowledge, i.e. it views the knowledge as an object. The main goal of the dissertation is to evaluate the influence of the structure of educational texts on the efficiency of transfer of explicit knowledge. The subject of the research are knowledge-structured texts, which can be created based on knowledge representation methods, so-called knowledge units and production rules. The research verifies the assumption that the knowledge-structured text has a qualitatively higher level than common text because it contains concentrated knowledge.

The dissertation consists of two main parts, literature review and the research part of the dissertation. The literature review presents a theoretical background of knowledge in the area of knowledge engineering. The research part of the thesis consists of three areas. In the first area of the research part the starting points are described, i.e. the concept of knowledge-structured text is defined and the methodology of its creation is proposed. The second area of the research part of the thesis is an application and monitoring the efficiency of the transfer of knowledge through educational texts of different structures. The second part consists of 3 different experiments. The first experiment aims to describe the specifics of knowledge-structured texts using quantitative characteristics. The second experiment aims to determine the impact of the structure of the educational text on learning outcomes and to determine whether users of learning texts are able to differentiate subjectively knowledge-structured educational texts from texts without intentional knowledge orientation. The third experiment aims to capture differences in brain activity for probands working with common and knowledge-structured texts. The differences are observed from 2 different points of view the learning phase and in the knowledge acquisition phase. The conclusion is the third part of the research part of the thesis. The results of the work show that the knowledge-structured text statistically significantly differs from the common structured text in terms of didactic characteristics of the text. The knowledge-structured text has a statistically significant higher success rate of knowledge transfer in the context of working with a different type of texts. Users do not subjectively perceive differences in structure in knowledge-based and commonly structured texts. The conclusion summarises the achieved results and presents opportunities for a future research.

Keywords

Knowledge, knowledge engineering, knowledge unit, knowledge-structured text, educational text, knowledge transfer.

Obsah

1	ÚVOD	5
2	CÍL A METODIKA PRÁCE	9
2.1	Cíl disertační práce.....	10
2.2	Metodika disertační práce	11
2.2.1	Dílčí kroky metodiky	11
2.2.2	Měření efektivnosti	14
2.2.3	Granty.....	15
2.2.4	Hypotézy.....	15
2.2.5	Vědecké metody disertační práce	16
2.2.6	Data, zpracování dat, užitý software	16
3	LITERÁRNÍ REŠERŠE	18
3.1	Vymezení základních konceptů a pojmů	18
3.1.1	Data	18
3.1.2	Informace	18
3.1.3	Znalost	19
3.1.4	Znalosti a umělá inteligence.....	21
3.1.5	Znalostní inženýrství v systémovém pojetí	22
3.2	Metody pro reprezentaci znalostí	24
3.2.1	Produkční pravidla.....	24
3.2.2	Rozhodovací tabulky a rozhodovací stromy	25
3.2.3	Sémantické sítě	26
3.2.4	Rámce.....	27
3.2.5	Znalostní jednotky	27
3.3	Text jako nástroj transferu znalostí z pohledu pedagogiky.....	29
3.3.1	Transfer znalostí	29
3.3.2	Učebnice a textové učební pomůcky ve vzdělávání	30
3.3.3	Měření parametrů učebnic	30
3.4	Metodický aparát pro měření efektivnosti transferu znalostí	33
3.4.1	Nástroje didaktické analýzy.....	33
3.4.2	Statistické modelování	37
3.4.3	Data miningové techniky.....	39
3.4.4	Biomedicínské inženýrství a neurotechnologie.....	44
4	VÝZKUMNÁ ČÁST DISERTAČNÍ PRÁCE	47
4.1	Východiska.....	50
4.1.1	Úvod kapitoly 4.1.....	50

4.1.2	Vymezení pojmu znalostně strukturovaný text	50
4.1.3	Předpoklady pro experiment I, II a III	52
4.1.4	Návrh metodiky pro tvorbu znalostně strukturovaného textu	52
4.1.5	Závěr kapitoly 4.1	54
4.2	Text a jeho didaktické charakteristiky	55
4.2.1	Úvod kapitoly 4.2	55
4.2.2	Experiment I	55
4.2.3	Konkrétní výstupy experimentu I	57
4.2.4	Závěr kapitoly 4.2	83
4.3	Text jako nástroj transferu znalostí	85
4.3.1	Úvod kapitoly 4.3	85
4.3.2	Experiment II	85
4.3.3	Konkrétní výstupy experimentu II	87
4.3.4	Závěr kapitoly 4.3	117
4.4	Text a biofeedback	119
4.4.1	Úvod kapitoly 4.4	119
4.4.2	Experiment III	120
4.4.3	Konkrétní výstupy experimentu III	121
4.4.4	Závěr kapitoly 4.4.	144
5	ZÁVĚR	146
6	SEZNAM POUŽITÝCH ZDROJŮ	150
7	SEZNAM OBRÁZKŮ	165
8	SEZNAM TABULEK	167
9	PŘÍLOHY	168

1 Úvod

V dnešní době je standardem téměř u všech větších, ale už i menších podniků či organizací užívat pojmy a slovní spojení typu: *znalostní podnik, kvalitní a vhodně řízené znalosti jako nástroj konkurenčního boje, koncept znalostní společnosti, znalostní organizace, učící se organizace, přechod od informační společnosti ke společnosti znalostní* a mnoho dalších. Pojmy jako *znalostní ekonomika, ekonomika řízená znalostmi* a *transfer znalostí* se objevují i v řadě vědeckých publikací (např. Chidambaram, 2014).

Společným prvkem zmíněných pojmů a slovních spojení je slovo *znalost* (angl. *knowledge*). V českém jazyce je význam slova *znalost* chápán jako strukturovaný souhrn vědomostí v určitém oboru či vlastnost toho, kdo je znalý někoho či něčeho. V anglickém jazyce má pojem *knowledge* více významů v závislosti na kontextu, překlad pak odpovídá českým pojmům: vzdělání, vědění, vědomost, znalosti, znalost, vědomí, vědomosti a dalším.

Pojem *znalost* není jen termínem pedagogickým, vyskytuje se ve všech sférách lidské činnosti. V technických, přírodních, společenských, medicínských a jiných oborech je potřeba vycházet z odborných znalostí daného oboru s ohlednutím na specifické technické, manažerské, organizační, politické, kulturní a jiné faktory.

Tacitní znalosti lze nalézt například v literatuře. Příběhy jsou od začátku lidstva přirozeným zdrojem pro sdílení znalostí. Ve vyprávěných i psaných příbězích jsou pomocí metafor, symbolů a analogií popsány archetypální problémové situace a návody, jak je řešit. Tyto návody představují znalosti. Se stejným typem znalostí je možné se setkat i v rámci náboženství.

V životě existuje i s opak pojmu *znalost*, tzv. *neznalost*. V souvislosti s ní platí v rámci morálního a trestně-právního kontextu věta *ignorantia juris non excusat* (neznalost zákona neomlouvá), která poukazuje na to, že neznalost zákona není polehčující okolností svědčící o nevině. Tím se nabádá k přijetí odpovědnosti za svoje skutky a činy. *Neznalost* a *nevědomost* jsou pojmy, kterými se zabývá například i řecká, indická či buddhistická filozofie.

Na znalosti lze nahlížet dvěma způsoby, a sice produktovým a procesním. V reálném světě nebývají tyto přístupy od sebe úplně odděleny; přestože se aplikují společně, jeden však prakticky vždy bývá dominantní. Procesní přístup je zaměřen převážně na znalosti tacitní z hlediska jejich řízení a sdílení jak na úrovni jednotlivců, tak v rámci celé organizace. Člověk je v rámci tohoto přístupu nositelem znalosti. Touto oblastí se zabývá obor znalostní management, který se zaměřuje na managementu znalostních pracovníků a skupinové řešení problémů, podporu efektivní komunikace a týmové spolupráce jako prostředku pro sdílení znalostí.

Druhým přístupem je pohled produktový, kde je kladen důraz na informační technologie a metody umělé inteligence pro zpracování dat, informací a znalostí. Z produktového přístupu ke znalostem vychází i předkládaná disertační práce, znalost je zde vnímána jako explicitně vyjádřená objektivní entita vázaná k určitému problému. Znalost z tohoto hlediska může být vlastněna, reprezentována, přenášena a v dalších procesech využívána, proto je při práci se znalostmi pozornost směřována na jejich tvorbu, kodifikaci, uchování, znovuvyužití a transfer.

Touto sférou se zabývá obor znalostní inženýrství. Znalostní inženýrství vzniklo na přelomu 60. a 70. let 20. století, kdy se odborníci na umělou inteligenci shodli na tom, že znalosti jsou základem pro řešení různých úloh a problémů. Nicméně odlišení hierarchie dat, informací, znalostí (případně moudrosti) lidé přirozeně vnímali již dávno před vznikem tohoto oboru. Důkazem toho je i báseň *The Rock* od T. S. Eliota, vydaná v roce 1934 (viz Příloha 2).

Znalostní inženýrství na jedné straně poskytuje metodické nástroje pro možnost implementace postupů umělé inteligence při zpracování a automatizovaném odvozování nových znalostí, na druhou stranu je silně svázáno nutností standardní formalizace znalostí pro možnost jejich počítačového zpracování. Jednou z metod užívanou ve znalostním inženýrství pro reprezentaci znalostí jsou znalostní jednotky.

Práce vychází z předpokladu, že lze vytvořit vzdělávací text, ve kterém budou explicitní znalosti reprezentovány prostřednictvím znalostních jednotek. Takto vytvořený text (znalostně strukturovaný text) se od běžného klasického vzdělávacího textu liší strukturou,

ale může se odlišovat i v jiných parametrech, jež mohou ovlivnit účinnost transferu znalostí.

Sestavení znalostně strukturovaného textu je však relativně náročné, a to z hlediska času, financí i nutnosti speciálně vyškolit autory. Na tvorbu zmíněného textu je třeba minimálně o třetinu více času, než při tvorbě běžně strukturovaného textu (Rauchová et al., 2013). Autoři musí znát kodifikaci a reprezentaci znalostí prostřednictvím znalostních jednotek a produkčních pravidel, či spolupracovat na tvorbě textu se znalostním inženýrem. Pokud by se ukázalo, že struktura textu nemá vliv na efektivnost transferu znalostí, nemá v tomto případě vůbec cenu uvažovat o tvorbě znalostně strukturovaných textů. Z toho důvodu je hlavním cílem disertační práce zhodnotit vliv struktury vzdělávacích textů na efektivnost transferu explicitních znalostí.

Pokud se prokáže, že struktura textu pozitivně ovlivňuje efektivnost transferu znalostí, je třeba se v budoucnu zabývat i druhou stránkou věci, tj. výše zmíněnou ekonomikou tvorby znalostně strukturovaných textů a najít bod zvratu, od kterého se vyplatí do specificky upravených textů investovat finanční prostředky.

Dále práce přispívá ke zjištění, jak lidský jedinec je schopen vnímat a pracovat s formalizovanou textovou strukturou znalostí, a to jak ze subjektivního tak objektivního hlediska. Obsah práce rovněž přispívá ke zjištění, jak efektivní může být komunikace v systému *člověk-stroj* (angl. *Man-Machine System*), a to v rámci úkolové, sémantické, syntaktické a částečně lexikální roviny, pokud by lidský jedinec získával znalosti, jako výstupy expertního systému formalizované prostřednictvím znalostních jednotek.

Disertační práce tematicky navazuje na dřívější kvalifikační práce a odborné knihy členů katedry systémového inženýrství Provozně ekonomické fakulty České zemědělské univerzity v Praze. Jedná se zejména o dvě habilitační práce s názvy *Modelování vzniku a sdílení znalostí* (Dömeová, 2009) a *Znalostní jednotky a jejich modelování* (Houška, 2011), diplomovou práci s názvem *Vyhledávání znalostí v textech* (Rauchová, 2012a) a disertační práci s názvem *Interoperabilita znalostí* (Kvasnička, 2013) a tři odborné knihy s názvy *Systems Approach to Knowledge Modelling* (Dömeová, Houška a Houšková Beránková, 2008), *Modelování znalostí* (Brožová et al., 2011) a *Mastering Knowledge* (Šubrt et al., 2014).

Výše uvedené kvalifikační práce a odborné knihy se zaměřují převážně na různé metody reprezentace znalostí, typy znalostí a způsoby jejich transferu případně sdílení v rámci organizací. Společným jmenovatelem těchto publikací jsou znalostní jednotky jako forma reprezentace znalostí, která je vhodná nejen pro automatizované zpracování v expertních systémech, ale zároveň je dobře vyjádřitelná i v přirozeném jazyce. V předchozích pracích byly rovněž definovány operace se znalostními jednotkami a jejich využití v různých kontextech: interoperabilita znalostí. Předmětem disertační práce je tvorba vzdělávacích textů na základě znalostních jednotek a sledování vlivu struktury textu na efektivnost transferu znalostí, což posouvá dosavadní výzkum znalostních jednotek do nových výzkumných oblastí, tj. pedagogiky, matematické lingvistiky a biomedicínského inženýrství.

2 Cíl a metodika práce

Před formulací cíle a metodiky práce s názvem *Měření efektivnosti znalostí* je třeba vymezit následující tři pojmy: *měření*, *efektivnost* a *znalost* a uvést, jak budou ve výzkumné části práce chápány.

Měření

Termín *měření znalostí* sám o sobě nedává smysl. Měření lze provádět pouze nepřímo, tj. předmětem měření jsou projevy znalostí, zejména výsledky učení a procesy probíhající při jejich zpracování. Měřit je dále možné parametry reprezentace znalostí a způsobu jejich kódování, v kontextu práce vzdělávacího textu. Použité metody měření jsou specifikovány v příslušných bodech metodického postupu.

Efektivnost

Efektivnost vychází z konceptu „3E“ (*Economy, Efficiency, Effectiveness*), tj. dělat věci hospodárně, účinně a účelně. Hospodárnost znamená zjistit, kdy se vyplatí investovat do znalostně strukturovaných textů, tj. minimalizace nákladů na tvorbu znalostně strukturovaných textů. Výzkumná část práce vychází zejména z pohledu účelnosti. V rámci účelnosti je sledováno, zda má význam znalostně strukturované texty vytvářet. Pokud je v práci sledována účinnost, tak v podobě dílčích měř v rámci jednotlivých experimentů (například doba učení vs. výsledky učení, apod.).

Znalost

Primárně bude znalost chápána jako produkt (objekt). Přestože při praktickém použití se těžko odděluje produktová a procesní složka znalosti, ve výzkumné části práce bude kladen důraz na analýzu znalosti jako objektu. Práce se zabývá výhradně explicitními znalostmi, které lze vybraným způsobem popsat, zachytit a formalizovat. Tacitní znalosti jsou považovány za znalosti, které není možné kodifikovat. Oblast tacitních znalostí proto leží mimo záběr této práce.

2.1 Cíl disertační práce

V souladu s výše uvedeným vymezením zaměřením práce je hlavním cílem disertační práce zhodnotit vliv struktury vzdělávacích textů na efektivnost transferu explicitních znalostí. Hlavní cíl práce bude dosažen prostřednictvím následujících dílčích cílů.

1. Zhodnotit současný stav poznání v oblasti znalostního inženýrství

Obor znalostního inženýrství rychle vyvíjí. Proto je třeba, aby se výzkumné experimenty neopakovaly, ale naopak navazovaly na aktuální světovou literaturu. Dále je třeba, aby se v nových výzkumech používaly nejnovější metody a postupy měření.

2. Formalizovat postup tvorby znalostně strukturovaných textů

V předchozích pracích, na které výzkum v disertační práci navazuje, nebylo předmětem zájmu definovat pojem znalostně strukturovaný text a plně formalizovat proces jeho tvorby. Proto je dílčím cílem této práce specifikovat charakteristiky znalostně strukturovaného textu a popsat způsob jeho tvorby. Smyslem je, aby ho mohl sestavit kdokoliv, kdo ho bude potřebovat pro účely vzdělávání a aby bylo možné znalostně strukturované texty nechat vytvořit pro účely navazujících experimentů jako službu.

3. Popsat specifika znalostně strukturovaných textů pomocí kvantitativních charakteristik

Vzdělávací texty se nejen tvoří, ale dají se také přebírat od jiných autorů a za podmínek stanovených legislativou a etickými zásadami používat ve vzdělávacím procesu. S tím je spojena potřeba mít možnost klasifikovat jakýkoliv existující text a měřit míru jeho příslušnosti do kategorie znalostně strukturovaného textu. Proto je dalším dílčím cílem práce tvorba kvantitativního profilu znalostně strukturovaného textu, který umožní například měřit koncentraci znalostí, které obsahuje.

4. Stanovit vliv struktury vzdělávacího textu na výsledky učení

Dílčí cíl souvisí s již zmíněným kritériem účelnosti. Je třeba zjistit, zda má význam znalostně strukturované texty vytvářet.

5. Zjistit, jaké postoje zaujímají uživatelé ke znalostně strukturovaným vzdělávacím textům ve srovnání s texty bez záměrné orientace na znalosti

Pro praktické nasazení konceptu znalostně strukturovaných textů je potřeba zjistit, jak je vnímají uživatelé, tj. čtenáři a studenti. Může se stát, že texty budou vyhodnoceny jako účinné v přenosu znalostí, ale nebudou pozitivně vnímány uživateli, kteří je následně nebudou používat. Předmětem výzkumu je zjištění, zda je uživatelé dokáží intuitivně rozlišit a pokud ano, tak jaké zaujímají postoje ke speciální struktuře textu.

6. Postihnout rozdíly v mozkové činnosti při práci s běžnými a znalostně strukturovanými texty, a to jak ve fázi učení, tak ve fázi vybavování znalostí

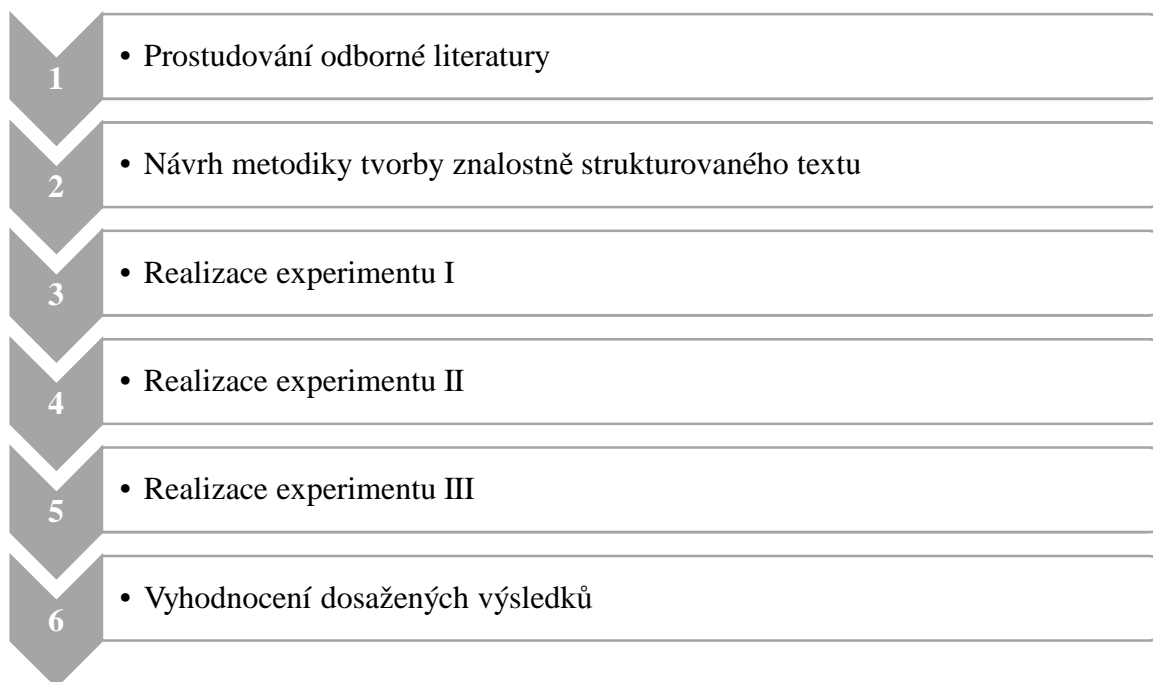
Výpovědi uživatelů o jejich postojích ke znalostně strukturovaným textům s činností jsou pouze subjektivní, což je pro formulaci validního závěru nedostatečné. Proto je posledním dílčím cílem práce stanovit rozdíly v aktivitě, již reálně vykazuje jejich mozek při zpracování textů různých struktur a zjistit, jaká mozková centra jsou během práce s texty zapojena.

2.2 Metodika disertační práce

Disertační práce se skládá ze dvou hlavních částí, literární rešerše a výzkumné části disertační práce. Literární rešerše představuje teoretický přehled stavu poznání v oblasti znalostního inženýrství. Výzkumná část práce se skládá ze tří oblastí. V první oblasti výzkumné části práce jsou popsána východiska, tj. je definován pojem *znalostně strukturovaný text* a dále je navržena metodika jeho tvorby. Druhá oblast výzkumné části práce je aplikační a sleduje efektivnost transferu znalostí prostřednictvím vzdělávacích textů různých struktur, a to pomocí 3 odlišných experimentů. Ve třetí oblasti výzkumné části práce, závěru, jsou shrnuty dosažené výsledky a představeny příležitosti pro navazující budoucí výzkum.

2.2.1 Dílčí kroky metodiky

Metodiku disertační práce lze shrnout do šesti na sebe navazujících kroků, viz schéma na obrázku 1.



Obrázek 1 Schéma metodiky disertační práce; zdroj: autorka

1. Prostudování odborné literatury

Literární přehled z oblasti znalostního inženýrství je vytvořen prostřednictvím citování zdrojů převážně z odborných monografií a vědeckých článků.

Literární rešerše je nejprve zaměřena na vymezení základních pojmů z oblasti znalostního inženýrství. Dále je zaměřena na metody pro reprezentaci znalostí. Další podkapitola se zabývá vzdělávacími texty jako nástroji pro transfer znalostí z pohledu pedagogických disciplín. V závěru literární rešerše je popsán metodický aparát pro měření efektivnosti transferu znalostí.

Tento krok metodiky vede k naplnění dílčího cíle 1.

2. Návrh metodiky tvorby znalostně strukturovaného textu

Na základě předchozího kroku je vymezen znalostně strukturovaný text a odlišen od ostatních typů vzdělávacích textů. Zároveň je představena navržená metodika pro tvorbu znalostně strukturovaného textu. Poznámka: V dalších krocích metodiky navazují 3 experimenty, které testují efektivnost znalostně strukturovaných textů z různých pohledů. Všechny experimenty vycházejí z originálních textů od Káry (2007), a to v rámci

vybrané problémové domény – zpracování zemědělských odpadů. Z důvodu respektování specifických požadavků jednotlivých experimentů je velikost textových fragmentů v rámci jednotlivých experimentů různá.

Tento krok metodiky vede k naplnění dílčího cíle 2.

3. Realizace experimentu I

Na základě literární rešerše jsou vybrány lingvistické charakteristiky, jež jsou předmětem testování. Poté jsou připraveny běžně strukturované a znalostně strukturované textové fragmenty. Následně je provedena analýza textových charakteristik z pohledu matematické lingvistiky (didaktická obtížnost textu) včetně statistického vyhodnocení. V následujícím kroku jsou testovány i klasifikátory umělé inteligence pro třídění typů textů dle jejich struktury (výskytu slovních konceptů). Posledním krokem experimentu je zhodnocení výsledků.

Tento krok metodiky vede k naplnění dílčího cíle 3.

4. Realizace experimentu II

Na základě literární rešerše jsou vybrány charakteristiky (doba studia textu, úspěšnost transferu znalostí, počáteční úroveň znalostí), jež jsou předmětem testování. Poté jsou připraveny běžně strukturované a znalostně strukturované textové fragmenty do formy textových brožur. Následně je navržena metodika testování, provedena pilotáž experimentu a experimentálně a statisticky otestovány jednotlivé nástroje experimentu (pretest, posttest, textové brožury). V následujícím kroku jsou osloveni respondenti a realizován experiment dle finální metodiky. Součástí experimentu je zjistit i subjektivní názor testovaných na vzdělávací texty různé povahy (vnímání rozdílnosti struktury a obtížnosti textových brožur). Poté jsou získaná data zpracována a statisticky vyhodnocena. Posledním krokem experimentu je zhodnocení výsledků.

Tento krok metodiky vede k naplnění dílčího cíle 4 a dílčího cíle 5.

5. Realizace experimentu III

Na základě výstupů experimentu II a literární rešerše jsou vybrány charakteristiky, a jim odpovídající neurotechnologie pro realizaci experimentu. Poté jsou připraveny běžně strukturované a znalostně strukturované texty do formy textových fragmentů. Následně je navržena metodika testování prostřednictvím funkční magnetické rezonance, provedena pilotáž experimentu a experimentálně otestovány jednotlivé nástroje experimentu. V následujícím kroku jsou osloveni probandi a realizován experiment dle finální metodiky. Poté jsou získaná data zpracována a statisticky vyhodnocena. Pro stanovení obecných závěrů nejsou získaná data dostačující, proto je součástí práce i návrh možného rozšíření experimentu III a návaznosti pro budoucí výzkum v oblasti biologické zpětné vazby od uživatelů textu.

Tento krok metodiky vede k naplnění dílčího cíle 4 a dílčího cíle 6.

6. Vyhodnocení dosažených výsledků

Poslední, třetí oblast, výzkumné části práce, je zaměřena na syntézu dosažených výsledků v rámci jednotlivých 3 experimentů. Zmíněná oblast je založena na závěrečném shrnutí a doporučení pro navazující výzkum.

Tento krok metodiky vede k naplnění hlavního cíle disertační práce.

2.2.2 Měření efektivity

Hlavním cílem disertační práce je zhodnotit vliv struktury vzdělávacích textů na efektivnost transferu explicitních znalostí, přičemž efektivnost je měřena:

- objektivně prostřednictvím didaktických charakteristik textu;
- subjektivně prostřednictvím názoru testovaných;
- objektivně prostřednictvím úspěšnosti transferu znalostí;
- objektivně prostřednictvím časové délky studia textu;
- objektivně prostřednictvím záznamu mozkové aktivity užitím neurotechnologie (funkční magnetické rezonance).

2.2.3 Granty

Výzkumná část práce vychází z experimentů a následných publikačních výstupů, jež byly realizovány v rámci financovaných grantových žádostí, v nichž byla autorka práce zároveň hlavní řešitelkou projektu. Jedná se o jeden projekt financovaný Celouniverzitní grantovou agenturou České zemědělské univerzity v Praze (CIGA ČZU) a dva projekty financované Interní grantovou agenturou Provozně ekonomické fakulty České zemědělské univerzity v Praze (IGA PEF), ve všech třech případech se jednalo o dvouleté projekty, viz následující seznam:

- Měření efektivity transferu znalostí v sektoru zpracování zemědělských odpadů (poskytovatel CIGA ČZU, trvání od 2013 do 2014, registrační číslo projektu 20131001);
- Stanovení kvantitativních charakteristik znalostního textu (poskytovatel IGA PEF, trvání od 2013 do 2014, registrační číslo projektu 20131020);
- Stanovení neuropsychologických charakteristik učení pro různé typy vzdělávacích textů prostřednictvím neurotechnologií (poskytovatel IGA PEF, trvání od 2015 do 2016, registrační číslo projektu 20151047).

2.2.4 Hypotézy

V disertační práci se vyskytují tři úrovně hypotéz, tj. *výzkumné hypotézy (VH)*, které představují obecný výzkumný předpoklad. Výzkumné hypotézy jsou dále na základě operacionalizace rozpracovány do podoby **pracovních hypotéz (PH)**, jež představují předpoklady o závislosti dvou či více proměnných. Pracovní hypotézy jsou dále rozvinuty do dílčích hypotéz, tzv. operativních hypotéz (OH), které mají podobu statistické nulové hypotézy pro daný statistický test.

Hypotézy jsou v práci číslovány tak, jak se za sebou vyskytují ve výzkumné části práce. Číslování operativních (OH) a **pracovních hypotéz (PH)** vychází z hierarchie, tj. je možné odlišit, které **pracovní hypotézy (PH)** jsou nadřazeny konkrétním operativním hypotézám (OH). Všechny hypotézy jsou v textu vizuálně odlišeny užitím různého stylu fontu písma, viz výše.

V rámci každého experimentu jsou stanoveny následující obecné výzkumné hypotézy.

V experimentu I je stanovena výzkumná hypotéza *VH1: Znalostně strukturovaný text se statisticky významně neliší od běžně strukturovaného textu z hlediska didaktických charakteristik textu.*

V experimentu II jsou stanoveny 2 výzkumné hypotézy *VH2* a *VH3*. *VH2: Neexistují žádné rozdíly v úspěšnosti transferu znalostí v rámci práce se znalostně a běžně strukturovanými texty. VH3: Uživatelé subjektivně nevnímají rozdíly ve struktuře u znalostně a běžně strukturovaných textů.*

V experimentu III je stanovena výzkumná hypotéza *VH4: Neexistují žádné rozdíly při aktivaci korové oblasti mozku při práci se znalostně a běžně strukturovanými texty.*

2.2.5 Vědecké metody disertační práce

V disertační práci jsou užity kombinace několika vědeckých metod. V rámci všeobecných vědních metod jsou v disertační práci použity empirické a obecně teoretické metody. Z empirických metod je využit převážně experiment a měření. Z obecně teoretických metod pak analýza, syntéza, indukce, dedukce, generalizace, abstrakce, komparace a analogie. Kromě uvedených empirických a obecně teoretických metod jsou v práci užity i specifické vědecké metody, mezi nimiž mají zvláštní postavení metody matematické a statistické, jež slouží k přesnému exaktnímu vyjádření jevů a stavů mezi nimi.

2.2.6 Data, zpracování dat, užitý software

Tři výše uvedené experimenty jsou zdrojem primárních dat. Základní datové matice a podklady pro analýzy k jednotlivým třem experimentům jsou součástí přiloženého paměťového nosiče (CD disku).

Většina statistických výpočtů a grafických výstupů či reportů je provedena v programu Statistica12 (Statsoft, Dell) dle Klímka, Stráže a Kasala (2009). Dále je v některých případech využit MS Office Excel. V rámci prvního experimentu je, mimo jiných programů, využit i volně dostupný software pro tvorbu rozhodovacích stromů bigML (2017).

V práci se vyskytují matematické vzorce, rovnice a proměnné, jejichž formát odpovídá konvenčnímu zápisu. Matematické zápisy a rovnice v textu jsou vloženy pomocí doplňku MS Office, Microsoft Equation 3.0.

Grafická zobrazení a schémata, která nejsou součástí výstupů výše uvedených programů, jsou zpracována v MS Office Word jako obrázek typu SmartArt či v aplikaci Nákresy od společnosti Google.

3 Literární rešerše

3.1 Vymezení základních konceptů a pojmů

3.1.1 Data

Data (lat. *datum*) lze vyložit jako něco daného, mohou být vyjádřena symboly, ale může jít i o smyslové vjemy (Lee et al., 2016; Wang et al., 2016). Z fyzikálního hlediska se data chápou jako určitá následnost znaků, odrážející bezprostředně zkoumanou skutečnost. Data sama o sobě význam nemají, odrážejí objektivní realitu a určité události bez vazby na okolní události (Truneček, 2004). Pojem data se v kontextu počítačové vědy vždy používal pro označení čísel, textu, zvuku, obrazu, případně pro jiné smyslové vjemy reprezentované v podobě vhodné pro zpracování počítačem (Garcia-Sciveres a Wang, 2016). Data bez dalšího popisu nebo kontextu nedávají smysl, ale jsou surovinou, z níž mohou vyvstávat informace (Cooper, 2014).

3.1.2 Informace

Informace dle Coopera (2014) jsou data v kontextech, tato data jsou použitelná a srozumitelná. Nejmenší jednotkou informace je jeden bit. Jeden bit udává, že něco je nebo není. Méně už o něčem říci nelze, proto je bit nejmenší jednotkou informace a je reprezentován binárně pomocí 0 a 1 (Zenil, Kiani a Tegnér, 2016). Informace jsou účelově zpracovaná data, jímž se v procesu interpretace přisuzuje jistý význam. Význam nabývá informace vzájemným propojením dat. Tento význam však může, ale nemusí být užitečný. Uživatel dále data analyzuje či transformuje myšlenkovými procesy podle své informační potřeby. Hodnota informací je pak důsledkem interpretačního procesu, který provádí jistý subjekt, má tedy subjektivní charakter (Truneček, 2004). Hodnota informace podle Sklenáka (2001) nemá přímou souvislost s případnou cenou dat. Data jsou jen nositeli potenciální hodnoty, díky čemuž mohou být i objektem obchodování. Data mohou být mnohdy nakupována za cenu nemalých nákladů, ale teprve až v okamžiku použití se může projevit jejich nepoužitelnost, například z důvodu nepřesností či neaktuálnosti (Gangopadhyay, Nishimura a Pal, 2016; Zhang et al., 2016). Potom taková data příjemci neposkytují žádnou informaci a tedy ani hodnotu (Lee et al., 2016., Nazari, 2016).

3.1.3 Znalost

Relace mezi pojmy data a informace je různými autory vnímána podobně, ale u pojmu znalost toto neplatí. Umělá inteligence přinesla další pojetí pohledu na informace, kdy se nad pojem informace klade znalost jako forma abstrakce a generalizace (Zdrahal et al., 2007). Řetězec od dat ke znalostem dle Trunečka (2004) vytváří určitou hierarchickou posloupnost, důležité je, že jednotlivé prvky řetězce nejsou tvořeny vzestupnou sumarizací. Na hierarchii *data – informace – znalost* staví svou práci řada autorů (Braganza, 2004; Aven, 2013; Cooper, 2010). Někteří autoři nad znalosti ještě řadí *moudrost a osvícení* (Jifa, 2013; Cooper, 2014). S rostoucí vzdáleností od dat je tím více obtížnější definovat jednotlivé pojmy a určit mezi nimi vztahy, vzdálenosti a vzájemnou podmíněnost. Obtížnost definovat pojem vyvstává už na úrovni znalostí.

Na pojem znalost nahlíží celá řada autorů různě (Nonaka a Takeuchi, 1996; Braganza, 2004; Aven, 2013).

Zaměstnanci, management, majitelé, zákazníci, ale též procesy, výrobky, služby, databáze znalostí atd. jsou zdrojem znalostí v podniku. Rozdíl mezi informacemi a znalostmi je v účelově koordinované akci. Informace jen akci popisuje, zatímco znalost ji vykonává. Nepoužitelné a nepoužité znalosti zůstávají informacemi do té doby, dokud nejsou transformovány v akci. Hlavními autory, kteří se zabývají znalostmi v organizaci, jsou Nonaka a Takeuchi (1995, 1997).

Klasifikace znalostí

Podle Mládkové (2005) mají znalosti dvě dimenze, a to explicitní a tacitní. Někteří autoři rozlišují kromě explicitních a tacitních znalostí ještě znalosti implicitní, které nejsou přímo vyjádřeny či dostupné v určitém zdroji (Choi, Kim a Ryu, 2014). Dle Maříka et al. (1993) se v počítačových expertních systémech jako implicitní označují znalosti rozptýlené v jednotlivých programových instrukcích, které se aplikují podle předem stanoveného algoritmu. Tacitní znalosti pak mohou být speciální skupinou implicitních znalostí (Choi, Kim a Ryu, 2014; Kamyaia, 2015). Explicitní znalost lze formálně vyjádřit pomocí jazyka, obrázku, písma, digitálního či notového záznamu, formulí, specifikací, manuálem.

Z toho vyplývá, že se s ní dá manipulovat, přenášet, skladovat, předávat ji mezi sebou, též však ukrást. Explicitní znalosti mají dle Trunečka (2004) tyto znaky:

- lze je formalizovat,
- je možno je systematicky uspořádat,
- dostávají většinou podobu informace,
- dají se bez větších problémů vyjadřovat,
- lze je sdílet.

Tacitní znalost pak v sobě kombinuje explicitní znalost se zkušenostmi, dovednostmi, intuicemi, pravidly, principy, mentálními modely a osobními představami konkrétního jedince či skupiny lidí. Tacitní znalosti mají velice osobní charakter, a to díky svázanosti s hodnotami, emocemi, idejemi, nápady konkrétního člověka. Tacitní znalosti je velmi obtížné vyjádřit či přenášet, někteří autoři se domnívají, že tacitní znalost se při pokusech o formalizaci může zničit. Velký potenciál v tacitních znalostech mají organizace (Nonaka et al., 2014). Kvalitou skupinových tacitních znalostí se zabývali autoři Erden, von Krogh a Nonaka (2008).

Tacitní znalosti mají dle Trunečka (2004) tyto znaky:

- jsou osobní a vázané na subjekt,
- je velmi obtížné je formalizovat a poskytnout někomu jinému,
- získávají se zkušeností a praxí,
- časem bývají považovány za něco samozřejmého, čeho si ostatní nemusí vůbec všimnout.

Odlišná interpretace pojmu znalost je odrazem dvou relativně samostatných přístupů (tvrdý a měkký), mezi nimiž většinou nedochází k propojení, oba tyto přístupy se vyvíjejí izolovaně. Tvrdý přístup využívá informační a znalostní technologie (Zdrahal et al., 2007) a aplikuje metody umělé inteligence. Typickými přístupy v tomto směru jsou například

data mining, práce s texty, či aplikace lingvistiky. Velmi často bývají využívány matematické metody. Měkký přístup je zaměřen na využívání tacitních znalostí, proces učení, skupinové řešení problému, učící se organizace (Nonaka et al., 2014). Na základě výše popsaných přístupů lze odlišit dvě pojetí znalostního managementu, vycházející z různých zdrojů a odlišné filosofie, tj. technologické a sociální pojetí.

Technologické pojetí využívá tvrdý přístup, tj. znalost vnímá jako objekt. Znalost má formu a je vázána k problému. V tomto euroamerickém pojetí je cílem znalostního managementu tvorba, kodifikace, uchování a přenos znalostí. Typické pro výše zmíněné pojetí je užití matematických metod a umělé inteligence (Lhotská, Mařík a Vlček, 2001). Sociální pojetí využívá měkkého přístupu a zaměřuje se na zlepšení efektivity podniku. Pracuje s tacitními znalostmi mající subjektivní povahu (Erden, von Krogh a Nonaka, 2008). Zaměřuje se na proces přeměny individuálních znalostí na znalosti kolektivní. Sociální pojetí bývá využíváno v japonských firmách, kdy do procesu „*knowledge creation*“ jsou vztaženy všechny úrovně zaměstnanců (Nonaka a Takeuchi, 1995; Nonaka a Takeuchi, 1997).

Vzhledem k potřebnosti obou přístupů znalostního managementu je v současné době snaha propojit dvojí pojetí znalostního managementu (Truneček, 2004). Vlastní řešení práce vychází z technologického pojetí znalostního managementu, využívající tvrdý přístup a pohled na znalost jako na objekt.

3.1.4 Znalosti a umělá inteligence

Moor (2003) tvrdí, že umělá inteligence (*Artificial Intelligence*) díky svým metodám změnila pohled na informace a staví nad ně znalosti jako formu generalizace a abstrakce. Jedná se v podstatě o vědní inženýrský obor, jenž se dle Maříka et al. (1993) zabývá tvorbou strojů, které mají inteligentní chování, s cílem dosáhnout úrovně lidského rozumu. Výzkum umělé inteligence není triviální, navíc bývá rozdělen i do mnoha názorově odlišných oblastí. Při řešení základních problémů z hlediska výzkumu umělé inteligence se vědci zabývají znalostmi, uvažováním, učením, plánováním, vnímáním a schopností manipulovat s předměty či zpracováním přirozeného jazyka a dalšími oblastmi (Mařík et al., 2007).

Metody umělé inteligence jsou využívány již od 70. let 20. století. V poslední době však jejich význam narůstá a s jejich aplikacemi se lze setkat prakticky denně, aniž by si to jejich uživatelé vůbec uvědomovali, například při využívání aplikací v rámci Internetu a Webu (Mohammad a Zitar, 2011).

Moor (2003) uvádí, že z hlediska metod umělé inteligence je v popředí zájmu odborníků distribuovaná umělá inteligence a strojové učení, což dokazují i četné aktuální publikace (např. při užívání automatizovaných klasifikačních regresních stromů při hledání faktorů ovlivňující rakovinu žaludku (Silvera et al., 2014), či sledování neuronových sítí a dalších data miningových technik v modelování a práci s geografickými daty (Tayyebi a Pijanowski, 2014). Dle Maříka (1997) se však do přístupů k řešení problémů umělé inteligence ještě řadí například neuronové sítě (Hastie, Tibshirami a Friedman, 2008), genetické programování (Popelka et al., 2014), prohledávání stavového prostoru, dobývání znalostí a expertní systémy (Amirian et al., 2015). Poslední zmíněný přístup, tj. expertní systémy, jsou využívány v rámci expertního inženýrství, jehož druhem je i znalostní inženýrství (*Knowledge Engineering*). Metody znalostního inženýrství pro reprezentace znalostí budou užity ve výzkumné části disertační práce.

3.1.5 Znalostní inženýrství v systémovém pojetí

Dle Janíčka et al. (2013) je systémové inženýrství základní disciplínou teorie systémů, jelikož má systémový, nadoborový a interdisciplinární a komplexní charakter. Více autorů, např. Glava a Glava (2011) nebo Brožová et al. (2011), vyzdvihuje význam obecné teorie systémů a systémového přístupu.

V současné době vzniká celá řada inženýrství v různých oborech, která v sobě vstřebala některé prvky systémového inženýrství. Tato nová inženýrství se prohlubovala směrem specializace konkrétního inženýrství (Lhotská, Mařík a Vlček, 2001).

Na přelomu 60. a 70. let se odborníci na umělou inteligenci shodli na tom, že znalosti jsou základem pro řešení různých úloh a problémů. Tato skutečnost ovlivnila začátek éry znalostního inženýrství, a to v podobě zpřístupňování znalostí počítačovým systémům (Janíček et al., 2013).

Znalostní inženýrství souviselo ve svých počátcích převážně s expertními systémy (Mařík a Kouba, 1991; Lhotská, Mařík a Vlček, 2001), které řeší problémy pomocí produktivních přístupů, jako je například prohledávání stavových prostorů apod. (Mařík et al., 1993; Mařík et al., 2007).

Základními elementy expertních systémů jsou báze znalostí, báze údajů a řídicí neboli inferenční mechanismus, který tvoří jádro celého systému. V průběhu let se funkce znalostních inženýrů vyvíjela (Rosenberg a Steinmueller, 2013), nyní je hlavním úkolem znalostního inženýra vytvářet jednotné znalostní infrastruktury, tj. abstraktní soustavy, jejímiž prvky jsou množiny znalostních systémů, jež umožňují realizaci množiny znalostních procesů (Hall, 2012). Znalostní infrastruktura je prostředkem pro zefektivnění práce se znalostmi, tj. má umožňovat správu znalostí v určité organizaci, např. podnik, univerzita, apod. (Janíček et al., 2013).

Znalostní inženýrství se dle Janíčka et al. (2013) zabývá veškerými činnostmi, jež jsou spojeny s vývojem znalostně orientovaných aktivit a aplikací (získávání, zpracování, prezentace, uchování a využívání znalostí). V tomto pojetí má znalostní inženýrství význam i v jiných disciplínách, jako ve znaleckém inženýrství, v inženýrství rizik, jakosti a v neposlední řadě v oblasti pedagogiky (Hsu et al., 2010; Chu, Hwang a Tsai, 2010; Wolff a Lockett, 2013).

3.2 Metody pro reprezentaci znalostí

Reprezentace znalostí jsou součástí vědního oboru znalostního inženýrství. Pro zachycení znalostí, které jsou pak dále využívány pro řešení problémů v expertních a znalostních systémech, se používají různé metody. Nejvýznamnější a nejčastěji používané metody pro reprezentaci znalostí bývají: produkční pravidla, rozhodovací tabulky, rozhodovací stromy, sémantické sítě, rámce (Mařík et al., 2007) nebo znalostní jednotky (Brožová et al., 2011).

Mařík et al. (1993) řadí mezi procedurální reprezentace znalostí produkční pravidla, rozhodovací tabulky, rozhodovací stromy. Mezi deklarativní reprezentace znalostí pak sémantické sítě a rámce. Jiní autoři, např. Collins et al. (1988), vyčleňují rámce jako třetí samostatné schéma pro reprezentaci znalostí, jenž představuje syntézu procedurálního a deklarativního přístupu.

3.2.1 Produkční pravidla

Produkční pravidla, jak uvádějí Drábek, Seidel a Traufer (2006), jsou založena na výrokové logice. Dle formy jejich zápisu mohou být také označovány jako *IF-THEN* (*KDYŽ-POTOM*) pravidla. Díky možnostem jednoduché práce s nimi bývají produkční pravidla jednou z nejpoužívanějších forem reprezentace znalostí. Eichhoff a Roller (2014) zmiňují, že pravidla mohou být vyjádřena několika způsoby, a to jak procedurálně, tak deklarativně:

- *KDYŽ podmínka, POTOM akce;*
- *KDYŽ předpoklad, POTOM důsledek.*

Dle Houšky (2011) se každé produkční pravidlo skládá ze dvou částí, z části podmínkové (antecedent) a důsledkové (konsekvent).

Podmínková část může zahrnovat buď jednoduchý, nebo složený výrok. V podmínkové části může být v případě užití složeného výroku užito více spojek výrokové logiky, tedy konjunkce (spojka „AND“), alternativy (spojka „OR“) či výlučné alternativy (spojka „XOR“). Také důsledková část může obsahovat jednoduchý, nebo složený výrok. Je-li použit složený výrok, pak má smysl pouze spojka „AND“, a to kvůli požadavku jednoznačnosti produkčního pravidla.

I když produkční pravidla už jsou relativně historickým konceptem, jejich využití a aplikace můžeme nalézt i v současnosti, např. v oblasti lingvistiky (Feng a Hirst, 2012) či pedagogiky (Keshtkar et al., 2013) a dalších oblastech.

3.2.2 Rozhodovací tabulky a rozhodovací stromy

Dalším ze způsobů, jak lze reprezentovat znalost, je rozhodovací tabulka (Kohavi, 1995). Dle autorů Hyafil a Rivesty (1976) rozhodovací tabulka vyjadřuje závislost mezi podmínkami a k nim určeným akcím. Obecná rozhodovací tabulka se skládá z řádků a sloupců, jenž formálně vytvářejí tři oblasti rozhodovací tabulky - oblast podmínek, akcí a pravidel.

