



Microcredencial AI4RE

Syllabus e Guia de Estudo

Gunnar Harde, Matthias Herbert,
Simon Jimenez, Daniela Kreiner,
Michael Mey, Michael Tesar,
Franz Zehentner



Termos de uso

1. Indivíduos e provedores de treinamento podem usar este syllabus e o guia de estudos como base para seminários, desde que os direitos autorais sejam reconhecidos e incluídos nos materiais do seminário. Qualquer pessoa que utilize este syllabus e guia de estudo em publicidade precisa do consentimento por escrito do IREB para esse fim.
2. Qualquer indivíduo ou grupo de indivíduos pode usar este syllabus e guia de estudo como base para artigos, livros ou outras publicações derivadas, desde que os direitos autorais dos autores e do IREB e.V., como a fonte e o proprietário deste documento, sejam reconhecidos nessas publicações.

© IREB e.V.

Todos os direitos reservados. Nenhuma parte desta publicação pode ser reproduzida, armazenada em um sistema de arquivamento ou transmitida de qualquer forma, ou por qualquer meio, seja eletrônico, mecânico, fotocópia, ou gravação ou qualquer outro, sem a autorização prévia e por escrito dos autores ou do IREB e.V.

Agradecimentos

Este syllabus e guia de estudos foram escritos por: Gunnar Harde, Matthias Herbert, Simon Jimenez, Daniela Kreiner, Michael Mey, Michael Tesar, Franz Zehentner.

As revisões foram realizadas por: Rainer Grau e Ana Moreira.

Os comentários de revisão foram fornecidos por: Gareth Rogers e Christian Ploninger. Edição de texto por Stan Bühne e Stefan Sturm. Traduzido para a língua portuguesa por George Fialkovitz, Guilherme Siqueira Simões, Martin Tornquist, Thiago Cesar Andrade.

Agradecemos a todos pelo envolvimento.

Versão beta aprovada para release em 23 de outubro de 2025 pelo Conselho do IREB por recomendação de Ana Moreira. Versão 1.0.0 aprovada para release em XX de fevereiro de 2026 pelo Conselho do IREB por recomendação de Ana Moreira.

O copyright © 2025–2026 para este syllabus e guia de estudo é dos autores acima mencionados. Os direitos foram transferidos para o IREB International Requirements Engineering Board e.V.

Propósito deste documento

Este syllabus e guia de estudos definem o conteúdo da microcredencial **AI4RE (Artificial Intelligence for Requirements Engineering)** estabelecida pelo IREB. Ele serve a dois propósitos principais.

- Os alunos podem usar o syllabus e o guia de estudos para se prepararem para o exame e desenvolverem uma compreensão estruturada de como a Inteligência Artificial (IA) pode ser aplicada na Engenharia de Requisitos (ER).
- Os provedores de treinamento reconhecidos pelo IREB podem usar este syllabus e o guia de estudos como base para desenvolver ofertas oficiais de treinamento que se alinhem com os objetivos de aprendizado da microcredencial.

O syllabus e o guia de estudos garantem consistência e transparência tanto para os alunos autônomos quanto para os formatos de treinamento dos provedores de treinamento reconhecidos pelo IREB.

Conteúdo deste syllabus e do guia de estudos

Este syllabus e guia de estudos atendem às necessidades de todas as pessoas envolvidas no tópico de ER e que buscam apoio da IA para seu trabalho. Destina-se a qualquer pessoa envolvida em atividades de engenharia de requisitos, por exemplo, Engenheiros de Requisitos, analistas de negócios, product owners e gerentes de produtos.

Escopo do conteúdo

Este syllabus e guia de estudos foram elaborados para abordar o impacto crescente da inteligência artificial na ER. Ele reflete a perspectiva do IREB sobre práticas responsáveis de ER e uma visão orientada para a IA de como as ER podem se beneficiar da automação. Seu conteúdo abrange as tecnologias típicas de IA e suas áreas de aplicação, o pipeline de processamento por trás dos chatbots e os pontos fortes e as limitações específicas de abordagens como o ajuste fino e a geração aumentada por recuperação (RAG). Ele destaca as oportunidades em que as ferramentas de IA podem apoiar a elicitacão, a documentação, a validação e o gerenciamento de requisitos, ao mesmo tempo em que enfatiza a importância da supervisão humana para garantir resultados confiáveis e aponta as possíveis ameaças do uso da IA.

Nível de detalhe

O nível de detalhamento deste syllabus e do guia de estudos permite um aprendizado consistente em nível internacional. Para isso, o syllabus e o guia de estudos incluem:

- Objetivos educacionais gerais;
- Conteúdos com a descrição dos objetivos educacionais
- Referências a literatura adicional, quando necessário

Objetivos Educacionais/ Níveis de Conhecimento Cognitivo

Todos os módulos e objetivos educacionais deste syllabus e do guia de estudos são atribuídos a um nível cognitivo. Os níveis são classificados da seguinte forma:

- **L1: Conhecer** (descrever, enumerar, caracterizar, reconhecer, nomear, lembrar, ...)— lembrar ou recuperar material aprendido anteriormente.
- **L2: Compreender** (explicar, interpretar, completar, resumir, justificar, classificar, comparar, ...) — compreender/construir o significado a partir de materiais ou situações dados.



O nível cognitivo L2 inclui o nível cognitivo L1

Exemplo:

Um objetivo de aprendizagem do tipo "Compreender a técnica de ER xyz" está no nível de conhecimento cognitivo (L2). Entretanto, a capacidade de compreender exige que os alunos conheçam a técnica RE xyz (L1).

Estrutura do syllabus e guia de estudo

O syllabus e o guia de estudo consistem em 5 capítulos principais. Cada capítulo cobre uma unidade educacional (UE). O título de cada capítulo principal reflete seu nível cognitivo, definido pelo nível mais alto entre seus subcapítulos.

Exemplo: OE 3.1

Esse exemplo mostra que o objetivo educacional OE 3.1 está descrito no subcapítulo 3.1.

Além disso, há um capítulo sobre a terminologia principal, que é essencial para trabalhar com IA. Isso serve como referência para o leitor. Nos exames, esses termos podem ser usados no contexto de questões relacionadas a ER.

Histórico de versões

Version	Date	Comment
1.0.0	22 de Junho de 2026	Versão Inicial baseada no Syllabus original do IREB em inglês.

Sumário

1	Noções básicas de IA	7
1.1	Tecnologias-chave de IA e suas áreas de aplicação	7
1.2	Nos bastidores dos chatbots: do prompt à resposta e RAG versus ajuste fino	8
1.3	Principais conclusões	9
2	Large Language Models (LLMs)	10
2.1	O conceito fundamental dos LLMs	10
2.2	Principais conclusões	13
3	Engenharia de Prompt	14
3.1	A importância do contexto	14
3.2	Padrões e técnicas de prompting	15
3.3	Principais conclusões	17
4	Riscos e responsabilidades no AI4RE	18
4.1	Riscos no AI4RE	19
4.2	Responsabilidades no AI4RE	22
4.3	Principais conclusões	25
5	Casos de uso de IA na ER	26
5.1	Elicitação	27
5.1.1	Exploração de novos domínios	27
5.1.2	Transcrição da comunicação com os stakeholders	29
5.1.3	Extração de requisitos entre fontes	30
5.2	Documentação	31
5.2.1	Formulação de requisitos	31
5.2.2	Transformação de requisitos em outras representações	33
5.3	Validação	34

5.4	Painel de Controle	35
5.4.1	Atribuição de atributos a requisitos	35
5.4.2	Priorização de requisitos	36
5.5	Principais conclusões	36
6	Terminologia de IA	37
7	Referências	41

1 Noções básicas de IA

Nível: L2

Duração: 0,5 horas

Objetivo: os candidatos podem diferenciar os vários tipos de ferramentas e modelos de IA, entender como eles são desenvolvidos e implantados e conhecer os principais conceitos, como fluxo de informações, RAG e ajuste fino.

Objetivos Educacionais

OE 1.1 Conhecer a variedade de tecnologias de IA e suas áreas de aplicação – nem toda IA é um chatbot. (L1)

OE 1.2 Explicar o que acontece nos bastidores ao interagir com um chatbot, descrever o conceito de Geração Aumentada por Recuperação (RAG) e compará-lo com o ajuste fino. (L2)

1.1 Tecnologias-chave de IA e suas áreas de aplicação

A Inteligência Artificial abrange todos os métodos que permitem aos computadores perceber, raciocinar ou agir de uma forma que classificamos como inteligente. Dependendo do autor, você poderá encontrar diferentes categorizações de IA. Cinco aparecem em quase todas as taxonomias (para obter definições detalhadas, consulte o capítulo 6):

- **Machine learning (ML) / Deep learning:** Os algoritmos aprendem padrões diretamente dos dados.
- **Visão computacional:** A visão computacional transforma pixels brutos em fatos estruturados.
- **Processamento de linguagem natural (NPL):** A NPL inclui tudo o que transforma a fala ou o texto em significado e vice-versa. Isso também inclui Large Language Models (LLMs), discutidos mais detalhadamente no capítulo 2.
- **Robótica:** A robótica combina fusão de sensores (integração de dados de vários sensores), mapeamento (construção de uma representação do ambiente), planejamento de caminho (decisão de como se mover) e controle de feedback (ajuste de ações com base na entrada do sensor) para que as máquinas possam navegar e manipular o mundo físico de forma autônoma.
- **Sistemas especialistas:** Os sistemas especialistas capturam o conhecimento humano como regras e ontologias explícitas, produzindo respostas auditáveis e determinísticas.

Embora os chatbots baseados em IA sejam úteis para os Engenheiros de Requisitos elaborarem ou reformularem os requisitos, eles representam apenas uma parte do kit de ferramentas de IA. Recursos como transcrição de reuniões (conversão de fala em texto) e análise de interface do usuário (visão computacional) geralmente são integrados em uma única interface. Isso pode ser feito combinando modelos especializados de IA ou, cada vez mais, usando um único modelo multimodal.

1.2 Nos bastidores dos chatbots: do prompt à resposta e RAG versus ajuste fino

Os chatbots se tornaram os representantes mais conhecidos dos aplicativos modernos de IA. O objetivo deste capítulo é entender os estágios entre digitar um prompt e ver uma resposta, bem como distinguir o ajuste fino do RAG.

Um chatbot parece uma caixa preta. Uma solicitação passa por vários estágios de processamento, cada um contribuindo para a resposta que você finalmente recebe.

Conhecer esse fluxo nos bastidores ajuda a resolver respostas inesperadas, elaborar prompts mais precisos e definir requisitos de sistema realistas.

O pipeline simplificado a seguir pode variar um pouco entre os diferentes fornecedores de ferramentas, mas captura os estágios mais importantes.

- **Entrada:** O usuário envia um prompt com itens de contexto opcionais, como arquivos, imagens ou documentos adicionais. Se for usado em um bate-papo, todas as respostas anteriores serão adicionadas ao prompt como um pré-texto. Imagine que o chatbot não tenha memória e tenha que ler toda a conversa com cada entrada novamente.
- **Pré-processamento:** O sistema tokeniza o texto [SeHB2016], remove o conteúdo não seguro e normaliza o idioma (no caso de um tipo de entrada não textual, por exemplo, fala, o sistema também converterá essa entrada em texto).
- **Montagem do contexto:** O contexto do sistema (consulte 3.1) e o contexto da sessão (ou do usuário) são mesclados e formam o contexto final aplicável à conversa atual.
- **Inferência:** O sistema treinado, como um LLM, usa seu conhecimento aprendido para gerar uma saída ou fazer uma previsão a partir dos novos dados de entrada. É a fase de "tempo de execução" em que o modelo aplica o que aprendeu durante o treinamento. Na ER, a inferência ocorre quando um LLM processa um prompt contendo, por exemplo, requisitos propostos e, em seguida, gera um requisito reformulado ou identifica possíveis problemas com base em sua compreensão.
- **Pós-processamento:** O sistema converte tokens brutos em texto ou outros tipos de resultados (p. ex., fala ou imagens). Etapas opcionais, como verificadores de fatos, filtros de palavras ou regras de formatação, também podem ser aplicadas e variam muito entre os diferentes provedores de modelos de LLM.
- **Saída:** O sistema mostra o resultado para o usuário na janela de bate-papo.

Os provedores podem percorrer as etapas de montagem e inferência do contexto, chamar ferramentas adicionais ou fazer o acompanhamento com prompts de linha de raciocínio (consulte o capítulo 3.2) até que os critérios de qualidade sejam atendidos.

