


Harness Engineering

do modelo ao sistema

Bryan de Oliveira
bryan.szero.io

Slides e material:



inovabra
ecossistema de inovação bradesco

Sobre mim

Bryan de Oliveira

bryan@szero.io

Doutorando em Ciência da Computação · UFG

Pesquisador e coordenador de projetos · CEIA / AKCIT

Especializado em agentes, aprendizado por reforço, e pós-treino

Fundador · SZERØ — Consultoria e IA para decisões em escala



A demo funciona. E em produção?

DEMO

“Consegue fazer?”

cliente

“Tenho R\$ 2.400 em atraso. Aceitam 30% de desconto?”

agente

“Claro! Acordo registrado.”

PRODUÇÃO

“Faz repetidamente, com custo, controle e evidência?”

t

timeout

x

dado errado

k


autorização

2
x

duplicidade

Vamos construir passo a passo.

Modelo, agente e harness são coisas diferentes



MODELO

produz uma resposta

AGENTE

observa, decide e age em um loop

HARNESS

controla o contexto, capacidades, execução e verificação

“Harness” é o sistema que permite o modelo agir com **consistência** e impõe **limites** para que ele não saia do escopo.

Nosso exemplo será sempre o mesmo

CASO FICTÍCIO · NEGOCIAÇÃO DE FATURA

fatura em atraso: R\$ 2.400

pedido: 30% de desconto

teto ilustrativo: 15%



O resultado é um **estado válido em sistemas externos.**

Versão 0: só uma chamada ao modelo




```
mensagens = [  
    {"role": "user", "content": pedido_do_cliente}  
]  
  
resposta = llm(mensagens)
```

llm(...) = chamar o modelo
pseudocódigo independente de provider


O software enviou informação e recebeu informação.

O que a chamada simples não consegue fazer




CONSULTAR

não lê o saldo



ALTERAR

não grava nada




OBSERVAR

não vê o resultado

“Se eu não tenho acesso ao mundo, só posso descrevê-lo com base em milhares de situações semelhantes que vi anteriormente.”

Falta observação e acesso autorizado.

Salto conceitual: o loop fechado



OBSERVAR → DECIDIR → AGIR → OBSERVAR

O agente reconsidera a situação depois de cada ação.

Ponte: aprendizado por reforço e sistemas de controle — estado/observação, decisão/ação, feedback.

O loop só é real se a **observação refletir o ambiente** e ações tiverem **consequências**.

Versão 1: o agente pode dar vários passos

```
historico = []

for passo in range(MAX_PASSOS):
    mensagens = montar_mensagens(tarefa, historico)
    resposta = llm(mensagens)

    if resposta.final:
        return resposta.texto

    observacao = executar(resposta.acao)
    historico += [resposta, observacao]
```

Agora existe um ciclo de decisões.

Mas o que significa
executar uma “ação”?

O modelo **propõe** a chamada; o harness **interpreta** e **decide executar**.


Um agente não é “um prompt maior”



Pode ser um único modelo e um único loop.

Ferramentas = capacidades disponíveis


Uma ferramenta liga uma decisão a um sistema externo.



`consultar_fatura lê · registrar_proposta altera · enviar_mensagem comunica`

A tool é a **capacidade exposta** — função, banco, API, sensor, outro modelo.

Versão 2: registramos as tools



`registrar_proposta = side effect`

```
ferramentas = [  
    consultar_fatura,  
    consultar_politica,  
    registrar_proposta,  
    enviar_mensagem,  
]  
  
resposta = llm(  
    mensagens=mensagens,  
    ferramentas=ferramentas,  
)
```

Expor a ferramenta ao modelo e permitir a execução são controles distintos.

Uma ferramenta pode ser outro modelo

A inteligência de uma empresa não precisa caber em um LLM.

Ferramenta também pode ser visão, áudio ou previsão.



Um sensor de temperatura ou um classificador de imagem devolve uma observação; o agente decide se abre uma ocorrência.

Para percepção, o **modelo de percepção é o produto** — o harness **orquestra**.

