

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO

ANDRÉ LUCIANO RAKOWSKI

**Aprendizagem Temporal Neuro-simbólica
em Redes de Tensores Lógicos**

Dissertação apresentada como requisito parcial
para a obtenção do grau de Mestre em Ciência da
Computação

Orientador: Prof. Dr. Luís Lamb

Porto Alegre
2024

CIP — CATALOGAÇÃO NA PUBLICAÇÃO

Rakowski, André Luciano

Aprendizagem Temporal Neuro-simbólica em Redes de Tensores Lógicos / André Luciano Rakowski. – Porto Alegre: PPGC da UFRGS, 2024.

82 f.: il.

Dissertação (mestrado) – Universidade Federal do Rio Grande do Sul. Programa de Pós-Graduação em Computação, Porto Alegre, BR-RS, 2024. Orientador: Luís Lamb.

1. IA neuro-simbólica. 2. Aprendizagem e Raciocínio Temporal. 3. Redes de Tensores Lógicos. 4. Lógica Temporal. I. Lamb, Luís. II. Título.

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Reitor: Prof. Carlos André Bulhões Mendes

Vice-Reitora: Prof^a. Patricia Pranke

Pró-Reitor de Pós-Graduação: Prof. Júlio Otávio Jardim Barcellos

Diretora do Instituto de Informática: Prof^a. Carla Maria Dal Sasso Freitas

Coordenador do PPGC: Prof. Alberto Egon Schaeffer Filho

Bibliotecário-chefe do Instituto de Informática: Alexsander Borges Ribeiro

AGRADECIMENTOS

À minha querida esposa Valéria, que tem sido minha rocha e porto seguro durante esta árdua jornada. Seu amor, paciência e apoio incondicional foram a base que me permitiu perseverar, mesmo nos momentos mais desafiadores. Você tem sido minha inspiração e motivação constante e, por isso, sou eternamente grato.

Aos meus queridos pais, Armindo e Marilei, agradeço por toda uma vida de sacrifícios, amor e incentivo. Vocês plantaram em mim a semente da curiosidade e do amor pelo aprendizado e alimentaram meu crescimento com sabedoria e valores inestimáveis. Vocês são a razão de eu estar aqui hoje e dedico este trabalho a vocês com todo meu amor e gratidão.

A Deus, meu guia e protetor, agradeço por me conceder saúde, força e sabedoria para completar esta jornada. A cada passo senti sua presença, me guiando e iluminando meu caminho. Sou grato por todas as bênçãos e graças que me foram dadas, permitindo-me alcançar este marco em minha vida.

Ao meu orientador, prof. Dr. Luís Lamb, expresso minha mais profunda gratidão por sua incansável orientação, paciência e conhecimento. Sua orientação foi fundamental para o desenvolvimento e conclusão deste trabalho. Obrigado por acreditar em mim, me desafiar e me apoiar, permitindo-me crescer como pesquisador e como pessoa.

RESUMO

A Inteligência Artificial (IA) e o Aprendizado Profundo trouxeram grandes mudanças para várias áreas da sociedade, da pesquisa à aplicação na indústria e se tornaram onipresentes. No entanto, ainda há questões em aberto e preocupações sobre a confiança na IA. Idealmente, um sistema de IA deve ser semanticamente sólido, explicável e confiável. Para atingir tais objetivos, sistemas que integram aprendizado e raciocínio incluem uma camada de raciocínio sólido combinada com estruturas de aprendizado profundo. A IA neuro-simbólica visa integrar a eficácia do aprendizado neural com a solidez do raciocínio lógico para obter ferramentas e modelos mais ricos. Um dos desafios é a integração do aprendizado e do raciocínio sobre o tempo nas redes neurais. Este trabalho integra o aprendizado e raciocínio temporal em sistemas neuro-simbólicos baseados em lógica de primeira ordem. Para fazer isso, mostra-se como adicionar aprendizado e raciocínio temporal nas Redes de Tensores Lógicos (LTN), um framework que combina aprendizagem e raciocínio simbólico e neural com a utilização de tensores. A adição de um novo predicado para especificar propriedades temporais em sistemas de aprendizado permite uma representação e raciocínio mais ricos sobre um grande número de problemas, que exigem explicitamente uma dimensão temporal. Este trabalho também mostra como a LTN passa a aprender e raciocinar sobre uma classe geral de problemas usando raciocínio temporal e conhecimento distribuído e resolver problemas complexos e evolutivos de aprendizado distribuído. Portanto, dentre os principais resultados e contribuições, destaca-se o aprendizado e o raciocínio temporal sobre problemas complexos de computação envolvendo modelagem de tempo, incluindo tempo distribuído. A modelagem de redes neurais neuro-simbólicas com o uso de axiomas temporais e regras claras também proporciona maior interpretabilidade, permitindo uma melhor compreensão da implementação do sistema neuro-simbólico proposto e, principalmente, maior escalabilidade e generalidade.

Palavras-chave: IA neuro-simbólica. Aprendizagem e Raciocínio Temporal. Redes de Tensores Lógicos. Lógica Temporal.

Neuro-symbolic Temporal Learning in Logic Tensor Networks

ABSTRACT

Artificial Intelligence (AI) and Deep Learning have changed many areas of society, from research to industrial applications, and have become ubiquitous. However, there are still open questions and concerns about trust in AI. Ideally, an AI system should be semantically sound, explainable, and trustworthy. To achieve these goals, systems that integrate learning and reasoning include a sound reasoning layer combined with deep learning frameworks. Neuro-symbolic AI aims to integrate the power of neural learning with the soundness of logical reasoning to obtain richer tools and models. One of the challenges is the integration of learning and reasoning about time in neural networks. This work integrates temporal learning and reasoning in neuro-symbolic systems based on first-order logic. To do this, we show how to add temporal learning and reasoning to Logical Tensor Networks (LTN), a framework that combines symbolic and neural learning and reasoning using tensors. The addition of a new predicate to specify temporal properties in learning systems allows for a richer representation and reasoning about a large number of problems, which explicitly require a temporal dimension. This work also shows how LTN can learn and reason about a general class of problems using temporal reasoning and distributed knowledge and solve complex and evolutionary distributed learning problems. Therefore, among the main results and contributions, we highlight the temporal learning and reasoning about complex computing problems involving time modeling, including distributed time. The modeling of neuro-symbolic neural networks using temporal axioms and clear rules also provides greater interpretability, allowing a better understanding of the implementation of the proposed neuro-symbolic system and, mainly, greater scalability and generality.

Keywords: Neuro-Symbolic AI. Temporal Learning and Reasoning. Logical Tensor Networks. Temporal Logic.

LISTA DE FIGURAS

Figura 2.1 Deep Learnig é uma subárea da Inteligência Artificial.	16
Figura 2.2 Rede Neural	22
Figura 2.3 IA Simbólica x Conexionista.....	26
Figura 3.1 Sistemas de aprendizagem neural-simbólica.....	31
Figura 3.2 Ciclo de aprendizagem neural-simbólica	33
Figura 3.3 Tipos de Sistemas neuro-simbólicos: Simbólico Neuro simbólico.	34
Figura 3.4 Tipos de Sistemas neuro-simbólicos: Simbólico[Neuro].	35
Figura 3.5 Tipos de Sistemas neuro-simbólicos: Neuro Simbólico.	35
Figura 3.6 Tipos de Sistemas neuro-simbólicos: Neuro: Simbólico → Neuro.	36
Figura 3.7 Tipos de Sistemas neuro-simbólicos: Neuro_{Simbólico}.	36
Figura 3.8 Tipos de Sistemas neuro-simbólicos: Neuro[Simbólico].	36
Figura 3.9 Lógica Temporal Linear e Lógica de Árvore Computacional.	42
Figura 3.10 Lógica Temporal de Allen.	43
Figura 3.11 Lógica Booleana x Lógica Fuzzy	44
Figura 4.1 Exemplo de modelagem de problemas em LTN.....	56
Figura 4.2 Exemplo de modelagem de problemas em LTN - Precisão e satisfatibi- lidade médias.	56
Figura 5.1 Problema do Jantar dos Filósofos na T-LTN.	72
Figura 5.2 Variação do erro no treinamento do predicado 'hasDeadlock'.....	73
Figura 5.3 Tempo médio que os filósofos comem para diferentes quantidades de filósofos: T-LTN x Semáforo	73
Figura 5.4 Tempo médio que os filósofos comem para diferentes quantidades de filósofos no Problema do Jantar dos Filósofos em Evolução	74
Figura 5.5 Perda no treinamento do predicado 'IhaveMud'.	74

LISTA DE TABELAS

Tabela 3.1 Principais operadores da Lógica Modal.	40
Tabela 4.1 Principais Métodos neuro-simbólicos	48

LISTA DE ABREVIATURAS E SIGLAS

AI	Inteligência Artificial
LTN	Redes de Tensores Lógicos
T-LTN	Redes de Tensores Lógicos Temporais

SUMÁRIO

1 INTRODUÇÃO	10
2 INTELIGÊNCIA ARTIFICIAL: UMA VISÃO GERAL	13
2.1 Aprendizado de Máquina	16
2.2 IA Conexionista e Aprendizado Profundo	20
2.3 IA Simbólica	24
2.4 Ética e Explicabilidade	27
3 IA NEURO-SIMBÓLICA: UMA CONVERGÊNCIA ENTRE SIMBOLISMO E CONEXISMO	30
3.1 Principais conceitos da IA neuro-simbólica	31
3.2 Lógica	37
3.2.1 Lógica Clássica	37
3.2.2 Lógica Modal	39
3.2.2.1 Lógica Temporal	40
3.2.3 Lógica Fuzzy	43
3.3 Lógica em IA Neuro-simbólica	45
4 TRABALHOS RELACIONADOS	47
4.1 Redes de Tensores Lógicos	52
5 REDES TENSORIAIS LÓGICAS TEMPORAIS (T-LTN): MÉTODOS, RE- SULTADOS E ANÁLISES	58
5.1 O Problema do Jantar dos Filósofos	60
5.2 O Problema do Jantar dos Filósofos em Evolução	63
5.3 O Problema das Crianças Enlameadas	64
5.4 Análises Experimentais	65
6 CONCLUSÕES E TRABALHOS FUTUROS	75
REFERÊNCIAS	79

1 INTRODUÇÃO

A Inteligência Artificial (IA) e o Aprendizado Profundo trouxeram grandes mudanças para várias áreas da sociedade, desde a pesquisa à aplicação na indústria. Esta mudança destaca o grande impacto que a aprendizagem profunda criou, tornando-a um tema-chave de estudo intenso e discussão frequente nos meios de comunicação (GARCEZ; LAMB, 2023). A influência do aprendizado profundo é especialmente evidente na forma como introduziu novas abordagens em muitos campos da computação e outros. Destaca-se por descobrir padrões complexos e contribuir no progresso de várias áreas.

No entanto, apesar do seu sucesso notável, a aprendizagem profunda tem enfrentado críticas e sido examinada profundamente, especialmente pelas suas falhas significativas (BADREDDINE et al., 2020). Alguns dos principais problemas observados incluem a sua vulnerabilidade a ataques e uma clara falta de transparência/explicabilidade. Isso se evidencia pela carência de um conjunto de regras formais de fácil compreensão que muitas vezes são essenciais em usos práticos. Além disso, espera-se que os sistemas inteligentes melhorem a sua aprendizagem ao longo do tempo. Infelizmente, a aprendizagem profunda também carece de métodos formais que incluam o aspecto cronológico, o que pode dificultar uma compreensão e representação completa principalmente dos sistemas em mudança. Por exemplo, em um ambiente no qual múltiplos processos competem por recursos ao longo do tempo, a incapacidade de capturar e analisar a sequência temporal das requisições e liberações de recursos pode levar os modelos de aprendizagem profunda a não reconhecerem a formação de deadlocks. Isso resulta em falhas na previsão e prevenção dessas situações, comprometendo a eficiência e a estabilidade do sistema.

O desenvolvimento da lógica baseada no tempo, desde suas raízes filosóficas até seu importante papel na ciência da computação e na IA é um grande avanço e uma fusão de campos (GARCEZ; LAMB; GABBAY, 2009). Este crescimento mostra a busca contínua por sistemas lógicos sólidos que possam lidar com a complexidade do tempo, uma busca que tornou a lógica baseada no tempo essencial na ciência da computação e na IA. Também, a área voltada à combinação neural-simbólica cresceu, mostrando uma fusão bem-sucedida da habilidade de aprendizagem das redes neurais com o raciocínio detalhado dos sistemas simbólicos (GARCEZ; BRODA; GABBAY, 2002).

O presente trabalho inicia um esforço para melhorar as Redes Tensoriais Lógicas (LTN) - *Logic Tensor Networks* (BADREDDINE et al., 2020) com habilidades de aprendizagem e raciocínio temporal. Este esforço baseia-se no papel crucial que a dimensão

temporal desempenha na compreensão e modelagem de sistemas em mudança. O novo método, denominado Redes Tensionais Lógicas Temporais (T-LTN), visa combinar a lógica baseada no tempo com a força expressiva da estrutura LTN, contribuindo para uma base sólida de aprendizagem e raciocínio cronológico.

Este trabalho visa estender a LTN, originando a T-LTN (Redes de Tensores Lógicos Temporais), para resolver um conjunto geral de problemas que mostram a necessidade de raciocínio e aprendizagem com conhecimento temporal. Através deste esforço, espera-se contribuir para a discussão sobre a melhoria do raciocínio baseado no tempo na IA, conduzindo potencialmente a soluções mais fortes para problemas complexos e dinâmicos.

Através da solução de problemas clássicos da computação na T-LTN, como o Problema do Jantar dos Filósofos e problemas dinâmicos como o Problema do Jantar dos Filósofos em Evolução e o Problema das Crianças Enlameadas, o estudo destaca o potencial significativo dessa abordagem na modelagem temporal e evolutiva. O Problema do Jantar dos Filósofos ilustra a capacidade da metodologia em lidar com impasses e sincronização em sistemas distribuídos ao longo do tempo. O Problema do Jantar dos Filósofos em Evolução introduz elementos dinâmicos, mostrando a adaptabilidade da metodologia a mudanças enquanto mantém controle sobre as operações neuro-simbólicas. Além disso, a aplicação da metodologia ao Problema das Crianças Enlameadas revela sua eficácia na compreensão da disseminação de informação e do raciocínio coletivo em ambientes multiagentes, utilizando lógica temporal para modelar estados de conhecimento em evolução dos agentes de maneira coerente.

Esta dissertação está organizada em seis capítulos. O capítulo 1 fornece uma breve visão geral da importância do raciocínio temporal na Inteligência Artificial (IA) e destaca o desafio de integrar o raciocínio temporal em estruturas de IA neuro-simbólicas. Ele delinea a declaração do problema e os objetivos da pesquisa, além de discutir o escopo e a importância deste estudo.

O capítulo 2 se desenvolve com uma exploração do Aprendizado de Máquina, definindo conceitos-chave e algoritmos principais juntamente com suas aplicações. Prossegue discutindo a IA Conexionista e a Aprendizagem Profunda, introduzindo redes neurais e destacando conquistas e limitações. O capítulo então faz a transição para a IA Simbólica, explicando a abordagem simbólica e sua importância na IA. A discussão sobre Ética e Explicabilidade visa contribuir para elucidar a necessidade de explicabilidade na IA, juntamente com a revisão das abordagens atuais.

O capítulo 3, IA neuro-simbólica: Uma Convergência de Simbolismo e Conexi-onismo, começa com a definição de IA neuro-simbólica e discute os benefícios de combinar abordagens simbólicas e conexionistas. Ele descreve as lógicas utilizadas na IA neuro-simbólica, incluindo Lógica Clássica, Lógica de Primeira Ordem e Lógica Modal com uma subseção sobre Lógica Temporal. A discussão se estende à Lógica Fuzzy, seus fundamentos e aplicação em IA neuro-simbólica. O capítulo termina com um exame dos desafios de integração e das metodologias existentes associadas à lógica na IA neuro-simbólica.

Uma visão geral da literatura existente sobre raciocínio temporal em IA neuro-simbólica é fornecida no capítulo 4. É fornecido um foco em Redes de Tensores Lógicos, apresentando-as e discutindo seu significado.

O capítulo 5 é dedicado à introdução das Redes Tensoriais Lógicas Temporais (T-LTN). Ele discute a aplicação da T-LTN na resolução do Problema do Jantar dos Filósofos, do Problema do Jantar dos Filósofos em Evolução e do Problema das Crianças Enlameadas. Uma seção sobre análises experimentais descreve a metodologia, apresenta os resultados e os discute.

O capítulo 6 resume as principais conclusões e discute as implicações da pesquisa. Também são fornecidas possibilidades futuras de pesquisa em raciocínio temporal em IA neuro-simbólica.

2 INTELIGÊNCIA ARTIFICIAL: UMA VISÃO GERAL

A Inteligência Artificial (IA) se destaca como um dos principais campos da tecnologia, combinando o poder do computador com a simulação da inteligência humana e da tomada de decisões.

Em sua essência, a IA visa desenvolver métodos que permitam que as máquinas realizem tarefas que normalmente exigem habilidades mentais humanas, como aprender, resolver problemas, fazer planos e compreender a linguagem. O crescimento da IA propiciou o nascimento de muitas áreas especializadas, desde a aprendizagem automática, onde os sistemas melhoram ao aprenderem com o que fazem, até à robótica, que consiste em criar máquinas que possam agir por si próprias. (XU et al., 2021, tradução nossa) introduz a questão de Alan Turing sobre se as máquinas podem pensar e sua proposta do teste de Turing como meio de avaliar a inteligência das máquinas. O artigo também reconhece também o desafio de definir o pensamento devido à sua natureza subjetiva. No entanto, o artigo apresenta o teste de Turing como um critério simples e definitivo para rotular uma máquina como inteligência artificial (IA), sem discutir criticamente as suas limitações e os debates em curso em torno dela,

“As máquinas podem pensar?” Alan Turing colocou esta questão em seu famoso artigo “*Computing Machinery and Intelligence*”. Ele acredita que para responder a essa questão, precisamos definir o que é pensar. Contudo, é difícil definir o que é pensar com clareza, porque pensar é um comportamento subjetivo. Turing então introduziu um método indireto para verificar se uma máquina pode pensar, o teste de Turing, que examina a capacidade de uma máquina de mostrar inteligência indistinguível da dos seres humanos. Uma máquina bem-sucedida no teste está qualificada para ser rotulada como inteligência artificial (IA).

A Inteligência Artificial (IA) representa um avanço fundamental no domínio da tecnologia, com o objetivo de replicar as habilidades cognitivas dos seres humanos nas máquinas. Essa busca tecnológica abrange uma ampla gama de capacidades, como percepção, raciocínio, aprendizagem e tomada de decisão, refletindo os processos de pensamento humano. A essência da IA reside na sua capacidade de emular estas tarefas mentais complexas, muitas vezes ultrapassando a velocidade e a eficiência humanas em domínios específicos. O desenvolvimento da IA é impulsionado pelo desejo de melhorar e, por vezes, substituir o esforço humano em diversas tarefas, refletindo uma mudança significativa na forma como as atividades mundanas e complexas são abordadas.

A evolução da IA foi profundamente influenciada pelas revoluções industriais, evidenciando uma tendência para a automação e a utilização de máquinas em diversos

setores. Segundo (SCHWAB, 2016) "hoje estamos no início de uma quarta revolução industrial. Ela teve início na virada do século e baseia-se na revolução digital. É caracterizada por uma internet mais ubíqua e móvel, por sensores menores e mais poderosos que se tornaram mais baratos e pela inteligência artificial e aprendizagem automática".

Esta transformação contínua apresenta oportunidades e desafios, à medida que os sistemas de IA assumem cada vez mais funções tradicionalmente desempenhadas por seres humanos. O potencial da IA para substituir o trabalho humano levanta questões cruciais sobre o futuro do emprego e a natureza do trabalho. No entanto, também abre possibilidades para uma maior eficiência e capacidade para enfrentar tarefas que estão além das capacidades humanas.

O campo da IA é caracterizado pelas suas vastas e multifacetadas áreas de investigação, atraindo a atenção de cientistas e tecnólogos de todo o mundo. Esta diversidade é evidente nas numerosas subdisciplinas da IA, incluindo, mas não se limitando a, algoritmos de pesquisa, representação de conhecimento, processamento de linguagem natural, sistemas especialistas e várias formas de aprendizagem automática, como a aprendizagem profunda. Cada uma destas áreas contribui de forma única para o desenvolvimento de sistemas inteligentes, oferecendo uma rica variedade de abordagens para emular as funções cognitivas humanas. O amplo espectro da investigação em IA não só sublinha a sua complexidade, mas também o seu potencial para revolucionar vários aspectos da vida e da indústria.

O progresso da IA tem sido marcado por momentos de intensa criatividade, misturados com períodos de reflexão e reavaliação. A história da IA passou pela criação de algoritmos importantes, a criação de redes fortes modeladas a partir do conhecimento do cérebro humano e a introdução de tecnologias revolucionárias, como o aprendizado profundo. Esses saltos fizeram com que a IA passasse de apenas teoria para o uso no mundo real, levando a aplicações em saúde, gestão de dinheiro, carros autônomos e muito mais. De acordo com (RUSSELL; NORVIG, 2010, tradução nossa)

O que a IA pode fazer hoje? Responder de forma concisa é difícil devido à variedade de atividades em tantos subcampos. [...] Veículos robóticos: Um carro robótico sem motorista chamado STANLEY percorreu o terreno acidentado do deserto de Mojave a 35 km/h, vencendo a corrida de 212 km em primeiro lugar no DARPA Grand Challenge de 2005. [...] Reconhecimento de fala: Um viajante que liga para a United Airlines para reservar um voo pode ter toda a conversa guiada por um sistema automatizado de reconhecimento de fala e gerenciamento de diálogo. [...] Planejamento e agendamento autônomos: A 160 milhões de milhas da Terra, o programa Remote Agent da NASA se tornou o primeiro programa autônomo a bordo a controlar o agendamento das

operações de uma espaçonave [...] Jogos: O DEEP BLUE da IBM se tornou o primeiro programa de computador a derrotar o campeão mundial em uma partida de xadrez [...] Combate ao spam: Algoritmos de aprendizado classificam diariamente mais de um bilhão de mensagens como spam [...] Planejamento logístico [...] Robótica [...] Tradução automática [...] Esses são apenas alguns exemplos de sistemas de inteligência artificial que existem hoje.

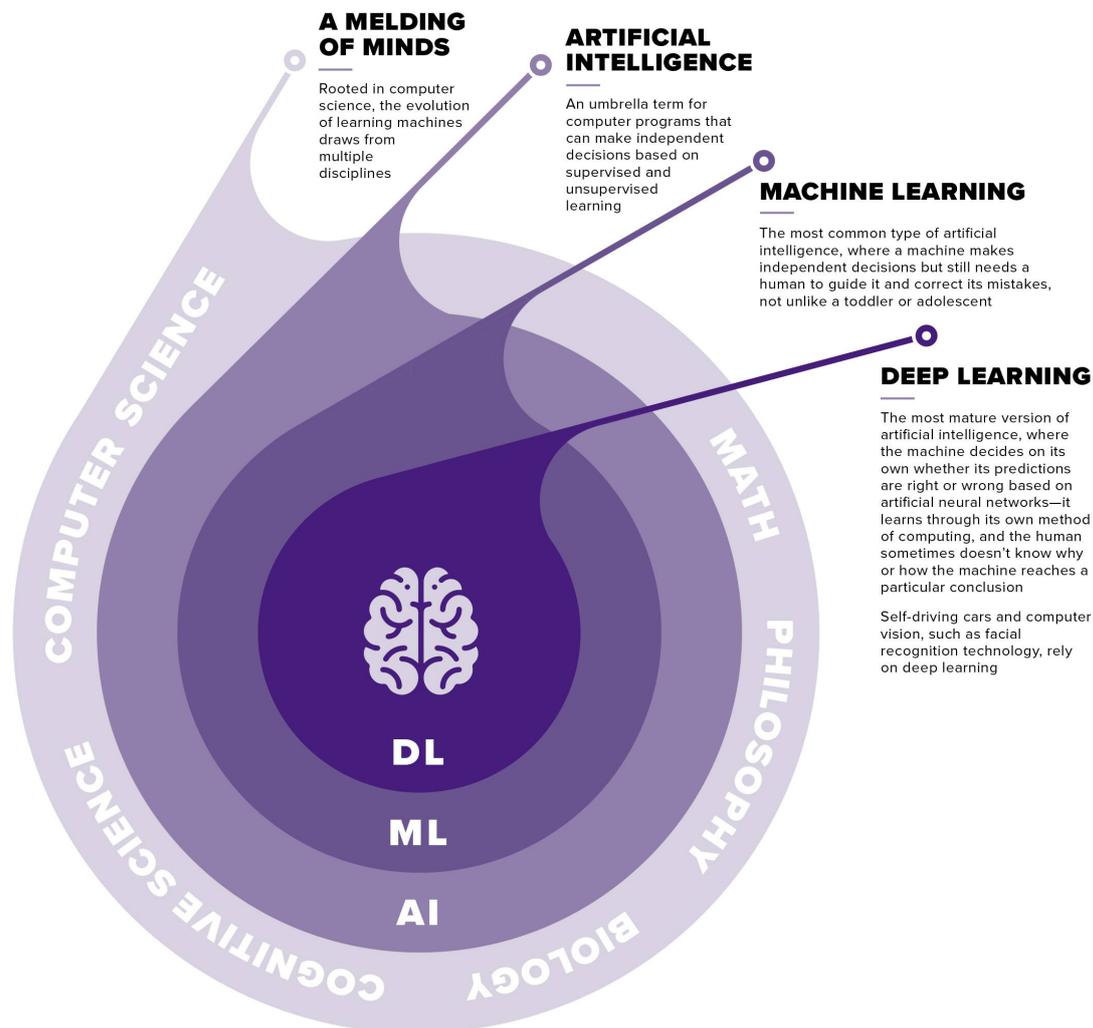
O estudo da IA é impulsionado pela busca de coisas novas, juntamente com uma análise cuidadosa dos efeitos morais, sociais e no mundo real da tecnologia de IA. É um ciclo ininterrupto de fazer suposições, testá-las e confirmá-las, com o objetivo de tornar os sistemas de IA mais confiáveis, eficientes e úteis. A Inteligência Artificial (IA) é uma área em constante mudança, enriquecida por diferentes técnicas e métodos que, juntos, ajudam a crescer e a ser utilizada em diversos campos. O aprendizado de máquina (ML), uma parte essencial dele, dá às máquinas a habilidade de aprender com as informações, aprimorando-se com o passar do tempo. Inclui uma variedade de métodos, como aprendizagem supervisionada e não supervisionada, cada um projetado para encontrar padrões e *insights* em dados.

