Strojové učení

Začíná 21. století. Očekává se, že to bude století informačních technologií, **informační a znalostní společnosti**. Zde se zamyslím nad znalostmi, které jsou základem znalostních (počítačových) systémů, a hlavně nad tvorbou znalostí. Ve všech oblastech lidské činnosti se neustále intenzivněji a intenzivněji prohlubuje poznání. Vytváří a upřesňují se příslušné teorie. Uplatňuje se matematika a formální přístupy k popisu těchto teorií. Teorie pak umožňují tyto oblasti algoritmizovat, umožňují převést teoretické znalosti do znalostního systému. Teorie mají ale jen omezený rozsah platnosti. Přesto je třeba je spojovat, řešit rozsáhlejší systémy, pokrývající více oblastí najednou. Je také třeba využívat je společně se zkušenostmi s jejich využitím. Tyto zkušenosti – znalosti už nebývají tak přesné, jako teoretické znalosti, mohou mít heuristický charakter, přesto mohou být velmi užitečné. Hrají, a ještě více budou hrát roli jakéhosi lepidla. To je důležitá integrační role. Ve znalostních systémech budou tedy hrát důležitou roli jak znalosti teoretické tak heuristické.

Do znalostních systémů se dnes znalosti dostávají převážně "ručně" prostřednictvím znalostních inženýrů, pomocí technologie nazývané znalostní inženýrství. Dostat znalosti do znalostních systémů ručně je ale hrozně **pracné**. Na začátku osmdesátých let, když se se znalostními systémy začínalo, se jednalo o systémy s desítkami pravidel (znalostí). I ty daly dost práce. Dnes ale, v snad největším systému CYC je už cca 10^6 převážně ručně nashromážděných obecných tvrzení (znalostí). Také ho 17 let vyvíjí rozsáhlý tým a je střídavě zatracován i oslavován, protože se střídavě zdá, že jde o beznadějné nebo zase velmi nadějné úsilí. Velkou pracnost je třeba omezit, tvorbu znalostí je třeba automatizovat. Na využití znalostí je orientována disciplína umělé inteligence (artificial intelligence, AI), na jejich automatizované vytváření část umělé inteligence - disciplína strojové učení (machine learning, **ML**). Strojové učení je jádrem současné umělé inteligence, a jeho rozvoj je hlavním předpokladem jejího dalšího rozvoje. Strojové učení je prakticky, až na název, shodné s velice moderní až módní disciplínou, nazývanou dobývání znalostí z databází (data mining). Když uvažuji o strojovém učení, mám tedy na mysli současně i tuto disciplínu.

Úspěchy a paradoxy

Strojové učení dosahuje **úspěchů**, jeho aplikace jsou právem oslavovány. Najdeme je v takových prestižních společnostech jako jsou Master Card, American Express nebo DaimlerChrysler, v oblastech jako je marketing, předvídání vývoje cen akcií, detekce peněžních podvodů, lékařská i technická diagnostika a robotí kopaná. Proto by vás mohlo překvapit, když uvidíte roboty nebo budete číst o robotech, kteří se dostávají do zjevně pro ně obtížně řešitelných nebo přímo neřešitelných situací. Vy přitom víte, že používají nebo mohou používat ty tak úspěšné technologie strojového učení. Nebo můžete číst o experimentu se strojovým učením, který vyřeší matematický problém nalezení všech rozkladů množiny na podmnožiny s 90%ní přesností, zatímco matematik nebo program, který jsem si pro to udělal, ho řeší s přesně 100%ní přesností. Nebo můžete sledovat diskusi na Internetu, kde se referuje o neuronové síti, která s počtem skrytých neuronů krásně zvyšuje přesnost rozpoznání parity[1]. Při 10 neuronech až někam k přesnosti 99,3%. Vy ale víte, že existují další přístupy strojového učení, které problém řeší přímo s přesně 100%ní přesností. To jsou **paradoxy.** Ilustrují kritiku, které zde chci strojové učení podrobit.

