
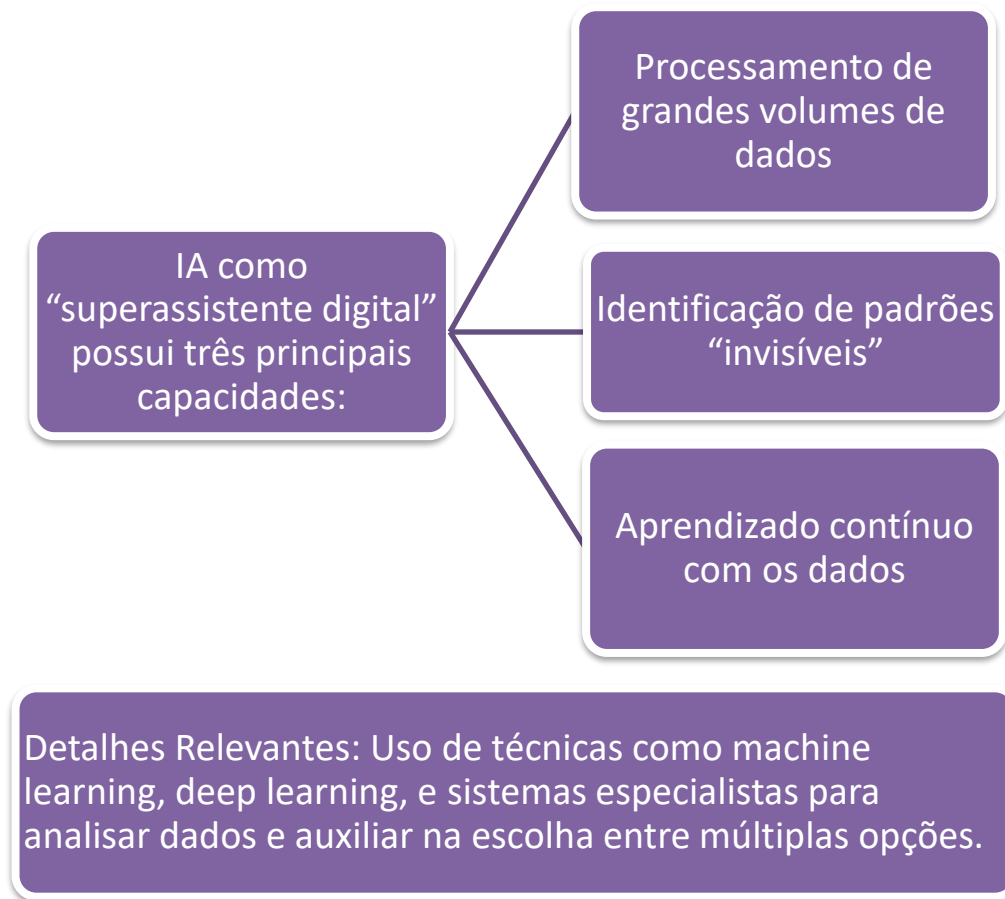




# Inteligência Artificial na Tomada de Decisão

Professor Leandro Pereira

# O que é IA na Tomada de Decisão?



# Processamento de Dados em Grande Escala

- IA pode analisar milhões de registros em segundos.
- Permite decisões baseadas em dados atualizados e completos.
- Exemplo: Amazon processa Bilhões de transações diárias
- **Detalhes Relevantes:** Algoritmos paralelos em GPUs, Big Data frameworks como Apache Spark, e técnicas de pré-processamento de dados otimizam essa análise.





