



# Mentální reprezentace znalostí





# Znalosti



## Znalost

= lidský odhad uložený v mysli získaný pomocí zkušeností a interakcí s okolím

= fyzický, mentální či elektronický záznam o vztazích, o kterých věříme, že existují mezi skutečnými či imaginárními entitami, silami, jevy...

= organizované informace využitelné na řešení problémů (Wolf, 1990)

= ...

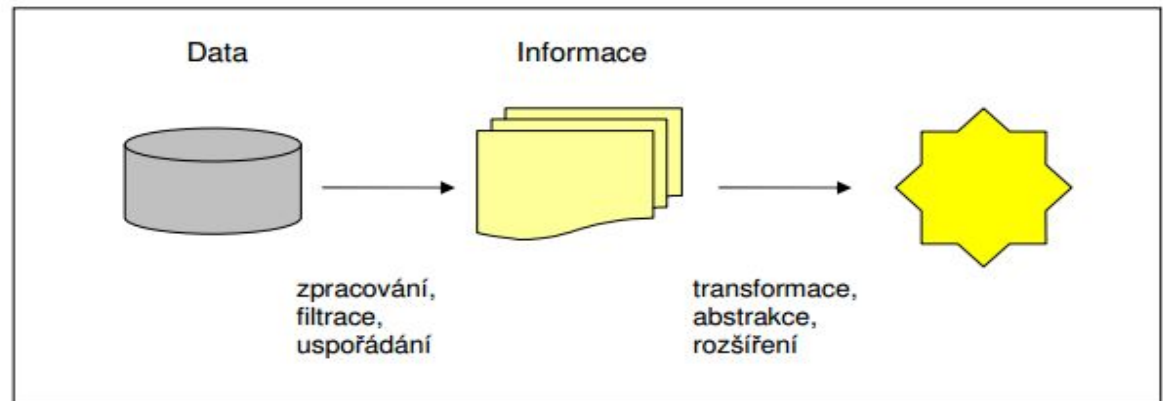
## Znalosti:

- získání pozorováním či odvozováním

- Explicitní → deklarativní repr.(co)
- Implicitní (primárně skryté, sdělitelné) → procedurální reprezentace (jak)
- Tacitní (nevědomé, nesdělitelné)

1. Data (+ relevance + účel =)
2. Informace (+ aplikace =)
3. Znalosti (+ intuice + zkušenosti =)
4. Moudrost

[Tobin, 1996]





# Znalosti



## Znalost

= lidský odhad uložený v mysli získaný pomocí zkušeností a interakcí s okolím

= fyzický, mentální či elektronický záznam o vztazích, o kterých věříme, že existují mezi skutečnými či imaginárními entitami, silami, jevy...

= organizované informace využitelné na řešení problémů (Wolf, 1990)

=...

## Znalosti:

- získání pozorováním či odvozováním

- **Explicitní** → deklarativní repr.(co)
- **Implicitní** (primárně skryté, sdělitelné) → procedurální reprezentace (jak)
- **Tacitní** (nevědomé, nesdělitelné)

Znalost: **umění vařit** (skutečná, koordinovaná akce) X Informace: **kuchařská kniha** (popis),  
informace je/není, znalost stupňovaná

(pěkné pojednání o rozdílu mezi informacemi a znalostmi: [Blog: Informace vs.znalosti](#))

- reprezentace: **jazyky** – syntax (pravidla vyjádření výrazů) a sémantiku (významy)


# Role reprezentace znalostí

- **Náhražka reality** (odhad důsledků akcí)
- **Soubor ontologických závazků** (v jakých pojmech uvažovat o světě)  
(diagnostika: MYCIN – pravidla, INTERNIST rámce)
- Prostředí pro lidské vyjadřování (**jazyk**)
- **Organizace znalostí** → kognitivní úspornost (hierarchie) –  
exempláře/prototypy

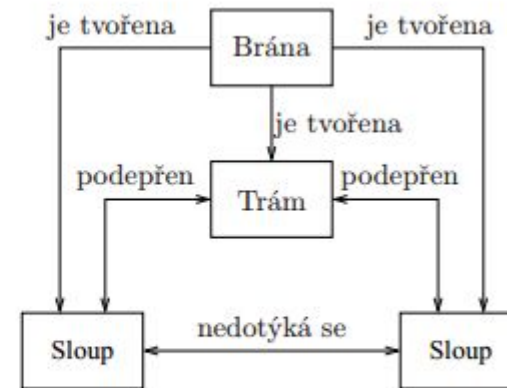
→ využití v expertních systémech  
(znalosti získány od experta)

# Reprezentace znalostí

- **Asociativní** – odpozorované/pravděpodobné vztahy objektů, nemusí být zdůvodnitelné




Obrázek 2: Jednoduchá skladba objektů - brána



Obrázek 3: Vztahy mezi objekty brány


# Reprezentace znalostí

- **Asociativní** – odpozorované/pravděpodobné vztahy objektů, nemusí být zdůvodnitelné
- **Kauzální** – zdůvodnitelné vztahy, příčina → důsledek
  - Inferenční sítě (hypotézy a jejich důsledky)
  - Pravděpodobnostní logika
  - Fuzzy logika



if A and B then M  
if A or C then N  
if B and not C then O  
if C and D then P  
if M or O then X  
if M and N then Y  
if N or O and P then Z

Obrázek 4: Příklad inferenční sítě



Obrázek 5: Pravděpodobnost, že člověk je vysoký

$$P(d|p) = \frac{P(p|d) \cdot P(d)}{P(p)}$$

$p$  podmínka pravidla,  
 $d$  důsledek pravidla,

U fuzzy logiky v inferenčních sítích je potřeba určit věrohodnost konjunkce hypotéz

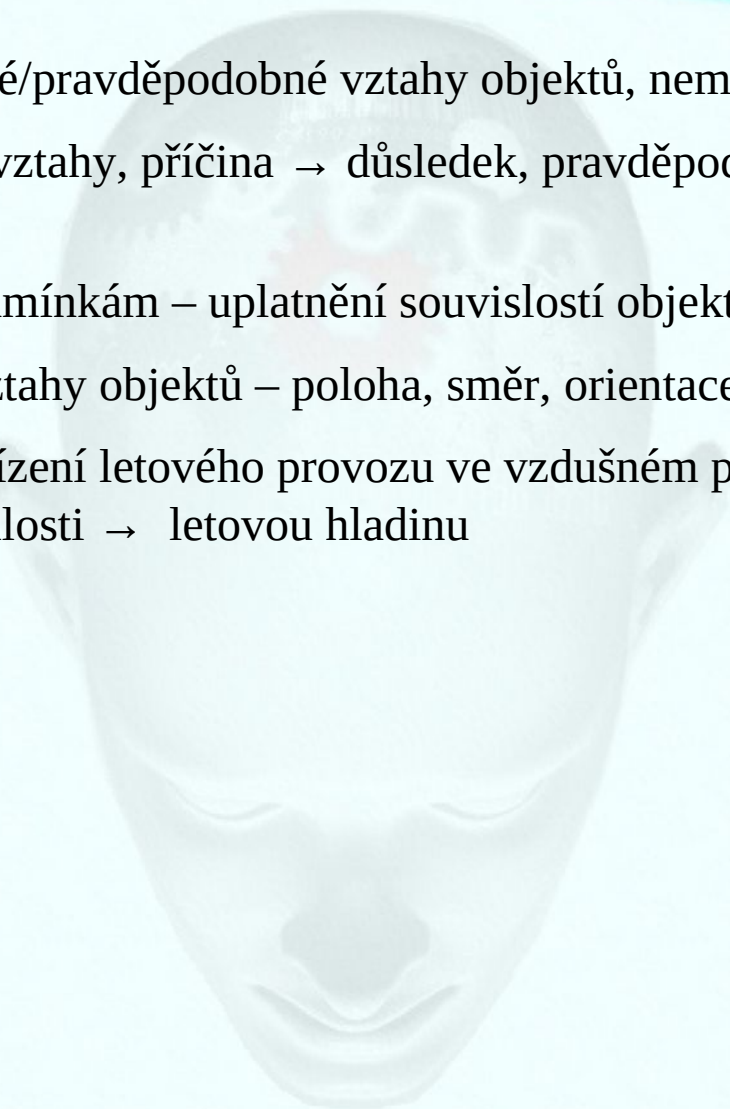
$$V(\wedge(t_1, t_2, t_3, \dots, t_n)) = \min(V(t_1), V(t_2), V(t_3), \dots, V(t_n))$$



# Reprezentace znalostí



- **Asociativní** – odpozorované/pravděpodobné vztahy objektů, nemusí být zdůvodnitelné
- **Kauzální** – zdůvodnitelné vztahy, příčina → důsledek, pravděpodobnostní/fuzzy logika, inferenční sítě
- **Kontextové** – vztahy ~ podmínkám – uplatnění souvislostí objektů (info dle kontextu)
- **Prostorové** – prostorové vztahy objektů – poloha, směr, orientace, rychlost...
  - informace potřebné pro řízení letového provozu ve vzdušném prostoru: podle typu letadla, jeho kurzu a rychlosti → letovou hladinu





# Reprezentace znalostí



- **Asociativní** – odpozorované/pravděpodobné vztahy objektů, nemusí být zdůvodnitelné
- **Kauzální** – zdůvodnitelné vztahy, příčina → důsledek, pravděpodobnostní/fuzzy logika, inferenční sítě
- **Kontextové** – vztahy ~ podmínkám – uplatnění souvislostí objektů (info dle kontextu)
- **Prostorové** – prostorové vztahy objektů – poloha, směr, orientace, rychlost...
- **Taxonomické** – souvislosti objektů, které generalizované
- **Časové** – znalosti založené na změnách v určitých časech – podmínění časově vázaných změn či výskytů jiných objektů
  - Jízdní řády



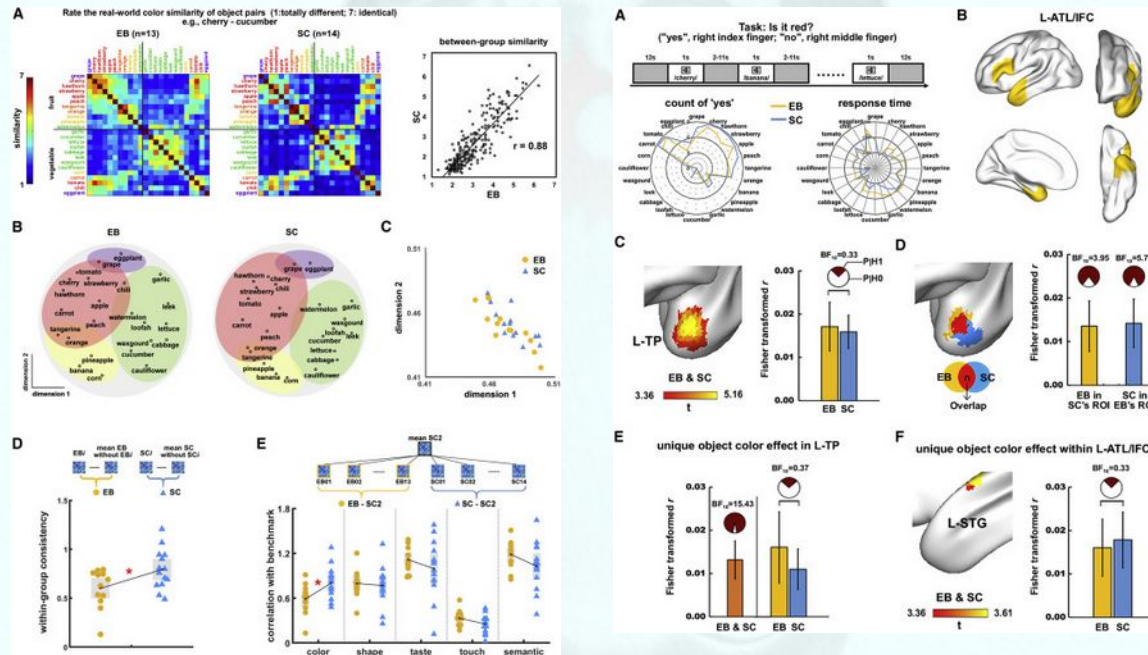
# Reprezentace znalostí



- **Asociativní** – odpozorované/pravděpodobné vztahy objektů, nemusí být zdůvodnitelné
- **Kauzální** – zdůvodnitelné vztahy, příčina → důsledek, pravděpodobnostní/fuzzy logika, inferenční sítě
- **Kontextové** – vztahy ~ podmínkám – uplatnění souvislostí objektů (info dle kontextu)
- **Prostorové** – prostorové vztahy objektů – poloha, směr, orientace, rychlost...
- **Taxonomické** – souvislosti objektů, které generalizované
- **Časové** – znalosti založené na změnách v určitých časech – podmínění časově vázaných změn či výskytů jiných objektů
- **Modelové** – známé/předpokládané souvislosti více provázaných objektů – ty se ovlivňují
  - křížovatky

# Reprezentace znalostí v paměti

- Kde?
- Experimenty s kognitivně slepými jedinci




- Dorsal anterior temporal lobe – object-color knowledge pro obě skupiny
- Visual cortex – object-color knowledge jen pro lidi se zrakem
- there are (at least) two forms of object knowledge representations in the human brain: sensory-derived and language- and cognition-derived knowledge

# Reprezentace znalostí v paměti


## • Kde?

- Testování pacientů se semantickou demencí
- Perceive in one modality and interpret in another one


a Distributed-only view



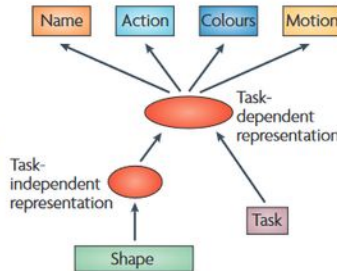
Gating architecture



b Distributed-plus-hub view




Convergent architecture




c Colour and object recognition


Task one stimulus: Which is coloured correctly?




Task one performance



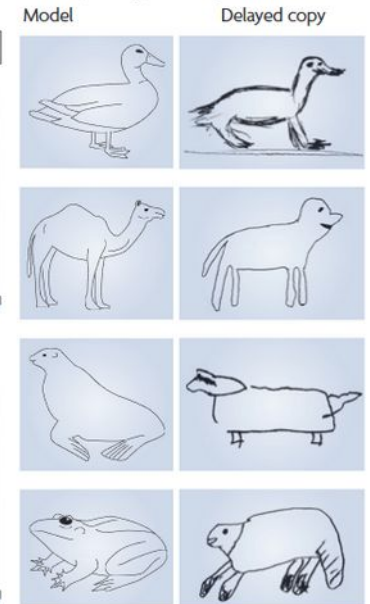
Task two stimulus: Which is the real animal?



Task two performance



d Delayed-copy drawing

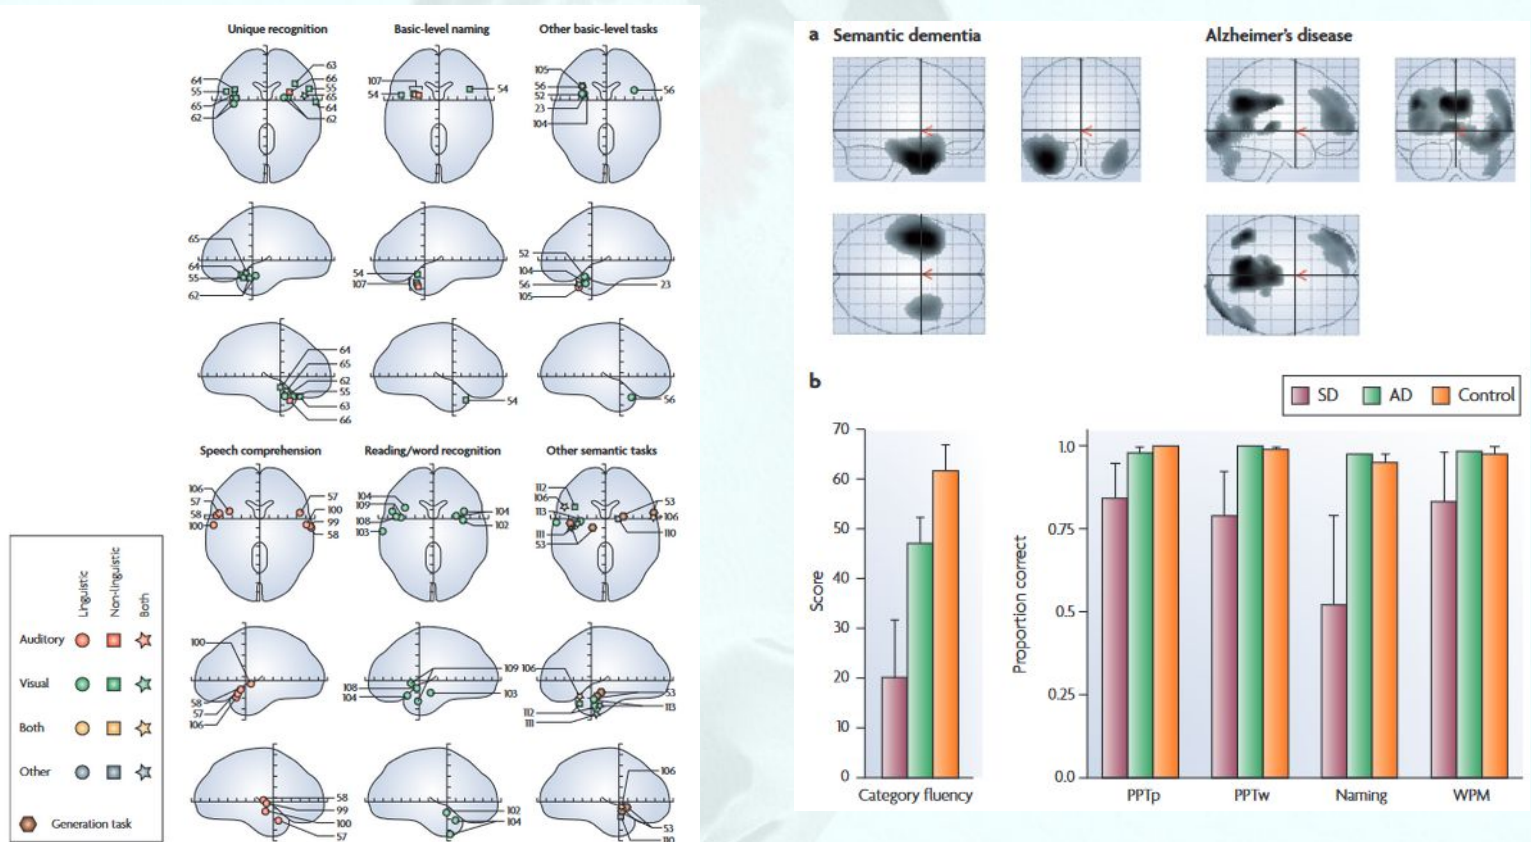


Patterson, Karalyn, Peter J. Nestor, and Timothy T. Rogers. "Where do you know what you know? The representation of semantic knowledge in the human brain." *Nature reviews neuroscience* 8.12 (2007): 976-987.

# Reprezentace znalostí v paměti

- Kde?

- Testování pacientů se semantickou demencí



Patterson, Karalyn, Peter J. Nestor, and Timothy T. Rogers. "Where do you know what you know? The representation of semantic knowledge in the human brain." *Nature reviews neuroscience* 8.12 (2007): 976-987.

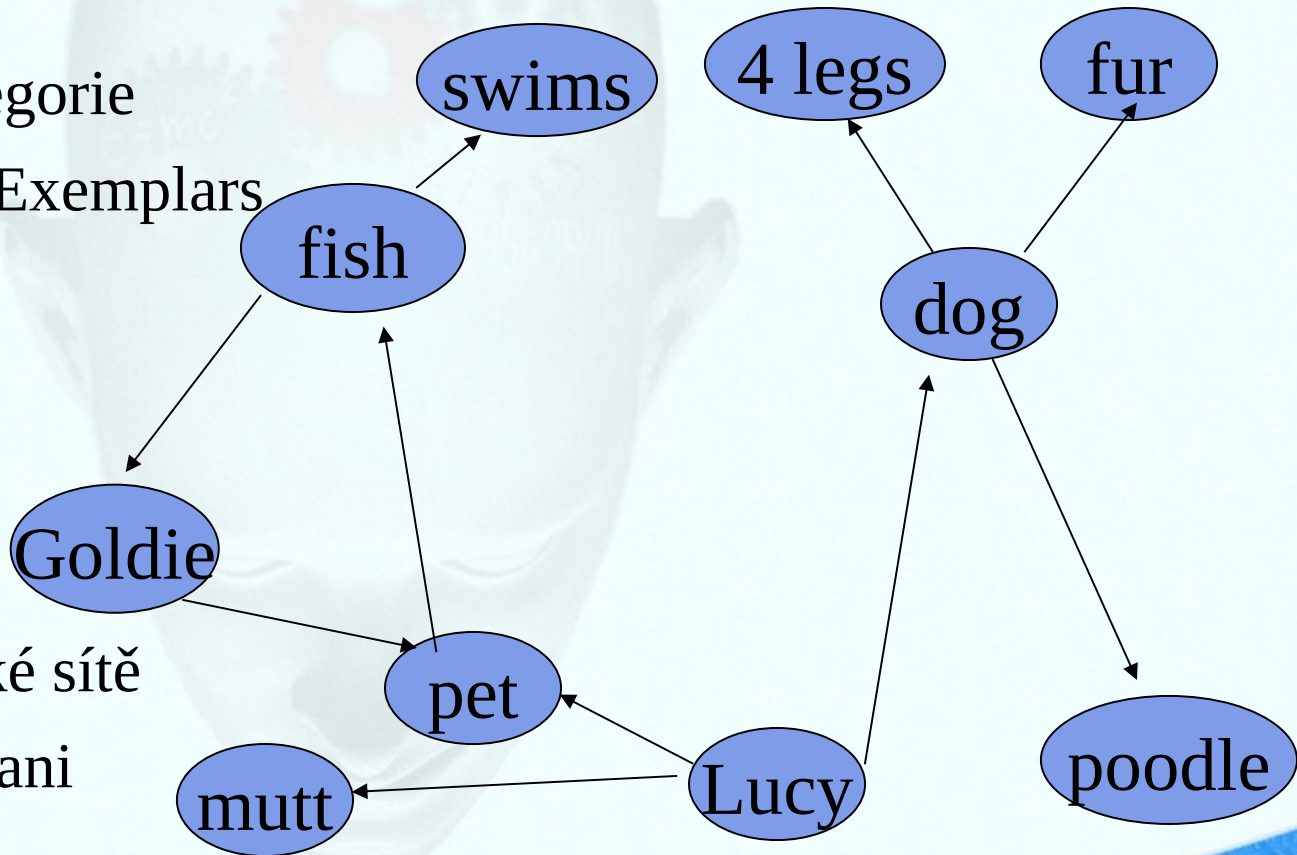
# Reprezentace znalostí v paměti

## • Jak?

- Logika
- Pravidla
- Koncepty a kategorie

- Prototypes, Exemplars
- Sem.site
- Rámce
- Schémata
- Scénáře

- Konekcionistické sítě
- Pravd.rozhodovani
- Představy






# Reprezentace znalostí v paměti





- Logika ~ logic-based programming, symbolic AI, prob. (Markov Logic Networks, Probabilistic Programming)
- Pravidla ~ Expert systems, Decision trees, association rule mining
- Koncepty a kategorie
  - prototypes ~ Nearest Neighbors, Centroid-based clustering
  - Exemplars ~ kNN (→ case-base reasoning)
  - Semantické sítě ~ scene graphs, graph-based repr., knowledge graphs, dynamic graph models
- Konekcionistické sítě ~ Neural nets, DNN, SOMs, Spiking NNets
- Embodied cognition ~ RL
- Probabilistic reasoning ~ Markov dec. process, GMM, VAE, Bayesian models (e.g., Latent Dirichlet Allocation)
- Představy ~ generative models


# Representation learning, embeddings



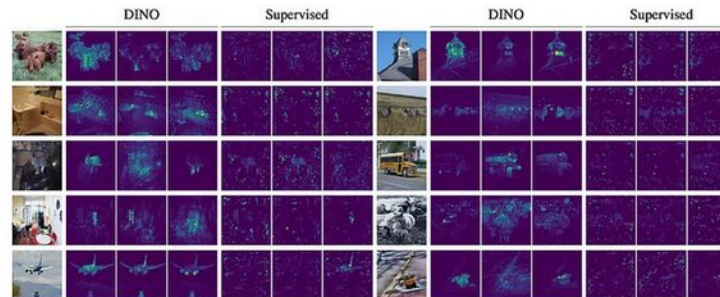
Feature engineering in a machine learning pipeline.



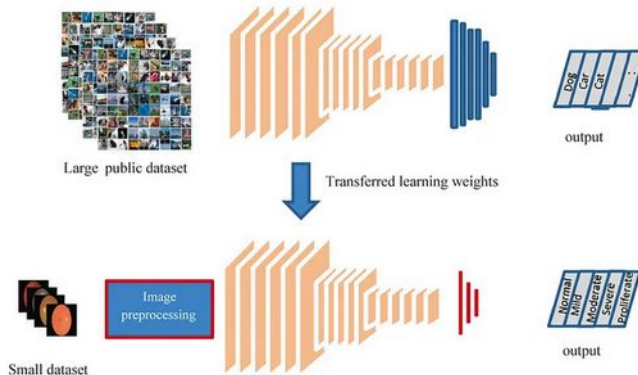
Possible embedding space of hidden representation found in self-supervised models.



Learned representations from different depths in a CNN.



Comparison between the self-attention heads in the last layer for DINO and a supervised ViT.



A visualization of transfer learning; successfully fine-tuning only a tiny section of the model on a significantly smaller dataset.




