

# ÚVOD DO STROJOVÉHO UČENÍ

## STROJOVÉ UČENÍ (Machine Learning)

je vědecká disciplína zabývající se umělou inteligencí světem. SU (ML) tvoří část umělé inteligence (AI). Hlavní oblasti zájmu ML jsou zejména algoritmy, které zlepšují svou výkonnost a zkušenosti.

ML poskytuje nástroje (algoritmy, programy) umožňující učení umělých objektů (artefaktů).

ML má své počátky někde v 60. letech, avšak největší rozvoj v oblasti algoritmů a metod automatizovaného učení inteligentních artefaktů pochází z cca posledních 10 let.

### **Strojové učení**

- Otázka, zda lze naprogramovat počítače tak, aby byly schopny se učit, je aktuální od okamžiku vynálezu počítače.
- Pod pojmem "učit se" se rozumí schopnost automatického zlepšování výkonnosti s tím, jak vzrůstá znalost a zkušenost:

**Definice:** O počítačovém programu říkáme, že se učí pomocí určité zkušenosti  $E$  vzhledem k nějaké třídě úloh  $T$  a mře výkonností  $P$ , pokud jeho výkonnost pro dané úlohy v  $T$  měřená  $P$  se zlepšuje použitím  $E$ .

- Zatím není známo, jak upříslit počítače tak, aby se učily jako lidé.
- Pro určité druhy úloh již byly vyvinuty efektivní učící algoritmy.
- Např. problémy typu rozeznávání řeči jsou řešeny pomocí strojového učení daleko lépe než pomocí jakýchkoliv jiných přístupů.
- Úspěch zaznamenaly mj. následující aplikace založené na strojovém učení:
  - ▶ programy schopné učit se rozeznávat vyslovovaná slova (1989);
  - ▶ predikce doby uzdravení pacientů s pneumonií (1997);
  - ▶ detekce zneužití kreditních karet (1989);
  - ▶ řízení autonomního vozidla na dálnicích (1989);
  - ▶ hry obdobné backgamonu na úrovni mistra světa (1992, 1995), aj.
- V oblasti teorie strojového učení byly v současnosti nalezeny postupy umožňující např. charakterizovat základní vztah mezi počtem trénovačích příkladů, počtem uvažovaných hypotéz, a očekávanou chybou naučených hypotéz.
- Byly také získány počáteční modely zvířecího a lidského učení pro porozumění vztahu vůči počítačovým učícím algoritmům.

Některé příklady stanovení učících problémů vzhledem k všeobecné definici:

- Hra v dámou – počítačový program, který by se učil např. hrát dámou, může zvyšovat svou výkonnost pomocí míry dané schopnosti zvítězit ve třídě úloh zahrnující dámou, pomocí zkušenosti získané hraním dámou proti sobě.

Učení se hrát dámou:

- $T$ : hra v dámou
- $P$ : procento vyhraných partií proti protivníkům
- $E$ : hraní partií proti sobě

Rozeznávání rukopisu:

- $T$ : rozeznání a klasifikace slov psaných rukopisem
- $P$ : procento korektně klasifikovaných slov
- $E$ : databáze rukopisných slov s danou klasifikací

Řízení robota:

- $T$ : jízda na veřejné čtyřproudé dálnici za použití senzorů
- $P$ : průměrná vzdálenost dosažená před výskytem chyby (posuzováno dohlížejícím člověkem)
- $E$ : posloupnost obrazů a řídicích příkazů zaznamenaných při sledování člověka-řidiče

Některé z úspěšných aplikací strojového učení:

- **Rozeznávání mluvených slov** nejúspěšnější aplikace tohoto typu využívají v nějaké formě strojové učení. Např. systém *SPHINX* (1989) se učí strategie rozeznávání primitivních zvuků (fonémů) a slov pro specifické jedince ze zaznamenaného zvukového signálu. Jsou využity neuronové sítě a metody pro učení Markovových modelů pro automatické přizpůsobení se individuálním řečníkům, jejich slovníku, charakteristikám mikrofonů, šumu na pozadí apod. Tyto techniky mají použití i v mnoha dalších problémech interpretace signálů.
- **Učení jízdy autonomního vozidla** trénování počítačem řízeného vozidla tak, aby jelo správným způsobem po různých typech silnic. Např. systém *ALVINN* (1989) používal strategie strojového učení k autonomní jízdě při rychlosti 70 mil/hod na vzdálenost 90 mil po veřejné dálnici za běžného provozu. Obdobné techniky mají aplikace v mnoha problémech regulace a řízení založených na využití senzorů.
- **Klasifikace nových astronomických struktur** metody strojového učení byly využity v mnoha aplikacích na rozsáhlé datové báze k naučení se obecných pravidelností skrytých v datech. Např. NASA použila algoritmus rozhodovacího stromu pro zjišťování jak klasifikovat nebeské objekty na Palomarské observatoři v programu prohledávání oblohy (1995). Tento systém je nyní používán k automatické klasifikaci objektů na základě dat majících objem rádu terabyte (obrazová data).
- **Naučení se hry v backgammon na úrovni mistra světa** program TD-Gammon (1992, 1995) se naučil svou strategii hraním více než 1 milionu partií sám se sebou a nyní hraje srovnatelně s mistrem světa. Techniky využité v TD-Gammonu jsou aplikovatelné v mnoha praktických problémech, kde je nutno provádět efektivní prohledávání rozsáhlých prostorů.

