

UNIVERSIDADE PRESBITERIANA MACKENZIE

DAMIANA COSTA NASCIMENTO

**TREEVO: PROPOSTA DE UM SISTEMA ESPECIALISTA
BASEADO EM REDES BAYESIANAS PARA AVALIAÇÃO
DE CONHECIMENTO E SUGESTÃO DE TREINAMENTO
CORPORATIVO**

**São Paulo
2024**

**UNIVERSIDADE PRESBITERIANA MACKENZIE
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA ELÉTRICA E COMPUTAÇÃO**

Damiana Costa Nascimento

**TREEVO: PROPOSTA DE UM SISTEMA ESPECIALISTA
BASEADO EM REDES BAYESIANAS PARA AVALIAÇÃO
DE CONHECIMENTO E SUGESTÃO DE TREINAMENTO
CORPORATIVO**

Projeto de Pesquisa apresentado ao Programa de Pós-Graduação em Engenharia Elétrica e Computação da Universidade Presbiteriana Mackenzie como parte dos requisitos para a obtenção do título de Mestra.

Orientador: Ismar Frango

São Paulo
2024

N244t Nascimento, Damiana Costa
TREEVO: proposta de um sistema especialista baseado em redes Bayesianas para avaliação de conhecimento e sugestão de treinamento corporativo / Damiana Costa Nascimento.

3.100 k

Dissertação (Mestrado em Engenharia elétrica e computação) - Universidade Presbiteriana Mackenzie, São Paulo, 2024.
Orientador: Ismar Frango Silveira
Bibliografia: f. 84-89

1. Sistemas especialistas. 2. Treinamentos. 3. Expertiza. 4. Redes bayesianas. I. Silveira, Ismar Frango, orientador. II. Título.

CDD 371.334

Folha de Identificação da Agência de Financiamento

Autor: Damiana Costa Nascimento

Programa de Pós-Graduação *Stricto Sensu* em Engenharia Elétrica e Computação

Título do Trabalho: TREEVO: PROPOSTA DE UM SISTEMA ESPECIALISTA BASEADO EM REDES BAYESIANAS PARA AVALIAÇÃO DE CONHECIMENTO E SUGESTÃO DE TREINAMENTO CORPORATIVO

O presente trabalho foi realizado com o apoio de ¹:

- CAPES - Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
- CNPq - Conselho Nacional de Desenvolvimento Científico e Tecnológico
- FAPESP - Fundação de Amparo à Pesquisa do Estado de São Paulo
- Instituto Presbiteriano Mackenzie/Isenção integral de Mensalidades e Taxas
- MACKPESQUISA - Fundo Mackenzie de Pesquisa
- Empresa/Indústria:
- Outro:

¹ **Observação:** caso tenha usufruído mais de um apoio ou benefício, selecione-os.

UNIVERSIDADE PRESBITERIANA MACKENZIE
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA ELÉTRICA E COMPUTAÇÃO

Damiana Costa Nascimento

**PROPOSTA DE UM SISTEMA ESPECIALISTA PARA AVALIAÇÃO DE
CONHECIMENTO E SUGESTÃO DE TREINAMENTO CORPORATIVO COM
REDES BAYESIANAS**

Projeto de Pesquisa apresentado ao Programa de Pós-Graduação em Engenharia Elétrica e Computação da Universidade Presbiteriana Mackenzie como parte dos requisitos para a obtenção do título de Mestra.

Aprovada em: 15/02/2024

BANCA EXAMINADORA

Documento assinado digitalmente



ISMAR FRANGO SILVEIRA

Data: 02/04/2024 11:10:19-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. Ismar Frango Silveira
Universidade Presbiteriana Mackenzie

Documento assinado digitalmente



MARIA AMÉLIA ELISEO

Data: 19/03/2024 17:25:28-0300

Verifique em <https://validar.iti.gov.br>

Profa. Dra. Maria Amélia Eliseo
Universidade Presbiteriana Mackenzie

Documento assinado digitalmente



ALEXANDRE CARDOSO

Data: 25/03/2024 10:28:41-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. Alexandre Cardoso
Universidade Federal de Uberlândia

Dedico esta dissertação à minha família, cujo apoio incondicional tem sido fundamental. Especialmente, homenageio meu pai, Hélio, cujo orgulho por mim é uma fonte constante de inspiração. Dedico também à memória de minha mãe, Veralice, que, embora não esteja mais fisicamente presente, acredito que esteja orgulhosa de minha trajetória e realizações.

Uma menção especial à minha noiva, Caroline, que foi meu alicerce, nunca permitindo que eu desistisse, sempre me incentivando e acreditando em mim.

AGRADECIMENTOS

Primeiramente, gostaria de expressar minha profunda gratidão a todos os meus professores pelo suporte, assistência, conversas valiosas e trocas de experiências ao longo dessa jornada.

Em especial, gostaria de agradecer à Prof.^a Dr.^a Pollyana Notargiacomo por me selecionar para o mestrado e me apoiar incessantemente, demonstrando paciência e incentivo, especialmente nos momentos em que pensei em desistir.

Também sou imensamente grata ao meu orientador, Prof. Dr. Ismar Frango, por me acolher em sua orientação, oferecer apoio e paciência durante o processo.

Minha gratidão se estende à Prof.^a Mestra Denise Lemes Neves, cujo encaminhamento e suporte foram cruciais para minha jornada no mestrado, além de todas as conversas enriquecedoras e apoio contínuo.

Um agradecimento especial ao meu pai, Hélio Nascimento, cujo apoio constante e orgulho foram fundamentais para mim.

Não posso deixar de agradecer ao meu amigo Leandro Martinez pela ajuda inestimável e conhecimentos compartilhados na elaboração do design e prototipação do projeto.

Também sou muito grata a Gabriel Dionízio, um amigo cujas discussões e assistência no frontend foram essenciais para o desenvolvimento do meu trabalho.

Um agradecimento caloroso à minha noiva, Caroline Poltronieri, pela sua compreensão, paciência e auxílio na revisão dos textos da minha pesquisa.

Agradeço também a Gélio Pierobon, Head de Tecnologia, e a Soraya dos Santos, Tech Manager, ambos do PicPay, pelas inúmeras e enriquecedoras conversas sobre avaliações e habilidades técnicas.

Estendo minha gratidão a Deus e aos Orixás pela oportunidade, aprendizado e suporte contínuos em minha jornada.

Por fim, um agradecimento especial ao Instituto MackPesquisa e à CAPES pela bolsa de estudos concedida, sem a qual a conclusão desta dissertação não seria possível.

Conhecimento próprio não é garantia de felicidade, mas isso está ao lado da felicidade e pode fornecer a coragem para lutar por ela.

Simone de Beauvoir

Faça a descoberta de si mesmo, e aos poucos você descobrirá que é mais seguro e compensador valorizar-se.

Clarice Lispector

RESUMO

Com o avanço da tecnologia, a utilização de sistemas especialistas tem se mostrado uma solução eficiente para auxiliar em processos complexos de tomada de decisão em diversas áreas. Esses sistemas combinam o conhecimento humano especializado com o poder computacional para fornecer orientações precisas e confiáveis, resultando em decisões mais informadas e assertivas. Além disso, a integração de funcionalidades de treinamento nesses sistemas tem se destacado como um elemento fundamental para o aprimoramento contínuo do conhecimento e das habilidades dos usuários. Eles são amplamente utilizados na medicina, finanças, engenharia e outras áreas para fornecer diagnóstico, tomada de decisão e resolver problemas complexos. As redes Bayesianas têm se mostrado uma abordagem promissora para modelar a incerteza e tomar decisões em diversos domínios complexos. Este estudo apresenta conceitos fundamentais, como probabilidade condicional e o teorema de Bayes, essenciais para compreender o funcionamento das redes Bayesianas. Além disso, são discutidos algoritmos de inferência probabilística, incluindo a propagação de probabilidades, que permite a atualização das probabilidades das variáveis de interesse em uma rede Bayesiana. Neste estudo, desenvolvemos um sistema destinado a avaliar o conhecimento em diversos tópicos técnicos. O principal objetivo desta pesquisa é explorar a viabilidade de determinar o nível de conhecimento de colaboradores através de um questionário de perguntas e respostas. Além disso, buscamos apresentar um treinamento sob medida, que se alinhe com o conhecimento já adquirido pelo colaborador. Para atingir esses fins, recorreremos ao uso de sistemas especialistas e redes Bayesianas, que juntos proporcionam sugestões de treinamento personalizados. O desenvolvimento do sistema foi realizado utilizando a linguagem Python, com o apoio do framework Experta, um mecanismo de inferência robusto. Por meio deste sistema, é possível determinar o nível de conhecimento técnico dos usuários, permitindo assim a recomendação de treinamentos específicos que se ajustam de forma precisa a cada perfil de conhecimento identificado.

Palavras-chave: *sistemas especialistas, treinamentos, experta, redes bayesianas*

ABSTRACT

With the advancement of technology, the use of expert systems has proven to be an efficient solution to assist in complex decision-making processes across various fields. These systems combine specialized human knowledge with computational power to provide precise and reliable guidance, resulting in more informed and assertive decisions. Moreover, the integration of training functionalities into these systems has emerged as a key element for the continuous improvement of users' knowledge and skills. They are widely used in medicine, finance, engineering, and other fields to provide diagnostics, decision-making, and solve complex problems. Bayesian networks have shown to be a promising approach for modeling uncertainty and making decisions in various complex domains. This study presents fundamental concepts, such as conditional probability and Bayes' theorem, essential for understanding the workings of Bayesian networks. Additionally, probabilistic inference algorithms, including probability propagation, which allows for the updating of probabilities of interest variables in a Bayesian network, are discussed. In this study, we developed a system aimed at assessing knowledge in various technical topics. The main goal of this research is to explore the feasibility of determining the level of knowledge of employees through a questionnaire of questions and answers. Furthermore, we seek to present tailor-made training that aligns with the knowledge already acquired by the employee. To achieve these ends, we resorted to the use of expert systems and Bayesian networks, which together provide personalized training suggestions. The development of the system was carried out using the Python language, with the support of the Experta framework, a robust inference mechanism. Through this system, it is possible to determine the technical knowledge level of users, thus allowing for the recommendation of specific trainings that accurately adjust to each identified knowledge profile.

Keywords: *expert systems, training, expert, bayesian networks*

Lista de Figuras

1	Estrutura básica de Sistema Especialista	8
2	Áreas dos sistemas especialistas entre 1984 e 2016	10
3	Como o Backward Chaining funciona	15
4	Como o Forward Chaining funciona	16
5	Roadmap Backend	19
6	Exemplo de redes Bayesianas	20
7	Exemplo de grafo cíclico	22
8	Exemplo de grafo acíclico	22
9	Etapas do desenvolvimento	32
10	Matriz CSD	39
11	Matriz CSD: Coluna de Certezas	39
12	Matriz CSD: Coluna de Suposições	40
13	Matriz CSD: Coluna de Dúvidas	41
14	Mapa conceitual	43
15	Matriz de competência	44
16	Arquitetura do framework Experta	45
17	Exemplo da criação de um fato	46
18	Exemplo de regra com LHS	47
19	Regras para criar <i>Rules</i>	47
20	Diagrama de sequência	49
21	Arquitetura do sistema especialista	50
22	Visão geral do especialista	51
23	Tela inicial	52

24	Tela com as perguntas	53
25	Resultados do questionário por temas	54
26	Treinamentos recomendados	55
27	Regra para somar ponto	57
28	Regra para subtrair ponto	58
29	Médias de acurácia, tempos de treinamento e teste	61
30	Tempo de treinamento	61
31	Nós do sistema especialista	63
32	Estrutura redes bayesianas	64
33	Percepção de utilidade: Pergunta 1	73
34	Percepção de utilidade: Pergunta 2	73
35	Percepção de utilidade: Pergunta 3	74
36	Percepção de facilidade: Pergunta 1	74
37	Percepção de facilidade: Pergunta 2	75
38	Influências sociais: Pergunta 1	76
39	Condições facilitadores: Pergunta 1	76
40	Intenção de uso: Pergunta 1	77
41	Intenção de uso: Pergunta 2	78

Lista de Tabelas

1	Sistemas especialistas por setores	10
2	Perguntas e conhecimento prévio	57

Lista de Abreviaturas e Siglas

I.A Inteligência Artificial

IA Inteligência Artificial

LHS Left Hand Side

LHS Right Hand Side

LPI Linguagem de Processamento de Informações

CSD Certeza, Suposição e Dúvida

GE General Electric

IA Inteligência Artificial

Management 3.0 Gestão 3.0

PDI Plano de Desenvolvimento Individual

TAM Technology Acceptance Model

UI User Interface

UML Unified Modeling Language

Sumário

1	INTRODUÇÃO	1
1.1	Objetivo Geral	1
1.1.1	Objetivos Específicos	1
1.2	Motivação	2
1.3	Justificativa	3
1.4	Organização	4
2	REFERENCIAL TEÓRICO	5
2.1	Sistemas Especialistas	5
2.1.1	Tipos de sistemas especialistas	12
2.1.2	Técnicas Backward Chaining e Forward Chaining	14
2.1.3	Exemplos de sistemas especialistas	16
2.2	Roadmap de backend	18
2.3	Redes bayesianas	19
2.3.1	Teorema de Bayes	22
2.3.2	Inferência em redes Bayesianas	23
2.4	Conceito de treinamento	24
2.4.1	Componentes de treinamentos corporativos	24
2.4.2	Universidades Corporativas	25
2.5	Conceito de aprendizagem	26
2.6	Trabalhos correlatos	27
3	METODOLOGIA	31
3.1	O sistema <i>TREEVO</i>	36
3.2	Implementação do sistema	37

3.2.1	Matriz CSD	38
3.2.2	Mapa conceitual	41
3.2.3	Matriz de competências	44
3.2.4	Framework Experta	45
	3.2.4.1 Fato	46
	3.2.4.2 Regra	46
3.2.5	Linguagem Python	47
3.2.6	Framework Flask	48
3.2.7	Arquitetura do sistema	48
3.3	Interface do sistema	51
3.4	Regras de negócio	55
3.5	Proposta de redes Bayesianas com Experta para sugestão de treinamentos	59
	3.5.1 Preparação dos dados	59
	3.5.2 Treinamento do modelo e teste dos dados	60
3.6	Estrutura da rede Bayesiana	62
3.7	Entrevista	65
4	RESULTADOS	71
4.1	Apresentação dos resultados	72
	4.1.1 Percepção de utilidade	72
	4.1.2 Percepção de facilidade de uso	73
	4.1.3 Influências sociais	75
	4.1.4 Condições facilitadoras	75
	4.1.5 Intenção de uso	76
4.2	Análise final dos resultados	78

5 CONCLUSÃO E TRABALHOS FUTUROS	80
5.1 Conclusão	80
5.2 Trabalhos futuros	82
REFERÊNCIAS BIBLIOGRÁFICAS	89
ANEXO: A Perguntas para avaliar o conhecimento em Java	90
ANEXO: B Perguntas para avaliar o conhecimento em Boas Práticas	92
ANEXO: C Informações pessoais	94

1 INTRODUÇÃO

1.1 Objetivo Geral

Este trabalho tem como objetivo desenvolver um protótipo de um sistema especialista para sugestão de cursos e treinamentos com redes Bayesianas para avaliar e aprimorar o conhecimento técnico dos colaboradores em diversas áreas tecnológicas. O sistema propõe analisar o nível de conhecimento atual dos usuários, fornecendo sugestões personalizadas que se alinham com suas necessidades específicas de aprendizado.

Ao fazer isso, o sistema não apenas promove o desenvolvimento contínuo das habilidades e conhecimentos dos usuários, mas também ocasiona a possibilidade de empoderar os líderes organizacionais, oferecendo-lhes *insights* valiosos para facilitar o desenvolvimento eficaz da força de trabalho e a tomada de decisões mais informadas e estratégicas.

1.1.1 Objetivos Específicos

O projeto visa aprimorar a precisão e eficiência na indicação de cursos e treinamentos por meio do desenvolvimento de um protótipo de sistema especialista denominado *TREEVO*. Utilizando a biblioteca *Experta* para a elaboração de regras de negócio e as redes bayesianas para o cálculo de probabilidades, *TREEVO* visa recomendar os cursos e treinamentos mais pertinentes. Este estudo objetiva verificar se o emprego dessas tecnologias pode potencializar a efetividade das sugestões, considerando o nível de conhecimento previamente identificado pelo *TREEVO*.

Para alcançar este feito, os seguintes objetivos específicos são propostos:

- Desenvolvimento e treinamento do modelo de rede Bayesiana: construir e treinar o modelo de rede Bayesiana para mapear relações probabilísticas relevantes na recomendação de cursos e treinamentos;
- Implementação de sistema especialista: desenvolver um sistema especialista que emprega a rede Bayesiana para gerar sugestões personalizadas de cursos e treinamentos;
- Avaliação: realizar avaliação do sistema e coletar feedbacks dos usuários para aprimorar e otimizar continuamente o sistema especialista.

Com o propósito de aprimorar a maneira como as sugestões de cursos e treinamento são feitas, utilizando uma abordagem baseada em dados para personalizar a aprendizagem. Espera-se que este trabalho contribua significativamente para o campo da tomada de decisão assistida por sistemas especialistas e redes Bayesianas, abrindo caminhos para inovações futuras e melhorias contínuas no campo da educação corporativa e desenvolvimento profissional.

1.2 Motivação

Enfrentamos hoje, no ambiente corporativo, o desafio significativo de avaliar e desenvolver de forma precisa o conhecimento técnico dos colaboradores. Essa precisão é crucial para a eficácia dos programas de treinamento e, conseqüentemente, para o sucesso da empresa. O equilíbrio entre o desenvolvimento baseado na experiência do colaborador e as necessidades da organização é complexo, mas fundamental.

A adoção de um sistema especialista pode ser a chave para superar esses obstáculos. Um sistema que oriente a seleção do treinamento mais adequado para cada colaborador pode não apenas economizar tempo, mas também otimizar os investimentos em capacitação.

Este estudo visa explorar o papel de um sistema especialista no aprimoramento do processo de aprendizado, destacando lacunas de conhecimento que precisam ser superadas e reconhecendo as competências já solidificadas que devem ser incentivadas. A intenção é desenvolver estratégias que permitam aos colaboradores não apenas melhorar suas habilidades, mas também se tornarem agentes multiplicadores de conhecimento dentro da organização. Para isso, utilizamos redes Bayesianas, visando oferecer recomendações de treinamento personalizado e efetivo.

Além disso, essa pesquisa tem o potencial de revelar percepções importantes a respeito da aplicação de tecnologias de sistemas especialistas no refinamento das estratégias de desenvolvimento de competências nas organizações. Ao explorar estas temáticas, almejamos enriquecer a literatura na área de desenvolvimento de pessoas e gestão de talentos, introduzindo uma visão renovada sobre o uso de sistemas inteligentes no aprimoramento e capacitação dos colaboradores.

1.3 Justificativa

A constante evolução do ambiente de trabalho e a necessidade de avaliar e desenvolver de maneira eficaz as competências técnicas dos colaboradores fundamentam a importância deste estudo. Frequentemente, essa avaliação pode ser complexa e desalinhada com as necessidades dos colaboradores e da empresa, um desafio que pode ser mitigado ao harmonizar a avaliação do conhecimento com a tecnologia adotada pela organização e sua relevância.

Em certas organizações, essa avaliação ainda é realizada de forma manual, com os colaboradores respondendo a um questionário sobre temas específicos e, posteriormente, calculando-se uma média ponderada de seu conhecimento.

Diante das mudanças contínuas em tecnologia e das demandas do mercado, torna-se crucial para as empresas entender e aperfeiçoar as habilidades de seu capital humano.

Esta pesquisa se concentra em três aspectos chave:

1. **Avaliação Precisa de Competências:** avaliar com precisão as habilidades técnicas dos colaboradores é vital para alinhar a força de trabalho às demandas atuais e futuras da organização.
2. **Personalização no Desenvolvimento Profissional:** o treinamento e desenvolvimento personalizados são importantes para a eficácia do aprendizado, atendendo melhor às necessidades e expectativas individuais dos colaboradores.
3. **Uso de Sistemas Especialistas:** a aplicação de sistemas especialistas, especialmente aqueles baseados em redes Bayesianas, para a gestão de talentos oferece uma abordagem inovadora. Esses sistemas podem fornecer análises precisas e recomendações personalizadas, otimizando o processo de desenvolvimento das competências.

Este estudo visa explorar como um sistema especialista pode aprimorar a eficiência e qualidade do desenvolvimento profissional, oferecendo *insights* valiosos para a gestão

de talentos nas organizações modernas. A pesquisa busca contribuir para a compreensão prática e teórica da aplicação de tecnologias avançadas na avaliação e no desenvolvimento de habilidades em ambientes corporativos.

1.4 Organização

Este documento está estruturado em capítulos que objetivam apresentar de forma clara e lógica o desenvolvimento e os resultados da pesquisa realizada. A organização do documento é a seguinte:

1. **Introdução:** este capítulo define o escopo da pesquisa, delineando seus objetivos, motivações e justificativas. A intenção é estabelecer o contexto e a relevância do estudo realizado.
2. **Referencial Teórico:** aqui, apresentamos uma revisão da literatura, abordando teorias e estudos anteriores que formam a base para a pesquisa.
3. **Proposta do Sistema Especialista:** neste capítulo, descrevemos detalhadamente a proposta do sistema especialista e do modelo de redes Bayesianas, incluindo sua arquitetura, funcionamento e os princípios teóricos que sustentam seu design e implementação.
4. **Resultados Obtidos:** este capítulo foca na análise e discussão dos resultados alcançados com a aplicação do sistema especialista com as redes Bayesianas, oferecendo uma avaliação crítica da eficácia do sistema.
5. **Conclusão:** por fim, o último capítulo sintetiza as principais descobertas, contribuições e implicações da pesquisa. Também são discutidas as limitações do estudo e sugeridas direções para pesquisas futuras.

2 REFERENCIAL TEÓRICO

2.1 Sistemas Especialistas

Weber (2017) apresenta que os sistemas especialistas possuem como premissa a solução de problemas que normalmente são feitos por “especialistas humanos”. Em uma definição clara, é um sistema que é projetado e desenvolvido para atender às necessidades de uma determinada aplicação e limitada do conhecimento humano.

O sistema especialista é capaz de decidir algo, com base no conhecimento justificado, que foi previamente atribuído por uma base de informações, de maneira similar à atribuição de tarefas a um especialista em uma área específica do conhecimento. As decisões tomadas por um especialista são feitas a partir de um conhecimento prévio, que foi construído com o passar de anos devido a sua formação e a sua experiência profissional.

De acordo com Belhot (1993), em sua publicação na década de 50, os fundamentos da Inteligência Artificial (*IA*), estabeleceu os pilares para os avanços futuros no campo, introduzindo conceitos essenciais como lógica matemática e teoria das funções recursivas. Esses avanços foram cruciais para aplicações iniciais, como jogos de xadrez e a prova de teoremas matemáticos e lógicos, que pavimentaram o caminho para desenvolvimentos subsequentes na área (McCorduck, 2004).

A criação da linguagem de processamento de informações (*LPI*), pelo *Logic Theorist* marcou um momento significativo, fornecendo um interpretador para o desenvolvimento de expressões simbólicas recursivas, fundamental para a automação do raciocínio lógico e simbólico.

Dentro desse contexto histórico, emergiram os sistemas especialistas, uma área proeminente da IA, destacando-se pela habilidade de emular a tomada de decisão de *experts* humanos em campos específicos. Esses sistemas se fundamentam em conjuntos ricos de regras e dados, aplicando-os para inferir novas informações ou solucionar problemas complexos, efetivamente simulando o raciocínio de especialistas humanos Russell e Norvig (2020). Posicionando-se como sistemas baseados em conhecimento, eles se distinguem pelo foco em domínios específicos, onde o conhecimento explícito sobre tarefas complexas é meticulosamente codificado em bases de conhecimento.