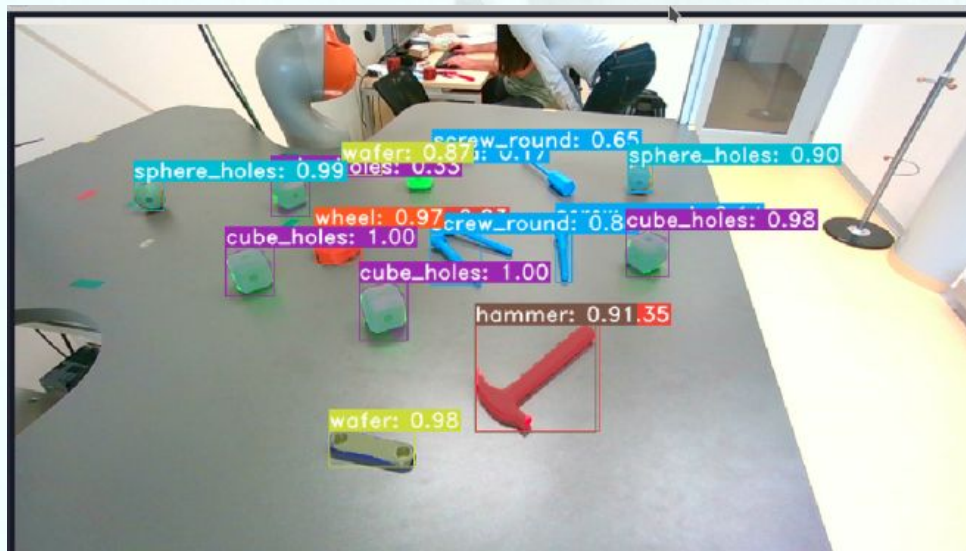

# Reprezentace znalostí v kognitivních robotických systémech



## Kolaborativní robotické pracoviště

Co je potřeba reprezentovat:

- Objekty a jejich vlastnosti
- Vztahy mezi objekty




# Reprezentace znalostí v kognitivních robotických systémech


## Kolaborativní robotické pracoviště

Co je potřeba reprezentovat:

- Objekty a jejich vlastnosti
- Vztahy mezi objekty
- Části objektů a jejich funkční vlastnosti



Obrázek 3.4: Modely objektů použity pro trénování rozpoznávání funkčních částí s barevně odlišeným rozdělením na jednotlivé části.







# Reprezentace znalostí v kognitivních robotických systémech



## Kolaborativní robotické pracoviště

Co je potřeba reprezentovat:

- Objekty a jejich vlastnosti
- Vztahy mezi objekty
- Části objektů a jejich funkční vlastnosti
- Pozice člověka, jeho ruky






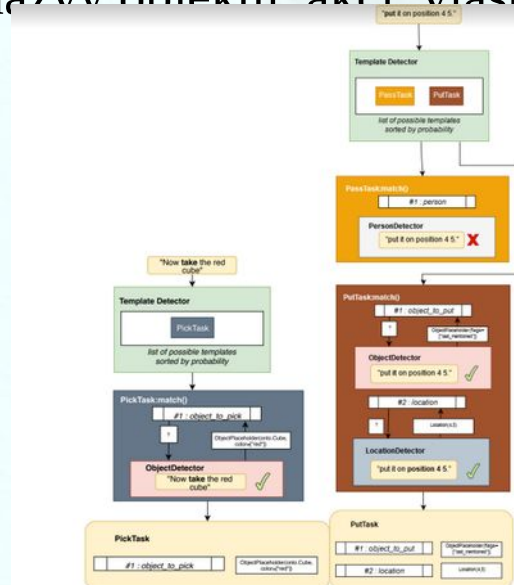

# Reprezentace znalostí v kognitivních robotických systémech



## Kolaborativní robotické pracoviště

Co je potřeba reprezentovat:

- Objekty a jejich vlastnosti
- Vztahy mezi objekty
- Části objektů a jejich funkční vlastnosti
- Pozice člověka, jeho ruky
- Jazyk: názvy objektů, akcí, vlastní pojmenování






# Reprezentace znalostí v kognitivních robotických systémech


## Kolaborativní robotické pracoviště

Co je potřeba reprezentovat:

- Objekty a jejich vlastnosti
- Vztahy mezi objekty
- Části objektů a jejich funkční vlastnosti
- Pozice člověka, jeho ruky
- Jazyk: názvy objektů, akcí, vlastní pojmenování
- Pracovní postupy výrobků



Obrázek 2.4: 3D model stavebnice pejška (dog) v částečně složeném stavu (vlevo) s fotografií skutečného výrobku (vpravo).






# Reprezentace znalostí v paměti



- Logika ~ logic-based programming, symbolic AI, prob. (Markov Logic Networks, Probabilistic Programming)
- Pravidla ~ Expert systems, Decision trees, association rule mining
- Koncepty a kategorie
  - prototypes ~ Nearest Neighbors, Centroid-based clustering
  - Exemplars ~ kNN (→ case-base reasoning)
  - Semantické sítě ~ scene graphs, graph-based repr., knowledge graphs, dynamic graph models
- Konekcionistické sítě ~ Neural nets, DNN, SOMs, Spiking NNets
- Embodied cognition ~ RL
- Probabilistic reasoning ~ Markov dec. process, GMM, VAE, Bayesian models (e.g., Latent Dirichlet Allocation)
- Představy ~ generative models



# Koncepty




## Co je koncept?

- Platón – znalost pojmů vrozená
- 70.léta – velký zájem – rámec, schéma, scénář
- Mentální reprezentace objektu, spojená s určitou znalostí a souborem věř
- K čemu jsou koncepty dobré?
  - Kognitivní ekonomie
  - Vyvozování
  - Jejich kombinace tvoří komplexní myšlenky
  - Proces komunikace

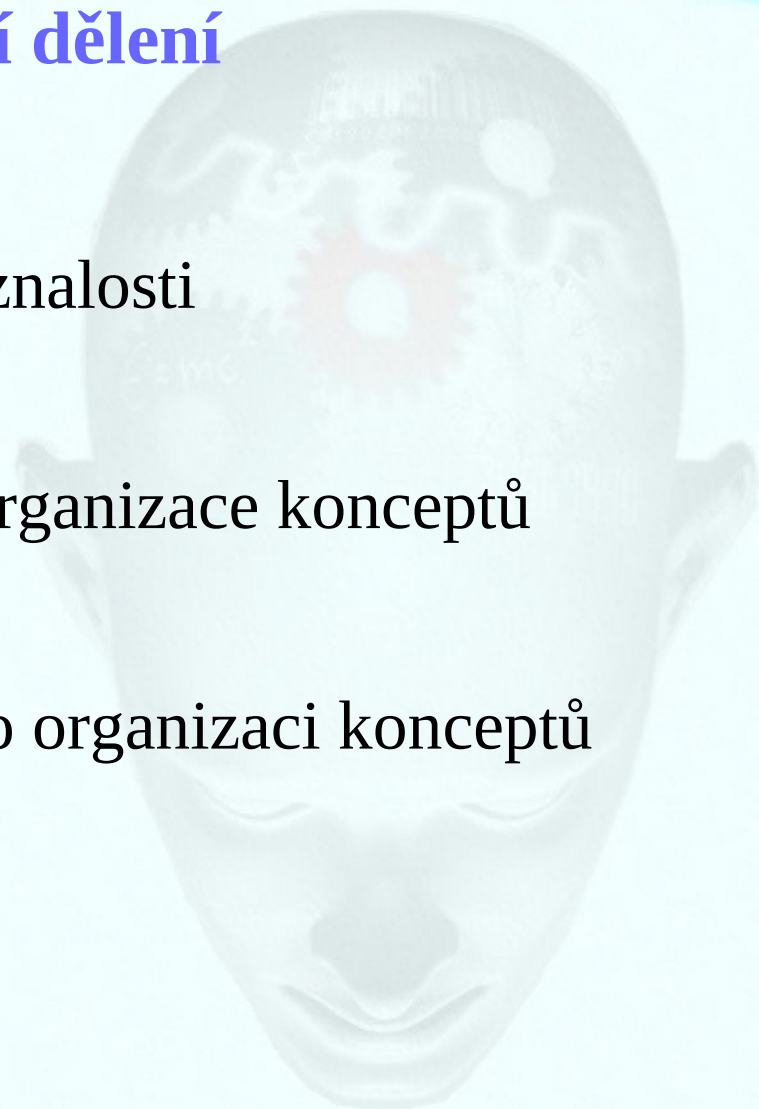


# Koncepty




## Základní dělení

- Koncepty
  - Jednotky znalosti
- Kategorie
  - Slouží k organizace konceptů
- Schémata
  - Rámce pro organizaci konceptů





# Koncepty




## Různé typy konceptů

- 1. Přístup na základě podobnosti – vysvětluje pomocí stupně podobnosti ke známému
- 2. Přístup na základě vysvětlovací báze – operuje s předchozí znalostí



# Koncepty




## Teorie tvorby konceptů

### Konceptové teorie

- Definice vlastností (Klasická)
- Prototypy
- Příklady
- Hierarchické sémantické sítě
- Teorie teorie



# Koncepty




## Definující vlastnosti

- Prozkoumat vlastnosti objektu a rozeznat, zda je příslušníkem daného konceptu
- Definující vlastnosti
  - *Podmínky nutné pro přítomnost v kategorii*
  - Příklad: Jaké jsou vlastnosti okna?





# Koncepty



## Problémy s vlastnostmi

- Teoretické problémy?
  - Obtížně definovatelné nutné vlastnosti
  - Obtížně definovatelné abstraktní koncepty




We easily recognise all these belonging to a category of “birds”, but they aren’t in any obvious sense “the same” as each other

**On what basis do we decide to refer to these different things as being examples of the same kind of entity?**

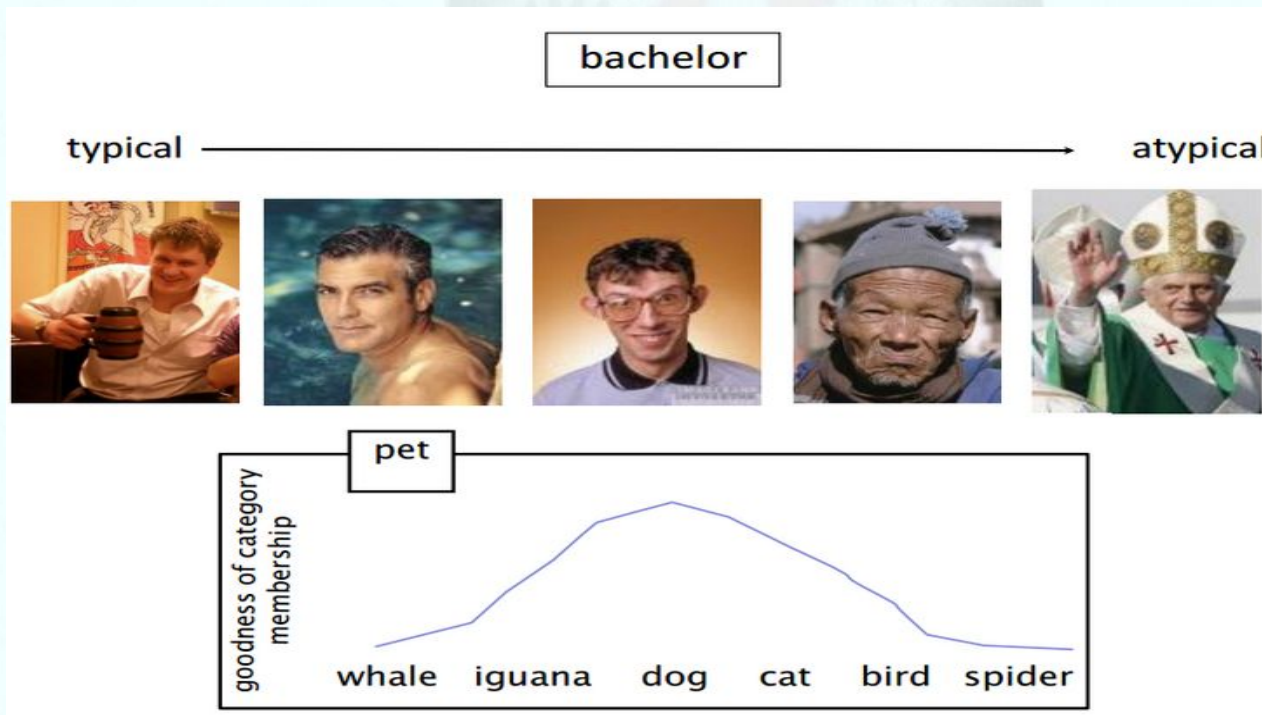


# Koncepty




## Problémy s vlastnostmi

- Efekt typičnosti – stupňovaná příslušnost (fuzzy příslušnost)





# Koncepty



## Kategorie

- Definice na základě nutných a postačujících „pravidel“ nedostatečná

sport

has a ball involved...  
what about:



or



involves running... what  
about:



or



involves exertion... what  
about:




or






# Koncepty




## Prototypy

- Abstraktní reprezentace vlastností, obsahující dostatečné vlastnosti, vhodné k identifikaci objektu
- Pracuje s fuzzy koncepty
- Fuzzy koncepty jsou kategorie, které nelze jednoduše definovat
- Dokladv: kategorie barev (11 kategorií). jen pro některé abstraktní



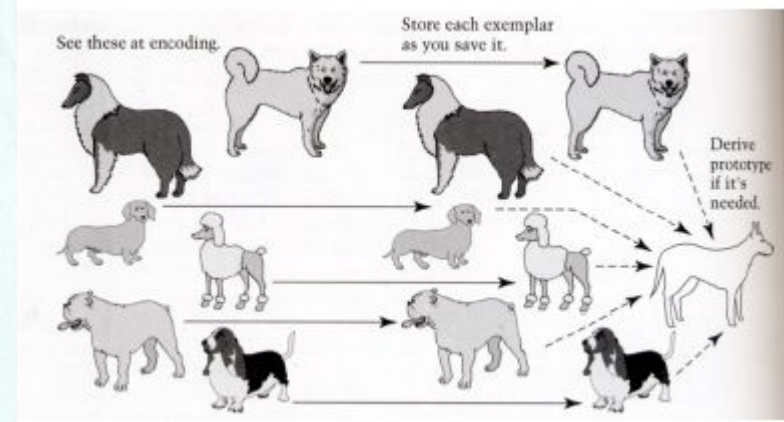


# Koncepty




## Exempláře

- Oproti prototypům je potřeba více příkladů z rozdílných úhlů pro správnou kategorizaci
- Koncept zeleniny= Hrách, mrkev, fazole
- Je paprika zelenina?
- Doklady: rychleji “Vlaštovka je pták” než “tučňák je pták”



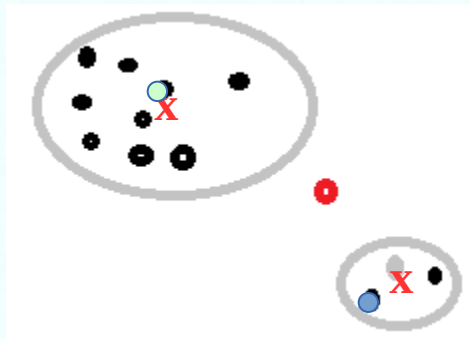


# Koncepty



## Exempláře

- Shodný s prototypem
  - Reprezentace není definice
- Rozdílné: reprezentace není abstraktní
- Kategorizace je porovnání uložených příkladů




- K-means
- GMM

Exemplář vs. prototyp




# Koncepty




## Propojení prototypu a definujících vlastností

- Empirické důkazy pro obojí
- Propojení ve formě „jádra“
  - Definující vlastnosti které prvek musí mít
- Prototyp
  - Charakterizuje typické příklady






# Koncepty




## Pochopení definujících vlastností

- Keil & Batterman (1984)
  - 5-10 leté děti mají vytvořit kategorie
  - Špinavý muž s pistolí ukradl televizi, protože mu rodiče řekli, že by jí měl mít.
  - Přátelská žena vzala rádio a nepomýšlela na to, že by jej vrátila
- Kdo je zloděj?
  - Až do deseti let nejsou děti schopny označit ženu jako zloděje.





# Koncepty




Úrovně re





# Koncepty




## Úrovně reprezentace

- Abstraktní úroveň shrnující obecné vlastnosti  
Nábytek, zvířata nadřazená
- Největší počet vlastností  
Židle, pták základní
- Nejčastěji používané  
Ušák, vrabec podřazená



# Koncepty



## Úrovně reprezentace

- Lidé používají nejčastěji základní úroveň při úlohách s volným pojmenováním
- Děti se učí základní úroveň dříve než ostatní
- Základní úroveň je v řeči dospělých více častá než ostatní
- Různé kultury používají stejné základní kategorie, nejvíce pro živé bytosti.



# Logika



## Reprezentační mohutnost

- Aristoteles – **sylogismy** – forma deduktivního vyvozování  
 $\forall S \text{ jsou } P. M \text{ je } S \rightarrow M \text{ je } P$

**Indukce, Dedukce, Abdukce**






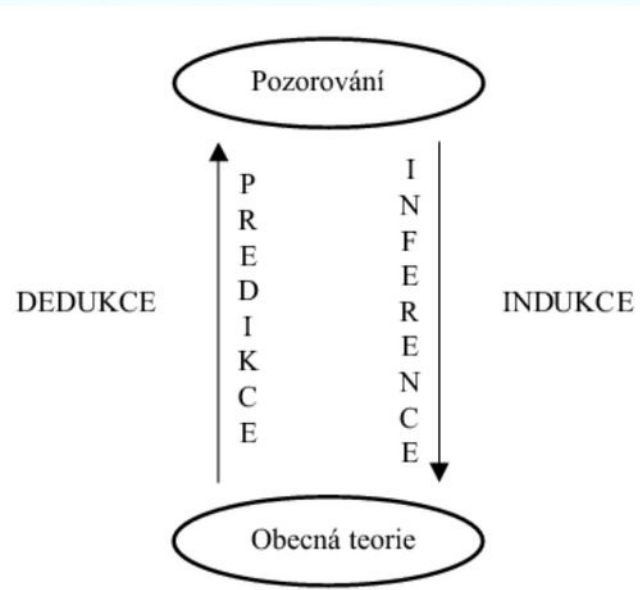
# Logika



## Reprezentační mohutnost

- Aristoteles – **sylogismy** – forma deduktivního vyvozování  
 $\forall S \text{ jsou } P. M \text{ je } S \rightarrow M \text{ je } P$

## Indukce, Dedukce, Abdukce



Abduction: "inference to the best explanation.", plausible hypothesis

**Observation:** You see water on the kitchen floor.

**Possible Explanations:**

- The sink might be leaking.
- Someone spilled a drink and didn't clean it up.
- There was a recent rainstorm, and water came in under the door.

**Abductive Reasoning:** Based on context, you choose the most likely explanation:

- If you know the sink has leaked before, you might infer "**The sink is leaking**" as the best explanation.
- If you notice a glass tipped over nearby, you might infer "**Someone spilled a drink.**"



# Logika



## Reprezentační mohutnost

- Aristoteles – **sylogismy** – forma deduktivního vyvozování  
 $\forall S \text{ jsou } P. M \text{ je } S \rightarrow M \text{ je } P$

### Indukce, Dedukce, Abdukce

- **Výroková logika** – axiomy a odvozovací pravidla (Modus ponens)

### Modus Ponens & Modus Tollens

**Modus ponens** is the name of any argument in the following form:

If A then B.

A is true.

Thus, B is also true.

**FOR EXAMPLE:**

If you buy the jumbo popcorn, then you will need a large drink.

You bought the jumbo popcorn.

So you will need a large drink.

**Modus tollens** is the name of any argument in the following form:

If A then B.

B is not the case.

Therefore, A is not the case either.

**FOR EXAMPLE:**

If you get the bon bons, you won't need popcorn.

Charlie needed popcorn.

So he did not get the bon bons.



# Logika



## Reprezentační mohutnost

- Aristoteles – **sylogismy** – forma deduktivního vyvozování  
 $\forall S \text{ jsou } P. M \text{ je } S \rightarrow M \text{ je } P$   
Indukce, Dedukce, Abdukce
- **Výroková logika** – axiomy a odvozovací pravidla (Modus ponens)
- **Predikátová logika** – kvantifikátory, operátory (predikáty= vlastnosti/vztahy)  
 $S(p)$  – unární relace  
navštěvovat (P, Kino) – binární relace

“Petr hraje na housle. Všichni co hrají na housle mají hud.sluch. Petr má hudební sluch.”

“Studenti, kteří chodí na kurz, dostanou kredit”

- problém čas



# Logika



## Reprezentační mohutnost

- Aristoteles – **sylogismy** – forma deduktivního vyvozování  
 $\forall S \text{ jsou } P. M \text{ je } S \rightarrow M \text{ je } P$

Indukce, Dedukce, Abdukce

- **Výroková logika** – axiomy a odvozovací pravidla (Modus ponens)
- **Predikátová logika** – kvantifikátory, operátory (predikáty= vlastnosti/vztahy)
- **Modální logika** - + možnost, nutnost, nemožnost

“John **MUST** be happy”

“It **MIGHT** rain today”

$\square$  for Necessarily and  $\diamond$  for Possibly

$$\diamond P \leftrightarrow \neg \square \neg P;$$

$$\square P \leftrightarrow \neg \diamond \neg P.$$

# Logika

## Reprezentační mohutnost

- Aristoteles – **sylogismy** – forma deduktivního vyvozování  
 $\forall S \text{ jsou } P. M \text{ je } S \rightarrow M \text{ je } P$   
Indukce, Dedukce, Abdukce
- **Výroková logika** – axiomy a odvozovací pravidla (Modus ponens)
- **Predikátová logika** – kvantifikátory, operátory (predikáty= vlastnosti/vztahy)
- **Modální logika** - + možnost, nutnost, nemožnost
- **Matematická logika** – teorie množin, model theory etc.
- **Neformální logika**
- ...



# Logika



## Výpočetní mohutnost

2 vyvozovací pravidla

modus ponens  $p \rightarrow q, p \Rightarrow q$

modus tollens  $p \rightarrow q, \text{non } q \Rightarrow \text{non } p$

- **Řešení problémů**

- Plánování – dedukce – pomalá, monotónní, ne zkušenost
- Rozhodování – pravděpodobnost splnění cíle
- Vysvětlení – abdukce
- **Učení** – induktivní zobecnění (nejistota), abdukce
- **Jazyk** – přirozený nástroj pochopení struktury jazyka, Chomsky o jazyce I logická forma

## Výpočetní mohutnost

2 vyvozovací pravidla

modus ponens  $p \rightarrow q, p \Rightarrow q$

modus tollens  $p \rightarrow q, \text{non } q \Rightarrow \text{non } p$

- **Řešení problémů**

- Plánování – dedukce – pomalá, monotónní, ne zkušenost
- Rozhodování – pravděpodobnost splnění cíle
- Vysvětlení – abdukce
- **Učení** – induktivní zobecnění (nejistota), abdukce
- **Jazyk** – přirozený nástroj pochopení struktury jazyka, Chomsky o jazyce I logická forma
- **Logické neuronové sítě/Neurosymbolická UI** – velká výpočetní mohutnost




# Logika



## Psychologická přijatelnost

- Důkazy existence mentální logiky – reakční časy, hlasité přemýšlení
- Skeptici – umí užít modus ponens, ne modus tollens

*“Pokud má karta D na jedné straně, má na druhé straně 3.”*






# Logika



## Psychologická přijatelnost


- Důkazy existence mentální logiky – reakční časy, hlasité přemýšlení
- Skeptici – umí užít modus ponens, ne modus tollens

*“Pokud má karta D na jedné straně, má na druhé straně 3.”*



Jiný systém než formální logiku

*If you borrow my car, you must fill up the gas tank.*



- schémata pragmatického usuzování (Cheng a Holyoak, 1985)
- Mentální modely – struktury reprezentací (Johnson-Laird, 1983)
- nedodrží pravděpodobnost v indukci (Tversky, 1983)



# Logika



## Neurologická přijatelnost

- Nevíme – možná synapse 1/0 dle logiky





# Logika

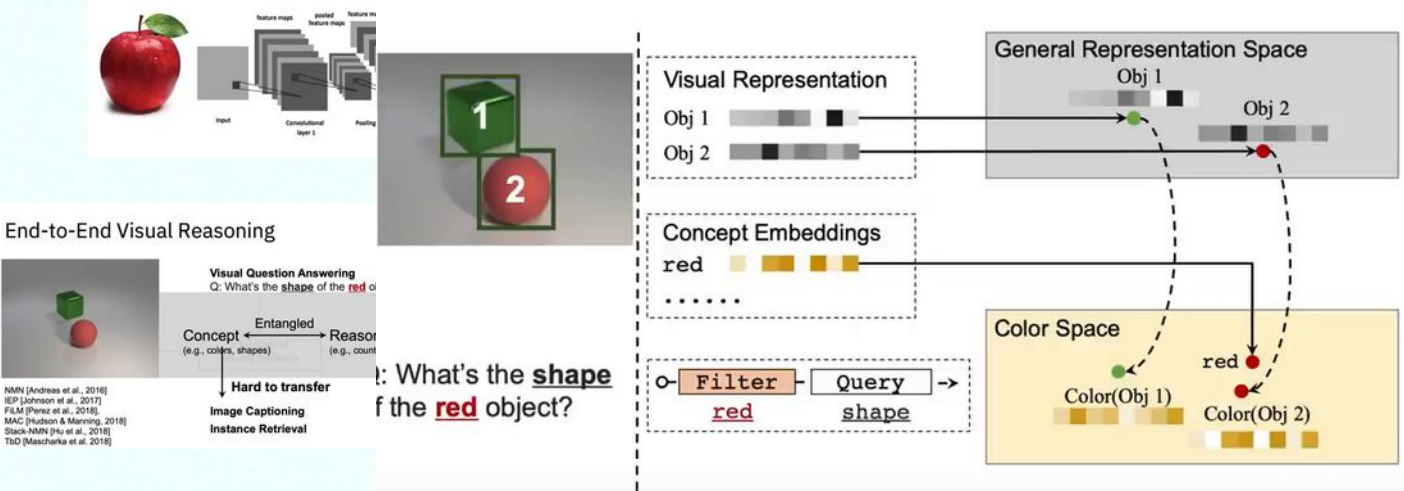


## Praktická použitelnost

- Ne hlubší pochopení učení
- PROLOG
- Neurosymbolic AI – train on data + embed constraints from domain knowledge, logic tensor networks, logical Nnets, DeepProbLog, Semantic loss, SPL, ...