- Strojové učení nyní tvoří značnou část oboru zvaného umělá inteligence. Jako disciplína bylo ovlivněno mnoha obory:

- *Umělá inteligence* – učení se symbolických reprezentací konceptů. Problém prohledávání/vyhledávání. Učení jako přístup ke zlepšování řešení problémů. Využívání již zaznamenané znalosti spolu s trénovacími daty pro řízení procesu učení.
- *Bayesovské metody* Bayesův teorém jako základ pro výpočet pravděpodobnosti hypotéz. Naivní Bayesovský klasifikátor. Algoritmy pro odhad hodnot nenaměřených proměnných.
- *Teorie výpočetní složitosti* teoretické hranice složitosti různých úloh učení, měřené v termínech nároků na výpočet, množství trénovacích příkladů, množství chyb apod., nutných pro požadované učení.
- *Teorie řízení* procedury pro učení se řízení procesů za účelem optimalizace předem stanovených cílů a pro předpovědi následných stavů řízených procesů.
- *Informační teorie* – měření entropie a informačního obsahu. Optimální kódy a jejich vztah k optimálním tréninkovým sekvencím pro kódování hypotéz.
- *Filosofie* – Occamovo ostří (princip jenž stanovuje, že nejlepší je nejjednodušší hypotéza). Analýzy oprávněnosti generalizací přesahující naměřená data.
- *Psychologie a neurobiologie* tzv. pravidlo praxe, podle kterého rychlosť učení ve velmi širokém rozsahu úloh vztřustá se získávanou praxí v daných úlohách (někdy také uváděno jako "čím více toho známe, tím snadněji se v tom dále zlepšujeme"). Neurobiologické studie motivovaly modely umělých neuronových sítí pro učení.
- *Statistika* charakteristiky chyb, které se vyskytují při odhadu přesnosti hypotézy založené na omezeném vzorku dat. Intervaly spolehlivosti, statistické testy.


Před tím, než začneme sestavovat učící algoritmus pro konkrétní úkol, je obvykle nutno zodpovědět některé otázky:

- Jaké existují algoritmy pro učení obecných cílových funkcí ze specifických trénovacích příkladů? Za jakých podmínek budou konkrétní algoritmy konvergovat k požadované funkci vzhledem k daným trénovacím datům? Které algoritmy poskytují nejlepší výkonnost a pro které problémy a reprezentace?
- Jak mnoho trénovacích dat je zapotřebí? Jaká obecná omezení mohou být nalezena, aby byl vytvořen vztah věrohodnosti naučených hypotéz k množství trénovacích dat a charakteru prostoru hypotéz?
- Kdy a jak může apriorní znalost pomoci řídit proces generalizace z příkladů? Může tato znalost pomáhat i když je pouze přibližně správná?
- Jaká je nejlepší strategie pro výběr použitelné trénovací zkušenosti a jak výběr této strategie mění složitost problému učení?
- Jaký je nejlepší způsob jak redukovat problém učení na problém jedné či více aproximačních funkcí? Lze tento proces automatizovat?
- Lze měnit reprezentaci problému tak, aby se zlepšila schopnost naučit se cílovou funkcí?

## ZDROJE ML

ML čerpá ze všech oblastí informatiky, matematiky, apod., které jsou k dosažení cíle (tj. učení se umělých objektů) jakkoliv použitelné. Např. kombinací logiky, databazové teorie a vhodných heuristik lze vytvořit systém pro získávání znalostí.

Z hlediska ML je podstatná znalost a metaznalost:



## UČENÍ

Schopnost učit se tvoří jeden z ústředních rysů inteligence. Učení je středobodem zajmu kognitivní psychologie a umělé inteligence. Strojové učení obě zmíněné disciplíny částečně spojuje.

Strojové učení studuje (výpočtové) procesy, které tvoří základ učení jak u lidí, tak u strojů.

ML se musí zabývat dvěma zásadními hledisky:

- problémy spojené s reprezentací znalosti, organizací paměti, a výkonnosti (což jsou rovněž problémy AI a kognitivních věd);
- učení se může vyskytnout v kterékoliv oblasti vyžadující inteligenci (diagnostika, plánování, přírozený jazyk, řízení pohybů ...).

## HISTORICKÝ POHLED NA ML

Asi od poloviny 50. let lze sledovat zájem o učení z výpočtových hledisek (hraní her jako např. šachy, rozpoznávání písma, tvorba abstraktních konceptů, verbální paměť). Na učení se pohlíželo jako na hlavní vlastnost intelligentních systémů a výzkum se soustředil na obecné mechanismy poznávání, vnímání a jednání.

Někdy uprostřed let 60. rozeznali psychologové a výzkumníci z AI důležitost tzv. doménové znalosti, což vedlo ke konstrukci prvních znalostí zaměřených systémů. Hlavní zájem byl ovšem zaměřen stále na doménově nezávislé metody, především na aplikace v oblasti vnitřního AI a rozpoznavání vzorů se koupř. zcela oddělily, přičemž AI-paradigma zahrnuje heuristické a symbolické metody na rozdíl od metod algoritmických a numerických.

Stálý vzrůst zájmu o ML se datuje od konce 70. let: zklamání z encyklopédického a příliš speciálního charakteru expertních systémů a návrat k obecným principům, dále nadějení z možnosti automatizovat získávání znalostí pro doménově specifické znalostní báze, a konečně velké naděje ukládané do modelování lidského učení (s aplikacemi např. v robotice).

ML se jako výrazná větev AI profilovalo během 80. let, kdy se začalo rozšiřovat do oblasti aplikací jako plánování, diagnostika, navrhování a řízení. Konkrétní aplikace v některých oblastech tzv. problémů reálného světa (průmysl, medicína, řízení...) spolu s pěknější metodologickou půdou pod nohami prokázaly přenosnost a použitelnost technologie ML. Systématické experimenty na sdílených datech a precisi teoretické analýzy se postupně staly normou (spíše než výjimkou).

