

EXPLORANDO REDES NEURAIIS E ENGENHARIA DO CONHECIMENTO: UMA REVISÃO NARRATIVA

Luciano Weber

Engenharia e Gestão do Conhecimento
Universidade Federal de Santa Catarina (UFSC) – Florianópolis – SC - Brasil

luciano.weberr@ufsc.br

Resumo

A Engenharia do Conhecimento, ao desenvolver tecnologias de Inteligência Artificial, utiliza diversas abordagens, técnicas e ferramentas, entre elas as Redes Neurais. Este artigo apresenta uma revisão narrativa sobre a intersecção entre Redes Neurais e Engenharia do Conhecimento, fundamentada em contribuições de autores renomados e publicações recentes. O objetivo é investigar e sintetizar estudos atuais sobre o uso de Redes Neurais na Engenharia do Conhecimento, utilizando o método PRISMA-ScR para a seleção de artigos científicos e literatura acadêmica. Este trabalho abrange os principais conceitos e definições, discute a relação entre os temas e inclui exemplos práticos que ilustram como as redes neurais artificiais afetadas para soluções práticas na vida cotidiana. Além disso, explora a intersecção entre o desenvolvimento científico-tecnológico e a aplicação dessas tecnologias, conforme evidenciado por autores como Burgin.

Palavras-chave

Redes neurais artificiais; Fundamentos de Engenharia do Conhecimento

1. INTRODUÇÃO

Este artigo apresenta uma visão abrangente e detalhada, por meio de uma revisão narrativa, buscando aprofundar a compreensão da relação entre Redes Neurais e Engenharia do Conhecimento. A revisão narrativa explora uma variedade de fontes de informação, incluindo artigos acadêmicos, livros, relatórios técnicos e documentos relevantes, com o objetivo de traçar um panorama completo da interação entre Redes Neurais e Engenharia do Conhecimento. O objetivo geral é analisar estudos que conceituam e emergem dessa relação multifacetada.

Os resultados desta revisão demonstram uma importância crescente das Redes Neurais na área da Engenharia do Conhecimento. Evidências de sua aplicação bem-sucedidas são identificadas em diversas áreas, como sistemas de recomendação, processamento de linguagem natural, tomada de decisões intuitivas, entre outros. A capacidade das Redes Neurais em aprender e representar o conhecimento de maneira adaptativa tem sido um fator-chave para seu sucesso nesse contexto.

Este trabalho visa inspirar futuras pesquisas e promover discussões construtivas sobre como maximizar essa sinergia para avançar no campo da Engenharia do Conhecimento. Para desenvolver este estudo, foram seguidos os ensinamentos da disciplina de Fundamentos da

Engenharia do Conhecimento, oferecidos no segundo trimestre de 2023 pelos professores Fernando Alvaro Ostuni Gauthier e Vinicius Faria Culmant Ramos, dentro do Programa de Pós-Graduação em Engenharia, Gestão e Mídia do Conhecimento da Universidade Federal de Santa Catarina. A obra “Redes Neurais: Princípios e Prática” de Haykin e Engel (2002), bem como “Teoria das Estruturas e Processos do Conhecimento” de Burgin (2017), serviram como pontos de partida. Outras obras relevantes, como Russell (2022), foram incluídas, além de uma pesquisa de artigos científicos nas maiores bases de dados existentes.

2. METODOLOGIA

A pesquisa descreve a estrutura metodológica da abordagem PRISMA-ScR (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*)¹ para orientar a revisão, garantindo transparência e consistência ao processo. Apesar de uma pesquisa narrativa não exigir o apontamento do referencial e dos métodos exigidos nas revisões de escopo e sistemática, optou-se por essa estratégia para aprimorar estudos futuros sobre o tema.

A base inicial utilizada pela Web of Science², como *strings* “rede neural” e “engenharia do conhecimento”, resultou em 29.412 artigos. Filtrando-se apenas por trabalhos revisados por pares, documentos de acesso livre e publicações de 2023, o volume foi limitado a 75 artigos, todos escritos em inglês. O resultado da pesquisa foi exportado para um arquivo RIS³ com informações completas, que foi então importado para o sistema Rayyan.ai⁴. Uma nova filtragem foi realizada com a leitura de títulos e resumos, resultando em 18 artigos mais aderentes ao objetivo do estudo para leitura integral. Nesta última leitura, denotou-se que apenas 7 continham informações relevantes para a composição deste trabalho.