O aprendizado profundo, um tipo específico de ML (Figura 2.1), usa camadas de redes neurais artificiais para modelar ideias complexas e diversos níveis de abstração e compreensão, e é fundamental em campos como reconhecimento de imagem e fala. Outra parte importante da IA é o Processamento de Linguagem Natural (PNL), que consiste em fazer com que as máquinas entendam e gerem a linguagem humana, levando a conversas mais naturais e eficazes entre pessoas e computadores.

Por sua vez, a robótica, fundida com a IA, visa criar máquinas independentes que podem interagir com o ambiente e realizar muitos trabalhos, se mostrando como uma mistura de detecção, planejamento e tomada de decisões. Os Sistemas Especialistas, outra parte fundamental, copiam as habilidades de tomada de decisão de especialistas humanos, oferecendo conselhos e respostas em áreas específicas, como diagnóstico médico e gestão de dinheiro.

Em suma, a Inteligência Artificial (IA) é um grande sucesso na área da computação, mostrando uma convergência de métodos e técnicas que juntos levam à automação inteligente e à tomada de decisões. Das habilidades do aprendizado de máquina às redes do aprendizado profundo, e das habilidades linguísticas do processamento de linguagem natural às tarefas autoexecutadas da robótica, a IA inclui uma ampla gama de estratégias e maneiras de fazer as coisas, cada uma contribuindo para o progresso do campo da IA.

Figura 2.1: Deep Learnig é uma subárea da Inteligência Artificial.



Fonte: Adaptado de (WHAT..., 2023).

2.1 Aprendizado de Máquina

A aprendizagem de máquina ou aprendizagem automática, uma parte ativa da inteligência artificial, está a liderar o progresso tecnológico, impulsionando muitas áreas e negócios. Trata-se de ensinar as máquinas a aprender com as informações, a melhorar na prática e a prever ou escolher sem instruções diretas. O aprendizado de máquina usa fórmulas matemáticas e análise de dados para encontrar padrões, descobrir conexões e obter conhecimento dos dados, ajudando em escolhas inteligentes e ações automáticas. (SHIVAHARE et al., 2022, tradução nossa) levanta um ponto crítico sobre a limitação das máquinas e da inteligência artificial (IA) – a autoridade final de tomada de decisão ainda reside nos seres humanos, que estão inerentemente vinculados às suas restrições físicas e cognitivas. Isto sublinha o desafio contínuo de integrar a IA nos processos de tomada

de decisão, garantindo ao mesmo tempo resultados éticos, responsáveis e imparciais. A menção da aprendizagem automática como um subconjunto da IA e o reconhecimento de vários algoritmos com os seus pontos fortes e fracos refletem a complexidade e a diversidade da investigação em IA,

O principal objetivo da evolução humana sempre foi procurar formas de moldar a natureza para satisfazer as nossas necessidades. Um marco importante nesse sentido é a invenção de uma máquina - chamada computador, que pode completar uma tarefa que lhe é dada em uma fração do tempo que um ser humano médio leva. Embora isso pareça ótimo, a única desvantagem é que a decisão ainda deve ser tomada por um homem que está limitado pelas limitações do corpo humano. A corrida para colher todos os benefícios deu origem ao que se chama de Inteligência Artificial. O aprendizado de máquina faz parte da IA, que trata da transmissão de conhecimento ao computador por meio de vários exemplos relacionados. Ao longo dos anos, vários algoritmos de aprendizado de máquina foram desenvolvidos, cada um com seus próprios méritos e deméritos.

O núcleo do aprendizado de máquina é sua habilidade de adaptar-se e melhorar ao longo do tempo. Ao serem expostos a novos dados e situações, os programas de aprendizado de máquina aprimoram constantemente seus conhecimentos, o que os torna mais precisos na previsão e na tomada de decisões. Essa capacidade de ajuste torna o aprendizado de máquina muito útil em áreas como reconhecimento de imagens, compreensão de idiomas e sugestões personalizadas. Ele pode analisar e compreender grandes quantidades de informações, extraindo detalhes importantes e apoiando ações inteligentes.

O aprendizado de máquina inclui muitos métodos diferentes, cada um adequado para vários problemas. A aprendizagem supervisionada treina modelos em dados com respostas conhecidas, ajudando o modelo a prever resultados para novos dados que nunca viu antes. A aprendizagem não supervisionada trabalha com dados sem respostas específicas, encontrando grupos e padrões ocultos por conta própria.

Aprendizado supervisionado é uma parte fundamental da inteligência artificial (IA), ajudando a construir modelos que podem prever ou classificar resultados de determinados dados. É uma parte principal do aprendizado de máquina, semelhante à forma como um aluno aprende com a ajuda de um professor. Na aprendizagem supervisionada, essa ajuda é dada por dados rotulados, sendo que cada dado corresponde à resposta certa para orientar a aprendizagem.

De acordo com (GOODFELLOW; BENGIO; COURVILLE, 2016, tradução nossa), "algoritmos de aprendizagem supervisionada são, a grosso modo, algoritmos de aprendizagem que aprendem a associar alguma entrada a alguma saída, dado um conjunto de

treinamento de exemplos de entradas x e saídas y ".

Ao configurar a aprendizagem supervisionada, os algoritmos aprendem a partir de um conjunto de dados de treinamento repleto de exemplos rotulados que mostram as respostas corretas ou os grupos dos quais fazem parte. Isso permite que os algoritmos encontrem padrões e conexões nos dados que os ajudem a prever os rótulos corretos. Através de repetidos aprendizados e ajustes, o algoritmo se ajusta para melhorar suas previsões, visando chegar o mais próximo possível das respostas corretas.

A aprendizagem supervisionada é usada quando precisamos prever coisas, como prever preços de ações no setor financeiro, diagnosticar doenças ou sugerir produtos em lojas online. O aprendizado supervisionado também é ótimo para classificar tarefas, como descobrir se um *e-mail* é spam, reconhecer números escritos à mão e detectar uso de cartão de crédito falso.

O caminho da aprendizagem supervisionada também envolve testar e confirmar seu valor. Depois que os modelos são treinados, eles são testados com novos dados para verificar sua capacidade de aplicar o que aprenderam a diferentes situações e para garantir que realmente aprenderam, e não apenas memorizaram. Esta etapa é fundamental para garantir que o modelo esteja pronto e confiável o suficiente para ser usado no mundo real, com foco na precisão e capacidade de adaptação.

A aprendizagem supervisionada é forte, mas enfrenta desafios como o *overfitting*, no qual os modelos ficam demasiado ajustados aos dados de treino e não conseguem aplicar o que aprenderam a novas situações. Ele também lida com tarefas complexas de escolha de recursos, escolha de modelos e definição de hiperparâmetros, todas exigindo atenção cuidadosa para criar modelos que prevejam com eficiência.

Em sua essência, na aprendizagem supervisionada, os algoritmos são treinados com conhecimento de dados rotulados, ajudando-os a aprender, a se adaptar e a melhorar, tornando-os fortes preditores que podem funcionar bem com precisão e compreensão no amplo mundo da inteligência artificial.

A **aprendizagem não supervisionada** é uma ideia profunda na inteligência artificial (IA), onde algoritmos encontram padrões e estruturas ocultas em dados que não possuem rótulos. Diferente da aprendizagem supervisionada, a aprendizagem não supervisionada não possui orientação definida, lidando com as complexidades dos dados sem respostas ou grupos definidos. Inicia um processo de exploração, encontrando conexões, grupos e diferenças nos dados, levando a uma melhor compreensão e representação de suas características naturais.

Conforme (GOODFELLOW; BENGIO; COURVILLE, 2016, tradução nossa), "algoritmos de aprendizagem não supervisionados experimentam um conjunto de dados contendo muitas categorias e, em seguida, aprendem propriedades úteis da estrutura desse conjunto de dados".

Na aprendizagem não supervisionada, os algoritmos assumem o papel de detectar semelhanças, diferenças e padrões nos dados, o que ajuda a classificar ou agrupar dados por suas características naturais. Existem dois métodos principais de aprendizagem não supervisionada: agrupamento e associação. O agrupamento agrupa dados semelhantes, facilitando a visualização de categorias ou segmentos naturais. A associação, por outro lado, tenta encontrar regras que mostrem conexões entre diferentes itens ou características dos dados, revelando relações que podem não ser óbvias à primeira vista.

A aprendizagem não supervisionada é importante em muitos usos e áreas, acrescentando profundidade à forma como interpreta-se e analisa-se os dados. É crucial na segmentação de mercado, onde identifica grupos de clientes com hábitos ou gostos semelhantes, levando a um marketing focado e serviços personalizados, por exemplo. A aprendizagem não supervisionada também é fundamental para encontrar anomalias de dados, detectar padrões incomuns ou valores discrepantes, o que é muito importante em áreas como segurança *online* e detecção de fraudes.

O verdadeiro poder da aprendizagem não supervisionada está na sua capacidade de mostrar o que está oculto, de se aprofundar nos dados além dos rótulos e categorias óbvios. Ele revela detalhes sutis e complexidades dos dados, permitindo uma exploração mais completa e livre de seus recursos. Mas a aprendizagem não supervisionada também enfrenta obstáculos como a confirmação de resultados e a decisão do número certo de grupos, que muitas vezes necessitam de conhecimento da área e de opinião especializada.

Aprendizagem por reforço é uma abordagem na inteligência artificial (IA) baseada em um método de aprendizagem da psicologia comportamental onde os agentes melhoram ao interagir com seu ambiente. Envolve experimentar diferentes ações para ver o que acontece, onde um agente faz escolhas, recebe *feedback* como recompensas ou penalidades e gradualmente melhora na escolha de ações para obter o máximo de recompensas ao longo do tempo.

Na aprendizagem por reforço, um agente passa por uma série de estados e escolhas, ajustando e refinando constantemente seu plano para obter os melhores resultados. O ambiente dá *feedback* às ações do agente com recompensas ou penalidades, orientando o agente para um melhor desempenho. Esta interação ativa entre o agente e o ambiente

incentiva um processo de aprendizagem onde o agente aprende a conectar estados a ações de uma forma que resulte em maiores recompensas no futuro.

A aprendizagem por reforço enfrenta obstáculos como a escolha entre tentar novas ações e persistir nas recompensadoras, e problemas em estabelecer as recompensas certas e lidar com a complexidade de muitos estados e escolhas possíveis, necessitando de algoritmos avançados e formas de representar as coisas.

Em sua essência, a aprendizagem por reforço trata de aprender por meio de tentativas e erros, exploração e aprendizagem, onde os agentes mudam seus planos para ter sucesso em situações complexas e mutáveis. Mostra um futuro onde a aprendizagem e a tomada de decisões serão feitas por conta própria, levando a IA a novos níveis de habilidade, flexibilidade e inteligência. Através da aprendizagem por reforço, a IA continua a melhorar, a descobrir e a ter um bom desempenho em várias áreas, abrindo novas oportunidades e áreas na computação inteligente e na tomada de decisões.

O Deep Learning, uma parte da aprendizagem automática, tornou-se uma influência poderosa, utilizando redes com muitas camadas para identificar padrões e ideias complexas a partir de dados e levou a resultados excelentes em muitas áreas. Segundo (GOODFELLOW; BENGIO; COURVILLE, 2016, tradução nossa) "a aprendizagem profunda já se revelou útil em muitas disciplinas de software, incluindo visão computacional, processamento de fala e áudio, processamento de linguagem natural, robótica, bioinformática e química, videogames, motores de busca, publicidade online e finanças".

No entanto, a aprendizagem automática enfrenta obstáculos, especialmente quando se trata de ética, preconceito e justiça. Os modelos precisam de verificação e confirmação cuidadosas para garantir que decidam de forma justa, sem preconceitos e de forma ética. Também é importante que possa-se entender como funcionam/aprendem os modelos de aprendizado de máquina e explicar suas decisões para que as possa-se confiar neles.

2.2 IA Conexionista e Aprendizado Profundo

A IA conexionista é um método revolucionário em inteligência artificial (IA) que obtém ideias de como o cérebro humano funciona. Ele se concentra em criar redes de neurônios ou nós artificiais que processam, alteram e transmitem informações, levando a ações complexas e adaptativas e a habilidades de tomada de decisão.

A aprendizagem profunda, principal exemplo de IA conexionista, transformou a IA ao permitir que os modelos aprendam ideias através de camadas de neurônios a partir

de uma grande quantidade de dados. Modelos de aprendizagem profunda, especialmente aqueles com muitas camadas, podem aprender padrões detalhados, o que os torna bons em tarefas como reconhecimento de imagens e fala, compreensão de linguagem e outras áreas.

No centro da IA conexionista e do aprendizado profundo está a ideia de aprender com os dados. Os modelos analisam os dados e ajustam suas configurações internas para compreender os padrões e links básicos, tornando-os melhores na predição de resultados.

O efeito da IA conexionista e da aprendizagem profunda é enorme, afetando muitas áreas da indústria e áreas de estudo. Deu às máquinas as habilidades para ver, ouvir e compreender o mundo, transformando simples detalhes sensoriais em ideias e escolhas significativas. Desde carros autônomos que conseguem lidar com o mundo real, até aplicações de saúde que ajudam no diagnóstico e planejamento de tratamentos, o alcance da IA conexionista é amplo e revolucionário.

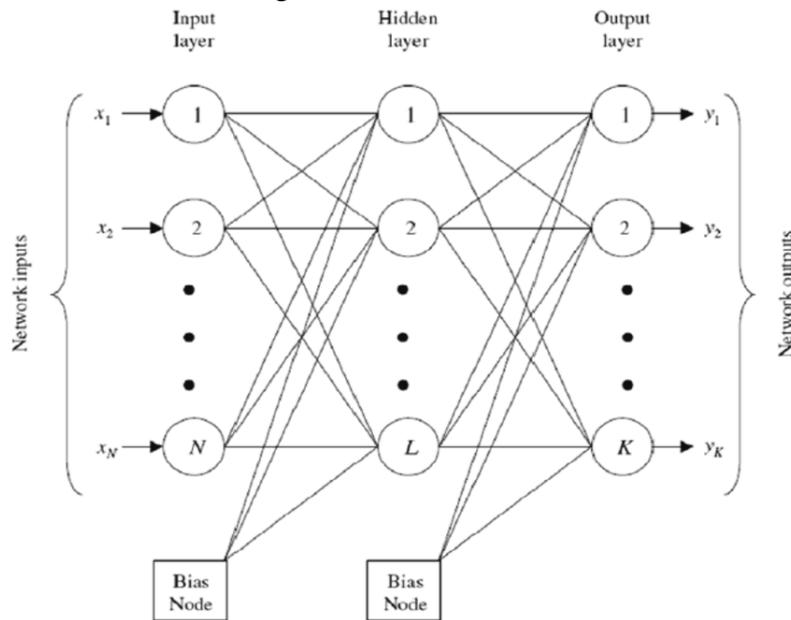
Mesmo com as suas grandes conquistas, a IA conexionista tem de lidar com questões como ser compreensível e ética. A natureza complexa das redes neurais profundas muitas vezes consiste em modelos que são difíceis de serem explicados e levantam questões sobre a sua abertura e responsabilidade. Além disso, garantir que os modelos possam lidar com ataques, preconceitos e incertezas é um ponto-chave na pesquisa e desenvolvimento contínuos.

A IA conexionista e a aprendizagem profunda são grandes avanços na IA, mostrando um tipo de inteligência que pode se adaptar e aprender com dados e ambientes complexos. Com seu grande impacto, esses métodos continuam ultrapassando os limites do que é possível, levando a IA a novos níveis de habilidade, criatividade e percepção.

Uma **rede neural** (Figura 2.2), no contexto da inteligência artificial, é um modelo baseado nas redes neurais biológicas do cérebro humano. Essas redes consistem em nós interligados ou “neurônios” que enviam e tratam informações, possibilitando muitas tarefas cognitivas. Na computação, as redes neurais oferecem uma estrutura que ajuda no aprendizado de máquina, permitindo que os computadores aprendam com os dados e façam escolhas inteligentes.

As redes neurais são compostas de camadas, cada uma com muitos neurônios. A primeira camada recebe dados, que são então processados nas camadas intermediárias com pesos que mudam durante o treinamento. A última camada fornece a previsão ou categoria. Cada neurônio de uma camada se liga a todos os neurônios da próxima, criando uma rede muito conectada. Esses links, ou pesos, são fundamentais, pois retêm o conhe-

Figura 2.2: Rede Neural



Uma rede neural é um modelo computacional inspirado na estrutura do cérebro humano, usado em aprendizado de máquina e inteligência artificial. Consiste em camadas de nós, ou “neurônios”, que simulam a forma como os neurônios humanos interagem. Cada nó recebe entradas, processa-as e passa a saída para outros nós.

Fonte: (LAHIRI, 2009).

cimento que a rede aprendeu e mudam durante o treinamento para melhorar as suposições da rede. As redes neurais são poderosas porque podem aprender e mostrar padrões e relacionamentos de dados complexos. São muito flexíveis e podem realizar muitas tarefas, desde reconhecer imagens e fala até compreender a linguagem e jogar.

Para treinar uma rede neural, os pesos são alterados com base no quanto as estimativas da rede estão distantes dos resultados reais. Isso geralmente é feito com retropropagação e gradiente descendente, que são métodos que reduzem o erro alterando os pesos para melhorar lentamente o desempenho da rede.

As redes neurais deram grandes passos e são agora uma parte fundamental da aprendizagem automática e da inteligência artificial. Sua capacidade de adaptar e aprender representações detalhadas os torna uma ferramenta forte em IA, impulsionando novas ideias e usos em diferentes campos.

Mas as redes neurais enfrentam desafios como o risco de se ajustarem muito aos dados de treinamento, serem difíceis de explicar e precisarem de muitos dados e poder computacional. Garantir que as redes neurais funcionem bem com novos dados, sejam compreensíveis e usadas de forma ética são áreas de pesquisa importantes.

As redes neurais são uma mistura incrível de ideias da biologia e da inovação computacional, permitindo que as máquinas aprendam, mudem e melhorem quando confron-

tadas com dados e ambientes complexos. Eles mostram a grande promessa da inteligência artificial para copiar e melhorar as habilidades de pensamento humano.

O **gradiente descendente** é um algoritmo de otimização essencial no treinamento de redes neurais, cujo objetivo é minimizar a função de custo ajustando os pesos das conexões da rede. A função de custo, ou função de perda, quantifica a diferença entre as previsões da rede e os valores reais dos dados de treinamento, proporcionando uma medida de erro que o algoritmo tenta reduzir. Segundo (BISHOP, 1995, tradução nossa),

Se uma função de ativação não linear, como uma sigmóide, for usada, ou se uma função de erro diferente for considerada, então uma solução de forma fechada não será mais possível. No entanto, se a função de ativação for diferenciável, como é o caso do sigmóide logístico, por exemplo, as derivadas da função de erro em relação aos parâmetros de peso podem ser facilmente avaliadas. Essas derivadas podem então ser usadas em uma variedade de algoritmos de otimização baseados em gradiente.

O processo começa com a inicialização dos pesos das conexões entre os neurônios da rede, que são atribuídos aleatoriamente ou com valores pequenos para garantir que a rede não esteja enviesada desde o início. Em seguida, realiza-se a propagação para frente (forward propagation), onde os dados de entrada passam pela rede camada por camada até que uma saída seja produzida. Essa saída é então comparada com os valores reais dos dados de treinamento, permitindo o cálculo da função de custo.

Após a propagação para frente, o algoritmo realiza a propagação para trás (backward propagation) para calcular o gradiente da função de custo em relação a cada peso da rede. Esse cálculo utiliza a regra da cadeia para derivadas parciais, começando pela camada de saída e retrocedendo até a camada de entrada. O gradiente indica a direção e a magnitude das mudanças necessárias nos pesos para reduzir a função de custo.

Finalmente, os pesos são atualizados subtraindo-se uma fração do gradiente, definida pela taxa de aprendizado. De acordo com (BISHOP, 1995, tradução nossa), "em uma implementação de software, as derivadas devem ser avaliadas usando retropropagação, pois isso proporciona maior precisão e eficiência numérica". Para (BUCKNER; GARSON, 2019, tradução nossa),

O algoritmo supervisionado mais amplamente utilizado é chamado de retropropagação. Para usar este método, é necessário um conjunto de treinamento composto por muitos exemplos de entradas e suas saídas desejadas para uma determinada tarefa. Este conjunto externo de exemplos "supervisiona" o processo de treinamento.

O algoritmo de retropropagação (*backpropagation*) permite calcular como pequenas mudanças nos pesos de cada neurônio afetam o erro global da rede, retrocedendo da camada de saída até as camadas ocultas. Essa retropropagação de erros é essencial para o aprendizado supervisionado, onde a rede compara suas saídas preditas com as saídas desejadas dos exemplos de treinamento. De acordo com (RUMELHART; HINTON; WILLIAMS, 1986, tradução nossa)

O procedimento ajusta repetidamente os pesos das conexões na rede de modo a minimizar uma medida da diferença entre o vetor de saída real da rede e o vetor de saída desejado. Como resultado dos ajustes de peso, unidades internas “ocultas” que não fazem parte da entrada ou da saída passam a representar características importantes do domínio da tarefa, e as regularidades na tarefa são capturadas pelas interações dessas unidades.

2.3 IA Simbólica

A Inteligência Artificial Simbólica, é um ramo da inteligência artificial que se concentra na manipulação e interpretação de símbolos para imitar o pensamento e a lógica humanos. Esta abordagem emprega vários métodos, tais como sistemas baseados em regras e redes semânticas, para representar conhecimento e permitir ações inteligentes em máquinas. De acordo com (ILKOU et al., 2020, tradução nossa),

As técnicas simbólicas são definidas por métodos simbólicos explícitos, como métodos formais e linguagens de programação, e geralmente são usados para conhecimento dedutivo. Eles consistem em regras lógicas de primeira ordem, enquanto outros métodos incluem regras, ontologias, árvores de decisão, planejamento e raciocínio. [...] a IA simbólica geralmente é associada a bases de conhecimento e sistemas especialistas, e é uma continuação de máquinas de von Neumann e Turing

No cerne da IA simbólica está o uso de símbolos e regras. Os símbolos representam objetos, conceitos e características em uma determinada área do problema, enquanto as regras definem os relacionamentos e operações que se aplicam a esses símbolos. Esta abordagem simbólica permite a representação estruturada do conhecimento, permitindo que as máquinas executem tarefas como resolução de problemas, raciocínio e compreensão da linguagem.

A IA simbólica dá forte ênfase à representação do conhecimento. O conhecimento nestes sistemas é explicitamente codificado, muitas vezes utilizando regras ou lógica, permitindo ao sistema fazer inferências e tomar decisões com base neste conhecimento.

Esta abordagem é particularmente eficaz em domínios com conhecimentos bem definidos, como medicina, direito e sistemas especialistas.

Os sistemas especialistas, uma aplicação notável da IA simbólica, visam imitar as capacidades de tomada de decisão de especialistas humanos em domínios específicos. Esses sistemas contam com uma base de conhecimento repleta de regras e fatos, juntamente com um mecanismo de inferência que aplica raciocínio lógico para gerar conclusões ou recomendações. Os sistemas especialistas são utilizados em vários campos, incluindo saúde, finanças e manufatura, onde fornecem orientação e soluções especializadas. Mas, de acordo com (MINSKY, 1991, tradução nossa).

Esse foco em problemas bem definidos produziu muitas aplicações bem-sucedidas, não importando que os sistemas subjacentes fossem muito inflexíveis para funcionar bem fora dos domínios para os quais foram projetados [...]. Assim, os sistemas contemporâneos de IA simbólica estão agora demasiado limitados para serem capazes de lidar com exceções às regras, ou de explorar fragmentos de conhecimento difusos, aproximados ou heurísticos.

Redes e *frames* semânticos são outras técnicas vitais na IA simbólica. As redes semânticas representam o conhecimento como um grafo, com nós representando conceitos e arestas denotando conexões entre eles. Já os *frames* são estruturas de dados hierárquicas utilizadas para representar cenários comuns, permitindo a herança de atributos e propriedades. Essas representações ajudam a organizar e recuperar conhecimento, permitindo que as máquinas compreendam e processem informações de maneira semelhante à humana.

Apesar das suas conquistas, a IA simbólica enfrenta desafios e críticas. Uma crítica principal é a sua dependência da representação explícita do conhecimento, que pode ser limitante quando se trata de informações ambíguas ou incompletas. Além disso, os sistemas simbólicos de IA são frequentemente baseados em regras e projetados manualmente, tornando-os menos adaptáveis a ambientes em mudança e a novos dados em comparação com outras abordagens de IA, como o aprendizado de máquina.

