THUANY SERPA / SPECIALIST PRODUCT DESIGN

Usuários Sintéticos

Como otimizar seu discovery validando hipóteses com AI_

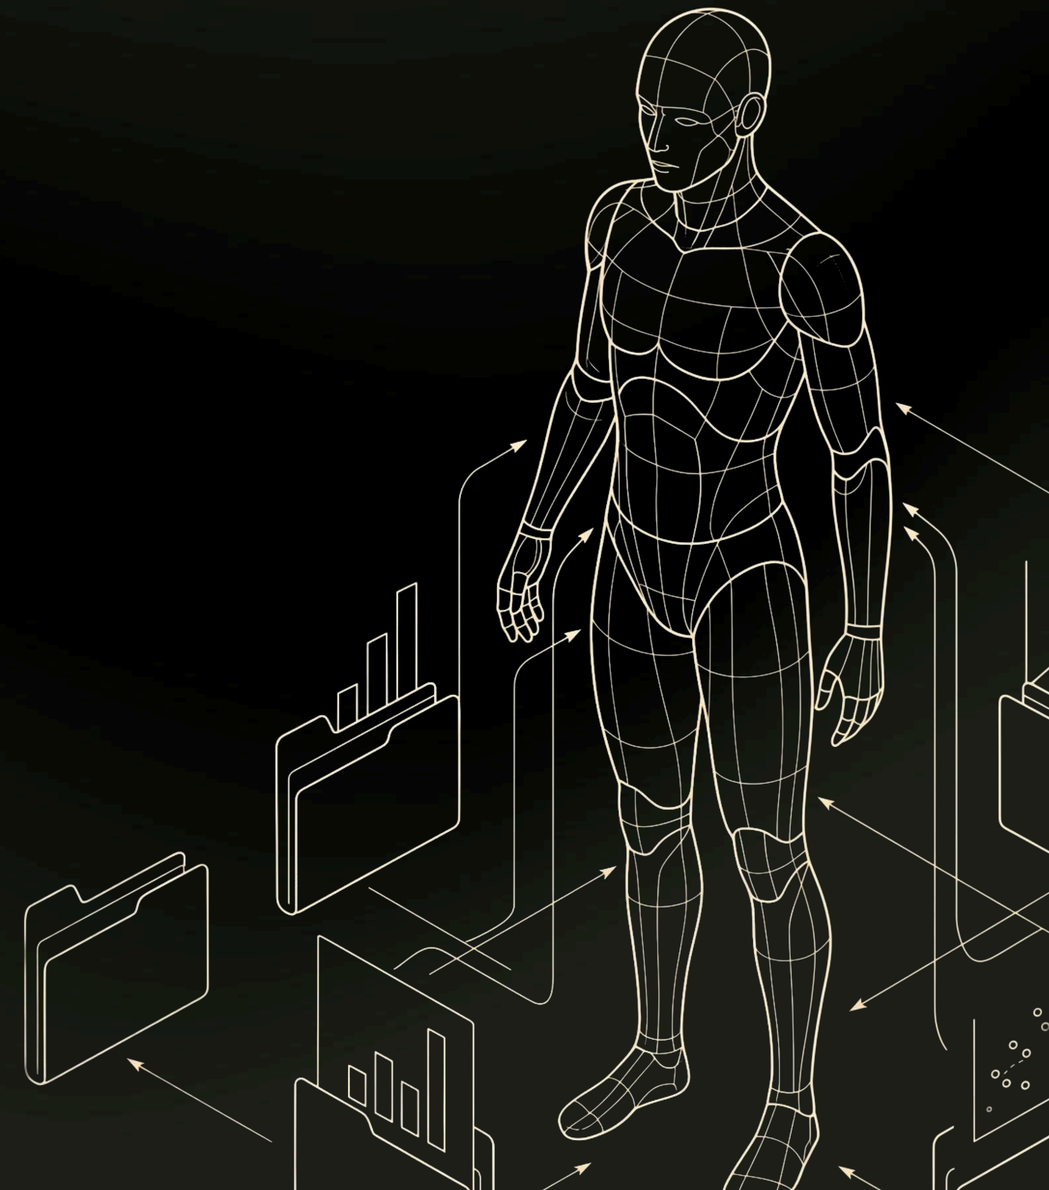

Oi 👋

Eu sou a Thuany

- ↳ +10 anos no design, com passagens por **SumUp**, **PicPay**, **Zé Delivery** e atualmente na **Cora**
- ↳ Pós graduada em Product Management e Inteligência Artificial
- ↳ Colecionadora de vinis e tutora de dois gatinhos