## CÍLE A VÝSLEDKY ML.

Společným zájmem je učení, avšak současný stav dle literatury naznačuje rozdělení zájmu do čtyř hlavních skupin:

- ① Modelování mechanismů tvorících podstatu lidského učení: Psychologický rámec v němž jde o vývoj algoritmů obecně konsistentních se znalostí lidské kognitivní architektury a o vysvětlení specifických jevů pozorovaných během učení. Výsledkem tohoto přístupu je řada modelů zahrnujících řešení problémů, přirozený jazyk, vnitřní, aj. Praktickým přínosem je např. predikce procesu učení a použití lze nalézt koupř. v oblasti návrhu instrukčních materiálů pro použití ve vzdělávacím procesu.
- ② Empirický přístup ke studiu ML: cílem je odkrýt obecné principy vztahující se k charakteristikám učicích algoritmů a k oblastem, v nichž působí. Standardním přístupem je experimentování, kde se mění algoritmus nebo doména a pozoruje se, jaký dopad tyto změny mají na učení. Výsledkem bývá odhalení slabých míst algoritmů, jejich vztahem k stovnám, ideje pro jejich zlepšení, a poznání zdrojů z nichž pramení obtíže.
- ③ Matematické studium ML: cílem je formulovat a dokázat teorémy o zvládnutí celých tříd problémů učení a o algoritmech navržených k řešení těchto problémů. Typický přístup zde zahrnuje definici nějakého problému učení, odhad zda může či nemůže být řešen pomocí rozumného počtu všechých

(tréninkových) příkladů, a nakonec důkaz, že odhad platí i při velmi obecných podmínkách. Zatímco empirický přístup používá experimentální techniky z fyziky a psychologie, matematický přístup využívá nástroje a pojmy informatiky a statistiky. Výpočtová teorie učení přinesla mnoho pronikavých a překvapivých teorémů a relativní obecnost učení a o metodách k řešení těchto problémů.

④ Aplikační přístup k ML: Primárním cílem je použití ML na problémy reálného světa. Mnoho aplikací umělé inteligence spoléhá na expertní systémy, které často využadují mnoho „člověkoleť“ ke svému vývoji a odladění. ML umí přeměnit trénovací data na znalost (např. na pravidla).

Typický postup zde zahrnuje formulaci problému v termínech ML, návrh reprezentace trénovacích příkladů a naučené znalosti, shromažďení trénovacích dat, použití ML k vygenerování znalostní báze, a dále práce s uživateli k dosažení znalostní báze do požadované podoby.

Tento přístup vedl k aplikacím ML v diagnostice, řízení procesů, plánování, aj.

To, co spojuje uvedené přístupy dohromady, je zájem o vývoj, pořozumění a zhodnocení učicích algoritmů. ML je věda o algoritmech. Důraz je kladen na vynuté algoritmy a na jejich vzájemný vztah.

## RÁMEC ML

Termín **učení** není snadné definovat, vždy lze najít mnoho protipříkladů. Pro naše účely vystačíme s poněkud nejednoznačným vymezením pojmu:

**Učení** je zlepšování výkonnosti prováděných činností v nějakém prostředí pomocí získávání znalostí vyplývajících ze zkušeností v daném prostředí.

Terminy jako výkonnost, prostředí, znalost, zkušenosť jsou ovšem poněkud vagní, ale to není na závadu. Např.:

Výkonnost představuje nějakou kvantitativní míru plnění nějakého úkolu, ovšem lze měřit různá hlediska jako přesnost, účinnost, pochopení...


Prostředí předpokládá nějaké externí uspořádání s jistými pravidly, avšak může být externí vzhledem k učení (k učícímu se systému) a může být součástí celkového systému.

Znalost implikuje nějaký typ unitní (interní) struktury dat, ale ta může být jakákoliv.

Zkušenosť vyžaduje určité mentální zpracovávání, což může být zaměřeno na vnijmáci vstup, na pochybový výstup, nebo dokonce na unitní dráhy.

Zlepšení zahrnuje požadovanou změnu výkonnosti. Místo „změna“ lze využadovat „zvýšení“.

Nejdůležitějším znakem uvedené definice je požadavek na to, že učení nelze popisovat izolovaně. Učicí se je vždy spojen s nějakou znalostní bázi z níž může vyvzakovat (usuzovat) a do níž ukládá získanou znalost:



Obr.: Interakce mezi učením, výkonností, znalostí a prostředím. (---- je volitelný spoj)

**DŮLEŽITÉ:** Prostě ukládání do paměti **není učení !!!**  
Toto tvrzení nejspíše nevyvolá pochyby – otázka ale je, **proč?** Důvod je ten, že pouhé memorování nezahrnuje **indukci**, která umožňuje usuzování o dalších případech (různých od téhod, které byly použity k trénování) pocházejících z téhož prostředí. Téměř všechn výzkum v oblasti ML se zabývá nějakou formou indukce.

### Výkonnost a její měření

Sledujeme-li např. cíl zlepšení: u učících se klasifikátorů to je přesnost klasifikace; systémy pro řešení problémů zlepšují svou účinnost ...

### Charakteristiky trénovacích dat

Program se učí analyzováním konečné posloupnosti dat. Tato data se nazývají **trénovací data**. Často pocházejí z aplikativní domény.

**Uzávřená a otevřená doména:** doména se nazývá uzavřená, pokud existuje pouze omezený počet vlastností, na nichž záleží a pokud v principu víme, které vlastnosti to jsou.