Tool call ≠ execução confirmada

PROPOSTA DE CHAMADA ≠ MUDANÇA NO MUNDO

Há um software intermediário interpretando a solicitação.



`registrar_proposta(...)` pode dar timeout ou rejeitar o valor por política interna.

Propor, tentar e mudar o estado são três eventos diferentes.

O primeiro problema de contexto

O modelo sabe negociar.

Mas não conhece NOSSA fatura nem NOSSA política.




Prompt gigante não resolve dados **dinâmicos**, **sensíveis** e **extensos**.

Prompt vs. Context Engineering


PROMPT ENGINEERING

Como escrever as instruções?




CONTEXT ENGINEERING

O que colocar diante do modelo, quando e como?



Prompt engineering trabalha **dentro do contexto**; context engineering **projeta o contexto**.

O pipeline de construção de contexto



A seleção do que **entra** e do que **fica de fora** é uma decisão de engenharia.

Versão 3: o harness monta as mensagens

```
cliente = consultar_cliente(cliente_id)
politica = buscar_politica_relevante(tarefa)

mensagens = [
    {"role": "system", "content": INSTRUcoes_BASE},
    {"role": "user", "content": formatar_tarefa(
        pedido=pedido_do_cliente,
        dados={"cliente": cliente,
              "politica": politica},
    )},
    *historico,
]

resposta = llm(mensagens, ferramentas)
```

INSTRUÇÃO

estável · canal de prioridade

DADOS DA TAREFA

cliente + política relevante

HISTÓRICO

roles dependem do provider

Dados recuperados são material de **tarefa** — não novas ordens de sistema.

Estado, histórico, memória e contexto

ESTADO

o que é verdade agora

HISTÓRICO


o que aconteceu nesta execução

MEMÓRIA

o que persiste entre execuções

CONTEXTO

o recorte apresentado agora



saldo = estado · mensagens = histórico · canal = memória

O contexto é uma **projeção temporária** de várias fontes.

Contexto sob demanda

JUST-IN-CASE

tudo, sempre



superlotado

JUST-IN-TIME

informação quando influencia a próxima ação



Prompts podem variar por **estado da jornada** — sem repetir fase já passada.

Microcaso: três etapas, três contextos




Pergunta: qual dado esse fluxo **não** manda em todas as etapas?

Temos usado o LLM para decisões que não são dele?

“Qual desconto devemos oferecer?”

Antes de chamar o modelo: existe uma regra exata?



A decisão sobre **onde usar IA** faz parte do projeto do harness.

Regras determinísticas continuam valiosas

```
teto = calcular_limite(cliente, politica)

# dado contextual para a negociação
contexto["desconto_maximo"] = teto

# enforcement: independente do modelo
def registrar_proposta(valor, cliente):
    if valor > teto:
        return ERRO_LIMITE_EXCEDIDO
    return salvar_proposta(valor, cliente)
```

O modelo pode explicar a proposta.

O código calcula e impõe o teto.

MODELO

recebe “limite = 15%” para comunicar

GATE

exige valor $\leq$ limite para registrar

Dizer o limite **melhora a escolha**; validar no executor **impede o efeito**.

O mapa das inteligências

Linguagem aberta



Classificação / scoring




Imagem / sensor



Regra exata



Ação consequente



caminho híbrido: combinar resultados de mais de um mecanismo

Escolha pela **estrutura do problema, custo, latência e disponibilidade.**


Exemplo: modelo de decisão para uma decisão delimitada

```
p = prever_probabilidade_pagamento(estado_cliente)

estrategia = (
    "negociacao_flexivel" if p < 0.30
    else "negociacao_padrao"
)

contexto["estrategia"] = estrategia
```

A probabilidade orienta a estratégia; o LLM formula a mensagem ao cliente.



Modelos **especializados** tornam o sistema mais confiável.

Uma arquitetura, várias formas de inteligência

O sistema decide onde usar inteligência.

O modelo generativo é um componente, não a arquitetura inteira.




A mesma startup pode usar visão na coleta, decision model para triagem e LLM para atendimento.

Troque “qual LLM?” por “qual **decisão** e qual **mecanismo**?”