Byl jsem loni v létě v Berlíně na **ECAI 2000**. To je nejdůležitější evropská konference o umělé inteligenc. Svou **úvahu** o strojovém učení jsem původně chtěl založit na poznatcích a přímých dojmech z této konference. Ale stav strojového učení se nemění rychle. ECAI ho pouze potvrdila a podobně ho potvrdily další události roku 2000, např. specializovanější ICML 2000 (International Conference on

[1] Tj. rozpoznání, zda je v množině nul a jedniček sudý počet jedniček.

Machine Learning – Mezinárodní konference o strojovém učení), nebo jeden workshop AAAI 2000, věnovaný přímo budoucnosti strojového učení. Je to možné nějak shrnout? Jaké je strojové učení? Jaká je evropská umělá inteligence? Jaká je v porovnání s ní česká umělé inteligence a strojové učení?

Myslím, že je možné udělat tyto závěry:

1. strojovému učení (a umělé inteligenci) se věnuje velká pozornost
2. přesto je ve strojovém učení patrná jakoby určitá stagnace
3. ale jsou patrné i náznaky nazrávání (velké?) změny
4. u nás se strojovému učení a umělé inteligenci věnuje poměrně velmi malá pozornost.

Stagnace spočívá v tom, že se uvedené a podobné další paradoxy dost intenzivně neřeší, i když by se řešit měly a mohly. V dalším tato tvrzení rozvedu. První a poslední závěry si nechám nakonec.

Učení není učení

Začnu **definicí** strojového učení[2] podle dnes snad nejuznávanější učebnice strojového učení (Mitchell, 1997): Systém se **učí**, jestliže se jeho výkonnost na dané třídě úloh zlepšuje se získáváním zkušeností. Myslím, že to je dobrá definice. Zobecňuje a shrnuje současné nejdůležitější filosoficko-biologicko-psychologicko-informatické představy o učení. Panuje také o ní neobyčejná shoda. Definice je hodně obecná (vágní), protože je založena na obecných pojmech zkušenost, třída úloh a výkonnost. Proto ji Mitchell nahrazuje **konkrétnější definicí**. Ta říká, že na učení je užitečné se dívat jako na vytvoření nějaké funkce. Popis takové funkce můžeme považovat za znalost. Příkladem znalosti může být pravidlo, určující, zda a jak má robot-fotbalista přihrát, odpovídající funkce je schopnost přihrát. Taková funkce může záviset na mnoha proměnných, jako je pozice přihrávajícího, spoluhráčů, protihráčů, rychlosti vystřeleného míče, rychlosti hráčů apod. Funkce se vytváří na základě konkrétních zkušeností, např. zkušeností popisujících situace vedoucí na úspěšnou, nebo neúspěšnou přihrávku. Návrháři vítěze RoboCup 99 (viz dále) např. použili 5000 situací popsaných 174 proměnnými, aby naučili roboty přihrávat. V učení jde o takové zobecnění zkušeností, které úsporným způsobem tyto zkušenosti popíše.

Zmiňovaná užitečnost konkrétnější definice je pochopitelná. Je to "z nouze ctnost". Většina současných přístupů ke strojovému učení totiž odpovídá této konkrétnější definici. A v tom je problém. O jaký **problém** jde? Srovnejme obě definice. Hlavní rozdíl vidím v tom, že zatímco druhá se zabývá samotným aktem vytvoření nějaké datové struktury, pomocí které je funkce-znalost v systému popsána, prvá definice (implicitně) integruje učení do kontextu většího systému. Jestliže součástí tohoto systému nebude řešení úloh nebo realizace výsledku tohoto řešení, nebude-li mít systém možnost užít své zkušenosti, nebude-li možno vyhodnotit jeho výkonnost, není možno hovořit o učení. Učení je zde pevně spjato s dalšími kognitivními funkcemi. Problém je v tom, že většina současných přístupů k strojovému učení toto nutné spojení nerespektuje, tj. **neodpovídá** (prvé) **definici**. To je základní příčinou paradoxů, to je příčinou stagnace. Jsou to jistě opovážlivá tvrzení, ale dále je doložím, hlavně poukázáním na příčiny tohoto stavu.