Pokud nemůžeme říci, co může ovlivnit řešení praktického problému, pak doménu nazýváme otevřenou.

**Příklad:** Rubikova kostka je klasickým příkladem uzavřené domény. I když řešení je často velice obtížné (pro některé z nás), v principu máme k dispozici veškerou informaci potřebnou k řešení - získáme ji ze stavu, v němž se kostka nachází.

**Předpověď počasí** je doména otevřená. Velmi závisí na okamžitém stavu atmosféry (gradienty tlaku a teploty), dále na oceánském proudu El Niño (objeveno nedávno) ... Přesnější předpověď vyžaduje např. uvažovat sluneční skvrny, hrubost povrchu Země ... Množství faktorů je téměř neohraničené.

**čistá a zašuměná data:** Učení je relativně snadné, pokud v trénovací množině nejsou chyby. Množina obsahující jen spolehlivé příklady se nazývá čistá (bez šumu). V opačném případě pak hovoříme o zašuměných datech - může vést k např. chybné klasifikaci apod.

**Pouze pozitivní příklady versus korekce nebo negativní příklady:** děti se učí mluvit a rozumět svému mateřskému jazyku pouze (zpočátku) nasloucháním rodičům a vlastními pokusy mluvit. Navíc, jejich první slova bývají pro rodiče srozumitelná. Je to proto, že dětem jsou předkládány pouze správné příklady řeči - nikoliv explicitně chybné příklady, které přesto rozezná.

Oproti tomu, průměrný kuchař-záčatečník se učí metodou pokusu a omylu jak uvařit vajíčko a jak horký tuk má být na pánev... Jsou zapotřebí pozitivní i negativní zkušenosti/příklady. Rovněž jsou nutné korekce. „Chybami se člověk učí“.

### Pravidelnost prostředí

Čtyři faktory ovlivňují obtížnost učení:

- ① **Složitost cílové znalosti** jež má být získána. Např. koncept zahrnující mnoho příznaků nebo podmínek může být k naučení složitější než ten, který jich má méně.
- ② **Množství irrelevantních příznaků či atributů.** Je-li v prostředí přítomno mnoho např. atributů jsoucích bez významu pro naučení se konceptu, systém může mít s učením problémy, protože nemusí být schopen rozlišit co je podstatné pro začlenění instance do určité třídy a co ne.
- ③ **Množství šumu v prostředí.** Uřízeného učení jsou dvě možné formy:
  - a) šum třídy zahrnuje zkreslení zpětné vazby, takže učci se dostavd nesprávné údaje od učitele.
  - b) šum atributů zahrnuje zkreslení údajů o samotné instanci, takže hodnota atributu může být posuhnuta či změněna. Všeobecně platí, že s vyšším šumem bývá učení obtížnější. Existují ovšem techniky pro zmenšení tohoto efektu.
- ④ **Drift konceptu,** což souvisí s časovou konsistencí prostředí. V některých případech může dojít k náhlé změně platnosti konceptu vlivem závislosti na čase (změna ročního období ...).

Od šumu bývá někdy obtížně rozeznatelný tzv.

## Učení řízené ("s učitelem") a neřízené ("bez učitele")

Stupeň (míra) řízení učení ovlivňuje učící proces. V některých případech učitel (nebo doménový expert) poskytuje učícímu se přímou zpětnou vazbu o přiměřenosti jeho výkonnosti. Tato vazba chybí u neřízeného učení. Většina problémů ML se týká řízeného učení.

U klasifikátorů předpokládá řízený úkol, že každá instance předložená systému během učení zahrnuje atribut specifikující třídu dané instance a cílem je indukovat koncept schopný přesně (co nejpřesněji) predikovat tento atribut (např. rozpoznávání písma).

U řešitelných problémů se řízené učení vyskytuje v případech, kdy učitel ukáže správný krok v každém bodě hledání či usuzování.

## On-line a off-line učení

Při on-line učení jsou příklady z učicí množiny poskytovány postupně, po jednom.

Při off-line učení jsou všechny trénovací instance poskytnuty systému naráz.

Je možný i způsob „mezi“, tj. příklady jsou předkládány po jednotlivých souborech.

## Inkrementální a neinkrementální učení

On-line a off-line učení jsou způsoby předávání příkladů algoritmu. Avšak samotný algoritmus rovněž může zpracovávat předkládaná data buď po jednotlivých instancích, což je tzv. inkrementální učení, nebo také může zpracovat množství instance naráz, což je naopak tzv. neinkrementální učení.

Přestože inkrementální metody se zdají být nejprimitivnější právě pro on-line učení a neinkrementální pro off-line, je důležité mit oba způsoby oddělené. Je totiž možné adaptovat neinkrementální metodu na on-line učení uchováním předchozích příkladů v paměti a každou novou instanci k nim přidat; poté znova spustit algoritmus s rozšířenou množinou trénovacích příkladů. Podobně lze použít inkrementální algoritmus pro off-line poskytovaná data tak, že se metoda nechá mnohokrát iterativně proběhnout trénovací množinou.

Algoritmus je inkrementální ve stupni k pokud (jsou-li poskytnuta on-line data) znova zpracovává nanejvýš k předchozích příkladů po přijetí každé trénovací instance. Algoritmus je neinkrementální pokud znova zpracovává všechny předchozí příklady. Oba přístupy mají své výhody:

Neinkrementální: lze vytvářet statistiky o trénovacích příkladech a tím umožnit lepší rozhodování.

Inkrementální: učinnější pro velké soubory dat. Vhodnější pro modelování lidského chování a pro autonomní činitele.