Outra base consultada foi a Scopus⁵, com as *strings* “*knowledge*” AND “*engineering*” AND “*fundamentals*”, resultando inicialmente em 8.151 documentos. Filtrando-se apenas artigos em inglês, com acesso livre, e de 2023, o total foi limitado a 63 publicações. Esta base foi exportada com dados completos para a extensão RIS e, em seguida, submetida ao Rayyan.ai

¹ Disponível em <http://www.prisma-statement.org>. Acesso: 20/9/2023.

² A Web of Science™ é uma plataforma abrangente que promove uma pesquisa com confiança a partir de quase 1,9 bilhão de referências mencionadas em mais de 171 milhões de registros. Fonte: <https://clarivate.com/webofsciencegroup/campaigns/web-of-science-base-de-dados-de-citacao-global-independentemaisconfiavel-domundo/>. Acesso: 20/9/2023.

³ Um arquivo RIS é um formato de arquivo de tags para troca de dados bibliográficos por programas de citação. Ele contém várias linhas de dados de citação, consistindo em um código de dois caracteres e valor correspondente delimitado por um hífen. As informações de citação incluídas em um arquivo RIS incluem dados como autor, título, data de publicação, palavras-chave, editora, resumo, endereço do autor, etc. Os arquivos RIS são legíveis por humanos e podem ser abertos com qualquer editor de texto, como Microsoft Notepad, Notepad++, e Apple TextEdit. Fonte: <https://docs.fileformat.com/pt/misc/ris/>. Acesso: 20/9/2023.

⁴ Rayyan é um aplicativo da web financiado pela Qatar Foundation, uma organização sem fins lucrativos do Qatar, utilizado primariamente para auxílio em pesquisas do tipo revisão sistemática e metanálise. Disponível em: <https://www.rayyan.ai/>. Acesso: 10/9/2023.

⁵ Segundo o Guia de Referência Rápida da Capes, o Scopus é a maior base de dados de resumos e citações de literatura revisada por pares, com ferramentas bibliométricas para acompanhar, analisar e visualizar a pesquisa. Scopus contém mais de 22.000 títulos de mais de 5.000 editores em todo o mundo, abrangendo as áreas de ciência, tecnologia, medicina, ciências sociais e Artes e Humanidades. Além disso, contém mais de 55 milhões de registros que remontam a 1823, dois quais 84% possuem referências que datam de 1996. Disponível em https://www.periodicos.capes.gov.br/images/documents/Scopus_Guia%20de%20refer%C3%Aancia%20r%C3%A1pida_10.08.2016.pdf. Acesso: 25/6/2023.

para refinamento dos artigos aderentes, resultando em 27 publicações. Da leitura integral, concluiu-se que 4 trouxeram contribuições explicitamente ao escopo deste estudo.

3. RESULTADOS: DA ENGENHARIA DO CONHECIMENTO

A primeira frase da Metafísica de Aristóteles diz que o homem, por natureza, anseia o saber⁶. Ao partir desse pressuposto, e apresentando ainda o pensamento de inúmeros outros filósofos de variadas épocas, Burgin (2017) divide o estudo do conhecimento em 3 partes: o teórico/experimental, a engenharia do conhecimento e a utilização/gestão do conhecimento. O autor cita também que há 3 teorias do conhecimento: a epistemologia (filosófica, interessada na criação e aquisição do conhecimento), as teorias matemáticas (lógica, algoritmos e linguística) e as teorias empíricas (como inteligência artificial, gestão do conhecimento, cognitivismo, entre outras). Ao reforçar o fato de que o conceito platônico de conhecimento como “crença verdadeira justificada” é insuficiente e ultrapassado, Burgin (2017) diz que o conhecimento passou a ser estudado coletivamente, indo além da individualidade filosófica da epistemologia. Deste modo, as instruções das pesquisas em conhecimento dividem-se em 3: análise da estrutura, análise axiológica dentro do contexto social e tecnológico, e análise funcional sobre como o conhecimento atua, é produzido e adquirido.

Assim, o “conhecimento⁷ se tornou o principal ativo estratégico para o século XXI e para todas as organizações” (Burgin, 2017)⁸. Devido às necessidades crescentes de conhecimento e de organizá-lo eficientemente, segundo Burgin, a sociedade intensifica seus estudos em 3 direções principais: a filosófica/metodológica, em que se incluem a epistemologia e os métodos científicos e matemáticos; a inteligência artificial (IA); a gestão do conhecimento.

