Modelagem Computacional do Raciocínio e Aprendizagem por Analogias

Renato Moraes Silva

Universidade Estadual de Campinas

Faculdade de Engenharia Elétrica e de Computação

Av. Albert Einstein, 400. 13083-852, Campinas, SP, Brasil

flarenatms@yahoo.com.br

***Resumo*—A eficiência da cognição humana é potencializada pelo uso do raciocínio e aprendizagem por analogias, que ocorre em todas as fases da vida, ajudando, por exemplo, uma criança a aprender o significado de uma palavra ou um adulto a criar uma obra artística ou a criar um algoritmo que simule um aspecto da inteligência humana. Diante da importância do uso de analogias, esse trabalho apresenta alguns modelos computacionais desse recurso cognitivo humano e alguns aspectos necessários para sua modelagem.**

***Palavras chaves* – alvo, analogias, aprendizagem, cognição, fonte, raciocínio, representações.**

I. Introdução

A analogia é um recurso de grande importância para a cognição humana e é utilizada na linguagem, na arte, na música, na ciência e em outras áreas. Essa capacidade cognitiva pode ser definida como a habilidade de ver um determinado objeto ou situação em um contexto como sendo semelhante a outro objeto ou situação em outro contexto (GENTNER, 2001). É a capacidade de explicar ou aplicar conceitos novos em termos de conceitos familiares ou de se comportar em um ambiente ou situação desconhecida usando conhecimentos adquiridos em outros ambientes já explorados ou situações passadas (FRENCH, 2002). Dessa forma, torna-se claro a importância da analogia no processo de tomada de decisões, na obtenção de conhecimento e na modelagem da cognição. Por isso, esse recurso pode ser utilizado para melhorar a performance de criaturas artificiais e tem sido estudado em uma variedade de perspectivas. Então, o objetivo deste trabalho é apresentar como esse tema tem sido abordado na literatura e estudar alguns modelos computacionais de analogia.

Segundo French (2003) a analogia é uma habilidade cognitiva básica que está presente nos seres humanos desde os primeiros anos de vida. Ela pode ser observada na simples capacidade dos bebês de imitar os adultos e reconhecer quando estão sendo imitados pelos mesmos. Avança na capacidade das crianças de relacionar uma imagem ou palavra a um objeto real. Por fim, pode ser observada nos adultos quando os mesmos usam relações complexas entre as diversas situações para agir no ambiente ou para obter novos conhecimentos. Como afirma Gentner (2001) a analogia é usada quando, por exemplo, se percebe o formato ou desenho de um rosto humano em uma pedra, quando um advogado usa argumentos em um tribunal com base em argumentos que deram certos em outros casos, no entendimento de metáforas, na tradução de textos para outra língua, entre outros. Logo, observa-se que a analogia é usada em inúmeros fenômenos da cognição humana e por isso, torna-se importante o desenvolvimento de modelos computacionais desse recurso cognitivo.

Este trabalho é organizado como segue. Na seção II são apresentados alguns aspectos básicos que normalmente são adotados para a modelagem do raciocínio e aprendizagem por analogias. Na seção III são apresentados alguns modelos computacionais de analogia. Na seção IV é apresentada uma discussão ou análise dos assuntos abordados. Por fim, na seção V são apresentam-se as conclusões.

II. Abordagem computacional do raciocínio e aprendizagem por analogias

O raciocínio e aprendizagem analógicos envolve o mapeamento entre dois domínios que são chamados de fonte (*source*) e alvo (target). Segundo French (2003) esses domínios são utilizados em fases ou processos abstratos que são considerados estritamente necessários para a tomada de decisões por meio de analogias, que são:

- percepção do problema-alvo;
- o reconhecimento de uma fonte, a partir da descrição do alvo;
- mapeamento da fonte sobre o alvo para encontrar elementos correspondentes;
- transferência de informações a partir da fonte para o alvo;
- avaliação do conhecimento importado;
- consolidação ou aprendizagem do resultado e generalização da experiência nova para usá-la no futuro.