## Representace zkušenosti

Před započetím získávání znalostí založené na zkušenosti je nutné zkušenosť vhodně reprezentovat.

Nejjednodušší přístup využívá **boolské či binární vlastnosti** – specifikace přítomnosti nebo absence určité vlastnosti. Např. předpokládejme, že nějaký tvor může vykazovat 3 možné příznaky: **chlupatost, štěkavost, hladovost**. Lze tedy reprezentovat tvora, vykazujícího 1. a 3. symptom, avšak nikoliv 2., jako množinu {chlupatý, →štěkavý, hladový}. Ekvivalentní reprezentace používá **bitové vektory**, kde pozice příslušného bitu odpovídá určité vlastnosti, přičemž 1 indikuje přítomnost a 0 nepřítomnost této vlastnosti.

Vektor **101** tedy popisuje chlupatého, nestěkajícího, hladového tvora.

Poněkud složitější formalismus popisuje každou instanci jako **soubor nominálních atributů** – obdoba boolských vlastností, která však umožňuje více než 2 vzájemně se vylučující hodnoty. Kupř. v uvedeném příkladu lze nahradit druhou vlastnost atributem **ZVUK**, který může nabývat hodnot **štěkání, mluvení, kvokání**. Lze ovšem vždy transformovat nominální reprezentaci do boolského formalismu, ale výsledek nemusí být vždy výhodný. Jsou-li hodnoty atributu navzájem výlučné, boolské kódování může specifikovat některé instance, jež se nikdy ve skutečnosti nemohou vyskytnout (pro určitou kombinaci kódů).

Výše uvedené atributy se nazývají **symbolické** na rozdíl od atributů **numerických**.

Numerické atributy mohou nabývat hodnot reálných, celočíselných, příp. ordinálních. Např. je možné popsat délku chlupů, silu štěkání a velikost hladu zmíněného trona. Numerické domény jsou velmi časté.

Je-li dán **k** numerických atributů, pak lze reprezentovat libovolnou danou instanci jako **bod v k-rozměrném prostoru**, kde atributy určují osy. Někdy se takovému prostoru říká **prostor instance**.

Pozn.: binární vektory lze považovat za speciální případ numerického kódování, kde hodnoty jsou omezeny na 0 a 1. Proto je snadné mnoha metod učení, které pracují s numerickými reprezentacemi, přizpůsobit pro binární reprezentaci (a také naopak).

Některé úlohy jsou však inherentě **relační** a proto vyzadují sofistikovanější formalismus. Např. situace se 3 kostkami a stolem: konkrétní instance, kdy kostky A a B leží na stole a kostka C leží na kostce A:



Danou situaci lze popsát souborem **relačních literálů**: (na A stůl), (na B stůl), (na C A), (volný C), (volný B). Každý literál popisuje jednotlivé hledisko, ale jejich počet pro různé situace může být různý. Relační jazyky zahrnují schémata vlastnosti, nominální i numerická. (volný B) je ekvivalentní boolské vlastnosti, (délka A 2.5) např. může specifikovat numerické hodnoty objektů. Cenu je ovšem vysoká složitost!

## 5 PARADIGMAT STROJOVÉHO UČENÍ

ML tvorí rozsáhlé pole, kde jednoticím činitelem je společný soubor cílů a podobných metodologií využitelných v hodnocování. Přesto existuje poměrně významné rozdělení ML (resp. výzkumníků v této oblasti) na následující skupiny (paradigmata):

① **Neuronové sítě:** reprezentují znalost pomocí mnoha-vrstvé sítě s jednotkami aktivovanými pomocí pravových hodnot řídicích aktivitu ze vstupních uzlů skrz vnitřní do výstupních. Váhy přiřazené jednotlivým spojům mezi neurony určují množství řízené aktivity v jednotlivých případech. Aktivace výstupních uzlů sítě může být převedena na numerické predikce nebo na diskrétní rozhodování. Zlepšení přesnosti klasifikace či predikce se dosahuje změnou vah spojů.

② **Učení založené na instancech (případech):** znalost je reprezentována specifickými případy (příklady) a spoléhá na flexibilní potvrzovací metody pro výběr těchto případů a jejich aplikaci na nové situace.

Jeden možný přístup je vyhledání již zaznamenaného případu nejbližšího podobného (pomocí nějaké metody vzdálenosti) okamžité situaci a použití tohoto případu pro klasifikaci či predikci. Postačuje i pouhé ukládání tréninkových příkladů do paměti, generalizace se uskuteční v čase výběru.

③ **Genetické algoritmy:** znalost je reprezentována jako soubor boolských nebo binárních znaků (někdy používaných jako podmínky a akce pravidel). Standardní učící algoritmus generuje nové kandidáty (potomky) z rodičů majících příznivé vlastnosti (vysoké skóre); skóre je dané nějakou měrou výkonnosti.

④ **Indukce pravidel:** používá IF-THEN pravidel (IF splněny podmínky THEN následuje akce), rozhodovacích stromů, či obdobné logické struktury znalostí. Informace o akcích je uložena buď v listech stromů nebo v THEN-části pravidla. V podmínečné části se používá logický povídavací proces.  
Učící algoritmus obvykle provádí tzv. „lačný“ prohledávací proces v prostoru rozhodovacích stromů (nebo v souboru pravidel) za použití statistické využitelnosti funkce pro výběr atributů, které mají být začleněny do znalostní struktury. Většina metod rekursivně rozděluje trénovací data do disjunktních množin a pokouší se summarizovat každou množinu jako konjunkci logických podmínek.