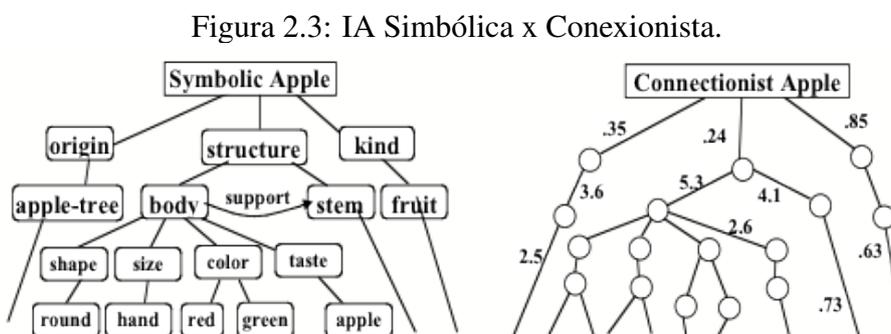
A IA simbólica serve como uma abordagem fundamental na inteligência artificial, concentrando-se no raciocínio simbólico e na representação do conhecimento. Técnicas como sistemas baseados em regras, redes semânticas e frames têm desempenhado um papel crucial no desenvolvimento de sistemas inteligentes capazes de raciocinar, resolver problemas e compreender a linguagem natural. Embora a IA simbólica tenha as suas limitações, particularmente no tratamento da ambiguidade e da adaptabilidade, continua a ser uma área significativa de estudo e aplicação em IA, contribuindo para o avanço das

máquinas inteligentes.

A Inteligência Artificial Simbólica (IA) e a IA Conexionista, também conhecidas como redes neurais ou aprendizagem profunda, representam duas abordagens diferentes dentro do campo mais amplo da IA, cada uma com os seus métodos e aplicações únicos. A IA simbólica baseia-se na manipulação de símbolos e regras para imitar o raciocínio e a cognição humanos. Ele se concentra na representação explícita do conhecimento, usando símbolos para entidades e regras do mundo real para definir relacionamentos e operações entre elas. Sistemas como os sistemas especialistas em IA Simbólica dependem de bases de conhecimento estruturadas e inferência lógica para resolver problemas e compreender a linguagem natural, tornando-os eficazes em domínios com conhecimento bem definido.

Por outro lado, a IA Conexionista inspira-se nas redes neurais do cérebro humano. Modelos como redes neurais artificiais (RNAs) consistem em nós interconectados ou “neurônios” que processam e transmitem informações. Esses modelos aprendem ajustando os pesos das conexões com base nos dados de entrada e nos erros de previsão, permitindo-lhes extrair automaticamente padrões e recursos dos dados brutos. A IA conexionista é excelente em tarefas como reconhecimento de imagem e fala e processamento de linguagem natural, onde a identificação de padrões implícitos em grandes conjuntos de dados é essencial.

Uma diferença fundamental entre os dois paradigmas é a sua abordagem à representação e aprendizagem do conhecimento. A IA simbólica depende da representação manual explícita do conhecimento, enquanto a IA conexionista usa a aprendizagem orientada por dados para adquirir automaticamente representações dos dados, conforme mostrado na Figura 2.3.



Fonte: (MINSKY, 1991).

Outra diferença está na forma como lidam com a ambiguidade e a generalização. Os sistemas de IA simbólica, sendo baseados em regras, podem ter dificuldades com informações ambíguas ou incompletas, uma vez que requerem regras e fatos precisos para

funcionarem eficazmente. Os modelos conexionistas, por outro lado, podem lidar com a ambiguidade e o ruído nos dados, até certo ponto, devido à sua capacidade de aprender com os dados. Isso lhes permite generalizar melhor para instâncias inéditas ou novas.

A interpretabilidade dos modelos também varia. A IA simbólica, com as suas regras e lógica explícitas, proporciona frequentemente modelos mais transparentes e interpretáveis, facilitando a compreensão e o acompanhamento do processo de tomada de decisão. Em contraste, os modelos conexionistas, com as suas redes complexas de pesos interligados, são frequentemente considerados “caixas negras”, dificultando a interpretação das suas decisões e processos de raciocínio.

Consequentemente, a IA Simbólica e a IA Conexionista apresentam duas abordagens distintas para alcançar a inteligência da máquina, cada uma com seus prós e contras. A IA Simbólica destaca o raciocínio simbólico e a representação clara do conhecimento, enquanto a IA Conexionista centra-se em redes neurais e na aprendizagem baseada em dados. Ambos os paradigmas fizeram contribuições substanciais para a IA, e a sua combinação, referida como modelos híbridos, é promissora para abordar limitações e capitalizar as suas respetivas vantagens.

2.4 Ética e Explicabilidade

No campo da Inteligência Artificial (IA), a ética e a explicabilidade são dois fundamentos cruciais que desempenham um papel significativo no desenvolvimento e utilização de tecnologias de IA. Estes aspectos não são apenas ideias abstratas; têm implicações diretas na forma como a IA é aplicada na prática e no seu impacto na sociedade. Na era digital, a combinação de ética e explicabilidade na IA serve como um guia, garantindo que os sistemas de IA se alinhem com os valores humanos, padrões morais e um sentido de transparência e compreensão. De acordo com o relatório da (UNESCO, 2021, tradução nossa),

O rápido crescimento da inteligência artificial (IA) criou muitas oportunidades a nível mundial, desde a facilitação de diagnósticos de saúde até à criação de conexões humanas através das redes sociais e à criação de eficiências laborais através de tarefas automatizadas. No entanto, estas rápidas mudanças também suscitam profundas preocupações éticas. Estas surgem do potencial que os sistemas de IA têm para incorporar preconceitos, contribuir para a degradação climática, ameaçar os direitos humanos e muito mais. Esses riscos associados à IA já começaram a agravar-se, somando-se às desigualdades existentes, resultando em danos adicionais para grupos já marginalizados.

A ética em IA refere-se aos princípios morais que orientam a criação, desenvolvimento e utilização de sistemas de IA. Abrange vários aspectos, incluindo justiça, responsabilidade, transparência e privacidade. A IA ética visa garantir que a tecnologia de IA seja construída e utilizada de forma responsável, defendendo os direitos humanos e os valores democráticos. O seu objetivo é prevenir preconceitos, discriminação e quaisquer danos potenciais decorrentes do uso da IA. As considerações éticas servem como medida de proteção, garantindo que as tecnologias de IA se alinhem com os padrões e valores sociais, enfatizando uma abordagem centrada nas pessoas que dá prioridade ao bem-estar e à dignidade dos indivíduos e das comunidades.

Por outro lado, a explicabilidade é uma dimensão da IA que se concentra em tornar as funções e decisões dos sistemas de IA inteligíveis e compreensíveis para os humanos. A IA explicável (XAI) permite que as partes interessadas, incluindo utilizadores, desenvolvedores e reguladores, compreendam como um sistema de IA chega às decisões, os fatores que influenciam os seus resultados e a lógica por detrás de resultados específicos. Esta transparência é vital para a responsabilização, pois permite a análise, validação e melhoria das tecnologias de IA, garantindo que funcionam de forma justa e precisa. De acordo com o relatório de (IBM, 2023, tradução nossa),

A IA explicável é usada para descrever um modelo de IA, seu impacto esperado e possíveis preconceitos. Ajuda a caracterizar a precisão, justiça, transparência e resultados do modelo na tomada de decisões baseada em IA. A IA explicável é crucial para uma organização construir confiança ao colocar modelos de IA em produção. A explicabilidade da IA também ajuda uma organização a adotar uma abordagem responsável ao desenvolvimento da IA.

A interseção entre ética e explicabilidade na IA promove um ambiente tecnológico que é moralmente correto e transparente. Incentiva o desenvolvimento de sistemas de IA que não só operem de forma eficiente e inteligente, mas também demonstrem um sentido de responsabilidade e integridade. Esta fusão é especialmente crucial em setores como os cuidados de saúde, as finanças e a justiça criminal, onde as decisões de IA têm um impacto profundo nas vidas humanas e nas estruturas sociais.

Por exemplo, na área da saúde, a IA ética e explicável pode melhorar o atendimento ao paciente, garantindo que os diagnósticos e tratamentos baseados na IA sejam precisos, justos e compreensíveis tanto para os profissionais de saúde como para os pacientes. Nas finanças, pode criar confiança e fiabilidade em serviços e produtos financeiros baseados na IA, garantindo justiça e não discriminação. No sistema de justiça penal, pode contribuir para garantir que a tomada de decisões baseada na IA esteja alinhada com os

princípios jurídicos e os direitos humanos, promovendo a transparência e a justiça.

No entanto, alcançar a ética e a explicabilidade na IA apresenta desafios. Requer uma abordagem multifacetada, abrangendo metodologias técnicas robustas, quadros regulamentares abrangentes e diálogos contínuos entre tecnólogos, especialistas em ética, reguladores e a sociedade. Implica o desenvolvimento de tecnologias inerentemente interpretáveis e o estabelecimento de diretrizes e padrões que priorizem considerações éticas na concepção e utilização da IA.

Em resumo, a ética e a explicabilidade são qualidades essenciais que definem a base das tecnologias de IA, orientando-as para caminhos benéficos e responsáveis. Incorporam os princípios e práticas que garantem que a IA se alinha com os valores, convicções morais e ambições sociais. Ao promover a IA ética e explicável, lança-se as bases para tecnologias que melhoram a vida humana, defendem a dignidade e contribuem positivamente para o bem-estar e o progresso da sociedade.

3 IA NEURO-SIMBÓLICA: UMA CONVERGÊNCIA ENTRE SIMBOLISMO E CONEXISMO

A Inteligência Artificial (IA) causou grandes impactos em vários domínios de pesquisa e negócios. No entanto, a confiança nas tecnologias de IA é uma preocupação entre empresários e cientistas (RAGHAVAN, 2019). Leslie Valiant (VALIANT, 2003), que recebeu o Prêmio Turing da ACM, observou que combinar habilidades de aprendizagem e raciocínio é crucial, mas desafiador, na computação.

A Inteligência Artificial (IA) é um campo da ciência e da tecnologia em constante mudança, com vários métodos e conceitos evoluindo ao longo dos anos. A IA neuro-simbólica é uma fusão de duas abordagens poderosas: simbolismo e conexionismo. Este capítulo investiga a história, a estrutura, os usos práticos, os desafios e o potencial futuro deste paradigma inovador de IA.

A IA neuro-simbólica se esforça para unir o tratamento do conhecimento simbólico com a aprendizagem baseada em dados por meio de redes neurais. Seu objetivo é criar sistemas que não apenas aprendam dinamicamente, mas também trabalhem e manipulem o conhecimento simbólico. Surgiu como uma resposta às limitações percebidas de abordagens puramente simbólicas ou conexionistas, representando uma convergência de ideias onde coexistem símbolos, regras, padrões e adaptabilidade.

Esta integração de simbolismo e conexionismo oferece uma forma mais versátil e adaptável de representar o conhecimento, facilitando a resolução de problemas complexos e a realização de inferências sofisticadas. O simbolismo envolve representar e manipular o conhecimento por meio de símbolos e regras lógicas, possibilitando o raciocínio abstrato. O conexionismo, através de redes neurais, permite que os sistemas aprendam padrões e representações diretamente a partir de dados brutos, melhorando continuamente o seu desempenho.

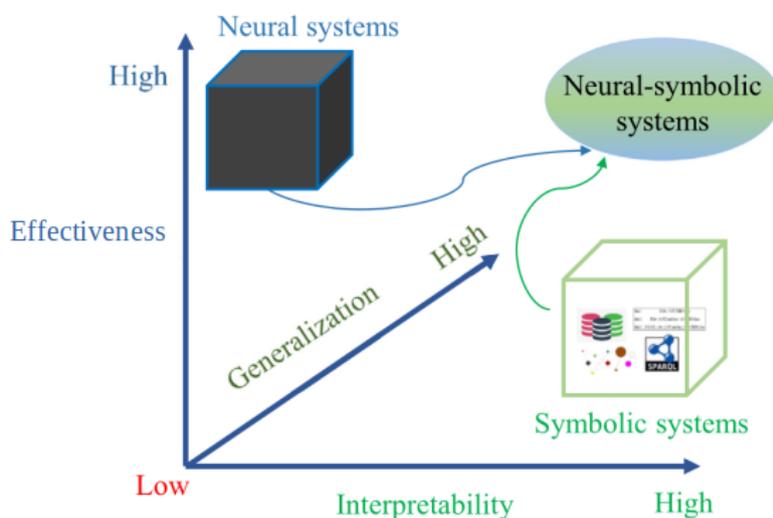
A IA neuro-simbólica combina simbolismo e conexionismo, permitindo que os sistemas aproveitem os pontos fortes das estruturas simbólicas e a adaptabilidade das redes neurais para um desempenho robusto e flexível. Vários setores, incluindo saúde, educação, finanças e manufatura, estão explorando a IA neuro-simbólica para aprimorar a tomada de decisões, agilizar processos e oferecer serviços inovadores. Por exemplo, pode auxiliar na área da saúde, ao permitir diagnóstico e tratamento personalizado, e na educação, ao criar sistemas de tutoria inteligentes.

Apesar do seu potencial, a integração do simbolismo e do conexionismo coloca

desafios técnicos, tais como a complexidade e a necessidade de dados de alta qualidade. Garantir a explicabilidade do modelo é outra preocupação significativa. Questões éticas, incluindo privacidade, justiça e responsabilidade por decisões automatizadas, também surgem no contexto da IA neuro-simbólica.

A investigação em curso continua a explorar novas formas de misturar simbolismo e conexionismo, levando ao desenvolvimento de novas arquiteturas e algoritmos. A IA neuro-simbólica está preparada para desempenhar um papel fundamental no futuro da IA, contribuindo para a criação de sistemas mais inteligentes e capazes. Veja a Figura 3.1 para uma representação visual.

Figura 3.1: Sistemas de aprendizagem neural-simbólica



Fonte: Adaptado de (YU et al., 2023).

3.1 Principais conceitos da IA neuro-simbólica

Basicamente, as redes neurais são aprendem a partir de vastos conjuntos de dados, destacando-se em tarefas como processamento de imagens, compreensão de linguagem natural e análise preditiva. Estas redes, baseadas na aprendizagem profunda, imitam a capacidade do cérebro humano de detectar padrões e aprender com dados empíricos. No entanto, as redes neurais muitas vezes funcionam como “caixas pretas”, oferecendo uma visão limitada dos seus processos de tomada de decisão. Eles também exigem dados extensos para treinamento e podem ter dificuldades com tarefas que exigem raciocínio abstrato de alto nível ou generalização a partir de dados esparsos.

Por outro lado, a IA simbólica, baseada nos princípios da lógica e do raciocínio formal, opera através de regras explícitas e representação estruturada do conhecimento.

É altamente interpretável e se destaca em tarefas que exigem raciocínio dedutivo, como prova de teoremas ou tomada de decisão baseada em regras. No entanto, os sistemas de IA simbólica são muitas vezes rígidos, incapazes de aprender com os dados e podem ter dificuldades com a complexidade e a variabilidade inerentes aos cenários do mundo real.

A IA neuro-simbólica procura preencher essas lacunas integrando as capacidades de aprendizagem das redes neurais com o raciocínio baseado em regras da IA simbólica. Esta integração permite que o sistema não apenas processe e aprenda com grandes conjuntos de dados, mas também aplique regras lógicas e raciocínio simbólico às suas representações aprendidas. Por exemplo, um sistema neuro-simbólico poderia aprender padrões a partir de dados (como uma rede neural) e depois aplicar regras lógicas a esses padrões para tomar decisões ou obter novos *insights*, combinando aprendizagem indutiva com raciocínio dedutivo.

Esta abordagem híbrida oferece diversas vantagens. Ele aumenta a capacidade do sistema de generalizar a partir de dados limitados, um salto significativo em relação aos modelos tradicionais de aprendizagem profunda. Também proporciona maior transparência e interpretabilidade na tomada de decisões em IA, um aspecto crucial em domínios sensíveis como cuidados de saúde, finanças e sistemas autônomos. Além disso, a IA neuro-simbólica pode facilitar uma aprendizagem mais eficiente, uma vez que o conhecimento simbólico pode orientar o processo de aprendizagem, reduzindo a necessidade de grandes conjuntos de dados.

Muitos investigadores antecipam que as técnicas neuro-simbólicas darão início à próxima onda de avanços na Inteligência Artificial, impulsionados pela crescente necessidade de os sistemas de IA serem explicáveis e interpretáveis (AGGARWAL; PARIKH, 2020). Uma limitação importante das redes neurais atuais é sua capacidade de representar a lógica proposicional, mas não a lógica completa de primeira ordem ou de ordem superior.

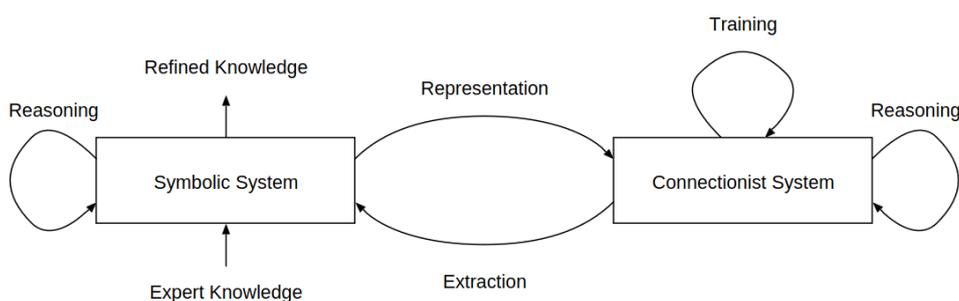
Os sistemas de IA exigem precisão semântica, explicabilidade e confiabilidade, necessitando de uma fusão de raciocínio robusto com aprendizagem profunda. A Inteligência Artificial neuro-simbólica busca combinar a eficiência do aprendizado neural com a precisão do raciocínio lógico para criar ferramentas e modelos mais sofisticados. Abordar aspectos temporais em redes neurais, como aprendizagem e raciocínio sobre o tempo, apresenta um dos desafios (BESOLD et al., 2022; MAO et al., 2021).

Uma abordagem para lidar com essas questões envolve a união de modelos neurais e representações lógicas para estabelecer conexões verificáveis, conhecidas como

integração neuro-simbólica. Esta integração desempenha um papel crucial na abordagem de preocupações importantes como a confiança, segurança, interpretabilidade e responsabilidade da IA. A computação neuro-simbólica visa harmonizar a aprendizagem robusta em redes neurais com o raciocínio e a explicabilidade fornecidos por representações simbólicas para modelar redes, conforme articulado em (GARCEZ; LAMB, 2023).

A integração neuro-simbólica de IA representa a fusão de abordagens computacionais simbólicas e subsimbólicas para o avanço das ciências cognitivas, da computação e da inteligência artificial (IA). Esta integração procura aproveitar as fortes capacidades de representação dos sistemas simbólicos e as capacidades de aprendizagem adaptativa das redes neurais, criando uma estrutura robusta para lidar com as complexidades e incertezas dos dados do mundo real. No centro destes princípios está a ideia de combinação eficaz, otimizando a sinergia entre ambos os paradigmas para aumentar a eficiência computacional, o raciocínio expressivo e a resiliência da aprendizagem. Estes princípios também destacam a importância das aplicações práticas e das implementações no mundo real como referências críticas para validar a utilidade e o impacto dos sistemas neurais-simbólicos. Em essência, os princípios da integração neural-simbólica servem como bases norteadoras para pesquisa e desenvolvimento, visando alcançar um modelo computacional unificado e potente, capaz de impulsionar a inovação e a excelência em domínios como bioinformática, robótica e web semântica (BESOLD et al., 2022) .

Figura 3.2: Ciclo de aprendizagem neural-simbólica



Fonte: (BADER; HITZLER, 2005).

(BADER; HITZLER, 2005) mostra, na Figura 3.2, uma interface simbólica, referida como *front-end*, empregada para inserir simbolicamente conhecimento especializado semi-detalhado em um sistema neural ou conexionista. Este sistema pode ser treinado a partir de dados brutos, mas também levando em consideração o conhecimento interno representado simbolicamente. O conhecimento adquirido durante o treinamento pode ser recuperado e enviado de volta para a interface simbólica, servindo agora tanto como *back-end* quanto como *front-end*. Isso permite maior processamento simbólico e utilização do

conhecimento. (GARCEZ; LAMB, 2020, tradução nossa) complementa:

O sucesso do aprendizado profundo indica que representações distribuídas com métodos baseados em gradiente são mais adequadas que as localistas para aprendizado e otimização. Ao mesmo tempo, as dificuldades das redes neurais em extrapolação, explicabilidade e raciocínio direcionado a objetivos apontam para a necessidade de uma ponte entre representações distribuídas e localistas.

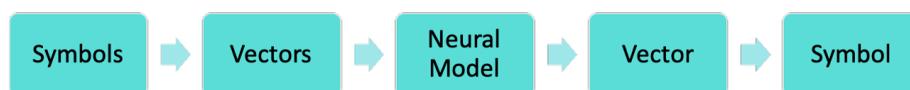
De acordo com (BESOLD et al., 2022, tradução nossa), algoritmos de tradução são comumente usados para atingir os seguintes objetivos: (i) criar uma implementação neural de uma lógica, (ii) estabelecer uma descrição lógica de um sistema neural, ou (iii) desenvolver um sistema de aprendizagem híbrido que combina elementos do conexionismo e da inteligência artificial simbólica. Também menciona que,

O ciclo de integração neural-simbólica inclui, portanto, (i) tradução de conhecimento simbólico (de base) para a rede, (ii) aprendizagem de conhecimento adicional a partir de exemplos (e generalização) pela rede, (iii) execução da rede (ou seja, raciocínio) e (iv) extração simbólica de conhecimento da rede. A extração fornece explicação e facilita a manutenção e a aprendizagem incremental ou de transferência.

Na *Palestra Memorial Robert S. Engelmores na AAAI 2020*, o Prof. Henry Kautz (KAUTZ, 2022) discutiu o estado histórico e atual da IA, enfatizando que a integração das abordagens Neural e Simbólica é crucial para o avanço futuro da IA (KOKEL, 2023, tradução nossa). Os seis tipos de Sistemas neuro-simbólicos são:

1) Simbólico Neuro simbólico: "As entradas simbólicas [...] são cada uma convertida em vetores por *word2vec*, *GloVe* ou similar [...] e passadas para uma rede neural. As unidades de saída da rede convertem a camada anterior para uma categoria simbólica ou sequência de símbolos através de uma operação *softmax*" (KAUTZ, 2022, tradução nossa), ilustrada na Figura 3.3.

Figura 3.3: Tipos de Sistemas neuro-simbólicos: Simbólico Neuro simbólico.

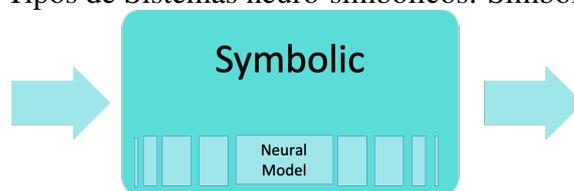


Fonte: (KOKEL, 2023).

2) Simbólico[Neuro]: "A [...] arquitetura emprega uma sub-rotina de reconhecimento de padrões neurais dentro de um solucionador de problemas simbólico [...]. O

solucionador de problemas é o Algoritmo de Busca de Monte Carlo em Árvores e sua função de avaliação heurística é uma rede neural. A maioria dos robôs e veículos autônomos são sistemas "[Neuro] Simbólicos" (KAUTZ, 2022, tradução nossa), ilustrado na Figura 3.4.

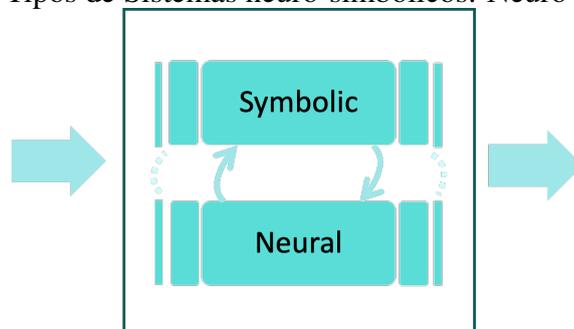
Figura 3.4: Tipos de Sistemas neuro-simbólicos: Simbólico[Neuro].



Fonte: (KOKEL, 2023).

3) Neuro | Simbólico: "Uma rede neural converte entradas não simbólicas, como os pixels de uma imagem, em uma estrutura de dados simbólica, que é então processada por um sistema de raciocínio simbólico [...]. O sistema de raciocínio simbólico fornece um sinal de *feedback* que é usado para treinar a rede neural. Se girar a figura do Neuro | Símbólico 90° no sentido anti-horário, ver-se-á que é semelhante com Simbólico[Neuro]; eles diferem porque a parte neuro é uma corrotina em vez de uma sub-rotina" (KAUTZ, 2022, tradução nossa), ilustrada na Figura 3.5.

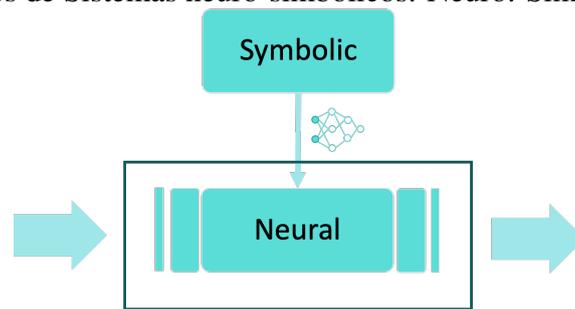
Figura 3.5: Tipos de Sistemas neuro-simbólicos: Neuro | Simbólico.