De acordo com Gentner (2001) os processos do raciocínio

analógico são relativamente independentes e podem ser exploradas de maneira fragmentada. Já, Leech (2008) defende que esses processos são inseparáveis, devido ao grau de interdependência entre seus componentes e por isso devem ser explorados em conjunto.

Além disso, segundo Nercessian (2009) para a construção de modelos de raciocínio analógico, devem ser consideradas as seguintes características:

- Papel do edifício: o processo de construção de uma analogia contribui significativamente para a mudança conceitual de um determinado conhecimento;
- Mapeamento adulador: na construção do modelo, existe um mapeamento da fonte para o alvo, cuja natureza dessa relação não possui uma forma determinada, mas que ao longo do tempo evolui e se torna estável;
- Visualização confractual: a estrutura visual do modelo analógico a ser construído não é baseada em uma estrutura existente, ou seja, não é baseada no alvo. Ela é baseada em uma estrutura imaginada ou em um cenário alternativo, que é implementado pelo processo de construção da analogia;
- Visualização como gerador: a visualização de um modelo serve mais como uma forma de geração de várias soluções possíveis, do que a geração de uma solução única;
- Manifesto analógico: Um modelo analógico pode ser explorado e manipulado e a entrada e saída podem ser compartilhados em tempo real e comparados com o alvo. Isso facilita o consenso sobre a geração e adoção de novas idéias.

III. Modelos Computacionais de analogia

Conforme foi apresentado na seção anterior, existem alguns aspectos comuns que são usados na modelagem do raciocínio e aprendizagem por analogias. Porém, são encontrados na literatura, diversos modelos que se diferenciam pela abordagem adotada, sendo que alguns são simbólicos, conexionistas ou híbridos. Outros se diferenciam pelo objetivo pelo qual foram criados ou por abranger apenas um ou vários processos da cognição por analogias. Diante disso, serão apresentados alguns modelos encontrados na literatura e serão discutidas suas principais características, necessárias para o entendimento de seu funcionamento.

A. Argus

O Argus (REITMAN, 1965) pode ser considerado o primeiro modelo computacional de analogia. Esse modelo possuia uma arquitetura que usava uma rede conceitual que relacionava as fontes para se chegar ao alvo desejado (FRENCH, 2002). O Argus resolvia analogias simples, tais como:

- eram apresentados para ele um primeiro conjunto de fontes: urso, porco, cadeira?;
- eram apresentados para ele um conjunto de alvos: pé, mesa, café, morango;
- ele tinha que descobrir uma relação, fazendo uma mapeamento entre os atributos dos dois conjuntos oferecidos.

Esse tipo de problema, pelos padrões atuais pode ser considerado trivial, porém o Argus foi muito importante já que deu início ao uso de poder das analogias na solução de problemas por meio de modelos computacionais.

B. IAM

O modelo IAM (Incremental Analogy Machine) (KEANE; BRAYSHAW, 1988) começa identificando um grupo de sementes na situação fonte e seleciona um elemento semente desse grupo, que servirá como representante. Tomando o exemplo apresentado em Keane, Ledgeway e Duff (1994), onde é feita uma analogia entre o sistema solar e os átomos, o domínio fonte dessa analogia é:

causa ((e (diferença_peso (sol, planeta), atrai (sol, planeta)), giram_em_torno(planeta, sol)) &
amarelo (sol) &
permitir (oxigênio-atmosfera (planeta), habitável (planeta))

Esse domínio pode ser dividido em três grupos:

1. *causa((e (diferença_peso (planeta, sol), atrai (sol, planeta)),giram_em_torno (planeta, sol))*
2. *permitir (oxigênio-atmosfera (planeta), habitável (planet a))*
3. *amarelo (sol)*

O maior grupo ou o que possui maior conectividade entre seus elementos é escolhido como representante do domínio fonte. Logo, no exemplo apresentado, o representante será o grupo 1.