☕ Vamos marcar um café?
tuserpa.me ↗

O elefante na sala das empresas AI-First

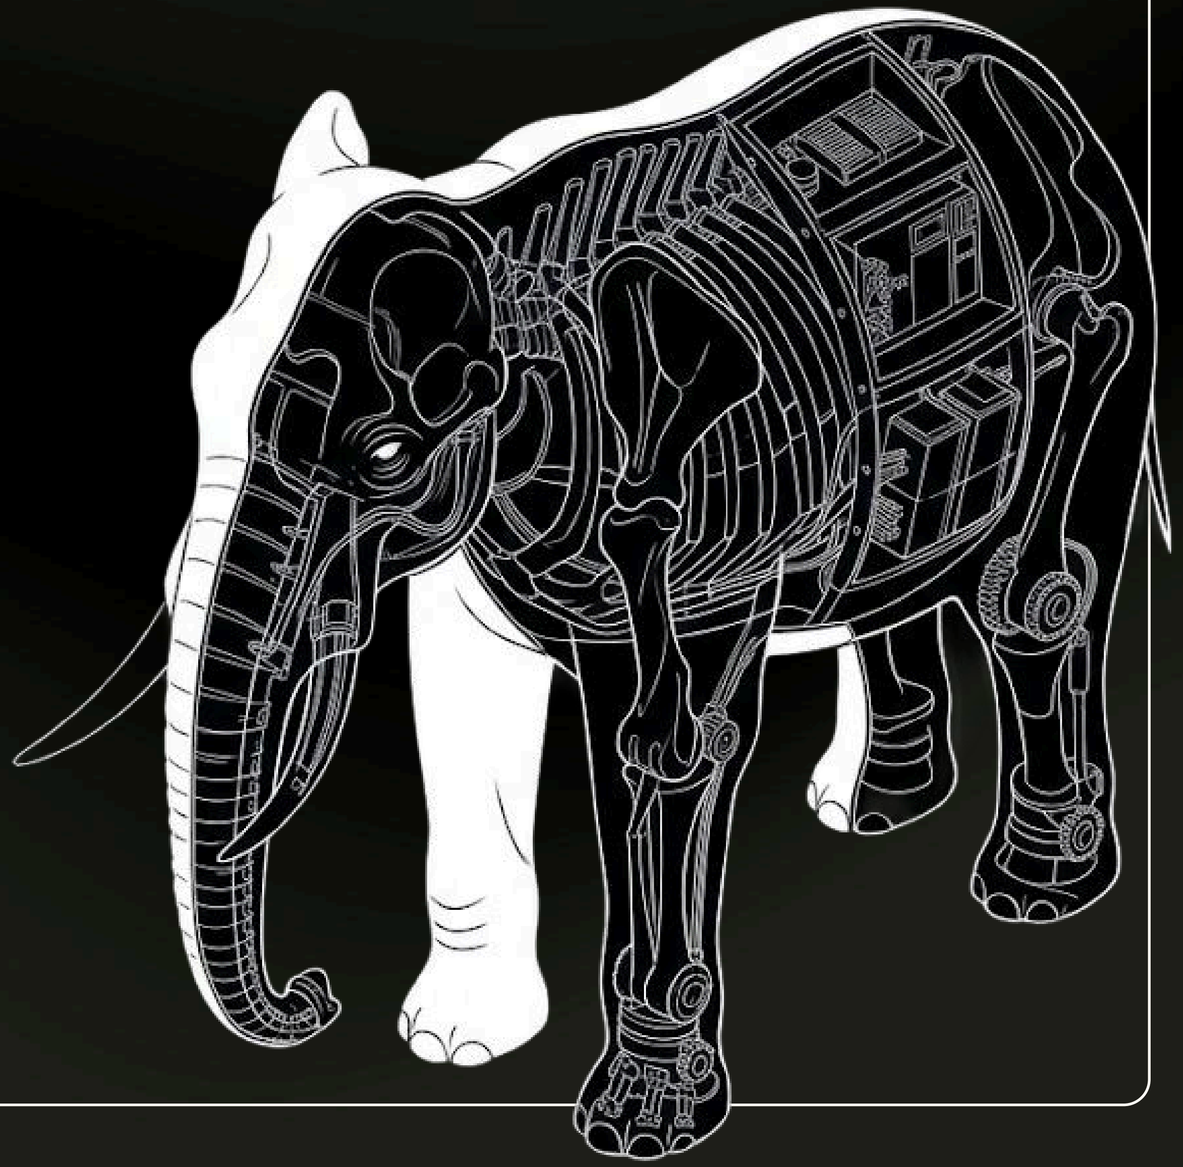

O problema do produto moderno

Hipóteses demais, ciclos de pesquisa de menos

ALGUMAS VERDADES DIFÍCEIS DE ENGOLIR

- O custo do build costumava obrigar a hipótese a passar pela quali e pela quanti antes de virar produto.
- Com a AI, o desenvolvimento ficou barato e esse freio sumiu. O teste pula direto pro produto como POC, e quem decide o que fica no ar é o próprio usuário.

Isso é user-centricity?

Usuário confuso, recebendo muitas atualizações, muitos produtos em beta e deixando de funcionar, deixando de utilizar recursos, etc

O aplicativo do [redacted] tá fora do ar a quase uma hora e **eu so queria** comprar [redacted]

mais alguém com esse problema na aba [redacted]? simplesmente não carrega nem aparece opções já entrei e sai diversas vezes da conta e não volta

Expectativa: uma **atualização** útil

Realidade: os donos desse hospício lançando o próximo pior update da história.
Como eles conseguem errar tanto no básico.
Custava fazer só o feijão com arroz?

Essa bomba desse **aplicativo** atualizou e agora ta tudo travando e dando erro. Toda nova mudança é pra piorar, impressionante

*Exemplos de reclamações em redes, relacionada a apps grandes, de empresas que estão escalando com AI.

E se pudéssemos

... levar ideias mais refinadas ao usuário sem travar a experimentação?

A pergunta não é “validar mais rápido”. É recolocar um filtro que não dependa do custo do desenvolvimento pra existir.

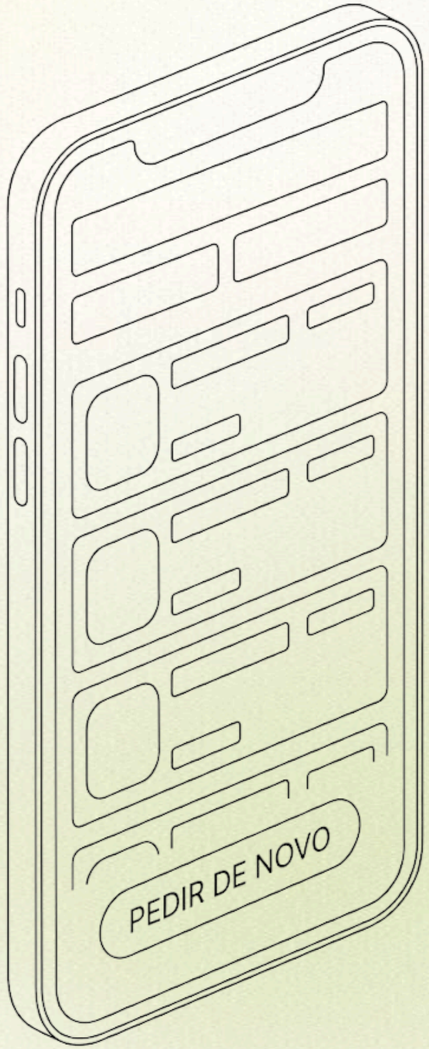

CASE EXEMPLO

App de delivery de um restaurante_

“Se ‘Pedir de novo’ for o CTA primário na home, o cliente novo aumenta recompra em 7 dias.”

Esse fio acompanha a palestra inteira: vamos montar um modelo simples conversacional com dados reais para validar essa hipótese antes do MVP

Motivos para usar sintéticos como filtro (não substituto) de pesquisa

TEMPO

A hipótese chega ao ciclo de pesquisa já crivada por dado real — a entrevista aprofunda, não descobre do zero se a direção faz sentido.