Na *montagem do contexto* da etapa, há dois meios de incorporar conhecimento adicional:

1. O **ajuste fino** incorpora o conhecimento adicional diretamente no modelo, tornando-o disponível para todas as interações futuras. Uma desvantagem desse método é que o modelo deve ser treinado novamente sempre que você adicionar novas informações, o que pode exigir muitos recursos. Além disso, a fonte do conhecimento

é mais difícil de identificar, uma vez que, após o ajuste fino, ela se torna parte do modelo.

2. O **RAG** utiliza um armazenamento de conhecimento separado que pode ser acessado com um mecanismo de busca acionado pelo modelo. Os dados/informações recém-adicionados ficam disponíveis instantaneamente, sem necessidade de retreinamento do modelo, e a fonte pode ser rastreada até o armazenamento de conhecimento.

O ajuste fino é excelente quando você pode investir em treinamento recorrente e precisa de respostas de baixa latência sem um repositório de conhecimento separado, mas corre o risco de se tornar desatualizado e não oferece citações de fontes integradas. O RAG mantém o conteúdo atualizado e rastreável.

Uma desvantagem é que o RAG introduz latência de pesquisa adicional e depende da qualidade do seu índice de recuperação, ou seja, as informações recuperadas só têm valor se forem de boa qualidade.

1.3 Principais conclusões

A IA tem muito mais a oferecer do que os chatbots. Para alguns casos de uso, os LLMs não são a ferramenta certa. Combinar a tarefa com a tecnologia de IA correta é fundamental para obter o melhor resultado possível; conhecer as possibilidades disponíveis é fundamental para usar todo o potencial da IA.

A adição de conhecimento ao seu chatbot atual pode ser feita por meio do ajuste fino e da incorporação do conhecimento no próprio modelo ou usando o RAG para ser mais flexível, adicionando conhecimento de fontes externas sob demanda.

2 Large Language Models (LLMs)

Nível: L1

Duração: 0,5 horas

Objetivo: Os candidatos podem afirmar que os LLMs são sistemas probabilísticos de previsão de texto e listar seus recursos e limitações comuns. Os candidatos sabem o que procurar ao interagir com os LLMs, lembram-se dos critérios para analisar seus resultados e listam os aspectos a serem considerados para sua integração responsável nos fluxos de trabalho.

Objetivos Educacionais

OE 2.1 Conhecer o conceito fundamental de como um LLM funciona em um nível elevado. (L1)

OE 2.2 Descrever como os LLMs funcionam, com base na previsão probabilística da próxima palavra e não com base no raciocínio ou na compreensão. (L2)

2.1 O conceito fundamental dos LLMs

O mecanismo central: previsão, não compreensão

Nos últimos anos, os Large Language Models [ZhWX2023] surgiram como uma classe de sistemas de IA capazes de processar e gerar textos semelhantes aos humanos. Eles são treinados em grandes quantidades de dados textuais e usam padrões estatísticos na linguagem para realizar tarefas como redigir documentos, resumir informações ou gerar casos de teste [VoFi2025]. Para um Engenheiro de Requisitos, compreender os recursos e as limitações dos LLMs é importante porque esses sistemas podem dar suporte a uma ampla gama de atividades de ER – desde a elicitação e a documentação de requisitos até a criação de glossários de domínio – ao mesmo tempo em que introduzem novos riscos e considerações [NoeA2024], [ZaDA2025].

Quando as pessoas experimentam um Grande Modelo de Linguagem pela primeira vez, as respostas podem parecer humanas. O texto é fluente, o tom se encaixa na pergunta e o resultado frequentemente parece demonstrar compreensão. A história real é mais simples: os LLMs são sistemas estatísticos de previsão de texto que geram uma palavra de cada vez com base em padrões aprendidos com dados de treinamento. Eles não entendem ou raciocinam – eles combinam padrões e continuam escrevendo. Dadas algumas palavras, eles escolhem o próximo segmento que é mais provável. Podemos pensar nisso como um autocompletar muito eficiente. Essa única ideia explica a maior parte de seu comportamento.

Geração probabilística e suas consequências

O modelo é treinado em uma grande quantidade de texto. Durante o treinamento, ele vê muitos exemplos de como as palavras se sucedem em diferentes situações, desde o bate-papo casual até a redação técnica. Seu objetivo nunca muda: para um determinado contexto, adivinhe o próximo token, que é um pequeno trecho de texto que pode ser uma palavra, parte de uma palavra ou pontuação.

Mais tarde, quando você fizer uma pergunta, o modelo usará o que aprendeu para continuar seu texto, um token por vez, cada escolha baseada em tudo o que veio antes.

Isso funciona bem porque a linguagem está repleta de padrões. A gramática cria uma estrutura, frases comuns se repetem em vários tópicos e muitos documentos seguem uma estrutura previsível. Se um sistema for muito bom em continuar esses padrões, o resultado parecerá coerente e relevante. Os modelos modernos usam uma arquitetura chamada de transformador [VaeA2017].

Uma parte importante desse processo, a autoatenção, ajuda o modelo a decidir quais partes de sua contribuição são mais importantes para a próxima etapa. É por isso que o modelo pode associar um pronome ao nome correto ou manter o controle de um tópico que foi introduzido muitas frases antes.

Implicações e modelos mentais para a Engenharia de Requisitos

O ponto importante é o que o sistema não está fazendo. Ele não está pensando como uma pessoa e não tem uma imagem interna do mundo. Não há intenção ou entendimento por trás das frases. O modelo reconhece e reproduz padrões que observou em muitos textos. Como esses padrões são ricos e variados, o resultado pode parecer uma compreensão, mas o mecanismo continua sendo uma previsão estatística.

No momento da geração, o modelo produz uma probabilidade para cada próximo token possível, considerando todo o contexto até o momento. Em seguida, ele escolhe um e o adiciona à saída. Às vezes, ele seleciona a opção principal, que tende a produzir um texto seguro e estável. Às vezes, ele coleta amostras da distribuição para adicionar variedade. Uma pequena quantidade de aleatoriedade pode ajudar a evitar respostas monótonas ou repetitivas. Em todos os casos, o texto visível é o resultado de muitas dessas pequenas decisões, cada uma delas uma escolha do próximo token com base no que já está lá.

Como esse é um processo probabilístico, o modelo pode cometer erros que ainda assim pareçam convincentes. Se você pedir que ele realize uma multiplicação longa, por exemplo, ele poderá gerar um número que parece razoável, mas está incorreto. Ele não o calculou. Ele simplesmente previu um número que segue estatisticamente o padrão de um problema de multiplicação, sem realizar o cálculo real. Para calcular corretamente as tarefas determinísticas, ou seja, tarefas que seguem um algoritmo claro, alguns modelos usam uma ferramenta em segundo plano [SceA2023], como uma calculadora ou um executor de código, enquanto o modelo de linguagem processa as instruções e a explicação. O modelo continua a prever o texto e usa a ferramenta para a tarefa determinística.

Às vezes, as pessoas pedem que um modelo mostre suas etapas [WeeA2022]. Isso pode melhorar os resultados em tarefas que se beneficiam da estrutura. O motivo é simples: o modelo viu muitos exemplos de explicações passo a passo em seus dados de treinamento (de livros didáticos, tutoriais, dados de perguntas e respostas), portanto, ele pode imitar esse formato. Os sistemas de raciocínio executam até mesmo etapas de planejamento privado antes de dar uma resposta. Eles redigem e revisam internamente e, em seguida, apresentam um resultado. Isso pode aumentar a qualidade, mas não altera o núcleo. O sistema ainda está prevendo o texto, apenas organizado em várias rodadas antes que você o veja.

Isso ajuda a separar duas camadas (superficial e factual) quando você lê o resultado do modelo. A *camada superficial* abrange a fluência, o tom e a estrutura, e geralmente é muito forte. Essas features são comuns nos dados e fáceis de reproduzir. A *camada factual* abrange datas, quantidades, nomes e casos extremos. É nesse ponto que a correspondência pura de padrões pode falhar. Se os dados de treinamento forem escassos ou inconsistentes em qualquer ponto, a continuação mais provável poderá se afastar da verdade. A conexão do modelo a mecanismos de pesquisa, bancos de dados ou chamadas de função aprimora essa camada porque a previsão do próximo token é baseada em informações novas ou computadas [LeeA2020]. O modelo ainda prevê, mas prevê com entradas melhores.

Para um Engenheiro de Requisitos, o modelo mental mais eficaz para uma IA é um autocompletar poderoso. Isso esclarece imediatamente seu papel: ele é um assistente de redação, não um especialista no domínio.

O modelo é altamente sensível a padrões, portanto, forneça um exemplo claro do resultado que você deseja que ele gere [BreA2020]. Se precisar de um requisito em um estilo específico, inclua um pequeno exemplo e peça ao modelo que o combine com o novo conteúdo. Isso muda as probabilidades para continuações que se encaixam em seu modelo e em seu estilo. Você pode até copiar várias histórias de usuários que escreveu no passado para definir o tom e a estrutura. Se você se preocupa com critérios de qualidade, como testabilidade, fraseologia inequívoca ou critérios mensuráveis, declare-os diretamente. O modelo geralmente inclui essas features porque instruções semelhantes ocorrem simultaneamente em seus dados de treinamento.

Na Engenharia de Requisitos, isso é importante tanto para a elaboração quanto para a revisão. Uma instrução vaga, como "escreva um requisito deste texto", convida a uma continuação vaga. Uma instrução precisa que inclua um modelo e uma definição clara do nível de detalhe esperado orienta o resultado em direção aos seus padrões. Você também pode solicitar que o modelo sinalize termos ambíguos e proponha alternativas mensuráveis. Normalmente, ele produzirá uma primeira passagem útil, pois já viu muitos exemplos de como as pessoas discutem clareza e medição.

Uma visão geral da base técnica: embeddings e vetores

Esses modelos não são determinísticos por padrão. Se você fizer a mesma pergunta duas vezes, poderá obter respostas diferentes devido à natureza probabilística de como eles geram o texto. Até mesmo uma única palavra em seu prompt pode levar o modelo a um caminho diferente e produzir um resultado muito diferente. Essa sensibilidade significa que o modelo pode ser desviado por um termo ou exemplo perdido e se afastar do que você deseja. No entanto, várias respostas diferentes podem ser respostas corretas e válidas para seu prompt.

Uma breve explicação sobre por que isso acontece. Quando o modelo escreve, ele nem sempre escolhe o próximo token mais provável. Ele coleta amostras de uma série de opções prováveis. A configuração que controla essa aleatoriedade é chamada de temperatura: uma temperatura baixa faz com que o modelo se atenha a escolhas mais seguras e óbvias, o que geralmente leva a respostas mais consistentes; uma temperatura mais alta permite que ele explore e varie mais, o que pode ser útil para o brainstorming, mas é menos estável.

Independentemente dessa variabilidade, você deve sempre tratar o resultado da IA como um rascunho que precisa ser revisado. Essa revisão serve a dois propósitos importantes: primeiro, identificar e descartar alucinações (informações factualmente incorretas que o modelo apresenta como verdadeiras [YeeA2023]) e, segundo, otimizar o resultado para seu contexto e requisitos específicos. O modelo não é confiável como uma calculadora – mesmo quando produz resultados consistentes, esses resultados ainda podem conter erros ou podem não corresponder perfeitamente às suas necessidades.

Essa perspectiva também esclarece o risco. Se o modelo fornecer um número incorreto ou citar o padrão errado, ele não está falhando na lógica. Ele está tendo sucesso na previsão no lugar errado. A solução é a verificação e o embasamento. Forneça o contexto correto em seu prompt, conecte o modelo a ferramentas de recuperação ou cálculo quando a precisão for importante e trate o resultado como um rascunho que precisa ser revisado. Nada disso exige que o modelo seja compreendido. É necessário apenas que você o guie em direção ao padrão correto e que conte com ferramentas e fontes em que os padrões por si só não são suficientes.

Se você estiver interessado em saber por que isso pode funcionar:

O modelo também representa tokens como vetores, que são longas listas de números. Os tokens que aparecem em contextos semelhantes obtêm vetores semelhantes. Isso cria um tipo de geometria que se alinha com o significado na prática. Um exemplo simples de métodos anteriores torna a ideia concreta. A diferença entre os vetores para rei e rainha tende a se assemelhar à diferença entre homem e mulher [MiSC2013]. O sistema não está armazenando entradas de dicionário; ele está aprendendo padrões numéricos que refletem como as pessoas usam as palavras.