Depois que foi escolhido um grupo é selecionada uma semente que representa esse grupo. Então no grupo 1, a semente escolhida é: *diferença_peso (planeta, sol)*. Essa semente foi escolhida porque é a relação mais forte do grupo 1. Ela poderia corresponder a *diferença_peso (elétron , núcleo)* se for considerado como domínio alvo, o domínio dos átomos. Essa etapa é chamada de jogo de sementes.

Depois que os jogos das sementes foram realizados e cada semente foi relacionada a uma semente do domínio alvo, são feitos jogos de todos os elementos de cada grupo do domínio fonte relativos aos elementos do domínio alvo. Nesses jogos vão ocorrer várias ambiguidades, por isso, os resultados dos jogos das sementes serão utilizados para removê-las por meio de filtragens de restrições. Logo, o resultado será um mapeamento isomórfico entre os elementos fonte e alvo (KEANE; LEDGEWAY; DUFF, 1994). Considerando a analogia entre o sistema solar e os átomos, será obtido o seguinte resultado:

- *diferença_peso(planeta, sol) = diferença_peso (elétron, núcleo)*
- *gira_em_torno (planeta, sol) = gira_em_torno (elétron, núcleo)*
- *atrai (sol, planeta) = atrai (núcleo, elétron)*

Então, o modelo analisa esses jogos e obtém o seguinte mapeamento: *planeta = elétron* e *sol = núcleo*. Depois disso é

realizado o processo de transferência de informações do domínio fonte para o domínio alvo, resultado em:

- *(diferença_peso, atrai) =t*
- *(diferença_peso, atrai) causa(e-diferença_peso-atrai,gira_em_torno) = t causa(e-diferença_peso-atrai, gira_em_torno)*

Onde t indica que este é um elemento transferido, o que significa que por analogia pode-se inferir que a diferença de pesos e a atração entre o elétron e o núcleo faz com que o elétron gire em torno do núcleo (KEANE; LEDGEWAY; DUFF, 1994).

C. ACME

O ACME (*Analogical Constraint Mapping Engine*) (HOLYOAK; THAGUARD, 1989) é um modelo que usa uma estrutura de rede neural massivamente paralela para encontrar um conjunto de correspondências globalmente consistentes entre a fonte e o alvo que estão sendo mapeados.

O modelo ACME cria uma rede que representa um conjunto de restrições a serem simultaneamente satisfeitas. Nessa rede cada neurônio corresponde a uma hipótese possível de emparelhamento para cada elemento da fonte em relação a cada elemento do alvo. Então, os neurônios competem entre si e os que possuem hipóteses contraditórias não conseguem se ativar, enquanto que os neurônios com hipóteses consistentes ativam simultaneamente. Depois que a rede é treinada e todos os mapeamentos foram avaliados, são escolhidos os neurônios que mais foram ativados e que representam uma potencial solução para o problema (HOLYOAK; THAGUARD, 1989).

De acordo com Holyoak e Thaguard (1989), um dos problemas do modelo ACME é que ele constrói um conjunto de hipóteses muito grande, que consequentemente torna a rede muito cara computacionalmente, o que pode sobrecarregar o sistema. Isso ocorre porque todos os elementos alvo são emparelhados com todos os elementos fonte, com a restrição de que os objetos são emparelhados com os objetos, predicados com predicados e sementes com sementes. Isso cria muitas hipóteses ambíguas e incorretas, que mais tarde serão descartadas, já que os neurônios correspondentes serão pouco ativados.

D. SME

O SME (*Structure Mapping Engine*) (FALKENHAINER; FORBUS; GENTNER, 1989) é um modelo computacional de analogia baseado na Teoria SMT (Teoria Dedre Gentner de Mapeamento Estrutural) (GENTNER, 1983).