Fonte: (KOKEL, 2023).

4) Neuro: Simbólico → Neuro: Esta "abordagem usa a Arquitetura SOP [Procedimento Operacional Padrão], mas com um regime de treinamento especial baseado em regras simbólicas [...]. Um exemplo notável é o de Lamplé e Charton (2020) para realizar matemática simbólica. Eles treinaram uma sequência de transformadores para sequenciar o sistema de aprendizagem profunda em pares de entrada-saída da forma (A, B) onde a expressão matemática A pode ser simplificado para a expressão B. Após o treinamento, dado uma expressão nunca antes vista, o sistema normalmente poderia simplificar corretamente. A rede neural não gerar uma derivação passo a passo; em vez disso, absorve suas lições de que poderia simplesmente adivinhar a resposta correta." (KAUTZ, 2022, tradução nossa), ilustrado na Figura 3.6.

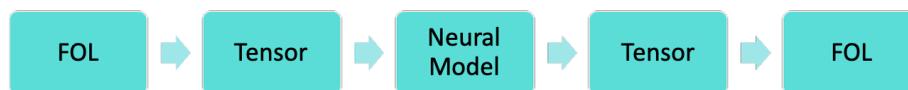
Figura 3.6: Tipos de Sistemas neuro-simbólicos: Neuro: Simbólico → Neuro.



Fonte: (KOKEL, 2023).

5) Neuro_{Symbolic}: Esta "arquitetura transforma regras simbólicas em modelos para estruturas dentro da rede neural [...]. Representações de produtos tensoriais (Smolensky et al. 2016) e redes de tensores lógicos (Serafini, Donadello e Garcez 2017) foram demonstrados para construir abstração e parte de hierarquias na rede. Esta é a arquitetura utilizada na T-LTN, apresentada neste trabalho. A abordagem não foi explorada para codificar regras disjuntivas que permitir o raciocínio combinatório por casos"(KAUTZ, 2022, tradução nossa), ilustrado na Figura 3.7.

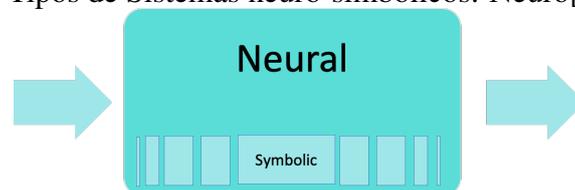
Figura 3.7: Tipos de Sistemas neuro-simbólicos: Neuro_{Simbólico}.



Fonte: (KOKEL, 2023).

6) Neuro[Simbólico]: "A idéia básica é incorporar um mecanismo de raciocínio simbólico dentro de um motor neural, com o objetivo de possibilitar o raciocínio super-neuro e combinatório"(KAUTZ, 2022, tradução nossa), ilustrado na Figura 3.8.

Figura 3.8: Tipos de Sistemas neuro-simbólicos: Neuro[Simbólico].



Fonte: (KOKEL, 2023).

Ao concluirmos esta exploração dos elementos fundamentais da IA neuro-simbólica, é essencial citar a questão da explicabilidade. De acordo com (YU et al., 2023), os sistemas de aprendizagem neural-simbólica emergiram como componentes cruciais da IA explicável. Para (GIBAUT et al., 2023), "Uma das principais características da IA neuro-simbólica é a sua explicabilidade. Dada a sua natureza de rede conexionista, uma IA neuro-simbólica sistema pode ser representado em um conjunto de expressões legíveis".

3.2 Lógica

A aprendizagem temporal e o raciocínio em IA neuro-simbólica são um domínio de pesquisa em evolução com o objetivo de melhorar as habilidades dos sistemas de inteligência artificial (IA) para aprender em cenários temporais.

A aprendizagem temporal na IA neuro-simbólica tem sido fundamental para tarefas que exigem uma compreensão diferenciada das mudanças temporais. A fusão de elementos neurais e simbólicos desempenhou um papel fundamental, permitindo uma abordagem mais holística para capturar relações temporais e aumentar as capacidades de aprendizagem e raciocínio (KYRIAKOPOULOS; GARCEZ, 2023).

A lógica, como campo de estudo, é diversa e multifacetada, abrangendo diversas formas e sistemas adaptados a diferentes necessidades e contextos. A lógica clássica, por exemplo, baseia-se em princípios binários de verdadeiro e falso, amplamente aplicados para avaliar argumentos e proposições em termos de sua validade e consistência. A lógica modal, em contraste, introduz conceitos de possibilidade e necessidade, permitindo uma análise mais complexa de proposições em diferentes “mundos possíveis”. A lógica difusa, outra variante, aborda conceitos vagos e ambiguidades, permitindo graus de verdade entre verdadeiro e falso absoluto, encontrando utilidade em áreas como inteligência artificial e sistemas de controle. A lógica temporal, por outro lado, concentra-se no exame de proposições e argumentos ao longo do tempo, essencial para o raciocínio sobre sistemas dinâmicos e sequenciais. Cada tipo de lógica fornece uma estrutura e ferramentas distintas para navegar pelas complexidades de argumentos, proposições e sistemas encontrados em vários campos e aspectos da vida.

3.2.1 Lógica Clássica

A lógica clássica, um aspecto fundamental do pensamento filosófico e matemático, remonta a estudiosos antigos como Aristóteles. Oferece uma abordagem sistemática para examinar argumentos lógicos, garantindo que as conclusões sejam firmemente baseadas no pensamento racional. Em sua essência, a lógica clássica gira em torno de princípios-chave como a lei da não contradição, a lei do terceiro excluído e a lei da identidade. Estes princípios estabelecem uma estrutura robusta para manter a consistência das deduções e inferências lógicas.

A lógica clássica também emprega símbolos matemáticos e equações para repre-

sentar seus princípios fundamentais e regras de inferência. Essas notações matemáticas dão vida aos argumentos lógicos, oferecendo um caminho estruturado para explorar os domínios do raciocínio e da dedução.

Os principais componentes da lógica proposicional são os conectivos, cada um com sua representação matemática única. A conjunção ("AND"), denotada como $P \wedge Q$, significa que ambas as proposições P e Q são verdadeiras. A disjunção ("OR"), expressa como $P \vee Q$, é válida se pelo menos uma das proposições P ou Q for verdadeira. A negação ("NÃO"), simbolizada como $\neg P$, inverte o valor verdade da proposição P .

A implicação é a base do raciocínio lógico. Representado como $P \rightarrow Q$, afirma que se a proposição P for verdadeira, então a proposição Q também deve ser verdadeira. A bicondicional, denotada como $P \leftrightarrow Q$, significa que ambas as proposições P e Q são verdadeiras ou falsas simultaneamente.

A lógica de predicados enriquece o cenário matemático da lógica clássica ao introduzir quantificadores. O quantificador universal, simbolizado como \forall , expressa que uma propriedade é válida para todos os elementos em um domínio. Por outro lado, o quantificador existencial, denotado como \exists , significa que existe pelo menos um elemento no domínio para o qual uma propriedade é válida.

As regras de inferência, também encontram expressão no simbolismo matemático. *Modus ponens*, uma regra fundamental, é expressa como $(P \wedge (P \rightarrow Q)) \rightarrow Q$, simbolizando que se P for verdadeiro e P implica Q , então Q também é verdadeiro. *Modus tollens*, outra regra fundamental, é representado como $(\neg Q \wedge (P \rightarrow Q)) \rightarrow \neg P$, incorporando o princípio de que se P implica Q e Q é falso, então P também deve ser falso.

As regras de inferência são fundamentais na lógica clássica, orientando a transição das premissas para as conclusões em argumentos lógicos. Estas regras, incluindo o *modus ponens* e o *modus tollens*, servem como princípios orientadores do raciocínio lógico, garantindo que cada passo se baseia numa base sólida de justificação racional. As provas formais na lógica clássica seguem uma abordagem sistemática, onde sequências de afirmações são cuidadosamente construídas, aderindo a regras e princípios estabelecidos para revelar conclusões válidas.

A lógica clássica encontra aplicações em vários campos, como matemática, ciência da computação e filosofia. Na matemática, desempenha um papel crucial nas provas e verificação de teoremas, estabelecendo-se como uma ferramenta fundamental no rigor matemático. Na ciência da computação, a lógica clássica é relevante em domínios como

algoritmos e inteligência artificial, onde o raciocínio lógico tem grande importância.

No entanto, a lógica clássica tem suas limitações. A sua abordagem binária aos valores de verdade, categorizando as declarações como verdadeiras ou falsas, pode ser restritiva, particularmente ao lidar com situações ambíguas ou pouco claras. Apesar destas limitações, a lógica clássica continua a ser fundamental no discurso intelectual, com os seus princípios sendo usados no pensamento racional e no raciocínio analítico. A sua relevância duradoura atesta o seu papel fundamental na formação da investigação lógica e da discussão racional.

3.2.2 Lógica Modal

Ao contrário da lógica clássica, que trata de proposições serem verdadeiras ou falsas, a lógica modal introduz nuances, considerando aspectos como possibilidade, necessidade e contingência. Permite-nos explorar afirmações para além da sua verdade imediata, investigando diferentes “mundos possíveis” para compreender as várias formas como uma proposição pode ser verdadeira ou falsa. A lógica modal é um ramo da lógica que se preocupa com a natureza da verdade e da modalidade.

Os operadores modais são elementos cruciais na lógica modal. Eles são usados para modificar proposições e incluem principalmente os operadores de necessidade (geralmente representado por \Box) e possibilidade (geralmente representado por \Diamond). Esses operadores ajudam a expressar proposições como "é necessariamente o caso que" ou "é possivelmente o caso que", enriquecendo assim o vocabulário da lógica e permitindo argumentos mais sofisticados. Na Tabela 3.1 podemos observar os principais operadores da lógica modal.

A lógica modal não é apenas uma ferramenta filosófica abstrata. Encontra aplicação em diversas disciplinas, como ciência da computação, onde ajuda a modelar e analisar sistemas e algoritmos computacionais. Em linguística, oferece *insights* sobre como as modalidades são expressas e compreendidas na linguagem humana. Assim, a lógica modal é uma área robusta da lógica, oferecendo um rico conjunto de ferramentas e conceitos para explorar a natureza da verdade e da realidade.

Saul Kripke, um notável filósofo e lógico, transformou a lógica modal ao introduzir o conceito de semântica de mundos possíveis. Esta nova abordagem estabeleceu uma estrutura robusta e unificada para compreender e examinar declarações modais, permitindo um exame mais abrangente de conceitos como necessidade, possibilidade e contin-

Tabela 3.1: Principais operadores da Lógica Modal.

Lógica	Símbolos	Expressões Simbolizadas
Lógica Modal	\Box	É necessário que ...
	\Diamond	É possível que ...
Lógica Deôntica	O	É obrigatório que...
	P	É permitido que...
	F	É proibido que...
Lógica Temporal	G	Sempre será o caso que ...
	F	Será o caso que ...
	H	Sempre foi assim que...
	P	Aconteceu que...
Lógica Doxástica	Bx	x acredita que ...
Lógica Epistêmica	Kx	x sabe que...

Fonte: (MARES, 2023).

gência. "Em muito pouco tempo Saul Kripke forneceu uma semântica adequada e rigorosa para diferentes sistemas modais axiomáticos e estabeleceu uma série de resultados relacionados"(ANTONELLI, 2018, tradução nossa).

3.2.2.1 Lógica Temporal

A lógica clássica funciona com valores de verdade fixos e carece de um mecanismo para explicar explicitamente o tempo e seus efeitos sobre os valores de verdade das declarações lógicas. A ideia fundamental por trás da lógica temporal é que uma afirmação lógica pode ter valores de verdade variados em diferentes momentos no tempo. (HODKINSON; REYNOLDS, 2007; GARCEZ; LAMB, 2006).

Uma das principais características da lógica temporal é a sua capacidade de expressar proposições sobre o passado, presente e futuro. Por exemplo, pode articular declarações como "eventualmente", "até" e "próximo". Isto é crucial em áreas como a ciência da computação, especialmente em áreas como a verificação formal, onde é essencial garantir que um sistema se comporte corretamente ao longo do tempo. De acordo com (GORANKO; RUMBERG, 2020, tradução nossa),

O termo Lógica Temporal tem sido amplamente utilizado para abranger todas as abordagens de raciocínio sobre tempo e informações temporais, bem como sua representação formal, dentro de uma estrutura lógica, e também de forma mais restrita para se referir especificamente ao tipo de abordagem lógica modal introduzida por volta de 1960 por Arthur Prior sob o nome *Tense Logic* e posteriormente desenvolvido por muitos lógicos e cientistas da computação.

A lógica temporal linear utiliza proposições atômicas para descrever estados ou

condições que podem ser verdadeiras ou falsas em momentos específicos. Por exemplo, uma proposição atômica como p pode representar a condição “está chovendo agora”.

Além das proposições atômicas, a lógica temporal linear incorpora operadores modais que permitem expressar relações temporais entre essas proposições. O operador X (próximo) indica que a proposição seguinte é verdadeira no próximo estado temporal. Por exemplo, Xp afirma que “será verdade que está chovendo no próximo momento”.

O operador G (globalmente) indica que uma proposição é verdadeira em todos os estados futuros. Assim, Gp significa que “é verdade que estará chovendo em todos os momentos futuros”.

Já o operador F (finalmente) indica que uma proposição será verdadeira em algum momento no futuro. Por exemplo, Fp indica que “é verdade que estará chovendo em algum momento no futuro”.

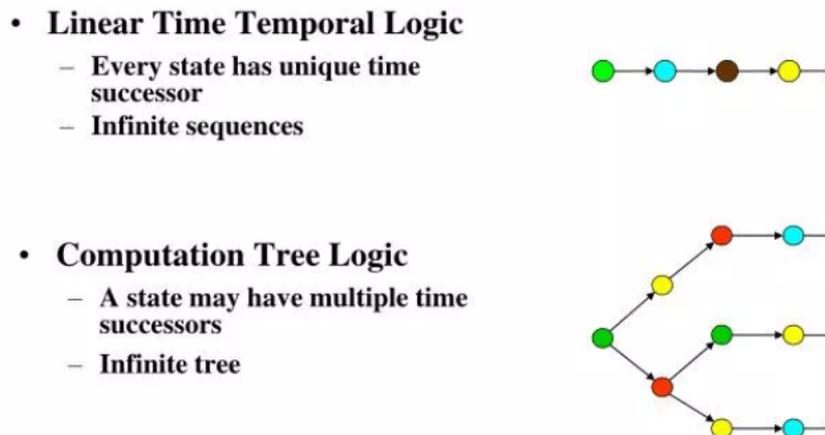
Por fim, o operador U (até) permite especificar que uma proposição à esquerda será verdadeira até que uma proposição à direita se torne verdadeira. Por exemplo, pUq significa que “está chovendo até que o sol apareça”.

A Lógica Temporal Linear (LTL) e A Lógica de Árvore Computacional (CTL), mostradas na Figura 3.9, são dois tipos avançados de lógica temporal, cada um com seus próprios recursos e aplicações especiais. LTL é baseado no conceito de uma linha reta de estados ou momentos no tempo. Isso significa que, a qualquer momento, existe apenas um próximo estado possível. LTL é particularmente útil para descrever características ao longo dos caminhos de ações em sistemas reativos e permite definir requisitos como “eventualmente P” ou “sempre P”.

Em contraste, o CTL utiliza um modelo de tempo ramificado, onde o futuro não é uma linha reta de estados, mas uma árvore de resultados possíveis, com cada estado levando a vários estados seguintes. Isto permite a expressão de características mais complexas que consideram muitos resultados futuros, o que é útil para sistemas que se comportam de forma imprevisível. CTL permite declarações sobre caminhos, tornando possível dizer coisas como “em todos os caminhos, eventualmente p” ou “há um caminho onde sempre p”.

A decisão de usar LTL ou CTL depende dos requisitos específicos do sistema que se está projetando ou verificando. O CTL, com a sua capacidade de levar em conta vários futuros potenciais, proporciona mais versatilidade e uma gama mais ampla de expressão. No entanto, pode ser mais complicado e menos direto que o LTL. LTL oferece uma maneira mais simples e direta de representar características relacionadas ao tempo.

Figura 3.9: Lógica Temporal Linear e Lógica de Árvore Computacional.



Fonte: (COLLIN, 2023).

(GORANKO; RUMBERG, 2020, tradução nossa) destaca ainda que,

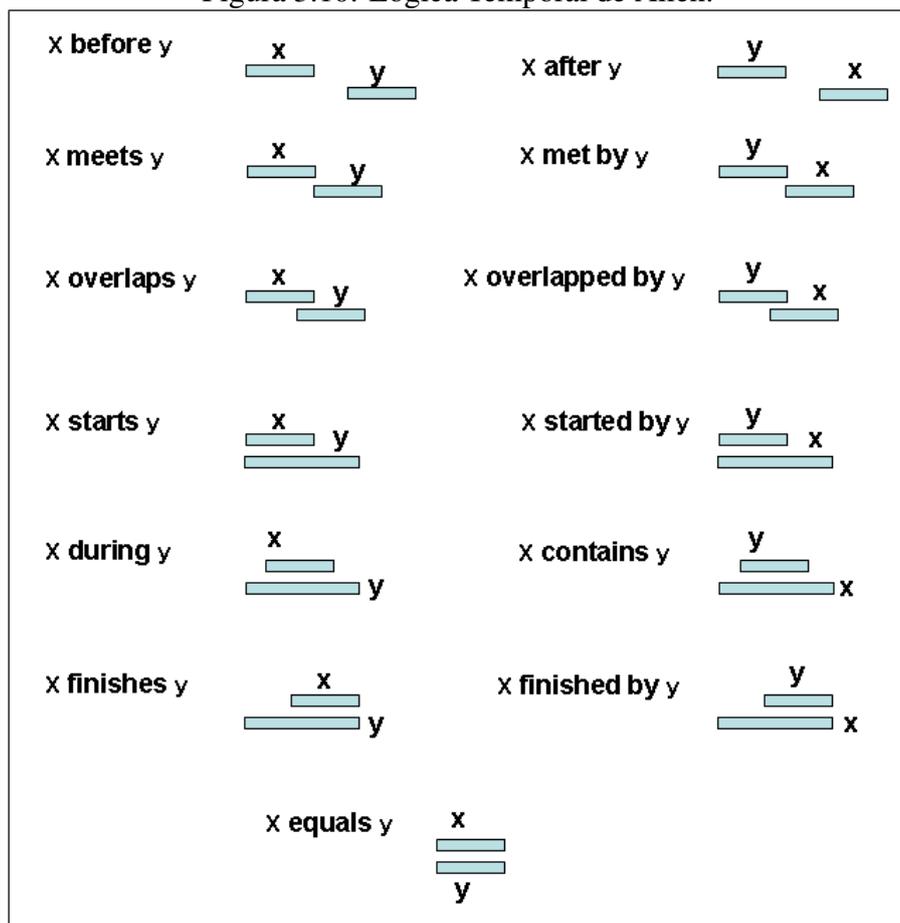
Os modelos de tempo baseados em instantes muitas vezes não são adequados para raciocinar sobre eventos com duração, que são melhor modelados se a ontologia temporal subjacente usar intervalos de tempo, ou seja, períodos em vez de instantes, como entidades primitivas. As raízes do raciocínio temporal baseado em intervalos remontam a Zenão e Aristóteles [...]. Num cenário baseado em intervalos, o famoso paradoxo da flecha voadora de Zenão (“Se a cada instante a flecha voadora fica parada, como é possível o movimento?”) não surge. Outros exemplos que naturalmente requerem raciocínio intervalado são: “Ontem à noite Alice chorou muito enquanto escrevia a carta e depois se acalmou” e “Bill estava tomando chá quando o carteiro chegou”.

"Em um influente trabalho inicial sobre o estudo formal da ontologia temporal baseada em intervalos e do raciocínio em IA, Allen (1983) considerou a família de todas as relações binárias que podem surgir entre dois intervalos em uma ordem linear, posteriormente chamadas de relações de Allen"(GORANKO; RUMBERG, 2020, tradução nossa), Figura 3.10.

A Lógica Temporal é usada para compreender e analisar questões filosóficas sobre o tempo, como uma estrutura para definir os significados de frases relacionadas ao tempo na linguagem normal, como uma linguagem para registrar conhecimento relacionado ao tempo na inteligência artificial e como uma ferramenta para gerenciar elementos relacionados ao tempo nos programas (GARCEZ et al., 2019; HODKINSON; REYNOLDS, 2007).

Por exemplo, para garantir que um programa contínuo, como um sistema operacional que não para, funcione corretamente, é importante delinear e confirmar formalmente suas operações intermináveis (BORGES; GARCEZ; LAMB, 2011). Além disso, para um programa onde vários processadores trabalham ao mesmo tempo, é necessário delinear e confirmar formalmente como eles funcionam juntos e permanecem sincronizados.

Figura 3.10: Lógica Temporal de Allen.



Fonte: (ELANGO VAN, 2023).

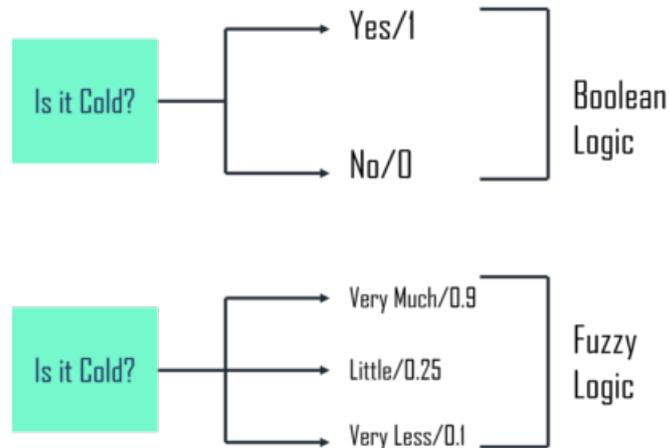
Na inteligência artificial, especificamente na compreensão da linguagem e na resolução de problemas, a ideia de ação é importante. A pesquisa de (ALLEN, 1984) concentra-se na criação de uma estrutura geral adequada para todas as informações baseadas no tempo necessárias aos programas de IA. Além disso, tem havido pesquisas sobre a adição de pensamento baseado no tempo em sistemas de aprendizagem ao longo do tempo, por exemplo (LAMB; BORGES; GARCEZ, 2007; GARCEZ; LAMB, 2003; PENNING et al., 2011).

3.2.3 Lógica Fuzzy

No campo da inteligência computacional, a lógica fuzzy se destaca pela versatilidade e adaptabilidade. Diferente da lógica binária usual, que categoriza estritamente as coisas como verdadeiras ou falsas (1 ou 0), a lógica difusa prospera em situações de incerteza. Permite vários níveis de verdade, uma noção que combina melhor com o pen-

samento humano e as complexidades do mundo real, conforme ilustrado na Figura 3.11.

Figura 3.11: Lógica Booleana x Lógica Fuzzy



Fonte: (SAYANTINI, 2023).

Lotfi A. Zadeh introduziu a lógica fuzzy na década de 1960 (ZADEH, 1965) como uma forma mais ampla de lógica clássica (booleana). Pretendia ser uma forma matemática de representar a imprecisão natural e a falta de precisão no pensamento e nas línguas humanas.

No cerne da lógica difusa está a ideia de um "conjunto difuso". Este é um grupo de objetos com vários níveis de pertencimento. Ao contrário dos conjuntos claramente definidos, os conjuntos difusos têm limites pouco claros. Os membros de um conjunto fuzzy possuem níveis de pertencimento que variam de 0 a 1, permitindo descrições mais detalhadas das informações. Esse recurso permite que a lógica difusa lide com ideias que não são claras ou facilmente definidas por valores exatos, como "quente" ou "frio".

Os sistemas de lógica difusa geralmente usam variáveis linguísticas – variáveis que têm palavras como valores em vez de números. Essas variáveis facilitam a definição de regras e a tomada de decisões de maneira direta e fácil de entender. Regras fuzzy, feitas com variáveis linguísticas, são o núcleo dos sistemas de inferência fuzzy. Essas regras geralmente são escritas no formato SE-ENTÃO e ajudam a orientar a tomada de decisões com base na veracidade das condições.

Em usos práticos, a lógica fuzzy é especialmente útil em sistemas de controle. É usado para criar controladores para sistemas complexos e difíceis de descrever matematicamente. A capacidade da lógica difusa de lidar com a incerteza e a imprecisão a torna uma ferramenta poderosa para criar sistemas adaptativos que funcionam bem em diferentes condições, sem a necessidade de entradas exatas.

A lógica difusa também é importante em sistemas que apoiam a tomada de de-

ções, onde ajuda a modelar o raciocínio humano e auxilia na tomada de decisões em situações complexas. A sua capacidade de imitar o pensamento humano torna possível desenvolver sistemas que correspondam melhor à intuição humana, melhorando a sua utilidade e eficácia. De acordo com (KULKARNI; LAD, 2021, tradução nossa),

A palavra "lógica difusa" refere-se a um método de raciocínio aproximado em um contexto mais preciso, mas sua definição mais ampla é geralmente associada a uma teoria matemática de classes com limites indefinidos ou "confusos". No Processamento de Linguagem Natural, a lógica fuzzy é usada em uma variedade de aplicações de Inteligência Artificial. Os sistemas especialistas, por exemplo, são sistemas de controle modernos e fazem uso intenso de lógica difusa. É usado em Redes Neurais porque simula como as pessoas tomam decisões, mas muito mais rápido.