Neural Networks / Deep Learning

### Neuro-Symbolic Concept Learning



Understanding

**Question:** Are there an equal number of large things and metal spheres?

**Program:** `equal_number(count(filter_size(Scene, Large)), count(filter_material(filter_shape(Scene, Sphere), Metal)))`

**Answer:** Yes

End-to-End Visual Reasoning

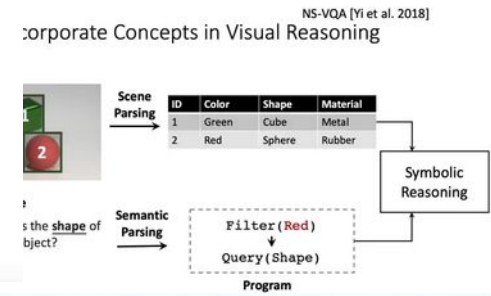
Visual Question Answering  
Q: What's the shape of the red object?

Concept (e.g., colors, shapes) ← Entangled → Reasoner (e.g., count)

Hard to transfer  
Image Captioning  
Instance Retrieval

MMN (Andreas et al., 2016)  
REP (Johnson et al., 2017)  
FILM (Phoca et al., 2018)  
MAC (Hudson & Manning, 2018)  
Stack-MMN (Yu et al., 2018)  
TAD (Mascharka et al., 2018)

Q: What's the **shape** of the **red** object?



## Praktická použitelnost

- Ne hlubší pochopení učení
- PROLOG
- Neurosymbolic AI – EQA – deductive abstract reasoning + data-driven learning

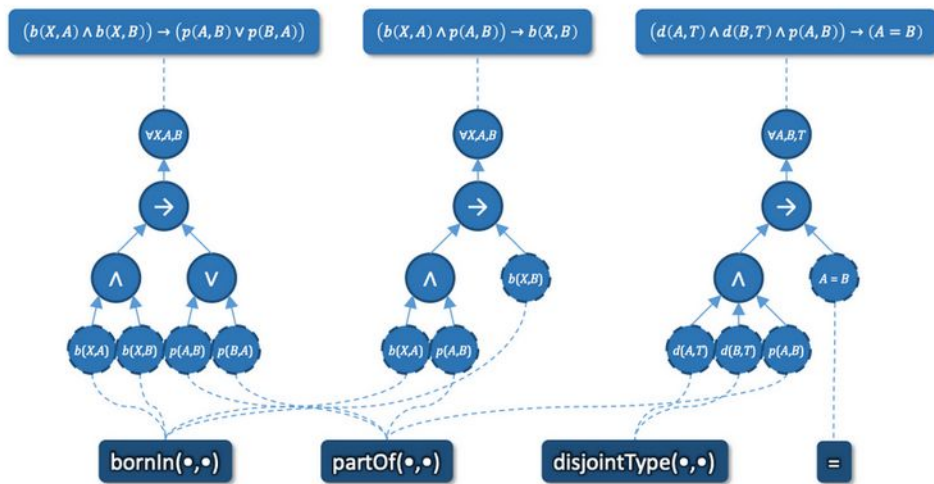


Figure 1: An example logical neural network structure modeling three rules.

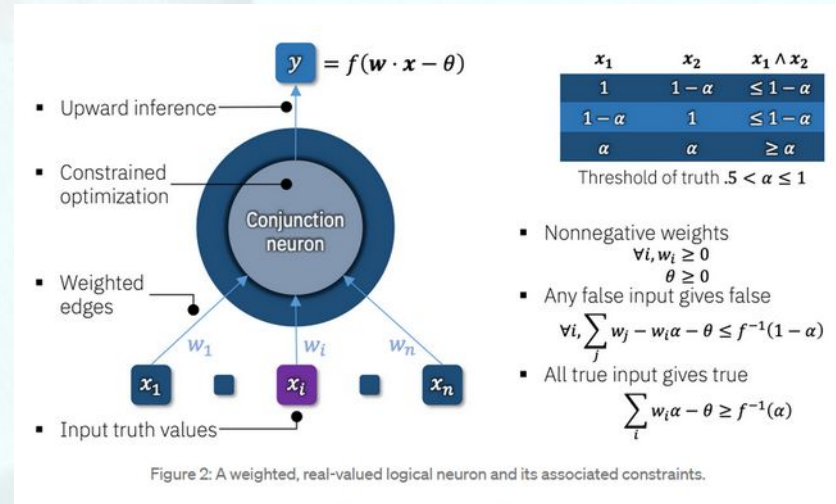


Figure 2: A weighted, real-valued logical neuron and its associated constraints.

## Praktická použitelnost

- Ne hlubší pochopení učení
- PROLOG
- Neurosymbolic AI/Logical NN – deductive abstract reasoning + data-driven learning; EQA

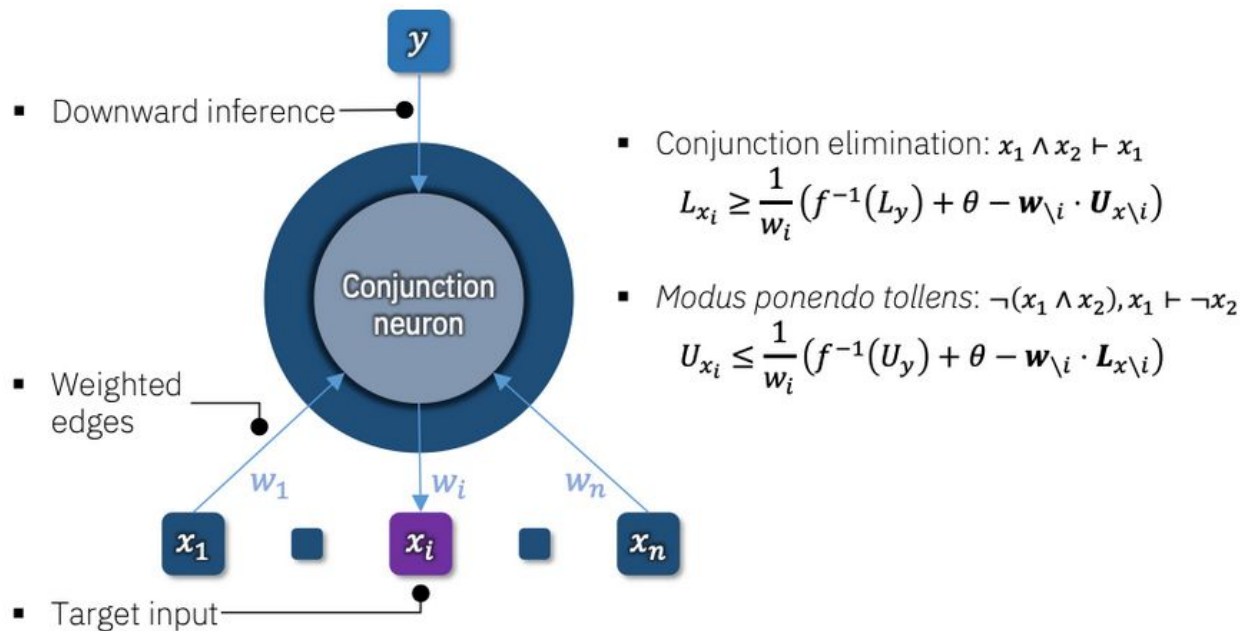


Figure 3: Downward inference with a weighted, real-valued neuron for lower and upper bounds on inputs L and U.

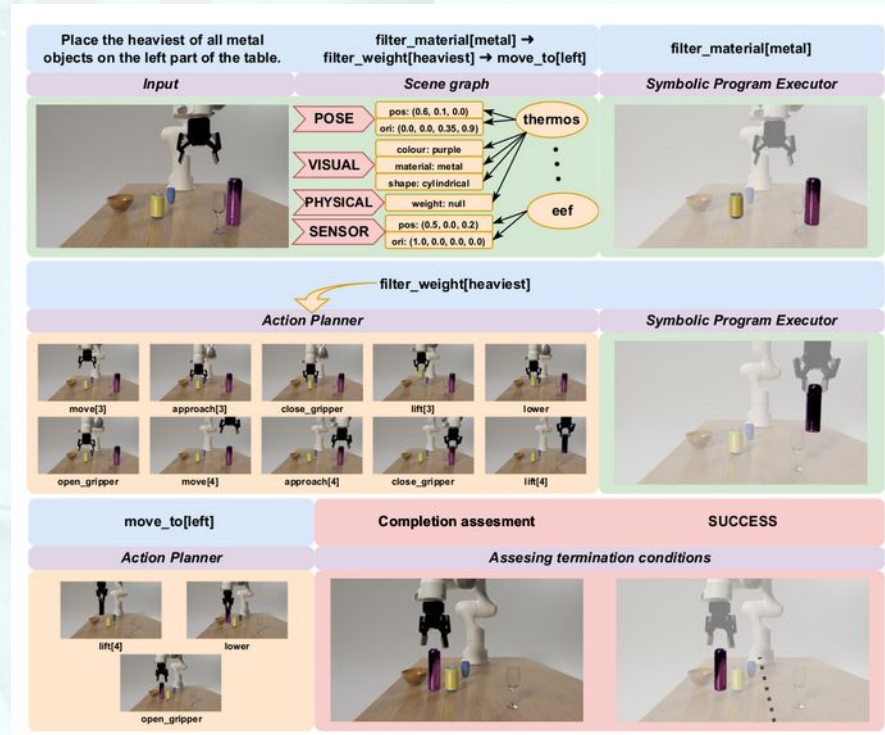
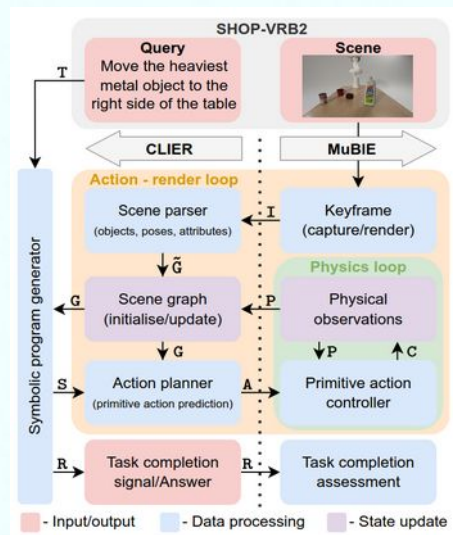


# Logika



## Praktická použitelnost

- Ne hlubší pochopení učení
- PROLOG
- Neurosymbolic AI/Logical NN – deductive abstract reasoning + data-driven learning; EQA



## Reprezentační mohutnost

- JESTLIŽE – PAK
- **Produkční systémy**
  - Báze dat (počáteční I odvozená data) – prac.paměť
  - Soubor produkčních pravidel ~ dlouhodobá paměť (procedurální, deklarativní)
  - Infereční stroj (porovná data s podmínkami, akci) ~ kognitivní procesor mozku
- 1.program UI 1956 – Logic Theorist (Newell, Shaw, Simon)
  - **ACT** – psychologické úlohy (Anderson, 1983)
  - **SOAR** (Newell, Laird, Rossenbloom)
- Informace o světě
- Jak se chovat ve světě
- Gramatická pravidelnost
- Do pravidel i modus ponens
- Logika lepší, pravidla větší výp. mohutnost

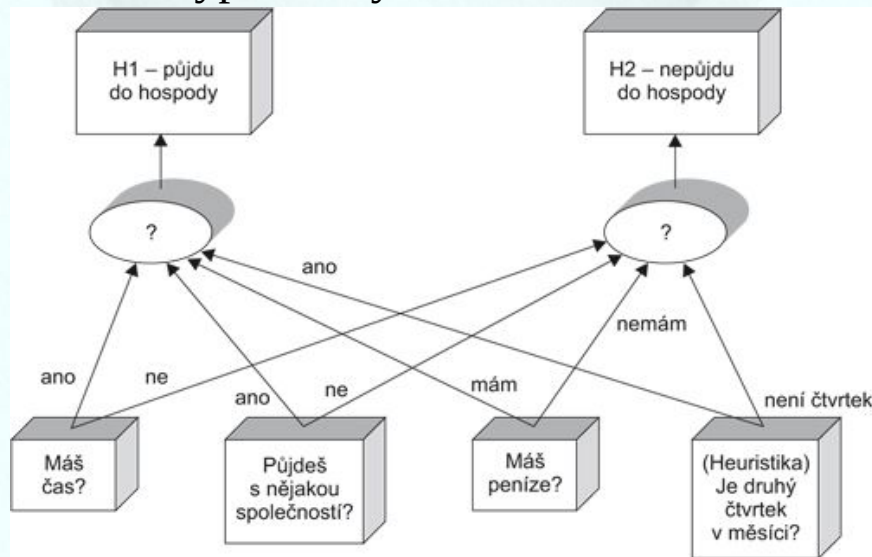


# Pravidla



## Výpočetní mohutnost

- **Řešení problémů** – prohledávání (do šířky, do hloubky), + heuristika (ne vše)  
-uvědomělé myšlení → sériové, ale může záviset na mnoha pravidlech užívaných současně
- **Plánování** – dopředně či zpětně či oboustranně
- **Rozhodování** – nutno další procesy – výpočet očekávané hodnoty, paralelní respektování omezení
- **Vysvětlení** – formování hypotéz, výsledek → abdukcí ze známých pravidel příčinu





# Pravidla



## Výpočetní mohutnost

- **Řešení problémů** – prohledávání (do šířky, do hloubky), + heuristika (ne vše)
  - uvědomělé myšlení → sériové, ale může záviset na mnoha pravidlech užívaných současně
- **Plánování** – dopředně či zpětně či oboustranně
- **Rozhodování** – nutno další procesy – výpočet očekávané hodnoty, paralelní respektování omezení
- **Vysvětlení** – formování hypotéz, výsledek → abdukci ze známých pravidel příčinu
- **Učení** – něco vrozené (mrkni na ránu, řeč?)
  - Induktivním zobecňováním, zkušenosti → víc pravidel vyššího řádu
  - Specializace
  - Pomalé přírůstky
- **Jazyk** – Chomsky – povědomí komplexní gramatika z pravidel

# Pravidla

## Psychologická přijatelnost

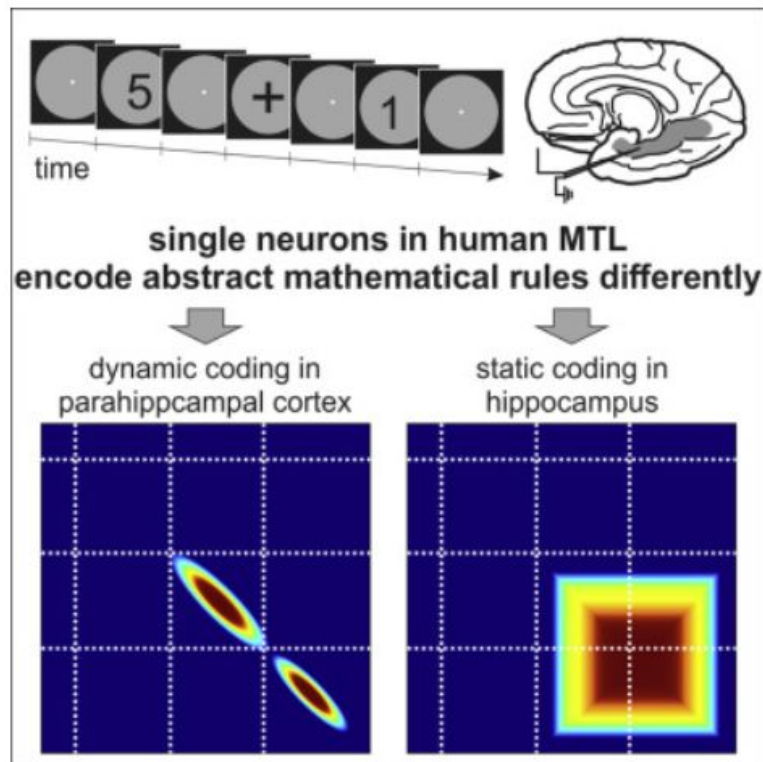
- nejlepší
- Newell – SOAR:
  - kryptoaritmetické úlohy
  - Odvozování na vyšších úrovních – prostor všech možných závěrů  
“Někteří lukostřelci nejsou kuželkáři” a “Všichni kanoisté jsou kuželkáři” → “Někteří lukostřelci jsou kanoisté”
- Čím víc se naučíme, tím dýl trvá naučit se víc rychle chunky → pravidla vyššího řádu
- Sociální stereotypy
- Učení piškvorek – neblokují/příliš
- Nabývání jazykových znalostí – Anderson – AJ dle pravidel

$$\begin{array}{r} \text{CROSS} \\ + \text{ROADS} \\ \hline \text{DANGER} \end{array}$$

# Pravidla

## Neurologická přijatelnost

- Nevíme jak implementovat pravidla do mozku (neuron vyšle impuls → způsobí vyslání impulsu neuronem na něj napojeným)
- Anderson – neurální implementaci svého ACT, 1. systém sériově, SOAR paralelně





# Pravidla



## Praktická použitelnost

- ACT – ve výuce (programování, důkazy)
- Inženýrské návrhářství – SOAR návrh počítačových algoritmů
- Expertní systémy
- 1. aplikované inteligentní systémy

Chunks:

```
Action023:  
  isa chase  
  agent dog  
  object cat  
Fact3+4:  
  isa addition-fact  
  addend1 three  
  addend2 four  
  sum seven
```

Productions:

```
IF the goal is to classify a person  
  and he is unmarried  
THEN classify him as a bachelor  
  
IF the goal is to add two digits d1 and d2 in a column  
  and  $d1 + d2 = d3$   
THEN set as a subgoal to write d3 in the column
```





# Pravidla



## Praktická použitelnost

- ACT – ve výuce (programování, důkazy)
- Inženýrské návrhářství – SOAR návrh počítačových algoritmů
- Expertní systémy
- 1. aplikované inteligentní systémy
- Verifikace systémů/pravidla provozu
- Inferring rules automatically – for our current setup

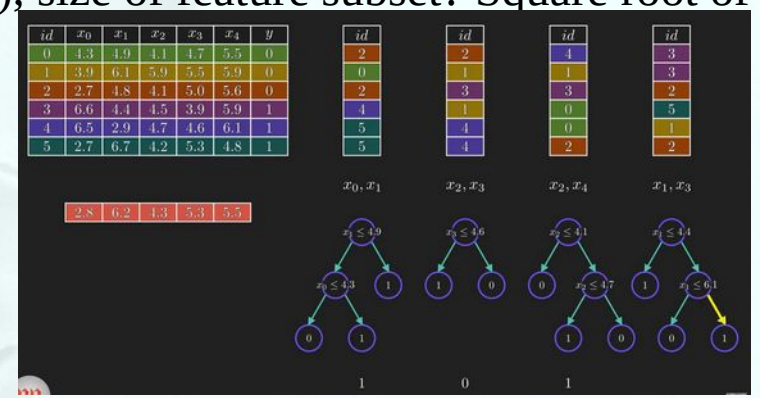
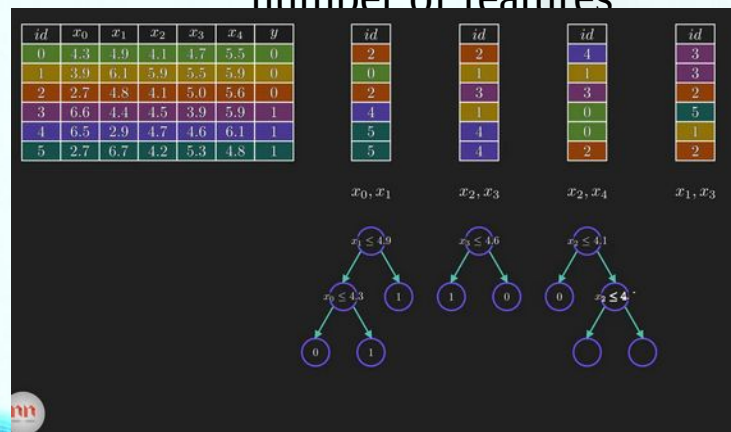




# Pravidla

## Praktická použitelnost

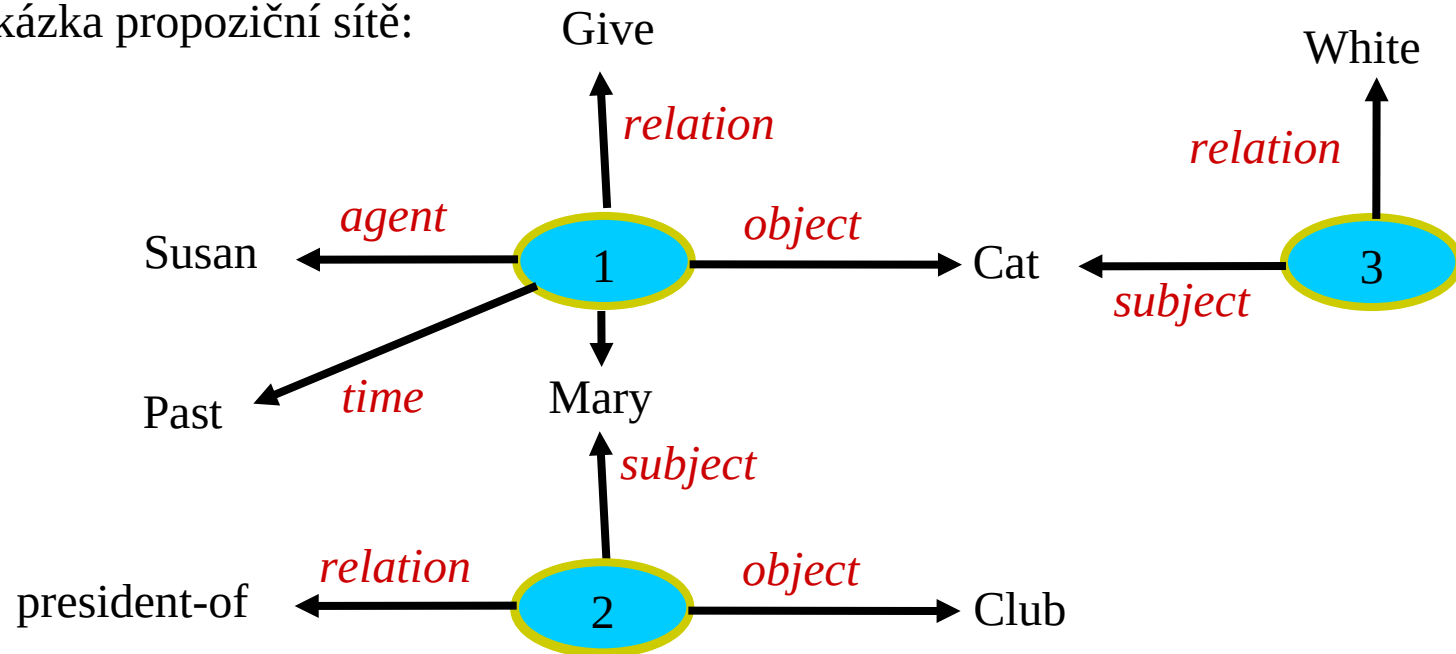
- ACT – ve výuce (programování, důkazy)
- Inženýrské návrhářství – SOAR návrh počítačových algoritmů
- Expertní systémy
- 1. aplikované inteligentní systémy
- Verifikace systémů/pravidla provozu
- Inferring rules automatically – for our current setup
- Random forest – pass new point through all → predictions → majority voting (1)
  - Bootstrapping (not same data for every tree) and random feature selection (reduce correlation between trees), size of feature subset? Square root of total number of features



<https://www.youtube.com/watch?v=v6VJ2RO66Ag>

# Pravidla: ACT model

- Anderson (1983, 1993, 1996, 2000, etc) navrhl ACT (Adaptive Control of Thought) jako přístup k modelování kognitivních procesů.
- Ukázka propoziční sítě:

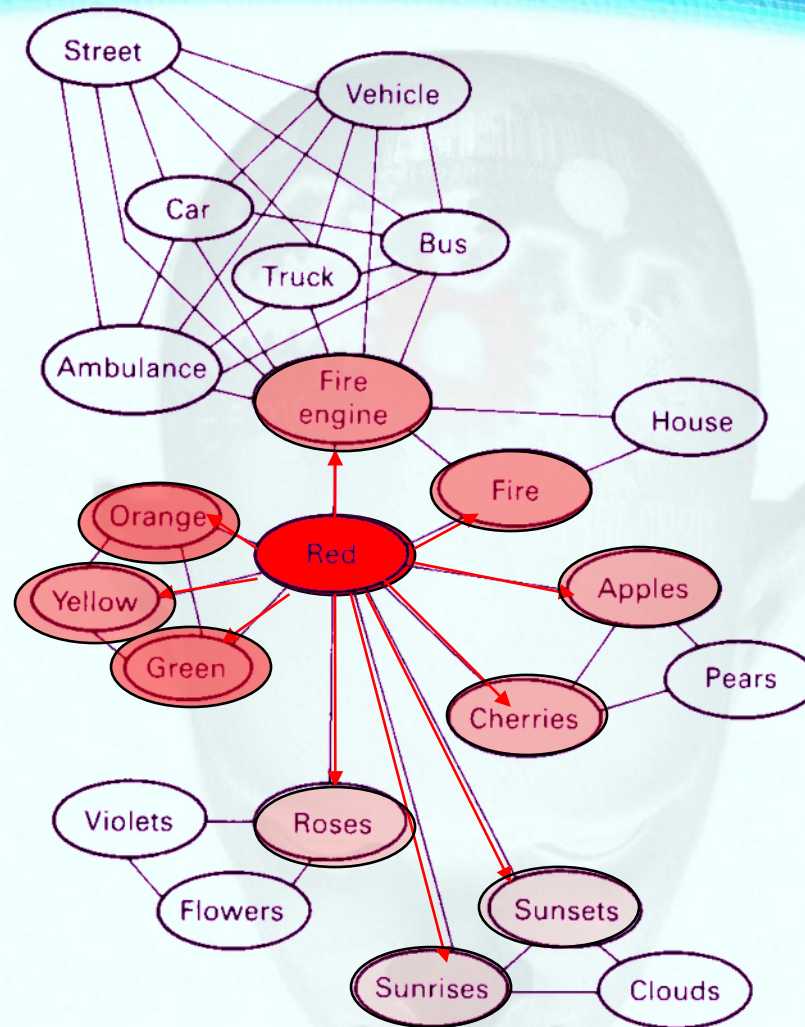


# Koncepty: Model sémantických sítí

- Uzly reprezentují koncepty v paměti
- Vztahy reprezentují hrany mezi jednotlivými uzly




