

Instrução Assistida por Inteligência Artificial



PROPOSTA DE PARCERIA

25/03/2022

CONTEÚDO



O presente documento divide-se em:

1. Institucional
2. Desafio
3. Principais Marcos
4. Marco 1
5. Marco 2
6. Marco 3
7. Cronograma e prazos
8. Produtização
9. Metodologia e time
10. Cases/Projetos Anteriores
11. Prazo total e investimento

INSTITUCIONAL



Possuímos
o maior
MktPlace
gerenciado
de
experts
em dados do BR!

Nós habilitamos a conexão entre desafios de negócios e a comunidade dos maiores especialistas brasileiros em dados

E como são entregas de alta complexidade técnica, gerenciamos o projeto para garantir o sucesso de cada iniciativa

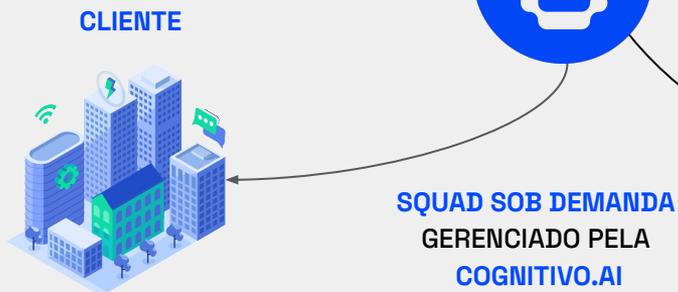
DATA TEAM ON DEMAND - METODOLOGIA

Primeiro, precisamos determinar uma lacuna do negócio que pode ser reduzida através do uso de uma solução de dados

- Pode ser um data lake, um relatório, um dash, um modelo de IA, ...

Nosso objetivo é acelerar e reduzir o risco na criação desta solução.

A contratação se dá por um **pool de horas mensal** de trabalho da **squad multidisciplinar**, que avança com o projeto segundo as boas práticas da **metodologia ágil**.



+250
PROJETOS
DE DADOS

+100
CLIENTES

Que tomam decisões
diariamente através de
dados

4%
MELHORES
PROFISSIONAIS
DE DADOS DO
MERCADO BR

CLIENTES

Trabalhamos com empresas de diferentes portes, setores e segmentos, desde startups de tecnologia até enterprises.



Levam o cliente em consideração e têm o skin on the game. Bem estruturados, com mindset correto e sempre buscando trabalhar com as melhores tecnologias e profissionais.

- **Lucas Zago, Diretor de Tecnologia da Tok&Stok**



A equipe da Cognitivo conseguiu nos proporcionar uma combinação ótima entre o conhecimento técnico e a visão de negócios.

- **Rodolfo Amstalden, Sócio Fundador da Empiricus**



A equipe da Cognitivo.ai foi resiliente e dedicada na resolução de problemas junto às equipes internas do Grupo Fleury no desenvolvimento da melhor solução possível.

- **Beatriz Tonhazolo, Inovação Grupo Fleury**



ATUAÇÃO

A Cognitivo.ai suporta iniciativas nos diferentes domínios da área de dados



ENGENHARIA DE DADOS

Trabalhos de ingestão e centralização de dados

Ex:

Desenvolvimento de coletores de dados

Estruturação de Data Lakes



BUSINESS INTELLIGENCE

Disponibilização de dados para as áreas de negócio

Ex:

Modelagem de Data Warehouses

Implementação de dashboards



INTELIGÊNCIA ARTIFICIAL

Análise descritiva e modelagem preditiva

Ex:

Análise descritiva

Modelos de classificação, regressão, recomendação, clusterização, otimização, ...



Startup especializada em levar a cultura data-driven às empresas recebe aporte de R\$ 2,4 milhões

Quinta-feira, 11 de março de 2021



A **Cognitivo AI**, startup que cria soluções para tornar o ambiente corporativo nacional data-driven, recebeu um aporte de **R\$ 2,4 milhões**. A rodada contou com vários investidores da **Empiricus**, como Rodolfo Amstalden, Leonardo Machado, Guilherme Queiroz, Matheus Baldi e Agapito Troina. Criada em 2017, é uma plataforma que seleciona, aloca e gerencia profissionais sob demanda para resolverem problemas de negócio por meio de projetos de dados.

"Conseguimos, em cerca de 2 semanas, entender o problema de negócio da empresa, transformá-lo em um problema de dados, arquitetar uma solução de ponta e montar um time de experts para implementar e incorporar a solução na realidade da empresa. Nas semanas seguintes, o time, criado a partir da nossa comunidade de profissionais

seudinheiro

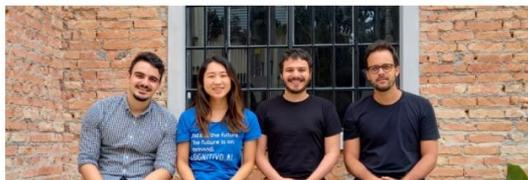
INOVAÇÃO

Buscando táxi em dia de chuva: como a Cognitivo quer se tornar o Uber dos profissionais de tecnologia

Startup recebeu R\$ 2,4 milhões na mais recente rodada de investimentos com "marketplace de experts gerenciado com inteligência artificial"

Kaype Abreu

10 de março de 2021 9:23 - atualizado às 19:20



exame.

EXAME IN

Startup Cognitivo recebe R\$ 2,4 mi para virar modelo em ciência de dados

Fundada em 2017, startup já executou 150 desafios com solução por dados para grandes empresas brasileiras

Valenti

18/03/2021 às 13h11
18/03/2021 às 13h23

leitura: 7 min



**FOCO NO RESULTADO,
QUALIDADE NAS ENTREGAS
E TRANSPARÊNCIA
NO DIA-A-DIA**

DESAFIO



Desafio

Utilização de técnicas de NLP com o objetivo de:

1. Detecção de significado nas peças processuais. Inclui identificação das alegações, exame de admissibilidade, cálculo da probabilidade de concessão de medidas cautelares.
2. Painel de jurimetria. Inclui priorização de processos e comparação com causas anteriores.
3. Redação de peças. Inclui geração de comunicações aos interessados e de instruções contendo sumarização de teses e predição da análise técnica e das propostas de encaminhamento.

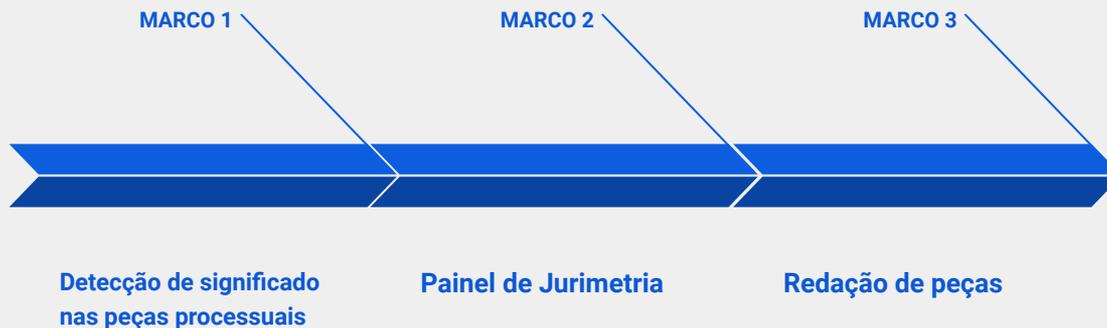
Proposta

A presente proposta contemplará os tópicos que descrevem como a Cognitivo.ai entende os possíveis caminhos para solução, sendo explícito as abordagens, riscos e racionais de cálculo de valores.

PRINCIPAIS MARCOS



Principais Marcos



Ordem de priorização

Entendemos que a ordem de atuação no desenvolvimento dos Marco deve-se seguir conforme sugerido pelo edital, uma vez que, no cenário que seja possível desenvolver um MVP, já temos chances de utilizar dos resultados deste MVP como insumos para o Marco seguinte, dado que foram identificados semelhanças de abordagem de desenvolvimento em alguns marcos.

MARCO 1

Rotas tecnológicas



MARCO 1

Detecção de significado nas peças processuais

Atividades previstas:

- Análise exploratória e validação de hipóteses
- Utilização de técnicas de modelagem
- Treino e Avaliação da performance
- Modelo baseline
- Modelo v1, v2, v3... v(n)
- Documentação e homologação

MARCO 1

Detecção de significado nas peças processuais

Prováveis rotas tecnológicas:

Utilização de modelos de NLP baseados na arquitetura de rede neural do tipo “transformer”, onde podem ser utilizados modelos treinados com diferentes fontes de dados. Para este objeto, acredita-se ser possível treiná-los de acordo com o contexto jurídico utilizando língua Portuguesa.

Um destes modelos pode ser o SemBERT, cuja abordagem do mesmo é baseado no nível de palavras que incorporam contextos semânticos do texto, essa técnica pode ser testado para:

- **Interpretação do contexto das petições iniciais para ser possível classificar 10 tópicos (Sim ou Não e checkbox) a serem preenchidos (de acordo com a explicação explícita no vídeo disponibilizado pelo TCU***
- **Para a identificação das irregularidades, extração dos fatos e evidências, pode ser utilizadas técnicas padrões de classificação, uma vez que já existe uma base descrita sobre as mesmas (100 irregularidades) além de abordagens de utilização de técnicas de aprendizado não supervisionado por similaridade.**

Em tempo de pesquisa e desenvolvimento, podem ser utilizadas outras técnicas/modelos, o escopo de atuação não está restrito ao modelo citado acima

*<https://www.youtube.com/watch?v=yD4ARSwLvQE&t=198s>

MARCO 1

Detecção de significado nas peças processuais

Geração de massa de dados

Por se tratar de uma necessidade de **extrapolação do estado da arte**, pode ser necessário utilizar de modelos prontos, porém sendo necessário o re-treino do mesmo de acordo com o contexto jurídico utilizando Língua Portuguesa

A geração da massa de dados divide-se em:

- Encomenda inicial pelo TCU (preferencialmente dump das petições em formato estruturado, pdf (texto) e/ou word)
- Qualidade dos dados (análise de volumetria mínima, formato dos arquivos, complexidade de leitura etc)
- Rotulação (identificação do que será necessário rotular e se será necessário)
- Saneamento (preparação dos datasets, desconsiderar teses irrelevantes, gerar massa de treino etc)

MARCO 1

Descrição de solução

O que será entregue?

- Documentação sobre todo o processo de modelagem e desenvolvimento (para cada modelo);
- Script em Python, com extensão .py (para cada modelo)
- Ambos entregáveis disponibilizados via Git (plataforma que hospeda códigos de desenvolvimento)

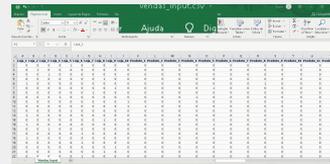
O que é necessário possuir para executar?