O SMT é uma teoria que defende a importância da semelhança estrutural entre os domínios fonte e alvo na produção de analogias. Para a criação dessa teoria foram realizados inúmeros experimentos psicológicos que confirmam a importância dos mapeamentos relacionais no raciocínio analógico (FRENCH, 2002).

Como mencionado o SME é baseado na teoria SMT e por isso também usa duas entradas: a fonte e o alvo. Esses dois domínios são representações simbólicas de uma estrutura predicados/argumentos, já que esse modelo não usa qualquer conhecimento semântico. Ele faz apenas manipulações sintáticas para produzir um conjunto de correspondências, pois acredita-se que a sintaxe pode capturar o significado. Cada representação nesse modelo pode incluir atributos, relações entre entidades (objetos individuais e constantes) e relações entre relações. Então, as entidades são mapeadas em outras entidades, as funções são mapeadas em outras funções, alguns atributos são ignorados e as relações são realizadas transversalmente. Nesse processo, é dada prioridade às relações de ordem superior, transmitindo assim a sistematicidade, que é um dos princípios da teoria SMT (FRENCH, 2002).

O modelo SME possui alguns pontos fracos, sendo que o que mais se destaca é que ele se apóia muito fortemente sobre a forma de conhecimento representado. Por exemplo, o modelo se diferencia fortemente entre os atributos e as relações, ignorando os primeiros e transformando os segundos em pedra fundamental do mapeamento. Porém, a única diferença é que os atributos são predicados com um argumento enquanto que as relações tem dois ou mais argumentos. Logo, é fácil perceber que cada atributo pode ser facilmente transformado em uma relação equivalente e vice e versa. Por exemplo:

$$quente(x) \leftrightarrow temperatura(x, alta)$$

O modelo, portanto, depende de um módulo de representação falsamente atribuído para acomodar esta dificuldade. Porém, não existem orientações sobre como este módulo poderia ser construído e quais critérios que devem ser usados na hora de separar os fatos que devem ser representados como atributos ou como relações. Na prática, é o programador humano que representa as situações de tal forma que elas sejam tratadas pelo modelo (PETROV, 1998).

Apesar de algumas limitações, segundo Petrov (1998) o modelo SME tem grande importância e influenciou inúmeros trabalhos sobre a modelagem computacional da analogia. Além disso, ele é um dos poucos modelos de analogia que fizeram sucesso, e que foi usado, como base para a construção de sistemas maiores. Um desses sistemas é o modelo MAC/FAC de recuperação baseado em analogias (FORBUS, 1995).

E. MAC/FAC

O modelo MAC/FAC é um modelo de recuperação por analogias, que usa em sua estrutura o modelo SME e assume que os episódios são encapsulados por representações de eventos passados que têm uma codificação dupla em LTM (um detalhado cálculo de predicados e representação de todas as propriedades e relações dos objetos em um episódio) e um resumo curto (uma representação vetorial indicando a frequência relativa de predicados que são usados na representação) (FORBUS, 1995).

A partir disso, esse modelo explica a recuperação de informações por meio de dois estágios: o MAC e o FAC. No

primeiro estágio as representações vetoriais são usadas para realizar uma pesquisa superficial a fim de se encontrar os episódios que compartilham predicados com o problema alvo. Os vetores de episódio que são LTM próximos ao vetor alvo são, então, selecionados para o processamento pele segundo estágio, o FAC, que usa o cálculo dos predicados para encontrar representações detalhadas dos episódios e faz uma disputa entre os candidatos para selecionar o que melhor corresponde ao alvo. Logo, observa-se que estas duas etapas simulam o domínio da semelhança superficial em recuperação, e usam o fato de que a recuperação é influenciada pela semelhança estrutural (FORBUS, 1995).

F. LISA

LISA (*Learning and Inference with Schemas and Analogies*) (HUMMEL; HOLYOAK, 1997) é um modelo computacional de analogia que representa predicados e objetos distribuídos como padrões de ativação ligados de maneira dinâmica em estruturas proposicionais. Desta forma, esse modelo tem a flexibilidade de um sistema conexionista e a sensibilidade estrutural de um sistema simbólico.