A Engenharia do Conhecimento refere-se então à tecnologia de produção, organização, transformação, gestão, preservação, captura e aquisição do conhecimento, enquanto a utilização do conhecimento estuda como as pessoas e organizações usam o conhecimento, desenvolvendo novas técnicas e abordagens para isso. Burgin diz que a análise estrutural do conhecimento busca uma compreensão sobre como se constrói o conhecimento e quais suas propriedades. Na análise axiológica, o objetivo é explicar características básicas enquanto fenômeno social⁹ e tecnológico. Já a análise funcional visa saber como o conhecimento funciona, é produzido e adquirido.

“Consequentemente, a engenharia do conhecimento é a aplicação de princípios científicos a fins práticos associados ao conhecimento, tais como a concepção, o fabrico, a manutenção e a operação de sistemas de conhecimento. (...) Engenharia do conhecimento é uma disciplina de engenharia que envolve a integração do conhecimento em sistemas computacionais, a fim de resolver problemas complexos que normalmente exigem um alto nível de conhecimento humano. (...) A engenharia do conhecimento consiste na construção, manutenção e desenvolvimento de sistemas baseados em conhecimento. (...) Um dos objetivos centrais da engenharia do conhecimento é identificar um léxico conceitual apropriado para a construção de uma ontologia.

⁶ Em grego clássico: “ὄλοι οἱ ἄνθρωποι φύσει ἐπιστήμην ἐπιθυμοῦσιν” (Aristóteles, 1998).

⁷ “O conhecimento é um dos recursos mais valiosos para uma organização, e o tipo mais importante de conhecimento está localizado na cabeça das pessoas”. (Orenga-Roglá & Chalmeta, 2019).

⁸ “Consequentemente, a necessidade de desenvolver a melhor estratégia para identificar, desenvolver e aplicar os ativos de conhecimento tornou-se crítica” (Burgin, 2017)

⁹ “O conhecimento é substituível em substância e em dinheiro, o que significa que o conhecimento pode substituir, até certo ponto, capital, trabalho ou materiais físicos. Ou seja, o conhecimento permite usar menos dinheiro, trabalho ou materiais físicos do que é possível prescindir desse conhecimento. Como resultado, a riqueza criada é medida menos pela produção do trabalho em si, mas mais e mais pelo nível geral de desenvolvimento científico e tecnológico” (Burgin, 2017).

As ontologias permitem construir modelos do domínio do conhecimento e definir os termos utilizados dentro do domínio e as relações entre eles. Existem diferentes tipos de ontologias, como ontologias de domínio, ontologias genéricas, ontologias de aplicação e ontologias representacionais”. (Burgin, 2017, p. 711)

Segundo Levy, Radar & Aviv (2019), Engenharia do Conhecimento (KE, de *Knowledge Engineering*) é a abordagem ponderada para modelar o conhecimento que atenda os objetivos organizacionais e necessidades das diversas partes interessadas. Zhu *et al.* (2023) dizem que os principais métodos de KE dividem-se em extração, fusão e processamento de conhecimento. Para Suder, Benhamins & Fensel (1998), a disciplina de KE assemelha-se à Engenharia de Software, no objetivo de transformar o processo de construção de sistemas baseados em conhecimento de uma arte para uma disciplina de engenharia. Rutenberg *et al.* (2015) dizem que a Engenharia do Conhecimento deriva da Inteligência Artificial.

3.1 DA INTELIGÊNCIA ARTIFICIAL

Segundo Russel (2022), discute-se IA desde a Antiguidade, porém seu início oficial é de 1956, quando os matemáticos John MacCarthy e Marvin Minsky convenceram o inventor da teoria da informação, Claude Shannon, e o criador do computador comercial da IBM, Nathaniel Rochester, a oferecerem uma capacitação de verão sobre a hipótese de que:

(...) em princípio é possível descrever tão precisamente todos os aspectos da aprendizagem, ou quaisquer outras características de inteligência, que uma máquina seja capaz de simulá-los. Haverá um esforço para descobrir como fazer máquinas usarem linguagem, formar abstrações e conceitos, resolver tipos de problema até então reservados a seres humanos, e evoluírem” (Russel, 2022, p. 17).

Três anos depois, em 1959, Arthur Samuel traz a definição de *Machine Learning* como a habilidade de um computador aprender. Para Gürel *et al.* (2023), hoje a IA está frequentemente em uso nas áreas médicas, em maquinário, energia, economia, farmácia, educação, com aceitação humana devido ao sucesso de suas aplicações, com desempenhos que ultrapassam métodos tradicionais. Além disso, a IA tornou-se uma ferramenta que oferece respostas rápidas a problemas complexos.