# Reconhecimento de Padrões

- Técnica para detectar regularidades em dados usando algoritmos de IA e estatística.
- Como Funciona?
  - Coleta de Dados (imagens, sons, números)
  - Extração de Características (formas, frequências, estatísticas)
  - Classificação (agrupa padrões similares)
- Técnicas Principais
  - Aprendizado Supervisionado (para padrões conhecidos) Ex.: Redes Neurais, SVM
  - Aprendizado Não-Supervisionado (para padrões ocultos) Ex.: K-Means, DBSCAN.
- Aplicações
  - Visão Computacional: Reconhecimento facial (OpenCV)
  - Áudio: Identificação de músicas (Shazam)
  - Finanças: Detecção de fraudes (séries temporais)
- Desafios
  - Variabilidade nos dados (ex.: diferentes ângulos em imagens)
  - Ruídos e dados incompleto



# Aprendizado Contínuo

- Capacidade de aprender com novos dados continuamente, sem perder conhecimento prévio. Evoluir sem obsolescência.
- Exemplo: ChatGPT ajustando respostas com feedback contínuo.
- Detalhes Relevantes: Técnicas como aprendizado online, aprendizagem incremental e reinforcement learning são utilizadas.



# Comparação entre Decisão Humana e IA

| Aspecto        | Decisão Humana            | Decisão por IA                  |
|----------------|---------------------------|---------------------------------|
| Velocidade     | Minutos ou horas          | Milissegundos                   |
| Volume         | Limitado                  | Milhões de dados ao mesmo tempo |
| Viés           | Pessoal ou cultural       | Depende dos dados de treino     |
| Cansaço        | Pode errar quando cansado | Sem fadiga                      |
| Transparência  | Compreensível             | Pode ser uma caixa-preta*       |
| Adaptabilidade | Limitada                  | Muito alta, com dados contínuos |

\*A transparência é tratada por meio da área de Explainable AI (XAI), é uma área de pesquisa e prática em IA que busca tornar os processos de decisão de modelos de machine learning (especialmente os complexos, como redes neurais profundas) transparentes, compreensíveis e auditáveis por humanos

# Análise de Dados

- Processo sistemático para extrair insights valiosos de dados brutos
- Etapas:

Coleta

Processamento

Análise Descritiva

Análise Preditiva

Ação Prescritiva

Visualização

- Importância:
  - Redução de incertezas
  - Otimização de recursos



# Coleta

- Captura de dados brutos de fontes internas, externas e dispositivos.
- Garantir dados relevantes, confiáveis e suficientes para suportar decisões.
  - Estruturados: Tabelas, planilhas, bancos SQL
  - Não estruturados: Textos, imagens, vídeos, áudios
  - Semi-estruturados: JSON, XML, logs de sistemas
- Exemplos: Sensores IoT em cidades inteligentes coletando dados de tráfego.





# Processamento de Dados

- Preparando os Dados
- Etapas:
  - Limpeza (valores missing, outliers)
  - Transformação (normalização, codificação)
  - Enriquecimento (junção de fontes)
- Ferramentas:
  - Python (Pandas, NumPy)
  - SQL
  - OpenRefine
- Caso Real:
  - Padronização de dados de clientes para CRM