Co jsou tedy **příčiny** tohoto problému? Vzájemně propletených příčin je zřejmě celá řada. Žádná asi nevyvolává problém sama o sobě, pouze k němu více či méně přispívá. Prvou příčinou je **nedorozumění** nebo neporozumění strojovému učení: Někteří výzkumníci přímo řeší strojové učení v souladu s výše specifikovanou konkrétnější definicí. To se projeví, když chceme strojové učení použít. Aplikaci strojového učení je pak třeba doplnit o další rozšiřující stavy-kroky. V souladu s Langley a Simon to mohou být: 1) formulace problému, tj. určení toho, co se bude učit, jaká funkce se bude vytvářet, jaká

[2] Dovolím si definici přesto, že jeden z otců umělé inteligence, Marvin Minsky, s použitím definic nesouhlasí. Taky paradox?

závislá proměnná se bude sledovat, 2) určení toho jaké nezávislé proměnné se budou při vytváření funkce používat, 3) shromažďování zkušeností, 4) vyhodnocení naučené znalosti a 5) zpoužitelnění znalosti, např. zajištění uživatelského prostředí, vysvětlování znalostí, zasazení do existujícího znalostního (expertního) systému. Např. návrháři vítěze RoboCup 99 1) určili, že budou roboty učit přihrávat, 2) vybrali pro to 174 proměnných a 3) použili 5000 situací zmiňovaných výše. Zejména kroky 1 a 2 dnes téměř nejsou zautomatizovány.

To se projeví v rigidním přístupu ke strojovému učení. Důsledkem je i paradox bezradných robotů. Návrhář robota určí pevnou množinu proměnných. Z jejich hodnot pak vznikne znalost. Např. kráčející robot z RoboCupu je schopen rozpoznat právě jen pět typů objektů, míč, spoluhráče, protihráče, branky, a lampiónky v rozích a středech delších hranic hřiště. Robot není schopen naučit se rozpoznávat objekt nový, např. mantinel hřiště nebo svou neschopnost mantinel přelézt. To by mu příště pomohlo bezradnost překonat.

K nedorozumění možná také přispívá to, že se strojové učení ve svých pravděpodobnostních přístupech překrývá a vzájemně ovlivňuje s problematikou řešenou matematickou statistikou, případně dalšími disciplínami. Ty mají své cíle přirozeně definované jinak. Neporozuměním je i neadekvátní pohled na zasazení strojového učení, na roli, jakou ve strojovém učení hraje **prostředí**. Neporozuměním je i přistupovat ke strojovému učení jako k řešení problémů. Učení je založeno spíše na **příležitosti**. Ve smyslu „náhoda přeje připraveným“. Má-li štěstí, že mu prostředí ukáže něco zajímavého, tj. nového, co dosud nezažil, čemu dosud nerozuměl, ale k čemu již doplněním svých znalostí dozrál, pak může dojít k pochopení a toužebnému AHA efektu. Důležitost prostředí např. pochopily části umělé inteligence, zabývající se agenty a roboty. Ty to až někdy přehánějí do opačného extrému. Říkají, že se vše dá najít v prostředí. Prosazují umělou inteligenci bez dudukce, bez znalostí o něm. Prostředí je však jak zdrojem informací, tak i zkušeností pro strojové učení. Proto je mu třeba věnovat náležitou pozornost.

