

# Methodological Advances in Expert Systems with Artificial Intelligence

Jesý Karolayne Sales dos Santos  
karolayne@academico.ufs.br  
Universidade Federal de Sergipe  
São Cristóvão, Sergipe, Brasil

Lauryane Santos Siqueira  
lauryanesiqueira@academico.ufs.br  
Universidade Federal de Sergipe  
São Cristóvão, Sergipe, Brasil

Eduardo Marques Braga Faria  
faria.eduardo@academico.ufs.br  
Universidade Federal de Sergipe  
São Cristóvão, Sergipe, Brasil

Kalil Araújo Bispo  
kalil@dcomp.ufs.br  
Universidade Federal de Sergipe  
São Cristóvão, Brasil

Gilton José Ferreira da Silva  
gilton@dcomp.ufs.br  
Universidade Federal de Sergipe  
São Cristóvão, Sergipe, Brazil

Michel S. Soares  
michel@dcomp.ufs.br  
Universidade Federal de Sergipe  
São Cristóvão, Sergipe, Brazil

## ABSTRACT

**Context:** With the advancement of artificial intelligence (AI), expert systems (ESs) continue to evolve and are essential to support decisions in complex domains such as healthcare, industry, and automation. **Problem:** The growth of AI technologies has expanded the possibilities of Expert Systems. With advances in natural language processing, there is a need for an updated mapping of the applications and methodologies of ESs, highlighting the role of new AI techniques. **Solution:** Literature review is essential to identify trends, methodologies, challenges, and innovations in ESs, providing a comprehensive overview of the most recent trends and their implications. **IS Theory:** When examining how ESs can integrate and process complex and constantly evolving data, this study is guided by the complex systems theory, which aims to explore how parts of systems exchange information and adapt to new conditions. **Method:** The study employs a qualitative and interpretative review to investigate the state of the art in inference methodologies, knowledge acquisition, and performance in ESs. **Summary of Results:** Expert systems have evolved significantly with the use of AI, including deep learning, hybrid models, and natural language processing, improving accuracy, adaptability, and the ability to process large volumes of data. **Contributions and Impact on the IS Field:** This study highlights the advances that make expert systems more effective, highlighting how the integration of AI improves the ability to deal with uncertainty and complex decisions. The new methodologies show potential to optimize reliability and decision making in critical environments.

## CCS CONCEPTS

• Information systems → Information systems applications;

## KEYWORDS

Expert Systems, Advances, Review, Artificial Intelligence, Performance

## 1 INTRODUÇÃO

Com o avanço acelerado da inteligência artificial (IA), os sistemas especialistas, que já foram pioneiros no apoio à tomada de decisão em áreas especializadas, continuam a evoluir para enfrentar novos desafios e expandir suas aplicações [80]. Os sistemas especialistas

simulam a tomada de decisão de profissionais experientes ao utilizar conhecimentos acumulados e estruturados, mas enfrentam dificuldades ao lidar com incertezas e grandes volumes de dados [71]. Na era da indústria 4.0 [63], essas tecnologias passaram por transformações significativas, incorporando novas metodologias que aprimoram suas capacidades e ampliam seu alcance [80].

Historicamente, os sistemas especialistas começaram a ganhar relevância na década de 1970, utilizando regras “Se, Então” para replicar o conhecimento humano [12]. Com a popularização durante os anos de 1980, os sistemas foram amplamente adotados por setores como a indústria e o militar, o que impulsionou seu desenvolvimento [70]. O surgimento de técnicas avançadas de IA, como redes neurais e aprendizado profundo, ampliou significativamente suas capacidades, tornando-os mais eficazes para tarefas que envolvem grandes volumes de dados, processamento e análise [44].

Embora revolucionários em seu tempo, os sistemas especialistas baseados em regras enfrentaram limitações significativas, especialmente ao lidar com dados incertos ou incompletos [72]. Inovações como as redes Bayesianas, que foram aplicadas na análise de segurança em ambientes de alto risco, como instalações nucleares, permitiram a realização de inferências mais precisas [21].

Outros avanços, como a integração de redes neurais BP com lógica *fuzzy*, aumentaram a precisão no diagnóstico de falhas industriais [79]. A integração de técnicas de visão computacional com IA elevou a capacidade dos sistemas especialistas em tarefas como a detecção de defeitos em linhas de produção [44].

Com a crescente complexidade dos problemas modernos, tornou-se evidente que abordagens puramente baseadas em regras são insuficientes. As metodologias híbridas, que combinam diferentes tecnologias de IA, surgem como soluções mais robustas. A integração de redes neurais profundas com sistemas baseados em regras ponderadas (*belief rule base*) demonstrou melhorar a precisão de previsões em cenários incertos [33], enquanto a lógica *fuzzy* (nebulosa) tem se mostrado eficaz na avaliação de riscos em ambientes dinâmicos [2]. Em um cenário urbano, a combinação de IA com *blockchain* em sistemas especialistas tem otimizado o controle de sensores e garantido a segurança dos dados em cidades inteligentes [50].

Uma análise abrangente sobre o desenvolvimento e a aplicação de sistemas especialistas, desde a década de 1970 até 2016, foi apresentada por Tan et al. [70]. Os autores abordaram a evolução dos sistemas especialistas (SE's) em áreas como medicina, manufatura e

gestão, oferecendo um panorama consolidado dos avanços. Em anos posteriores ao trabalho de Tan et al. [70], as técnicas de Inteligência Artificial (IA), tal como o Processamento de Linguagem Natural com Modelos de Linguagem de Grande Escala (LLM) [55], passaram por transformações significativas com o surgimento dos modelos GPT em 2018 [51], o que pode ter impactado no desenvolvimento dos SE's.

Considerando a evolução da IA, este trabalho tem por objetivo analisar as tendências, metodologias e desafios dos sistemas especialistas entre 2017 e 2024. A pesquisa investiga como inovações na aquisição de conhecimento e inferência superaram limitações anteriores, comparando sistemas históricos com aplicações recentes e avaliando o impacto da IA na precisão e desempenho dos sistemas, além de atualizar revisões anteriores e apontar tendências futuras.

## 2 FUNDAMENTAÇÃO TEÓRICA

Os sistemas especialistas tradicionais, fundamentados em regras e no conhecimento de especialistas de uma área específica, apresentam várias características principais que os tornam eficientes para resolver problemas delimitados. Esses sistemas são geralmente voltados para tarefas bem definidas, onde a tomada de decisão é realizada com base em processos heurísticos e dados previamente acumulados [16].

O sistema especialista é um sistema computacional que imita a habilidade humana de um especialista ao tomar decisões em um específico domínio de conhecimento, cujo método comum de representação fundamenta-se em regras do tipo condicional [71]. Os SE's tradicionais incorporam conhecimentos não documentados extraídos de um especialista humano. Diferentemente da programação convencional, os problemas desses sistemas não possuem uma solução algorítmica satisfatória, e baseiam-se na inferência para alcançar soluções razoáveis [27].

O objetivo do sistema especialista é codificar o conhecimento de um especialista humano como um conjunto de regras que pode ser aplicada aos dados automaticamente. O sistema especialista baseado em regras possui três componentes principais: a base de conhecimento, o motor de inferência e a base de dados de fatos. A solução é obtida usando o raciocínio do motor de inferência, que conecta as regras especificadas na base de conhecimento com as informações oferecidas pela base de dados de fatos, e esta armazena um conjunto de resultados para comparar com as condições [69].

Desde o desenvolvimento dos sistemas especialistas na década de 1970, as regras são a forma de representação originalmente escolhida [22]. A maioria das aplicações sobre metodologias em sistemas especialistas, publicadas entre 1984 e 2016, continuam dedicando-se ao uso de regras para a representação do conhecimento [77]. Estudos como [31, 47, 85] demonstram a continuidade, aplicabilidade e contemporaneidade da abordagem baseada em regras.

Segundo Efstathiou [22] há dois tipos de inferência que são comumente aplicados a sistemas especialistas para a dedução da informação, o encadeamento para frente (*forward chaining*) e o encadeamento regressivo (*backward chaining*). O primeiro mecanismo obtém a solução a partir da procura de regras cujas condições atendem a fatos previamente conhecidos, e cada nova solução constitui um novo fato. Esse processo é continuamente repetido até que nenhuma informação a mais seja adicionada na lista de fatos

conhecidos. O encadeamento regressivo, por outro lado, relaciona conclusões conhecidas ou hipotéticas com as regras, a fim de determinar sua veracidade, e então tornando-se um fato [27].

A abordagem baseada em regras, no entanto, apresenta limitações. As regras não são tão úteis para representar conhecimento genérico ou princípios gerais, além de serem inflexíveis [22]. A velocidade do sistema baseado em regras não é dominante em comparação a outros tipos de sistemas especialistas, uma vez que todo o conjunto de regras no banco de dados precisa ser averiguado quando uma regra é usada [71], de modo que novos formatos de representação de conhecimento foram ganhando popularidade [22].