# Análise Descritiva

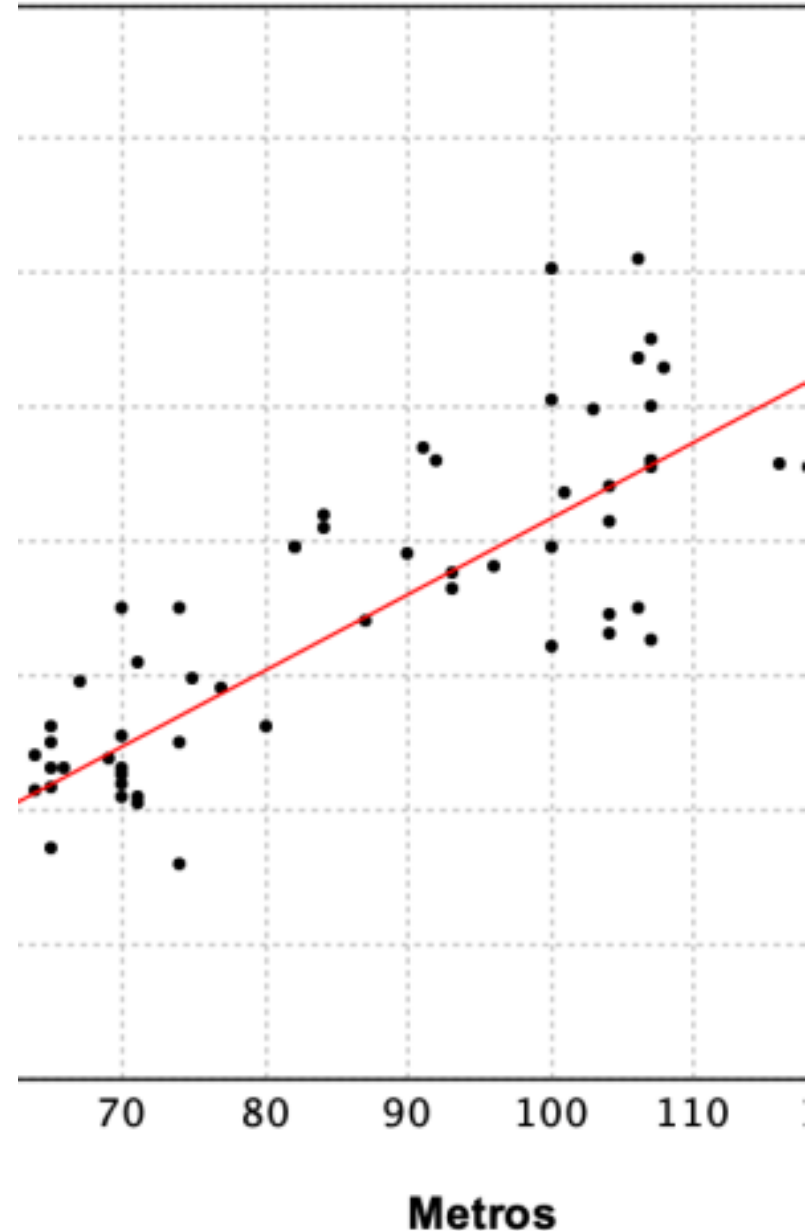
- Identificação de padrões, tendências e anomalias. Mostra o que aconteceu
- Ferramentas: Estatística descritiva (média, mediana) e visualizações (gráficos de linha, heatmaps). Tableau, Power BI
- Utiliza ETL (Extract, Transform, Load), dashboards interativos e análise OLAP (Online Analytical Processing).
- Exemplo:
  - Relatório de vendas por região no último trimestre
  - KPI (Key Performance Indicators)