Não gastar 2 semanas para descobrir que o CTA confunde quem ainda explora o cardápio

DINHEIRO

Recrutamento, incentivo e síntese ficam reservados pra perguntas que já sobreviveram a um primeiro crivo.

Recrutamento só se a hipótese sobreviver ao sintético

BASE DE CLIENTES

Sua base é finita e desgastável. O sintético evita gastar boa vontade validando o que poderia ter sido filtrado antes.

Não queimar cliente fiel testando atalho óbvio demais

Entra lixo, sai lixo

Vamos cuidar primeiro da camada de dados

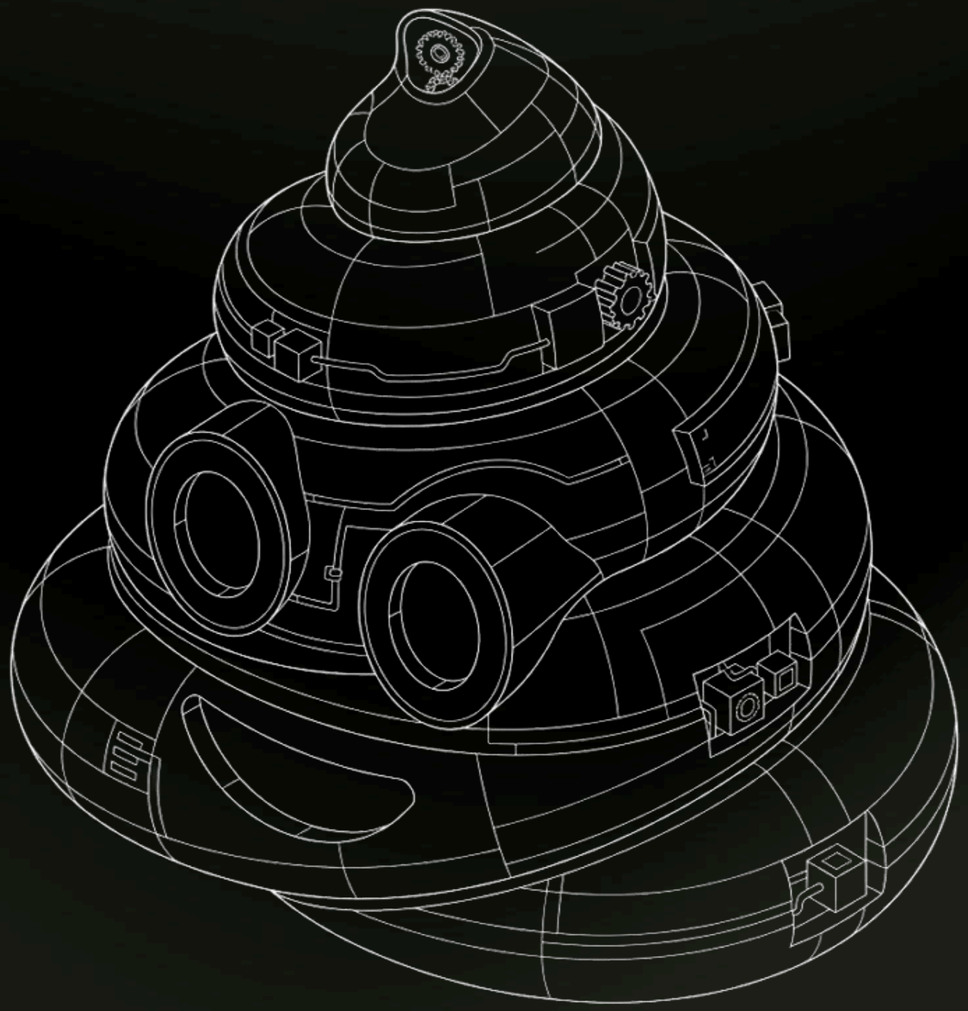

A conversa só é boa quando temos as evidências disponíveis

Quatro camadas alimentam o índice do cluster. Sem elas, a síntese improvisaria.
Com elas, a resposta aponta pra fonte.

1 - QUEM

Demográfico / Firmográfico

Cadastro e contexto

ex.: 34 anos · zona sul · 2 pedidos · veio do Instagram

2 - NÚMEROS

Dados quantitativos

frequência, ticket, recência, conversão

ex.: 5 sessões / 2 pedidos · ticket R$ 62 · 0 favoritos · 2 abandonos

3 - DECLARA

Dados qualitativos

entrevista, reviews, tickets de suporte

ex.: “quero ver o cardápio sem pressa” · “só descubro o frete no final”

4 - FAZ

Comportamental

eventos, sessões, hesitações, abandonos

ex.: scroll longo → compara itens → drop no frete → volta pra home · Hotjar · Mixpanel · GA4

PREPARANDO OS DADOS

Embedding

É necessário que a informação qualitativa esteja buscável, trackeável e que tenha coerência. Isso é possivel através do modelo embedding, que consiste na transformação dos textos em vetores.

1. TEXTO BRUTO
“quero ver o cardápio sem pressa”

→

2. VETOR
[0.82, −0.31, 0.15, 0.47, ...]

→

3. POSIÇÃO
um ponto no espaço, perto de quem "quer dizer" algo parecido

Nenhuma dessas falas compartilha as mesmas palavras. O embedding aproxima quem tem a mesma intenção e afasta quem não tem. É isso que torna o dado qualitativo buscável e trackeável.