- Máquina Local e/ou ambiente virtual (VM)
- Processo totalmente manual (baixar dados de entrada, executar o script, analisar o excel de saída etc)***vide nota**

***A Cognitivo.ai pode atuar tanto somente no desenvolvimento dos modelos para testar e validar sua viabilidade como também na produção (vide seção produção), o foco inicial se dará apenas no desenvolvimento dos modelos, a produção dependerá de alinhamento e negociação com a equipe técnica (T.I) do TCU**

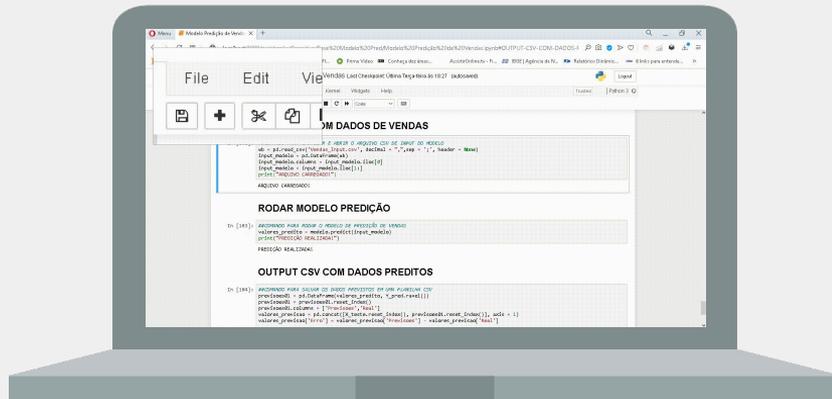
EXEMPLO ILUSTRATIVO
E CONCEITUAL

CSV IN

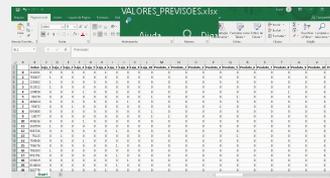


MENSAS	VALORES
...	...

SCRIPT PYTHON



CSV OUT



VALORES	PREVIZOES
...	...

MARCO 1

Desafios do marco

No atual momento de desenvolvimento desta proposta, ainda não é possível obter mais detalhes da solução, uma vez que conforme descrito no edital, ainda existe algumas etapas de negociação, sendo assim os principais desafios que podem impactar no investimento e prazo aqui descritos são:

- **Clareza da quantidade de modelos a serem desenvolvidos**
- **Clareza da complexidade e necessidade de produtização dos modelos desenvolvidos**
- **Incertezas sobre a qualidade dos dados (volumetria, consistência e robustez)**

O backlog será desenvolvido em tempo de negociação do projeto, uma vez que será possível refinar os pontos/incertezas anteriormente citados

A aferição dos resultados, métricas de performance e percentuais a serem atingidos deverão ser negociados uma vez que seja feita a etapa de sanitização (passado a etapa de qualidade dos dados), no atual momento da elaboração da proposta, dado o nível de detalhes disponibilizados não é possível estimar, mensurar nem definir tais pontos.

MARCO 2

Rotas tecnológicas



MARCO 2

Painel de Jurimetria

Atividades previstas:

- Entendimento do negócio e sobre como os dados são representados;
- Levantamento funcional dos indicadores e criação do mockup do dashboard
- Desenvolvimento dos ETLs para materializar os indicadores mapeados
- Desenvolvimento da camada de visualização
- Disponibilização do dashboard desenvolvido
- Documentação e homologação

Painel de Jurimetria

Prováveis rotas tecnológicas:

A abordagem de desenvolvimento de um dashboard padrão de mercado consiste em um trabalho tipicamente de Business Intelligence, onde que, dado o escopo e necessidade apresentadas no edital, este trabalho pode ir um pouco além, sendo necessário uso de recursos de machine learning para se chegar nos resultados esperados a serem apresentados no painel

Pela quantidade de detalhes apresentadas no vídeo do edital* e dado que o painel apresentado é meramente ilustrativo/fictício, entendemos que as rotas tecnológicas a serem utilizadas consistirão em utilizar de abordagens tradicionais de desenvolvimento de projetos de B.I como também de projetos de NLP (classificação - scores de probabilidades, análise de similaridade etc):

- Para comparação com causas anteriores, poderão ser testados todas as técnicas de NLP disponíveis e conhecidas atualmente, entendendo qual delas dispõe da melhor performance

Painel de Jurimetria

Geração de massa de dados

Por se tratar de uma necessidade de extrapolação do estado da arte, pode ser necessário utilizar de modelos prontos, porém sendo necessário o re-treino do mesmo de acordo com o contexto jurídico utilizando Língua Portuguesa

A geração da massa de dados divide-se em:

- Encomenda inicial pelo TCU (preferencialmente dump das causas anteriores em formato estruturado, pdf (texto) e/ou word)
- Se existir, dados prontos e estruturados para o desenvolvimento do mockup do dashboard
- Qualidade dos dados (análise de volumetria mínima, formato dos arquivos, complexidade de leitura etc)
- Rotulação (identificação do que será necessário rotular e se será necessário)
- Saneamento (preparação dos datasets, desconsiderar peças irrelevantes, gerar massa de treino etc)

MARCO 2

Descrição de solução

No cenário que seja necessário desenvolvimento de modelo, a solução será:

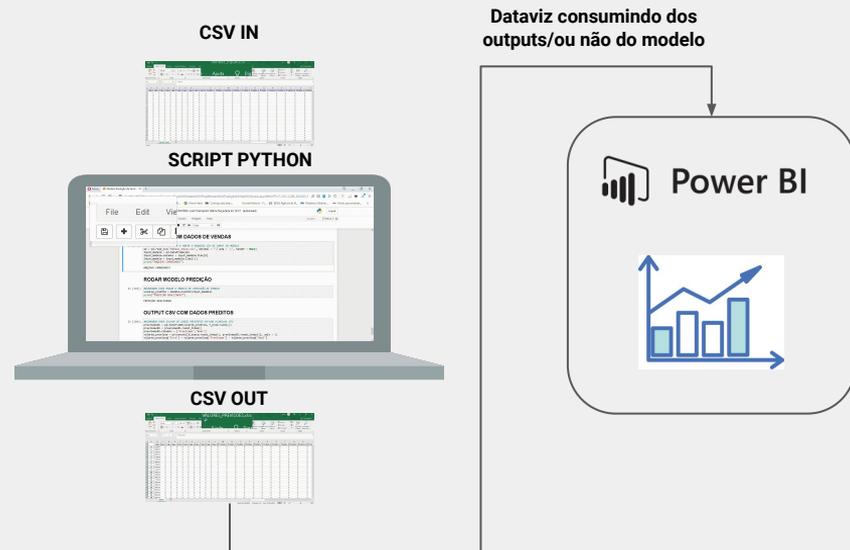
O que será entregue?

- Documentação sobre todo o processo de entrevistas, análise funcional e de modelagem
- Script em Python, com extensão .py (para o cenário que tenha sido necessário desenvolvimento de um modelo para ser materializar os resultados no dashboard)
- Painel desenvolvido em alguma ferramenta de DataViz de mercado (PowerBi, Tableau, DataStudio, Metabase, Qlik etc) ou via linguagem de programação*
- Ambos entregáveis disponibilizados via Git (plataforma que hospeda códigos de desenvolvimento)

O que é necessário possuir para executar o modelo?

- Máquina Local e/ou ambiente virtual (VM)
- Processo totalmente manual (baixar dados de entrada, executar o script, analisar o excel de saída etc)***vide nota**

EXEMPLO ILUSTRATIVO
E CONCEITUAL



*A Cognitivo.ai pode atuar tanto somente no desenvolvimento do modelo como também na produtização (vide seção Produtização), o foco inicial se dará apenas no desenvolvimento do modelo, a produtização dependerá de alinhamento e negociação com a equipe técnica (T.I) do TCU. A definição do dataviz deverá ser negociada junto a equipe técnica TCU, sendo discutido se o mesmo será desenvolvido em ferramenta de mercado ou via linguagem de programação python, a integração do mesmo também deverá ser negociada

MARCO 2

Desafios do marco

No atual momento de desenvolvimento desta proposta, ainda não é possível obter mais detalhes da solução, uma vez que conforme descrito no edital, ainda existe algumas etapas de negociação, sendo assim os principais desafios que podem impactar no investimento e prazo aqui descritos são:

- Clareza da necessidade e quantidade de modelos a serem desenvolvidos neste Marco
- Incertezas sobre a qualidade dos dados (volumetria, consistencia e robustez)
- Clareza da complexidade e necessidade de produtização dos modelos desenvolvidos
- Clareza sobre layout, indicadores e informações contidas no painel de jurimetria
- Clareza sobre dinâmica de funcionamento do painel de jurimetria e suas devidas conexões/relações com outros sistemas e informações

O backlog será desenvolvido em tempo de negociação do projeto, uma vez que será possível refinar os pontos/incertezas anteriormente citados

A aferição dos resultados, métricas de performance, percentuais e o que seria um entregável aceito do painel deverão ser negociados uma vez que seja feita a etapa de negociação e sanitização (passado a etapa de qualidade dos dados), no atual momento da elaboração da proposta, dado o nível de detalhes disponibilizados não é possível estimar, mensurar nem definir tais pontos.

MARCO 3

Rotas tecnológicas



MARCO 3

Redação de peças

Atividades previstas:

- Análise exploratória e validação de hipóteses
- Utilização de técnicas de modelagem
- Treino e Avaliação da performance
- Modelo baseline
- Modelo $v_1, v_2, v_3 \dots v(n)$
- Documentação e homologação

MARCO 3

Redação de peças

Prováveis rotas tecnológicas:

A abordagem de desenvolvimento de um modelo de sumarização e geração de texto para o contexto jurídico é complexa, abordagens padrão de fato não resolverão o problema. Quando tratamos sobre Predição de Análise e do encaminhamento, existe a possibilidade de serem reaproveitados resultados das pesquisas anteriores dos outros Marco, contemplando também modelos de classificação padrão para se chegar no resultado probabilístico da predição de análise.

Para o desenvolvimento do modelo de sumarização e geração de texto:

- Podemos utilizar de abordagens já realizadas em projetos semelhantes no qual a Cognitivo.ai desenvolveu. Nesse cenário, será preciso avaliar se os resultados obtidos estão aderentes ao cenário exposto (contexto jurídico), caso negativo, podemos partir para novas técnicas com caráter de pesquisa e assim chegar em um resultado próximo do esperado

MARCO 3

Redação de peças

Geração de massa de dados

Pode ser necessário entendimento das teses passadas buscando compreender quais trechos foram retirados e sumarizados. No cenário que exista um padrão para se identificar e realizar a sumarização, podemos realizar este trabalho seja de forma manual e/ou utilizando de recursos de apoio.

A geração da massa de dados divide-se em:

- Encomenda inicial pelo TCU (preferencialmente dump das teses anteriores em formato estruturado, pdf (texto) e/ou word)
- Qualidade dos dados (análise de volumetria mínima, formato dos arquivos, complexidade de leitura etc)
- Rotulação (identificação do que foi sumarizado anteriormente e o que deve ser sumarizado para gerar massa de treino)
- Saneamento (preparação dos datasets, desconsiderar teses irrelevantes, gerar massa de treino etc)

Descrição de solução

O que será entregue?

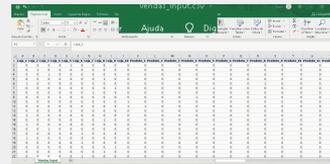
- Documentação sobre todo o processo de modelagem e desenvolvimento (para cada modelo);
- Script em Python, com extensão .py (para cada modelo)
- Ambos entregáveis disponibilizados via Git (plataforma que hospeda códigos de desenvolvimento)

O que é necessário possuir para executar?