Uma inovação do modelo LISA, em relação a outros modelos conexionistas, como o ACME , é que para analisar a ligação entre os elementos da fonte e do alvo ele considera não só o nível de ativação dos neurônios, como inclui um eixo de tempo nessa análise. Isso significa que esse modelo considera que os padrões de ativação podem oscilar ao longo do tempo. Então se essa oscilação ocorre em sincronia, os neurônios são considerados vinculados, senão, são considerados desvinculados (HUMMEL; HOLYOAK, 2007). Então, por exemplo: “João contratou Maria” requer oscilação dos elementos “João” e “empregador” alternando-se em sincronia com os elementos “Maria” e “funcionária” (KOKINOV; FRENCH, 2003).

Outra inovação apresentada pelo modelo LISA é que ele trata o mapeamento analógico como um problema de classificação de padrões e como uma forma de aprendizagem. Para isso, ele estabelece correspondências entre os elementos de forma gradual e vai aprendendo os pesos das conexões entre esses elementos, o que permite que ele encontre a solução sem a necessidade de realizar os processos de satisfação de restrição massivamente paralelos como era feito no modelo ACME, o que diminui o custo computacional e evita a sobrecarga no sistema.

G. DRAMA

O DRAMA (*Distributed Representation Analogy Mapper*) (ELIASMITH; THAGARD, 2001) é baseado no modelo ACME. Porém ele tem melhorias em relação ao número de fenômenos de mapeamento analógico contabilizados, possui menor grau de dominância da estrutura em relação ao mapeamento de considerações, sem sacrificar a plausividade neurológica e psicológica e ainda considera semântica e sintaxe em paralelo, permitindo que ambas influenciem todas as fases do processamento de mapeamento.

Esse modelo computacional de analogia usa redução holográfica de representações que é um esquema de representação distribuída, que tenta modelar os efeitos de estrutura e significado do desempenho humano no mapeamento analógico. Por ser um processo complexo, a redução holográfica de representações será explicada por meio da ilustração extraída de Eliasmith e Thagard (2001), de forma a facilitar o entendimento. Então:

- Dados A, B e C. Se
- C = A ⊗ B (leia-se: C é igual a A envolvido em B), então
- C # A ≈ B (leia-se: C correlacionado com A é aproximadamente igual a B)
- e C # B ≈ A.

Esse processo é ilustrado pela figura 1.

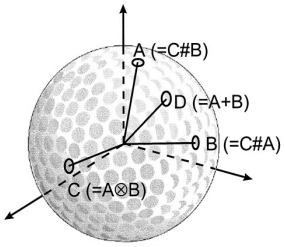

Figura 1: processo de redução holográfica de representações

Segundo Eliasmith e Thagard (2001) a redução holográfica de representações torna o modelo mais coerente com alguns aspectos do processo de criação de analogias em humanos, pois existe uma concordância entre conexionistas e neurocientistas de que os esquemas de representação no cérebro humano são distribuídos.

H. DORA

Dora (*Discovery of Relations by Analogy*) (DOUMAS; HUMMEL; SANDHOFER, 2008) é um modelo computacional do raciocínio e aprendizagem por analogias baseado no modelo LISA, apresentado anteriormente. Assim como o LISA, esse modelo também é simbólico-conexionista, que em virtude de suas representações distribuídas e sua solução para os problemas de ligação dinâmica representa o processo analógico de uma forma que é ao mesmo tempo semanticamente rico e significativamente simbólico.

Segundo Doumas, Hummel e Sandhofer (2008) o modelo DORA foi criado para simular a descoberta de novas propriedades e relações e entender os fenômenos empíricos envolvidos no domínio da aprendizagem relacional e no desenvolvimento de representações relacionais em crianças e adultos. Ou seja, os autores desse modelo, o criaram para realizar simulações e tentar entender como as crianças e adultos adquirem conceitos analógicos e os representa de forma útil ao raciocínio e aprendizagem.