Horní řádky rozhodovací tabulky zachycují otázky. Každá zjišťovací otázka představuje jednu výchozí podmínku. Dohromady pak výchozí podmínky (všechny horní řádky tabulky) vytváří oblast podmínek. Dolní řádky rozhodovací tabulky odpovídají akcím, které mají být vykonány v závislosti na výchozích podmínkách. Sloupce zaznamenávají částečné znalosti formou pravidel, která určují vztah mezi podmínkami a akcemi. Všechny sloupce tvoří oblast pravidel (Kohavi, 1995).

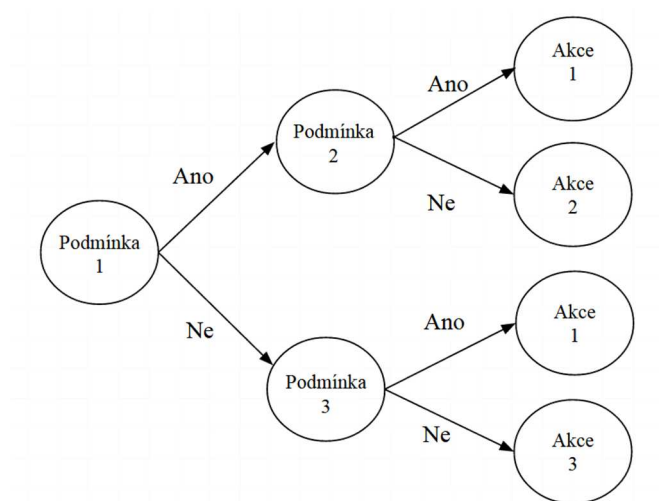
Každé políčko tabulky, průsečík řádku a sloupce (tj. proměnné a_{hj} a b_{ij} , kde $h = 1, 2, \dots, q$, $i = 1, 2, \dots, m$, $j = 1, 2, \dots, n$) může být buď prázdné (není-li pravidlo relevantní), nebo může obsahovat odpověď na příslušnou otázku (jedná-li se o řádek, kterému odpovídá podmínka) nebo rozhodnutí (odpovídá-li řádku akce). Odpovědi na otázky a rozhodnutí nabývají pouze dvou hodnot, nejčastěji se zapisují slovně „ANO“, „NE“, či jinými bivalentními symboly (Quinlan, 1987; Rokach, 2016).

Rozhodovací stromy jsou grafickou obdobou rozhodovacích tabulek, tzn. rozhodovací tabulku lze překreslit do podoby rozhodovacího stromu, jak zobrazuje obrázek 2 (Hyafil a Rivesta, 1976).

Rozhodovací strom, jak uvádí Quinlan (1986), lze chápat jako uspořádanou čtveřici (G, q, p, α) , kde: G je kořenový graf typu strom, q je zobrazení přiřazující neterminálním uzlům otázky (podmínky), p je zobrazení přiřazující hranám grafu G odpovědi na otázku (pravidla), α je zobrazení přiřazující terminálním uzlům jednotlivá rozhodnutí (akce).

Dále musejí být splněny následující tři omezení:

1. Na žádné cestě vedoucího z kořene do některého uzlu nejsou dva uzly, kterým by byla přiřazena stejná otázka.
2. Každý neterminální uzel u o úrovni $l(u)$ má tolik sousedů s úrovní $l(u) + 1$, kolik odpovědí má otázka přiřazená danému neterminálnímu uzlu.
3. Hranám spojujícím neterminální uzel u o úrovni $l(u)$ s jeho sousedy na úrovni $l(u) + 1$ jsou přiřazeny všechny odpovědi na otázku $q(u)$.



Obrázek 2 Ukázka obecného rozhodovacího stromu, zdroj: Mařík et al., (1993), zpracování vlastní

3.2.3 Sémantické sítě

Znalosti mohou být též reprezentovány pomocí orientovaného ohodnoceného grafu, sémantické sítě (Mallat et al., 2015). Sémantická síť umožňuje vyjádřit vztahy fyzikální, kauzální, taxonomické. Uzly grafu reprezentují objekty a hrany grafu reprezentují relace mezi objekty. Hrany grafu jsou orientované od konkrétnější entity k obecnější a jsou ohodnocené typem vazby (Sowa, 2014). Mezi nejčastěji používané typy vazeb patří „je“ (*is-a*), „je částí“ (*part-of*), „je druhem“ (*a-kind-of*). Mezi hlavní výhody sémantických sítí patří jednoduchost reprezentace a možnost poskytnutí vyšší úrovně porozumění akcím, příčinám a událostem vyskytujících se v dané doméně (Mallat et al., 2015). Nevýhoda spočívá právě v omezenosti grafického vyjádření, které v případě většího množství uzlů a hran může být nepřehledné (Mařík et al., 1993). V databázích vědeckých příspěvků je možné se setkat s velkým počtem aplikací a využití sémantických sítí. V oblasti

pedagogiky a lingvistiky ji využívají např. Cohen et al., 2016; Navigli a Ponzetto, 2012 nebo Jørgensen et al., 2014.

3.2.4 Rámce

Dle Collinse et al. (1988) jsou rámce další možností, jak lze reprezentovat znalosti. Informace jsou v nich sdružovány podobně jako v sémantických sítích. Rámce se skládají z položek, jež popisují jednotlivé vlastnosti objektu (Presutti et al., 2012). Položky nabývají konkrétních hodnot v průběhu užívání rámce. Rámce lze zapsat pomocí tabulek. Popis položky sestává z jejího jména a hodnoty položky. Jména položek odpovídají hranám a jejich hodnoty uzlům sémantických sítí (Lomov a Shishaev, 2014).

Rámce oproti sémantickým sítím však poskytují též možnost členění jednotlivých položek, a tak lze získávat další informace o popisované vlastnosti objektu. Položky se dělí na fasety. Ke každé fasetě může být přidružen jeden nebo několik démonů. Démon je spící procedura, která se aktivuje, až pokud nastanou určité události (Mařík et al., 1993).

Rámec, který je podtřídou nebo instancí jiného rámce, automaticky dědí všechny jeho položky, avšak nutně nemusí dědit i jejich hodnotu (Mařík et al., 1997).

3.2.5 Znalostní jednotky

Mezi nové koncepty vhodné pro reprezentaci znalostí patří znalostní jednotky, kterými se ve svých pracích zabývají Dömeová, Houška a Houšková Beránková (2008) či Brožová et al. (2011). Znalostní jednotka poskytuje uživatelům návod na řešení elementárních problémů.

Dle Brožové et al. (2011) má znalostní jednotka analytickou a jazykovou formu. Analytická forma znalostní jednotky je vyjadřována jako:

$$KU = \{X, Y, Z, Q\} \quad 1$$

Kde X je problémová situace, Y je elementární problém, Z je cíl řešení elementárního problému, Q je řešení elementárního problému.

Jazyková forma se opírá o produkční pravidlo, které je rozšířené o dvě nové explicitně vyjádřené komponenty X (popis problémové situace) a Z (cíl řešení elementárního problému).

Zápis znalostní jednotky pak má tento obecný univerzální tvar:

„Když je třeba v rámci problémové situace X řešit elementární problém Y , aby bylo dosaženo cíle Z , potom je třeba aplikovat řešení Q .“

Znalostní jednotka je atomickým objektem, který není možné ani účelně dělit na více částí. V případě oddělení některé z částí ztrácí objekt kvalitu znalosti. Na znalostní jednotky lze aplikovat i operace, které vycházejí z hierarchického přístupu modelování znalostí. Unární operace jsou operacemi, kdy vstupem je jedna znalostní jednotka a výstupem taktéž jedna znalostní jednotka. Mezi unární operace patří „drill-down“ a „roll-up“. Binární operace vyžadují dva vstupy (dvě znalostní jednotky) a přinášejí výstup jednu novou znalostní jednotku. Mezi binární operace patří „jednoduché skládání“, „jednoduchý rozklad“, „integrace“ a „desintegrace“ (Houška, 2011).

Na základě výše popsaného konceptu znalostních jednotek byla na České zemědělské univerzitě v Praze vytvořena skripta pro výuku lineárního programování (Houška a Beránková, 2008). Jedná se o texty, které na rozdíl od běžných vzdělávacích textů umožní uživatelům práci s kvalitativně odlišnou (vyšší) formou textu s explicitně vyjádřenými znalostmi. Během několika experimentů (Houška a Houšková Beránková, 2007) s těmito texty ve vzdělávání bylo prokázáno, že studenti intuitivně vnímají rozdíly mezi texty, které jsou vytvořeny pomocí znalostních jednotek a normálními texty, avšak sami od sebe nedokážou přesně definovat, v čem spočívá tento rozdíl. Pedagogické dopady (dané úspěšností v testu) výuky na základě textů s explicitně vyjádřenými znalostmi, prostřednictvím znalostních jednotek, jsou pozitivní. Na pozitivních dopadech výsledků se projevil i fakt, že se studenti díky specifické úpravě textu, kromě postupů, také dozvídají proč a jak jednotlivé činnosti dělat a též proč se je mají učit (Dömeová, Houška a Houšková Beránková, 2008).

3.3 Text jako nástroj transferu znalostí z pohledu pedagogiky

3.3.1 Transfer znalostí

Z pohledu pedagogiky jsou zdrojem přenosu znalostí didaktické prostředky užívané v procesu vyučování. Skalková (2007) definuje didaktické prostředky jako všechny materiální předměty, které zajišťují, podmiňují a zefektivňují průběh vyučovacího procesu. Dle Maňáka (1995) by měly didaktické prostředky spolu se zvolenými metodami a organizačními formami výuky přispívat k dosažení výchovně-vzdělávacích cílů. Skalková (2007) zmiňuje, že součástí didaktických prostředků jsou učební pomůcky.

Dle Maňáka (1995) lze učební pomůcky rozdělit do několika kategorií: a to na skutečné předměty (přírodniny, výrobky, preparáty), modely (statické a dynamické), zobrazení (obrazy, symbolická zobrazení statická – diaprojekce, zpětná projekce, epiprojekce či dynamická projekce – film, video, televize), zvukové pomůcky (hudební nástroje, gramofonové desky, nosiče hudby), dotykové pomůcky (reliéfové obrazy, slepecké písmo), literární pomůcky (učebnice, příručky, atlasy, texty), software pro vyučovací automaty a počítače.

Ve výzkumné části disertační práce z hlediska výše zmíněné klasifikace Maňáka (1995) se autorka zaměřuje pouze na literární učební pomůcky, a to na učební texty. Na učební texty nahlíží jako na možný zdroj dat, informací a znalostí (se striktně odlišenými vlastnostmi z pohledu znalostního inženýrství), a to tak, že sleduje úspěšnost přenosu znalostí (transferu znalostí) u čtenářů, kteří text používají k učení a možnému následnému řešení problémů.

Jedním z aktuálních témat v oblasti transferu znalostí je měření jeho efektivnosti a efektivity, a to jak na úrovni vzdělávacích institucí, tak na úrovni podnikové. Problematice hodnocení efektivity vzdělávání a různých pedagogických modelů se věnují Tudor (2012) či Singer a Moscovici (2008). Starý a Chvál (2009) popisují modely kvality a efektivity na pedagogické úrovni. Jeden z velmi často sledovaných aspektů efektivity vzdělávání je efektivita vyučovacích metod (Maňák a Janík, 2009), jež může být ovlivněna např. i prací s texty. Experimenty související s analýzou učebních textů a učebnic mají

za cíl objasnit význam některých vlastností a parametrů učebnic a potažmo zhodnotit i jejich možný vliv na výsledky vzdělávání (Mikk, 2007).

3.3.2 Učebnice a textové učební pomůcky ve vzdělávání

Učebnice dle Maňáka (2003) je chápána jako učební pomůcka obsahující systematický výklad učiva. Přesnější a podrobnější vymezení učebnice a vzdělávacích textů nelze nalézt, vyjma jejich charakteristik dle různých kritérií výchovně-vzdělávacího procesu (Průcha et al., 1998). Průcha et al. (1998) chápe učebnici jako edukační konstrukt, působící jako prvek kurikulárního projektu, jenž je součástí systému didaktických prostředků materiální povahy, jako druh školních didaktických textů. Spolu s učebnicemi se mezi školní didaktické texty řadí například i vzdělávací texty, pracovní listy, knihy, encyklopedie, texty psané na tabuli, čítanky, slovníky, sbírky úloh, atlasy apod. Přičemž jednotlivé druhy didaktických textů plní ve výchovně-vzdělávacím procesu různé funkce (Maňák a Knecht, 2008).

Učebnice a učební texty jsou dlouhodobě předmětem pedagogického výzkumu v České republice. Současný výzkum učebnic v českém prostředí se zaměřuje na dvě oblasti, a to: a) v oblasti teorie kurikula a reálné výuky, b) hodnocení vlastností učebnic prováděné pomocí exaktních nástrojů (Maňák a Klapko, 2006). První oblast výzkumu sleduje začlenění učebnic do komplexního systému *kurikulum a výuka*, sleduje se tedy uplatnění učebnic a jiných médií při výuce, resp. soulad obsahu vzdělávání vymezeného v kurikulárních dokumentech s jeho konečnou realizací ve výuce (Maňák a Klapko, 2006).

V posledních letech je však v českém výzkumu učebnic a textových fragmentů u autorů jako např. Beneš et al. (2009) nebo Hrabí (2012) nejvíce zájmu věnováno druhé výše zmíněné oblasti, a to v podobě měření parametrů textů učebnic, spadají sem zejména *měření obtížnosti textu učebnic, měření sémantické koherence textu, měření didaktické vybavenosti učebnic* či *obsahová analýza učebnic* (Knecht a Janík, 2007).

3.3.3 Měření parametrů učebnic

Průcha (2006) navrhl měření didaktické vybavenosti učebnic tak, že rozlišuje 27 verbálních a 9 obrazových komponentů. Komponenty jsou rozříděny do třech kategorií, a to podle toho, jakou funkci v rámci učebnice plní. První kategorií je *Aparát prezentace učiva*,

do něhož se zahrnuje výkladový text, shrnutí, modely, tabulky, schémata apod. Druhou kategorií je *Aparát řízení učení* - do něhož se zařazují například otázky a úkoly k schématům, cvičení, užití zvláštního fontu písma či barev pro určité části textu. Třetí kategorií je *Aparát orientace v učebnici*, kam spadá členění na lekce, rejstřík, užití živých záhlaví apod.

Dle toho, jak jsou v učebnicích zastoupeny jednotlivé komponenty výše zmíněných třech kategorií, lze vypočítat dílčí koeficienty.

Dílčí koeficienty didaktické vybavenosti učebnice se skládají z koeficientu využití aparátu prezentace učiva (*EI*), koeficientu využití aparátu řízení učení (*EII*), koeficientu využití aparátu orientačního (*EIII*), koeficient využití verbálních komponentů (*Ev*), koeficient využití obrazových komponentů (*Eo*). Navíc se měří též *celkový koeficient didaktické vybavenosti učebnice (E)*. Způsob výpočtu a instrukce k této metodice, včetně interpretace výsledků uvádí Průcha (1998).

Ve výzkumné části disertační práce jsou využity textové fragmenty, ne celé učebnice. Proto je pro měření parametrů těchto textů vhodné použít metodu pro měření obtížnosti textu.

Analýza obtížnosti textu bývá používána i v zahraničí, například někteří autoři (Mavasoglu a Dincer, 2014) analyzují obtížnost textu v učebnicích v komparaci se vzdělávacími texty dostupnými na internetu. V Indii byla využita analýza vzdělávacích textů jako nástroj pro zjištění příčiny špatných čtenářských dovedností u žáků na nižších stupních základní školy (Gupta, 2014). Nejvíce nástrojů pro měření obtížnosti textů (*readability formulas*) je vypracováno pro anglický jazyk, mezi nejznámější a nejčastěji používané ukazatele patří *Flesch reading ease* a *Flesch–Kincaid grade level*, přičemž oba ukazatele jsou založeny na počtu a délce slov a vět v analyzovaném textu. Tyto základní ukazatele se využívají nejen v pedagogice (Tinkler a Woods 2013), ale i například při sledování obtížnosti textových materiálů určených pro pacienty či příslušníky rodin, ve kterých je pacient s chorobou, která vyžaduje zvláštní režim, popsany v textových materiálech apod. (Wang et al. 2013).

Pro český jazyk rozpracoval ukazatele pro měření obtížnosti vzdělávacích textů Průcha (1984), který měří celkovou obtížnost textu jako sumu sémantické a syntaktické obtížnosti. Podrobný popis výpočtu a vzorce jsou součástí kapitoly 2.4.1. popisující nástroje didaktické analýzy.

Řešení výzkumné části práce vyžaduje zpracování většího množství textů, aby bylo možno navržené ukazatele kvantifikovat a stanovit typické rozsahy jejich hodnot pro znalostní texty. Někteří autoři, např. Tannenbergová (2009, 2011), Janoušková (2008) nebo Hodis (2003), zpracovávají texty a provádí vyhodnocení jejich charakteristik ručně.

Již Pala (2000) však ukázal, že softwarové výstupy analýzy textu jsou účinnější než klasické ruční zpracování, byť jsou s ním spojeny určité problémy, zejména v českém jazykovém prostředí. Programy pro analýzu textu a jejich praktické aplikace jsou běžně dostupné pro angličtinu (Textalyzer.net, Text Quest). Český jazyk má celou řadu specifik. META-NET, excelentní internetová síť financovaná Evropskou komisí, provedla analýzu současných jazykových zdrojů a technologií, jak uvádí Bojar et al. (2012) v Sérii Bílé knihy, specifika českého jazyka v digitálním věku se odrážejí i v omezeném množství dostupných programů pro jazykové analýzy. Software pro analýzu českého jazyka nejčastěji slouží ke kontrole pravopisu, webovému vyhledávání, hlasové ovládní a strojovému překladu. Pro textovou analýzu z hlediska didaktiky je množství dostupných softwarových prostředků omezené.

3.4 Metodický aparát pro měření efektivnosti transferu znalostí

3.4.1 Nástroje didaktické analýzy

Pro zjišťování vlivu textů jako nástrojů transferů znalostí jsou ve výzkumné části práce použity didaktické testy, a to ve dvou fázích. Za prvé ve formě pretestu pro zjištění předchozí úrovně znalostí (Ozuru, Dempsey a McNamara, 2009), za druhé pro zjištění úspěšnosti transferu znalostí jako klasický posttest (Arzhakov a Silnov, 2016).

Je však nutné, aby oba dva typy testů splňovaly určité didaktické předpoklady. Chrástka (2007) uvádí několik vzorců, pomocí nichž lze ověřit nejen vlastnosti jednotlivých testových úloh, ale i didaktického testu jako celku. Při analýze obtížnosti testových úloh se počítá hodnota obtížnosti Q , která udává procento testovaných ve vzorku, kteří danou úlohu zodpověděli nesprávně:

$$Q = 100 \frac{n_n}{n} \quad 2$$

Kde Q je hodnota obtížnosti, n_n je počet testovaných osob ve skupině, které odpověděly nesprávně nebo neodpověděly, n je celkový počet testovaných ve vzorku.

Někdy bývá vyjadřován index obtížnosti P , jako procento testovaných ve skupině, kteří danou úlohu zodpověděli správně:

$$P = 100 \frac{n_s}{n} \quad 3$$

Kde P je index obtížnosti, n_s je počet testovaných ve skupině, kteří odpověděli správně, n je celkový počet testovaných ve vzorku.

Citlivost testových úloh se měří ukazateli, které vyjadřují rozlišovací schopnost úloh, tj. jak dalece daná úloha zvýhodňuje testované osoby s lepšími vědomostmi, před osobami s horšími vědomostmi. Proto je nutné před konstrukcí samotného ukazatele rozdělit

skupinu testovaných podle celkového počtu dosažených bodů na stejně velké dvě části, tj. testování s lepším skóre a testování s horším skóre celkových dosažených bodů.

Koeficientů pro určení citlivosti testových úloh je mnoho, avšak mezi nejjednodušší patří koeficient *ULI* (*upper-lower-index*):

$$d = \frac{n_L - n_H}{0,5n} \quad 4$$

Kde d je koeficient citlivosti *ULI*, n_L je počet osob z lepší skupiny, které danou úlohu zodpověděly správně, n_H je počet osob z horší skupiny, které danou úlohu zodpověděly správně, n je celkový počet testovaných ve vzorku.

Všechny koeficienty citlivosti nabývají hodnot od -1 do +1 a platí, že čím má koeficient vyšší hodnotu, tím úloha lépe rozlišuje mezi osobami s lepšími vědomostmi a mezi osobami s horšími vědomostmi. Je-li koeficient roven 0, tak osoby z obou skupin jsou v úloze stejně úspěšné a úloha nerozlišuje mezi těmito skupinami, pokud je koeficient velmi nízký nebo dokonce záporný, tak se jedná o komplikovaně formulované úlohy nebo obtížné úlohy s výběrovými odpověďmi.

Dle Chrásky (2007) se při analýze vlastností didaktického testu jako celku řeší jeho validita, reliabilita a praktičnost. Validita je základní vlastnost didaktického testu. Někteří autoři (Zainal, 2012; Naqvi, Hashmi a Hussain, 2010) testují validitu, aby zjistili, zda pomocí testů zkouší opravdu to, co má být zkoušeno. Disman (2011) uvádí, že reliabilita didaktického testu ukazuje jeho spolehlivost, tj. zda při opakování testování za týž podmínek lze získat stejné nebo obdobné výsledky. Chráska (2007) exaktně měří reliabilitu pomocí koeficientu reliability, který nabývá hodnot od 0 do 1. U testů s vyšším počtem otázek než 10 je vhodné, aby koeficient reliability nabýval minimálně hodnoty 0,8.

Koeficienty reliability se počítají více způsoby, ale velmi často užívaný bývá Kuderův-Richardsonův vzorec, který například užívají ve své práci i Miller a Achterberg (2000):

$$r_{kr} = \frac{m}{m-1} \left(1 - \frac{\sum ab}{s^2}\right) \quad 5$$

Kde r_{kr} je koeficient reliability, m je počet úloh v testu, a je podíl žáků ve vzorku, kteří řešili úlohu testu správně, b je podíl žáků ve vzorku, kteří řešili úlohu testu nesprávně, s je směrodatná odchylka pro celkové výsledky žáků v testu.

Pomocí standardizace didaktického testu, jak uvádí Štuka et al. (2013), lze porovnat výkon jednotlivého testovaného s reprezentativním vzorkem ostatních testovaných. Vytvoří se testová norma, pomocí které lze testovaného zařadit do určité stupnice či škály. Nejjednodušší metodou je standardizace pomocí percentilů, kdy se určuje percentilové pořadí PR dle vzorce:

$$PR = 100 \frac{n_k - \frac{n_i}{2}}{n} \quad 6$$

Kde PR je percentilové pořadí, n_i je četnost daného výsledku, n_k je kumulativní četnost daného výsledku, n je celkový počet testovaných ve vzorku. Hodnota percentilového pořadí určí, kolik procent testovaných referenční skupiny mělo výsledek horší než daný testovaný nebo stejný jako on.

Mezi další nástroje didaktické analýzy v rámci oblasti měření parametrů textů, ve smyslu nástrojů pro transfer znalostí, je analýza obtížnosti textů.

K posuzování obtížnosti textů učebnic (textových fragmentů) psaných v českém jazyce je využívána metodika vypracovaná Průchou (1984), kdy celkovou obtížnost textu T lze vypočítat dle následujících vzorců:

$$T = T_s + T_p \quad 7$$

Kde T_s je stupeň syntaktické obtížnosti textu (v bodech), T_p je stupeň sémantické obtížnosti textu (v bodech).

$$T_s = 0,1\bar{V}\bar{U} \quad 8$$

Kde \bar{V} je průměrná délka věty v počtu slov, \bar{U} je průměrná délka větných úseků (syntaktická složitost věty).

$$T_p = 100 \frac{\sum P \sum P_1 + 2 \sum P_2 + 3 \sum P_3}{\sum N} \quad 9$$

Kde N je celkový počet slov v analyzovaném textu, $\frac{\sum P}{\sum N} \cdot 100$ je procentuální proporce substantivních pojmů, $\frac{\sum P_1}{\sum N} \cdot 100$ je procentuální proporce substantivních běžných pojmů, $\frac{\sum P_2}{\sum N} \cdot 100$ je procentuální proporce substantivních odborných pojmů, $\frac{\sum P_3}{\sum N} \cdot 100$ je procentuální proporce substantivních faktografických pojmů.

Dále se mimo celkové obtížnosti vyjadřuje i koeficient hustoty odborné informace, a to buď v podobě vyjádření proporce odborných a faktografických pojmů na celkové sumě slov i či proporce odborných a faktografických pojmů na celkové sumě všech substantivních pojmů h .

$$i = 100 \frac{\sum P_2 + \sum P_3}{\sum N} \quad 10$$

$$h = 100 \frac{\sum P_2 + \sum P_3}{\sum P} \quad 11$$

Interpretaci jednotlivých hodnot uvádí Průcha (1984). Pro různé vyučovací předměty a různé textové fragmenty z učebnic pro ročníky základních škol, včetně jejich vývoje v letech, je možno nalézt v pracích u mnoha českých autorů (Tannenbergová, 2009; Tannenbergová, 2011; Janoušková, 2008; Hodis, 2003).

3.4.2 Statistické modelování

Následující výčet statistických metod není úplný, poukazuje pouze na metody, jež jsou použity v rámci výzkumné části práce. Jedná se zejména o základní popisné statistiky, postupy v rámci statistické indukce, tj. teorie odhadu a testování statistických hypotéz, analýza kategoriálních dat a další. Jelikož se jedná o standardně užívané metody, nejsou jednotlivé vzorce uváděny, ale je uvedena publikace, ve které je možné vyčíst jednotlivé způsoby výpočtu, znění nulových hypotéz apod.

Základní popisné statistiky jsou chápány jako číselné hodnoty podávající základní informaci o vlastnostech statistického souboru. Podle toho, jaké vlastnosti rozdělení charakteristiky popisují, rozdělují se na charakteristiky polohy, variability, šikmosti a špičatosti (Lindsey, 2009). Charakteristiky polohy poskytují informaci o daném rozdělení. Míra polohy je taková hodnota náhodné veličiny, kolem které se soustřeďují všechny ostatní hodnoty náhodné veličiny. Mezi střední hodnoty se řadí průměry a ostatní střední hodnoty. Charakteristiky variability hodnot znaků jsou čísla, která popisují proměnlivost sledovaného kvantitativního znaku. Je-li variabilita hodnot znaku nízká, pak příčiny, které ji způsobují, jsou pokládány za nepodstatné. Naopak vysoká variabilita svědčí o nevyrovnanosti souboru (Tsokos a Wooten, 2016). Základní mírou variability je rozptyl, který měří současně variabilitu hodnot kolem aritmetického průměru a variabilitu ve smyslu vzájemných odchylek jednotlivých hodnot znaku. Charakteristiky šikmosti a špičatosti se vyhodnocují výjimečně. Statistické hodnoty mající stejnou polohu a variabilitu se mohou lišit tvarem rozdělení četností. Liší-li se stupeň koncentrace malých hodnot a stupeň koncentrace velkých hodnot, vykazuje rozdělení četností znaku zešikmení. Pokud se liší stupeň koncentrace hodnot prostřední velikosti od stupně koncentrace ostatních hodnot, pak rozdělení četností vykazuje výraznou špičatost či je ploché (Hastie, Tibshirami a Friedman, 2008).

Další oblastí statistického modelování užitého ve výzkumné části práce je statistická indukce sestávající se z teorie odhadu a testování statistických hypotéz. Díky statistické

indukci lze usuzovat o vlastnostech základních souborů na základě dat z náhodných výběrových vzorků. U teorie odhadu se odhaduje neznámý parametr populace na základě náhodného výběru (Tsokos a Wooten 2016). U statistického testování jsou využívány jak jednovýběrové, dvouvýběrové i vícevýběrové testy, a to buď v parametrické podobě (jsou-li splněny předpoklady pro užití parametrických testů) nebo v jejich méně silných (z hlediska síly testu a schopnosti zamítnutí nulové hypotézy) neparametrických obdobách. Z parametrických dvouvýběrových testů je ve výzkumné části práce použit např. test o shodě dvou relativních četností, test o shodě dvou průměrů u nezávislých vzorků (T test) a test o shodě dvou rozptylů (F test).

Pro testování statisticky významné závislosti faktoru na hodnotu náhodné veličiny je použit zástupce vícevýběrových parametrických testů - analýza rozptylu (ANOVA), konkrétně jednofaktorová analýza rozptylu, která sleduje vliv pouze jednoho kvalitativního znaku na kvantitativní znak. V případě zamítnutí nulové hypotézy o neexistenci rozdílů v průměrech u jednotlivých obměn (variant) statistického znaku na zvolené hladině významnosti, bylo provedeno i podrobnější vyhodnocení, tzv. post-hoc analýza (Gravetter a Wallnau, 2009). V případě nesplnění předpokladů pro užití parametrického testu ANOVA (např. data nepochází ze souboru s normálním rozdělením (lze otestovat pomocí Shapiro-Wilkova testu), heteroskedasticita rozptylů (lze otestovat pomocí Whiteova testu)), je možné využít neparametrickou obdobu – Kruskal Wallisův test a Duncanovu metodu pro případnou následnou post-hoc analýzu (Bassett, Bremner a Morgan, 2000).

Dále součástí výzkumné části práce je i testování statistických hypotéz o nezávislosti kvalitativních znaků v kontingenčních tabulkách. Kontingenční tabulky slouží k vizualizaci vztahů mezi jednotlivými kvalitativními znaky. Relevantní hypotézy se testují pomocí χ^2 testu. V případě zamítnutí nulové hypotézy o nezávislosti znaků na zvolené hladině významnosti je možné ověřit i sílu závislosti, a to pomocí Pearsonova koeficientu kontingence či na základě jiných koeficientů (Lindsey, 2009).

Další pokročilejší statistické metody užití ve výzkumné části práce jsou podrobněji popsány v následující kapitole Data miningové techniky. Nulová hypotéza tvrdí, že neexistuje rozdíl mezi relativními četnostmi prvního a druhého souboru.

3.4.3 Data miningové techniky

Strojové učení (jako součást umělé inteligence) a jeho metody jsou například využívány v oblasti data miningových technik, kdy je potřeba vyhledat jisté závislosti, vzory a trendy na základě vlastností dat uložených v databázích, např. v (Nauman a Thompson, 2014; Moradi et al., 2013; Tayyebi a Pijanowski, 2014).

Jedním z hlavních problémů strojového učení (*machine learning*) je klasifikační problém, tj. přiřazení tříd objektům (rozpoznání jednotlivých objektů), se kterým se lze setkat v pracích u Szymczyk a Szymczyk, 2015; da Silva et al., 2015; Rajan et al., 2009. Dle toho, jakým způsobem se stroj učí, jsou rozlišovány metody strojového učení s učitelem a bez učitele. Při strojovém učení s učitelem (Chen et al., 2010; Huang et al., 2014) je stroji předkládána sada objektů se známou klasifikací, které se naučí a dále je sám schopen přiřadit neznámý objekt do definovaných tříd. U učení bez učitele (Amirian et al., 2015) stroj sám musí odhalit třídy objektů například pomocí shlukové analýzy (Shi, 2014). Četně využívané ke klasifikaci bývají umělé neuronové sítě (Wang et al., 2010; Egrioglu et al., 2014; da Silva et al., 2015) a klasifikační a regresní stromy (Silvera et al., 2014; Shao a Lunetta, 2012; Tayyebi a Pijanowski, 2014). Oba tyto přístupy se řadí do strojového učení s učitelem a kromě klasifikace umožňují i predikci (Egrioglu et al., 2014; Moradi et al., 2013). Někteří autoři pracují s více modely v rámci výše zmíněných přístupů a vzájemně je porovnávají z hlediska jejich přesnosti a správnosti klasifikace (Razi a Athappilly, 2005; Moraes et al., 2013). Aplikace modelů založených na umělé inteligenci zasahují do širokého spektra oblastí např. od informačních technologií (Mohammad a Zitar, 2011), přes fyziku (Moradi et al., 2013), geologii (Szymczyk a Szymczyk, 2015), lingvistiku (Rajan et al., 2009) až do medicíny (Silvera et al., 2014) a dalších oblastí.

Klasifikační a regresní stromy

Klasifikační stromy (též známé jako rozhodovací stromy) jsou vhodným nástrojem pro klasifikaci, regresní stromy jsou pak zobecněním stromů klasifikačních. Výhoda stromů spočívá v tom, že uživateli poskytnou jasnou srozumitelnou posloupnost rozhodnutí, jejichž výsledkem je zařazení daného objektu (na základě jeho vlastností) do jedné ze tříd. Další výhodou je přehlednost a názornost stromů v případě jejich grafického zobrazení.

Algoritmy klasifikačních stromů jsou odolné vůči odlehlým a chybějícím hodnotám a nekladou žádné podmínky na typ pravděpodobnostního rozdělení zkoumaných veličin (Pošík, 2011).


Hastie, Tibshirami a Friedman (2008) uvádějí, že užití všech klasifikačních stromů je stejné. V každém uzlu je určena veličina, podle níž se strom dělí, a její hranice, která určuje, kde přesně se má dělení provést. Pokud nejde o stromy binární, je možné, že z jednoho uzlu „vyrůstají“ více než dvě větve, tzn. že dochází pouze k jemnějšímu dělení dle dané proměnné do více skupin najednou. Rozdíly mezi jednotlivými typy stromů jsou především v algoritmech, jimiž se stromy vytváří, tzn. v algoritmech učení. Algoritmy se liší způsobem, jakým dochází k výběru proměnné, podle které se bude dělení provádět, i hranice, kterou se dělení povede. Volba metody obecně záleží na typu trénovacích dat, jejich rozsahu a kvalitě. Existují algoritmy určené speciálně pro klasifikaci (QUEST), ale i metody, které se umí vypořádat s klasifikací a predikcí (CART, CHAID), tj. klasifikací dosud neznámých případů (např. Moradi et al., 2013).

V práci jsou užity pouze stromy typu CART (*Classification and Regression Trees*), jako užívali např. Razi a Athappilly (2005). Jedná o stromy binární, v každém uzlu dochází k dělení jen na dva další uzly. Pro diskrétní vstupní veličiny jsou možné dělicí body určeny zcela přirozeně, spojité veličiny se určitým způsobem diskretizují. Hledání „optimálního“ stromu není výpočetně uskutečnitelné, jednu diskrétní veličinu je možné rozdělit na dvě skupiny (a to $2k - 1$ způsoby, kde k je počet úrovní, pro ordinální prediktory je k dispozici $k - 1$ dělicích bodů). CART stromy se vytváří tzv. hladovým způsobem, tzn. v každém kroku se úplným prohledáním najde taková proměnná a takový dělicí bod, jež přinesou nejvyšší zlepšení klasifikace nebo regrese (Hastie, Tibshirami a Friedman, 2008).

Strom by měl dobře odpovídat dostupným datům z trénovací množiny, nemusí být nijak rozsáhlý, a je-li k tomu určen, měl by být užitečný při predikci. Strom nemusí úplně přesně vystihovat každý z trénovacích případů, ale měl by postihnout obecnější závislosti, které v datech jsou. Snižování složitosti stromu a možného zlepšení jeho prediktivních vlastností se provádí pomocí tzv. prořezávání (*prunning*), tím se zabrání přeučení stromu a zachovají se jen ta větvení, která popisují obecné závislosti v datech (Pošík, 2011).

Neuronové síť

Hastie, Tibshirami a Friedman (2008) uvádějí, že umělá neuronová síť je algoritmus, který kopíruje chování lidského mozku, jenž je tvořen velkým množstvím propletených buněk, neuronů, které spolu komunikují pomocí elektrických impulzů. Model neuronu zobrazuje obrázek 3.



Obrázek 3 Model neuronu, zdroj: Jiřina (2003)

Každý model neuronu se skládá ze tří částí, tj. vstupní, výstupní a funkční. Na základě vah mohou být jednotlivé vstupy potlačeny, nebo naopak zvýhodněny. Funkční část transformuje zpracované vstupy ve výstupy. Výstupní část přivádí informaci ke vstupním částem jiných neuronů.

Výstup neuronu $f(\xi)$ je spočten v momentě, kdy suma vstupů do neuronu x_i vynásobena jejich konkrétními vahami w_i překročí určitou hodnotu, kterou nazýváme práh θ . Neuron lze pak popsat pomocí vzorce:

$$\xi = \sum_{i=1}^n x_i w_i - \theta$$
$$y = f(\xi)$$
12

Kde x_i je konkrétní hodnota na i -tém vstupu, w_i je pak váha tohoto vstupu, θ je prahová hodnota, n je celkový počet vstupů, f je transformační funkce a y je hodnota na výstupu.

Samotný neuron je schopen obdobné složitosti, jako klasická regresní analýza (Lindsey, 2009). Dojde-li však k propojení více neuronů do větších struktur, projeví se síla neuronové sítě, jelikož právě díky složitosti spojení je schopna neuronová síť najít i složité a nelineární vztahy (Jiřina, 2003). Neurony jsou v síti uspořádány do vrstev: vstupní, skryté a výstupní (Dostál et al., 2005). Hastie, Tibshirami a Friedman (2008) podrobně popisují jednotlivé trénovací algoritmy, chybové funkce pro aktivace skrytých vrstev či možné typy výstupních aktivačních funkcí. Modul programu Statistica12, Statistica Data Miner, nabízí několik typů sítí, tj. MLP - Vícevrstvou perceptronovou síť, RBF - Radial Basis Function, SOFM - Kohonenovu síť, Lineární síť a Bayesovské sítě (PNN a GRNN). Každá z těchto sítí má jiné vlastnosti, jejich výběr závisí na typu a povaze úlohy a charakteru dostupných dat (Jiřina, 2003).

Text mining

Měření informační hustoty textů je jednou z důležitých otázek obsahové analýzy textů. První typ přístupů, zastoupený např. Maedou (1981), byl zaměřen na analýzu struktury textu a získávání důležitých informací v nich obsažených. Druhý typ přístupů, zastoupen např. Paice (1990), byl zaměřen na výstavby nových textů pomocí počítače, například na abstrakty vědeckých článků. Souběžně s tím byly vyvinuty obecné postupy techniky dolování dat. V průběhu let paralelně s předchozími přístupy, vznikl text mining jako určitá část data miningu - dolování dat z textů (Rokach a Mainon, 2014; Punitha a Punithavalli, 2012).

Text mining je nástroj pro získávání informací z textů. Obvykle zahrnuje metody pro kategorizaci dokumentů, získávání informací z dokumentů, navázaný data mining, rozpoznávání klíčových slov a vzorců v textu, předzpracování dat z textů, web mining (prohledávání textových dokumentů na internetových stránkách) a hypertextové prohledávání a další (Srivatsva a Sahami, 2009).

Frekvenční matice (*Term document matrix*) je dle Petrushina a Khana (2007) základní nástroj text miningu. Frekvenční matice slouží k prvnímu předzpracování dokumentů, aby mohla být odfiltrována zakázaná slova (*stop words*), nalezena synonyma (*synonyms*) a identifikovány kořeny slov (*stem*) a odebrány jejich předpony, přípony, koncovky (*stemming*) apod.

Srivatsava a Sahami (2009) definují slovo jako sekvenci písmen v rámci definované abecedy. V práci jsou užívány pojmy „slovo (*word*)“ a „pojem (*term*)“ jako synonyma.

Samatova et al. (2013) považují korpus jako množinu l dokumentů a slovník jako množinu N pojmů, které se objevují v korpusu, na dokument může být nahlíženo jako na určitý soubor slov. Tento soubor slov může být znázorněn formou vektoru, kde každá složka vektoru je spojena s jedním pojmem ze slovníku.

$$\theta: d \rightarrow \theta(d) = (tf(t_1, d), tf(t_2, d), \dots, tf(t_N, d)) \in R^N \quad 13$$

Kde d reprezentuje dokument, t_i reprezentuje pojem, $tf(t_i, d)$ reprezentuje četnost pojmu t_i v dokumentu $d, i = 1, 2, \dots, N$.

Pokud se slovník skládá z N pojmů, dokument d je zobrazen v N -dimenzionálním prostoru, korpus skládající se z l dokumentů může být reprezentován jako frekvenční matice D , jejíž řádky jsou indexovány podle dokumentů a sloupce podle pojmů. Každý vstup na pozici (i, j) vyjadřuje četnost pojmu $t_j, j = 1, 2, \dots, N$ v dokumentu $i, i = 1, 2, \dots, l$.

$$D = \begin{pmatrix} tf(t_1, d_1) & \dots & tf(t_N, d_1) \\ \vdots & \ddots & \vdots \\ tf(t_1, d_l) & \dots & tf(t_N, d_l) \end{pmatrix} \quad 14$$

Vzhledem k velkému počtu jednotlivých algoritmů text miningu se autoři zabývali zejména analýzou výkonu vybraných sémanticky a ontologicky založených třídících technik textových dokumentů (TDCT). Jejich výzkum potvrdil hypotézu o vlivu přiřazení "typ úkolu - TDCT" na účinnost zpracování údajů měřeno dobou potřebnou na zpracování a přesností zařazení do shluku.

Byly také publikovány a realizovány praktické aplikace a případové studie z různých domén. V medicíně (Pereira et al., 2013) použil text miningový přístup k snížení složitosti klasifikace epileptických procesů. V univerzitním prostředí Rábová (2012) představuje přístup, jak získat obchodní role z různých zdrojů, aby byly přístupné pro další zpracování. Udržitelný rozvoj je jedním z velmi často diskutovaných témat dnešní doby. Jak je uvedeno v publikaci od autorů Liew, Adhitya a Srinivasan (2014), firmy a další instituce zveřejňují

zprávy o svých příspěvcích k dosažení cílů a úkolů udržitelnosti. Ve své práci autoři použili metodiku text miningu, aby identifikovali trendy udržitelnosti a postupy ve zpracovatelských odvětvích.

Další zajímavou aplikací je využití obsahové analýzy pro automatizovanou analýzu nestrukturovaných dat (Noll et al., 2013). Autoři používali velký vzorek dokumentů, formulovali a potvrdili hypotézu o snížení práce a zvýšení rychlosti analýzy obsahu, pokud se provádí automaticky.

3.4.4 Biomedicínské inženýrství a neurotechnologie

V době, kdy neurotechnologie nebo skenovací techniky mozku jsou stále více přístupné pro účely pedagogického výzkumu, je možné provádět experimenty nezávisle na specializovaných místech, jako jsou nemocnice nebo kliniky.

Hruby a Goswami (2011) ve své přehledové studii seznamují čtenáře s pracemi autorů, kteří využívají poznatky o aktivaci korových oblastí mozku testovaných osob. Tyto informace mohou pak významně pomáhat při objasňování důležitých otázek, v jejichž rámci jsou tvořeny a formulovány koncepty optimálních vzdělávacích strategií a navrhovány nové inovativní kurikulární modely.

Ferstl (2007) popisuje vhodné hemodynamické a elektrofyziologické metody, pomocí nichž lze zkoumat neuronální koreláty psychických procesů, které lze podchytit a popsat v rámci čtení a porozumění textu. Mezi základní metody, které shromažďují informace o mozkových oblastech aktivovaných čtenářskými úlohami zaměřenými na dekodování slov, jednoduchých vět a souvětných konstrukcí a jenž mapují mozkovou aktivitu v průběhu čtenářského zpracovávání syntaktických a sémantických struktur textových pasáží a při vytváření tzv. situačních modelů a mentálních reprezentací narativních textů, patří například funkční magnetická rezonance (Ezzyat a Davachi, 2011), pozitronová emisní tomografie (Kim et al., 2012), elektroencefalografie (Baretta et al., 2012), magnetoencefalografii (Friese et al., 2008).

Mnoho studií se zaměřuje na využití technik skenování mozku pro měření mozkové aktivity studentů při práci se vzdělávacími texty různých stylů. Nejvíce používané dvě technologie jsou pak: elektroencefalografie (EEG) a funkční magnetické rezonance

(fMRI). Jak vyplývá z literárního průzkumu, oba dva typy neurotechnologií jsou používány v oblasti pro specifické účely. Také Jindráček, Škoda a Doulík (2013) zmiňují ve své přehledové studii využívání EEG pro rozlišení různých stylů textu včetně příkladů dobré praxe. Jejich práce poskytuje seznam nejvíce používaných parametrů, které je vhodné měřit v pedagogických experimentech v rámci práce se vzdělávacími texty různých stylů.

Anderson, Murphy a Poesio (2014) se ve své studii zaměřené na fMRI zabývají konceptem různé úrovně konkrétnosti. Za tímto účelem používají nejmodernější lexikální zdroje (WordNet 3.1) jako zdroj pro poměrně velký počet kategorií rozdílů a porovnávají taxonomický styl organizace s doménovým modelem. Používají multivariační analýzu vzorců, aby prokázali, že všechny taxonomické kategorie a domény mohou být odlišné od údajů fMRI. Schultz (2012) poskytuje hloubkovou analýzu a porovnává obě technologie z praktického hlediska.

Jedním z kroků disertační práce je navrhnout design výzkumu, zabývající se sledováním vlivu učení se z různých typů vzdělávacích textů na aktivitu jednotlivých mozkových oblastí, přičemž při tvorbě metodiky experimentu je nutné respektovat i aspekty jako věk probandů, pohlaví, absence neurologických onemocnění, preference strany při psaní (praváči vs. leváci) a další (Ezzyat a Davachi, 2011).