# Análise Preditiva

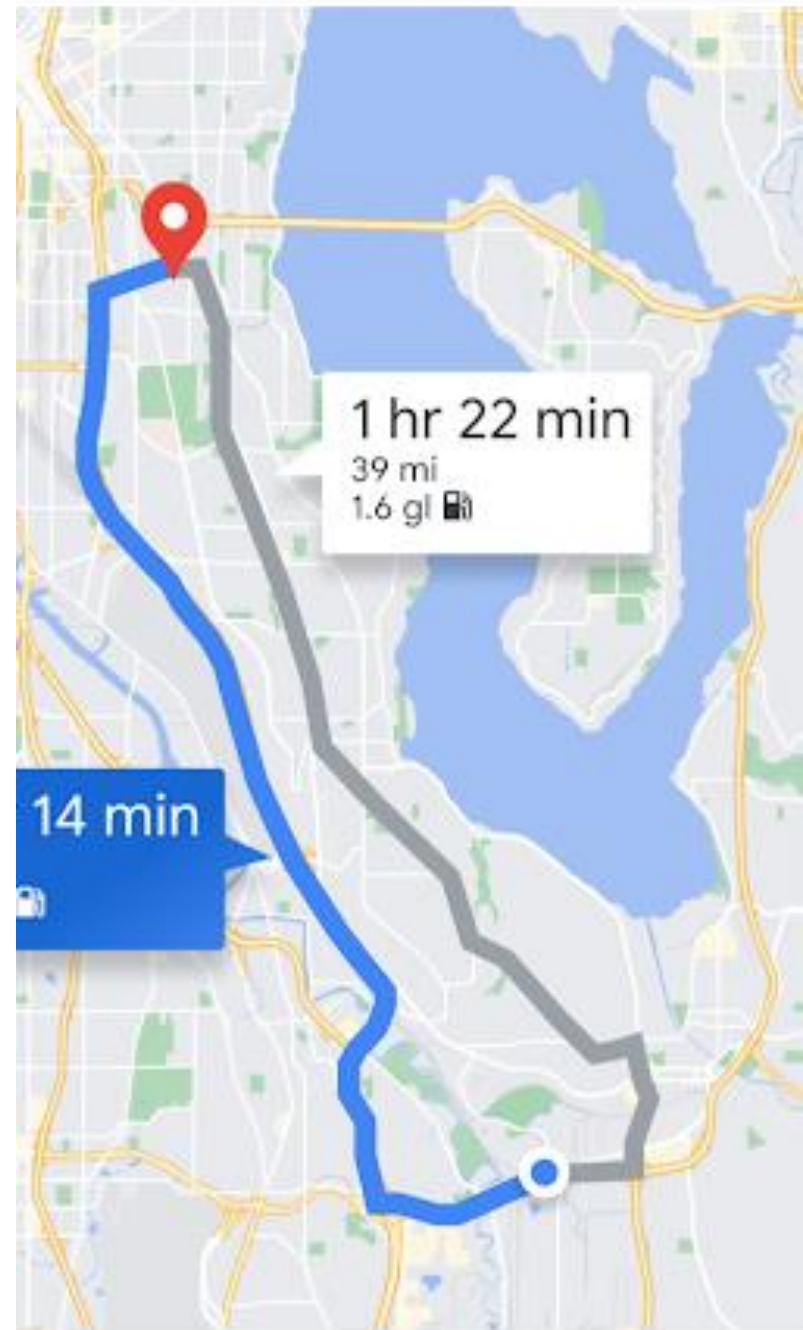
- Modelos estatísticos e de aprendizado de máquina prevendo resultados futuros (ex.: risco de inadimplência).
- Modelos Técnicas: Redes neurais, regressão, algoritmos de classificação.
- Algoritmos como regressão linear, árvores de decisão, redes neurais e modelos ensemble como Random Forest e XGBoost.
- Exemplo: Previsão de demanda sazonal para otimizar estoque.

Aptos de SBC: Metros vs Pre



# Análise Prescritivo

- Objetivo ao Responder "O que devemos fazer?"
- Recomendações baseadas em dados (ex.: ofertas personalizadas).
- Técnicas:
  - Otimização matemática
  - Sistemas de recomendação
  - Simulações
- Ferramentas:
  - Gurobi
  - Google OR-Tools
- Exemplo:
  - Otimização de rotas de entrega para reduzir custos
  - Plataforma de streaming sugerindo filmes com base no histórico.





# Visualização

- Comunicar insights de forma clara
- Melhores Práticas:
  - Escolha de gráficos adequados
  - Hierarquia visual
  - Evitar poluição
- Ferramentas:
  - Power BI
  - Tableau
  - Matplotlib
- Exemplo:
  - Dashboard executivo com KPIs