Outros autores trazem definições: “IA é a área de pesquisa da Ciência da Computação que busca desenvolver soluções computacionais que simulam o raciocínio humano na solução de problemas” (Heinzle, Gauthier & Fialho, 2010, p. 230). Sampaio e Fernandes (2023) dizem que a IA concede ao computador “a capacidade de tomar decisões através da análise de dados de forma independente, seguindo regras predefinidas ou modelos de reconhecimento de padrões. Studer, Benjamins & Fensel (1998) dizem que IA é o raciocínio sobre modelos mundanos e, portanto, “não é estranho que os pesquisadores de IA tenham adotado o termo ontologia para descrever o que pode ser representado (computacionalmente) do mundo em um programa”.

Thayyib *et al.* (2023) lembram que na 4ª Revolução Industrial (I4.0)¹⁰ desabrocharam inúmeras tecnologias disruptivas. Tomar decisões é cada vez mais descentralizado na rede informatizada, especialmente com uso de IA e da *Big Data Analytics* (BDA).

Para Sarkar *et al.* (2023), a IA usa sistemas que decifram dados e informações e treinam na direção de objetivos definidos. Esses autores dizem que há vários domínios de métodos em

¹⁰ Indústria 4.0 ou 4ª Revolução Industrial são expressões que tratam de tecnologias de automação e troca de dados utilizando conceitos de sistemas ciber-físicos, Internet das Coisas (IoT) e computação em nuvem. O foco da 4ª Revolução Industrial é melhorar a eficiência e a produtividade de processos.

IA, como representar conhecimento, explorar soluções, deduzir e aprender. O aprendizado de máquina (ML – de *machine learning*) detecta tendências e categoriza para uso posterior.

“Uma entidade do ML é o aprendizado profundo (DL – *deep learning*), que invoca redes neurais artificiais (RNAs). Essas redes envolvem um grupo de componentes de computação refinados e intercomunicantes, envolvendo “*perceptrons*”, comparáveis aos neurônios no tecido nervoso humano, e simulando a transmissão de excitações elétricas dentro do sistema nervoso cerebral humano (Sarkar *et al.* 2023, p. 4).

Mackay e Nowell (2023) explicam ML sob a perspectiva da introdução das redes neurais: “sucesso na produção de insights precisos e acionáveis a partir de grandes conjuntos de dados, difíceis ou impossíveis de serem obtidos por processamento humano”.

Segundo Sarkar *et al.* (2023), ML possui sinônimos em alguns algoritmos típicos: Regressão Logística (LR), Classificação Bayesiana Naive (NBC), k Vizinho Mais Próximo (KNN), Regressão Linear Múltipla (MLR), Máquina de Vetores de Suporte (SVM), Rede Neural Probabilística (PNN), Binário Discriminação de Kernel (BKD), Análise Discriminante Linear (LDA), Floresta Aleatória (RF), Rede Neural Artificial (RNA), Mínimos Quadrados Parciais (PLS), Análise de Componentes Principais (PCA), entre outros. Esses autores lembram que o aprendizado profundo (DL), entidade essencial de *machine learning*, pauta-se em paradigmas de Redes Neurais Profundas (DNN), Redes Neurais Convolucionais (CNN), Redes Neurais (RNN), autoencoders e Máquinas Boltzmann Restritas (RBN) (Sarkar *et al.* 2023).