Terminologie magnetické rezonance

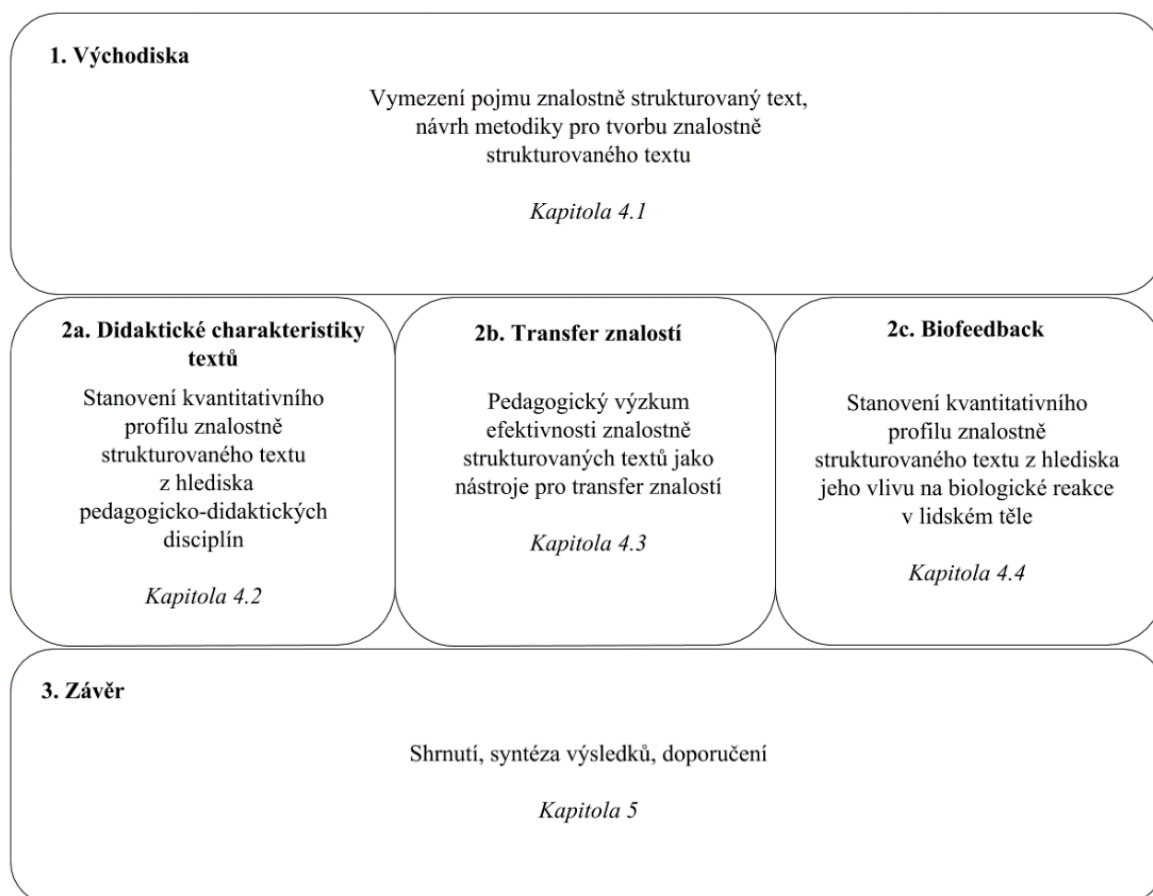
Voxel je pojem z počítačové grafiky, jenž slouží k označení částice objemu představující hodnotu v pravidelné mřížce třídímního prostoru. Používá se pro zobrazení, vizualizaci a analýzu vědeckých a lékařských dat. Poloha voxelu je dána jeho souřadnicemi v datové struktuře (Norman et al., 2006).

MNI prostor (spolu s Talairachovým prostorem) je jeden z nejčastěji využívaných standardních prostorů. Dle souřadnicového systému standardního prostoru bývá obraz přestavěn, tzv. registrace obrazu. Následně je pak umožněno použití standardních neuroanatomických atlasů. Zároveň je u všech obrazů dosažen stejný úhel, ve kterém je vyšetřovaný objem nařezán. MNI prostor je založen na zprůměrovaných 305 obrazech z magnetické rezonance mozku zdravých jedinců (Lancaster et al., 2007).

Definice a ohraničení Roi (*region of interest*) je předmětem volumetrie mozku. K jednotlivým názvům a oblastem viz více v rámci neuroanatomie (Fix, 2002). Nalezení signifikantní Roi se dělá pomocí statistiky na úrovni skupin tak, že se aplikuje v každém voxelu požadovaný test na skupinová data (např. jednovýběrový T test, pokud se jedná o jednu skupinu, nebo dvouvýběrový T test, pokud je zájmem zkoumat rozdíly mezi dvěma skupinami, příp. ANOVA, atd.). Poté je potřeba výslednou mapu testové statistiky (např. T hodnoty) naprahovat na zvolené úrovni statistické signifikance. V tomto případě se ve fMRI používají 2 přístupy; tzv. *voxel-level inference* a *cluster-level inference*. *Voxel-level inference* je přístup, kdy se na základě požadovaného p (např. $p < 0,05$) zjistí prahová T hodnota a zobrazují se nadprahové voxely. *Cluster-level inference* je alternativní přístup, kdy se na základě požadovaného p (např. $p < 0,05$) zjistí prahová velikost klusteru a zobrazují se ty klastry (*clusters*), které mají nadprahový počet voxelů (Casanova et al., 2007; Eickhoff, 2012).

4 Výzkumná část disertační práce

Vlastní výzkumná část práce je rozčleněna do třech na sebe navazujících oblastí. Schéma výzkumné části práce zobrazuje obrázek 4.



Obrázek 4 Schéma výzkumné části disertační práce, zdroj: autorka

První oblast (kapitola 4.1) obsahuje východiska, ve kterých je pro účely této práce definován pojem znalostně strukturovaný text a zároveň je zde uveden i návrh metodiky pro tvorbu znalostně strukturovaného textu.

Druhá oblast je aplikační a vychází ze třech experimentů (experiment I, experiment II a experiment III), které vedou ke zhodnocení efektivnosti vzdělávacích textů různé struktury dle třech různých hledisek. V rámci všech tří experimentů se pracuje s texty, které jsou upraveny do běžně strukturované a znalostně strukturované podoby. Všechny experimenty testují shodné texty, jež vznikly přepracováním původních textů od Káry (2007) v rámci vybrané problémové domény zpracování zemědělských odpadů. Pro účely

jednotlivých experimentů jsou pak tyto texty poupraveny do textových brožur dle tematických suboblastí (experiment II) či rozděleny do více homogenních textových fragmentů (experiment I a experiment III).

Experiment I (kapitola 4.2) je zaměřen na tvorbu vzdělávacích textů různých struktur a měření jejich didaktických charakteristik. Součástí experimentu je i nalezení vhodného klasifikátoru pro třídění typů textů dle výskytu slovních konceptů (významný statistický faktor). Experiment byl realizován na základě projektu IGA PEF s názvem „Stanovení kvantitativních charakteristik znalostního textu“.

Experiment II (kapitola 4.3) se zaměřuje na účinnost znalostně strukturovaného textu, a to z dvou úhlů pohledu, v rámci čistého transferu znalostí (bez vlivu počáteční úrovně znalostí) a prostřednictvím objektivního zhodnocení struktury textů jejich uživateli. Před samotnou realizací experimentu byla provedena rozsáhlá pilotáž, která testovala vhodnost nástrojů (pretestů, posttestů) testovací procedury pomocí didaktických analýz. Experiment byl realizován v rámci projektu CIGA ČZU s názvem „Měření efektivity transferu znalostí v sektoru zpracování zemědělských odpadů“.

Experiment III (kapitola 4.4) se zaměřuje na biologické zpětné reakce v lidském těle při práci s texty, resp. čtení textů různých struktur. Experiment byl realizován v rámci projektu IGA PEF s názvem „Stanovení neuropsychologických charakteristik učení pro různé typy vzdělávacích textů prostřednictvím neurotechnologií“.

Po představení jednotlivých aplikačních oblastí a jednotlivých experimentů následuje poslední, třetí oblast, která je zaměřena na syntézu dosažených výsledků a závěrečná shrnutí a doporučení (kapitola 5).

Všechny výsledky a výstupy v rámci kapitol 4.1, 4.2, 4.3 a 4.4 byly publikovány jako články v časopisech či konferenční články. Každá tato kapitola má v rámci úvodní podkapitoly zmíněno, kde konkrétně byly zmíněné výsledky publikovány.

Autorka disertační práce je autorkou či spoluautorkou i dalších publikací zabývajících se tématem znalostně strukturovaných textů ve srovnání s texty jiné struktury i z jiných úhlů pohledu, než je uvedeno v cílech disertační práce.

Jedná se například o tematiku tvorby kalkulačního schématu pro zavádění znalostně strukturovaných textů (Rauchová a Houška (2013b)), využití systémové dynamiky pro zhodnocení nákladů na znalostně strukturované směrnice v zemědělském podniku (Horáková, Rydval a Houška, 2017) či využití text miningových technik pro získání dat, informací a znalostí z textů pro pedagogické účely (Horáková a Rydval, 2015; Horáková, Krejčí a Rydval, 2017; Krejčová a Horáková, 2017). Tematické zaměření zmíněných dalších publikací je již však mimo navržený rámec výše uvedeného schématu výzkumné části práce.

4.1 Východiska

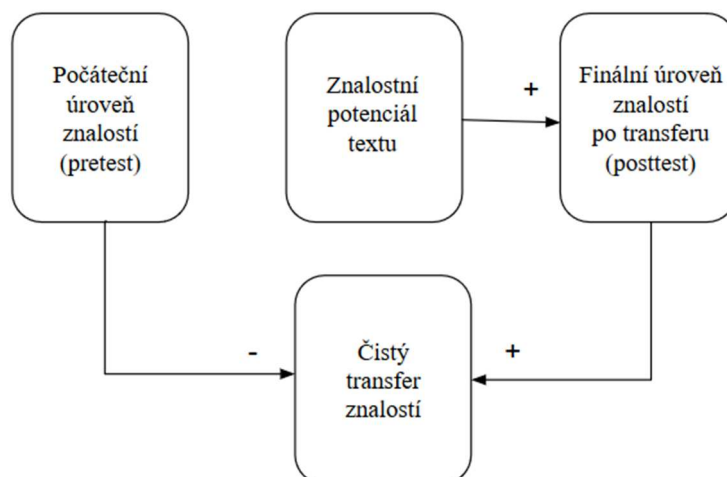
4.1.1 Úvod kapitoly 4.1

Nejprve pro účel práce je nutné jasně specifikovat pojem znalostně strukturovaný text. Navazující experimenty I, II a III ověřují efektivnost explicitně vyjádřených znalostí prostřednictvím znalostně strukturovaných textů ve srovnání s jinými typy vzdělávacích textů. To znamená, že musí být jasně definováno, z čeho se tento text skládá a jaká je jeho struktura. Dále je třeba definovat, jak tento text je možné rozpoznat od ostatních textů a jak jsou nazývány texty, které nebudou splňovat podmínky pro zařazení do kategorie znalostně strukturovaný text. Vzhledem k tomu, že v dalších krocích výzkumné části práce budou vytvářeny znalostně strukturované texty a s nimi následně provedeny experimenty, je též třeba uvést obecný postup (schéma) pro tvorbu znalostně strukturovaného textu. Dle této metodiky byly vytvořeny texty, se kterými byly následně realizovány navazující experimenty (na obrázku 4 označeny jako části 2a, 2b a 2c). Metodika zároveň může posloužit jako návod, jak znalostně strukturovaný text vytvořit. Problematiku již autorka práce publikovala (Houška a Rauchová, 2013), kapitola vznikla rozpracováním této publikace.

4.1.2 Vymezení pojmu znalostně strukturovaný text

V této práci je pod pojmem znalostně strukturovaný text (angl. *knowledge structured text*), v dřívějších publikacích autorky byl označován též jako znalostní text (angl. *knowledge text*), chápán text, jenž obsahuje znalosti v explicitní formě. Na základě předchozích výzkumů Dömeové et al. (2008) je vhodné pro explicitní vyjádření znalosti využívat produkční pravidlo a jeho rozšířenou verzi, tzv. znalostní jednotku (angl. *knowledge unit*).

Znalostně strukturovaný text je takový text, který má sloužit jako nástroj pro transfer znalostí. Transferem znalostí je pro účely této práce myšlen přenos znalostí a s nimi potažmo i informací a dat na základě textu při odstranění vlivu počáteční úrovně znalostí. Počáteční úroveň znalostí a transferu znalostí lze zjistit pomocí testů. Čistý transfer znalostí je pak rozdíl transferu znalostí očištěný o vliv počáteční úrovně znalostí.



Obrázek 5 Transfer znalostí, zdroj: autorka

Znalostně strukturovaný text z hlediska Tobinovy (1996) hierarchie dat-informací-znalostí obsahuje všechny tři složky z hierarchie. Jedná se o však o text, kde znalosti jsou vyjádřeny formou znalostní jednotky či produkčního pravidla. Pokud se ve znalostně strukturovaném textu objevují samostatné informace, mají zde spíše doplňkový charakter.

Podrobný popis metod znalostního inženýrství pro reprezentaci znalostí, tj. produkčních pravidel a znalostních jednotek je součástí kapitoly 3.2.

Jiné texty, sloužící jako nástroj pro transfer znalostí rovněž obsahující všechny složky hierarchie data-informace-znalosti, které mají znalosti vyjádřené implicitně, jsou pro účely této práce označovány jako texty běžně strukturované (*standard structured text*). V dřívějších publikacích autorky byly označovány též jako texty běžné, normální či standardní.

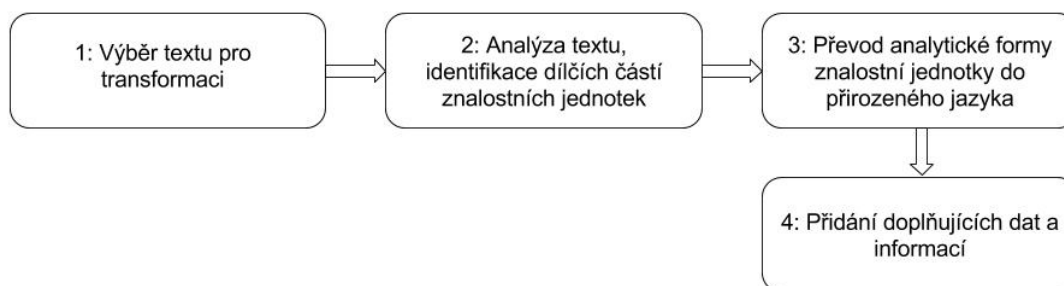
Z hlediska formy mohou mít jak znalostně strukturované, tak běžně strukturované texty podobu tištěnou i elektronickou. Vzhledem k tomu, že znalostně strukturovaný text se liší od běžně strukturovaného textu formou vyjádření znalosti, je patrné, že změnou struktury, tj. jinou formou vyjádření znalosti, užitím znalostních jednotek či produkčních pravidel, lze z běžně strukturovaného textu vytvořit text znalostně strukturovaný a naopak. Tvorba textu není jazykově limitována, tj. lze ji aplikovat jak v rámci českého jazyka, tak v rámci jiných jazyků, ve kterých je možné vyjádřit a ve stejném smyslu i chápat *if-then* konstrukci produkčního pravidla. Ukázka běžně a znalostně strukturovaných textových fragmentů v anglickém jazyce je součástí Přílohy 3.

4.1.3 Předpoklady pro experiment I, II a III

Pro účely aplikační oblasti výzkumné části práce se předpokládá, že v případě porovnání dvou různých stylů textů (znalostně strukturovaný vs. běžně strukturovaný text) je znalostně strukturovaný text vytvořen úpravou textu běžně strukturovaného. Dále se v experimentech předpokládá, že oba dva typy textů jsou homogenní z hlediska výběru problémové domény, v rámci které reprezentují znalosti, dále z hlediska členění textových fragmentů do odstavců či zvýrazňování konkrétních pojmů v textu, z hlediska délky textových fragmentů (vyjádřené průměrným počtem slov).

4.1.4 Návrh metodiky pro tvorbu znalostně strukturovaného textu

Pro vytvoření znalostně strukturovaného textu z běžně strukturovaného textu je možné vycházet z následujících čtyř kroků, zobrazených na obrázku 6.



Obrázek 6 Návrh metodiky tvorby znalostně strukturovaného textu; zdroj: autorka

Krok 1: Výběr textu pro transformaci

První krok je zásadní fází celého procesu. Jak již bylo zmíněno výše, je třeba identifikovat běžně strukturovaný text, který je nástrojem pro transfer znalostí, tzn. že obsahuje všechny složky z hierarchie data-informace-znalosti, ale znalosti jsou v textu vyjádřeny implicitně. Tento text pak posléze bude transformován do znalostně strukturované podoby.

Ne vždy text, který je k dispozici, musí být charakterizován jako běžně strukturovaný text. Mohou být identifikovány i ostatní typy textů, které lze zařadit do dvou skupin:

První skupinu tvoří texty (pro účely této práce nazývány jako informativní texty), které poskytují pouze data a informace. Účelem takovýchto textů je informovat čtenáře o faktech, událostech a jiných skutečnostech. Často je možné se setkat s texty

informativního charakteru ve faktografických disciplínách, jako je historie či geografie. Jelikož znalostní složka z pohledu znalostního inženýrství v těchto textech není obsažena, je nelogické a neúčelné transformovat tyto typy textu do znalostně strukturované podoby.

Druhá skupina textů je již ve své původní verzi vysoce strukturovaná (pro účely této práce nazývány formalizovanými texty). Jedná se zejména o texty ve velmi formalizovaných vědních disciplínách jako je matematika, fyzika, operační výzkum apod. Texty přirozeně popisují procedury, algoritmy, což vyjadřuje znalost ve své čisté podobě.

Krok 2: Analýza textu, nalezení dílčích částí znalostních jednotek

V běžně strukturovaném textu je znalost obvykle schována. Aby byla objevena, je třeba analyzovat jednotlivé věty, odstavce, či delší textové fragmenty a úseky. Na úrovni jednotlivých vět je třeba se zaměřit na souvětí a nalézt tří-dimenzionální konstrukci (Havlíček, Brožová, Šubrt, 2006): vztah mezi dvěma objekty doplněný o cíl řešeného problému. V takovém případě je třeba pro nalezení subjektu znalosti analyzovat celý odstavec.

Poté, co je znalost v textu extrahována, je třeba ji reprezentovat pomocí znalostní jednotky. Zejména je nutné nalézt všechny čtyři komponenty znalostní jednotky, tj. přiřadit jim jednotlivé části souvětí (vět). V této fázi se stále jedná o analýzu, nikoliv o syntézu, jelikož jednotlivé individuální věty dosahují pouze kvality informace.

Krok 3: Převod analytické formy znalostní jednotky do přirozeného jazyka

Tento krok je syntézou. Ve třetí fázi dochází ke spojení informace z jednotlivých částí znalostní jednotky do jednoho celku, a vyjádření znalosti v přirozeném jazyce. Je samozřejmé, že znalostní jednotka je obvykle vyjádřena jako souvětí. Na jedné straně mohou vznikat věty delší, než byly v původní verzi textu, na druhé straně text obsahuje explicitně vyjádřenou znalost. Věty, souvětí či textové fragmenty jsou upraveny po stránce stylistické, ale jejich smysl zůstává nezměněn.

Krok 4: Přidání dat a doplňujících informací

Žádný text nemůže být poskládán jen ze souvětí reprezentujících individuální znalostní jednotky, protože by to bylo pro čtenáře velice obtížné. Proto je možné do souvětí přidávat

doplňující tvrzení na úrovni informací, jež jednotlivé znalosti doplňují, vysvětlují části znalosti, poskytují nezbytná data apod. Tento přístup je v souladu se znalostním řetězcem (Aven, 2013).

4.1.5 Závěr kapitoly 4.1

V první kapitole výzkumné části práce byl definován pojem znalostně strukturovaný text, byl odlišen od běžně strukturovaného textu a také od ostatních typů textů - informativních textů a formalizovaných textů. Znalostně strukturovaný text i běžně strukturovaný text jsou nástroji pro transfer znalostí z pohledu metod znalostního inženýrství, tj. při rozlišení hierarchie data-informace-znalosti. Znalostně strukturovaný text obsahuje znalosti explicitně vyjádřené, běžně strukturovaný text má znalosti vyjádřené implicitně. Dále je popsána metodika sestávající se ze čtyř hlavních kroků, jak lze z běžně strukturovaného textu vytvořit znalostně strukturovaný text. V prvním kroku je třeba provést výběr textu pro transformaci, v druhém kroku analýzu textu a nalézt dílčí části znalostních jednotek, ve třetím kroku se převede analytická forma znalostní jednotky do přirozeného jazyka, ve čtvrtém kroku se přidají data a doplňující informace.

4.2 Text a jeho didaktické charakteristiky

4.2.1 Úvod kapitoly 4.2

Druhá část výzkumné části práce je založena na pedagogickém výzkumu, resp. didaktické analýze textu, která vede ke stanovení kvantitativního profilu znalostně strukturovaného textu.

Kapitola 4.2 vznikla na základě projektu s názvem Stanovení kvantitativních charakteristik znalostního textu (poskytovatel IGA PEF, trvání od 2013 do 2014, registrační číslo projektu 20131020).

V rámci experimentu I jsou sledovány aspekty ovlivňující učení se z textu, a to zejména obtížnost textu, tj. z pohledu syntaktické a sémantické obtížnosti textu. Nejdříve jsou obecně popsány dílčí kroky celého výzkumu, poté jsou pro jednotlivé kroky experimentu popsány konkrétní výstupy. Součástí experimentu je i krok zabývající se nalezením vhodných nástrojů umělé inteligence pro klasifikaci, tj. zařídění neznámých textů do jedné ze skupin (znalostně strukturovaný či běžně strukturovaný text) na základě statisticky odlišného výskytu slovních konceptů. Závěr experimentu obsahuje shrnutí výsledků a komparaci výsledků s jinými autory.

Předkládanou problematiku již autorka práce publikovala. Nejprve byly publikovány výsledky v rámci předvýzkumu (Rauchová et al., 2014), poté výsledky na relevantním vzorku textových fragmentů (Horáková a Houška, 2014b), klasifikační analýza vzdělávacích textů pomocí metod umělé inteligence byla rovněž publikována (Horáková, Houška a Dömeová, 2017). Kapitola 4.2 vznikla zejména rozpracováním posledních dvou výše zmíněných publikací.

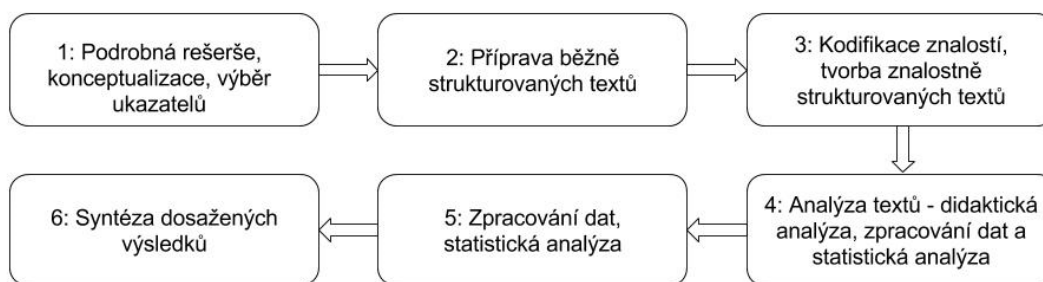
4.2.2 Experiment I

Pedagogický výzkum zaměřený na didaktickou analýzu textů měl podobu experimentálního výzkumu s využitím techniky paralelních skupin, tj. práce se dvěma skupinami textových fragmentů.

Pro experiment byla stanovena následující výzkumná hypotéza:

VH1: Znalostně strukturovaný text se statisticky významně neliší od běžně strukturovaného textu z hlediska didaktických charakteristik textu.

Následující obrázek 7 zobrazuje šest na sebe navazujících kroků experimentu. Konkrétní výstupy jednotlivých kroků experimentu jsou detailně popsány v navazující kapitole 4.2.3.



Obrázek 7 Schéma experimentu I; zdroj: autorka

V prvním kroku experimentu bylo třeba provést podrobnou rešerši a konceptualizaci, což představuje detailní prostudování vědecké literatury, a to zejména v oblasti nástrojů a způsobů analýz textu pro didaktické účely. Následně byly vybrány stávající a definovány nové vhodné ukazatele pro didaktickou analýzu dvou typů textu - znalostně strukturovaných a běžně strukturovaných textů. Na základě činností v rámci prvního kroku bylo definováno 6 pracovních hypotéz, které v kroku 4 a 5 byly předmětem statistického testování.

V druhém kroku je třeba se zaměřit na problémovou doménu, vybrat vhodnou tematickou oblast pro reprezentaci znalostí. Vzdělávací texty musely splňovat charakteristiky běžně strukturovaného textu.

Ve třetím kroku bylo třeba kodifikovat znalosti z běžně strukturovaného textu. Na kodifikaci spolupracovali expert na danou problémovou doménu a znalostní inženýr. Znalostní inženýr kodifikoval znalosti obsažené v běžně strukturovaných textech pomocí metod pro reprezentaci znalostí. Následovala tvorba znalostně strukturovaných textů, kdy znalostní inženýr přetvářel běžně strukturované texty v texty znalostně strukturované pomocí konceptu znalostní jednotky popsaného v literární rešerši v rámci podkapitoly 3.2.5.

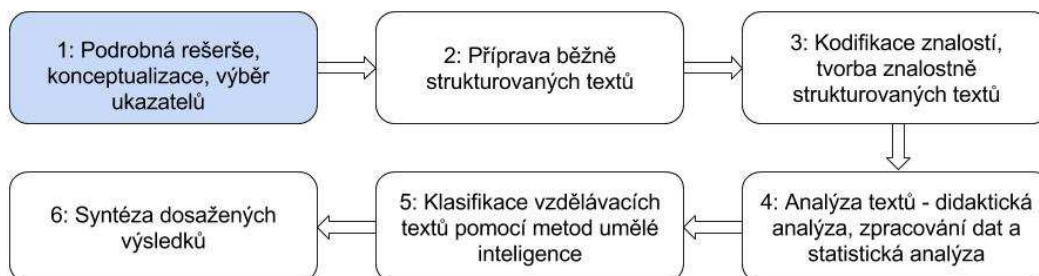
Ve čtvrtém kroku byla provedena didaktická analýza textu, jež souvisela se softwarovým (v některých případech i ručním) zpracováním obou dvou typů vzdělávacích textů, tj. znalostně strukturovaných i běžně strukturovaných textů, a vypočtením všech relevantních didaktických ukazatelů textů (resp. parametrů stanovených v rámci prvního kroku experimentu). Dále byly výstupy softwaru či ručního zpracování uspořádány do datové matice pro následnou statistickou analýzu dat. Cílem statistické analýzy bylo podchytit rozdílnost sledovaných ukazatelů u znalostně strukturovaných a běžně strukturovaných textů pomocí statistické indukce, tj. metody teorie odhadu a testování statistických hypotéz.

V pátém kroku byla provedena klasifikace textových dokumentů na základě frekvence výskytu slovních konceptů. Pro znalostně i běžně strukturovaný text byla vytvořena frekvenční matice. Poté byla sledována schopnost vybraných klasifikátorů (umělé neuronové sítě, rozhodovací stromy, klasifikační a regresní stromy) klasifikovat neznámý text dle jejich struktury do třídy znalostně strukturovaný vs. běžně strukturovaný.

V šestém, posledním, kroku došlo k syntéze dosažených výsledků, tj. k zamítnutí či nezamítnutí stanovených pracovních hypotéz a formulaci závěrů z hlediska kvantitativního profilu obtížnosti a sémanticko-syntaktické struktury textu a vhodnosti klasifikačních nástrojů.

4.2.3 Konkrétní výstupy experimentu I

1. krok: Podrobná rešerše, konceptualizace, výběr ukazatelů, definice pracovních hypotéz



Obrázek 8 Experiment I: 1. krok – podrobná rešerše, konceptualizace, výběr ukazatelů; zdroj: autorka

Podrobné rešerše a konceptualizace představují detailní prostudování vědecké literatury, a to zejména v oblasti nástrojů a způsobů analýz textu pro didaktické účely, na jejímž základě jsou vyřčeny relevantní pracovní hypotézy. Této oblasti se věnuje teoretická část práce, a to podkapitola 3.3.3. Pro následující analýzu textů byly vybrány stávající (standardně užívané) a definovány nové vhodné ukazatele pro didaktickou analýzu textu. Mezi stávající ukazatele byly vybrány:

- Celková obtížnost textu (T);
- Syntaktická obtížnost textu (T_s);
- Sémantická obtížnost textu (T_p);
- Koeficient hustoty odborné informace vyjádřený proporcí odborných a faktografických pojmů na celkovou sumu slov (i);
- Koeficient hustoty odborné informace vyjádřený proporcí odborných a faktografických pojmů na celkovou sumu substantivních pojmů (h).

Dále s ohledem na tvorbu znalostně strukturovaných textů dle Houšky a Rauchové (2013) byly navrženy a zařazeny do analýzy i další ukazatele, popisující větnou strukturu vět znalostně strukturovaných textových fragmentů. Mezi nově navržené ukazatele byly vybrány:

- *Průměrný počet příslovcí ve větě;*
- *Průměrný počet příslovcí v souvětí;*
- *Průměrný počet vět v souvětí;*
- *Průměrný počet souvětí na větu;*
- *Počet vybraných slovních konceptů.*

Dle předvýzkumu Rauchové et al. (2014) byly mezi vybrané slovní koncepty zařazeny následující pojmy: *když, jestliže, jestliže, jestli, jestlipak, zda, zda-li, zdalipak, pakliže, pokud, pak, poté, potom, tak, s cílem, v rámci, a proto, a tudíž, a tak, aby.*

Výběr ukazatelů byl proveden na základě literární rešerše experimentů u jiných autorů (McCrary and Stylianides, 2014; Miller, 2011) a na základě předcházejícího předvýzkumu (Rauchová et al. 2014), tj. didaktické analýzy textu, provedené na menším vzorku textových fragmentů.

Cílem experimentu bylo analyzovat statisticky významný vzorek textových fragmentů a nezamítnout či zamítnout následující pracovní hypotézy.

Pracovní hypotézy v rámci 4. kroku experimentu

PH1.0: Celková obtížnost textu (T) je shodná u běžně strukturovaného textu a znalostně strukturovaného textu.

PH2.0: Koefficient hustoty odborné informace (proporce odborných a faktografických pojmů na celkovou sumu slov) (i) je shodný u běžně strukturovaného textu a znalostně strukturovaného textu.

PH3.0: Průměrný počet vět na souvětí (V_a) je shodný u znalostně strukturovaného textu a běžně strukturovaného textu.

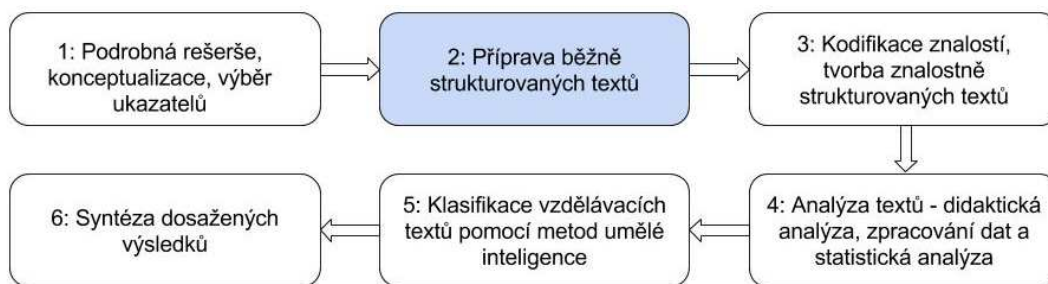
PH4.0: Průměrný počet vybraných slovních konceptů (C) je shodný u znalostně strukturovaného textu a běžně strukturovaného textu.

Pracovní hypotézy v rámci 5. kroku experimentu:

PH5.0: Vybrané umělé neuronové (ANN) sítě poskytují stejné relativní frekvence správné klasifikace znalostně strukturovaných textů a běžně strukturovaných vzdělávacích textů jako vybrané rozhodovací stromy (bigML).

PH6.0: Vybrané umělé neuronové (ANN) sítě poskytují stejné relativní frekvence správné klasifikace znalostně strukturovaných textů a běžně strukturovaných vzdělávacích textů jako vybrané klasifikační a regresní stromy (CART).

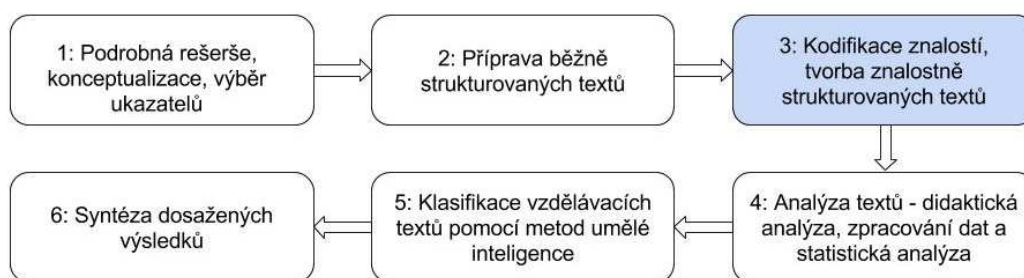
2. krok: Příprava běžně strukturovaných textů



Obrázek 9 Experiment I: 2. krok – Příprava běžně strukturovaných textů; zdroj: autorka

V dalším kroku bylo třeba připravit sadu běžně strukturovaných textů, odpovídající definici v kapitole 4.1. Jednalo se o vzdělávací texty zabývající se tematikou zpracování zemědělských odpadů a navazujících témat. Texty, resp. textové fragmenty, jež byly předmětem následující didaktické analýzy, jsou dostupné na přiloženém CD. Jednalo se celkem o 30 textových fragmentů, odpovídající charakteristice běžně strukturovaných textů. Příprava běžně strukturovaných textů probíhala v rámci připravovaných výstupů grantu CIGA ČZU "Měření efektivity transferu znalostí v sektoru zpracování zemědělských odpadů" (poskytovatel CIGA ČZU, trvání od 2013 do 2014, registrační číslo projektu 20131001). Běžně strukturované texty vznikly úpravou textů od Káry et al. (2007). Texty následně prošly i didaktickou úpravou a revizí dle návodů Průchy (1998), více viz literární rešerše, podkapitola 3.3.2.

3. krok: Kodifikace znalostí, tvorba znalostně strukturovaných textů

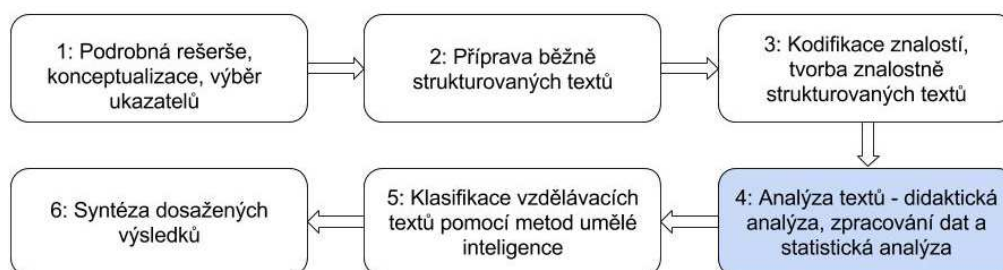


Obrázek 10 Experiment I: 3. krok – Kodifikace znalostí, tvorba znalostně strukturovaných textů; zdroj: autorka

Na základě předchozího kroku bylo třeba vytvořit dle metodiky Houšky a Rauchové (2013) znalostně strukturované texty. Kodifikace znalostí vycházela z běžně strukturovaných textů. Zároveň byl kvůli odborné přesnosti zařazen do procesu kodifikace i dialog s expertem na vybranou problémovou doménu. Způsob kodifikace znalostí pomocí

znalostních jednotek a dalších metod pro reprezentace znalostí včetně jejich časové náročnosti popsali Rauchová et al. (2013). Výsledné texty jsou dostupné na přiloženém CD. Jedná se celkem o 30 textových fragmentů odpovídající charakteristice znalostně strukturovaných textů.

4. krok: Analýza textu – didaktická analýza, zpracování dat a statistická analýza



Obrázek 11 Experiment I: 4. krok – Analýza textů – didaktická analýza, zpracování dat a statistická analýza; zdroj: autorka

Nejprve byly spočteny základní popisné statistiky (průměr, minimum, maximum, rozptyl a směrodatná odchylka) pro všechny relevantní proměnné, odděleně pro znalostně strukturovaný a běžně strukturovaný text, viz tabulka 1, kde S_s je počet jednoduchých vět (myšleno dle terminologie české mluvnice) a $S_c^{(n)}$ je počet souvětí obsahujících n jednoduchých vět.

Proměnná	Běžně strukturovaný text (BST)					Znalostně strukturovaný text (ZST)				
	Průměr	Minimum	Maximum	Rozptyl	Směrodatná odchylka	Průměr	Minimum	Maximum	Rozptyl	Směrodatná odchylka
N	249,8	161	311	1064,1	32,62	255,7	194	335	1098,0	33,1
U	26,1	8	41	67,9	8,24	25,6	10	43	63,4	8,0
S_s	7,5	2	12	8,5	2,91	3,7	0	11	6,3	2,5
$S_c^{(2)}$	4,6	0	9	6,8	2,61	4,1	0	9	5,4	2,3
$S_c^{(3)}$	2,2	0	5	2,2	1,49	2,7	0	7	2,8	1,7
$S_c^{(4)}$	0,5	0	2	0,6	0,77	0,8	0	4	0,9	1,0
$S_c^{(5)}$	0,2	0	1	0,2	0,40	0,4	0	2	0,3	0,5
$S_c^{(6+)}$	0,1	0	1	0,1	0,30	0,3	0	3	0,4	0,6
S_c	7,6	2	13	11,2	3,34	8,1	2	15	9,0	3,0
V_a	2,4	0,4	3,3	0,3	0,54	2,7	2	4,4	0,2	0,5
Q	2,7	0	6	3,3	1,83	9,5	2	17	10,4	3,2
P_1	67,2	39	94	183,9	13,56	66,6	47	92	121,1	11,0
P_2	12,4	0	75	104,3	10,21	11,2	0	27	36,7	6,1
P_3	3,8	0	14	9,7	3,11	3,8	0	14	9,7	3,1
P_4	4,5	0	18	10,5	3,24	4,5	0	18	9,8	3,1
P_5	10,3	1	19	18,4	4,29	10,32	1	19	18,4	4,3

Tabulka 1 Základní popisné statistiky pro běžně a znalostně strukturované texty; zdroj: autorka

Na základě čtyř pracovních hypotéz (PH1.0 - PH4.0) definovaných v prvním kroku experimentu I (podkapitola 4.2.3) a dat uvedených výše v tabulce 1, bylo cílem otestovat následující operativní hypotézy (OH1.1 – OH4.6).

OH1.1: Neexistuje rozdíl v průměrných hodnotách počtu slov mezi běžně a znalostně strukturovaným textem.

OH1.2: Neexistuje rozdíl v průměrných hodnotách počtu sloves mezi běžně a znalostně strukturovaným textem.

OH1.3: Neexistuje rozdíl v průměrných hodnotách syntaktické obtížnosti textu mezi běžně a znalostně strukturovaným textem.

OH1.4: Neexistuje rozdíl v průměrných hodnotách sémantické obtížnosti textu mezi běžně a znalostně strukturovaným textem.

OH2.1: Neexistuje rozdíl v průměrných hodnotách koeficientu hustoty odborné informace (proporce odborných a faktografických pojmů v celkovém počtu slov) mezi běžně a znalostně strukturovaným textem.

OH2.2: Neexistuje rozdíl v průměrných hodnotách koeficientu hustoty odborné informace (proporce odborných a faktografických pojmů v celkovém počtu pojmů) mezi běžně a znalostně strukturovaným textem.

OH3.1: Neexistuje rozdíl v průměrných hodnotách v počtu jednoduchých vět mezi běžně a znalostně strukturovaným textem.

OH3.2: Neexistuje rozdíl v průměrných hodnotách počtu souvětí skládajících se ze dvou vět mezi běžně a znalostně strukturovaným textem.

OH3.3: Neexistuje rozdíl v průměrných hodnotách počtu souvětí skládajících se ze tří vět mezi běžně a znalostně strukturovaným textem.

OH3.4: Neexistuje rozdíl v průměrných hodnotách počtu souvětí skládajících se ze čtyř vět mezi běžně a znalostně strukturovaným textem.

OH3.5: Neexistuje rozdíl v průměrných hodnotách počtu souvětí skládajících se z pěti vět mezi běžně a znalostně strukturovaným textem.

OH3.6: Neexistuje rozdíl v průměrných hodnotách počtu souvětí skládajících se z více než pěti vět mezi běžně a znalostně strukturovaným textem.

OH3.7: Neexistuje rozdíl v průměrných hodnotách celkového počtu souvětí mezi běžně a znalostně strukturovaným textem.

OH3.8: Neexistuje rozdíl v průměrných hodnotách podílu celkového počtu vět na souvětí mezi běžně a znalostně strukturovaným textem.

OH4.1: Neexistuje rozdíl v průměrných hodnotách počtu vybraných slovních konceptů mezi běžně a znalostně strukturovaným textem.

OH4.2: Neexistuje rozdíl v průměrných hodnotách počtu běžných pojmů mezi běžně a znalostně strukturovaným textem.

OH4.3: Neexistuje rozdíl v průměrných hodnotách počtu odborných pojmů mezi běžně a znalostně strukturovaným textem.

OH4.4: Neexistuje rozdíl v průměrných hodnotách počtu faktografických pojmů mezi běžně a znalostně strukturovaným textem.

OH4.5: Neexistuje rozdíl v průměrných hodnotách počtu numerických pojmů mezi běžně a znalostně strukturovaným textem.

OH4.6: Neexistuje rozdíl v průměrných hodnotách opakujících se pojmů mezi běžně a znalostně strukturovaným textem.

Poznámka: Pracovní hypotézy a operativní hypotézy netvoří hierarchii. Například není záměrem pochopit operativní hypotézy OH4.1 - OH4.6 jako partikularizace pracovní hypotézy H4.0. Jedná se o hypotézy, jež pouze spadají pod analýzu stejného druhu (tj. sémantickou obtížnost textu).

Následující tabulka 2 ukazuje výsledky párového T testu pro závislé vzorky běžně strukturovaných textů (BST) a znalostně strukturovaných textů (ZST), a rozhodnutí, zda-li je, či není zamítnuta výše zmíněná nulová hypotéza.

Proměnná	Typ textu	Průměr	Směr. odchylka	<i>t</i> hodnota	<i>p</i> hodnota	Operativní hypotéza	Výsledek testu s hladinou $\alpha = 0,05$
<i>N</i>	BST	249,8000	32,62	-2,0493	0,044884	OH1.1	Zamítnuta
	ZST	255,6667	33,13				
<i>U</i>	BST	26,1167	8,24	0,6404	0,524364	OH1.2	Nezamítnuta
	ZST	25,5833	7,96				
<i>T_s</i>	BST	28,0115	25,94	4,149494	0,000108	OH1.3	Zamítnuta
	ZST	13,5023	10,10				
<i>T_p</i>	BST	22,0048	9,96	2,277690	0,026384	OH1.4	Zamítnuta
	ZST	19,7780	7,35				
<i>h</i>	BST	20,9395	10,22	1,2690	0,209409	OH2.1	Nezamítnuta
	ZST	20,2580	8,26				
<i>i</i>	BST	8,27834	4,88	1,7473	0,086172	OH2.2	Nezamítnuta
	ZST	7,63884	3,19				
<i>S_s</i>	BST	7,5167	2,90	9,7706	0,000000	OH3.1	Zamítnuta
	ZST	3,6667	2,50				
<i>S_c⁽²⁾</i>	BST	4,5833	2,61	1,7810	0,080057	OH3.2	Nezamítnuta
	ZST	4,0833	2,31				
<i>S_c⁽³⁾</i>	BST	2,2167	1,48	-1,9285	0,058608	OH3.3	Nezamítnuta
	ZST	2,6500	1,68				
<i>S_c⁽⁴⁾</i>	BST	0,4833	0,77	-2,8013	0,006872	OH3.4	Zamítnuta
	ZST	0,7833	0,92				
<i>S_c⁽⁵⁾</i>	BST	0,2000	0,40	-2,2560	0,027792	OH3.5	Zamítnuta
	ZST	0,3500	0,54				
<i>S_c⁽⁵⁺⁾</i>	BST	0,1000	0,30	-1,8352	0,071522	OH3.6	Nezamítnuta
	ZST	0,2500	0,62				
<i>S_c</i>	BST	7,5833	3,34	-1,8112	0,075194	OH3.7	Nezamítnuta
	ZST	8,1167	3,00				
<i>V_a</i>	BST	2,3930	0,54	-4,2878	0,000068	OH3.8	Zamítnuta
	ZST	2,7281	0,47				
<i>C</i>	BST	2,7000	1,82	-14,0022	0,000000	OH4.1	Zamítnuta
	ZST	9,5167	3,22				

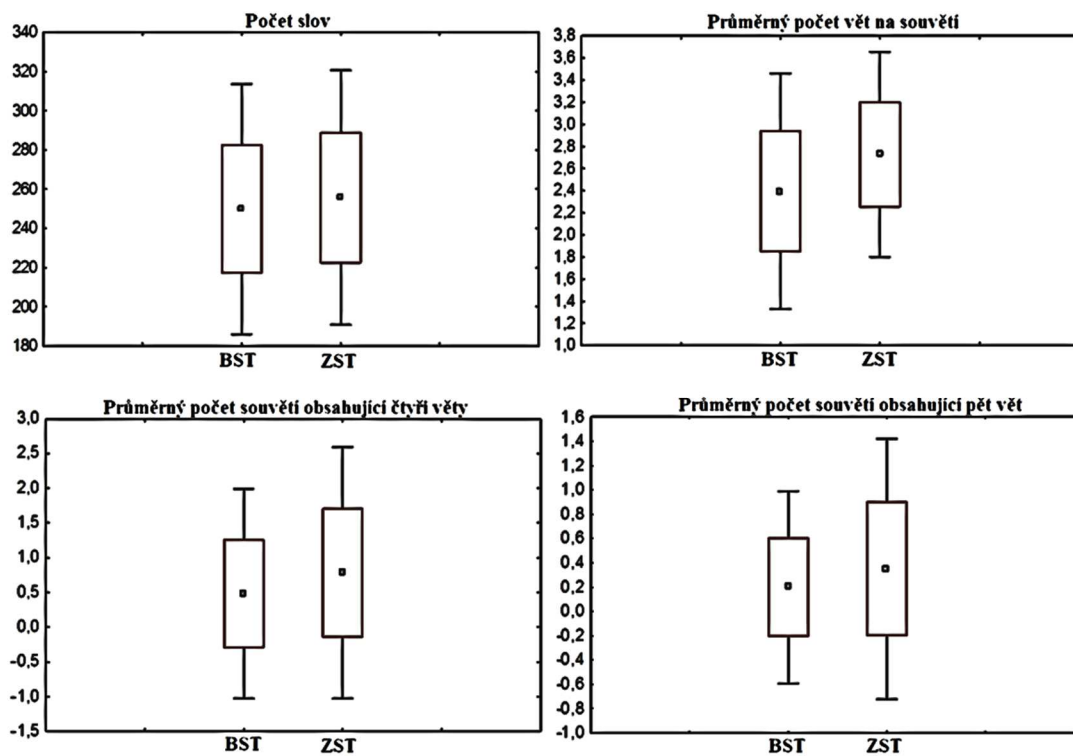
P_1	BST	67,2167	13,55	0,6034	0,548555	OH4.2	Nezamítnuta
	ZST	66,5833	11,00				
P_2	BST	12,3833	10,21	1,3313	0,188226	OH4.3	Nezamítnuta
	ZST	11,2333	6,05				
P_3	BST	3,7966	3,11	0,3308	0,741982	OH4.4	Nezamítnuta
	ZST	3,7797	3,10				
P_4	BST	4,5167	3,24	0,0000	1,000000	OH4.5	Nezamítnuta
	ZST	4,5167	3,12				
P_5	BST	10,3167	4,29	-0,2346	0,815359	OH4.6	Nezamítnuta
	ZST	10,3167	4,29				

Tabulka 2 Statistická analýza, výsledky párového T testu; zdroj: autorka

Jak je uvedeno v Tabulce 2, obě formy textu se statisticky významně liší u následujících aspektů:

- N ... počet slov, $N(\text{ZST}) > N(\text{BST})$;
- T_s ... syntaktická obtížnost, $T_s(\text{ZST}) < T_s(\text{BST})$;
- T_p ... sémantická obtížnost, $T_p(\text{ZST}) < T_p(\text{BST})$;
- S_s ... počet jednoduchých vět, $S_s(\text{ZST}) < S_s(\text{BST})$;
- $S_c^{(4)}$... počet souvětí skládající se ze čtyř vět, $S_c^{(4)}(\text{ZST}) > S_c^{(4)}(\text{BST})$;
- $S_c^{(5)}$... počet souvětí skládající se z pěti vět, $S_c^{(5)}(\text{ZST}) > S_c^{(5)}(\text{BST})$;
- V_a ... průměrný počet vět na souvětí, $V_a(\text{ZST}) > V_a(\text{BST})$;
- C ... počet vybraných slovních konceptů, $P(\text{ZST}) > P(\text{BST})$.