# Fechando o Ciclo: Dados para Ação

Coleta

Processar

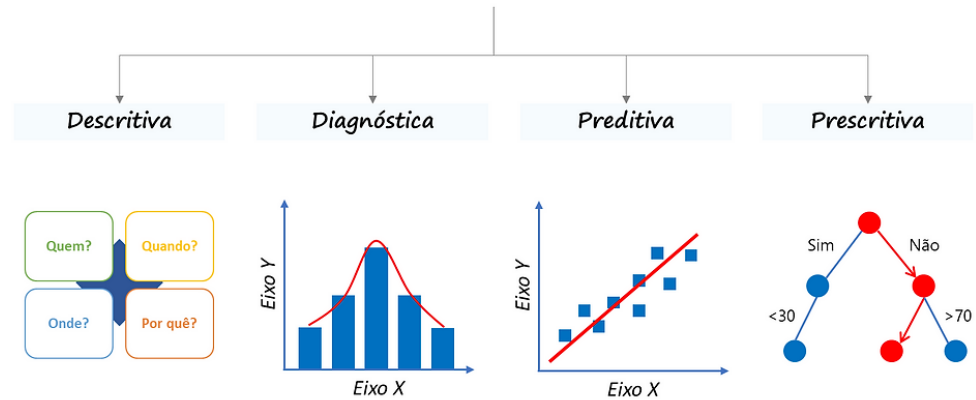
Descrever

Prever

Agir

Visualizar

## TIPOS DE ANÁLISES DE DADOS




# Comparação dos Tipos de Análise

| Tipo        | Entrada            | Processo                 | Saída                 | Ferramenta Popular                |
|-------------|--------------------|--------------------------|-----------------------|-----------------------------------|
| Descritivo  | Dados históricos   | Agregação e visualização | Relatórios e gráficos | Tableau, Power BI                 |
| Preditivo   | Dados históricos   | Modelagem estatística    | Previsões e cenários  | Python, scikit-learn, XGBoost     |
| Prescritivo | Dados + restrições | Otimização matemática    | Plano de ação ideal   | IBM Decision Optimization, Gurobi |

# Como a IA Aprende a Decidir

- IA aprende com dados
- Três tipos principais de aprendizado:
  - Supervisionado
  - Não-supervisionado
  - Por reforço
- O tipo de aprendizado é escolhido de acordo com o problema, a disponibilidade de rótulos e a interação com o ambiente.






# Aprendizado Supervisionado

- Definição: Modelos aprendem a partir de dados rotulados (entrada + resposta correta)
- Principais Técnicas:
  - Classificação: Prever categorias (ex.: spam/não spam)
  - Regressão: Prever valores contínuos (ex.: preço de imóveis)
- Algoritmos Populares: Regressão Linear, Árvores de Decisão, Redes Neurais
- Aplicações Práticas: Diagnóstico médico, Previsão de vendas, Reconhecimento de imagens
- Benefícios: Alta precisão em tarefas bem definidas, Resultados interpretáveis
- Desafios: Necessidade de muitos dados rotulados, Risco de overfitting



# Aprendizado Não-Supervisionado

- Definição: Modelos que identificam padrões em dados sem rótulos ou respostas pré-definidas
- Principais Técnicas:
  - Clustering (Agrupamento): K-Means, DBSCAN
  - Redução de Dimensionalidade: PCA, t-SNE
  - Associação: Regras de mercado (ex.: "quem compra A também compra B")
- Exemplos:
  - Agrupar clientes por comportamento de compra . Clustering: K-Means.
  - Visualizar dados complexos em 2D/3D. Redução de Dimensionalidade: PCA.
  - Identificar transações fraudulentas: Detecção de Anomalias
- Vantagens: Não precisa de dados rotulados, Revela insights inesperados
- Desafios: Difícil avaliar resultados, Sensível à qualidade dos dados



# Aprendizado por Reforço

- IA aprende com tentativa e erro
- Agente inteligente aprende sozinho interagindo com um ambiente, recebendo recompensas ou punições por suas ações.
- Ambiente: Mundo onde o agente atua (ex.: tabuleiro, estrada).
- Recompensa: Feedback numérico (ex.: +1 por vencer, -1 por bater).
- Ação → Observação → Recompensa → Ajuste da Estratégia
- Exemplo: Robôs, jogos, carros autônomos
- Algoritmos: Q-Learning, Deep Q-Networks (DQN), Policy Gradients
- Desafios: Dificuldade em definir recompensas, Treinamento demorado

