Um Assistente Virtual para Suporte a Assistência Técnica de Bombas Centrífugas em Processos Industriais

Otavio de Almeida Bianchini*. Marilza Antunes de Lemos*

**Universidade Estadual Paulista (UNESP), Instituto de Ciência e Tecnologia de Sorocaba, Brasil, 18087-180*
Departamento de Engenharia de Controle Automação
{e-mail: (otavio.bianchini@unesp.br)(marilza.lemos@unesp.br)}

Abstract: Research in automatic fault diagnosis using Artificial Intelligence (AI) techniques has been ongoing for decades, and more recently, methods like Machine Learning have improved the predictive capabilities of industrial systems. However, these advancements do not eliminate the need for technicians to complement maintenance work, whether in replacing components, performing preventive maintenance, or carrying out other maintenance actions. An effective maintenance process requires a well-trained team, established procedures, and supporting systems. Chatbots and virtual assistants have demonstrated success in human interactions across various fields. The present work explores this resource and presents the development of a Chatbot-type virtual assistant to support the technical team maintaining centrifugal pumps in an industrial context. The application aims to assist with the specificities of these devices, as well as in field removal and installation operations. The development was carried out with the Chatterbot tool in the Python language. Specialized technical knowledge was modeled and embedded in the application. Machine Learning resources in Chatterbot were applied to train and refine user responses. Preliminary tests with a reduced database indicated that the E-MANUEL chatbot achieved a success rate of 89.2%, and in only 7.7% of interactions it was unable to provide a response to the user within the expected context.

Resumo: A pesquisa em diagnóstico automático de falhas com técnicas de Inteligência Artificial (IA) existe há décadas, e recentemente, métodos como Machine Learning têm melhorado a predição de falhas em sistemas industriais. No entanto, esses avanços não substituem a necessidade de técnicos para complementar a manutenção, seja na substituição de componentes, na manutenção preventiva ou em outras ações. Um processo de manutenção eficaz requer uma equipe bem treinada, procedimentos estabelecidos e sistemas de suporte. Chatbots e assistentes virtuais têm mostrado sucesso em interações com humanos em diversas áreas.. O presente trabalho explora esse recurso e apresenta o desenvolvimento de um assistente virtual do tipo *Chatbot* para dar suporte à equipe técnica de manutenção de bombas centrífugas em um contexto industrial. A aplicação visa auxiliar sobre especificidades desses dispositivos, bem como em operações de retirada e instalação dos equipamentos. O desenvolvimento foi realizado com a ferramenta Chatterbot na linguagem Phyton. Conhecimento técnico especializado foi modelado e embutido na aplicação. Recursos de *Machine Learning* em Chatterbot foram aplicados para treinamento e refinamento das respostas ao usuário. Testes preliminares com banco de dados reduzido indicaram que o *chatbot* E-MANUEL obteve uma taxa de sucesso de 89,2%, e apenas em 6,2% das interações não foi capaz de gerar resposta ao usuário dentro do contexto esperado.

Keywords: Virtual assistant; Chatbot; Intelligent System; Machine Learning; Artificial intelligence; Centrifugal pumps; Maintenance.

Palavras-chaves: Assistente virtual; Chatbot; Sistema Inteligente; Machine Learning; Inteligência Artificial; Bombas centrífugas; Manutenção.

1. INTRODUÇÃO

Atualmente, o planejamento e execução das ações de manutenção são vistos como parte do processo produtivo ao garantir a confiabilidade nos processos da empresa, a qual se traduz em competitividade no mercado (CARELLI & MACIEL, 2006; MENGUE & SELITO, 2013). Um estudo realizado por Silva et al. (2017) mostra a aplicação e os impactos do processo de manutenção utilizando uma bomba centrífuga Agrimec, modelo BCI 300, aplicada ao contexto industrial de transporte de água. O trabalho evidencia como a devida manutenção reduz muitas perdas para a empresa, sendo a financeira causada pela parada repentina na produção, a pessoal causada por acidentes de fábrica ou a perda ambiental resultante dos contaminantes gerados e perdidos no meio ambiente. McKee et al. (2011) estudou modos de falhas em bombas centrífugas, destacando sintomas, causas e formas de combatê-las. Ele aponta que bombas modernas têm sensores acoplados para monitoramento em tempo real, mas muitos operadores não sabem interpretar essas informações, sugerindo um sistema inteligente com IA para diagnóstico. A pesquisa em diagnóstico automático de falhas usando IA já

existe há décadas (ZHU et al., 2023; HE; HE, 2017; HOANG; KANG, 2019). Recentemente, o foco tem sido em sistemas preditivos que, com Machine Learning, analisam dados históricos e preveem falhas em elementos de automação (CARVALHO et al., 2019; SUSTO et al., 2014; THEISSLER et al., 2021). Porém, apesar de todos esses avanços em diagnóstico e predição de falhas automáticos, nenhum desses métodos eliminam a necessidade de um técnico complementar o trabalho de manutenção, seja pela substituição de componentes na planta industrial ou de outras ações humanas de manutenção. Um processo eficaz de manutenção pode requerer uma equipe técnica bem treinada, processos de manutenção bem estabelecidos e um conjunto de sistemas que auxiliem esta equipe. Atualmente as aplicações *Chatbot*s ou assistentes virtuais vem obtendo sucesso em interações com humanos em diversas áreas, incluindo a área de educação e treinamento (ALHASSAN et al., 2022; NEUMANN et al., 2021; CHANG; HWANG; GAU, 20222). O presente trabalho explora esse recurso e apresenta o desenvolvimento de um assistente virtual do tipo *Chatbot* com a proposta de dar suporte à equipe técnica de manutenção de bombas centrífugas em um contexto industrial. O *chatbot* visa auxiliar sobre especificidades desses dispositivos, bem como em operações de retirada e instalação em campo.