A eficácia dos sistemas especialistas, portanto, está diretamente ligada à qualidade e abrangência do conhecimento que é codificado, refletindo a importância das bases estabelecidas nas primeiras décadas de pesquisa em IA. A colaboração interdisciplinar entre a lógica matemática, ciência da computação e psicologia cognitiva nesse período foi crucial, alimentando o desenvolvimento de tecnologias capazes de processar e simular aspectos do raciocínio humano, levando à criação de sistemas especialistas que se mantêm fundamentais no avanço da I.A. Russell e Norvig (2020)

Nos anos de 1960, os pesquisadores deram ênfase em simular o complexo processo de pensamento, de modo a desenvolver métodos gerais, que poderiam ser aplicados de maneira semelhante em diversos problemas de diferentes áreas. Pressionados para desenvolver um programa de propósito geral e com a necessidade de produzir sistemas inteligentes para aplicações práticas, eles passaram a concentrar seus estudos na criação de métodos e técnicas que pudessem ser utilizados em problemas especializados. Dessa maneira, dedicou-se muita atenção às regras heurísticas, à semelhança do processo humano na tomada de decisões (em que raramente considera todas as soluções possíveis para um único problema, mas concentra-se em poucas que considera então mais prováveis).

Segundo Belhot (1993), durante a década de 70, os cientistas de *I.A.* (Inteligência Artificial), concentraram-se nas técnicas de representação e busca. Isso envolveu a formulação de problemas com a definição de valores e o controle da busca, visando torná-la eficiente, levando em consideração as limitações de capacidade dos computadores. Contudo, esta iniciativa não produziu os resultados esperados e, no fim da década, a mais importante descoberta foi feita, quando perceberam que a capacidade de um programa depende mais do conhecimento que ele possui, que dos formalismos ou esquemas de inferência que ele emprega.

Era evidente que o conhecimento analisado não poderia ser de senso comum (domínio geral). Reconheceu-se que era mais fácil extrair e representar o conhecimento especializado. Mais crucial ainda foi a percepção de que o conhecimento e as regras heurísticas são específicos para certos domínios e não são intercambiáveis entre eles. Isso significava que os sistemas baseados no conhecimento deveriam buscar soluções para problemas restritos, específicos, ou seja, problemas normalmente sujeitos à consideração de especialistas humanos. (BELHOT, 1993)

Assim, de acordo com esse contexto, começaram a ser desenvolvidos os programas de computador com propósitos específicos, ou seja, sistemas que eram especialistas em certas áreas limitadas do conhecimento. Tais programas foram chamados *sistemas especialistas* e, dessa forma, deu-se o início de um novo campo de pesquisas dentro da Inteligência Artificial.

Para Waterman (1986) e Negnevitsky (2002), os *sistemas especialistas* apresentam vantagens e desvantagens. Como vantagens destacam-se:

- Possuir inteligência e conhecimento, ao contrário dos sistemas tradicionais, que não possuem essas características;
- As decisões são precisas e rápidas, mesmo quando há inúmeras regras de negócio envolvidas no processo;
- Apresentam capacidade de explicar o processo de raciocínio;
- Possuem uma estrutura unificada onde cada regra tem o conhecimento disponível de forma independente;
- É possível usar o mesmo ambiente de projeto em diferentes aplicações quando o conhecimento pode ser separado de seu processamento.

Sobre as desvantagens, destacam-se:

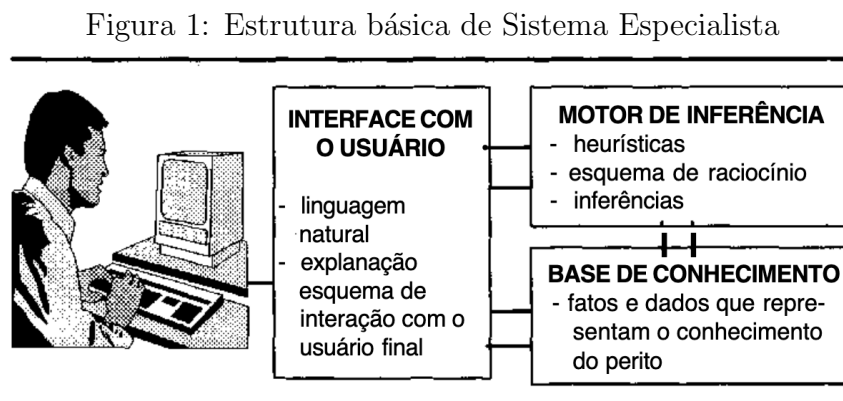
- Utilizam o raciocínio representacional como fator principal;
- Trabalham com o processo de raciocínio dedutivo ao invés do raciocínio indutivo;
- Ocasionalmente promovem relacionamentos entre regras e, portanto, praticamente não apoiam a definição do papel de uma única regra no processo de raciocínio;
- Erros podem acontecer durante o raciocínio, possivelmente devido à dificuldade em lidar com a ambiguidade, regras conflitantes e dificuldades de atualização ou aprendizado em sua base de conhecimento.

Uma das desvantagens mais relevantes é a dificuldade de extrair conhecimento de especialistas por meio de algum mecanismo, como um questionário, ou observar as ações

realizadas por especialistas, pois envolve tanto aspectos técnicos quanto pessoais (GUPTA; SINGHAL, 2013).

Considerando que a qualidade do conhecimento armazenado é um fator decisivo no potencial de um sistema especialista, se o conhecimento armazenado não for adequadamente extraído e interpretado para obter as informações necessárias, o sistema especialista pode dar respostas erradas ou nenhuma resposta (LAI; WANG; HUANG, 2011).

Na figura 1, Mendes (1997) apresenta a estrutura básica de um sistema especialista, que consiste em três elementos básicos: interface do Usuário, motor de inferência e base de conhecimento.



Fonte: Mendes (1997, p. 41)

Interface com usuário: essa base de regras e fatos se comunica com o usuário e mecanismo de raciocínio, permitindo a identificação do problema a ser resolvido, as possíveis soluções e o raciocínio para a conclusão do problema proposto ao sistema. Com base em fatos e regras e na interação com os usuários, obtém-se as informações necessárias para solucionar o problema. Para Mendes (1997), a interface é provavelmente o elemento que consome a maior parte do tempo de um desenvolvedor de sistemas especialistas.

Motor de inferência: é o principal elemento para a criação do sistema especialista. É mediante ele que fatos, regras e heurísticas integram uma base de conhecimento e podem ser aplicados ao processo de resolução de problemas. O recurso do motor de inferência se baseia em um conjunto de técnicas de inferência que são processadas de maneira progressiva e regressiva.

Base de conhecimento: corresponde à integração de outras bases de conhecimento


criadas por regras que utilizam o conhecimento, a informação, a frequência e os níveis de acesso de cada usuário em cada parte da organização. As bases de dados tradicionais que contém arquivos, registros e relacionamentos, neste contexto, são substituídas por regras, fatos e bases heurísticas que representam o conhecimento de pessoas especialistas na área de construção do sistema. Esse conhecimento é classificado como fatos e regras, ou outra representação, como lógica matemática ou redes semânticas (WAGNER, 2017).

Para Souza (2017), a base de conhecimento pode ser dividida de duas formas:

- **Base de fatos:** representa o conhecimento inicialmente conhecido e pode ser vista como um pressuposto para a resolução de problemas. Também é descrita como o conhecimento de domínio público, que pode ser extraído de textos, manuais, normas, livros, checagem de fatos e resultados experimentais;
- **Base de regras:** representa o conhecimento extraído diretamente de especialistas (heurísticas), a partir de fatos conhecidos e suas inferências. Neste contexto, o termo *heurística* refere-se à habilidade ou simplificação que os especialistas utilizam para otimizar sua busca por uma solução para um problema.

Wagner (2017) realizou uma pesquisa na qual coletou 311 registros relacionados ao uso de sistemas especialistas em várias áreas do conhecimento entre os anos de 1985 e 2016. A pesquisa mostrou que a utilização de sistemas especialistas migrou da medicina para outras áreas do conhecimento, como mostra a figura abaixo.

Figura 2: Áreas dos sistemas especialistas entre 1984 e 2016



Fonte: Wagner (2017) - p. 87

O gráfico da figura 2 mostra que, entre os anos 1980 e 1990, áreas funcionais de sistemas especialistas, como Operações e Finanças, receberam maior atenção. No início dos anos 2000, havia interesse em aplicações para serviços de produção e contabilidade. Mais tarde, outras áreas se interessaram pela aplicação de sistemas especialistas, como Recursos Humanos e Marketing.

Além disso, Wagner (2017) apresentou estudos referentes a setores específicos que utilizam sistemas especialistas, como mostrado na tabela 1.

Tabela 1: Sistemas especialistas por setores

Setores	Estudos
Contabilidade	34
Aeroespacial	13
Agricultura	6
Automotivo	13
Bancário	30
Química	5
Construção e Mineração	7
Educação	14

Continua na próxima página

Tabela 1 – continuação da página anterior

Setores	Estudos
Serviços Financeiros	28
Governamental	10
Assistência Médica	4
Tecnologia da Informação	14
Seguros	12
Serviços Legais	2
Industrial/Fábrica	31
Médico	24
Militar	14
Óleo e Gás	11
Publicidade	1
Imobiliário	1
Varejo	6
Pesquisa Científica	3
Telecomunicações	11
Transportes	2
Serviços de Utilidade Pública	7
Total	311

Fonte: Adaptado de Wagner (2017)

De acordo com a tabela 1 é possível ver sistemas especialistas utilizados em diferentes áreas da indústria.

Na dinâmica atual do mundo corporativo, a adoção de sistemas especialistas pode se tornar um aliado, particularmente em empresas onde o mapeamento de conhecimento técnico costuma ser uma tarefa manual. Tradicionalmente, empregando a técnica de matriz de competência (Management 3.0, 2024), os colaboradores preenchem formulários detalhando suas competências em diversos temas técnicos, e a empresa, por sua vez, utiliza essas informações para calcular uma média ponderada do conhecimento sobre as tecnologias empregadas. A introdução de sistemas especialistas revoluciona esse processo ao minimizar a necessidade de consultas constantes a especialistas humanos, assegurando que o suporte necessário esteja disponível mesmo em momentos críticos.

Esses sistemas desempenham um papel vital em manter a continuidade e a confiança nas operações, especialmente em contextos onde há uma carência de profissionais es-

pecializados. Eles são projetados para serem acessíveis a todos dentro da organização, permitindo que decisões baseadas em conhecimento técnico sejam tomadas rapidamente. Além disso, sua capacidade de processamento acelerado facilita respostas ágeis a qualquer solicitação. Quando devidamente implementados, os sistemas especialistas aumentam a segurança das soluções adotadas, diminuindo significativamente os riscos de erros. Essa eficiência não apenas otimiza a gestão do conhecimento técnico, mas também reforça a robustez e a agilidade das estratégias empresariais.

2.1.1 Tipos de sistemas especialistas

Existem diversos tipos de sistemas especialistas, que são citados por Junior (2008) como:

- **Interpretação:** refere-se a sistemas capazes de deduzir descrições de situações a partir da observação de fatos. Envolve a análise de dados para determinar as possíveis relações e seus significados, considerando várias interpretações e descartando aquelas que não são consistentes. Esses sistemas possuem mecanismos para lidar com dados incorretos, distorcidos ou ausentes;
- **Diagnósticos:** os sistemas de diagnósticos detectam falhas provenientes da interpretação de dados. Ao analisar essas falhas, podem-se chegar a conclusões diversas que vão além da simples interpretação dos dados. O sistema de interpretação de dados já está integrado a esses processos. É necessário identificar os problemas por trás das falhas do sistema de interpretação, dos equipamentos e do próprio diagnóstico, que podem não ter sido detectados devido a falhas anteriores. Os sistemas de diagnósticos precisam capacitar o diagnosticante a tomar decisões, especialmente em determinados casos em que os dados sobre o sistema podem ser inacessíveis, caros ou perigosos de serem recuperados;
- **Monitoramento:** a interpretação deste sistema deve considerar as observações de sinais sobre o comportamento monitorado. Verifica-se, de maneira contínua, determinado comportamento em limites preestabelecidos, sinalizando quando for necessário realizar uma intervenção para o sucesso da execução. Um sinal pode ser interpretado de diferentes maneiras, dependendo da situação global percebida

naquele momento, fazendo com que a interpretação varie também, de acordo com os fatos que o sistema percebe;

- **Predição:** envolve a modelagem de dados do passado e do presente, que permite que haja uma determinada previsão do futuro. Utiliza raciocínio hipotético para verificar tendências, considerando variações de entrada dos dados;
- **Planejamento:** o sistema prepara um programa de iniciativas que serão tomadas para atingir um objetivo, com etapas e subetapas estabelecidas. Caso haja etapas conflitantes, são definidas aquelas que têm prioridade. É similar ao sistema para predição e, normalmente, opera em problemas grandes de soluções complexas, que demandam uma análise mais aprofundada do especialista, com princípio de funcionamento e, em determinados casos, feita por tentativas de soluções;
- **Projeto:** possui características semelhantes ao sistema de planejamento, onde são elaboradas especificações para atingir os objetivos dos requisitos. Além disso, é capaz de justificar as decisões que são tomadas para o projeto final, usando essas justificativas para orientar soluções futuras. É fundamental apresentar uma visão global do projeto em todas as suas etapas de alteração, acompanhando e aplicando as mudanças necessárias não apenas no local da alteração, mas em todos os pontos impactados pela alternativa atual;
- **Depuração:** é um sistema com mecanismos para criar soluções para o mau funcionamento que provoca distorções de dados. De maneira automática, esse sistema faz verificações nas partes do projeto, a partir de mecanismos para validação de cada etapa necessária a qualquer processo;
- **Reparo:** é um sistema que cria e desenvolve planos para resolver os reparos verificados na etapa de diagnóstico. Esses sistemas são poucos, uma vez que o ato de executar o reparo de algo é uma tarefa complexa. Normalmente, esses sistemas têm uma capacidade de diagnóstico e soluções para os consertos;
- **Instrução:** trata-se de um sistema que possui mecanismos para verificar e corrigir o comportamento no processo de aprendizagem de estudantes. Normalmente, esse sistema é incorporado a subsistemas, incluindo um sistema de diagnóstico e reparo, que são fundamentados em uma descrição hipotética do conhecimento dos

estudantes. O funcionamento do sistema é baseado em interações com o estudante, sugerindo situações que se adaptam ao comportamento de cada pessoa. Essas situações podem aumentar em complexidade, guiando o assunto de forma didática. Assim, quando o aluno alcança conhecimento em um determinado tópico, avança para o seguinte;

- **Controle:** é um sistema que gerencia o comportamento geral de outros sistemas, sendo mais completo, de modo geral, já que se deve interpretar os fatos de uma situação atual, com a verificação dos dados passados e fazendo uma predição futura. Ele apresenta também os diagnósticos possíveis de problemas, elaborando um plano específico para sua correção, que é executado e monitorado para que se atinja o objetivo planejado.

2.1.2 Técnicas Backward Chaining e Forward Chaining

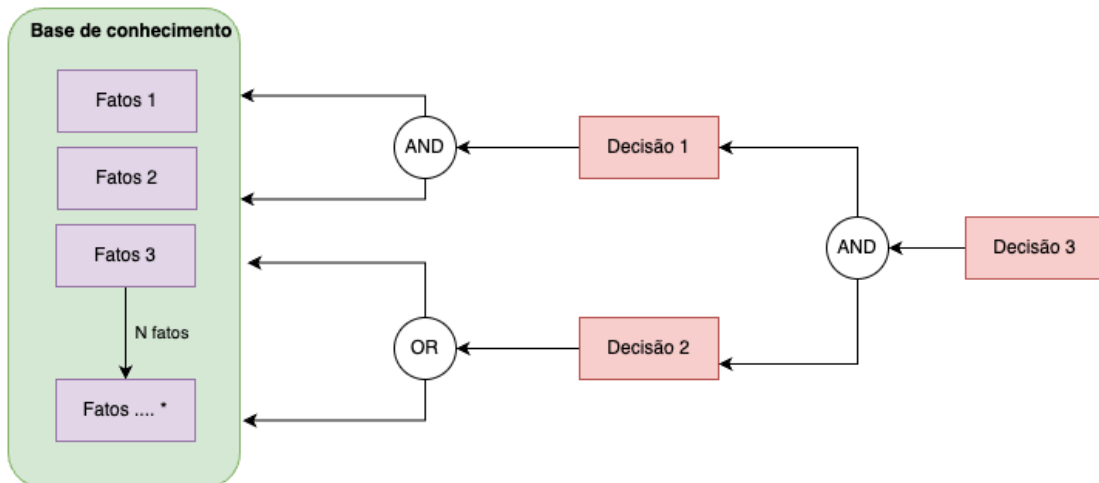
Existem duas técnicas principais usadas em sistemas especialistas, **Backward Chaining**, conhecida como encadeamento reverso ou de regressão e **Forward Chaining**, denominada encadeamento direto.

O *Backward Chaining* é um método pelo qual um sistema começa a partir de um objetivo ou conclusão específica e trabalha de trás para frente para encontrar as informações necessárias para apoiar essa conclusão. Ele procede de regras e fatos conhecidos para chegar à resposta desejada. Segundo os autores Russell e Norvig (2010), é o processo de resolução de problemas, começando com uma proposição e um conjunto de regras que orientam a proposição e, em seguida, trabalhando de trás para frente, unificando as regras com informações da base de fatos, até que a proposição seja verificada ou considerada falsa.

Nesta situação, o sistema de inferência conhece a decisão final e tenta descobrir as condições que teriam levado a essa decisão. É sobretudo utilizado para encontrar a causa de um problema. A técnica de encadeamento reverso é um método importante para a tomada de decisão automática em sistemas especialistas. Isso torna os sistemas mais eficientes e precisos no processamento de informações, principalmente quando decisões complexas precisam ser tomadas com base em uma série de fatos. Essa técnica é utilizada para sistemas de depuração, diagnóstico e prescrição. A imagem 3 representa o enca-

deamento regressivo em um sistema especialista. Partindo da meta desejada, o sistema busca na base de conhecimento os fatos necessários para justificar essa conclusão. Utiliza operadores lógicos *AND*, exigindo que todos os fatos ligados sejam verdadeiros, e *OR*, onde qualquer fato pode validar a regra. O processo é iterativo, avaliando quais condições prévias devem ser satisfeitas para atingir a decisão final.

Figura 3: Como o Backward Chaining funciona



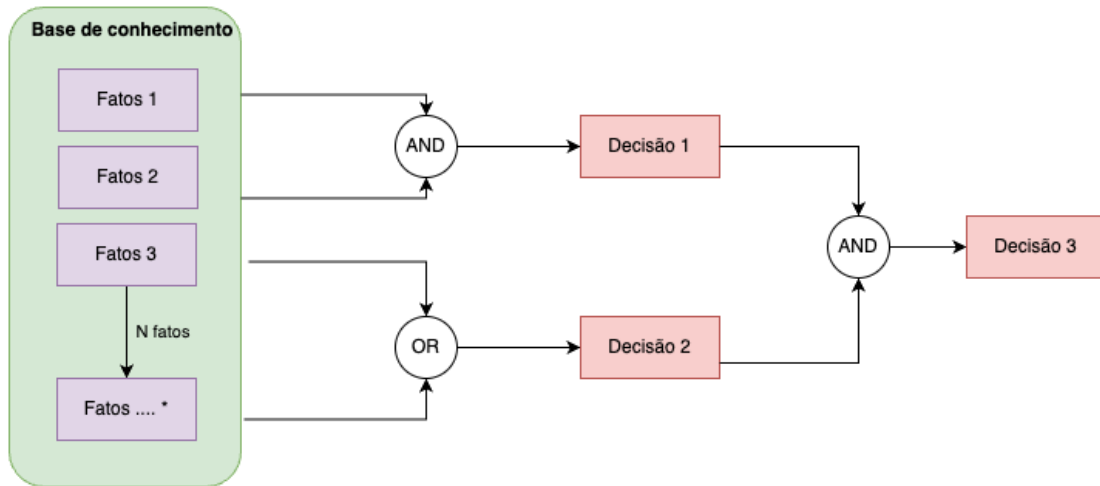
Fonte: elaborada pela autora (2023)

A técnica de *Forward Chaining*, também conhecida como encadeamento progressivo ou encadeamento direto, é uma abordagem utilizada em sistemas especialistas para inferir conclusões a partir de um conjunto de regras. Diferentemente do *Backward Chaining*, que começa com uma meta e trabalha retroativamente, o *Forward Chaining* começa com fatos iniciais e aplica as regras sequencialmente até chegar a uma conclusão. Utiliza uma base de conhecimento, ou conjunto de regras, para inferir novas conclusões a partir de fatos previamente identificados, ou seja, o mecanismo de inferência começa avaliando os fatos, as derivações e as condições existentes antes de deduzir novas informações. Esse método é usado para responder a uma pergunta específica com base em uma lista de regras predefinidas.

Essa técnica é particularmente útil quando o objetivo é inferir conclusões a partir de um conjunto inicial de fatos ou informações. Para Russell e Norvig (2010), é amplamente aplicada em sistemas especialistas para tomada de decisões, controle de processos e monitoramento em tempo real. A ideia central de avançar sequencialmente aplicando regras e atualizando fatos é comum a todas as suas implementações, conforme demonstrado na

imagem 4. A técnica inicia com os fatos conhecidos na base de conhecimento e aplica regras lógicas para alcançar novas decisões. Operadores *AND* e *OR* são usados para combinar os fatos e levar a decisões subsequentes, seguindo uma abordagem sequencial até a conclusão desejada ser deduzida a partir dos dados disponíveis.

Figura 4: Como o Forward Chaining funciona



Fonte: elaborada pela autora (2023)

O método *Backward Chaining* é mais difícil de implementar do que o *Forward Chaining* porque necessita que o sistema especialista tenha conhecimento prévio do problema em questão. Além disso, pode levar mais tempo para ser processado porque o sistema precisa avaliar muitas interdependências antes de chegar a uma conclusão.

2.1.3 Exemplos de sistemas especialistas

Os primeiros sistemas especialistas foram produtos de projetos, produzidos por equipes interdisciplinares por vários anos. Os sistemas referenciados como clássicos, segundo Belhot (1993), são assim chamados porque forneceram o modelo e paradigma para o desenvolvimento de outros sistemas.

Um exemplo de sistema clássico é o DENDRAL, que pode ter sido o projeto de maior duração. O projeto foi iniciado em 1965, com parceria entre *Stanford Spectrometry Laboratory* e *Stanford Heuristic Programming Project*, e tem como objetivo inferir as possíveis estruturas moleculares de compostos desconhecidos, usando dados de espectroscopia de massa e análise de ressonância magnética, em conjunto com conhecimentos heurísticos,

similar ao usado pelos químicos quando executam a mesma tarefa. Dessa maneira, a geração sistemática de todas as estruturas orgânicas plausíveis para uma molécula ainda não conhecida, significa que seu desempenho é algumas vezes superior ao de especialistas da área.

Na obra, o autor ainda destaca o mais famoso sistema especialista na área da medicina, o chamado *MYCIN*, que foi iniciado nos anos 1970, na Universidade de Stanford, com propósito de projetar um sistema que servisse de auxílio aos médicos no diagnóstico e tratamento de infecções bacterianas no sangue. Atualmente, ele está sendo usado comercialmente por médicos clínicos em pesquisas e no ensino de medicina. Os sistemas especialistas que estão sendo desenvolvidos em medicina incluem a interpretação de dados de testes médicos, diagnóstico de doenças, tratamento de doenças e instrução de diagnóstico médico.

Já na área da geologia, destaca-se o sistema PROSPECTOR, desenvolvido pelo Stanford Research Institute, em 1974. Ele é um sistema de consulta desenvolvido para auxiliar na exploração mineral e foi criado para fornecer suporte profissional a geólogos e profissionais envolvidos na identificação e avaliação de jazidas minerais. O sistema usa inteligência artificial e técnicas de processamento de dados para analisar informações geológicas, geoquímicas e geofísicas, entre outras coisas, explicado pelos autores Hart, Duda e Einaudi (1978). Possui uma extensa base de conhecimento, incluindo dados históricos de exploração mineral, características geológicas relevantes, perfis minerais, padrões de mineralização e modelos de depósitos. Ele ajuda os geólogos a identificar áreas com potencial para exploração mineral com base em certos critérios, como a presença de certos minerais, formações geológicas favoráveis e características estruturais. Com o sistema, os estudiosos podem fazer análises detalhadas e gerar mapas que mostram as áreas com maior probabilidade de conter depósitos minerais.