O mínimo de Machine Learning

que você precisa saber

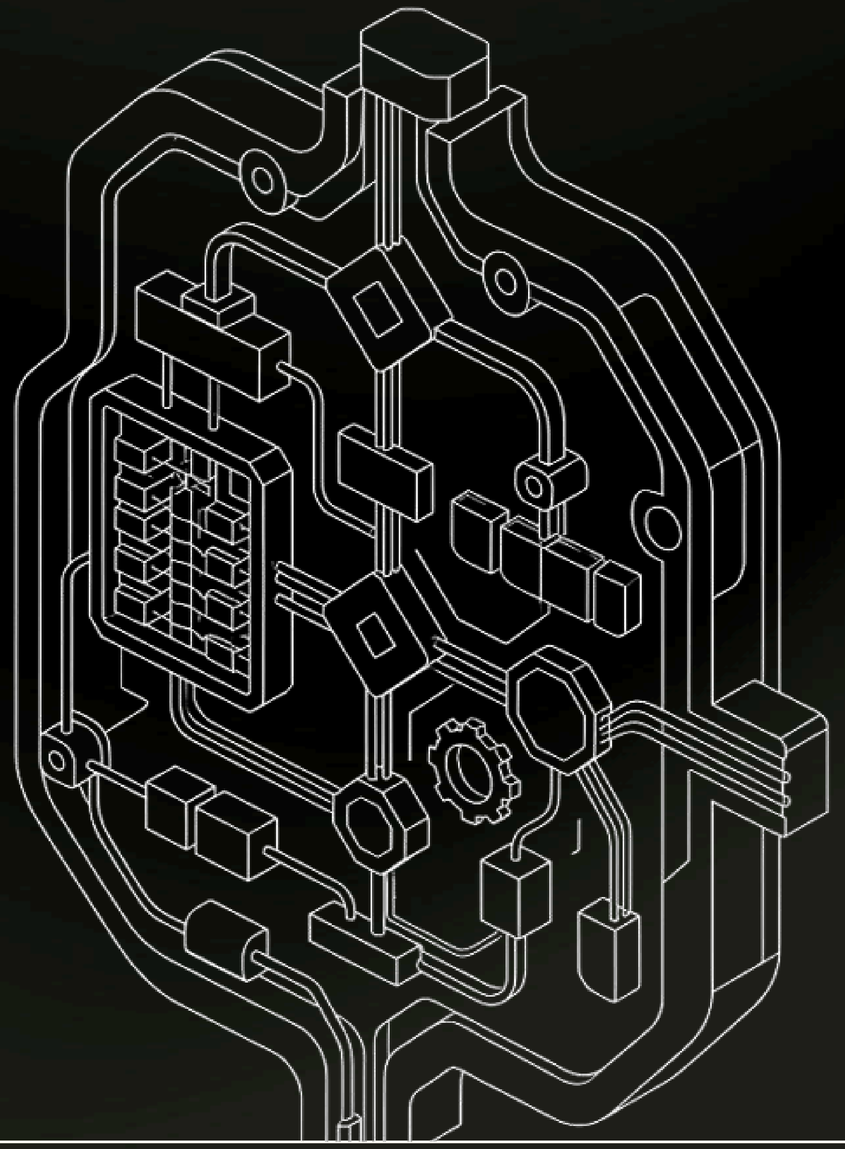

Persona nasce de ~~suposição~~.
O sintético nasce de dados

QUADRO BRANCO

"Acho que existem três tipos"

Ana
32 anos
solteira,
prática

Bruno
40 anos
ocupado,
pai

Carla
19 anos
estudante,
foodie

Fonte: amostra, vozes da cabeça, qualitativo

Personas projetadas - Forma imposta, imutável

CLUSTERIZAÇÃO

"Existem esses grupos na base"

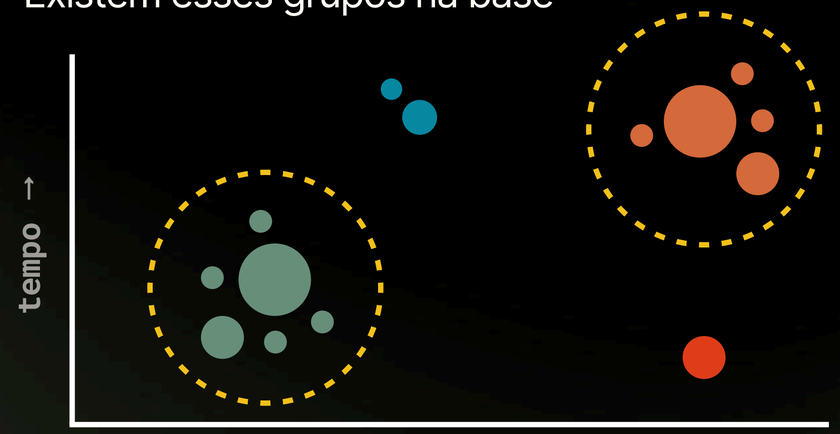

Forma real que emerge - auditável e mutável

K-Prototype acha o grupo, DBSCAN acha quem foge dele

Dois algoritmos, somente dois *

K-PROTOTYPE

Número + Categoria em uma única distancia

Atributo	C1	C2
Pedidos (num.)	<3	>12
Prato (cat.)	Varia sempre	Repete 1 - 2
Horário (cat.)	Aleatório	Fixo - Almoço

C1 → Explorador novo
menos de 3 pedidos, troca de categoria, sem favorito

C2 → Habitual do almoço
mais de 12 pedidos, 1 - 2 pratos fixos, sempre no almoço

DBSCAN

Densidade separa padrão de ruído

C3 → Outlier
ticket alto, frequencia alta, abandono crônico no checkout

Criando os sintéticos

Transformando o perfil e a voz em um modelo virtual

1/4

Traduzindo um cluster em perfil

O cluster é um grupo de pessoas com padrões parecidos. Antes de conversar, o sistema resume o que mais repete sem fingir que todos são iguais

EXEMPLO - SEGMENTO EXPLORADOR

Padrão predominante: que define o segmento

> de 3 meses de uso · compara opções · ainda não criou favoritos · hesita quando o custo aparece tarde_

Origem: cadastro + métricas + eventos.

O CUIDADO TÉCNICO

Predominância não significa universalidade

Parte do grupo pode agir diferente. O perfil guarda variação, outliers e campos sem evidência.

Resultado: um arquétipo auditável, não uma pessoa média inventada.

Transformando o perfil em um JSON

O JSON organiza o arquétipo num formato que o sistema consegue ler, versionar e usar em toda conversa.

EXEMPLO DE JSON

```
{
  "persona_id": "explorador_v1",
  "profile": {
    "lifecycle": "novo",
    "goal": "explorar com segurança"
  },
  "behavior": {
    "pattern": ["explora", "compara"],
    "frictions": ["custo tardio"]
  },
  "voice": {
    "register": "direto",
    "retrieval_scope": "explorador"
  },
  "boundaries": {
    "unknown": "baixa_confianca"
  }
}
```

Traduzindo o JSON

persona_id
nome do cluster de forma informativa

profile
quem é e o que busca

behavior
como costuma agir e onde trava

voice
qual conjunto de falas reais pode ser recuperado

boundaries
quando não há dado suficiente para responder

O JSON não contém “a verdade do usuário”. Contém instruções rastreáveis para a simulação.