- Máquina Local e/ou ambiente virtual (VM)
- Processo totalmente manual (baixar dados de entrada, executar o script, analisar o excel de saída etc)***vide nota**

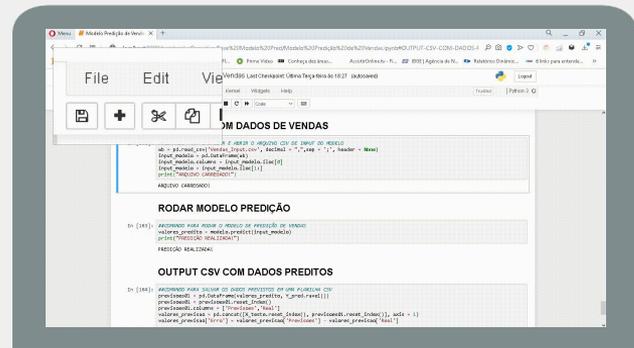
***A Cognitivo.ai pode atuar tanto somente no desenvolvimento dos modelos para testar e validar sua viabilidade como também na produção (vide seção produção), o foco inicial se dará apenas no desenvolvimento dos modelos, a produção dependerá de alinhamento e negociação com a equipe técnica (T.I) do TCU**

CSV IN



MENSAS	VALORES
...	...

SCRIPT PYTHON



```
#!/usr/bin/env python3
# -*- coding: utf-8 -*-
import pandas as pd
import numpy as np
import os
import sys

# Carregar o arquivo CSV de entrada
arquivo_entrada = 'dados_entrada.csv'
df = pd.read_csv(arquivo_entrada)

# Preparar os dados para o modelo
X = df[['tempo', 'tempo_mes', 'tempo_dia']]
y = df['valor_mes']

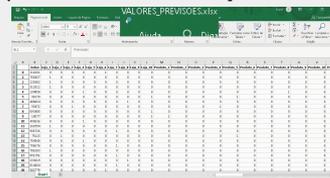
# Treinar o modelo
modelo = LinearRegression()
modelo.fit(X, y)

# Rodar o modelo para prever
arquivo_saida = 'dados_saida.csv'
df_saida = pd.DataFrame()

for i in range(0, df.shape[0]):
    X_test = df[['tempo', 'tempo_mes', 'tempo_dia']].iloc[i:i+1]
    y_pred = modelo.predict(X_test)
    df_saida = df_saida.append({'tempo': df['tempo'].iloc[i], 'tempo_mes': df['tempo_mes'].iloc[i], 'tempo_dia': df['tempo_dia'].iloc[i], 'valor_mes': y_pred})

# Salvar o arquivo de saída
df_saida.to_csv(arquivo_saida, index=False)
```

CSV OUT (texto resumizado para cada tese de input)



MENSAS	VALORES
...	...

MARCO 3

Desafios do marco

No atual momento de desenvolvimento desta proposta, ainda não é possível obter mais detalhes da solução, uma vez que conforme descrito no edital, ainda existe algumas etapas de negociação, sendo assim os principais desafios que podem impactar no investimento e prazo aqui descritos são:

- Clareza da necessidade e quantidade de modelos a serem desenvolvidos neste Marco
- Incertezas sobre a qualidade dos dados (volumetria, consistencia e robustez)
- Clareza da complexidade e necessidade de produtização dos modelos desenvolvidos

O backlog será desenvolvido em tempo de negociação do projeto, uma vez que será possível refinar os pontos/incertezas anteriormente citados

A aferição dos resultados, métricas de performance, percentuais e o que seria um entregável aceito do painel deverão ser negociados uma vez que seja feita a etapa de negociação e sanitização (passado a etapa de qualidade dos dados), no atual momento da elaboração da proposta, dado o nível de detalhes disponibilizados não é possível estimar, mensurar nem definir tais pontos.

CRONOGRAMA





PRAZO MARCO 1

12 MESES

Nossa estimativa é que a duração de 12 meses para este marco seja suficiente para ao menos ter resultados da pesquisa e algum modelo MVP desenvolvido, dado todas as incertezas que cercam a iniciativa.

Marco 1 - 3~4 meses cada modelo - estimativa

Conforme mencionado anteriormente, ainda não é possível definir a quantidade de modelos necessários neste marco, pode ser que 1 modelo seja suficiente, como pode ser necessários mais modelos para cada caso. Nossa estimativa é baseada em projetos anteriores em cenários semelhantes

ETAPAS	Mês 1				Mês 2				Mês 3				Mês 4					
	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	S11	S12	S13	S14	S15	S16		
Refinamento/Diagnóstico	Somente 1º modelo																	
Análise exploratória																		
Definição de métrica de resultado																		
Modelo Baseline																		
Modelo v1, v2, ...																		
Documentação																		
Homologação																		

O cronograma pode ser afetado pelos seguintes aspectos não mapeados.: Processos internos e prazos da equipe TCU, (principalmente na fase de encomenda de dados), requisitos de segurança, particularidade dos dados para tratar LGPD, complexidade para obter os dados, necessidade de tratamento/estruturação para disponibilizar o dado e volumetria de dados.



PRAZO MARCO 2

12 MESES (9 meses de modelos + 3 meses de dashboard)

Nossa estimativa, dado todas as incertezas que cercam a iniciativa. é que a duração de 12 meses para este marco seja suficiente para ao menos ter resultados da pesquisa e algum modelo MVP desenvolvido como também um dashboard trazendo os principais indicadores

Marco 2 - 3~4 meses cada modelo - estimativa

Conforme mencionado anteriormente, ainda não é possível definir a quantidade de modelos necessários neste marco, pode ser que 1 modelo seja suficiente, como pode ser necessários mais modelos para cada caso. Nossa estimativa é baseada em projetos anteriores em cenários semelhantes

ETAPAS	Mês 1				Mês 2				Mês 3				Mês 4					
	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	S11	S12	S13	S14	S15	S16		
Refinamento/Diagnóstico	Somente 1º modelo																	
Análise exploratória																		
Definição de métrica de resultado																		
Modelo Baseline																		
Modelo v1, v2, ...																		
Documentação																		
Homologação																		

O cronograma pode ser afetado pelos seguintes aspectos não mapeados.: Processos internos e prazos da equipe TCU, (principalmente na fase de encomenda de dados), requisitos de segurança, particularidade dos dados para tratar LGPD, complexidade para obter os dados, necessidade de tratamento/estruturação para disponibilizar o dado e volumetria de dados.

Marco 2 - 3 meses (Dashboard) - estimativa

ETAPAS	Mês 1				Mês 2				Mês 3			
	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	S11	S12
Análise e entrevistas funcionais	█											
Desenvolvimento do Mockup			█									
Desenvolvimento dos ETLs					█							
Desenvolvimento do Dataviz						█						
Documentação	█						█					
Homologação										█		

O cronograma pode ser afetado pelos seguintes aspectos não mapeados.: Processos internos e prazos da equipe TCU, (principalmente na fase de encomenda de dados), requisitos de segurança, indisponibilidade da equipe para as entrevistas funcionais, particularidade dos dados para tratar LGPD, complexidade para obter os dados, necessidade de tratamento/estruturação para disponibilizar o dado e volumetria de dados.



PRAZO MARCO 3

6 MESES

Nossa estimativa, dado todas as incertezas que cercam a iniciativa. é que a duração de 6 meses para este marco seja suficiente para ao menos ter resultados da pesquisa e algum modelo MVP desenvolvido como também um dashboard trazendo os principais indicadores

Marco 3 - 3~6 meses cada modelo - estimativa

Conforme mencionado anteriormente, ainda não é possível definir a quantidade de modelos necessários neste marco, pode ser que 1 modelo seja suficiente, como pode ser necessários mais modelos para cada caso. Nossa estimativa é baseada em projetos anteriores em cenários semelhantes

ETAPAS	Mês 1				Mês 2				Mês 3				Mês 4					
	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	S11	S12	S13	S14	S15	S16		
Refinamento/Diagnóstico	Somente 1º modelo																	
Análise exploratória																		
Definição de métrica de resultado																		
Modelo Baseline																		
Modelo v1, v2, ...																		
Documentação																		
Homologação																		

O cronograma pode ser afetado pelos seguintes aspectos não mapeados.: Processos internos e prazos da equipe TCU, (principalmente na fase de encomenda de dados), requisitos de segurança, particularidade dos dados para tratar LGPD, complexidade para obter os dados, necessidade de tratamento/estruturação para disponibilizar o dado e volumetria de dados.

PRODUTIZAÇÃO



DISCLAIMER

A Cognitivo.ai entende como produtização ter o modelo desenvolvido gerando resultados sistematicamente e não somente um modelo para validar a viabilidade/prototipagem, de forma que torne o resultado de desenvolvimento um produto utilizável no dia a dia

Serão apresentados nesta proposta 2 opções distintas de produtização dos modelos desenvolvidos, onde que estes deverão ser negociados junto a equipe técnica do TCU a contemplação ou não no escopo de desenvolvimento

Para o cenário que seja considerado o desenvolvimento da produtização, será necessário acrescentar o prazo apresentado para cada modelo distinto desenvolvido (3 ou 4 meses)

Este prazo entendemos que é coerente dado experiências anteriores, uma vez que produtizar um modelo de I.A cuja solução pode extrapolar o estado da arte, existe a chance da utilização de recursos e técnicas complexas de engenharia de dados/DevOps.

OPÇÕES DE PRODUTIZAÇÃO

CONCEITOS

Temos 2 opções de produtização:

- **Opção 1:** Modelo executado em batch (assíncrono)
- **Opção 2:** API (síncrono online)

Conceito batch/microbatch assíncrono (OPÇÃO 1):

- Processamento de dados em lotes
- Esta abordagem é mais adequada quando pode-se ter os resultados do modelo de forma assíncrona
- Os resultados do modelo, nesta abordagem, costumam-se depender de dados de entrada (inputs) mais estáticos ou que sofrem menos mutabilidade ao longo do tempo (ao longo da semana, ao longo da quinzena etc)

Conceito síncrono online (OPÇÃO 2):

- Processamento dos dados no momento que é feita a requisição do modelo, onde são gerados resultados de forma síncrona
- Esta abordagem é mais adequada quando é necessário que para cada input (entrada de dados), gere no mesmo instante os resultados para aquele input.
- Nesta abordagem, geralmente trabalha-se com dados de input que sofrem mais mutabilidade ao longo do tempo (ao longo do dia por exemplo)

OPÇÃO 1

MODELO EXECUTADO EM BATCH

OPÇÃO 2

MODELO COMO API

ESPECIFICIDADES	OPÇÃO 1	OPÇÃO 2
AMBIENTE	Container	Container
INPUT DE DADOS	Leitura de banco de dados e/ou arquivo origem de dados (csv, txt)*	Via request HTTP
OUTPUT DE DADOS (RESULTADOS DO MODELO)	Escrita em banco de dados e/ou arquivo destino de dados (csv, txt)	Via response HTTP
USABILIDADE	Acesso direto ao dado	Via API/Endpoint
IDEAL PARA (não exaustivo)	Quando é possível acesso direto aos dados (bancos/arquivos)	Quando a integração com outros sistemas só é viável via API
PRAZO DE DESENVOLVIMENTO	3 MESES	4 MESES

(*) **Nota:** no cenário em que o input de dados será feito a partir de arquivos (csv, txt etc) é necessário que os mesmos estejam sempre atualizados conforme a necessidade.

METODOLOGIA E TIME



METODOLOGIA ON DEMAND

Data Team On Demand é um serviço da Cognitivo.ai que fornece acesso a uma equipe de dados formada pelos melhores do mercado sob demanda

Com o Data Team On Demand, conseguimos ter flexibilidade e agilidade para trabalhar o desenvolvimento da maneira com que for necessário e as skills necessárias.

Através deste serviço, você pode encerrar, continuar ou mudar a estrutura do time como preferir.