Belhot (1993) ainda apresenta outros exemplos, como o XCON, que é utilizado na configuração de computadores; o DELTA, usado para diagnosticar falhas em locomotivas; e o REACTOR, que auxilia no diagnóstico de tratamento de acidentes em reatores nucleares.

Weatherbell (2023) é **uma empresa** que utiliza técnicas de aprendizado de máquina e modelos preditivos para previsões meteorológicas. Ela combina interpretação de dados

climáticos, diagnósticos de padrões atmosféricos e monitoramento em tempo real para oferecer previsões precisas.

IBM Watson Legal é um sistema especialista que utiliza interpretação de leis, diagnósticos de casos jurídicos e monitoramento de precedentes para auxiliar advogados em pesquisas jurídicas e na tomada de decisões legais. Ele usa tecnologias de processamento de linguagem natural e aprendizado de máquina para analisar vastas quantidades de dados legais (IBM, 2023).

Desenvolvido pela GE (2023) General Electric, o Predix APM é um sistema especialista usado na indústria para monitorar e prever falhas em equipamentos industriais. Ele utiliza interpretação de dados de sensores, diagnósticos de desempenho e predição para detectar anomalias e recomendar ações corretivas antes que ocorra uma falha catastrófica.

O AlphaGo desenvolvido pela Deepmind (2023), uma empresa de inteligência artificial adquirida pela Google, traz um sistema especialista projetado para jogar o jogo de tabuleiro Go. Utilizando técnicas avançadas de aprendizado de máquina, o AlphaGo derrotou jogadores profissionais de Go de nível mundial, demonstrando a capacidade dos sistemas especialistas em superar humanos em tarefas complexas.

Esses exemplos fornecem uma visão geral dos sistemas especialistas e suas aplicações em diferentes áreas.

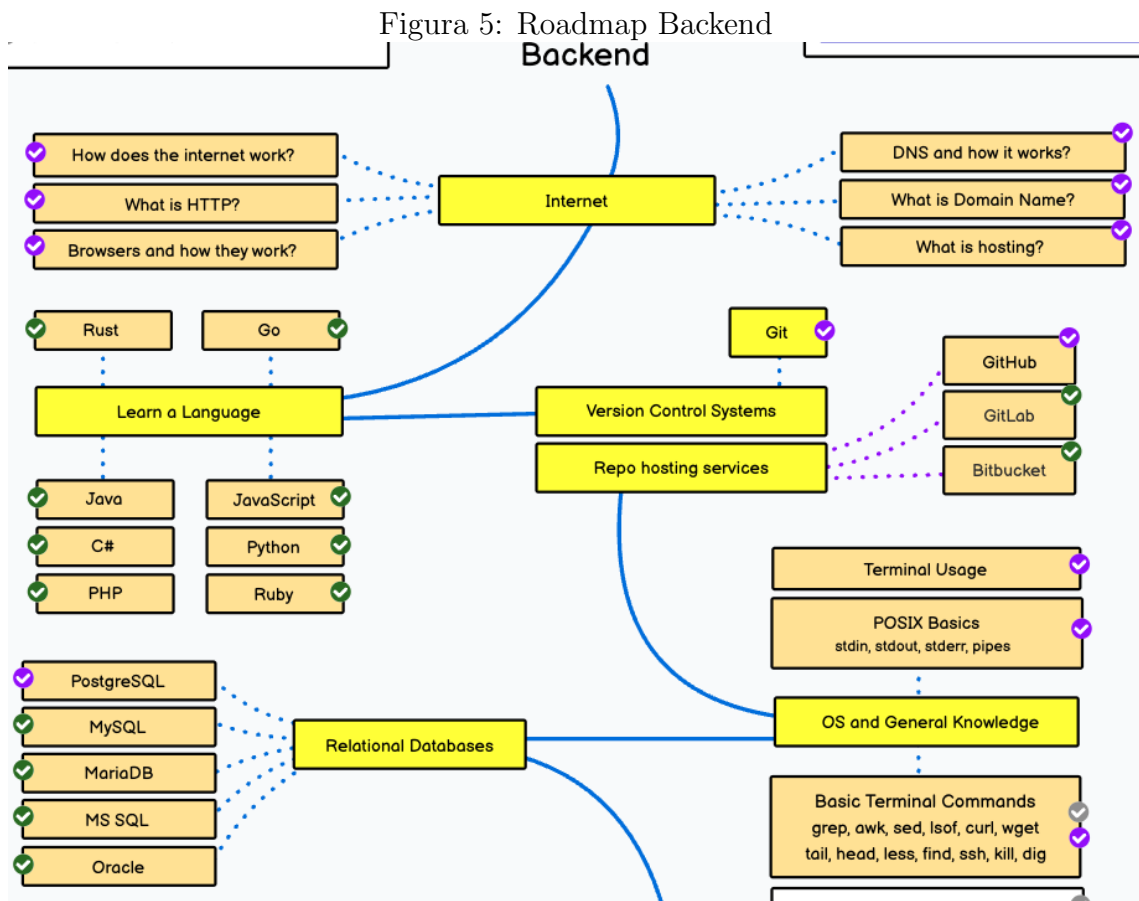
2.2 Roadmap de backend

O *roadmap* de *backend*, ou roteiro de desenvolvimento para o backend, é uma ferramenta importante para orientar o desenvolvimento de sistemas e aplicativos. Ele define as etapas e os conhecimentos necessários para construir e aprimorar a camada do servidor de um sistema, que é responsável pelo processamento de dados, lógica de negócios e integração com outros sistemas.

O roadmap fornece uma visão clara dos passos a serem seguidos no desenvolvimento do sistema. Ele ajuda a equipe de desenvolvimento a entender quais tecnologias, linguagens de programação, frameworks e ferramentas são relevantes e necessárias para alcançar os objetivos do projeto.

No geral, um roadmap de backend é uma ferramenta valiosa para o desenvolvimento de sistemas, pois fornece orientação, planejamento estratégico, evolução contínua, compatibilidade e escalabilidade. Ele promove a comunicação e o alinhamento entre as partes envolvidas, permitindo que o desenvolvimento seja mais eficiente e eficaz.

Na figura 5, é possível conferir um exemplo de roadmap backend da área técnica.



Fonte: elaborada pela autora (2023)

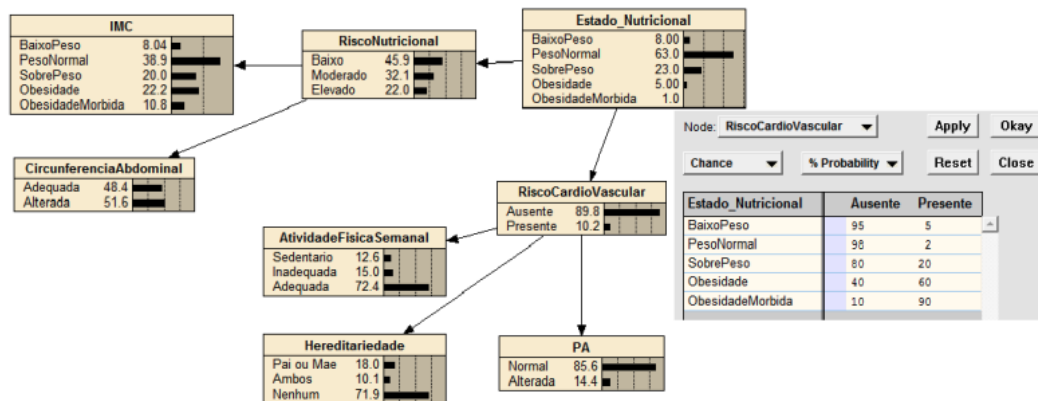
2.3 Redes bayesianas

Uma rede Bayesiana é um modelo gráfico que descreve os relacionamentos probabilísticos entre diversas variáveis e permite inferências baseadas nessas probabilidades. Essas redes oferecem uma representação visual clara das relações entre as variáveis, levando em consideração as distribuições de probabilidade e a independência entre elas. Como resultado, é possível usar uma rede Bayesiana para responder a perguntas sobre qualquer variável incluída nessa distribuição (SARDINHA; PAES; ZAVERUCHA, 2018).

De acordo com Pear (1988), as redes Bayesianas têm se tornado a metodologia padrão na construção de sistemas que envolvem conhecimento probabilístico, sendo aplicáveis em diversas áreas, como medicina, engenharia, biologia, entre outras. A representação de uma rede Bayesiana é feita por meio de um modelo matemático conhecido como grafo direcionado acíclico, que busca retratar as relações existentes em uma determinada situação. Essa representação consiste em nós que representam as variáveis relevantes do domínio e arcos que conectam esses nós, os quais são responsáveis por representar as interações probabilísticas entre as variáveis.

Na representação, estabelece-se uma dependência entre os nós, geralmente chamada de nó pai e nó filho. As variáveis que produzem o arco são conhecidas de variáveis pai, e as que recebem o arco são conhecidas de variáveis filhas. Podemos ver um exemplo na figura 6.

Figura 6: Exemplo de redes Bayesianas



Fonte: Nassar (2012)

As redes Bayesianas se fundamentam no princípio do teorema de Bayes, que utiliza a probabilidade de um sistema com base na ocorrência de um evento atual (DAHIRE, 1988). Essas redes têm a capacidade de identificar as variáveis na estrutura que podem influenciar o valor de outras. Quando existe uma trilha ativa entre um par de variáveis, isso indica que elas não são independentes. Por outro lado, para Sardinha, Paes e Zaverucha (2018), se todas as conexões entre essas variáveis estiverem bloqueadas, elas serão condicionalmente independentes umas das outras.

De acordo com Nassar (2012), as redes Bayesianas são uma forma de representação do conhecimento utilizada para construir bases de conhecimento em sistemas especialis-

tas. Elas consistem em componentes estruturais que representam a relação causal entre as variáveis de entrada e as variáveis de saída do sistema, juntamente com os valores de probabilidade que indicam a força dessa relação. Normalmente, as redes Bayesianas são desenvolvidas através da transferência de conhecimento dos especialistas do domínio para os engenheiros de conhecimento do sistema. No entanto, pesquisas têm explorado a construção de redes Bayesianas por meio de algoritmos capazes de estimar valores de probabilidade e identificar nós da rede a partir de um banco de dados. Nassar (2012) ainda explica que as redes Bayesianas buscam representar a realidade ao inferir a probabilidade de um ou mais eventos com base em evidências observadas. Essas evidências são percepções nas quais se baseiam as afirmações probabilísticas (RUSSELL; NORVIG, 2005).

As redes Bayesianas são compostas por dois componentes principais: um qualitativo e outro quantitativo.

O componente qualitativo expressa o conhecimento por meio de um modelo gráfico, que consiste em um conjunto de nós e arcos, formando um grafo direcionado acíclico. Cada nó representa uma variável aleatória, podendo ser discreta ou contínua. Esses nós são conectados por arcos direcionados, que representam dependências por meio de variáveis de domínio em estudo. Quando um arco parte do nó C e chega ao nó J, diz-se que C é pai de J, e J é filho de C. Esses modelos gráficos representam variáveis, também conhecidas como nós, e as regras são dependências condicionais entre as variáveis, representados pelos arcos direcionados.


O componente quantitativo é formado pelas probabilidades totais e condicionais, *a priori*, associadas aos nós e arcos presentes no componente qualitativo. Cada nó X_i possui uma distribuição de probabilidades condicionais $P(X_i | \text{pais}(X_i))$, que expressa a influência dos nós pais (onde $\text{pais}(X_i)$ representa o conjunto dos nós pais do nó X_i). As redes Bayesianas são caracterizadas por não apresentarem ciclos direcionados, o que significa que não é possível percorrer um caminho respeitando as direções dos arcos e voltar ao mesmo nó. São conhecimentos como um conjunto de probabilidades condicionais associadas aos arcos presentes no modelo gráfico, e as probabilidades estimadas a partir das hipóteses que estão sendo diagnosticadas.

As distribuições de probabilidade condicionais mencionadas, que representam o co-

nhecimento adquirido por especialistas ou a partir de dados, podem ser formalizadas através de teoremas matemáticos. Neste trabalho, abordaremos o Teorema de Bayes nos próximos capítulos, pois esse teorema constitui a base para a parte quantitativa das redes Bayesianas.


Nas figuras 7 e 8 são mostrados exemplos de gráfico cíclico e acíclico:

Figura 7: Exemplo de grafo cíclico



Fonte: elaborada pela autora (2023)

Figura 8: Exemplo de grafo acíclico



Fonte: elaborada pela autora (2023)

2.3.1 Teorema de Bayes

O Teorema de Bayes, formulado pelo estatístico inglês Thomas Bayes, fornece um método para atualizar probabilidades a partir de novas informações. Ele é amplamente

utilizado na inferência estatística e probabilística, permitindo fazer inferências sobre eventos desconhecidos com base em eventos observados.

O teorema estabelece uma relação entre as probabilidades condicionais de dois eventos, conhecidos como evento A e evento B. Paulino, Turkman e Murteira (2003) afirmam que a probabilidade de A ocorrer, dado que B ocorreu, é igual à probabilidade de B ocorrer, dado que A ocorreu, multiplicada pela probabilidade inicial de A ocorrer, e dividida pela probabilidade de B ocorrer independentemente de A.

O teorema é formulado da seguinte maneira:

$$P(A|B) = (P(B|A) * P(A)) / P(B)$$

Onde:

- $P(A|B)$ é a probabilidade do evento A ocorrer dado que o evento B ocorreu.
- $P(B|A)$ é a probabilidade do evento B ocorrer dado que o evento A ocorreu.
- $P(A)$ e $P(B)$ são as probabilidades marginais dos eventos A e B, respectivamente.

O Teorema de Bayes é fundamental para a inferência estatística, pois permite atualizar as crenças sobre um evento com base em novas evidências. É amplamente utilizado em várias áreas, como medicina, ciência de dados, inteligência artificial, processamento de linguagem natural e reconhecimento de padrões.

2.3.2 Inferência em redes Bayesianas

A inferência Bayesiana é um framework estatístico que se baseia no Teorema de Bayes para realizar inferências e fazer previsões sobre parâmetros desconhecidos ou eventos futuros.

O Teorema de Bayes, que serve como fundamento para a inferência Bayesiana, estabelece a relação entre a probabilidade condicional de um evento dado um conjunto de evidências e a probabilidade das evidências, dadas o evento. Ele permite atualizar as crenças prévias sobre o evento com base em novas informações disponíveis.

A inferência Bayesiana difere da abordagem tradicional ao incorporar conhecimento prévio sobre os parâmetros em análise na forma de uma distribuição de probabilidade

inicial, chamada de distribuição *a priori*. Essa distribuição representa a incerteza ou crença prévia sobre os parâmetros antes de observar quaisquer dados. Com a chegada de novos dados, a distribuição *a priori* é atualizada para uma distribuição *a posteriori*, combinando a informação prévia com os dados observados. A distribuição *a posteriori* reflete a incerteza atualizada sobre os parâmetros, sendo utilizada para realizar inferências e previsões.

2.4 Conceito de treinamento

Segundo Chiavenato (2002), citado pelas autoras Farias, Sousa e Silva (2021), treinamento é o processo educacional de curto prazo, aplicado de maneira sistemática e organizada.

Ao realizar treinamento e desenvolvimento da equipe, segundo as autoras, permite que a organização tenha um aumento de produtividade e motivação, além de ter por parte de seus funcionários, soluções e inovações para os problemas do cotidiano. Elas ainda destacam que para uma empresa ser profissional e qualificada, é necessário o desenvolvimento de um ambiente dinâmico, com cursos, palestras, treinos etc., e é por esse motivo que existe treinamento e desenvolvimento.

2.4.1 Componentes de treinamentos corporativos

As autoras Chiavenato (2002) destacam que existem diversos treinamentos, com opções variadas para as empresas melhor se adaptarem, indo de acordo com suas estratégias e objetivos, e apresentam tipos de treinamento organizacionais que são mais utilizados, como:

- **Treinamento de interação:** É um treinamento relevante, pensando principalmente nos regulamentos de cada empresa, uma vez que ele ajuda o colaborador a se aperfeiçoar em seu cargo atual.

Esse treinamento busca orientar e capacitar o funcionário com as tarefas devidas que serão passadas, sendo obrigatório esse treinamento a cada colaborador que se integre à empresa, de modo a cumprir toda a ordem e medida de segurança, devendo

ser adotado para segurança de todos os funcionários.

- **Treinamento comportamental:** Para que se possa ter sucesso em qualquer empresa, é preciso manter o ambiente de trabalho da melhor forma possível. Ele serve como forma de capacitar e orientar o colaborador a se portar de acordo com cada situação destinada a ele no dia-a-dia de um expediente, assim como auxiliar na melhor comunicação no ambiente de trabalho, deixando-o harmônico e satisfatório.
- **Treinamento motivacional:** Treinar e motivar tem um aspecto benéfico na dinâmica da empresa, uma vez que, de acordo com as autoras, sem motivação ninguém vai a lugar nenhum. Além disso, com motivação, pode-se observar resultados positivos.
- **Treinamento corporativo:** Treinamento que pode ser feito de diversas formas, como por meio de aulas teóricas ou práticas, voltados ao trabalho que o colaborador realizará. Ele serve para desenvolver melhor determinadas funções que serão exercidas, a partir do desenvolvimento pessoal ou do jeito técnico que aquela função pede.

É notório que o treinamento corporativo é essencial para o desenvolvimento dos funcionários e, conseqüentemente, para a melhora dos resultados da empresa.

- **Treinamento técnico:** É uma estratégia de educação corporativa voltada à capacitação dos colaboradores por meios técnicos, sendo compreendido aspectos mais práticos do cotidiano da empresa e do funcionário. Tem como foco, o desenvolvimento das competências técnicas dos colaboradores, de maneira que as atividades específicas sejam executadas com maior qualidade e eficiência, podendo ser chamado também de treinamento de *hard skills*, um tipo de treinamento que foca no desenvolvimento de funcionários em habilidades e competências, ou seja, aqueles conhecimentos que poderão facilitar a vida do profissional na hora de executar alguma atividade.

2.4.2 Universidades Corporativas

Segundo Vergara e Ramos (2002), as Universidades Corporativas são um tema que se tornou centro das atenções da Administração, já que nos últimos anos, verificou-se uma ênfase no aprendizado como forma de empresas e pessoas atualizarem-se frente as constantes e rápidas mudanças do mundo atualmente.

Com uma competição global acirrada no mundo dos negócios e a constante inovações tecnológicas, as empresas têm vivenciado uma mudança intensa e as universidades corporativas se apresentam como uma alternativa as organizações, no processo de desenvolvimento das pessoas, de forma contínua e alinhada de forma estratégica, com a contribuição na produção, acumulação e difusão de conhecimentos. É por meio destas universidades que as empresas tentam superar o modelo estático e reativo de treinamento e desenvolvimento.

Para Branco (2006), a universidade corporativa pode ser implantada tanto por empresas que desejam ampliar e padronizar os programas de treinamento, quanto aquelas que pretendem oferecer ao funcionário novas oportunidades de desenvolvimento.

A autora destaca também que algumas das aplicações que normalmente são observadas nas universidades corporativas são a formação e desenvolvimento gerencial; educação de executivos; saúde e segurança do trabalho; treinamento de força de vendas; procedimentos e rotina de trabalho; treinamento na operação do software de gestão integrada; disseminação, por meio de treinamento formal, das políticas da empresa; certificação de revendedores, distribuidores e empresas de assistência técnica; fidelização do cliente final, por intermédio de programas especiais de treinamento.

2.5 Conceito de aprendizagem

De acordo com Doro (2022), é possível entender a aprendizagem organizacional como um processo sistêmico no qual as organizações desenvolvem e atualizam suas competências e se adaptam às mudanças, tornando-se capazes de aumentar seu desempenho e promover inovações. O autor ainda refere-se ao “processo sistêmico”, como um movimento realizado pela organização como um todo.

O autor ainda destaca que, devido à grandeza da aprendizagem organizacional, ela é realizada na prática por meio de processos diversificados, onde pesquisadores se debruçam nestes processos e realizaram observações e estudos empíricos, na busca de compreender a forma e em quais condições cada um processo contribuiu para a aprendizagem organizacional.

Outro autor destacado na obra, é Pereira (1998), que definiu cinco disciplinas da “or-

ganização que aprende”, sendo: domínio pessoal, modelos mentais, visão compartilhada, aprendizado em equipe e pensamento sistêmico.

O modelo de ”organização que aprende” requer um funcionamento efetivo, além do desenvolvimento contínuo de novas habilidades e capacidades de compreender o todo, o engajamento dos colaboradores e seu alinhamento com o propósito organizacional.

Pereira, Aidar e Lopes (2021) destacam alguns elementos da cultura organizacional, como: *aprendizagem no trabalho*, as empresas orientam a aprendizagem e o desenvolvimento para atividades em seus locais de trabalho, causando desvantagem à oferta de cursos formais; *clima benéfico a aprendizagem*, as empresas disponibilizam oportunidades, ferramentas e condições de aprendizado, ressaltando que o fracasso foi desmistificado por representar uma forma de aprendizado; *aprendizagem organizacional*, possui agentes organizados, constituídos por indivíduos que aprendem, o conhecimento adquirido é revertido na memória organizacional; *estrutura de aprendizagem*, representa como se estrutura o trabalho entre os grupos. Esses elementos desempenham papel de influência ou de relação com a cultura de aprendizagem, onde a cultura organizacional exerce um papel de extrema relevância no processo de aprendizagem, uma vez que se um ambiente tem um clima agradável, apresenta algum tipo de recompensa, os membros conseguem perceber com clareza das estratégias organizacionais, as pessoas são incentivadas a aprender.

2.6 Trabalhos correlatos

Nesta seção, serão apresentados trabalhos correlatos recentes que abordam a utilização de redes Bayesianas em sistemas especialistas. Serão discutidos exemplos de aplicações em diferentes áreas, demonstrando como as redes Bayesianas têm sido empregadas para representar o conhecimento especializado e auxiliar na tomada de decisões. Os trabalhos selecionados destacam as contribuições mais recentes nesse campo, oferecendo insights valiosos sobre o uso de redes Bayesianas em sistemas especialistas.

O trabalho intitulado *A hybrid recommender system for recommending relevant movies using an expert system*, dos autores Walek e Fojtik (2019), apresenta o desenvolvimento de um sistema de recomendação chamado Predictory, que tem o objetivo de recomendar filmes relevantes aos usuários. O sistema combina diferentes abordagens,

incluindo um módulo de filtragem colaborativa baseado no algoritmo SVD e lógica fuzzy.

O Predictory utiliza informações sobre os gêneros de filmes favoritos e impopulares do usuário para gerar recomendações personalizadas. Além disso, a lógica fuzzy é empregada para avaliar a importância dos filmes e determinar a lista final de recomendações. Esse sistema especialista considera vários parâmetros, como a avaliação média dos filmes, o número de avaliações e a similaridade entre filmes já avaliados pelo usuário.

Uma das principais contribuições desse trabalho é a criação de um sistema híbrido complexo na área de recomendação de filmes, que supera as abordagens tradicionais, como sistemas de filtragem colaborativa, sistemas baseados em conteúdo e sistemas híbridos ponderados.

Já no trabalho *An Intelligent Personalized Fashion Recommendation System*, as autoras Stan e Mocanu (2019) apresentam um sistema automatizado que recomenda conjuntos de roupas com base nas preferências do usuário. Utilizando duas redes neurais convolucionais modeladas a partir do AlexNet, o sistema identifica peças de roupa e seus atributos. Em seguida, são utilizadas pontuações para avaliar as preferências do usuário na combinação de diferentes itens, garantindo recomendações mais adequadas.

O sistema de recomendação proposto gera conjuntos de roupas com base em uma peça específica fornecida como imagem, considerando as preferências do usuário. Para isso, identifica o tipo de roupa e seus atributos, estabelecendo regras de compatibilidade entre as peças de acordo com suas propriedades. O objetivo é atribuir pontuações a diferentes combinações de tipos e estilos de roupas, aprimorando dinamicamente as recomendações.

Outro fator importante a ser considerado é a personalidade de cada usuário. Para abordar esse problema, é criado um guarda-roupa pessoal e um conjunto de pontuações é atribuído com base tanto em regras de moda quanto nas preferências do usuário. Essas pontuações são atualizadas dinamicamente de acordo com as escolhas do usuário.