⑤ **Analytické učení:** znalost reprezentována logickými pravidly, avšak typicky využívá vyhledávání pro řešení mnohakrokrovního problému. Inferenční pravidla jsou použita k hledání důkazu teoremu, jenž vyjadřuje řešený problém. Učící algoritmus spolehlá na tzv. výchozí znalost pro konstrukci důkazu či vysvětlení, důkazy zkompiluje do složitějších pravidel řešících podobné situace menším hledáním (nebo dokonce jen v jednom kroku).

Co je nutno před zvolením učícího algoritmu určit

Inkrementální nebo dávkové učení?

Zapomínání minulých trénovacích instancí?

Korektory obvykle musí udržovat záznamy o rozsáhlých souborech instancí. Pro inkrementální učení to je spatné - učení je snazší (jednodušší) pokud po prozkoumání trénovací instance ji můžeme zapomenout. Inkrementální učení je řízeno novými instancemi a nepotřebuje uchovávat celou historii.

Správná (či optimální odpověď) vs. konvergence ke přiměřené odpovědi?

Diagnóza je buď správná nebo chybná. Na postup lde učení může být odpovědi více.

Rozsah trénovací množiny?

Lepší algoritmy se učí z méně příkladů.

Pořadí předkládaných trénovacích instancí?

Může ovlivnit kupti rychlosť učení (od jednoduchého ke složitému...).

Končí někdy proces učení?

Užitečnou vlastností algoritmu je rozpoznaní okamžiku, kdy už není co se dál učit.

Je naučená informace přístupná?

U NN a GA není, což může vzbuzovat nedůvěru uživatelů. Pravidla ES lze snadno zobrazit a analyzovat. Rozložení vah u NN může být záhadné a nesrozumitelné.

## INDUKTIVNÍ UČENÍ

Patří k nejdůležitějším metodám ML. Má významné aplikace v mnoha oborech.

Intuitivní chápání induktivního učení:


- Kolik rvan je třeba spatřit, aby člověk došel k usudku, že vrána je černá?
- Jak lze porozumět konceptu „prvočíslo“ známe-li pojem „přirozené číslo“ (1, 2, 3, ...) a význam aritmetických operátorů? Předkládáme-li postupně příklady a protipříklady prvočísel, např. 2ano, 3ano, 4ne, 5ne, 114ne, 123ne, 31ano, pak zde nelze ještě určit, zda jiná přírož. čísla jsou nebo nejsou prvočísla, např. č. 4.

V praxi se ovšem snažíme o závěry: jiná sudá č. než 2 nebyla prvočíslo - z toho lze (správně) generalizovat, že kromě 2 žádné sudé číslo není prvočíslo. Dále dva příklady (11, 31) končí 1 a žádný z protipříkladů ne - mohli bychom usoudit (chybně), že přírož. č. končící 1 jsou prvočísla (21 není); tzv. přehnaná (neoprávněná) generalizace. Rovněž lze indukovat (na základě uvedených příkladů), že žádné prvočíslo není > 100 (chybně; tzv. podceněná generalizace).

Přeceněná i podceněná generalizace jsou na základě předložených dat obě správné. Přidali-li bychom např. 21ne, 109ano, pak je nutno obě chybné generalizace zmírnit nebo opustit.

**Induktivní inference:** proces opakovánoho zjednoování a modifikace předchozích hypotéz o konceptu pomocí příkladů a protipříkladů.


Cílem induktivní inference je konvergence ke správné odpovědi za předpokladu, že jsou dána dostatečná data. Jdrem induktivního inferenčního procesu je tzv. aktualizační procedura, která má jako vstupy a) nové příklady a protipříklady, b) předchozí příklady a protipříklady, c) aktuální hypotézu, a na výstupu poskytuje novou (korigovanou) hypotézu:



Základem induktivní inference je soubor konceptů, který vytváří možné hypotézy. Každý koncept reprezentuje soubor instancí (speciální koncepty reprezentující samy sebe): instance - přirozená čísla, koncepty - podmnožiny přiroz. čísel v uvedeném příkladu.

Přirozené částečné uspořádání konceptů je **hierarchie konceptů**: protože každý koncept zastupuje soubor instancí, pak nějaký koncept A je považován za specifitější než koncept B pokud platí  $A \subseteq B$ . V takovém případě hovoříme o tom, že A je hierarchicky niže než B. Hierarchie závisí na aktuální reprezentaci.

• **Explicitní hierarchie** - je v podstatě orientovaný acyklický graf. Příklad:



Složitější koncepty:

- konjunktivní koncept (např. liché A prvočíslo)
- disjunktivní koncept (např. přirozené číslo sudé V prvočíslo)


Komplexnější koncepty musí být při tvorbě hierarchie předem zahrnuty do grafu jako uzly.

• **Hierarchie vztahů** - vztah je neuspořádaný soubor pevného počtu vlastností; vlastnost je posloupnost (uspořádání) pevného počtu aspektů; aspekt je buď základní term nebo symbol otazníku (?). Příklad: /, aspekty { (velký, červený, kruh), (velký, ?, ?) } vztah

Vztah se skládá ze 2 vlastností po 3 hledisech (aspektech). Koncept reprezentuje všechny dvojice velkých objektů, z nichž jeden je červený kruh.

Hierarchie vzorů vytváří uspořádání následovně:  
 základní termíny jsou specifickější než proměnné. deoxy  
 Určitá vlastnost je specifickější než jiná pokud každý  
 její aspekt je buď identický s odpovídajícím aspektem  
 druhé vlastnosti nebo je specifickější, a nejméně jeden  
 aspekt ~~je~~ v první vlastnosti je striktě specifickější než  
 odpovídající aspekt ve vlastnosti druhé.