Figura 1. Noção resumida de IA e ML

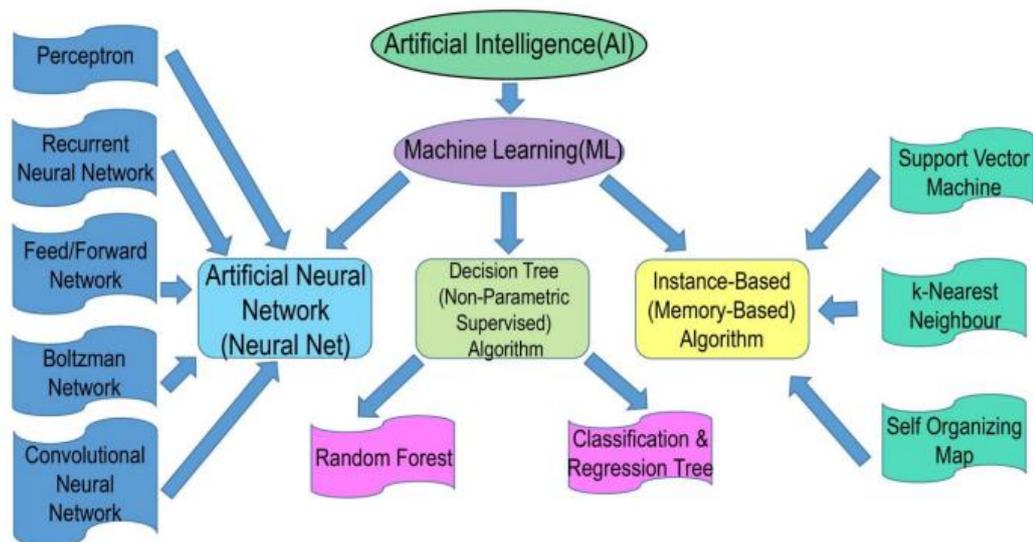


Figura 1: Sarkar *et al.* 2023

Gheisari *et al.* (2023) dizem que *Deep Learning* é uma forma poderosa de analisar big data, permitindo que computadores aprendam sem serem ensinados. Sampaio e Fernandes (2023) concordam que o aprendizado de máquina é subcampo da IA e possibilita desenvolver programas computacionais que aprendem e melhoram de desempenho automaticamente, baseados em experiência:

O ML pode ser implementado por meio de aprendizagem supervisionada e não supervisionada. A aprendizagem não supervisionada reduz dados altamente dimensionais a um número menor de dimensões ou identifica padrões a partir dos dados. (...) na aprendizagem supervisionada, os

algoritmos usam dados rotulados antecipadamente (designados como conjunto de treinamento) (Sampaio e Fernandes, 2023, p. 4).

Li, Li & Lin (2023) dizem que o poder computacional geral cresce e melhora o poder de processar dados, o que aperfeiçoa a generalização de modelos. A esse respeito, Surianarayanan *et al.* (2023) lembra que a Internet das Coisas (IoT) cresceu muito, gerou uma enorme quantidade de dados, e agora a humanidade vai deparar-se cada vez mais com melhorias de trânsito inteligente, casa inteligente, cidade inteligente, transporte inteligente¹¹.

3.1.2 DAS REDES NEURAIAS

Conforme verifica-se na vasta literatura explorada para este artigo, existem vários tipos de redes neurais artificiais (RNAs), cada uma projetada para resolver problemas específicos. Entre os tipos mais comuns de redes neurais e suas aplicações estão: *Feedforward Neural Networks* (FNNs): *Perceptron*, *Multilayer Perceptron* (MLP), *Convolutional Neural Networks* (CNNs), Redes Siamesas, Redes CNNs pré-treinadas, *Recurrent Neural Networks* (RNNs), *Long Short-Term Memory* (LSTM), *Gated Recurrent Unit* (GRU), Redes Neurais Recorrentes Bidirecionais (Bi-RNNs), *Autoencoders*, *Variational Autoencoders* (VAEs), Redes Generativas Adversariais (GANs), *Conditional GANs*, Redes Neurais Recorrentes Profundas (DNNs), Redes Neurais Convolucionais Recorrentes (CRNNs), *Transformers*, BERT (*Bidirectional Encoder Representations from Transformers*), GPT (*Generative Pre-trained Transformer*), Redes Neurais Recorrentes Residuais (RNNs Residuais), entre outras.

Wang *et al.* (2023) dizem que o conceito de redes neurais e do modelo matemático neural surgiu em 1943, com McCulloch e Pitts. Chen *et al.* (2023) dizem que as redes neurais simulam o processo de aprendizagem humano, com estrutura de vários níveis. Sampaio e Fernandes (2023) explicam que a estrutura topológica das RNAs possui elementos de processamento (neurônios artificiais) conectados por coeficientes e organizados em camadas, onde há uma estrutura de regressão flexível prevendo a relação entre entradas e saídas.

Studer, Benjamins & Fensel (1998) citam 3 estruturas para modelar Engenharia do Conhecimento por meio das redes neurais artificiais: CommonKADS, MIKE e PROTÉGÉ-II. Haykin e Engel (2002) conceituam rede neural como um processador “maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso”¹².

No livro “Redes Neurais”, Haykin (2017) trata da relação das redes neurais com a Engenharia do Conhecimento em várias perspectivas, como modelagem de conhecimento, aprendizado de máquina, reconhecimento de padrões, tomada de decisões inteligentes, representação de conhecimento e generalização. A discussão sobre a modelagem do conhecimento é uma parte fundamental do conteúdo.

4. DISCUSSÃO

¹¹ “Os dados adquiridos devem ser processados imediatamente para produzir insights significativos e decisões acionáveis” (Surianarayanan *et al.*, 2023).

¹² Esses autores enfatizam a semelhança com o cérebro em dois aspectos: “1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem; 2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido” (Haykin e Engel, 2002).