É por isso que o modelo pode compreender o significado semântico. Os tokens que aparecem em contextos semelhantes recebem representações numéricas semelhantes, chamadas de embeddings. Na prática, isso significa que o vetor de "requisito do usuário" está mais próximo da "necessidade dos stakeholders" do que do "esquema do banco de dados". Isso permite que o LLM identifique requisitos semelhantes ou encontre dependências, mesmo quando uma terminologia diferente é usada.

2.2 Principais conclusões

Em resumo, este capítulo descreve os comportamentos fundamentais e a terminologia dos LLMs que influenciam sua aplicação na ER. Um Engenheiro de Requisitos que entende de prompts, tokens, alucinações, ajuste fino e conceitos relacionados, como embeddings e RAG, pode avaliar melhor quando e como empregar LLMs de forma eficaz, garantindo que os resultados gerados agreguem valor e não comprometam a qualidade dos requisitos.

3 Engenharia de Prompt

Nível: L2

Duração: 0,5 horas

Objetivo: os candidatos compreendem os fundamentos de prompting, incluindo critérios de qualidade, técnicas e padrões, e conseguem explicar como esses elementos influenciam a qualidade dos resultados gerados pela IA na ER.

Objetivos Educacionais

OE 3.1 Explicar a importância do contexto para produzir resultados precisos ao usar ferramentas baseadas em IA. (L2)

OE 3.2 Citar o objetivo geral dos padrões de prompt no ER e reconhecer como eles diferem das técnicas de prompting. (L1)

3.1 A importância do contexto

Grandes Modelos de Linguagem, como GPT, Claude, Gemini ou similares, geram texto prevendo o próximo token de saída mais provável. Isso não indica uma "compreensão" da entrada e da situação atual em uma conversa. Um contexto claramente definido restringe o espaço da solução e orienta o modelo para o conhecimento especializado do domínio, resultando em um resultado mais preciso e acionável.

Há duas camadas de contexto que moldam a qualidade dos resultados:

- **Contexto do sistema:** O contexto do sistema é fixo para cada sessão. Ele se origina do sistema ou do prompt inicial fornecido pelo criador do modelo, dos dados de treinamento do modelo e de suas configurações internas, como a temperatura, que controla a aleatoriedade do resultado. Esses fatores determinam aspectos como o idioma padrão, o tom das respostas e a data limite do conhecimento. Por exemplo, um modelo pode sempre responder em inglês, usar um estilo neutro e incluir apenas o conhecimento até uma determinada data. O contexto do sistema geralmente não pode ser alterado, mas pode ser complementado pela entrada do usuário. A capacidade de adicionar contexto é limitada pelo tamanho da janela de contexto, que define o número máximo de tokens – entrada e saída combinadas – que um modelo pode processar em uma única interação.
- **Contexto do usuário:** O contexto do usuário é dinâmico e muda a cada conversa ou mesmo a cada mensagem que você troca com um LLM. Isso pode incluir detalhes sobre o projeto ou produto, como um dispositivo médico em conformidade com a ISO 13485, um sistema bancário em conformidade com a PSD2 ou uma plataforma de e-learning. Também abrange a perspectiva dos stakeholders, como equipe de enfermagem, analistas financeiros ou estudantes, bem como os padrões e normas aplicáveis, como IEC 62304 [IEC62304], GDPR [GDPR2016], ou FDA 21 CFR Part 11 [FDA1997]. Além disso, o contexto do usuário pode definir o papel que a IA deve assumir (p. ex., "Você é um Engenheiro de Requisitos especialista"), especificar a finalidade da consulta (como gerar casos de teste ou validar requisitos) e fornecer material de apoio, como modelos ou exemplos.

Quando o contexto está ausente, o modelo se baseia exclusivamente em seus dados de treinamento e produz respostas com base na probabilidade estatística. Esse resultado pode parecer plausível, mas muitas vezes não tem relevância no domínio e valor prático. Em RE, isso geralmente significa que o resultado não é acionável nem tem qualidade suficiente.

3.2 Padrões e técnicas de prompting

Ao interagir com Grandes Modelos de Linguagem, a qualidade do resultado depende não apenas do contexto (o que o modelo deve saber), mas também de como as instruções são formuladas.

Padrões de Prompting

Os padrões de prompting são estruturas reutilizáveis que ajudam a formular prompts de forma consistente e eficaz.

Um padrão comum é o RTF (Role-Task-Format):

- **Papel:** Uma descrição da função que a IA deve assumir.
- **Tarefa:** O trabalho específico a ser realizado.
- **Formato:** A estrutura esperada da saída.

Exemplo:

Você é um analista de negócios profissional que cria resumos claros dos resultados de workshops.

Leia as notas do workshop a seguir e crie um resumo estruturado que destaque as metas, os insights, as decisões e as próximas etapas.

Apresente o conteúdo em forma de lista curta com marcadores concisos, sob títulos de seção claros.

Combinando esses três elementos, os usuários podem orientar o modelo para que ele se afaste de respostas genéricas e chegue a resultados mais precisos e acionáveis.

Existem muitos padrões desse tipo (consulte [WheA2023]). Alguns exemplos importantes são:

- **Linha de Raciocínio:** Peça à IA para explicar seu raciocínio passo a passo antes de fornecer o resultado final.
- **CRISPE:** padrão detalhado com contexto, papel, instruções, etapas, parâmetros e exemplos.

Benefícios dos padrões de prompting

Os padrões de prompting oferecem várias vantagens que melhoram a qualidade dos resultados da IA e a eficiência do processo de ER.

- **Benefícios práticos:** Padrões de prompting aumentam a usabilidade das respostas ao fornecer instruções claras desde o início. A definição do formato desejado reduz a necessidade de pós-processamento e economiza tempo. Os prompts bem

estruturados também reduzem o número de iterações necessárias para chegar a resultados úteis.

- **Benefícios cognitivos:** O uso de padrões de prompting força os usuários a pensar cuidadosamente sobre suas necessidades antes de solicitar a IA. Ao tornar explícitos o papel, a tarefa e o formato, a ambiguidade é minimizada e o raciocínio por trás de um prompt se torna transparente e reproduzível.
- **Benefícios metodológicos:** Os padrões de prompting podem ser reutilizados em diferentes tarefas, garantindo a consistência e reduzindo a curva de aprendizado para novos usuários. Dentro de uma equipe, eles criam um padrão compartilhado para trabalhar com IA. Quando combinadas com técnicas de prompting (veja abaixo), elas fornecem uma estrutura estável e flexibilidade situacional, levando a resultados mais confiáveis e adaptáveis.

Técnicas de prompting

As técnicas de prompts são maneiras situacionais de formular prompts. Ao contrário dos padrões, eles não prescrevem a estrutura, mas influenciam a forma como o modelo interpreta as solicitações:

- **Zero disparos:** uma solicitação sem fornecer exemplos

Exemplo:

Leia a transcrição da entrevista a seguir e crie um resumo conciso que destaque os principais tópicos, os principais argumentos e as declarações importantes. Evite interpretações pessoais.

Transcrição: [adicione a transcrição da entrevista aqui]*

* O texto entre colchetes [] é um espaço reservado para a entrada fornecida pelo usuário

- **Poucos disparos:** forneça alguns exemplos e, em seguida, faça sua solicitação

Exemplo:

Aqui estão dois exemplos de como converter requisitos em histórias de usuários

Requisito: "Pesquisar tarefas" → História do usuário: Como usuário, quero pesquisar tarefas para poder encontrar itens rapidamente.

Requisito: "Redefinir senha" → História do usuário: Como usuário, quero redefinir minha senha para que eu possa recuperar o acesso.

Agora sua tarefa:

Converta os seguintes requisitos em User Stories:

- Atribuir prioridades à tarefa
- Adicionar comentários a uma tarefa
- Filtrar tarefas por status

- **Baseado em templates:** fornece uma estrutura que a IA deve usar para seus resultados

Exemplo:

Leia as seguintes anotações do workshop e resuma os resultados. Use exatamente essa estrutura:

1. Título do workshop:
2. Data e participantes:
3. Principais objetivos: 3–5 pontos
4. Principais insights: lista com marcadores
5. Decisões tomadas: lista com marcadores
6. Perguntas abertas / Próximas etapas: lista com marcadores

Notas do workshop: [adicionar notas do workshop aqui]*

* O texto entre colchetes [] é um espaço reservado para a entrada fornecida pelo usuário

3.3 Principais conclusões

Os grandes modelos de linguagem preveem, mas não entendem. Na ER, os resultados confiáveis da IA dependem de um contexto preciso e completo. Sem contexto, os resultados recorrem a clichês e suposições; com um contexto rico, eles refletem a experiência no domínio. No entanto, um bom contexto por si só não é suficiente: a maneira como os prompts são elaborados determina a eficácia com que a IA pode usar esse contexto. Os padrões de prompting fornecem estruturas reutilizáveis, enquanto as técnicas de prompting refinam a interpretação e o estilo. Juntos, eles oferecem suporte a resultados consistentes e contextualizados, adaptados às necessidades dos stakeholders.

4 Riscos e responsabilidades no AI4RE

Nível: L2

Duração: 1 hora

Objetivo: Os candidatos podem explicar os riscos, as limitações e os requisitos de proteção de dados ao usar IA na ER e podem descrever os principais aspectos do uso responsável e em conformidade.

Objetivos Educacionais

OE 4.1 Citar os riscos típicos associados ao uso de IA na ER. (L1)

OE 4.2 Explicar a evolução do papel do Engenheiro de Requisitos em processos com suporte de IA. (L2)

A aplicação eficaz da IA na ER exige comprovação, validação e curadoria humanas abrangentes em todas as atividades apoiadas. Perguntas geradas por IA, entradas de glossário e conteúdo extraído exigem uma avaliação cuidadosa para garantir o alinhamento com o contexto do projeto e as necessidades dos stakeholders. Embora a IA possa identificar padrões de terminologia e processar transcrições de entrevistas, os resultados automatizados podem interpretar erroneamente conceitos específicos do domínio ou introduzir ambiguidades que comprometam o entendimento compartilhado (Princípio 3 do CPRE, [IREB2024]). O processo de validação torna-se particularmente crítico quando a IA processa comunicações escritas ou orais. Observações casuais e discussões especulativas exigem interpretação humana para distinguir requisitos genuínos de ideias preliminares que podem não justificar a documentação formal por meio de técnicas de elicitación estabelecidas (consulte o capítulo 4.2 em [GleA2024]).

Os resultados de IA baseados em templates, incluindo requisitos formatados e histórias de usuários, exigem uma verificação rigorosa para garantir a precisão semântica e o alinhamento dos stakeholders. Os requisitos gerados pela IA devem manter seu significado original e, ao mesmo tempo, aderir aos critérios de qualidade (consulte o capítulo 3.8 em [GleA2024]), apoiando a orientação para o valor (Princípio 1 do CPRE, [IREB2024]), em vez de alcançar uma mera conformidade formal. Da mesma forma, as representações visuais criadas pela IA, como protótipos e diagramas UML, exigem validação para confirmar que estão em um nível de abstração adequado (consulte o capítulo 3.1.2 em [GleA2024]) e alinhadas com a finalidade pretendida dos produtos de trabalho baseados em modelos (consulte o capítulo 3.4 em [GleA2024]), e não introduzem, por exemplo, nenhuma suposição prematura de design. Se os atributos e metadados dos requisitos forem atribuídos com a ajuda da IA, será necessário o julgamento humano para confirmar se os fatores críticos, como o valor de negócio e o status de aprovação dos stakeholders, foram avaliados corretamente. As atribuições propostas devem refletir com precisão o status do projeto e apoiar o gerenciamento eficaz de requisitos (consulte o capítulo 6.5 em [GleA2024]) e não devem resultar em informações enganosas.

4.1 Riscos no AI4RE

O uso de IA na ER oferece benefícios significativos, mas também introduz riscos específicos que podem afetar a precisão, a relevância e a confiabilidade dos resultados. Esses riscos decorrem tanto das limitações técnicas dos modelos de IA quanto da forma como são aplicados em contextos de ER. Compreender os riscos discutidos abaixo é essencial para os Engenheiros de Requisitos, pois permite que eles antecipem possíveis problemas, implementem estratégias de atenuação e mantenham a integridade do processo de requisitos.