METODOLOGIA



Disponibilizaremos **entregáveis parciais** durante todo o projeto



Disponibilizamos todo o **código via Git**

principal



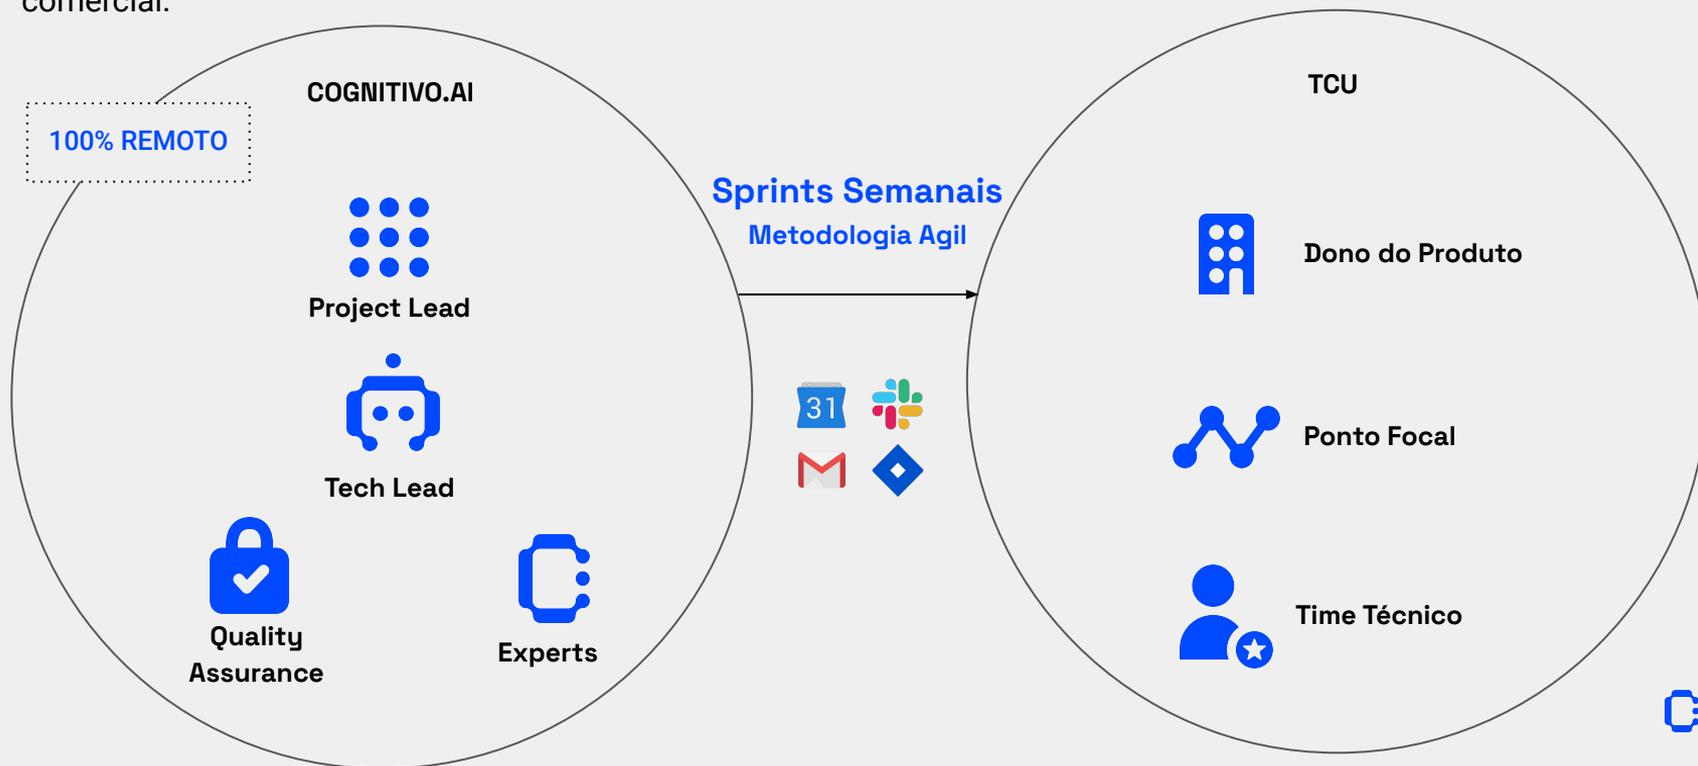
Documentação
explicando tudo o que foi desenvolvido, relatórios de data-quality, performance



Apresentação dos principais resultados do **projeto**

DIA A DIA

As reuniões entre o squad montado pela Cognitivo.ai e o seu time ocorrem de forma 100% remota nas bordas do horário comercial.



FERRAMENTAS

Utilizamos diversas ferramentas de **acompanhamento**, **gestão** e **comunicação** do projeto com o TCU

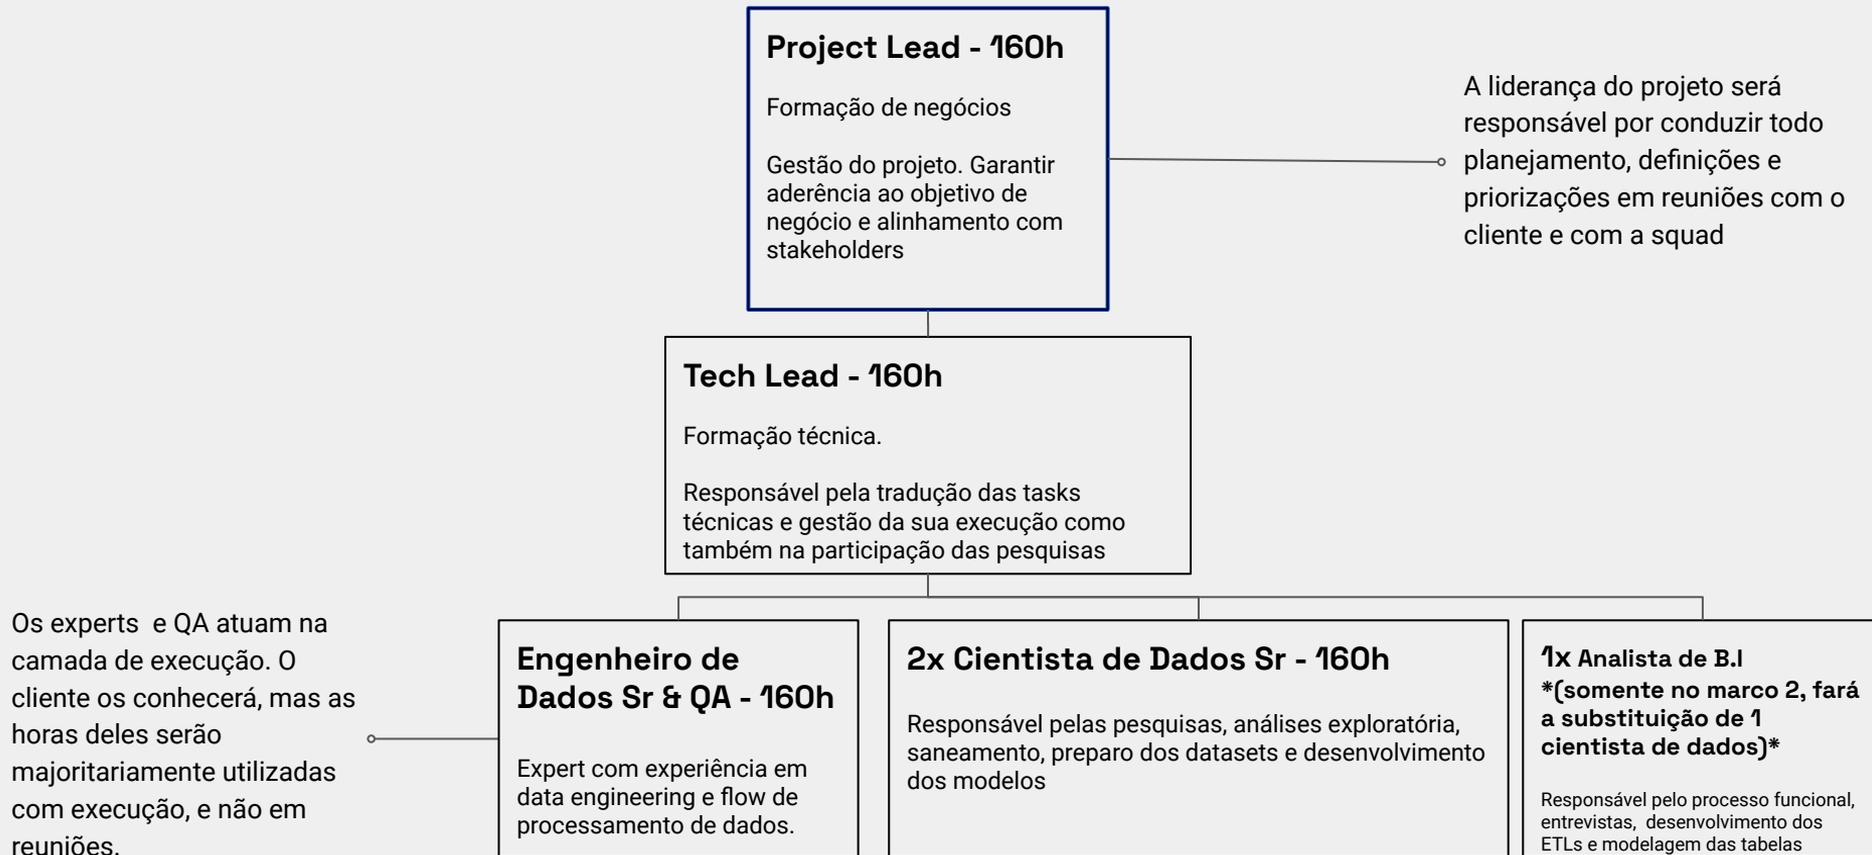
 **Slack** para comunicação assíncrono ou síncrona com as equipes

 **Hubstaff** para acompanhamento, tracking e comprovação das horas trabalhadas, pesquisas realizadas e desenvolvimento (possibilidade de Print Screen da tela do usuário para comprovação)

 **E-mail** para comunicação e formalização de acordos entre as partes

 **Clickup** para gestão do projeto, registro de backlog, divisão de sprints, épicos etc

SQUAD COGNITIVO 800H/MÊS



CURRÍCULOS - possibilidades de atuação

Exemplos de profissionais que pertencem ou pertenceram à comunidade de experts da Cognitivo*

Project Lead

Wolgrand Berthoux → <https://www.linkedin.com/in/wolgrandberthoux/>

Laura Marcolino → <https://www.linkedin.com/in/lauramarcolino/>

Expert NLP

Alessandro Bokan → <https://www.linkedin.com/in/alessandrobokan/>

Felipe Almeida → <https://www.linkedin.com/in/felipeqbalmeida/>

Expert Cientista de Dados

Leonardo Pena → <https://www.linkedin.com/in/leonardo-pena/>

Alexandre Lima → <https://www.linkedin.com/in/alexandrevasconceloslima/>

Expert BI

Dagner Fonseca → <https://www.linkedin.com/in/dagner/>

Diogo Arrieta → <https://www.linkedin.com/in/dioqoarrieta/>

Engenheiro de dados

Bruno Faustino → <https://www.linkedin.com/in/bruno-faustino-amorim-459817116/>

Marcelo Santino → <https://www.linkedin.com/in/msantino/>

Sidney Oliveira → <https://www.linkedin.com/in/sidneyoliveiracirqueira/>

*Os experts apresentados são somente a título de exemplo da capacidade técnica da Cognitivo.ai, não necessariamente farão parte da equipe do projeto. Uma vez a parceria firmada, a equipe Cognitivo definirá quais serão os experts que de fato atuarão no projeto, respeitando normas de compliance de ambas as partes.