# Koncepty: Sémantické síť

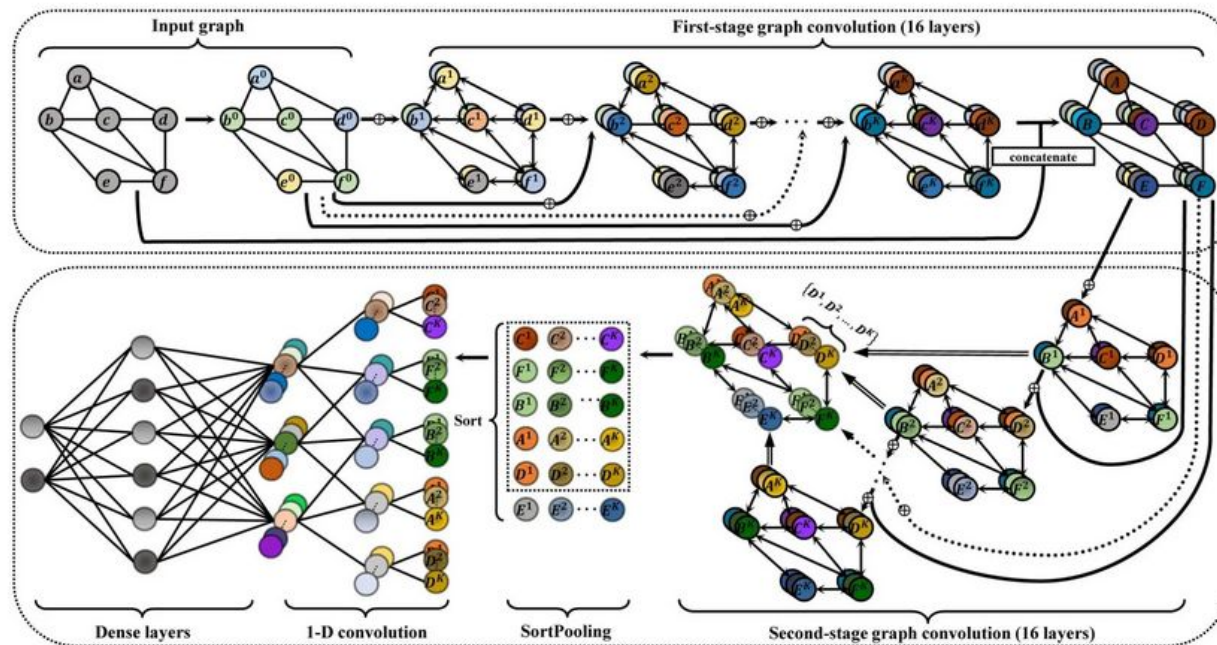


# Koncepty: GNN

GNN Learning Steps



GNNs: 2D convolution vs. graph convolution – source.




Deep Graph Convolutional Network (DGCNNII) – source.

# Koncepty: GNN

## Graph Attention Networks (GATs)

Introduce **attention mechanisms** to the aggregation step in GNNs (adding weight to the aggregation step).

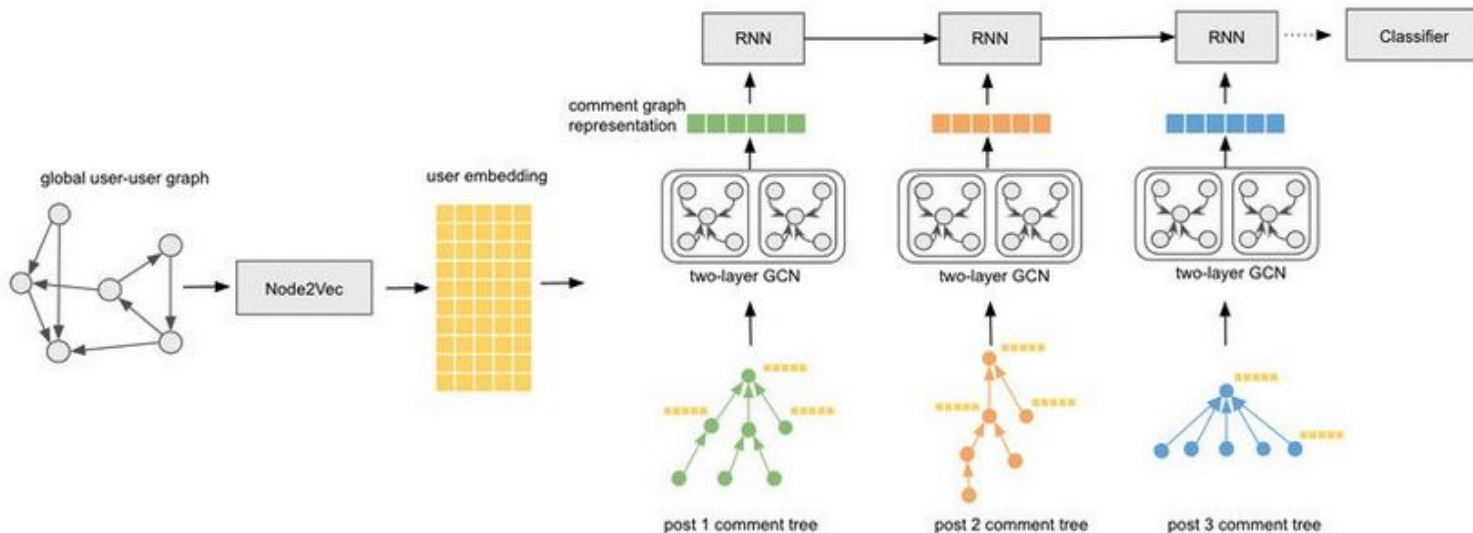


Graph Attention Network (GAT) – [source](#).

# Koncepty: GNN

## Graph Recurrent Networks (GRNs)

Combine the principles of recurrent neural networks (RNNs) with graph neural networks. In GRNs, node features are updated through recurrent mechanisms, allowing the model to capture dynamic changes in graph-structured data over time. Examples of applications include traffic prediction in road networks and analyzing time-evolving social networks.

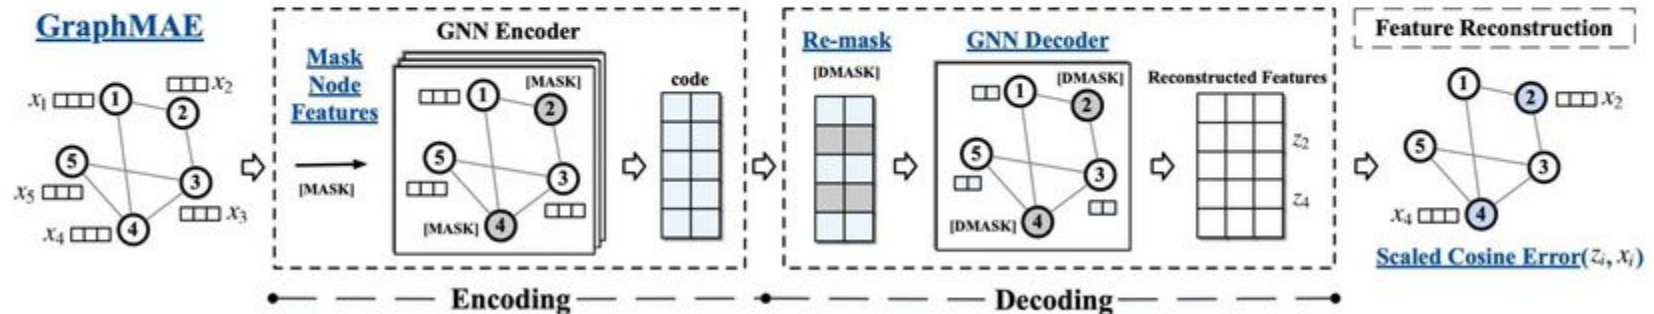


GRNs are well-suited for dynamic graphs and temporal graph data (graphs that evolve) – [source](#).

# Koncepty: GNN

## Graph Autoencoders (GAEs)

Designed for unsupervised learning tasks on graphs. A GAE learns to encode the graph (or subgraphs/nodes) into a lower-dimensional space (embedding) and then reconstructs the graph structure from these embeddings. The **objective** is to learn representations that capture the essential structural and feature information of the graph. GAEs are particularly useful for tasks such as link prediction, clustering, and anomaly detection in graphs, where explicit labels are not available.

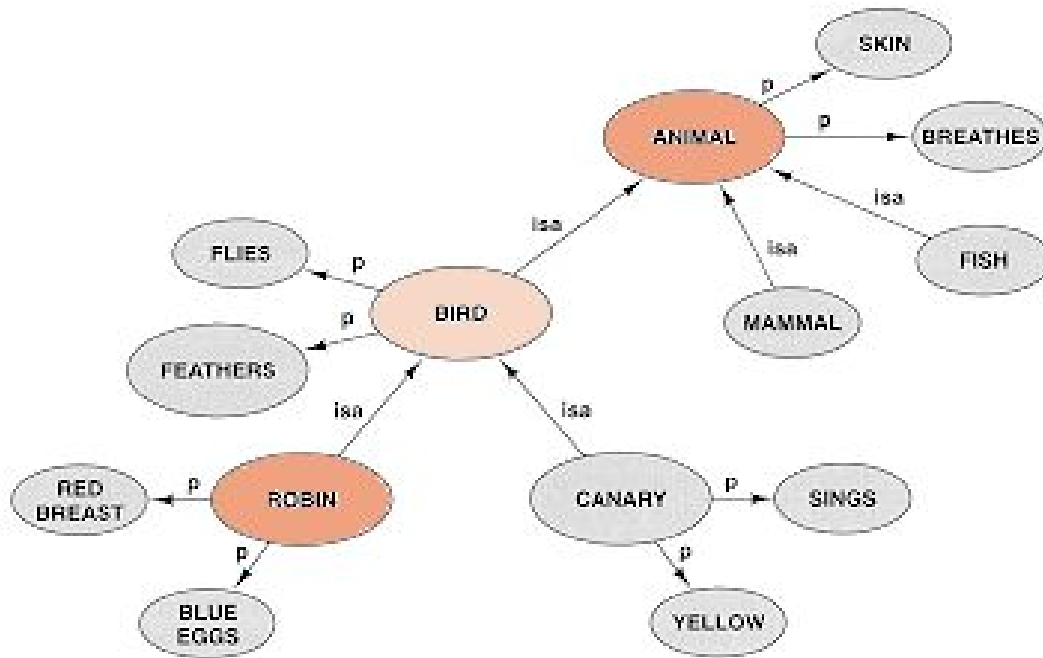


Graph Autoencoder (GAE) structure – [source](#).

# Koncepty: Šíření aktivace

- Aktivace napomáhá procesu vyhledávání
- Pokud se koncept stane aktivním, aktivují se okolní koncepty
- **Aktivace se šíří do všech přilehlých uzlů**
- Příklad: „Drozd je zvíře“

# Koncepty: Collins & Quillian




# Koncepty: Šíření aktivace

- Pokud se potkají dva proudy šíření aktivace vznikne průsečík
- Robins  $\Rightarrow$  BIRD  $\Leftarrow$  Animals
- Pokud není průnik, nedojde k řešení
- Pokud nastane průsečík, je provedena vyvozovací fáze, která potvrdí pravdivost

# Koncepty: Testování šíření aktivace



**Sentence Verification Times**



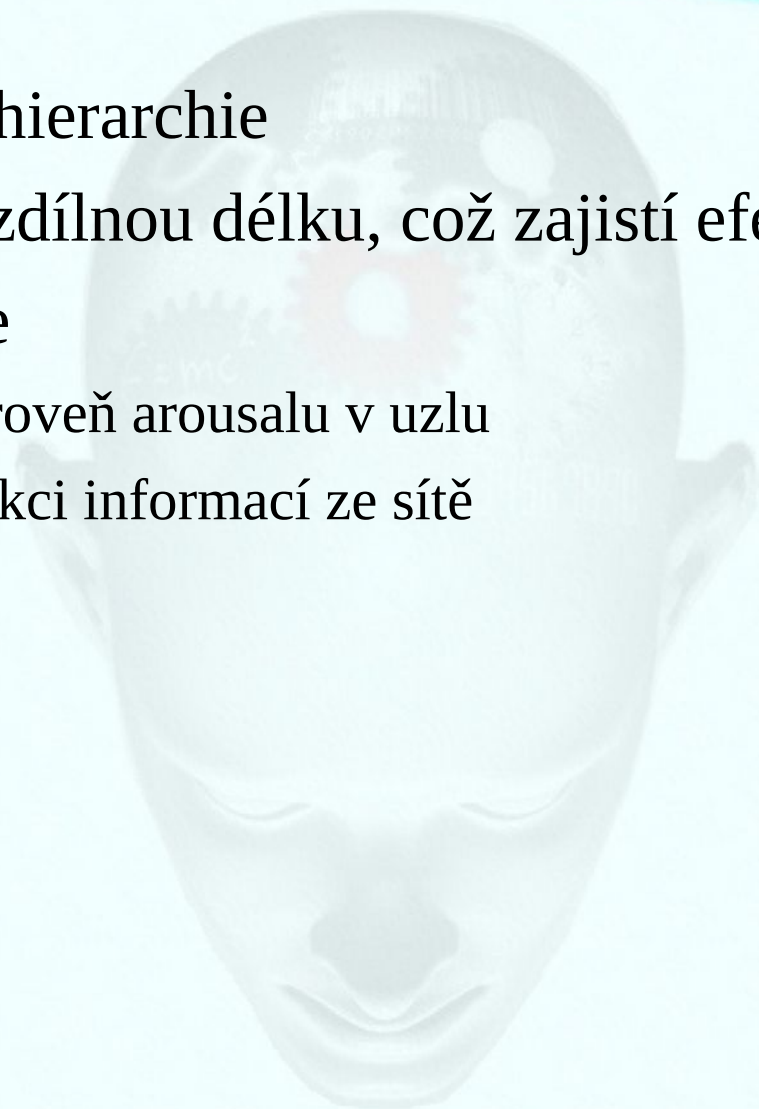
- Větší vzdálenost=
- delší reakční čas



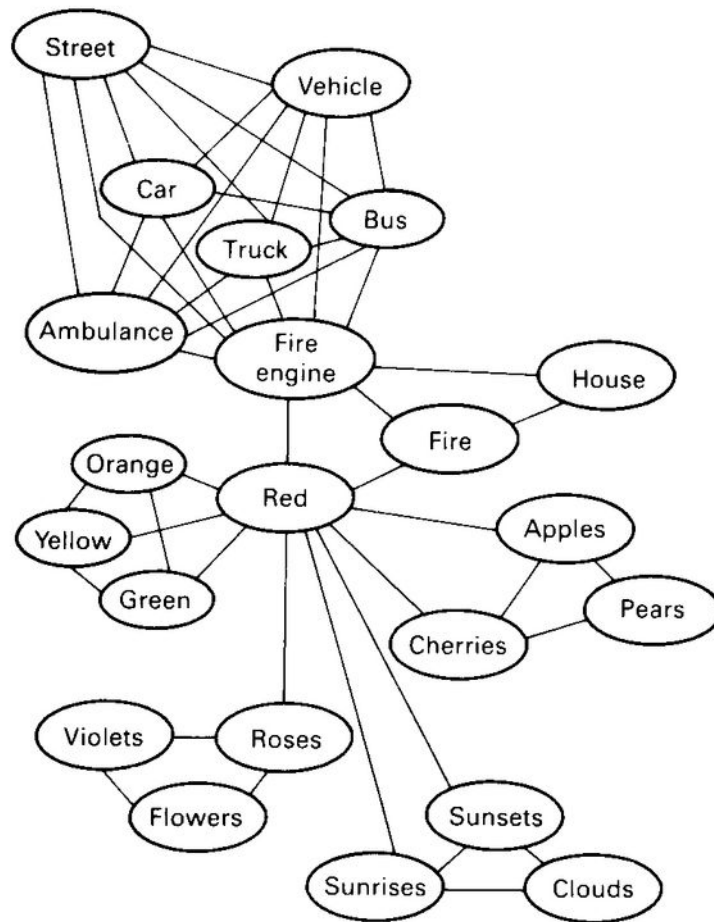
# Collins & Loftus (1975) sémantický model



- Zjednodušení hierarchie
- Hrany mají rozdílnou délku, což zajistí efekt typičnosti
- Šíření aktivace
  - Aktivace je úroveň arousalu v uzlu
  - Slouží k extrakci informací ze sítě



# Koncepty: Modifikace modelu síťe



# Koncepty: Sémantický priming

➤ Koncepty propojené šířící se aktivací

<u>Prime</u>		<u>Probe</u>
Doctor	→	Nurse
Bread	→	Butter
Doctor	-----	Butter
Bread	-----	Nurse

➤ Pouze někdy priming facilituje zpracování.

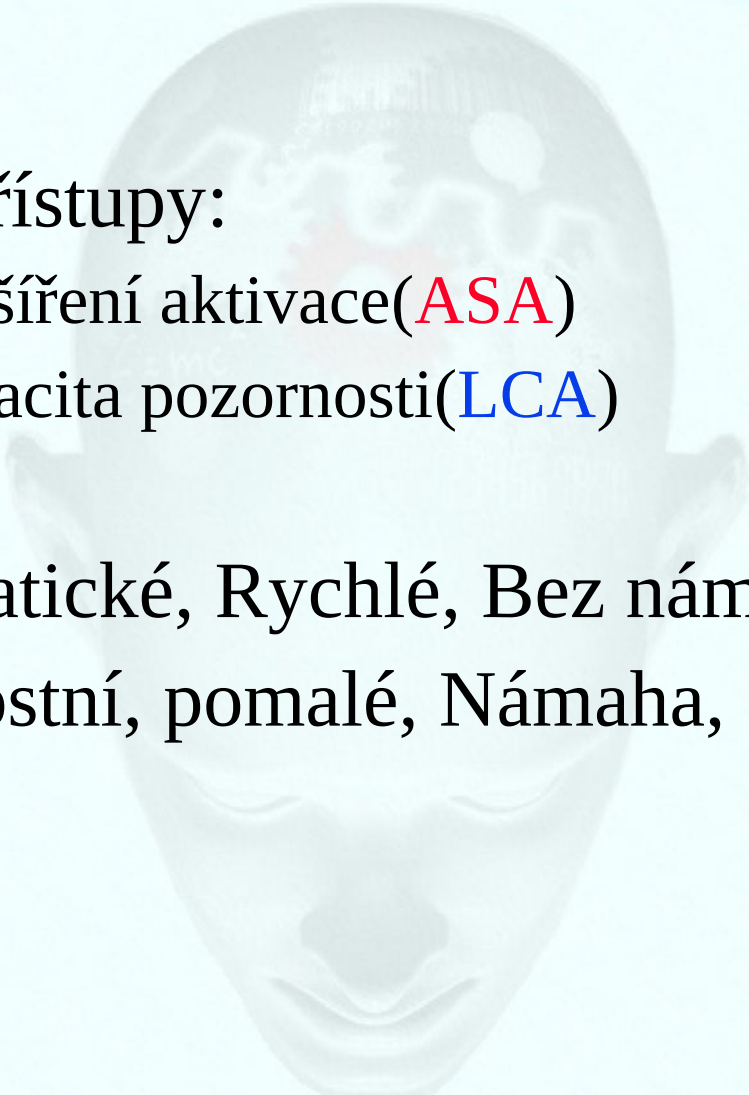
# Koncepty: Šíření aktivace

- Šíření aktivace je automatický proces
- Je řízen pomocí vstupních dat
- Jak mohou očekávání ovlivnit význam?
  - Automatické vs. Vědomé (pozorostní) procesy
  - Rychlé vs. pomalé
  - Bez úsilí vs. Volní



# Koncepty: Dva typy zpracování



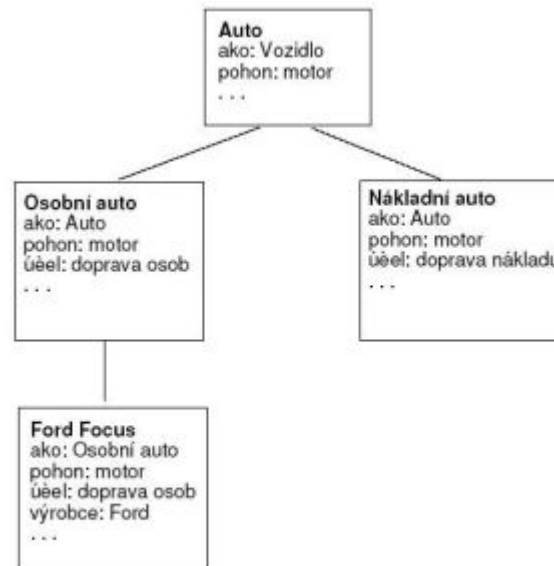
- Alternativní přístupy:
    - Automatické šíření aktivace(**ASA**)
    - Omezená kapacita pozornosti(**LCA**)
  - **ASA** : Automatické, Rychlé, Bez námahy,
  - **LCA**: Pozornostní, pomalé, Námaha,
- 

# Koncepty: Rámce

- Reprezentace stereotypních situací (schéma)
- Přirozené sekvence rámců = scénář
- Hierarchie – statické vlastnosti, dědění...  
→ OOP

Položky dělit na fasety (hodnota)  
→ na fasetě démon (akce)

- Každý jednoduchý rámec lze reprezentovat sémantickou sítí



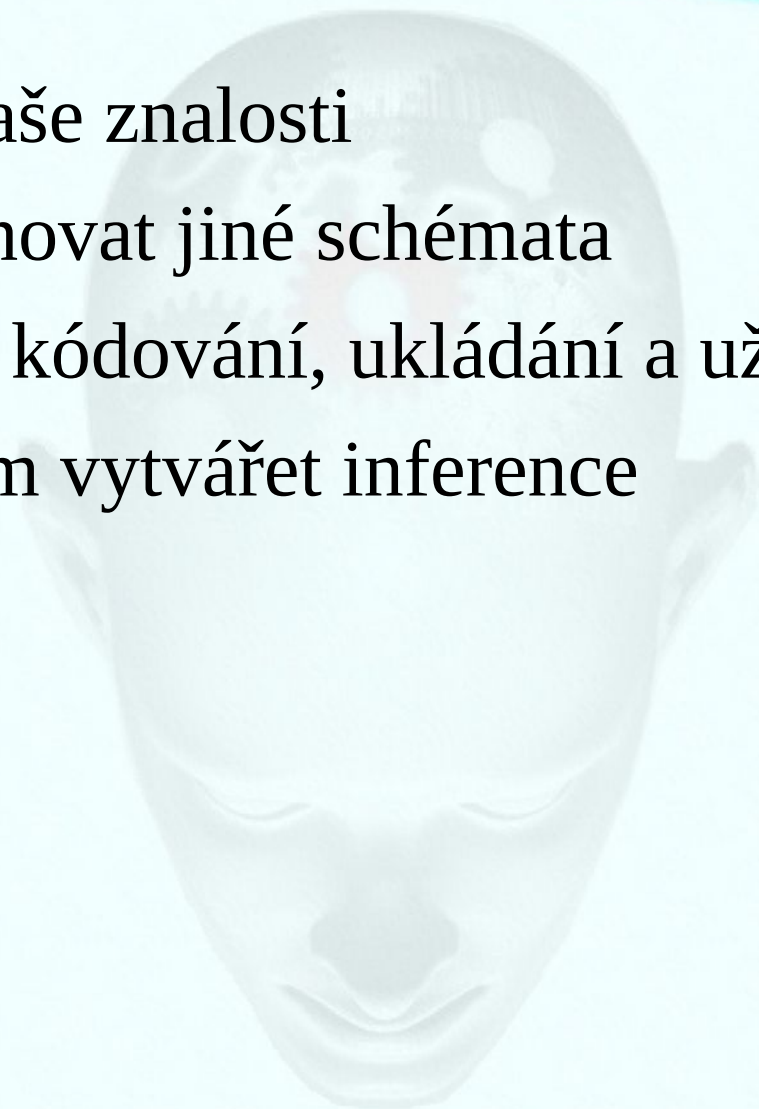
Obr. 4.14 Příklad hierarchie rámců



# Koncepty: Schémata



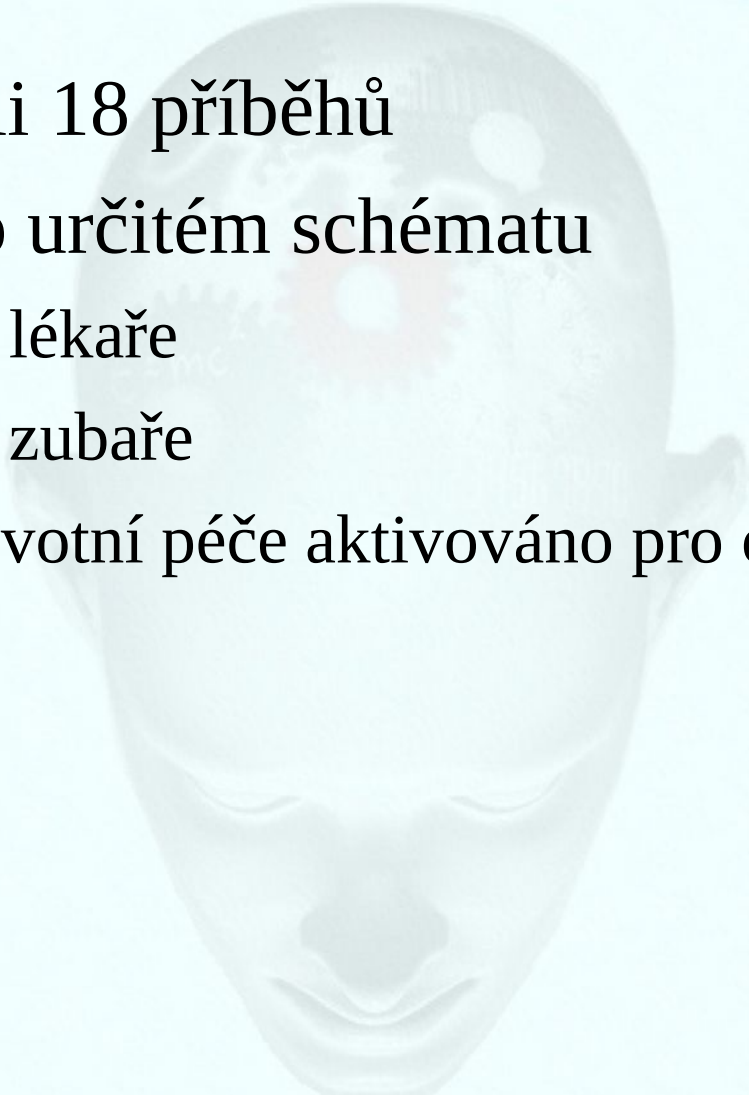
- Organizují naše znalosti
- Mohou obsahovat jiné schémata
- Pomáhají při kódování, ukládání a užití znalostí
- Pomáhají nám vytvářet inference