3/4

Recuperando a voz com RAG*

O perfil diz como o grupo age. O qualitativo mostra como ele fala sobre isso.

O RAG conecta os dois na hora da pergunta.

CHAT

Por que mostrar o preço por último gera atrito?

A pergunta vira embedding e busca apenas no qualitativo do segmento explorador.

FALAS RECUPERADAS

“Só descubro o custo quando já escolhi tudo.”

“Prefiro comparar antes de me comprometer.”

Fonte e data seguem junto com cada fragmento.

* **RAG (Retrieval Augmented Generation)** é uma técnica utilizada para ampliar a capacidade de resposta de LLMs, combinando o conhecimento interno do modelo de linguagem com sistemas de recuperação de informações.

4/4

Montar o pacote que alimenta o LLM

O modelo não recebe só “responda como um explorador”. Ele recebe peças com funções diferentes.

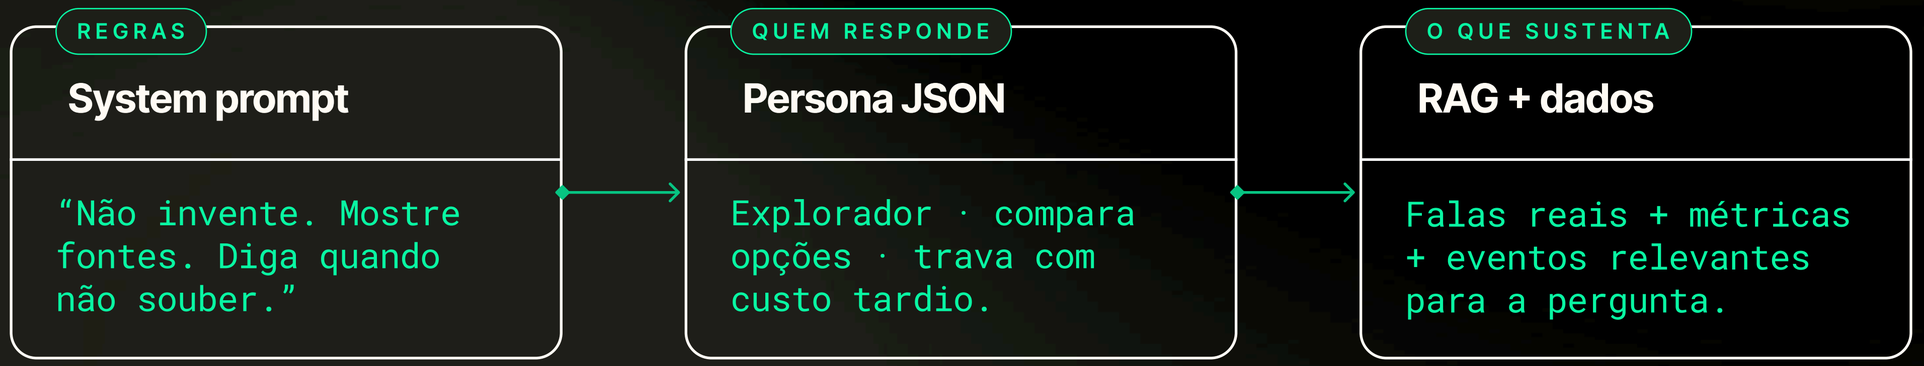

_ pronto para receber perguntas

regras + JSON + evidências + pergunta → resposta simulada

O LLM interpreta o pacote. Não cria a persona nem sua história do zero.

Conversando com os dados

Usando os usuários sintéticos, e melhorando as funcionalidades e modelo

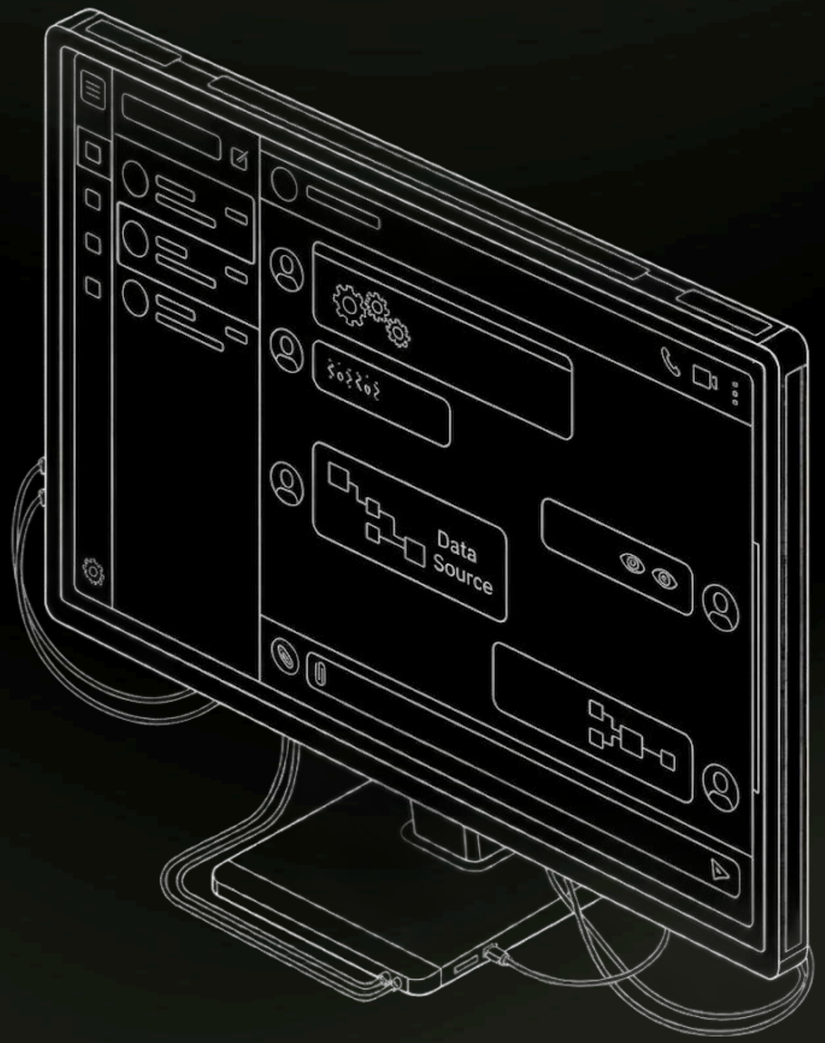

SCREENING

Antes de conversar, escolha o recorte

Nem toda pergunta cabe em toda a base. O screening calibra quem pode responder com assertividade — e quanto da amostra isso representa.