Alucinações

Os LLMs podem produzir resultados plausíveis, mas factualmente incorretos, inventando detalhes ou referências que simplesmente não existem. Na ER, isso pode resultar em normas fabricadas, declarações de stakeholders ou comportamentos do sistema sendo tratados como requisitos válidos. O modelo não tem um conceito interno de "saber", portanto, não pode indicar quando está adivinhando ou quando não tem dados suficientes.

Exemplo:

A IA cita a "ISO 20258p" como uma diretriz de segurança, embora esse padrão não exista.

Falsa precisão

Alguns resultados de IA parecem formalmente corretos, mas são semanticamente sem sentido ou não verificáveis. Os requisitos redigidos em uma linguagem tecnicamente precisa ainda podem não ser testáveis ou ser ambíguos na prática.

Exemplo:

"O sistema deve ter um desempenho ideal em todos os momentos" pode parecer plausível, mas "ideal" é indefinido e "em todos os momentos" não é realista e não pode ser testado.

Amplificação do viés

Os modelos de IA podem reforçar ou ampliar os vieses presentes em seus dados de treinamento, levando a requisitos ou personas sistematicamente distorcidos. Isso pode introduzir injustiça ou discriminação no projeto do sistema se não for detectado.

Exemplo:

Em um projeto de requisitos de sistema de RH, a IA tem a tarefa de gerar personas para candidatos a emprego. Com base em dados históricos de recrutamento tendenciosos, ela descreve consistentemente os candidatos à liderança como homens, com idade entre 35 e 50 anos e com experiência em finanças. Esse viés, se não for corrigido, corre o risco de incorporar suposições discriminatórias em fluxos de trabalho de contratação automatizados e até mesmo violar leis de igualdade de oportunidades.

Vazamento de dados

Informações sensíveis ou confidenciais podem ser expostas de forma não intencional quando usadas com serviços externos de IA. Mesmo os dados anônimos podem ser identificáveis se combinados com outras fontes.

Exemplo:

Em um projeto de saúde, transcrições anônimas de entrevistas com pacientes são enviadas para um serviço de resumo de IA baseado em nuvem fora da União Europeia¹. A autoridade responsável pela proteção de dados determina posteriormente que combinações exclusivas de sintomas e datas de tratamento nas transcrições são suficientes para identificar pacientes individuais. Isso constitui uma violação do GDPR [GDPR2016] e resulta em uma multa muito alta.

Violações de propriedade intelectual

Os resultados da IA podem reproduzir material protegido ou confidencial de dados de treinamento ou de prompts anteriores, aumentando os riscos legais e contratuais.

Exemplo:

A IA produz uma especificação de requisitos que contém um texto literal do manual do produto de um concorrente.

Conhecimento desatualizado

Os modelos treinados com base em dados históricos podem operar já desatualizados, por exemplo, sem normas, tecnologias ou regulamentações recentes. Essa é uma limitação estática presente desde a implantação e é particularmente crítica em domínios regulamentados, onde requisitos desatualizados podem levar à não conformidade.

Exemplo:

A IA recomenda uma restrição que envolve um protocolo de rede que foi descontinuado há dois anos.

Model drift

Com o tempo, a precisão dos resultados de um sistema de IA pode diminuir devido à evolução do conhecimento do domínio, dos padrões de dados ou das condições operacionais. Esse é um risco dinâmico que aparece durante o uso. Sem monitoramento, esse desvio pode resultar em erros sutis, mas significativos.

¹ Embora os exemplos deste capítulo possam fazer referência a regulamentações da UE, eles têm caráter meramente ilustrativo e devem ser adaptados à estrutura jurídica e ao contexto cultural de cada projeto.

Exemplo:

Uma IA ajustada para conformidade bancária em 2023 começa a produzir recomendações desatualizadas após mudanças regulatórias em 2024.

Estouro da janela de contexto

Quando a quantidade de entrada excede a capacidade de contexto de um modelo, as informações anteriores podem ser descartadas, levando a resultados incompletos ou inconsistentes.

Exemplo:

Durante um workshop de elicitação de requisitos em grande escala, o modelo de IA (com um limite de contexto de 16.000 tokens) processa as anotações da reunião em tempo real. As declarações iniciais dos stakeholders sobre os requisitos de segurança são silenciosamente descartadas do resultado porque excedem a capacidade de contexto do modelo, resultando em especificações incompletas e na omissão de features críticas de segurança.

Desalinhamento com o escopo

A IA pode gerar requisitos que estejam fora do escopo do projeto ou que entrem em conflito com as metas acordadas, principalmente se os prompts forem vagos ou incompletos.

Exemplo:

Ao elaborar requisitos para um aplicativo móvel, a IA começa a propor features para uma versão de desktop que nunca foi planejada. A equipe de desenvolvimento passa vários dias analisando essas features irrelevantes antes de perceber que eles estão fora do escopo, atrasando a fase de design acordada.

Dependência excessiva na IA

Confiar demais nos resultados de IA sem a validação humana adequada pode levar ao aceite de requisitos falhos ou tendenciosos, reduzindo a qualidade geral e aumentando o risco do projeto.

Exemplo:

Uma equipe de projeto do setor automotivo adota requisitos de segurança gerados por IA para uma feature de direção autônoma sem a devida revisão humana. Meses depois, durante a inspeção regulatória, os auditores descobrem que vários requisitos contradizem os padrões de segurança obrigatórios, forçando um redesenho dispendioso e atrasando o lançamento do produto.

Opacidade

Muitos modelos de IA funcionam como caixas-pretas, dificultando o rastreamento de como os resultados específicos foram obtidos. Na ER, essa falta de transparência pode minar a confiança dos stakeholders e complicar a validação dos requisitos.

Exemplo:

A IA propõe a priorização de determinados requisitos, mas não consegue explicar a lógica da classificação, o que dificulta a revisão.

Obrigações de transparência

Regulamentações como a Lei de IA da UE [EUIA2026] introduzem um requisito legal de divulgação quando o conteúdo é gerado por uma IA, embora essas regras sejam bastante específicas e não se apliquem a todos os resultados. Isso cria um risco de conformidade se as equipes publicarem determinados tipos de resultados de IA sem os rótulos necessários ou controle.

Para a saída de texto, que é comum na ER, a obrigação de rotular o conteúdo como gerado por IA se aplica especificamente quando o texto se destina a informar o público sobre assuntos de interesse público. A maioria dos artefatos típicos de ER, como especificações internas, histórias de usuários ou itens do backlog, não se enquadraria nessa categoria.

A divulgação também não é necessária se o resultado gerado pela IA tiver sido submetido a um processo de revisão humana e uma pessoa ou organização assumir a responsabilidade editorial por sua publicação. Em um contexto de ER, isso se alinha ao princípio de que um Engenheiro de Requisitos, Product Owner ou outro stakeholder deve sempre validar e assumir a responsabilidade pelos requisitos antes de serem aceitos.

Exemplo:

Uma equipe usa uma IA para gerar um relatório publicado a partir de um conjunto de requisitos aprovados, detalhando como seu novo software financeiro está em conformidade com os regulamentos de transparência do governo. Este relatório é um assunto de interesse público. Se o relatório fosse publicado automaticamente sem que um diretor de conformidade ou líder de projeto o revisasse e assumisse a responsabilidade oficial por seu conteúdo, provavelmente violaria as leis de transparência de IA. A organização poderia sofrer penalidades legais por apresentar uma análise gerada por IA em um assunto público sem a divulgação necessária ou a supervisão humana.

4.2 Responsabilidades no AI4RE

A introdução da IA nos processos de ER não substitui o Engenheiro de Requisitos; em vez disso, ela *amplia e aprofunda* o papel.

[DDOS2024] O Engenheiro de Requisitos agora atua não apenas como elicitador, documentador e validador de requisitos, mas também como *regulador de processos apoiados por IA*, garantindo que os resultados sejam relevantes, confiáveis, explicáveis e em conformidade com as regras e os padrões éticos aplicáveis.

Os principais aspectos do papel ampliado incluem:

Designer de processos de IA, integrador e colaborador técnico

O Engenheiro de Requisitos contribui para a seleção de ferramentas de IA, define sua integração no processo de ER e colabora estreitamente com as equipes técnicas (p. ex., desenvolvedores de IA, cientistas de dados, TI) para garantir que as ferramentas sejam configuradas, treinadas e mantidas adequadamente. Isso inclui a avaliação de sua adequação a tarefas específicas de ER (p. ex., classificação, resumo, verificações de qualidade) e o alinhamento dos formatos de entrada/saída com os padrões de modelagem e documentação.

Exemplo:

Selecionar um LLM para remover duplicatas de requisitos, integrá-lo ao repositório da equipe e definir regras sobre como as duplicatas são sinalizadas e revisadas.

Design de prompting e revisor de qualidade

O Engenheiro de Requisitos elabora e refina os prompts que orientam a IA em direção a resultados relevantes, precisos e sensíveis ao contexto e, em seguida, avalia criticamente esses resultados em relação ao conhecimento do domínio, às necessidades dos stakeholders e aos critérios de qualidade. Isso garante que as sugestões de IA nunca sejam adotadas sem verificação humana.

Exemplo:

Desenhar um template de prompt para gerar critérios de aceite que inclua explicitamente limites de desempenho e rejeite qualquer requisito gerado por IA que não seja testável.

Gerente de risco e conformidade

O Engenheiro de Requisitos identifica e reduz os riscos legais, éticos e operacionais do uso de IA, desde a proteção de dados pessoais e a prevenção de preconceitos até a garantia de que os resultados atendam aos requisitos regulamentares e contratuais. Isso inclui escolher opções de processamento (p. ex., local vs. nuvem), garantir a minimização dos dados e detectar desvios do modelo.

Exemplo:

Pseudonimização do feedback dos stakeholders antes de fazer o upload para um serviço de IA hospedado fora da jurisdição e verificar rotineiramente se a IA ainda está produzindo sugestões em conformidade com a regulamentação.

Impacto ambiental do uso de IA

A IA generativa tem um impacto ambiental, principalmente devido à energia necessária para treinar e operar modelos grandes. Embora muitos desses fatores estejam fora do controle direto dos Engenheiros de Requisitos, a maneira como a IA é selecionada e usada no processo de ER pode influenciar o consumo de energia. O uso irrefletido ou desnecessariamente intensivo de ferramentas de IA, portanto, introduz riscos ambientais, de reputação e de governança para projetos e organizações.

Exemplo:

Uma equipe de projeto planeja executar um LLM continuamente em segundo plano para monitorar e reclassificar todos os requisitos em tempo real. O Engenheiro de Requisitos identifica que esse padrão de uso "sempre ativo" consumiria muito mais energia do que uma abordagem de processamento em lote programado, com poucos benefícios adicionais. Ao recomendar o processamento em lote, o Engenheiro de Requisitos reduz o impacto ambiental e ainda atende às necessidades analíticas da equipe.

Comunicador com os stakeholders e construtor de confiança

Criar confiança significa não apenas compartilhar os resultados apoiados pela IA, mas também tornar ativamente transparente o que pode e o que não pode ser explicado e os motivos por trás desses limites. O Engenheiro de Requisitos garante que os stakeholders sejam informados de forma transparente sobre o uso da IA, seu papel no processo de ER, seus benefícios e suas limitações.

Isso inclui facilitar o aprendizado, a negociação e a formação de consenso entre os stakeholders. Essas atividades centradas no ser humano são essenciais para qualquer processo de ER e requerem atenção especial quando partes do processo são automatizadas ou aceleradas usando IA.

Um aspecto fundamental desse papel é tornar explicáveis os resultados apoiados pela IA [DDOS2024], e rastreáveis, além de criar espaço para discussão quando surgirem preocupações ou reservas éticas sobre o uso da IA. Criar confiança significa abordar essas questões explicitamente em vez de evitá-las.

Exemplo:

Em um workshop de elicitação de requisitos, o Engenheiro de Requisitos explica quais etapas são assistidas por IA, explica o raciocínio por trás das sugestões geradas por IA e observa quaisquer limitações em sua capacidade de explicação. Os stakeholders são convidados a expressar suas preocupações, questionar os resultados apoiados pela IA e discutir estratégias para lidar com dados confidenciais e possíveis limitações da IA no projeto.