# Bower, Black, & Turner (1979)

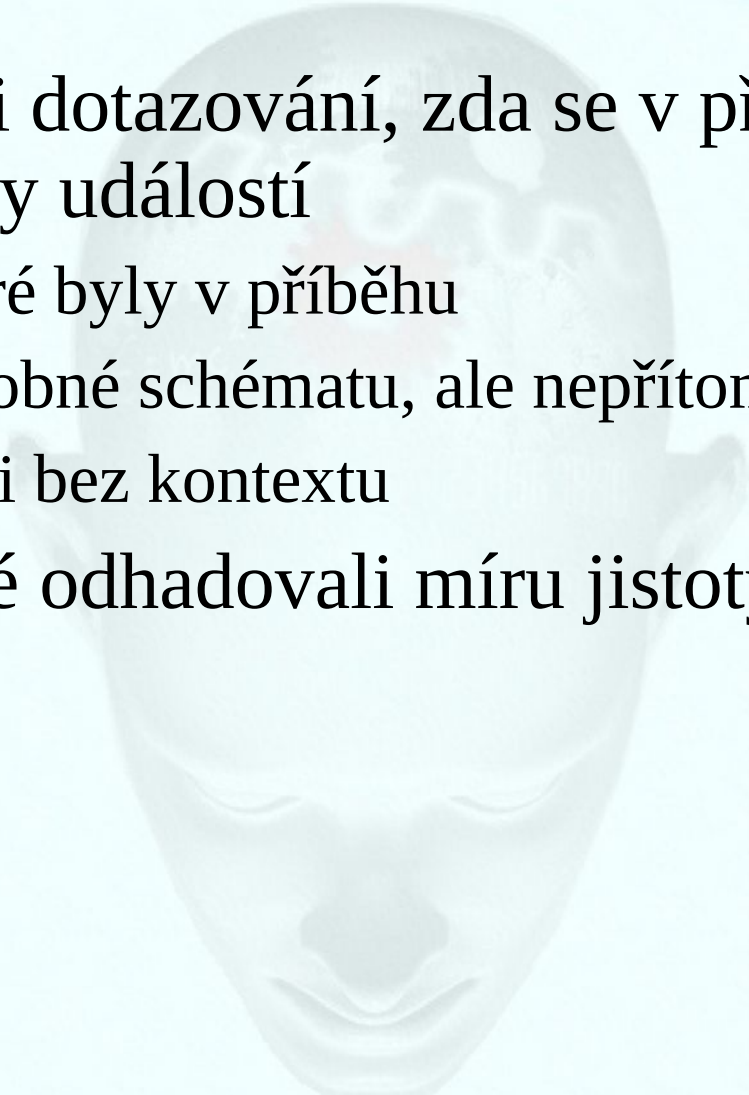


- Účastníci četli 18 příběhů
  - 1, 2, nebo 3 o určitém schématu
    - 1 o návštěvě lékaře
    - 1 o návštěvě zubaře
    - Schéma zdravotní péče aktivováno pro oba
- 



# Bower, Black, & Turner (1979)



- Účastníci byli dotazováni, zda se v příběhu objevily 3 typy událostí
    - Události, které byly v příběhu
    - Události podobné schématu, ale nepřítomné v příběhu
    - Nové události bez kontextu
  - Účastníci také odhadovali míru jistoty vlastních vyjádření
- 



# Koncepty: Schémata

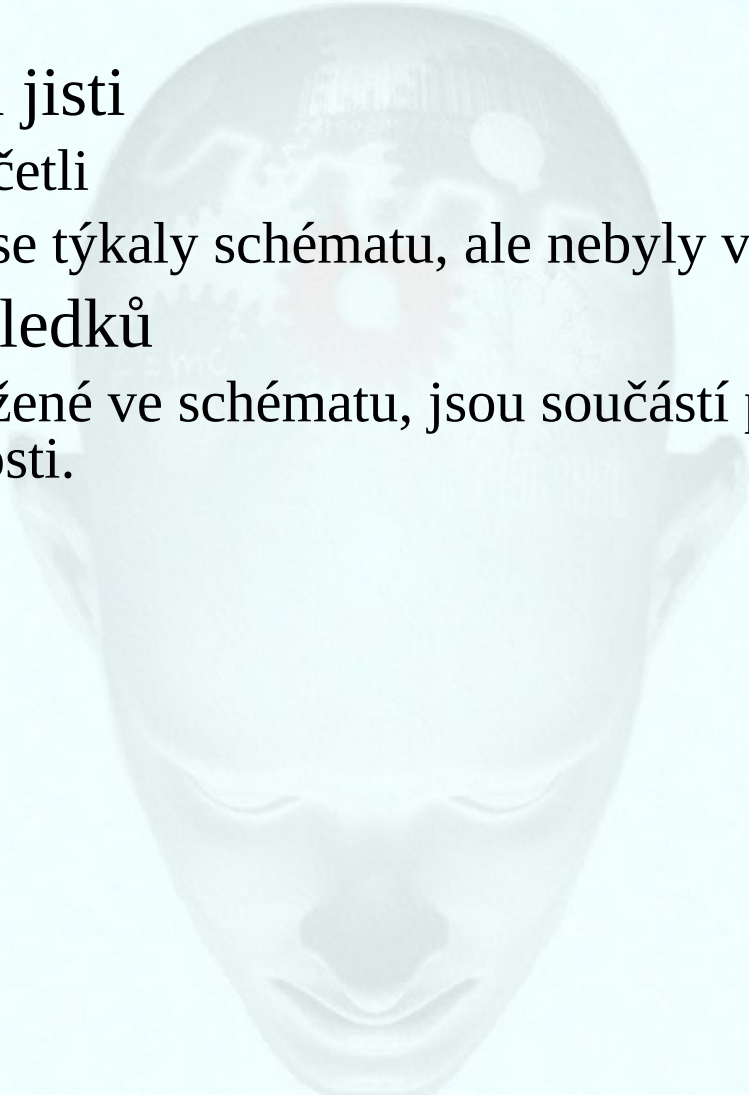


- Schémata jsou modely externího světa založené předchozí zkušenosti
- Schémata konceptů pro situace, události nebo sled akcí.
- Abstrakce umožňující objektům, aby byly zařazeny do obecných kategorií.



# Bower, Black, & Turner (1979)



- Účastníci si byli jisti
    - Události, které četli
    - Události, které se týkaly schématu, ale nebyly v příběhu
  - Interpretace výsledků
    - Myšlenky obsažené ve schématu, jsou součástí paměti na aktuálně prožívané události.
- 

# Koncepty: Skripty - scénáře

- Typy schémat o událostech
- Struktury zachycující sled událostí určitých stereotypních činností
  - Jídlo v restauraci, návštěva kina, návštěva lékaře
- Scénáře mají typické role
  - (Zákazník, číšník, kuchař), (doktor, sestra, pacient)



# Scénáře

- Pokud slyšíme nebo čteme o nějakém scénáři, je komplexně aktivován v naší hlavě
- Můžeme vyvozovat scény a akce, které nejsou explicitně přítomné

Scénáře a schémata  
tvoří paměť!



# Schank and Abelman (1977)

- Scénář návštěvy restaurace
  - Posad' se
  - Prohlídni si lístek
  - Objednej si jídlo
  - Jez
  - Zaplat'
  - Odejdi
- 73% subjektů popisovalo stejné akce  
48% se shodlo na dalších 9 akcích




# Koncepty: Konceptuální svaz

Konceptuální svazy se používají pro reprezentování ontologií, pro jejich revizi, zjemňování a sdílení.

Concept Types	Attributes				
	nonalcoholic	hot	alcoholic	caffeinic	sparkling
HerbTea	x	x			
Coffee	x	x		x	
MineralWater	x				x
Wine			x		
Beer			x		x
Cola	x			x	x
Champagne			x		x

Tab. 4.4 Typy nápojů (extenze) a atributy (intenze) – dle Sowa



Obr. 4.15 Konceptuální svaz nápojů a jejich atributů (dle Sowa)

**Svaz:** položky uspořádaný  
 Minimální/maximální prvek

uspořádání  $\leq$  (tato relace umožňuje definovat hierarchie)  
 $\cap$  (největší dolní mez neboli infimum)  
 $\cup$  (nejmenší horní mez neboli supremum)

- $a \cap b \leq a, a \cap b \leq b$
- pokud  $c \leq a$  a  $c \leq b$ , pak  $c \leq a \cap b$
- $a \leq a \cup b, b \leq a \cup b$
- pokud  $a \leq c$  a  $b \leq c$ , pak  $a \cup b \leq c$

Konceptuální analýza

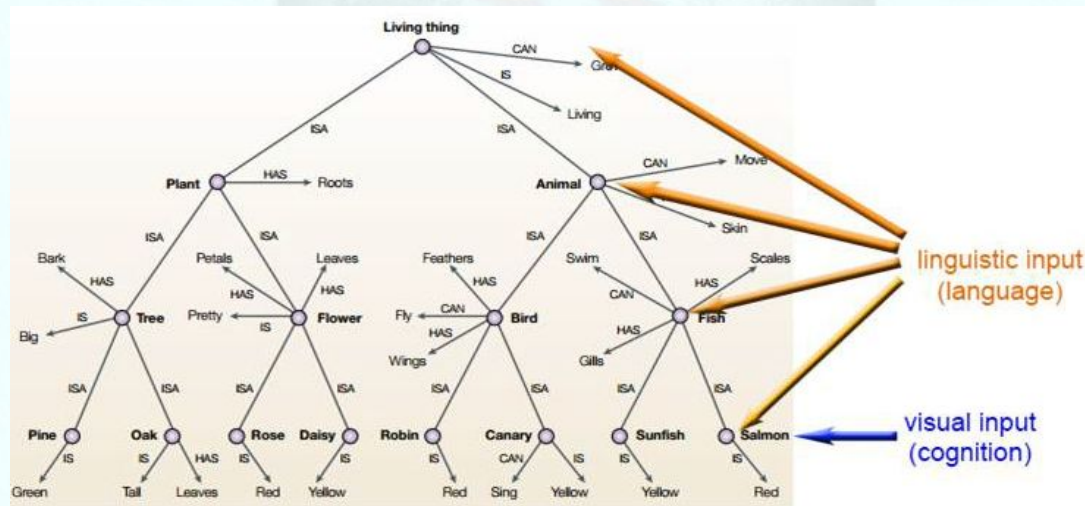


# Koncepty



## Reprezentační mohutnost

- Definované pojmy ne vždy – spíše reprezentace typických věcí či situací
- Uspořádání jinak než pravidla - hierarchie



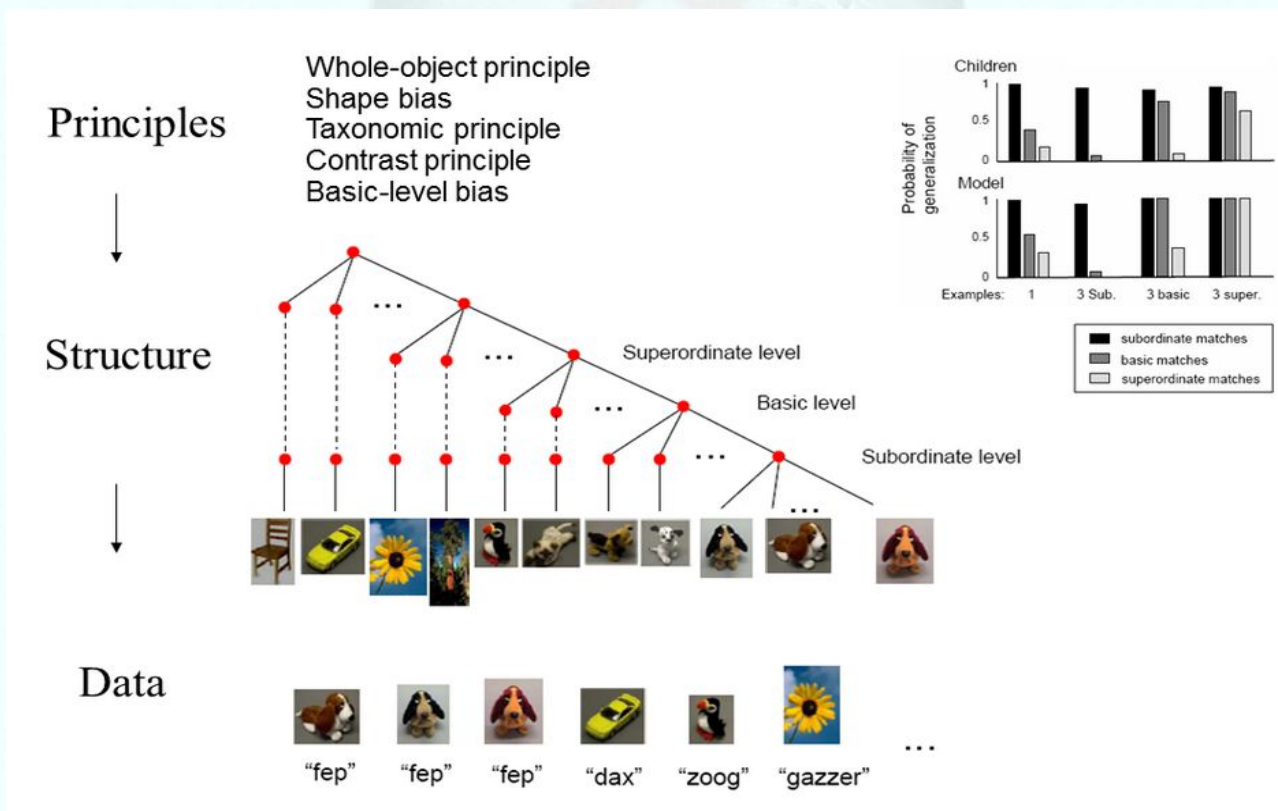


# Koncepty



## Reprezentační mohutnost

- Definované pojmy ne vždy – spíše reprezentace typických věcí či situací
- Uspořádání jinak než pravidla - hierarchie





# Koncepty



## Reprezentační mohutnost

- Definované pojmy ne vždy – spíše reprezentace typických věcí či situací
- Uspořádání jinak než pravidla - hierarchie





# Koncepty




## Výpočetní mohutnost

- Hierarchie → **výkonné** výpočetní postupy
- Která pravidla uplatňovat? - **šíření aktivace** – vybavíme si koncept a aktivace šíří na jiné koncepty co s ním propojeny do sítě
- **Zhuštění informace** do podoby pojmu – nejlépe v nových situacích
- **Řešení problémů**
  - **Plánování** – obecná pravidla → úspěch → scénář/koncept → aplikace konceptu, kde často opakuje
  - **Rozhodování** – někdy rychlé, zrádné
  - **Vysvětlení** – zhuštění, vysvětlující schémata
- **Učení** – pojmy vrozené, ze zkušenosti či odvozené od jiných pojmů  
-induktivní zobecnění X z mnoha příkladů
- **Jazyk** – většina pojmů slovo
  - mentální lexikon (soubor pojmů repr. V myslí) – WordNet (hierarchicky)
  - učíme mluvit – ne jen gram.pravidla, I pojmový systém

# Koncepty

## Psychologická přijatelnost

- jak potvrdit mentální reprezentace? - psych.exp., počítačové simulace
- Pravidla – simulace, pojmy – psycholog.experiment
- Pojmy spíše typické podmínky než definující – prototyp (nechali lidi v univerzitní knihovně bez knih → co tam bylo? (knihy))
- Nálezy prototypů odpovídají konceptům v rámci
- Znalost pojmu spjata s pův.příklady – exempláře a analogie



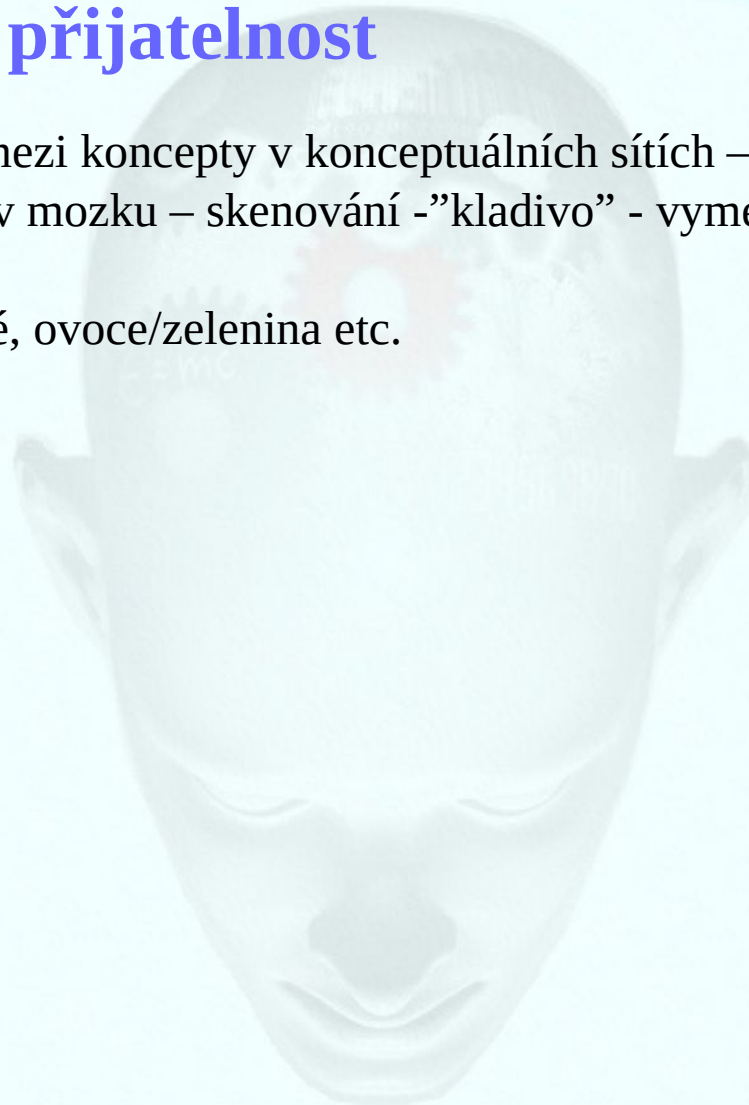


# Koncepty



## Neurologická přijatelnost

- Šíření aktivace mezi koncepty v konceptuálních sítích – jako aktivace neuronů
- Organizace řeči v mozku – skenování -”kladivo” - vymezení oblasti vnímání slov a produkce
- Poruchy – neživé, ovoce/zelenina etc.



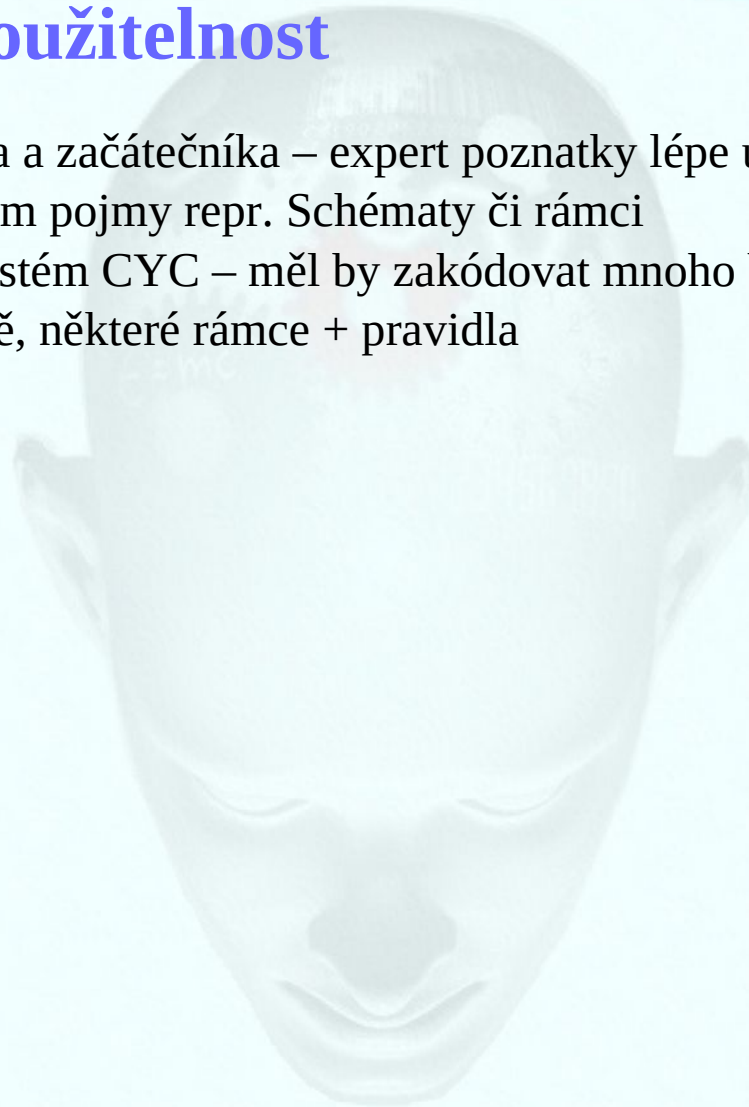


# Koncepty



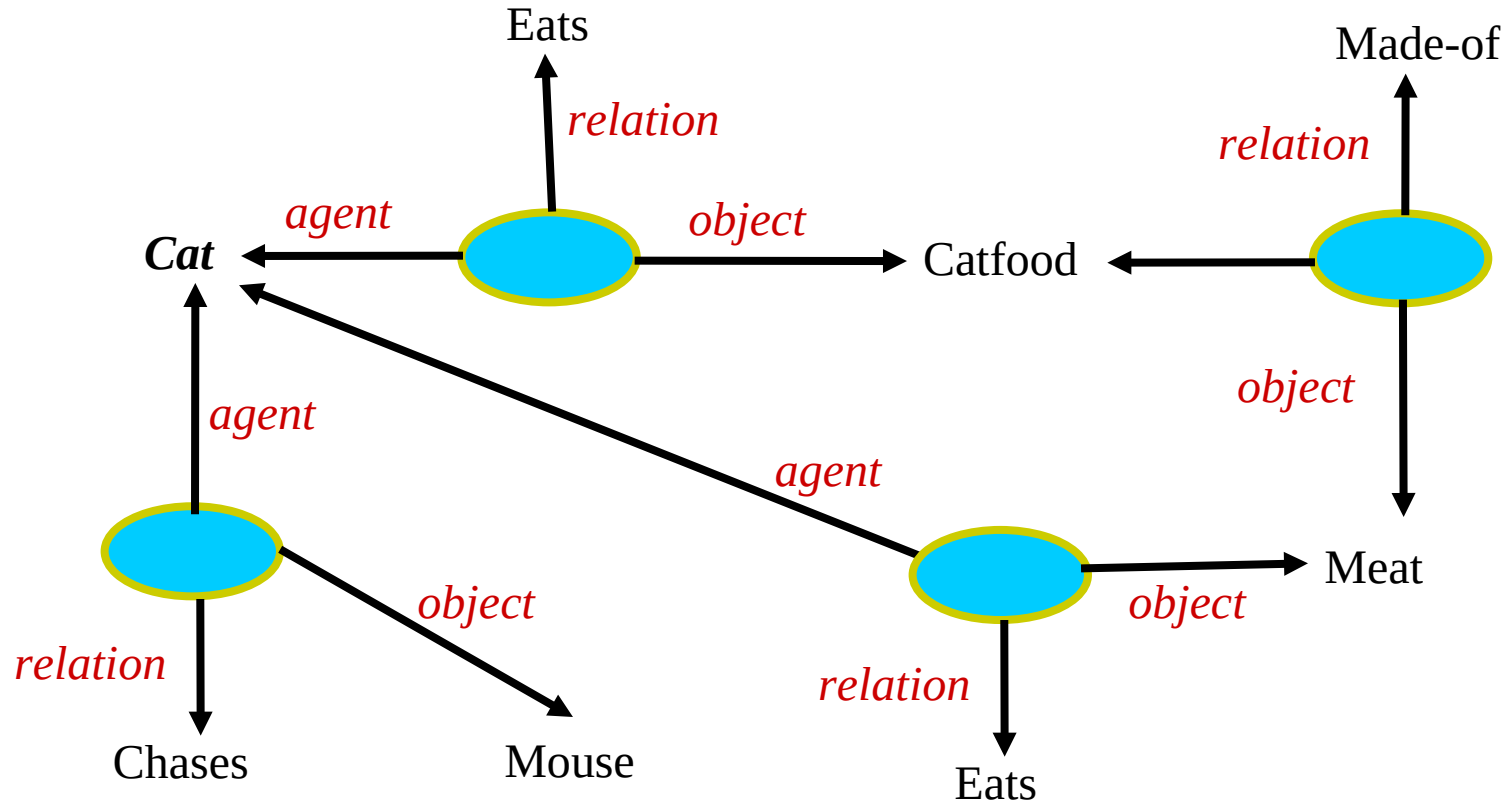
## Praktická použitelnost

- Rozdíl odborníka a začátečníka – expert poznatky lépe utříděny
- Plánovací problém pojmy repr. Schémata či rámci
- Rámce v UI – systém CYC – měl by zakódovat mnoho běžných znalostí
- Jen rámce vzácně, některé rámce + pravidla



# Pravidla + Koncepty (ACT-R)

- Význam každého konceptu v síti je reprezentován také pomocí propozic.