Diversas outras técnicas, como aprendizado indutivo, lógica *fuzzy*, sistemas baseado em caso (*case-based*) e redes neurais artificiais têm sido usadas para o desenvolvimento de sistemas especialistas, particularmente para a representação do conhecimento [71, 77].

Segundo Zadeh [83], a lógica *fuzzy* é empregada em sistemas especialistas como uma alternativa para lidar com as incertezas tanto possibilistas quanto probabilísticas inerentes à base de conhecimento que alimentam os sistemas. Conforme o autor, muitas informações contidas na base de conhecimento são imprecisas, ambíguas, incompletas ou inexatas, uma vez que se originam do conhecimento humano. Nesse contexto, diferentemente da lógica booleana incorporada na abordagem clássica baseada em regras, a inferência pela lógica *fuzzy* associa a cada hipótese (regra) um fator de certeza, de modo que a regra pode ser expressa por uma probabilidade condicional, tal que a probabilidade resultante é definida como um número difuso.

Cahyaningrum et al. [14] destacam que a lógica *fuzzy* beneficia sistemas especialistas ao lidar simultaneamente com dados precisos e imprecisos, por meio de conjuntos *fuzzy* que variam de 0 a 1. Isso permite uma representação mais realista das incertezas, contribuindo para decisões mais informadas. Componentes como o *fuzzifier*, motor de inferência, base de conhecimento *fuzzy* e *defuzzifier* proporcionam flexibilidade e adaptabilidade ao sistema [72]. Complementando essa visão, Mangla et al. [43] destacam que a abordagem é eficaz para prever problemas desconhecidos e complexos, sendo uma ferramenta eficiente em sistemas de apoio à decisão.

Aplicações dos sistemas especialistas *fuzzy* têm sido recorrentes ao longo dos anos. Esses sistemas são aplicados em uma variedade de domínios, incluindo planejamento ecológico e ambiental, sistemas de controle, integração de conhecimento, diagnóstico e detecção de falhas, classificação de sistemas, diagnósticos médicos, segurança de computadores, classificação de dados, entre outros [42].

As aplicações dos sistemas especialistas *fuzzy* são revisados por Tavana e Hajipour [72] entre o período de 1982 a 2018. Os autores evidenciam o aumento de estudos sobre os sistemas *fuzzy* durante o período, mais significativo no ano de 2018, concentrando-se na área de diagnóstico médico. Dentre as pesquisas sobre os sistemas especialistas *fuzzy*, novos algoritmos híbridos têm sido propostos para melhorar seu desempenho, os quais frequentemente são combinados com redes neurais artificiais.

Sistemas especialistas e redes neurais tem características únicas e às vezes complementares. Enquanto os sistemas especialistas

expressam uma abordagem lógica e simbólica, as redes neurais usam uma abordagem numérica e dependente [72].

A computação neural pode ser combinada com software convencional para produzir sistemas híbridos de alta eficácia. Embora os sistemas especialistas ofereçam a vantagem de poder modificar a base de conhecimento à medida que novas regras e informações surgem, a aquisição de conhecimento continua a exigir intensa interação humana, tornando-se um obstáculo ao desenvolvimento rápido e generalizado dos sistemas especialistas [46].

A geração de uma base de conhecimento ainda mostra-se como uma tarefa difícil em sistemas especialistas desenvolvidos com a abordagem baseada em regras devido à sua inerente exigência de regras explícitas. Esse problema surge porque muito do conhecimento humano é implícito, principalmente o conhecimento especializado [82].

O uso da rede neural, por sua vez, possibilita a modificação da base de conhecimento por meio do treinamento do conjunto de dados, eliminando assim mudanças de programação e reconstrução de regras [46]. Redes neurais não requerem uma série completa de regras e programas extensivos para interpretá-las. Uma rede neural aprende o processo de tomada de decisão humana por meio de exemplos [67].

Na combinação do sistema especialista baseado em regras com a rede neural artificial, a rede é principalmente empregada para gerar a base de conhecimento, e o sistema especialista é processado para fornecer explicação, usando a relação entre a entrada e saída da rede [82]. De forma semelhante, Ghanmi et al [26] e Souza et al [62] abordam a integração de redes neurais com lógica *fuzzy*. No sistema híbrido desenvolvido por Souza et al. [62] para a identificação de malwares, as camadas da rede neural são aplicadas para as etapas de fuzzificação, ativação e geração de saída final do modelo.

Abordagens com uso de Redes Neurais Artificiais têm se destacado devido à grande quantidade de dados gerada continuamente em diferentes campos científicos e industriais ao redor do mundo [68]. O aprendizado profundo (*deep learning*) permitiu o uso de redes neurais com grande número de camadas e neurônios para lidar com grandes quantidades de informações e, assim, ultrapassar as limitações mais significativas que existiam nas abordagens precursoras no processo de formação da base de conhecimento [4] por meio da integração de memória associativa em seu procedimento de inferência [86].

No entanto, devido à imprecisão da abordagem orientada a dados na presença de incertezas e ruídos nos dados, têm-se observado a junção dessa abordagem com os sistemas especialistas baseados em conhecimento, visto que estes podem abordar vários tipos de incerteza [33].

Com o desenvolvimento das técnicas de aprendizado de máquina, essas abordagens híbridas têm ganhado relevância ao combinar as características fortes de cada metodologia [1]. Elas têm sido amplamente usadas na solução de problemas não estruturados nos anos recentes, como no reconhecimento de imagens e processamento de linguagem natural [40, 73].

Recentes avanços nos modelos de aprendizagem profunda em linguagem natural, como o GPT, têm demonstrado a capacidade de compreender instruções em linguagem humana e gerar textos coerentes por meio da probabilidade associada a sequências de palavras [84]. Isso possibilita a transformação do processo de aquisição

de conhecimento realizado pelos sistemas especialistas, agregando conhecimento denso sobre uma área de domínio a partir de textos, a exemplo do estudo de Du et al. [20].

O sistema especialista descrito por Du et al. [20] incorpora um modelo de linguagem de grande escala (LLM) e baseia-se no GPT-4 para processar dados de sensoriamento remoto de florestas. Na construção da base de conhecimento do domínio, é utilizada uma API OpenAI Embedding para incorporar texto de conhecimento específico e convertê-lo em vetores numéricos. Em seguida, o processo de inferência ocorre com a utilização do modelo GPT-4 na base de dados vetorizada. A extração de regras de domínio a partir de textos, baseada em LLM, também é desenvolvida por Janatian et al. [35] para extrair automaticamente representações estruturadas da legislação e auxiliar a criação de um sistema especialista jurídico.

Em sistemas que utilizam modelos LLMs, a presença de um especialista pode melhorar a relevância e a precisão das respostas. No entanto, a configuração de prompts personalizados e ajustes finos podem ser feitos automaticamente pelo sistema, permitindo que ele funcione efetivamente em muitos casos sem supervisão direta do especialista, tornando o envolvimento do especialista opcional [78]. A metodologia proposta por Wang et al. [78] garante que o sistema esteja aderente aos requisitos de domínio específicos. Contudo, a abordagem apresenta algumas limitações, como um tempo de processamento mais elevado nas inferências em comparação a modelos tradicionais de aprendizado de máquina e redes neurais, além de dificuldades em escalabilidade e implantação devido à significativa demanda computacional em termos de memória e processamento.

Ao longo das décadas, os sistemas especialistas evoluíram de abordagens exclusivamente baseadas em regras para metodologias híbridas que integram redes neurais, aprendizado profundo e lógica *fuzzy*. Como evidenciado pelos artigos citados, essas mudanças aumentaram a adaptabilidade e a capacidade de lidar com grandes volumes de dados e incertezas, expandindo sua aplicação em áreas complexas. Considerando esse cenário, torna-se fundamental avaliar as recentes tendências metodológicas, seus benefícios, e os desafios enfrentados, especialmente na integração de modelos avançados de IA.

Sistemas especialistas com inteligência artificial utilizam redes de regras-fato para tomar decisões com base em fatos e regras predefinidas [64]. A técnica de gradiente descendente permite ajustar esses sistemas, promovendo precisão ao associar fatos e minimizar erros. Ao estruturar redes híbridas, esses sistemas podem combinar o aprendizado com a lógica, garantindo conformidade a regras enquanto aprimoram a capacidade preditiva.

Em conjunto com a inteligência artificial, os sistemas especialistas aplicam técnicas como redes baseadas em regras e redes neurais para identificar eventos relevantes em dados textuais não estruturados. O processamento de linguagem natural permite extrair e classificar eventos em registros diários, aprimorando a precisão e eficiência em operações de monitoramento [17]. Esse método combina regras linguísticas e aprendizado profundo, criando uma ferramenta robusta para análise automatizada em áreas complexas.