O modelo DORA executa quatro operações básicas:

- recuperação de proposições da memória de longo prazo;
- mapeamento analógico de proposições que estão atualmente na memória de trabalho;
- descoberta de relações entre proposições para predicação

e refinamento das mesmas;

- transformar as ligações entre proposições em estruturas de maior aridade por meio de aprendizado supervisionado.

As operações básicas do modelo DORA são ilustrados pela Figura 2, onde pode-se observar pela parte "a" da figura que o modelo descobre uma representação com um conjunto vinculado de características que o descrevem. Já na parte "b" é mostrada a relação final de representações. Nela há uma camada de unidades semânticas, representada pelos pequenos círculos. Acima tem a camada de predicados-objetos. Na próxima RB (*role-binding*) o modelo descobre as primeiras relações entre os objetos-predicados. E na última camada as relações iniciais são transformadas em uma única relação mais pura e de maior aridade.

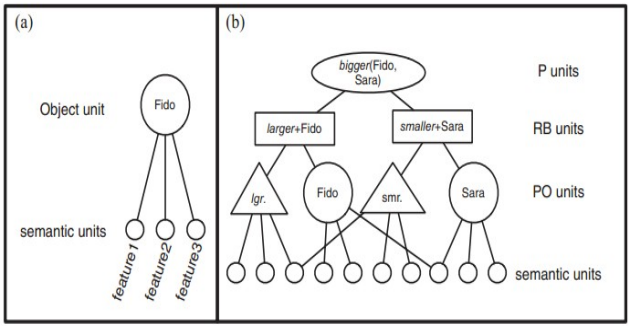

Figura 2: Estrutura de proposições no modelo DORA.

De acordo com Doumas, Hummel e Sandhofer (2008) as simulações realizadas com o modelo DORA mostraram que no raciocínio analógico em crianças e adultos, primeiro são compreendidas as relações individuais de cada objeto ou predicado e só depois são compreendidas as estruturas plenas formadas por cada relação. Doumas, Hummel e Sandhofer (2008) apresentam também outras inferências em relação ao processo de construção de analogias em adultos e crianças obtidas pela observação das simulações realizadas, mas essas inferências não serão apresentadas devido à limitação de espaço e porque não são importantes para o entendimento do modelo DORA.

I. Galatea

O Galatea (DAVIES; GOEL; NERCESSIAN, 2009) é um modelo computacional que representa como os humanos usam o raciocínio analógico para a resolução de problemas de design. Então, um das questões que este trabalho procura responder é: como alguém constrói um projeto de design novo usando uma analogia com projetos vistos ou criados anteriormente? Logo, o foco deste modelo são as analogias visuoespaciais, que são instâncias do raciocínio analógico unido com o conhecimento visual, ou o ato de visualizar e transformar imagens mentalmente.

O Galatea usa uma linguagem visual cognitiva chamada Covlan, para representar o conhecimento visuoespacial. As principais características dessa linguagem são o uso de elementos visuais primitivos, como retângulos e linhas, e transformações visuais simples, como replicar ou fundir objetos (DAVIES; GOEL; NERCESSIAN, 2009).

Conforme é apresentado em Davies, Goel e Nercessian (2009) as entradas do Galatea, ou seja as fontes, são informações de natureza visual. Depois que ele recebe as entradas, ele realiza múltiplos passos rumo a solução do problema por meio de uma série de estados de conhecimento e transformações desses estados. Os estados de conhecimento são conhecimentos visuais representados simbolicamente e podem ser chamados de imagens simbólicas ou s-imagens. Para exemplificar melhor, o modelo segue os seguintes passos:

- identifica a primeira s-imagens do alvo;
- identifica as transformações visuais e os argumentos da s-imagem atual na fonte;
- identifica os objetos usados na transformação visual da s-imagem atual para a próxima s-imagem;
- identifica os objetos correspondentes na s-imagem atual do alvo;
- aplica uma transformação visual na s-imagem do alvo análoga ao que foi aplicado na fonte, gerando uma nova s-imagem no alvo;
- mapeia os objetos originais para os novos objetos do problema alvo;
- mapeia os novos objetos do problema alvo para os objetos correspondentes do problema fonte;
- verifica e os objetivos foram satisfeitos. Em caso afirmativo, o problema está resolvido. Caso contrário deve-se iniciar todos os passos novamente, a partir da última s-imagem gerada pelo modelo.