4.3 Principais conclusões

A IA intensifica, e não substitui, o pensamento crítico na ER. O Engenheiro de Requisitos deve reconhecer e reduzir os riscos, avaliar criticamente os resultados da IA e garantir que somente os resultados validados entrem no baseline dos requisitos. Além do monitoramento, o Engenheiro de Requisitos assume um papel estratégico: projetar processos com suporte de IA, proteger a conformidade e documentar as decisões para fins de auditoria. A competência tecnológica, o conhecimento do domínio e o julgamento humano continuam sendo decisivos para garantir que a IA aumente o valor e promova a confiança dos stakeholders.

5 Casos de uso de IA na ER

Nível: L2

Duração: 2,5 horas

Objetivo: Os candidatos podem explicar como as ferramentas de IA podem apoiar as atividades de ER, descrever suas limitações e esclarecer a necessidade de validar os resultados gerados pela IA.

Termos: Elicitação, documentação, validação, gerenciamento, exploração, transcrição, extração, contexto do sistema, formulação, transformação, precisão semântica, critérios de qualidade

Objetivos Educacionais

OE 5.1 Citar os casos de uso típicos de IA na elicitação, documentação, validação e gerenciamento de requisitos. (L1)

OE 5.2 Explicar a importância da curadoria humana dos resultados de IA na ER e descrever a função do Engenheiro de Requisitos para garantir resultados válidos. (L2)

O advento das tecnologias de IA apresenta novas oportunidades para apoiar os Engenheiros de Requisitos em suas atividades principais. No entanto, é fundamental entender que a IA serve como uma ferramenta de apoio e não como um substituto para a experiência e o julgamento humanos no trabalho de ER.

As tecnologias de IA podem auxiliar os Engenheiros de Requisitos nas quatro principais atividades de ER: elicitação, documentação, validação e gerenciamento de requisitos [IREB2024]. Eles oferecem o potencial de acelerar as tarefas, ampliar as perspectivas e aprimorar as verificações de consistência. Este capítulo explora casos de uso ilustrativos para cada atividade, ao mesmo tempo em que ressalta que os resultados gerados pela IA devem passar por uma análise humana cuidadosa. Em última análise, o Engenheiro de Requisitos é responsável por garantir que esses resultados sejam relevantes, metodologicamente sólidos e alinhados aos objetivos do projeto e aos padrões de qualidade.

A aplicação adequada da IA na ER exige um entendimento completo dos recursos e das limitações dessas tecnologias. Os Engenheiros de Requisitos devem desenvolver a competência para avaliar criticamente os resultados da IA, reconhecendo onde eles agregam valor, mas também onde podem introduzir riscos ou imprecisões. Ao trabalhar de forma prática com ferramentas de IA, todos os princípios, práticas e critérios de qualidade estabelecidos nos capítulos anteriores deste documento permanecem totalmente aplicáveis e devem ser cuidadosamente considerados. Para obter informações abrangentes sobre conceitos e práticas fundamentais de ER, consulte o syllabus do CPRE Foundation Level [IREB2024] e o Handbook que o acompanha [GleA2024].

Observe que você pode encontrar exemplos práticos adicionais sobre a implementação do suporte de IA nas práticas de ER no booklet do #AIREB Special Interest Group [IREB2025] e no AI4RE Prompt Guide [IREB2026].

5.1 Elicitação

A elicitación está no centro da ER. Envolve a coleta, a interpretação e a estruturação de informações de fontes como stakeholders, documentos e sistemas para entender o que um sistema deve alcançar. Esse processo não se limita a fazer perguntas: ele requer escuta ativa, compreensão do contexto e capacidade de traduzir as informações informais em requisitos formais e acionáveis.

Há três áreas na elicitación em que a IA pode oferecer suporte eficaz:

- **Exploração:** Antes que os requisitos possam ser extraídos, os Engenheiros de Requisitos devem primeiro entender o domínio, os objetivos, os stakeholders e as restrições. As ferramentas de IA podem dar suporte a isso, resumindo o conhecimento do domínio, identificando grupos de stakeholders e ajudando a preparar guias de entrevistas estruturadas e workshops. Essa exploração inicial garante que os esforços de elicitación sejam bem-informados e focados.
- **Transcrição:** As entrevistas e workshops com os stakeholders geram dados qualitativos valiosos que devem ser capturados com precisão. A transcrição assistida por IA converte o diálogo falado e os artefatos visuais em formatos estruturados e pesquisáveis, reduzindo o esforço manual e melhorando a rastreabilidade. Isso ajuda a garantir que insights valiosos sejam registrados e acessíveis para análise posterior.
- **Extração:** Uma vez documentada a entrada dos stakeholders, a próxima etapa é extrair requisitos claros e acionáveis. A IA pode ajudar a identificar e categorizar os requisitos funcionais, os atributos de qualidade e as restrições a partir de dados brutos, como anotações de reuniões, e-mails ou transcrições. O agrupamento desses requisitos por tópico ou área de features ajuda ainda mais a esclarecer as prioridades e dependências.

Juntas, essas atividades constituem uma abordagem abrangente para a elicitación, combinando experiência humana com suporte de IA para aumentar a eficiência, a cobertura e a qualidade.

5.1.1 Exploração de novos domínios

A fase exploratória da RE estabelece as bases para todas as atividades subsequentes de RE, ao desenvolver uma compreensão abrangente do domínio, dos stakeholders e do contexto operacional antes do início formal da coleta de requisitos. A IA pode acelerar essa fase crítica apoiando as atividades de pesquisa, ampliando as perspectivas analíticas e estruturando as abordagens de envolvimento dos stakeholders, embora seus resultados sirvam apenas como pontos de partida e exijam validação por meio de conhecimento humano e interação direta com os stakeholders.

A IA pode resumir a documentação interna e as fontes disponíveis publicamente para fornecer visões gerais do domínio, abrangendo objetivos, terminologia, desafios e contextos regulatórios, além de analisar as estruturas organizacionais para possíveis grupos de stakeholders que, de outra forma, poderiam ser ignorados.

Ele pode gerar guias de entrevistas estruturadas com perguntas abertas adaptadas para conversas exploratórias e auxiliar na organização de workshops de requisitos, identificando os principais tópicos, os papéis dos stakeholders e as possíveis áreas de conflito ou alinhamento. Esses recursos demonstram como a IA pode aprimorar o trabalho exploratório dos Engenheiros de Requisitos, melhorando a eficiência da pesquisa e a cobertura dos stakeholders. No entanto, o verdadeiro valor depende do uso dessas ferramentas como catalisadores para uma investigação mais profunda, e não como substitutos do pensamento crítico e do envolvimento dos stakeholders, que são essenciais para estabelecer um entendimento compartilhado (Princípio 3 do CPRE, [IREB2024]).

Identificação do contexto do sistema

A IA pode melhorar significativamente a identificação dos elementos do contexto do sistema descritos no CPRE Foundation Level Syllabus (Princípio 4 do CPRE, [IREB2024] e [GleA2024]). Quando artefatos como listas de stakeholders, diagramas de contexto do sistema, descrições de processos ou organogramas estão disponíveis, a IA pode extrair as informações relevantes e classificá-las de acordo com os cinco aspectos principais (stakeholders, documentos, sistemas, processos e eventos), além de revelar relacionamentos e dependências entre as fontes. Isso ajuda os Engenheiros de Requisitos a formar uma visão abrangente dos limites do sistema e do contexto e reduz o risco de perder elementos essenciais.

Como alternativa, a IA pode gerar listas de perguntas estruturadas e listas de verificação projetadas especificamente para obter informações dos stakeholders sobre cada um dos cinco aspectos do contexto do sistema. Esses instrumentos gerados pela IA podem servir como ferramentas abrangentes de elicitación durante as entrevistas ou workshops com os stakeholders, garantindo a cobertura sistemática de todas as dimensões do contexto. A IA pode adaptar as perguntas para domínios ou tipos de sistemas específicos, incorporando as melhores práticas das técnicas de elicitación de requisitos (consulte o capítulo 4.2 em [GleA2024]) e, ao mesmo tempo, mantendo a consistência com os critérios de qualidade estabelecidos para os produtos de trabalho (consulte o capítulo 3.8 em [GleA2024]).

Estabelecimento de um entendimento compartilhado

O estabelecimento de um entendimento compartilhado (Princípio 3 do CPRE, [IREB2024]) depende fundamentalmente do uso consistente da terminologia entre todos os participantes do projeto. Os glossários (consulte o capítulo 3.5 em [GleA2024]) funcionam como coleções centrais de definições que reduzem o risco de má interpretação e garantem que os stakeholders, os Engenheiros de Requisitos e os desenvolvedores operem com a mesma base conceitual. A IA pode acelerar significativamente a criação e a manutenção de glossários abrangentes, analisando a documentação existente do projeto, as comunicações dos stakeholders e os materiais específicos do domínio para identificar os termos que precisam de definição. A IA pode detectar o uso inconsistente da terminologia em diferentes documentos, sinalizar possíveis homônimos (os mesmos termos usados para conceitos diferentes) e sugerir sinônimos que devem ser padronizados.

Além disso, a IA pode propor definições iniciais com base na análise contextual de como os termos são usados no ambiente do projeto, fornecendo aos Engenheiros de Requisitos um ponto de partida sólido para o desenvolvimento do glossário.

5.1.2 Transcrição da comunicação com os stakeholders

A comunicação eficaz com os stakeholders forma a base de uma ER bem-sucedida. No entanto, capturar e preservar insights de entrevistas e workshops pode ser um desafio se informações valiosas surgirem em formatos informais e não estruturados. A conversão de diálogos falados e artefatos visuais em documentação estruturada e editável ajuda a garantir que as informações essenciais sejam preservadas e tenham disponibilidade para análise, validação e integração em processos formais de engenharia de requisitos. Isso favorece a rastreabilidade e o alinhamento da equipe, que são essenciais para o sucesso de um projeto.

As ferramentas de transcrição baseadas em IA podem aprimorar significativamente esse processo de conversão, gerando transcrições a partir de gravações de entrevistas com stakeholders, limpando o texto bruto e resumindo os principais pontos de discussão.

Isso pode acelerar a transição da conversa para a documentação formal dos requisitos. Para workshops colaborativos, a IA pode transcrever o conteúdo do quadro branco, notas adesivas e esboços em formatos estruturados que facilitam o compartilhamento e o refinamento colaborativo, o que é particularmente valioso em ambientes de desenvolvimento ágeis ou distribuídos. Esses recursos dão suporte à criação de requisitos transparentes e rastreáveis e reduzem o esforço de documentação manual. Ao mesmo tempo, os resultados gerados pela IA devem ser cuidadosamente revisados e refinados pelos Engenheiros de Requisitos para garantir a precisão, a integridade e o alinhamento com as intenções dos stakeholders e as metas do projeto.

Processamento de entrevistas com stakeholders e gravações de áudio

A IA generativa [FHJZ2024] pode aumentar substancialmente a eficiência da elicitação de requisitos por meio da transcrição automatizada de entrevistas com stakeholders, transformando gravações de áudio em texto estruturado que facilita a análise e a documentação sistemáticas. Esse recurso permite que os Engenheiros de Requisitos se concentrem inteiramente na dinâmica da entrevista e no envolvimento dos stakeholders durante as sessões de elicitação (consulte o capítulo 4.2 em [GleA2024]), em vez de dividir a atenção entre a escuta ativa e a tomada de notas. Os serviços de transcrição de IA podem identificar diferentes locutores, marcar o tempo das conversas e até mesmo destacar possíveis declarações de requisitos ou terminologias importantes que possam justificar a inclusão em glossários de projetos (consulte o capítulo 3.5 em [GleA2024]).

Análise de entrevistas transcritas

Além disso, a IA pode analisar entrevistas transcritas para extrair requisitos preliminares, identificar as preocupações dos stakeholders e sugerir perguntas de acompanhamento que se alinham às técnicas sistemáticas de elicitação, como os métodos de questionamento ou as técnicas de colaboração descritas em [GleA2024] e no capítulo 4.2.

5.1.3 Extração de requisitos entre fontes

Análise de e-mails, bate-papos, atas de reuniões e tópicos de colaboração

A IA pode analisar sistematicamente e-mails, bate-papos, atas de reuniões e tópicos de colaboração para revelar conteúdo relevante para os requisitos, que muitas vezes passa despercebido nesses canais informais. Essa extração automatizada fortalece a identificação da fonte de requisitos (consulte o capítulo 4.1 em [GleA2024]), capturando requisitos implícitos, preocupações dos stakeholders e dicas contextuais de comunicações em andamento. A IA pode classificar itens por tipo (requisitos funcionais, requisitos de qualidade e restrições), detectar conflitos entre declarações formais e informais e sinalizar inconsistências com documentos oficiais. Isso é especialmente valioso em ambientes ágeis, em que os requisitos evoluem por meio da interação contínua com os stakeholders e do feedback informal.