A técnica do sistema especialista “perfeito” propõe um modelo abstrato para avaliar o desempenho de algoritmos de *machine learning*. Esse modelo permite a geração de dados sem ruído para treinar e testar redes neurais e sistemas especialistas com diferentes características [65]. A abordagem é útil para validar o desempenho

de sistemas, ajustando-os antes de introduzir dados reais. O método facilita a análise da resiliência do sistema a perturbações e a sua capacidade de generalização.

O desenvolvimento de sistemas especialistas treinados em hardware busca otimizar o uso de redes de regras-fato, ajustando pesos com o método de gradiente descendente. Implementado em circuitos, esse modelo visa reduzir os custos e consumo energético em comparação com sistemas baseados em software, ao mesmo tempo que garante previsibilidade temporal, essencial em aplicações de controle em tempo real [6]. Esse sistema pode ser aplicado em áreas de automação, onde precisão e eficiência são requisitos críticos.

Sistemas especialistas utilizam motores de inferência, como o encadeamento direto, para realizar diagnósticos automatizados em problemas de hardware e software [10]. Esse método compara sintomas registrados com regras, permitindo identificar a causa de falhas de maneira eficiente e acessível. O encadeamento direto é especialmente útil em sistemas de diagnóstico, pois baseia-se em regras *IF-THEN*, que facilitam a compreensão e aplicação em diferentes contextos de manutenção.

### 3 TRABALHOS RELACIONADOS

O estudo de Liao [42] oferece uma revisão das metodologias e aplicações de sistemas especialistas (ES) entre 1995 e 2004, destacando a evolução de técnicas como redes neurais, lógica *fuzzy*, sistemas baseados em regras e agentes inteligentes. O estudo também identifica tendências futuras, como a integração de metodologias sociais, cognitivas e de comportamento humano na criação de sistemas mais adaptativos. O trabalho de Liao [42] se relaciona ao contexto do presente estudo ao abordar como as metodologias de sistemas especialistas evoluíram e se diversificaram ao longo dos anos, acompanhando o avanço da inteligência artificial e sua aplicação em diferentes setores.

Uma análise mais abrangente dos avanços dos sistemas especialistas híbridos entre 1988 e 2010 é apresentado no trabalho de Sahin et al. [54]. O autor destaca a integração de técnicas como redes neurais, lógica *fuzzy* e teoria dos conjuntos aproximados (TCA) aos sistemas especialistas. Os algoritmos mais utilizados incluem backpropagation para redes neurais e algoritmos genéticos para otimização de regras. Durante esse período, a aplicação dessas técnicas evoluiu significativamente em áreas como diagnóstico médico e detecção de falhas industriais, proporcionando sistemas mais adaptáveis e eficazes no tratamento de incertezas e dados incompletos.

A evolução dos sistemas especialistas desde seu desenvolvimento na década de 1970 até 2016 é apresentado no trabalho de Tan et al. [70]. Os autores também diagnosticaram abordagens de IA, como sistemas baseados em regras e lógica *fuzzy*, categorizando aplicações em sete disciplinas principais. Os resultados indicam que esses sistemas aprimoram a eficiência operacional e têm potencial para substituir funções em diversas áreas.

Na análise longitudinal de mais de 30 anos de estudos de caso de sistemas especialistas, desde de 1984 até o ano de 2016, apresentada por Wagner [77], destaca a evolução das técnicas de aquisição de conhecimento, representação do conhecimento e impacto dos sistemas em várias indústrias. A pesquisa mostra como os sistemas clássicos baseados em regras evoluíram para modelos híbridos,

incorporando técnicas de IA modernas, como redes neurais. Essa transição reflete diretamente o contexto da evolução dos sistemas especialistas, que ao longo dos anos passaram a integrar abordagens mais complexas e flexíveis, acompanhando as inovações em inteligência artificial e aprendizado de máquina.

O artigo de Janjanam et al. [36], por sua vez, oferece uma visão geral da arquitetura dos sistemas, com foco nas metodologias como encadeamento para frente, encadeamento regressivo e método de valor de regra. Ele aborda os desafios na aquisição de conhecimento, mecanismo de inferência e interface com o usuário. O estudo também destaca a evolução desses sistemas ao longo dos anos, enfatizando a necessidade de ferramentas mais eficientes para o desenvolvimento.

As técnicas de visão computacional usadas para melhorar a precisão e eficiência dos sistemas especialistas são exploradas em [44]. O estudo centra-se principalmente em como o aprendizado profundo e redes neurais convolucionais (CNNs) podem ser integrados com sistemas especialistas para processar grandes volumes de dados visuais. Isso reflete diretamente a evolução dos sistemas especialistas, que agora se beneficiam de tecnologias avançadas para lidar com tarefas complexas, como a análise de imagens e tomada de decisão automatizada.

Kayumov et al. [38] avalia as metodologias de detecção de defeitos em tecidos usando sistemas especialistas. Os autores classificam os métodos em sete categorias, incluindo abordagens estruturais, estatísticas, baseadas em modelos, e de aprendizado de máquina. O estudo destaca a importância de sistemas automatizados de detecção de defeitos para melhorar a qualidade de produtos têxteis e discute os desafios de adquirir imagens de alta qualidade para análise. O estudo de Kayumov et al. [38] contribui à presente abordagem ao demonstrar como os sistemas especialistas evoluíram para lidar com novas demandas industriais usando técnicas avançadas de IA.

Incluindo o aspecto estrutural dos sistemas, Ahmadi e Abadi [5] exploram a utilização das propriedades de orientação a objetos da linguagem C++ no desenvolvimento de sistemas especialistas para planejamento estratégico. A pesquisa demonstra como o uso de C++ facilita o gerenciamento da complexidade do código e otimiza o processo de planejamento estratégico. Ahmadi e Abadi [5] mostra a evolução dos sistemas especialistas ao adotar técnicas mais eficientes de programação para lidar com problemas estratégicos complexos.

Os autores Goda e Bay [29] exploram o uso do método de encadeamento para frente (*forward chaining*) em sistemas especialistas para diagnóstico de pragas e doenças em plantas, com foco na agricultura. A pesquisa revela que essa técnica é amplamente utilizada em sistemas especialistas devido à sua capacidade de processar fatos conhecidos e aplicar regras de inferência para chegar a conclusões precisas, beneficiando os agricultores com diagnósticos rápidos e eficientes.

Na pesquisa de Dattawadkar e Vani [19] apresenta-se um sistema especialista baseado em lógica *fuzzy* para detecção de enchentes, utilizando tecnologia IoT e LoRa. O estudo destaca a capacidade da lógica *fuzzy* de lidar com dados imprecisos e não lineares, fornecendo resultados que têm semelhança com resultados humanos. A integração com LoRa, uma tecnologia sem fio de baixo consumo, possibilita a coleta eficiente de dados de sensores em áreas remotas. O estudo exemplifica como os sistemas especialistas evoluíram para

incorporar novas tecnologias, como IoT, em aplicações críticas para detecção de desastres.

O estudo de Inayatulloh et al. [32] propôs um modelo de sistema especialista para aprimorar a performance de advogados, utilizando inteligência artificial para otimizar o processo de análise de casos jurídicos. A pesquisa combinou abordagens qualitativas e quantitativas para identificar fatores de desempenho e necessidades de tecnologia na advocacia. O modelo resultante integra um motor de inferência e uma base de conhecimento, possibilitando maior eficiência no processamento de dados legais e melhorando a tomada de decisões. Esse sistema contribui para a evolução da IA aplicada ao setor jurídico, tornando-o mais acessível e automatizado.

Yin et al. [81] explora o uso de inteligência artificial em veículos aéreos não tripulados (UAVs), discutindo aplicações como sistemas especialistas para tomada de decisões em combate aéreo e planejamento automático para desvio de obstáculos. Os autores analisam como métodos de aprendizado profundo e redes neurais aprimoram a detecção de alvos e a percepção situacional em UAVs. Além disso, o artigo destaca a importância da IA distribuída para coordenação entre múltiplos UAVs, promovendo a colaboração em tarefas complexas. Essa integração ilustra a evolução do desempenho em sistemas especialistas aplicados a tecnologias autônomas.

O artigo de Liang e Straub [41] investiga o uso de um sistema especialista treinado por aprendizado de máquina para detectar conteúdo enganoso online, baseando-se em características de mensagens, sem considerar o texto em si. Os autores exploram fatores como contexto textual, histórico do autor e emoção, utilizando redes configuradas para avaliar a relevância desses elementos na detecção de conteúdo falso. Essa abordagem contribui para o campo de sistemas especialistas aplicados à segurança cibernética, destacando o potencial da IA para aprimorar a análise de confiabilidade em mídias sociais.

O estudo de Egereonu et al. [23] apresenta o desenvolvimento de um sistema especialista para diagnóstico de doenças musculoesqueléticas, integrando técnicas de aprendizado de máquina e regras baseadas em conhecimento. Com uma precisão de 92%, o sistema permite diagnósticos rápidos e confiáveis ao comparar dados clínicos com padrões predefinidos, facilitando o trabalho de profissionais da saúde. Esse modelo mostra como a IA pode melhorar a eficiência e a precisão no diagnóstico médico, ilustrando a evolução dos sistemas especialistas na área da saúde e reforçando sua importância para suporte clínico.