2. CHATBOTS

Chatbot, ou assistente virtual, é um *software* que simula diálogo com humanos de forma natural, por texto ou voz (Hussain et al., 2023). Com a crescente digitalização da sociedade, o uso de *chatbots* passou a auxiliar diversas atividades, como assistentes pessoais e terapia de autoajuda (Serban et al., 2017). Esses programas reduzem custos e lidam com vários clientes simultaneamente, além de serem populares pelo *design* amigável e pela apresentação direta da informação (Adamopoulou; Moussiades, 2020a). De modo geral, existe uma arquitetura e um conjunto de conceitos comuns que envolvem as aplicações Chatbots, iniciando pela captação da entrada do usuário, seja por texto ou por voz (CAHN, 2017). Captada a entrada do usuário, a próxima etapa envolve a compreensão da linguagem natural através do NLU (*Natural Language Understand*) (ALHASSAN et al.,2022), responsável pela compreensão do texto do usuário. A compreensão ocorre pela extração das *intents* (intenções do usuário), elementos do texto que serão usados como base para a busca da resposta que deve ser fornecida pelo *chatbot* (ADAMOPOLOU; MOUSSIADES, 2020b). (NEUMANN et al., 2021). O componente de Gerenciamento de Diálogo é responsável por armazenar e atualizar os contextos e intenções da conversa (ADAMOPOLOU; MOUSSIADES, 2020b). O aprendizado de máquina (ML) é a subárea mais pesquisada e aplicada em Inteligência Artificial (IA). É um método iterativo de aprendizagem automática baseado na análise de dados por algoritmos. Para assistentes virtuais, ML é uma ferramenta poderosa que melhora a compreensão da comunicação humana e torna as respostas mais naturais e eficazes.

2.1 Chatterbot

O Chatterbot (Cox, 2021) é uma biblioteca Python para criar chatbots usando regras e aprendizado de máquina. Ele facilita a criação, treinamento e teste de chatbots conversacionais, permitindo que o chatbot melhore suas respostas ao interagir com humanos e outras fontes de dados. Utilitários permitem atualizar o grafo de conhecimento e treinar o chatbot com dados previamente carregados. Inicialmente, uma instância do Chatterbot não treinada não sabe se comunicar, mas à medida que recebe mais entradas, sua precisão e variedade de respostas aumentam, melhorando seu desempenho com o tempo. A biblioteca Chatterbot trabalha com um conjunto de conceitos, sendo os principais:

Adaptadores lógicos – determinam a lógica de como ChatterBot seleciona uma resposta para uma determinada instrução de entrada.

Declaração – (*Statement*) representa uma instrução de entrada que o *chatbot* recebeu de um usuário ou uma instrução de saída que o *chatbot* retornou com base em alguma entrada.

Pré-processadores –funções que podem ser usadas para modificar a entrada de texto que o *chatbot* recebe antes que o texto seja passado para o adaptador lógico para processamento.

3. MANUTENÇÃO DE BOMBAS CENTRÍFUGAS

O conceito de manutenção vem evoluindo indo além da correção de falhas imediatas, incluindo cuidados sistemáticos para prevenir falhas, detectando e corrigindo anomalias (SILVA; NASCIMENTO, 2020). Existem três tipos principais de manutenção: corretiva, que repara equipamentos após falhas; preventiva, que realiza operações periódicas para garantir a qualidade (SILVA et al., 2017); e preditiva, que supervisiona constantemente para agir antes que anomalias causem danos (SANTOS et al., 2023).

3.1 Bombas centrífugas

Bombas são turbomáquinas que geram regiões de baixa e alta pressão em um fluido. A bomba centrífuga, a mais usada na indústria pela sua versatilidade (THIN; KHAING; AYE, 2008), utiliza a força centrífuga para transferir energia ao fluido. A Figura 1 mostra sua estrutura básica, onde um motor, geralmente elétrico, acopla-se ao eixo e transmite energia mecânica ao rotor, que transfere essa energia ao fluido (SILVA et al., 2017). O fluido é sugado, entra no centro do rotor e, ao girar, é impulsionado para as bordas, sendo expelido pelo bocal de descarga.

Figura 1 - Diagrama de uma bomba centrífuga

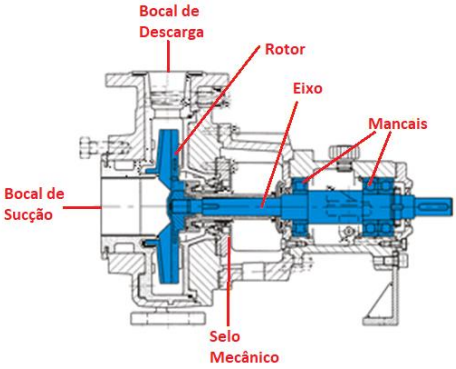

Fonte: Autoria própria

Os mancais lubrificam os eixos, exigindo manutenção regular do nível e da qualidade do óleo, com trocas periódicas. O selo, por sua vez, previne vazamentos de fluido, evitando a

contaminação do óleo (SILVA et al., 2017). Outros itens a serem verificados nas bombas incluem a fixação dos parafusos, além da presença de vazamentos e ferrugem, identificáveis por inspeção visual (MENGUE; SELITO, 2013).