1. Pergunta

Hipótese em linguagem natural

"Pedir de novo" como CTA muda a decisão de compra?

2. Calibragem

Filtros do cluster

Pedidos, onboarding, sessões, região com população?

3. Saída

% assertividade

Escolhe os melhores clusters e abre o chat nesse recorte

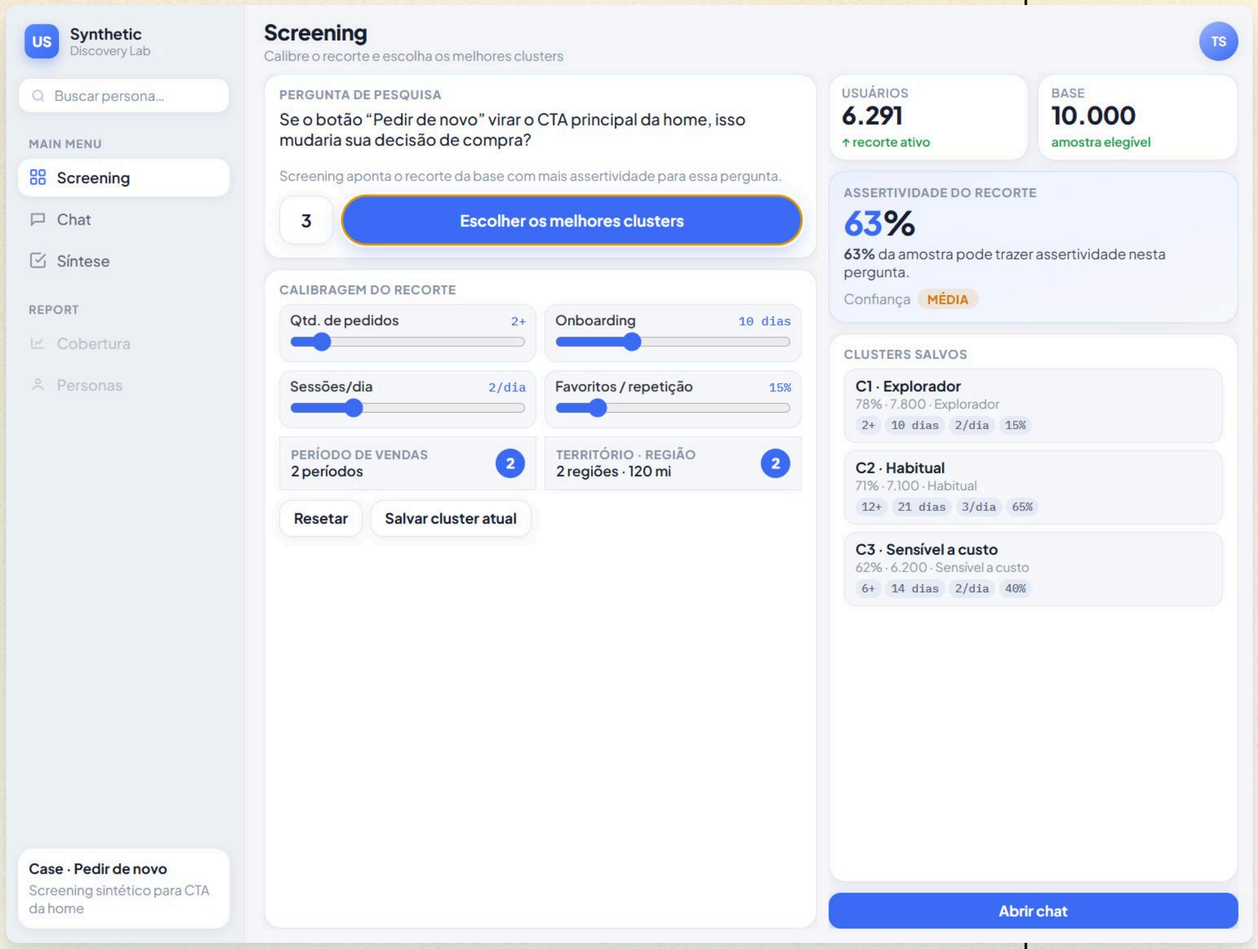

CHAT

A pergunta para as personas

O sistema recupera

Perfil JSON · métricas do segmento · eventos · falas qualitativas sobre repetição, escolha e custo.

O sistema ainda não sabe

Reação real ao novo botão · efeito causal na recompra · emoção vivida diante da interface.