Více parametrů uvedených výše je v korelaci (například v případě, že počet souvětí je vyšší u znalostně strukturovaného textu, lze předpokládat, že počet slov je také vyšší pro znalostně strukturovaný text, apod.). Obrázek 12 představuje porovnání hodnot pomocí box plotů u vybraných parametrů.



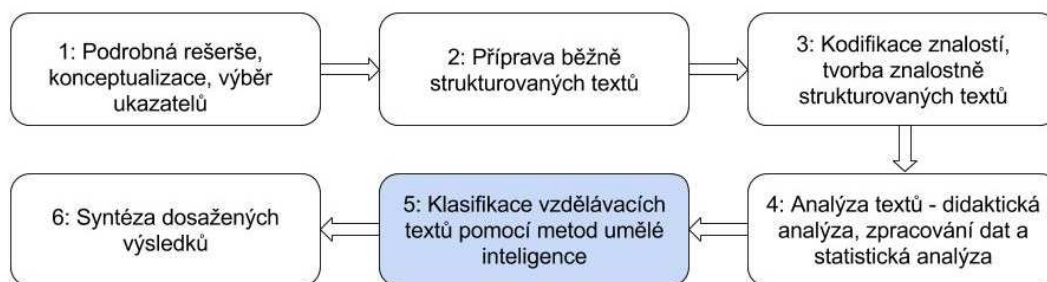
Obrázek 12 Box ploty pro vybrané parametry znalostně strukturovaného textu (ZST) a běžně strukturovaného textu (BST), zpracováno v programu Statistical12; zdroj: autorka

S použitím stejného přístupu k potvrzení platnosti původních pracovních hypotéz PH1.0 - PH4.0 o rozdílech ve vlastnostech mezi běžně strukturovaným textem (BST) a znalostně strukturovaným textem (ZST), byly získány výsledky uvedené v tabulce 3.

Proměnná	Typ textu	Průměr	Směrodatná odchylka	t hodnota	p hodnota	Pracovní hypotéza	Výsledek testu na hladině $\alpha = 0,05$
Celková obtížnost textu	BST	50,078	29,532	4,67358	0,000018	PH1.0	Zamítnuta
	ZST	33,333	13,823				
Proporce odborných a faktografických pojmů v celkovém počtu slov	BST	20,849	10,188	1,28765	0,202894	PH2.0	Nezamítnuta
	ZST	20,172	8,280				
Průměrný počet jednoduchých vět na souvětí	BST	2,393	0,544	-4,2878	0,000068	PH3.0	Zamítnuta
	ZST	2,728	0,472				
Počet vybraných slovních konceptů	BST	2,700	1,825	-14,002	0,000000	PH4.0	Zamítnuta
	ZST	9,517	3,223				

Tabulka 3 Platnost pracovních hypotéz; zdroj: autorka

5. krok: Klasifikace vzdělávacích textů pomocí metod umělé inteligence



Obrázek 13 Experiment I: 5. krok – Klasifikace vzdělávacích textů pomocí metod umělé inteligence; zdroj: autorka

Klasifikace vychází z frekvence slovních konceptů, která je u znalostně strukturovaných textů statisticky významně vyšší než u běžně strukturovaných textů, jak potvrdily výsledky v předcházejícím kroku experimentu I (PH4.0 byla zamítnuta).

Klasifikace textů v rámci prezentovaného výzkumu sestávala z následujících 5 etap (A až E).

A. V první etapě klasifikace bylo třeba připravit textové fragmenty. Vycházelo se ze shodných textů jako v kroku 1 experimentu I, s výjimkou toho, že každý fragment z kroku 1 byl ještě rozdělen na 2 fragmenty pro klasifikaci. Celkem tedy bylo vytvořeno 120 textových fragmentů, kde polovina z nich byla běžně strukturovaná a druhá polovina

byla znalostně strukturovaná. Průměrný rozsah textových fragmentů byl 205 slov, nejkratší fragment měl rozsah 161 slov a nejdelší fragment 311 slov.

B. Ve druhé etapě byly textové fragmenty analyzovány data miningovými nástroji programu STATISTICA 12, modul Text Miner. Byla vytvořena frekvenční matice (*term document matrix*) (Srivastava a Sahami, 2009) pro slovní koncepty (více kapitola 3.3.3), jejichž výskyt v textech byl sledován v práci Horákové a Houšky (2014b). Řádky matice představují specifické případy (fragmenty textu) a sloupce představují absolutní četnosti pozorovaných výskytů vybraných slovních konceptů. Vytvořená frekvenční matice měla 120 řádků a 25 sloupců. Celá frekvenční matice je k dispozici přiloženém CD.

C. Ve třetí etapě byly vytvořeny modely pro klasifikaci fragmentů textu v programu STATISTICA 12, modul Data Miner. Jednalo se zejména o umělé neuronové sítě (ANN) a klasifikační a regresní stromy (CART). Pro srovnání byly vytvořeny i rozhodovací stromy, pomocí bezplatné verze produktu pro strojové učení, BigML.

Jiřina (2003) uvádí, že práce s umělými neuronovými sítěmi v programu Statistica vyžaduje rozdělení dat do tří souborů: trénovací, testovací a validační. Bishop (2005) zmiňuje, že poměr rozdělení souborů je typicky 50:25:25 nebo 70:15:15, ale doporučuje se zvolit poměr, který poskytuje vyváženější výsledky trénovacího, testovacího a validačního výkonu. Proto byl pro tuto část experimentu zvolen poměr 70:15:15, který poskytoval vyváženější výsledky všech tří zmíněných výkonů ve srovnání s poměrem 50:25:25.

D. Čtvrtá etapa sestávala z předpovědi, tj. klasifikace dříve neznámých případů. Pro předpověď bylo využito 30 textových fragmentů (15 textových fragmentů znalostně strukturovaných a 15 běžně strukturovaných). Byla pozorována přesnost klasifikace struktury textu (běžně strukturovaný text vs. znalostně strukturovaný text) jednotlivých vybraných modelů (klasifikátorů).

E. Poslední etapa 5. kroku experimentu I byla statistická analýza, tj. definice statistických (operativních) hypotéz a statistické testování s využitím vybraného parametrického testu (viz podkapitoly). Cílem tohoto kroku je porovnat, který algoritmus umělé inteligence poskytuje statisticky vyšší přesnost klasifikačního výkonu.

Pro klasifikaci bylo vybráno pět umělých neuronových sítí s vyváženým výkonem pro každý soubor dat (trénovací, testování a validační). 4 sítě byly typu MLP (Multilayer Perceptron Network), 1 byla typu RBF (Radial Basis Function). Podrobné charakteristiky jednotlivých sítí, tj. chybová funkce, typ aktivace skryté vrstvy, funkce aktivace výstupu, počet skrytých vrstev (označovaných jako střední číslo v názvu umělé neuronové sítě), tréninkové algoritmy a výkonnostní charakteristiky jsou uvedeny v tabulce 4.

Tabulka 5 zobrazuje pro všechny umělé neuronové sítě, charakterizované v tabulce 4, přehled o přesnosti jejich schopnosti přiřadit text dvěma vybraným stylům, tj. znalostně strukturovaný vs. běžně strukturovaný text.


Charakteristiky umělých neuronových sítí								
Číslo ANN	Název ANN	Trénovací výkon	Testovací výkon	Validační výkon	Trénovací algoritmus	Chybová funkce	Aktivace skryté vrstvy	Výstupní aktivací funkce
ANN 1	MLP 49-19-2	100,00	94,44	100,00	BFGS	Entropie	Logistická	Softmax
ANN 2	RBF 49-22-2	82,14	72,22	94,44	RBF	Entropie	Gaussova	Softmax
ANN 3	MLP 49-13-2	97,62	83,33	100,00	BFGS	Suma čtverců	Identita	Exponenciální
ANN 4	MLP 49-10-2	100,00	88,89	94,44	BFGS	Suma čtverců	Logistická	Exponenciální
ANN 5	MLP 49-16-2	97,62	77,78	94,44	BFGS	Suma čtverců	Identita	Exponenciální

Tabulka 4 Charakteristiky umělých neuronových sítí; zdroj: autorka

Název ANN	Klasifikace	BST	ZST
MLP 49-19-2	Celkem textových fragmentů	60	60
	Správně klasifikováno textových fragmentů	60	59
	Chybně klasifikováno textových fragmentů	0	1
RBF 49-22-2	Celkem textových fragmentů	60	60
	Správně klasifikováno textových fragmentů	48	51
	Chybně klasifikováno textových fragmentů	12	9
MLP 49-13-2	Celkem textových fragmentů	60	60
	Správně klasifikováno textových fragmentů	59	56
	Chybně klasifikováno textových fragmentů	1	4
MLP 49-10-2	Celkem textových fragmentů	60	60
	Správně klasifikováno textových fragmentů	59	58
	Chybně klasifikováno textových fragmentů	1	2
MLP 49-16-2	Celkem textových fragmentů	60	60
	Správně klasifikováno textových fragmentů	59	54
	Chybně klasifikováno textových fragmentů	1	6

Tabulka 5 Schopnost klasifikace jednotlivých neuronových sítí (report z programu Satistica); zdroj autorka

Pro porovnání byly vybrány 4 klasifikační binární stromy typu CART. Stromy se lišily počtem uzlů (terminálních i neterminálních). Každý rozhodovací strom měl jinou importanci (tj. důležitost, nikoliv statistická významnost) vybraných slovních konceptů, dle kterých dochází k dělení uzlů, tj. klasifikaci do tříd. Následující obrázek 14 ukazuje importanci jednotlivých pojmů pro jednotlivé stromy (CART 1-4), na svislé ose je zobrazena importance (škála 0-1, přičemž 1 odpovídá nejvýznamnější dělicí proměnné), na vodorovné ose jsou dělicí proměnné, tj. pojmy (koncepty), dle kterých je prováděna klasifikace do dvou tříd (znalostně strukturovaný text vs. běžně strukturovaný text).



Obrázek 14 Importance vybraných pojmů pro závislou proměnnou typ textu; zdroj: autorka

Následující obrázky 15, 16 a 17 jsou reporty zobrazující struktury jednotlivých klasifikačních stromů. Uzly, které se již dále nedělí (koncové terminální uzly), již nemají v řádku vyplněné všechny položky. Struktura klasifikačního stromu je však dobře patrná i z tradičního grafického zobrazení stromů. Obrázek č. 18 znázorňuje tradiční grafické zobrazení pro vybraný rozhodovací strom (CART 3).

Uzel č.	Uzel levé větve	Uzel pravé větve	Velikost vzorku v uzlu	Velikost vzorku běžný text	Velikost vzorku znalostní text	Vybraná kategorie	Dělicí proměnná	Dělicí konstanta
1	2	3	120	60	60	běžný	jestliže	0,5
2	4	5	66	58	8	běžný	když	1,5
4			63	58	5	běžný		
5			3	0	3	znalostní		
3			54	2	52	znalostní		

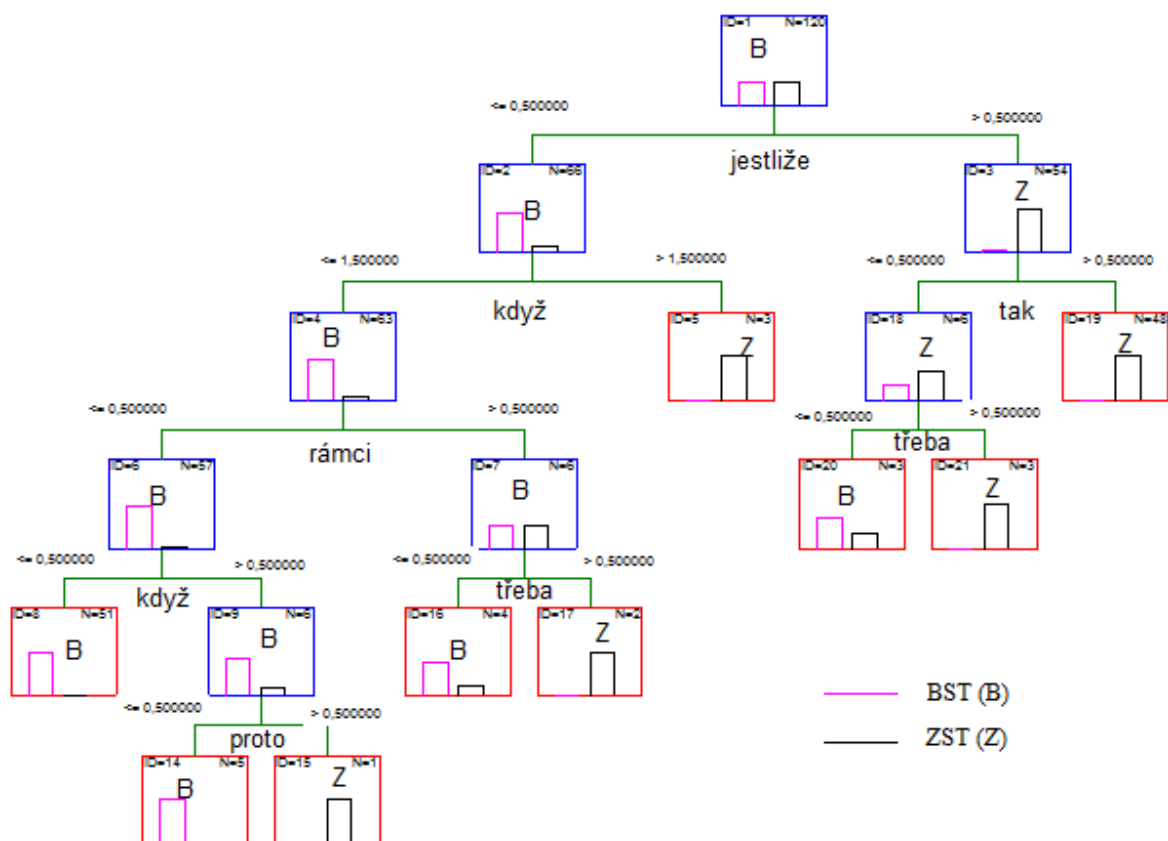
Obrázek 15 Struktura klasifikačního stromu CART 1 (report z programu STATISTICA 12, StatSoft); zdroj: autorka

Uzel č.	Uzel levé větve	Uzel pravé větve	Velikost vzorku v uzlu	Velikost vzorku běžný text	Velikost vzorku znalostní text	Vybraná kategorie	Dělicí proměnná	Dělicí konstanta
1	2	3	120	60	60	běžný	jestliže	0,5
2	4	5	66	58	8	běžný	když	1,5
4	6	7	63	58	5	běžný	rámci	0,5
6	8	9	57	55	2	běžný	když	0,5
8			51	50	1	běžný		
9	14	15	6	5	1	běžný	proto	0,5
14			5	5	0	běžný		
15			1	0	1	znalostní		
7	16	17	6	3	3	běžný	třeba	0,5
16			4	3	1	běžný		
17			2	0	2	znalostní		
5			3	0	3	znalostní		
3	20	21	54	2	52	znalostní	tak	0,5
20	22	23	6	2	4	znalostní	třeba	0,5
22	24	25	3	2	1	běžný	že	1,5
24			2	2	0	běžný		
25			1	0	1	znalostní		
23			3	0	3	znalostní		
21			48	0	48	znalostní		

Obrázek 16 Struktura klasifikačního stromu CART 2 (report z programu STTISTICA 12, StatSoft); zdroj: autorka


Uzel č.	Uzel levé větve	Uzel pravé větve	Velikost vzorku uzlu	Velikost vzorku běžný text	Velikost vzorku znalostní text	Vybraná kategorie	Dělicí proměnná	Dělicí konstanta
1	2	3	120	60	60	běžný	jestliže	0,5
2	4	5	66	58	8	běžný	když	1,5
4	6	7	63	58	5	běžný	rámci	0,5
6	8	9	57	55	2	běžný	když	0,5
8			51	50	1	běžný		
9	14	15	6	5	1	běžný	proto	0,5
14			5	5	0	běžný		
15			1	0	1	znalostní		
7	16	17	6	3	3	běžný	třeba	0,5
16			4	3	1	běžný		
17			2	0	2	znalostní		
5			3	0	3	znalostní		
3	18	19	54	2	52	znalostní	tak	0,5
18	20	21	6	2	4	znalostní	třeba	0,5
20			3	2	1	běžný		
21			3	0	3	znalostní		
19			48	0	48	znalostní		

Obrázek 17 Struktura klasifikačního stromu CART 3 (report z programu STTISTICA 12, StatSoft); zdroj: autorka

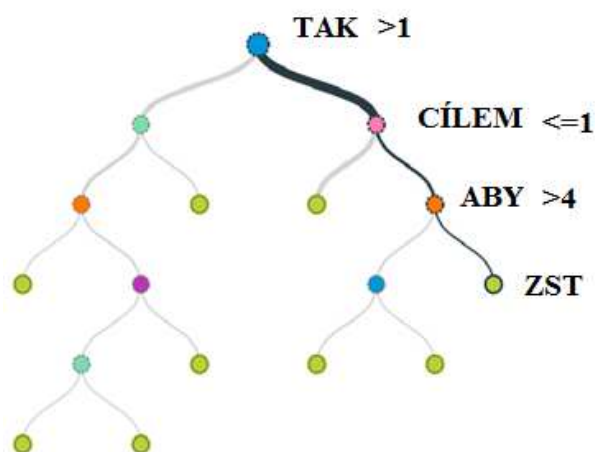


Obrázek 18 Grafické zobrazení klasifikačního stromu CART 3; zdroj: autorka

Dále byly pro porovnání vytvořeny 4 modely rozhodovacích stromů (bigML1, bigML2, bigML3, bigML4) v online verzi programu pro rozhodovací stromy v rámci strojového učení (bigML). Obrázek 19 ukazuje souhrnnou importanci jednotlivých dělicích proměnných za všechny 4 modely dohromady. Je patrné, že proměnná *tak* má největší vliv. Obrázek 20 je ukázkou struktury 4. modelu a jeho pravé krajní větve vedoucí k predikci znalostně strukturovaného textu. Z obrázu lze vyčíst, že pokud se v textovém fragmentu vyskytuje koncept ak více než 1 krát, koncept cílem maximálně 1 krát a aby více než 4 krát, zařadí rozhodovací strom text do třídy ZST, tj. znalostně strukturovaný text.

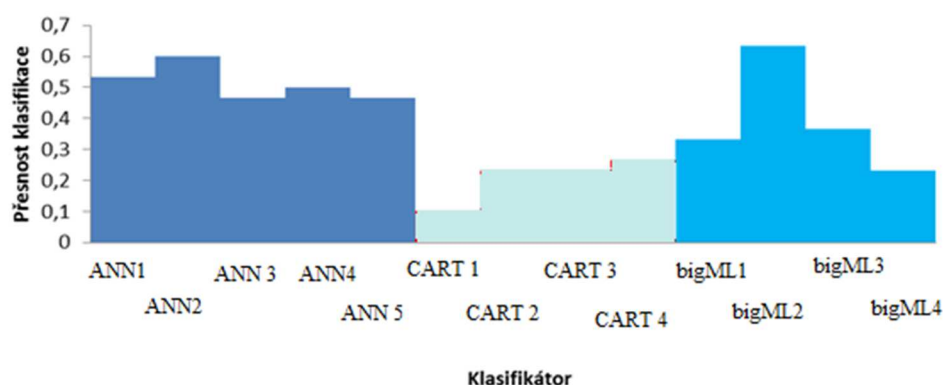


Obrázek 19 Souhrnná importance za všechny 4 modely; zdroj: autorka



Obrázek 20 Ukázka jednoho z modelů bigML se zaměřením na jeho pravou krajní větev, zpracováno v machine learning systému bigML; zdroj: autorka

Jednotlivým klasifikátorům umělé inteligence (5 neuronových sítí, 4 stromy CART a 4 rozhodovací stromy bigML) byly předloženy dosud neznámé textové fragmenty o rozsahu $n = 30$. Byla provedena predikce na základě sledovaných parametrů (frekvenční matice) a byla sledovaná správnost zařazení textu (klasifikace) do příslušné třídy (běžně strukturovaný text vs. znalostně strukturovaný text). Jednotlivé výstupy predikce pro všechny klasifikátory jsou dostupné na přiloženém CD. Z výstupů jsou zřejmé relativní četnosti správné klasifikace textových fragmentů do skupin, viz obrázek 21.



Obrázek 21 Grafické zobrazení přesnosti predikce jednotlivých nástrojů umělé inteligence, zdroj: autorka

Tři umělé neuronové sítě zařadily správně polovinu nebo více než polovinu neznámých textových fragmentů, tj. ANN 1 (správně 16, nesprávně 14), ANN 2 (správně 18, nesprávně 12), ANN 4 (správně 15, nesprávně 15), 2 neuronové sítě méně než polovinu, tzn. ANN 3 (správně 14, nesprávně 16), ANN 5 (správně 14, nesprávně 16). Všechny užívané klasifikační a regresní stromy přiřadily správně méně než polovinu neznámých textových fragmentů, tj. CART 1 (správně 3, nesprávně 27), CART 2 (správně 7, nesprávně 23), CART 3 (správně 7, nesprávně 23), CART 4 (správně 8, nesprávně 22). 1 model rozhodovacích stromů bigML (tj. bigML2, správně 19, nesprávně 11) přiřadil správně více než polovinu neznámých dokumentů, 3 zbývající méně než polovinu (tj. bigML1, správně 10, nesprávně 20; bigML3, správně 11, nesprávně 19; bigML4, správně 7, nesprávně 23).

V souladu s návrhem výzkumu byly definovány následující pracovní hypotézy:

PH5.0 Vybrané umělé neuronové (ANN) sítě poskytují stejné relativní frekvence správné klasifikace znalostně strukturovaných textů a běžně strukturovaných vzdělávacích textů jako vybrané rozhodovací stromy (bigML).

PH6.0 Vybrané umělé neuronové (ANN) sítě poskytují stejné relativní frekvence správné klasifikace znalostně strukturovaných textů a běžně strukturovaných vzdělávacích textů jako vybrané klasifikační a regresní stromy (CART).

Bylo testováno dvacet operativních hypotéz pro ANN vs. CART.

OH5.(ij): ANN (i) dosahuje stejnou relativní četnost správné klasifikace do třídy znalostně strukturovaných textů nebo běžně strukturovaných vzdělávacích textů jako CART (j), $i \in \{1,2,3,4,5\}, j \in \{1,2,3,4\}$.

Kde i označuje pořadové číslo ANN, j označuje pořadové číslo CART.

Dále, bylo testováno dvacet operativních hypotéz pro ANN vs. bigML.

OH6.(im): ANN (i) dosahuje stejnou relativní četnost správné klasifikace do třídy znalostně strukturovaných textů nebo běžně strukturovaných vzdělávacích textů jako bigML (m), $i \in \{1,2,3,4,5\}, m \in \{1,2,3,4\}$.

Kde i označuje pořadové číslo ANN, m označuje pořadové číslo bigML.

Testovací kritéria pro 40 operativních hypotéz jsou zobrazena v následující tabulce 6.

	CART 1	CART 2	CART 3	CART 4	bigML 1	bigML2	bigML 3	bigML 4
ANN 1	3,607865	2,389755	2,389755	2,108185	1,56315	– 0,78558	1,297498	2,389755
ANN 2	4,05999	2,880476	2,880476	2,605251	2,070197	– 0,26553	1,808397	2,880476
ANN 3	3,151444	1,894662	1,894662	1,607399	1,054093	-1,2975	0,785584	1,894662
ANN 4	3,380617	2,143199	2,143199	1,858698	1,309307	-1,0421	1,0421	2,143199
ANN 5	3,151444	1,894662	1,894662	1,607399	1,054093	-1,2975	0,785584	1,894662

Tabulka 6 testová kritéria pro 40 operativních hypotéz; zdroj: autorka

Tučně označená testová kritéria ($|U| < |U|_{\alpha}$), ukazují na takové kombinace klasifikátorů, které přinášejí shodné četnosti ve správnosti zařazení, běžným fontem psaná testová kritéria ($|U| > |U|_{\alpha}$), ukazují na takové kombinace klasifikátorů, které přinášejí rozdílné četnosti ve správnosti zařazení, např. testové kritériu U při porovnání ANN 1 a CART 1 je 3,607865, což je vyšší než tabulková hodnota pro zvolenou hladinu významnosti alfa ($\alpha = 0,05$), tj. dílčí nulová hypotéza je zamítnuta, tzn. ANN 1 nemá stejnou relativní četnost správného zařazení do třídy znalostních či standardních vzdělávacích textů jako CART 1.

Výsledky ukazují, že pokud jsou porovnávány neuronové sítě (ANN 1, ANN 2, ANN 3, ANN 4 a ANN 5) s klasifikačními a regresními stromy CART (CART 1, CART 2, CART 3

a CART 4), tak mimo kombinace CART 4 vs. ANN 5 a CART 4 vs. ANN 3, lze říci, že neuronové sítě poskytují přesnější predikci, což je i v souladu s tvrzením Jiřiny (2003). Komparaci neuronových sítí, CART stromů a klasické regrese provedli i např. Razi a Athappilly (2005). Dle nich má nejvyšší chybu MAPE (mean absolute percentage error) užití regrese, poté CART stromy a nejnižší neuronové sítě, ale při vzájemném testování správných klasifikací pomocí neuronových sítí a CART stromů autoři nepotvrdili statisticky významný rozdíl, což se projevilo i ve výsledcích výše uvedených při porovnání některých neuronových sítí a rozhodovacích stromů ze systému bigML. Lin et al. (2010) zkoumal 5 modelovacích technik: Artificial Neural Networks (ANNs), Radial Basis Function (RBF), Support Vector Regression (SVR) a Multivariate Adaptive Regression Splines (MARS), z nichž vyhodnotil jako nejlepší SVR, která ovšem vyžaduje víc vstupních údajů než jiné metody.

Významnými faktory, které mohou ovlivnit přesnost klasifikací neuronových sítí, jsou: velikost vzorků trénovací, testovací a validační množiny a velikost vzorků pro predikci. Např. Rajan et al. 2009 či Mohammad a Zitar (2011) dokázali nalézt neuronové sítě s lepšími predikčními schopnostmi právě díky vzorkům většího rozsahu. Tayyebi a Pijanowski (2014) zjistili, že ANN jsou přesnější, ale hůře interpretovatelné. Dobré výsledky mohou dávat genetické algoritmy v kombinaci se systémy založené na imunologických reakcích živých organismů (Mohammad a Zitar, 2011). Také Puniškis et al. (2006) doporučuje kombinaci více metod. Dalšími faktory ovlivňující přesnost klasifikace jsou i typy užitých algoritmů či specifika řešené úlohy.

Klasifikační úloha na rozřazení znalostně strukturovaných a běžně strukturovaných textů má úskalí v tom, že i přes to, že text je označen jako znalostně strukturovaný, tak dle metodiky Houšky a Rauchové (2013) může obsahovat nejen produkční pravidla a znalostní jednotky, ale i doplňující, upřesňující informace bez znalostního potenciálu, což může způsobovat i určité narušení pro klasifikátory v rámci hledaných vztahů a souvislostí mezi jednotlivými proměnnými.

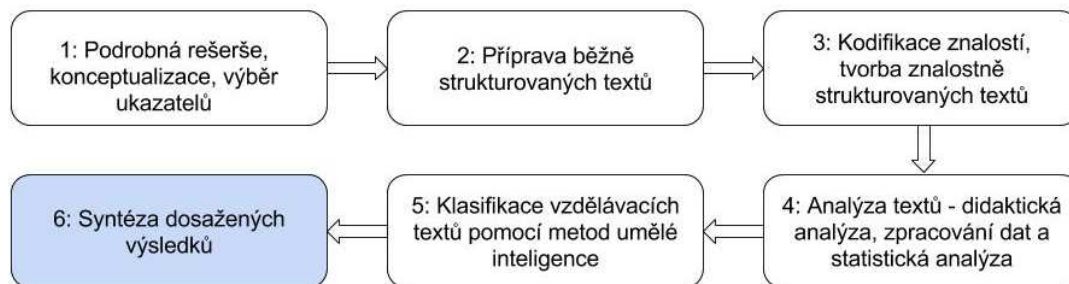
Na druhou stranu klasifikace vzdělávacích textů podle jejich stylu (znalostně strukturovaný vs. běžně strukturovaný text) může přispět k rozvoji tzv. znalostního obsahu (Content Knowledge) učebnic a vzdělávacích textů v souvislosti s modelem TRACK (Technological Pedagogical Content Knowledge) navrženým Mishrou a Koehlerem (2006).

Navíc klasifikace textů může přispět i ke zlepšení metod pro měření zmíněného TRACK modelu, kterými se zabývají například Archambault a Barnett (2010). Proto do budoucna bude cílem rozšířit množinu vzorků, nalézt nové neuronové sítě s vyšší schopností správné klasifikace a rozšíření práce s metodami umělé inteligence o fuzzy logiku, tak jako např. Huang et al. 2014, Chen et al. 2010, aby bylo možné určit, s jakou mírou příslušnosti je text „spíše znalostně strukturovaný“ či „spíše běžně strukturovaný“. Což by mohlo mít výhody nejen v rámci analýz vzdělávacích dokumentů pro školy a univerzity, ale též pro přípravu materiálů v rámci profesního a celoživotního vzdělávání.

Tři odlišné skupiny mohou profitovat z výsledků analýzy, a to: *čtenáři textu* (studenti, uživatelé atd.), *autoři vzdělávacích textů* a *analytici (hodnotitelé) učebnic*. Jak bylo zjištěno v předchozím výzkumu (Horáková a Houška, 2016), čtenáři nejsou obecně schopni vnímat rozdíly mezi styly textu. Reakce čtenářů na text jsou nezávislé na metodách měření; ani objektivní měření pomocí funkční magnetické rezonance (Horáková, Houška a Luhanová, 2016), ani subjektivní zpětná vazba prostřednictvím dotazníkového průzkumu (Rauchová a Houška, 2013a) nepotvrdila schopnost čtenářů vnímat rozdíly mezi různými styly textů. Na druhé straně záměrná struktura znalostně strukturovaného textu umožňuje motivovat čtenáře, aby upozornila na nejdůležitější výroky v textu, jak ukazuje Reichelt et al. (2014). Autoři textů mohou tento přístup použít, aby se ujistili, že skutečně kodifikují znalosti namísto čistých informací nebo dokonce pouze dat (Dömeová et al., 2008). Navíc, pokud se jako zdroj pro vypracování vzdělávacího textu používá produkční pravidlo, jako základ znalostní báze expertního systému, získává autor zpětnou vazbu, zda úspěšně vkládá znalosti z expertního systému do svého textu. Výše analyzované algoritmy by mohly sloužit i analytikům textu (hodnotitelům) učebnice jako další analytický přístup, vedle běžně užívané analýzy obtížnosti textu a čitelnosti textu (Hrabí, 2012; Húbelová, 2010).

Franzolin a Bizzo (2015) definují laxitu jako "tendenci měnit vědecké poznatky, prezentované v učebnicích, aby byly pro studenty co nejvíce přístupné. Rigorismus je opakem laxity, tj. tendence přiblížit znalosti co nejvěrněji vědeckým principům, snažení se je správně a striktně předat." Pokud tedy bude možné zjistit, zda je text v souladu se znalostně strukturovaným nebo běžně strukturovaným textem, bude možné při pohledu na znalosti vyučované na školách (univerzitách) najít rovnováhu mezi "laxitou" a "rigorismem" podle příslušné úrovně vzdělání.

6. krok: Syntéza dosažených výsledků



Obrázek 22 Experiment I: 6. krok – Syntéza dosažených výsledků; zdroj: autorka

Mimo hypotézy PH2.0 týkající se rozdílnosti v koeficientech hustoty odborné informace mezi znalostně strukturovanými a běžně strukturovanými texty, všechny pracovní hypotézy jsou zamítnuty na hladině významnosti $\alpha = 0,05$. Následují komentáře a porovnání výsledků s prací jiných autorů.

Existuje statisticky významný rozdíl u celkové obtížnosti textu mezi znalostně strukturovaným a běžně strukturovaným textem. Běžně strukturované texty dosahují vyšší hodnoty než znalostně strukturované texty.

Na první pohled výsledek nedává smysl. Autoři, kteří se zabývají měřením obtížnosti textů v učebnicích (např. McCrory a Stylianides (2014) nebo Miller (2011)) ukazují závislost mezi množstvím znalostí v textu a celkovou složitostí textu jako "čím vyšší je množství znalostí v textu, tím vyšší je obtížnost textu". Vysvětlení lze nalézt ve způsobu výpočtu celkové obtížnosti textu. Stupeň obtížnosti textu T se spočte jako součet syntaktické obtížnosti T_s a sémantické obtížnosti T_p , viz vzorce 8 a 9. Na základě zamítnutí platnosti pracovních hypotéz PH1.3 a PH1.4 (obě hodnoty T_s a T_p jsou výrazně nižší pro znalostně strukturované texty), je přirozené, že hodnota celkové obtížnosti textu T je rovněž nižší pro znalostně strukturované texty.

Neexistuje statisticky významný rozdíl u koeficientu informační hustoty mezi znalostně strukturovaným a běžně strukturovaným textem.

Na rozdíl od výsledků v rámci předvýzkumu (Rauchová et al., 2014), se nepotvrdil předpoklad o rozdílech mezi texty v této charakteristice. Je přirozené, že koeficient hustoty odborné informace h je nezávislý na stylu textu. Počet podstatných jmen je vždy podobný

jako počet pojmů v textu (vzorec 11). Hlavní rozdíl mezi výsledky předvýzkumu a aktuálními výsledky je způsoben u koeficientu hustoty odborné informace i (vzorec 10). Je zřejmé, že rozptyl hodnot hrál důležitou roli v předvýzkumu (viz střední hodnoty a směrodatné odchylky pro běžně strukturované a znalostně strukturované texty v tabulce 2 pro parametr i) a významně ovlivnil odhady.

Existuje statisticky významný rozdíl u průměrného počtu jednoduchých vět na souvětí mezi znalostně strukturovaným a běžně strukturovaným textem. Znalostně strukturované texty dosahují vyšší hodnoty než běžně strukturované texty.

Tento výsledek přirozeně vyplývá z rozkladu znalostně strukturovaného textu založeného na formálním modelu znalostní jednotky a její jazykové formy, viz vzorec 1. Věta se vždy minimálně skládá ze dvou jednoduchých vět vyjadřujících jak předchůdce (antecedent), tak následníka (konsekvent) znalostní jednotky. Někdy je nutné vysvětlit některé části znalostní jednotky podrobněji, v důsledku toho může vzrůst počet jednoduchých vět. To je v souladu s hlavním proudem literatury o managementu znalostí nebo znalostního inženýrství. Všichni autoři, jejichž práce jsou v rámci literární rešerše zmíněny, chápou znalosti jako rozšířená data nebo informace. Tato myšlenka je v současné době běžná a objevuje se i ve více oblastech, např. v zemědělství (Rydval, Bartoska a Brozova, 2014) nebo v rámci projektového managementu (Mochida, 2011). Je zřejmé, že k vyjádření znalostí je zapotřebí více slov a jednoduchých vět než k vyjádření obsahující informace nebo jen samotná data.

Existuje statisticky významný rozdíl u průměrného počtu vybraných slovních konceptů mezi znalostně strukturovaným a běžně strukturovaným textem. Znalostně strukturované texty dosahují vyšší hodnoty než běžně strukturované texty.

Na rozdíl od operačních hypotéz OH4.2 - OH4.6, které se zaměřují na běžné pojmy, faktografické pojmy atd., pracovní hypotéza PH4.0 pracuje se slovy, typickými pro výrazy (koncepty) znalostních jednotek, zejména se spojky (jestliže, když, aby, atd.). I když není žádný rozdíl v obsahu prohlášení textových fragmentů (hypotézy OH4.2 - OH4.6 nebyly zamítnuty), může hrát důležitou roli fakt, pokud jsou elektronickým vzdělávacím dokumentům přidělena metadata (Šimek et al., 2012), není třeba doprovázet změnu stylu textu změnou metadat. Na druhé straně je formální struktura znalostně

strukturovaného textu příliš jedinečná pro statistickou analýzu, aby bylo možné rozlišit mezi běžně strukturovanými a znalostně strukturovanými texty.

V této části kapitoly byl analyzován relevantní vzorek výukových textů na zpracování odpadu zemědělství s cílem zjistit rozdíly mezi jejich běžnou a znalostní formou. Ve srovnání s běžně strukturovaným textem, text znalostně strukturovaný se vyznačuje tím, že obsahuje ve větách více slov (v průměru), vyšším výskytem souvětí vyjadřující kompletní znalost, jakož i relativně vyšší počet jednoduchých vět na souvětí (opět v průměru). Vybrané slovní koncepty a intenzita jejich výskytu ve znalostně strukturovaném textu umožní rozlišit právě mezi dvěma zmíněnými formami textu.

Několik parametrů, které mohou být použity pro rozlišení textu, by mohlo sloužit i pro účely dalšího výzkumu zabývajícího se hodnocením obecného včetně schopnosti přiřazení k jednomu či druhému typu textu (běžně nebo znalostně strukturovaný text). V literatuře je možné najít mnoho druhů analýz zabývající se klasifikací stylů dokumentů (populární, vyprávěcí, vědecký, atd.) nebo sentimentální analýzy obsahu dokumentů (např. Feldman, 2013, přehledová studie aktuálního stavu v této oblasti). Na základě výše zmíněných výsledků bude možné definovat nový typ takové analýzy.

V rámci klasifikační analýzy byla měřena a diskutována schopnost tří široce používaných klasifikačních technik: umělé neuronové sítě (ANN), klasifikační a regresní stromy (CART) a rozhodovací stromy (bigML) k odlišení znalostně strukturovaného a běžně strukturovaného stylu vzdělávacích textů. Různé metody umělé inteligence mohou poskytnout uspokojivé výsledky založené na konkrétním účelu použití, na možnostech získání vstupních parametrů nebo na objemu trénovacích, testovacích a validačních množin vzorků.

Bylo testováno 120 textových fragmentů z učebnic. 60 textových fragmentů bylo znalostně strukturovaných, 60 fragmentů běžně strukturovaných. Většina výsledků klasifikačních modelů ANN poskytovala vyšší míru úspěšnosti klasifikace v porovnání s modely CART. Na druhé straně většina rozhodovacích stromů bigML dosáhla stejné úspěšnosti jako modely ANN.

Tato zjištění jsou užitečná pro analýzu znalostního obsahu v mnoha modelech zabývajících se znalostmi v pedagogice, zejména při tvorbě učebnic, analýze učebnic a při rozhodování o obsahu textu, který by případně měl/neměl být zařazen do/z učebnice.

Další výzkum je možné zaměřit na aplikace jiných algoritmů umělé inteligence nebo kombinace více metod umělé inteligence. Nahrazení bivalentní klasifikace (1 = běžně strukturovaný text, 0 = znalostně strukturovaný text, nebo naopak) diskrétním nebo kontinuální měřítkem by také mohlo rozšířit soubor analytických nástrojů používaných pro hodnocení obtížnosti textu.

Jak již bylo zmíněno, jsou dobře známy přístupy a ukazatele pro měření sémantické nebo syntaktické obtížnosti vzdělávacích textů nebo učebnic. Přístup uvedený v této práci může vést k návrhu ukazatelů pro měření znalostního obsahu textu, které můžou obecně přispět k doplnění metodiky analýzy učebnic. Rozšíření souboru výukových textů pro analýzu a klasifikaci by přispělo ke zpřesnění výsledků. Kromě toho, pokud bude možné rozlišit texty podle jejich stylu (s explicitně nebo implicitně vyjádřenými znalostmi), je možné lépe nalézt rovnováhu mezi laxitou a rigorismem znalostí vyučovaných ve školách.

4.2.4 Závěr kapitoly 4.2

Cílem experimentu I bylo identifikovat rozdíl mezi vzdělávacími texty psanými běžnou formou (běžně strukturované texty) a znalostně strukturovanými texty, které byly vytvořeny záměrným použitím metod znalostního inženýrství. Dílčím cílem experimentu I bylo otestovat vhodnost klasifikátorů z nástrojů umělé inteligence (rozhodovací stromy, klasifikační stromy a umělé neuronové sítě) a zjistit, který z nich a s jakou přesností umí lépe klasifikovat neznámé texty z hlediska výskytu slovních konceptů, typických pro znalostně strukturovaný text. Výzkumný vzorek byl tvořen šedesáti dokumenty – vzdělávacími texty z oblasti zpracování zemědělských odpadů, které byly autorkou práce převedeny do znalostně strukturované podoby. Nad sadou indikátorů, které se používají pro hodnocení didaktických textů, byly formulovány pracovní a operativní hypotézy, jejichž platnost byla testována pomocí párového T testu. Ukázalo se, že znalostně strukturované texty vykazují ve srovnání s běžně strukturovanými texty statisticky významně ($\alpha = 0,05$) nižší koeficient celkové obtížnosti, jelikož je při srovnatelném množství faktických a technických informací složen z významně většího počtu

jednoduchých vět spojených v souvětí reprezentující znalost. Na základě významně větší frekvence vybraných konceptů je pak možné oba typy textů odlišit i formálně, na čemž je možné založit další výzkum: automatizované rozpoznávání stylu vzdělávacího textu a měření obsahu znalostí, které jsou v něm obsaženy. Další důležitou otázkou podstatnou pro budoucí výzkum je vnímání odlišností textu z pohledu čtenářů. I přesto, že je možné měřit a počítat komplexní obtížnost textu, jež se u znalostně strukturovaných textů prokázala jako podstatně nižší ve srovnání s běžně strukturovanými texty, je třeba zjistit, zda i stanovisko čtenářů je v souladu s tímto teoretickým předpokladem. Z toho důvodu byl realizován další experiment na vnímání rozdílů mezi texty u čtenářů – studentů středních zemědělských škol, zemědělců a agronomů. Navazující experiment II je rozpracován v kapitole 4.3.

4.3 Text jako nástroj transferu znalostí

4.3.1 Úvod kapitoly 4.3

Třetí část výzkumné části práce je zaměřena na pedagogický výzkum efektivnosti znalostně a běžně strukturovaných textů jako nástroje pro transfer znalostí. Výzkum byl založen na experimentu II. Jednalo se o testovací proceduru, jež měla za cíl sledovat aspekty ovlivňující učení se z textu a porovnat výsledky pro texty ve znalostně strukturované formě s texty běžně strukturovanými.

Kapitola 4.3 vznikla na základě projektu s názvem Měření efektivity transferu znalostí v sektoru zpracování zemědělských odpadů (poskytovatel CIGA ČZU, trvání od 2013 do 2014, registrační číslo projektu 20131001). Byl realizován experiment dle navržené metodiky a získány výsledky. Finálnímu experimentu předcházelo důkladné pilotní šetření včetně didaktických analýz metodických nástrojů experimentu, tj. testů, jež přispěly ke zlepšení navržené metodiky experimentu. Interpretace a další reanalýzy výsledků finálního experimentu jsou rovněž součástí této kapitoly.

Kapitola 4.3 vychází z již publikovaných příspěvků. Výsledky pilotního šetření byly prezentovány na doktorské konferenci Think Together 2014 a v časopise *International Education studies* (Horáková a Houška, 2014a), výsledky zpětné vazby od uživatelů byly prezentovány na vědecké doktorské konferenci *Think Together 2016* a na konferenci *15th International Conference on Efficiency and Responsibility in Education* (Horáková a Houška, 2016).

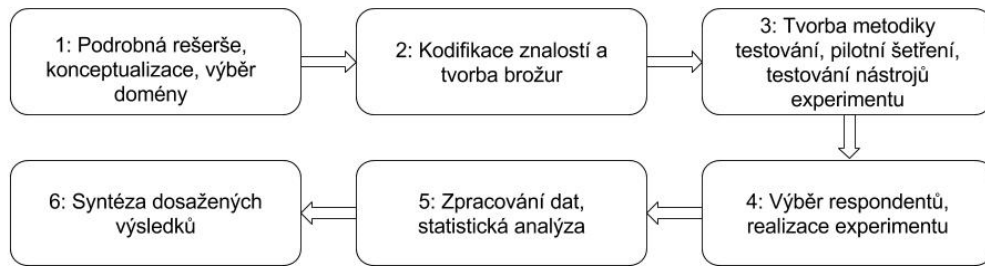
4.3.2 Experiment II

Pro experiment II byly stanoveny následující dvě výzkumné hypotézy.

VH2: Neexistují žádné rozdílnosti v úspěšnosti transferu znalostí v rámci práce se znalostně a běžně strukturovanými texty.

VH3: Uživatelé subjektivně nevnímají rozdíly ve struktuře u znalostně a běžně strukturovaných textů.

Schéma experimentu II zobrazuje obrázek 23.



Obrázek 23 Schéma experimentu II; zdroj: autorka

První krok experimentu II v podobě podrobné rešerše a konceptualizace souvisel s prostudováním odborné literatury a zúžením záběru a konkretizaci pracovních hypotéz. Dále navazoval výběr problémové domény. V rámci této činnosti bylo cílem konkretizovat oblast vhodnou pro transfer znalostí v dané tematické oblasti, tj. sekundárního zpracování zemědělských odpadů.