**CASES/PROJETOS
ANTERIORES**



CASES

I.A. / NLP



Desafio: A CGVF, reconhecido escritório de advocacia, tinha um grande volume de publicações e processos para acompanhar diariamente. Para isso, era necessário um grande corpo de advogados que liam os processos e os classificaram de acordo com instância, órgão, tipo de publicação e tipo de pedido.

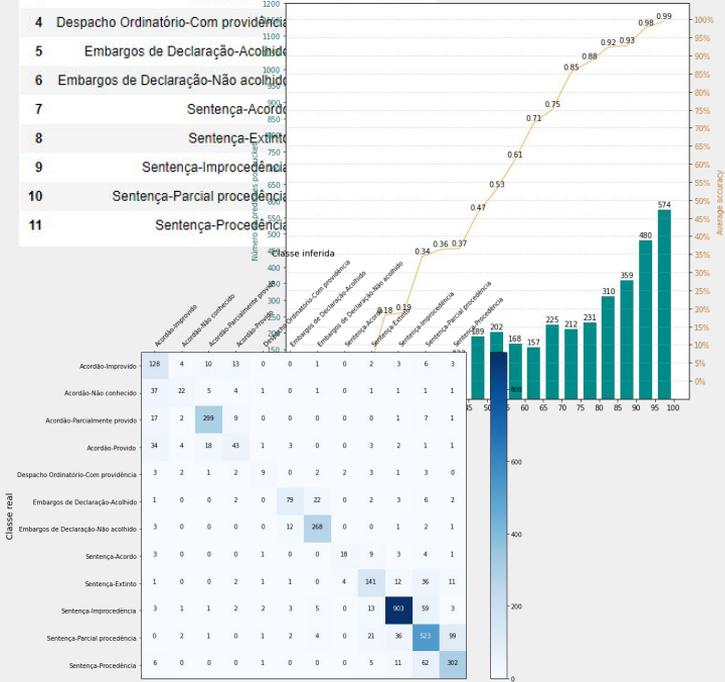
Solução: Utilizamos todo o histórico das publicações e classificações para criar um modelo de NLP que classifica as publicações automaticamente a partir dos textos do processo.

O modelo tem acurácia de 82%. Através dele será possível economizar aproximadamente 1 milhão de reais por ano eliminando mão de obra "manual" de leitura desses documentos.

5 meses de desenvolvimento



	resultado_composto	support	accuracy
0	Acórdão-Improvido	1590	98.30%
1	Acórdão-Não conhecido	96	100.00%
2	Acórdão-Parcialmente provido	399	96.99%
3	Acórdão-Provido	361	94.46%
4	Despacho Ordinatório-Com providência	207	
5	Embargos de Declaração-Acolhido	603	
6	Embargos de Declaração-Não acolhido	650	
7	Sentença-Acordo	850	
8	Sentença-Extinto	750	
9	Sentença-Improcedência	650	
10	Sentença-Parcial procedência	521	
11	Sentença-Procedência	42	



CASES

I.A. / NLP

4 meses de desenvolvimento

rockcontent

Desafio: A Rock Content, uma das maiores empresas de marketing de conteúdo do Brasil, tinha um trabalho manual interno muito grande para resumir os textos que estavam sendo criados. Muito tempo e dinheiro era gasto com esse trabalho operacional.

Solução: Criação de um modelo de NLP que tinha como input um texto e como output o resumo com um parâmetro de número de palavras pré determinado.

Foi quase impossível distinguir o resumo feito pela máquina e por um colaborador. E o modelo está ajudando a Rock a reduzir custos operacionais desnecessários.

CASES

I.A. / CLUSTERING DE CLIENTES

3 meses de desenvolvimento



Desenvolvimento de **modelo de clustering** para identificação dos perfis existentes na base, que abriu espaço para **redução em até 40% do esforço operacional** no processo de cotação de seguros e **melhores ações de marketing**.



Desafio: Maior corretora de seguros auto do Brasil, e a maior do segmento online. Em sua plataforma é possível fazer cotações de forma totalmente digital, e receber propostas de 16+ seguradoras, adequadas às suas necessidades e perfil específicos.

Aterrisava na plataforma uma diversidade muito grande de leads, e como não havia nenhum conhecimento analítico sobre a base histórica, o tratamento dado a cada pedido era genérico. Chegava-se a realizar até 30 cotações para cada pedido, o que representava não apenas um **grande custo operacional**, mas também **atrito com as seguradoras parceiras**, que cotavam para muitos perfis descolados do seu público usual.

Solução: Desenvolveu-se - em um framework open-source - um **modelo de aprendizado não-supervisionado** ("clustering") sobre um histórico de alguns anos de registros de cotação, de onde extraiu-se 5 grupos de leads que contemplavam 98,9% da base. Sobre estes grupos, avaliou-se quais produtos e seguradoras parceiras tinham maior propensão de lhes agradecer e converter em uma venda.

Este script abriu possibilidades para um conjunto de ações otimizadas, que iam desde a **redução do custo operacional em até 40% no processo de cotação**, uma vez que os pedidos passaram a ser cotados apenas nas 3 parceiras que mais agradavam cada lead, até em **melhorias nas ações de marketing**, no sentido de comunicar-se de forma mais personalizada com o mercado.

Ex: cluster "motoristas de aplicativo"



CASES

I.A. / PREDIÇÃO DE DEMANDA PARA VAREJO

4 meses de desenvolvimento



Modelo de Inteligência artificial capaz de **prever a venda dia-a-dia do próximo mês** para cada um dos 40.000 itens do portfólio, **errado em média ~ 1 unidade/item/dia** em cada loja, para mais ou para menos.



Desafio: Rede de supermercados que representa um dos maiores players do mercado capixaba, com portfólio de +40K SKUs vendidos em diferentes mixes entre suas lojas e atacarejos.

O indicador de **ruptura em estoque chegava em 15%** para em algumas categorias de SKUs, sob um processo de gestão do abastecimento baseado na utilização de uma solução de prateleira. → objetivo era nunca ultrapassar 5%.

Além de ser **totalmente blackbox**, o modelo por trás da solução contratada **não era personalizado, não poderia ser adaptado continuamente, e comprometida a escalabilidade** da rede, uma vez que pagava-se por licença.

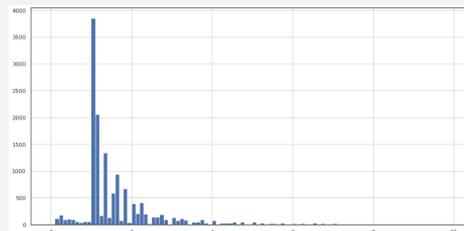
Solução: A partir de um histórico de 2 anos de dados de vendas, preços, promoções, e etc, treinou-se, em apenas 12 semanas, uma modelo **random-forest com tunagem de hiperparâmetros**, capaz de **prever a venda em nível de SKU para todos os 40K SKUs em uma janela de 1 mês**.

Testes em sliding windows mostraram que **o modelo erra menos de 1 unidade/item/dia** de vendas nas 2 unidades escopo do projeto.

ENTREGAS E RESULTADOS

MODELO MVP FINAL: RANDOM FOREST + TUNAGEM DE HIPERPARÂMETROS

Loja 11 - Análise dos resíduos: Produtos pouca venda



Distribuição do Erro Médio Abs

mean	0.07
std	0.27
min	0
25%	0
50%	0
75%	0
max	1.9

COGNITIVO.AI

CASES

I.A. / PREDIÇÃO DE DEMANDA

4 meses de desenvolvimento



Modelos de Inteligência artificial capazes de **prever a venda dos próximos 4 meses** para cada um dos SKUs do portfólio, gerando um **retorno de R\$ 1.5 MM no período de 2 meses**.

Jasmine

Desafio: Indústria do segmento alimentício, focada na produção de health food que buscava aumentar a precisão da sua estimativa de demanda através do uso de IA.

Método utilizado para prever demanda tinha boa precisão em nível global, mas **errava consideravelmente em nível de SKU** e necessitava de intervenções manuais.

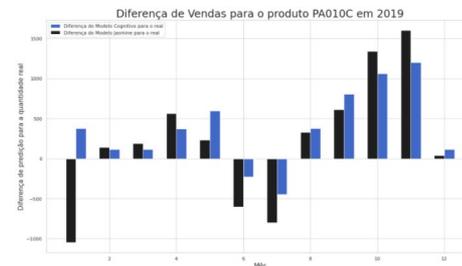
Genário gerava impacto direto em diferentes áreas de negócio e tinha como consequências **ruptura, excesso de estoque e perda de produtos** por prazo de validade próximo, resultando em **perda no faturamento**.

Solução: A partir de um histórico de 10 anos de dados de vendas normais, em apenas **10 semanas**, foram entregues **122 modelos** capazes de **prever a venda em nível de SKU** em uma janela de **120 dias de antecedência**.

Ao analisar o ganho gerado pelos modelos desenvolvidos, o retorno para a Jasmine correspondeu à **R\$ 1.5 MM no período de 2 meses**, a partir de **redução de ruptura, estoque excedente e perdas**.

ENTREGA DE RESULTADOS

produto	media_movel_4	random_forest	Valor_Unitario_Produto	diferenca	roi
31	1753.15625	577.0	275.079976	1176.15625	323537.032942
22	2040.87500	289.0	154.343942	1751.87500	270391.292676
36	1210.21875	201.0	153.952013	1009.21875	155371.258180
29	1044.37500	84.0	154.090448	960.37500	147984.614461
56	1813.28125	877.5	153.989103	935.78125	144100.115554



CASES

I.A. / PREDIÇÃO DE DEMANDA PARA VAREJO

3 meses de desenvolvimento



Modelo de Inteligência artificial capaz de **predizer a venda dentro da categoria de perecíveis** em janelas de 7, 21 e 60 dias de antecedência, **saving de 1.8 Milhões de reais** apenas no primeiro mês de uso



Desafio: Rede do Varejo Supermercadista, originária de Mogi das Cruzes, em 1976 Crescimento acelerado a partir de 1999 em direção ao Vale do Paraíba / Litoral Norte Paulista, 5.200 funcionários, 28 lojas, Faturamento bruto estimado em BRL 1 bi.

Problema de ruptura de estoque principalmente quando se olhava para a categoria de perecíveis(Açoquem frios... etc), “ As vezes precisamos ser agressivo em preço por conta da validade, quando se o nosso processo tiver alta acuracidade estaremos sempre buscando a melhor margem”

- **Problema de ruptura & excesso de estoque**

Solução: Desenvolvimento de modelos de predição de demanda utilizando de técnicas de machine learning, ao total no cenário inicial de 2 lojas e 2500 SKUs.

Foram testados 6 modelos preditivos(MA, ARIMA, RANDOM FOREST, LINEAR REGRESSION, PROPHET, KNN) que buscavam equilibrar a acurácia para as diferentes combinações loja + SKU.

Como resultado o modelo **reduziu o erro de demanda em 19%** o que resultou num **saving de 1.8MM** somente no primeiro mês



CASES

I.A. / OTIMIZAÇÃO DA PRODUÇÃO

3 meses de desenvolvimento

Desenvolvimento em **apenas 8 semanas** de um otimizador capaz de **identificar lacuna financeira de R\$6MM de margem** e determinar o mix ótimo de produção dos diferentes SKUs para capturar esta oportunidade.