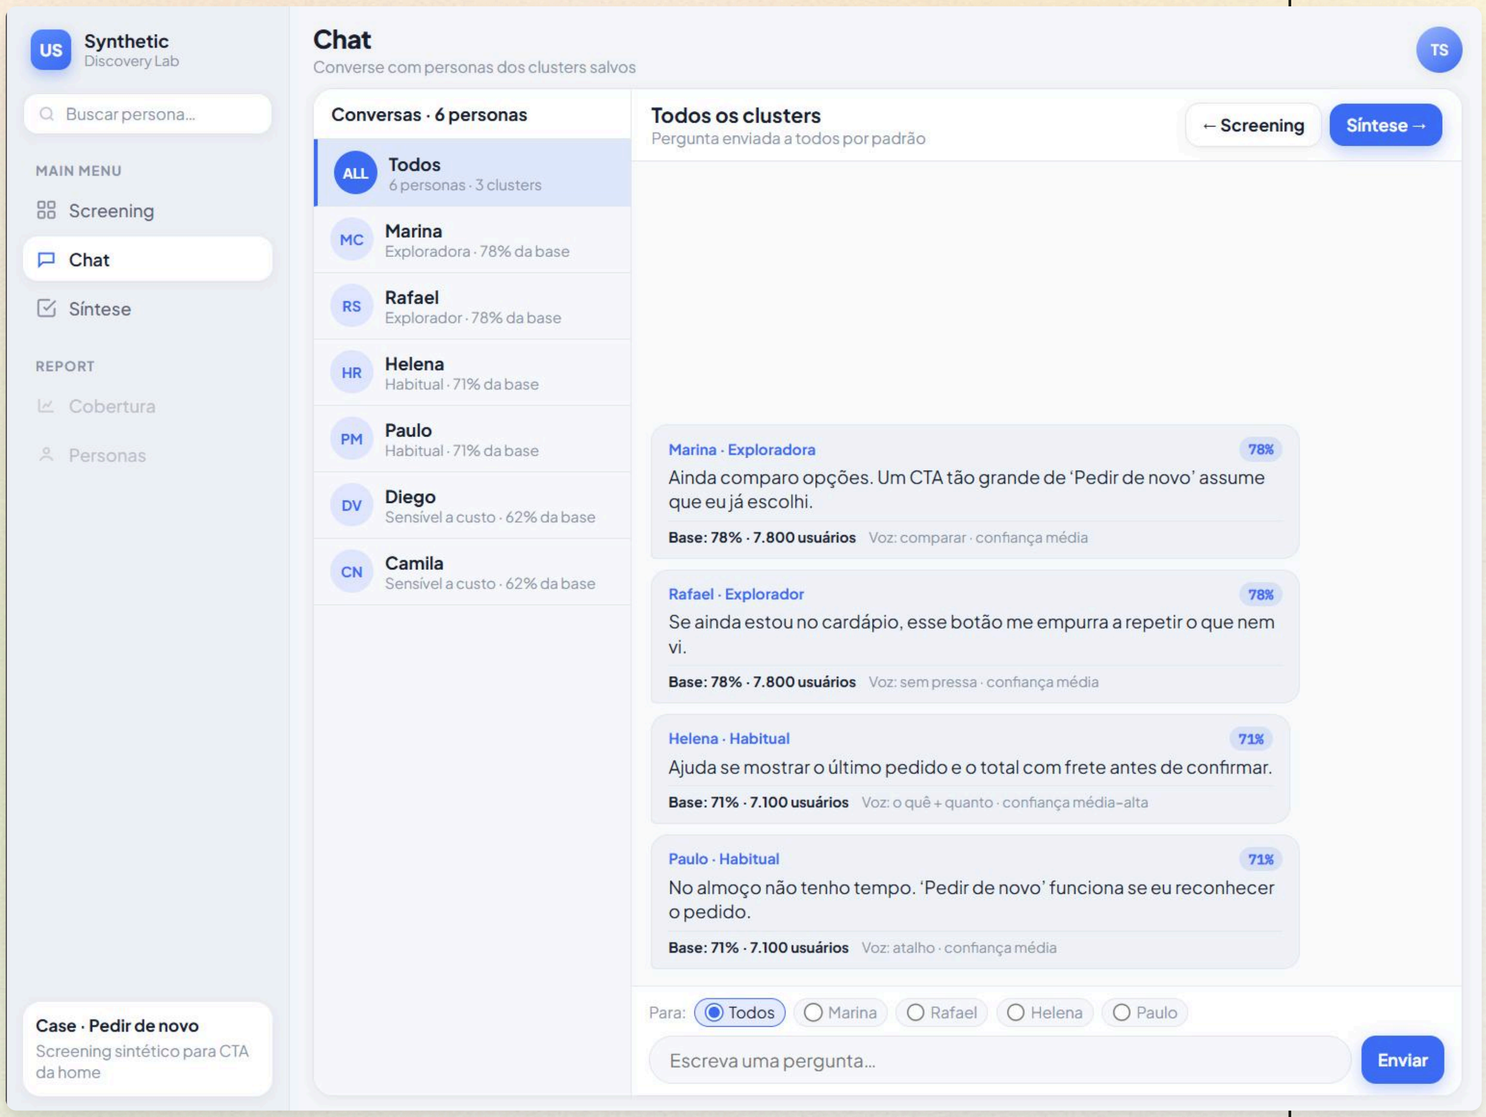

Quando os dados apontam o sucesso

Qual resultado final é esperado após uma conversa com os dados

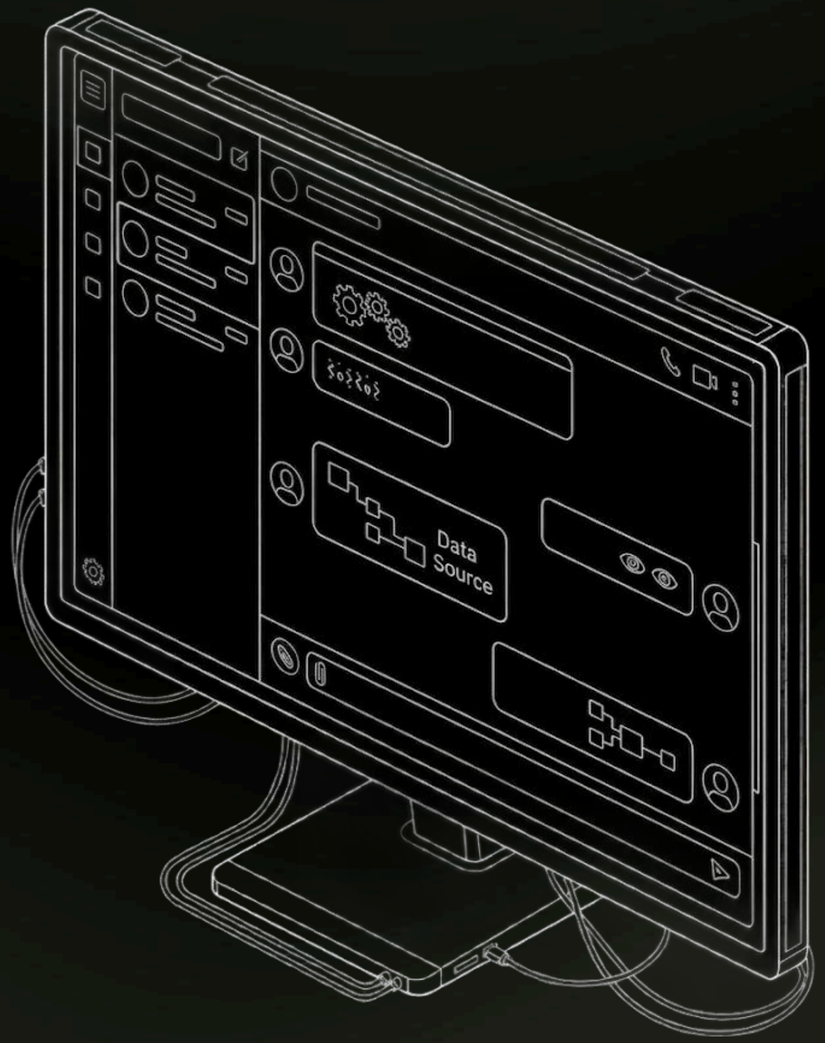

CHAT

Síntese da conversa

Com as personas calibradas e atualizadas é possivel saber com mais certeza quando é momento de falar com o usuário real.