Entre os autores treinados, as redes neurais artificiais são apresentadas como um meio eficaz de representar informações em sistemas computacionais, ligando diretamente Inteligência Artificial com Engenharia do Conhecimento. Esses RNAs são capazes de codificar o conhecimento de forma distribuída, o que significa que o conhecimento não é armazenado em locais específicos, mas é distribuído nos pesos das conexões entre neurônios artificiais. Os autores exploram como as redes neurais podem aprender a representação do conhecimento a partir de dados. Isso é feito através do processo de treinamento, no qual a rede ajusta seus pesos e parâmetros com base em exemplos de entrada e saída. Isso permite que a rede adquira conhecimento a partir de dados de treinamento, tornando-se capaz de realizar tarefas específicas.

A relação entre Redes Neurais e Engenharia do Conhecimento se fortalece quando observamos a capacidade das RNAs em generalizar o conhecimento aprendido para fazer planejamento ou tomar decisões em novas situações que não foram vistas durante o treinamento. Essa capacidade de adaptação é essencial na Engenharia do Conhecimento, onde sistemas precisam lidar com dados e cenários variados. Mais ainda, foi possível conceituar redes neurais profundas, que são redes com várias camadas ocultas, permitindo a criação de representações hierárquicas de conhecimento, onde camadas mais profundas podem aprender conceitos abstratos e complexos com base nas informações extraídas pelas camadas mais superficiais.

A Engenharia do Conhecimento refere-se à tecnologia de produção, organização, transformação, gestão, preservação, captura e aquisição do conhecimento. As redes neurais são fundamentais para essas tarefas devido à sua habilidade de analisar e analisar grandes volumes de dados rapidamente, descobrir padrões ocultos e fazer especificações precisas. Por exemplo, em sistemas de recomendação, as RNAs podem analisar o comportamento do usuário e oferecer sugestões personalizadas. No processamento de linguagem natural, as RNAs podem interpretar e gerar texto de forma semelhante à humana, facilitando a interação homem-máquina.

Além disso, a interdisciplinaridade entre a Engenharia do Conhecimento e a Inteligência Artificial, através das redes neurais, sugere um campo rico para futuras pesquisas e desenvolvimentos tecnológicos. A capacidade das redes neurais em aprender e representar o conhecimento de maneira adaptativa tem sido um fator-chave para seu sucesso nesse contexto. O aprendizado de máquina (ML), um campo de IA que se concentra na capacidade de sistemas computacionais aprenderem e melhorarem automaticamente a partir da experiência, é fortemente interligado com a Engenharia do Conhecimento. Haykin (2017) explora como as redes neurais são bem adequadas para critérios de consideração devido à sua capacidade de aprender representações hierárquicas e não lineares dos dados.

As redes neurais também possuem capacidade de processamento de linguagem natural (PLN), aplicadas no reconhecimento de padrões em textos, incluindo tarefas como classificação de sentimentos, tradução automática e sumarização de texto. Essas capacidades são essenciais para a Engenharia do Conhecimento, que frequentemente lida com grandes volumes de informações textuais. As redes neurais podem pré-processar dados e extrair características relevantes para o reconhecimento de padrões, descobrir padrões intrínsecos em dados não rotulados e superar a variabilidade nos dados e a necessidade de dados de treinamento representativos.

Essas questões envolvem diversas aplicações práticas na Engenharia do Conhecimento, como reconhecimento de padrões, processamento de linguagem natural, visão computacional, controle de sistemas complexos e muito mais. O aprendizado de máquina surge então como um campo da IA que se concentra na capacidade de sistemas computacionais aprenderem e melhorarem automaticamente a partir da experiência. A capacidade das redes neurais de

aprender e adaptar-se a partir de dados novos e variados destaca sua importância na construção de sistemas de conhecimento resilientes e dinâmicos.

Com efeito, a análise estrutural do conhecimento, conforme discutida por Burgin (2017), busca uma compreensão sobre como se construir o conhecimento e quais suas propriedades. Na análise axiológica, o objetivo é explicar características básicas enquanto aspectos sociais e tecnológicos. Já a análise funcional visa saber como o conhecimento funciona, é produzido e adquirido. Essas análises são beneficiadas diretamente pelas capacidades das redes neurais em processar e analisar dados complexos, contribuindo para uma compreensão mais profunda e prática do conhecimento em diversos contextos.