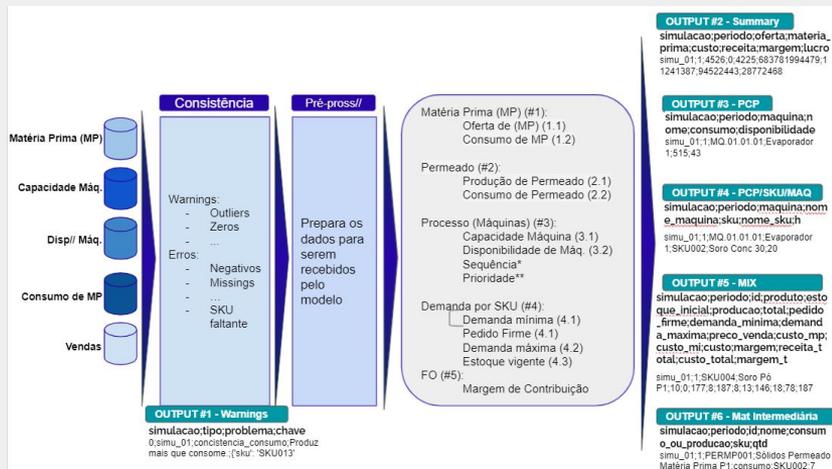


Desafio: Indústria especializada na produção para o mercado b2b de itens para nutrição humana, animal e para indústria alimentícia derivados do soro de leite

O desafio era desenvolver uma ferramenta de otimização de produção que auxilie no atingimento da melhor margem de contribuição global de acordo com demanda e capacidade produtiva com diferentes SKUs

Solução: Desenvolvimento de uma I.A. que permite a simulação de diversos cenários de negócio para que compreendam, em cada uma delas, qual o mix ideal de produção que maximiza sua margem.

Os outputs auxiliam tanto no planejamento da produção quanto no direcionamento da força de vendas e planejamento estratégico.



CASES

I.A. / PREDIÇÃO DE RUPTURA

3 meses de desenvolvimento



Modelo capaz de **prever o fenômeno de ruptura em estoque** em janelas de **15, 30, 45 e 90 dias de antecedência** em rede de mais de 120 lojas multi-marca em nível nacional com **acurácia superior a 80%**

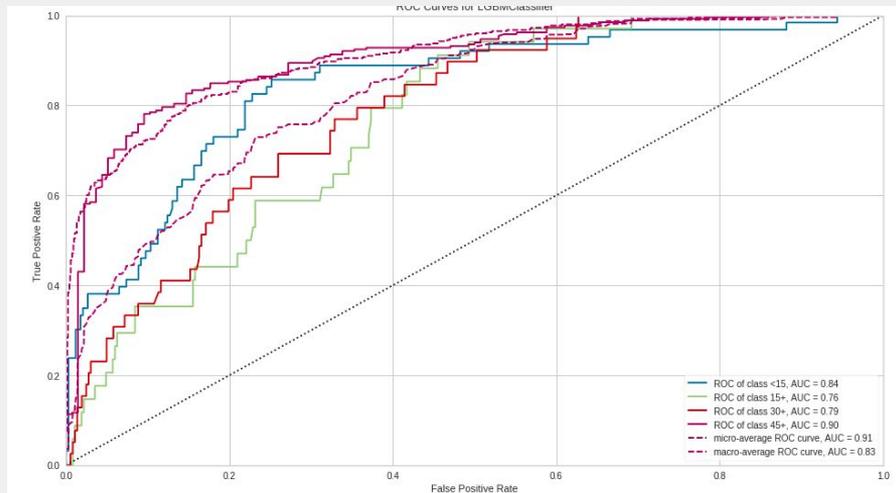


Desafio: Consultoria de trade mkt, que atende algumas das principais marcas varejistas do mundo, queria ajudar seus clientes a **antever ruptura de estoque**, e assim, maximizar retornos financeiros, ao invés de apenas entregar relatórios com lagging indicators

Um desses clientes era uma **rede de +120 lojas em nível BR** que sofria muito com a cadeia de supply e logística da categoria de eletrodomésticos, que compreendia cerca de 30 sub-categorias entre televisores, geladeiras, fogão, e etc de marcas como LG, Brastemp, Consul, Bosch, e etc.

Solução: Criamos em **apenas 8 semanas** um modelo de inteligência artificial sobre um framework open-source, que capta fenômenos de sazonalidade sobre variáveis de vendas e, trabalhado em conjunto com variáveis de estoque, tags de promoção, e etc, é capaz de **determinar os itens que entrarão em ruptura em cada uma das lojas** em diferentes janelas de antecedência.

A **acurácia da predição variou entre 80% e 95%** entre as janelas de 90 e 15 dias de antecedência., respectivamente, e foi a base para um roll-out para as demais categorias.



CASES

I.A. / PREVISÃO DE CHURN

3 meses de desenvolvimento



Desenvolvimento de **modelo preditor de evasão para IES** com forte presença no sudeste brasileiro. O sucesso da IA treinada no EAD foi tão grande que trouxe **recordes históricos para as taxas de rematrícula**.

MULTIVIX

Desafio: IES com mais de 25k alunos com forte atuação no sudeste brasileiro.

O **índice de churn na modalidade EAD chegava a 30%** por semestre para alguns cursos, representando uma grande lacuna financeira.

Apesar de existir um time focado na gestão da permanência, entendia-se que suas **ações eram pouco efetivas**, e eram **tomadas tardiamente**, quando a **decisão da evasão já estava tomada**. Ou seja, alocava-se um grande número de pessoas para se fazer análises e executar ações, e estas ações não atingiam os resultados esperados.

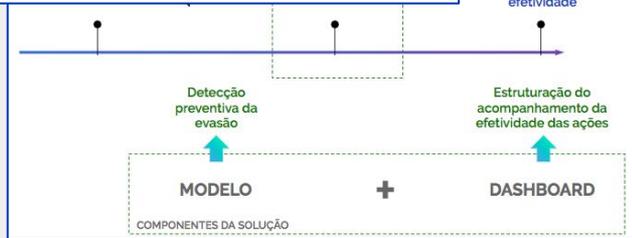
Solução: Em 12 semanas criou-se um **modelo de IA para prever quais eram os alunos mais propensos a evadirem nos próximos 3 meses**. As redes neurais foram treinadas considerando-se variáveis de identidade (idade, gênero, CEP, ...) e de comportamento (pagamentos, notas, exercícios, acessos à plataforma, ...).

O **resultado foi integrado a um dashboard que auxiliava o time de negócios** a observar as propensões sob diferentes óticas e planejar ações antecipadamente.

O sucesso foi tão grande que atingiu-se **recordes históricos de rematrícula**, graças às ações que eram planejadas pelo time de negócios com base nas **previsões que chegaram a acertar 91% dos futuros evasores**.



2
Ações para reverter a evasão e acompanhamento da efetividade



CASES

I.A. / OTIMIZAÇÃO DAS ENTREGAS

4 meses de desenvolvimento



Desenvolvimento em **apenas 8 semanas** de um otimizador capaz de **economizar +R\$1,3MM/ano** no processo de distribuição dos produtos-projetos entre os clientes finais.



Desafio: Indústria de papel e celulose que representa 5% do mercado nacional de embalagens de papelão.

Havia uma dificuldade muito grande em analisar diariamente todas as variáveis de pedidos, produção nas dezenas de fazendas, tabelas de frete, preço e etc e distribuir com alta rentabilidade as entregas para dezenas de clientes espalhados por todo estado de SC ao longo do mês. A madeira fina chegou a fechar alguns meses com margem negativa...

Solução: Desenvolvimento de uma I.A. baseada em um algoritmo de otimização inteira mista, segundo o paradigma de orientação a objetos.

O código, feito sobre um *framework open-source*, absorve um conjunto de tabelas de restrições de negócios e retorna a forma ótima de se distribuir as entregas de toda a produção de madeira entre os clientes, maximizando a função $\sum(\text{preço_venda} - \text{custo_frete}) * \text{ton_produtos}$, ou seja, o retorno financeiro gerado pela operação.

Serve hoje não apenas como uma ferramenta de planejamento operacional, como também de simulador de cenários de negócios.

```
solucao
cod_cliente cod_produto cod_projetos pedidos preco_venda custo_frete
1: 7808 20648 57 55,24
2: 8822 19985 57 783,82 85,00
3: 6803 19985 129 734,99 80,00
4: 6803 19985 135 509,28 80,00
5: 15395 19985 140 748,59 74,00
6: 6803 19985 140 2513,28 80,00
7: 15395 19985 140 435,83 74,00
8: 6803 19985 156 4585,93 80,00
9: 8822 19985 150 973,94 85,00
10: 81 20648 172 381,98 200,00
11: 81 22285 172 297,71 157,00
12: 2061 22285 172 45,95 157,00
13: 9225 19985 172 601,20 78,00
14: 15252 22285 172 59,23 157,00
15: 15419 20648 172 203,63 210,00
16: 15319 20648 172 293,63 210,00
17: 15688 20648 172 344,91 200,00
18: 9225 19985 173 212,79 78,00
19: 15688 20648 173 41,46 200,00
20: 176 20648 202 98,24 210,00
21: 2512 20648 202 620,62 210,00
22: 7540 20648 202 709,21 210,00
23: 7808 20648 202 484,61 210,00
24: 8822 19985 202 171,71 85,00
25: 15688 20648 202 42,99 200,00
26: 8822 19985 220 812,54 85,00

1 sacrificio <- .98
2 margem_umento <- .8
3 configuracao <- baseline()
4 tb_fretes = tb_fretes
5 tb_preços = tb_preços
6 tb_capacidades = tb_capacidades
7
8
9
10 modelo <- configuracao$gera_modelo(tb_pedidos, sacrificio, margem_umento)
11
12 solucao <- configuracao$solucao(modelo) %>%
13   pluck("solucao")
```

Matematicamente, o problema pode ser descrito como:

maximizar

$$\sum_{i,j,k} (s_{ijk} - c_{ijk}) \cdot w_{ijk},$$

sujeito a

$$\begin{cases} w_{ij} \geq 0, \forall i, j, k \\ \sum_j w_{ijk} \leq W_{ik}, \forall i, k \\ \sum_j w_{ijk} \geq p_k \cdot W_{ik} \\ \sum_i w_{ijk} \leq m_{ij} \cdot C_{jk}, \forall j, k \\ w_{ijk} \leq S_{jk}, \forall j, k \end{cases}$$

onde:

- s_{ijk} é o preço da tonelada do produto k vendido do projeto j para o cliente i ;
- c_{ijk} é o custo do frete por tonelada do produto k do projeto j para o cliente i ;
- w_{ijk} é o montante em toneladas do produto k alocado do projeto j para o cliente i ;
- W_{ik} é o montante em toneladas do produto k solicitado pelo cliente i ;
- C_{jk} é a capacidade em toneladas de entrega do produto k pelo projeto j ;
- $S_{jk} \in [0, 1]$ é o sacrifício na entrega do produto k pelo projeto j ;
- m_{ij} é a margem de erro percentual considerada globalmente para todas as capacidades;
- $p_k = \min \left\{ 1, \sum_j C_{jk} / \sum_i W_{ik} \right\}$.

CASES

I.A. / MODELO DE RECOMENDAÇÃO

3 meses de desenvolvimento

Desenvolvimento de **modelos de recomendação** para serem embedados no portal de compras on-online de uma grande distribuidora farmacêutica, que a permite **maximizar a receita** esperada através de **sugestões de compras personalizadas**.