Na workshopu o učení, na kterém jsem byl před rokem, si jeden účastník povzdechl: "Dá to strašnou práci" (přimět počítač, aby se něco užitečného naučil). Myslím, že to plyne z výše uvedené situace i z dalších omezení strojového učení, o kterých dnes víme: algoritmy strojového učení jsou většinou výpočetně velmi náročné, vytvořená znalost může mít charakter lokálního optima, dochází k přepřizpůsobení, tj. k přílišnému ovlivnění výsledné znalosti konkrétními zkušenostmi. Za této situace je oprávněná snaha řešit složitý problém podle heuristiky **od jednoduššího ke složitějšímu**. To odpovídá řešení typu bottom-up (zespoda nahoru). Tj., navrhují a zkoušejí se jednotlivé dílčí algoritmy strojového učení, vytvářejí se jednoduché, nestrukturované, dílčí znalosti. To vede na **roztříštěnost** strojového učení. Jsou propracovány hlavně následující, poměrně samostatné ale trochu se i překrývající oblasti, rozlišované dle reprezentace znalostí nebo přístupu: učení rozhodovacím stromům, pravidlům, případové učení (case-based), pravděpodobnostní přístupy, neuronové sítě, bayesovské sítě, genetické algoritmy.

"Bottom-up" stanovisko zaujal i workshop Automated Learning and Discovery (1998). Zde se mj. navrhuje řada výzkumných cílů, např. strojové učení ve velmi velkých databázích s hodně-dimenzionálními prostory vlastností, strojové učení robotů, strojové učení pro více-úlohové zpracování, pro extrakci informací z textů. Napočítal jsem 29 takových cílů. Výzkum pak např. v oblasti extrakce informací z textů spočívá v tom, že se vezmou známé metody zpracování textů, jako je syntaktická analýza, a známá jazyková báze znalostí, WordNet, pomocí kterých se odvodí informace o zpracovávaných textech, a z nich pak, pomocí známých technik strojového učení, např. neuronových sítí, indukují schopnosti, jako rozpoznávání vlastních jmen. Jde o **čistou aplikaci** strojového učení. Z hlediska pracnosti je v tom řádově 70% zpracování přirozeného jazyka a 30% strojového učení.

Paradox nepřesného nalezení rozkladů množiny, zmiňovaný výše, plyne z jednoduchého – nestrukturálního přístupu k strojovému učení. Podíváte-li se na to, jak nalezení rozkladů řeší např. program, který jsem si pro to udělal, zjistíte, že k tomu používá více poměrně složitě propojených

pojmů. Odhaduji kolem 30 běžných matematických a programovacích pojmů - relací. Nemůžeme se pak divit, že se jedinou aproximací jedné funkce nedosáhne stejných výsledků. Nejjednodušší je vysvětlení posledního paradoxu. Ten je způsoben nerespektováním skutečnosti, že pro různá prostředí jsou vhodné různé reprezentace znalostí nebo přístupy. Pro rozpoznání parity nejsou vhodné neuronové sítě, vhodné je užít tzv. induktivní logické programování.

„Od jednoduššího ke složitějšímu" je možný přístup, ale racionálnější, vyváženější by byl, kdyby se používal spolu s top-down (shora dolu), kdyby se zároveň vytvářel celkový obraz strojového učení. Dnes pro to neexistuje žádná společná jednotící **teorie**. Minsky dokonce hledání takové teorie zpochybňuje. To považuji za nerozumné a neopodstatněné. Závěrem několika workshopů, kterých jsem se v poslední době zúčastnil, kde se detailně o strojovém učení diskutovalo, naopak bylo konstatování, že taková teorie by byla velice potřebná. Taková teorie také nemusí mít hned podobu přesných matematických axiomů a teorémů. Proč by to nemohl být postupně upřesňovaný soubor znalostí, na kterých se jakž takž shodneme.