E por último, no trabalho *Toward a better expert system for auditor going concern opinions using Bayesian network inflation factors*, os autores Desai, Bucaro e Kim (2023) apresentam um modelo analítico como a primeira etapa no desenvolvimento de sistemas especialistas para enriquecer o conhecimento dos auditores e apoiar o processo de decisão sobre pareceres de continuidade operacional. Utilizando redes Bayesianas, o modelo

oferece informações sobre a revisão ou ajuste dos auditores na probabilidade de emitir uma opinião com base na presença de um, dois ou três fatores de risco observáveis publicamente nas demonstrações financeiras: prejuízo operacional líquido, fluxos de caixa negativos das operações e capital de giro negativo. Os resultados revelam que o relacionamento incremental de um, dois ou três fatores é eficaz na modelagem das decisões dos auditores especialistas ao emitir um parecer técnico e sugere a existência desses fatores de inflação mensuráveis, que representam fatores situacionais e específicos do especialista auditor.

Os três trabalhos apresentados abordam diferentes aspectos e aplicações dos sistemas especialistas em suas respectivas áreas. O primeiro trabalho se concentra na recomendação de filmes, utilizando uma abordagem híbrida que combina filtragem colaborativa e lógica fuzzy. O segundo trabalho trata da recomendação de roupas, utilizando redes neurais convolucionais e pontuações para avaliar as preferências do usuário. Já o terceiro trabalho envolve a aplicação de redes Bayesianas para auxiliar na tomada de decisão de pareceres de continuidade operacional de auditores.

Em conjunto, esses trabalhos ressaltam a importância dos sistemas especialistas na solução de problemas complexos e na melhoria da experiência do usuário em diferentes domínios. Essas abordagens inovadoras têm o potencial de impulsionar ainda mais o avanço da inteligência artificial e contribuir para o desenvolvimento de sistemas cada vez mais sofisticados e eficazes.

Os estudos citados fornecem uma perspectiva valiosa para o desenvolvimento do projeto desta pesquisa. As técnicas de recomendação de filmes e de conjuntos de roupas, bem como a aplicação de redes Bayesianas na auditoria, ressaltam a versatilidade e a eficácia dos sistemas especialistas em contextos diversificados. As abordagens híbridas e a modelagem avançada oferecem *insights* fundamentais para a concepção do meu sistema especialista baseado em regras e redes Bayesianas, destinado ao levantamento do conhecimento técnico dos colaboradores e à sugestão de cursos apropriados. A integração bem-sucedida de metodologias variadas nos trabalhos correlatos reforça a relevância e o potencial do meu projeto em contribuir significativamente para a otimização de processos de aprendizado e desenvolvimento profissional dentro das organizações.

Cada um dos trabalhos correlatos contribui para esta pesquisa ao demonstrar a eficácia

como cada um aborda a personalização e a análise de dados complexos. O Predictory demonstra como diferentes técnicas podem ser combinadas para criar recomendações mais acuradas, o que é paralelo à combinação de regras e probabilidades na pesquisa para sugerir cursos. A abordagem de análise de imagens e preferências pessoais no sistema de moda ilustra a relevância de adaptar as recomendações ao usuário individual, uma estratégia que foi adaptada para criar recomendações de treinamento que se ajustam ao perfil único de conhecimento de cada colaborador. Por fim, o uso de redes Bayesianas na auditoria realça a eficácia desta técnica em gerir a incerteza, uma capacidade que emprego para aprimorar a precisão das recomendações de cursos. Este trabalho avança em relação a eles ao focar no contexto específico do levantamento de conhecimento técnico e na formação contínua dos colaboradores, ampliando a aplicabilidade dos sistemas especialistas e redes Bayesianas para o desenvolvimento de talentos dentro das organizações.

3 METODOLOGIA

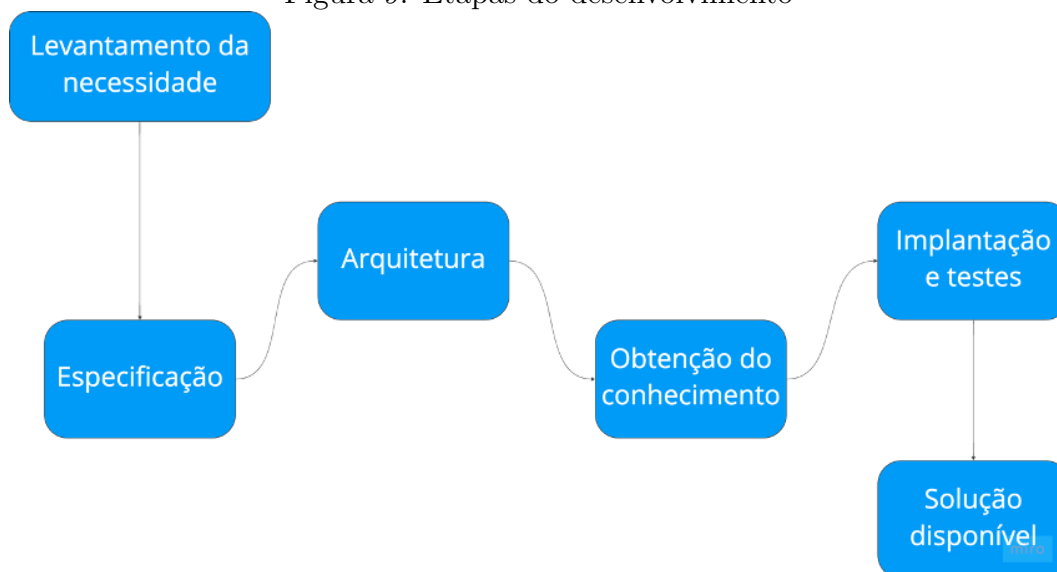
Este capítulo descreve em detalhes o desenvolvimento do sistema especialista denominado *TREEVO*, um acrônimo que representa a fusão entre *Tecnologia e Evolução*. O sistema incorpora metodologias de sistemas especialistas baseados em regras para avaliar o conhecimento técnico dos colaboradores, e utiliza redes bayesianas para recomendar os cursos ou treinamentos mais apropriados, calculando probabilidades para identificar lacunas em stacks e ferramentas específicas do setor tecnológico. Assim, *TREEVO* visa apresentar opções de treinamento personalizadas que se alinhem melhor às necessidades de cada colaborador, baseando-se em uma análise probabilística realizada pela rede bayesiana. Esta análise permite determinar o nível de proficiência do colaborador, sua capacidade de disseminar conhecimento ou a necessidade de apoio adicional em suas atividades.

Atualmente, a identificação de lacunas de competências e a customização de treinamentos para atendê-las são processos manuais e demorados, que consomem recursos significativos, especialmente em equipes com menor experiência. Este cenário impõe desafios à liderança, que gasta um tempo considerável nesta tarefa. Portanto, o propósito deste estudo é propor um protótipo de sistema especialista capaz de avaliar com precisão o nível de conhecimento dos colaboradores e sugerir cursos de forma personalizada e eficiente, otimizando o processo de desenvolvimento profissional.

O foco deste projeto está na área de *backend*, e a base de conhecimento consiste em uma série de questões relacionadas a *Java* e *Boas Práticas*, cada uma vinculada a regras específicas que serão minuciosamente discutidas nas próximas seções. As perguntas utilizadas neste trabalho podem ser encontradas nos anexos A e B.

Para compreender melhor o método proposto e a estrutura de desenvolvimento do sistema, baseado nos princípios da engenharia de software conforme apresentado por Pressman e Maxim (2016), é abordado um ciclo completo de vida do software. Este ciclo contempla desde a análise de requisitos até a manutenção do sistema em produção. A construção do sistema é dividida em seis fases, conforme ilustrado na figura 9 e são detalhadas abaixo.

Figura 9: Etapas do desenvolvimento



Fonte: elaborada pela autora (2023)

- **Fase 1: Levantamento da necessidade**

Durante esta fase, realizou-se uma análise detalhada do processo e das dificuldades enfrentadas, com o objetivo de identificar oportunidades de contribuição para este projeto de pesquisa. Os líderes enfrentam o desafio de selecionar cursos que se alinhem precisamente com as necessidades de desenvolvimento de cada colaborador. A avaliação do conhecimento é realizada por meio de uma planilha, que registra respostas sobre o domínio de diversas tecnologias, e subsequente mapeamento dessas tecnologias em relação à proficiência de cada colaborador.

Há, contudo, obstáculos significativos para determinar a priorização dos cursos. Esse processo, ainda executado manualmente, carece de precisão e não oferece garantia de que todo o conhecimento do colaborador foi adequadamente capturado. Além disso, a identificação eficaz das lacunas de conhecimento se apresenta como uma tarefa complexa, indicando a necessidade de uma solução mais sistemática e automatizada.

Para Sommerville (2019), o levantamento de requisitos é uma atividade crítica no desenvolvimento de software, pois fornece a base para todo o processo de engenharia de software. É uma etapa fundamental no desenvolvimento, pois estabelece a base para o projeto e implementação de um sistema que atenda aos requisitos necessários.

- **Fase 2: Especificação**

Nesta etapa, se realizou a definição detalhada da estrutura do sistema especialista,

denominado *TREEVO*, planejando suas especificações técnicas e operacionais. Foi determinada a área de atuação do sistema, com ênfase no desenvolvimento backend, e selecionadas as tecnologias e metodologias a serem avaliadas, como Java e Boas Práticas. Elaborou-se o conjunto de perguntas, cada uma com múltiplas opções de resposta, e estabeleceram-se critérios para perguntas que requerem conhecimentos prévios.

Foram estabelecidos os parâmetros para a categorização do nível de conhecimento dos colaboradores, distribuídos em categorias que variam de iniciante a expert. A pontuação foi escalonada de 0 a 100, com faixas definidas para cada nível: de 0 a 25 pontos classifica o colaborador como iniciante, de 26 a 50 como intermediário, de 51 a 75 como avançado, e de 76 a 100 como expert.

A pontuação atribuída às respostas também foi meticulosamente distribuída. Para a resposta *Não conheço*, atribui-se 0 pontos; *Conheço pouco* equivale a 10 pontos; *Conheço*, 30 pontos; e *Domino*, 50 pontos. Em situações em que o conhecimento prévio é essencial, e as respostas são *Não conheço* ou *Conheço pouco*, haverá uma dedução de pontos que varia de 10 a 20, dependendo do nível de complexidade da pergunta. Esta abordagem estratificada garante uma avaliação e uma análise que leva em conta as pequenas diferenças e características individuais, oferecendo uma compreensão mais rica e detalhada do conhecimento técnico dos colaboradores.

Segundo Pressman e Maxim (2016), o processo de especificação é um artefato crucial no desenvolvimento de software, pois fornece uma descrição precisa e unificada do sistema a ser construído.

- **Fase 3: Arquitetura**

Nesta fase, a arquitetura do sistema foi cuidadosamente planejada e esboçada com uma abordagem centrada na funcionalidade, independentemente de tecnologias específicas – uma estratégia tecnologicamente agnóstica.

O sistema é projetado para duas personas principais: o colaborador e o especialista. O especialista é encarregado de elaborar perguntas em sua área de expertise, seja ela tecnologia, gestão ou outra área relevante, enriquecendo a base de conhecimento do sistema e armazenando essas informações em um banco de dados.

Por outro lado, o colaborador interage com a interface gráfica do *TREEVO*, seleti-

onando a área de conhecimento que deseja avaliar. As perguntas formuladas pelo especialista são então apresentadas ao colaborador. Após respondê-las, o sistema processa as respostas utilizando uma base de fatos, que é um repositório de conhecimento conhecido, e um motor de inferência, que é uma ferramenta lógica capaz de deduzir novas informações a partir de regras predefinidas e fatos conhecidos. Com base nessa análise, o sistema classifica o nível de conhecimento do colaborador.

Esta classificação é enviada a um modelo de rede bayesiana, que, por meio de cálculos probabilísticos, determina o treinamento mais adequado e personalizado para o colaborador, considerando variáveis como classificação de conhecimento, nível de senioridade atual e tecnologia relevante.

A integração desses elementos permite que o sistema forneça ao colaborador uma descrição detalhada, imagens e links dos cursos mais indicados para aprimorar suas competências.

A *base de fatos* é crucial neste contexto, pois armazena informações verificáveis que o sistema utiliza para avaliar as respostas dos colaboradores. Já o *motor de inferência* utiliza essa base de fatos para aplicar regras lógicas e derivar conclusões, que, neste caso, correspondem ao nível de competência do colaborador. É o motor de inferência que permite que o sistema especialista opere de forma autônoma, raciocinando sobre os dados inseridos e produzindo recomendações confiáveis.

Para Pressman e Maxim (2016), a arquitetura desempenha um papel crucial no sucesso de um sistema de software, impactando diretamente sua qualidade, manutenibilidade, desempenho e extensibilidade. Ela fornece uma base sólida para o desenvolvimento de software de alta qualidade e escalabilidade.

- **Fase 4: Obtenção do conhecimento**

Este estágio é crucial, pois trata da captura e do enriquecimento contínuo do conhecimento, um processo vital para a eficácia do sistema. Um especialista na matéria em questão é responsável por compilar um conjunto de perguntas pertinentes ao tema em foco. Mais do que isso, o especialista assume o papel de mantenedor do sistema, atualizando constantemente o banco de perguntas — adicionando, modificando ou excluindo questões conforme necessário. Isso garante que a base de conhecimento do sistema permaneça atualizada e rica, permitindo, em conjunto com as regras pré-

definidas também pelo especialista, extrair e validar eficientemente o conhecimento dos colaboradores.

No coração do ecossistema de um sistema especialista, a base de fatos atua como um repositório dinâmico de informações, enquanto o motor de inferência processa esses dados para formar novos entendimentos e conclusões. Através desse mecanismo, o sistema especialista pode validar e qualificar o conhecimento dos colaboradores de forma robusta e confiável.

A obtenção do conhecimento se dá por meio da interação do colaborador com o sistema. Quando um colaborador responde às perguntas, ele está fornecendo dados que refletem seu entendimento e proficiência nas áreas questionadas. Essas respostas são comparadas e analisadas em relação à base de conhecimento existente, permitindo ao motor de inferência aplicar as regras definidas para avaliar a precisão e profundidade do conhecimento do colaborador. Assim, o sistema especialista, por meio da sua arquitetura e algoritmos, transforma as interações individuais dos colaboradores em *insights* valiosos sobre suas habilidades e lacunas de conhecimento.

Para Russell e Norvig (2020), envolve identificar, capturar e representar o conhecimento relevante de especialistas em um determinado domínio. Isso pode ser feito por meio de entrevistas, observações, análise de documentos e outros métodos de coleta de dados.

- **Fase 5: Implantação e testes**

Neste estágio, o sistema *TREEVO* já se encontra implementado e disponível para os testes iniciais com os usuários. Para a validação inicial, contamos com a participação de 25 desenvolvedores de diversas senioridades, variando de júnior a expert. Com o objetivo de coletar feedbacks precisos e detalhados sobre a usabilidade e aceitação do sistema pelos usuários, foi aplicado o formulário de pesquisa conhecido como TAM 2, Technology Acceptance Model 2 .

O uso do TAM 2 é essencial para entender melhor como os usuários percebem a utilidade e a facilidade de uso do *TREEVO*. Este modelo ampliado de aceitação tecnológica ajuda a identificar fatores que influenciam a disposição dos usuários em adotar e usar o sistema de forma regular. Ele considera variáveis como a percepção de utilidade (se os usuários acreditam que o sistema melhorará seu desempenho) e

a percepção de facilidade de uso (se os usuários acreditam que o sistema é fácil de operar). Além disso, o TAM 2 incorpora elementos que examinam influências externas sobre essas percepções, como suporte social e condições facilitadoras, fornecendo assim uma compreensão abrangente da aceitação do sistema.

O formulário aplicado está disponível na seção de anexos deste documento. Ele é uma ferramenta vital para coletar essas percepções e ajustar o sistema de acordo com as necessidades e expectativas dos usuários, garantindo uma implementação bem-sucedida e uma adoção mais ampla do *TREEVO*.

- **Fase 6: Solução disponível**

Nesta etapa, concluímos uma série de testes e configurações cruciais, incluindo o estabelecimento de um banco de dados para armazenar as questões, a criação de um *storage* de armazenamento para as imagens dos treinamentos e a compilação de uma lista de treinamentos que será consultada após as análises realizadas pela rede bayesiana. Com essas ações completas, o sistema *TREEVO* está pronto para ser hospedado em um ambiente de nuvem, tornando-se acessível a todos os usuários através de uma URL específica.

Segundo Pressman e Maxim (2016), esse processo requer um planejamento cuidadoso e uma execução precisa para garantir que o sistema seja configurado corretamente e esteja pronto para uso.

Importante salientar, esta versão do *TREEVO* não inclui funcionalidades de segurança, como validação de acesso, o que significa que está aberta a qualquer pessoa que disponha do link. Esta decisão permite um acesso amplo e facilitado ao sistema, embora futuras atualizações possam contemplar a implementação de medidas de segurança para gerenciar o acesso de forma mais restrita e segura.

3.1 O sistema *TREEVO*

O *TREEVO* é um sistema especialista projetado para avaliar o nível de conhecimento de colaboradores nas empresas e, com base nos resultados, sugerir treinamentos específicos adaptados a cada nível de conhecimento avaliado. A partir disso, o *TREEVO* ajuda a aprimorar a produtividade dos líderes na identificação e avaliação de possíveis lacunas

nas competências técnicas das pessoas, estimulando o desenvolvimento e capacitação profissional dos colaboradores. O sistema também pode ser utilizado como suporte ao processo de entrevistas, identificando candidatos com habilidades relevantes para o trabalho.

O protótipo foi construído utilizando o framework Experta na última versão estável 1.9.4, Python 3.9, e Flask, um framework web para pequenas aplicações e Bootstrap, um framework que fornece estrutura CSS para criação de páginas HTMLs responsivas.

Já a interface é interativa e apresenta um conjunto de perguntas de múltipla escolha focadas em Java e boas práticas de programação. Além disso, inclui questões estatísticas relacionadas ao cargo atual do usuário, gênero e etnia. As respostas fornecidas são analisadas por um sistema especialista baseado em regras, que classifica o nível de conhecimento do usuário em categorias: iniciante, intermediário, avançado e expert.

Para realizar a classificação eficiente e sugerir o treinamento mais apropriado, o sistema utiliza uma rede Bayesiana. Esta rede necessita de informações, como a classificação dada pelo sistema especialista, a tecnologia abordada nas perguntas, a senioridade do usuário, identidade de gênero e etnia. Com base nesses dados, a rede bayesiana é capaz de fornecer uma recomendação de treinamento personalizada, alinhada ao perfil do usuário.

Este sistema reflete os princípios discutidos por Luger (2016), onde sistemas especialistas são integrados com redes Bayesianas para uma análise mais precisa e personalizada. Além disso, segue a abordagem de Jones (2008), enfatizando a importância da personalização em sistemas baseados em inteligência artificial (IA).

3.2 Implementação do sistema

Para Sommerville (2019), a implementação de um sistema refere-se ao processo de desenvolvimento, configuração e implantação de um sistema de software ou hardware para que ele possa ser usado em um ambiente operacional. Envolve a tradução dos requisitos e especificações do sistema em um produto funcional e utilizável, assim como design, codificação, testes e implantação.

3.2.1 Matriz CSD

A Matriz CSD (BRETAS, 2015) é um framework responsável por conectar os pensamentos, estruturar as informações e, especialmente, nortear as ideias para a prospecção de projetos, a partir de três perguntas essenciais. São elas:

- O que já se sabe a respeito?
- Quais as possibilidades e/ou o que se acredita saber?
- Quais perguntas podem ser feitas?.

A partir dessas perguntas, criam-se três colunas em um quadro para que seja possível fazer anotações. Segundo Bretas (2015), a matriz foi criada pela consultoria de design de serviços Livework. Essa matriz foi construída com base no levantamento de ideias e no conhecimento dos cenários estudados, categorizando as percepções sobre o que as pessoas têm certeza, o que elas apenas supõem e o que têm de dúvidas.

A sigla CSD consiste em três pilares: certezas, suposições e dúvidas. Tem como responsabilidade listar as preocupações e pontos de atenção do projeto e reunir as informações em um só lugar, possibilitando visualizar tudo o que já se sabe e o que se deseja descobrir. A matriz CSD é importante para começar projetos e, principalmente, acelerar o processo de descoberta.

Para Bretas (2015), a matriz é uma ferramenta visual que permite constatar que a quantidade de certeza é menor do que se pensava anteriormente, tornando a prática da empatia mais prática e eficaz.

A matriz CSD criada para este trabalho está descrita na imagem 10. Foram propostas ideias e concepções que ajudaram na criação das regras de negócio, no entendimento e no funcionamento do sistema. A matriz não é estática, ela pode ser utilizada no processo de desenvolvimento do sistema para registrar mudanças atuais e em andamento, assim como dúvidas sanadas posteriormente.

Figura 10: Matriz CSD

Certezas	Suposições	Dúvidas
<p>Sistema terá pelo menos duas personas</p> <p>Persona 1: colaborador (pessoa que fará o treinamento)</p> <p>Persona 2: Liderança (pessoa que acompanhará a evolução dos treinamentos)</p> <p>Sistema proposto para o time de tecnologia</p>	<p>A indicação personalizada de cursos vai tornar o processo de aprendizagem mais eficiente.</p> <p>Incluir no desenvolvimento técnico da pessoa pode fazer com que eles fiquem mais motivados.</p> <p>Com o sistema a gestão poderá ter mais visibilidade sobre a produtividade de cada pessoa do time.</p> <p>Utilizar o sistema pode melhorar a curva de aprendizagem do time.</p>	<p>O sistema vai trazer ou indicar cursos?</p> <p>É possível fazer treinamentos através do sistema?</p> <p>Quais são as personas que vão servir como base para indicações de cursos?</p> <p>Quais são os dados necessários para inputar no sistema?</p>
<p>Colaborador só poderá escolher treinamentos entre os indicados pelo sistema</p> <p>Para indicar os treinamentos, o sistema usará uma base de questões afirmativas</p> <p>O questionário será no formato de múltipla escolha</p> <p>Colaborador e gerente poderão acompanhar o progresso de cada colaborador e gerar relatórios para a liderança</p>	<p>Utilizar o sistema pode ajudar nos gaps técnicos das pessoas do time e ajudá-las a serem mais produtivas</p> <p>Integrar o sistema com o sistema de RH da empresa técnica pode fazer com que todos os colaboradores se motivem mais rápido.</p>	<p>Os cursos vão ficar no sistema especialista?</p> <p>Existe limite de cursos que o aluno poderá fazer?</p> <p>Como mapear os gaps técnicos?</p> <p>Quem vai inputar as regras? Liderança ou um perfil diferente?</p>
<p>No mínimo 2 pessoas participam da avaliação, sendo 1 liderança e 1 pessoa participante</p> <p>Sistema vai gerar certificado</p> <p>Criar uma única persona: Colaborador</p> <p>Lista de afirmativas (as invés do questionário)</p>		<p>As pessoas do time se avaliam entre si?</p> <p>O que o sistema vai avaliar?</p> <p>Quais serão as regras?</p> <p>Quais métodos e dados para avaliar produtividade?</p>
<p>Gerar relatório final sobre as escolhas e o treinamento apresentado</p> <p>Sistema vai avaliar duas características: - pessoa - função</p> <p>A lista de treinamentos virá do ProPlay Academy</p> <p>Mapear treinamentos que tragam agilidade e produtividade</p>		

Fonte: elaborada pela autora (2023)

Conforme visto na figura 11, na coluna Certezas, incluímos os elementos que estão definidos e consolidados no projeto, ou seja, o conhecimento existente.