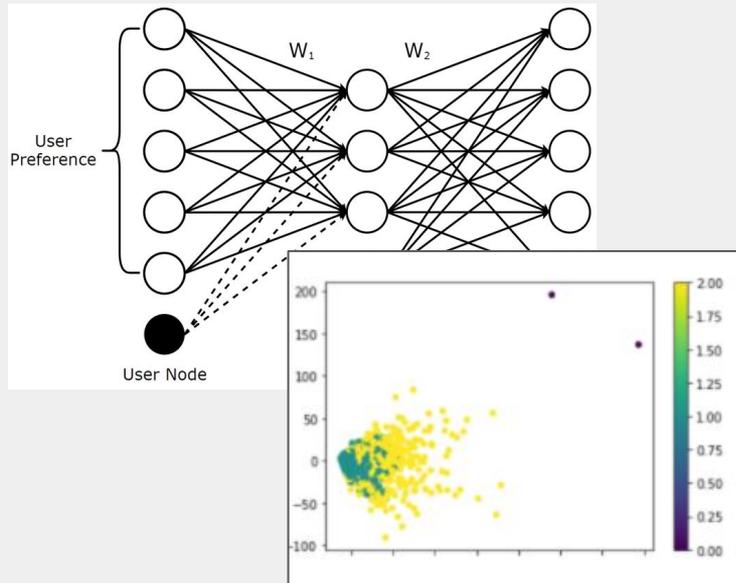


Desafio: Tradicional distribuidor farmacêutico, que representa +100 indústrias fornecedoras e vende +9 mil SKUs para +10 mil PDVs..

30% da sua receita era oriunda do portal online, que estava passando por uma reformulação para entregar um look n feel de e-commerce aos clientes.

O desafio trazido para a plataforma cognitivo foi a criação do **modelo de recomendação** que os permitiria entregar uma **experiência personalizada** a cada cliente dentro da plataforma, através de **sugestões de compra geradas por IA** que levavam em conta o histórico daquele usuário, sazonalidade, clientes semelhantes, co-ocorrências de itens, e etc.

Solução: Através do nosso time de *data science* foram concluídos um conjunto de 3 modelos de IA (1 user-based e 2 item-based), a ser usados em conjunto para entregar uma **recomendação aderente** a cada usuário no momento da sua compra.



CASES

I.A. / PREDIÇÃO DE CHURN INVOLUNTÁRIO

5 meses de desenvolvimento



Desenvolvimento de **modelo de predição de churn** para identificação dos assinantes mais propensos a não renovar uma assinatura por problemas com o meio de pagamento, capaz de **economizar pelo menos R\$500 mil/ano**.

globoplay

Desafio: 2a maior plataforma de streaming de conteúdo nacional, que conta com uma base de MM de assinantes e vive momento intenso de reposicionamento e crescimento.

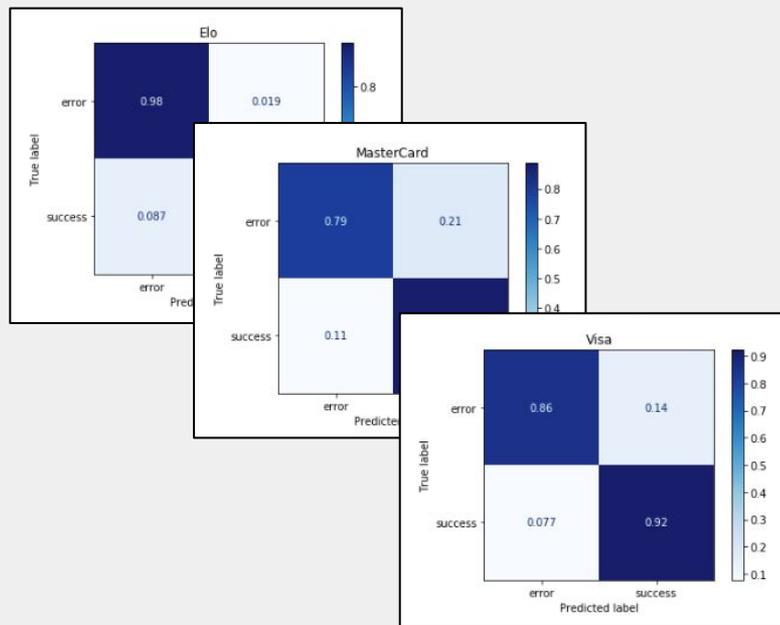
Além do churn voluntário, que está mais diretamente relacionado à qualidade do produto e da experiência de consumo, a plataforma também sofria muito com o **churn involuntário**, relacionado a problemas no momento da cobrança.

Além de uma **lacuna de receita** gerada pela taxa de +6% a.m., gastava-se também muitos recursos em ações de **cobrança manuais** (alto custo operacional) e **pouco efetivas**. E num contexto de intensa briga por MS, o leak de clientes era especialmente preocupante.

Solução: Em apenas 8 semanas criou-se um modelo de IA para prever quais eram as assinaturas mais propensas a sofrerem um churn involuntário no próximo mês.

O book de atributos contava com features de identidade do usuário, comportamento de consumo, e meio de pagamento.

Não apenas foram corrigidas algumas deficiências estruturais descobertas durante a fase de avaliação da oportunidade e qualidade, como validou-se que o modelo permitia à operação recuperar +R\$500mil/ano (sem alterar o processo as-is).



CASES

I.A. / CLUSTERING DE CLIENTES



Desafio: A Too Seguros é uma seguradora do Banco Pan que oferece soluções para carros e motos.

Viam uma grande oportunidade financeira no seu processo genérico de precificação, que não levava em conta a condição financeira ou risco de cada cliente. Tudo isso dentro de um contexto do lançamento do seu primeiro produto online.

Solução: Desenvolveu-se análises utilizando de **modelos de aprendizado não-supervisionado** (“*clustering*”) onde descobriu-se aproximadamente 10 grandes grupos de clientes com características diferentes em uma base com mais de 200K clientes.

Notou-se que, além da oportunidade de aumento do preço de seguro para clientes que detinham melhores condições financeiras ou maiores riscos de sinistro, também havia uma oportunidade de redução do preço para alguns grupos sob determinadas condições, com foco na redução de churn.

Estima-se que as personalizações carregavam uma oportunidade de incremento de rentabilidade na ordem de R\$MM.

3 meses de desenvolvimento



17%



Augusto

25 a 40 anos
Sul e SP
Prazo médio de financiamento
Valor alto e sem-alto do seguro
Moto baixa cilindrada de 10 a 15k

14%



Joana

40 a 60 anos
Nordeste
Prazo longo de financiamento
Valor alto e semi-alto do seguro
Moto baixa cilindrada de 10 a 15k

12%



Marcelo 66%

25 a 40 anos
Prazo longo e médio de financiamento
Valor baixo e mediano do seguro
Moto alta e baixa cilindrada de 15 a 30k

CASES

I.A. / MANUTENÇÃO PREVENTIVA

4 meses de desenvolvimento

Desenvolvimento em **apenas 12 semanas de um modelo** preditivo de alarmes de falha com o objetivo de apoiar a tomada de decisão preventiva da área de manutenção.



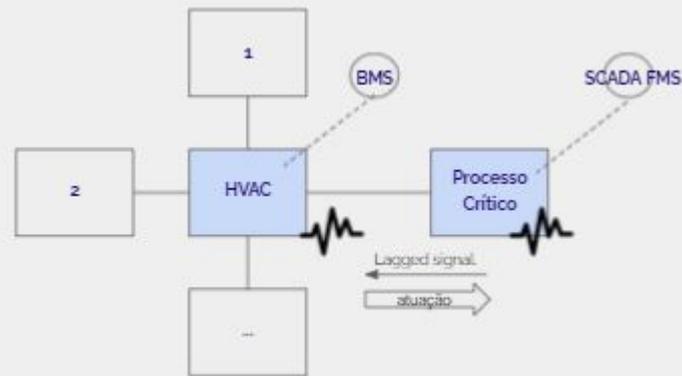
Desafio: Multinacional dinamarquesa que atua no mercado farmacêutico, Presente em mais de 70 países, Doenças crônicas: obesidade, diabetes, hemofilia, desordem de crescimento

O desafio era desenvolver uma ferramenta para apoio a manutenção preventiva, até aquele momento o time de manutenção da Novo Nordisk atuava de forma muito reativa, o sistema que utilizavam apenas enviava alarmes de anomalia na produção, muitas vezes a atuação do time era tardia.

Solução: Desenvolvimento de **um modelo de I.A.** que permite a partir do histórico de alarmes e sensores (FMS) do sistema de HVAC desenvolver um modelo capaz de prever um possível alarme em uma janela de 15 minutos a frente.

Dessa forma o time de manutenção poderia atuar de forma preventiva nos equipamentos antes mesmo que o alarme acontecesse.

O modelo na fase de teste de performance chegou a atingir a **acuracidade de 91%**, no momento estamos realizando o deploy do algoritmo com o sistema do time de Manutenção



CASES

I.A. / MODELAGEM DE CHURN

3 meses de desenvolvimento



Desenvolvimento de **modelo preditor de churn** a partir de técnicas de aprendizado supervisionado, capaz de **reduzir 8% do cancelamento** logo nos primeiros testes de negócio.

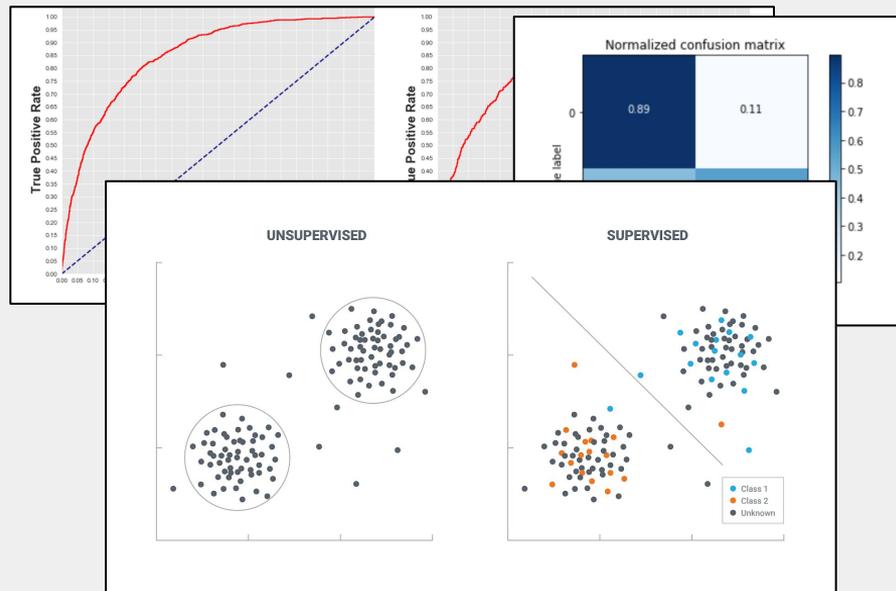


Desafio: Editora e publicadora independente de informações financeiras e conteúdos sobre investimento online, que conta com uma base de +300K assinantes.

Uma característica comum deste mercado é a **compra impulsiva**, muito orientada ao medo ou ambição dos leads em extrair o máximo rendimento possível do dinheiro de seu dinheiro. Por mais que as ações de marketing trouxesse muitos leads, só no free-trial **chegava-se a perder 35% dos clientes para alguns produtos**, e o time de atendimento operava segundo **heurísticas genéricas** sobre a base.

Solução: A partir de variáveis explicativas de identidade (perfil de risco, endereço, idade, gênero, ...), comportamento (acessos, abertura de e-mails, participações em plantões, ...) e preferência (assinaturas, relatórios consumidos, ...) utilizou-se de técnicas de **aprendizado supervisionado** para criação de um **modelo preditor de churn** e estudo da curva de desagregamento associada aos padrões de risco.

Os primeiros testes A | B realizados consistiram em fornecer diariamente uma **lista inteligente ao time de atendimento** a partir dos resultados do modelo, para que eles pudessem proativamente contatar os assinantes com maior risco de cancelamento, e o grupo de teste apresentou uma **taxa de cancelamento 8% menor** que o grupo de controle.