Em resumo, a lógica fuzzy é uma abordagem excepcional em inteligência computacional, fornecendo um método para representar incerteza e imprecisão. O seu foco no raciocínio humano, juntamente com a sua flexibilidade, tornam-no numa ferramenta essencial para a criação de sistemas inteligentes que possam lidar eficazmente com as complexidades e incertezas do mundo real.

3.3 Lógica em IA Neuro-simbólica

A conexão entre a lógica e a IA neuro-simbólica é uma mistura complexa de raciocínio simbólico e computação neural, cada uma adicionando suas próprias qualidades únicas ao campo da inteligência artificial. A lógica, profundamente enraizada na matemática e na filosofia, oferece uma forma bem organizada de representar o conhecimento e conduzir o raciocínio. Traz clareza, precisão e uma base sólida para uma representação simbólica clara, permitindo que as máquinas executem tarefas que necessitam de dedução lógica, verificações de consistência e inferência.

A IA neuro-simbólica, por outro lado, é uma abordagem que visa combinar os elementos simbólicos da lógica com os aspectos mais intuitivos e focados no aprendizado das redes neurais. Ele se esforça para conectar as habilidades de pensamento de alto nível da IA simbólica com a aprendizagem adaptativa e as habilidades de generalização da IA neural. Essa combinação permite que os sistemas neuro-simbólicos utilizem os melhores recursos de ambas as abordagens, criando modelos que são compreensíveis e flexíveis o suficiente para lidar com diferentes tipos de complexidade nos dados.

Na IA neuro-simbólica, a lógica é crucial porque ajuda a adicionar conhecimento

prévio, regras e informações estruturadas aos modelos de aprendizagem. Permite a inclusão de conhecimentos claros de forma que possam ser facilmente utilizados e ajustados dentro do sistema. Regras e limites lógicos podem direcionar o processo de aprendizagem, fornecendo uma base para o modelo fazer inferências e decisões que correspondam a regras ou conhecimentos predefinidos.

As redes neurais, dentro da IA neuro-simbólica, oferecem a capacidade de aprender e reconhecer padrões e representações diretamente dos dados. Elas fornecem adaptabilidade e habilidade para gerenciar a incerteza, o ruído e a variabilidade encontrados em dados do mundo real. As redes neurais são capazes de aprender a aproximar funções complexas, categorizar dados e fazer previsões, melhorando assim o raciocínio lógico com aprendizagem e generalização orientadas por dados.

A interação entre redes lógicas e neurais na IA neuro-simbólica é exibida de várias maneiras. Regras lógicas e formas simbólicas podem ser combinadas com modelos neurais, direcionando o processo de aprendizagem e melhorando a capacidade do modelo de fazer generalizações a partir de dados limitados. Em contrapartida, as redes neurais podem ser utilizadas para aprender representações que são utilizadas em processos de raciocínio lógico, permitindo ao sistema lidar com a incerteza e aprender com as experiências.

Em última análise, a relação entre lógica e IA neuro-simbólica é mutuamente benéfica. A lógica contribui com estrutura, clareza e capacidades de raciocínio explícito, enquanto as redes neurais trazem adaptabilidade, habilidades de aprendizagem e capacidade de processar dados complexos e não estruturados. Juntos, elas ajudam na criação de sistemas de IA que são ao mesmo tempo intelectualmente profundos e praticamente versáteis, capazes de aprender e raciocinar de maneira semelhante à inteligência humana.

4 TRABALHOS RELACIONADOS

No amplo, e em constante evolução, domínio da Inteligência Artificial (IA), a IA neuro-simbólica destaca-se como um paradigma significativo e inovador, fundindo os pontos fortes das abordagens neurais e simbólicas. Esta integração procura combinar as capacidades flexíveis de aprendizagem das redes neurais com as capacidades de raciocínio claro dos sistemas simbólicos, levando à criação de sistemas mais capazes e inteligentes.

A fusão de métodos simbólicos e subsimbólicos tem atraído atenção considerável devido ao seu potencial para trazer um raciocínio mais humano aos sistemas de IA. Este capítulo se concentrará em um conjunto cuidadosamente escolhido de trabalhos mais influentes e críticos que influenciaram enormemente a direção da IA neuro-simbólica. Objetiva-se destacar as principais contribuições que servem como elementos fundamentais no crescimento e progresso deste campo interdisciplinar. Este capítulo abordará o progresso e o desenvolvimento do campo da integração neuro-simbólica, ver Tabela 4.1.

Em (BADREDDINE et al., 2022), um método inovador chamado *Logic Tensor Networks* (LTNs) é introduzido, com o objetivo de integrar o raciocínio lógico com sistemas de aprendizagem baseados em tensores. Este estudo destaca a capacidade das LTNs de enfrentar os desafios dos dados relacionais e aprimorar o raciocínio e a interpretabilidade dos modelos de aprendizado de máquina.

O artigo (DONG et al., 2018) apresenta *Neural Logic Machines (NLMs)*, um sistema diferenciável construído para raciocínio lógico. O artigo demonstra a eficácia dos NLMs na aprendizagem a partir de vários tipos de dados, tanto simbólicos como não simbólicos, fortalecendo assim o vínculo entre redes neurais e raciocínio lógico.

Em (TRAN; GARCEZ, 2021), os autores exploram a combinação de raciocínio lógico com modelos gráficos probabilísticos usando Máquinas Lógicas de Boltzmann. Este estudo enfoca o potencial da lógica probabilística para avançar o raciocínio da máquina, mantendo ao mesmo tempo as habilidades de aprendizado de dados do modelo.

Por fim, (RIEGEL et al., 2020) apresenta uma nova forma de incluir estruturas lógicas em redes neurais, denominadas Redes Neurais Lógicas. Esta pesquisa ilustra como as Redes Neurais Lógicas podem apoiar o raciocínio simbólico dentro de uma estrutura subsimbólica, indicando um caminho promissor para a integração de métodos neuro-simbólicos.

O artigo "*The Neuro-Symbolic Concept Learner*" de (MAO et al., 2019) apresenta um aprendiz de conceito neuro-simbólico que se destaca na compreensão de cenas, pala-

avras e frases por meio de supervisão natural. Este trabalho mostra a eficácia da combinação de representações simbólicas e subsimbólicas para melhorar a interpretabilidade e generalização em diferentes tarefas.

Finalmente, "Generative Neurosymbolic Machines" de (JIANG; AHN, 2020) descreve uma estrutura generativa que integra o raciocínio simbólico com a modelagem generativa. Este estudo destaca o potencial dos modelos generativos neuro-simbólicos na captura de distribuições complexas de dados, ao mesmo tempo que aprimora os processos de raciocínio interpretáveis.

Tabela 4.1: Principais Métodos neuro-simbólicos

Método	Descrição
Redes de Tensores Lógicos (LTN) (BADREDDINE et al., 2022)	LTN é um modelo computacional neuro-simbólico e formalismo. Ele apóia o aprendizado e o raciocínio por meio da Lógica Real - uma lógica de primeira ordem diferenciável, de muitos valores e de ponta a ponta - como uma linguagem de representação para aprendizado profundo (BADREDDINE et al., 2022).
Neural Logic Machine (NLM) (DONG et al., 2018)	NLM é uma arquitetura neuro-simbólica para aprendizagem indutiva e raciocínio lógico. Usando redes neurais e um processador simbólico (DONG et al., 2018).
Máquinas lógicas de Boltzmann (LBM) (TRAN; GARCEZ, 2021)	LBM é um sistema neuro-simbólico capaz de representar qualquer fórmula lógica proposicional na forma normal disjuntiva estrita (TRAN; GARCEZ, 2021).
Redes Neurais Lógicas (LNN) (RIEGEL et al., 2020)	LNN é uma nova estrutura que fornece redes neurais para aprendizagem e lógica simbólica para conhecimento e raciocínio. Cada neurônio tem um significado como componente em fórmulas lógicas ponderadas de valor real (RIEGEL et al., 2020).
Neuro-Symbolic Concept Learner (NS-CL) (MAO et al., 2019)	NS-CL é um modelo capaz de aprender conceitos visuais, palavras e análise semântica de frases sem supervisão explícita. O modelo aprende "olhando" imagens e lendo perguntas e respostas emparelhadas, construindo assim uma representação de cena baseada em objetos e traduzindo frases em programas simbólicos que podem ser executados (MAO et al., 2019).
Máquinas neuro-simbólicas Generativas (GNM) (JIANG; AHN, 2020)	GNMs é um modelo generativo que combina os benefícios de representações distribuídas e simbólicas para suportar representações estruturadas de componentes simbólicos e geração baseada em densidade (JIANG; AHN, 2020).

Fonte: (GIBAUT et al., 2023).

Os métodos neuro-simbólicos visam preencher a lacuna entre as formas simbólicas e subsimbólicas de representar o conhecimento na IA, combinando a IA simbólica tradicional com redes neurais. Os sistemas neuro-simbólicos fornecem uma forma organi-

zada de representar e pensar sobre conceitos, eventos e conexões relacionados ao tempo, o que é vital em muitas tarefas mentais e práticas. Usando estruturas neuro-simbólicas, o tempo pode ser representado simbolicamente para um raciocínio temporal preciso, e também modelado subsimbolicamente através de redes neurais para compreender a natureza contínua e mutável dos eventos relacionados ao tempo. Essa forma dupla de representar o tempo leva a uma compreensão e manuseio mais profundos do tempo, ajudando em atividades como raciocínio, planejamento e previsão do tempo, usando os melhores aspectos dos métodos simbólicos e neurais. Além disso, os modelos neuro-simbólicos poderiam ajudar a criar sistemas de IA mais fáceis de compreender e mais eficazes, capazes de lidar com desafios complexos relacionados com o tempo em áreas como a compreensão da linguagem, a robótica e outras.

A lógica temporal é uma seção da lógica prática que oferece várias técnicas para representar e analisar proposições com um aspecto temporal combinando ideias da lógica modal, lógica clássica de primeira ordem e lógica de ordem superior (HODKINSON; REYNOLDS, 2007). Sendo eficaz na modelagem, análise, verificação e especificação de sistemas distribuídos, a lógica temporal é o principal sistema lógico empregado na ciência da computação e na inteligência artificial e tem atraído considerável interesse (GARCEZ; LAMB; GABBAY, 2009).

Com base nos fundamentos estabelecidos por esses estudos, a fusão da lógica temporal com redes neurais leva a uma forma sofisticada de compreender e modelar o conhecimento que muda ao longo do tempo. A *Lógica Temporal Conexionista (CTL)*, (GARCEZ; LAMB, 2003), se destaca como um exemplo chave, convertendo habilmente princípios temporais em configurações de redes neurais. Esta conversão não é apenas uma questão de representação – é um esforço para criar uma base computacional para o raciocínio baseado no tempo dentro da estrutura de uma IA.

Continuando nesta direção, a criação da arquitetura do *Agente Cognitivo Simbólico Neural (NSCA)*, (PENNING et al., 2011), marca um passo significativo para tornar esses conceitos uma realidade. O núcleo da NSCA é a *Máquina de Boltzmann Temporal Recorrente e Restrita (RTRBM)*, um método engenhoso que representa regras baseadas no tempo como suposições baseadas em crenças e regras previamente estabelecidas. Esta representação não é estática, mas dinâmica, capturando e analisando a progressão do tempo para melhorar a compreensão e interação do agente com o seu entorno.

Indo além, *Redes de Grafos Temporais (TGNs)*, (ROSSI et al., 2020), conforme descrito no trabalho citado, introduzem uma nova abordagem no tratamento de grafos di-

nâmicos, vistos como sequências cronometradas de eventos. Ao contrário das redes de grafos estáticos convencionais, os TGNs animam os nós e links, vinculando-os a aspectos de tempo. Esta integração do tempo é profunda, permitindo a monitorização de relações e estados em mudança ao longo do tempo. A estrutura TGN é versátil, mas poderosa, oferecendo uma base sólida para projetos de aprendizagem profunda em grafos dinâmicos.

No estudo de (MAO et al., 2021) é apresentado um novo tipo de rede neuro-simbólica chamada *Redes Temporais e de Quantificação de Objetos (TOQ-Nets)*, marcando um importante desenvolvimento na inteligência artificial. As TOQ-Nets são projetadas com um recurso estrutural exclusivo que lhes permite aprender e identificar eventos relacionais complexos relacionados ao tempo. Esse recurso está integrado à estrutura das TOQ-Nets, criando uma estrutura forte capaz de modelar e compreender dinâmicas relacionais e relacionadas ao tempo detalhadas. Combinando a quantificação de tempo e objetos em um ambiente de rede neural, as TOQ-Nets superam as redes neuro-simbólicas tradicionais no reconhecimento e interpretação de padrões de eventos complicados, frequentemente encontrados em situações do mundo real.

A introdução de TOQ-Nets por (MAO et al., 2021) abre novas possibilidades para examinar a combinação de raciocínio simbólico e aprendizagem de redes neurais. Ao combinar a análise estruturada do raciocínio simbólico com a capacidade de aprendizagem flexível das redes neurais, as TOQ-Nets oferecem um caminho promissor para um reconhecimento e compreensão de eventos mais avançado. Esta pesquisa enfatiza o potencial das TOQ-Nets como uma estrutura poderosa para impulsionar as capacidades de aprendizagem neuro-simbólica, que é crucial em diversas áreas, incluindo análise de vídeo, robótica e sistemas interativos. A característica estrutural distinta das TOQ-Nets contribui para a discussão mais ampla sobre a fusão de métodos simbólicos e subsimbólicos na inteligência artificial, sublinhando o valor da integração do tempo e da quantificação de objetos para alcançar uma compreensão mais profunda de eventos relacionais complexos relacionados ao tempo.

No estudo de (FAINEKOS et al., 2009), os autores mostram o desafio do planejamento de movimento lógico temporal para robôs móveis. Eles usam especificações de lógica temporal para desenvolver uma abordagem estruturada para especificações de controle essenciais, como acessibilidade e invariância, que são críticas para a navegação e controle do robô. A abordagem também inclui especificações mais complexas, como sequenciamento e prevenção de obstáculos, essenciais para uma navegação suave e segura de robôs móveis em ambientes em constante mudança. A lógica temporal fornece

uma estrutura sólida para definir e garantir a adesão a essas especificações de controle, provando ser uma ferramenta vital para delinear e resolver problemas de planejamento de movimento. O uso da lógica temporal no planejamento de movimento melhora a precisão e a confiabilidade das operações robóticas e oferece uma maneira sistemática de enfrentar desafios complicados de navegação.

A inovação do estudo no uso da lógica temporal para o planejamento de movimento foi bem-sucedida em sua abordagem abrangente e formalizada das complexidades da navegação do robô. O foco no sequenciamento e na prevenção de obstáculos ressalta a precisão e flexibilidade que a lógica temporal oferece no desenvolvimento de estratégias para robôs móveis navegarem por caminhos complexos, evitar obstáculos e seguir uma sequência definida de tarefas. Esta abordagem supera os métodos tradicionais de planejamento de movimento, introduzindo um nível de formalidade capaz de gerenciar requisitos complexos. Esta exploração do planejamento de movimentos lógicos temporais abre novas possibilidades para melhorar a autonomia e a eficácia dos robôs móveis, estabelecendo um novo padrão para futuras pesquisas na combinação de lógica formal com sistemas de controle robóticos. Isso ultrapassa os limites do que pode ser alcançado no campo do planejamento e controle de movimento robótico.

Os métodos mencionados acima são únicos, mas complementares, cada um abrindo seu próprio caminho para uma compreensão e utilização mais profundas da dinâmica relacionada ao tempo em sistemas de IA. Vistos através das lentes dos sistemas neuro-simbólicos, eles destacam coletivamente a importância da lógica temporal e sua combinação com redes neurais. Esta fusão move o campo para sistemas de IA que não só “pensam” em símbolos, mas também se “adaptam” ao longo do tempo.

Além disso, a interação da lógica temporal, das redes neurais e da representação gráfica dinâmica nessas estruturas revela uma vasta gama de possibilidades para pesquisas e aplicações avançadas. Desde a compreensão de relações complicadas relacionadas ao tempo em dados do mundo real até o acompanhamento do mundo em mudança da representação do conhecimento, a união desses métodos proporciona um ambiente rico para o crescimento. À medida que o campo avança, a fusão do raciocínio temporal e do processamento neural-simbólico provavelmente abrirá novas possibilidades, orientando a comunidade de IA em direção a modelos que possam raciocinar sobre o tempo de maneiras sofisticadas e aplicações anteriormente consideradas muito difíceis.

A LTN de (BADREDDINE et al., 2020), conforme apresentado anteriormente, suporta lógica completa de primeira ordem com símbolos de função, mas carece de um

método formalizado para representar o tempo. Ao contrário das abordagens anteriores, este trabalho estende o LTN para incluir um aspecto temporal, permitindo uma modelagem mais abrangente de problemas e melhorando o desenvolvimento de tecnologias de IA neuro-simbólicas.

A aprendizagem temporal e o raciocínio dentro da IA neuro-simbólica mostram uma grande promessa para o futuro, com avanços contínuos definidos para expandir as capacidades da IA em contextos dinâmicos e relacionados ao tempo.

4.1 Redes de Tensores Lógicos

No vasto campo da inteligência artificial (IA), a fusão da lógica simbólica e das redes neurais está a trabalhar para preencher a lacuna entre o raciocínio de alto nível e o processamento de dados de baixo nível. Uma contribuição importante para este campo são as *Redes Tensoriais Lógicas (LTN)* introduzidas em (BADREDDINE et al., 2020). A LTN representa uma combinação promissora de lógica e aprendizagem que aponta para o futuro da IA. LTN mostra o potencial de combinar a lógica simbólica clássica com as capacidades das redes neurais para descobrir padrões subjacentes em dados complexos e oferecer habilidades de raciocínio diferenciadas.

A ideia central por trás do LTN é fundir a precisão do raciocínio lógico com uma estrutura de aprendizagem flexível usando redes de tensores. Esta integração visa abordar a incerteza e a complexidade inerentes encontradas nos dados do mundo real, mantendo ao mesmo tempo uma abordagem estruturada ao raciocínio. A arquitetura do LTN é cuidadosamente projetada para incorporar fórmulas lógicas como restrições dentro de um modelo contínuo, permitindo uma transição perfeita entre a lógica simbólica e as representações subsimbólicas. Esse recurso exclusivo permite que o LTN opere em um ambiente onde a consistência lógica e o aprendizado a partir dos dados coexistem de forma harmoniosa.

A base do LTN é construída sobre a combinação do poder expressivo da lógica de primeira ordem (FOL) e da capacidade de aprendizagem das redes de tensores neurais. A formulação do LTN segue os princípios do FOL para representar o conhecimento de forma estruturada, enquanto o uso de redes de tensores facilita o aprendizado a partir dos dados. Esta dupla natureza da LTN não só permite a adaptação aos dados, mas também a adesão a restrições lógicas predefinidas, representando um passo significativo em direção a uma IA mais robusta e compreensível.

A abordagem operacional do LTN é projetada para processar informações de uma forma que retenha o núcleo do raciocínio lógico, ao mesmo tempo que é adaptável ao aprendizado a partir dos dados. A estrutura LTN permite a criação e otimização de uma função de valor de verdade, que desempenha um papel crucial na avaliação do cumprimento de declarações lógicas. O processo de otimização em LTN é realizado por meio de retropropagação, que ajusta os parâmetros da rede para garantir consistência lógica e minimizar erros na representação dos dados.

Além disso, a versatilidade da LTN estende-se a vários domínios, incluindo representação de conhecimento, processamento de linguagem natural e aprendizagem relacional, entre outros. A capacidade da LTN de combinar perfeitamente lógica e aprendizagem abre novas possibilidades para resolver problemas complexos que exigem um equilíbrio entre raciocínio e adaptabilidade. A estrutura LTN representa um passo promissor no desenvolvimento de sistemas mais inteligentes e interpretáveis.

O conceito fundamental da LTNs é o de *Real Logic*. As definições de LTN abaixo seguem exatamente aquelas introduzidas pelos autores de (BADREDDINE et al., 2020, tradução nossa).

Definição 1: A *Lógica Real* é definida sobre uma linguagem de primeira ordem \mathcal{L} com uma assinatura que contém um conjunto \mathcal{C} de símbolos constantes (objetos), um conjunto \mathcal{F} de símbolos funcionais, um conjunto \mathcal{P} de símbolos relacionais (predicados) e um conjunto \mathcal{X} de símbolos variáveis. As fórmulas \mathcal{L} permitem-nos especificar o conhecimento relacional com variáveis, que são marcadores de posição para objetos de um determinado domínio, como de costume.

Definição 2: Os objetos podem ser de diferentes tipos. Na LTN, conforme definido em (BADREDDINE et al., 2020) funções e predicados são tipados. Portanto, assume-se que existe um conjunto não vazio de símbolos \mathcal{D} chamados símbolos de domínio.

Definição 3: A *Lógica Real* também pode conter variáveis proposicionais, como segue: se P é um predicado 0-ário com $\mathbf{D}_{in}(P) = \langle \rangle$ (a sequência vazia de domínios) então P é uma variável proposicional (um átomo com valor de verdade no intervalo $[0, 1]$).

Definição 4: Um termo é construído recursivamente da maneira usual a partir de símbolos constantes, variáveis e símbolos de funções.

Definição 5: São usados os operadores lógicos $\{\neg\}$ (negação) e $\{\wedge, \vee, \rightarrow, \leftrightarrow\}$ (conjunção, disjunção, implicação e bicondicional, respectivamente) e $\{\forall, \exists\}$ (universal e existencial, respectivamente). A semântica da *Lógica Real* é distinta da semântica abstrata canônica da *Lógica de Primeira Ordem* (FOL). Na *Lógica Real*, os domínios são interpretados concretamente por tensores no campo real. Todo objeto denotado por constantes, variáveis e termos é interpretado como um tensor de valores reais. As funções são interpretadas como funções reais ou operações tensorais. Os predicados são interpretados como funções ou operações tensorais projetadas em um valor no intervalo $[0, 1]$. A semântica dos conectivos é definida de acordo com a semântica da lógica fuzzy de primeira ordem. (BADREDDINE et al., 2020).

Definição 6: Na *Lógica Real*, os símbolos são baseados em recursos de valor real. Uma fundamentação para uma linguagem lógica \mathcal{L} no conjunto de do-

mínios \mathcal{D} fornece a interpretação tanto dos símbolos de domínio em \mathcal{D} quanto dos símbolos não lógicos em \mathcal{L} .

Definição 7: Um aterramento \mathcal{G} associa a cada domínio $D \in \mathcal{D}$ um conjunto $\mathcal{G}(D) \subseteq \bigcup_{n_1 \dots n_d \in \mathbb{N}^*} \mathbb{R}^{n_1 \times \dots \times n_d}$. Para cada $D_1 \dots D_n \in \mathcal{D}^*$, $\mathcal{G}(D_1 \dots D_n) = \times_{i=1}^n \mathcal{G}(D_i)$, isto é $\mathcal{G}(D_1) \times \mathcal{G}(D_2) \times \dots \times \mathcal{G}(D_n)$. Observe que os elementos em $\mathcal{G}(D)$ podem ser tensores de qualquer classificação d e quaisquer dimensões $n_1 \times \dots \times n_d$, como \mathbb{N}^* denota a estrela Kleene de \mathbb{N} .³

Definição 8: Um \mathcal{G} de base de \mathcal{L} é uma função definida na assinatura de \mathcal{L} que satisfaz as seguintes condições:

$\mathcal{G}(x) = \langle d_1 \dots d_k \rangle \in X_{i=1}^k \mathcal{G}(\mathbf{D}(x))$ para cada símbolo de variável $x \in \mathcal{X}$, com $k \in \mathbb{N}_0^+$. Observe que $\mathcal{G}(x)$ é uma sequência e não um conjunto, o que significa que o mesmo valor de $\mathcal{G}(\mathbf{D}(x))$ pode ocorrer múltiplas vezes em $\mathcal{G}(x)$, como é usual em um conjunto de dados de *Machine Learning* com "atributos" e "valores";

$\mathcal{G}(f) \in \mathcal{G}(\mathbf{D}_{\text{in}}(f)) \rightarrow \mathcal{G}(\mathbf{D}_{\text{out}}(f))$ para cada símbolo de função $f \in \mathcal{F}$;

$\mathcal{G}(p) \in \mathcal{G}(\mathbf{D}_{\text{in}}(p)) \rightarrow [0, 1]$ para cada símbolo de predicado $p \in \mathcal{P}$.

Definição 9: Seja $\mathbf{t}(x_1, \dots, x_n)$ uma sequência $t_1 \dots t_m$ de m termos contendo n variáveis distintas x_1, \dots, x_n . Deixe cada termo t_i em \mathbf{t} conter n_i variáveis $x_{j_{i1}}, \dots, x_{j_{in_i}}$.

$\mathcal{G}(\mathbf{t})$ é um tensor com dimensões $(|\mathcal{G}(x_1)|, \dots, |\mathcal{G}(x_n)|)$ tal que o elemento deste tensor indexado por k_1, \dots, k_n , escrito como $\mathcal{G}(\mathbf{t})_{k_1 \dots k_n}$, é igual à concatenação de $\mathcal{G}(t_i)_{k_{j_{i1}} \dots k_{j_{in_i}}}$ por $1 \leq i \leq m$;

$\mathcal{G}(f(\mathbf{t}))_{i_1 \dots i_n} = \mathcal{G}(f)(\mathcal{G}(\mathbf{t})_{i_1 \dots i_n})$, ou seja, a aplicação elemento a elemento de $\mathcal{G}(f)$ a $\mathcal{G}(\mathbf{t})$;

$\mathcal{G}(p(\mathbf{t}))_{i_1 \dots i_n} = \mathcal{G}(p)(\mathcal{G}(\mathbf{t})_{i_1 \dots i_n})$, ou seja, a aplicação elemento a elemento de $\mathcal{G}(p)$ a $\mathcal{G}(\mathbf{t})$.