Segundo Davies, Goel e Nercessian (2009), o Galatea mostra que o uso de representações visuoespaciais organizadas são suficientes para a transferência analógica de um problema fonte para um problema alvo. Logo, o raciocínio visuoespacial é útil para muitas subtarefas analógicas usadas para a resolução de problemas, como no caso de um designer que usa conhecimentos obtidos no desenvolvimento de outros projetos para a criação de projetos novos.

IV. DISCUSSÃO

Os modelos computacionais de raciocínio e aprendizagem por analogias apresentados neste trabalho representam uma pequena fração do número de modelos que foram criados até hoje. Eles foram escolhidos para serem estudados devido ao grau de importância e por um fator cronológico adotado pelo autor. Não foi possível apresentar mais modelos devido à limitação de espaço para a realização do trabalho.

Uma das observações que podem ser feitas é que nos últimos anos, o número de trabalhos publicados sobre modelos computacionais de analogia parecem ter diminuído. Por exemplo, o último modelo encontrado e apresentado neste trabalho, o Galatea, foi criado em 2009, o que pode ser considerado um grande tempo em relação ao avanço das pesquisas nas mais diversas áreas nos tempo atuais. Isso talvez ocorra devido a boa qualidade dos modelos desenvolvidos até

o momento, principalmente os que foram desenvolvidos a partir da década de 90. Mas, acredita-se que o principal fator seja a complexidade do processo de raciocínio e aprendizagem por analogias. Parece ser muito difícil criar novos modelos que tenham avanços em relação aos modelos já existentes.

Entre os modelos apresentados neste trabalho, o que mais se aproxima do processo de uso de analogias nos humanos é o modelo Galatea, que usa analogias visuoespaciais. O problema é que esse modelo usa uma característica importante do raciocício analógico humano, que é o uso de conhecimentos visuais, mas não aborda outros tipos de recursos adotados no processo de criação e uso de analogias. Uma pessoa que nasceu cega, por exemplo, não usará analogias visuoespaciais.

Por outro lado, os outros modelos apresentados neste trabalho não poderiam ser usados em problemas complexos comuns ao cotidiano humano, que são solucionados por analogias visuais ou de outra natureza. Por exemplo, os modelos conexionistas não conseguiriam armazenar a mesma carga de memória e conhecimento usados pelos humanos em seus processos analógicos. Em todos os modelos os autores fizeram simulações considerando um número pequeno de fontes usado para se obter um alvo de um problema. Já nos humanos, provavelmente o número de fontes utilizadas para se resolver um problema de complexidade média, seja computacionalmente inviável de se utilizar nesses modelos. O mesmo pode–se dizer dos modelos cognitivos, como o Argus e o IAM que só são viáveis para problemas de complexidade menor do que os suportados pelos modelos conexionistas.

Outro ponto a ser destacado é que procurou-se por trabalhos que implementassem algum modelo de raciocínio e aprendizagem por analogias em algum robô ou *animat*, mas nada foi encontrado. Esse fato é estranho porque como foi debatido no trabalho o uso de analogias é importante para a cognição humana e é usada em vários momentos, até por crianças. A complexidade do processo analógico pode ser o principal fator que impede até hoje o seu uso em criaturas artificiais. Isso pode ser mudado se modelos mais elaborados e que usem menos recursos computacionais forem criados.