Druhý krok byl zaměřen na předání znalosti a kodifikaci znalosti pomocí znalostních jednotek. Na této činnosti spolupracoval expert na problémovou doménu a znalostní inženýr, který pomocí vhodných metod pro reprezentaci znalostí kodifikoval získanou znalost z dané problémové domény. Poté následovalo sestavení znalostně strukturovaných textů. Tato činnost souvisela s tvorbou vzdělávacích textů pomocí znalostních jednotek. Vytvořené texty musely korespondovat s běžně používanými didaktickými zásadami pro tvorbu vzdělávacích textů. Proto nově vytvořené texty prošly korekturou, která se zaměřila i na didaktické zásady psaní textů, více Průcha (1998).

Třetí krok experimentu byl zaměřen na přípravnou fázi samotného experimentu. Cílem bylo připravit metodiku testování za použití didaktických a pedagogických zásad pro zvolený typ výzkumu. Pro stanovení sledovaných a měřených aspektů v rámci výzkumu byla použita pravidla pro tvorbu hodnotících kritérií dle Bazermana a Moora (2013). Pilotní šetření mělo za cíl ověřit navrženou metodiku experimentu na malém vzorku respondentů a zjistit, zda výzkum poskytne dostatečně reliabilní a validní výsledky, v případě potřeby upravit metodiku tak, aby byla vhodná pro samotný experiment. Součástí pilotáže bylo i otestování nástrojů (didaktických testů) experimentu z pedagogického pohledu (Chráška, 2007).

Ve čtvrtém kroku došlo k samotné realizaci experimentu dle finální metodiky. Cílem bylo experimentálně otestovat odlišnosti při práci s běžně a znalostně strukturovanými texty.

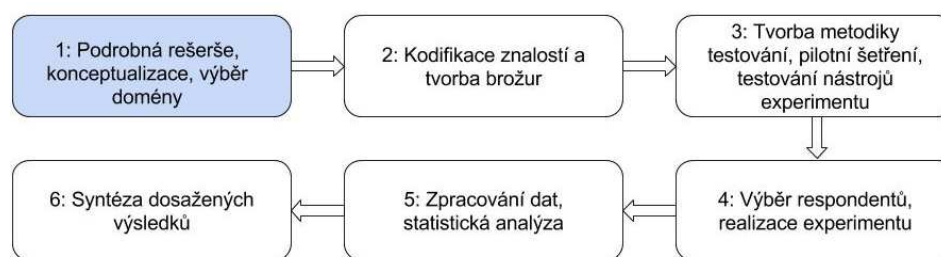
Výběr respondentů byl zajištěn externí společností. Vzorek respondentů musel být reprezentativní a splňovat požadavky specifikované ve finální metodice. Ověření, zda znalost byla správně předána uživatelům, spočívalo ve spolupráci experta na problémovou doménu a didaktika.

Pátý krok experimentu byl zaměřen na získání a zpracování primárních dat, výstupů z experimentu, do datové matice, použitelné pro další reanalýzy. Statistická analýza experimentu měla za cíl kromě základních popisných charakteristik sledovaných veličin odhalit též pomocí souhrnných metod statistické indukce rozdílnosti mezi běžně strukturovaným a znalostně strukturovaným textem. Cílem experimentu bylo vyhodnotit výsledky experimentu a posoudit úspěšnost transferu znalostí prostřednictvím vzdělávacích textů ke konečným uživatelům z praxe a vyhodnotit zpětnou vazbu od účastníků experimentu.

V šestém kroku došlo k zhodnocení výsledků analýz, nezamítnutí/zamítnutí stanovených operativních a pracovních hypotéz a zobecnění výsledků o běžně strukturovaných a znalostně strukturovaných textů z hlediska jejich efektivity transferu znalostí v procesu učení se z textů.

4.3.3 Konkrétní výstupy experimentu II

1. krok: Podrobná rešerše, konceptualizace, výběr problémové domény

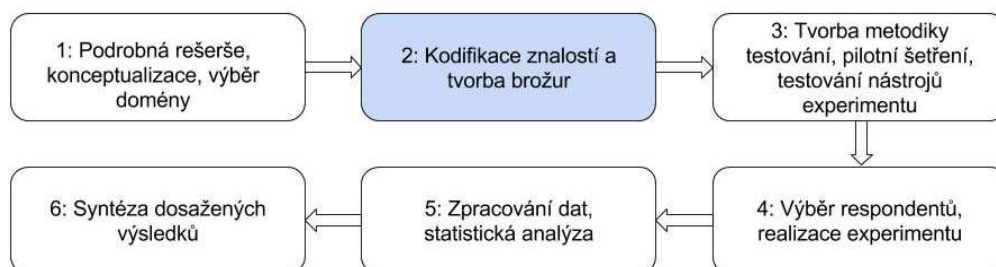


Obrázek 24 Experiment II: 1. krok – Podrobná rešerše, konceptualizace, výběr domény; zdroj: autorka

Podrobná rešerše a konceptualizace byla obdobná jako v experimentu I, jelikož tato část byla shodně řešena v rámci projektu CIGA ČZU "Měření efektivity transferu znalostí v sektoru zpracování zemědělských odpadů" (poskytovatel CIGA ČZU, trvání od 2013 do 2014, registrační číslo projektu 20131001). Běžně strukturované texty vznikly úpravou

textů od Káry et al. (2007). Texty následně prošly i didaktickou úpravou a revizí dle návodů Průchy (1998), více viz kapitola 3.3.

2. krok: Kodifikace znalostí a tvorba brožur

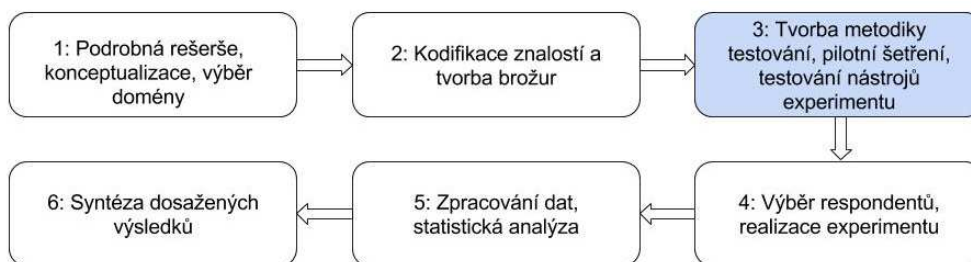


Obrázek 25 Experiment II: 2. krok – Kodifikace znalostí a tvorba brožur; zdroj: autorka

V dalším kroku bylo třeba připravit sadu znalostně strukturovaných textů, odpovídající definici v kapitole 4.1. Jednalo se o vzdělávací texty zabývající se tematikou zpracování zemědělských odpadů a navazujících témat. Texty, resp. textové fragmenty, byly zpracované do brožury. Každá brožura se skládala ze 4 tematických suboblastí. Ukázka textové brožury je součástí příloženého CD.

Celkem byly k dispozici 4 formáty brožur, jejichž název odpovídal čtyřmístnému kódu z 0 a 1 (1100, 0011, 1010, 0101), kde 0 znamenala suboblast zpracovanou běžně strukturovanou formou, 1 znamenala suboblast zpracovanou znalostně strukturovanou formou, první místo kódu znázorňovalo suboblast chemie, druhé místo kódu suboblast legislativy, třetí místo suboblast praxe, čtvrté místo suboblast ekonomiky. Např. brožura typu 1100 znamenala, že suboblast chemie a legislativy byla zpracována znalostně strukturovanou formou, praxe a ekonomika formou běžně strukturovanou.

3. krok: Tvorba metodiky testování, pilotní šetření, testování nástrojů experimentu



Obrázek 26 Experiment II: 3. krok – Tvorba metodiky testování, pilotní šetření, testování nástrojů experimentu; zdroj: autorka

Cílem tohoto kroku bylo navržení metodiky experimentu a využití statistických a didaktických metod v předvýzkumné fázi pedagogického výzkumu pro odstranění nedostatků metodiky experimentu a nezamítnutí/zamítnutí následujících sedmi pracovních hypotéz (*Poznámka: Nezamítnutí/zamítnutí pracovních hypotéz PH7.0, PH8.0, PH9.0, PH10.0, PH11.0, PH12.0 a PH13.0 mělo pouze vliv v rámci pilotáže a na úpravy metodiky testování, nikoliv na celkové závěry experimentu.*):

PH7.0: Výsledky (měřené v bodech) získané v pretestu i posttestu jsou normálně rozděleny.

PH8.0: Transfer znalostí prostřednictvím znalostně strukturovaného textu (měřený v bodech), transfer znalostí prostřednictvím běžně strukturovaného textu (měřený v bodech) i čistý transfer znalostí (měřený v bodech) jsou normálně rozděleny.

PH9.0: Doba studia textu *TST* (měřená v sekundách) je normálně rozdělena.

PH10.0: Typ textu (znalostně strukturovaný text vs. běžně strukturovaný text) nemá vliv na čistý transfer znalostí (měřený v bodech).

PH11.0: Průměrný čistý transfer znalostí (měřený v bodech) je shodný ve všech tematických suboblastech (chemie, legislativa, praxe, ekonomika). Výsledky posttestů u obou skupin A a B jsou normálně rozděleny.

PH12.0: Všechny didaktické charakteristiky (Q , P , n_H , n_L , ULI , a , b , c) se v průměru shodují u obou skupin A a B.

PH13.0: Standardizace testů je shodná v posttestech u obou skupin A a B (měřené percentilovým pořadím žáků a současně výsledky (měřené v bodech) získané v posttestu u obou skupin A a B jsou normálně rozděleny.

Metodika testování

Experiment měl podobu testovací procedury, kterou navrhla autorka (Rauchová, 2012b) a skládal se ze 4 částí: pretestu, vzdělávacího textu, posttestu a dotazníku.

Na řešení úloh prvního oddílu bylo vyhrazeno 15 minut, na čtení textu 30 minut, na řešení úloh posttestu bylo vyhrazeno 15 minut, na závěr byl testovaným předložen dotazník.

Jelikož se již potvrdilo v několika pedagogických experimentech (Ozuru, Dempsey a McNamara, 2009; Tarchi, 2010), že vliv počáteční úrovně znalostí na další transfer v procesu vzdělávání je významný, byl z tohoto důvodu součástí experimentu i pretest, který sloužil jako nástroj pro zjištění počáteční úrovně znalostí testovaných bez vlivu vzdělávacího textu.

Text byl nástrojem pro transfer znalostí ze čtyř suboblastí (chemie, legislativa, praxe, ekonomika) v rámci vybrané problémové domény korespondující s tématem projektu, tj. bioplyn a bioplynové stanice (více o brožurách viz předchozí krok).

Každá testovaná osoba obdržela text ve formě brožury, přičemž znalosti ze dvou suboblastí byly zachyceny běžně strukturovaným vzdělávacím textem a další dvě znalostně strukturovaným textem dle metodiky, kterou navrhli Houška a Rauchová (2013).

Posttest byl nástrojem pro zjištění efektu transferu znalostí pomocí textů. Čistý transfer znalostí KT_{netto} v bodech se vypočetl dle vzorce:

$$KT_{netto} = P_{POST} - P_{PRE} = KT_K + KT_O \quad 15$$

Kde KT_{netto} je čistý transfer znalostí v bodech, P_{POST} je počet bodů obsažených v posttestu, P_{PRE} je počet bodů získaných v pretestu, KT_K je čistý transfer znalostí v bodech

pomocí znalostně strukturovaného textu, KT_O je čistý transfer znalostí v bodech pomocí běžně strukturovaného vzdělávacího textu.

Jedním z cílů experimentu bylo zjistit, zda KT_K se statisticky významně liší od KT_O .

Jelikož didaktické testy (pretest i posttest) jsou nástrojem experimentu, pomocí nichž se má spolehlivě měřit transfer znalostí, bylo nutné v rámci předvýzkumu ověřit i jejich didaktické vlastnosti.

Oba testy se skládaly z 20 úloh s výběrem právě jedné správné odpovědi, přičemž ke každé ze 4 suboblastí se vztahovalo 5 otázek. Chráska (2007) doporučuje ke každé otázce dát na výběr jednu z 6 odpovědí, přičemž by se mezi nimi měla objevit i možnost *nevím*, kvůli zamezení tipování odpovědí. Otázky pretestu i posttestu zjišťovaly totéž, jen byly odlišně formulované. V každém testu byla polovina otázek charakteru doplnění informace a druhá polovina doplnění znalosti.

Dotazník byl nástrojem pro zjištění názorů účastníků experimentu na jednotlivé texty z hlediska jejich srozumitelnosti, tematické obtížnosti, přirozenosti. Ve fázi předvýzkumu dotazník navíc zjišťoval, i zda respondenti měli dostatek času na plnění úkolů, zpětnou vazbu o průběhu a formě testování a další.

Data získaná v předvýzkumu

Členové týmu projektu s názvem „Měření efektivity transferu znalostí v sektoru zpracování zemědělských odpadů“ oslovili celkem 40 studentů (vysokoškolských a středoškolských) tvořící nereprezentativní výběrový vzorek, jehož rozsah byl pro účely předvýzkumu postačující (Chráska, 2007).

Studenti se osobně účastnili celého experimentu ve fázi předvýzkumu. Byli zařazeni do dvou menších skupin, a to 24 studentů bylo ve skupině A (experimentální), 16 studentů bylo ve skupině B (kontrolní). Skupina A obdržela pretest a posttest, skupina B s nimi pracovala v opačném pořadí, tj. pretest je shodný s posttestem skupiny A a posttest je shodný s pretestem skupiny A. Aby byla zachována rovnost podmínek, byla vytvořena i podrobná metodika pro administrátory experimentu, kteří dohlíželi nad experimentem a zajistili tak jeho regulérní průběh. Studenti svoji účastí aktivně přispěli ke zlepšení

samotné metodiky vlastního experimentu, který probíhal na jaře 2014 na reprezentativním vzorku o rozsahu 63 testovaných (studenti ze středních zemědělských škol, zemědělci a agronomové).

Pro získání základní představy o získaných datech byly použity ukazatele popisné statistiky, a to zejména míry centrální tendence a míry rozptylu získaných dat (Lindsey, 2009). Dále například výpočet konfidenčního intervalu pro průměr z oblasti statistické indukce (Bassett et al., 2000), či parametrické testování statistických hypotéz o shodě dvou průměrů (T test) a o shodě dvou rozptylů (F test) a též testování předpokladu normálního rozdělení dat pomocí testu distribuce (Shapiro-Wilkův test) podrobně popsané v knize (Gravetter a Wallnau, 2009). Pro zjištění statistické rozdílnosti průměrů u více skupin byla použita metoda jednofaktorové analýzy rozptylu (ANOVA).

V rámci předvýzkumu proběhlo statistické zpracování výsledků, testování hypotéz a vyvození závěrů z hlediska vlastností jednotlivých nástrojů výzkumu (didaktická analýza testů). Nejprve byly spočteny základní popisné statistiky, uvedené v tabulce 7. Maximální množství bodů obdržených u testovaných v pretestu bylo 12, v posttestu 15, průměrný čistý transfer byl 4,20 bodů, přičemž v průměru se na něm podílel z 52,38 % transfer pomocí běžně strukturovaných vzdělávací textů, zbylých 47,67 % tvořil transfer pomocí znalostně strukturovaných textů. Doba studia textu (TST) v průměru byla 806,83 sekund, přičemž nejdelší potřebná doba byla 1201 sekund. Což ukázalo, že čas vyhrazený ke studiu textu 30 minut je dostatečný a obsahuje ještě časovou rezervu.

V dalším kroku byly testovány operativní hypotézy OH7.1, OH7.2, OH8.1, OH8.2, OH8.3 a OH9.1.

OH7.1: Data proměnné P_{PRE} jsou normálně rozdělena.

OH7.2: Data proměnné P_{POST} jsou normálně rozdělena.

OH8.1: Data proměnné KT_{netto} jsou normálně rozdělena.

OH8.2: Data proměnné KT_O jsou normálně rozdělena.

OH8.3: Data proměnné KT_K jsou normálně rozdělena.

OH9.1: Data proměnné TST jsou normálně rozdělena.

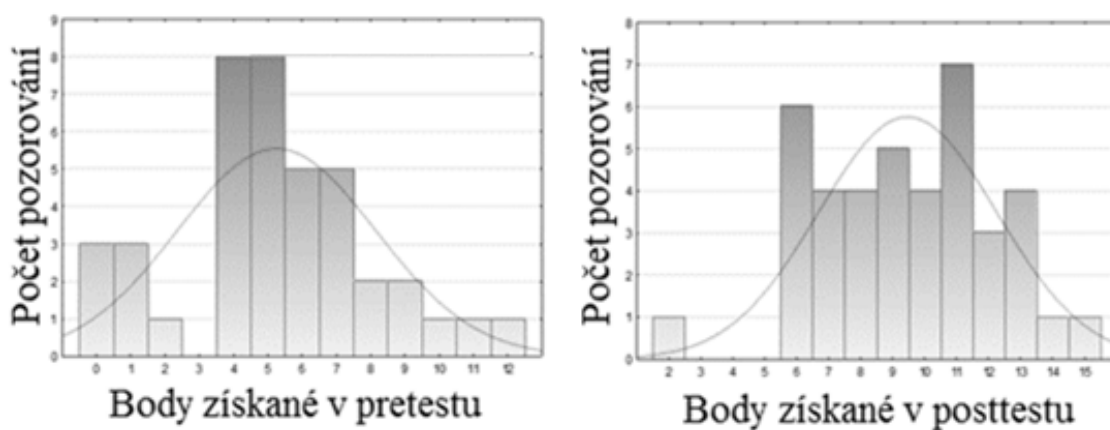
Nejprve byla graficky znázorněna rozdělení četností jednotlivých charakteristik a pomocí Shapiro-Wilkova testu byly vypočteny p hodnoty pro výše uvedené operativní hypotézy (Tabulka 8). Nulová hypotéza tvrdí, že data pocházejí ze souboru s normálním rozdělením. U všech sledovaných proměnných je p hodnota větší než zvolená hladina významnosti $\alpha = 0,05$, proto ve všech případech nelze zamítnout nulovou hypotézu, tj. data pocházejí ze souboru s normálním rozdělením. Ani jednu z operativních hypotéz OH7.1, OH7.2, OH8.1, OH8.2, OH8.3 a OH9.1 nelze zamítnout. Grafické zobrazení rozdělení dat vybraných proměnných zachycují histogramy na obrázku 27, 28, a 29.

Proměnná	Průměr	Interval průměru - 95%	Interval průměru +95%	Minimum	Maximum	Směrodatná odchylka
P_{PRE} [body]	5,23	4,30	6,15	0,00	12,00	2,88
P_{POST} [body]	9,43	8,54	10,31	2,00	15,00	2,77
KT_{netto} [body]	4,20	3,37	5,03	-1,00	12,00	2,58
KT_o [body]	2,20	1,52	2,88	-2,00	7,00	2,11
KT_k [body]	2,00	1,46	2,54	-2,00	5,00	1,69
TST [s]	806,83	750,13	863,52	497,00	1201,00	177,28

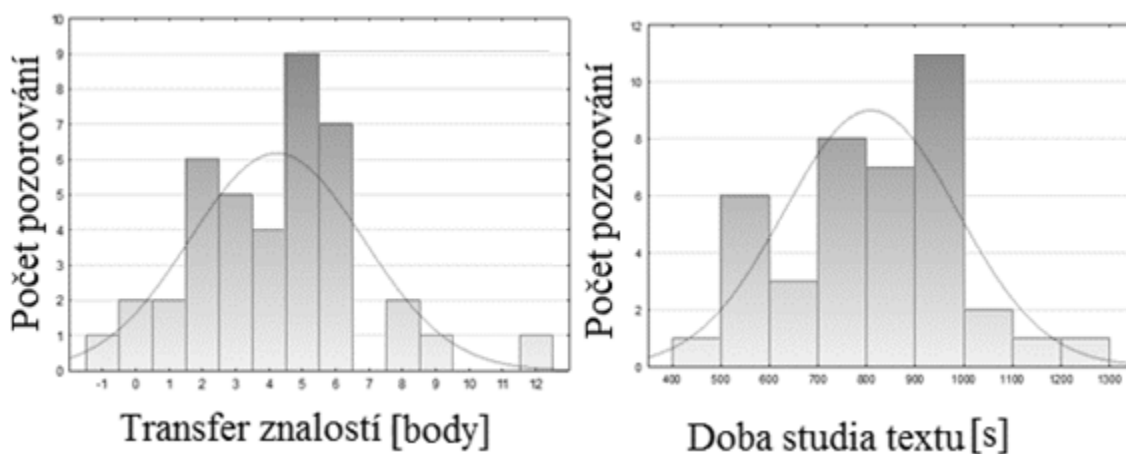
Tabulka 7 Popisné statistiky sledovaných proměnných, pilot, experiment II; zdroj: autorka

Proměnná	p hodnota	$\alpha = 0,05$; vztah k OH
P_{PRE} [body]	0,16	nezamítnuta
P_{POST} [body]	0,33	nezamítnuta
KT_{netto} [body]	0,15	nezamítnuta
KT_o [body]	0,26	nezamítnuta
KT_k [body]	0,06	nezamítnuta
TST [s]	0,17	nezamítnuta


Tabulka 8 P hodnoty Shapiro-Wilkova testu, pilot, experiment II; zdroj: autorka



Obrázek 27 Histogramy proměnné P_{PRE} (vlevo) a P_{POST} (vpravo), pilot, experiment II; zdroj: autorka



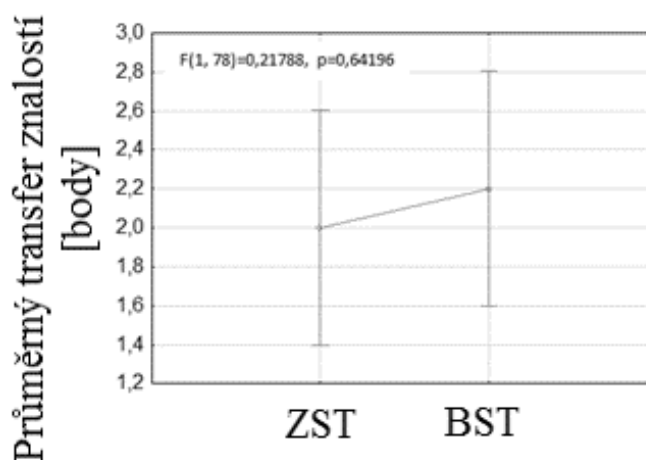
Obrázek 28 Histogramy proměnné KT_{neto} (vlevo) a TST (vpravo), pilot, experiment II; zdroj: autorka



Obrázek 29 Histogramy proměnné KT_K (vlevo) a KT_o (vpravo), pilot, experiment II; zdroj: autorka

Pomocí analýzy rozptylu bylo zjišťováno, zda typ textu má vliv na čistý transfer znalostí. OH10.1: Znalostně strukturovaný text (ZST) i běžně strukturovaný text (BST) se v průměru podílejí na shodném transferu znalostí.

P hodnota ANOVA F testu byla $p = 0,6420$, což bylo větší než zvolená hladina významnosti $\alpha = 0,0500$, proto ve všech případech nulová hypotéza nebyla zamítnuta. Grafické zobrazení ukazují box-ploty na obrázku 30.



Obrázek 30 Box-plot znázorňující vliv rozdílnosti typu textu na průměrný transfer znalostí; zdroj: autorka

Dále bylo pomocí analýzy rozptylu zjišťováno, zda téma suboblasti textu má vliv na čistý transfer znalostí.

OH11.1: Všechny suboblasti se podílejí v průměru na stejném transferu znalostí.

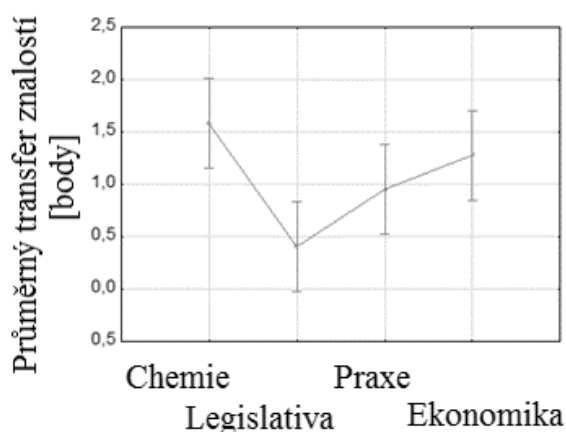
P hodnota ANOVA F testu byla $p = 0,0014$, tj. byla nižší než zvolená hladina významnosti $\alpha = 0,0500$, proto byla zamítnuta operativní hypotéza OH 11.1, tzn. existuje alespoň jedna oblast, která se svým průměrem liší od ostatních. Pro podrobnější vyhodnocení byl užit Tukeyho test.

OH11.2: Téma legislativy a ekonomie má stejný vliv na transfer znalostí.

OH11.3: Téma legislativy a chemie má stejný vliv na transfer znalostí.

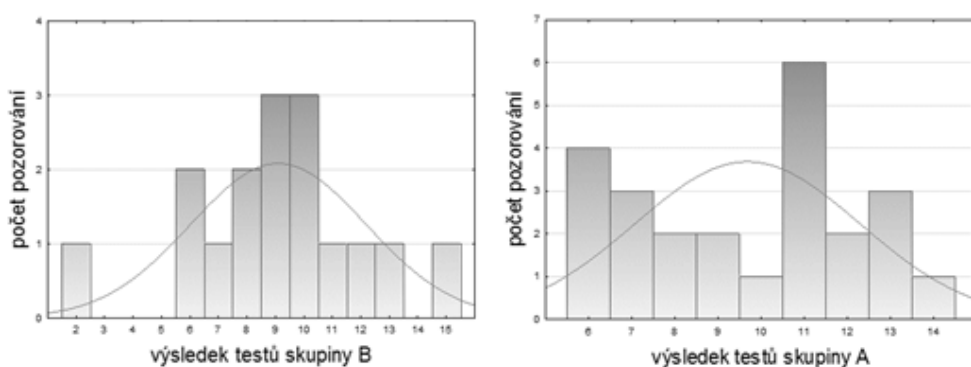
Operativní hypotézy pro Tukeyho test OH11.2 a OH11.3 byly na zvolené hladině významnosti $\alpha = 0,05$ obě zamítnuty. Bylo zjištěno, že statisticky významný rozdíl byl mezi tématy legislativa a chemie ($p = 0,000751$) a mezi tématy legislativa a ekonomika ($p = 0,022417$), což je patrné i z obrázku 31.

Bylo třeba se zaměřit právě na texty z oblasti legislativy, které v průměru přispěly nejméně k transferu znalostí. Jelikož i v odpovědích v rámci dotazníku toto téma obdrželo nejvyšší četnost z hlediska nejvyšší obtížnosti ve srovnání s ostatními tématy, byla tato oblast textových brožur upravena pro finální testování.



Obrázek 31 Box-ploty znázorňující vliv rozdílnosti tématu suboblastí problémové domény na průměrný transfer znalostí, pilot, experiment II; zdroj: autorka

Dále byla provedena didaktická analýza testů, aby bylo zjištěno, zda užívané nástroje výzkumu měří spolehlivě předané znalosti. Testování byli rozděleni do skupin A a B. 24 studentů bylo ve skupině A, 16 studentů bylo ve skupině B. Skupina A obdržela pretest a posttest, skupina B s nimi pracovala v opačném pořadí. Cílem didaktické analýzy bylo vypočítat ukazatele obtížnosti jednotlivých testových úloh, jejich citlivosti, reliability testu a percentilovou škálu výsledků posttestu pro skupinu A i B a tyto testy navzájem statisticky porovnat, k ukazatelům více v literární rešerši dle Chráska (2007).



Obrázek 32 Histogramy u výsledků posttestů u skupiny B (vlevo) a A (vpravo), pilot, experiment II; zdroj: autorka

Číslo otázky	<i>Q</i>	<i>P</i>	n_H	n_L	<i>ULI</i>	<i>a</i>	<i>b</i>	<i>c</i>
1	29,17	70,83	6,00	11,00	0,42	0,71	0,29	0,21
2	37,50	62,50	4,00	11,00	0,58	0,63	0,38	0,23
3	29,17	70,83	5,00	12,00	0,58	0,71	0,29	0,21
4	62,50	37,50	6,00	3,00	-0,25	0,38	0,63	0,23
5	20,83	79,17	9,00	10,00	0,08	0,79	0,21	0,16
6	66,67	33,33	3,00	5,00	0,17	0,33	0,67	0,22
7	66,67	33,33	2,00	6,00	0,33	0,33	0,67	0,22
8	29,17	70,83	10,00	7,00	-0,25	0,71	0,29	0,21
9	12,50	87,50	11,00	10,00	-0,08	0,88	0,13	0,11
10	70,83	29,17	1,00	6,00	0,42	0,29	0,71	0,21
11	62,50	37,50	4,00	5,00	0,08	0,38	0,63	0,23
12	29,17	70,83	6,00	11,00	0,42	0,71	0,29	0,21
13	29,17	70,83	10,00	7,00	-0,25	0,71	0,29	0,21
14	83,33	16,67	1,00	3,00	0,17	0,17	0,83	0,14
15	75,00	25,00	2,00	4,00	0,17	0,25	0,75	0,19
16	79,17	20,83	1,00	4,00	0,25	0,21	0,79	0,16
17	58,33	41,67	2,00	8,00	0,50	0,42	0,58	0,24
18	66,67	33,33	0,00	8,00	0,67	0,33	0,67	0,22
19	75,00	25,00	1,00	5,00	0,33	0,25	0,75	0,19
20	50,00	50,00	5,00	7,00	0,17	0,50	0,50	0,25

Tabulka 9 Didaktická analýza posttestu u skupiny A, pilot, experiment II; zdroj: autorka

Číslo otázky	Q	P	n_H	n_L	ULI	a	b	c
1	12,50	87,50	8,00	6,00	-0,25	0,88	0,13	0,11
2	31,25	68,75	5,00	6,00	0,13	0,69	0,31	0,21
3	43,75	56,25	4,00	5,00	0,13	0,56	0,44	0,25
4	87,50	12,50	1,00	1,00	0,00	0,13	0,88	0,11
5	43,75	56,25	5,00	4,00	-0,13	0,56	0,44	0,25
6	43,75	56,25	3,00	6,00	0,38	0,56	0,44	0,25
7	43,75	56,25	4,00	5,00	0,13	0,56	0,44	0,25
8	37,50	62,50	6,00	4,00	-0,25	0,63	0,38	0,23
9	93,75	6,25	0,00	1,00	0,13	0,06	0,94	0,06
10	56,25	43,75	3,00	4,00	0,13	0,44	0,56	0,25
11	31,25	68,75	4,00	7,00	0,38	0,69	0,31	0,21
12	62,50	37,50	4,00	2,00	-0,25	0,38	0,63	0,23
13	56,25	43,75	2,00	5,00	0,38	0,44	0,56	0,25
14	50,00	50,00	3,00	5,00	0,25	0,50	0,50	0,25
15	31,25	68,75	6,00	5,00	-0,13	0,69	0,31	0,21
16	68,75	31,25	3,00	2,00	-0,13	0,31	0,69	0,21
17	75,00	25,00	1,00	3,00	0,25	0,25	0,75	0,19
18	75,00	25,00	0,00	4,00	0,50	0,25	0,75	0,19
19	87,50	12,50	1,00	1,00	0,00	0,13	0,88	0,11
20	62,50	37,50	1,00	5,00	0,50	0,38	0,63	0,23

Tabulka 10 Didaktická analýza posttestu u skupiny B, pilot, experiment II; zdroj: autorka

Obrázek 32 znázorňuje histogramy výsledů posttestu u jednotlivých skupin A a B.

Byly stanoveny operativní hypotézy.

OH12.1: Výsledky posttestu u skupiny A jsou normálně rozděleny.

OH12.2: Výsledky posttestu u skupiny B jsou normálně rozděleny.

Jelikož p hodnota byla větší než zvolená hladina významnosti ($\alpha = 0,0500$), tak u Shapiro-Wilkova testu u skupiny B data pocházela ze skupiny s normálním rozdělením ($p = 0,8919$), tj. OH12.2 nelze zamítnout. U skupiny A je p hodnota nižší než zvolená hladina významnosti ($p = 0,0462$), tj. při zvolené hladině významnosti $\alpha = 0,0500$ data

nepocházela ze souboru s normálním rozdělením, avšak při snížení hladiny významnosti na $\alpha = 0,01$, nulovou hypotézu OH12.1 již zamítnout nelze.

Z tabulky č. 9 je patrné, že ve skupině A u 10 otázek více než 50 % testovaných zodpovědělo nesprávně. U čtyř otázek byl koeficient citlivosti záporný, což bylo potřeba pro další výzkum napravit a dané otázky přeformulovat. Z tabulky č. 10 je patrné, že ve skupině B u 12 otázek více než 50 % testovaných zodpovědělo nesprávně. U šesti otázek byl koeficient citlivosti záporný, u jedné byl roven nule, což bylo potřeba pro další výzkum napravit a dané otázky přeformulovat. Záporný koeficient *ULI* byl současně v obou skupinách pouze u otázky č. 8, která se týkala měrných investičních nákladů na výstavbu bioplynové stanice.

Dále byly vypočítány koeficienty reliability testů. Skupiny A měla koeficient $r_{kr} = 0,97228$ a skupina B měla $r_{kr} = 0,5988$. Tento významný rozdíl byl způsoben rozdílnými hodnotami sumy ukazatelů *c* (poslední sloupce v tabulce 9 a tabulce 10) a směrodatnou odchylkou pro výsledky testování. U skupiny A byla reliabilita dostatečná, u skupiny B by bylo vhodné, aby se koeficient reliability přiblížil k hranici 0,8, jak uvádí Chráska (2007).

Pro jednotlivé ukazatele byly spočteny i základní popisné charakteristiky posttestů, viz tabulka 11, u každé proměnné bylo v závorce uvedeno, jaké skupiny se ukazatel týká, tj. A či B. Z tabulky 11 lze vyčíst například, že levá strana konfidenčního intervalu pro průměr u koeficientu citlivosti dosahovala záporných hodnot, z čehož vyplývá, že by otázky měly být přeformulovány.

Dále byly jednotlivé průměrné hodnoty vybraných didaktických ukazatelů posttestů u skupiny A a skupiny B testovány pomocí T testu, resp. F testu, tj. zda jsou jejich průměrné hodnoty, resp. rozptyly, statisticky odlišné či nikoliv.

OH12.3: Rozptyly u proměnných $Q(B)$ a $Q(A)$ jsou shodné.

OH12.4: Průměry u proměnných $Q(B)$ a $Q(A)$ jsou shodné.

OH12.5: Rozptyly u proměnných $P(B)$ a $P(A)$ jsou shodné.

OH12.6: Průměry u proměnných $P(B)$ a $P(A)$ jsou shodné.

OH12.7: Rozptyly u proměnných $n_H(B)$ a $n_H(A)$ jsou shodné.

OH12.8: Průměry u proměnných $n_H(B)$ a $n_H(A)$ jsou shodné.

OH12.9: Rozptyly u proměnných $n_L(B)$ a $n_L(A)$ jsou shodné.

OH12.10: Průměry u proměnných $n_L(B)$ a $n_L(A)$ jsou shodné.

OH12.11: Rozptyly u proměnných $ULI(B)$ a $ULI(A)$ jsou shodné.

OH12.12: Průměry u proměnných $ULI(B)$ a $ULI(A)$ jsou shodné.

OH12.13: Rozptyly u proměnných $a(B)$ a $a(A)$ jsou shodné.

OH12.14: Průměry u proměnných $a(B)$ a $a(A)$ jsou shodné.

OH12.15: Rozptyly u proměnných $b(B)$ a $b(A)$ jsou shodné.

OH12.16: Průměry u proměnných $b(B)$ a $b(A)$ jsou shodné.

OH12.17: Rozptyly u proměnných $c(B)$ a $c(A)$ jsou shodné.

OH12.18: Průměry u proměnných $c(B)$ a $c(A)$ jsou shodné.

Jednotlivé výsledky testování včetně p hodnot F testů a T testů jsou zachyceny v tabulce 12. Jednotlivé ukazatele se statisticky od sebe významně neliší s výjimkou ukazatele n_L (počet osob z lepší skupiny, které danou úlohu zodpověděly správně), zde je p hodnota T testu ($p \approx 0$) nižší než zvolená hladina významnosti $\alpha = 0,05$. Výše uvedené operativní


hypotézy OH12.3 až OH12.18. nelze na zvolené hladině významnosti zamítnout, mimo OH12.10.

Z hlediska standardizace didaktických textů byly sestaveny percentilové škály a rovněž tyto škály byly testovány z hlediska jejich statistické odlišnosti.

OH12.19: Rozptyly u proměnných *percentilové pořadí (B)* a *percentilové pořadí (A)* jsou shodné.

OH12.20: Průměry u proměnných *percentilové pořadí (B)* a *percentilové pořadí (A)* jsou shodné.

P hodnota T testu byla vyšší než zvolená hladina významnosti ($\alpha = 0,05$, $p = 0,8286$), proto nelze zamítnout nulovou hypotézu OH12.20 resp. OH12.19 o shodě průměrů resp. rozptylů, průměrné percentilové pořadí se tedy statisticky významně neliší u skupiny A a B. Obrázek 33 znázorňuje percentilové pořadí jednotlivých skupin.



Obrázek 33 Grafické znázornění percentilového pořadí u skupiny A a B, pilot experiment II; zdroj: autorka

Proměnná	Rozsah otázek	Průměr	Interval průměru - 95 %	Interval průměru + 95 %	Minimum	Maximum	Směrodatná odchylka
Q (B)	20,000	54,688	44,472	64,903	12,500	93,750	21,828
P (B)	20,000	45,313	35,097	55,528	6,250	87,500	21,828
n_H (B)	20,000	3,200	2,186	4,214	0,000	8,000	2,167
n_L (B)	20,000	4,050	3,198	4,902	1,000	7,000	1,820
ULI (B)	20,000	0,106	-0,008	0,221	-0,250	0,500	0,244
a (B)	20,000	0,453	0,351	0,555	0,063	0,875	0,218
b (B)	20,000	0,547	0,445	0,649	0,125	0,938	0,218
c (B)	20,000	0,203	0,175	0,230	0,059	0,250	0,058
Q (A)	20,000	51,667	41,263	62,070	12,500	83,333	22,230
P (A)	20,000	48,333	37,930	58,737	16,667	87,500	22,230
n_H (A)	20,000	4,450	2,854	6,046	0,000	11,000	3,410
n_L (A)	20,000	7,150	5,807	8,493	3,000	12,000	2,870
ULI (A)	20,000	0,225	0,094	0,356	-0,250	0,667	0,280
a (A)	20,000	0,483	0,379	0,587	0,167	0,875	0,222
b (A)	20,000	0,517	0,413	0,621	0,125	0,833	0,222
c (A)	20,000	0,203	0,186	0,219	0,109	0,250	0,036

Tabulka 11 Popisné statistiky didaktických charakteristik testů, pilot, experiment II; zdroj: autorka

Proměnná	Průměr 1	Průměr 2	T hodnota	p hodnota (T test)	Směrodatná odchylka 1	Směrodatná odchylka 2	F hodnota	p hodnota (F test)
Q (B) vs. Q (A)	54,688	51,667	0,434	0,667	21,828	22,230	1,037	0,937
P (B) vs. P (A)	45,313	48,333	-0,434	0,667	21,828	22,230	1,037	0,937
n_H (B) vs. n_H (A)	3,200	4,450	-1,384	0,175	2,167	3,410	2,477	0,055
n_L (B) vs. n_L (A)	4,050	7,150	-4,079	0,000	1,820	2,870	2,487	0,054
ULI (B) vs. ULI (A)	0,106	0,225	-1,430	0,161	0,244	0,280	1,312	0,560
a (B) vs. a (A)	0,453	0,483	-0,434	0,667	0,218	0,222	1,037	0,937
b (B) vs. b (A)	0,547	0,517	0,434	0,667	0,218	0,222	1,037	0,937
c (B) vs. c (A)	0,203	0,203	-0,016	0,988	0,058	0,036	2,664	0,039

Tabulka 12 T test a F test pro vybrané didaktické charakteristiky, pilot, experiment II; zdroj: autorka

Uplatnění analýzy vlastností testových úloh a didaktických testů jako celku slouží běžně jako objektivní nástroj systematického zjišťování výsledků výuky, tak jak je vidět u mnoha autorů (Skalková, 2007; Vaculová, 2008; Slavík et al., 2012), na druhé straně užívání pouze

statistiky nemusí být vždy relevantní (Půlpán, 2012). Tento typ analýzy lze využít i v jiné sféře, a to v oblasti předvýzkumu pedagogického experimentu, kdy má charakter testovací procedury. Pomocí zmíněné analýzy lze zlepšit nástroje samotného výzkumu.

Z hlediska nových moderních metod testování a vyhodnocování, jak uvádí Dvořák (2011), lze též pro získání více informací z testů využít i robustní metody tvorby a vyhodnocování testů, např. metoda IRT (Item Response Theory), MDT (Measurement Decision Theory) či Znalostní prostory (Knowledge Spaces). Poslední zmíněné metody se ukazují vhodné pro testování nové generace, tj. pomocí tzv. znalostních prostorů lze modelovat znalosti a konstruovat testy, které poskytnou obsáhlou informaci o vlastnostech testovaného. Navíc znalostní prostory mohou poskytnout detailní mapu učebního pokroku (vývojové kontinuum, progression map), jejich použití lze tedy využít nejen na testování, v pedagogické praxi, ale právě k měření čistého transferu znalostí, který je očištěn o vliv původních, předchozích znalostí v rámci experimentu.

Z předvýzkumu vyplynuly některé poznatky, pomocí nichž lze zlepšit samotný výzkum:

1. Čas potřebný ke studiu textů je dostatečný, jelikož průměrný čas je 806,83 sekund (13,43 minut), testovaní mají v rámci experimentu k dispozici 30 minut, proto je možné tento čas snížit na 25 minut a přesto bude ponechána dostatečná rezerva. Zbývající časy na pretest (15 minut) a posttest (15 minut) jsou rovněž dostačující, jak potvrdili účastníci v diskusi či v závěrečném dotazníku.

2. Důležité bylo zaměřit se na texty z oblasti legislativy, jelikož u nich docházelo ke statisticky významně nižším transferům znalostí než u oblastí ekonomiky či chemie. Zároveň v dotaznících testování nejčastěji uváděli tuto oblast jako nejtěžší. Pro samotný experiment bylo třeba u brožur zkontrolovat téma legislativy i z hlediska jejich čitelnosti,

sémantické a syntaktické obtížnosti dle Tannenbergové (2009) a tyto ukazatele statisticky porovnat se stejnými ukazateli i z ostatních témat (chemie, ekonomika, praxe).

3. Bylo nutné se zaměřit se na otázky v testech, jejichž koeficienty citlivosti *ULI* byly záporné či velmi blízké nule a přeformulovat je, popřípadě změnit možné odpovědi v nabídce.


4. Po přeformulování odpovědí bylo třeba znovu otestovat u obou testů parametr n_L , zda se již statisticky významně neliší u obou skupin.

5. Dále bylo potřeba přepočítat koeficienty reliability a zaměřit se, aby se koeficient u skupiny B přiblížil hranici 0,8.

6. Statistická analýza dat pocházející z nereprezentativního vzorku ukázala, že transfer znalostí není ovlivněn typem textu, tj. průměrný transfer znalostí pomocí vzdělávacích textů je shodný pro znalostně i běžně trukturované texty (nelze usuzovat obecnější závěry, ty jsou předmětem vlastního výzkumu a práce s reprezentativním vzorkem), avšak do budoucna je vhodné zaměřit se i na jiné exaktně měřitelné přínosy znalostně strukturovaných textů ve vzdělávacím procesu.

V úvodu 3. kroku experimentu II bylo vyřčeno sedm pracovních hypotéz, přičemž 5 z nich nebylo zamítnuto (**PH7.0**, **PH8.0**, **PH9.0**, **PH10.0**, **PH13.0**). U **PH11.0** dvě dvojice tematických suboblastí (legislativa a chemie, legislativa a ekonomie) se v průměrném čistém transferu znalostí od sebe statisticky významně lišily. U **PH6.0** se průměrné hodnoty lišily u charakteristiky n_L .

4. krok: Výběr respondentů, realizace experimentu



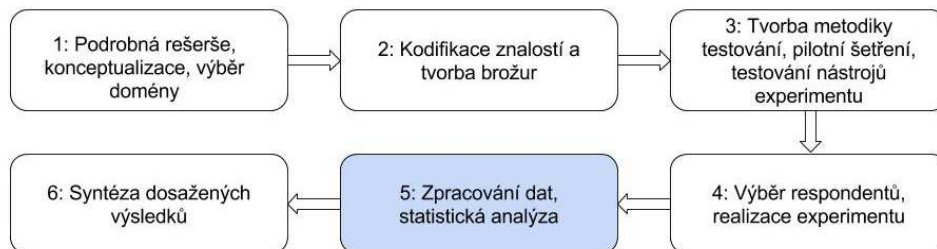
Obrázek 34 Experiment II: 4. krok – Výběr respondentů, realizace experimentu; zdroj: autorka

Výběr respondentů a realizace experimentu, dle upravené metodiky z předchozího kroku experimentu, proběhla ve spolupráci se společností Úhlava o.p.s., sídlící v Klatovech. Česká zemědělská univerzita v Praze, především Provozně ekonomická fakulta je hlavním partnerem Úhlavy, o.p.s. pro vzdělávací aktivity. Ve spolupráci s univerzitou navazuje Úhlava, o.p.s. na tradice zemědělského školství a školství zaměřeného na venkov, které má v Klatovech velkou tradici.

Experimentu se účastnilo 63 respondentů, tj. studentů ze středních zemědělských škol, zemědělců a agronomů, kteří zároveň podali zpětnou vazbu o tom, jak na ně jednotlivé textové fragmenty působily a jak respondenti texty vnímali.

Testování proběhlo v několika dnech dle uvedené upravené metodiky (dle výsledků z kroku 3 experimentu II). Testování se účastnil i administrátor, který dohlížel na průběh a dodržení shodných podmínek celého testování.

5. krok: Zpracování dat, statistická analýza



Obrázek 35 Experiment II: 5. krok – Zpracování dat, statistická analýza; zdroj: autorka

Pro samotný experiment byly stanoveny následující pracovní hypotézy:

PH14.0: Textové brožury jsou statisticky významným nástrojem pro transfer znalostí (body získané v posttestu jsou statisticky významně odlišné než body v pretestu).

PH15.0: Na čistém transferu znalostí se podílejí znalostně strukturované texty stejnou měrou jako běžně strukturované texty.

PH16.0: Typ textu nemá vliv na čas potřebný ke studiu textů.