Definição 10: A semântica dos conectivos é definida de acordo com a semântica da lógica fuzzy de primeira ordem. Conjunção (\wedge), disjunção (\vee), implicação (\rightarrow) e negação (\neg) estão associadas, respectivamente, a uma norma t (T), uma t -norma conformidade (S), uma implicação difusa (I) e uma negação difusa (N) operação FuzzyOp $\in \{T, S, I, N\}$.

Definição 11: Sejam ϕ e ψ duas fórmulas com variáveis livres x_1, \dots, x_m e y_1, \dots, y_n , respectivamente. Suponhamos que as primeiras variáveis k sejam comuns a ϕ e ψ . Lembre-se de que \diamond e \circ denotam o conjunto de conectivos unários e binários, respectivamente.

Definição 12: A semântica dos quantificadores ($\{\forall, \exists\}$) é definida com o uso de agregação. Seja Agg um operador de agregação simétrico e contínuo, $\text{Agg} : \bigcup_{n \in \mathbb{N}} [0, 1]^n \rightarrow [0, 1]$. Para cada fórmula ϕ contendo x_1, \dots, x_n variáveis livres, suponha, sem perda de generalidade, que a quantificação se aplica às primeiras variáveis h .

Definição 13 (Teoria/Base de Conhecimento): (BADREDDINE et al., 2020). Uma teoria da Lógica Real é um triplo $\mathcal{T} = \langle \mathcal{K}, \mathcal{G}(\cdot \mid \theta), \Theta \rangle$, onde \mathcal{K} é um conjunto de fórmulas lógicas fechadas de primeira ordem definidas no conjunto de símbolos $S = D \cup X \cup C \cup F \cup P$ denotando, respectivamente, domínios, variáveis, constantes, símbolos de funções e predicados; $\mathcal{G}(\cdot \mid \theta)$ é um par aterramento amétrico para todos os símbolos $s \in S$ e todos os operadores lógicos; e $\Theta = \{\Theta_s\}_{s \in S}$ é o espaço de hipóteses para cada conjunto de parâmetros θ_s associado ao símbolo s . O aprendizado e o raciocínio em uma teoria de Lógica Real estão ambos associados à busca e aplicação do conjunto de valores dos parâmetros θ do espaço de hipóteses Θ que maximizam a satisfação das fórmulas em \mathcal{K} . A satisfatibilidade de uma teoria $\mathcal{T} = \langle \mathcal{K}, \mathcal{G}_\theta \rangle$ em relação ao operador agregador SatAgg é definida como $\text{SatAgg}_{\phi \in \mathcal{K}} \mathcal{G}_\theta(\phi)$.

No campo do Processamento de Linguagem Natural (PNL), as LTNs poderiam

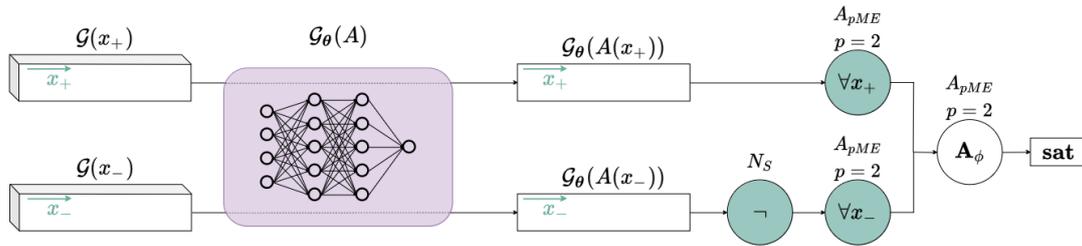
ser empregadas para tarefas de análise semântica, que envolvem o mapeamento de sentenças de linguagem natural para formas lógicas. Esta aplicação pode auxiliar muito no esclarecimento da semântica do texto. Além disso, as capacidades das LTNs estendem-se a tarefas como previsão de links e resolução de entidades, que são essenciais para identificar ou eliminar a ambiguidade de entidades. Eles podem desempenhar um papel fundamental na aprendizagem ou no alinhamento de ontologias, um esforço crucial para aplicações relacionadas à web semântica e outros domínios que requerem representação estruturada de conhecimento.

No domínio da robótica, as LTNs mostram-se promissoras para tarefas de planejamento e controle que se beneficiam de uma representação lógica do ambiente e das tarefas. Da mesma forma, no campo da bioinformática, eles poderiam ser empregados para modelar redes biológicas ou analisar dados biológicos de maneira logicamente consistente. Para tarefas de raciocínio de bom senso que exigem que as máquinas raciocinem de maneira semelhante aos humanos para compreender e navegar no mundo, as LTNs podem ser valiosas.

Além disso, em cenários que envolvem verificação e validação, especialmente em sistemas críticos de segurança, onde a consistência lógica e a conformidade com as especificações são de extrema importância, as LTNs são particularmente relevantes. Finalmente, no domínio dos sistemas de recomendação, a utilização de LTNs para capturar relações entre entidades como utilizadores e itens de uma forma mais estruturada tem o potencial de melhorar o desempenho. Na figura 4.1 é mostrado um exemplo de uso da LTN (BADREDDINE et al., 2020, tradução nossa):

Estamos, portanto, interessados em aprender os parâmetros θ do MLP usados para modelar o classificador binário. Amostramos 100 pontos de dados uniformemente de $[0, 1]^2$ para preencher o conjunto de dados de exemplos positivos e negativos. O conjunto de dados foi dividido em 50 pontos de dados para treinamento e 50 pontos para teste. O treinamento foi realizado para um número fixo de 1000 épocas utilizando retropropagação com o otimizador Adam com tamanho de lote de 64 exemplos. A figura 4.2 mostra a precisão da classificação e o nível de satisfação do LTN nos conjuntos de treinamento e teste, com média de 10 execuções usando um intervalo de confiança de 95%. A precisão mostrada é a proporção de exemplos classificados corretamente, sendo um exemplo considerado positivo se o classificador gerar um valor superior a 0,5. Observe que um modelo pode atingir uma precisão de 100% enquanto a satisfação da base de conhecimento ainda não é maximizada. Por exemplo, se o limite para um exemplo ser considerado positivo for 0,7, todos os exemplos poderão ser classificados corretamente com uma pontuação de confiança de 0,7. Nesse caso, embora a precisão já esteja maximizada, a satisfação de $\forall x_+ A(x_+)$ ainda seria 0,7 e ainda pode melhorar até que a confiança para cada amostra atinja 1,0.

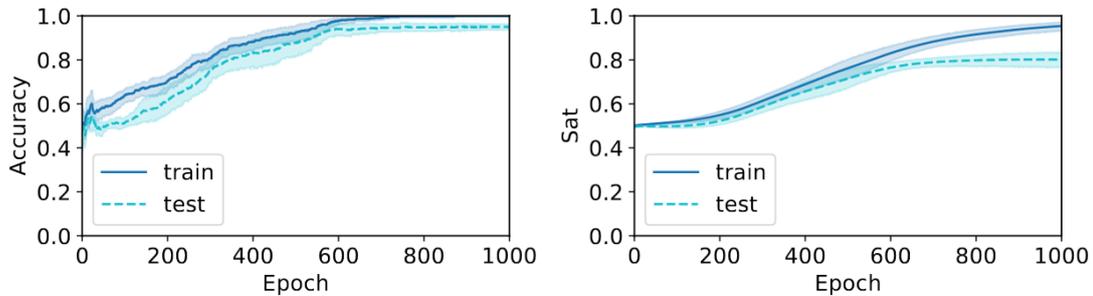
Figura 4.1: Exemplo de modelagem de problemas em LTN.



"Grafo computacional de tensor simbólico para o exemplo de classificação binária. Na figura, $\mathcal{G}x_+$ e $\mathcal{G}x_-$ são entradas para a rede $\mathcal{G}_\theta(A)$ e as linhas pontilhadas indicam a propagação da ativação de cada entrada através da rede, o que produz duas saídas" (BADREDDINE et al., 2020, tradução nossa).

Fonte: (BADREDDINE et al., 2020).

Figura 4.2: Exemplo de modelagem de problemas em LTN - Precisão e satisfatibilidade médias.



"Tarefa de classificação binária (desempenho do conjunto de treinamento e teste): Precisão média (esquerda) e satisfatibilidade (direita). Devido às inicializações aleatórias, a precisão e a satisfatibilidade começam em média em 0,5 com o desempenho aumentando rapidamente depois de algumas épocas" (BADREDDINE et al., 2020, tradução nossa).

Fonte: (BADREDDINE et al., 2020).

Através das LTNs, tarefas complexas de raciocínio tradicionalmente relegadas ao domínio da lógica simbólica podem agora ser abordadas com a vantagem adicional de aprender a partir dos dados. Isto não só abre caminho para aplicações de IA mais sofisticadas, mas também conduz potencialmente ao desenvolvimento de sistemas de IA mais robustos e adaptáveis.

A "Real Logic", conforme discutida no contexto da LTN, representa uma evolução da lógica de primeira ordem tradicional ao incorporar capacidades diferenciais e lidar com valores contínuos. Enquanto a lógica de primeira ordem clássica é fundamentalmente discreta e baseada em predicados que operam sobre objetos discretos e quantificadores universais/existenciais, a Real Logic estende esse formalismo para incluir suporte a diferenciação contínua e valores reais. Isso significa que além de lidar com afirmações sobre a verdade ou falsidade de proposições, a Real Logic pode expressar e manipular

relações e inferências que dependem de valores numéricos contínuos e de suas variações.

5 REDES TENSORIAIS LÓGICAS TEMPORAIS (T-LTN): MÉTODOS, RESULTADOS E ANÁLISES

Na LTN, os problemas são modelados logicamente através da composição de predicados lógicos. Os predicados podem ser construídos usando funções Lambda ou redes neurais. Eles retornam um valor de verdade difuso (*fuzzy*) para cada entrada de predicado, indicando o grau de verdade do predicado para uma determinada entrada. As funções Lambda são melhores para pequenas operações matemáticas que não requerem treinamento. Por exemplo, $getTime(x)$, usado na modelagem do Problema do Jantar dos Filósofos, mostrado neste capítulo, é um exemplo de predicado composto por uma função lambda que recebe um vetor de 3 elementos (que representa o estado do filósofo) e retorna o último elemento da matriz que corresponde ao tempo da última mudança de estado do filósofo.

As redes neurais em predicados LTN são treinadas de forma neuro-simbólica, ou seja, axiomas lógicos compõem a definição lógica de cada predicado. As entradas das redes neurais (predicados) são tensores na LTN. E de acordo com a saída da rede é calculada a *satisfatibilidade* dos axiomas lógicos que modelam o predicado, no qual satisfatibilidade é um valor fuzzy no intervalo $[0..1]$ de acordo com a satisfação dos axiomas que compõem as regras de o problema modelado. A partir deste erro (*1 menos satisfatibilidade*), os pesos da rede neural são ajustados.

Portanto, predicados pré-treinados podem ser usados para modelar outros predicados. A partir deste princípio, a LTN foi estendida à aprendizagem e ao raciocínio temporal, incluindo o tempo distribuído. Por exemplo, o predicado *before* (antes) é um predicado LTN pré-treinado. O T-LTN consiste em estender o LTN com a adição de predicados \mathcal{P} que representam operadores temporais.

A seguir, define-se formalmente o predicado *before*, usado para estender a LTN.

Definição 14 O predicado *before* denota o operador temporal 'antes de', $before(A, B)$, e indica que A acontece no tempo estritamente antes de B . na T-LTN, $before(A, B)$ gera um valor difuso próximo de 1 se A ocorrer antes de B e um valor mais próximo de zero caso contrário.

O predicado *before* recebe como entrada duas variáveis (A e B) que representam o respectivo *timestamp* dos objetos em análise e a saída é um verdadeiro valor fuzzy se A ocorreu antes de B . Os axiomas para modelar o predicado *before* (e calcular o erro) consistem em: se A ocorre antes B , então $before(A, B)$ mapeia para um valor fuzzy verdadeiro;

caso contrário, deverá mapear para um valor falso difuso.

Além disso, pode-se criar uma função lambda que retorne a hora de um objeto. Por exemplo, dada a modelagem de um objeto na LTN, pode-se criar a função $getTime(object)$ que obtém o horário em que o objeto executou determinada ação. O tempo discreto foi usado majoritariamente neste trabalho.

Na lógica temporal, podemos definir o operador “*depois*” em termos do predicado “antes” usando negação e disjunção temporal. O operador “depois” indica que um evento ocorre após outro evento. Se denotarmos “depois” como A e “antes” como B , então podemos expressar “A depois de B” da seguinte forma:

$$A \text{ depois } B \equiv \neg(A \text{ antes } B) \wedge \neg(A = B)$$

Esta definição pode ser explicada da seguinte forma:

$\neg(A \text{ antes } B)$: Isso significa que não é o caso de A ocorrer antes de B .

$\neg(A = B)$: Isso garante que A e B não ocorram simultaneamente, ou seja, não são o mesmo evento.

Assim, quando $\neg(A \text{ antes } B)$ e $\neg(A = B)$ são verdadeiros, podemos concluir que A ocorre depois de B .

Para representar a igualdade (“*igual*”) apenas com o predicado “antes”, podemos usar uma combinação de negação e conjunção temporal. Se denotarmos a igualdade como $A = B$, onde A e B são eventos, podemos expressar “A é igual a B” da seguinte forma:

$$A = B \equiv \neg(A \text{ antes } B) \wedge \neg(B \text{ antes } A)$$

Esta definição pode ser explicada da seguinte forma:

$\neg(A \text{ antes } B)$: Isso significa que não é o caso de A ocorrer antes de B .

$\neg(B \text{ antes } A)$: Isso significa que não é o caso de B ocorrer antes de A .

Assim, quando $\neg(A \text{ antes } B)$ e $\neg(B \text{ antes } A)$ são verdadeiros, podemos concluir que A e B ocorrem simultaneamente, o que significa que são iguais.

Expressar o operador “depois” em termos do predicado “antes” usando negação e conjunção temporal oferece uma vantagem significativa na representação de relações temporais entre eventos na lógica temporal. Esta abordagem permite uma definição mais concisa e formal das relações de eventos, simplificando a lógica necessária para expressar essas relações. Além disso, ao utilizar predicados simples como “antes” e “igual”,

fica mais claro o entendimento das relações temporais, facilitando a interpretação dos resultados. A representação em termos de “antes” também pode ser implementada mais facilmente em sistemas de lógica temporal, aproveitando o suporte existente para predicados básicos. Em resumo, ao converter o operador "depois" no predicado "antes", as expressões temporais tornam-se mais claras, mais concisas e formais, ao mesmo tempo que simplificam a sua implementação em sistemas de lógica temporal.

O predicado *before*, em T-LTN, consiste em uma rede neural perceptron que recebe 2 valores de entrada e é composta por 5 camadas com respectivamente 2, 10, 15, 15 e 1 neurônios respectivamente. A rede foi treinada com um conjunto de dados de 64 estados divididos entre *after* e *before*. Após 100 épocas de treinamento (através da satisfatibilidade dos axiomas lógicos que modelam o predicado), obteve-se 100% de acerto na validação cruzada. Os dados utilizados para o treinamento dos predicados na T-LTN consistem em conjuntos de valores de entrada e a saída fuzzy esperada do predicado para cada entrada. Estes dados foram gerados algoritmicamente.

Nas próximas seções, será discutida a modelagem da computação clássica em T-LTN envolvendo tempo e será mostrado como o raciocínio temporal e o aprendizado são obtidos na T-LTN. Adicionamos predicados temporais em LTN através de predicados compostos por redes neurais e treinados através de axiomas lógicos da semântica de cada operador. Podemos encadear vários predicados *before*, por exemplo, através do uso de operadores lógicos de primeira ordem.

5.1 O Problema do Jantar dos Filósofos

Para ilustrar que a T-LTN é capaz de aprender e raciocinar sobre eventos simultâneos que envolvem a noção de tempo como uma dimensão relevante, optou-se por modelar o clássico Problema do Jantar dos Filósofos (DIJKSTRA, 1971). Isto servirá para ilustrar a robustez da T-LTN na resolução de problemas temporais num modelo neuro-simbólico, o que contribui para a interpretabilidade do modelo. Ainda, mostrar-se-á a simplicidade do desenvolvimento de axiomas temporais em T-LTN e como esta estrutura pode resolver problemas escaláveis temporais de forma simples.

O Problema do Jantar dos Filósofo afirma que começa-se com K filósofos sentados ao redor de uma mesa circular com um garfo entre cada par de filósofos. Há um garfo entre cada filósofo. Um filósofo pode comer se conseguir pegar os dois garfos adjacentes a ele. Um garfo pode ser pego por qualquer um dos vizinhos adjacentes, mas não por

ambos. O problema do jantar dos filósofos é um exemplo de problema frequentemente usado no projeto de algoritmos paralelos e sistemas de software distribuídos para ilustrar problemas de sincronização e técnicas para analisá-los e resolvê-los.

A figura 5.1 mostra de forma simplificada a modelagem do problema do jantar dos filósofos na T-LTN. Problemas reais são modelados através de tensores, que representam propriedades, características ou estados do respectivo problema. Para modelar o problema, representou-se cada filósofo como um vetor de três elementos, de modo que o primeiro elemento representa se o filósofo quer comer e o segundo elemento representa se o filósofo está comendo. O terceiro elemento contém o *timestamp* da última mudança de estado do filósofo. O estado global é representado por uma lista de vetores de tamanho K , onde K é o número de filósofos.

O tempo é representado discretamente por uma variável numérica inteira global. Isto facilita a simulação de eventos simultâneos em problemas que envolvem controle temporal distribuído.

Os tensores que modelam o estado do problema são as entradas para os predicados na T-LTN. Desenvolveu-se três predicados lambda cujo domínio é o estado global dos filósofos. Os predicados retornam um valor verdade difuso. O predicado lambda *wantEat()* expressa se um filósofo quer comer, o predicado lambda *eating()* expressa se o filósofo está comendo e o predicado lambda *getTime()* retorna o *timestamp* da última mudança de estado do filósofo. A variável *filósofo*, denotada por P , representa o filósofo que está analisando se pode comer e *left(Philosopher)* (denotado por L) e *right(Filósofo)* (denotado por R) o filósofo à esquerda e à direita do filósofo, respectivamente.

Os predicados em LTN, entre outras abordagens, podem ser desenvolvidos por redes neurais perceptron cuja função de erro consiste na satisfação de axiomas lógicos que modelam o comportamento esperado do predicado. Por exemplo, o predicado *hasDeadlock* foi modelado usando axiomas lógicos que modelam casos nos quais há um impasse no Problema do Jantar dos Filósofos como três filósofos (P, L e R) querendo comer simultaneamente. Usou-se o predicado *wantEat* para compor axiomas no predicado *hasDeadlock*. A figura 5.2 mostra a variação do erro durante o treinamento do predicado *hasDeadlock*.

E esta é a ideia central da T-LTN ao estender o LTN: uma vez definido um predicado temporal (*antes*, por exemplo), podemos usar este predicado para compor outros predicados. Então o T-LTN torna-se capaz de aprender e raciocinar sobre problemas que envolvem modelagem temporal.

O principal predicado para o problema do jantar dos filósofos é *canEat*, que consiste em uma rede perceptron multicamadas que retorna um valor difuso no intervalo [0..1] correspondente ao valor verdadeiro se o filósofo puder comer. Considerou-se como verdadeiros predicados com valores de verdade maiores ou iguais a 0,7.

O predicado *canEat* foi construído como uma rede neural perceptron e necessita do predicado *hasDeadlock* previamente treinado para modelar seus axiomas. O predicado *hasDeadlock* tem como objetivo detectar se existe um deadlock no estado atual em análise. Por exemplo, se *P*, *L* e *R* estão esperando um pelo outro para comer, há um impasse. No predicado *canEat*, o impasse, quando ocorre, é resolvido com a ajuda do predicado temporal *before*, que escolhe o filósofo que está esperando há mais tempo para comer para ser desbloqueado. Com a adição de axiomas temporais é possível não apenas que o predicado *canEat* (uma rede neural) resolva o impasse, mas também evite a ocorrência de fome.

A entrada na rede neural do predicado *canEat*, assim como a maioria dos predicados neste trabalho, não recebe o estado total do problema na forma bruta, mas sim em uma forma pré-processada. Isso simplifica o desenvolvimento e o treinamento do modelo, bem como diminui a complexidade da rede neural. Outra consequência disso é que, sem modificações nos predicados, o sistema é escalável para gerenciar qualquer número de filósofos.

Dois outros predicados foram criados para gerenciar a mudança de estado dos filósofos de acordo com os predicados anteriores. Além disso, são responsáveis por controlar quanto tempo um filósofo permanece comendo ou esperando para comer. Os problemas são *eatingManager* e *wantEatManager* que decidem quando um filósofo começa a querer comer ou quando ele começa/termina de comer.

Para exemplificar a modelagem de um predicado, mostra-se a seguir alguns dos axiomas da modelagem lógica do predicado que gerencia se um filósofo pode comer:

$$\begin{aligned} & \text{Not}(\text{eating}(R)) \wedge \text{Not}(\text{eating}(L)) \wedge \\ & \text{Not}(\text{eating}(P)) \wedge \text{hasDeadlock}(\text{stateDeadlock}) \\ & \wedge \text{wantEat}(P) \wedge \text{canEat}(\text{state}) \end{aligned}$$

$$\begin{aligned}
& \text{Not}(\text{eating}(R)) \wedge \text{Not}(\text{eating}(L)) \wedge \\
& \text{Not}(\text{eating}(P)) \wedge \text{hasDeadlock}(\text{stateDeadlock}) \\
& \quad \wedge \text{before}(P, L) \wedge \text{before}(P, R) \\
& \quad \wedge \text{wantEat}(P) \wedge \text{canEat}(\text{state}) \\
& \\
& (\text{eating}(R) \vee \text{eating}(L)) \vee \\
& \text{eating}(P) \vee \text{eating}(P) \vee \text{Not}(\text{wantEat}(P)) \\
& \quad \vee (\text{hasDeadlock}(\text{stateDeadlock}) \\
& \quad \wedge \text{before}(P, L) \wedge \text{before}(P, R)) \\
& \quad \wedge \text{Not}(\text{canEat}(\text{state}))
\end{aligned}$$

5.2 O Problema do Jantar dos Filósofos em Evolução

O Problema do Jantar dos Filósofos em Evolução representa uma expansão dinâmica de um problema clássico no campo da ciência da computação, conhecido como o Problema do Jantar dos Filósofos. Originalmente concebido por Edsger W. Dijkstra em 1965, este problema serve como uma alegoria para os desafios de alocação de recursos e sincronização de processos em um ambiente *multithread*. Na versão padrão, cinco filósofos sentam-se ao redor de uma mesa, cada um com um prato de espaguete e um garfo colocado entre eles. O problema é que cada filósofo precisa de dois garfos para comer, criando assim uma situação em que a partilha de recursos e a prevenção de impasses se tornam cruciais. No Problema do Jantar dos Filósofos em Evolução considera-se a adição de um novo filósofo (nascimento) e a exclusão de um filósofo existente (morte).

À medida que a tecnologia avançou e os problemas computacionais se tornaram mais complexos. O Problema do Jantar dos Filósofos em Evolução adapta o cenário clássico para refletir os desafios modernos da ciência da computação, como sistemas distribuídos e processamento em tempo real. Esta evolução não apenas testa os limites das soluções tradicionais, como *mutex* e semáforos, mas também exige a exploração de novas abordagens e algoritmos.

Ao explorar o Problema do Jantar dos Filósofos em Evolução percebe-se que a simplicidade do problema original é expandida para abordar as complexidades dos ambientes de computação contemporâneos. Isto mostra a natureza em constante mudança da ciência da computação, na qual problemas antigos são reinventados para acompanhar o avanço da tecnologia. Esta evolução não só fornece informações sobre as complexidades da sincronização de processos e gestão de recursos em sistemas modernos, mas também serve como uma ponte que liga as teorias fundamentais da ciência da computação com as suas aplicações práticas no mundo digital de hoje. De acordo com (KRAMER; MAGEE, 1990, tradução nossa),

Um dos maiores desafios no fornecimento de serviços distribuídos sistemas é a acomodação da mudança evolutiva. Isto pode envolver modificações ou extensões do sistema que não foram previstas em tempo de *design*. Além disso, em muitos domínios de aplicação existe um requisito de que o sistema acomode tal mudança dinamicamente, sem parar ou perturbar a operação dessas partes do sistema não afetadas pela mudança.

No Problema do Jantar dos Filósofos em Evolução, considera-se a adição de um novo filósofo (nascimento) e a exclusão de um filósofo existente (morte). A condição necessária para o nascimento ou morte de um filósofo é que seus vizinhos estejam em estado passivo, ou seja, o filósofo não deve se envolver ou criar transações no estado passivo. Assim, desenvolveu-se um predicado que identifica se um filósofo e seus vizinhos estão no estado passivo.

A solução assemelha-se à do clássico problema do jantar dos filósofos, com a diferença de que os filósofos devem entrar num estado passivo quando solicitados a incluir ou excluir um filósofo ao seu lado. O predicado responsável por analisar se os filósofos envolvidos na morte ou nascimento de outro filósofo estão no estado passivo é *arePassiveNeighbors*.