3.2 Modos de falhas em bombas centrífugas

Cavitação

Na indústria química, a cavitação, caracterizada pela formação de bolhas em tubulações e máquinas, é uma preocupação comum (BINAMA; MUHIRWA; BISENGIMANA, 2016). Essas bolhas causam mudanças de pressão que podem danificar bombas por erosão (MCKEE et al., 2011). Devido à dificuldade de detecção visual, os métodos de monitoramento focam nos efeitos secundários, como emissão sonora e corrosão (BINAMA; MUHIRWA; BISENGIMANA, 2016). Para mitigar o impacto, recomenda-se polir o rotor, usar revestimentos de elastômeros e ajustar o ângulo das pás de entrada (15° a 30°) (JARDIN; RIFFEL; COSTA, 2016).

Falha de Lubrificação

A lubrificação tem por função reduzir a fricção entre partes móveis permitindo uma movimentação facilitada. Alguns fatores para o devido funcionamento das bombas devem ser considerados: lubrificante adequado para a operação, dosagem correta, contaminação e vida útil do próprio lubrificante. A falha pode se dar por meio de contaminantes, como água e partículas sólidas, ou pelo aumento de temperatura que aumenta sua viscosidade, reforçando a manutenção e monitoramento constante do óleo de lubrificação. (CHEN et al., 2022).

Falha de Rolamento

Ligado ao rotor da bomba, o rolamento é responsável por garantir uma melhor movimentação da máquina e, caso falhe, pode provocar um aumento de temperatura, vibração, perda de eficiência. Em casos mais extremos, ocasiona a parada da máquina (CHEN et al., 2022). Sua falha pode ser causada pela falha de lubrificação, reforçando a importância da boa lubrificação; sobrecarga causada pela operação do sistema fora da sua operação ideal (BEP ou *Best Efficiency Point*) (MCKEE et al., 2011); partículas estranhas prensadas nos elementos rotativos, e impacto que podem gerar trincas; e, por fim, desalinhamento que podem ser corrigidos pela devida montagem do equipamento em sua área de trabalho. (JARDIN; RIFFEL; COSTA, 2016)

Falha no Selo

Os selos mecânicos são estruturas cilíndricas que tem por função evitar a perda de fluídos entre as partes da bomba. A falha do selo pode ser ocasionada devido a uma abertura nas faces lapidadas que permitem a entrada de sólidos entre as superfícies, e com o movimento produzido gera um alto desgaste da face rígida. Posteriormente, será responsável por várias falhas de vedação (MCKEE et al., 2011).

Desbalanceamento e Desalinhamento

Desalinhamento ocorre com o desvio do nível ou angulação de uma extremidade do eixo principal da bomba, causando um deslocamento na posição do eixo. Já o desbalanceamento diz respeito a uma má distribuição de pesos ao longo da bomba que pode ser causado por incrustação, falha na montagem, qualidade do material, entre outros. Ambos os erros são estruturais podendo ser corrigidos com a devida montagem da bomba e têm como consequência o aumento de vibração do sistema. (CHEN et al., 2022)

4. MATERIAIS E MÉTODOS

O assistente virtual proposto, denominado E-MANUEL, é um chatbot autônomo para suporte na manutenção de bombas centrífugas. Implementado em Python devido às suas bibliotecas voltadas para IA e Deep Learning, o desenvolvimento foi realizado na IDE PyCharm (JETBRAINS S.R.O, 2024) usando a ferramenta Chatterbot. Esta ferramenta permite que o assistente aprenda continuamente a linguagem humana e utilize diálogos prontos em seu repertório.

4.1 Especificações técnicas da bomba centrífuga

O modelo de bomba escolhido para modelagem neste trabalho foi o ETA da empresa KSB, uma das principais fornecedoras de bombas centrifugas industriais no Brasil e que dispõe de documentação técnica acessível. O modelo é indicado para bombeamento de líquidos limpos ou turvos como água, óleos e sistema de resfriamento. O código de classificação adotado para este modelo segue a ordem: fabricante, modelo, diâmetro do flange de recalque, diâmetro do rotor e o número de estágios (Figura 2).

Figura 2 - Nomenclatura de bomba centrífuga

KSB	ETA	80	-	40
Marca	Modelo	Diâmetro nominal do flange de recalque		Diâmetro nominal do rotor

Fonte: Autoria própria

As especificações técnicas para o usuário obter melhor desempenho do equipamento, são (KSB ,2013):

- Temperatura máxima: 140° C (acima de 80° deve conter câmara de resfriamento instalado)
- Vazão máxima: 1800 m³/s
- Elevação máxima: 120m
- O lubrificante a ser usado deve seguir as especificações apresentadas na Tabela 1.