Capacidade não é autoridade

CONSEGUE $\neq$ PODE

A ação proposta ainda precisa de autorização.



Tool schema descreve a **capacidade**; o permission gate **decide** executar.

Versão 4: permission gate no executor

```
acao = obter_acao(resposta)


if not permissao_valida(usuario, acao):
    return NEGADO

if requer_aprovacao(acao):
    return AGUARDANDO_APROVACAO

resultado = executar(acao)
```

A solicitação de 30% pode ser rejeitada pelo executor mesmo que o modelo a apresente.


MODELO propõe → HARNESS autoriza → FERRAMENTA executa



Permissão considera **identidade**, **cliente** alvo, **operação**, **valor** e **contexto**.

Escada de autonomia

Mais consequência = controles mais fortes.




Autoridade é escolha de produto e engenharia.

Guardrails: instrução não substitui barreira

Instruções orientam. Barreiras restringem.

Dados externos não são ordens para o sistema.




Separe instruções, dados e enforcement — e opere com menor privilégio.

A armadilha do “Pronto!”

Resposta final $\neq$ resultado confirmado


“Enviei a mensagem” é uma afirmação, não uma evidência.



O modelo responde “acordo registrado”, mas a proposta não existe no CRM.

O risco é o sistema não ter prova de conclusão.

Exemplo: O que aconteceu com a proposta?



A gravação deu timeout; o agente respondeu sem confirmar o estado.

O erro foi declarar sucesso sem provar o resultado.

Diagnóstico: onde deveria morar a correção?

Não trocamos necessariamente o modelo.

Podemos melhorar a operação em volta dele.

1 · Limite de iterações

MAX_PASSOS, tempo e custo como política do processo

2 · Execução idempotente

retry seguro: a mesma operação não duplica o efeito

3 · Verificador do resultado

estado externo confirma (ou não) a conclusão

A correção mora no harness.


Versão 5: um verificador separado

```
resultado = executar(acao)
estado_real = consultar_sistema_de_registro()

confirmado = verificar_objetivo(
    tarefa=tarefa,
    estado=estado_real,
)

if confirmado:
    return SUCESSO
```

trilha A




trilha B



O sistema só comunica “proposta registrada” depois de localizar a proposta de valor correto.

O verificador consulta a **fonte da verdade** — separado de quem gera a resposta.

Sucesso, pendência e falha não são a mesma coisa



API aceita a proposta, mas a atualização do banco é assíncrona: a verificação imediata ainda não encontra o novo status.

Aceitar a solicitação não é concluir a mudança — apresentar pendência honestamente.

Um agente precisa saber parar

```
for passo in range(MAX_PASSOS):  
    if excedeu_tempo() or excedeu_custo():  
        return ESCALAR  
    ...
```

Limites de passos · tempo · custo · tentativas

Poder sem limites vira risco operacional.
Queima tokens e não resolve o problema.



Limites são políticas do processo.

Retry sem idempotência pode duplicar ações

```
chave = chave_idempotente(tarefa, cliente_id)

resultado = registrar_proposta(
    proposta,
    idempotency_key=chave,
)

if resultado == TIMEOUT:
    estado = consultar_proposta_por_chave(chave)
```

sem chave



→ duas propostas

com idempotency key



→ uma proposta


TIMEOUT ≠ NÃO EXECUTOU · retry seguro precisa considerar duplicidade

Timeout diz que perdemos o retorno — não que a operação não aconteceu.

Fallback e supervisão humana

Autonomia não é tudo ou nada.

O agente pode parar, pedir confirmação ou escalar.



Desconto fora da política → não executar; criar solicitação de revisão e retomar após aprovação.

Pedir aprovação não significa que a ferramenta já foi executada.

Observabilidade: qual caminho levou ao resultado?

```
registrar_trace(  
  etapa="registrar_proposta",  
  acao=acao,  
  resultado=resultado,  
  verificado=confirmado,  
)
```

Sem trajetória, temos somente o palpite sobre a causa.

Resposta ruim por política antiga? Por falha na observação? Por decisão errada?