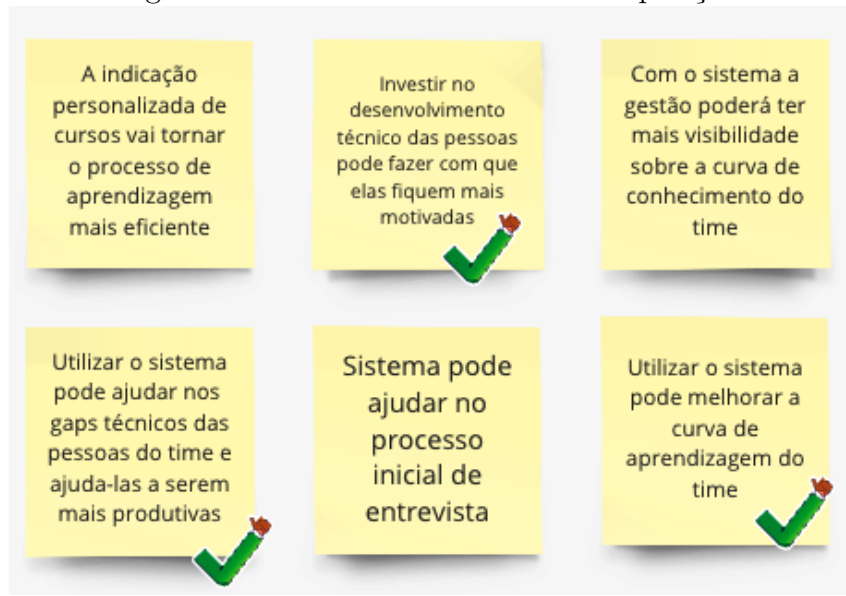
Figura 11: Matriz CSD: Coluna de Certezas

<p>Persona 1: colaborador (pessoa que fará o treinamento)</p>	<p>Persona 2: Liderança (pessoa que acompanhará a evolução dos treinamentos)</p>	<p>Sistema proposto para o time de tecnologia</p>
<p>Colaborador só poderá escolher treinamentos entre os indicados pelo sistema</p>	<p>Para indicar os treinamentos, o sistema usará uma base de questões afirmativas</p>	<p>O questionário será no formato de múltipla escolha</p>
<p>Gerar relatório final sobre as escolhas e o treinamento apresentado</p>	<p>Sistema vai avaliar duas características: - pessoa - função</p>	<p>Mapear treinamentos que tragam agilidade e produtividade</p>

Fonte: elaborada pela autora (2023)

As Suposições são hipóteses que necessitam de validação e podem originar-se de experiências anteriores, requerendo confirmação. Elas também representam pontos que podem provocar divergências de opiniões entre as pessoas. A figura 12 ilustra um exemplo de uma coluna de suposições.

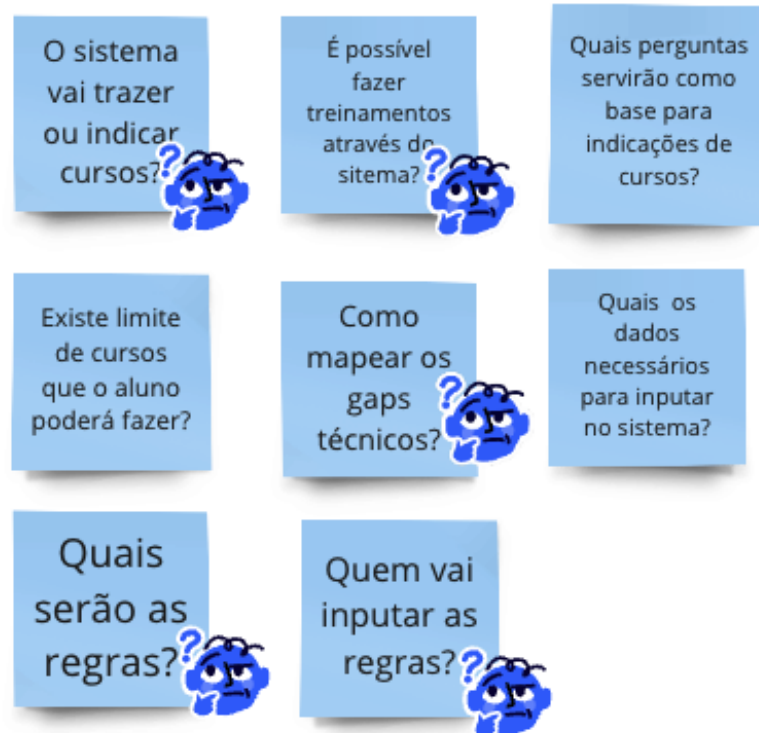
Figura 12: Matriz CSD: Coluna de Suposições



Fonte: elaborada pela autora (2023)

Já a coluna de Dúvidas abrange tudo o que ainda não se sabe em relação ao projeto e é preciso descobrir. Um exemplo é ilustrado na figura 13.

Figura 13: Matriz CSD: Coluna de Dúvidas



Fonte: elaborada pela autora (2023)

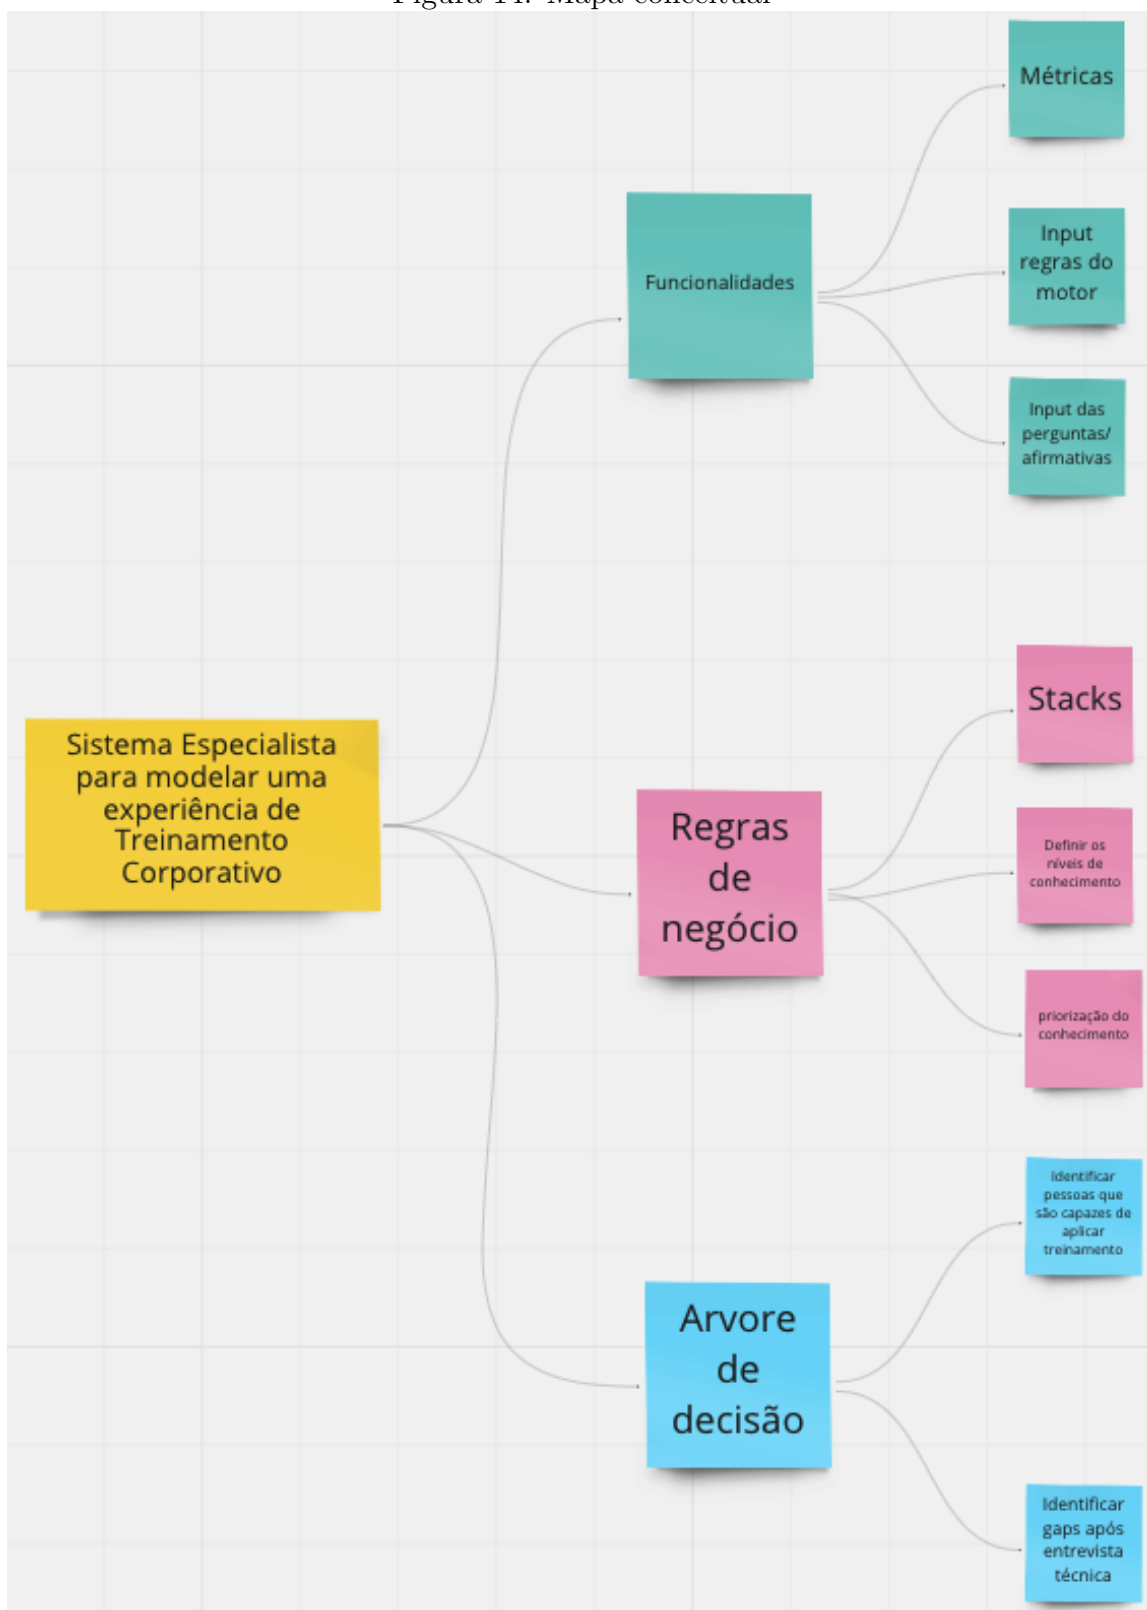
3.2.2 Mapa conceitual

O mapa conceitual é um diagrama usado para representar visualmente alguma ideia ou conceito, permitindo que diferentes aspectos sejam associados dentro de uma mesma representação. Pode ser construído manualmente ou com a ajuda de ferramentas gráficas. Tem uma estrutura hierárquica descrita por meio de retângulos ou círculos, também conhecidos como nós, que são conectados por linhas e setas, também conhecidos como arcos.

Para Moreira (2006), o mapa conceitual pode ser entendido e apresentado como diagramas hierárquicos para conceitualizar uma ou mais disciplinas, ou partes delas, e pode ser considerado um guia simplificado para criação de disciplinas ou conteúdos. Diante disso, um mapa conceitual pode ser planejado com uma pergunta, um contexto, um tema ou uma pesquisa. Além disso, pode ser utilizado como recurso para todas as etapas, por exemplo: abordar um tema, uma aula, uma unidade de ensino, um capítulo de livro, realizar síntese de texto, seja no desenvolvimento de novos conhecimentos ou na avaliação da aprendizagem.

Em outra perspectiva, Moreira (1997) afirma que é importante deixar claro no mapa quais conceitos são mais importantes no contexto aplicado e quais são os secundários ou os específicos. As setas podem ser usadas para fornecer um sentido de direção para algumas relações conceituais, mas não necessariamente. Um exemplo é mostrado na figura 14.

Figura 14: Mapa conceitual



Fonte: elaborada pela autora (2023)

3.2.3 Matriz de competências

Uma matriz de competências é uma representação gráfica das funções e competências dos colaboradores de uma empresa. Para a aplicação da matriz, são definidas competências e níveis esperados na organização, sendo então associado cada colaborador ao nível correspondente (KURUBA, 2019).

A matriz de competências possui benefícios que podem ser percebidos por todos os gestores de uma organização. Além de compreender pontos fortes e fracos do time, a partir da matriz, os gestores também são capazes de identificar as características e facilitar a alocação de pessoas para projetos específicos. Além de saber onde precisam melhorar, os colaboradores podem ser designados para atividades que melhor maximizem seu potencial. Ao final, a empresa obtém melhores resultados, pois o objetivo da ferramenta é organizar e otimizar os processos, levando a melhores resultados.

A matriz do Management 3.0 é uma ferramenta que permite criar um mapeamento das competências necessárias para a organização, alinhando-as com as habilidades existentes na equipe. É uma prática recomendada elaborar uma lista de competências específicas para cada cargo ou processo, ajudando a identificar lacunas e necessidades específicas. Essa matriz oferece uma visão clara das competências essenciais para orientar programas de desenvolvimento pessoal e treinamento. Ela permite uma avaliação precisa das áreas em que cada colaborador pode crescer profissionalmente, possibilitando aos gestores a criação de um Plano de Desenvolvimento Individual (PDI) personalizado para capacitar os colaboradores conforme as necessidades identificadas. Um exemplo de como montar uma matriz é mostrado na figura 15.

Figura 15: Matriz de competência

Competencies	Required		John	Emma	Liz	Matt	Sue
	Journeyman	Master					
Cocktails	1	1	Apprentice	Master	Journeyman	Apprentice	Apprentice
Customer Service	5	0	Master	Journeyman	Journeyman	Journeyman	Journeyman
Cooking	1	2	Journeyman	Apprentice	Journeyman	Master	Apprentice
Bookkeeping	1	1	Apprentice	Apprentice	Apprentice	Apprentice	Journeyman
Serving	1	3	Master	Master	Master	Journeyman	Master

	Apprentice
	Journeyman
	Master

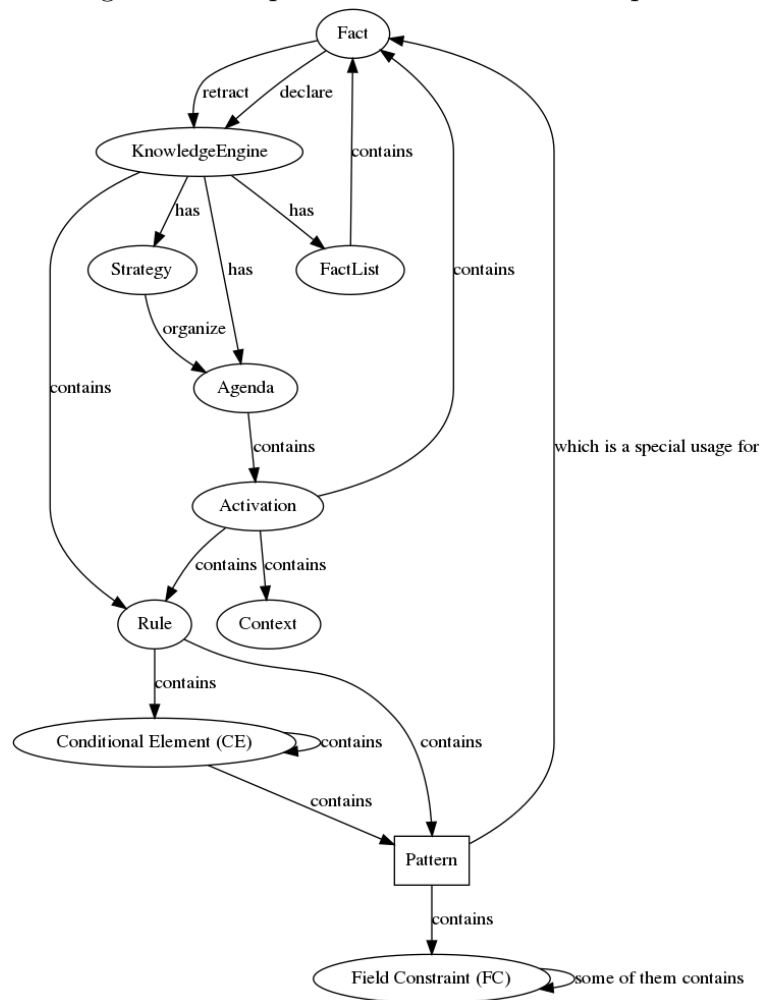
Fonte: Management 3.0

3.2.4 Framework Experta

A biblioteca Experta é uma ferramenta de código aberto desenvolvida em Python e baseada no CLIPS para a criação de sistemas especialistas. Ela fornece uma implementação fácil de usar da técnica de Forward Chaining, ou de encadeamento direto, que é um dos métodos mais comuns usados na construção de sistemas especialistas.

Segundo Perez (2018), com a biblioteca Experta, é possível criar diversas regras usando uma sintaxe simples e expressiva, permitindo definir o conhecimento e as relações lógicas necessárias para resolver problemas específicos. A biblioteca lida com o processo de inferência, capaz de fazer correspondências entre um conjunto de fatos e um conjunto de regras, executando ações com base nas regras correspondentes, para deduzir novas informações ou tomar decisões com base no conhecimento previamente definido.

Figura 16: Arquitetura do framework Experta



Fonte: Perez (2018)

3.2.4.1 Fato

Dentro do framework Experta, fatos são os componentes iniciais e necessários da biblioteca. Eles são usados pelas funções para criar fatos lógicos relacionados ao problema em questão.

Em um sistema especialista, um fato é uma informação objetiva e verificável que é considerada verdadeira dentro do domínio específico do sistema. É uma declaração que pode ser avaliada como verdadeira ou falsa com base em evidências ou regras estabelecidas.

Figura 17: Exemplo da criação de um fato

```
>>> f = Fact(a=1, b=2)
>>> f['a']
1
```

Fonte: Perez (2018)

Como visto na figura 17, os fatos são a unidade fundamental de informações. Eles desempenham um papel essencial no processo de raciocínio do sistema, permitindo que ele analise e tome decisões sobre o problema em questão.

3.2.4.2 Regra

Em um sistema especialista, uma regra é uma declaração lógica que estabelece uma relação entre condições e uma conclusão. As regras são utilizadas para inferir novos dados com base nas informações fornecidas e nos fatos conhecidos pelo sistema. No Experta, as regras têm dois componentes principais, conhecidos como Left Hand Side (LHS) e Right Hand Side (RHS) .

- O LHS representa as condições sob as quais uma regra deve ser executada ou acionada;
- Já o RHS representa o conjunto de ações a serem executadas quando a regra é ativada. Para que um fato corresponda a um padrão, é necessário que todas as restrições desse padrão sejam avaliadas como verdadeiras em relação a ele.

Na figura 18 é mostrado um exemplo de criação de *rules* usando condicionais.

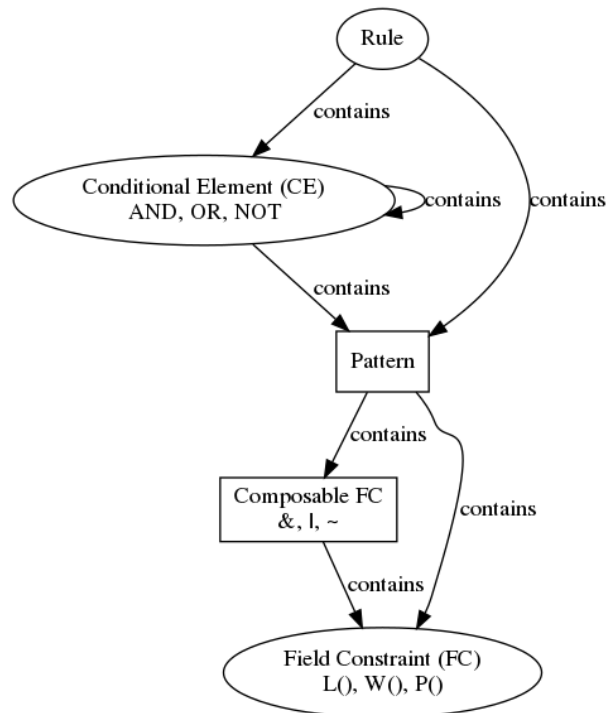
Figura 18: Exemplo de regra com LHS

```
@Rule(  
    AND(  
        OR(User('admin'),  
           User('root')),  
        NOT(Fact('drop-privileges'))  
    )  
)  
def the_user_has_power():  
    """  
    The user is a privileged one and we are not dropping privileges.  
    """  
    enable_superpowers()
```

Fonte: Perez (2018)

O diagrama da figura 19 mostra arquitetura de *rules* para criar novas regras.

Figura 19: Regras para criar *Rules*



Fonte: Perez (2018)

3.2.5 Linguagem Python

Python é uma linguagem de programação de alto nível, interpretada e de propósito geral que tem ganhado popularidade em diversos campos, tornando-se uma das linguagens

mais utilizadas por programadores ao redor do mundo. Segundo a revista Spectrum (2022), foi considerada a melhor linguagem de programação de 2022.

É uma linguagem versátil que pode ser utilizada em uma ampla gama de aplicações. É frequentemente usada no desenvolvimento de aplicativos web, por meio de frameworks populares como Django e Flask. Esses frameworks fornecem uma estrutura robusta para a construção de sites e serviços web escaláveis.

Além disso, é amplamente utilizada em ciência e análise de dados, oferecendo ferramentas poderosas para manipulação, visualização e análise.

3.2.6 Framework Flask

O Flask é um popular framework web em Python utilizado para desenvolver aplicativos web. É conhecido por sua simplicidade, flexibilidade e facilidade de aprendizado, tornando-o uma escolha popular para projetos de todos os tamanhos.

Uma das principais vantagens do Flask é sua arquitetura minimalista, que permite aos desenvolvedores escolher e adicionar apenas os componentes necessários para o projeto em questão.

Segundo Flask (2023), este framework é amplamente utilizado em várias aplicações, desde projetos pequenos e pessoais até aplicações empresariais de grande escala. Sua flexibilidade e modularidade tornam-no uma escolha popular para o desenvolvimento de APIs, sites, sistemas de gerenciamento de conteúdo e muito mais.

3.2.7 Arquitetura do sistema

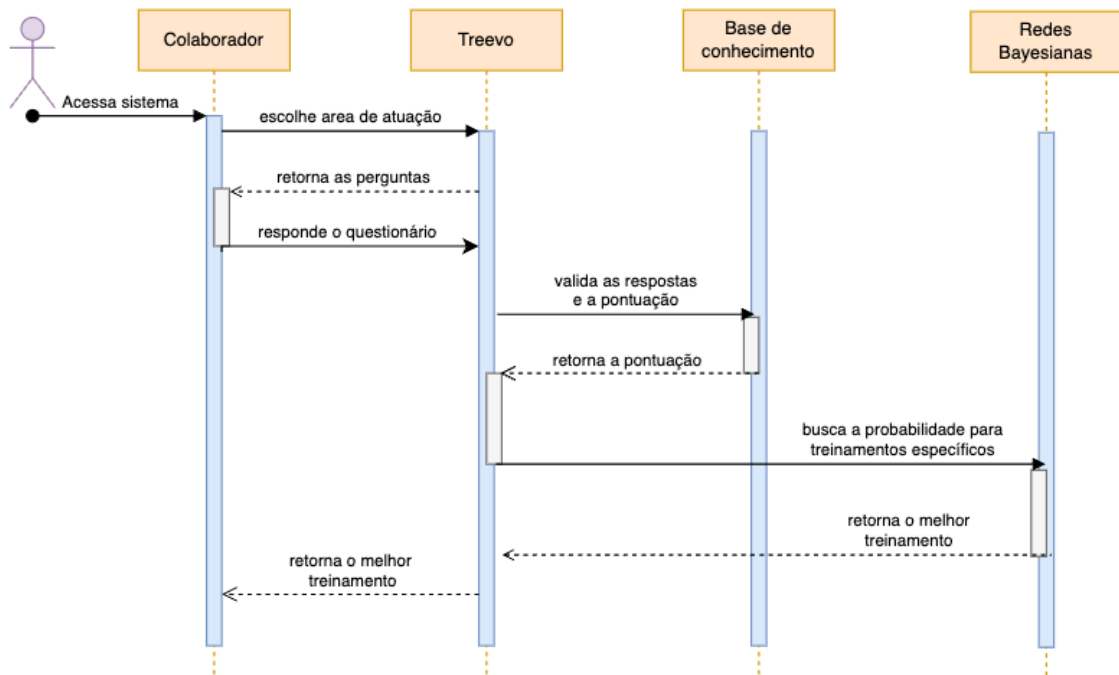
A arquitetura de sistemas é crucial para o sucesso do desenvolvimento de software, integrando decisões de design que afetam a funcionalidade e desempenho, segundo Bass, Clements e Kazman (2013).