CASES

I.A. / OTIMIZAÇÃO DA DISTRIBUIÇÃO

3 meses de desenvolvimento

Desenvolvimento em **apenas 16 semanas** de um otimizador capaz de **trazer uma priorização de pedidos** focando em buscar no faturamento ótimo para a Brinox.

GRUPO BRINOX

Desafio: Fabricação e comercialização de utilidades domésticas (talheres, fôrmas, panelas, e diversos outros itens). Atualmente, fazem parte do portfólio as marcas Brinox, Coza e Haus Concept.

O desafio era desenvolver uma ferramenta de otimização da distribuição de pedidos ótima que reduzisse excesso de estoque e perda de vendas. Além de melhorar o nível de atendimento e o principal otimizasse o faturamento.

A complexidade era agravada por tratar-se de um portfólio de 6K SKUs, fabricados em 4 plantas, distribuídos em 3 CDs, e que atendem a cerca de 3K clientes ativos espalhados pelo BR

Solução: Desenvolvimento de uma I.A. que permite a simulação de diversos cenários de negócio para que compreendam, em cada uma delas, qual a distribuição de priorização ótima de pedidos a serem atendidos.

Os outputs eram capazes de simular cenários variando-se restrições pré-determinadas em tempo de projeto

Varíavel ativa ↓

Dia: 22/10/2020 | Pedidos Atendidos: 107 | Cobertura Estoque: 78% | Max(Faturamento): 1.2MM

Pedido ID	Estoque CD - Item A	Estoque CD - Item B	...	Cliente ID	Tempo Fila	Item A	Item B	...	Faturamento Esperado
#6546	370	200	...	#6335	7	30	30	...	R\$7.530,00
#7453	450	830	...	#865	0	200	100	...	R\$12.650,00
...
#2145	1000	580	...	#865	14	1000	150	...	R\$24.869,00



INTELIGÊNCIA ARTIFICIAL MODELAGEM



Desafio: Um dos maiores custos de um pecuarista de corte como a Prodap é com a nutrição do rebanho durante o período de confinamento, cujo planejamento é amparado em curvas teóricas de engorda, que são imprecisas

Solução: Através de Inteligência Artificial criamos um modelo que estima o peso de cada lote de bois com base nos dados históricos da Prodap, cujos resultados são disponibilizados em uma aplicação e demonstraram 90% de acurácia

Em técnicas de backtesting, a expectativa é de que seja possível a **validação de peso de um lote com mais de 95% de acurácia, o que seria traduzido numa melhor precificação de lote para venda (que teria potencial de aumentar em 10% o faturamento com venda de lotes)**

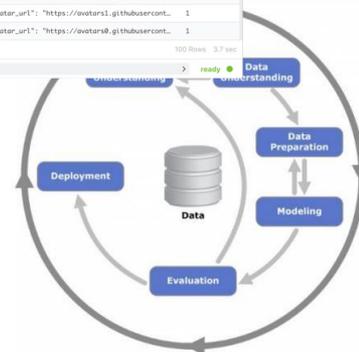
5 meses de desenvolvimento



```
renamed as (
  select
    user_id,
    starred_at as first_starred_at,
    user,
    row_number() over (partition by user_id order by starred_at) as star_idx
  from source
```

USER_ID	FIRST_STARRED_AT	USER	STAR_IDX
1400683	2019-02-09T08:47:28+00:00	["avatar_url": "https://avatars2.githubusercontent.com..."]	1
38860775	2019-09-04T17:48:58+00:00	["avatar_url": "https://avatars1.githubusercontent.com..."]	1
6055551	2018-08-03T01:03:35+00:00	["avatar_url": "https://avatars3.githubusercontent.com..."]	1
4157788	2018-09-25T19:18:05+00:00	["avatar_url": "https://avatars2.githubusercontent.com..."]	1
33949347	2017-10-10T00:33:33+00:00	["avatar_url": "https://avatars1.githubusercontent.com..."]	1
7726537	2019-08-02T23:15:33+00:00	["avatar_url": "https://avatars1.githubusercontent.com..."]	1
3673026	2018-03-05T23:41:22+00:00	["avatar_url": "https://avatars0.githubusercontent.com..."]	1

Process for Data Mining



CASES

ANALYTICS / ATIVAÇÃO DE CONTA

4 meses de desenvolvimento



Análise para entendimento dos padrões associados à **ativação das contas**. Atualmente estamos ajudando nosso cliente a enriquecer seu ecossistema de dados para atingirmos o milestone de **modelagem de IA estimadora da propensão à ativação**.



Desafio: Plataforma de investimentos com mais de 90K clientes e mais de R\$20 bi em custódia contratada, com atuação em mais de 30 municípios brasileiros.

Existia um grande **leak no funil de vendas: apenas ~2% dos leads que começaram o cadastro ativavam sua posição**. Ademais, todas as ações de mkt, vendas e assessoria eram pautadas em excel, e desconfiava-se muito do poder analítico da baixa variedade de variáveis explicativas.

Solução: Utilizou-se de todo **ferramental de estatística descritiva** para analisar o histórico de 1 ano de registros de descrito pelas 8 principais variáveis cadastrais, de forma a entender seus Information Value (IV), extrair os insights preliminares, e capturar os QWs.

Ex de QW: “apesar de mulheres ativarem posição mais que homens, a base é muito mais populada por homens”. → As primeiras ações de marketing personalizadas para o público feminino derivaram deste insight.

Atualmente este projeto está on hold, enquanto nosso cliente segue o roadmap que traçamos juntos para aumento da variabilidade de dados de seu ecossistema, ao qual seguirá o **desenvolvimento de uma I.A.** para estimação da propensão à ativação, para **ações de venda personalizadas**.

Dados analisados

1. Base cadastral – Clientes que abriram conta (TB_Clientes_V2.txt)
2. Base de posições - TB_Posicao.txt

• Período analisado: Contas abertas à partir de fevereiro de 2018

• Variável resposta:

0 – Não ativa

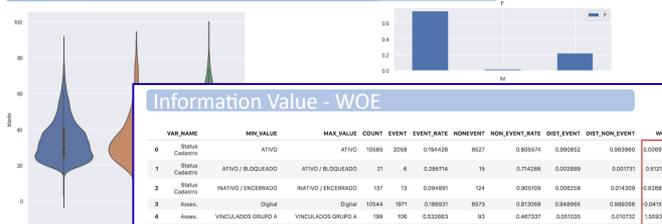
• Variáveis disponíveis:

1. Status Cadastro
2. Asses. Digital
3. UF
4. Idadad
5. Tp. C
6. Estad
7. Sexo
8. Perf

• Variáveis mais importantes:

1. Perf
2. Idadad
3. UF
4. Sexo

Gráficos



As pessoas que a mais

Information Value - WOE

VAR_NAME	MIN_VALUE	MAX_VALUE	COUNT	EVENT	EVENT_RATE	NONEVENT	NON_EVENT_RATE	DIST_EVENT	DIST_NONEVENT	WOE	IV
0	Status Cadastro	ATIVO	1088	2058	0.194228	8827	0.805674	0.906862	0.988390	0.000980	0.007297
1	Status Cadastro	ATIVO / BLOQUEADO	21	6	0.285714	15	0.714286	0.002869	0.001031	0.532192	0.007297
2	Status Cadastro	INATIVO / ENCERRADO	137	13	0.044911	124	0.955089	0.006259	0.014309	0.188649	0.007297
3	Asses. Digital	Digital	10544	1871	0.186931	8573	0.813069	0.848865	0.988268	0.041584	0.048423
4	Asses. Vinculados Grupo A	VINCULADOS GRUPO A	189	106	0.560823	83	0.447327	0.591035	0.071072	1.89322	0.048423
5	UF	BA	246	26	0.105697	220	0.894303	0.048177	0.223734	0.86796	0.627103
6	UF	CE	217	30	0.092666	187	0.867834	0.006629	0.022733	0.898889	0.627103
7	UF	DF	345	93	0.269566	252	0.730274	0.044776	0.229195	0.427893	0.627103
8	UF	ES	265	39	0.147170	226	0.852830	0.087777	0.229079	0.338491	0.627103
9	UF	GO	246	27	0.109354	219	0.890646	0.019774	0.087972	0.530868	0.627103
10	UF	MG	1007	182	0.180666	816	0.819333	0.026341	0.064046	0.271275	0.627103
11	UF	OUTROS	1441	164	0.113810	1277	0.886190	0.019890	0.023200	0.823200	0.627103
12	UF	PE	279	42	0.150538	237	0.849462	0.020221	0.027346	0.301068	0.627103
13	UF	PI	871	118	0.135687	753	0.864313	0.066813	0.068819	0.191891	0.627103
14	UF	RJ	2023	149	0.073653	1874	0.926346	0.008981	0.008488	0.121647	0.627103
15	UF	RS	526	86	0.163498	440	0.836502	0.041608	0.060773	0.232846	0.627103
16	UF	SC	348	41	0.117816	307	0.881664	0.016740	0.034626	0.184793	0.627103
17	UF	SP	4079	1081	0.265173	3018	0.734887	0.874933	0.348268	0.383100	0.627103

O Woe resume a diferença de distribuição de ativos e não ativos. Por exemplo: No caso da idade, temos um Woe > 0, para pessoas de 41 a 50 anos, logo a proporção de ativações em relação a proporção de não ativação nessa faixa é maior que 1, portanto podemos concluir que pessoas mais velhas tendem a ativar mais.

INVESTIMENTO



INVESTIMENTO

DATA TEAM ON DEMAND

SERVIÇOS	PERÍODO OU %	VALOR MENSAL:	VALOR TOTAL:
Data Team On Demand	30 meses	R\$ 179.176,000	R\$ 5.400.28000
Remuneração Variável	Máx 20%	R\$ 216.011,20	R\$ 6.480.336,00

INVESTIMENTO

Planilha de custo

PREÇO AJUSTADO	
Preço total	\$5,400,280.00
Preço mensal	\$179,176.00
Receita Líquida	\$167,439.97
Custo Total Mensal	\$112,149.42
Margem Bruta	33.02%
Ticket médio	OK
Validação Final	OK

CUSTO EQUIPE MENSAL				
Profissional	Valor/hora	Horas mensais	Total	Número de profissionais
Business/Negócio - Project Lead - Sênior	150	160	\$24,000	
Data Science - Tech Lead - Sênior	120	160	\$19,200	
Data Science - Data Scientist - Sênior	130	160	\$20,800	
Data Science - Data Scientist - Sênior	130	160	\$20,800	
Data Engineering - Engenheiro de dados - Sênior	150	160	\$24,000	
Custo Total Equipe	680	160	\$108,800	

CUSTO COM FERRAMENTAS MENSAL				
	AWS Fixo	AWS Variável		
AWS	909.55	909.55	0 Dólar	5.7 4.8244
Outras ferramentas	939.87		IOF	6.38%
Custo Total Ferramentas	1849.42			
CUSTO COMPUTADOR BLINDADO				
Custo	1500			
CUSTO COM BÔNUS MENSAL				
Bônus mensal	0			
IMPOSTO SOBRE A RECEITA				
Alíquota SP	6.55%	Adicional		2.90%
Alíquota final	6.55%			

Por se tratar de um projeto de pesquisa de alta complexidade, consideramos recursos full time e preço hora padrão para a senioridade requerida do projeto, dentro do preço estão incluídos recursos físicos (máquinas, processamento, provedores cloud etc), como também custos operacionais e gestão interna do projeto



OBRIGADO