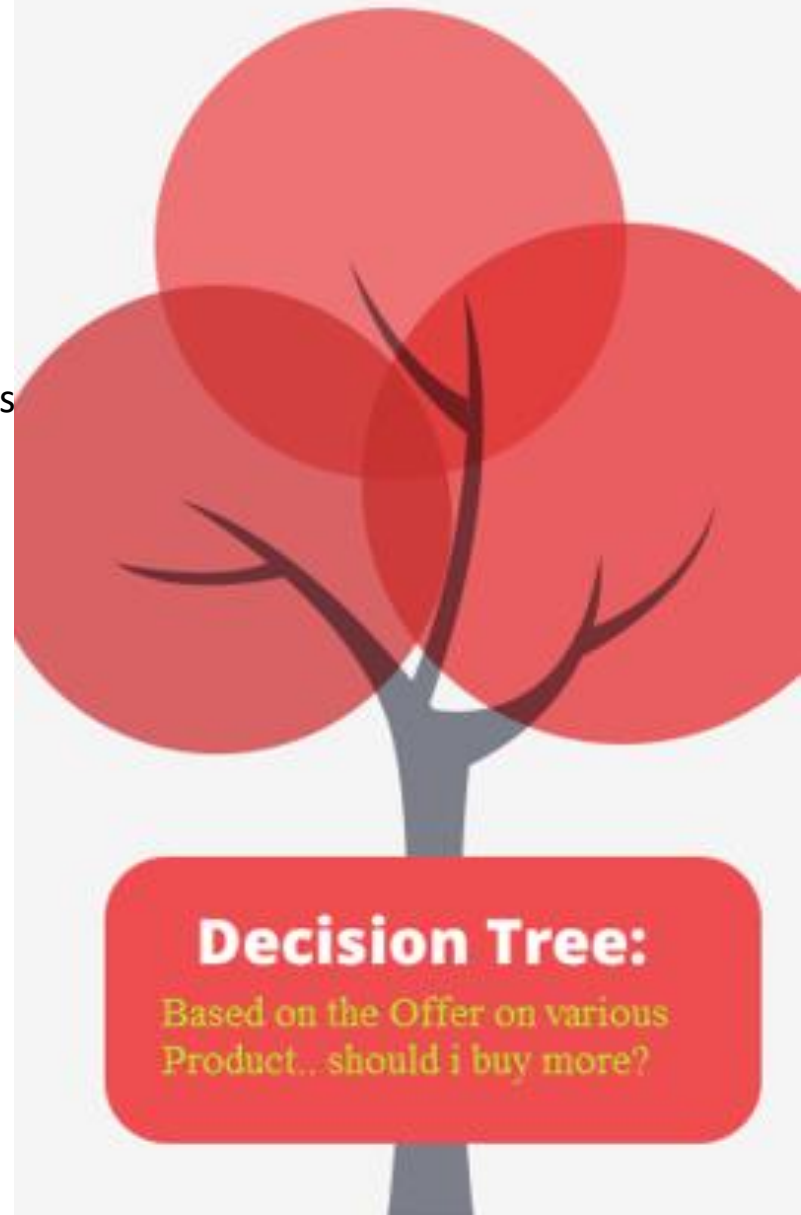




# Árvores de Decisão

- Algoritmo de ML que divide os dados em decisões sequenciais (como um fluxograma)
- Como Funciona:
  - Nós: Perguntas sobre os dados (ex.: "Idade > 30?")
  - Ramos: Respostas possíveis (Sim/Não)
  - Folhas: Resultados finais (classes ou valores)
- Aplicações: Diagnóstico médico, Análise de crédito, Sistemas de recomendação
- Utilizam entropia ou índice de Gini para decidir a melhor divisão de dados nos nós da árvore.
- Vantagens:
  - Fácil interpretação (regras claras)
  - Funciona com dados numéricos e categóricos
  - Pouco pré-processamento necessário
- Desafios:
  - Risco de overfitting
  - Sensível a pequenas variações nos dados


## DECISION TREE





# Redes Neurais

- Modelos computacionais que simulam neurônios interconectados para aprender padrões complexos dos dados
- Principais Elementos:
  - Camadas: Entrada → Escondidas → Saída
  - Neurônios: Unidades de processamento com pesos ajustáveis
  - Função de Ativação: ReLU, Sigmoid, Tanh
- Como Aprendem?
  - Propagação direta (feedforward)
  - Cálculo do erro
  - Retropropagação (backpropagation)
  - Ajuste dos pesos