## 4 METODOLOGIA

A revisão de literatura é uma abordagem essencial para conceituar áreas de pesquisa e sintetizar pesquisas anteriores [48], e pode ser a melhor ferramenta metodológica para fornecer respostas [61].

Diferentes diretrizes são empregadas para conduzir uma revisão de literatura. No escopo qualitativo, a revisão narrativa e descritiva direcionam-se para a interpretação, descrição e identificação de padrões na literatura existente [53]. A pesquisa qualitativa é importante para revelar fatores que podem fundamentar a construção de testes e modelos utilizando dados quantitativos, captar padrões e desenvolver hipóteses relevantes, enriquecendo a análise e interpretação dos dados coletados, o que é essencial para direcionar futuras pesquisas na área de sistemas de informação [76].

O presente estudo utiliza a revisão narrativa da literatura, caracterizada por um processo não exaustivo, que permite a identificação ampla de contribuições metodológicas sem as restrições formais de uma revisão sistemática [53]. O estudo foi conduzido em quatro etapas principais:

- (1) Definição do escopo da revisão: A Revisão foi estruturada para responder duas questões principais: Quais são os principais avanços metodológicos em sistemas especialistas após 2017, e como essas metodologias impactam a inferência e a aquisição de conhecimento?
- (2) Busca e seleção de artigos: A coleta de trabalhos foi realizada nas bases *ScienceDirect*, *Scopus* e *Google Scholar*, utilizando palavras-chave como “*expert systems*” e variações como “*machine learning in expert systems*”. Artigos publicados entre 2017 e 2024, cujo conteúdo trata de novas metodologias ou aplicações relevantes baseado no título, resumo e palavras-chaves foram priorizados;
- (3) Análise dos trabalhos identificados: Os artigos selecionados foram analisados sob três dimensões principais, metodologia inferencial, aquisição de conhecimento e desempenho comparativo baseado em critérios de precisão diagnóstica, tempo de resposta e eficiência computacional relatada nos trabalhos; A análise de desempenho realiza uma comparação quantitativa dos *benchmarks* de precisão e *recall* mencionados nos artigos, observando as variações no desempenho entre diferentes aplicações.
- (4) Síntese dos resultados: Os achados foram organizados em tendências e desafios.

## 5 RESULTADOS E DISCUSSÕES

Os resultados e discussões centram-se em duas estruturas importantes para o avanço dos sistemas especialistas: a aquisição de conhecimento e os métodos inferenciais.

Nessa seção são discutidos os avanços e as limitações encontrados nesses dois componentes e o desempenho dos sistemas modernos, evidenciando o impacto das metodologias na eficiência e adaptabilidade dos sistemas especialistas.

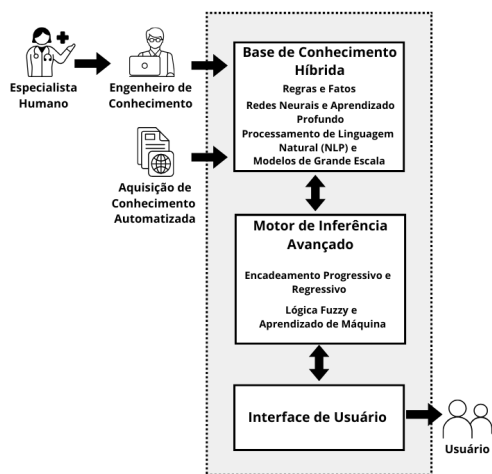
Enquanto os sistemas especialistas desenvolvidos na década de 1970 utilizavam uma base de conhecimento rígida codificada em regras e inferência limitada, tornando-se inflexíveis e menos eficientes em cenários de incertezas ou com bases de conhecimento crescentes, a estrutura moderna supera essas limitações com aprendizado automático, lógica *fuzzy* e módulos adaptativos, promovendo maior flexibilidade e desempenho.

A Figura 1 apresenta a estrutura moderna dos sistemas especialistas, destacando a integração de métodos híbridos e novas tecnologias de IA, conforme discutido nesta seção.

### 5.1 Aquisição do Conhecimento

A aquisição de conhecimento é frequentemente considerada o maior desafio no desenvolvimento de sistemas especialistas. Esse processo exige a extração e organização precisas de informações especializadas, provenientes tanto de documentos quanto do conhecimento tácito de especialistas. Para isso, técnicas como entrevistas, observação de casos reais e análise de literatura são essenciais, garantindo

**Figura 1: Estrutura Moderna de Sistemas Especialistas Integrando IA e Métodos Híbridos**



Fonte: Elaborada pelos autores.

que o sistema consiga representar o conhecimento humano de forma aplicável e confiável dentro de seu domínio [18].

Nos estágios iniciais, a aquisição de conhecimento em sistemas especialistas baseava-se fortemente no raciocínio lógico para obter conclusões a partir de grandes conjuntos de regras “Se, Então”, criadas para capturar o conhecimento dos especialistas. Essa abordagem lógica permitiu que os sistemas resolvessem problemas em áreas como medicina, engenharia e negócios, onde conjuntos de regras explicitamente definidas podiam modelar o raciocínio dos especialistas em cenários específicos [12].

No entanto, com a expansão dos sistemas especialistas para domínios mais variados, surgiram limitações importantes. As regras, por serem rígidas e específicas, mostraram-se inflexíveis e menos eficazes para capturar conhecimentos mais amplos ou adaptar-se a situações dinâmicas e diversificadas. Isso revelou a necessidade de abordagens mais sofisticadas para lidar com o conhecimento em contextos menos previsíveis [22].

A transição para bases de conhecimento mais robustas é ilustrada por Kaplan et al. [37], que apresentam uma base de conhecimento composta por regras e fatos para orientar decisões no design de motores, e por Strydom [66], que destaca o uso de sistemas baseados em regras para integrar conhecimentos declarativos e procedimentais em plantas industriais. Embora eficazes, esses sistemas ainda enfrentaram as limitações da rigidez das regras, restringindo sua aplicabilidade a cenários bem definidos [22].

Com o avanço das técnicas de representação de conhecimento, as aplicações dos sistemas especialistas *fuzzy* têm se mostrado recorrentes e eficazes em diversos domínios [42]. Casado et al. [25] exploram esses recursos para facilitar a representação de relações causais complexas e melhorar a interpretabilidade dos sistemas, agregando um grau de precisão superior na modelagem de inferências.

Essa evolução foi particularmente notável na área médica, onde Chen et al. [15] demonstram como frameworks simbólicos computacionais permitem que diretrizes clínicas sejam adaptadas para atender às necessidades individuais dos pacientes, aumentando a flexibilidade e a capacidade de refletir nuances do conhecimento médico. Em outra abordagem, Setiawan et al. [58] utilizam ontologias para estruturar características taxonômicas e definir axiomas para a identificação precisa de espécies, demonstrando o potencial dos sistemas especialistas em lidar com conhecimentos taxonômicos complexos e autoajustáveis.

O surgimento de métodos de aprendizado de máquina impulsionou ainda mais a evolução na aquisição de conhecimento. Com o uso de técnicas avançadas, como o módulo BRB-DL de Islam et al. [34], que incorpora novas crenças e ajusta-se continuamente com base em dados atualizados, o sistema especialista consegue lidar com grandes volumes de dados incertos de forma mais precisa.

Purnamasari et al. [39] utilizam sistemas especialistas *fuzzy* em análise de adequação de terras para previsão de rendimento agrícola. Neste modelo, critérios ecológicos são estruturados em uma base de conhecimento, o que possibilita definir regras *fuzzy* para classificar a adequação de diferentes áreas para o cultivo de mandioca. Por meio da utilização de funções de pertencimento *fuzzy*, o sistema traduz o conhecimento dos especialistas em termos computacionais que permitem a avaliação contínua da adequação das terras, adaptando-se a variáveis ecológicas e promovendo previsões agrícolas mais precisas.

Na área de diagnósticos médicos, Santosa et al. [56] mostram como uma base de conhecimento estruturada em lógica *fuzzy* permite classificar sintomas de catarata em diagnósticos específicos, como “Imatu” - estágio inicial da catarata, “Matu” - estágio mais avançado e “Hypermatu” - estágio ainda mais avançado. Essa estrutura traduz o conhecimento clínico em regras que permitem ao sistema lidar com a incerteza nos dados de entrada de forma mais eficaz e adaptável ao comportamento dos sintomas.

Blagodatsky et al. [11] exploram o desenvolvimento de uma base de conhecimento otimizada para sistemas especialistas voltados à análise de projetos tecnológicos complexos, utilizando algoritmos de aprendizado de máquina. A formalização de critérios de avaliação permite traduzir variáveis, como o desempenho do gestor e a viabilidade comercial, em regras de decisão que refletem o conhecimento especialista sobre o potencial de cada projeto. Ao automatizar essa estrutura de regras, o sistema é capaz de gerar recomendações ajustadas às condições dinâmicas de novos dados, promovendo a adaptabilidade do sistema de suporte à decisão.

