

Correlação vs Causalidade

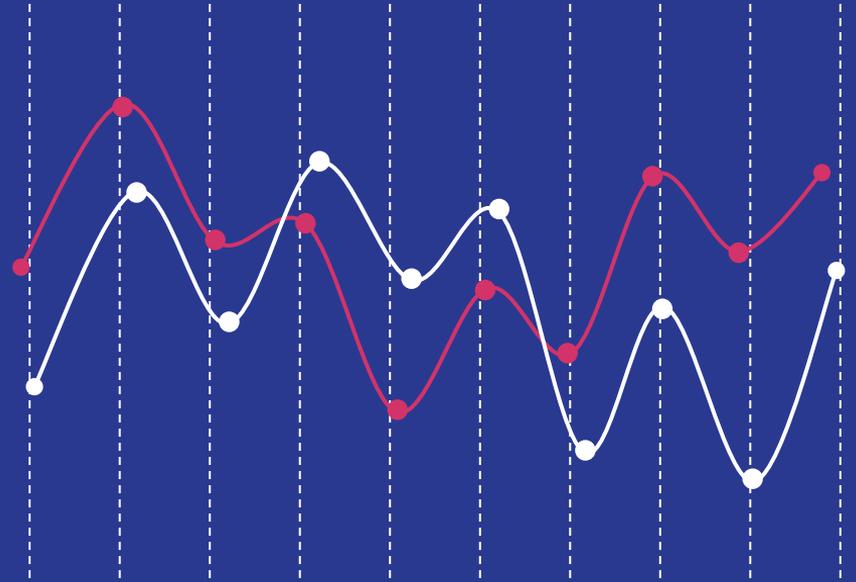
Gabriel Araujo
Brenda Ramires

Um problema

- Pouco tempo antes da Copa do Mundo de 2014, foi criada uma campanha publicitária em que, diversas vezes, crianças olhavam para a câmera e diziam que nunca viram o Brasil ganhar uma copa
- Em julho do mesmo ano, o país conhece o 7 a 1 :(
- Como o Brasil nunca ganhou esse título após o nascimento das crianças do comercial, seriam elas as responsáveis pelas nossas derrotas?



Correlação



Correlação

- Relação estatística entre variáveis
- Mede a interdependência entre elas
- Mesmo eventos sem relação de causa podem ter alto coeficiente de correlação

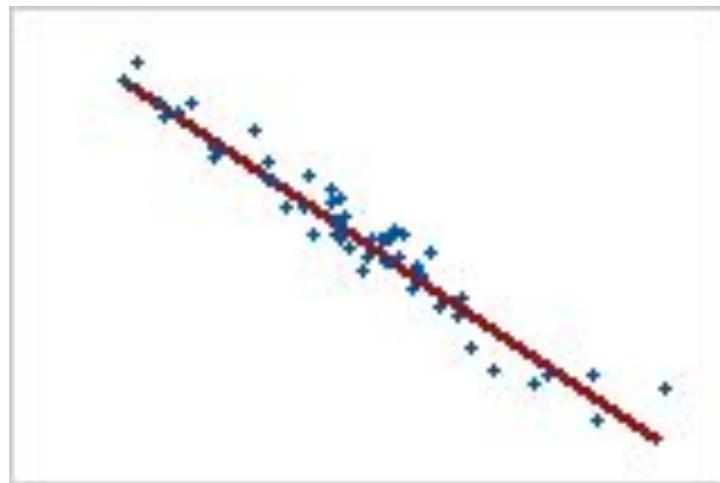


Correlação



Correlação

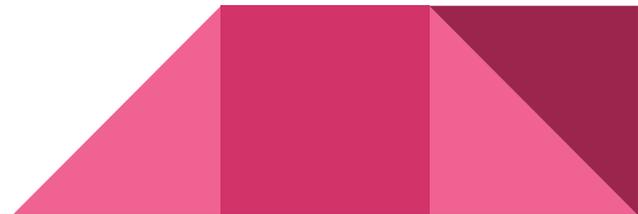
- Relação estatística entre variáveis
- Mede a interdependência entre elas
- Correlação positiva:
 - Ambas as variáveis se movem no mesmo sentido do gráfico
- Correlação negativa:
 - As variáveis se movem em sentidos opostos no gráfico



Causalidade

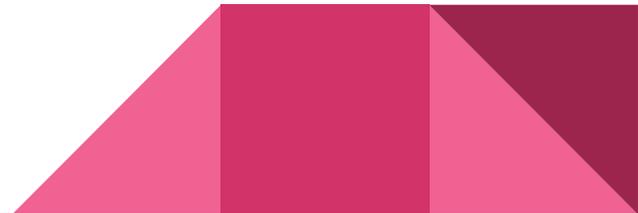
Causalidade

- Uma relação causal entre variáveis
- É também uma correlação (o inverso não se aplica)
- Diferentes tipos
- Diversos métodos para testar
- Perguntas essenciais
 - Inferência causal
 - Descoberta causal