Tabela 1 - Lubrificante para o modo de operação da bomba

Velocidade da bomba	≤ 1800RPM	>1800RPM
ATLANTIC	Duro AW 68	Duro AW 46
CASTROL	Hyspin 68	Hyspin 46
ESSO	Teresso 68	Terresso 46
IPIRANGA	Ipitur AW 68	Ipitur AW 46
MOBIL OIL	Mobil D.T.E. - 26	Idem
SHELL	Tellus oil 68	Tellus oil 46
TEXACO	Rigail oil RO 100	Rigail oil RO 68
PETROBRAS	Marbrax TR 52	Marbrax TR 52

Fonte: Autoria própria

No modelo de bomba KSB ETA o diâmetro do flange pode variar entre 32mm a 300mm e o diâmetro de rotor pode variar de 12cm a 50cm. Deste modo, os tamanhos utilizados neste trabalho foram 125mm de flange e 40cm de rotor, ou seja, a bomba KDB ETA125-40. Com isso novas especificações

técnicas foram definidas (Figura 3), importantes para informar o técnico e definir os devidos procedimentos na bomba.

Figura 3 - Especificações baseadas nos diâmetros de flange e rotor

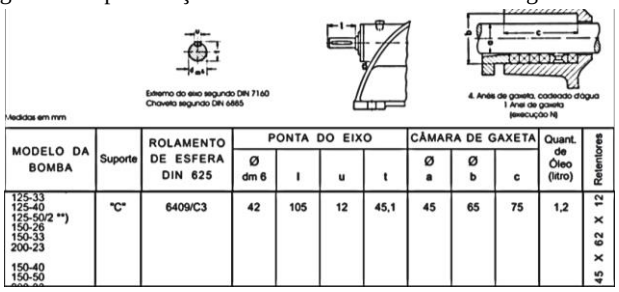

MODELO DA BOMBA	Suporte	ROLAMENTO DE ESFERA DIN 625	PONTA DO EIXO				CÂMARA DE GAXETA			Quant. de Óleo (litro)	Retentores
			Ø dm 6	l	u	t	Ø a	Ø b	c		
125-33 125-40 125-50/2 **) 150-26 150-33 200-23 150-40 150-50	"C"	6409/C3	42	105	12	45,1	45	65	75	1,2	45 X 62 X 12

Fonte: KSB (2013)

4.2 Modelagem dos Processos de Manutenção da Bomba Centrífuga

O usuário pode solicitar ajuda ao *chatbot* E-MANUEL em uma de três categorias:

I. Informações de dados técnicos,
II. Processo de inspeção (*checklist*)
III. Guia de ações de manutenção

A implementação de cada processo utiliza uma de duas técnicas: adaptador lógico ou treinamento com diálogos (*Deep Learning*), apresentados na Tabela 2.

Tabela 2 – Relação entre categoria, técnica e adaptador logico

Categoria	Técnica	Adaptador lógico
Informações de dados técnicos	Adaptador lógico	BuscaDadosTec
Checklist	Adaptador lógico	Checklist
Ações de manutenção	Deep learning	BestMach

Fonte: Autoria própria

O *BestMach* é um adaptador lógico padrão do Chatterbot responsável pelo processo de geração de resposta baseadas em *Deep Learning*. Já os demais adaptadores são de autoria própria desenvolvidos para suprir as necessidades específicas do E-MANUEL.

I. Informação de Dados Técnicos

Para que o E-MANUEL disponibilize ao usuário informações das bombas centrifugas instaladas na planta industrial, é necessário acesso ao banco de dados da empresa. Neste trabalho, foi implementado um pequeno banco de dados (BD) para simular essa base de dados técnicos. O ambiente de desenvolvimento utilizado foi o PgAdmin4 que permite gerenciar banco de dados Postgrees (POSTGRESQL, 2024). No banco de dados as informações técnicas da bomba foram armazenadas na tabela **dados_tecnicos**, com as seguintes informações:

- **codigo** - identificação da bomba na planta industrial (chave primária),
- **tm_rotor** - diâmetro do rotor em milímetros (mm),
- **velocidade** - velocidade de rotação que o rotor opera em Rotação Por Minuto (RPM)
- **produto** - substância com a qual o sistema opera.

Foi criada ainda a tabela **lubrificação** conectada à tabela **dados_tecnicos** por meio da chave estrangeira cd_bomba que referencia a chave primária **código**:

- **quantidade** - refere-se ao volume de lubrificante necessário em Litros (L)
- **frequencia_troca** - refere-se ao período em dias da troca de óleo.

Para descobrir a **intenção** (*intent*) do usuário, E-MANUEL busca por um grupo de palavras que indiquem a *intent* da entrada do usuário, diferindo estas palavras entre um adaptador lógico e outro. A relação entre adaptadores lógicos, palavras-chave e *intent* é mostrada na Tabela 3.

Tabela 3 - Relação entre adaptadores, palavras-chave e *intents*

Adaptador lógico	Palavras de contexto	Palavra-chave	Intent
BuscaDadosTec		Rotor	Tamanho do rotor
		Velocidade, rotação	Velocidade de rotação
		Produto, substância	Produto com que opera
		modelo	Modelo da bomba
		Empresa, fabricante	Empresa fabricante
		Código, numeração	Código da bomba
BuscaDadosLub	Óleo, lubrificante, lubrificação	Frequência, período	Período de troca de óleo
		Fabricante, empresa	Fabricante do lubrificante
		Volume, quantidade	Volume de lubrificante
		Marca, tipo	Marca do lubrificante

Fonte: autoria própria

Identificada a *intent* e o contexto da requisição, os adaptadores realizam a busca no BD para responder ao usuário. A relação entre *intents* e resposta fornecida pelos adaptadores está apresentada na Tabela 4 onde '{}' corresponde ao parâmetro instanciado com o dado técnico obtido no BD.