V. Conclusão

Este trabalho apresentou os princípios básicos a serem abordadas na modelagem computacional do raciocínio e aprendizagem por analogias e apresentou também alguns modelos criados até os dias atuais.

Os modelos apresentados mostram que é possível usar o processo analógico da cognição humana em sistemas computacionais e consequentemente esse processo pode ser usado para melhorar as habilidades cognitivas de criaturas artificiais.

Porém, observou-se que muitos progressos devem ocorrer para que sejam criados modelos mais eficientes e que simulem melhor o processo de uso de analogias no raciocínio e aprendizagem dos humanos.

Referencias

DAVIES, J.; GOEL, A. K.; NERCESSIAN, N. J. "A Computational Model of Visual Analogies in Design", Cognitive Systems Research: Special Issue on Analogies, 10, 204-215, 2009.

DOUMAS, L. A. A.; HUMMEL, J. E.; SANDHOFER, C. M. "A Theory of the Discovery and Predication of Relational Concepts", Psychological Review, 115, 1-43, 2008.

ELIASMITH, C.; THAGARD, P. "Integrating Structure and Meaning: a Distributed Model of Analogical Mapping", Cognitive Science, 25, 245-286, 2001.

FALKENHAINER, B.; FORBUS, K. D.; GENTNER, D. "The Structure-mapping Engine Artificial Intelligence", Artificial Intelligence, 41, 1-63. 1989.

FORBUS, K. D.; GENTNER, D.; LAW, K. "MAC/FAC: A Model of Similarity-Based Retrieval", Cognitive Science, 19, 141-205, 1995.

FRENCH, R. M. "The Computational Modeling of Analogy-making" Trends in Cognitive Sciences, 6(5), 200-205, 2002.

GENTNER, D. "Structure-mapping: A Theoretical Framework for Analogy", Cognitive Science", 7(2), 155-170, 1983.

GENTNER, D. ; HOLYOAK, K. J.; KOKINOV, B. N. "The Analogical Mind: Perspective from Cognitive Science". Cambridge, MA: MIT Press, 2001.

HOLYOAK, K. J.; THAGARD, P. "Analogical Mapping by Constraint Satisfaction", Cognitive Science, 13, 295-355, 1989.

HUMMEL, J.; HOLYOAK, K. (1997). "Distributed representations of structure: A theory of analogical access and mapping", Psychological Review,104, 427-466 , 1997.

KEANE, M. T.; BRAYSHAW, M. "The Incremental Analogical Machine: A computational model of analogy", in D. Sleeman (Ed). European Working Session on Learning, London: Pitman, 1988, pp. 53–62.

KEANE, M. LEDGEWAY, T; DUFF, S. "Constraints on Analogical Mapping: A Comparison of Three Models", Cognitive Science, 18(3), 387-438, 1994.

KOKINOV, B.; FRENCH, R. M "Computational Models of Analogy-making", in . In Nadel, L. (Ed.) Encyclopedia of Cognitive Science. Vol. 1, London: Nature Publishing Group, 2003, pp.113 - 118.

LEECH, R.; MARESHAL, D. Cooper, R. P. "Analogy as Relational Priming: a Developmental and Computational Perspective on the Origins of a Complex Cognitive skill", Behavioral and Brain Sciences 31, 357-414, 2008.

NERCESSIAN, N. J. CHANDRASEKHARAN, S. "Hybrid Analogies in Conceptual Innovation in Science", Cognitive Systems Research Journal, Special Issue: Integrating Cognitive Abilities. 10: pp. 178-188, 2009.

PETROV, A. A. "Dynamic Emergent Computational Model Of Analogy-Making Based on Decentralized Representations", 1998. 130f. Tese (Doutorado em Ciências Cognitivas) - Tese, New Bulgarian University, Sofia – Bulgária, 1998.

REITMAN, R. "Cognition and Thought: an Information Processing Approach", New York: John Wiley & Sons, Inc., 1965, 312 p., 1965.