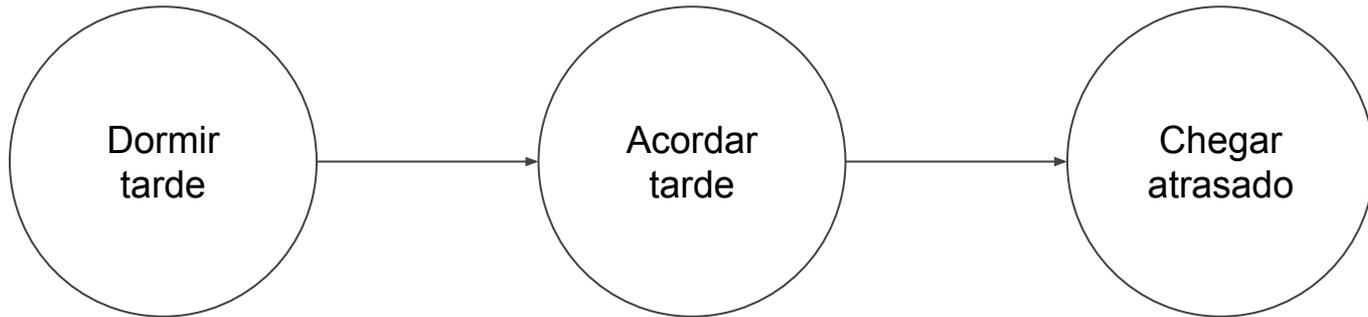
Causalidade

- Representação: modelo causal
 - Grafo direcionado
 - Nós: variáveis
 - Arestas: Relacionamento causal