O algoritmo 1 corresponde ao pseudocódigo que implementa o adaptador lógico BuscaDadosTec, que busca por palavras-chave de três grupos distintos: palavras que remetam a uma pergunta, palavras que indiquem a *intent* e palavras de contexto. Ao obter a *intent*, o código realiza uma consulta no BD para retornar a informação solicitada pelo usuário.

Tabela 4 - Relação entre *intents* e respostas

Intent	Resposta
Tamanho do rotor	O rotor mede {}cm
Velocidade de rotação	Essa máquina opera á {}rpm
Produto com que opera	Esta bomba está operando com {}
Modelo da bomba	Essa máquina é uma bomba é uma {}
Empresa fabricante	A bomba foi feita pela {}
Código da bomba	Essa bomba está registrada como {}
Período de troca de óleo	O oléo precisa ser trocado a cada {} dias
Empresa que fabrica o lubrificante	Essa marca é produzida pela {}
Volume de lubrificante necessário	A bomba precisa de {}L de oléo
Marca do lubrificante	Esta bomba utiliza óleo {}

Fonte: autoria própria

Algoritmo 1 - BuscaDadosTec

```
1   INÍCIO
2       LEIA (frase,listaPalavras)
3       conecta com banco de dados
4       STR intends[ ] ← lista de intents
5       intencao ← encontra item de intends[ ] mais próxima ao objetivo do usuário
6       retorno ← busca no BD pelo dado correspondente ao valor da intenção
7       STR saida ← frase criada baseada no retorno
8       confidence ← calcula_chance do adaptador logico  responder bem o usuário
9       statement ← novo Statement(saida, confidence)
10      RETORNA statement
11  FIM
```

Na linha 8, o cálculo de confiança foi gerado por meio da equação (1).

$$confidence = (chanceInt * 0.6 + chanceDuvida * 0.4 - chanceLub * 0.2) * Ajuste \quad (1)$$

A fórmula foi balanceada experimentalmente, por meio de testes em *statements* críticos. O cálculo fornece um valor que corresponde a chance do adaptador lógico responder corretamente o usuário, cada adaptador lógico terá o seu próprio cálculo e os valores de confiança serão comparados para encontrar aquele que melhor responde ao usuário. Na fórmula, **chanceInt** é o grau de similaridade da *intent* encontrada, este é o fator de maior relevância no cálculo. Foram utilizados graus de similaridade ao invés de absolutos para que palavras com erros de digitação possam ser reconhecidas. O fator **chanceDuvida** indica a chance de ser uma dúvida do usuario. O fator **chanceLub** indica a proximidade com a palavra lubrificação, este fator busca identificar o contexto trazido pelo usuário. Os valores de chanceInt, chanceDuvida e chanceLub são obtidos por meio de uma função interna que se utiliza do método *SequenceMatcher()* para retornar um valor numérico de comparativo entre palavras.

Ajuste é um fator adicionado à confiança dos adaptadores lógicos para evitar interferência com o BeastMach, o adaptador lógico responsável pelos processos de *Machine Learning*. O valor do fator foi definido realizando-se testes com as frases mais conflitantes onde as palavras-chave de *intents* eram mencionados em contextos tratados por *Machine Learning*, visando maximizar a taxa de acerto e o valor encontrado foi 0.8.

II. Processo de Inspeção

Seguindo as orientações do manual técnico da bomba KBS-ETA (KSB, 2013), um *checklist* e orientações correspondentes foram implementados no *chatbot*, contendo os seguintes tópicos: alinhamento do conjunto, nível do óleo, aperto de parafusos, movimentação do eixo, acoplamento, vazamentos na gaxeta. Para iniciar um processo de *checklist* o usuário pode usar frases como "Vamos fazer a *checklist*" ou "Preciso começar o processo de *checklist* desta bomba". O processo de *checklist* é iniciado pelo adaptador lógico *checklist* pela detecção da palavra-chave e *intent checklist*. Uma visão simplificada do fluxo de informações pode ser vista na Figura 4.

Figura 4 – Interações na execução do Checklist

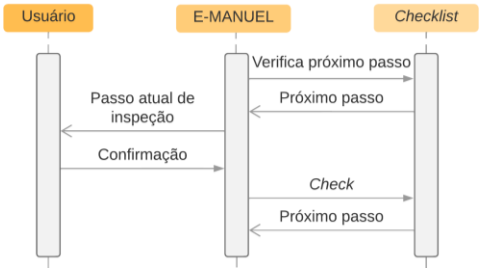

Iniciado o processo, E-MANUEL instancia internamente a *checklist* com os diferentes itens que devem ser verificados e sua condição de inspeção: **falso** para itens ainda não verificados e **verdadeiro** para itens verificados. Em seguida pergunta ao usuário sobre um item não verificado da *checklist*, podendo receber como resposta de confirmação como "Certo", "Está pronto" ou "O sistema está alinhado" para que seja aceito como realizado (*check*). Nessa fase, E-MANUEL atualiza o *checklist* e dispara o passo seguinte. Para cada item de verificação o *chatbot* envia uma mensagem personalizada de acordo com a Tabela 5.