Určitý vzor (koncept) je specifickější než jiný, pokud  
 vlastnosti v obou vzorech mohou být položeny do 1-1  
 korespondence, přičemž každá vlastnost prvního vzoru  
 je buď identická s odpovídající vlastností vzoru  
 druhého nebo specifickější, a nejméně 1 vlastnost  
 prvního vzoru je striktě specifickější než odpovídající  
 vlastnost v druhém vzoru.



Obr.: část vzorové hierarchie

Hierarchie vzorů se používá tehdy když jsou koncepty příliš rozsáhlé, aby se daly explicitně reprezentovat. Proto se používají metody výpočtu obecnosti (specifickosti) konceptů.

### Doplňek

#### Obecný a striktě obecný

Uvažme soubor instancí, pozitivně klasifikovaných hypotézou  $h_1$  a  $h_2$ . Kladě-li  $h_2$  méně omezení na instance, pak je schopna klasifikovat pozitivně více instancí (každá instance klasifikovaná pozitivně hypotézou  $h_1$  bude také vždy pozitivně klasifikovaná hypotézou  $h_2$ ).

Pak říkáme, že  $h_2$  je obecnější než  $h_1$  (a  $h_1$  je specifickější než  $h_2$ ). Obecnější hypotéza oklasifikuje pozitivně více instancí.

Nechť  $x \in X$  je libovolná instance a  $h \in H$  nějaká hypotéza. Vyhovuje-li  $x$  hypotéze  $h$ , pak platí  $h(x) = 1$ .

Nechť  $h_j$  a  $h_k$  jsou boolské funkce definované na  $X$ . Pak  $h_j$  je obecnější nebo stejně obecná jako  $h_k$  ( $h_j \geq_g h_k$ ) pouze tehdy, platí-li

$$(\forall x \in X) [(h_k(x) = 1) \rightarrow h_j(x) = 1]$$

Striktě obecnější ( $h_j >_g h_k$ ) pouze tehdy, platí-li

$$(h_j \geq_g h_k) \wedge (h_k \neq_g h_j)$$

## • Konjunktivní hierarchie

Vzory jsou často limitovanou metodou k popisu vlastnosti "neboť" vyžadují, aby byly předem určeny všechny vlastnosti. Kromě toho mohou být určeny jen vlastnosti přítomné, nikoliv chybějící v konceptu.

Konjunktivní hierarchie zobecňuje vzorové hierarchie v mnoha ohledech, včetně obou uvedených.

Každý koncept je reprezentován konjunkcí, kde konjunkce je seznam libovolné délky:

$$[C_1, C_2, \dots, C_n]$$

Každá konjunkce  $C_i$  má formu

$$[\neg] P_i(\text{Arg}_i1, \dots, \text{Arg}_i m)$$

kde  $P_i$  je predikátový symbol,  $\text{Arg}_ij$  jsou seznamy argumentů  $P_i$ ,  $\neg$  je operátor negace ( $[\neg]$  znamená, že negace je volitelná: konjunkce může být negativní nebo pozitivní).


Příklad: 4 koncepty:

Koncept 1:  $[\text{na}(Z, X), \text{na}(Z, Y), \text{box}324(Y), \text{klin}(Z)]$


Koncept 2:  $[\text{na}(Z, X), \text{na}(Z, Y), \neg\text{dote}(X, Y)]$

Koncept 3:  $[\text{na}(Z, X), \text{na}(Z, Y), \text{centrovan}\text{e}-\text{na}(Z, Y)]$

Koncept 4:  $[\text{na}(Z, X), \text{na}(Z, Y)]$



## Koncept „OBLOUK“ (Patrick Winston)



Koncept 1 se vztahuje ke struktuře v níž klin spočívá na konkrétním boxu (box324) a na libovolném jiném objektu.

Koncept 2 popisuje strukturu v níž každý objekt spočívá na libovolných dvou nedotýkajících se objektech.

Koncept 3 popisuje strukturu v níž nějaký objekt je na lib. dvou objektech a na jednom z nich je centrováně.

Koncept 4 se vztahuje ke strukturálně nějaký objekt spočívá na nějakých dvou objektech.

Zjedně je 4. koncept obecnější než ostatní a 1., 2. a 3. nejsou hranají ani konkrétnější ani obecnější.

### Induktivní inferenční algoritmy

Vstupem jsou + a - příklady, výstupem je hypotéza.

Většinou jsou jako (proti)příklady použity nejspecifičtější příklady (instance) - avšak jako příklady lze použít všechny koncepty, je však třeba opatrnosti při použití významu takových konceptů.

Positivní (+) příklady nepředstavují problém: je-li koncept „prvočísla“ předložen jako pozitivní příklad, pak v důsledku toho všechna prvočísla jsou v cílovém konceptu (výstup inferenčního algoritmu) T:

$$+: \forall x \in X, x \in T$$

Avšak použití konceptu jako negativního (-) příkladu neznamená, že v cílovém konceptu T není žádoucí prvočíslo, nýbrž že alespoň jedno tam není:

*Vicekna prvočísla nepatří, ale nějaké prvočíslo mohou aho.*  
-:  $\exists x \in X, x \notin T$  (tzv. slabá negace; silná negace:  
 $\forall x \in X, x \notin T$ )

Je-li dána hierarchie konceptů, existují dvě přizněné heuristiky pro vytrážení hypotéz/cílových konceptů:

- 1) Vyber nejspecifičtější koncept, který zahrnuje příklady nyní známé;
- 2) vyber nejobecnější koncept, který neobsahuje praktické příklady nyní známé.