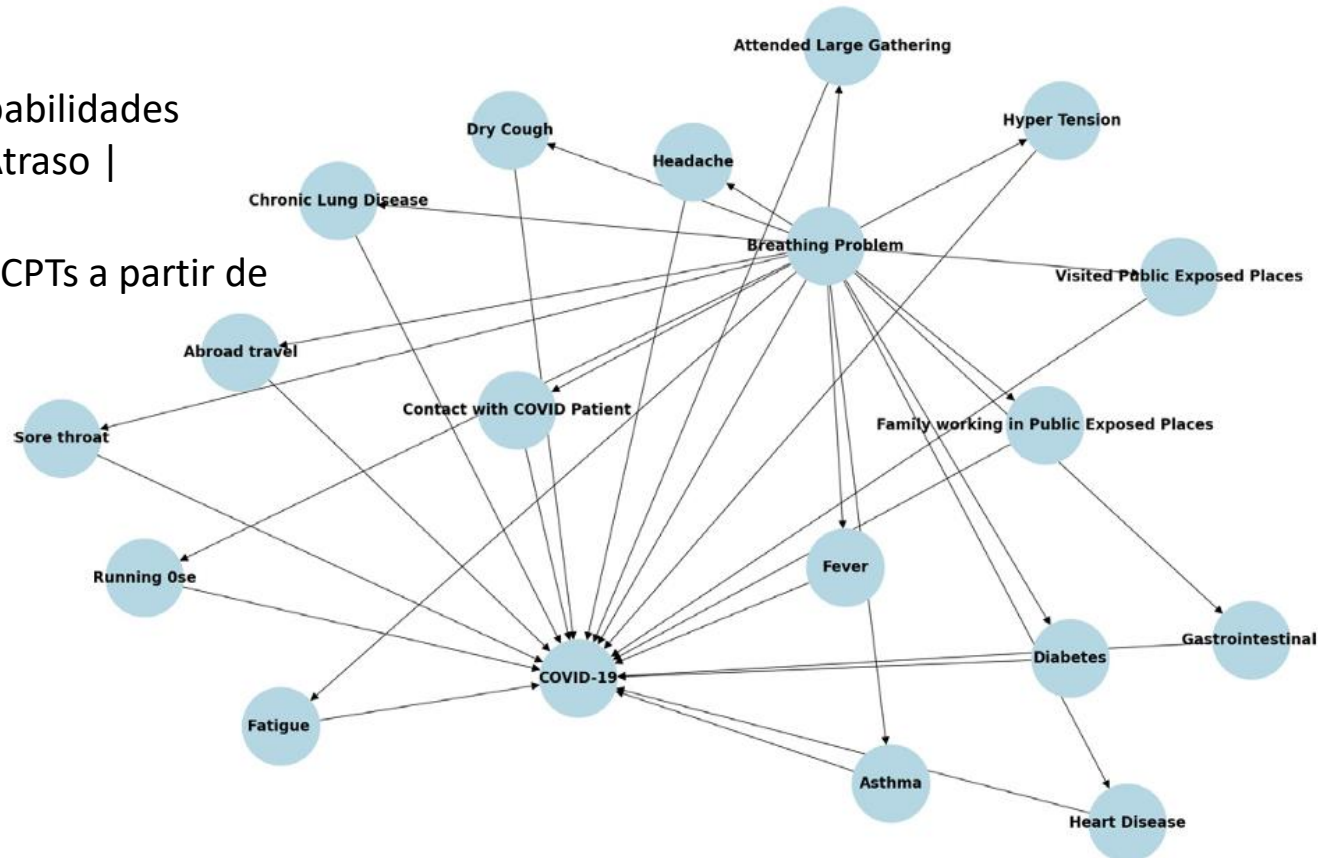
# Redes Neurais

- Onde Usamos?
  - Visão computacional
  - Processamento de linguagem
  - Sistemas de recomendação
  - Carros autônomos
- Vantagens:
  - Aprendem padrões não-lineares complexos
  - Boa generalização (com dados suficientes)
- Desafios:
  - Requer muitos dados
  - Computacionalmente intensivo
  - Difícil interpretação ("caixa preta")



# Redes Bayesianas


- Grafos probabilísticos que representam relações de causa-efeito entre variáveis.
- Combinam Teoria de Probabilidades + Teoria de Grafos.
- Elementos-Chave:
  - Nós: Variáveis (ex.: "Chuva", "Trânsito", "Atraso").
  - Arestas: Dependências probabilísticas (ex.: "Chuva  $\rightarrow$  Trânsito").
  - Tabelas de Probabilidade Condicional (CPT): Quantificam as relações.
- Como Funcionam?
  - Inferência: Calcula probabilidades desconhecidas (ex.:  $P(\text{Atraso} \mid \text{Chuva}=\text{Sim})$ ).
  - Aprendizado: Ajusta as CPTs a partir de dados.