# Pravidla + Koncepty (ACT-R)

The activation  $A_i$  of a chunk  $i$  is defined fully as:

$$A_i = B_i + \sum_j W_j S_{ji} + \sum_k PM_{ki} + \epsilon$$

noise

## Base activation

$$B_i = \ln\left(\sum_{j=1}^n t_j^{-d}\right)$$

- $n$ : The number of presentations for chunk  $i$ .
- $t_j$ : The time since the  $j$ th presentation.
- $d$ : The decay parameter almost always set to 0.5.

## Kontext

**Match Scale,  $P$ :** This reflects the amount of weighting given to the similarity in slot  $k$ . By default this is a constant across all slots with the value of 1 and is set with the :mp parameter.

**Match Similarities,  $M_{ki}$ :** The similarity between the value  $k$  in the retrieval specification and the value in the corresponding slot of chunk  $i$ .

## Partial matching

**Sources of Activation:** The elements  $j$  being summed over are the chunks which are in the slots of the goal chunk.

**Weighting:**  $W_j$  is the amount of activation from source  $j$ .

**Strengths of Association:**  $S_{ji}$  is the strength of association from source  $j$  to chunk  $i$ .

$$S_{ji} = S - \ln(\text{fan}_j)$$

$S$ : A parameter to be estimated (set with the maximum associative strength, :mas, parameter)



$\text{fan}_j$ : is the number of chunks in which  $j$  is the value of a slot plus one for chunk  $j$  being associated with itself.

# Reprezentace znalostí v kognitivních robotických systémech


## Kolaborativní robotické pracoviště

Co je potřeba reprezentovat:

- Objekty a jejich vlastnosti
- Vztahy mezi objekty
- Části objektů a jejich funkční vlastnosti
- Pozice člověka, jeho ruky
- Jazyk: názvy objektů, akcí, vlastní pojmenování
- Pracovní postupy výrobků



Obrázek 2.4: 3D model stavebnice pejska (dog) v částečně složeném stavu (vlevo) s fotografií skutečného výrobku (vpravo).



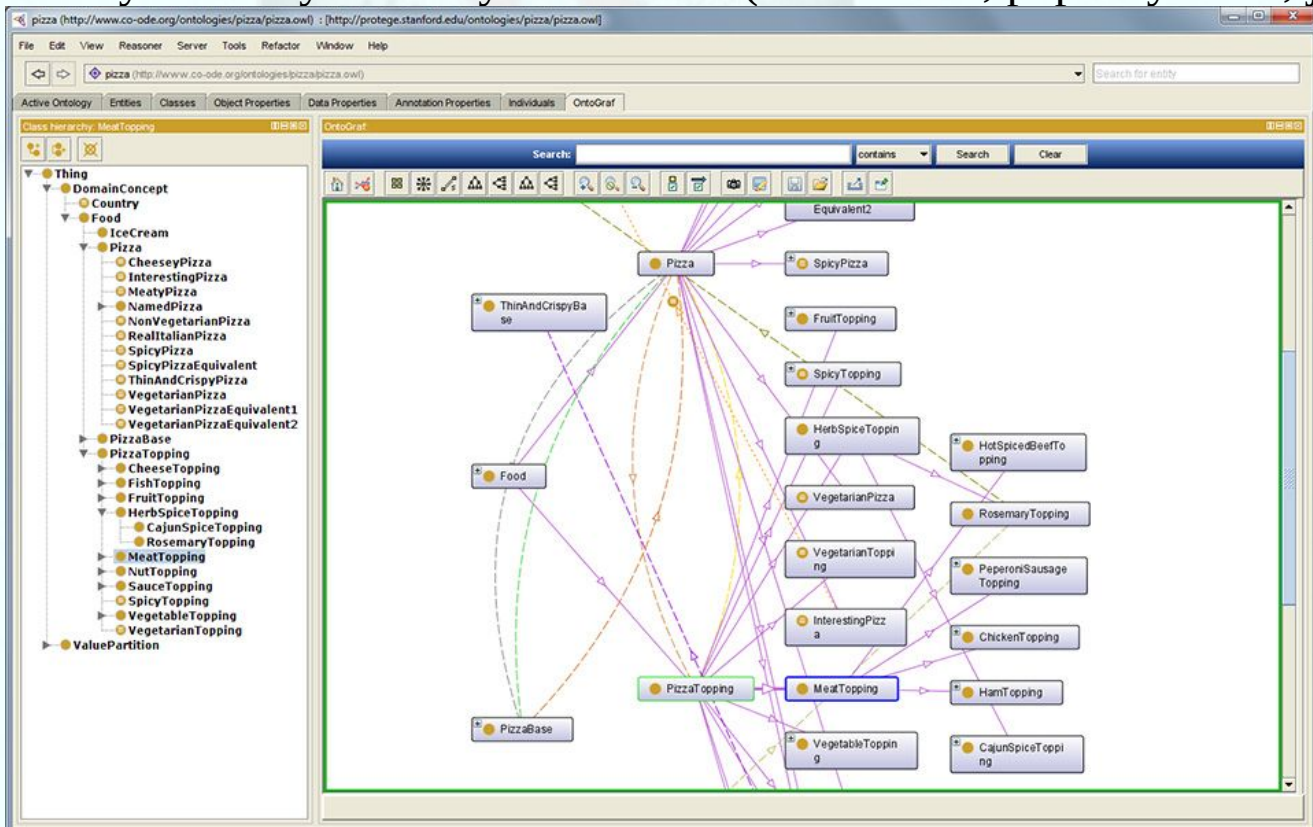




# Reprezentace znalostí v kognitivních robotických systémech

## Ontologie

- Zachycení vztahů mezi objekty (šroubovák je ostrý, křížový šroubovák je typu šroubovák -> křížový šroubovák je ostrý)
- Možnost zachytit vztahy na různých úrovních (affordances, popis výrobku, jazyk, atp.)





# Ontologie

## Reprezentace znalostí

The screenshot shows the CROW ontology editor interface. On the left, a class hierarchy is visible, including **CUBE** and various color and action classes. The main window displays the **Individuals: CUBE** view, listing 32 instances of the **CUBE** class. The right panel shows **Property assertions: CUBE**, detailing object and data properties for the selected instance.

k,

CROW: Instance (kostka) s různými vlastnostmi, které se naplňují



# Ontologie



## Reprezentace znalostí

The screenshot displays the CROW ontology editor interface. On the left, a class hierarchy tree is visible, starting with 'MaterialThing' at the root. It branches into 'Tag', 'TaggedText', 'TaggedToken', 'TemporalThing', 'ActionResult', and 'MaterialThing'. Under 'MaterialThing', there are several sub-classes: 'RightWrist', 'Tool', 'WorkMaterial', and 'Workpiece'. 'Tool' includes 'ClampingTool', 'DrivingTool', 'Screwdriver', 'Glue', 'HandTool', 'PowerTool', and 'WorkMaterial'. 'WorkMaterial' includes 'Consumable', 'Adhesive', 'Fastener', and 'Workpiece'. 'Workpiece' includes 'CarRoof', 'Cube', 'ExcavatorBucket', 'Sphere', 'Wafer', and 'Wheel'. The 'Cube' class is highlighted in blue. On the right, the 'Cube' class details are shown. The 'Usage' tab is active, displaying 'Usage: Cube' and 'Asserted'. Below this, there are sections for 'Annotations', 'Description', and 'Equivalent To'. The 'Description' section shows 'Equivalent To' with a plus sign, 'SubClass Of' with 'Workpiece', 'General class axioms' with a plus sign, 'SubClass Of (Anonymous Ancestor)' with a plus sign, 'Instances' with 'CUBE', 'Target for Key' with a plus sign, 'Disjoint With' with a plus sign, and 'Disjoint Union Of' with a plus sign.

CROW: Hierarchie tříd



# Ontologie



## Reprezentace znalostí

- Zachycení vztahů mezi objekty (šroubovák je ostrý, křížový šroubovák je typu šroubovák -> křížový šroubovák je ostrý)
- Možnost zachytit vztahy na různých úrovních (affordances, popis výrobku, jazyk, atp.)
- Ukládání pomocí triples (redCube, hasColor, red)
- Nástroj Protégé, RDFlib formát, Apache Jena Fuseki database – real data

Tabulka 7: Ukázka rozdílu práce s RDF grafem versus OOP přístup (vytvoření červené kostky, tedy instance třídy „cube“ s červenou barvou a následná změna x-ové pozice)

### RDFlib:

```
graph.addN([(„redCube“, „type“, „cube“, graph), („redCube“,  
„hasColor“, „red“, graph)])  
graph.remove(„redCube“, „x“, None)  
graph.add(„redCube“, „x“, 12)
```

### OOP:

```
redCube = onto.Cube(color="red")  
redCube.x = 12
```

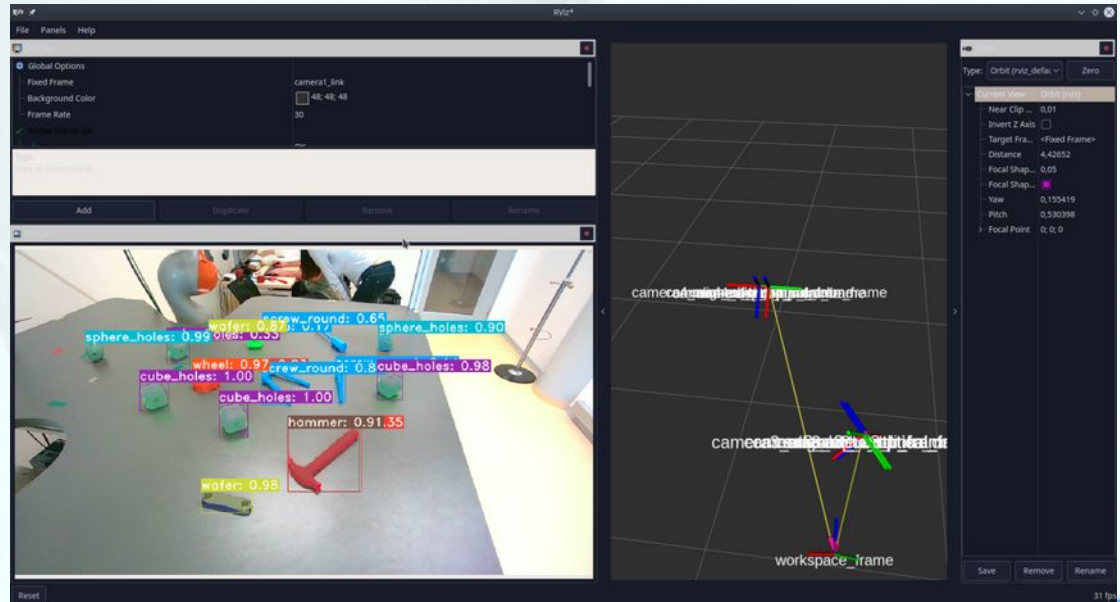
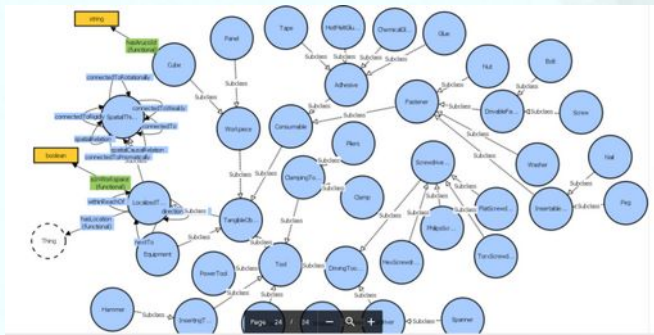


# Ontologie



## Vlastnosti objektů




- Zachycení vztahů mezi objekty (šroubovák je ostrý, křížový šroubovák je typu šroubovák -> křížový šroubovák je ostrý)
- Možnost zachytit vztahy na různých úrovních (affordances, popis výrobku, jazyk, atp.)
- Ukládání pomocí triples (redCube, hasColor, red)
- Nástroj Protégé, RDFlib formát, Apache Jena Fuseki database – real data







# Ontologie

## Reprezentace prac.postupu




Obrázek 2.4: 3D model stavebnice pejska (dog) v částečně složeném stavu (vlevo) s fotografií skutečného výrobku (vpravo).



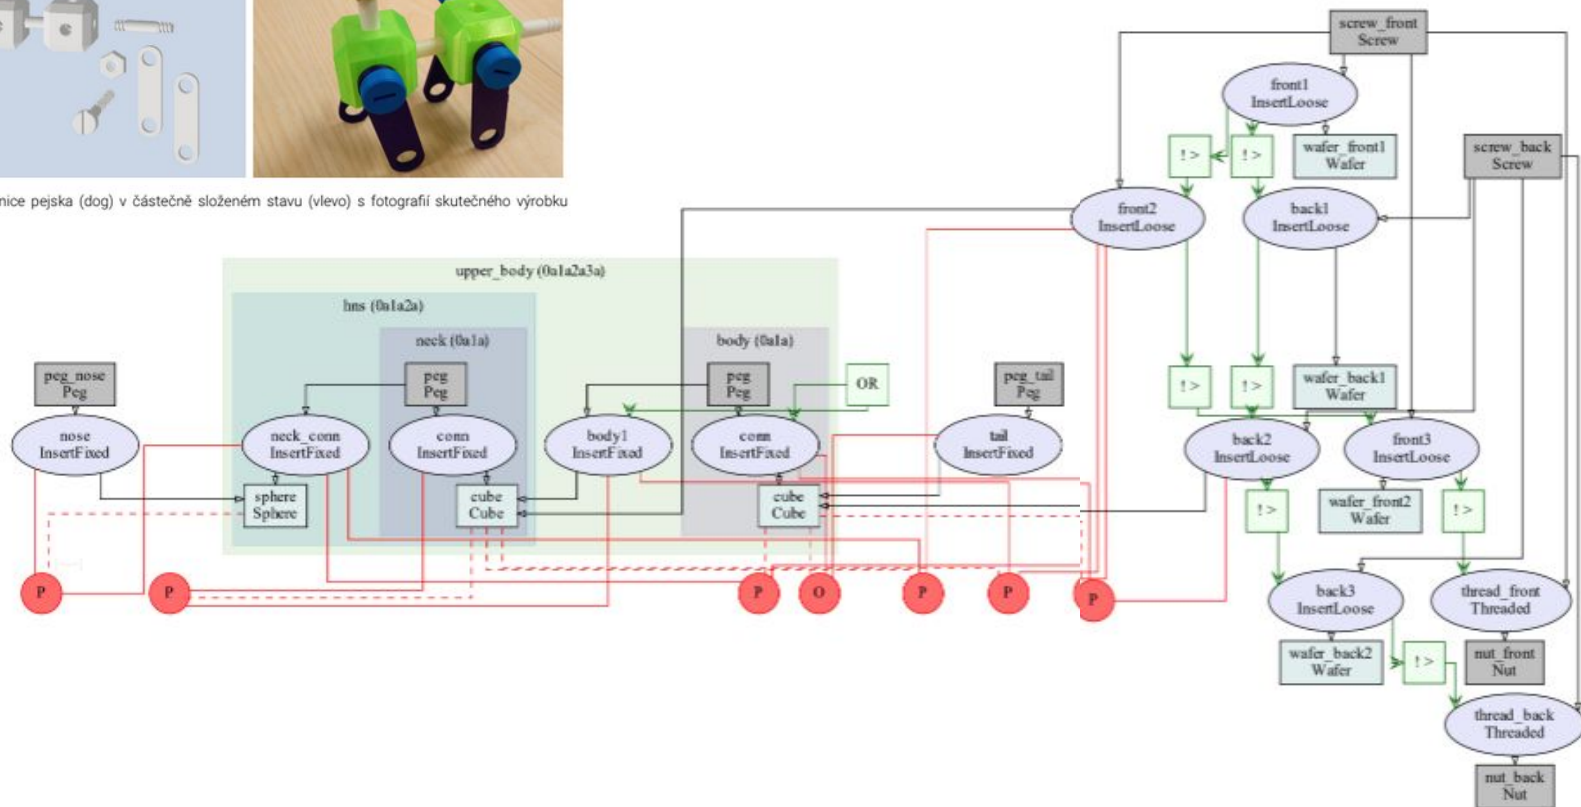
Obrázek 2.2: Výrobek „0a1a2a“: 3D model (vlevo), graf instancí objektů v ontologii (uprostřed) a graf znázorňující stavbu (vpravo). Graf instancí v ontologii ukazuje, že objekty a operace z konstrukce 0a1a byly automaticky přiřazeny také konstrukci 0a1a2a.

# Ontologie

## Reprezentace prac.postupu



Obrázek 2.4: 3D model stavebnice pejška (dog) v částečně složeném stavu (vlevo) s fotografií skutečného výrobku (vpravo).



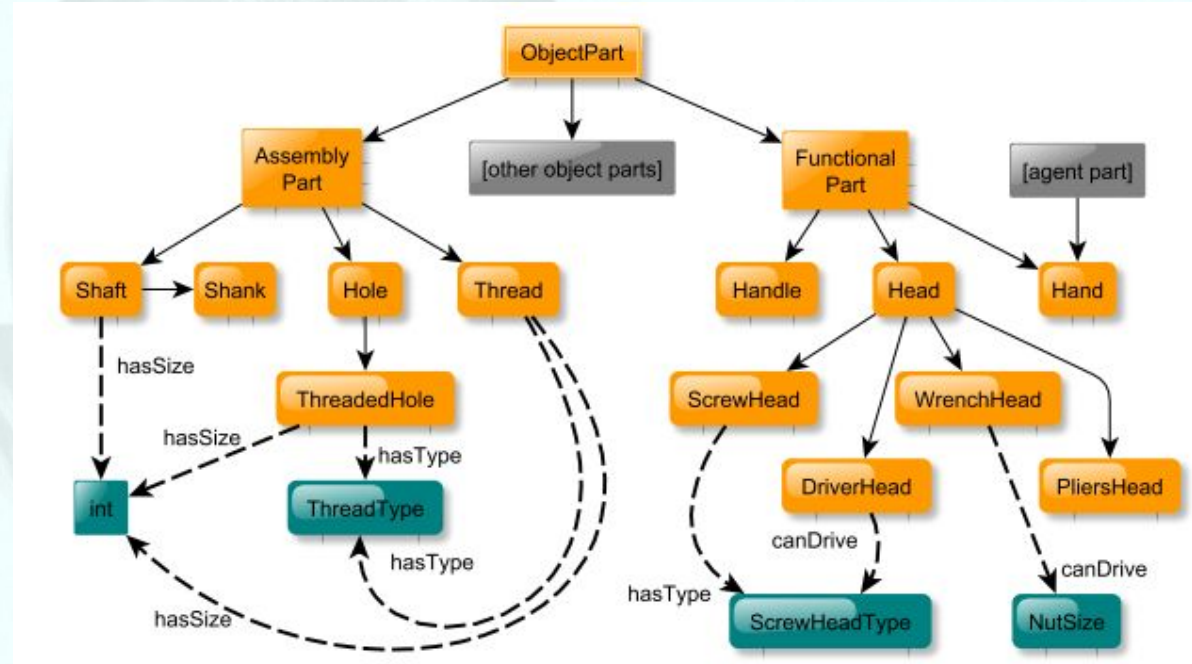
Obrázek 2.5: Automaticky generovaný graf konstrukce pejška (viz obr. 2.4). Šedě jsou znázorněny spojovací materiály, bílé v obdélníkových objekty, fialové operace, v červených kružcích jsou prostorové relace, v zelených čtverečích časové relace. Různě zbarvená pozadí některých uzlů znázorňují jejich příslušnost do „podčástí“ definovaných v externích souborech



# Ontologie



## Affordances



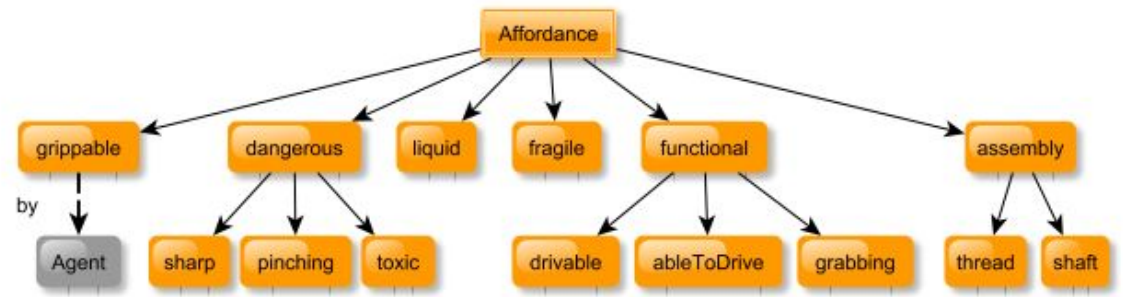
Obrázek 3.1: Diagram zobrazující strukturu v znalostní bázi, která zachytává části objektů s přiřazenými funkcionalitami. Zeleně jsou znázorněny třídy, které nerepresentují části objektů a šedě třídy, které nemají přiřazenou funkcionalitu. Spojení plnou čarou reprezentují strukturu tříd (šipky směřují k podtřídám) a spojení přerušovanou čarou reprezentují vlastnosti.



# Ontologie




## Affordances



Obrázek 3.2: Typy funkcionalit a vlastností objektů (resp. jejich částí), uložených v znalostní bázi.

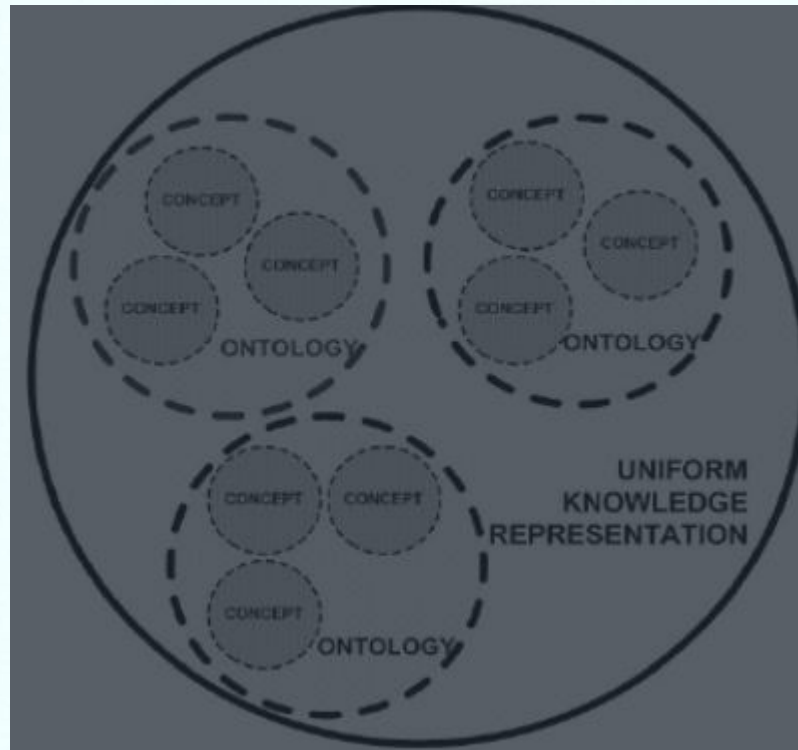


Obrázek 3.4: Modely objektů použity pro trénování rozpoznávání funkčních částí s barevně odlišeným rozdělením na jednotlivé části.