PH17.0: Věk respondenta nemá vliv na čas potřebný ke studiu textů.

PH18.0: Všechny tematické oblasti jsou stejně obtížné.

PH19.0: Více než polovina respondentů pozná, který text se svou strukturou liší od ostatních.

Úspěšnost transferu znalostí

Nejprve byly spočteny základní popisné statistiky uvedené v tabulce 13. Maximální množství bodů obdrženyých u testovaných v pretestu bylo 9, v posttestu 20, průměrný čistý transfer byl 10,71 bodů, přičemž v průměru se na něm podílel ze 42,57 % transfer pomocí běžně strukturovaných vzdělávací textů, zbylých 57,43 % tvořil transfer pomocí znalostně strukturovaných textů. Dále byla graficky znázorněna rozdělení četností jednotlivých charakteristik a pomocí Shapiro-Wilkova testu byla testována normalita rozdělení. Pro normalitu rozdělení u sledovaných charakteristik byly stanoveny následující operativní hypotézy.

OH14.1: Data proměnné P_{PRE} jsou normálně rozdělena.

OH14.2: Data proměnné P_{POST} jsou normálně rozdělena.

OH14.3: Data proměnné KT_{netto} jsou normálně rozdělena.

OH14.4: Data proměnné KT_O jsou normálně rozdělena.

OH14.5: Data proměnné KT_K jsou normálně rozdělena.


Nulová hypotéza tvrdí, že data pocházejí ze souboru s normálním rozdělením. U jedné sledované proměnné (KT_{netto}) je p hodnota větší než zvolená hladina významnosti $\alpha = 0,05$, proto nelze zamítnout nulovou hypotézu (OH14.3), tj. data pocházejí ze souboru s normálním rozdělením. U zbylých čtyř sledovaných proměnných ($P_{PRE}, P_{POST}, KT_O, KT_K$) je p hodnota menší než zvolená hladina významnosti $\alpha = 0,05$, proto je zamítnuta nulová hypotéza (OH14.1, OH14.2, OH14.4., OH14.5), tj. data nepocházejí ze souboru s normálním rozdělením. Vypočtené p hodnoty Shapiro-Wilkova testu jsou v tabulce 14, grafická zobrazení rozdělení dat vybraných proměnných zobrazují histogramy na obrázcích 36, 37, 38, 39 a 40.

Proměnná	Průměr	Interval průměru - 95%	Interval průměru +95%	Minimum	Maximum	Směrodatná odchylka
P_{PRE} [body]	3,24	2,66	3,82	0,00	9,00	2,30
P_{POST} [body]	13,95	12,97	14,94	5,00	20,00	3,90
KT_{netto} [body]	10,71	9,60	11,83	1,00	19,00	4,43
KT_O [body]	4,56	3,94	5,17	0,00	10,00	2,43
KT_K [body]	6,16	5,24	7,087	0,00	16,00	3,66


Tabulka 13 Popisné statistiky sledovaných proměnných experimentu II; zdroj: autorka

Proměnná	p hodnota	$\alpha = 0,05$; vztah k OH
P_{PRE} [body]	0,0036	zamítnuta
P_{POST} [body]	0,0017	zamítnuta
KT_{netto} [body]	0,1996	nezamítnuta
KT_O [body]	0,0265	zamítnuta
KT_K [body]	0,0430	zamítnuta


Tabulka 14 P hodnoty Shapiro-Wilkova testu, proměnné experimentu II; zdroj: autorka




Obrázek 36 Histogram proměnné P_{PRE} , experiment II; zdroj: autorka




Obrázek 37 Histogram proměnné P_{POST} , experiment II; zdroj: autorka



Obrázek 38 Histogram proměnné KT_{netto} , experiment II; zdroj: autorka



Obrázek 39 Histogram proměnné KT_o , experiment II; zdroj: autorka



Obrázek 40 Histogram proměnné KT_K , experiment II; zdroj: autorka

Dále byly stanoveny další operativní hypotézy.

OH14.6: Rozptyly P_{POST} a P_{PRE} jsou shodné.

OH14.7: Průměry P_{POST} a P_{PRE} jsou shodné.

Byly testovány rozdíly mezi proměnnými P_{PRE} a P_{POST} , a to pomocí T testu, resp. F testu. Bylo zjišťováno, zda jsou jejich průměrné hodnoty, resp. rozptyly, statisticky odlišné či nikoliv. Průměry i rozptyly pro proměnné P_{PRE} a P_{POST} se od sebe statisticky významně liší, p hodnota T testu ($p \approx 0$) i p hodnota F testu ($p = 0,000051$) je nižší než zvolená hladina významnosti $\alpha = 0,05$, proto je v obou případech zamítnuta nulová hypotéza (OH14.6 i OH14.7). Z toho vyplývá, že průměrný bodový zisk z pretestu je statisticky významně odlišný od průměrného bodového zisku v posttestu. Z tohoto zjištění vyplývá, že prostřednictvím textových brožur došlo ke statisticky významnému transferu znalostí.

Čistý transfer znalostí dle vzorce 15 je spočten jako body získané v posttestu snížené o vliv počáteční úrovně znalosti (body získané v pretestu). Na čistém transferu znalostí se podílel transfer prostřednictvím znalostně strukturovaných textů (v průměru 6,16 body) a transfer prostřednictvím běžně strukturovaných textů (v průměru 4,56 body).

Dále bylo třeba zjistit, zda se na čistém transferu znalostí podílely obě textové struktury shodně.

OH15.1: Rozptyly KT_O a KT_K jsou shodné.


OH15.2: Rozptyly KT_O a KT_K jsou shodné.

Z toho důvodu byly testovány rozdíly mezi proměnnými KT_O a KT_K , a to pomocí T testu, resp. F testu, tj. zda jsou jejich průměrné hodnoty, resp. rozptyly, statisticky odlišné či nikoliv. Průměry i rozptyly pro proměnné KT_O a KT_K se statisticky od sebe významně liší, p hodnota T testu ($p = 0,004452$) a p hodnota F testu ($p = 0,001503$) nižší než zvolená hladina významnosti $\alpha = 0,05$, proto je v obou případech zamítnuta nulová hypotéza (OH15.1 i OH15.2). Z toho vyplývá, že průměrný čistý transfer znalostí prostřednictvím běžně strukturovaného textu (4,56 bodů) je statisticky významně odlišný od průměrného transferu znalostí prostřednictvím znalostně strukturovaného textu (6,16 bodů).

Vliv typu textu na čas potřebný k jejich studiu

Poté bylo sledováno, jestli existuje vliv typu textu na průměrnou délku času potřebného ke studiu brožury, tj. textu sloužícího jako nástroj pro transfer znalostí. Průměrná hodnota u studia textu byla 27,44 minut, minimální délka času byla 24 minut, maximální délka času byla 30 minut. Na obrázku 41 jsou zobrazeny 95% intervaly spolehlivosti pro proměnnou čas vyjádřenou v minutách, pro jednotlivé typy brožur s kódy 0101, 0011, 1100 a 1010 (význam kódu viz krok 2 experimentu II). Dále byl pomocí jednofaktorové ANOVA testován vliv typu textu na čas potřebný k jejich studiu.

OH16.1: Všechny průměrné hodnoty času jsou pro jednotlivé typy brožur shodné. P hodnota pro F test je $p = 0,87753$, z čehož vyplývá, že OH16.1 na hladině významnosti ($\alpha = 0,05$) nelze zamítnout. Typ brožury, tj. pořadí oblastí zpracovaných znalostně strukturovanou formou a běžně strukturovanou formou textu nemá vliv na průměrnou délku studia textu.




Obrázek 41 Vliv typu textu na průměrnou délku studia brožury; zdroj: autorka

Vliv věku na čas potřebný ke studiu textů

Dále bylo sledováno, jestli existuje vliv věku respondenta na průměrnou délku času potřebného ke studiu brožury, tj. textu sloužící jako nástroj pro transfer znalostí. Průměrná hodnota pro věk respondentů byla 36,127 let. Minimální hodnota věku byla 16 let, maximální hodnota 65 let. Na obrázku 42 jsou zobrazeny 95% intervaly spolehlivosti pro proměnnou věk vyjádřený v letech pro jednotlivé věkové kategorie. Dále byl pomocí jednofaktorové ANOVA testován vliv věku na čas potřebný ke studiu textů.

OH17.1: Všechny průměrné hodnoty času jsou pro jednotlivé věkové kategorie shodné. P hodnota pro F test je $p = 0,28762$, z čehož vyplývá, že OH 17.1 na hladině významnosti ($\alpha = 0,05$) nelze zamítnout. Typ věkové kategorie nemá vliv na průměrnou délku studia textu.



Obrázek 42 Vliv věkové kategorie na průměrnou délku studia brožury; zdroj: autorka

Tematická obtížnost problémových domén

Dále bylo sledováno, jak moc obtížné po stránce obsahové byly textové fragmenty z jednotlivých 4 suboblastí, tj. chemie (A), praxe (B), legislativy (C) a ekonomiky (D). Respondenti měli tyto oblasti seřadit od 1 (velice snadná tematika) do 4 (velice obtížná tematika). Jako velice snadnou tematiku volili respondenti problematiku legislativy, tj. oblast C. Jako snadnou tematiku volili respondenti problematiku chemie, tj. oblast A. Jako obtížnou tematiku volili respondenti problematiku ekonomiky, tj. oblast D. Jako velice obtížnou tematiku volili respondenti problematiku praxe, tj. oblast B.

Téma textu	Obtížnost tématu			
	1	2	3	4
A	18	30	8	7
B	12	8	13	29
C	29	17	12	6
D	4	8	30	21

Tabulka 15 Absolutní četnosti obtížnosti textu v závislosti na tématu; zdroj: autorka

Vnímání odlišnosti struktury textů

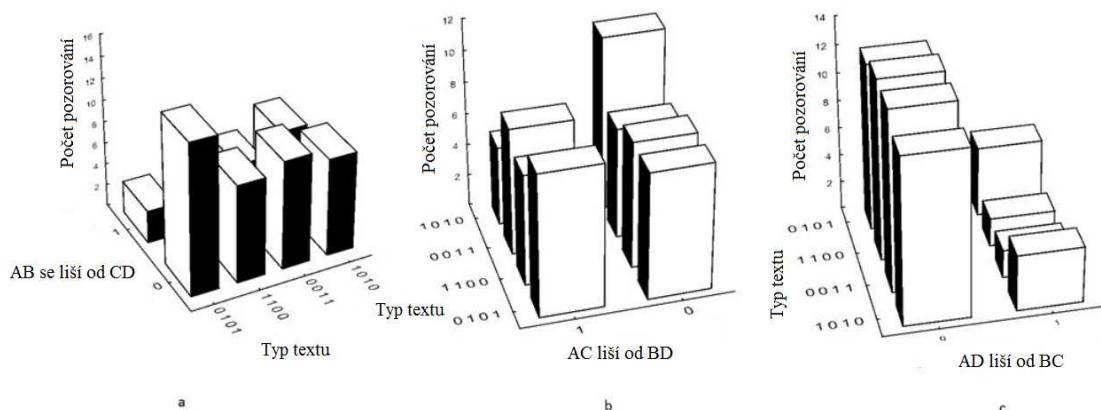
Respondenti měli možnost se vyjádřit, jak vnímají odlišnost povahy textu (jeho struktury, nikoli ve smyslu tematické oblasti). Tzn. měli posoudit, zda se v brožuře, kterou dostali ke studiu, liší z hlediska struktury textu části A, B od C, D, nebo A, C od B, D nebo A, D

od B, C. Odpovědi, které respondenti zaznamenali v závislosti na typu textu, se kterým pracovali, jsou graficky znázorněny pomocí dvourozměrných histogramů (obrázek 42). Na ose x je u zmíněných obrázků typ textu (1010, 0011, 1100, 0101), na ose y je znázorněno, jestli respondenti vnímali odlišnost mezi vybranými dvojicemi (1) nebo nevnímali odlišnost (0), na svislé ose je znázorněn počet pozorování.

Z obrázku 43a) vyplývá, že odlišnost mezi strukturou textů v A, B a C, D vnímalo 11 respondentů, kteří pracovali s texty ve variantách 0011 a 1100, kde odlišnost byla i ve skutečnosti. Ta byla dána typem zpracování, tj. znalostně strukturovanou a běžně strukturovanou formou textu. Odlišnost vnímalo i 10 respondentů, kteří pracovali se zbývajícím typem brožur, ale tyto texty neměly ve skutečnosti odlišnou strukturu, která by byla záměrně zapracovaná do fragmentů při tvorbě textu.

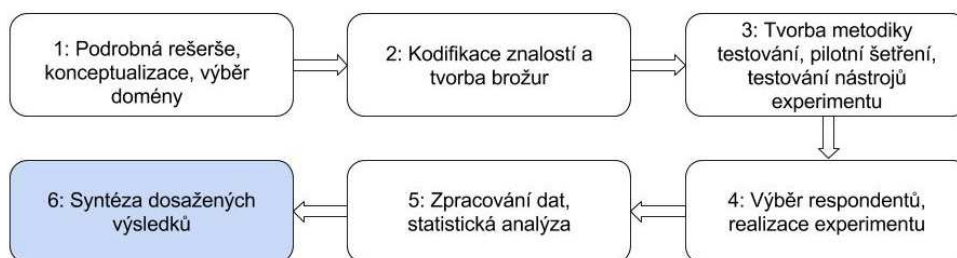
Z obrázku 43b) vyplývá, že odlišnost mezi strukturou textů v A, C a B, D vnímalo 9 lidí, kteří pracovali s texty ve variantách 1010 a 0101, kde odlišnost byla i ve skutečnosti, tj. byla dána typem zpracování, tj. znalostně strukturovanou a běžně strukturovanou formou textu. Odlišnost vnímali i 4 respondenti, kteří pracovali se zbývajícím typem brožur, ale tyto texty neměly ve skutečnosti odlišnou strukturu, která by byla záměrně zapracovaná do fragmentů při tvorbě textu.

Z obrázku 43c) vyplývá, že odlišnost mezi strukturou textů v A, D a B, C vnímalo celkem 13 lidí, ve skutečnosti jim však nebyla předložena žádná brožura, která by vykazovala odlišnost, jež by byla záměrně aplikovaná do fragmentů při tvorbě textu.



Obrázek 43 Histogramy odlišnosti textů v závislosti na variantě brožury: a) A, B se liší od C, D v závislosti na variantě textu; b) A, C se liší od B, D v závislosti na variantě textu; c) A, D se liší od B, C v závislosti na variantě textu; zdroj: autorka

6. krok: Syntéza dosažených výsledků



Obrázek 44 Experiment II: 6. krok - Syntéza dosažených výsledků; zdroj: autorka

Vyhodnocení výsledků experimentu je založeno na statistické analýze čistého transferu znalostí a zpětné vazby od účastníků experimentu, čímž jsou, kromě měření úspěšnosti čistého transferu znalostí a času potřebného ke studiu textů, objektivizovány i subjektivní názory účastníků experimentu II na vzdělávací texty, které byly nástrojem transferu explicitních znalostí.

V rámci syntézy dosažených výsledků jsou zamítnuty 4 pracovní hypotézy (PH16.0, PH17.0, PH18.0, PH19.0) a nezamítnuty dvě pracovní hypotézy (PH14.0 a PH15.0), tzn. že na zvolené hladině významnosti alfa ($\alpha = 0,05$):

Neexistuje statisticky významný vliv typu textu na čas potřebný ke studiu textů.

Není prokázán statisticky významný vliv věku respondenta na čas potřebný ke studiu textů.

Není prokázáno, že respondenti vnímají konkrétní oblast v rámci dané problémové domény jako nejméně obtížnou.

Nelze prokázat, že více než polovina respondentů pozná, který text se svou strukturou liší od ostatních.

Textové brožury jsou statisticky významným nástrojem pro transfer znalostí.

Na čistém transferu znalostí se statisticky významně podílejí větší měrou znalostně strukturované texty než běžně strukturované texty.

4.3.4 Závěr kapitoly 4.3

Kapitola se zabývala experimentem zaměřeným na efektivnost transferu znalostí prostřednictvím běžně strukturovaného a znalostně strukturovaného textu. V první části kapitoly bylo popsáno schéma testovací procedury. Design experimentu se skládal z šesti na sebe navazujících kroků: 1. podrobná rešerše, konceptualizace a výběr problémové domény; 2. kodifikace znalostí a tvorba brožur; 3. návrh metodiky testování, pilotní šetření, testování nástrojů experimentu; 4. výběr respondentů, realizace experimentu; 5. zpracování dat a statistická analýza; 6 syntéza dosažených výsledků. Experiment měl charakter testovací procedury, byl realizován na 63 respondentech ve spolupráci se společností Úhlava o.p.s. Respondenti byli studenti ze středních zemědělských škol, zemědělci a agronomové. Všem testovaným byly předloženy pretesty, textové brožury, posttesty a dotazníky. Pretesty sloužily k podchycení počáteční úrovně znalostí, textové brožury se skládaly ze čtyř tematických suboblastí, přičemž vždy dvě byly zpracovány znalostně strukturovanou formou a zbylé dvě běžně strukturovanou formou. Textové brožury byly nástrojem transferu znalostí. Posttest byl nástrojem měření transferu znalostí. Čistý transfer znalostí byl rozdílem transferu znalostí očištěného o vliv počáteční úrovně znalostí zjištěné pretestem. Testování vyplnili na závěr experimentu dotazník, kde se subjektivně vyjádřili k textovým brožurám, tj. jejich obtížnosti a struktuře.

Z experimentu vzešly následující výsledky: 1. Nelze prokázat statisticky významný vliv typu textu na čas potřebný ke studiu textů. 2. Nelze prokázat statisticky významný vliv věku respondenta na čas potřebný ke studiu textů. 3. Nelze prokázat, že respondenti vnímají konkrétní oblast v rámci dané problémové domény jako nejméně obtížnou. 4. Nelze

prokázat, že více než polovina respondentů pozná, který text se svou strukturou liší od ostatních. 5. Textové brožury jsou statisticky významným nástrojem pro transfer znalostí. 6. Na čistém transferu znalostí se statisticky významně podílejí větší měrou znalostně strukturované texty než běžně strukturované texty.

4.4 Text a biofeedback

4.4.1 Úvod kapitoly 4.4

Kapitola 4.4 navazuje na dvě předešlé kapitoly a představuje alternativy pro další výzkum zaměřený na znalostně strukturované texty. Prezentuje možnosti experimentu zaměřeného na účinnost textu z pohledu objektivního biologického lidského vnímání, tzv. biofeedback. Neurotechnologie představují relativně novou a progresivní třídu přístupů, jež přispívají k objektivním měřením nejen ve vzdělávání. Tato kapitola vychází ze dvou hlavních neurotechnologických diagnostických metod: elektroencefalografie (EEG) a funkční magnetické rezonance (fMRI), které se často používají v rámci pedagogických výzkumů k porovnání korové aktivity mozku při práci se vzdělávacími texty. V první části kapitoly je představen návrh metodiky pro výběr vhodné zobrazovací techniky a následně je prezentován možný design experimentu v rámci fMRI studie, která se soustřeďuje na zkoumání rozdílů mezi běžně strukturovanými a znalostně strukturovanými texty při jejich zpracování lidským mozkem.

Kapitola 4.4 vznikla na základě projektu s názvem Stanovení neuropsychologických charakteristik učení pro různé typy vzdělávacích textů prostřednictvím neurotechnologií (poskytovatel IGA PEF, trvání od 2015 do 2016, registrační číslo projektu 20151047). Byl realizován experiment dle navržené metodiky a získány první naměřené výsledky. Interpretace a další reanalýzy výsledků či případné rozšíření experimentu již byly nad rámec výše zmíněného projektu.

První výsledky otevírají nové otázky a příležitosti pro následný budoucí výzkum, proto se na ně zaměřuje poslední krok experimentu III.

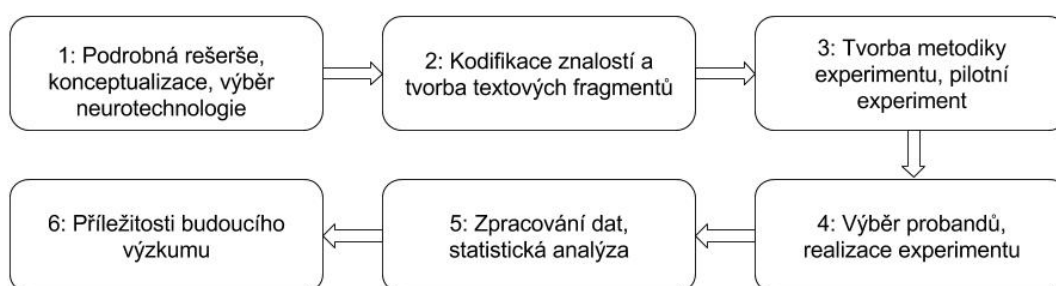
Kapitoly 4.4.2 - 4.4.4 vychází zejména z již publikovaných konferenčních příspěvků. Návrh výběru vhodné neurotechnologie byl prezentován na konferenci ERIE 2015 (Horáková, Houška a Luhanová, 2015), design experimentu částečně vycházel z výsledků prezentovaných Horákovou a Houškou (2016), finální návrh designu experimentu včetně naměřených výsledků byl prezentován na konferenci DIVAI 2016 (Horáková, Houška a Luhanová, 2016).

4.4.2 Experiment III

Cílem experimentu bylo odhalit rozdíly v aktivitách lidského mozku při čtení textů (běžně strukturovaných a znalostně strukturovaných) a zpětného vybavování dat, informací a znalostí, které byly v textech prezentovány. Byla formulována výzkumná hypotéza:

VH4: Neexistují žádné rozdíly při aktivaci korové oblasti mozku při práci se znalostně a běžně strukturovanými texty.

Schéma experimentu III zobrazuje obrázek 45.



Obrázek 45 Schéma experimentu III - oblasti; zdroj: autorka

Z potřeby kvalifikovaně měřit a podchytit další odlišnosti a dotvořit tak komplexní kvantitativní profil znalostního textu vychází navazující výzkum, který navrhuje využití neurotechnologií k určení neuropsychologických charakteristik učení pro různé typy vzdělávacích textů. Využití neurotechnologií, konkrétně funkční magnetické rezonance (fMRI), pro výzkum korové aktivity při čtení znalostně strukturovaných textů a vlastní provedení experimentu na relevantním vzorku respondentů za použití statistických metod je předmětem experimentu III.

Pro přípravu metodiky navazujícího experimentu je vhodné vědět, které faktory budou v rámci měření pomocí funkční magnetické rezonance podstatné a které nikoli. Z výzkumů Ezzyata a Davachiho (2011) nebo Kima et al. (2012) a dalších autorů je patrné, že pohlaví probanda, jeho preference strany při psaní (pravák/levák) či výskyt vážného neurologického onemocnění typu epilepsie může významně zkreslit výsledky.

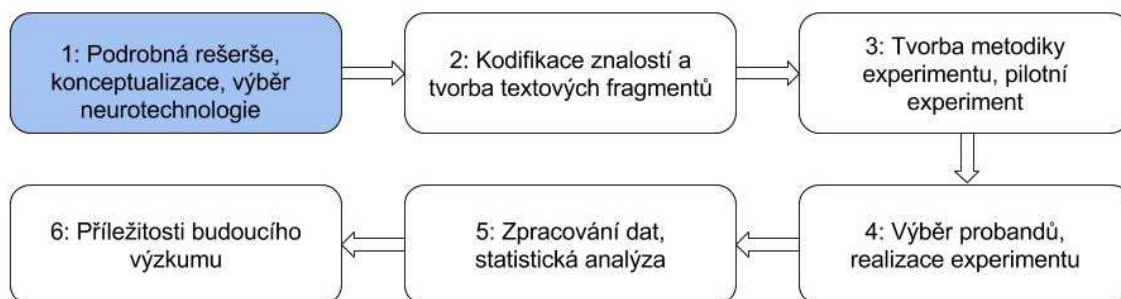
Na druhé straně na základě výsledků kapitoly 4.3 bylo zjištěno, že pokud budou v rámci měření předloženy stejné nebo obdobné textové fragmenty jako v již realizovaném

experimentu I a experimentu II, tak čas vyhrazený pro prezentaci jednotlivých typů textů může být obdobné délky jako v experimentu II, jelikož v průměru (bez vlivu typu brožury) četli respondenti text stejně dlouhou dobu. Dalším zjištěním je, že není třeba rozlišovat více věkových skupin a dle toho upravovat specifikaci měření. Dále bylo zjištěno, že více než polovina probandů subjektivně nerozpozná, který text se svou strukturou liší od ostatních, proto je vhodné objektivně toto ověřit i pomocí neurotechnologií, tj. zjistit, zda je mozková aktivita menší/větší při transferu znalostí prostřednictvím různých struktur textů.

Experiment III se skládá z šesti na sebe navazujících kroků: Podrobná rešerše, konceptualizace a výběr neurotechnologie; Kodifikace znalostí a tvorba textových fragmentů; Tvorba metodiky experimentu, pilotní experiment; Výběr probandů, realizace experimentu; Zpracování dat, statistická analýza; Příležitosti budoucího výzkumu.

4.4.3 Konkrétní výstupy experimentu III

1. krok: Podrobná rešerše, konceptualizace, výběr neurotechnologie



Obrázek 46 Experiment III - 1. krok - Podrobná rešerše, konceptualizace, výběr neurotechnologie; zdroj: autorka

Neurotechnologie v pedagogických experimentech

V dnešní době jsou neurotechnologie nebo techniky pro zobrazování a skenování mozkové činnosti více přístupné pro účely pedagogického výzkumu. Cena za zařízení dostatečné kvality i snížení velikosti přístrojů umožňují provádět experimenty nezávisle na specializovaných místech, jako jsou nemocnice nebo kliniky. V navržené metodice experimentu je cílem využít techniky mozkového skenování pro měření mozkové aktivity studentů v rámci práce se vzdělávacími texty různých stylů. Metodika se pak zejména

zaměřuje na funkční magnetickou rezonanci (fMRI). Jak vyplývá z literárního průzkumu, jak fMRI, tak elektroencefalografie (EEG) se používají v praxi pro pedagogické účely. Jindráček, Škoda a Doulík (2013) se zabývají přehledem užívaných neurotechnologických metod a nejčastěji používaných parametrů v pedagogických experimentech, zejména pak v rámci práce se vzdělávacími texty různých stylů. Schultz (2012) poskytuje hloubkovou analýzu a porovnání obou výše zmíněných technologií z hlediska jejich praktičnosti, více viz kapitola 3.4.4.

Návrh výběru neurotechnologie

Pro správný návrh experimentu a zejména pro výběr relevantní neurotechnologické metody bylo třeba vycházet z pravidel pro stanovení hodnotících kritérií (Bazerman a Moore, 2013). Kritéria vybraná pro konkrétní rozhodovací problém musela být v souladu s cílem řešení problému. Soubor kritérií navíc musel splňovat následující podmínky (Bazerman a Moore, 2013):

Úplnost – žádný důležitý aspekt hodnocení není vynechán;

Operacionalita - každé kritérium je dobře definováno, tj. tvůrce rozhodnutí popisuje jeho obsah jasně včetně vymezení a způsobu měření jeho jednotek;

Jedinečnost - každý aspekt hodnocení je zmíněn přesně jednou;

Minimální rozsah souboru - kritéria skutečně okrajového (slabého) vztahu k cíli řešení problému jsou vynechána.

Soubor kritérií

Dle doporučení Bazermana a Moora (2013), byla pro výběr vhodné neurotechnologie stanovena následující kritéria:

Náklady

Jedná se o kritérium ceny měřené objektivně v měnové jednotce (Kč). Zahrnuje dvě dílčí kritéria: fixní náklady a variabilní náklady. Fixní náklady jsou spojené s nákupem

technologie, variabilní náklady se počítají jako náklady na technologii používanou pro 1 účastníka experimentu.

Dostupnost

Toto kritérium přínosu je ohodnoceno subjektivně pomocí Saatyho metody a přepočteno na procentní podíl 100 % (viz např. Saaty a Liem, 2010). Kritéria hodnotí dostupnost technologie v regionu, pokud je využívána jako služba poskytnutá třetí stranou nebo v prostoru, pokud je technologie zakoupena.

Časová náročnost experimentu

Jedná se o kritérium měřené objektivně v časových jednotkách požadovaných pro provedení experimentu s jedním účastníkem.

Technická obtížnost experimentu

Jedná se o kritérium měřené subjektivně pomocí Saatyho metody a přepočítané na procentní podíl 100 %. Popisuje obtížnost provedení experimentu, např. při přípravě, či ohledně dalšího potřebného vybavení (notebooky, dataprojektory, zpětná zrcátka atd.).

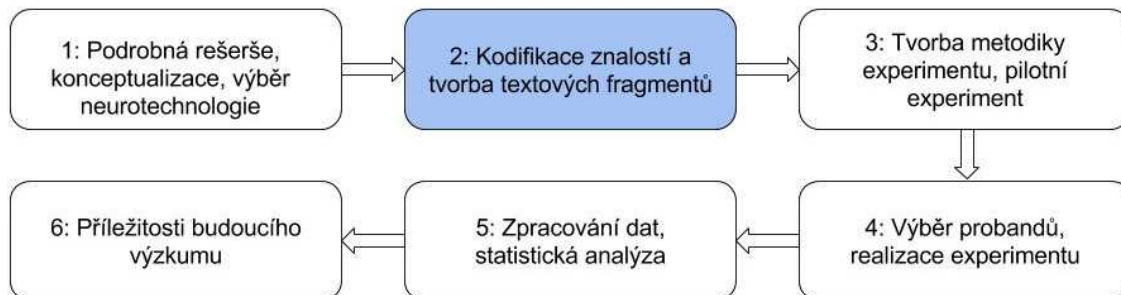
Relevance ve shodných hlediscích

Toto kritérium je hodnoceno subjektivně. Vyjadřuje názor experta, který v počtu bodů (stupnice od 0 do 5) ohodnotí danou neurotechnologickou diagnostickou metodu z pohledu, jak je daná metoda vhodná pro plánovaný výzkum.

Dle výše zmíněných kritérií byla pro experiment vybrána neurotechnologie – funkční magnetická rezonance. Subjektivní hodnocení bodovací či Saatyho metodou prováděl zkušený lékař s neurologickou atestací.

Pro spolupráci, tj. konzultace k designu experimentu a jeho realizaci, byli osloveni odborníci ze Středoevropského technologického institutu v Brně (CEITEC) v rámci výzkumného programu Výzkum mozku a lidské mysli. Konkrétně se jednalo o odborníky z výzkumných skupin Multimodální a funkční zobrazování a Aplikované neurovědy. Samotný experiment byl realizován jako služba v Laboratoři multimodálního a funkčního zobrazování.

2. krok: Kodifikace znalostí a tvorba textových fragmentů

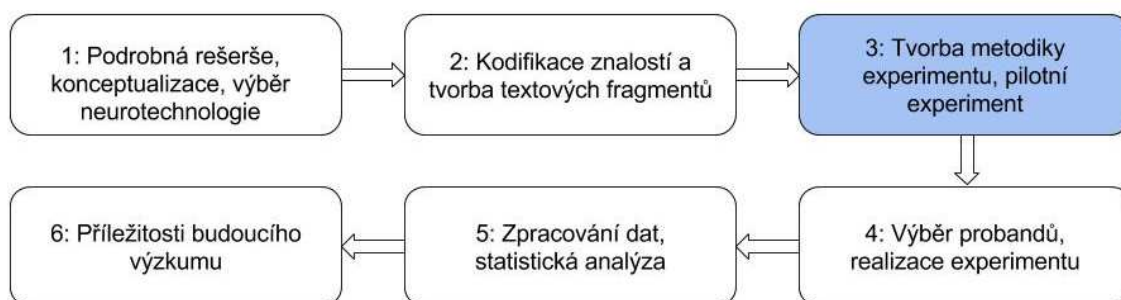


Obrázek 47 Experiment III - 2. krok - Kodifikace znalostí a tvorba textových fragmentů; zdroj: autorka

Textové fragmenty prezentované v experimentu

Myšlenka experimentu vychází z předpokladu, že jsou k dispozici dva styly vzdělávacích textů. Jeden je vytvořen pomocí koncepce znalostních jednotek a druhý je vytvořen jako klasický studijní text (Houška a Rauchová, 2013). Oba typy textů obsahují stejná témata (tj. jsou vybrány ze stejné problémové domény). Obě skupiny textů jsou rozděleny do 15 textových fragmentů. Podobně jako u studie od autorů Mason a Just (2011) má každý textový fragment rozsah od 100 do 150 slov. To znamená, že probandům je během experimentu prezentováno celkem 30 textových fragmentů (15 běžně strukturovaných (Sent A) a 15 znalostně strukturovaných (Sent B)).

3. krok: Tvorba metodiky experimentu, pilotní experiment



Obrázek 48 Experiment III - 3. krok – Tvorba metodiky experimentu, pilotní experiment; zdroj: autorka

Úkoly plněné probandy

Úkol A

V prvním úkolu měli participanti číst věty či krátké odstavce (textové fragmenty). Každý trial (stimul, věta, odstavec, fragment) vypadal tak, že se zobrazil text na 15 sekund (bílé písmo na černém pozadí uprostřed zorného pole). Poté se na 5 sekund zobrazil fixační kříž, aby byly jednotlivé trialy od sebe odděleny. V prvním úkolu byly probandům prezentovány celkem tři typy trialů, tj. dva typy textových fragmentů (běžně strukturované a znalostně strukturované) a tzv. *baseline* (řetězec písmen X, vizuálně stejného rozsahu jako ostatní textové fragmenty, ale bez řečového obsahu). Pořadí trialů bylo náhodné.

Úkol B

V druhém úkolu participanti četli tvrzení a odpovídali pomocí tlačítka (ANO/NE) o správnosti těchto tvrzení. Tvrzení vycházela z textových fragmentů prezentovaných v rámci úkolu A. Trialů měly stejnou podobu, všechny trvaly přesně 20 sekund. Otázka byla zobrazena po dobu maximálně 15 sekund. Jakmile proband odpověděl, zobrazil se fixační kříž, který byl zobrazen tak dlouho, aby trial trval 20 sekund. V této úloze nebyl typ trialu *baseline*. Pořadí trialů bylo náhodné.

Pomocí fMRI měření v prvním úkolu tedy bylo možné zobrazit místa v mozku kde je:

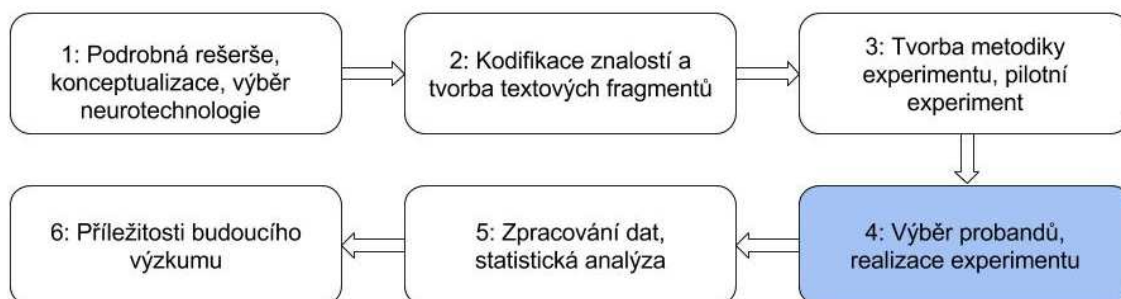
- 1) větší/menší aktivita při větách typu Sent A (běžně strukturovaný text) než při *baseline*,
- 2) větší/menší aktivita při větách typu Sent B (znalostně strukturovaný text) než při *baseline*.

V druhém úkolu se nepracovalo s trialem typu *baseline*. Je možné tedy zobrazit pouze místa, kde je aktivita větší/menší při tvrzení typu Sent A v porovnání s tvrzením typu Sent B.

Etický a morální kontext

V neposlední řadě musela být dodržována i etická a morální pravidla tohoto experimentu. To znamená, že data získaná od účastníků experimentu byla anonymně zpracována. Probandi podepsali informovaný souhlas o účasti na experimentu a poskytnutí všech potřebných údajů pro vědecké účely (Příloha 1). Podle Hrubyho (2012) je třeba závěry interpretovat ve spolupráci s odborníky v oblasti neurovědy, neuropsychologie a pedagogiky. Zejména je pak potřeba dojít k relevantním závěrům, na což upozorňuje Farivar (2001).

4. krok: Výběr probandů, realizace experimentu



Obrázek 49 Experiment III - 4. krok – Výběr probandů, realizace experimentu; zdroj: autorka

Účastníci experimentu a jejich role

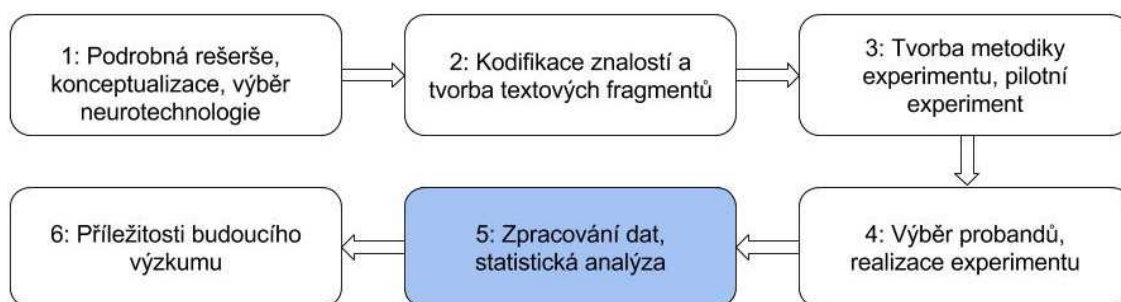
Na základě literární rešerše obdobných experimentů se počet probandů nejčastěji pohybuje v jednotkách či pár desítkách osob. Martín-Loeches et al. (2008) mají ve svých studiích genderově vyvážený soubor účastníků, Robertson et al. (2000) vybírají pouze probandy píšící pravou rukou (*dextralita*). Pro tento typ experimentu je nejčastěji oslovovaná věková kategorie probandů od 19 do 40 let (Speer et al., 2000; Martín-Loeches et al., 2008).

V rámci prezentovaného výzkumu se experimentu účastnilo 24 probandů (12 žen a 12 mužů), přičemž nejmladšímu účastníkovi bylo 18 let a nejstaršímu 37 let (věkový medián byl 23,9 let), všichni z nich byli charakterizováni dextralitou.

Každý účastník vyplnil formulář o své zdravotní situaci, tj. byly brány v úvahu předchozí nemoci, operace, genetické zátěže apod. Experimentu se nesměl účastnit proband, jehož zdravotní stav vykazoval odchylky od normálu (Smart a Burrell, 2015).

Testování se kromě probandů účastnil i administrátor experimentu (biomedicínský inženýr z CEITEC Brno), který provázel probandy celým experimentem a dohlížel na shodné podmínky celého procesu u všech testovaných.

5. krok: Zpracování dat, statistická analýza



Obrázek 50 Experiment III - 5. krok – Zpracování dat, statistická analýza; zdroj: autorka

Metodika zpracování dat

Data získaná v rámci standardní fáze experimentu byla zpracovávána v několika etapách. V první etapě byla data zpracována stejnou posloupností kroků pro všechny probandy, tj. nejprve došlo k předzpracování dat a poté byly spočteny statistiky na úrovni jednotlivce. Předzpracování dat zahrnovalo slícování fMRI snímků, korekci (*slice timing correction*), slícování průměrného fMRI snímku a anatomického snímku, prostorovou normalizaci fMRI snímků a anatomického snímku do společného stereotaktického prostoru a prostorovou filtraci. Statistika na úrovni jednotlivce obsahovala nastavení lineárního modelu pro úkol A a výpočet dvou efektů (Sent A vs. baseline, Sent B vs. baseline) a nastavení lineárního modelu pro úkol B a výpočet efektu (Sent B vs. Sent A). V úkolu A byla sledována aktivita v úsecích, kdy byl zobrazen text. V úkolu B byla sledována aktivita v úsecích dvě sekundy před odpovědí po okamžik odpovědi, tzn. periody, v nichž nejčastěji dochází k rozhodnutí k odpovědi.

Ve druhé etapě byla provedena skupinová statistika. Pomocí jednovýběrového T testu bylo testováno, ve kterých mozkových regionech se efekty signifikantně liší od nuly. Hladina statistické významnosti byla nastavena na $\alpha = 0,05$ a ve výsledcích bylo zohledněno mnohonásobné testování pomocí FWE (*Family wise error*) korekce. Pro testování rozdílů mezi znalostně a normálně strukturovaným textem pro dvě proměnné *Přesnost odpovědi*

probandů a Reakční čas potřebný pro rozhodnutí o pravdivosti tvrzení byly použity některé další dvouvýběrové testy, např. F test, T test (Hastie, Tibshirani, Friedman, 2013).

Stanovení hypotéz

Bylo stanoveno 5 pracovních hypotéz:

PH20.0: Běžně strukturovaný text (Sent A) se ve srovnání s řetězcem textu (baseline) statisticky významně liší při aktivaci oblastí mozku.

PH21.0: Znalostně strukturovaný (Sent B) se ve srovnání s řetězcem textu (baseline) statisticky významně liší při aktivaci oblastí mozku.

PH22.0: Vnímání znalostně strukturovaného textu (Sent B) těsně před rozhodnutím o pravdivosti tvrzení je ve srovnání s běžně strukturovaným textem (Sent A) z hlediska aktivace oblastí mozku statisticky významně odlišné.

PH23.0: Přesnost odpovědí probandů z hlediska pravdivosti tvrzení je shodná pro znalostně i běžně strukturovaný text.

PH24.0: Reakční čas potřebný pro rozhodnutí o pravdivosti tvrzení je shodný pro znalostně i běžně strukturovaný text.

V rámci každé pracovní hypotézy byly též nadefinovány operativní hypotézy v podobě nulových statistických hypotéz, které byly následně testovány pomocí statistických testů.

Simultánně s oběma úseky fMRI měření byla nasnímana EKG křivka a dechová křivka. V průběhu úkolu B byly zaznamenávány odpovědi probandů (pomocí hlasovacího zařízení s dvěma tlačítky ANO/NE). Behaviorální data z úkolu B, tj. odpovědi probandů na jednotlivá tvrzení a reakční čas počítaný od okamžiku zobrazení tvrzení jsou na příloženém CD.

Výsledky

Výsledky jsou rozděleny do několika částí dle testovaných pracovních hypotéz. První část zobrazuje výsledky z úlohy A při efektu Sent A ve srovnání s baseline, druhá část zobrazuje výsledky z úlohy A při efektu Sent B ve srovnání s baseline, třetí část zobrazuje výsledky


z úlohy B při efektu Sent B ve srovnání se Sent A. Čtvrtá část zobrazuje výsledky Sent A ve srovnání se Sent B pro průměrný počet přesných odpovědí. Pátá část zobrazuje výsledky Sent A ve srovnání se Sent B pro průměrný reakční čas.

Úkol A, efekt Sent A vs. baseline

V této části úkolu byla zkoumána následující operativní hypotéza:

OH20.1: V žádném voxelu se neprojevuje zkoumaný efekt (Sent A > baseline).

Barevná místa na obrázku 51 ukazují mozkové regiony, kde byla zjištěna vyšší aktivita při čtení textu běžně strukturovaného (Sent A) než při baseline (řetězce písmen X).



Obrázek 51 Mozkové regiony s vyšší aktivitou při čtení textu Sent A než při baseline (Poznámka: L = levá strana, P = pravá strana.); zdroj: autorka

Pro efekt Sent A vs. baseline bylo nalezeno 5 mozkových regionů, kde byla statisticky signifikantní aktivita, tj. byla zjištěna vyšší aktivita těsně před odpovědí na výrok běžně strukturovaného textu (Sent A) než při baseline (řetězce písmen X).

Následuje doplňková tabulka 16 charakteristik k jednotlivým oblastem zájmu (Region of interest). K popisu oblasti slouží tzv. standardní prostor, který využívá souřadnicový systém. V tomto experimentu byl využit MNI prostor. Názvy regionů jsou ponechány v anglickém jazyce (podle zvyklostí se uvádějí v latině či angličtině). K jednotlivým názvům a oblastem viz více v rámci neuroanatomie (Fix, 2002).

Region	Číslo oblasti	Velikost oblasti [cm³]	MNI souřadnice [mm] maxima
L/R occipital middle g; L/R calcarine; L/R lingual g; L/R occipital inferior g; L fusiform g	1	41,80	21 -100 -8
L temporal middle g; L temporal superior g;	2	9,30	-60 -43 1
L hippocampus	3	1,90	-30 -37 1
L precentral g; L postcentral g; L frontal inferior/middle g	4	7,75	-48 -4 49
L SMA	5	1,20	-9 8 55

Tabulka 16 Doprovodná skupinová statistika za 24 probandů pro mozkové regiony s vyšší aktivitou při čtení textu Sent A než při baseline (Poznámka: L = left; R = right; g = gyrus; SMA = supplementary motor area.); zdroj: autorka

T hodnota je výsledkem *T* testu pro data z konkrétního voxelu, jehož MNI souřadnice jsou uvedeny v tabulce 16 (výše). V tomto voxelu je testovaný efekt nejsignifikantnější (tzn. největší poměr mezi silou efektu a směrodatnou odchylkou efektu přes všechny subjekty). Nicméně zkoumaná aktivita většinou není specifická pro jeden daný voxel, proto se ve fMRI často určuje signifikance na úrovni celých klastrů voxelů (shluků nadprahových voxelů). *P* hodnoty, které se vztahují k celé Roi, a *T* hodnotu v maximum zobrazuje následující tabulka 17.

Region	Číslo oblasti	T hodnota v maximu	p hodnota (cluster)
L/R occipital middle g; L/R calcarine; L/R lingual g; L/R occipital inferior g; L fusiform g	1	13,18	< 0,001
L temporal middle g; L temporal superior g;	2	8,37	< 0,001
L hippocampus	3	6,90	0,003
L precentral g; L postcentral g; L frontal inferior/middle g	4	6,82	< 0,001
L SMA	5	5,41	0,026


Tabulka 17 Doprovodná skupinová statistika za 24 probandů pro mozkové regiony s vyšší aktivitou při čtení textu Sent A než při baseline (Poznámka: L = left; R = right; g = gyrus; SMA = supplementary motor area.); zdroj: autorka

Úkol A, efekt Sent B vs. baseline

V této části úkolu byla zkoumána následující operativní hypotéza:

OH21.1: V žádném voxelu se neprojevuje zkoumaný efekt (Sent B > baseline).

Barevná místa na obrázku 52 ukazují mozkové regiony, kde byla zjištěna vyšší aktivita při čtení textu znalostně strukturovaného (Sent B) než při baseline (řetězce písmen X).