5. CONSIDERAÇÕES FINAIS

Com base em nossos autores treinados, fornecemos-se definições sobre Engenharia do Conhecimento, Inteligência Artificial e Redes Neurais Artificiais, bem como a relação existente entre esses temas. A abordagem deste trabalho foi a mais abrangente possível, por isso não houve o detalhamento das redes neurais. Estudos futuros podem ser realizados a partir deste trabalho, para tratar especificamente dos exemplos práticos e das questões éticas envolvidas.

Está demonstrado como as redes neurais desempenham um papel crucial na tomada de decisões inteligentes em uma ampla gama de aplicações, como aprender com dados, lidar com incertezas e tomar decisões informadas, o que torna uma ferramenta valiosa na Engenharia do Conhecimento e na construção de sistemas inteligentes que podem agir de maneira adaptativa e eficaz em ambientes complexos.

Futuras pesquisas podem explorar mais o fundo da integração de redes neurais em sistemas de conhecimento para resolver problemas específicos, além de investigar as implicações éticas e sociais dessa tecnologia. A sinergia entre redes neurais e a Engenharia do Conhecimento tem o potencial de transformar a maneira como abordamos a aquisição, gestão e aplicação do conhecimento em diversas áreas, desde a educação até a indústria. Assim, a evolução contínua das redes neurais e seu papel na Engenharia do Conhecimento promete avanços avançados na forma como entendemos e utilizamos o conhecimento, promovendo inovações que podem beneficiar amplamente a sociedade.

REFERÊNCIAS

- Aristóteles. *Metafísica*. [Edição trilingue por Valentín García Yebra]. Madrid, Gredos, 1998.
- Burgin, Mark. *Theory of Knowledge: Structures and Processes*. World Scientific Publishing: Singapore, 2017.
- Gheisari, M.; Ebrahimzadeh, F.; Rahimi, M.; Moazzamigodarzi, M.; Liu, Y.; Dutta Pramanik, P.K.; Heravi, M.A.; Mehbodniya, A.; Ghaderzadeh, M.; Feylizadeh, M.R.; et al. Deep learning: Applications, architectures, models, tools, and frameworks: A comprehensive survey. *CAAI Trans. Intell. Technol.* 2023, Early View. (15) (PDF)
- Gürel, AE., Ağbulut, Ü., Bakir, H., Ergün, A., Yildiz, G. A state of art review on estimation of solar radiation with various models. *Heliyon*. 2023 Jan 21;9(2):e13167. doi: 10.1016/j.heliyon.2023.e13167. PMID: 36747538; PMCID: PMC9898075.

- Haykin, Simon; Engel, Paulo Martins. *Redes Neurais: Princípios e Prática*. 2. ed. Porto Alegre: Bookman, 2002
- Heinzle, Roberto; Gauthier, Fernando Alvaro Ostuni; Fialho, Francisco Antonio Pereira. Semântica nos sistemas de apoio a decisão: o estado da arte. *Revista da UNIFEPE*, v. 1, n. 8, p. 225-248, 2017.
- Johari, Rina Tasia; Ramli, Rizauddin; Zulkoffli, Zuliani; Saibani, Nizaroyani. A Systematic Literature Review on Vision-Based Hand Gesture for Sign Language Translation. *Jurnal Kejuruteraan*, [S.L.], v. 35, n. 2, p. 287-302, 30 mar. 2023. Penerbit Universiti Kebangsaan Malaysia (UKM Press). [http://dx.doi.org/10.17576/jkukm-2023-35\(2\)-03](http://dx.doi.org/10.17576/jkukm-2023-35(2)-03).
- Levy, M., Hadar, I. & Aviv, I. A requirements engineering methodology for knowledge management solutions: integrating technical and social aspects. *Requirements Eng* 24, 503–521 (2019). <https://doi.org/10.1007/s00766-018-0298-x>
- Li, Zhuo; Li, Hengyi; Meng, Lin. Model Compression for Deep Neural Networks: a survey. *Computers*, [S.L.], v. 12, n. 3, p. 60, 12 mar. 2023. MDPI AG. <http://dx.doi.org/10.3390/computers12030060>.
- Mackay, Calum Torin; Nowell, David. Informed machine learning methods for application in engineering: a review. *Proceedings Of The Institution Of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, [S.L.], p. 095440622311645, 17 abr. 2023. SAGE Publications. <http://dx.doi.org/10.1177/09544062231164575>.
- Orenga-Roglá, S., Chalmeta, R. Methodology for the Implementation of Knowledge Management Systems 2.0. *Bus Inf Syst Eng* 61, 195–213 (2019). <https://doi.org/10.1007/s12599-017-0513-1>
- Qu, Xiaoye; Gu, Yingjie; Xia, Qingrong; LI, Zechang; Wang, Zhefeng; Huai, Baoxing. A Survey on Arabic Named Entity Recognition: past, recent advances, and future trends. *Ieee Transactions On Knowledge And Data Engineering*, [S.L.], p. 1-18, 2023. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/tkde.2023.3303136>.
- Rautenberg, S. et al. ontoKEM: uma ferramenta para construção e documentação de ontologias. In: *Seminário de Pesquisa em Ontologia no Brasil*, 1., 2008, Niterói. Anais. Niterói, 2008. CD-ROM.
- Russell, S. *Inteligência artificial a nosso favor: Como manter o controle sobre a tecnologia*. Tradução Berilo Vargas. São Paulo, Companhia das Letras. 2022.
- Sampaio, Pedro Sousa; Fernandes, Pedro. Machine Learning: a suitable method for biocatalysis. *Catalysts*, [S.L.], v. 13, n. 6, p. 961, 1 jun. 2023. MDPI AG. <http://dx.doi.org/10.3390/catal13060961>.
- Sarkar, Chayna; Das, Biswadeep; Rawat, Vikram Singh; Wahlang, Julie Birdie; Nongpiur, Arvind; Tiewsoh, Iadarilang; Lyngdoh, Nari M.; Das, Debasmita; Bidarolli, Manjunath; Sony, Hannah Theresa. Artificial Intelligence and Machine Learning Technology Driven Modern Drug Discovery and Development. *International Journal Of Molecular Sciences*, [S.L.], v. 24, n. 3, p. 2026, 19 jan. 2023. MDPI AG. <http://dx.doi.org/10.3390/ijms24032026>.