A solução para este problema também é generalizada para vários filósofos e mostra que o T-LTN é capaz de resolver problemas temporais distribuídos e/ou em constante mudança.

5.3 O Problema das Crianças Enlameadas

Outro problema que resolveu-se na T-LTN é o Problema das Crianças Enlameadas. De acordo com (FEDYANIN, 2017), modelos formais de raciocínio ou conhecimento de pessoas sobre o raciocínio ou conhecimento de outras pessoas são geralmente chama-

dos de modelos epistêmicos ou modelos de reflexão. Esses modelos podem ser aplicados em muitos campos. Por exemplo, o serviço de segurança não deve ignorar o raciocínio e o conhecimento de potenciais intrusos e especialmente seu raciocínio e conhecimento sobre raciocínio e conhecimento dos serviços de segurança. Outro exemplo é a incorporação explícita ou implícita em um modelo de comportamento de um robô, modelos de comportamento de outros agentes (com base no raciocínio e no conhecimento).

Ainda segundo (FEDYANIN, 2017, tradução nossa), a história básica do problema é a seguinte: "Três crianças têm rostos enlameados e cada um pode ver os rostos dos outros, mas não seu próprio. Uma professora anuncia às crianças: "pelo menos um de você está com a cara enlameada". Aí ela pergunta: "Você sabe se seu rosto está enlameado ou não? Se sim, levante a mão". Nenhuma criança levanta a mão. Então, depois de algum tempo, a professora pergunta a mesma coisa, e novamente nenhuma criança levanta a mão. Mais algum tempo passa, e quando a pergunta é feita pela terceira vez, cada criança levanta a mão".

O estado global do problema é representado por um vetor binário, no qual cada elemento representa uma criança. Caso a criança não tenha lama, o valor da sua respectiva posição no vetor é zero; se a criança tiver lama na testa, o valor é um.

Para modelar esse problema foi criado o predicado *IhaveMud*, que decide se a criança tem lama na testa. Para modelar os axiomas e treinar a rede neural do predicado *IhaveMud* foi necessário criar predicados auxiliares que comparam se o tempo (passo) é maior, menor ou igual ao número de crianças com lama na testa. Além disso, a rede aprende através dos axiomas que, uma vez que a criança tenha certeza de que tem lama na testa, ela permanece com a certeza ao longo do tempo.

Tal como acontece com outros problemas, o tempo é discreto e inteiro. Cada tempo (1, 2, 3...) corresponde à rodada/etapa em que é perguntado às crianças se alguma delas tem certeza de que tem lama na testa.

A solução para o Problema das Crianças Enlameadas descrita neste trabalho pode ser generalizada para qualquer valor de n (número de crianças no total) e k (número de crianças com lama na testa).

5.4 Análises Experimentais

No campo da computação distribuída e dos sistemas multiagentes, o desenvolvimento de métodos eficazes para resolver problemas complexos e em constante mudança

é um esforço contínuo. Entre os vários desafios enfrentados, os problemas relacionados com a modelagem do tempo e da evolução são particularmente notáveis devido à sua complexidade e relevância prática. Ao combinar lógica temporal e redes de tensores, a abordagem deste trabalho oferece um método eficaz para trabalhar com as complexidades inerentes a cenários distribuídos e em evolução. Através da análise aprofundada de problemas clássicos como o Problema do Jantar dos Filósofos bem como de problemas mais dinâmicos como o Problema do Jantar dos Filósofos em Evolução e o Problema das Crianças Enlameadas, este estudo ilustra o potencial significativo da abordagem proposta no avanço da compreensão e resolução de problemas relacionados à modelagem temporal e da evolução.

O Problema do Jantar dos Filósofos, um desafio bem conhecido na computação distribuída, mostra a capacidade da metodologia de lidar com questões relacionadas a impasses e sincronização dentro de uma estrutura distribuída no tempo.

O Problema do Jantar dos Filósofos em Evolução introduz elementos dinâmicos, no qual os componentes e interações do sistema evoluem ao longo do tempo. A adaptabilidade desta metodologia a essas mudanças, ao mesmo tempo que garante um controle e entendimento das operações do sistema neuro-simbólico, destaca sua versatilidade e aplicabilidade prática.

Além disso, o estudo explora o problema das crianças enlameadas, um problema clássico que envolve conhecimentos distribuído em sistemas multiagentes. A aplicação da metodologia a este problema demonstra o seu potencial para desvendar as complexidades da disseminação de informação e do raciocínio colectivo em um ambiente distribuído. O uso da lógica temporal na metodologia permite uma compreensão e modelagem diferenciadas dos estados de conhecimento em evolução dos agentes, facilitando a resolução coerente do problema.

Em todos esses diversos domínios de problemas, os princípios básicos da metodologia de uso de lógica temporal e redes de tensores servem como uma estrutura robusta para decifrar interações em cenários distribuídos no tempo e em evolução. Ao analisar detalhadamente cada problema e mostrar suas capacidades de resolução de problemas, este estudo contribui significativamente para a compreensão e resolução de desafios na modelagem temporal e da evolução. Através de análises cuidadosas, este trabalho visa fornecer *insights* valiosos para discussões em computação distribuída e sistemas multiagentes, oferecendo caminhos potenciais para maior exploração e inovação.

Na Figura 5.3, destacada em azul, apresenta-se uma análise experimental deta-

lhada conduzida para avaliar a eficácia da metodologia proposta quando aplicada ao clássico Problema do Jantar dos Filósofos dentro da estrutura de Redes Tensionais Lógicas Temporais (T-LTN). Estas experiências cobrem uma ampla gama de cenários, envolvendo diferentes números de filósofos, desde um pequeno grupo de 5 até um conjunto substancial de 700. O objetivo principal desta investigação é determinar o tempo médio que cada filósofo passa comendo, oferecendo informações sobre como o sistema funciona em várias escalas.

Além disso, analisou-se o desvio padrão dos tempos em que os filósofos estavam comendo nesses diversos cenários. Esta medição fornece *insights* sobre a variabilidade e, conseqüentemente, a estabilidade do desempenho do sistema. Para garantir dados robustos para análise, cada cenário experimental passou por 100 repetições. Esta análise estatística fornece uma visão clara de como a metodologia proposta lida com os desafios inerentes apresentados pelo Problema do Jantar dos Filósofos particularmente no que diz respeito à resolução de impasses/*deadlocks*.

A Figura 5.3 fornece evidências convincentes da eficácia da metodologia proposta na resolução bem-sucedida do Problema do Jantar dos Filósofos. Um destaque importante dos resultados é a capacidade da metodologia de lidar e resolver habilmente impasses, um desafio bem conhecido na computação distribuída. Este resultado não só confirma a robustez da metodologia, mas também enfatiza o seu potencial como uma estrutura confiável para gerenciar e resolver problemas de sincronização e impasses em sistemas distribuídos. Através de uma análise estatística, a figura não só demonstra a capacidade da metodologia em resolver o problema com precisão, mas também a sua eficiência na navegação em cenários de impasse, abrindo caminhos promissores para aplicações mais amplas e complexas no campo da computação distribuída.

Ao abordar as complexidades inerentes ao Problema do Jantar dos Filósofos dentro da T-LTN, dois aspectos principais merecem destaque: escalabilidade e justiça. Estes aspectos não são apenas essenciais para garantir uma solução robusta para o problema em questão, mas também para estabelecer as bases para a aplicabilidade da metodologia a uma gama mais ampla de desafios de computação distribuída do mundo real.

A escalabilidade é exemplificada pela capacidade da solução T-LTN de manter um desempenho estável, mesmo quando o número de filósofos cresce de um grupo modesto de 5 para uma coorte substancial de 700. Esta consistência demonstra a capacidade da metodologia de lidar com uma escala crescente de operação sem uma diminuição proporcional no desempenho. A capacidade de sustentar um desempenho consistente à medida

que o número de filósofos aumenta é uma forte indicação do potencial da metodologia para ser utilizada em sistemas distribuídos de grande escala.

Por outro lado, a justiça é de extrema importância para garantir a alocação equitativa de recursos, neste caso, proporcionando a cada filósofo uma oportunidade justa de comer, minimizando assim os casos de fome e promovendo um funcionamento equilibrado do sistema. A importância da justiça vai além de um conceito teórico e estende-se ao domínio prático, onde a alocação equitativa de recursos é muitas vezes um requisito crítico.

Mesmo com muitos filósofos, não houve aumento significativo da fome. Isso ocorre porque o T-LTN usa lógica temporal para modelar os predicados para o Problema do Jantar dos Filósofos. A lógica temporal introduz um mecanismo de controle que garante justiça durante impasses. Neste sistema, o filósofo que esperou mais tempo sem comer ganha a próxima vez. Esta abordagem evita a fome e garante uma alocação equitativa de recursos.

A Figura 5.3, em cor laranja, apresenta uma análise comparativa que descreve o desempenho de uma abordagem baseada em semáforos¹ para gerenciar impasses no mesmo problema e cenários de teste. A abordagem do semáforo, um método tradicional para lidar com simultaneidade e impasses, serve como uma referência relevante para comparar o desempenho da solução T-LTN.

Portaneto, a escalabilidade e a justiça aprimoradas da T-LTN, conforme mostrado na Figura 5.3, têm implicações promissoras para aplicações práticas no gerenciamento de processos distribuídos. O uso da lógica temporal fornece uma solução dinâmica e justa para os desafios da computação distribuída, tornando o T-LTN uma ferramenta valiosa para sistemas distribuídos do mundo real.

A busca por clareza e compreensão no domínio das redes neurais, particularmente na decifração de interações complexas entre múltiplos agentes, é crucial. A metodologia proposta dá passos significativos nessa direção, garantindo que os predicados representados pelas redes neurais sejam claros e compreensíveis. Essa clareza é alcançada treinando as redes neurais com base em axiomas lógicos projetados para modelar cada situação específica.

A aplicação da T-LTN a problemas como o Jantar dos Filósofos em Evolução e o Problema das Crianças Enlameadas serve como uma demonstração convincente das capacidades desta metodologia. O T-LTN prova ser uma estrutura potente, capaz não apenas de

¹ <https://docs.python.org/3/library/threading.html#semaphore-objects>

aprender, mas também de raciocinar sobre processos distribuídos, multiagentes e em evolução à medida que se desenrolam ao longo do tempo. Esta capacidade de aprendizagem e raciocínio é fundamental no desenvolvimento de soluções robustas para os complexos desafios encontrados em ambientes de computação distribuída.

A Figura 5.4 apresenta experimentos conduzidos em vários cenários, envolvendo diferentes números de filósofos, variando de 10 a 700. É importante ressaltar que esses experimentos vão além de cenários estáticos; eles incorporam elementos dinâmicos nos quais há eventos de nascimento e morte durante a execução do experimento. Este aspecto dinâmico acrescenta uma camada adicional de complexidade, forçando a metodologia a adaptar-se e a gerir de forma eficiente a evolução.

A capacidade da T-LTN de lidar eficazmente com a dinâmica de nascimentos e mortes de filósofos, garantindo ao mesmo tempo um bom funcionamento do sistema, é uma prova da sua robustez. Esse recurso é especialmente vital porque reflete sistemas distribuídos do mundo real, nos quais os agentes frequentemente entram e saem do sistema de forma dinâmica. A capacidade de manter a estabilidade e a justiça em meio a essas mudanças dinâmicas mostra a adequação da metodologia.

Em síntese, a clara explicabilidade e interpretabilidade dos predicados, facilitada por axiomas lógicos, juntamente com a capacidade demonstrada da T-LTN de aprender e raciocinar sobre a evolução dos processos multiagentes, destacam o progresso significativo alcançado por esta metodologia. A Figura 5.4 enfatiza ainda mais essa narrativa ao mostrar a robustez e escalabilidade da metodologia, mesmo em situações de evolução dinâmica.

No vasto campo da inteligência artificial e dos sistemas multiagentes, a resolução de problemas lógicos serve como um método fundamental para descobrir as capacidades e restrições das metodologias propostas. Entre os vários problemas lógicos, o Problema das Crianças Enlameadas se destaca como um exemplo clássico de raciocínio multiagente, encapsulando a essência do raciocínio epistêmico dentro de uma comunidade de agentes. Este *puzzle*, mostra a distribuição de conhecimento e raciocínio colectivo entre os agentes.

O T-LTN surge como uma estrutura robusta que combina a precisão lógica da lógica temporal com as capacidades expressivas das redes tensores. Essa fusão cria uma plataforma poderosa capaz de modelar e raciocinar sobre cenários complexos e que evoluem no tempo, envolvendo vários agentes. A aplicação da T-LTN ao Problema das Crianças Enlameadas vai além da exploração acadêmica; representa uma investigação profunda que revela o potencial da T-LTN na navegação no complexo cenário do raciocínio multi-

agente.

O Problema das Crianças Enlameadas, enraizado na lógica epistêmica, apresenta um cenário em que um grupo de crianças se envolve em um raciocínio coletivo para determinar o estado de suas testas enlameadas. O *puzzle* revela uma rica complexidade de estados epistêmicos, questões e deduções que as crianças navegam para chegar a uma conclusão coletiva.

Usar o T-LTN para resolver o Problema das Crianças Enlameadas mostra parte da capacidade da T-LTN em modelar os estados epistêmicos dos agentes, acompanhando a evolução de seu conhecimento ao longo do tempo e facilitando o raciocínio coletivo. Os princípios lógicos que constituem a base da T-LTN fornecem uma estrutura robusta para representar os estados epistêmicos das crianças, formular as suas questões e articular as suas deduções. Além disso, as redes tensores dentro da LTN fornecem uma plataforma versátil e expressiva para capturar as interações sutis e a evolução dos estados de conhecimento entre as crianças.

Por exemplo, se uma criança (C_1) vê que nenhuma outra criança tem lama, isso implica que ela é a criança enlameada. O axioma abaixo modela isso. Neste caso foi utilizado o predicado *muddyIsee*, que não foi composto como uma rede neural, mas como uma função lambda que retorna o número de crianças com lama que a criança observadora está vendo. Ainda foi necessário um predicado auxiliar para identificar se o retorno de *muddyIsee* é zero, cuja interpretação é que C_1 não vê nenhuma criança com lama, se verdadeiro.

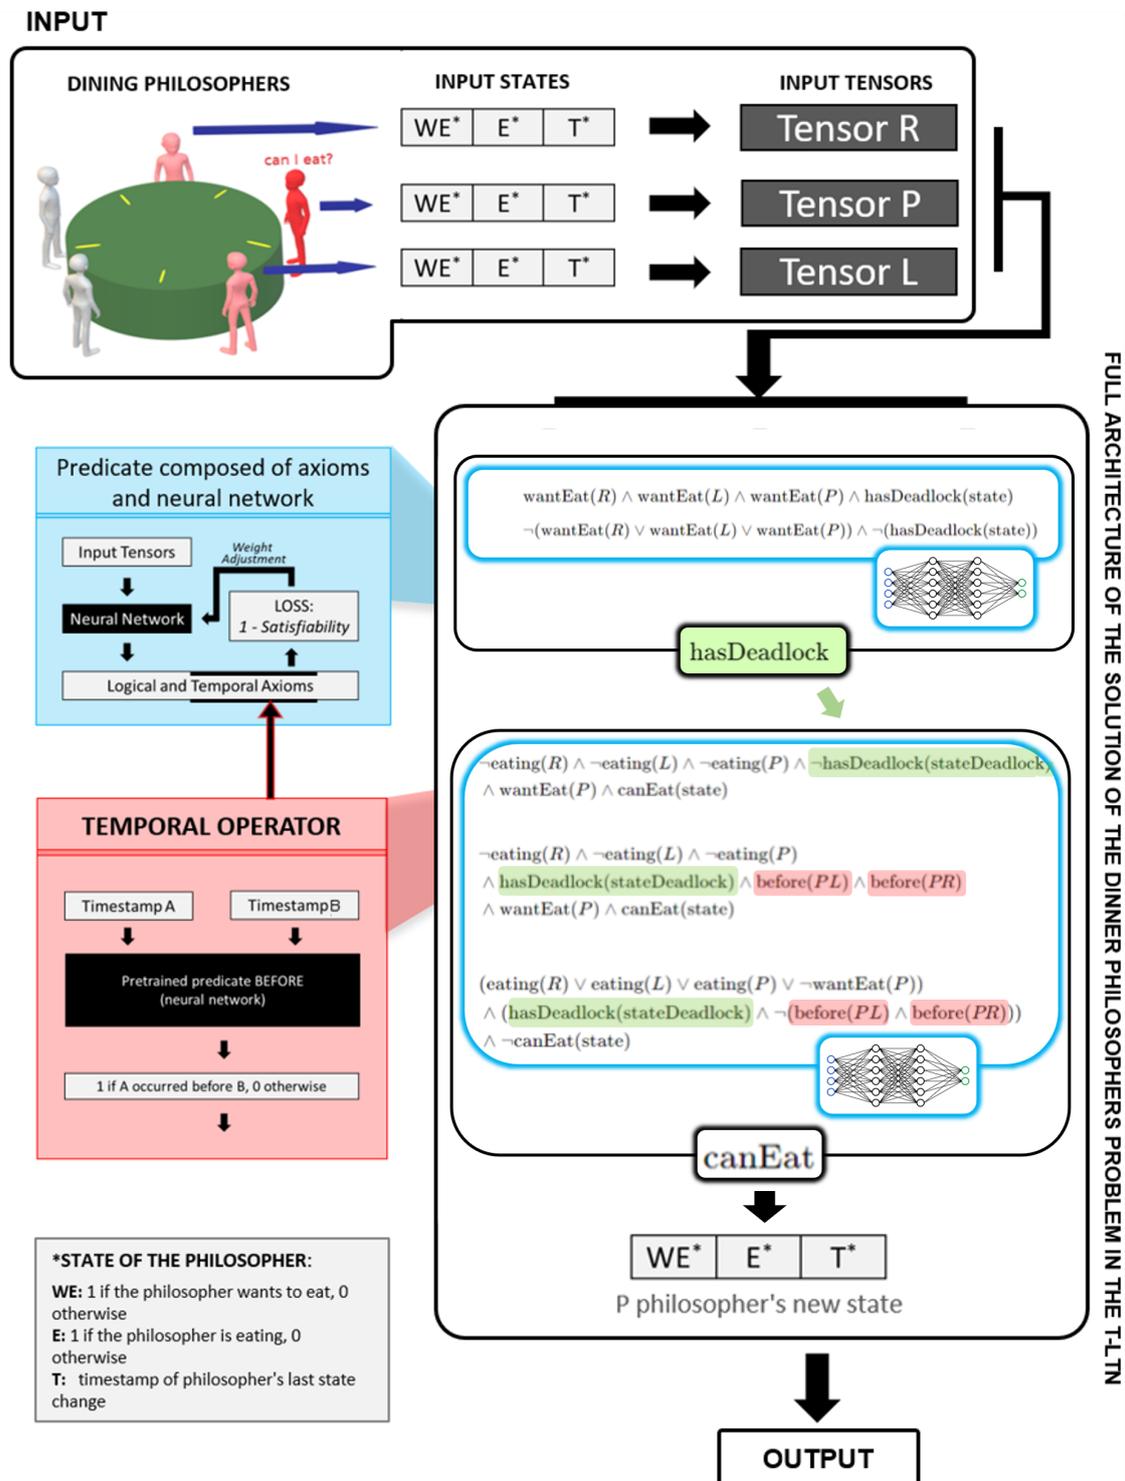
$$K_{C_1}(\text{noneMuddyIsee}(\text{muddyIsee}(\text{othersChildrenState}))) \\ \rightarrow \text{IhaveMud}(\text{inputState})$$

Este, juntamente com os demais axiomas que modelam o problema em questão, incluindo o uso de axiomas temporais para identificar as fases de resolução do problema, compõe o predicado *IhaveMud*. A figura 5.5 mostra a evolução do erro no treinamento da respectiva rede neural.

Além disso, a resolução bem-sucedida do Problema das Crianças Enlameadas com o T-LTN serve como uma forte evidência da competência da T-LTN em abordar as complexidades do raciocínio multiagente. Ele demonstra o potencial da T-LTN para oferecer soluções explicáveis e interpretáveis, o que é essencial para aplicações práticas nas quais é fundamental compreender o raciocínio por trás das decisões.

Em resumo, usar o T-LTN para resolver o Problema das Crianças Enlameadas representa um passo significativo na busca de trabalhar com as complexidades do raciocínio multiagente. Ele não apenas fornece uma solução eficaz para um problema clássico, mas também destaca o potencial da T-LTN como uma estrutura robusta para enfrentar uma ampla gama de desafios em sistemas multiagentes. Os conhecimentos obtidos com este esforço contribuem com informações valiosas para as discussões em curso no campo do raciocínio multiagente, abrindo caminho para uma maior exploração e inovação.

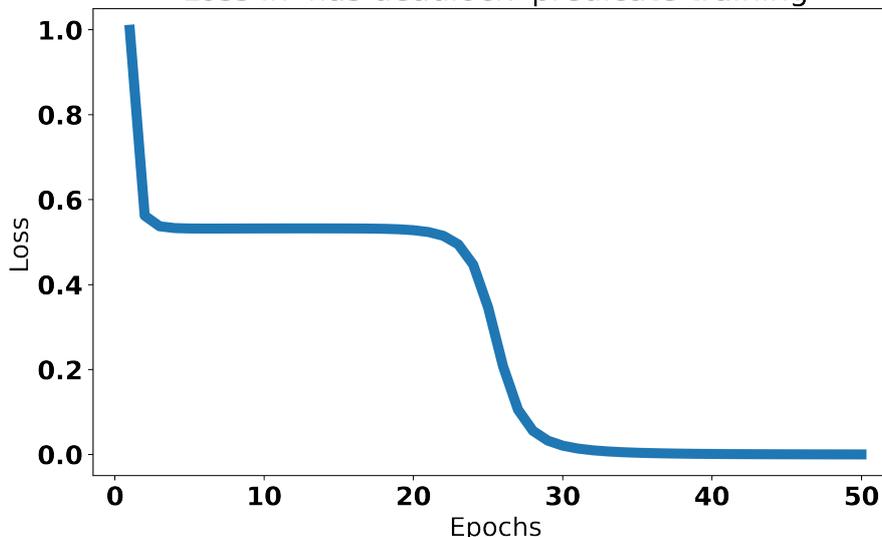
Figura 5.1: Problema do Jantar dos Filósofos na T-LTN.



No canto superior esquerdo da figura pode-se observar uma representação do problema do jantar dos filósofos, neste caso composto por cinco filósofos. O filósofo vermelho escuro quer comer. Assim, consulta a rede neural que tem como entrada seu respectivo estado (P), bem como dos filósofos à sua esquerda (L) e à sua direita (R). Pode-se observar a modelagem lógica do problema no lado direito da figura. Em azul, são mostrados predicados compostos por redes neurais, conforme mostrado no diagrama azul à esquerda. Em vermelho estão os operadores temporais cuja semântica está no quadro vermelho à esquerda. Esta é uma arquitetura de alto nível.

Fonte: O Autor.

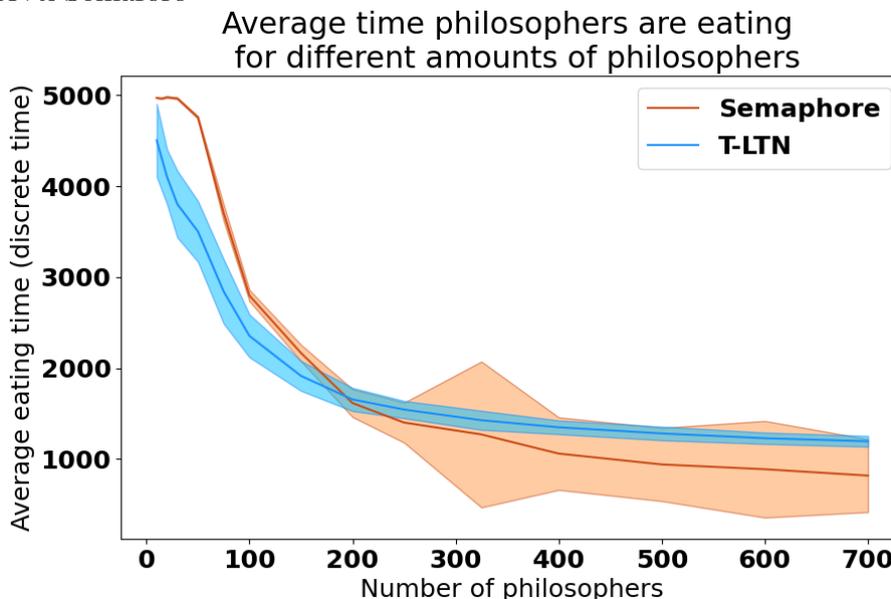
Figura 5.2: Variação do erro no treinamento do predicado 'hasDeadlock'.
Loss in 'has deadlock' predicate training



O predicado *hasDeadlock* tem como objetivo detectar um *deadlock*. Consiste em uma rede neural Perceptron treinada através da satisfação de axiomas lógicos que modelam o respectivo problema de detecção de deadlock para o problema do jantar dos filósofos. A rede é composta por 5 camadas com 3 entradas (tensores de estado dos filósofos) e, respectivamente, 10, 15, 15, 10 e 1 neurônios. O treinamento foi realizado por 50 épocas em um conjunto de dados de 1.728 estados de filósofos rotulados como deadlock ou não. A função de erro foi baseada na satisfatibilidade dos axiomas lógicos que modelam o predicado.

Fonte: O Autor.