Analisando documentos existentes e requisitos de referência cruzada

Além disso, a IA generativa [FHJZ2024] pode analisar sistematicamente documentos existentes de várias fontes (consulte o capítulo 4.1 em [GleA2024]), inclusive documentação de processos de negócios, documentos regulatórios, especificações de sistemas legados e relatórios de análise de mercado.

Em seguida, ele pode identificar os requisitos explícitos e implícitos que podem estar incorporados nesse material. A IA pode processar vários formatos de documentos simultaneamente e extrair possíveis requisitos funcionais, requisitos de qualidade e restrições, categorizando-os de acordo com a estrutura de classificação de requisitos descrita em [GleA2024], capítulo 1.1. A IA também pode cruzar os requisitos extraídos com o escopo do projeto e os limites do sistema para garantir sua relevância. Além disso, ele pode identificar as relações entre os requisitos encontrados em diferentes documentos de origem. Essa extração automatizada oferece suporte a uma cobertura abrangente das fontes de requisitos além das contribuições diretas dos stakeholders, ajudando a garantir que o conhecimento organizacional documentado e as obrigações regulatórias sejam devidamente capturados na especificação de requisitos.

Analisar padrões e fornecer sugestões para investigação adicional

A IA pode analisar padrões nas entradas extraídas dos stakeholders para identificar possíveis lacunas nos requisitos, suposições implícitas ou aspectos do sistema negligenciados que os stakeholders podem ter considerado evidentes, mas não conseguiram articular explicitamente. Ao comparar as declarações dos stakeholders com frameworks de requisitos abrangentes e listas de verificação específicas do domínio, a IA pode sugerir áreas para investigação adicional e propor perguntas que ajudem a obter requisitos subconscientes, conforme descrito no modelo Kano (consulte o capítulo 4.2 em [GleA2024]). A IA também pode identificar inconsistências entre as diferentes perspectivas dos stakeholders: estas podem indicar requisitos em falta ou conflitos não resolvidos que requerem atenção através de técnicas de resolução de conflitos (ver capítulo 4.3, em [GleA2024]). No entanto, o Engenheiro de Requisitos deve validar todos os insights gerados pela IA por meio de processos sistemáticos de engajamento e verificação dos stakeholders.

Eles devem garantir que as lacunas identificadas sejam requisitos genuínos e não suposições de IA; que esses requisitos representem, de fato, os desejos e as necessidades reais dos stakeholders (Princípio 2 do CPRE, [IREB2024]) e não apenas uma completude teórica.

5.2 Documentação

Após a exploração do domínio, a transcrição e a extração dos requisitos, o próximo desafio é expressá-los de forma precisa e clara. Isso envolve duas atividades intimamente ligadas:

- **Formulação:** A formulação se concentra na estruturação dos requisitos usando formatos padronizados e critérios de qualidade. Sejam expressos como declarações no estilo IEEE, casos de uso ou histórias de usuários, os requisitos bem formulados melhoram a clareza, a comparabilidade e a rastreabilidade. As ferramentas de IA podem ajudar na seleção de um formato apropriado, no refinamento da linguagem e na decomposição de requisitos complexos em subelementos acionáveis. Além disso, as tabelas de sinônimos geradas pela IA podem ajudar a manter a consistência em toda a documentação, especialmente em domínios com terminologia especializada.
- **Transformação:** A transformação, por outro lado, garante que os requisitos sejam compreensíveis e utilizáveis em diversos grupos de stakeholders e contextos técnicos. Isso inclui a reescrita de requisitos em linguagem simples, a adaptação de resumos para públicos específicos e a conversão entre formatos, como a geração de modelos a partir de texto ou vice-versa.

A IA também oferece suporte à criação de personas a partir das informações dos stakeholders, à geração de casos de teste a partir dos requisitos e até mesmo à comparação das especificações com o código-fonte para validar a implementação. Por outro lado, a IA pode ajudar a extrair requisitos das bases de código existentes, apoiando a documentação e os esforços de modernização.

Juntas, a formulação e a transformação preenchem a lacuna entre a precisão técnica e a compreensão dos stakeholders. Eles garantem que os requisitos não sejam apenas corretos e completos, mas também utilizáveis, testáveis e alinhados aos objetivos de negócio.

5.2.1 Formulação de requisitos

A fase de formulação transforma a entrada bruta dos stakeholders em declarações de requisitos claras e estruturadas, adequadas para implementação e validação. As ferramentas de IA podem aprimorar significativamente esse processo, apoiando a padronização, mantendo a consistência terminológica e decompondo requisitos complexos em componentes gerenciáveis que se alinham às práticas de ER estabelecidas.

Aplicação de templates IEEE padronizados e templates de frases

A IA generativa [FHJZ2024] pode dar suporte aos Engenheiros de Requisitos que usam templates IEEE padronizados e templates de frases (consulte o capítulo 3.3 em [GleA2024]), estruturando automaticamente as declarações de requisitos de acordo com padrões sintáticos e diretrizes de formatação estabelecidos.

A IA pode analisar as entradas informais dos stakeholders ou as descrições preliminares de requisitos e transformá-las em requisitos individuais devidamente formatados que seguem os padrões do IEEE, como o ISO/IEC/IEEE 29148, garantindo uma estrutura consistente e melhorando a qualidade geral da especificação.

Eliminação de armadilhas comuns

A IA pode sugerir cláusulas condicionais apropriadas, especificar critérios mensuráveis e, na redação técnica, (consulte o capítulo 3.2 em [GleA2024]) pode ajudar a eliminar armadilhas comuns, como voz passiva, quantificadores universais ou descrições incompletas. Esse suporte automatizado à formatação permite que os Engenheiros de Requisitos se concentrem na validação do conteúdo e no alinhamento dos stakeholders, em vez de perder tempo com correções de estilo. Ele garante que todos os requisitos sigam as diretrizes de templates estabelecidos que promovem clareza e consistência em toda a especificação.

Formular as contribuições dos stakeholders como histórias de usuários

A IA pode ajudar a formular as contribuições dos stakeholders como histórias de usuários bem estruturadas, seguindo templates de frases estabelecidas, como o formato amplamente utilizado "Como [tipo de usuário], quero [objetivo] para que [benefício]" ([GleA2024], capítulo 3.3). A IA pode analisar descrições dos stakeholders, transcrições de entrevistas ou declarações informais de requisitos para identificar papéis dos usuários, funcionalidades desejadas e valor de negócio, e então estruturar essas informações de acordo com as convenções das histórias dos usuários.

Sugestão de critérios de aceite

A IA também pode sugerir critérios de aceite apropriados, identificar elementos de história ausentes e garantir que as histórias de usuários mantenham o foco no valor do usuário em vez de detalhes de implementação. Esse recurso é particularmente valioso em contextos de desenvolvimento ágil em que as histórias de usuários servem como artefatos de requisitos primários em backlogs de produtos (consulte o capítulo 3.6 em [GleA2024]). Dessa forma, a IA ajuda a manter a consistência no formato da história e a integridade em grandes coleções de histórias.

Geração de glossários de domínios e tabelas de sinônimos

Ao apoiar a geração de glossários de domínio e tabelas de sinônimos, a IA ajuda a esclarecer a terminologia específica do domínio e a promover o uso consistente da linguagem entre as equipes, abordando as preocupações com ambiguidades encontradas em produtos de trabalho baseados em linguagem natural (consulte o capítulo 3.2 em [GleA2024]).

Decomposição de requisitos

Além disso, a IA pode identificar subdivisões lógicas nos requisitos de alto nível, ajudando a decompô-los em sub-requisitos acionáveis, especificações em nível de sistema ou critérios de aceite que facilitam o alinhamento da implementação com as metas de negócio. Esse trabalho de formulação se baseia no entendimento do domínio estabelecido durante as atividades de exploração, nas percepções documentadas dos processos de transcrição e no conteúdo estruturado das fases de extração.

Ele garante que os requisitos sejam expressos em formatos que suportem colaboração, desenvolvimento e validação eficazes em todo o processo de ER.

5.2.2 Transformação de requisitos em outras representações

Na ER moderna, a transformação é mais do que apenas traduzir o texto de um idioma para outro: trata-se de transformar os requisitos em formatos e perspectivas dos stakeholders. À medida que os sistemas se tornam mais complexos e as equipes mais interdisciplinares, a capacidade de transformar os requisitos de forma eficaz torna-se essencial para a clareza, o alinhamento e a rastreabilidade.

Conversão de requisitos de linguagem natural em modelos visuais

As ferramentas de IA auxiliam os Engenheiros de Requisitos, permitindo uma transição fluida entre as representações e as necessidades dos stakeholders. Eles podem converter os requisitos de linguagem natural em modelos visuais, como diagramas UML ou BPMN (consulte o capítulo 3.4 em [GleA2024]), tornando a estrutura do sistema, os fluxos de trabalho e os relacionamentos mais fáceis de entender do que apenas por meio de texto. Por outro lado, a IA pode descrever modelos visuais em texto estruturado para melhorar a acessibilidade para os stakeholders não técnicos e apoiar a documentação. Além dos diagramas gerais, a IA também pode gerar artefatos UML específicos, como diagramas de classes, atividades ou casos de uso, bem como fluxos de trabalho BPMN que visualizam decisões e processos, sempre com foco na especificação de requisitos e não no design detalhado.

Criação de protótipos

IA Generativa [FHJZ2024] pode dar suporte aos Engenheiros de Requisitos na criação de protótipos exploratórios (consulte o capítulo 3.7 em [GleA2024]), gerando automaticamente wireframes, maquetes ou até mesmo protótipos funcionais com base em especificações de requisitos ou histórias de usuários. A IA pode analisar os requisitos funcionais e as descrições da interface do usuário para produzir representações visuais que ajudam os stakeholders a entender melhor o comportamento proposto para o sistema e a validar os requisitos por meio de exemplos concretos. A IA pode criar protótipos com diferentes níveis de fidelidade, desde simples wireframes para validação inicial do conceito até maquetes mais sofisticadas que demonstram os fluxos de interação do usuário e os conceitos de interface. Essa geração automatizada de protótipos permite a iteração rápida e a coleta de feedback dos stakeholders, apoiando o processo de validação (consulte o capítulo 4.4 em [GleA2024]), fornecendo representações tangíveis de requisitos abstratos que os stakeholders podem avaliar e refinar.

Criação de conteúdo visual dinâmico

A IA oferece diversas outras aplicações para aprimorar a comunicação e a validação na ER, além das atividades essenciais de ER. Esses recursos podem melhorar o envolvimento dos stakeholders e a qualidade dos requisitos quando empregados adequadamente. Desde transformar a documentação de requisitos em conteúdo visual dinâmico, como vídeos explicativos, até traduzir requisitos técnicos em linguagem simplificada para stakeholders

não técnicos e gerar resumos direcionados para públicos específicos (p. ex., executivos, usuários finais, desenvolvedores), a IA pode ajudar a garantir que a entrega de informações seja relevante para o público-alvo, mantendo a consistência das especificações.

Criação de personas de usuários

A tecnologia de IA pode sintetizar as informações dos stakeholders para criar personas de usuários que complementem os métodos tradicionais de identificação de stakeholders (consulte o capítulo 4.1 em [GleA2024]).

Derivação de casos de teste

A IA pode derivar casos de teste dos requisitos para apoiar as atividades de validação (consulte o capítulo 4.4 em [GleA2024]).

Análise de código legado

A IA pode analisar o código legado para extrair requisitos implícitos para os esforços de documentação.

Comparação de especificações

A IA também pode comparar as especificações com o código implementado para garantir a conformidade ou identificar discrepâncias, o que é particularmente valioso em setores regulamentados que exigem rastreabilidade rigorosa dos requisitos.