Ve strojovém učení se požadují **přesvědčivé příklady aplikací**. To by bylo jistě správné, pokud by se to nepřehánělo. Ono se to ale přehání. To je dokumentováno zastoupením prací na ICML 2000: 54% experimentálních, 11% formálních a 35% aplikačních. Žádné, nepočítám-li pozvané referáty, zobecňující. Konkrétní práce nejsou doprovázeny patřičným zobecňujícím nadhledem. Jak je to možné? Jak to, že toto zobecnění, které hraje v učení tak důležitou roli, neumíme aplikovat na somotný proces učení? Existuje zde opět jakási nezdravá nevyváženost.

Podobně téměř povinnou součástí každé experimentálně orientované práce o strojovém učení je **hodnocení** navržené metody – systému. To by bylo v pořádku, kdyby se hodnocení přisuzovalo odpovídající místo. Něco jako „ano, naše hodnocení je jistě velice přibližné, ale lépe to neumíme". To tak není. Metody se srovnávají různě. Často se používá kvalitativní hodnocení; to, že systém vůbec má nějakou vlastnost, např. dedukci nebo učení. To moc nevypovídá, protože vlastnosti je třeba posuzovat v kontextu s vlastnostmi dalšími. Problematické je i kvantitativní hodnocení. Neviděl jsem takové, které by říkalo, že navržená metoda je ve všech ohledech horší (lepší) než metody jiné. Jsou v některých vlastnostech lepší, ale horší v dalších. Tento přístup je dost **neobjektivní**. Záleží na subjektivním výběru hodnocených vlastností a na výběru toho, s čím se srovnává. Neobjektivní hodnocení může brzdit vývoj celé disciplíny. Proto dávám přednost způsobům hodnocení, které se uplatňují v RoboCup. Tam hrají týmy robotů turnaj v robotí kopané. Různé systémy se srovnávají v jejich celkových výkonnostech - ve smyslu výše uvedené obecné definice strojového učení. Lepší výkonnost má ten, kdo vyhrává. Jsou-li si systémy výkonnostně blízké, může být výsledek hodnocení náhodný. V opačném případě se pravda velmi rychle ukáže.

Tato situace mi připomíná situaci v biologii pře Darwinem. (Biologům se omlouvám za své nejspíš hodně zjednodušené představy.) Docházelo tehdy k rozsáhlému podrobnému zkoumání jednotlivých biologických druhů (dnes se odhaduje jejich počet na několik milionů) bez znalosti - uvědomění si jejich podstatných vlastností, daných evolučním pohledem. Ve strojovém učení se dnes převážně také rozsáhle zkoumají jednotlivé algoritmy bez důkladnější znalosti vztahů mezi nimi.

Integrace, integrace a integrace

V předchozích příčinách se jednalo o neporozumění role kontextu strojového učení, role prostředí, přílišnou konkrétnost, roztříštěnost, zdůrazňování některých dílčích hledisek. Vlastně se jednalo o zvláštní případy nedostatečné integrace strojového učení do celého znalostního systému. V podobném duchu je možné kritizovat i malou **integraci** v rámci celé umělé inteligence. Integrace ale musí být založena na analýze toho, co je potřeba integrovat. V umělé inteligenci např. nejsou jasně rozpoznány základní (kognitivní) funkce, které by bylo možno použít pro řešení dalších funkcí. Dochází k tomu, že se např. v rámci strojového učení řeší problematiky identifikace nebo plánování. Ty by se mohly a měly

řešit samostatně, důkladněji a s ohledem na vícenásobné použití. Souvisí to také s přístupem k **standardizaci**. V komerční informatice disciplína softwarového inženýrství postupně prosazuje standard UML (Unified Modeling Language - Standardizovaný jazyk modelování). V umělé inteligenci je užití UML zatím bílou vránou. To vede jednak na plýtvání duševním potenciálem, jednak to zhoršuje možnosti řešení složitých systémů. Softwarové inženýrství je v tom dále než umělá inteligence. Mezi těmito disciplínami existuje jen malá spolupráce. Je to příklad nedostatečné integrace v oblasti informačních technologií.