## 5.2 Métodos Inferenciais

A estrutura fundamental dos sistemas especialistas é composta por dois componentes principais: a base de conhecimento e a engenharia ou mecanismo de inferência. A base de conhecimento armazena os dados e as regras que o sistema utiliza para gerar soluções, enquanto a engenharia de inferência é responsável por aplicar essas regras a novos dados para chegar a conclusões [36]. Este mecanismo de inferência é essencial, pois é ele quem realiza o raciocínio necessário para resolver o problema em questão. Utilizando os dados armazenados, a engenharia de inferência responde

às requisições dos usuários, aplicando as regras para gerar soluções e tomar decisões [27].

Sendo considerado o “cérebro” do sistema especialista, o mecanismo de inferência é projetado para determinar qual técnica de busca heurística deve ser usada para explorar as regras da base de conhecimento para resolver problemas, responder a perguntas ou tomar decisões específicas dentro de um domínio [74]. As duas abordagens comuns de busca, o encadeamento progressivo (*Forward Chaining*) e o encadeamento regressivo (*Backward Chaining*) são técnicas realizadas para realizar a correspondência entre as regras da base de conhecimento e os dados presentes no banco de fatos [22].

Historicamente, a primeira implementação importante de um sistema especialista foi o DENDRAL, que utilizava uma combinação de inferência heurística com o paradigma Generate-Test. Esse paradigma é uma técnica de busca que permite encontrar soluções por meio da geração e teste sistemático de alternativas. A abordagem de gerar hipóteses e testar essas hipóteses, de forma iterativa, tornou-se uma das bases da lógica de inferência desses sistemas. Após o DENDRAL, as técnicas de encadeamento (*Forward e backward*) foram base no processo inferencial dos sistemas especialistas pioneiros

Ao longo do tempo, os sistemas especialistas evoluíram para adotar abordagens mais sofisticadas. As técnicas de encadeamento foram aprimoradas, com ênfase na busca por soluções cada vez mais eficientes e adaptativas, conforme o sistema enfrentava novos tipos de problemas, conforme descrito na subseção 5.2.1.

**5.2.1 Tendências em métodos inferenciais.** Os sistemas especialistas, desde suas versões iniciais com a inferência baseada em regras, sempre se apoiaram em métodos inferenciais para tomar decisões. Esses sistemas eram projetados para inferir conclusões a partir de um conjunto de regras predefinidas, criando um processo de raciocínio dedutivo [13]. No entanto, essa abordagem inicial se limitava à rigidez das regras, incapaz de lidar com incertezas ou variabilidade nos dados. A inovação seguinte foi a introdução da lógica *fuzzy*, que não só permitiu a modelagem de incertezas, mas também possibilitou uma maneira mais flexível de inferir conclusões. Sistemas como o baseado em lógica *fuzzy* passaram a integrar valores imprecisos, melhorando a capacidade de inferência em cenários complexos, como no diagnóstico médico [49] e na previsão de falhas [3].

Wagner et. al [77] observou um declínio acentuado do sistema especialista “clássico” em favor de sistemas híbridos baseados em conhecimento. Esses novos sistemas normalmente empregam uma variedade de técnicas de IA, incluindo redes neurais e lógica *fuzzy* em combinação com regras.

A construção de sistema híbrido usando o *Case-Based Reasoning (CBR)* com as Redes Neurais profundas é proposto para lidar com as incertezas, que são difíceis de lidar em sistemas convencionais baseados em regras [57]. Técnicas de aprendizado profundo (deep learning) permitem que os sistemas identifiquem padrões complexos nos dados e façam previsões com alto grau de precisão, revolucionando áreas como a saúde [28] e a engenharia preditiva [9].

A incorporação de sistemas híbridos representa uma inovação aos métodos de inferência ainda mais significativos. Estes sistemas combinam abordagens distintas como a lógica *fuzzy*, redes neurais

e aprendizado de máquina, otimizando a inferência ao explorar as forças de cada uma dessas metodologias. Alowaidi, Husam, et al. [9] ao combinar redes neurais convolucionais (CNNs) e sistemas baseados em regras de crença (belief rule base) para diagnosticar falhas em sistemas hidrelétricos, mostra a capacidade dos sistemas híbridos em inferir com base em grandes volumes de dados não estruturados. Na integração da Lógica *Fuzzy*, Entropia e Redes Neurais para previsão de chuvas na monção indiana, a inferência é realizada pela combinação desses métodos, onde a lógica *fuzzy* gerencia incertezas, a entropia auxilia na análise da variação dos dados, e a rede neural aprimora o aprendizado a partir de padrões históricos [59].

Evidencia-se também a integração de sistemas especialista com técnicas de aprendizado de máquina. Em [8] o motor de inferência utiliza regras *fuzzy* e agrupamento de dados para classificar e priorizar os itens de inventário. Ramanathan e Sharma [52] abordam o uso de Máquinas de Vetores de Suporte (SVM) como técnica de inferência em um sistema baseado em conhecimento que lida com múltiplas classificações. A técnica SVM é integrada ao motor de inferência para categorizar dados em várias classes, melhorando a precisão em problemas complexos de classificação.

Uma das inovações recentes no campo da IA é a utilização de modelos de linguagem de grande escala (LLMs). A integração dessa metodologia a sistemas baseados em conhecimento, como o Med-PaLM 2 [60], Radiology-Llama2 [60], introduz uma nova camada de inferência ao permitir que os sistemas baseados em conhecimento não apenas processem dados estruturados, mas também interpretem informações não estruturadas, como textos. Esses modelos são capazes de extrair informações relevantes de fontes vastas e dinâmicas, oferecendo inferências baseadas em aprendizado contínuo e adaptativo, o que os torna robustos e flexíveis.

A evolução dos métodos inferenciais nos sistemas especialistas reflete um avanço contínuo em direção a maior adaptabilidade, precisão e capacidade de lidar com incertezas. O avanço das metodologias híbridas, juntamente com a incorporação de redes neurais e os modelos de linguagem de grande escala, neste último caso de modo ainda embrionário, tem permitido que esses sistemas se adaptem a um mundo cada vez mais dinâmico e repleto de informações complexas. Em vez de depender de regras fixas, os sistemas especialistas modernos fazem uso de inferências baseadas em aprendizado, o que os torna cada vez mais aplicáveis em diversas áreas, como a medicina, engenharia e finanças. O futuro dos sistemas especialistas dependerá da capacidade de integrar e otimizar essas metodologias, proporcionando soluções mais eficazes e precisas em uma gama ainda mais ampla de contextos.

### 5.3 Desempenho de Sistemas Especialistas

O estudo de Egereonu et al. [23] sobre o sistema especialista desenvolvido para diagnóstico de doenças musculoesqueléticas destaca um desempenho elevado, com precisão de 92% na identificação de padrões clínicos. Esse sistema, ao integrar aprendizado de máquina e regras baseadas em conhecimento, aprimora o diagnóstico, permitindo maior rapidez e precisão. A implementação resultou em benefícios notáveis para profissionais da saúde, reduzindo o tempo de diagnóstico e melhorando a assertividade em tratamentos complexos. O uso de dados clínicos estruturados permitiu um

Tabela 1: Quadro comparativo de sistemas especialistas históricos e novas metodologias encontradas na literatura revisada

1965–1980: Sistemas Especialistas Iniciais		
Sistema	Método	Descrição / Limitações
DENDRAL (1965, [24]) MYCIN (1974, [75]), PUFF (1978, [7]), XCON (1980, [45]) PROSPECTOR (1978, [30])	Paradigma Generate-Test Inferência baseada em regras	Sistema inicial com heurísticas para testar hipóteses. Regras rígidas. Sistemas para diagnóstico médico. Baixa generalização.
	Inferência probabilística	Sistema para prospecção mineral. Lento em inferências complexas.
1983–1994: Sistemas Fuzzy e Híbridos		
Sistemas Fuzzy (1983, [83])	Lógica Fuzzy	Sistemas desenvolvidos para lidar com incertezas e melhorar acurácia das decisões.
Sistemas Híbridos (1994, [82])	Redes Neurais + Regras	Integra aprendizado e inferência simbólica. Maior capacidade adaptativa.
2018–2021: Aplicações Modernas		
Sistema Fuzzy na saúde (2018, [56]) Blockchain para cidades inteligentes (2020, [4]) Sistema de detecção de conteúdo enganoso (2021, [65])	Método Fuzzy Mamdani IoT e Blockchain	Classificação de estágios da catarata. Controle seguro de sensores em cidades inteligentes.
	Aprendizado de Máquina	Detecta conteúdo enganoso em mídias sociais.
2022–2024: Avanços Recentes		
CBR (2022, [57]) Med-PaLM 2 (2023, [69]) Tree-GPT (2023, [20]) Sistema para diagnóstico de falhas (2024, [9])	CBR e Deep Learning LLMs GPT-4 Belief-Rule Base e Deep Learning	Resolução de problemas com base em casos passados. Interpretação de dados não estruturados em medicina. Sensoriamento remoto de florestas. Diagnóstico de falhas industriais.