Tabela 5 - Relação entre etapa do checklist e resposta

Etapa	Resposta
lubrificante	O nível do óleo está adequado?
parafusos	Por favor verifique se os parafusos estão bem apertados
nivelamento	O equipamento está devidamente nivelado?
acoplamento	O motor está devidamente acoplado a bomba?
movimentação	O eixo consegue movimentar livremente?
gaxeta	Tudo certo com a gaxeta?

Fonte: autoria própria

III. Guia para Ações de Manutenção

Além do processo de *checklist*, ações de manutenção isoladas foram modeladas no E-MANUEL, incluindo processos de pré e pós manutenção. São eles: Instalação da Bomba, Desmontagem da Bomba, Troca de Lubrificante, Troca de Rolamento, Análise do estado do Lubrificante. O suporte em ações de manutenção foi implementado no *chatbot* com o adaptador lógico *BestMatch*, utilizando o algoritmo de classificação *Naive Bayesian* para determinar se um *statement* de entrada atende a um conjunto específico de critérios que garantem que uma resposta seja gerada a partir desse adaptador lógico. Para isso foram criadas bases de diálogos que iniciam com o pedido do usuário por orientações e seguem por uma sequência passo a passo de operação do *chatbot* e indicação de conclusão por parte do usuário. Ao todo foram utilizados 57 diálogos.

A função *train()* do Chatterbot foi utilizada para o treinamento utilizando como parâmetros o *chatbot* criado e as caixas de diálogos desenvolvidas, reunidas no arquivo treino.py. Num contexto treinado com diversos diálogos envolvendo o estado do lubrificante, E-MANUEL conseguiu dialogar e orientar o usuário solicitando detalhes sobre a condição do óleo: se está excessivamente quente, se apresenta impurezas e se está abaixo do nível. Caso o óleo esteja quente, o *chatbot* sugere a verificação do nível de óleo e alinhamento do conjunto. Caso o óleo apresente impurezas é indicada a troca e envio para análise em laboratório especializado, pois o resultado pode indicar outras falhas no equipamento. Caso o óleo esteja somente abaixo do nível adequado, a orientação é a de completar o óleo até o nível e realizar a inspeção de vazamentos. Não havendo vazamentos, e o consumo do óleo esteja ocorrendo mais rápido, é sugerida uma reanálise da frequência de troca.

5. RESULTADOS E DISCUSSÕES

Por se tratar de um protótipo, não foram implementados elementos de *front-end* em E-MANUEL, assim a troca de mensagens durante a interação é realizada via terminal com indicações do E-MANUEL e do usuário (Figura 5). A Tabela 6 apresenta informações dos testes realizados, onde a coluna **N° de testes** representa o total de testes realizados em cada categoria (função), a coluna **N° sucessos** representa a quantidade de testes que retornaram as respostas esperadas dentre as respostas não esperadas o **N° erro relevante** representa o número de testes que retornaram respostas relevantes, as respostas consideradas relevantes são aquelas que são obtidas pelo adaptador lógico ou caixa de diálogo esperados, mesmo que não retorne a resposta correta,

indicando que o E-MANUEL foi capaz de entender o contexto do que foi solicitado, a coluna **N° não relevante** representa o total de testes que retornaram respostas equivocadas e fora do contexto.

Figura 5 - Conversa com o E-MANUEL

Iniciando assistente ...
chatbot: Olá, sou seu assistente virtual E-MANUEL e vou te ajudar com sua manutenção
chatbot: Com qual bomba trabalharemos hoje?
você: vou trabalhar com a ab-1234
chatbot: Eu encontrei AB1234, é esse que você quer?
você:

Fonte: Acervo pessoal

Os relatórios do Unitest mostraram que, para testes com a mesma entrada de usuário, mas diferentes bombas, as saídas, erros e acertos foram idênticos para as 10 bombas no banco de dados. Testes que falharam ocorreram em diálogos de busca pelo código, instruções de instalação, processo de desmontagem e checklist. A Figura 6 apresenta as taxas de resolução e relevância obtidas nos testes.

Tabela 6 - Distribuição dos testes e resultados

Função	Especificação	N° de testes	N° sucessos	N° erro relevante	N° não relevante
Busca de dados técnicos	Tamanho de rotor	40	40	0	0
	Velocidade de rotação	40	40	0	0
	Produto de trabalho	40	40	0	0
	Modelo de bomba	40	40	0	0
	Empresa fabricante	40	40	0	0
	código	40	20	0	20
Busca de dados de lubrificação	Frequência de troca	40	40	0	0
	fabricante	40	40	0	0
	Volume necessário	40	40	0	0
	Marca	40	40	0	0
Checklist	Checklist	40	30	10	0
Processos de manutenção	Instalação	40	20	20	0
	montagem	40	40	0	0
	desmontagem	40	30	0	10
	troca de rolamento	40	40	0	0
	desmontar cavalete	10	10	0	0
	falha de rolamento	20	10	0	10
	falha de lubrificação	20	20	0	0
	Total	**650**	**580**	**30**	**40**

Fonte: autoria própria

Observa-se que E-MANUEL obteve uma taxa de sucesso de 89,2%, e apenas em 6,2% das interações não foi capaz de atribuir resposta dentro do contexto esperado. As falhas ocorridas nas interações podem ser classificadas em: (a) interações durante o guia do processo de instalação da bomba; (b) frases muito suscintas do usuário nas quais E-MANUEL consegue correlacionar a entrada com múltiplas respostas. Para este projeto não foram utilizados métricas de qualidade textual e semântica por não se tratar de um chatbot generativo, ou seja, as respostas não são geradas e sim já estão prontas no chatbot.