Uma trace permite saber qual documento foi recuperado e qual chamada aconteceu.

TRACE


●	09:00:01	entrada
●	09:00:02	contexto montado
●	09:00:03	decisão
●	09:00:04	tool: registrar_proposta
●	09:00:05	observação — TIMEOUT
●	09:00:06	verificação

O erro pode estar no contexto, na ferramenta ou no fluxo — **não só no LLM.**

Da falha de produção para um caso de teste

INCIDENTE → **caso reproduzível** → **teste de regressão**

Faça do erro um aprendizado durável.



Cada mudança em prompt, modelo, tool, política ou retrieval **roda os testes**.

Evals: medir o que importa

topo subjetivo

RUBRICA HUMANA / LLM-JUIZ

qualidade subjetiva

VERIFICADORES

objetivo de negócio

ASSERTIONS

regras exatas

base determinística

“Resposta empática”

→ `rubrica`

“Proposta registrada no CRM”

→ `verificador`


“Nenhuma proposta acima do teto”

→ `assertion`

Não use LLM-juiz para checar soma exata quando o **código faz melhor.**

Custo e latência são decisões de harness

Menos contexto irrelevante. Menos passos inúteis. Modelo adequado por etapa. Cache e ferramentas quando fizer sentido.



O histórico inteiro é enviado em toda chamada sem necessidade; o sistema pode manter resumo e recuperar detalhes sob demanda.

Otimização não pode remover informação crítica nem degradar qualidade.

Versão final, parte A: preparar e propor

```
def executar_agente(tarefa, usuario):  
    historico = []  
    estado = carregar_estado(usuario)  
  
    for passo in range(MAX_PASSOS):  
        contexto = buscar_contexto_relevante(  
            tarefa, estado, historico  
        )  
        mensagens = montar_mensagens(  
            tarefa, contexto, historico  
        )  
        ferramentas = ferramentas_disponiveis(  
            usuario, estado  
        )  
        resposta = llm(  
            mensagens=mensagens,  
            ferramentas=ferramentas,  
        )
```

1. Carregar estado
2. Montar contexto
3. Montar input
4. Expor ferramentas
5. Chamar o modelo

contexto + capabilities → input

O agente recebe a fatura real e a política pertinente antes de escolher se consulta ou propõe.

Cada linha é uma decisão do desenvolvedor.

Versão final, parte B: autorizar, observar, verificar


```
registrar_no_historico(historico, resposta)

if resposta.tem_acao:
    acao = extrair_acao(resposta)
    if not autorizado(usuario, acao):
        return ESCALAR_OU_NEGAR

    resultado = executar_com_idempotencia(acao)
    observacao = observar(resultado)
    registrar_no_historico(historico, observacao)
    estado = recarregar_estado_real()
    confirmado = verificar_objetivo(tarefa, estado)
    registrar_trace(acao[0], acao, observacao, confirmado)

    if verificar_objetivo(tarefa, estado):
        return SUCESSO

return ESCALAR
```



Sem proposta real no CRM, o sistema não pode retornar sucesso, mesmo com resposta convincente do LLM.

Sem proposta real no CRM, o sistema não pode retornar “sucesso”.

O que fazer e o que evitar

FAÇA

- ✓ comece pelo fluxo
- ✓ contexto seletivo
- ✓ privilégios mínimos
- ✓ verifique resultados
- ✓ transforme falhas em testes

EVITE

- ✗ framework primeiro
- ✗ prompt gigante
- ✗ regra só em linguagem natural
- ✗ todas as tools
- ✗ confiar no “Feito!”

O critério é a **natureza da decisão** e o **custo do erro**.

Seis perguntas para o restante do dia

CONTEXTO

o que o modelo vê?

CAPACIDADES

o que ele pode acionar?

INTELIGÊNCIA

quem deve decidir?

HARNESS DA SUA STARTUP

AUTORIDADE

o que ele pode fazer?

EVIDÊNCIA

como provar o resultado?

APRENDIZADO

como melhorar?

Bryan de Oliveira
bryan.szero.io



inovabra
ecossistema de inovação **bradesco**