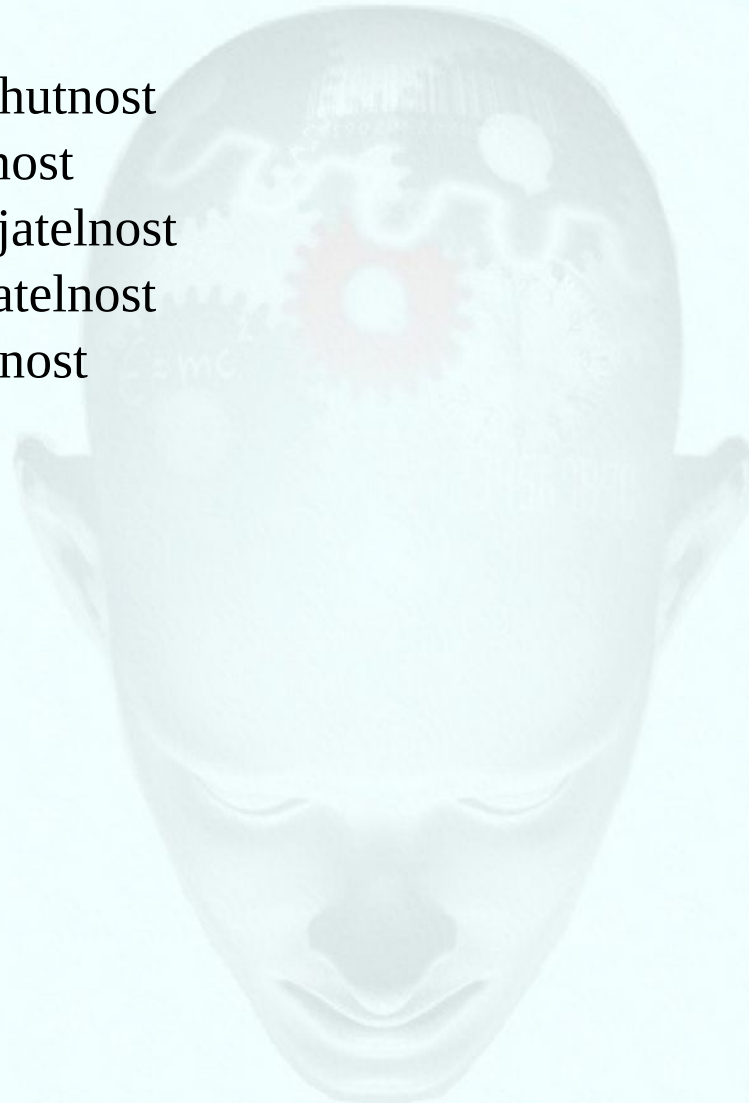
Obrázek 3.3: Ukázka detekce funkčních částí objektů.

# Ontologie



# Posouzení přístupů

- Reprezentační mohutnost
- Výpočetní mohutnost
- Psychologická přijatelnost
- Neurologická přijatelnost
- Praktická použitelnost






# Ontologie



## Výpočetní náročnost

- Roste s počtem entit
- Problém při real-time usuzování





# Ontologie



## Reprezentační mohutnost

- Využívají logiku prvního řádu, vztahy objektů
- Různé třídy, reprezentace konceptů pro danou oblast a vztahy mezi třídami, slovník a taxonomie, problém může být kontrolovaný slovník
- Reprezentace pomocí triples (Kostka, isA, Objekt)
- Definování vlastností různých tříd -> lze usuzovat, který objekt je pozorovaný na základě zděděných vlastností
- Inference nad vlastnostmi, výběr daných objektů/tříd

Tabulka 7: Ukázka rozdílu práce s RDF grafem versus OOP přístup (vytvoření červené kostky, tedy instance třídy „cube“ s červenou barvou a následná změna x-ové pozice)

### RDFlib:

```
graph.addN([(„redCube“, „type“, „cube“, graph), („redCube“,  
„hasColor“, „red“, graph)])  
graph.remove(„redCube“, „x“, None)  
graph.add(„redCube“, „x“, 12)
```

### OOP:

```
redCube = onto.Cube(color=„red“)  
redCube.x = 12
```



# Ontologie



## Neurologická přijatelnost

- Šíření aktivace mezi uzly – síla spojení lze přidat ke spojení mezi koncepty jako interní vlastnost
- Kognitivní ontologie
  - <https://www.youtube.com/watch?v=2acb4YlT1V8>



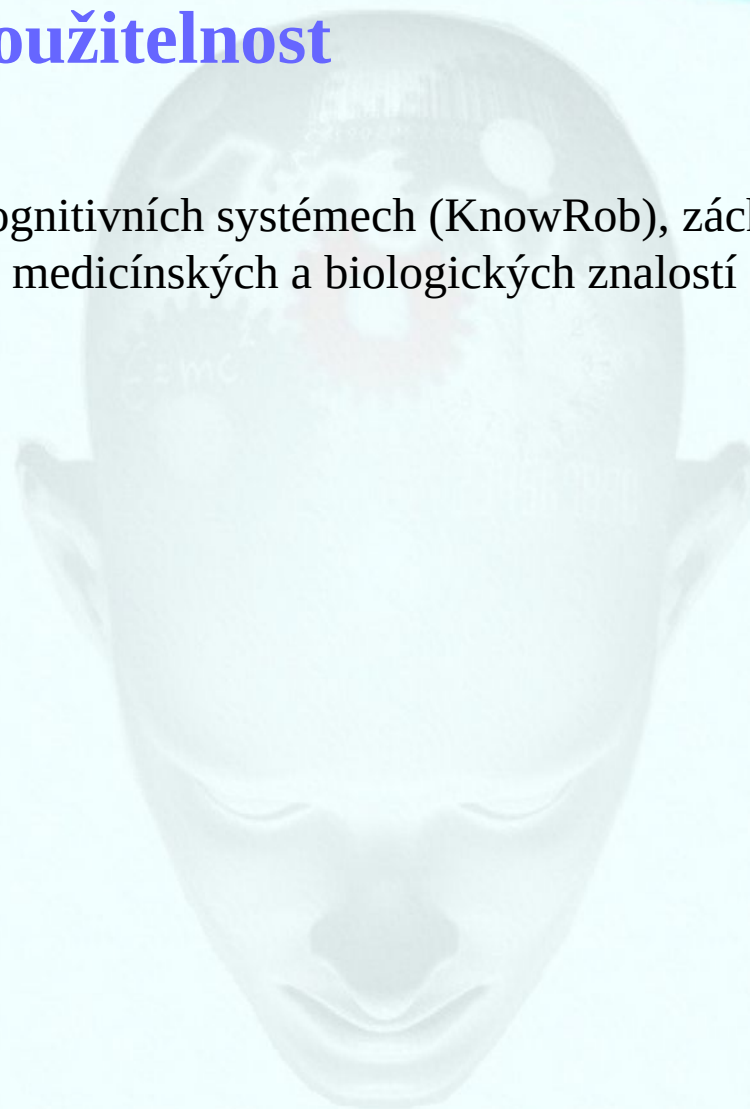


# Ontologie



## Praktická použitelnost

- Ukázáno výše
- využití ve velkých kognitivních systémech (KnowRob), záchranný robot (Tradr), reprezentace medicínských a biologických znalostí



# 3D scene graphs

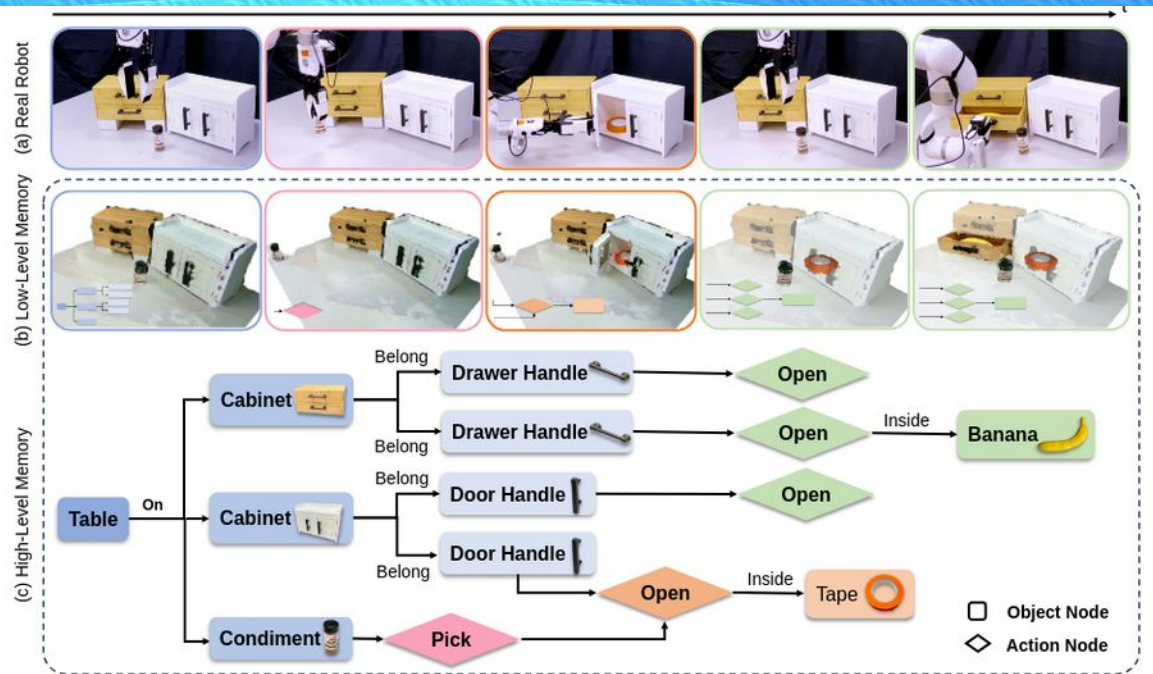


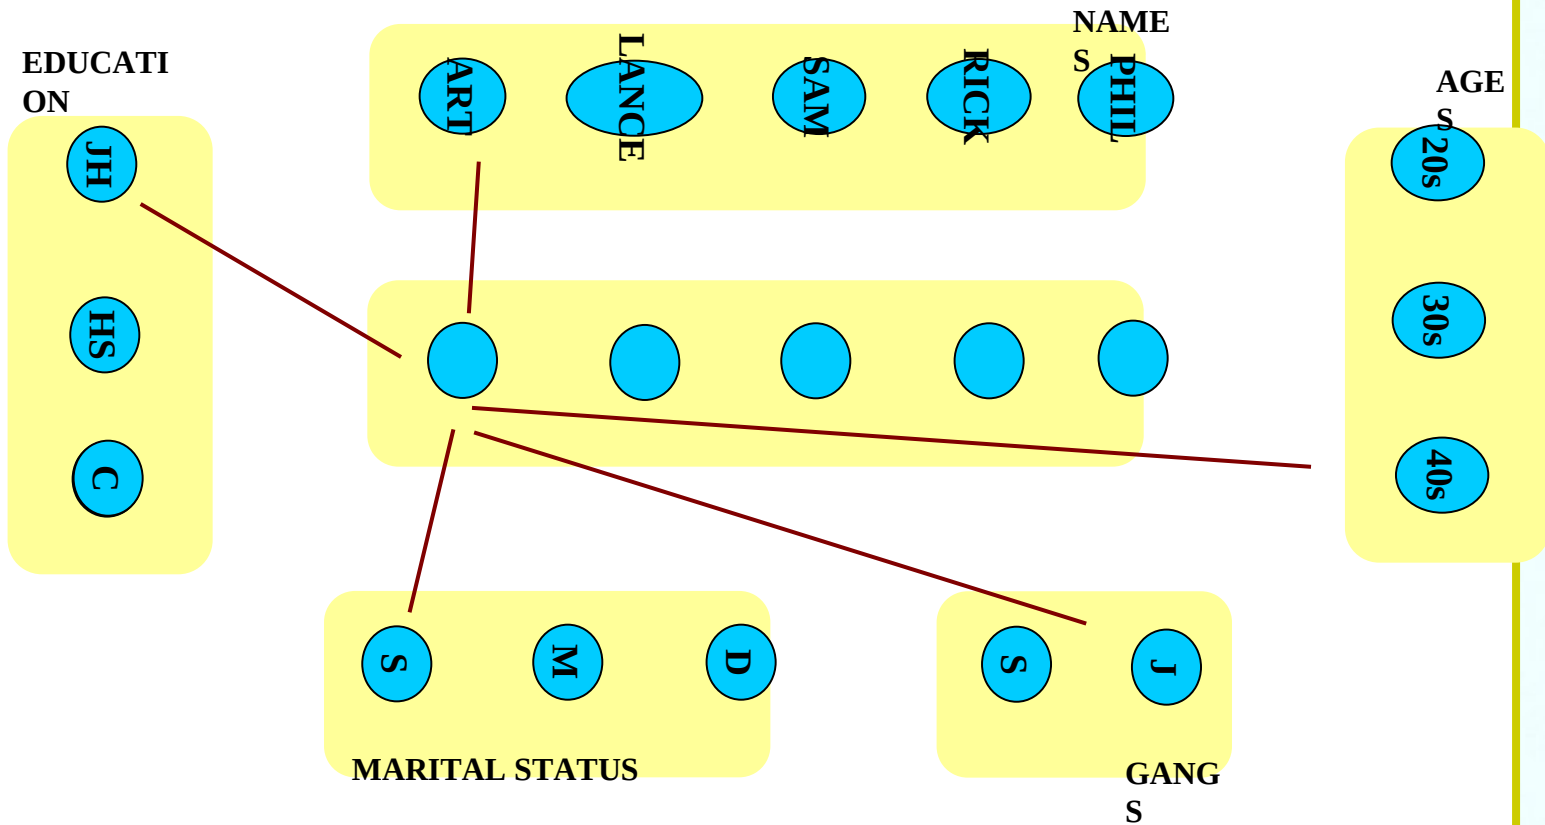
Figure 2: **Action-Conditioned 3D Scene Graph from Interactive Scene Exploration.** We depict a scenario wherein a robot arm explores a tabletop scene containing two cabinets and a condiment obstructing the left door. (a) The robot arm actively interacts with the scene, completing the interactive scene exploration process. (b) We showcase the corresponding low-level memory in our ACSG. The small graph on the bottom-left of each visualization represents a segment of the final scene graph. (c) We present the high-level memory of our ACSG. The graph reveals that picking up the condiment serves as a precondition for opening the door, and opening the bottom drawer allows the observation of the concealed banana.

<https://arxiv.org/pdf/2402.15487>

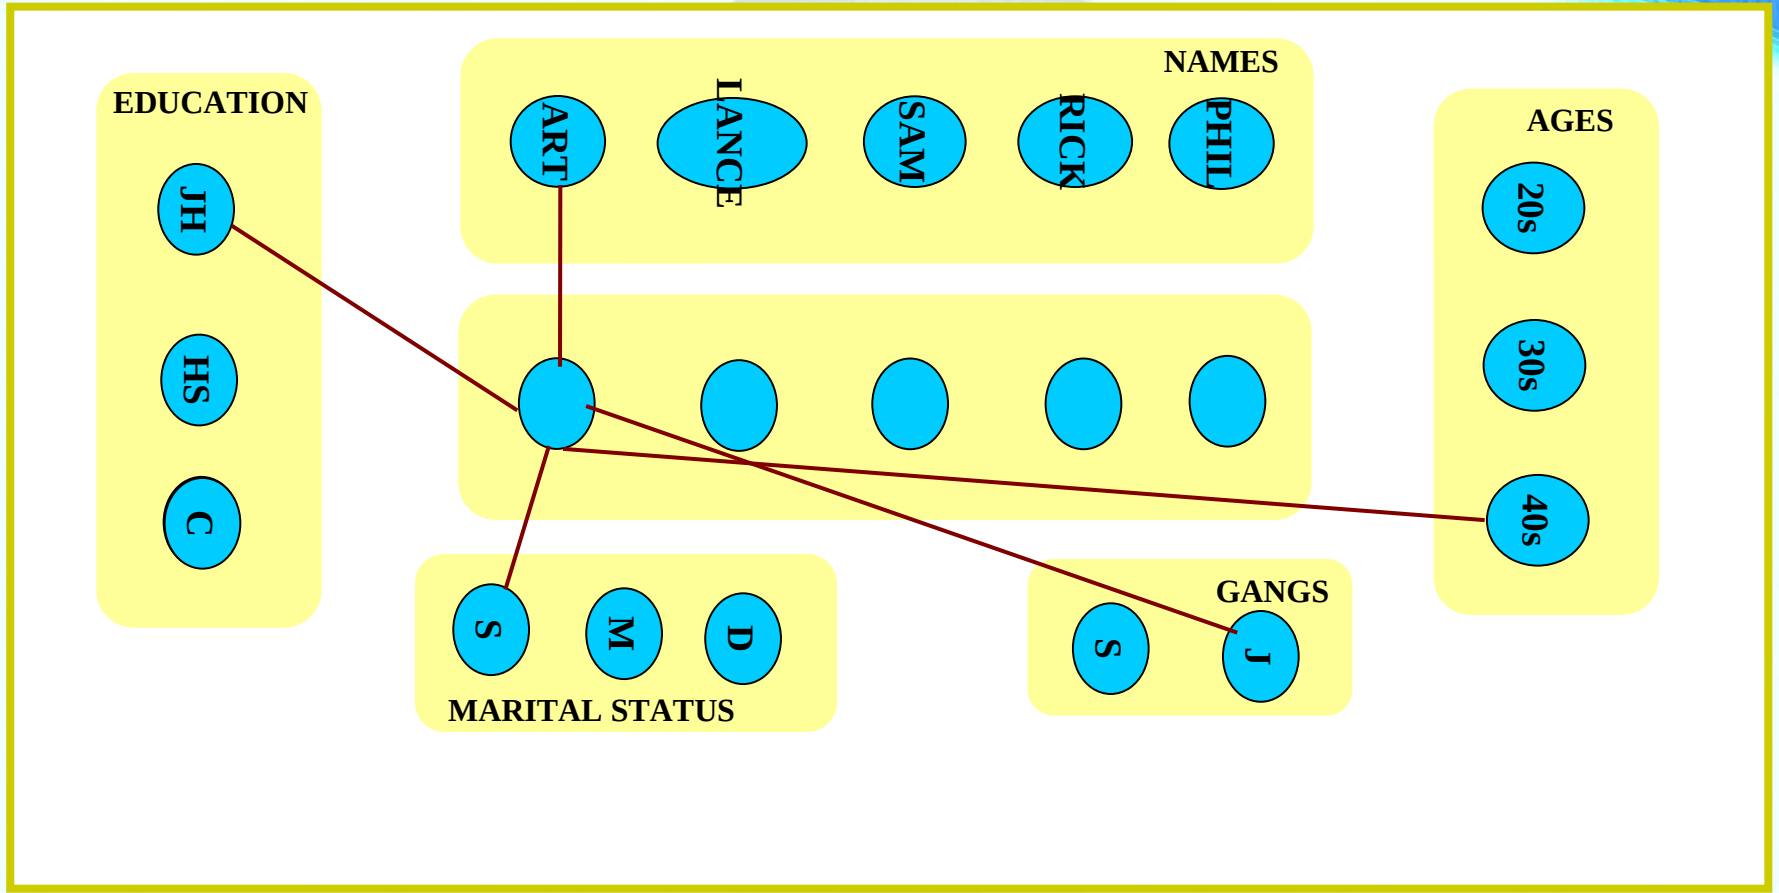
RoboEXP: Action-Conditioned Scene Graph via  
Interactive Exploration for Robotic Manipulation