Fonte: Elaborado pelos autores.

processamento eficaz, sendo um avanço significativo para o setor de saúde.

Liang e Straub [41] analisaram um sistema especialista para detecção de conteúdo enganoso em mídias sociais, observando uma acurácia de 85% no reconhecimento de padrões enganosos. O desempenho deste sistema foi atribuído ao uso de redes de aprendizado de máquina treinadas para identificar traços emocionais e contextuais nos textos. A capacidade de analisar múltiplos fatores, sem depender exclusivamente do conteúdo textual, proporcionou uma inferência mais robusta e precisa. Esses resultados reforçam o potencial de sistemas especialistas na segurança cibernética, contribuindo para identificar conteúdos falsos de forma eficiente.

Em relação ao sistema de detecção de enchentes baseado em lógica *fuzzy*, Dattawadkar e Vani [19] demonstraram a capacidade do sistema em interpretar dados imprecisos, com uma precisão de 87%. Esse desempenho indica uma elevada eficácia em monitorar áreas vulneráveis, mesmo com dados irregulares dos sensores. A integração de tecnologia IoT de baixo consumo permite que o sistema funcione de maneira eficiente em áreas remotas, onde o monitoramento de desastres é crucial. A lógica *fuzzy* foi fundamental para lidar com a variabilidade dos dados, promovendo um desempenho adaptativo em ambientes desafiadores.

No contexto industrial, [38] examinaram um sistema especialista para a detecção de defeitos em tecidos, observando uma precisão de 89%. O sistema utiliza redes neurais para identificar falhas e imperfeições, proporcionando uma análise mais detalhada dos padrões dos tecidos. A capacidade de trabalhar com dados visuais de alta qualidade elevou a confiabilidade do sistema, especialmente em linhas de produção com alto fluxo. Essa aplicação otimiza o controle de qualidade na indústria têxtil, reduzindo o desperdício e aprimorando a qualidade do produto final.

Um sistema especialista jurídico [32] foi proposto para o suporte em análise de casos, que alcançou um desempenho satisfatório,

reduzindo em 20% o tempo de análise de processos. A integração de IA nesse sistema possibilitou a automatização de tarefas repetitivas, aumentando a eficiência na preparação de documentos legais. Com base em dados de casos anteriores, o sistema aprimora o processo de decisão dos advogados, oferecendo suporte estratégico nas argumentações. O desempenho observado reforça a eficácia dos sistemas especialistas em áreas de análise intensiva, como o setor jurídico.

A Tabela 1 descreve comparativamente os sistemas históricos e inovações que surgiram para superar as limitações, demonstrando as novidades implementadas ao longo do tempo e os avanços mapeados nesta pesquisa.

## 6 CONCLUSÃO

Este estudo realizou uma revisão de literatura sobre os avanços nos sistemas especialistas (SEs), destacando aprimoramentos em métodos inferenciais e técnicas de aquisição de conhecimento. Abordagens como o aprendizado de máquina, além do uso de lógica *fuzzy*, fortaleceram a capacidade de inferência em cenários complexos, ampliando as aplicações para saúde e diagnóstico industrial.

As técnicas híbridas, como a integração de redes neurais com lógica *fuzzy* e modelos de linguagem de grande escala, possibilitaram aos SEs processar dados complexos, melhorando a precisão em ambientes com dados não estruturados e expandindo a aquisição de conhecimento. Esses avanços destacam os SEs como ferramentas essenciais em aplicações críticas e indicam direções para futuras pesquisas.

Estudos futuros podem complementar a revisão literária com abordagens mais robustas, como meta-análises, para validar tendências e identificar fatores limitantes. Também podem explorar outras estruturas dos SEs, como linguagens de programação, recursos computacionais e formas de reduzir o consumo computacional, além de investigar aplicações emergentes, como blockchain e computação quântica.