# Redes Bayesianas

- Aplicações:
  - Diagnóstico médico (sintomas  $\rightarrow$  doenças).
  - Filtros de spam (palavras  $\rightarrow$  probabilidade de spam).
  - Sistemas de recomendação.
- Vantagens:
  - Modela incerteza e relações complexas.
  - Interpretável (grafos visíveis).
- Desafios:
  - Complexidade em redes grandes.
  - Requer dados para estimar probabilidades.





# Aplicações Reais da IA por Setor

- **Saúde**

- CNN (Redes Neurais Convolucionais): Analisa imagens médicas (radiografias, ressonâncias) para detectar padrões.
- IBM Watson: Cruza dados clínicos e pesquisas para sugerir tratamentos personalizados.

- **Economia/Finanças**

- LSTM: Rede neural para prever séries temporais (ações, câmbio) com memória de longo prazo.
- Isolation Forest: Algoritmo que identifica transações raras (fraudes) sem necessidade de rótulos prévios.

- **Varejo**

- TensorFlow Recommenders: Sistema de recomendação que aprende com histórico de compras.
- Q-Learning: Técnica de aprendizado por reforço para ajustar preços dinamicamente.



# Aplicações Reais da IA por Setor

- **Indústria 4.0**
  - YOLO: Modelo de visão computacional que inspeciona produtos em tempo real.
  - Gurobi: Otimizador matemático para planejamento de produção eficiente.
- **Agricultura**
  - U-Net: Rede neural segmenta imagens de satélite para monitorar plantações.
  - ARIMA: Modelo estatístico prevê safras com base em dados históricos.
- **Logística**
  - Google OR-Tools: Biblioteca de otimização para rotas de entrega com múltiplas paradas.



# IA na Tomada de Decisão - Apresentações

Criar apresentação escolhendo 1 tema por grupo das seguintes opções:

1. Algoritmos paralelos em GPUs
2. Big Data frameworks
3. Explainable AI (XAI)
4. Dados Estruturados, Não estruturados, Semi-estruturados
5. Random Forest, XGBoost
6. IBM Decision Optimization, Gurobi e Google OR-Tools
7. Power BI, Tableau e Matplotlib
8. K-Means e DBSCAN
9. PCA e t-SNE
10. Q-Learning, Deep Q-Networks (DQN) e Policy Gradients
11. Algoritmo Apriori
12. ETL (Extract, Transform, Load) e OLAP (Online Analytical Processing)
13. Algoritmos genéticos e simulated annealing
14. Funções de ativação ReLU, sigmoid e softmax
15. Teorema de Bayes
16. Entropia e índice de Gini
17. Algoritmos CNNs (Redes Neurais Convolucionais)
18. Análise de cestas de compras (market basket analysis)
19. SHAP (SHapley Additive exPlanations)

## **Planilha Grupo**

[https://docs.google.com/spreadsheets/d/1kc-kz3jWt1vrflXyYVKVh8NDjHyNzvls/edit?usp=drive\\_link&oid=103512574630558837636&rtpof=true&sd=true](https://docs.google.com/spreadsheets/d/1kc-kz3jWt1vrflXyYVKVh8NDjHyNzvls/edit?usp=drive_link&oid=103512574630558837636&rtpof=true&sd=true).

## **Pasta Repositório**

[https://drive.google.com/drive/folders/17X-8Vm\\_cqKUDF7r1XEWceJvYJELMkpiP?usp=sharing](https://drive.google.com/drive/folders/17X-8Vm_cqKUDF7r1XEWceJvYJELMkpiP?usp=sharing)