5.3 Validação

IA generativa [FHJZ2024] enfrenta limitações inerentes ao criar requisitos que os Engenheiros de Requisitos devem reconhecer e abordar. A IA pode gerar requisitos que parecem ser sintaticamente corretos e que seguem templates estabelecidos (consulte o capítulo 3.3 em [GleA2024]), mas que, na verdade, não atendem aos desejos e necessidades genuínos dos stakeholders (Princípio 2 do CPRE, [IREB2024], capítulo 2) ou que não estão fundamentados no contexto real do sistema (Princípio 4 do CPRE, [IREB2024]). Além disso, os requisitos gerados pela IA geralmente não têm a precisão e a verificabilidade necessárias que caracterizam os requisitos de alta qualidade, podendo introduzir ambiguidades ou especificações incompletas que violam os critérios fundamentais de qualidade. Os engenheiros de requisitos devem permanecer atentos aos resultados da IA que podem parecer abrangentes, mas que, na verdade, ignoram requisitos funcionais críticos, requisitos de qualidade ou restrições, ou que propõem soluções em vez de capturar os requisitos reais de acordo com o princípio Problema–Requisito–Solução. (Princípio 5 do CPRE, [IREB2024]).

Manter a consistência

A IA pode ajudar os Engenheiros de Requisitos a manter a consistência entre as especificações de requisitos e os backlogs de produtos, detectando automaticamente contradições, funcionalidade sobreposta e inconsistências de terminologia que podem surgir à medida que os produtos de trabalho evoluem ao longo do tempo. A IA pode cruzar os requisitos com os glossários estabelecidos (consulte o capítulo 3.5 em [GleA2024]) e identificar instâncias em que os mesmos conceitos são descritos usando termos diferentes.

Isso apoia o uso consistente da terminologia, que é essencial para o entendimento compartilhado (Princípio 3 do CPRE, [IREB2024]). As ferramentas de IA também podem analisar as dependências entre os requisitos e sinalizar possíveis conflitos que possam comprometer a coerência geral da especificação. No entanto, garantir uma consistência verdadeira requer mais do que a correspondência automatizada de padrões; exige uma compreensão da lógica empresarial subjacente, das prioridades dos stakeholders e da arquitetura do sistema. O Engenheiro de Requisitos deve validar se as inconsistências detectadas pela IA representam problemas genuínos em vez de variações aceitáveis e deve garantir que as melhorias de consistência sugeridas pela IA estejam alinhadas com os objetivos do projeto e não introduzam inadvertidamente novos conflitos ou comprometam a adequação dos requisitos individuais.

Orientação para o valor, adequação e necessidade

A validação dos requisitos gerados pela IA exige uma avaliação rigorosa de acordo com o princípio de orientação para o valor (Princípio 1 do CPRE, [IREB2024]) para garantir que cada requisito proposto contribua de forma significativa para satisfazer os desejos e as necessidades dos stakeholders, em vez de parecer apenas razoável isoladamente. Os Engenheiros de Requisitos devem avaliar se os requisitos gerados pela IA são realmente necessários, rastreando-os até a origem dos stakeholders (consulte o capítulo 4.1 em [GleA2024]) e verificando seu alinhamento com as metas de negócio identificadas e as metas do usuário. Quanto aos requisitos gerados por humanos, o foco deve ser a adequação e a necessidade (consulte o capítulo 3.8 em [GleA2024]): verificar se a IA não introduziu requisitos que excedam o escopo real das necessidades dos stakeholders ou as restrições do projeto.

Nível de abstração

O Engenheiro de Requisitos também deve avaliar se os requisitos gerados pela IA se enquadram nos níveis de abstração escolhidos (consulte o capítulo 3.1.2 em [GleA2024]) e se estão em um nível de detalhe adequado (consulte o capítulo 3.1.3 em [GleA2024]) para a fase atual do projeto. Deve-se garantir que os requisitos atendam à finalidade pretendida, em vez de criar complexidade desnecessária ou desvios de escopo que possam comprometer o sucesso do projeto.

5.4 Painel de Controle

A IA pode dar suporte a duas tarefas importantes do gerenciamento de requisitos: *atribuição de atributos a requisitos e priorização de requisitos*.

5.4.1 Atribuição de atributos a requisitos

A IA pode simplificar a atribuição de atributos aos requisitos, analisando seu conteúdo e propondo valores com base em padrões estabelecidos e critérios específicos do projeto. Conforme descrito no capítulo 6.5 [GleA2024], os atributos documentam metadados importantes que permitem que os stakeholders acessem informações relevantes durante todo o ciclo de vida do projeto.

Por meio da análise textual e da comparação com requisitos semelhantes de projetos atuais ou anteriores, a IA também pode sugerir valores para atributos comuns, como prioridade, complexidade, fonte ou pessoa responsável. As atribuições de atributos ausentes também podem ser identificadas, e a completude pode ser garantida em grandes conjuntos de requisitos, apoiando assim as práticas de documentação sistemática essenciais para o gerenciamento eficaz de requisitos (consulte o capítulo 6.1 em [GleA2024]).

5.4.2 Priorização de requisitos

A IA generativa [FHJZ2024] pode ajudar os Engenheiros de Requisitos a priorizar os requisitos (consulte o capítulo 6.8 em [GleA2024]), analisando vários critérios simultaneamente e propondo classificações com base em uma avaliação do valor de negócio, da urgência, do esforço, das dependências e de outros fatores relevantes.

A IA pode processar uma grande quantidade de requisitos e contribuições dos stakeholders para identificar padrões e compromissos que podem ser negligenciados durante a priorização manual, garantindo ao mesmo tempo a consideração sistemática de todas as etapas de priorização descritas em [GleA2024] capítulo 6.8. A IA também pode gerar análises comparativas entre os requisitos, destacando possíveis conflitos ou dependências que possam influenciar as decisões de priorização. Além disso, ele pode adaptar as sugestões de priorização com base nas diferentes perspectivas dos stakeholders ou nas mudanças nas restrições do projeto.

A priorização eficaz vai muito além da análise algorítmica e requer uma compreensão profunda das necessidades dos stakeholders, da estratégia de negócios e do contexto do projeto — elementos que a IA não consegue compreender plenamente. Envolver os stakeholders apropriados nas decisões de prioridade continua sendo essencial (consulte o capítulo 6.8 em [GleA2024]), e as sugestões da IA devem ser validadas em relação a esses julgamentos e metas estratégicas. Para manter o alinhamento com o princípio de orientação para o valor (Princípio 1 do CPRE, [IREB2024]), a priorização deve refletir as necessidades reais dos stakeholders, em vez de métricas abstratas.

No desenvolvimento iterativo, a natureza dinâmica da priorização exige ainda mais a supervisão humana contínua para garantir que as recomendações de IA permaneçam relevantes à medida que as condições do projeto evoluem.

5.5 Principais conclusões

A IA pode aprimorar todas as atividades essenciais de RE — elicitación, documentação, validação e gerenciamento de requisitos —, melhorando a eficiência, a estrutura e a consistência. Ela deve ser vista como uma ferramenta de apoio que acelera as tarefas, mas não substitui a experiência humana. Os Engenheiros de Requisitos devem selecionar os resultados da IA para garantir que estejam corretos, relevantes e alinhados com os objetivos do projeto. Em última análise, a IA serve como auxílio para o julgamento humano, enquanto a responsabilidade pela qualidade dos requisitos permanece com o Engenheiro de Requisitos.

6 Terminologia de IA

Nível: L1

Duração: 0,5 horas

Objetivo: Os candidatos conhecem a terminologia que é essencial para trabalhar com IA.

Objetivos Educacionais

OE 6.1 Lembrar e identificar a terminologia básica essencial para trabalhar com IA. (L1)

Este capítulo explica a terminologia essencial para entender e trabalhar com IA, especialmente com Grandes Modelos de Linguagem.

Chatbot

Um chatbot é um sistema de IA projetado para simular conversas humanas por meio de texto ou fala [ZhWX2023]. Os chatbots modernos baseados em LLMs podem entender o contexto, manter o histórico de diálogos e gerar respostas coerentes e sensíveis ao contexto. Na ER, os chatbots podem ajudar os Engenheiros de Requisitos transcrevendo entrevistas com stakeholders, recuperando informações de documentos ou apoiando tarefas de documentação por meio de diálogo interativo.

Linha de Raciocínio

A linha de raciocínio é uma abordagem na qual o LLM é solicitado a explicar seu prompt passo a passo antes de fornecer a resposta final [WeeA2022]. Na ER, isso pode apoiar a transparência e a rastreabilidade, por exemplo, ao analisar requisitos conflitantes ou avaliar alternativas de design.

Visão computacional

A visão computacional transforma pixels brutos em fatos estruturados [Szel2022]. As redes de visão modernas detectam objetos, leem textos de uma imagem e estimam a profundidade espacial. O exemplo mais conhecido é provavelmente a feature de desbloqueio facial dos telefones modernos.

Janela de contexto

A janela de contexto define o número máximo de tokens que um LLM pode considerar de uma só vez (incluindo o prompt e a saída gerada) [BreA2020]. Esse limite restringe o quanto de uma especificação de requisitos ou histórico de diálogo pode ser levado em conta ao gerar respostas. Para tarefas de ER, como a validação de requisitos ou a análise do feedback dos stakeholders, o conhecimento do tamanho da janela de contexto ajuda a estruturar as entradas de forma eficiente. No entanto, isso nem sempre é algo do tipo "maior é melhor": quanto mais informações você fornecer a um LLM, melhor ele será no início, mas o excesso de informações também pode fazer com que o modelo se distraia.

Deep learning

A deep learning é um subconjunto da Machine Learning que usa redes neurais (como transformadores para linguagem e redes convolucionais para imagens) para lidar com tipos de dados e tarefas complexas, incluindo a aprendizagem por reforço [GoBC2016].

Embeddings

Os embeddings são representações vetoriais numéricas de texto que capturam o significado semântico [VoFi2025]. Na ER, os embeddings permitem a pesquisa semântica, a detecção de duplicatas, o agrupamento e a rastreabilidade entre requisitos e artefatos relacionados, mesmo quando a redação difere. Os embeddings formam a base para muitas funções de recuperação e análise, mas não geram texto por si só.

Sistemas especializados

Os sistemas especializados capturam o conhecimento humano como regras e ontologias explícitas, produzindo respostas auditáveis e determinísticas [Bari2025]. Eles ainda são preferidos para domínios como direito tributário ou triagem médica, em que a transparência supera a probabilidade e não há absolutamente nenhuma margem para erros. O software fiscal moderno pode, por exemplo, utilizar IA para analisar suas contas, declarações de renda e outros dados para calcular o valor do imposto que você deve.

Ajuste fino

O ajuste fino é o processo de adaptação de um LLM pré-treinado a um domínio ou tarefa específica, treinando-o com dados adicionais relevantes [HoRu2018]. Para tarefas de ER, o ajuste fino pode alinhar o modelo com a terminologia do domínio, a linguagem regulamentar ou os padrões organizacionais, melhorando assim a precisão dos requisitos gerados ou das verificações de conformidade. O ajuste fino requer esforço, conhecimento especializado e dados com controle de qualidade para ser eficaz.

Prompt de poucos disparos / zero disparos

O prompt de poucos disparos e o prompt de zero disparos são técnicas nas quais o modelo executa uma tarefa com poucos ou nenhum exemplo no prompt [BreA2020], [DAIR2024]. Na RE, esses recursos podem ser usados para classificar requisitos, gerar critérios de aceite ou reformular especificações sem a necessidade de grandes volumes de dados de treinamento específicos para cada tarefa.

Alucinação

A alucinação é uma consequência direta do mecanismo probabilístico descrito no capítulo 1.1 [FHJZ2024]. Uma alucinação ocorre quando um LLM produz um texto estatisticamente provável que é factualmente incorreto ou não tem suporte de dados de origem. Na ER, as alucinações podem ser particularmente problemáticas se os detalhes inventados forem confundidos com declarações dos stakeholders ou fatos de domínio. Os Engenheiros de Requisitos que usam LLMs devem, portanto, validar o conteúdo gerado pela IA com base em fontes confiáveis, de acordo com o princípio 6 do CPRE de que requisitos não validados

são inúteis [IREB2024]. Todos os resultados gerados pela IA devem ser tratados como um rascunho não verificado.

Machine Learning (ML)

Nos algoritmos de Machine Learning, os padrões são aprendidos diretamente dos dados [Bish2006]. O ML clássico prevê números ou categorias; redes de deep-learning, como transformadores e redes neurais convolucionais, lidam com linguagem, imagens e políticas de aprendizado por reforço. A qualidade do resultado aumenta com o tamanho e a relevância do conjunto de treinamento. Por exemplo, um modelo poderia usar dados anteriores de vendas de casas e prever os preços das propriedades a serem vendidas.