## REFERÊNCIAS

- [1] [n. d.]. A Hybrid Decision Support System for Adaptive Trading Strategies: Combining a Rule-based Expert System with a Deep Reinforcement Learning Strategy, author = Kwon, Yuhee and Lee, Zoonky, journal = Decision Support Systems, volume = 177, pages = 114100, year = 2024, publisher = Elsevier. ([n. d.]).
- [2] S. A. Abdymanapov, M. Muratbekov, S. Altynbek, and A. Barlybayev. 2021. Fuzzy Expert System of Information Security Risk Assessment on the Example of Analysis Learning Management Systems. *IEEE Access* 9 (2021), 156556–156565.
- [3] Andre de A Abilio, John D Wolodko, Richard B Eckert, and Torben L Skovhus. 2024. Development of an expert system for assessing failures in oil and gas pipelines due to microbiologically influenced corrosion (MIC). *Engineering Failure Analysis* 163 (2024), 108426.
- [4] Ricardo Carreño Aguilera, Miguel Patiño Ortiz, Adan Acosta Banda, and Luis Enrique Carreño Aguilera. 2021. Blockchain cnn deep learning expert system for healthcare emergency. *Fractals* 29, 06 (2021), 2150227.
- [5] Mohsen Ahmadi and Moein Qaisari Hasan Abadi. 2020. A Review of Using Object-Oriented Properties of C++ for Designing Expert System in Strategic Planning. *Computer Science Review* 37 (2020), 100282.
- [6] Fateen Ahmed and Jeremy Straub. 2022. Initial Work on the Development of a Hardware-Based Gradient Descent Trained Expert System. *Systems* 10 (2022), 160.
- [7] Janice S Aikins, John C Kunz, Edward H Shortliffe, and Robert J Fallat. 1983. PUFF: an expert system for interpretation of pulmonary function data. *Computers and biomedical research* 16, 3 (1983), 199–208.
- [8] Adnan Aktepe, AK Turker, S Ersoz, A Dalgic, and N Barisci. 2018. An inventory classification approach combining expert systems, clustering, and fuzzy logic with the ABC method, and an application. *South african journal of industrial engineering* 29, 1 (2018), 49–62.
- [9] Husam Alowaidi, GC Prashant, T Gopalakrishnan, and M Sundar Rajan. 2024. Convolutional Deep Belief Network Based Expert System for Automated Fault Diagnosis in Hydro Electrical Power Systems. *Journal of Machine and Computing* 4, 2 (2024), 327.
- [10] Muhammad Rehan Anwar. 2023. Analysis of Expert System Implementation in Computer Damage Diagnosis with Forward Chaining Method. *International Transactions on Artificial Intelligence* 1, 2 (2023), 139–155.
- [11] G A Blagodatsky, S V Vologdin, M M Gorohov, and D A Perevedencev. 2019. Intellectual training algorithm of expert system's knowledge base at weakly structured problem area. *Journal of Physics: Conference Series* 1260, 3 (aug 2019), 032006.
- [12] David C. Brock and Burton Grad. 2022. Expert Systems: Commercializing Artificial Intelligence. *IEEE Annals of the History of Computing* 44, 01 (Jan. 2022), 5–7.
- [13] Bruce G Buchanan and Reid G Smith. 1988. Fundamentals of expert systems. *Annual review of computer science* 3, 1 (1988), 23–58.
- [14] Yuniana Cahyaningrum, Suryono Suryono, and Budi Warsito. 2021. Fuzzy-Expert System for Indicator and Quality Evaluation of Teaching and Learning Processes Online Study Programs. In *E3S Web of Conferences*, Vol. 317. EDP Sciences, 05021.
- [15] Chen Chen, Adrien Ugon, Chenglu Sun, Wei Chen, Carole Philippe, and Andrea Pinna. 2019. Towards a Hybrid Expert System Based on Sleep Event's Threshold Dependencies for Automated Personalized Sleep Staging by Combining Symbolic Fusion and Differential Evolution Algorithm. *IEEE Access* 7 (2019), 1775–1792.
- [16] Seung Yeoun Choi and Sean Hay Kim. 2021. Knowledge Acquisition and Representation for High-Performance Building Design: A Review for Defining Requirements for Developing a Design Expert System. *Sustainability* 13, 9 (2021), 4640.
- [17] Lucas P. Cinelli, José F. L. Oliveira, et al. 2021. Automatic event identification and extraction from daily drilling reports using an expert system and artificial intelligence. *Journal of Petroleum Science and Engineering* 205 (2021), 108939.
- [18] Welbson Siqueira Costa and Shirly Christiany Macedo Silva. 2005. Aquisição de conhecimento: O grande desafio na concepção de sistemas especialistas. *Holos* 2 (2005), 37–46.
- [19] Deepak Jayant Dattawadkar and Sunita Babanrao Vani. 2021. A Review on Fuzzy Based Flood Warning Expert System using IoT and LoRa Technology. *International Research Journal of Engineering and Technology (IRJET)* 8, 3 (2021), 1601–1603.
- [20] Siqi Du, Shengjun Tang, Weixi Wang, Xiaoming Li, and Renzhong Guo. 2023. Tree-GPT: Modular Large Language Model Expert System for Forest Remote Sensing Image Understanding and Interactive Analysis. arXiv:2310.04698 [cs.CV] <https://arxiv.org/abs/2310.04698>
- [21] L. Audouin E. Chojnacki, W. Plumecocq. 2019. An expert system based on a Bayesian network for fire safety analysis in nuclear area. *Elsevier ScienceDirect Journals* 105 (2019), 28–40.
- [22] Janet Efstathiou. 1988. Expert systems, fuzzy logic and rule-based control explained at last. *Transactions of the Institute of Measurement and Control* 10, 4 (1988), 198–206.
- [23] Sunny Kalu Egereonu, Nnanna Ekedede, Anthony Ifeanyi Otuonye, Chukwue-meka Etus, Emmanuel Chukwudi Amadi, and Ubazue Ugochukwu Egereonu. 2024. Development of an Expert System for Diagnosing Musculoskeletal Disease. *International Journal of Intelligent Information Systems* 13, 4 (2024), 78–93.
- [24] Edward A. Feigenbaum and Bruce G. Buchanan. 1993. DENDRAL and Meta-DENDRAL: Roots of Knowledge Systems and Expert System Applications. *Artificial Intelligence* 59, 1 (1993), 233–240.
- [25] Álvaro Garzón Casado, Pablo Cano Marchal, Juan Gómez Ortega, and Javier Gámez García. 2019. Visualization and Interpretation Tool for Expert Systems Based on Fuzzy Cognitive Maps. *IEEE Access* 7 (2019), 6140–6150.
- [26] Hanen Ghanmi, Adel Ghith, and Tarek Benameur. 2023. Ring spun yarn quality prediction using hybrid neural networks. *The Journal of The Textile Institute* 114, 1 (2023), 66–74.
- [27] Joseph C Giarratano and Gary Riley. 1989. *Expert Systems: Principles and Programming*. Brooks/Cole Publishing Co.
- [28] Prashant Sadashiv Gidde, Shyam Sunder Prasad, Ajay Pratap Singh, Nitin Bhatheja, Satyartha Prakash, Prateek Singh, Aakash Saboo, Rohit Takhar, Salil Gupta, Sumeet Saurav, et al. 2021. Validation of expert system enhanced deep learning algorithm for automated screening for COVID-Pneumonia on chest X-rays. *Scientific Reports* 11, 1 (2021), 23210.
- [29] Karina Dhena Goda and Jenny Ronawati Bay. 2024. Forward Chaining Method in Expert System for Diagnosing Pests and Plant Diseases: A Systematic Literature Review. *Journal of Artificial Intelligence and Engineering Applications* 3, 3 (2024), 871–875.
- [30] Peter Edward Hart, Richard O Duda, and Marco T Einaudi. 1978. PROSPECTOR—a computer-based consultation system for mineral exploration. *Journal of the International Association for Mathematical Geology* 10, 5 (1978), 589–610.
- [31] Emam Hossain, Mohammad Shahadat Hossain, Pär-Ola Zander, and Karl Andersson. 2022. Machine learning with Belief Rule-Based Expert Systems to predict stock price movements. *Expert Systems with Applications* 206 (2022), 117706.
- [32] Muhammad Inayatullo, Rivaldhy N. Muhammad, Anisya Sonita, Onsardi, Diana, Vivit Fitriyanti, and Abnan Pancasilawati. 2022. Expert System Conceptual Model to Increase Lawyer Performance. *International Journal of Applied Engineering & Technology* 4, 2 (2022), 27–32.
- [33] Raihan Ul Islam, Mohammad Shahadat Hossain, and Karl Andersson. 2020. A deep learning inspired belief rule-based expert system. *IEEE Access* 8 (2020), 190637–190651.
- [34] Raihan Ul Islam, Mohammad Shahadat Hossain, and Karl Andersson. 2020. A Deep Learning Inspired Belief Rule-Based Expert System. *IEEE Access* 8 (2020), 190637–190651.
- [35] Samyar Janatian, Hannes Westermann, Jinzhe Tan, Jaromir Savelka, and Karim Benyekhlef. 2023. From Text to Structure: Using Large Language Models to Support the Development of Legal Expert Systems. arXiv:2311.04911 [cs.CL] <https://arxiv.org/abs/2311.04911>
- [36] Durgaprasad Janjanam, Bharathi Ganesh, and L. Manjunatha. 2021. Design of an expert system architecture: An overview. In *Journal of Physics: Conference Series*, Vol. 1767. IOP Publishing, 012036.
- [37] R. Kaplan, C.F. Landy, and V. Lun. 1989. An expert system for the design of 3-phase squirrel cage induction motors. *Transactions of the South African Institute of Electrical Engineers* 80, 1 (1989), 14–19.
- [38] Ahror Kayumov, Muslimjon Sobirov, and Khurshid Musayev. 2024. Methods of fabric defect detection using expert systems—a systematic literature review. *E3S Web of Conferences* 538 (2024), 04015.
- [39] Dohyeong Kim, Soyeon Caren Han, Yingru Lin, Byeong Ho Kang, and Sungyoung Lee. 2018. RDR-based knowledge based system to the failure detection in industrial cyber physical systems. *Knowledge-Based Systems* 150 (2018), 1–13.
- [40] Konstantin Kulagin, Mansur Salikhov, and Rustam Burnashev. 2023. Designing an Educational Intelligent System with Natural Language Processing Based on Fuzzy Logic. In *2023 International Russian Smart Industry Conference (SmartIndustryCon)*. 690–694.
- [41] Xinyu (Sherwin) Liang and Jeremy Straub. 2021. Deceptive Online Content Detection Using Only Message Characteristics and a Machine Learning Trained Expert System. *Sensors* 21 (2021), 7083.
- [42] Shu-Hsien Liao. 2005. Expert system methodologies and applications—a decade review from 1995 to 2004. *Expert Systems with Applications* 28, 1 (2005), 93–103.
- [43] Monika Mangla, Nonita Sharma, and Poonam Mittal. 2021. A fuzzy expert system for predicting the mortality of COVID'19. *Turkish Journal of Electrical Engineering and Computer Sciences* 29, 3 (2021), 1628–1642.
- [44] Yasunari Matsuzaka and Ryu Yashiro. 2023. AI-Based Computer Vision Techniques and Expert Systems. *AI* 4, 1 (2023), 289–302.
- [45] John McDermott. 1982. R1: A rule-based configurator of computer systems. *Artificial intelligence* 19, 1 (1982), 39–88.
- [46] Larry R Medsker. 1995. *Expert Systems and Neural Networks*. Springer Science & Business Media, 39–56.
- [47] Emad Mohamed, Parinaz Jafari, and Ahmed Hammad. 2022. Mixed qualitative–quantitative approach for bidding decisions in construction. *Engineering, Construction and Architectural Management* 29, 6 (2022), 2328–2357.