Obrázek 52 Mozkové regiony s vyšší aktivitou při čtení textu Sent B než při baseline (Poznámka: L=levá strana, P = pravá strana.); zdroj: autorka

Pro efekt Sent B vs. baseline bylo nalezeno 7 mozkových regionů, kde byla statisticky signifikantní aktivita, tj. byla zjištěna vyšší aktivita těsně před odpovědí na výrok znalostně strukturovaného textu (Sent B) než při baseline (řetězce písmen X).

Následuje doplňková tabulka 18 charakteristik k jednotlivým oblastem zájmu (region of interest). K popisu oblasti slouží tzv. standardní prostor, který využívá souřadnicový systém. V tomto experimentu byl využit MNI prostor. Názvy regionů jsou ponechány v anglickém jazyce (podle zvyklostí se uvádějí v latině či angličtině). K jednotlivým názvům a oblastem viz více v rámci neuroanatomie (Fix, 2002).

Region	Číslo oblasti	Velikost oblasti [cm³]	MNI souřadnice [mm] maxima
L/R occipital middle g; L/R calcarine; L/R lingual g; L/R occipital inferior g; L fusiform g	1	45.3	-24 -91 -17
L temporal middle g; L temporal superior g;	2	12.4	-60 -40 1
L precentral g	3	2.8	-48 -7 49
L hippocampus	4	2.3	-27 -28 -5
L SMA	5	1.5	-3 2 61
L frontal inferior g	6	2.5	-51 8 34
L thalamus	7	1.2	-12 -16 13

Tabulka 18 Doprovodná skupinová statistika za 24 probandů, pro mozkové regiony s vyšší aktivitou při čtení textu Sent B než při baseline (Poznámka: L = left; R = right; g = gyrus; SMA = supplementary motor area.); zdroj: autorka

T hodnota je výsledkem *T* testu pro data z konkrétního voxelu, jehož MNI souřadnice jsou uvedeny v tabulce 18 (výše). V tomto voxelu je testovaný efekt nejsignifikantnější (tzn. největší poměr mezi silou efektu a směrodatnou odchylkou efektu přes všechny subjekty). Nicméně zkoumaná aktivita většinou není specifická pro jeden daný voxel, proto se ve fMRI často určuje signifikance na úrovni celých klastrů voxelů (shluků nadprahových voxelů). *P* hodnoty, které se vztahují k celé Roi, a *T* hodnotu v maximum zobrazuje následující tabulka 19.

Region	Číslo oblasti	T hodnota v maximu	p hodnota (cluster)
L/R occipital middle g; L/R calcarine; L/R lingual g; L/R occipital inferior g; L fusiform g	1	12,88	< 0,001
L temporal middle g; L temporal superior g;	2	7,62	< 0,001
L precentral g	3	6,80	< 0,001
L hippocampus	4	6,10	0,001
L SMA	5	5,78	0,011
L frontal inferior g	6	5,43	0,001


Tabulka 19 Doprovodná skupinová statistika za 24 probandů, pro mozkové regiony s vyšší aktivitou při čtení textu Sent B než při baseline (Poznámka: L = left; R = right; g = gyrus; SMA = supplementary motor area.); zdroj: autorka

Úkol B, efekt Sent B vs. Sent A

V této části úkolu byla zkoumána následující operativní hypotéza:

OH22.1: V žádném voxelu se neprojevuje zkoumaný efekt (Sent B > Sent A).

Barevná místa na obrázku 53 ukazují mozkové regiony, kde byla zjištěna vyšší aktivita těsně před odpovědí na výrok znalostně strukturovaného textu (Sent B) než těsně před odpovědí na výrok běžně strukturovaného textu (Sent A).



Obrázek 53 Mozkové regiony s vyšší aktivitou při čtení textu Sent B než Sent A (Poznámka: L = levá strana, P = pravá strana.); zdroj: autorka

Pro efekt Sent B vs. Sent A byly nalezeny 4 mozkové regiony, kde byla statisticky signifikantní aktivita, tj. byla zjištěna vyšší aktivita těsně před odpovědí na výrok znalostně

strukturovaného textu (Sent B) než těsně před odpovědí na výrok běžně strukturovaného textu (Sent A).

Následuje doplňková tabulka 20 s charakteristikami k jednotlivým oblastem zájmu (Region of interest). K popisu oblasti slouží tzv. standardní prostor, který využívá souřadnicový systém. V tomto experimentu byl využit MNI prostor. Názvy regionů jsou ponechány v anglickém jazyce (podle zvyklostí se uvádějí v latině či angličtině). K jednotlivým názvům a oblastem viz více v rámci neuroanatomie (Fix, 2002).

Region	Číslo oblasti	Velikost oblasti [cm³]	MNI souřadnice [mm] maxima
R occipital superior g; R cuneus	1	1,9	12 -100 16
R calcarine; R lingual g; R precuneus	2	2,2	18 -55 10
L calcarine; L/R lingual g	3	3,5	6 -82 -5
L temporal superior/middle g	4	1,7	-54 -70 10

Tabulka 20 Doprovodná skupinová statistika za 24 probandů pro mozkové regiony s vyšší aktivitou při čtení textu Sent B než při Sent A (Poznámka: L = left; R = right; g = gyrus.); zdroj: autorka

T hodnota je výsledkem *T* testu pro data z konkrétního voxelu, jehož MNI souřadnice jsou uvedeny v tabulce 20 (výše). V tomto voxelu je testovaný efekt nejsignifikantnější (tzn. je zde největší poměr mezi silou efektu a směrodatnou odchylkou efektu přes všechny subjekty). Nicméně zkoumaná aktivita většinou není specifická pro jeden daný voxel, proto se ve fMRI často určuje signifikance na úrovni celých klastrů voxelů (shluků nadprahových voxelů). *P* hodnoty, které se vztahují k celé Roi, a *T* hodnotu v maximum zobrazuje následující tabulka 21.

Region	Číslo oblasti	T hodnota v maximu	p hodnota (cluster)
R occipital superior g; R cuneus	1	5,37	0,003
R calcarine; R lingual g; R precuneus	2	5,14	0,001
L calcarine; L/R lingual g	3	5,03	< 0,001
L temporal superior/middle g	4	4,63	0,004

Tabulka 21 Doprovodná skupinová statistika za 24 probandů pro mozkové regiony s vyšší aktivitou při čtení textu Sent B než při Sent A (Poznámka: L = left; R = right; g = gyrus.); zdroj: autorka

Průměrný počet přesných odpovědí

V této části byly zkoumány následující operativní hypotézy:

OH23.1: Průměrný počet přesných odpovědí probandů z hlediska pravdivosti tvrzení není pro Sent A a Sent B rozdílný.

OH23.2: Rozptyl počtu přesných odpovědí probandů z hlediska pravdivosti tvrzení není pro Sent A a Sent B rozdílný.

Průměrný počet přesných odpovědí probandů z hlediska pravdivosti tvrzení byl pro Sent A (běžně strukturovaný text) 14,867 a pro Sent B (znalostně strukturovaný text) 16,267, p hodnota pro F test byla 0,575 a p hodnota pro dvouvýběrový T test byla 0,533 (při hladině významnosti $\alpha = 0,05$). To znamená, že rozptyly i průměry se statisticky významně neliší.



Obrázek 54 Box plot pro průměrný počet přesných odpovědí (správně určena pravdivost textu); zdroj: autorka

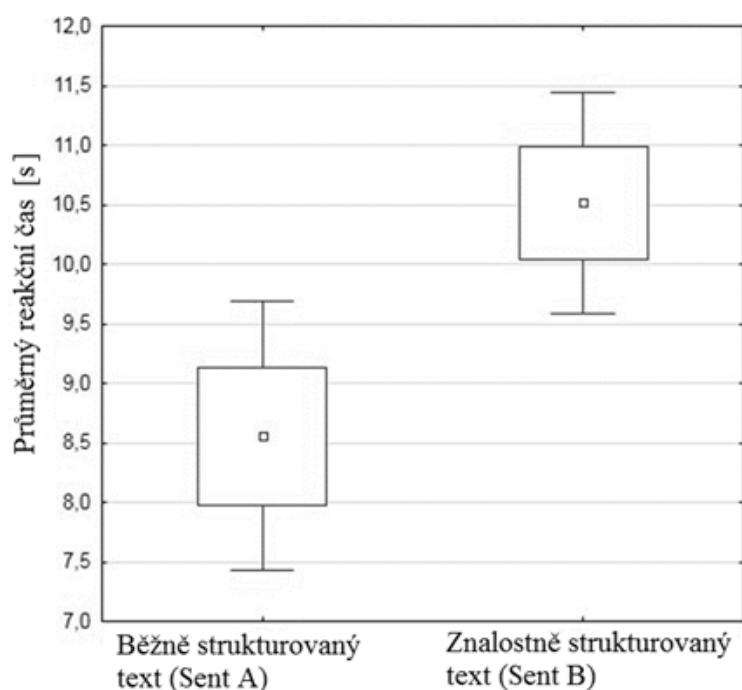
Průměrný reakční čas potřebný pro rozhodnutí o pravdivosti tvrzení

V této části byly zkoumány následující operativní hypotézy:

OH24.1: Průměrný reakční čas potřebný pro rozhodnutí o pravdivosti tvrzení nebyl pro Sent A a Sent B rozdílný.

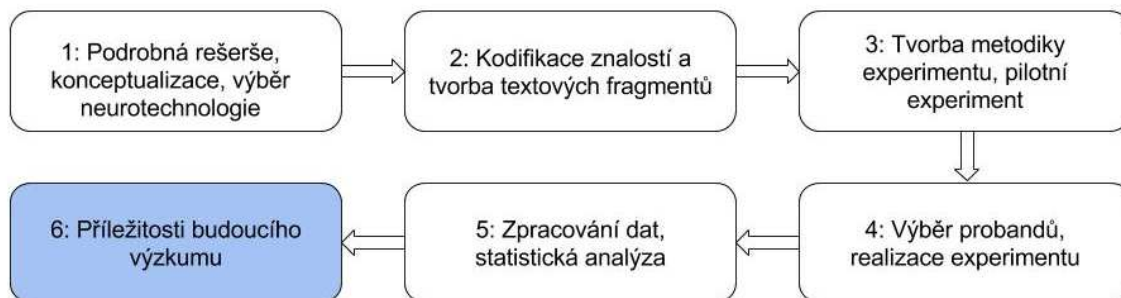
OH24.2: Rozptyl reakčních časů potřebných pro rozhodnutí o pravdivosti tvrzení nebyl pro Sent A a Sent B rozdílný.

Průměrný reakční čas potřebný pro rozhodnutí o pravdivosti tvrzení u Sent A (běžně strukturovaný text) byl 8,555 sekund a průměrný čas u Sent B (znalostně strukturovaný text) byl 10,515 sekund, p hodnota pro F test byla 0,465 a p hodnota pro dvouvýběrový T test byla 0,014 (při hladině významnosti $\alpha = 0,05$). To znamená, že rozptyly se statisticky významně neliší a průměry se statisticky významně liší.



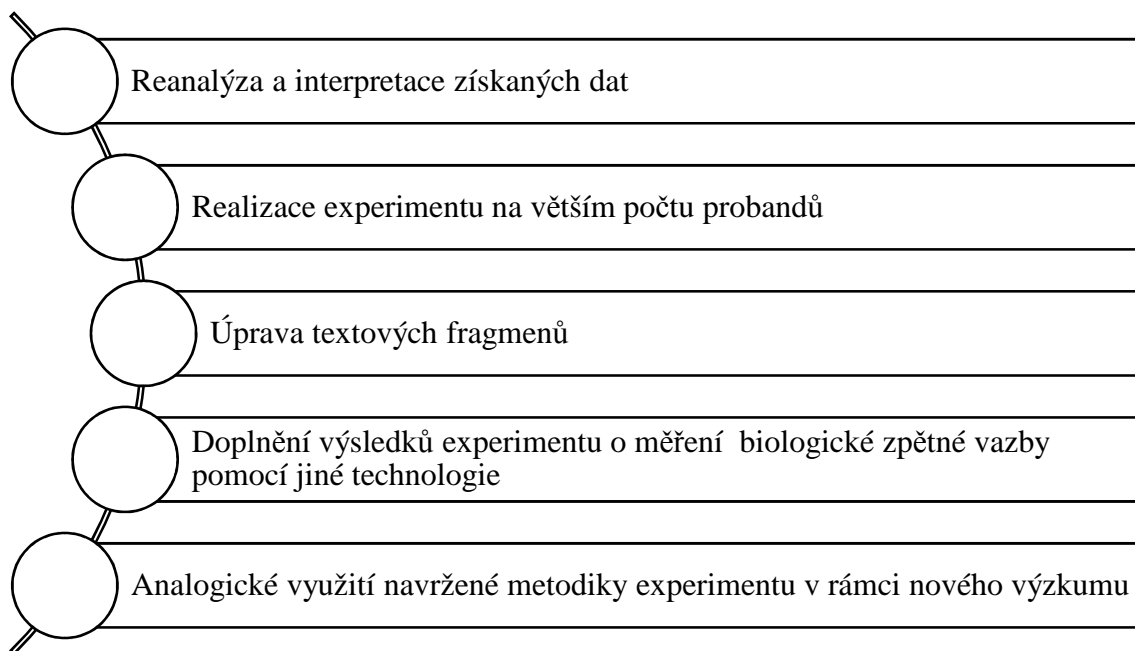
Obrázek 55 Box ploty pro průměrný reakční čas; zdroj: autorka

6. krok: Příležitosti budoucího výzkumu



Obrázek 56 Experiment III - 6. krok – Příležitosti budoucího výzkumu; zdroj: autorka

Na základě prvních výsledků realizovaného experimentu popsaného výše, se otevírá celá řada otázek a námětů vhodných pro budoucí a navazující výzkum v oblasti vzdělávacích textů, konkrétně se zaměřením na znalostně strukturované texty. Následující obrázek 57 ukazuje možné cesty budoucího výzkumu. Budoucí výzkum může být zaměřen na řešení problematiky komplexně, tj. do řešení bude zahrnuto více oblastí nebo specializovaně, kdy budou podrobně zkoumány dílčí aspekty a parametry jen jedné oblasti.



Obrázek 57 Oblasti možného dalšího zaměření výzkumu znalostně strukturovaných textů; zdroj: autorka

Reanalýza a interpretace získaných dat

V rámci získaných výsledků prozatím není vhodné dělat závěry o tom, jestli dochází k jiným mozkovým aktivitám při načítání různých stylů vzdělávacích textů, než bylo zkoumáno.

Do budoucna se lze kromě výše uvedených hypotéz zaměřit i na další analýzy, například sledovat korelaci rozdílných mozkových aktivit ve vybraných oblastech mozku v závislosti na pohlaví probanda, sledovat korelaci rozdílných mozkových aktivit ve vybraných oblastech mozku v závislosti na předchozí úrovni znalostí probanda, kterou sám proband před čtením textu ohodnotil nebo sledovat korelaci rozdílných mozkových aktivit ve vybraných oblastech mozku v závislosti na úrovni vzdělání probanda a další.

Data pro výše zmíněné analýzy jsou k dispozici, je však potřeba je interpretovat za součinnosti odborníků z více oblastí, tj. biomedicínského inženýra, neurologa, lékaře, psychologa či pedagoga. K tomu, aby byly vyřčeny závěry je potřeba provést celou řadu doplňujících a doprovodných reanalýz.

Realizace experimentu na větším počtu probandů

Další možností rozšíření experimentu je oslovit další probandy, kteří by se účastnili experimentu dle totožné metodiky popsané výše. K rozšíření počtu zapojených probandů může dojít tak, že budou osloveni lidé, již budou odpovídat souboru probandů, kteří se experimentu už účastnili. Tj. budou splňovat požadované věkové charakteristiky, bude zachován poměr zastoupení mužů a žen, respondenti budou zdravotně způsobilí, budou preferovat pravou ruku při psaní (dextralita) apod. To umožní rozšířit vzorek probandů, a posílí tak možné statistické závěry.

Další z možností je zaměřit se na rozšíření vzorku o probandy i jiných věkových skupin, tj. sledovat mozkovou aktivitu probandů při čtení textů u věkových skupin například ve školním věku, adolescentů, probandů dospělých, či probandů ve starším věku. Čímž bude možné sledovat, zda se některá věková skupina při načítání textu liší od jiné a zda tyto případné odlišnosti jsou shodné u všech prezentovaných stylů vzdělávacích textů. V případě, že bude docházet ke statisticky významným odlišnostem, je možné

výzkum směřovat dál v rámci přípravy a výzkumu učebnic a vzdělávacích textových opor pro celoživotní vzdělávání.

Další z možností je rozšířit vzorek probandů, tak aby bylo možné sledovat i vliv jiných aspektů, než je věk, jako například sledování rozdílností mozkové aktivity při čtení různých stylů textů u praváků a leváků (při rozšíření probandů o leváky, za podmínek *ceteris paribus*), nebo zaměřením se na rozdílnosti u probandů se specifickými poruchami učení (při rozšíření probandů o ty s poruchami učení, při stejné skladbě poruch učení, za podmínek *ceteris paribus*). Dále je možné zaměřit se na probandy s vážným onemocněním mozku, např. epileptiky, a porovnat jejich mozkové reakce se zdravými jedinci (při rozšíření probandů o epileptiky, za podmínek *ceteris paribus*). V případě, že bude docházet ke statisticky významným odlišnostem u některých z uvedených aspektů, je možné výzkum směřovat dál v rámci přípravy a výzkumu učebnic a vzdělávacích textových opor v pedagogicko-psychologickém kontextu.

Úprava textových fragmentů

Další možností budoucího výzkumu je realizovat experiment na základě metodiky popsané výše z pohledu práce a plnění úkolů probandy s jinými textovými fragmenty. Tzn. zaměřit se na další tematické oblasti (problémové domény), v rámci kterých budou vytvořeny nové vzdělávací texty, a to běžně strukturované povahy. Na základě běžně strukturovaných textů lze dle metodiky Houšky a Rauchové (2013) kodifikovat znalosti pomocí znalostních jednotek a produkčních pravidel do podoby znalostně strukturovaných textů s cílem identifikovat nejen rozdílnosti v rámci transferu znalostí u různých problémových domén při různém stylu vzdělávacího textu, ale zejména zjistit, jestli i dochází k rozdílné mozkové aktivitě při načítání těchto textů v rámci čtení různých textových stylů. Toto zjištění by doplnilo výsledky subjektivního zhodnocení probandů u různých tematických oblastí a různých stylů textů (Horáková a Houška, 2016).

V rámci experimentu fMRI je při tvorbě textů, resp. textových fragmentů o rozsahu jen několika vět, třeba dbát na to, aby textové fragmenty byly homogenní z hlediska lingvistických charakteristik, tj. průměrný počet vět, průměrný počet souvětí, průměrný počet vět na souvětí, průměrný celkový počet slov, průměrná sémantická obtížnost textu, průměrná syntaktická obtížnost textu, průměrná celková obtížnost textu.

Doplnění výsledků experimentu o měření biologické zpětné vazby pomocí jiné technologie

V budoucím výzkumu je možné získané výsledky doplnit i o další proměnné naměřené pomocí jiných technologií, jež budou dotvářet kvantitativní profil pro znalostně strukturované texty ve srovnání s běžně strukturovanými texty. Výše uvedený experiment byl realizován s využitím fMRI, nicméně kromě mozkové aktivity je možné sledovat i kožní odpor, EKG a další parametry.

Dále je možné uvažovat i o EEG, nicméně je třeba upravit cíl experimentu a přeformulovat výzkumné hypotézy, jelikož EEG se hodí pro jiný typ úkolu a neposkytuje tak přesné výsledky jako fMRI. EEG je tedy možné využít, nicméně vhodnost této technologie a případnou úpravu v rámci metodiky experimentu je třeba konzultovat s odborníky (neurolog, psycholog, biomedicínský inženýr).

V tomto směru je možné použít i metodu sledování pohybu očí (eyetracking), pomocí které lze analyzovat, zda u různých typů textů dochází ke stejnému načítání, či stejné intenzitě zaměření očí v jednotlivých částech textu (areas of interest), případně ke zpětnému vracení se v textu apod. více o eyetrackingu např. Molinari (2015). Na Provozně ekonomické fakultě České zemědělské univerzity v Praze je možnost zmíněný experiment realizovat, a to v Laboratoři pro studium lidského chování (HUBRU), která se zabývá komplexním výzkumem lidského chování a je též vybavena biometrikou. Jednoduchý pilotní výzkum s využitím eyetrackingu na stejných textech použitých pro fMRI byl též realizován. Na základě prvních výsledků byla navržena metodika takového experimentu (Mudrychová et al., 2017).

Analogické využití navržené metodiky experimentu v rámci nového výzkumu

Metodiku prezentovanou výše lze upravit a analogicky použít například v rámci nového pedagogicky orientovaného výzkumu, ve kterém je možné zaměřit se na srovnání vzdělávacích textů s jinými didaktickými prostředky, jako například multimédia, výukové hry, výukové prezentace apod. předávané žákům nebo studentům pomocí audiální, vizuální či audiovizuální techniky.

V posledních letech je trendem modernizovat vyučovací proces, ať už se to týká jeho obsahu, modernizace vyučovacích metod, či zařazení moderních prostředků didaktické

techniky do vyučování. Snahu o modernizaci a její kladné dopady na výsledky transferu znalostí, informací a dat dokazují četné příspěvky na pedagogických či infromatických konferencích, např. Mata, Lazar a Lazar, 2016; Martinik, 2016; Burianova, Turcani a Balogh, 2016; Akanova et al., 2016.

Na druhé straně se začínají objevovat názory některých autorů (Schugar a Schugar, 2014; Mangen et al., 2013; Chen et al., 2014), na nežádoucí účinky digitálních informačních technologií, které mohou způsobovat tzv. digitální demenci či kybernemoc, které se projevují negativními dopady nejen na intelekt a paměť, ale i na duševní a tělesné zdraví (Spitzer, 2014).

Z tohoto pohledu se zdá relevantní zaměřit budoucí výzkum na tištěné texty a učebnice a sledovat jejich dopad na pracovní paměť, soustředěnost a čtení s porozuměním. Navíc je možné sledovat i biologické reakce v lidském těle při čtení tištěných textů a porovnávat je s ostatními didaktickými prostředky (jako např. Spitzer (2012)). V tomto smyslu by se mohl dále ubírat budoucí výzkum, tedy směrem ke zdravému užívání techniky na školách či univerzitách s ohledem na efektivní transfer znalostí.

4.4.4 Závěr kapitoly 4.4.

Kapitola se zabývala možnostmi experimentu zaměřeného na účinnost textu z pohledu objektivního biologického lidského vnímání, tzv. biofeedback. V první části kapitoly byl zohledněn návrh výběru neurotechnologie, přičemž při respektování požadavků na kritéria (úplnost, operacionalita, jedinečnost a minimální rozsah) byla vybrána následující kritéria: náklady, dostupnost, časová náročnost experimentu, technická obtížnost experimentu a relevance ve shodných hlediscích. Na základě těchto kritérií byla vybrána technologie funkční magnetická rezonance (fMRI). Ve spolupráci se zástupci Středoevropského technologického institutu v Brně (CEITEC) v rámci výzkumného programu Výzkum mozku a lidské mysli byl navržen design experimentu. Design experimentu se dotýkal šesti na sebe navazujících oblastí: účastníci experimentu a jejich role, textové fragmenty prezentované v experimentu, úkoly plněné probandy, metodika zpracování dat, výzkumné hypotézy, etický a morální kontext.

Cílem experimentu bylo odhalit rozdíly v aktivitách lidského mozku v rámci čtení běžně strukturovaných a znalostně strukturovaných textů a zpětného vybavování dat, informací a znalostí, které byly v prvním kroku v textech prezentovány.

Z měření vzešly první výsledky, tj. bylo identifikováno 5 mozkových oblastí, ve kterých byla zjištěna vyšší aktivita při čtení běžně strukturovaného textu ve srovnání s baseline (textový řetězec textu z písmen X vizuálně stejné délky, ale bez řečového obsahu). Dále bylo nalezeno 7 mozkových oblastí, kde byla vyšší aktivita při čtení znalostně strukturovaného textu ve srovnání s baseline. V případě odpovědí probandů o pravdivosti tvrzení prezentovaného ve znalostně či běžně strukturované textové podobě byly identifikovány 4 oblasti mozku, kde byla vyšší aktivita u znalostně strukturovaného textu než u běžně strukturovaného textu. Co se týče správnosti odpovědí, tak v přesnosti z hlediska pravdivosti tvrzení není u textů prezentovaných v běžné či znalostní podobě statisticky významný rozdíl. Statisticky významný rozdíl se objevil u průměrného reakčního času při rozhodnutí o pravdivosti tvrzení, tj. pokud tvrzení bylo původně prezentované ve formě znalostně strukturovaného textu, tak průměrný reakční čas rozhodnutí o pravdivosti tvrzení byl delší, než pokud tvrzení pocházelo z běžně strukturovaného textu.

Tato zjištění však není vhodné v této fázi generalizovat, je třeba provést celou řadu reanalýz a získané výsledky konzultovat s odborníky z více oblastí (neurologie, medicína, psychologie a pedagogika), aby nedošlo k nerelevantním závěrům. Reanalýza a interpretace získaných dat spolu dalšími příležitostmi jako: realizace experimentu na větším počtu probandů, úprava textových fragmentů, doplnění výsledků experimentu o měření biologické zpětné vazby pomocí jiné technologie či analogické využití navržené metodiky experimentu v rámci nového výzkumu jsou jedněmi z možných oblastí, kterými se může ubírat budoucí výzkum znalostně strukturovaných textů.

5 Závěr

Znalosti od počátku lidstva doprovázejí lidskou činnost. Ačkoliv znalostní inženýrství vzniklo jako vědní obor až v druhé polovině 20. století, význam znalostí pro řešení problémů v rámci problémových archetypálních situací, jejich vymezení vůči nižším (informacím) či vyšším úrovním (moudrosti) se již dávno objevovalo v literatuře, náboženství či filozofii. S přirozeným vývojem společnosti, nástupem milénia, nových generací a technologickým vývojem lidé opustili informace a postupně přešli ke znalostem, tj. začalo se hovořit o tzv. znalostní společnosti, která nahradila společnost informační.

V současnosti existuje mnoho definic znalostí, nad nimiž stojí dva základní přístupy ke znalostem: produktový a procesní. Disertační práce se zabývá přístupem produktovým, a to z toho důvodu, že je zaměřen na zkoumání znalosti jako objektu. Znalost z tohoto úhlu pohledu může být vlastněna, kodifikována, přenášena, využívána, uchována apod. V této práci je znalost reprezentována pomocí konceptu znalostní jednotky. Pomocí znalostních jednotek lze vytvořit vzdělávací texty, jež mají explicitně vyjádřenou znalost. Hlavním cílem disertační práce bylo zhodnotit vliv struktury vzdělávacích textů na efektivnost transferu explicitních znalostí. Výsledky výzkumu lze shrnout následujícím způsobem.

1. Byl zhodnocen současný stav poznání v oblasti znalostního inženýrství. Ukázalo se, které výzkumné experimenty byly již realizovány a které aktuální metody a postupy měření a následného vyhodnocení jsou vhodné pro splnění dílčích cílů. Dále bylo zjištěno, že u textů je třeba z hlediska didaktiky sledovat jejich celkovou obtížnost, která se u česky psaných textů počítá jako suma syntaktické a sémantické obtížnosti. Bylo zjištěno, že počáteční úroveň znalostí musí být brána v potaz, pokud se měří přenos znalostí v pedagogice. V neposlední řadě byly představeny diagnostické neurologické metody a jejich relevance pro objektivní měření při práci uživatelů s texty.

2. Byl formalizován postup tvorby znalostně strukturovaných textů. Podařilo se jej vyjádřit pomocí relativně jednoduché procedury, kterou, jak bylo ověřeno, zvládne v krátké době i uživatel (autor), který nemá předchozí zkušenosti s tvorbou vzdělávacích textů. Zejména pro neškolené autory je postup přínosem, neboť mu garantuje, že do vzdělávacího textu opravdu vkládá všechny podstatné informace a sestavuje z nich znalosti.

3. Byla popsána specifika znalostně strukturovaných textů pomocí kvantitativních charakteristik. Bylo zjištěno, že se znalostně strukturovaný text statisticky významně liší od běžně strukturovaného textu z hlediska didaktických charakteristik textu. Přestože vykazuje vyšší průměrný počet vět v souvětích a vyšší průměrný počet vybraných slovních konceptů, má nižší celkovou obtížnost. Nižší celková obtížnost znalostně strukturovaných textů je ovlivněna koeficientem hustoty odborné informace (proporce odborných a faktografických pojmů na celkovou sumu slov), který je u obou typů textů shodný, což snižuje celkovou náročnost textu pro čtenáře.

Na základě významné statistické odlišnosti ve výskytu slovních konceptů byly sledovány vybrané klasifikátory (nástroje umělé inteligence) a jejich schopnost zařazení neznámého textu do skupiny znalostně strukturovaný vs. běžně strukturovaný text. Bylo zjištěno, že vybrané umělé neuronové sítě poskytují stejné relativní frekvence správné klasifikace znalostně strukturovaných textů a běžně strukturovaných vzdělávacích textů jako vybrané rozhodovací stromy. Vybrané umělé neuronové sítě dále poskytují vyšší relativní frekvence správné klasifikace znalostně strukturovaných textů a běžně strukturovaných vzdělávacích textů než vybrané klasifikační a regresní stromy.

4. Byl stanoven vliv struktury vzdělávacího textu na výsledky učení. Textové brožury jsou statisticky významným nástrojem pro transfer znalostí. Znalostně strukturovaný text vykazuje statisticky významnou vyšší úspěšnost transferu znalostí v rámci práce se znalostně a běžně strukturovanými texty. Na čistém transferu znalostí se statisticky významně podílejí větší měrou znalostně strukturované texty ve srovnání s běžně strukturovanými texty. Na druhou stranu nelze prokázat statisticky významný vliv typu textu na čas potřebný ke studiu textů ani vliv věku respondenta na čas potřebný ke studiu textů. Tento výsledek lze považovat za pozitivní, neboť ukazuje, že odlišná struktura textů nepředstavuje bariéru pro uživatele při práci s těmito texty.

5. Bylo zjištěno, že uživatelé subjektivně nevnímají rozdíly ve struktuře u znalostně a běžně strukturovaných textů. Nepodařilo se prokázat, že více než polovina respondentů pozná, který text se svou strukturou liší od ostatních.

6. Byly popsány shody a rozdíly v mozkové činnosti při práci s různě strukturovanými texty. Závěry při sledování této činnosti ve fázi učení a vybavování

nejsou jednoznačné. Ke stanovené hypotéze, o neexistenci rozdílů při aktivaci korové oblasti mozku při práci se znalostně a běžně strukturovanými texty není možné zaujmout jednoznačný postoj. Z experimentu vyplynulo, že je třeba provést navazující reanalýzy dat a případně provést navazující experimenty, které svými výsledky hypotézu potvrdí či vyvrátí. Do budoucna je možné experiment III doplnit například o: realizaci experimentu na větším počtu probandů, úpravu textových fragmentů, doplnění výsledků experimentu o měření biologické zpětné vazby pomocí jiné technologie či analogické využití navržené metodiky experimentu v rámci nového výzkumu. Nyní lze pouze konstatovat, že:

- Běžně strukturovaný text (Sent A) ve srovnání s řetězcem textu (baseline) se statisticky významně liší při aktivaci oblastí mozku.
- Znalostně strukturovaný (Sent B) ve srovnání s řetězcem textu (baseline) se statisticky významně liší při aktivaci oblastí mozku.
- Vnímání znalostně strukturovaného textu (Sent B) těsně před rozhodnutím o pravdivosti tvrzení je ve srovnání s běžně strukturovaným textem (Sent A) z hlediska aktivace oblastí mozku statisticky významně odlišné.
- Přesnost odpovědí probandů z hlediska pravdivosti tvrzení je shodná pro znalostně i běžně strukturovaný text.
- Reakční čas potřebný pro rozhodnutí o pravdivosti tvrzení je vyšší pro znalostně strukturovaný text než běžně strukturovaný text.

Z výsledků všech experimentů vyplynulo, že znalostně strukturované texty mají edukační potenciál. Podílejí se účinně na transferu znalostí. Pomocí nich lze snížit celkovou obtížnost vzdělávacího textu na úkor navýšení jiných lingvistických ukazatelů. Na druhou stranu uživatelé tyto rozdíly nevnímají.

Do budoucna by bylo vhodné se na texty zaměřit z pohledu jejich využití. Je možné rozšířit obecný výzkum znalostně strukturovaných textů např. o studie, zjišťující vhodnou cílovou skupinu čtenářů, studentů. Cílem studie by bylo zjistit, zda je vhodné se zaměřit na tzv. normální jedince nebo na jedince se specifickými potřebami. Jedinci se specifickými potřebami mohou být jak studenti s poruchami učení či naopak nadaní

a talentovaní žáci, studenti. V rámci výzkumných studií je vhodné zaměřit se i na typ vzdělávání, tj. vhodnost speciálně upravených textů v rámci školního či celoživotního vzdělávání.

Vývoj moderních technologií ovlivňuje odklon od klasických textových učebních pomůcek a učebnic v rámci vzdělávání. Texty ve vzdělávání bývají doprovázeny a v některých případech plně nahrazeny multimediálními oporami. Je však nutné podotknout, že po řadě let začleňování moderních nástrojů do výuky a obecnému přesycení společnosti moderními technologiemi, se ve vědeckých časopisech začínají objevovat studie, jež znovu nalézají potenciál transferu znalostí prostřednictvím textových učebních materiálů, ať už v elektronické či klasické tištěné verzi. Z tohoto úhlu pohledu navazující experimenty a studie zaměřené na znalostně strukturované texty mají své opodstatnění.

Z pohledu komunikace *člověk-stroj* je možné do budoucna uvažovat o tvorbě expertních systémů, jejichž výstupy, tj. expertní rady, doporučení, rozhodnutí a návody pro řešení konkrétních problémů budou zpracovány ve formě znalostně strukturovaných textů. Jedinec tuto strukturu textu nevnímá odlišně od běžně strukturovaných textů, je schopen dle těchto textů úkoly řešit s vyšší přesností a celkově má tato struktura textu nižší celkovou obtížnost (z pohledu čitelnosti textu) ve srovnání s běžně strukturovanými texty. Do budoucna by však bylo třeba navrhnout, jakým způsobem připravit vhodně bázi znalostí, jak v systému nadefinovat dílčí části znalostní jednotky a jakým způsobem je automaticky generovat.

6 Seznam použitých zdrojů

- AKANOVA, A. et al., 2016. Assesment tools for evaluation knowledge of online students. In: *Efficiency and Responsibility in Education 13th International Conference Proceedings*. Prague: CULS Prague, 9-17. ISBN 978-80-213-2646-0.
- AMIRIAN, E. et al., 2015. Integrated cluster analysis and artificial neural network modeling for steam-assisted gravity drainage performance prediction in heterogeneous reservoirs. *Expert Systems with Applications*, 42.2: 723-740.
- ANDERSON, A. J.; MURPHY, B.; POESIO, M., 2014. Discriminating taxonomic categories and domains in mental simulations of concepts of varying concreteness. *Journal of cognitive neuroscience*, 26.3: 658-681. doi: 10.1162/jocn_a_00508.
- ARCHAMBAULT, L. M.; BARNETT, J. H., 2010. Revisiting technological pedagogical content knowledge: Exploring the TPACK framework. *Computers & Education*, 55.4: 1656-1662. doi: 10.1016/j.compedu.2010.07.009.
- ARZHAKOV, A. V.; SILNOV, D. S., 2016. New approach to designing an educational automated test generation system based on text analysis. *ARPJ Journal of Engineering and Applied Sciences*, 11.5: 2993-2997.
- AVEN, T., 2013. A conceptual framework for linking risk and the elements of the data–information–knowledge–wisdom (DIKW) hierarchy. *Reliability Engineering & System Safety* [online], 111: 30-36. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S095183201200213X>.
- BARETTA, L. et al., 2012. Investigating reading comprehension through EEG. *Ilha do Desterro A Journal of English Language, Literatures in English and Cultural Studies*, 63: 069-100.
- BASSETT, E. E. et al., 2000. *Statistics: problems and solutions*. World Scientific. ISBN 981-02-4321-9.
- BAZERMAN, M. H.; MOORE, D. H., 2013. Introduction to Managerial Decision Making. *Judgment in Managerial Decision Making*, 1-10.
- BENEŠ, P.; JANOUŠEK, R.; NOVOTNÝ, M., 2009. Hodnocení obtížnosti textu středoškolských učebnic. *Pedagogika* [online], 59: 291-297. Dostupné z: http://pages.pdf.cuni.cz/pedagogika/files/2013/12/P_2009_3_06_Hodnocen%C3%AD_291_297.pdf.
- BIGML, Inc., 2017. *BigML - Machine Learning made easy* [online]. BigML, c2017 [cit. 2017-05-31]. Dostupné z: <https://bigml.com/>
- BISHOP, C. M., 2005. *Neural networks for pattern recognition*. Oxford: Oxford university press. ISBN-13: 978-0198538646.

BOJAR, O. et al., 2012. *The Czech Language in the Digital Age*. Berlin, Germany: Springer-Verlag Berlin Heidelberg.

BRAGANZA, A., 2004. Rethinking the data–information–knowledge hierarchy: towards a case-based model. *International Journal of Information Management* [online], 24.4: 347-356. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S0268401204000519>.

BROŽOVÁ, H. et al., 2011. *Modelování znalostí*. Professional Publishing. ISBN 978-80-7431-069-0.

BURIANOVA, M., TURCANI, M.; BALOGH, Z., 2016. From classic to smart technology. In: *Efficiency and Responsibility in Education 13th International Conference Proceedings*. Prague: CULS Prague, 59-65. ISBN 978-80-213-2646-0.

CASANOVA, R. et al., 2007. Biological parametric mapping: a statistical toolbox for multimodality brain image analysis. *Neuroimage*, 34.1: 137-143.

COHEN, M. S. et al., 2016. Effects of aging on value-directed modulation of semantic network activity during verbal learning. *NeuroImage* [online], 125: 1046-1062. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S1472029913003056>.

COLLINS, A.; BROWN, J. S.; NEWMAN, S. E., 1988. Cognitive Apprenticeship. Teaching the Craft of Reading, Writing and Mathematics. *Thinking: The Journal of Philosophy for Children*, 8.1:2-10. doi: 10.5840/thinking19888129.

COOPER, P., 2010. Data, information and knowledge. *Anaesthesia & Intensive Care Medicine* [online], 11.12: 505–506. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S1472029910002353>.

DA SILVA, C. E. T. et al., 2015. Classification of food vegetable oils by fluorimetry and artificial neural networks. *Food Control*, 47: 86-91.

DISMAN, M., 2011. *Jak se vyrábí sociologická znalost*, Praha: Karolinum. ISBN 978-80-246-0139-7.

DÖMEOVÁ, L., 2009. *Modelování vzniku a sdílení znalostí*. Habilitační práce. Praha: Česká zemědělská univerzita.

DÖMEOVÁ, L.; HOUŠKA, M; HOUŠKOVÁ BERÁNKOVÁ, M., 2008. *Systems Approach to Knowledge Modelling*. Hradec Králové: Graphical Studio Olga Čermáková. ISBN 978-80-86703-30-5.

DOSTÁL, P. et al., 2005. *Pokročilé metody manažerského rozhodování*. Praha: Grada Publishing. ISBN 80-247-1338-1.

DRÁBEK, O.; SEIDL, P.; TAUFER, I., 2006. Umělé neuronové sítě–základy teorie a aplikace (3). *CHEMagazín: Časopis pro chemicko-technickou a laboratorní praxi*, 4.21: 36-39.

DVOŘÁK, J., 2011. Moderní způsoby tvorby a vyhodnocování testů. *Meranie vedomostí ako súčasť zvyšovania kvality vzdelávania*, 39.

EGRIOGLU, E. et al., 2014. Recurrent multiplicative neuron model artificial neural network for non-linear time series forecasting. *Procedia-Social and Behavioral Sciences*, 109: 1094-1100.

EICHHOFF, J. R.; ROLLER, D., 2014. Approach to Learning Production Rules for Grammar-Based Functional Design. In: *GI-Jahrestagung*. 1977-1978.

EICKHOFF, S. B. et al., 2012. Activation likelihood estimation meta-analysis revisited. *Neuroimage*, 59.3: 2349-2361.

ERDEN, Z.; VON KROGH, G.; NONAKA, I., 2008. The quality of group tacit knowledge. *The Journal of Strategic Information Systems* [online], 17.1: 4-18. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S0963868708000048>.

EZZYAT, Y.; DAVACHI, L., 2011. What constitutes an episode in episodic memory?. *Psychological Science*, 22.2: 243-252.

FARIVAR, R., 2001. Review of The Mind within the Net: Models of Learning, Thinking, and Acting. *Cognitive Systems Research*, 2.3: 235-240.

FELDMAN, R., 2013. Techniques and Applications for Sentiment Analysis: The Main Applications and Challenges of One of the Hottest Research Areas in Computer Science. *Communications of the ACM*, 56. 4: 82 – 89. ISSN 0001-0782.

FENG, V. W.; HIRST, G., 2012. Text-level discourse parsing with rich linguistic features. In: *Proceedings of the 50th Annual Meeting of the Association for Computational Linguistics: Long Papers*. Association for Computational Linguistics, 1: 60-68.

FERSTL, E. C., 2007. The functional neuroanatomy of text comprehension: what's the story so far? In: SCHMALHOFER, F. PERFETTI, C. A. *Higher level language processes in the brain: Inference and comprehension processes*. Mahwah: Psychology Press. ISBN-13: 978-1138004115.

FIX, J. D., 2002. Neuroanatomy. Lippincott Williams & Wilkins. ISBN 0-7817-7245-1.

FRANZOLIN, F.; BIZZO, N., 2015. Types of Deviation in Genetics Knowledge Presented in Textbooks Relative to the Reference Literature. *Procedia - Social and Behavioral Sciences*, 167: 223-228. doi: 10.1016/j.sbspro.2014.12.666.

FRIESE, U. et al. Neural indicators of inference processes in text comprehension: An event-related functional magnetic resonance imaging study. *Journal of Cognitive Neuroscience*, 2008, 20.11: 2110–2124.

GANGOPADHYAY, K.; NISHIMURA, A.; PAL, R., 2016. Can the information technology revolution explain the incidence of co-movement of skill premium and stock prices?. *Economic Modelling* [online], 53: 107–120. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S026499931500348X>.

GARCIA-SCIVERES, M.; WANG, X., 2016. Data encoding efficiency in pixel detector readout with charge information. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment* [online], 815: 18–22. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S0168900216000176>.

GRAVETTER, F. J.; WALLNAU, L. B., 2009. *Statistics for the Behavioral Sciences*. Wadsworth: Cengage Learning. ISBN 13: 978-1-1111-83099-1.

GLAVA, A.; GLAVA, C., 2011. The Model and the Didactic Modelling: An Analytic Point of View. *Procedia - Social and Behavioral Sciences*, 15: 2228-2231.

GUPTA, R., 2014. Expectations vs. Reality: The Readability of Texts in the Primary Grades in India. *Procedia - Social and Behavioral Sciences* [online], 116: 3916–3920. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S1877042814008830>.

HALL, J. G., 2012. Engineering knowledge engineering. *Expert Systems*, 29.5: 427–428.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J., 2008. *The elements of statistical learning. Data mining, Inference and Prediction*. Berlin: Springer, Springer series in statistics. ISBN 978-0-387-84857-0.

HODIS, V., 2003. Hodnocení učebnice Praktické činnosti pro 6. - 9. ročník základních škol: *Provoz a údržba domácnosti* [online]. Dostupné z: <http://epedagog.upol.cz/eped3.2003/index.htm> edn.

HORÁKOVÁ, T.; HOUŠKA, M., 2014a. On Improving the Experiment Methodology in Pedagogical Research. *International Education Studies*, 7.9: 84-98. ISSN: 1913-9020.

HORÁKOVÁ, T.; HOUŠKA, M., 2014b. Quantitative Differences among Normal and Knowledge Texts on Agriculture Waste Processing. *AGRIS on-line Papers in Economics and Informatics*, 4: 59-68. ISSN: 1804-1930.

HORÁKOVÁ, T.; HOUŠKA, M., 2016. Different Types of Educational Texts: Differences Percieved by the Students. In: *Efficiency and Responsibility in Education 13th International Conference Proceedings*. Prague: CULS Prague, 178-185. ISBN 978-80-213-2646-0.

HORÁKOVÁ, T.; HOUŠKA, M.; DÖMEOVÁ, L., 2017. Classification of the Educational Texts Styles with the Methods of Artificial Intelligence, *Journal of Baltic Science Education*, 16, In press. ISSN 1648-3898.

HORÁKOVÁ, T.; HOUŠKA, M.; LUHANOVÁ, K., 2016. Differences Among Knowledge and Normal Educational Texts: a fMRI Study. In: *11th International Scientific Conference on Distance Learning in Applied Informatics*. Štúrovo, Slovakia: Wolters Kluwer, 523-532. ISBN 978-80-7552-249-8.

HORÁKOVÁ, T.; HOUŠKA, M.; LUHANOVÁ, K., 2015. Distinguishing the educational text styles by neurotechnologies: research design. In: *Proceedings of the 12th International Conference Efficiency and Responsibility in Education*. Prague: CULS Prague, 160-166. ISBN 978-80-213-2560-9.

HORÁKOVÁ, T.; KREJČÍ, I.; RYDVAL, J., 2017. Students' reflections on teaching the system dynamics at CULS Prague. In: *Efficiency and Responsibility in Education 14th International Conference Proceedings*. Prague: CULS Prague, 130-136. ISBN 978-80-213-2762-7.

HORÁKOVÁ, T.; RYDVAL, J.; HOUŠKA, M., 2017. Creating the Knowledge Texts in Agriculture Companies: A Cost Modeling Approach, *AGRIS on-line Papers in Economics and Informatics*, 9.2. In Press. ISSN 1804-1930. doi: 10.7160/aol.2017.0902xx.

HOUŠKA, M., 2011. *Znalostní jednotky a jejich modelování*. Habilitační práce. Praha: Česká zemědělská univerzita.

HOUŠKA, M.; BERÁNKOVÁ, M., 2008. *Lineárního programování: cvičebnice*, Praha: PEF, ČZU v Praze. ISBN 978-80-213-1869.