# Konekcionistické modely

- Informace o jednotlivých objektech jsou uloženy v neuronové síti

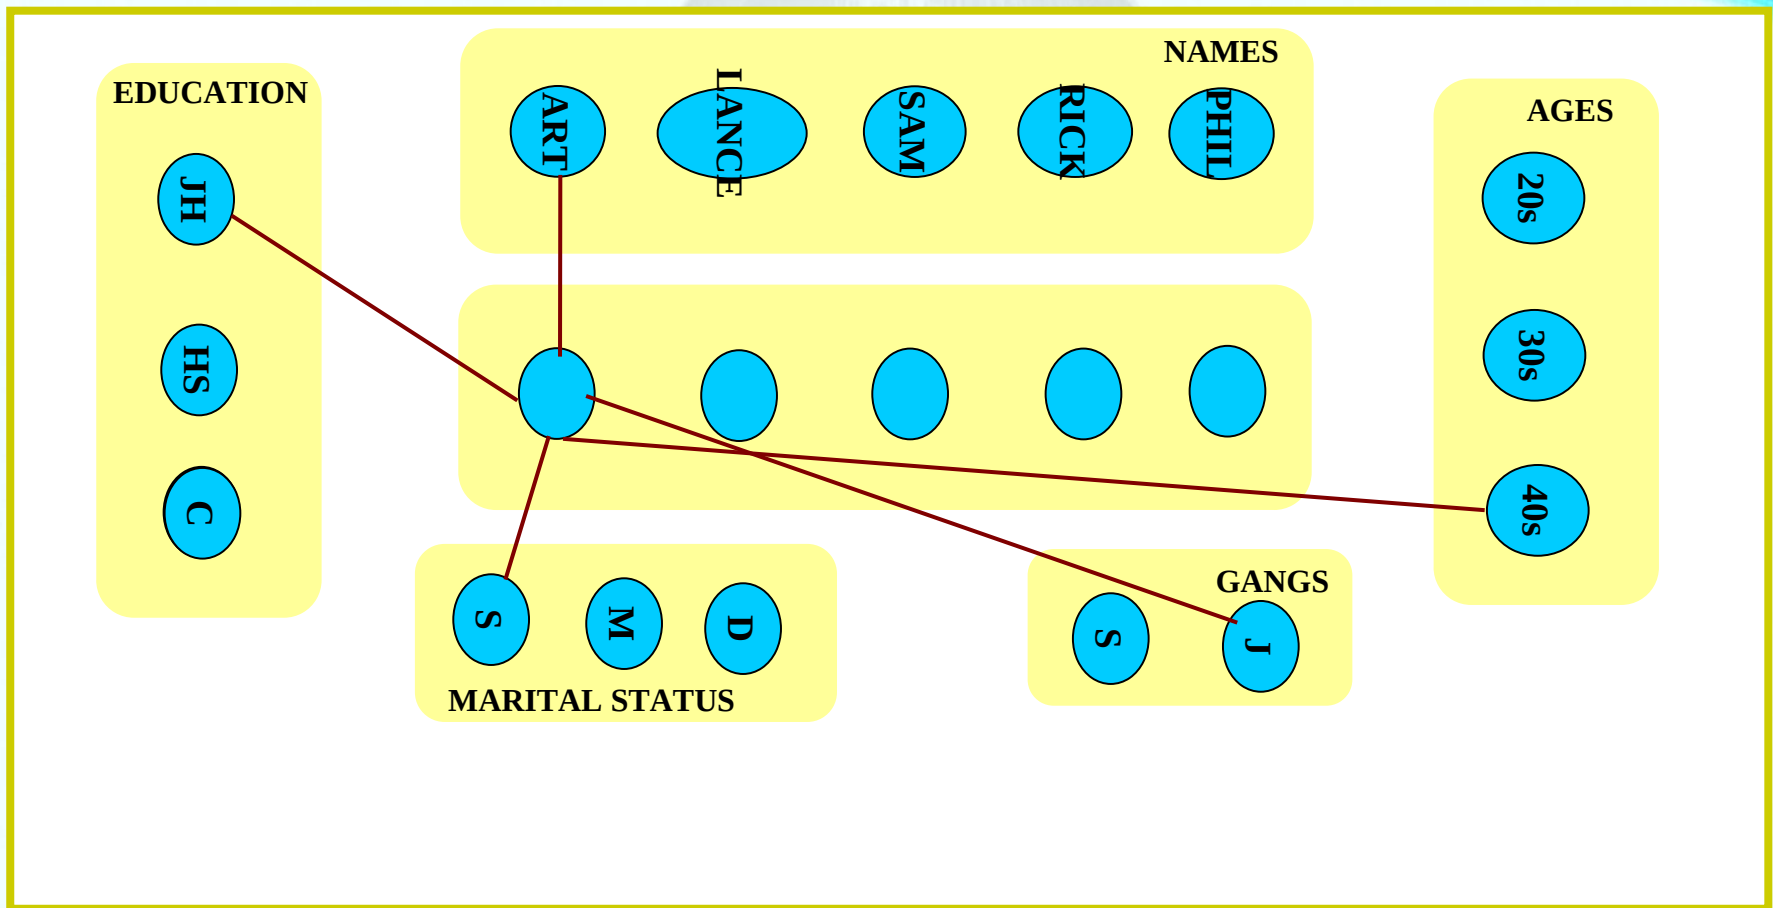


# Konekcionistické modely

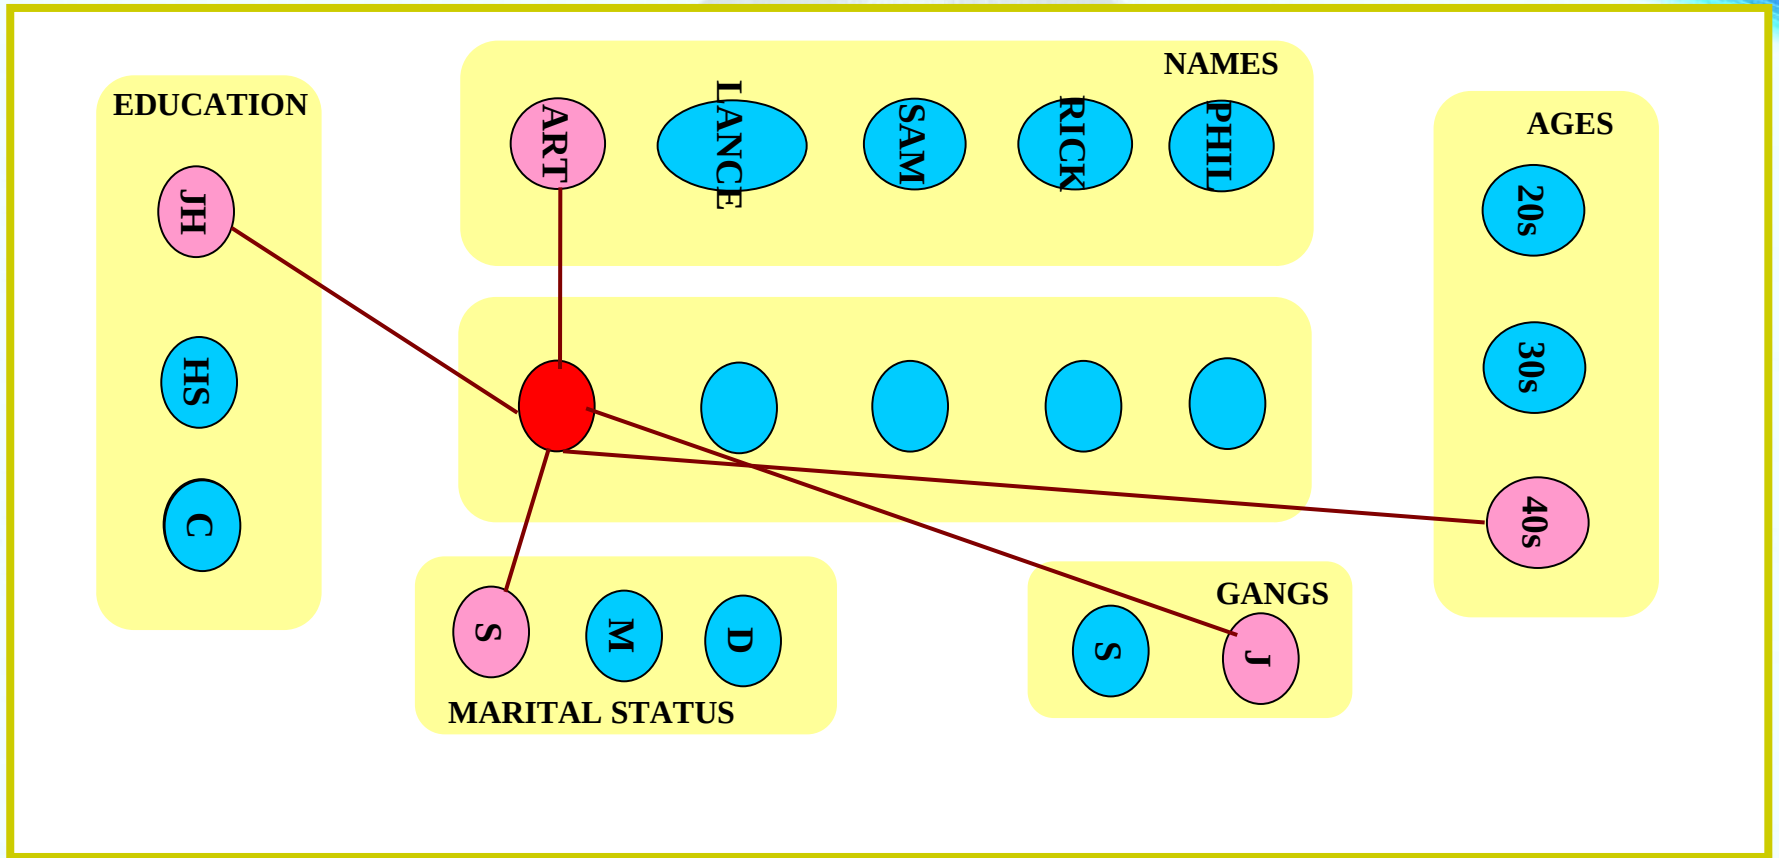




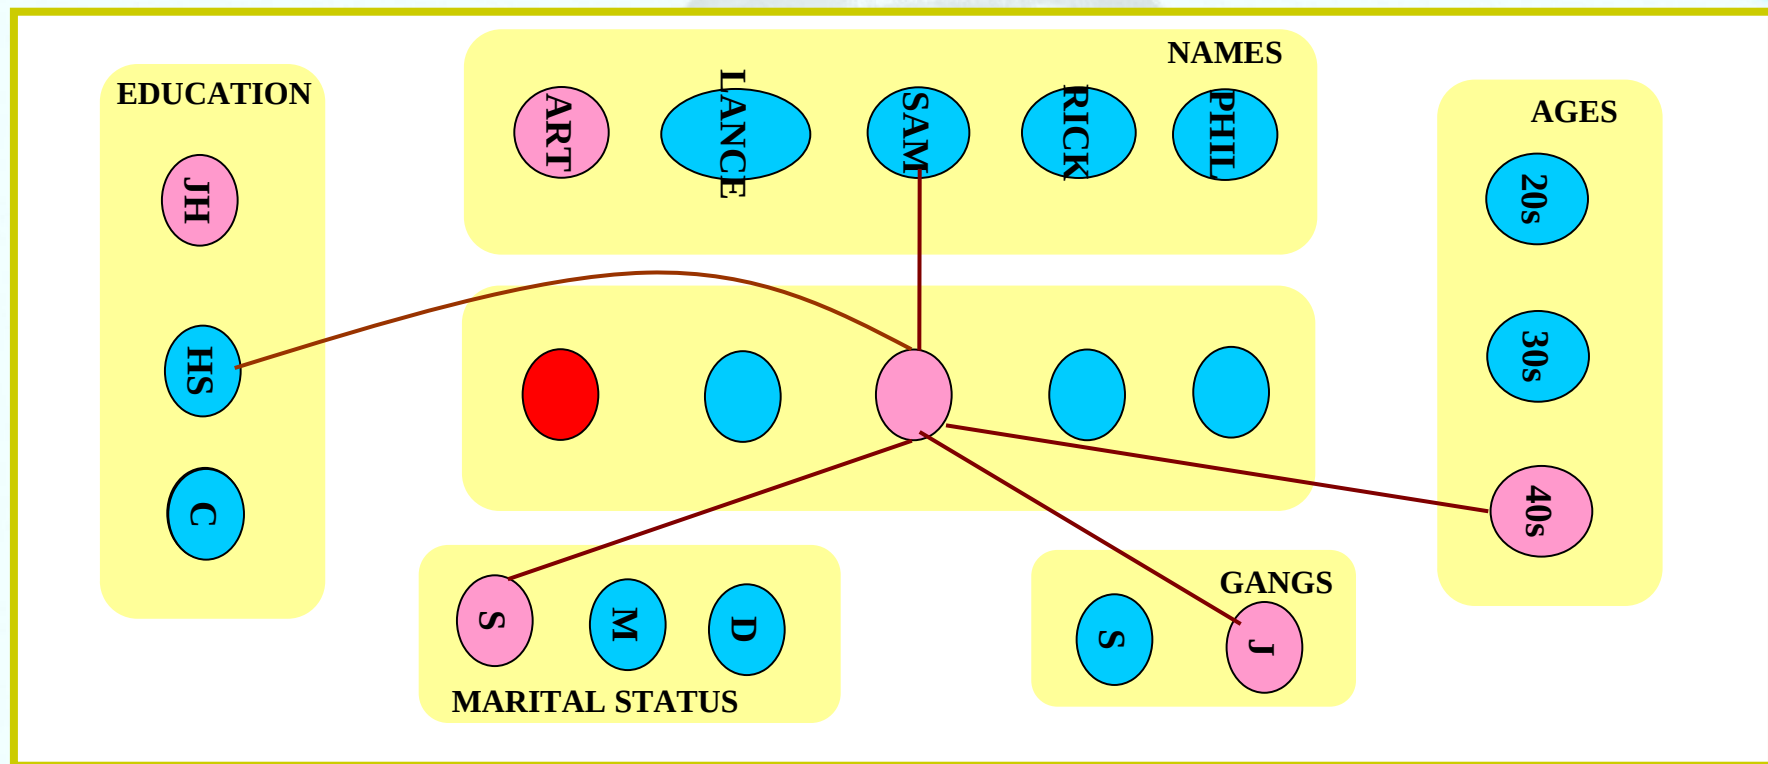
# Konekcionistické modely



# Konekcionistické modely

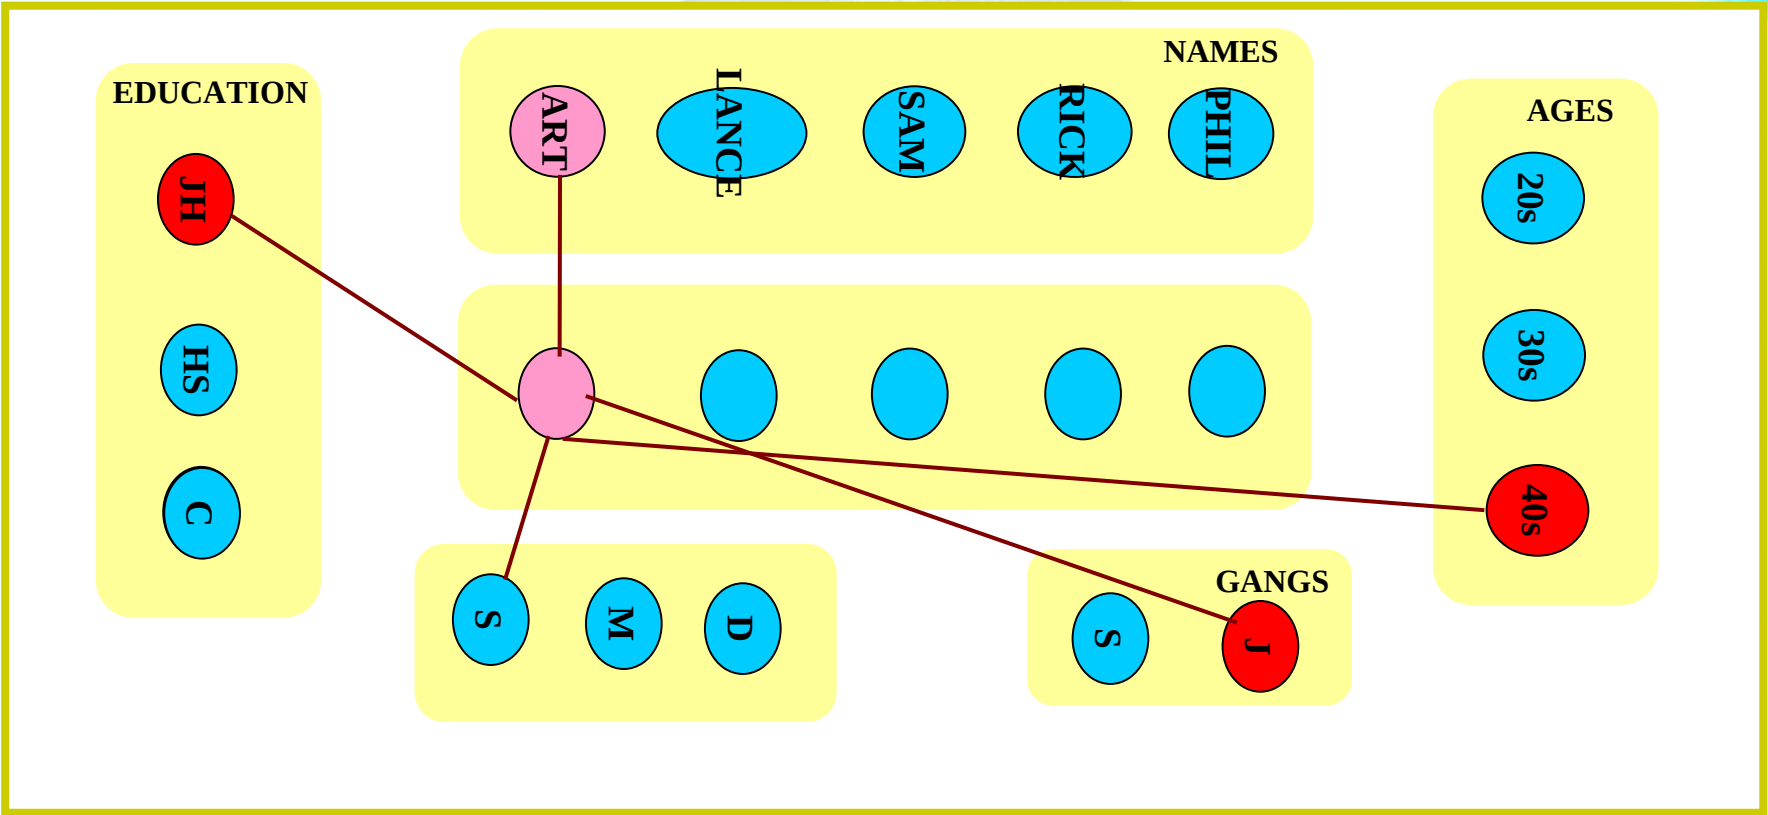


# Konekcionistické modely





# Konekcionistické modely



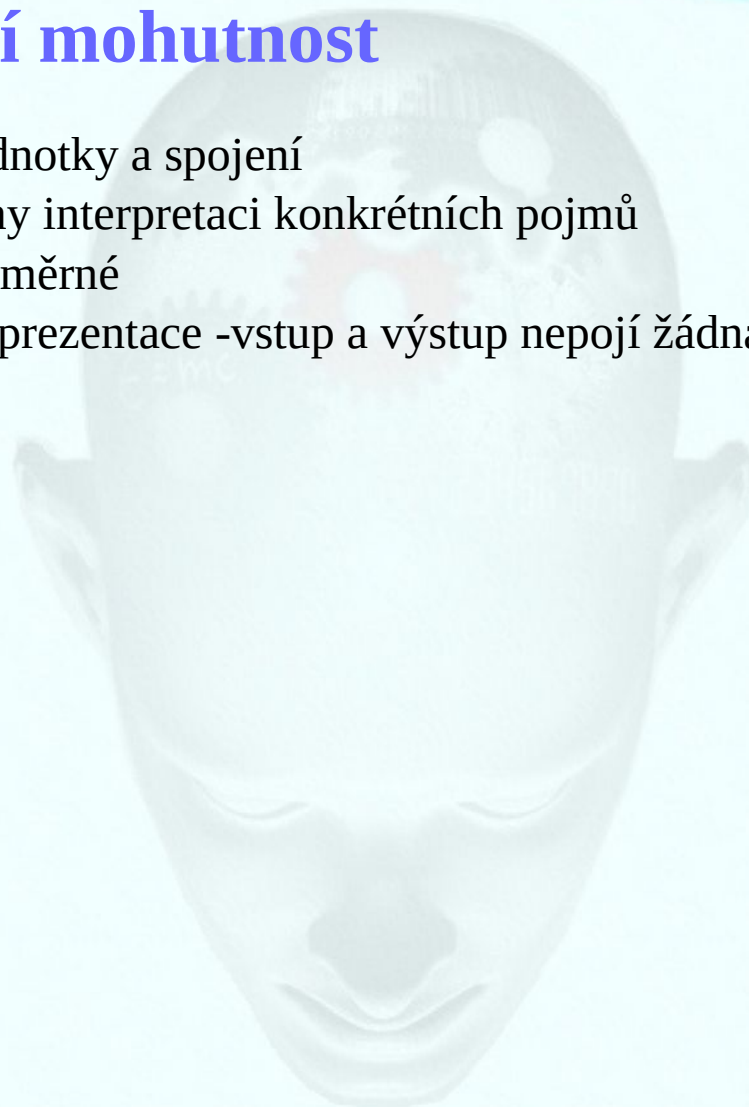


# Konekcionistické modely



## Reprezentační mohutnost

- Jednoduché – jednotky a spojení
- Lokální – neurony interpretaci konkrétních pojmů
- Propojení jednosměrné
- Distribuovaná reprezentace -vstup a výstup nepojí žádná předem daná interpretace
- Synchronizace
- “black box”



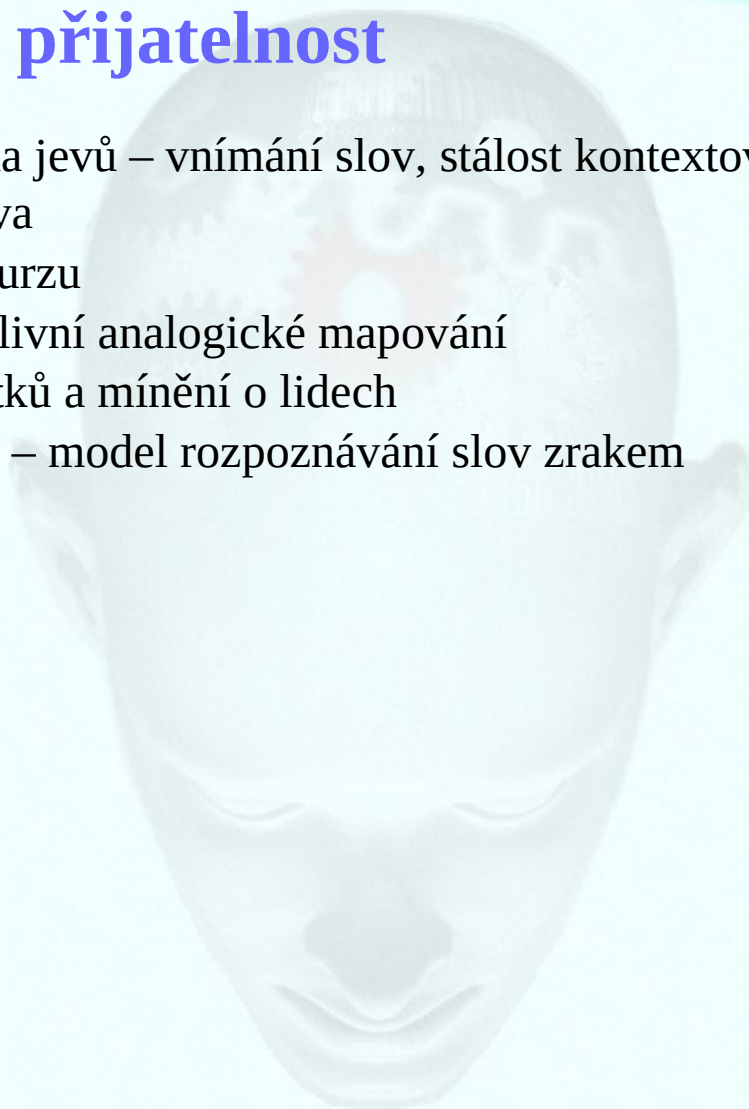


# Konekcionistické modely



## Psychologická přijatelnost

- Vysvětlení mnoha jevů – vnímání slov, stálost kontextových písmen ovlivňuje vnímatelnost slova
- Porozumění diskurzu
- Účel analogie ovlivní analogické mapování
- Vytváření poznatků a mínění o lidech
- Backpropagation – model rozpoznávání slov zrakem



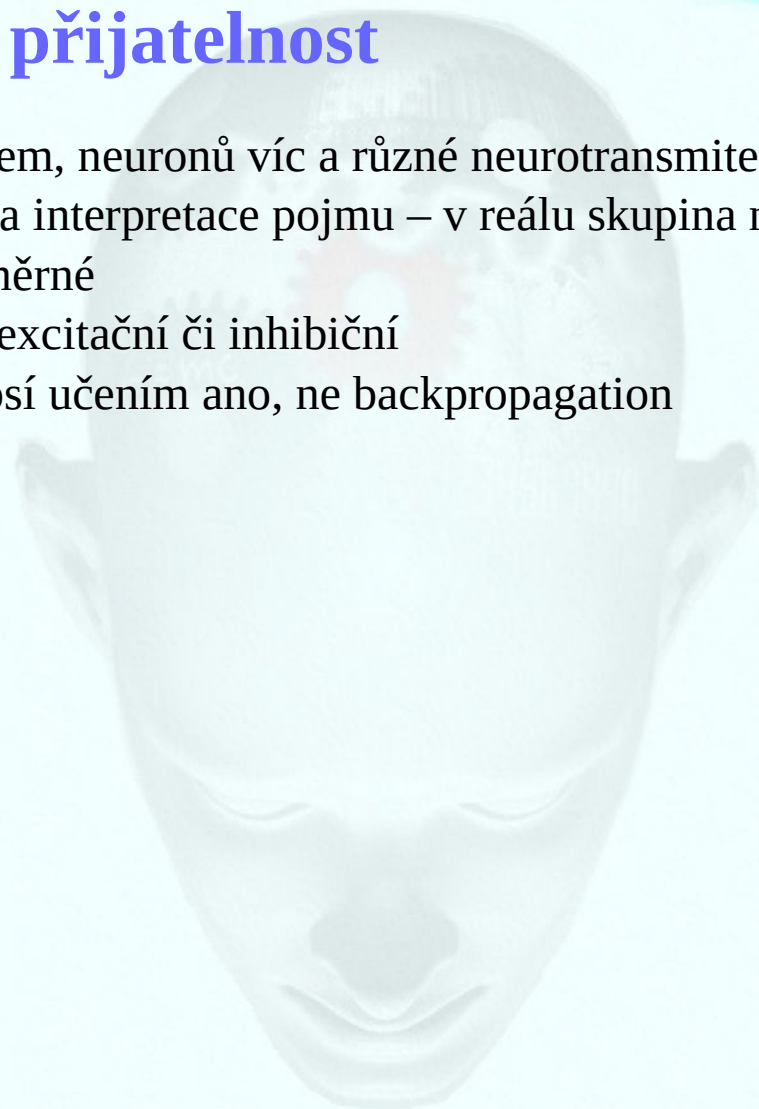


# Konekcionistické modely



## Neurologická přijatelnost

- Podobné s mozkiem, neuronů víc a různé neurotransmitery
- Lokální -jednotka interpretace pojmu – v reálu skupina neuronů
- Synapse jednosměrné
- Neuron jen buď excitační či inhibiční
- Posilování synapsí učením ano, ne backpropagation



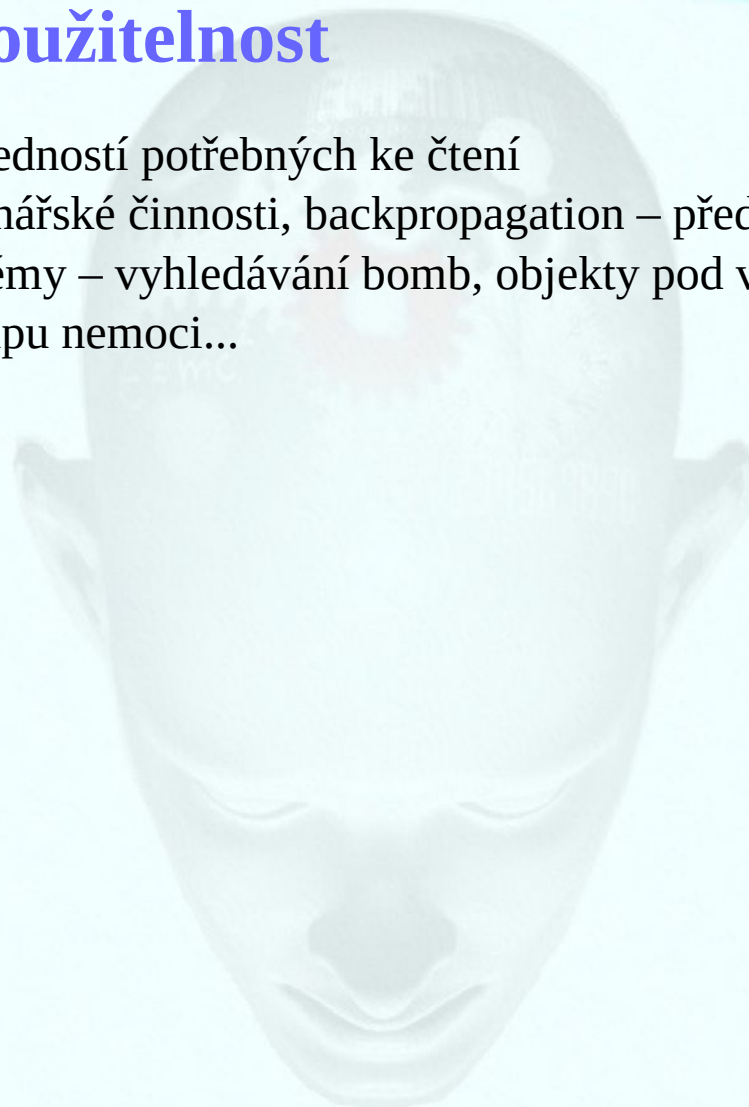


# Konekcionistické modely



## Praktická použitelnost

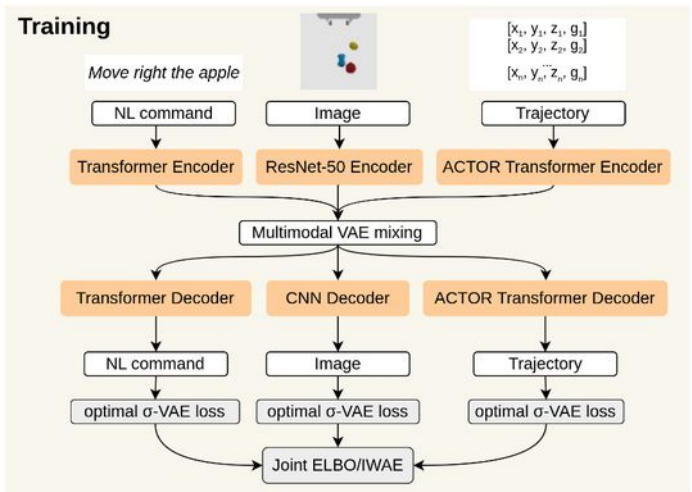
- Popis druhů dovedností potřebných ke čtení
- Projekční a návrhářské činnosti, backpropagation – předpověď pnutí materiálu
- Inteligentní systémy – vyhledávání bomb, objekty pod vodou, rukopis rozpoznat
- Předpověď nástupu nemoci...






# Predstavy - VAEs

## Training



## Inference



Sejnova, Gabriela, Michal Vavrecka, and Karla Stepanova. "Bridging Language, Vision and Action: Multimodal VAEs in Robotic Manipulation Tasks." IROS (2024).





# Summary

Cognitive Representation	ML/AI Methods
Logika	Logic-based programming, symbolic AI, probabilistic logic, Markov Logic Networks
Pravidla	Decision trees, association rule mining, expert systems, rule learning methods
Koncepty a Kategorie	Nearest Neighbors, centroid-based clustering, Bayesian categorization models
Exemplars	kNN, case-based reasoning
Sémantické sítě	Knowledge graphs, graph-based representation, temporal knowledge graphs
Konekcionistické sítě	Neural networks, SOMs, spiking networks, deep learning
Embodied Cognition	Reinforcement learning, robotics, sensorimotor ML models, active inference
Představy	Generative models (VAEs, GANs), simulation-based models