V umělé inteligenci existují dvě použití těchto heuristik:

## ① Nejlepší odhad („best guess“)

Tato verze induktivní inference v každém okamžiku činnosti uvažuje jedinou hypotézu o konceptu, která se nejlépe shoduje s doté doby prozkoumanými příklady a protipříklady. Vždy když je zkouman nový údaj, tak předchozí hypotéza je minimálně narušena, aby vyhověla tomuto údaji.

Protože však může být několik způsobů jak minimálně narušit hypotézu (koncept), nevhodný výběr příkladu může občas vést ke zpětnému návratu po vlastní stopě (backtracking).


Pojem *minimální narušení* lze interpretovat různě.

Procedura podle P. Winstona:

- 1) Dán  $\Theta$  (nový): Minimálně zobecni poslední hypotézu tak, aby pokryla nový  $\Theta$  a zároveň nepokryla žádný z předchozích  $\Theta$ . Není-li to možné (neexistuje-li takový koncept), vrát se zpět k předchozí volbě a znova zpracuj  $\Theta$  až do daného bodu. Neexistuje-li taková volba, pak skonči neúspěchem.
- 2) Dán nový  $\Theta$ : Drž, že současně platná hypotéza nepokrývá nový  $\Theta$ . Pokud pokrývá, vrát se zpět k předchozí volbě a znova zpracuj  $\Theta$  až zpracované k danému okamžiku. Neexistuje-li taková volba, pak skonči neúspěchem.

Pozn.: Ačkoliv uvedená procedura je „konzervativní“ z hlediska vytáčených generalizací, ne vždy najde tu nejspecifickější správnou hypotézu.

Příklad: mějme např. následující rozšířenou hierarchii numerických konceptů:



- a)  $\Theta \oplus \{2, 36, 214\}$       H: ?  $\{2, 36, 214\}$   
     $\Theta \oplus \text{lichá prvoč.}$        $\rightarrow$  nová H: sudá nebo prvočísla  
     $\Theta \oplus \{150\}$        $\rightarrow$  nová H: sudá nebo prvočísla  
     $\Theta \oplus \text{přiroz.} < 200$        $\rightarrow$  nenarušuje platnou hypotézu  
    Konečná hypotéza H: sudá nebo prvočísla
- b)  $\Theta \oplus \text{sudá} < 100$       H: ?  $\text{sudá} < 100$   
     $\Theta \oplus \{150\}$        $\rightarrow$  nová H: sudá přiroz.  
     $\Theta \oplus \{2, 36, 214\}$        $\rightarrow$  platná H narušena, návrat.....  
     $\Theta \oplus \{2, 36, 214\}$        $\rightarrow$  nová H: přiroz. < 200  
     $\Theta \oplus \{2, 36, 214\}$        $\rightarrow$  nenarušuje platnou hypotézu  
    Konečná hypotéza H: přiroz. < 200

## ② Nejménší závazek („least commitment“)

Předchozí metoda si občas vynutí zpětný návrat po vlastní stopě. Tato metoda uznává skutečnost, že obvykle není k dispozici dost informace k vytvoření jedné hypotézy. Místo toho se druhá metoda snaží po celou dobu udržovat hranice možných konceptů, udržujíc je co nejdále od sebe. Výstupní hypotéza tedy není jediný koncept, nýbrž ohrazení (vymezení) možných konceptů.

Používá se Mitchellův prostor verzí: Po celou dobu se udržují dvě sady konceptů - koncepty horní hranice a koncepty dolní hranice. Aktuální koncept je pak přinejmenším tak specifický jako jeden z konceptů horní hranice a přinejmenším tak obecný jako některý z konceptů spodní hranice.

Počáteční horní /spodní hranice je nejobecnější /nejspecifickější koncept hierarchie. Tím, jak přicházejí nové příklady a protipříklady, spodní hranice se zvyšuje a horní snižuje. Jejich kardinalita se může budovat zmenšovat nebo zvětšovat.

Skládají-li se v určitém okamžiku obě hranice z téhož jediného konceptu, pak je to cílový koncept.

### 1. Dán nový $\Theta$ :

- Odstraň z U (horní hranice) všechny koncepty jež nejsou tak obecné jako příklad. ↓ specifikace
- Minimálně zobecni každý koncept v L (spodní hranice), aby byl tak obecný jako nový příklad. ↑ zobecnení
- Odstraň z L všechny koncepty, které nejsou specifickější než některý prvek U.
- Odstraň z L jakýkoliv koncept obecnější než nejší jiný v L.

### 2. Dán nový $\Theta$ :

- Odstraň z L všechny koncepty obecné jako  $\Theta$ .
- Maximálně specializuj každý koncept v U tak, aby nebyl tak obecný jako nový  $\Theta$ .
- Odstraň z U všechny koncepty, které nejsou obecnější než nějaký prvek z L.
- Odstraň z U jakýkoliv koncept jenž je specifickější než nějaký jiný koncept v U.

Příklad: (tatož hierarchie numerických konceptů)

počáteční horní hranice : přiroz. č.

--- spodní --- : sudé < 100, neprvočísla, {150}, liché prvoč., {2, 36, 214}

⊕ {2, 36, 214} → nová U: přirozená čísla

→ nová L: {2, 36, 214}

⊕ prvočísla → nová U: přirozená čísla

→ nová L: sudá nebo prvočísla

⊖ lichá č. → nová U: sudá nebo prvočísla

→ nová L: sudá nebo prvočísla

Konečná hypotéza: Sudá čísla nebo prvočísla

↑ Pozitivní příklady zobecňují specifické modely a „proškrťávají“ obecné modely.

↓ Negativní příklady specializují obecné modely a „proškrťávají“ specifické modely.