- Studer, R., Benjamins, V. R., & Fensel, D. (1998). Knowledge engineering: principles and methods. *Data & knowledge engineering*, 25(1-2), 161-197. [https://doi.org/10.1016/S0169-023X\(97\)00056-6](https://doi.org/10.1016/S0169-023X(97)00056-6)
- Surianarayanan, Chellammal; Lawrence, John Jeyasekaran; Chelliah, Pethuru Raj; Prakash, Edmond; Hewage, Chaminda. A Survey on Optimization Techniques for Edge Artificial Intelligence (AI). *Sensors*, [S.L.], v. 23, n. 3, p. 1279, 22 jan. 2023. MDPI AG. <http://dx.doi.org/10.3390/s23031279>.
- Thayyib, P. V.; Mamilla, Rajesh; Khan, Mohsin; Fatima, Humaira; Asim, Mohd; Anwar, Imran; Shamsudheen, M. K.; Khan, Mohd Asif. State-of-the-Art of Artificial Intelligence and Big Data Analytics Reviews in Five Different Domains: a bibliometric summary. *Sustainability*, [S.L.], v. 15, n. 5, p. 4026, 22 fev. 2023. MDPI AG. <http://dx.doi.org/10.3390/su15054026>.
- Tricco, A.C., Lillie, E, Zarin, W, O'Brien, KK, Colquhoun, H, Levac, D, Moher, D, Peters, MD, Horsley, T, Weeks, L, Hempel, S et al. PRISMA extension to scope reviews (PRISMA-ScR): checklist and explanation. *Ann Intern Med*.169(7):467-473. 2018.
- Wang, X., Ren, Y., Luo, Z., He, W., Hong, J., Huang, Y. Deep learning-based EEG emotion recognition: Current trends and future perspectives. *Front Psychol*. 2023 Feb 27;14:1126994. doi: 10.3389/fpsyg.2023.1126994. PMID: 36923142; PMCID: PMC10009917.
- Xuan, L., Lichang, D., Yafang, Z., Zu-Guo, Y., Wen, Z., Jian-Yu, S., Dong-Sheng, C., Li, Z., Haowen, C., Bosheng, S., Philip, S. Y., Xiangxiang, Z., Comprehensive evaluation of deep and graph learning on drug–drug interactions prediction, *Briefings in Bioinformatics*, Volume 24, Edição 4, julho de 2023, bbad235, <https://doi.org/10.1093/bib/bbad235>
- Zhu, Di; YIN, Hailian; Xu, Yidan; Wu, Jiaqi; Zhang, Bowen; Cheng, Yaqi; Yin, Zhanzuo; Yu, Ziqiang; Wen, Hao; LI, Bohan. A Survey of Advanced Information Fusion System: from model-driven to knowledge-enabled. *Data Science And Engineering*, [S.L.], v. 8, n. 2, p. 85-97, 26 abr. 2023. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s41019-023-00209-8>.