Mám také pocit, že umělá inteligence podléhá módním vlivům, že se dá **ovlivnit prohlášeními silných osobností**. Na Minského se svádí, že zavinil zpoždění rozvoje neuronových sítí. Příkladem módních vlivů může být dnešní vztah k stochastičnosti; dnes je "vše" stochastické, před 20 lety bylo naopak "vše" deterministické; prostředí ale zůstalo stejné. Strojové učení možná výrazně ovlivnilo tvrzení Lenata, že pokrok ve strojovém učení je závislý na pokroku ve zpracování přirozeného jazyka (to je další část umělé inteligence) a obráceně pokrok ve zpracování přirozeného jazyka je závislý na pokroku ve strojovém učení. Proto on také ve svém systému CYC ani jednu z těchto technologií zpočátku nepoužíval. Sice tak elegantně "vyřešil" problém "slepice a vejce", ale strojovému učení tím nepomohl. Podobně sem může patřit i závěr Langeley a Simona, že strojové učení třeba nemusí být plně automatizovatelné nikdy. To je ostatně ekvivalentní tomu, že se třeba nepodaří zkonstruovat plnou umělou inteligenci. Takto opatrně formulovaná prohlášení jsou nenapadnutelná. Otázkou je, stojí-li to za to riskovat, že si někdo té opatrnosti nevšimne.

Tento stav, potíže, stagnace se také projevily na ECAI 2000. Když jsem se v polovině konference potkal s kolegou, dospěli jsme ke shodnému závěru, „zatím nic moc“, tj. zatím nebylo vidět nic moc nového a zajímavého. Ten pesimistický pohled byl ovlivněn také tím, že se na začátku odbývaly hlavně konkrétní workshopy. Pozvané přednášky začaly později. Zejména ty přinesly obecnější, obsáhlejší a perspektivnější pohledy. Naštěstí, jak na ECML a dalších konferencích, tak i ve strojovém učení a umělé inteligenci byly a jsou tedy vidět jakési jiskérky – zárodky naděje.

Za nejdůležitější zárodek považuji **snahy o integraci**. Jejich součástí byl i odvážný návrh na znovuuvážení koncepce GPS (General Problem Solver – obecný řešitel problémů). Nezůstává jen u snah. Aplikace v reálném prostředí (a referáty o nich) jsou příklady této integrace. V takových aplikacích je nezbytné skloubit minimálně tři části: část zpracovávající informace o prostředí, část zpracovávající tyto informace do plánů a část realizující naplánované řídící zásahy v prostředí. Příkladem takových aplikací jsou roboti nebo konkrétněji, roboti hrající kopanou. Ta se hraje (organizuje, prezentuje, rozebírá apod.) pod názvem RoboCup. Součástí konference ECAI 2000 RoboCup přímo nebyl. Mistrovství Evropy se hrálo na jaře v Amsterodamu a mistrovství světa až po konferenci v Melbourne. Přesto byl RoboCup na konferenci přítomen nepřímo v jedné přehledové přednášce a mnoha pochvalných poznámkách a narážkách. RoboCup 99, součást konference IJCAI 99, která se také konala v Evropě, měl velký ohlas. V této souvislosti na mne dělaly sympatický dojem časté sebekritické a sebeironizující poznámky německých hostitelů. Ti, ve srovnání s ročníkem 1998, nedopadli na RoboCup 99 tak dobře, ale nebáli se na konkrétních příkladech ukazovat některé důvody. Nepřispívá sám takový přístup k úspěchům? Možná už ale tušili, že si to v Melbourne vynahradí.

Další rozsáhlé „robotické“ projekty, které mne zaujaly byly projekty švédské nepilotované helikoptéry a amerického nepilotovaného vesmírného plavidla. Byly zajímavé nejen jako příklady úspěšnosti a nezbytnosti integrace mnoha kognitivních funkcí, ale i svým odlišným vztahem ke strojovému učení. Švédský projekt s jednoduchým strojovým učení počítá, americký ne. Ptal jsem se proč ne. Důvod je „zajímavý“. NASA je tak opatrná, že "nechce ztratit 100%-ní kontrolu nad zařízením"; řešení to musí respektovat.