Processamento de Linguagem Natural (NLP)

O processamento de linguagem natural inclui tudo o que transforma a fala ou o texto em significado e vice-versa [QieA2020]. Ele abrange desde analisadores baseados em regras até os atuais chatbots LLM, além de módulos de fala para texto e texto para fala.

Prompt

Um prompt é a entrada fornecida a um LLM para orientar sua saída [Kuka2024]. Pode ser uma pergunta, uma instrução ou um texto parcial. Na prática da ER, os prompts determinam a relevância e a precisão dos resultados gerados, por exemplo, ao solicitar que um LLM proponha formulações alternativas de um requisito ou extraia requisitos funcionais de entrevistas com stakeholders. A qualidade do prompt tem um impacto direto sobre a utilidade da resposta.

Engenharia de prompt

A engenharia de prompt é a prática de projetar e refinar prompts para obter, de forma confiável, os resultados desejados de um LLM [CZLZ2025]. Isso é semelhante à elaboração de perguntas precisas para entrevistas ou estruturas de modelos na ER: a clareza e a estrutura melhoram a qualidade das informações obtidas.

Geração Aumentada por Recuperação (RAG)

A geração aumentada por recuperação (RAG) é um processo que usa embeddings para encontrar documentos relevantes e, em seguida, os passa para um LLM para gerar uma resposta [LeeA2020]. No RE, o RAG garante que os resultados da IA se baseiem em especificações reais, notas dos stakeholders ou documentos normativos, reduzindo o risco de alucinações e mantendo os resultados específicos do projeto, em vez de se basearem puramente nos dados de treinamento internos do próprio modelo.

Robótica

A robótica combina fusão de sensores (integração de dados de vários sensores), mapeamento (criação de uma representação do ambiente), planejamento de caminho (decisão de como se mover) e controle de feedback (ajuste de ações com base nas entradas dos sensores) para que as máquinas possam navegar e manipular o mundo físico de forma autônoma. [Szel2022]. As aplicações variam de coletores de armazém e drones autônomos a aspiradores de pó que mapeiam a sua sala de estar e podem evitar obstáculos.

Prompt do sistema / instrução

Um prompt do sistema é um tipo especial de prompt que define o comportamento ou o papel abrangente do LLM (p. ex., "Você é um Engenheiro de Requisitos assistente...") [CZLZ2025]. Isso garante que os resultados gerados sigam os guias de estilo organizacional ou as práticas recomendadas de ER.

Temperatura

A temperatura é um parâmetro que controla a aleatoriedade da saída de um LLM [BreA2020]. Valores baixos tornam o modelo mais determinístico, produzindo frases consistentes, enquanto valores mais altos criam resultados mais variados e criativos. Na ER, as temperaturas mais baixas geralmente são preferíveis para a consistência na formulação dos requisitos, enquanto os valores mais altos podem ser úteis para gerar diversas ideias de soluções. No entanto, em muitos LLMs, a temperatura não pode ser definida pelos usuários.

Token

Um token é uma unidade de texto – geralmente uma palavra, parte de uma palavra ou pontuação – que o modelo processa [SeHB2016]. Os LLMs operam com tokens em vez de frases inteiras, e seu desempenho e custo são parcialmente determinados pelo número de tokens processados. Em contextos de RE, os limites de tokens podem afetar a quantidade de texto de especificação, contribuições dos stakeholders ou conteúdo do glossário que pode ser processada em uma única interação..

Transformador

Os transformadores são a arquitetura de rede neural por trás da maioria dos LLMs modernos [VaeA2017]. Ele usa um mecanismo de atenção para avaliar a importância das palavras em relação umas às outras, independentemente da posição, permitindo o manuseio eficiente de sequências longas e padrões de linguagem complexos. Na RE, os transformadores permitem que as ferramentas de IA interpretem e gerem textos de requisitos com alta consciência contextual, por exemplo, identificando dependências ou mantendo uma terminologia consistente em todos os documentos.

Vetor

Uma representação matemática de dados como uma lista ordenada de números [MCCD2013]. No contexto de embeddings, os vetores capturam o significado semântico do texto colocando palavras, frases ou requisitos semelhantes próximos uns dos outros em um espaço multidimensional. Na ER, os vetores permitem operações como pesquisa de similaridade, agrupamento de requisitos relacionados ou vinculação das necessidades dos stakeholders com a documentação existente, mesmo quando são usadas redações diferentes.

7 Referências

- [Bari2025] Barisic, Davor: Exploring the Landscape of Expert Systems: A Review. International Journal of Management Trends: Key Concepts and Research, 4(1), 58–68, 2025.
- [Bish2006] Bishop, Christopher M.: Pattern Recognition and Machine Learning. Springer, 2006.
- [BreA2020] Brown, Tom et al.: "Language models are few-shot learners". Advances in Neural Information Processing Systems 33 (2020): 1877–1901.
- [CZLZ2025] Chen, Banghao, Zhaofeng Zhang, Nicolas Langrené, and Shengxin Zhu: Unleashing the Potential of Prompt Engineering for Large Language Models. Patterns 6, no. 6 (2025).
- [DAIR2024] DAIR.AI. Zero-Shot Prompting. Prompting Guide, 2024. <https://www.promptingguide.ai/en/techniques/zeroshot>. Última visita Outubro 2025.
- [DDOS2024] Deters, Hannah, Droste, Jakob, Obaidi, Marti, Schneider, Kurt: How Explainable Is Your System? Towards a Quality Model for Explainability, Springer Nature Switzerland, 2024.
- [EUAI2026] The EU Artificial Intelligence Act (AIA), 2026. <https://artificialintelligenceact.eu> Última visita Fevereiro 2026.
- [FDA1997] FDA 21 CFR Part 11: U.S. Food and Drug Administration. Title 21 Code of Federal Regulations Part 11: Electronic Records; Electronic Signatures. EUA. Government Publishing Office, 1997. <https://www.ecfr.gov/current/title-21/chapter-I/subchapter-A/part-11> Última visita Novembro 2025.
- [FHJZ2024] Feuerriegel, Stefan, Jonas Hartmann, Christian Janiesch e Patrick Zschech: Generative AI. Business & Information Systems Engineering vol. 66(1), páginas 111-126, Fevereiro de 2024.
- [GDPR2016] European Union. General Data Protection Regulation (EU) 2016/679. Official Journal of the European Union, 2016. <https://eurlex.europa.eu/eli/reg/2016/679/oj> Última visita Novembro 2025.
- [GleA2024] M. Glinz et al.: Handbook for the CPRE Foundation Level according to the IREB Standard (Version 1.2.0). IREB e.V., Karlsruhe, 2024. <https://cpre.ireb.org/en/downloads-and-resources/downloads#cpre-foundation-level-handbook>. Última visita Setembro 2025.
- [Glin2024] M. Glinz: A Glossary of Requirements Engineering Terminology (Version 2.1.0). IREB e.V., Karlsruhe, 2024. <https://cpre.ireb.org/en/downloads-and-resources/downloads#cpre-glossary>. Última visita Setembro 2025.
- [GoBC2016] Goodfellow, Ian, Yoshua Bengio, and Aaron Courville: Deep Learning. MIT Press, 2016.

- [HoRu2018] Howard, Jeremy e Sebastian Ruder. Universal Language Model Fine-tuning for Text Classification. In Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (ACL), 2018.
- [IEC62304] International Electrotechnical Commission. IEC 62304: Medical Device Software—Software Life Cycle Processes. IEC, 2006.
<https://webstore.iec.ch/en/publication/6792> (Note: Confirmed as current in 2021). Última visita Outubro 2025.
- [IREB2025] #AIREB Booklet on RE and AI. <https://cppe.ireb.org/en/downloads-and-resources/downloads#ai-snippets>. Última visita Outubro 2025.
- [IREB2024] IREB Certified Professional for Requirements Engineering Foundation Level Syllabus (version 3.2.0). IREB e.V., Karlsruhe, 2024.
<https://cppe.ireb.org/en/downloads-and-resources/downloads#cppe-foundation-level-syllabus>. Última visita Setembro 2025.
- [IREB2026] AI4RE Prompt Guide. Prompt templates for various RE use cases by IREB.
<https://ireb.atlassian.net/wiki/spaces/airebpromptguide/overview>. Última visita Fevereiro 2026.
- [Kuka2024] Kuka, V. (2024, October 22). Prompt Engineering,
https://learnprompting.org/docs/basics/prompt_engineering. Última visita Outubro 2025.
- [LeeA2020] Lewis, Patrick et al.: "Retrieval-augmented generation for knowledge-intensive NLP tasks" Advances in Neural Information Processing Systems 33 (2020): 9459–9474.
- [MiSC2013] Mikolov, T., Sutskever, I., Chen, K., et al. (2013). "Distributed representations of words and phrases and their compositionality." Advances in Neural Information Processing.
<https://proceedings.neurips.cc/paper/2013/hash/9aa42b31882ec039965f3c4923ce901b-Abstract.html>. Última visita Outubro 2025.
- [MCCD2013] T. Mikolov, K. Chen, G. Corrado, J. Dean: Efficient Estimation of Word Representations in Vector Space. 2013. arXiv:1301.3781 (2013).
- [NoeA2024] Norheim, J.J., Rebentisch, E., Xiao, D., Draeger, L., et al. (2024). "Challenges in applying large language models to Requirements Engineering tasks." Design Science <https://www.cambridge.org/core/journals/design-science/article/challenges-in-applying-large-language-models-to-requirements-engineering-tasks/1FC7666F0A0B4E7091D2D4B2D46321B5>. Última visita Outubro 2025.
- [QieA2020] Qiu, Xipeng et al.: Pre-trained Models for Natural Language Processing: A Survey. Science China Technological Sciences vol. 63, no 10 (2020): 1872–1897.

- [RaeA2019] Radford, Alec e. al: "Language models are unsupervised multitask learners." OpenAI blog 1, no. 8 (2019): 9. https://cdn.openai.com/better-language-models/language_models_are_unsupervised_multitask_learners.pdf. Última visita Outubro 2025.
- [SceA2023] Schick, T., Dwivedi-Yu, J., Dessì, R., et al. (2023). "Toolformer: Language models can teach themselves to use tools." Advances in Neural Information Processing Systems. https://proceedings.neurips.cc/paper_files/paper/2023/hash/d842425e4bf79ba039352da0f658a906-Abstract-Conference.html. Última visita Outubro 2025.
- [SeHB2016] Sennrich, Rico, Barry Haddow, and Alexandra Birch: Neural Machine Translation of Rare Words with Subword Units. Em Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers), 1715–1725. Association for Computational Linguistics, Berlin, Germany, 2016.
- [Szel2022] Szeliski, Richard: Computer Vision: Algorithms and Applications (2ª ed.). Springer Nature, 2022.
- [VaeA2017] Vaswani, Ashish et al.: "Attention is All you Need." Em I. Guyon, U. Von Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, & R. Garnett (eds.), Advances in Neural Information Processing Systems 30 (NeurIPS 2017). Curran Associates, 2017.
- [VoFi2025] A. Vogelsang, J. Fischbach (2025). Using Large Language Models for Natural Language Processing Tasks in Requirements Engineering: A Systematic Guideline. In: A. Ferrari, G. Ginde (eds.) Handbook on Natural Language Processing for Requirements Engineering. Cham: Springer Nature. Preprint available for free at <https://arxiv.org/pdf/2402.13823>. Última visita Fevereiro 2026.
- [WeeA2022] Wei, Jason et al.: "Chain-of-thought prompting elicits reasoning in large language models." Advances in Neural Information Processing Systems 35 (2022): 24824–24837.
- [WheA2023] White, Jules et al.: "A prompt pattern catalog to enhance prompt engineering with chatgpt." arXiv preprint arXiv:2302.11382 (2023).
- [YeeA2023] Ye, H., Liu, T., Zhang, A., Hua, W., Jia, W. (2023). "Cognitive mirage: A review of hallucinations in large language models." arXiv preprint arXiv:2309.06794
- [ZaDA2025] Zadenoori, M.A., Dąbrowski, J., Alhoshan, W., et al. (2025). "Large Language Models (LLMs) for Requirements Engineering (RE): A Systematic Literature Review." arXiv preprint arXiv:2509.11446
- [ZhWX2023] Zhao, Wayne, Yuan Wang, Xing Xie, et al.: A Survey of Large Language Models. 2023. arXiv:2303.18223 (2023).