- Diagrama sequência:

Como citam Pilone e Pitman (2005), é um tipo de diagrama utilizado em Engenharia de Software, dentro da modelagem UML (Unified Modeling Language). Ele é

essencialmente utilizado para representar a interação entre objetos em um determinado processo ou contexto, mostrando como essas interações ocorrem em termos de sequência temporal, conforme a figura 20.

Figura 20: Diagrama de sequência

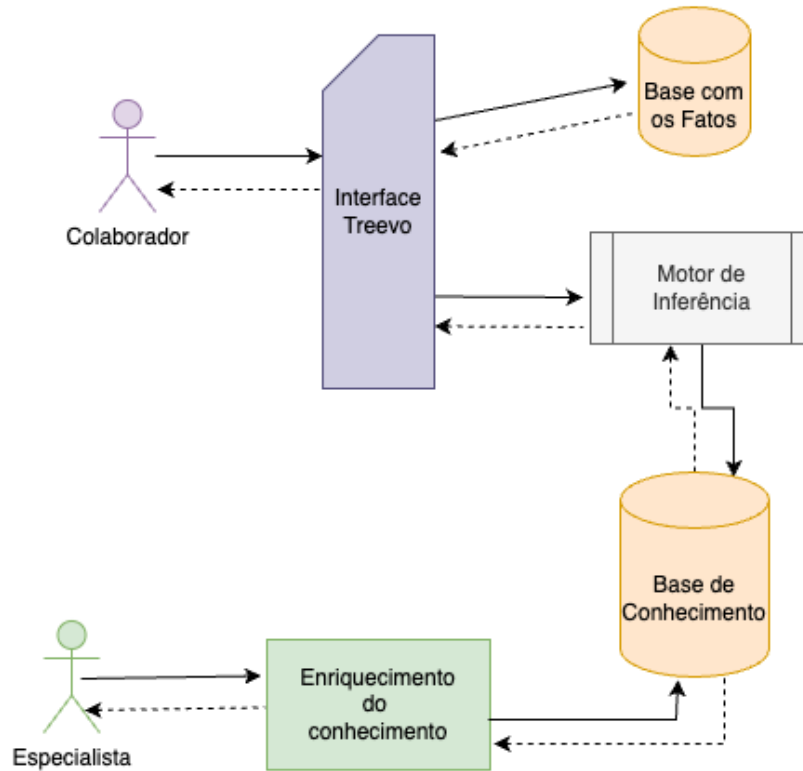


Fonte: elaborada pela autora (2023)

- Estrutura do sistema especialista:

Na arquitetura do sistema proposto, a interação do usuário ocorre por meio de uma interface frontend intuitiva, projetada para facilitar o acesso e o preenchimento de questionários. Esta interface está integrada diretamente à base de fatos, permitindo a coleta e utilização de dados reais. Paralelamente, ela se conecta ao motor de inferência, que opera com base em um conjunto de regras definidas por um especialista. Esse motor de inferência desempenha um papel crucial no processo, pois é responsável por enriquecer e atualizar continuamente a base de conhecimento, garantindo que as informações disponibilizadas sejam precisas e relevantes, conforme a figura 21.

Figura 21: Arquitetura do sistema especialista



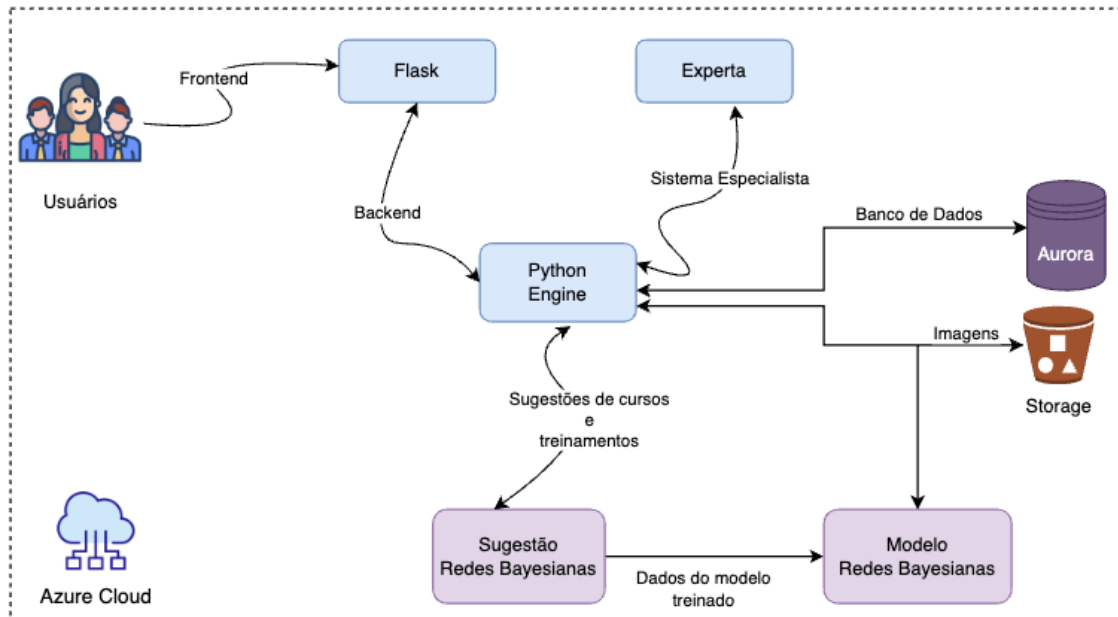
Fonte: elaborada pela autora (2023)

- Visão geral:

É visão abrangente e detalhada do funcionamento do sistema, enfatizando suas integrações, os componentes empregados, a infraestrutura subjacente e as tecnologias implementadas. Ela destaca como cada elemento contribui sinergicamente para o desempenho global do sistema, assegurando eficiência, escalabilidade e adaptabilidade às necessidades futuras.

A figura 22 apresenta a visão geral do sistema proposto.

Figura 22: Visão geral do especialista



Fonte: elaborada pela autora (2023)

3.3 Interface do sistema

Uma interface de sistemas, também conhecida como *User Interface* ou UI, é o meio pelo qual os usuários interagem com um sistema ou aplicativo. Ela define como os componentes visuais e funcionais são organizados e apresentados aos usuários, permitindo que eles realizem tarefas, acessem informações e interajam com o sistema de forma eficiente e intuitiva.

A figura 23 é tela inicial do sistema onde constam informações e também a possibilidade de escolher a área de interesse para testar seus conhecimentos. Para este trabalho, será utilizado somente a área de backend com as perguntas de Java. Elas também estão dispostas no anexo deste trabalho.

Figura 23: Tela inicial

Treevo

Aprimore seus conhecimentos

A Treevo é um sistema especializado dedicado ao aprendizado e evolução de profissionais de diversas áreas de atuação. Através de um questionário, o sistema identifica usando inteligência artificial quais são os possíveis pontos de melhorias e com isso, sugere de forma assertiva os treinamentos de aprimoramentos focados no que foi identificado.

Como funciona?

- Responda o questionário**
Responda apenas algumas perguntas para descobrir os treinamentos mais indicados para você.
- Aguarde nossa avaliação**
Nosso sistema conta com uma inteligência artificial capaz de identificar seus pontos fortes e a desenvolver.
- Decole na sua carreira**
Faça os treinamentos indicados para alcançar seus objetivos mais rápido.

Qual sua área de atuação?

Clique para gerar a sua área de atuação.

Desenvolvedor BackEnd [Testar agora](#)

© Copyright 2022 - Treevo | Daniela Costa

Fonte: elaborada pela autora (2023)

Figura 24: Tela com as perguntas

The screenshot shows the Treevo application interface. At the top, there is a header with the Treevo logo and the text 'Treevo'. Below the header, the main heading is 'Vamos começar?' (Let's start?). Underneath, it says 'Responda as perguntas para saber os treinamentos mais indicados para você.' (Answer the questions to know the most recommended trainings for you.).

A progress bar at the top of the quiz section shows 15% completion. The section is titled 'Conhecimentos sobre Java' (Java Knowledge). Below the title, there is a sub-heading: 'Conte para gente o que você conhece sobre Java e o que você ainda precisa aprender.' (Tell us what you know about Java and what you still need to learn.).

The quiz consists of eight questions, each with a text input field where the user has entered 'Não conheço' (I don't know):

- Você conhece as features do Java 12? (Do you know the features of Java 12?)
- Você conhece Funções em Java? (Do you know Functions in Java?)
- Você conhece Threads em Java? (Do you know Threads in Java?)
- Você conhece Java Realtime? (Do you know Java Realtime?)
- Você conhece e consegue criar uma aplicação com Spring do zero? (Do you know and can create an application with Spring from scratch?)
- Você conhece Data JPA, Spring Data MongoDB? (Do you know Data JPA, Spring Data MongoDB?)
- Você conhece Gradle? (Do you know Gradle?)
- Você conhece Resilience4j? (Do you know Resilience4j?)

At the bottom of the quiz, there is a blue button labeled 'Salvar e avançar' (Save and advance).

Fonte: elaborada pela autora (2023)

Conforme mostrado na Figura 24, as perguntas são exibidas de acordo com a área de interesse selecionada na tela anterior, como exibido na figura 23. Elas foram previamente cadastradas em um arquivo de texto, e o sistema as lê e as exibe na tela, desta forma:

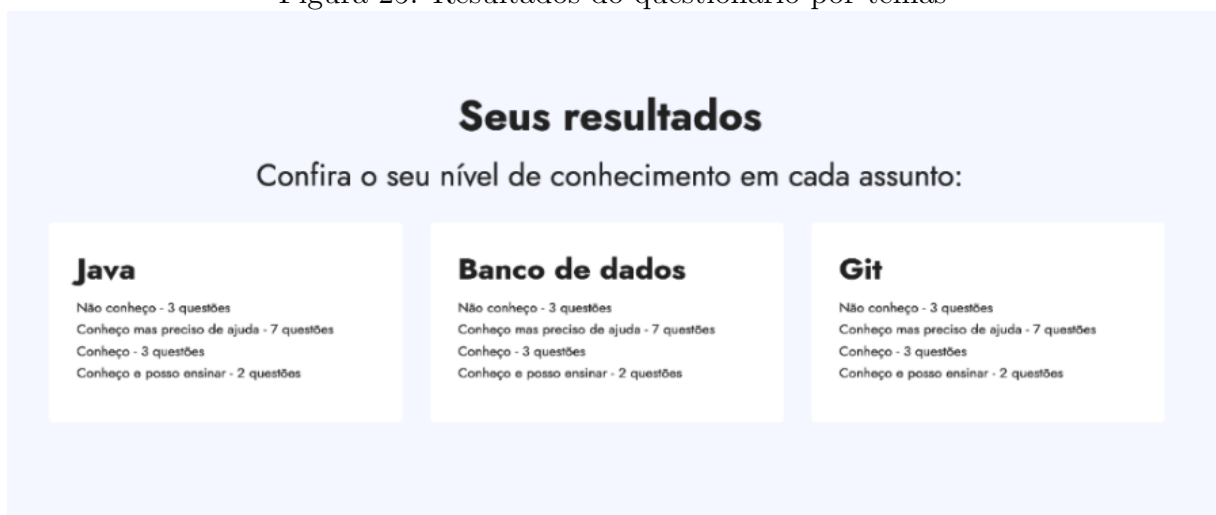
- Não conheço;

- Conheço pouco e preciso de apoio;
- Conheço e tenho autonomia;
- Domino e posso ensinar.

À medida que as perguntas vão sendo respondidas, um percentual é atualizado até o final do processo.

Na última etapa, exibimos uma tela com o resultado final, após avaliar as questões preenchidas anteriormente, conforme a imagem 24. Os resultados são exibidos, conforme exemplificado na figura 25, e podemos ter apenas uma ou várias opções.

Figura 25: Resultados do questionário por temas



Fonte: elaborada pela autora (2023)

Após avaliar as respostas do questionário anteriormente preenchido, apresentamos os cursos e treinamentos mais adequados ao nível de conhecimento do colaborador, exibidos na figura 26.

Figura 26: Treinamentos recomendados

Cursos sugeridos
Esses são os cursos que vão te ajudar a decolar na sua carreira

		
Mongo DB Domine o desenvolvimento em MongoDB para Web e Mobile. O guia definitivo do banco de dados não-relacional. Acessar curso	Java 12 Aprenda java e se torne um programador e obtenha skills para certificação. Acessar curso	Git na Prática Venha mergulhar em programação, data-science, front-end, back-end, mobile, devops. Acessar curso

Fonte: elaborada pela autora (2023)

3.4 Regras de negócio

As regras nos sistemas especialistas desempenham um papel fundamental, servindo como o núcleo da lógica e do processo decisório do sistema. Luger (2016) explica que estas regras são comumente estruturadas em formato *if-then*, onde *if* representa uma condição específica e *then* a consequente ação a ser executada. Esse arranjo busca imitar o processo de raciocínio dos especialistas humanos em áreas específicas, permitindo que o sistema faça inferências ou tome decisões com base em dados e informações fornecidas.

Jones (2008) enfatiza ainda a importância da modelagem de conhecimento em sistemas especialistas para emular a expertise humana em um domínio específico. Essas regras são elaboradas em colaboração com especialistas do domínio em questão, garantindo que o sistema reflita com precisão o conhecimento e a experiência profissional relevantes.

No contexto deste sistema específico, foi desenvolvida uma metodologia de pontuação para cada resposta. Pontos são atribuídos com base no nível de conhecimento demonstrado em cada tópico. A soma dos pontos de todas as respostas resulta em uma pontuação geral, a qual é utilizada para classificar o conhecimento do usuário em diferentes níveis

de senioridade.

No sistema desenvolvido, a avaliação do conhecimento do usuário é quantificada numa escala de pontuação que varia de 0 a 100 pontos. Esta escala está estruturada em quatro categorias distintas, cada uma representando um nível específico de conhecimento e expertise:

1. Iniciante (0 a 25 pontos): esta faixa indica um nível básico de familiaridade ou a ausência de conhecimento na área em questão. Usuários classificados aqui estão no estágio inicial de aprendizagem.
2. Intermediário (26 a 50 pontos): usuários que pontuam nesta categoria têm um entendimento moderado do tópico. Eles possuem conhecimento além do básico, mas ainda não alcançaram um alto nível de proficiência.
3. Avançado (51 a 75 pontos): esta faixa é para usuários com um bom grau de conhecimento e habilidade. Eles demonstram um entendimento aprofundado, mas ainda têm espaço para se tornarem especialistas.
4. Expert (76 a 100 pontos): usuários nesta categoria são altamente proficientes, demonstrando um nível de conhecimento e habilidade que os classifica como especialistas ou peritos no assunto.

O sistema atribui pontos às respostas dos usuários com base no seu grau autoavaliado de conhecimento, conforme as seguintes opções:

- Não conheço: atribui 0 pontos, indicando ausência de conhecimento sobre o tópico.
- Conheço pouco: concede 10 pontos, refletindo um conhecimento básico ou limitado.
- Conheço”: resulta em 30 pontos, mostrando um entendimento moderado.
- Domino: oferece 50 pontos, representando um alto nível de conhecimento e domínio do assunto.

Essa estrutura de pontuação permite uma avaliação detalhada e personalizada do nível de conhecimento do usuário, facilitando a identificação do estágio apropriado de aprendizado e desenvolvimento.

A complexidade das regras implementadas no sistema é amplificada devido à importância de levar em conta o conhecimento prévio dos usuários em relação aos tópicos abordados pelas perguntas. Essa necessidade surge da premissa de que o entendimento de conceitos avançados está frequentemente fundamentado em uma base sólida de conhecimentos básicos. Para ilustrar claramente essa relação, as perguntas, juntamente com os conhecimentos prévios associados a elas, são detalhadas na tabela 2. Esta tabela serve como um recurso visual que ajuda a entender como o conhecimento em uma área pode influenciar ou indicar o nível de compreensão em outra, estabelecendo assim uma avaliação mais precisa e contextualizada do perfil de conhecimento do usuário.

Tabela 2: Perguntas e conhecimento prévio

Perguntas	Pré-requisito
1. O quanto você conhece de Orientação Objeto?	N/A
2. Você conhece Java Persistence API?	Pergunta 3
3. Você conhece Lambda?	Pergunta 2
4. Você conhece Stream API?	Pergunta 1
5. O quanto você conhece Tratamento Erro?	Pergunta 1
6. Você conhece Collections?	Pergunta 1
7. Você conhece Interfaces Funcionais?	Pergunta 1
8. Você conhece framework SprintBoot?	N/A
9. Você conhece Spring GraphQL?	N/A
10. Você conhece Java Reativo?	N/A

Fonte: elaborada pela autora (2023)

Após o estabelecimento e definição clara das regras, podemos dar início à sua implementação, como demonstrado nas figuras 27 e 28. Estas figuras apresentam uma representação visual do processo de criação das regras utilizando o framework Experta na linguagem Python, ilustrando a aplicação prática dessas regras no âmbito do sistema.

Figura 27: Regra para somar ponto

```
# regras traçadas com pre-requisitos / soma +30 pontos
@Rule(ConhecimentoPerguntasJava(p2="conheco") &
      ~ConhecimentoPerguntasJava(p3="nao_conheco") &
      ~ConhecimentoPerguntasJava(p3="conheco_pouco"))
def regra_p2_condicao_p3(self):
    self.pontuacao_total += 30
    self.declare(ResultadoConhecimentoJava(pontuacao=self.pontuacao_total))
```

Fonte: elaborada pela autora (2023)

Na Figura 27, observa-se a aplicação de uma regra específica: ela verifica se a resposta da pergunta P2 é "conheço" e, simultaneamente, se a resposta da pergunta P3 não é "não_conheço" nem "conheço_pouco". Se ambas as condições forem atendidas, indicando a validade da regra, então 30 pontos são adicionados ao total da pontuação do usuário.

Na Figura 28, apresenta-se uma regra de subtração. Esta regra estipula que, se a resposta para a pergunta P4 for "não_conheço" e, ao mesmo tempo, a resposta para a pergunta P5 for "domino", haverá uma dedução de 10 pontos. Essa regra implica que o usuário não deve indicar um nível de conhecimento em P5 superior ao de P4, considerando que o conhecimento abordado em P4 é pré-requisito para entender adequadamente o conteúdo de P5.

Figura 28: Regra para subtrair ponto

```
# regras traçadas com pre-requisitos / subtrai -10 pontos
@Rule(ConhecimentoPerguntasJava(p4="nao_conheco")
      & ConhecimentoPerguntasJava(p5="domino"))
def regra_p4_nao_conheco(self):
    self.pontuacao_total -= 10
    self.declare(ResultadoConhecimentoJava(pontuacao=self.pontuacao_total))
```

Fonte: elaborada pela autora (2023)

Com base no contexto apresentado sobre as regras implementadas neste sistema, podemos concluir que elas são importantes para garantir uma avaliação precisa e realista do conhecimento do usuário. As regras, cuidadosamente desenhadas para considerar o conhecimento prévio e a relação entre diferentes áreas de conhecimento, permitem uma análise mais refinada das respostas dos usuários.

As regras de pontuação e subtração, apresentadas anteriormente demonstram a complexidade e a inteligência do sistema. Elas asseguram que a pontuação final reflète não apenas as respostas isoladas, mas também a coerência e profundidade do conhecimento do usuário. Em particular, a abordagem de subtrair pontos quando o conhecimento em questões de nível avançado supera o conhecimento em questões de nível básico, que são pré-requisitos, é uma inovação significativa. Isso evita sobreavaliações e garante que a pontuação final seja um reflexo verdadeiro da competência e compreensão do usuário em cada tópico.

3.5 Proposta de redes Bayesianas com Experta para sugestão de treinamentos

Neste estudo, propomos a integração de redes bayesianas ao framework Experta com o objetivo de aprimorar a análise de probabilidades em um sistema especialista focado em sugestões de treinamentos. As redes bayesianas são aplicadas para modelar as relações causais entre as respostas de questionários, o nível de conhecimento do usuário e a probabilidade de sugerir treinamentos específicos. Essas probabilidades recalculadas são integradas às regras de inferência do Experta, culminando em sugestões de treinamento mais precisas e personalizadas Jensen e Nielsen (2007).

O sistema é projetado para efetuar inferências e previsões com base em variáveis como classificação, habilidade (skill), senioridade, identidade de gênero e cor. Detalhes adicionais sobre esta implementação serão explorados na seção subsequente.

A combinação do Experta com as redes bayesianas confere ao sistema especialista a habilidade de calcular probabilidades dinâmicas e realizar inferências probabilísticas sofisticadas. Isso resulta em uma ponderação mais precisa dos valores de probabilidade, permitindo recomendar o treinamento mais adequado com base no perfil de conhecimento individual de cada colaborador. Esta abordagem aprimora a eficácia e relevância das recomendações do sistema, contribuindo significativamente para o desenvolvimento contínuo dos colaboradores Koller e Friedman (2009).

3.5.1 Preparação dos dados

A preparação dos dados constitui um passo fundamental para assegurar a qualidade e a confiabilidade das análises subsequentes. O processo empregado neste estudo envolveu leitura, categorização e balanceamento dos dados, executado através de um script em Python. As etapas foram as seguintes:

- **Leitura dos dados:** nesta etapa, foram criados arquivos CSV, correspondentes a diferentes conjuntos de dados, e armazenados em um dicionário para fácil acesso e manipulação.
- **Categorização dos dados:** foi aplicado um mapeamento incremental para converter

valores categóricos em valores numéricos em cada coluna dos DataFrames, facilitando o processamento dos dados.

- **Balanceamento dos dados:** para evitar viés devido a desequilíbrios de classe, foi realizado o balanceamento dos dados, igualando o número de amostras de cada classe.

Essas etapas visam garantir que os dados estejam prontos para análises e modelagem, sendo representativos e livres de distorções significativas.

3.5.2 Treinamento do modelo e teste dos dados

O treinamento de modelos em redes Bayesianas é um aspecto crucial para garantir que suas inferências sejam precisas e confiáveis. Este processo envolve ajustar os parâmetros do modelo para que ele possa representar corretamente as distribuições de probabilidade condicional das variáveis, com base em dados observados. Também envolve dois aspectos principais: aprender a estrutura da rede e estimar os parâmetros da rede.

- **Aprendizagem da estrutura:** a estrutura de uma rede bayesiana é definida pelas relações de dependência entre as variáveis. O aprendizado da estrutura pode ser realizado de forma supervisionada ou não supervisionada, utilizando algoritmos baseados em pontuação ou restrições. Heckerman (1995) discute métodos para a aprendizagem de estruturas em redes bayesianas, explorando tanto abordagens baseadas em dados quanto em conhecimento prévio.
- **Estimativa dos parâmetros:** após a estrutura da rede ser definida, o próximo passo é estimar os parâmetros, que geralmente são as probabilidades condicionais associadas a cada nó. Murphy (2012) fornece uma abordagem abrangente para a estimativa de parâmetros em redes bayesianas, cobrindo desde técnicas básicas até métodos mais avançados.

O processo para treinar e testar os dados é uma etapa importante para avaliar a eficácia do modelo proposto. Utilizamos o classificador *Naive Bayes*, conhecido por sua simplicidade e eficiência em diversas aplicações de aprendizado de máquina Hand e Yu (2009).

Nos testes, foi avaliado a performance de um modelo de classificação Naive Bayes em conjuntos de dados de diferentes tamanhos, variando de 5k a 100k. Os resultados revelaram uma acurácia média consistente de 100% em todos os DataFrames, indicando uma alta eficácia do modelo na classificação dos dados. Contudo, é importante notar que uma acurácia de 100% pode às vezes ser um indicativo de sobreajuste, especialmente em cenários com alta complexidade de dados Zhang (2004). O resultado do teste é mostrado na figura 29.