HOUŠKA, M.; HOUŠKOVÁ BERÁNKOVÁ, M., 2007. Individual Learning Based on Elementary Knowledge Concept. In: *International Conference Interactive Computer Aided Blended Learning*. Florianopolis, Brazil: International Association of Online Engineering, 1-6. ISBN: 978-3-89958-277-2.

HOUŠKA, M.; RAUCHOVÁ, T., 2013. Methodology of creating the knowledge text. In: *Efficiency and Responsibility in Education 10th International Conference Proceedings*. Prague: CULS Prague, 197-203. ISBN 978-80-213-2378-0.

HRABÍ, L., 2012. Natural Science Textbooks for the Fourth Grade and their Text Difficulty. *Environmetrics*, 7.2: 1-7. doi: 10.14712/18023061.322.

HRUBY, G. G.; GOSWAMI, U., 2011. Neuroscience and reading: A review for reading education researchers. *Reading Research Quarterly*, 46.2: 156-172.

HRUBY, G. G., 2012. Three requirements for justifying an educational neuroscience. *British journal of educational psychology*, 82.1: 1-23. doi: 10.1111/j.2044-8279.2012.02068.x.

HSU, C. K., HWANG, G. J.; CHANG, C. K., 2010. Development of a reading material recommendation system based on a knowledge engineering approach. *Computers & Education* [online], 55.1: 76-83. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S036013150900339X>.

HUANG, W., OH, S.; PEDRYCZ, W., 2014. Design of hybrid radial basis function neural networks (HRBFNNs) realized with the aid of hybridization of fuzzy clustering method (FCM) and polynomial neural networks (PNNs). *Neural Networks*, 60: 166-181.

HÚBELOVÁ, D., 2010. Analyses Textbooks Regional Geography for Primary School. *Geographical Information*, 14.1: 55-63.

HYAFIL, L.; RIVEST, R. L., 1976. Constructing optimal binary decision trees is NP-complete. *Information Processing Letters*, 5.1: 15-17.

CHEN, F., CHEN, Y.; KUO, J., 2010. Applying moving back-propagation neural network and moving fuzzy neuron network to predict the requirement of critical spare parts. *Expert Systems with Applications*, 37: 4358-4367.

CHEN, G. et al., 2014. A comparison of reading comprehension across paper, computer screens, and tablets: Does tablet familiarity matter?. *Journal of Computers in Education*, 1.2-3: 213-225.

CHIDAMBARAM, R., 2014. To become a knowledge economy. *Current Science*, 106.1: 936-941.

CHOI, S.; KIM, J.; RYU, K., 2014. Effects of context on implicit and explicit lexical knowledge: an event-related potential study. *Neuropsychologia* [online], 63: 226-34. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S002839321400308X>.

CHRÁSKA, M., 2007. *Metody pedagogického výzkumu*, Praha: Grada. ISBN 978-80-247-4.

CHU, H. C.; HWANG, G. J.; TSAI, C. C., 2010. A knowledge engineering approach to developing mindtools for context-aware ubiquitous learning. *Computers & Education* [online], 54.1: 289-297. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S0360131509002073>.

JANÍČEK, P. et al., 2013. *Expertní inženýrství v systémovém pojetí*. Praha: Grada. ISBN 978-80-247412-7-7.

JANOUSHKOVÁ, E., 2008. *Analýza učebnic zeměpisu*. Disertační práce. Brno: Masarykova univerzita.

JIFA, G., 2013. Data, Information, Knowledge, Wisdom and Meta-Synthesis of Wisdom-Comment on Wisdom Global and Wisdom Cities. *Procedia Computer Science* [online], 17: 713-719. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S1877050913002251>.

JINDRÁČEK, V.; ŠKODA, J.; DOULÍK, P., 2013. Dětské čtenářství v didaktických souvislostech a perspektivy neurovědních poznatků, *Pedagogická orientace* [online], 23.5: 691-716. Dostupné z: <http://dx.doi.org/10.5817/PedOr2013-5-691>.

JÍŘINA, M., 2003. *Jak na neuronové síť v programu STATISTICA - neuronové síť*. Praha: StatSoft. ISBN 978-80-904033-1-4.

JØRGENSEN, B. M.; BLOK, R.; ALSHOLM, A. M., 2014. Effect of feedback? The use of semantic network analysis-the case of the teacher training course goonline. In: *ICED 2014*.

- KAMIYA, N., 2015. The effectiveness of intensive and extensive recasts on L2 acquisition for implicit and explicit knowledge. *Linguistics and Education* [online], 29: 59–72. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S0898589814000801>.
- KÁRA, J., 2007. Výroba a využití bioplynu v zemědělství. ISBN 978-80-86884-28-8.
- KIM, S. et al., 2012. Neural correlates of bridging inferences and coherence processing. *Journal of Psycholinguistic Research*, 41.4: 311–321.
- KESHTKAR, F. et al., 2013. A Data Mining Approach to Construct Production Rules in an Educational Game. In: *AIED 2013 Workshops Proceedings*.
- KLÍMEK, P.; STRÍŽ, P.; KASAL, R., 2009. *Počítačové zpracování dat v programu STATISTICA*. Bučovice: Martin Stříž. ISBN 978-80-731852-6-8.
- KNECHT, P.; JANÍK, T., 2008. Učebnice z pohledu pedagogického výzkumu. In: *Učebnice z pohledu pedagogického výzkumu*. Brno: Paido, 9. ISBN 978-80-7315-174-4.
- KOHAVI, R., 1995. The power of decision tables. In: *Machine Learning: ECML-95*. Berlin: Springer, 174-189.
- KREJČOVÁ, K.; HORÁKOVÁ, T., 2017. Text mining analysis of future teachers' self-reflection: gender classification. In: *Efficiency and Responsibility in Education 14th International Conference Proceedings*. Prague: CULS Prague, 176-182. ISBN 978-80-213-2762-7.
- KVASNIČKA, R., 2013. *Interoperabilita znalostí*. Disertační práce. Praha: Česká zemědělská univerzita.
- LANCASTER, J. L. et al., 2007. Bias between MNI and Talairach coordinates analyzed using the ICBM 152 brain template. *Human brain mapping*, 28.11: 1194-1205.
- LEE, D. Y. et al., 2016. A linked data system framework for sharing construction defect information using ontologies and BIM environments. *Automation in Construction* [online], 68: 102–113. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S0926580516300838>.
- LHOTSKA, L.; MARIK, V.; VLCEK, T., 2001. Medical applications of enhanced rule-based expert systems. *International Journal of Medical Informatics* [online], 63.1-2: 61–75. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S1386505601001721>.
- LIEW, W. T.; ADHITYA, A.; SRINIVASAN, R., 2014. Sustainability trends in the process industries: A text mining-based analysis. *Computers in Industry*, 65.3: 393-400.
- LIN, C. W.; HONG, T. P.; LU, W. H., 2010. Linguistic data mining with fuzzy FP-trees. *Expert Systems with Applications*, 37.6: 4560-4567. doi: 10.1016/j.eswa.2009.12.052.
- LINDSEY, J. K., 2009. *Introduction to Applied Statistics: A modelling approach*. New York: OXFORD University Press. ISBN-10: 0198528949.

- LOMOV, P. A.; SHISHAEV, M., 2014. Visualization of Ontologies on the Basis of Cognitive Frames for Knowledge Transmission. In: *EJC*. 283-290.
- MAEDA, T., 1981. An approach toward functional text structure analysis of scientific and technical documents. *Information Processing & Management*, 17.6: 329-339.
- MALLAT, S. et al., 2015. Semantic Network Formalism for Knowledge Representation: Towards Consideration of Contextual Information. *International Journal on Semantic Web and Information Systems (IJSWIS)*, 11.4: 64-85.
- MANGEN, A.; WALGERMO, B. R.; BRØNNICK, K., 2013. Reading linear texts on paper versus computer screen: Effects on reading comprehension. *International Journal of Educational Research*, 58: 61-68.
- MAŇÁK, J., 1995. *Nárys didaktiky*. Brno: Masarykova univerzita. ISBN 80-210-1124-6.
- MAŇÁK, J.; KLAPKO, D., 2006. *Učebnice pod lupou*, Brno: Paido. ISBN 80-7315-124-3.
- MAŇÁK, J.; KNECHT, P., 2008. *Hodnocení učebnic*, Brno: Paido. ISBN 978-80-7315-148-5.
- MARTÍN-LOECHES, M. et al., 2008. Brain activation in discourse comprehension: a 3t fMRI study. *Neuroimage*, 41.2: 614-622.
- MAŘÍK, V.; KOUBA, Z., 1991. Some knowledge-acquisition methods for prospector-like systems. *Knowledge-Based Systems* [online], 4.4: 225-230. Dostupné z: <http://www.sciencedirect.com/science/article/pii/0950705191900524>.
- MARTINIK, I., 2016. Rich-media used as secondary schools as results on MERINGO project SWOT analysis. In: *Efficiency and Responsibility in Education 13th International Conference Proceedings*. Prague: CULS Prague, 349-356. ISBN 978-80-213-2646-0.
- MAŘÍK, V. et al., 1993. *Umělá inteligence 1*. Praha: Academia. ISBN 80-200-0496-3.
- MAŘÍK, V. et al., 1997. *Umělá inteligence 2*. Praha: Academia. ISBN 80-200-0504-8.
- MAŘÍK, V. et al., 2007. *Umělá inteligence 5*. Praha: Academia. ISBN 978-80-200-1470-2.
- MASON, R. A.; JUST, M. A., 2011. Differentiable cortical networks for inferences concerning people's intentions versus physical causality. *Human Brain Mapping*, 32.2: 313-329.
- MATA, L.; LAZAR, G; LAZAR, I., 2016. Exploring interactive whiteboards impact on pedagogical competences development. In: *Efficiency and Responsibility in Education 13th International Conference Proceedings*. Prague: CULS Prague, 357-365. ISBN 978-80-213-2646-0.

MAVASOGLU, M.; DINCER, S., 2014. Readability and french language teaching texts: an analysis of french language teaching websites and textbooks. *Procedia-Social and Behavioral Sciences* [online], 116: 256-259. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S1877042814002055>.

McCRORY, R.; STYLIANIDES, A. J., 2014. Reasoning-and-proving in mathematics textbooks for prospective elementary teachers. *International Journal of Educational Research*, 64: 119-131. ISSN 0883-0355.

MIKK, J., 2007. *Hodnocení učebnic*, Brno, Paido, 11-23. ISBN 978-80-7315-148-5.

MILLER, C. K.; ACHTERBERG, Ch. L., 2000. Reliability and validity of a nutrition and food-label knowledge test for women with type 2 diabetes mellitus. *Journal of Nutrition Education*, 32.1: 43-48.

MILLER, D., 2011. ESL reading textbooks vs. university textbooks: Are we giving our students the input they may need?. *Journal of English for Academic Purposes*, 10.1: 32-46. ISSN 1475-1585.

MISHRA, P.; KOEHLER, M. J., 2006. Technological pedagogical content knowledge: A framework for teacher knowledge. *Teachers College Record*, 108.6: 1017-1054. doi: 10.1111/j.1467-9620.2006.00684.x.

MLÁDKOVÁ, L., 2005. *Moderní přístupy k managementu – tacitní znalost a jak ji řídit*. C. H. Beck. ISBN 80-7179-310-8.

MOHAMMAD, A. H.; ZITAR, R. A., 2011. Application of genetic optimized artificial immune system and neural networks in spam detection. *Applied Soft Computing*, 11.4: 3827-3845.

MOCHIDA, S., 2011. Knowledge Mining for Project Management and Execution. *Journal of Advanced Computational Intelligence and Intelligent Informatics*, 15.4: 454-459. ISSN 1343-0130.

MOLINARI, G., 2015. From learners' concept maps of their similar or complementary prior knowledge to collaborative concept map: Dual eye-tracking and concept map analyses. *Psychologie Française*.

MOOR, J., 2003. *The Turing test: the elusive standard of artificial intelligence*. Springer Science & Business Media. ISBN 1-4020-1204-7.

MORADI, G.; MOHADESI, M.; MORADI, M. R., 2013. Prediction of wax disappearance temperature using artificial neural networks. *Journal of Petroleum Science and Engineering*, 108: 74-81.

MORAES, R.; VALIATI, J. F.; NETO, W. P. G., 2013. Document-level sentiment classification: An empirical comparison between SVM and ANN. *Expert Systems with Applications*, 40.2: 621-633.

MUDRYCHOVÁ, K. et al., 2017. Retrieving Knowledge from Texts: Design of an Experiment with Human Users. In: *Efficiency and Responsibility in Education 14th International Conference Proceedings*. Prague: CULS Prague, 270-278. ISBN 978-80-213-2762-7.

NAQVI, S. I. H.; HASHMI, M. A.; HUSSAIN, A., 2010. Validation of objective-type test in biology at secondary school level. *Procedia-Social and Behavioral Sciences*, 2.2: 3909-3913.

NAUMAN, T. W.; THOMPSON, J. A., 2014. Semi-automated disaggregation of conventional soil maps using knowledge driven data mining and classification trees. *Geoderma*, 213: 385-399.

NORMAN, K. A. et al., 2006. Beyond mind-reading: multi-voxel pattern analysis of fMRI data. *Trends in cognitive sciences*, 10.9: 424-430.

SILVERA, S. A. N. et al., 2014. Diet and lifestyle factors and risk of subtypes of esophageal and gastric cancers: classification tree analysis. *Annals of epidemiology*, 24.1: 50-57.

NAVIGLI, R.; PONZETTO, S. P., 2012. BabelNet: The automatic construction, evaluation and application of a wide-coverage multilingual semantic network. *Artificial Intelligence*, 193: 217-250.

NAZARI, M., 2016. The actuality of determining information need in geographic information systems and science (GIS): A context-to-concept approach. *Library & Information Science Research* [online], 38.2: 133-147. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S0740818816301025>.

NOLL, J.; SEICHTER, D.; BEECHAM, S., 2013. Can Automated Text Classification Improve Content Analysis of Software Project Data?. In: *Empirical Software Engineering and Measurement, 2013 ACM/IEEE International Symposium on IEEE*. 300-303.

NONAKA, I.; TAKEUCHI, H., 1995. *The knowledge-creating company: How Japanese companies create the dynamics of innovation* [online]. Oxford university press. Dostupné z: <http://www.sciencedirect.com/science/article/pii/0024630196815093>.

NONAKA, I.; TAKEUCHI, H., 1997. Knowledge in Organisations. *Elsevier* [online], Dostupné z: <http://www.sciencedirect.com/science/article/pii/B9780750697187500093>.

NONAKA, I. et al., 2014. Dynamic fractal organizations for promoting knowledge-based transformation – A new paradigm for organizational theory. *European Management Journal* [online], 32.1: 137-146. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S026323731300025X>.

OZURU, Y.; DEMPSEY, K.; MCNAMARA, D. S., 2009. Prior knowledge, reading skill, and text cohesion in the comprehension of science texts. *Learning and instruction*, 19.3: 228-242.

- PAICE, Ch. D., 1990. Constructing literature abstracts by computer: techniques and prospects. *Information Processing & Management*, 26.1: 171-186.
- PALA, K., 2000. *Počítačové zpracování přirozeného jazyka*. 1st edn. Brno: FI, MU.
- PEREIRA, L. et al., 2013. ICD9-based text mining approach to children epilepsy classification. *Procedia Technology*, 9: 1351-1360.
- PETRUSHIN, V. A.; KHAN, L., 2007. *Multimedia data mining and knowledge discovery*. Heidelberg: Springer.
- POPELKA, O. et al., 2014. WWW portal usage analysis using genetic algorithms. *Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis*, 57.6: 201-208.
- POŠÍK, P., 2011. *Jak na data mining v programu STATISTICA Data Miner*, Praha: StatSoft.
- PRESUTTI, V.; DRAICCHIO, F.; GANGEMI, A., 2012. Knowledge extraction based on discourse representation theory and linguistic frames. In: *International Conference on Knowledge Engineering and Knowledge Management*. Berlin: Springer, 114-129.
- PRŮCHA, J., 1984. *Hodnocení obtížnosti učebnic: Struktury a parametry učiva*. Výzkumný ústav odborného školství.
- PRŮCHA, J., 1998. *Učebnice: Teorie a analýzy edukačního média*. Brno: Paido. ISBN 80-8593-149-4.
- PRŮCHA, J., 2006. Učebnice: Teorie, výzkum a potřeby praxe. In: MAŇÁK, J.; KLAPKO, D. *Učebnice pod lupou*. Brno: Paido, 9-21. ISBN 80-7315-124-3.
- PŮLPÁN, Z., 2012. *Odhad informace z dat vágní povahy*. Academia. ISBN 978-80-200-2076-5.
- PUNIŠKIS, D.; LAURUTIS, R.; DIRMEIKIS, R., 2015. An artificial neural nets for spam e-mail recognition. *Elektronika ir Elektrotechnika*, 69.5: 73-76.
- PUNITHA, S. C.; PUNITHAVALLI, M., 2012. Performance evaluation of semantic based and ontology based text document clustering techniques. *Procedia Engineering*, 30: 100-106.
- QUINLAN, J. R., 1986. Induction of decision trees. *Machine learning*, 1.1: 81-106.
- QUINLAN, J. R., 1987. Generating Production Rules from Decision Trees. In: *IJCAI*. 304-307.
- RÁBOVÁ, I., 2012. Methods of Business Rules Harvesting in University Environment. In: *9th International Scientific Conference on Distance Learning in Applied Informatics*. Sturovo, Slovakia, 261-267.

RAUCHOVÁ, T., 2012a. *Vyhledávání znalostí v textech*. Diplomová práce. Praha: Česká zemědělská univerzita.

RAUCHOVÁ, T., 2012b. Design of an Experiment for Measuring the Efficiency of Knowledge Texts. *PEFnet2012, Mendel University in Brno*.

RAUCHOVÁ, T.; HOUŠKA, M., 2013a. Efficiency of Knowledge Transfer through Knowledge Texts: Statistical Analysis. *Journal on Efficiency and Responsibility in Education and Science*, 6.1: 46-60. ISSN: 1803-1617.

RAUCHOVÁ, T.; HOUŠKA, M., 2013b. A Calculation Scheme for Measuring the Efficiency of Knowledge Texts for Vocational Education. *Procedia - Social and Behavioral Sciences*, 106: 10-19. ISSN: 1877-0428.

RAUCHOVÁ, T. et al., 2013. Time efficiency of knowledge codification for vocational education. In: *Efficiency and Responsibility in Education 10th International Conference Proceedings*. Prague: CULS Prague, 534-541. ISBN 978-80-213-2378-0.

RAUCHOVÁ, T. et al., 2014. Comparative Analysis of Quantitative Indicators of Normal and Knowledge Texts. In: *10th International Scientific Conference on Distance Learning in Applied Informatics*. Štúrovo, Slovakia: Wolters Kluwer, 621-632. ISBN 978-80-7478-497-2.

RAZI, M. A.; ATHAPPILLY, K., 2005. A comparative predictive analysis of neural networks (NNs), nonlinear regression and classification and regression tree (CART) models. *Expert Systems with Applications*, 29.1: 65-74.

RAJAN, K. et al., 2009. Automatic classification of Tamil documents using vector space model and artificial neural network. *Expert Systems with Applications*, 36.8: 10914-10918.

REICHEL, M. et al., 2014. Talk to me personally: Personalization of language style in computer-based learning. *Computers in Human Behavior*, 35: 199-210. doi: 10.1016/j.chb.2014.03.005.

ROBERTSON, D. A. et al., 2000. Functional neuroanatomy of the cognitive process of mapping during discourse comprehension. *Psychological science*, 11.3: 255-260.

ROKACH, L., 2016. Decision forest: Twenty years of research. *Information Fusion*, 27: 111-125.

ROKACH, L.; MAIMON, O., 2014. *Data Mining with Decision Trees: Theory and Applications*. Singapore: World Scientific Publishing.

ROSENBERG, N.; STEINMUELLER, W. E., 2013. Engineering knowledge. *Industrial and Corporate Change*, 22.5: 1129-1158.

RYDVAL, J.; BARTOSKA, J.; BROZOVA, H., 2014. Semantic Network in Information Processing for the Pork Market. *Agris on-line Papers in Economics and Informatics*, 6.3: 59. ISSN 1804-1930.

SAATY, T. L.; LIEM, T., 2010. Fuzzy Judgement and Fuzzy Sets. *International Journal of Strategic Decision Sciences*, 2010, 1.1: 23-40.

SAMATOVA, N. F. et al., 2013. *Practical graph mining with R*. Boca Raton: CRC Press, 2013. ISBN 13:978-1-4398-6084-7.

SEDLAČÍKOVÁ, B. 2012. Matematická lingvistika. *Historie matematické lingvistiky*, 5-7. ISBN 978-80-7204-815-1.

SHAO, Y.; LUNETTA, R. S., 2012. Comparison of support vector machine, neural network, and CART algorithms for the land-cover classification using limited training data points. *ISPRS Journal of Photogrammetry and Remote Sensing*, 70: 78-87.

SHI, G. 2014. *Chapter 7 - Cluster Analysis*. Elsevier, Oxford.

SCHULTZ, T. L., 2012. Technical tips: MRI compatible EEG electrodes: advantages, disadvantages, and financial feasibility in a clinical setting. *The Neurodiagnostic Journal*, 52.1: 69-81.

SCHUGAR, J. T.; SCHUGAR, H. R., 2014. Reading in the post-PC era: Students' comprehension of interactive e-books. *Paper presented as the American Educational Research Association, Philadelphia, PA*.

SINGER, F. M.; MOSCOVICI, H., 2008. Teaching and learning cycles in a constructivist approach to instruction. *Teaching and Teacher Education*, 24.6: 1613-1634.

SKALKOVÁ, J., 2007. *Obecná didaktika - 2. rozšířené a aktualizované vydání*. Grada. ISBN 978-80-1247-1821-7.

SKLENÁK, V., 2001. *Data, informace, znalosti a Internet*. Praha: C. H. Beck. ISBN 80-7179-409-0.

SLAVÍK, M., 2012. *Vysokoškolská pedagogika*. Grada, 2012. ISBN 978-80-247-4054-6.

SMART, O.; BURRELL, L., 2015. Genetic programming and frequent itemset mining to identify feature selection patterns of iEEG and fMRI epilepsy data. *Engineering applications of artificial intelligence*, 39: 198-214.

SOWA, J. F., 2014. *Principles of semantic networks: Explorations in the representation of knowledge*. Morgan Kaufmann. ISBN-13: 9781483207711.

SPEER, N. K. et al., 2009. Reading stories activates neural representations of visual and motor experiences. *Psychological science*, 20.8: 989-999.

SPITZER, M., 2014. Information technology in education: Risks and side effects. *Trends in Neuroscience and Education*, 3.3: 81-85.

SPITZER, M., 2012. Education and neuroscience. *Trends in Neuroscience and Education* [online], 1.1: 1-2. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S2211949312000075>.

STARÝ, K.; CHVÁL, M., 2009. Kvalita a efektivita výuky: metodologické přístupy. In: JANÍKOVÁ, M. et al. *Výzkum výuky: Tematické oblasti, výzkumné přístupy a metody*. Brno: Paido, 63-81. ISBN 978-80-7315-180-5.

SRIVASTAVA, A. N.; SAHAMI, M., 2009. *Text mining: Classification, clustering, and applications*. New York: CRC Press. ISBN 978-142-0059403.

SZYMCZYK, P.; SZYMCZYK, M., 2015. Classification of geological structure using ground penetrating radar and Laplace transform artificial neural networks. *Neurocomputing*, 148: 354-362.

SIMEK, P. et al., 2012. Using metadata description for agriculture and aquaculture papers. *Agris on-line Papers in Economics and Informatics*, 4.4: 79. ISSN 1804-1930.

ŠTUKA, Č. et al., 2013. *Testování při výuce medicíny. Konstrukce a analýza testů na lékařských fakultách*. Praha: Karolinum. ISBN 978-80-246-2369-6.

TANNENBERGOVÁ, P., 2009. Učebnice dějepisu pro 6. ročník základní školy z pohledu jejich didaktické vybavenosti. *E-pedagogium*, 5: 108-121.

TANNENBERGOVÁ, P., 2011. Učebnice dějepisu pro 6. ročník ZŠ z pohledu hodnocení obtížnosti jejich výkladového textu. In: DOLEŽELOVÁ, J. *Vybrané problémy oborové didaktiky dějepisu 4 (v disertačních pracích studentů doktorských studijních programů)*. Brno: Masarykova univerzita, 6-16. ISBN 978-80-210-5587-2.

TARCHI, Ch., 2010. Reading comprehension of informative texts in secondary school: A focus on direct and indirect effects of reader's prior knowledge. *Learning and Individual Differences*, 20.5: 415-420. doi: 10.1016/j.lindif.2010.04.002.

TAYYEBI, A.; PIJANOWSKI, B. C., 2014. Modeling multiple land use changes using ANN, CART and MARS: Comparing tradeoffs in goodness of fit and explanatory power of data mining tools. *International Journal of Applied Earth Observation and Geoinformation*, 28: 102-116.

TINKLER, S.; WOODS, J., 2013. The readability of principles of macroeconomics textbooks. *The Journal of Economic Education*, 44.2: 178-191. doi: 10.1080/00220485.2013.770345.

TOBIN, D. R., 1996. *Transformational learning: Renewing your company through knowledge and skills*. John Wiley & Sons. ISBN 0-471-13289-6.

TRUNEČEK, J., 2004. *Management znalostí*. C. H. Beck. ISBN 80-7179-884-3.

TSOKOS, C.; WOOTEN, R., 2016. Chapter 8 - Basic Statistics. In: *The Joy of Finite Mathematics* [online]. Boston: Academic Press, 265-327. ISBN 9780128029671. Dostupné z: <https://doi.org/10.1016/B978-0-12-802967-1.00008-5>.

TUDOR, S. L., 2012. A study on the efficiency of using combined modern and traditional didactic strategies. *Procedia-Social and Behavioral Sciences*, 33: 989-993.

VACULOVÁ, I., 2008. Dovednosti žáků základní školy ve výuce fyziky: výzkum dovedností a procesu jejich osvojování. *Pedagogická orientace*, 18.2: 3-21.

WANG, L.-W. et al., 2013. Assessing readability formula differences with written health information materials: application, results, and recommendations. *Research in Social and Administrative Pharmacy*, 9.5: 503-516.

WANG, X. et al., 2016. From numeric data to information granules: A design through clustering and the principle of justifiable granularity. *Knowledge-Based Systems*, 101: 100-113.

WOLFF, K.; LUCKETT, K., 2013. Integrating multidisciplinary engineering knowledge. *Teaching in Higher Education*, 18.1: 78-92.

ZAINAL, A., 2012. Validation of an ESL writing test in a Malaysian secondary school context. *Assessing Writing*, 17.1: 1-17.

ZDRAHAL, Z. et al., 2007. Worlds and transformations: Supporting the sharing and reuse of engineering design knowledge. *International Journal of Human-Computer Studies*, 65.12: 959-982.

ZENIL, H.; KIANI, N. A.; TEGNÉR, J., 2016. Methods of information theory and algorithmic complexity for network biology. In: *Seminars in cell & developmental biology*. Academic Press, 51: 32-43.

ZHANG, Y. et al., 2016. Market reaction to internet news: Information diffusion and price pressure. *Economic Modelling*, 56: 43-49. ISSN 02649993. doi: 10.1016/j.econmod.2016.03.020.

7 Seznam obrázků

Obrázek 1 Schéma metodiky disertační práce; zdroj: autorka.....	12
Obrázek 2 Ukázka obecného rozhodovacího stromu, zdroj: Mařík et al., (1993), zpracování vlastní.....	26
Obrázek 3 Model neuronu, zdroj: Jiřina (2003).....	41
Obrázek 4 Schéma výzkumné části disertační práce, zdroj: autorka	47
Obrázek 5 Transfer znalostí, zdroj: autorka.....	51
Obrázek 6 Návrh metodiky tvorby znalostně strukturovaného textu; zdroj: autorka.....	52
Obrázek 7 Schéma experimentu I; zdroj: autorka.....	56
Obrázek 8 Experiment I: 1. krok – podrobná rešerše, konceptualizace, výběr ukazatelů; zdroj: autorka.....	57
Obrázek 9 Experiment I: 2. krok – Příprava běžně strukturovaných textů; zdroj: autorka.....	60
Obrázek 10 Experiment I: 3. krok – Kodifikace znalostí, tvorba znalostně strukturovaných textů; zdroj: autorka	60
Obrázek 11 Experiment I: 4. krok – Analýza textů – didaktická analýza, zpracování dat a statistická analýza; zdroj: autorka	61
Obrázek 12 Box ploty pro vybrané parametry znalostně strukturovaného textu (ZST) a běžně strukturovaného textu (BST), zpracováno v programu Statistica12; zdroj: autorka.....	67
Obrázek 13 Experiment I: 5. krok – Klasifikace vzdělávacích textů pomocí metod umělé inteligence; zdroj: autorka	68
Obrázek 14 Importance vybraných pojmů pro závislou proměnnou typ textu; zdroj: autorka.....	72
Obrázek 15 Struktura klasifikačního stromu CART 1 (report z programu STTISTICA 12, StatSoft); zdroj: autorka	72
Obrázek 16 Struktura klasifikačního stromu CART 2 (report z programu STTISTICA 12, StatSoft); zdroj: autorka	73
Obrázek 17 Struktura klasifikačního stromu CART 3 (report z programu STTISTICA 12, StatSoft); zdroj: autorka	73
Obrázek 18 Grafické zobrazení klasifikačního stromu CART 3; zdroj: autorka	74
Obrázek 19 Souhrnná importance za všechny 4 modely; zdroj: autorka	75
Obrázek 20 Ukázka jednoho z modelů bigML se zaměřením na jeho pravou krajní větev, zpracováno v machine learning systému bigML; zdroj: autorka.....	75
Obrázek 21 Grafické zobrazení přesnosti predikce jednotlivých nástrojů umělé inteligence, zdroj: autorka.....	76
Obrázek 22 Experiment I: 6. krok – Syntéza dosažených výsledků; zdroj: autorka	80
Obrázek 23 Schéma experimentu II; zdroj: autorka.....	86
Obrázek 24 Experiment II: 1. krok – Podrobná rešerše, konceptualizace, výběr domény; zdroj: autorka	87
Obrázek 25 Experiment II: 2. krok – Kodifikace znalostí a tvorba brožur; zdroj: autorka	88
Obrázek 26 Experiment II: 3. krok – Tvorba metodiky testování, pilotní šetření, testování nástrojů experimentu; zdroj: autorka	89
Obrázek 27 Histogramy proměnné P_{PRE} (vlevo) a P_{POST} (vpravo), pilot, experiment II; zdroj: autorka	94
Obrázek 28 Histogramy proměnné $K_{T_{netto}}$ (vlevo) a TST (vpravo), pilot, experiment II; zdroj: autorka	94
Obrázek 29 Histogramy proměnné K_{T_K} (vlevo) a K_{T_O} (vpravo), pilot, experiment II; zdroj: autorka.....	95
Obrázek 30 Box-plot znázorňující vliv rozdílnosti typu textu na průměrný transfer znalostí; zdroj: autorka.....	95
Obrázek 31 Box-ploty znázorňující vliv rozdílnosti tématu suboblastí problémové domény na průměrný transfer znalostí, pilot, experiment II; zdroj: autorka	96
Obrázek 32 Histogramy u výsledků posttestů u skupiny B (vlevo) a A (vpravo), pilot, experiment II; zdroj: autorka	97
Obrázek 33 Grafické znázornění percentilového pořadí u skupiny A a B, pilot experiment II; zdroj: autorka	102
Obrázek 34 Experiment II: 4. krok – Výběr respondentů, realizace experimentu; zdroj: autorka.....	106
Obrázek 35 Experiment II: 5. krok – Zpracování dat, statistická analýza; zdroj: autorka.....	106

Obrázek 36 Histogram proměnné P_{PRE} , experiment II; zdroj: autorka	109
Obrázek 37 Histogram proměnné P_{POST} , experiment II; zdroj: autorka	109
Obrázek 38 Histogram proměnné KT_{netto} , experiment II; zdroj: autorka	110
Obrázek 39 Histogram proměnné KT_O , experiment II; zdroj: autorka	110
Obrázek 40 Histogram proměnné KT_K , experiment II; zdroj: autorka	111
Obrázek 41 Vliv typu textu na průměrnou délku studia brožury; zdroj: autorka	113
Obrázek 42 Vliv věkové kategorie na průměrnou délku studia brožury; zdroj: autorka	114
Obrázek 43 Histogramy odlišnosti textů v závislosti na variantě brožury: a) A, B se liší od C, D v závislosti na variantě textu; b) A, C se liší od B, D v závislosti na variantě textu; c) A, D se liší od B, C v závislosti na variantě textu; zdroj: autorka	116
Obrázek 44 Experiment II: 6. krok - Syntéza dosažených výsledků; zdroj: autorka	116
Obrázek 45 Schéma experimentu III - oblasti; zdroj: autorka	120
Obrázek 46 Experiment III - 1. krok - Podrobná rešerše, konceptualizace, výběr neurotechnologie; zdroj: autorka	121
Obrázek 47 Experiment III - 2. krok - Kodifikace znalostí a tvorba textových fragmentů; zdroj: autorka	124
Obrázek 48 Experiment III - 3. krok – Tvorba metodiky experimentu, pilotní experiment; zdroj: autorka	124
Obrázek 49 Experiment III - 4. krok – Výběr probandů, realizace experimentu; zdroj: autorka	126
Obrázek 50 Experiment III - 5. krok – Zpracování dat, statistická analýza; zdroj: autorka	127
Obrázek 51 Mozkové regiony s vyšší aktivitou při čtení textu Sent A než při baseline (Poznámka: L = levá strana, P = pravá strana.); zdroj: autorka	129
Obrázek 52 Mozkové regiony s vyšší aktivitou při čtení textu Sent B než při baseline (Poznámka: L=levá strana, P = pravá strana.); zdroj: autorka	132
Obrázek 53 Mozkové regiony s vyšší aktivitou při čtení textu Sent B než Sent A (Poznámka: L = levá strana, P = pravá strana.); zdroj: autorka	135
Obrázek 54 Box plot pro průměrný počet přesných odpovědí (správně určena pravdivost textu); zdroj: autorka	138
Obrázek 55 Box ploty pro průměrný reakční čas; zdroj: autorka	139
Obrázek 56 Experiment III - 6. krok – Příležitosti budoucího výzkumu; zdroj: autorka	140
Obrázek 57 Oblasti možného dalšího zaměření výzkumu znalostně strukturovaných textů; zdroj: autorka	140

8 Seznam tabulek

<i>Tabulka 1 Základní popisné statistiky pro běžně a znalostně strukturované texty; zdroj: autorka</i>	<i>62</i>
<i>Tabulka 2 Statistická analýza, výsledky párového T testu; zdroj: autorka.....</i>	<i>66</i>
<i>Tabulka 3 Platnost pracovních hypotéz; zdroj: autorka.....</i>	<i>68</i>
<i>Tabulka 4 Charakteristiky umělých neuronových sítí; zdroj: autorka</i>	<i>70</i>
<i>Tabulka 5 Schopnost klasifikace jednotlivých neuronových sítí (report z programu Satistica); zdroj autorka</i>	<i>71</i>
<i>Tabulka 6 testová kritéria pro 40 operativních hypotéz; zdroj: autorka.....</i>	<i>77</i>
<i>Tabulka 7 Popisné statistiky sledovaných proměnných, pilot, experiment II; zdroj: autorka</i>	<i>93</i>
<i>Tabulka 8 P hodnoty Shapiro-Wilkova testu, pilot, experiment II; zdroj: autorka</i>	<i>93</i>
<i>Tabulka 9 Didaktická analýza posttestu u skupiny A, pilot, experiment II; zdroj: autorka</i>	<i>98</i>
<i>Tabulka 10 Didaktická analýza posttestu u skupiny B, pilot, experiment II; zdroj: autorka.....</i>	<i>99</i>
<i>Tabulka 11 Popisné statistiky didaktických charakteristik testů, pilot, experiment II; zdroj: autorka</i>	<i>103</i>
<i>Tabulka 12 T test a F test pro vybrané didaktické charakteristiky, pilot, experiment II; zdroj: autorka</i>	<i>103</i>
<i>Tabulka 13 Popisné statistiky sledovaných proměnných experimentu II; zdroj: autorka</i>	<i>108</i>
<i>Tabulka 14 P hodnoty Shapiro-Wilkova testu, proměnné experimentu II; zdroj: autorka.....</i>	<i>108</i>
<i>Tabulka 15 Absolutní četnosti obtížnosti textu v závislosti na tématu; zdroj: autorka.....</i>	<i>114</i>
<i>Tabulka 16 Doprovodná skupinová statistika za 24 probandů pro mozkové regiony s vyšší aktivitou při čtení textu Sent A než při baseline (Poznámka: L = left; R = right; g = gyrus; SMA = supplementary motor area.); zdroj: autorka.....</i>	<i>130</i>
<i>Tabulka 17 Doprovodná skupinová statistika za 24 probandů pro mozkové regiony s vyšší aktivitou při čtení textu Sent A než při baseline (Poznámka: L = left; R = right; g = gyrus; SMA = supplementary motor area.); zdroj: autorka.....</i>	<i>131</i>
<i>Tabulka 18 Doprovodná skupinová statistika za 24 probandů, pro mozkové regiony s vyšší aktivitou při čtení textu Sent B než při baseline (Poznámka: L = left; R = right; g = gyrus; SMA = supplementary motor area.); zdroj: autorka</i>	<i>133</i>
<i>Tabulka 19 Doprovodná skupinová statistika za 24 probandů, pro mozkové regiony s vyšší aktivitou při čtení textu Sent B než při baseline (Poznámka: L = left; R = right; g = gyrus; SMA = supplementary motor area.); zdroj: autorka</i>	<i>134</i>
<i>Tabulka 20 Doprovodná skupinová statistika za 24 probandů pro mozkové regiony s vyšší aktivitou při čtení textu Sent B než při Sent A (Poznámka: L = left; R = right; g = gyrus.); zdroj: autorka.....</i>	<i>136</i>
<i>Tabulka 21 Doprovodná skupinová statistika za 24 probandů pro mozkové regiony s vyšší aktivitou při čtení textu Sent B než při Sent A (Poznámka: L = left; R = right; g = gyrus.); zdroj: autorka.....</i>	<i>137</i>

9 Přílohy

Příloha 1: Informovaný souhlas s účastí ve výzkumné studii v rámci Experimentu III

Příloha 2: T. S. Eliot: Ukázka z básně The Rock (1934) v původním jazyce

Příloha 3: Ukázka běžně strukturovaného a znalostně strukturovaného textového fragmentu v anglickém jazyce, zdroj: Horáková a Houška, 2014b

Příloha 1

Informovaný souhlas s účastí ve výzkumné studii

Vážený účastníku,

děkujeme za Váš zájem o účast ve studii, která má za cíl sledovat vaši reakci na různé typy textových fragmentů pomocí funkční magnetické rezonance (fMRI).

Co je MRI?

MRI je neinvazivní vyšetřovací metoda, která umožňuje zobrazovat strukturu, popř. také složení či funkci tkání v lidském těle a to za pomoci statického magnetického pole s velkou magnetickou indukcí a slabých proměnlivých magnetických polí a radiofrekvenčních pulzů. Vyšetření je zcela nebolestivé. Vzhledem k silnému magnetickému poli je však nutné dodržovat bezpečnostní zásady. Vyšetření např. nesmí podstoupit osoba s magneticky vodivými implantáty nebo kardiostimulátorem. K vyšetření MRI se používají přístroje označované jako MR tomografy nebo také MR skenery.

Co je fMRI?

Funkční magnetická rezonance (fMRI) je neinvazivní zobrazovací vyšetřovací metoda, která sleduje aktivitu jednotlivých mozkových oblastí s využitím MR tomografu. Vyšetření je zcela nebolestivé. Od vyšetřovaného jedince je pouze požadováno, aby ležel v klidu v MR tomografu a případně dle pokynů vykonával jednoduchý úkol.

Jak bude projekt probíhat?

Vlastní MR vyšetření bude sestávat z několika úseků.

1. anatomický snímek, cca 5 minut

Před tímto měřením Vás pouze požádáme, abyste ležel/a v klidu.

2. fMRI měření s vizuální stimulací, cca 18 minut

V průběhu tohoto úseku budete sledovat textové fragmenty, které se budou objevovat na zobrazovacím zařízení ve vašem zorném poli. Váš úkol bude pozorně číst texty a snažit se zapamatovat jejich obsah.

3. fMRI měření při určování pravdivosti tvrzení, cca 10 minut

Laborant Vám promítne na zobrazovací zařízení několik tvrzení v souvislosti s předchozími zobrazenými texty. Vy budete určovat pomocí hlasovacího zařízení pravdivost tvrzení (levé tlačítko PRAVDA, pravé NEPRAVDA). Pokuste se odpovědět správně.

Budete instruováni po celou dobu vyšetření ležet v klidu bez pohnutí, ale uvolněně. Mezi jednotlivými úseky s Vámi bude komunikovat obsluha přístroje.

Během fMRI měření bude probíhat také záznam srdeční činnosti (metoda se nazývá elektrokardiografie – EKG) ze 4 elektrod, z nichž 2 budou umístěny nad horní částí hrudní kosti a 2 pod levý spodní okraj hrudního koše. Dále bude snímán pohyb hrudního koše pomocí dýchacího pásu umístěného na břichu a kožní vodivost pomocí dvou elektrod umístěných na ukazováku a prostředníku jedné ruky.

Vyšetření proběhne jednorázově, jedná se tedy o 1 návštěvu, která celkem zabere asi cca 45 minut (z toho cca 33 minut vlastní MR vyšetření). Při této studii Vám nebudou podávány žádné léky ani nebude prováděn odběr krve či jiných biologických vzorků.

Bezpečnost a možné nežádoucí účinky/rizika vyšetření pomocí MR, EKG, dýchacího pásu a snímání kožní vodivosti

Před vyšetřením na magnetické rezonanci budete dotázáni personálem na přítomnost kovových materiálů v těle a na jakékoliv jiné implantáty. Vyšetření nelze provést u osob, v jejichž těle nebo na jeho povrchu se nachází předmět z magnetických kovů. Kardiostimulátor či jiný přístroj ovlivnitelný magnetickým polem vylučuje provedení tohoto vyšetření.

Přítomnost nevhodných kovových materiálů či elektronických zařízení ve Vašem těle by mohla vážně či fatálně poškodit Vaše zdraví. Mnoho nových implantátů a zařízení je již koncipováno jako MR kompatibilních, avšak toto musí být doloženo certifikací výrobce nebo zdravotní zprávou od ošetřujícího lékaře. Možnost vyšetření posoudí odborný pracovník z pracoviště magnetické rezonance a má právo vyšetření odmítnout, pokud se bude domnívat, že by mohlo být poškozeno Vaše zdraví.

Účast ve studii Vám rovněž nedoporučujeme, pokud máte na těle rozsáhlé tetování nebo jste-li těhotná žena.

Vlastní magnetické pole v přístroji magnetické rezonance je zdraví neškodné, v některých případech můžete pouze po dobu vyšetřování cítit nepohodlí z uzavřeného prostoru a ze zvuku, který souvisí s činností přístroje. Vzácně můžete mít pocit kovu v ústech nebo pocit blikajících světél. Vzhledem k omezenému prostoru při vyšetření v MR tomografu může být vyšetření nerealizovatelné, pokud trpíte klaustrofobií. Pokud jste si tohoto vědom/a, oznamte to, prosím, výzkumníkovi nebo komukoliv z personálu MR pracoviště.

EKG snímání je rovněž zcela bezpečné rutinní vyšetření spočívající v záznamu slabé elektrické aktivity srdce. Určité nepohodlí zde může způsobit fixace elektrod lepením a jejich následné odlepení po skončení měření. Snímání kožní vodivosti je také zcela bezpečné, určité nepohodlí zde může způsobit fixace elektrod lepením a jejich následné odlepení po skončení měření.

Potvrzuji, že jsem byl/a seznámen/a s průběhem experimentu, rozumím mu a souhlasím s jeho provedením.

Jméno a příjmení (vyplňte hůlkovým písmem): _____

Datum a místo: _____

Podpis probanda: _____

Příloha 2

Choruses from "The Rock"

I

The Eagle soars in the summit of Heaven,
The Hunter with his dogs pursues his circuit.
O perpetual revolution of configured stars,
O perpetual recurrence of determined seasons,
O world of spring and autumn, birth and dying!
The endless cycle of idea and action,
Endless invention, endless experiment,
Brings knowledge of motion, but not of stillness;
Knowledge of speech, but not of silence;
Knowledge of words, and ignorance of the Word.
All our knowledge brings us nearer to our ignorance,
All our ignorance brings us nearer to death,
But nearness to death no nearer to GOD.
Where is the Life we have lost in living?
Where is the wisdom we have lost in knowledge?
Where is the knowledge we have lost in information?
The cycles of Heaven in twenty centuries
Bring us farther from GOD and nearer to the Dust.

Příloha 3: Ukázka běžně strukturovaného a znalostně strukturovaného textového fragmentu v anglickém jazyce, zdroj: Horáková a Houška, 2014b

Originál textového fragmentu je psán v českém jazyce (Kára, 2007). Vybraný textový fragment byl přeložen a upaven do podoby běžně strukturovaného textu:

"The waste arisen from industry production differs in comparison with the one arisen from households in more properties. It differs in the composition influenced with the kind of the production. It can often contain elements, which are of the hazardous character for people as well as for the nature (toxic, explosive, flammable, etc.). That is the reason for special manipulation for such waste. Individual productions generate waste of different properties and thus there is no unique procedure for processing it. Waste from the chemical productions is often really dangerous and has to be modified before processing. Metallurgy also produces a large amount of dangerous waste. Food productions generate waste that could be transformed into a fertilizer and used in agriculture. Building industry can often recycle the waste in order to be re-used for the production of building materials or for building the houses."

Znalostně strukturovaný textový fragment vytvořený dle metodiky Houšky a Rauchové (2013) vypadá následovně:

"If we consider the waste arisen from industry production and describe its properties, then it differs from the households one in more characteristics influenced with the source of the waste. If it contains elements denoted as hazardous for people or nature (toxic, explosive, flammable, etc.), then we should manipulate with the waste carefully. When we consider the industrial waste and describe its processing, we should bear in mind that each production generates a different kind of the waste, and thus there is no unique way of processing the waste. If dangerous waste is processed, the manipulation procedure should be described in detail in order to prevent the consequences to the environment, e.g. using the modification of the waste from chemical production aimed at the reduction of the content of the toxic metals, such as cadmium, nickel, lead, etc. When we deal with the waste processing and aim at exploiting the maximum value obtained from the waste, then we can e.g. transform the food production waste into fertilizers, building production waste into building material, etc."