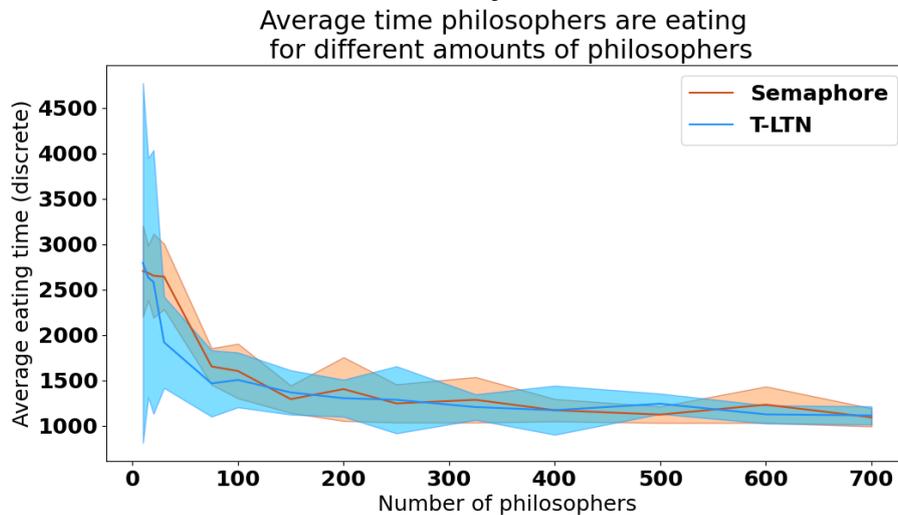
Figura 5.3: Tempo médio que os filósofos comem para diferentes quantidades de filósofos: T-LTN x Semáforo



Análise da variação do tempo que cada filósofo passou comendo em experimentos do Problema do Jantar dos Filósofos. A linha azul mostra o tempo médio que cada filósofo comeu e a área azul mostra o desvio padrão desse tempo quando gerenciado pelo T-LTN, usando tempo discreto. Para a mesma configuração, a linha e a área em laranja mostram o resultado para os filósofos gerenciados por semáforo.

Fonte: O Autor.

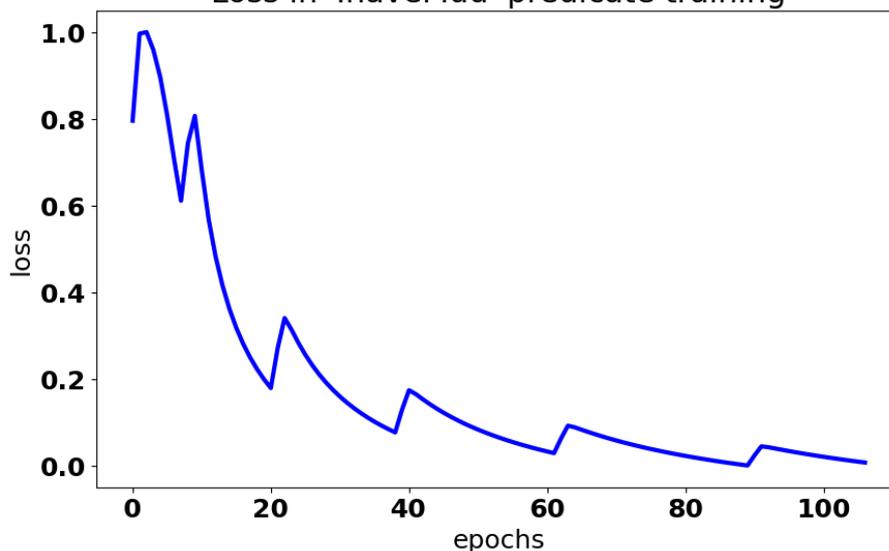
Figura 5.4: Tempo médio que os filósofos comem para diferentes quantidades de filósofos no Problema do Jantar dos Filósofos em Evolução



O tempo médio que os filósofos comeram para diferentes números de filósofos no Problema do Jantar dos Filósofos em Evolução. O número de filósofos indicado no gráfico é o inicial, pois neste problema os filósofos nascem e morrem durante a simulação. Além disso, os filósofos têm tempos de vida diferentes, portanto um filósofo pode nascer no início da simulação e outro pode nascer no último estágio da simulação e, portanto, não comer. A linha azul mostra o tempo médio que cada filósofo comeu e a área azul mostra o desvio padrão desse tempo quando gerenciado pelo T-LTN.

Fonte: O Autor.

Figura 5.5: Perda no treinamento do predicado 'IhaveMud'.
Loss in 'IhaveMud' predicate training



Varição do erro no treinamento do predicado *IhaveMud*.

Fonte: O Autor.

6 CONCLUSÕES E TRABALHOS FUTUROS

A aprendizagem e o raciocínio temporal são componentes vitais da IA neuro-simbólica, melhorando significativamente a modelagem e a resolução de vários desafios computacionais. Conforme demonstrado neste trabalho, isso é particularmente aplicável a problemas que envolvem sincronização sensível ao tempo e alocação distribuída de recursos, como o clássico Problema do Jantar dos Filósofos.

Redes de Tensores Lógicos (LTNs) apresentam uma estrutura robusta para aprendizagem e raciocínio neuro-simbólico. Ela permite o treinamento de redes neurais utilizando axiomas lógicos (lógica de primeira ordem). Os problemas são representados por meio desses axiomas lógicos, e o treinamento da rede neural é orientado pela avaliação da satisfatibilidade desses axiomas com base em cálculos de rede.

Mas a LTN não abordara adequadamente os conceitos de aprendizagem temporal. No entanto, está bem estabelecido que os problemas computacionais muitas vezes implicam a evolução do conhecimento, que é inerentemente de natureza temporal. Este estudo apresenta a T-LTN, uma estrutura projetada para facilitar o aprendizado e o raciocínio sobre o tempo.

No esforço para aprimorar a estrutura original das Redes de Tensores Lógicos (LTN), introduziu-se elementos de aprendizagem e raciocínio temporal incorporando operadores temporais construídos por meio de predicados LTN. Esta melhoria permite a modelagem de problemas complexos que envolvem inerentemente dimensões temporais dentro de uma estrutura recém-concebida, conhecida como Redes de Tensores Lógicos Temporais (T-LTN). A introdução de operadores temporais serve como uma ponte, conectando a natureza estática dos predicados lógicos tradicionais com a essência dinâmica das sequências temporais, melhorando assim as capacidades de representação e raciocínio da arquitetura LTN.

Esta inovação permite a inclusão de dependências e transições temporais, que muitas vezes são essenciais para uma compreensão abrangente e uma modelagem precisa de problemas complexos que envolvem dimensões temporais. Por exemplo, a estrutura T-LTN pode lidar eficazmente com cenários como modelagem de sequência de eventos, extração de relações temporais e processos de tomada de decisão sensíveis ao tempo.

A aprendizagem, um aspecto fundamental da estrutura LTN, mantém o seu papel central na T-LTN, permitindo que a rede se adapte e evolua com base nos dados temporais que encontra. A componente de aprendizagem da T-LTN é concebida não só para com-

preender as estruturas lógicas subjacentes, mas também para compreender a dinâmica temporal, levando a uma representação mais abrangente do problema em questão. Além disso, o mecanismo de aprendizagem está harmoniosamente integrado com os operadores temporais, garantindo que a base de conhecimento da rede evolua em sincronia com as complexidades temporais dos dados.

Ao fundir o raciocínio temporal com as capacidades de aprendizagem originais do LTN, a estrutura da T-LTN torna-se bem estruturada para resolver uma gama mais ampla de problemas. A incorporação de operadores temporais construídos através de predicados LTN é um avanço que amplia as capacidades do LTN, tornando-a um *framework* mais robusto e versátil, capaz de modelar problemas complexos envolvendo tempo. Esta fusão de tempo e lógica dentro de uma configuração de rede tensorial destaca o potencial para maior exploração e inovação no campo do raciocínio neuro-simbólico, oferecendo novos caminhos para pesquisa e aplicação em vários domínios, incluindo processamento de linguagem natural e robótica.

A estrutura T-LTN, com seu raciocínio temporal aprimorado e recursos de aprendizagem, representa um passo promissor na abordagem dos desafios colocados por problemas complexos entrelaçados com o tempo. Significa um progresso significativo no aproveitamento da sinergia entre a lógica simbólica, o raciocínio temporal e a aprendizagem automática, estabelecendo as bases para abordagens de resolução de problemas mais sofisticadas e diferenciadas no campo da inteligência artificial.

Certos problemas temporais apresentam um desafio único que exige o uso da lógica de primeira ordem (FOL) para resolução devido à sua intrincada dinâmica relacional e temporal. No entanto, uma melhoria notável na abordagem de tais problemas foi alcançada através da incorporação de predicados temporais. Esta inclusão aumenta significativamente a legibilidade e interpretabilidade dos axiomas que definem o problema. Esses axiomas, que são essenciais para descrever a estrutura e as restrições do problema, desempenham um papel vital no treinamento da rede neural para compreender e resolver o problema temporal de forma eficaz.

O uso de predicados temporais resulta em uma representação mais intuitiva das relações e dinâmicas temporais, tornando os axiomas mais acessíveis e fáceis de compreender. Consequentemente, esta simplificação tem um impacto positivo na facilidade com que estes axiomas podem ser empregados para treinar a rede neural, melhorando em última análise o processo de aprendizagem.

A demonstração prática da escalabilidade da T-LTN na abordagem de problemas

temporais destaca o seu potencial como uma ferramenta poderosa no campo do raciocínio e aprendizagem temporal. Esta abordagem se destaca por simplificar a representação de relações temporais, preservando ao mesmo tempo a precisão e expressividade da lógica de primeira ordem (FOL). Simultaneamente, garante um treinamento eficiente da rede neural para resolver o problema em questão. A combinação de legibilidade aprimorada, interpretabilidade aprimorada e escalabilidade estabelece a T-LTN como um avanço significativo no domínio do raciocínio neuro-simbólico, estabelecendo uma base sólida para maior exploração e aplicação na resolução de problemas temporais em vários domínios.

Neste trabalho, apresentou-se as soluções para três problemas clássicos de computação envolvendo tempo distribuído: o Problema do Jantar dos Filósofos, o Problema do Jantar dos Filósofos em Evolução e o Problema das Crianças Enlameadas. Destacou-se a clareza e interpretabilidade na modelagem desses problemas utilizando a T-LTN, enfatizando sua escalabilidade e versatilidade.

Além disso, demonstrou-se o desempenho da T-LTN no contexto de aprendizagem e raciocínio temporal distribuído e evolutivo. Isto serve como evidência da robustez da T-LTN no tratamento eficaz de problemas temporais.

A T-LTN tem várias aplicações potenciais em diferentes áreas, destacando-se especialmente pelo seu uso no raciocínio e aprendizado temporal. Um exemplo é a aplicação na robótica para tarefas de planejamento. Utilizando declarações lógicas temporais e habilidades de aprendizado da rede, a T-LTN pode contribuir significativamente para a criação de planos eficientes e logicamente sólidos para ações de robôs em ambientes dinâmicos. Em sistemas de monitoramento de pacientes, a T-LTN pode ajudar a analisar dados temporais, como sinais vitais e registros médicos ao longo do tempo, para prever crises de saúde ou a progressão de doenças. Na agricultura de precisão, a T-LTN pode ser utilizada para modelar dados temporais de crescimento das culturas, condições climáticas e práticas agrícolas. Isso ajuda a prever rendimentos de colheita e otimizar o uso de recursos como água e fertilizantes, melhorando a eficiência e a sustentabilidade agrícola.

Em trabalhos futuros, planeja-se testar a confiabilidade das Redes de Tensores Lógicos Temporais (T-LTN), aplicando-as a problemas do mundo real em vários campos. Objetiva-se demonstrar a eficácia da T-LTN através de diversas aplicações, proporcionando uma compreensão abrangente do seu potencial como uma ferramenta versátil para lidar com o raciocínio e a aprendizagem relacionados ao tempo. Uma área específica de interesse é a robótica, na qual a T-LTN pode ser usada para tarefas de planejamento. O uso da T-LTN para planejamento em robótica apresenta uma aplicação prática onde as

declarações lógicas temporais e as habilidades de aprendizagem da rede podem contribuir significativamente para a criação de planos eficientes e logicamente sólidos para ações do robô em ambientes dinâmicos.

Além disso, expandir-se-á a estrutura T-LTN adicionando mais instruções lógicas temporais. Espera-se que esta expansão amplie o alcance e a precisão do raciocínio temporal dentro da estrutura da T-LTN, aumentando assim a sua capacidade de modelar e resolver problemas temporais mais complexos. A inclusão de declarações lógicas temporais adicionais melhorará ainda mais a representação das relações e dinâmicas temporais, fornecendo uma estrutura mais detalhada e expressiva para o raciocínio temporal.

Além disso, planeja-se aprofundar o conceito de aprendizado e raciocínio em tempo ramificado, incorporando operadores temporais adicionais na estrutura T-LTN. O tempo ramificado envolve a consideração de múltiplos caminhos futuros possíveis, em contraste com o tempo linear, que assume uma única trajetória futura predeterminada. Ao introduzir o aprendizado e o raciocínio em tempo ramificado, o objetivo é capacitar a T-LTN para modelar e raciocinar sobre vários cenários futuros potenciais, melhorando muito sua aplicabilidade em domínios que exigem a consideração de vários resultados possíveis.

Além disso, esta extensão ao aprendizado e raciocínio em tempo ramificado introduzirá uma nova camada de capacidades de raciocínio temporal ao T-LTN, permitindo uma análise e compreensão mais sofisticadas de problemas temporais.

Em resumo, o próximo trabalho visa não apenas destacar a aplicabilidade prática da T-LTN em cenários do mundo real, mas também melhorar significativamente seu raciocínio temporal e habilidades de aprendizagem. Através da expansão de predicados e operadores lógicos temporais, juntamente com a exploração de aprendizagem e raciocínio de tempo ramificado, a estrutura T-LTN está preparada para evoluir para uma ferramenta mais sólida e versátil para resolver uma ampla gama de problemas temporais em diversos domínios.

REFERÊNCIAS

- AGGARWAL, G.; PARIKH, D. Neuro-symbolic generative art: A preliminary study. **ArXiv**, abs/2007.02171, 2020.
- ALLEN, J. F. Towards a general theory of action and time. **Artificial Intelligence**, v. 23, n. 2, p. 123–154, 1984. Available from Internet: <<https://www.sciencedirect.com/science/article/pii/0004370284900080>>.
- ANTONELLI, M. Kripke’s modal logic: A historical study. **Rivista di Storia della Filosofia**, 2018. Available from Internet: <<https://doi.org/10.13130/2037-4445/11081>>.
- BADER, S.; HITZLER, P. Dimensions of neural-symbolic integration - A structured survey. **CoRR**, abs/cs/0511042, 2005. Available from Internet: <<http://arxiv.org/abs/cs/0511042>>.
- BADREDDINE, S. et al. Logic tensor networks. **Artificial Intelligence**, v. 303, p. 103649, feb 2022.
- BADREDDINE, S. et al. Logic tensor networks. **CoRR**, abs/2012.13635, 2020. Available from Internet: <<https://arxiv.org/abs/2012.13635>>.
- BESOLD, T. R. et al. Neural-symbolic learning and reasoning: A survey and interpretation. In: _____. **Neuro-Symbolic Artificial Intelligence: The State of the Art**. [S.l.]: IOS Press, 2022.
- BISHOP, C. M. **Neural Networks for Pattern Recognition**. [S.l.]: Oxford University Press, 1995.
- BORGES, R.; GARCEZ, A. d.; LAMB, L. Learning and representing temporal knowledge in recurrent networks. **IEEE Trans. Neural Networks**, v. 22, n. 12, p. 2409–2421, 2011.
- BUCKNER, C.; GARSON, J. **Connectionism**. 2019. <<https://plato.stanford.edu/entries/connectionism/>>. Accessed: 2023-10-23.
- COLLIN. **Temporal Logics PowerPoint Presentation**. 2023. <<https://www.slideserve.com/collin/temporal-logics>>. [Online; accessed 21-October-2023].
- DIJKSTRA, E. W. Hierarchical ordering of sequential processes. **Acta Inform.**, Springer Nature, v. 1, n. 2, p. 115–138, 1971.
- DONG, H. et al. Neural logic machines. In: **International Conference on Learning Representations**. [S.l.: s.n.], 2018.
- ELANGO VAN, V. **Allen’s Temporal Logic: 13 Base Relations**. 2023. [Online; accessed 21-October-2023]. Available from Internet: <https://www.researchgate.net/figure/Allens-Temporal-Logic-13-Base-Relations_fig4_258548440>.
- FAINEKOS, G. E. et al. Temporal logic motion planning for dynamic robots. **Automatica**, v. 45, n. 2, p. 343–352, 2009. ISSN 0005-1098. Available from Internet: <<https://www.sciencedirect.com/science/article/pii/S000510980800455X>>.

FEDYANIN, D. Threshold and network generalizations of muddy faces puzzle. In: **2017 IEEE 11th International Conference On Application Of Information And Communication Technologies (AICT)**. [S.l.: s.n.], 2017. p. 1–5.

GARCEZ, A.; LAMB, L. Neurosymbolic ai: the 3rd wave. **Artificial Intelligence Review**, 2020. Available from Internet: <<https://dx.doi.org/10.1007/s10462-023-10448-w>>.

GARCEZ, A. d. et al. Neural-symbolic computing: An effective methodology for principled integration of machine learning and reasoning. **FLAP**, v. 6, n. 4, p. 611–632, 2019.

GARCEZ, A. d.; LAMB, L. Reasoning about time and knowledge in neural symbolic learning systems. In: **NIPS**. [S.l.: s.n.], 2003.

GARCEZ, A. d.; LAMB, L. A connectionist computational model for epistemic and temporal reasoning. **Neur. Computation**, v. 18, n. 7, p. 1711–1738, 2006.

GARCEZ, A. d'Avila; LAMB, L. C. Neurosymbolic ai: the 3rd wave. **AI Magazine**, p. 1–20, 2023.

GARCEZ, A. S. d.; LAMB, L. C. Reasoning about time and knowledge in neural-symbolic learning systems. In: **Proceedings of the 16th International Conference on Neural Information Processing Systems**. [S.l.]: MIT Press, 2003. p. 921–928.

GARCEZ, A. S. d'Avila; BRODA, K.; GABBAY, D. M. **Neural-symbolic learning systems - foundations and applications**. [S.l.]: Springer, 2002.

GARCEZ, A. S. d'Avila; LAMB, L.; GABBAY, D. M. **Neural-symbolic cognitive reasoning**. [S.l.]: Springer, 2009.

GIBAUT, W. et al. Neurosymbolic ai and its taxonomy: a survey. arXiv, 2023. Available from Internet: <<https://arxiv.org/abs/2305.08876>>.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. [S.l.]: MIT Press, 2016. ISBN 978-0262035613.

GORANKO, V.; RUMBERG, A. **Temporal Logic**. 2020. <<https://plato.stanford.edu/entries/logic-temporal/>>. Stanford Encyclopedia of Philosophy. Available from Internet: <<https://plato.stanford.edu/entries/logic-temporal/>>.

HODKINSON, I.; REYNOLDS, M. Temporal logic. In: **Handbook of Modal Logic**. [S.l.]: Elsevier, 2007. v. 3, p. 655–720.

IBM. **What is explainable AI?** 2023. Accessed: 2023-10-27. Available from Internet: <<https://www.ibm.com/topics/explainable-ai>>.

ILKOU, E. et al. **Symbolic Vs Sub-symbolic AI Methods: Friends or Enemies**. 2020. Available on ResearchGate. Available from Internet: <https://www.researchgate.net/profile/Eleni_Ilkou2/publication/345243725_Symbolic_Vs_Sub-symbolic_AI_Methods_Friends_or_Enemies/links/5fa15e6392851c14bcff6ac2/Symbolic-Vs-Sub-symbolic-AI-Methods-Friends-or-Enemies.pdf>.

JIANG, J.; AHN, S. Generative neurosymbolic machines. **Advances in Neural Information Processing Systems**, v. 33, p. 12572–12582, 2020.

KAUTZ, H. A. The third ai summer: Aaai robert s. engelmore memorial lecture. **AI Magazine**, Wiley Online Library, v. 43, n. 1, p. 105–125, 2022. Available from Internet: <<https://onlinelibrary.wiley.com/doi/10.1002/aaai.12036>>.

KOKEL, H. **The 6 Types of Neuro-Symbolic Systems**. 2023. Accessed: 2023-10-17. Available from Internet: <<https://harshakokel.com/posts/neurosymbolic-systems/>>.

KRAMER, J.; MAGEE, J. The evolving philosophers problem: dynamic change management. **IEEE Transactions on Software Engineering**, v. 16, n. 11, p. 1293–1306, 1990.

KULKARNI, K. N.; LAD, R. K. Fuzzy logic and its developmental advances: A review. In: **Proceedings of the International Conference on IoT Based Control Networks & Intelligent Systems - ICICNIS 2021**. [S.l.: s.n.], 2021. Available at SSRN: <<https://ssrn.com/abstract=3883128>> or <<http://dx.doi.org/10.2139/ssrn.3883128>>.

KYRIAKOPOULOS, S.; GARCEZ, A. Continual reasoning: Non-monotonic reasoning in neurosymbolic ai using continual learning. **arXiv preprint arXiv:2305.02171**, 2023. Available from Internet: <<http://arxiv.org/pdf/2305.02171>>.

LAHIRI, S. kumar. **A schematic diagram of artificial neural network and architecture of the feed forward network with one hidden layer**. 2009. Accessed: 2023-10-23. Available from Internet: <https://www.researchgate.net/figure/A-schematic-diagram-of-artificial-neural-network-and-architecture-of-the-feed-forward_fig1_26614896>.

LAMB, L.; BORGES, R.; GARCEZ, A. d. A connectionist cognitive model for temporal synchronisation and learning. In: **AAAI**. [S.l.: s.n.], 2007. p. 827–832.

MAO, J. et al. The neuro-symbolic concept learner: Interpreting scenes, words, and sentences from natural supervision. In: INTERNATIONAL CONFERENCE ON LEARNING REPRESENTATIONS, ICLR. **International Conference on Learning Representations**. [S.l.], 2019.

MAO, J. et al. Temporal and object quantification networks. In: **IJCAI**. [S.l.: s.n.], 2021.

MARES, E. D. **Modal Logic**. 2023. The Stanford Encyclopedia of Philosophy (Spring 2022 Edition). Available from Internet: <<https://plato.stanford.edu/entries/logic-modal/>>.

MINSKY, M. **Logical vs. Analogical or Symbolic vs. Connectionist or Neat vs. Scruffy**. 1991. In Artificial Intelligence at MIT, Expanding Frontiers, Patrick H. Winston (Ed.), Vol.1, MIT Press, 1990. Reprinted in AI Magazine, Summer 1991. Available from Internet: <<https://web.media.mit.edu/~minsky/papers/SymbolicVs.Connectionist.html>>.

PENNING, L. de et al. A neural-symbolic cognitive agent for online learning and reasoning. In: **IJCAI**. [S.l.: s.n.], 2011. p. 1653–1658.

RAGHAVAN, S. **2020 AI predictions from IBM research**. 2019. Accessed: 2020-01-14. Available from Internet: <<https://www.ibm.com/blogs/research/2019/12/2020-ai-predictions/>>.

RIEGEL, R. et al. **Logical neural networks**. 2020.

- ROSSI, E. et al. Temporal graph networks for deep learning on dynamic graphs. 2020.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, Nature Publishing Group, v. 323, n. 6088, p. 533–536, 1986.
- RUSSELL, S.; NORVIG, P. **Artificial Intelligence: A Modern Approach**. 3. ed. [S.l.]: Prentice Hall, 2010.
- SAYANTINI. **What is Fuzzy Logic in AI and What are its Applications?** | **Edureka**. 2023. <<https://www.edureka.co/blog/fuzzy-logic-ai/>>. Last updated on May 14, 2023.
- SCHWAB, K. **The Fourth Industrial Revolution**. 1st. ed. New York: Crown Business, 2016. ISBN 978-1-5247-5886-8.
- SHIVAHARE, B. D. et al. Survey paper: Comparative study of machine learning techniques and its recent applications. In: **2022 2nd International Conference on Innovative Practices in Technology and Management (ICIPTM)**. [S.l.: s.n.], 2022. v. 2, p. 449–454.
- TRAN, S. N.; GARCEZ, A. d'Avila. **Logical boltzmann machines**. 2021.
- UNESCO. **Ethics of Artificial Intelligence**. 2021. Accessed: 2023-10-27. Available from Internet: <<https://www.unesco.org/en/artificial-intelligence/recommendation-ethics>>.
- VALIANT, L. G. Three problems in computer science. **J. ACM**, v. 50, n. 1, p. 96–99, 2003.
- WHAT Is AI? 2023. <<https://www.lsu.edu/ai/what-is-ai.php>>. Accessed: 2023-10-23.
- XU, Y. et al. Artificial intelligence: A powerful paradigm for scientific research. **The Innovation**, v. 2, n. 4, p. 100179, 2021. ISSN 2666-6758. Available from Internet: <<https://www.sciencedirect.com/science/article/pii/S2666675821001041>>.
- YU, D. et al. A survey on neural-symbolic learning systems. **Neural Networks**, v. 166, p. 105–126, 2023. ISSN 0893-6080. Available from Internet: <<https://www.sciencedirect.com/science/article/pii/S0893608023003398>>.
- ZADEH, L. Fuzzy sets. **Information and Control**, v. 8, n. 3, p. 338–353, 1965. ISSN 0019-9958. Available from Internet: <<https://www.sciencedirect.com/science/article/pii/S001999586590241X>>.