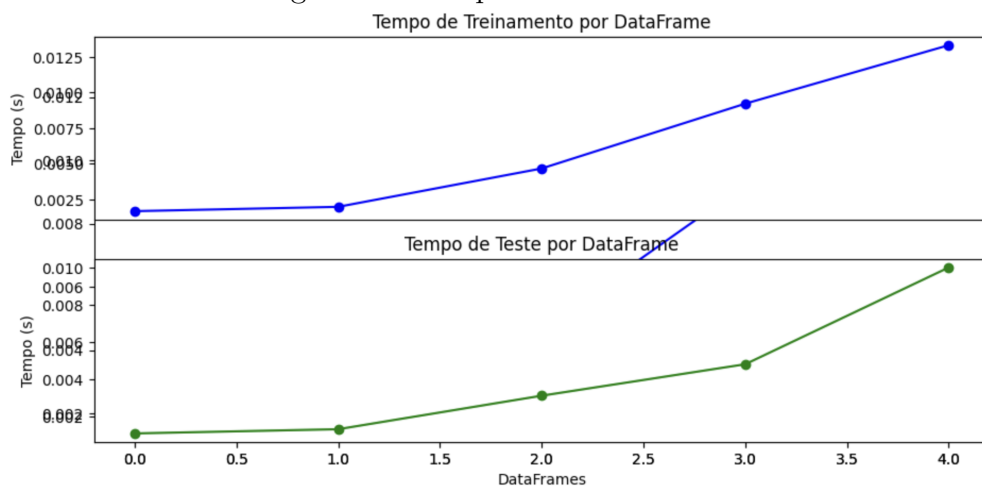
Figura 29: Médias de acurácia, tempos de treinamento e teste

DataFrame	Acurácia Média	Tempo de Treinamento Médio (s)	\
0	5k	1.0	0.001684
1	10k	1.0	0.001987
2	20k	1.0	0.004677
3	50k	1.0	0.009221
4	100k	1.0	0.013322

DataFrame	Tempo de Teste Médio (s)
0	0.001102
1	0.001328
2	0.003126
3	0.004814
4	0.010008

Fonte: elaborada pela autora (2023)

Figura 30: Tempo de treinamento



Fonte: elaborada pela autora (2023)

Na figura 30 é apresentado dois gráficos separados de linhas para representar o tempo médio de treinamento e teste em relação aos diferentes DataFrames, permitindo uma

visualização clara das tendências de tempo para cada conjunto de dados.

Quanto aos tempos de treinamento e teste, foi observado na figura 29 um aumento proporcional ao tamanho dos conjuntos de dados. Por exemplo, o tempo médio de treinamento para o conjunto 5k foi de aproximadamente 0.0017 segundos, aumentando para 0.0133 segundos no conjunto 100k. Similarmente, o tempo médio de teste variou de 0.0011 segundos para 5k até 0.0100 segundos para 100k. Estes resultados refletem a eficiência e a rapidez do classificador Naive Bayes, alinhando-se com a literatura que destaca sua simplicidade computacional e boa performance em várias aplicações Rish (2001).

Estes experimentos são relevantes para compreender o desempenho do modelo em diferentes volumes de dados, ressaltando a importância de uma avaliação equilibrada entre precisão e eficiência computacional em modelos de aprendizado de máquina.

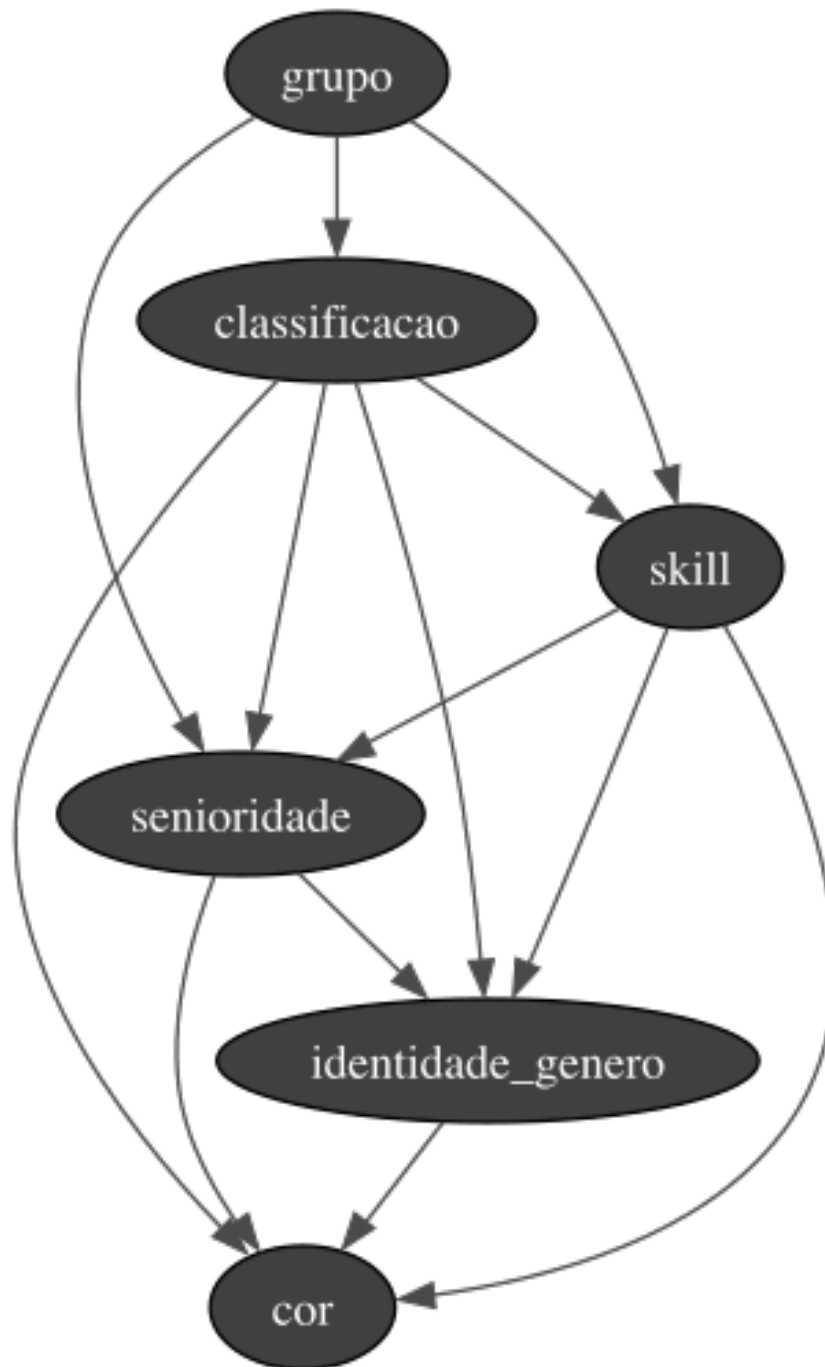
3.6 Estrutura da rede Bayesiana

As redes bayesianas, são modelos gráficos probabilísticos que representam um conjunto de variáveis e suas dependências condicionais através de um grafo direcionado acíclico (DAG), como visto na figura 8. A estrutura de uma rede bayesiana é composta por nós, que representam as variáveis aleatórias, e arestas direcionadas, que simbolizam dependências probabilísticas entre estas variáveis Koller e Friedman (2009). Estas dependências são quantificadas através de tabelas de probabilidade condicional associadas a cada nó, que expressam a relação entre uma variável e suas variáveis predecessoras no grafo.

Para Koller e Friedman (2009), a estrutura da rede permite inferências eficientes, facilitando a compreensão das relações causais entre as variáveis e a predição de resultados sob incerteza. A forma como as arestas são conectadas reflete a independência condicional entre as variáveis, um conceito central nas redes bayesianas, permitindo que o modelo capture a complexidade das relações entre os dados de maneira intuitiva e matematicamente rigorosa.

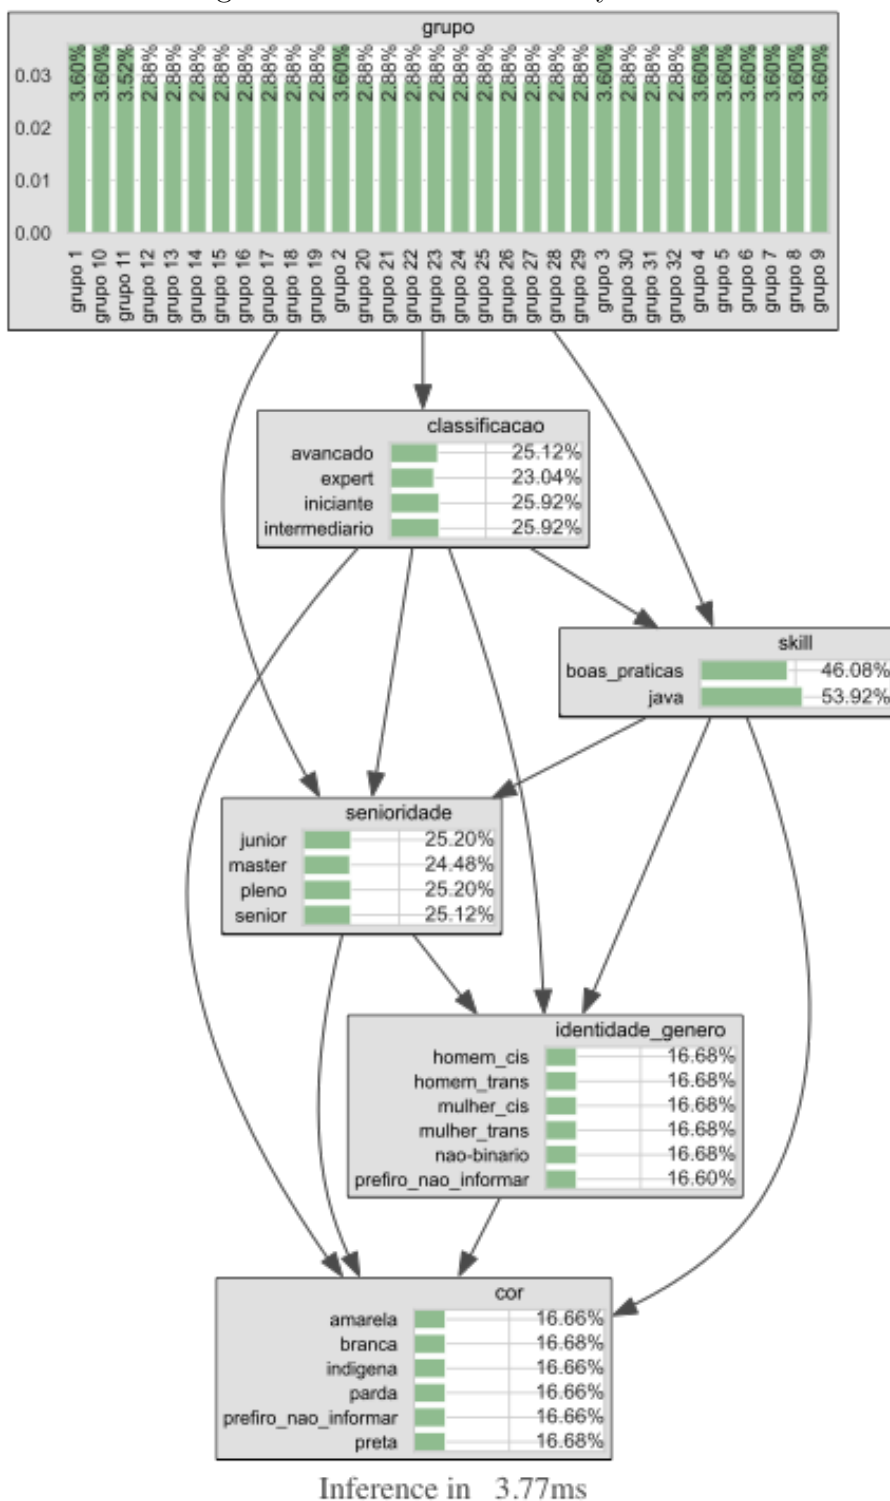
Na figura 31 é possível observar os nós gerados para essa proposta de sistema.

Figura 31: Nós do sistema especialista



Fonte: elaborada pela autora (2023)

Figura 32: Estrutura redes bayesianas



Fonte: elaborada pela autora (2023)

Na figura 32 é apresentada uma estrutura completa de redes Bayesianas mostrando as probabilidades para cada nó.

Neste capítulo, foi explorado a integração de redes bayesianas com um sistema espe-

cialista para aprimorar a recomendação de treinamentos. Esta abordagem representa um avanço na modelagem de sistemas especialistas, permitindo uma análise mais profunda e fundamentada das necessidades de treinamento individualizadas.

A estrutura de redes bayesianas, com seus nós representando variáveis importantes como habilidade (skill), senioridade e identidade de gênero, e as arestas indicando relações de dependência, fornece uma base sólida para compreender as complexas interações entre diferentes fatores que influenciam a necessidade de treinamento. A capacidade de quantificar e modelar essas dependências permite que o sistema especialista faça recomendações precisas e personalizadas, adaptadas às características únicas de cada indivíduo.

Além disso, o uso do classificador Naive Bayes, conhecido por sua eficiência e eficácia, reforça a robustez do sistema especialista. A combinação desta técnica com as redes bayesianas oferece um equilíbrio ideal entre precisão e eficiência computacional, o que é crucial em aplicações práticas onde o tempo de resposta e a precisão são essenciais.

Em resumo, este capítulo demonstra o potencial das redes bayesianas em enriquecer os sistemas especialistas, especialmente no contexto de sugestão de treinamentos. Esta abordagem não só melhora a precisão das recomendações, mas também oferece *insights* valiosos sobre as dinâmicas subjacentes que influenciam as necessidades de desenvolvimento profissional. As implicações deste estudo são vastas, prometendo avanços significativos na personalização e eficácia dos programas de treinamento.

3.7 Entrevista

A etapa de entrevista é indispensável nesta pesquisa, permitindo uma avaliação detalhada do sistema *TREEVO* sob a ótica dos usuários. Essencial para entender a percepção de impacto e a aceitação do sistema, a entrevista fornece *insights* valiosos sobre a utilidade, a usabilidade e o potencial transformador do *TREEVO* na prática profissional dos usuários.

Foi adotado o modelo de aceitação de tecnologia TAM 2 (Technology Acceptance Model 2) para orientar a coleta e análise de dados nas entrevistas. Este modelo robusto ajuda a explorar profundamente as percepções dos usuários sobre diferentes aspectos do sistema, incluindo sua utilidade e facilidade de uso, além de fatores externos que

influenciam a aceitação tecnológica.

A entrevista contou com a participação de 25 desenvolvedores de software, abrangendo um espectro de senioridade de júnior a expert. Este grupo diversificado permitiu captar uma variedade de visões e experiências, enriquecendo a compreensão do sistema *TREEVO*.

O feedback foi sistematicamente coletado por meio de um formulário, facilitando uma análise estruturada e detalhada das respostas dos usuários. O formulário foi desenhado para explorar os seguintes itens principais, conforme definidos pelo modelo TAM 2:

1. **Percepção de Utilidade:** Avalia se os usuários acreditam que o uso do *TREEVO* incrementará seu desempenho no trabalho.
2. **Facilidade de Uso Percebida:** Investiga se os usuários consideram o *TREEVO* fácil de entender e utilizar.
3. **Influências Sociais:** Mede o efeito das opiniões de colegas e superiores sobre a decisão do usuário de usar o *TREEVO*. Também avalia se o uso do *TREEVO* é visto como prestigioso ou benéfico para o status profissional do usuário.
4. **Condições Facilitadoras:** Examina se os usuários percebem que a organização oferece o apoio necessário para usar o *TREEVO*. Também avalia se os usuários sentem que têm os recursos técnicos necessários para utilizar o *TREEVO* efetivamente.

Além de validar a aplicabilidade e a eficácia do *TREEVO*, as entrevistas desempenham um papel crítico em identificar áreas para melhorias, assegurando que o sistema atenda efetivamente às exigências e às necessidades dos profissionais da área de tecnologia. A análise detalhada das respostas ao formulário TAM 2 oferece uma base sólida para futuras otimizações do sistema, com o objetivo de maximizar sua aceitação e impacto positivo entre os usuários.

As perguntas direcionadas aos colaboradores foram extraídas do formulário do Google Form e estão detalhadas nas páginas subsequentes.

Treevo - Questionário de Avaliação de Tecnologia

Olá! 😊 Te damos as boas-vindas ao nosso questionário de avaliação de tecnologia! Este formulário é parte crucial do processo de melhoria contínua do nosso sistema especialista **Treevo**, que visa avaliar o nível de conhecimento dos usuários em stacks de tecnologia como Java e Boas Práticas. Seu feedback é extremamente importante para nós.

O objetivo deste questionário é entender sua experiência com o sistema, incluindo a facilidade de uso, utilidade percebida, influências sociais e condições facilitadoras. As informações coletadas aqui serão usadas para aprimorar a plataforma, garantindo que ela atenda melhor às suas necessidades e expectativas.

O questionário é baseado no modelo TAM 2 (Technology Acceptance Model 2) e consiste em uma série de afirmações. Por favor, avalie cada afirmação usando a escala de Likert, onde **1** significa "**Discordo Totalmente**" e **5** significa "**Concordo Totalmente**". Há também espaço para comentários adicionais no final, onde você pode expressar suas opiniões e sugestões livremente.

Sua participação é voluntária e todas as respostas são confidenciais. Agradecemos antecipadamente pelo tempo dispensado e pela sua valiosa contribuição.

Muito obrigada!

* Indica uma pergunta obrigatória

Percepção de Utilidade:

1. O sistema ajuda a identificar áreas de conhecimento nas stacks de backend como Java e Boas Práticas que preciso melhorar. *

Marcar apenas uma oval.

1 2 3 4 5

Disc Concordo Totalmente

2. 2. O sistema é eficaz em identificar meu atual nível de conhecimento em Java e Boas Práticas. *

Marcar apenas uma oval.

1 2 3 4 5

Disc Concordo Totalmente

3. 3. As recomendações de cursos feitas pelo sistema são relevantes para o meu desenvolvimento profissional. *

Marcar apenas uma oval.

1 2 3 4 5

Disc Concordo Totalmente

Percepção de Facilidade de Uso Sem título:

4. 1. A interface do sistema é intuitiva e fácil de navegar. *

Marcar apenas uma oval.

1 2 3 4 5

Disc Concordo Totalmente

5. 2. Os resultados e sugestões de cursos fornecidos pelo sistema são claros e compreensíveis. *

Marcar apenas uma oval.

1 2 3 4 5

Disc Concordo Totalmente

Influências Sociais:

6. 1. Pessoas cujas opiniões valorizo recomendam que eu use o sistema. *

Marcar apenas uma oval.

1 2 3 4 5

Disc Concordo Totalmente

Condições Facilitadoras:

7. 1. Sinto que tenho suporte técnico adequado para usar o sistema quando necessário. *

Marcar apenas uma oval.

1 2 3 4 5

Disc Concordo Totalmente

Intenção de Uso:

8. 1. Planejo usar este sistema regularmente para avaliar meu nível e orientar meu aprendizado. *

Marcar apenas uma oval.

1 2 3 4 5

Disc Concordo Totalmente

9. 2. Recomendaria este sistema a outros gestores e desenvolvedores ou estudantes interessados em medir seu conhecimento. *

Marcar apenas uma oval.

1 2 3 4 5

Disc Concordo Totalmente

Feedback Adicional

10. Quais recursos adicionais você gostaria de ver no sistema?

11. Comentários gerais sobre sua experiência com o sistema.

Este conteúdo não foi criado nem aprovado pelo Google.

Google Formulários

4 RESULTADOS

Esta seção dedica-se à análise dos resultados adquiridos através do questionário de avaliação aplicado aos usuários do sistema especialista *TREEVO*, que contou com a participação de 25 indivíduos de uma empresa do setor tecnológico. Através de uma abordagem metódica, baseada no Modelo de Aceitação de Tecnologia versão 2 (TAM 2) Davis (1989), amplamente reconhecido por sua eficácia na avaliação da aceitação e do uso de sistemas tecnológicos, os dados coletados oferecem uma visão aprofundada sobre a percepção dos usuários em relação ao sistema. A aplicação do questionário TAM 2, juntamente com o uso da escala *Likert* para quantificar atitudes e opiniões, facilita uma compreensão detalhada e quantitativa das respostas dos participantes Boone e Boone (2012).

Revisitando o sistema *TREEVO*, trata-se de um protótipo de sistema especialista desenvolvido para identificar o nível de conhecimento de colaboradores na área de *backend*, especificamente em tecnologias Java e Boas Práticas. O sistema utiliza modelos de redes bayesianas para, a partir do nível de conhecimento detectado, calcular a probabilidade e sugerir o curso mais adequado para o colaborador.

Após o usuário responder ao questionário, o *TREEVO* determina seu nível de conhecimento, variando de iniciante a especialista, e encaminha essa informação para a rede bayesiana. Essa, por sua vez, utiliza os dados como parâmetros para oferecer recomendações personalizadas de cursos.

Importante ressaltar que, embora o nível de conhecimento identificado não seja diretamente comunicado ao usuário, as sugestões de cursos foram validadas e se mostraram pertinentes para a maioria dos participantes, especialmente aqueles nos cargos de júnior e pleno. Contudo, observou-se que para usuários com maior experiência, ocupando posições de sênior e especialista, as questões propostas pelo questionário pareceram ser de complexidade reduzida. Este feedback sugere a necessidade de expandir o escopo e o nível de dificuldade das perguntas para abranger adequadamente o espectro de conhecimento desses profissionais mais avançados.

A análise dos dados coletados revela *insights* valiosos sobre a eficácia do *TREEVO* em mapear competências e sugerir treinamentos alinhados às necessidades de desenvolvimento

dos colaboradores. A utilização do TAM 2 como instrumento de avaliação demonstrou ser efetiva para capturar as percepções dos usuários quanto à utilidade e facilidade de uso do sistema Venkatesh e Bala (2008). Entretanto, o *feedback* recebido aponta para oportunidades de melhoria, especialmente na adequação do sistema às necessidades de usuários com níveis de experiência mais elevados. Ajustes nos critérios de avaliação e na diversidade das questões podem contribuir para otimizar a precisão das recomendações de treinamento, tornando o *TREEVO* uma ferramenta ainda mais robusta e inclusiva para o desenvolvimento profissional dentro da organização.

4.1 Apresentação dos resultados


A metodologia de avaliação baseia-se em um questionário projetado em torno de várias afirmações que refletem aspectos-chave do modelo TAM 2, incluindo usabilidade, utilidade percebida, facilidade de uso percebida e intenção de uso. As respostas foram coletadas usando uma escala Likert de cinco pontos, variando de *Discordo totalmente* a *Concordo totalmente*, conforme demonstrado abaixo:

4.1.1 Percepção de utilidade

As respostas indicam uma forte concordância com a utilidade do sistema. A maioria dos respondentes atribuiu altas pontuações (4 ou 5 na escala Likert) às perguntas relacionadas à utilidade do sistema, sugerindo que eles percebem o sistema como benéfico e relevante para suas necessidades. Essa afirmação pode ser vista nas figuras 33, 34 e 35


1. O sistema ajuda a identificar áreas de conhecimento nas stacks de backend como Java e Boas Práticas que preciso melhorar:
2. O sistema é eficaz em identificar meu atual nível de conhecimento em Java e Boas Práticas:
3. As recomendações de cursos feitas pelo sistema são relevantes para o meu desenvolvimento profissional:

Figura 33: Percepção de utilidade: Pergunta 1



Fonte: elaborada pela autora (2023)

Figura 34: Percepção de utilidade: Pergunta 2




Fonte: elaborada pela autora (2023)

4.1.2 Percepção de facilidade de uso

Os participantes responderam favoravelmente às questões relacionadas à facilidade de uso do sistema, com uma tendência a pontuações mais altas. Isso indica que os usuários acham o sistema intuitivo e de fácil navegação, conforme as figuras 36 e 37 mostram. A facilidade percebida é um aspecto crítico para a adoção de novas tecnologias, e as altas

Figura 35: Percepção de utilidade: Pergunta 3




Fonte: elaborada pela autora (2023)

pontuações aqui sugerem que isso pode ser um fator significativo na aceitação geral do sistema.