Figura 6 - Distribuição dos Resultados dos Testes

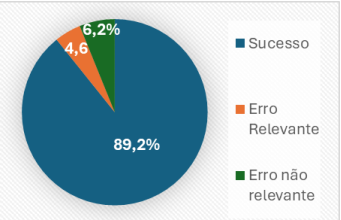

Fonte: autoria própria

Tempo de resposta do chatbot foi medido por meio da função *time()* da biblioteca *time* do Python. Esta medida foi realizada iterando simulações de entrada e saída e medindo a diferença entre o tempo de início e o tempo final da iteração.

Os testes de tempo foram realizados em um sistema PC Intel Core i5-7200U CPU 2.5GHz, Memória RAM 8GB, SO Windows 10, 64 bits. Os resultados foram separados de acordo com a categoria da interação. A Figura 7 apresenta o tempo de resposta do *chatbot* em interações de busca de dados no banco de dados. O tempo médio que o *chatbot* leva para retornar valores na busca de dados técnicos apresentam uma média de 1,34.

Figura 7 - Tempo de resposta para interações de busca por dados técnicos

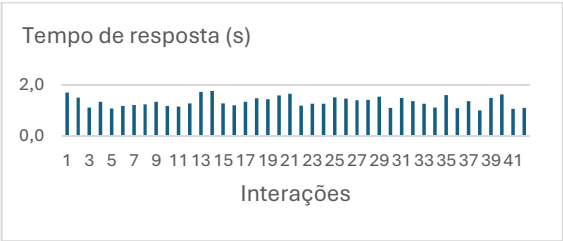

Os tempos de resposta obtidos para interações de *checklist* são apresentados no gráfico da Figura 8. O tempo médio de resposta em interações sobre checklist foi de 1,31 segundos.

Figura 8 - Tempo de resposta para interações sobre *checklist*

A Figura 9 apresenta tempos de resposta em interações de orientação ao usuário em ações de manutenção. Essas interações são as que apresentaram maior tempo de resposta, com um tempo médio de resposta de 1,43 segundos.

Figura 9 - Tempo de resposta para guiar o usuário em processos de manutenção

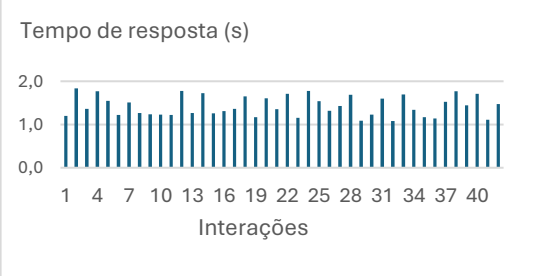

Fonte: autoria própria

6. CONCLUSÃO

A proposta de um sistema de suporte à equipe técnica de manutenção industrial foi implementada na forma de um *chatbot* e com um pequeno banco de dados. Os testes sobre as interações com o usuário mostraram que E-MANUEL obteve uma taxa de sucesso de 89,2%, e apenas em 6,2% delas não foi capaz de gerar resposta dentro do contexto esperado. Uma das principais funcionalidades do Chatterbot Python é a capacidade de treinar o *chatbot* com conjuntos de dados específicos. Porém, essa experiência precisa ser mais explorada no dominio da manutenção, uma vez que a base de diálogos para treinamento se mostrou restrita. Um dos motivos foi a indisponibilidade de um banco de dados industrial real. O outro motivo talvez seja pelo caráter da aplicação que se propõe a guiar o usuário a ações corretas e por isso o modelo não permita muitas variações nas respostas. A parte disso, Chatterbot se mostrou uma poderosa ferramenta com a possibilidade do *chatbot* ser melhorado de forma incremental à medida que novos diálogos expandam sua base de conhecimento. Por fim para uma melhor avaliação e aplicabilidade da ferramenta sugere-se uma futura parceria com indústrias para adequar E-MANUEL para uma situação real de aplicação.

REFERÊNCIAS

Adamopoulou, E. and Moussiades, L. (2020a). Chatbots: History, technology, and applications. *Machine Learning with Applications*, 2, 100006.

Adamopoulou, E. and Moussiades, L. (2020b). An overview of chatbot technology. In *IFIP International Conference on Artificial Intelligence Applications and Innovations*, volume 15, pages 373–383, Neos Marmaras. Springer.

Alhassan, N.A., Albarrak, A.S., Bhatia, S., and Agarwa, P. (2022). A novel framework for arabic dialect chatbot using machine learning. *Computational Intelligence and Neuro-science*, 2022, 1844051–11.

Binama, M., Muhirwa, A., and Bisengimana, E. (2016). Cavitation effects in centrifugal pumps-a review. *International Journal of Engineering Research and Applications*, 6(5), 52–63.

Cahn, J. (2017). *CHATBOT: Architecture, design, & development*. Senior thesis, University of Pennsylvania, School of Engineering and Applied Science, Department of Computer and Information Science, Philadelphia.