Z nových přístupů považuji za nejzajímavější spojení strojového učení a ontologií. **Ontologií** se rozumí síť pojmů, které jsou pospojovány různými relacemi, např. relacemi zobecnění, nebo býti-částí. Za

zajímavé to považuji proto, že jde o nejsložitější reprezentaci znalostí, se kterou se ve strojovém učení dnes pracuje. Na ECML byl příslušný workshop zaměřen na problematiku zpracování přirozeného jazyka. Zatím se prezentované algoritmy omezují na vytváření pouze určitých částí ontologie, např. buď některých typů relací, nebo pojmů. Jsou často silně motivovány potřebou získávání znalostí z Internetu. Jsou založeny na zpracování textu, jeho syntaktické analýze, použití existující ontologie, např. WordNet. To je rozsáhlá báze popisující sémantiku nejběžnějších anglických slov. Výsledkem strojového učení je obohacení ontologie, např. o nové pojmy, nové relace, nové vzory struktur pro zpracování textů.

Potěší také záměrná podpora **pokročilejších částí strojového učení**. Např. ICML 2000 přímo a úspěšně povzbuzovala prezentaci tematiky orientované na uplatnění strojového učení v dalších kognitivních funkcích, v plánování, zpracování přirozeného jazyka, zpracování vizuální informace, robotice, vědeckém objevování. To byla dříve témata, která se objevovala jen velmi zřídka. Jde také o integraci. Ta zde ovšem teprve začíná. Jde většinou o propojení strojového učení s jedinou další kognitivní funkcí. Integrace také není zatím zdůrazňována přímo z hlediska strojového učení. Až to vše uzraje, až se to dovede do důsledků, až se vše propojí se vším, může z toho být velká změna (kvality) umělé inteligence. Ale i nemusí …

A jak u nás doma

K celkově optimistickému pohledu na strojové učení přispívá i **pozornost**, která se strojovému učení, umělé inteligenci a informačním technologiím (ve světě) věnuje. Je přirozené, že v informační společnosti má informatika zelenou. Ilustrovala to pozornost, kterou konferenci věnovali němečtí hostitelé, ilustrovala to i vyžádaná úvodní přednáška člena vedení automobilky DaimlerChrysler AG, která velice optimisticky oznamovala široké současné a ještě více budoucí použití umělé inteligence a strojového učení v automobilovém průmyslu. Dokumentoval bych to dále na několika číslech a trochu srovnal s poměry u nás: Česká společnost pro kybernetiku a informatiku má asi 250 členů, z toho odhaduji možná 100 pracuje v umělé inteligenci. Její německá obdoba, Gessellschaft für Informatik, 20.000, z toho 3.000 pracuje v umělé inteligenci. V České republice věnovala Grantová agentura AV v roce 2000 1,2% ze svého rozpočtu na informatiku, v Evropě Pátý rámcový program v letech 1999-2002 30,5%. RoboCup 2000 se celkově zúčastnilo 150 týmů, z Německa 18. Německo bylo letos dokonce v RoboCup 2000 úspěšnější než USA. Od nás se nezúčastnil žádný tým. Když jsem navrhoval jedné vysoké škole téma diplomové práce , která by připravila účast České republiky v RoboCup, nebylo to shledáno dost tvůrčí. Výše jsem hovořil o jakýchsi jiskérkách naděje. Poletují i v Čechách, nebo se dokonce blýská na lepší časy? Koncem roku 2000 uspořádala některá česká pracoviště seminář Dobývání znalostí z databází 2000. V roce 2001 se chystá konference Znalosti 2001 a další akce, které problematiku strojového učení pokryjí.