- [48] Guy Paré, Marie-Claude Trudel, Mirou Jaana, and Spyros Kitsiou. 2015. Synthesizing information systems knowledge: A typology of literature reviews. *Information Management* 52, 2 (2015), 183–199.
- [49] Vitaliy Polishchuk, Sergii Pavlov, Sergii Polishchuk, Sergii Shuvalov, Andriy Dalishchuk, Natalia Sachaniuk-Kavets'ka, Kuralay Mukhsina, and Abilkaiyr Nazerke. 2024. Medical Fuzzy-Expert System For Prediction of Engraftment Degree of Dental Implants in Patients With Chronic Liver Disease. *Informatyka, Automatyka, Pomiary w Gospodarce i Ochronie Środowiska* 14, 1 (2024), 90–94.
- [50] Julián Patiño-Ortiz ADAN ACOSTA BANDA R. CARREÑO AGUILERA, Miguel Patiño-Ortiz. 2020. Internet of Things Expert System for Smart Cities using the Blockchain Technology. *Miscellaneous* 29, 01 (2020), 2150036. <https://doi.org/10.1142/s0218348x21500365>
- [51] Mohaimenul Azam Khan Raiaan, Md Saddam Hossain Mukta, Kaniz Fatema, Nur Mohammad Fahad, Sadman Sakib, Most Marufatul Jannat Mim, Jubaeer Ahmad, Mohammed Eunus Ali, and Sami Azam. 2024. A review on large Language Models: Architectures, applications, taxonomies, open issues and challenges. *IEEE Access* (2024).
- [52] Thirumalaimuthu Thirumalaiappan Ramanathan and Dharmendra Sharma. 2017. Multiple classification using svm based multi knowledge based system. *Procedia computer science* 115 (2017), 307–311.
- [53] Ammar Rashid and Muhammad Mahboob Khurshid. 2022. A Descriptive literature review and classification of business intelligence and big data research. In *Science and Information Conference*. Springer, 865–879.
- [54] Seda Sahin, Mehmet R Tolun, and Reza Hassanpour. 2012. Hybrid expert systems: A survey of current approaches and applications. *Expert systems with applications* 39, 4 (2012), 4609–4617.
- [55] Shexmo Richarlison Ribeiro dos Santos, Raiane Eunice S. Fernandes, Marcos Cesar Barbosa dos Santos, Michel S. Soares, Fabio Gomes Rocha, and Sabrina Marczak. 2024. Increasing Test Coverage by Automating BDD Tests in Proofs of Concepts (POCs) using LLM. In *Proceedings of the XXIII Brazilian Symposium on Software Quality (SBQS '24)*. Association for Computing Machinery, New York, NY, USA, 519–525.
- [56] I Santosa, L Romla, and S Herawati. 2018. Expert System Diagnosis of Cataract Eyes Using Fuzzy Mamdani Method. *Journal of Physics: Conference Series* 953, 1 (jan 2018), 012138.
- [57] Shahryar Sarabi, Qi Han, Bauke de Vries, A Georges L Romme, and Dora Almassy. 2022. The nature-based solutions case-based system: a hybrid expert system. *Journal of Environmental Management* 324 (2022), 116413.
- [58] Foni A. Setiawan, Remy Puspasari, Lindung P. Manik, Zaenal Akbar, Yulia A. Kartika, Ika A. Satya, Dadan R. Saleh, Ariani Indrawati, Keiji Suzuki, Hatim Albasri, and Masaaki Wada. 2021. Ontology-Assisted Expert System for Algae Identification With Certainty Factors. *IEEE Access* 9 (2021), 147665–147677.
- [59] Pritpal Singh. 2018. Indian summer monsoon rainfall (ISMR) forecasting using time series data: a fuzzy-entropy-neuro based expert system. *Geoscience Frontiers* 9, 4 (2018), 1243–1257.
- [60] Karan Singhal, Tao Tu, Juraj Gottweis, Rory Sayres, Ellery Wulczyn, Le Hou, Kevin Clark, Stephen Pfohl, Heather Cole-Lewis, Darlene Neal, et al. 2023. Towards expert-level medical question answering with large language models. *arXiv preprint arXiv:2305.09617* (2023).
- [61] Hannah Snyder. 2019. Literature review as a research methodology: An overview and guidelines. *Journal of Business Research* 104 (2019), 333–339. <https://www.sciencedirect.com/science/article/pii/S0148296319304564>
- [62] Paulo Vitor de C Souza, Augusto J Guimaraes, Thiago Silva Rezende, Vanessa Souza Araujo, Luiz Antônio F do Nascimento, and Lucas Oliveira Batista. 2020. An intelligent hybrid model for the construction of expert systems in malware detection. In *2020 IEEE conference on evolving and adaptive intelligent systems (EAIS)*. IEEE, 1–8.
- [63] Charles Steinmetz, Achim Rettberg, Fabíola Gonçalves C. Ribeiro, Greycy Schroeder, Michel S. Soares, and Carlos E. Pereira. 2018. Using Ontology and Standard Middleware for integrating IoT based in the Industry 4.0. *IFAC-PapersOnLine* 51, 10 (2018), 169–174. 3rd IFAC Conference on Embedded Systems, Computational Intelligence and Telematics in Control CESCIT 2018.
- [64] Jeremy Straub. 2021. Expert system gradient descent style training: Development of a defensible artificial intelligence technique. *Knowledge-Based Systems* 228 (2021), 107275.
- [65] Jeremy Straub. 2021. Machine learning performance validation and training using a 'perfect' expert system. *MethodsX* 8 (2021), 101477.
- [66] D.B. Strydom. 1990. Industrial application of a real-time expert system. *Transactions of the South African Institute of Electrical Engineers* 81, 2 (1990), 1–6.
- [67] Mohammed HA Tafti. 1992. Neural networks: a new dimension in expert systems applications. *ACM SIGMIS Database: the DATABASE for Advances in Information Systems* 23, 1 (1992), 51–54.
- [68] Hamed Taherdoost. 2023. Deep Learning and Neural Networks: Decision-Making Implications. *Symmetry* 15, 9 (2023).
- [69] Jyotismita Talukdar, Thipendra P Singh, and Basanta Barman. 2023. *Artificial Intelligence in Healthcare Industry*. Springer.
- [70] Chee Fai Tan, LS Wahidin, SN Khalil, N Tamalidin, J Hu, and GWM Rauterberg. 2016. The application of expert system: A review of research and applications. *ARPN Journal of Engineering and Applied Sciences* 11, 4 (2016), 2448–2453.
- [71] Haocheng Tan. 2017. A Brief History and Technical Review of the Expert System Research. In *IOP Conference Series: Materials Science and Engineering*, Vol. 242. IOP Publishing, 012111.
- [72] Madjid Tavana and Vahid Hajipour. 2020. A practical review and taxonomy of fuzzy expert systems: methods and applications. *Benchmarking: An International Journal* 27, 1 (2020), 81–136.
- [73] Arailym Teubayeva, Aigul Shaikhanova, Baurzhan Ospan, Ayan Sultan, Mariyam Abu, and Nurbakyt Darmenkyzy. 2023. Machine Learning Expert System for Recognizing Emotions in text Umai Cloud Services. In *2023 IEEE International Conference on Smart Information Systems and Technologies (SIST)*. 293–298.
- [74] KP Tripathi. 2011. A review on knowledge-based expert system: concept and architecture. *IJCA Special Issue on Artificial Intelligence Techniques-Novel Approaches & Practical Applications* 4 (2011), 19–23.
- [75] William Van Melle. 1978. MYCIN: a knowledge-based consultation program for infectious disease diagnosis. *International journal of man-machine studies* 10, 3 (1978), 313–322.
- [76] Polyxeni Vassilakopoulou and Eli Hustad. 2023. Bridging digital divides: A literature review and research agenda for information systems research. *Information Systems Frontiers* 25, 3 (2023), 955–969.
- [77] William P Wagner. 2017. Trends in expert system development: A longitudinal content analysis of over thirty years of expert system case studies. *Expert systems with applications* 76 (2017), 85–96.
- [78] Zhiqiang Wang, Yiran Pang, and Yanbin Lin. 2024. Smart Expert System: Large Language Models as Text Classifiers. *arXiv:2405.10523 [cs.CL]* <https://arxiv.org/abs/2405.10523>
- [79] Yanjun Xiao, Shuhan Deng, Furong Han, Xiaoliang Wang, Yunfeng Jiang, and Kai Peng. 2022. Intelligent Health Diagnosis of Lithium Battery Pole Double Rolling Equipment Driven by Hybrid BP Neural Network and Expert System. *IEEE Access* 10 (2022), 80208–80224.
- [80] Xianzhe Yang and Changsheng Zhu. 2024. Industrial Expert Systems Review: A Comprehensive Analysis of Typical Applications. *IEEE Access* 12 (2024), 88558–88580.
- [81] Rui Yin, Zhi-qiang Wang, Wei Li, and Xin-xin Xu. 2020. The Application of Artificial Intelligence Technology in UAV. In *2020 5th International Conference on Information Science, Computer Technology and Transportation (ISCTT)*. IEEE, 238–241.
- [82] Youngohc Yoon, Tor Guimaraes, and George Swales. 1994. Integrating artificial neural networks with rule-based expert systems. *Decision Support Systems* 11, 5 (1994), 497–507.
- [83] Lotfi Asker Zadeh. 1983. The role of fuzzy logic in the management of uncertainty in expert systems. *Fuzzy sets and systems* 11, 1-3 (1983), 199–227.
- [84] Wayne Xin Zhao, Kun Zhou, Junyi Li, Tianyi Tang, Xiaolei Wang, Yupeng Hou, Yingqian Min, Beichen Zhang, Junjie Zhang, Zican Dong, Yifan Du, Chen Yang, Yushuo Chen, Zhipeng Chen, Jinhao Jiang, Ruiyang Ren, Yifan Li, Xinyu Tang, Zikang Liu, Peiyu Liu, Jian-Yun Nie, and Ji-Rong Wen. 2024. A Survey of Large Language Models. *arXiv:2303.18223 [cs.CL]* <https://arxiv.org/abs/2303.18223>
- [85] Xinlei Zhou, Han Du, Yongjun Sun, Haoshan Ren, Ping Cui, and Zhenjun Ma. 2023. A new framework integrating reinforcement learning, a rule-based expert system, and decision tree analysis to improve building energy flexibility. *Journal of Building Engineering* 71 (2023), 106536.
- [86] Sharif Noor Zisad, Etu Chowdhury, Mohammad Shahadat Hossain, Raihan Ul Islam, and Karl Andersson. 2021. An Integrated Deep Learning and Belief Rule-Based Expert System for Visual Sentiment Analysis under Uncertainty. *Algorithms* 14, 7 (2021).

Received 20 February 2007; revised 12 March 2009; accepted 5 June 2009