1. A interface do sistema é intuitiva e fácil de navegar:


Figura 36: Percepção de facilidade: Pergunta 1



Fonte: elaborada pela autora (2023)

2. Os resultados e sugestões de cursos fornecidos pelo sistema são claros e compreensíveis:

Figura 37: Percepção de facilidade: Pergunta 2



Fonte: elaborada pela autora (2023)

4.1.3 Influências sociais


A maioria dos usuários expressou uma tendência a recomendar o sistema a colegas e pares, o que sugere que as influências sociais são positivas em relação à adoção do sistema. Os dados podem ser vistos na figura 38. O feedback indica que a comunidade de usuários valoriza o sistema, o que pode contribuir para sua adoção mais ampla e aceitação dentro da organização.

1. Pessoas cujas opiniões valorizo recomendam que eu use o sistema:

4.1.4 Condições facilitadoras

Os participantes sentiram que possuíam o suporte necessário e os recursos adequados para usar o sistema eficazmente, o que é essencial para a implementação bem-sucedida de qualquer nova tecnologia. A figura 39 mostra a adesão positiva. A percepção de uma infraestrutura e suporte técnico adequados sugere que as condições facilitadoras estão presentes para encorajar o uso continuado do sistema.


Figura 38: Influências sociais: Pergunta 1



Fonte: elaborada pela autora (2023)

1. Sinto que tenho suporte técnico adequado para usar o sistema quando necessário:

Figura 39: Condições facilitadores: Pergunta 1



Fonte: elaborada pela autora (2023)


4.1.5 Intenção de uso

Os usuários demonstraram uma forte intenção de continuar utilizando o sistema, indicando uma aceitação favorável e uma percepção de valor a longo prazo, como demonstrado

nas figuras 40 e 41. A intenção de uso contínuo reflete não apenas a satisfação com o sistema atual, mas também o potencial para sua integração contínua nas práticas de gestão de conhecimento e desenvolvimento de competências dentro da organização.

1. Planejo usar este sistema regularmente para avaliar meu nível e orientar meu aprendizado:


Figura 40: Intenção de uso: Pergunta 1



Fonte: elaborada pela autora (2023)

2. Recomendaria este sistema a outros gestores e desenvolvedores ou estudantes interessados em medir seu conhecimento:

Figura 41: Intenção de uso: Pergunta 2



Fonte: elaborada pela autora (2023)

4.2 Análise final dos resultados

Após uma análise criteriosa dos dados obtidos através do questionário baseado na escala Likert, é possível concluir que o sistema especialista foi percebido positivamente pelos seus usuários. Esta conclusão é fundamentada em diversas métricas chave obtidas, refletindo as percepções dos usuários em relação à utilidade, facilidade de uso, influência social, condições facilitadoras e intenção de uso do sistema.

Portanto, os dados coletados e analisados neste estudo fornecem uma validação robusta da eficácia e relevância do sistema especialista. Os resultados indicam uma aceitação favorável do sistema, sugerindo seu potencial para influenciar positivamente as práticas de gestão de conhecimento e desenvolvimento de competências dentro da organização. Isso responde diretamente aos objetivos iniciais do estudo, destacando a capacidade do sistema em aprimorar a gestão do conhecimento e auxiliar na tomada de decisões sobre treinamentos e desenvolvimento da força de trabalho.

Estes resultados abrem caminho para futuras pesquisas e desenvolvimentos, sugerindo que a adoção de sistemas especialistas pode ser uma estratégia valiosa para organizações

que buscam promover a inovação e a excelência em suas operações e práticas de gestão de talentos.

5 CONCLUSÃO E TRABALHOS FUTUROS

Este capítulo marca a culminação do estudo sobre o desenvolvimento e a implementação do sistema especialista *TREEVO*, destinado a avaliar e aprimorar o conhecimento técnico dos colaboradores no setor tecnológico. Através da aplicação do Modelo de Aceitação de Tecnologia versão 2 (TAM 2), foram coletadas e analisadas percepções de 25 profissionais de uma empresa de tecnologia, proporcionando *insights* valiosos sobre a eficácia, a usabilidade e o impacto do sistema em seu desenvolvimento profissional. A conclusão deste estudo reflete sobre as contribuições significativas do *TREEVO* para o campo da avaliação de competências técnicas, destacando os resultados obtidos e delineando as lições aprendidas ao longo deste processo.

Prosseguindo, a discussão se volta para os horizontes futuros, explorando as potenciais direções para o aprimoramento e expansão do *TREEVO*. Com base no feedback dos usuários e nas observações da aplicação prática do sistema, identificamos áreas cruciais para desenvolvimento futuro, incluindo a validação dos resultados com líderes organizacionais, a automação da retroalimentação para enriquecimento da base de conhecimento, e a expansão do escopo do sistema para abarcar uma gama mais ampla de áreas tecnológicas. Essas perspectivas visam não apenas a otimização do *TREEVO* como ferramenta de desenvolvimento profissional, mas também a sua integração mais ampla nos processos de recrutamento, seleção e educação continuada no setor tecnológico, reforçando sua relevância e aplicabilidade em um mercado em constante evolução.

5.1 Conclusão

Este estudo, ao avaliar as respostas obtidas através do questionário *Likert*, revelou uma aceitação favorável do sistema *TREEVO*, destacando-se notavelmente na sua capacidade de empregar redes Bayesianas para oferecer recomendações de treinamento personalizadas. A aplicação eficaz dessas redes evidenciou a competência do sistema em discernir as necessidades de aprendizado dos usuários e propor cursos alinhados ao seu desenvolvimento profissional. Tal realização sublinha o valor do *TREEVO* como uma ferramenta de suporte decisivo para a evolução da força de trabalho, conciliando as demandas de capacitação dos colaboradores com os objetivos de progresso e inovação empresarial.

Além disso, a resposta positiva dos participantes em relação à usabilidade, relevância, impacto social, infraestrutura de apoio e propensão ao uso continuado do sistema enfatiza sua efetividade e a aceitação no ambiente corporativo. Portanto, o *TREEVO* se posiciona como um recurso indispensável no gerenciamento de conhecimento, facilitando a identificação de focos de atenção para o treinamento e promovendo o desenvolvimento sustentável das habilidades na organização.

Três perguntas fundamentais puderam ser respondidas através da realização deste estudo, concernentes à implantação de um sistema especialista com o suporte de redes Bayesianas para a otimização do conhecimento e aprimoramento da força laboral em contextos organizacionais:

- **Como as redes Bayesianas podem ser aplicadas para identificar lacunas de conhecimento específicas e recomendar treinamentos adequados?**

O estudo demonstrou que o sistema *TREEVO*, ao integrar redes Bayesianas, possui a capacidade única de analisar o conhecimento atual dos colaboradores e, com base nisso, sugerir opções de treinamento que se alinham precisamente às suas necessidades de desenvolvimento.

- **Qual é o impacto da facilidade de uso e da percepção de utilidade do sistema *TREEVO* na disposição dos colaboradores para adotar tecnologias de aprendizado?**

Os resultados apontam que a facilidade de uso e a percepção de utilidade do *TREEVO* contribuem significativamente para a aceitação e a motivação dos colaboradores em utilizar o sistema para seu desenvolvimento profissional, indicando que uma interface intuitiva e um claro entendimento dos benefícios são cruciais para a adoção da tecnologia.

- **Quão relevantes são as recomendações de treinamento do sistema para o desenvolvimento profissional dos colaboradores?**

As recomendações de treinamento fornecidas pelo sistema *TREEVO* foram avaliadas como extremamente pertinentes ao desenvolvimento profissional dos colaboradores, conforme demonstrado pelas altas pontuações recebidas nesta dimensão na escala

Likert. Essa percepção destaca o alinhamento efetivo entre as sugestões de cursos e as necessidades individuais de aprendizado, reforçando o valor do sistema na promoção do crescimento e aperfeiçoamento profissional dentro da organização.

5.2 Trabalhos futuros

A pesquisa e o desenvolvimento do sistema especialista *TREEVO* representam um passo significativo na direção de uma avaliação mais precisa e personalizada do conhecimento dos colaboradores em empresas de tecnologia. Entretanto, vislumbrando a evolução contínua e a otimização do sistema, destacamos áreas importantes para trabalhos futuros. Estas iniciativas visam não apenas aprimorar a eficácia do *TREEVO* mas também garantir sua relevância e aplicabilidade a longo prazo.

- **Validação dos Resultados com Líderes:**

Estruturar um processo de validação junto aos líderes para assegurar que os níveis de conhecimento identificados pelo *TREEVO* estejam alinhados com as percepções dos líderes sobre as competências de seus colaboradores. Isso visa reforçar a precisão das avaliações e das recomendações de treinamentos propostas pelo sistema.

- **Retroalimentação e Enriquecimento da Base de Conhecimento:**

Implementar um mecanismo automatizado que permita a atualização e o enriquecimento contínuo da base de conhecimento por parte dos especialistas. Esse processo facilitará a manutenção da relevância e adaptabilidade do sistema às evoluções do setor tecnológico.

- **Priorização de treinamentos e colaboradores:**

Desenvolver metodologias que auxiliem os líderes a identificar e priorizar quais treinamentos são mais críticos para cada colaborador, visando a otimização dos recursos dedicados ao desenvolvimento profissional.

- **Integração com processos seletivos e educação:**

Avaliar a implementação do *TREEVO* como ferramenta de apoio em processos seletivos, proporcionando uma análise inicial das competências técnicas dos candidatos,

ou como parte dos critérios de admissão em programas de formação e educação continuada.

- **Expansão para diversas áreas tecnológicas:**

Expandir a aplicabilidade do *TREEVO* para abarcar outras áreas do conhecimento, como Design, Frontend, Mobile e até Gestão. Essa expansão permitiria uma avaliação mais abrangente das competências técnicas, atendendo a uma variedade maior de perfis profissionais.

Estes itens delineiam um caminho promissor para o aprimoramento e a expansão do sistema *TREEVO*, visando não apenas aumentar sua precisão e eficácia, mas também estender seu alcance e aplicabilidade a um espectro mais amplo de contextos profissionais e educacionais no campo tecnológico.

Este estudo representa um passo significativo na compreensão de como sistemas especialistas podem ser utilizados para enriquecer a gestão do conhecimento e o desenvolvimento de talentos nas organizações. As descobertas aqui apresentadas não apenas contribuem para o campo acadêmico, mas também oferecem *insights* práticos para líderes e profissionais que buscam inovar e aprimorar suas práticas, técnicas e de gestão. Esperamos que as conclusões e recomendações deste trabalho inspirem futuras pesquisas e práticas, impulsionando o crescimento e a evolução no emocionante mundo da gestão do conhecimento e do desenvolvimento profissional.

REFERÊNCIAS BIBLIOGRÁFICAS

- BASS, L.; CLEMENTS, P.; KAZMAN, R. Software Architecture in Practice. USA: 2019 22nd International Conference on Control Systems and Computer Science (CSCS), 2013. https://edisciplinas.usp.br/pluginfile.php/5922722/mod_resource/content/1/2013%20-%20Book%20-%20Bass%20%20Kazman-Software%20Architecture%20in%20Practice%20%281%29.pdf, 3rd ed Acesso: 20 Ago 2023.
- BELHOT, R. V. Conceitos e Desenvolvimento de Sistemas Especialistas. São Carlos: [s.n.], 1993.
- BOONE, H. N.; BOONE. Analyzing Likert Data. USA: Journal of Extension, 2012. 50(2), 1-5.
- BRANCO, A. R. O perfil das universidades corporativas no Brasil. São José dos Pinhais: Revista de Administração Mackenzie, 2006. Vol 7, n.4, p. 99-120.
- BRETAS, A. Matriz de Certezas, Suposições e Dúvidas. São Paulo: Medium - Educação Fora da Caixa, 2015. <https://bit.ly/2qkaKQ0>. Acesso: 20 set 2022.
- CHIAVENATO, I. Recursos Humanos. 7. ed. São Paulo: Atlas, 2002.
- DAHIRE, S. Bayesian Network inference for probabilistic strength estimation of aging pipeline systems. California: International Journal of Pressure Vessels and Piping, 1988. <https://doi.org/10.1016/j.ijpvp.2018.01.004>, v. 162, p. 30-39, 2018.
- DAVIS, F. D. Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology. USA: MIS Quarterly, 1989. 13(3), 319-340.
- DEEPMIND. AlphaGo. United States: Google DeepMind, 2023. <https://www.deepmind.com/research/highlighted-research/alphago>. Acesso: 10 mai 2023.
- DESAI, V.; BUCARO, A. C.; KIM, W. J. Toward a better expert system for auditor going concern opinions using Bayesian network inflation factors. USA: International Journal of Accounting Information Systems, 2023. <https://doi.org/10.1016/j.accinf.2023.100617>, Acesso: 11 Mai 2023.

DORO, F. P. Aprendizagem organizacional: apresentação de um modelo conceitual. São Paulo: Brazilian Journal of Development, 2022.

FARIAS, D. P.; SOUSA, H. G. L.; SILVA, J. G. Processo de treinamento e desenvolvimento profissional a distância. São Paulo: [s.n.], 2021. Técnico em Recursos Humanos - ETEC Profa Anna de Oliveira Ferraz.

FLASK. Flask Documentation. USA: flask, 2023. <https://flask.palletsprojects.com/en/2.3.x/>. Acesso: 15 abr 2022.

GE. Asset Performance Management - APM. United States: GE Digital, 2023. <https://www.ge.com/digital/applications/asset-performance-management>. Acesso: 10 mai 2023.

GUPTA, S.; SINGHAL, R. Fundamentals and characteristics of an expert system. New York: International Journal on Recent and Innovation Trends in Computing and Communication, 2013. V1, n3, p. 110–113.

HAND, D. J.; YU, K. Idiot's Bayes—Not So Stupid After All? USA: International Statistical Review, 2009. 69(3), 385-398.

HART, P. E.; DUDA, R. O.; EINAUDI, M. T. PROSPECTOR: A Computer-Based Consultation System For Mineral Exploration. California: Journal of the International Association for Mathematical Geology, 1978. <https://www.sri.com/wp-content/uploads/2021/12/739.pdf>. Acesso: 05 fev 2023.

IBM. Watson Discovery. United States: IBM, 2023. <https://www.ibm.com/cloud/watson-discovery/legal-research/>. Acesso: 10 mai 2023.

JENSEN, F. V.; NIELSEN, T. D. Bayesian Networks and Decision Graphs. USA: Springer, 2007.

JONES, M. T. Artificial Intelligence: A Systems Approach. USA: Jones And Bartlett Publishers, 2008.

JUNIOR, E. G. A. Um sistema especialista para o auxílio na detecção de defeitos em hardwares de microcomputadores considerando incertezas. São José – SC: Universidade

do Vale do Itajaí, 2008. <http://siaibib01.univali.br/pdf/FabioAgustinhodaSilva.pdf>. Acesso: 03 ago 2022.

KOLLER, D.; FRIEDMAN, N. Probabilistic Graphical Models: Principles and Techniques. USA: MIT Press, 2009.

KURUBA, M. Role Competency Matrix: a step-by-step guide to an objective. Rio Grande do Sul: Springer, 2019.

LAI, M.; WANG, W.; HUANG, H. Linking the benchmarking tool to a knowledge-based system for performance improvement. New York: Expert Systems with Applications, 2011. V38, p. 10579–10586.

LUGER, G. F. Artificial Intelligence: Structures and Strategies for Complex Problem Solving. USA: Pearson, 2016. https://www.uoitc.edu.iq/images/documents/informatics-institute/exam_materials/artificial%20intelligence%20structures%20and%20strategies%20for%20%20complex%20problem%20solving.pdf, 6rd ed Acesso: 10 Set 2023.

MENDES, R. D. Inteligência artificial: sistemas especialistas no gerenciamento da Informação. Brasília DF: IBICT - Instituto Brasileiro de Informação em Ciência e Tecnologia, 1997. Livro Inteligência artificial - issn 1518-8353 - v. 26, n.1, p. 39-45.

MOREIRA, M. A. Mapas conceituais e aprendizagem significativa. Rio Grande do Sul: Instituto de Física. Universidade Federal do Rio Grande do Sul, 1997. <http://www.if.ufrgs.br/~moreira/mapasport.pdf>. Acesso: 20 set 2022.

MOREIRA, M. A. Mapas Conceituais e Diagramas V. Rio Grande do Sul: Instituto de Física. Universidade Federal do Rio Grande do Sul, 2006.

NASSAR, S. M. Tratamento de Incerteza: Sistemas Especialistas Probabilísticos. Brasil: Departamento de Informática e Estatística, 2012. http://www.inf.ufsc.br/~silvia.nassar/disciplinas/sep/material_didatico/MaterialDidatico.pdf, Acesso: 15 Fev 2023.

NEGNEVITSKY, M. Artificial Intelligence. A Guide to Intelligent Systems. New York: Person Education, 2002.

PAULINO, C. D.; TURKMAN, M. A. A.; MURTEIRA, B. Estatística Bayesiana Probabilísticos. Lisboa: Fundação Calouste Gulbenkian, 2003.

PEAR, J. Probabilistic Reasoning in Intelligent Systems: Network of Plausible Inference. California: Morgan Kaufmann Series, 1988. <https://flask.palletsprojects.com/en/2.3.x/>, p. 108-124.

PEREIRA, G. O.; AIDAR, S.; LOPES, V. A. F. CULTURA ORGANIZACIONAL E APRENDIZAGEM: UMA REVISÃO INTEGRATIVA. São Paulo: ENCICLOPÉDIA BIOSFERA, Centro Científico Conhecer, 2021.

PEREIRA, P. M. A Quinta Disciplina: Arte e Prática da Organização de Aprendizagem. Jandaia - GO: Best Seller Círculo do Livro, 1998. 2nd ed. Trabalho original publicado em 1990.

PEREZ, R. A. M. Experta Documentation. Madri: Experta Documentation, 2018. <https://experta.readthedocs.io/en/latest/index.html>. Acesso: 12 mai 2022.

PILONE, D.; PITMAN, N. UML 2.0 in a Nutshell: A Desktop Quick Reference. USA: In a Nutshell (O'Reilly), 2005.

PRESSMAN, R. S.; MAXIM, B. R. Engenharia de Software: Uma Abordagem Profissional. USA: McGraw-Hill, 2016.

RISH, I. An empirical study of the naive Bayes classifier. USA: IJCAI 2001 Workshop on Empirical Methods in Artificial Intelligence, 2001. https://www.researchgate.net/publication/228845263_An_Empirical_Study_of_the_Naive_Bayes_Classifier, Acesso: 24 Out 2023.

RUSSELL, S.; NORVIG, P. Artificial Intelligence A Modern Approach. New Jersey: Prentice Hall Series In Artificial Intelligence, 2005. 932 p.

RUSSELL, S.; NORVIG, P. Artificial Intelligence A Modern Approach. California: Prentice Hall Series In Artificial Intelligence, 2010. 3rd ed. p 330-337.

RUSSELL, S.; NORVIG, P. Artificial Intelligence: A Modern Approach. USA: Pearson Series in Artificial Intelligence, 2020. 4 ed.

- SARDINHA, R.; PAES, A.; ZAVERUCHA, G. Revising the structure of Bayesian network classifiers in the presence of missing data. USA: Information Sciences, 2018. <https://flask.palletsprojects.com/en/2.3.x/>, p. 108-124.
- SOMMERVILLE, I. Engenharia de Software. São Paulo: Person, 2019. 10 ed.
- SOUZA, D. C. Sistema especialista baseado em regras ponderado por tendências aplicado ao monitoramento de processos industriais. Paris: Universidade Federal do Rio Grande do Norte, 2017. Tese de Doutorado. Universidade Federal do Rio Grande do Norte.
- SPECTRUM, I. Top Programming Languages 2022. USA: Spectrum IEEE, 2022. <https://spectrum.ieee.org/top-programming-languages-2022#toggle-gdpr>. Acesso: 5 abr 2022.
- STAN, C.; MOCANU, I. An Intelligent Personalized Fashion Recommendation System. USA: 2019 22nd International Conference on Control Systems and Computer Science (CSCS), 2019. 10.1109/CSCS.2019.00042, Acesso: 17 Mai 2023.
- VENKATESH, V.; BALA, H. Technology Acceptance Model 3 and a Research Agenda on Interventions. USA: Decision Sciences, 2008. 39(2), 273-315.
- VERGARA, S. C.; RAMOS, D. R. M. Motivos para criação de Universidades Corporativas - Estudo de caso. Rio de Janeiro: Revista de Administração Mackenzie, 2002. Ano 3, n.2, p. 79-98.
- WAGNER, W. P. Trends in expert system development: A longitudinal content analysis of over thirty years of expert system case studies. New York: Elsevier Ltd, 2017. Vol 76. p. 85-96.
- WALEK, B.; FOJTIK, V. A hybrid recommender system for recommending relevant movies using an expert system. USA: Expert Systems with Applications, 2019. <https://doi.org/10.1016/j.eswa.2020.113452>, Acesso: 15 Mai 2023.
- WATERMAN, D. A. A Guide to Expert Systems. New York: Addison-Wesley, 1986.
- WEATHERBELL. Weather Bell Expert System. New York: IBM, 2023. <https://www.weatherbell.com/#featured/>. Acesso: 10 mai 2023.

WEBER, C. J. Desenvolvimento de um sistema especialista para seleção. São Paulo: [s.n.], 2017. Tese de doutorado - Escola Politécnica da Universidade De São Paulo - p. 41.

ZHANG, H. The Optimality of Naive Bayes. Canada: University of New Brunswick, 2004. <https://www.cs.unb.ca/~hzhang/publications/FLAIRS04ZhangH.pdf>, Acesso: 23 Out 2023.

A Perguntas para avaliar o conhecimento em Java

1. Você conhece Orientação Objeto?

- Não conheço
- Conheço pouco e preciso de apoio
- Conheço e tenho autonomia
- Domino e posso ensinar

2. Você conhece Java Persistence API?

- Não conheço
- Conheço pouco e preciso de apoio
- Conheço e tenho autonomia
- Domino e posso ensinar

3. Você conhece Generics?

- Não conheço
- Conheço pouco e preciso de apoio
- Conheço e tenho autonomia
- Domino e posso ensinar

4. Você conhece Lambda?

- Não conheço
- Conheço pouco e preciso de apoio
- Conheço e tenho autonomia

- Domino e posso ensinar
5. Você conhece Interfaces Funcionais?
- Não conheço
 - Conheço pouco e preciso de apoio
 - Conheço e tenho autonomia
 - Domino e posso ensinar
6. Você conhece Stream API?
- Não conheço
 - Conheço pouco e preciso de apoio
 - Conheço e tenho autonomia
 - Domino e posso ensinar
7. Você conhece Tratamento Erro?
- Não conheço
 - Conheço pouco e preciso de apoio
 - Conheço e tenho autonomia
 - Domino e posso ensinar
8. Você conhece Collections?
- Não conheço
 - Conheço pouco e preciso de apoio
 - Conheço e tenho autonomia

- Domino e posso ensinar
9. Você conhece conceitos de Threads?
- Não conheço
 - Conheço pouco e preciso de apoio
 - Conheço e tenho autonomia
 - Domino e posso ensinar
10. Você conhece Java Reativo?
- Não conheço
 - Conheço pouco e preciso de apoio
 - Conheço e tenho autonomia
 - Domino e posso ensinar

B Perguntas para avaliar o conhecimento em Boas Práticas

1. Você conhece CleanCode?
- Não conheço
 - Conheço pouco e preciso de apoio
 - Conheço e tenho autonomia
 - Domino e posso ensinar
2. Você conhece os princípios de SOLID?

- Não conheço
- Conheço pouco e preciso de apoio
- Conheço e tenho autonomia
- Domino e posso ensinar

3. Você conhece o princípio KISS?

- Não conheço
- Conheço pouco e preciso de apoio
- Conheço e tenho autonomia
- Domino e posso ensinar

4. Você conhece o princípio YAGN?

- Não conheço
- Conheço pouco e preciso de apoio
- Conheço e tenho autonomia
- Domino e posso ensinar

5. Você conhece o princípio DRY?

- Não conheço
- Conheço pouco e preciso de apoio
- Conheço e tenho autonomia
- Domino e posso ensinar

C Informações pessoais

1. Qual a sua cor?

- Preta
- Branca
- Parda
- Amarela
- Indígena
- Prefiro não informar

2. Qual o seu gênero?

- Homem cis
- Mulher cis
- Homem trans
- Mulher trans
- Não Binário
- Prefiro não informar

3. Qual a sua senioridade atual?

- Junior
- Pleno
- Senior
- Especialista