A síntese também pode ajudar a escolher quais são os públicos mais aderentes para campanhas de marketing, ou growth desde que tenhamos acesso aos dados

É possivel integrar leitura de imagens, previsibilidade de comportamento do usuário em tela, análise heuristica e de usabilidade, etc

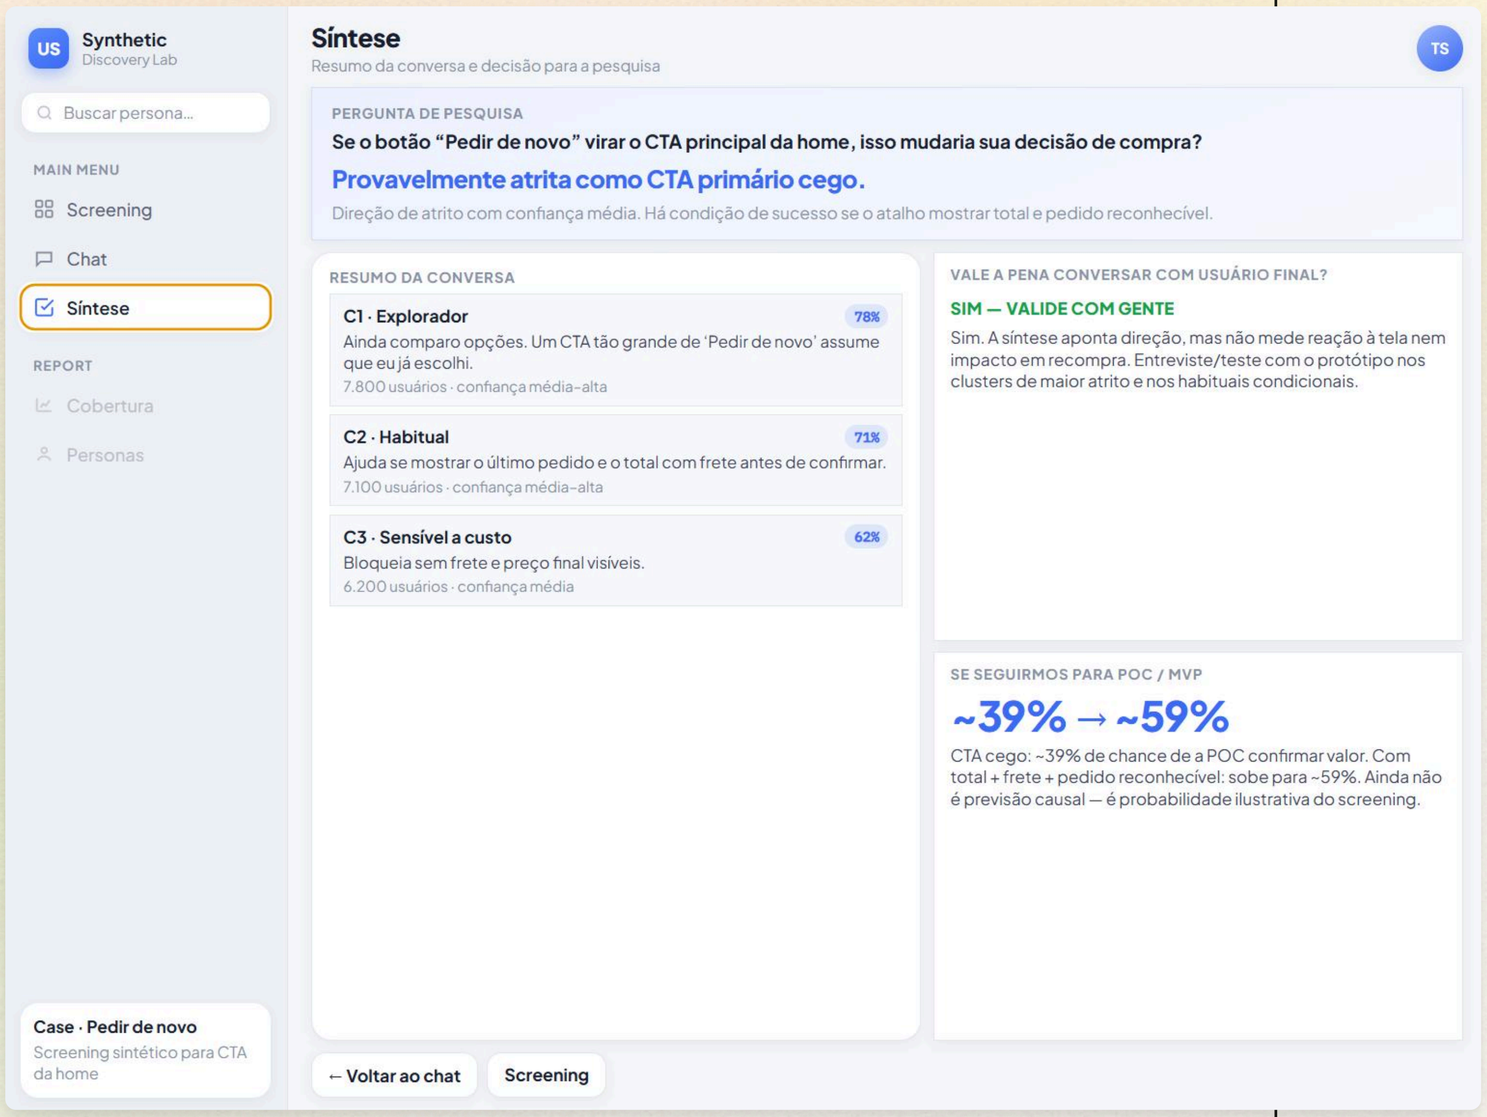

Sintético não substitui pesquisa. Torna a pesquisa real melhor e mais assertiva

TEMPO

hipótese interrogada com personas antes do campo

DINHEIRO

ciclo econômico com teste pré validado no ar, diminuindo ruído

BASE

usuário no centro novamente, com produto estável

O loop sempre volta pro humano. Agora ele volta no momento certo.

tuserpa.me

Obrigada!