Carelli, A.C. and Maciel, M. da S. (2006). *Manutenção preditiva para tomada de decisão: um caso de bombas centrífugas industriais.* Trabalho de conclusão de curso, Universidade Federal do Rio de Janeiro, Escola de Química, Rio de Janeiro. Bacharelado em Engenharia Química.

Carvalho, T.P., Soares, F.A., Vita, R., Francisco, R.D.P., Basto, J.P. and Alcalá, S.G.A. (2019) systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 137, 106024.

Chang, C.Y., Hwang, G.J. and Gau, M.L. (2022) Promoting students' learning achievement and self-efficacy: A mobile chatbot approach for nursing training. *British Journal of Educational Technology*, 53(1), 171-188.

Chen, L., Wei, L., Wang, Y., Wang, J., and Li, W. (2022). Monitoring and predictive maintenance of centrifugal pumps based on smart sensors. *Sensors*, 22(6), 2106.

Cox, G. (2021). Chatterbot. About Chatterbot. Revisão 181c69f2. Disponível em <https://Chatterbot.readthedocs.io/en/stable/>. Acesso em: 31 Mar. 2023

He, M., and He, D. (2017). Deep learning based approach for bearing fault diagnosis. *IEEE Transactions on Industry Applications*, *53*(3), 3057-3065.

Hoang, D.T., and Kang, H.J. (2019). A survey on deep learning based bearing fault diagnosis. Neurocomputing, 335, 327-335.

Hussain, S., Al-Hashmi, S.H., Malik, M.H., and Kazm, S.I.A. (2023). Chatbot in e-learning. In *SHS Web of Conferences*, volume 156, pages 1002–5, Les Ulis. EDP Sciences.

Jardim, J.V.A., Riffel, D.B., and Moraes Costa, A.L. de (2016). Análise de falhas de uma bomba centrífuga. In *Anais do Congresso Nacional de Engenharia Mecânica*, page 0601, Fortaleza. CONEM.

Jetbrains S.R.O. (2024) *PyCharm, o IDE da JetBrains para Python em ciência de dados e desenvolvimento para web*. PyCharm. Disponível em <https://www.jetbrains.com/pt-br/PyCharm> Acesso em: 07 mar. 2024

KSB (2013). *Manual de serviço: KSB ETA*. Acesso em: 02 Fev 2024.

McKee, K., Forbes, G., Mazhar, I., Entwistle, R., and Howard, I. (2011). A review of major centrifugal pump failure modes with application to the water supply and sewerage industries. In *ICOMS Asset Management Conference*, Gold Coast. Asset Management Council. Acesso em: 13 abr. 2023.

Mengue, D.C. and Sellitto, M.A. (2013). Estratégia de manutenção baseada em funções de confiabilidade para uma bomba centrífuga petrolífera. *Revista Produção Online*, 13(2), 759—783.

Neumann, A.T., Arndt, T., Köbis, L., Meissner, R., Martin, A.,De Lange, P., Pengel, N., Klamma, R., and Wollersheim, H.-W. (2021). Chatbots as a tool to scale mentoring processes: Individually supporting self-study in higher education. *Frontiers in Artificial Intelligence*, 4, 668220.

Postgresql. (2024) *PostgreSQL: The World's Most Advanced Open Source Relational Database*. PostgreSQL Disponível em <https://www.postgresql.org/> Acesso em: 05 mar. 2024

Santos, A.F.C. dos, Bovério, M.A., and Silva, D.P. da (2023). Análise técnica de intervenção corretiva em bomba centrífuga. In *Anais do SITEFA*, page e614, Sertãozinho. Fatec Deputado Waldyr Alceu Trigo. Acesso em: 13 fev. 2024.

Serban, C., Sankar, and et al. (2017). A deep reinforcement learning chatbot. ArXiv, arXiv:1709.02349v2:40.

Silva, C.G. dos S.S. (2017). *Desenvolvimento de ferramenta gerencial para cálculo do índice de confiabilidade em manutenção de bombas centrífugas considerando os fatores humanos*. Dissertação, Escola Politécnica, Universidade Federal da Bahia, Salvador. Mestrado em Ciências em Engenharia Industrial.

Silva, T.A.F. and Nascimento, G.M. (2020). Importância da manutenção preditiva por análise de vibração num conjunto motor e bomba aplicado (um estudo de caso). In *Anais do Simpósio Nacional de Ciências e Engenharias (SINACEN)*, pag. 112–131, Anápolis. UniEVANGELICA.

Susto, G.A., Schirru, A., Pampuri, S., Mcloone, S. and Beghi, A. (2014) Machine learning for predictive maintenance: A multiple classifier approach. *IEEE transactions on industrial informatics*, 11(3), 812-820.

Theissler, A., Pérez-Velázquez, J., Kettelgerdes, M. and Elger, G. (2021) Predictive maintenance enabled by machine learning: Use cases and challenges in the automotive industry. *Reliability engineering & system safety*, 215, 107864.

Thin, K.C., Khaing, M.M., and Aye, K.M. (2008). Design and performance analysis of centrifugal pump. *World Academy of Science, Engineering and Technology*, 46(1), 422–429

Zhu, Z., Lei, Y., Qi, G., Chai, Y., Mazur, N., An, Y., and Huang, X. (2023) A review of the application of Deep Learning in intelligent fault diagnosis of rotating machinery. *Measurement*, 206, 112346.