Causalidade - *chain*

- Conexões em linha reta
- Arestas apontam no mesmo sentido



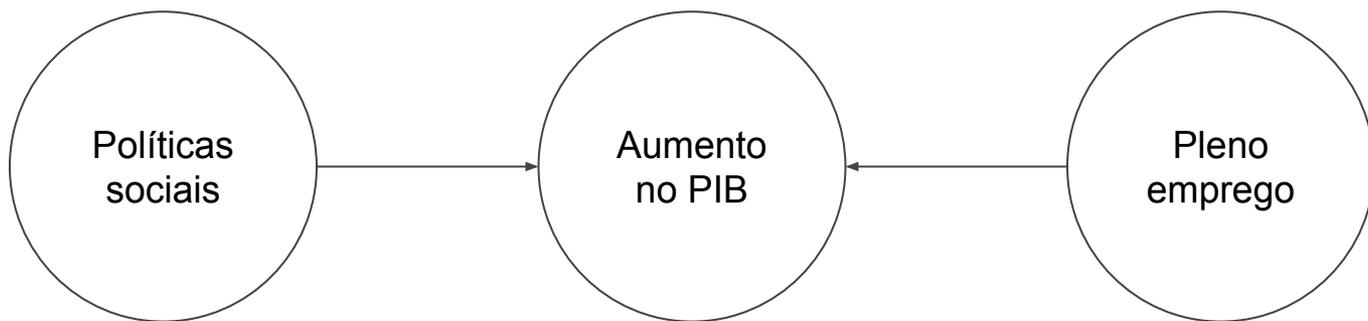
Causalidade - *fork*

- Uma causa têm múltiplos efeitos
- Dois efeitos têm uma causa em comum

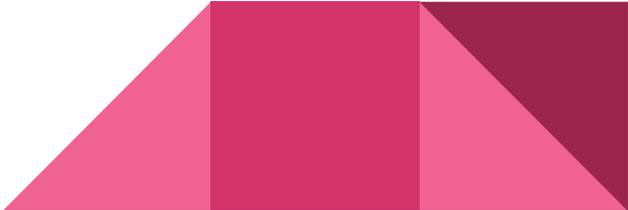


Causalidade - *collider*

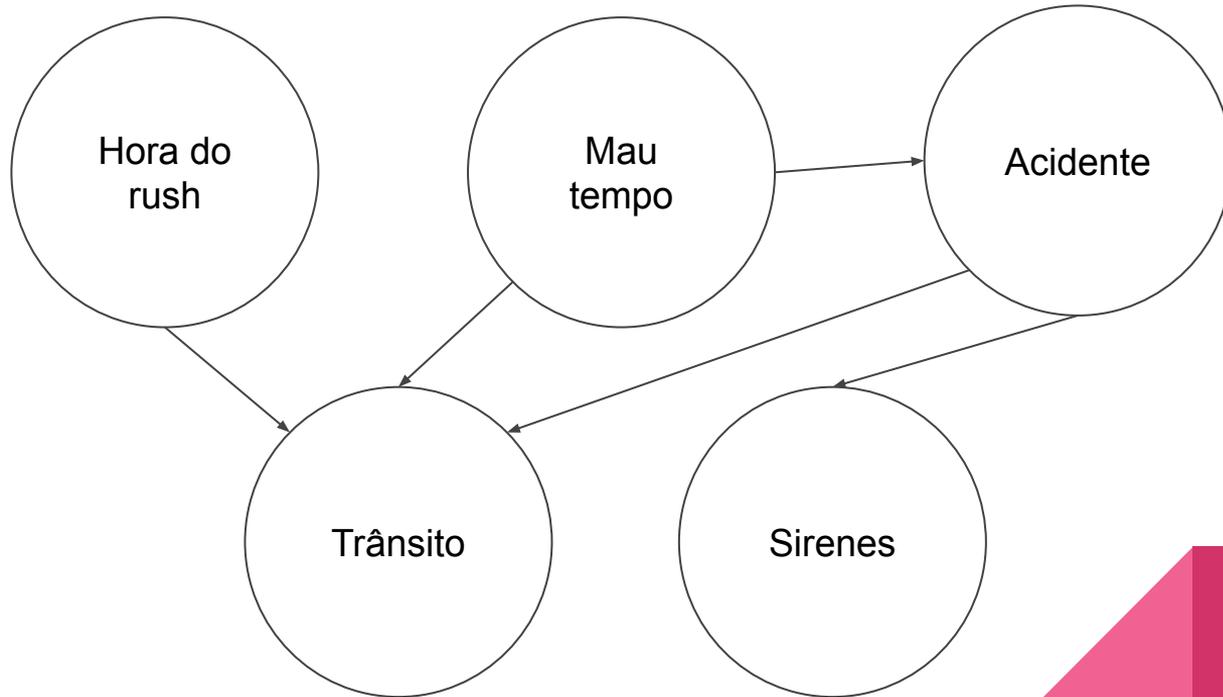
- Múltiplas causas para um efeito
- O efeito explica possível correlação entre causas



Causalidade

- Tipos de variáveis:
 - Confundidora
 - Influencia tanto variáveis dependentes quanto independentes
 - Interveniente
 - Var. independente que intervêm no estudo
 - Latente
 - Var. não observada diretamente
- 

Causalidade - modelos



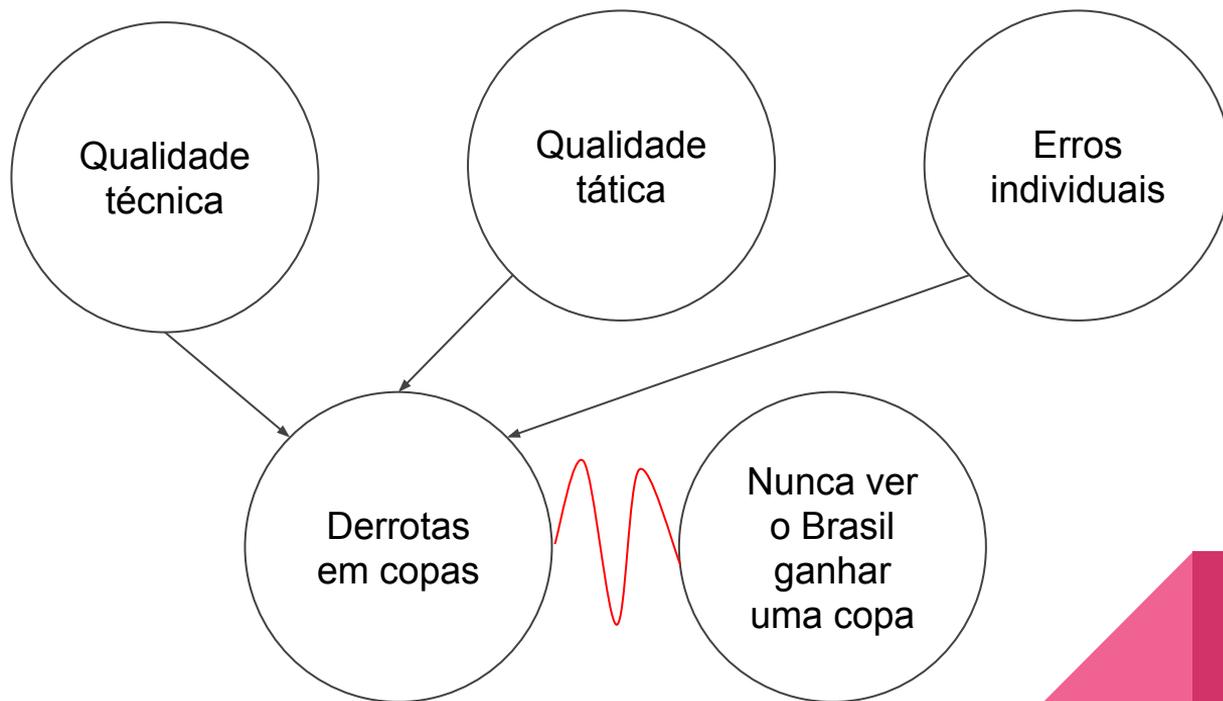
Correlação vs Causalidade

Correlação vs Causalidade

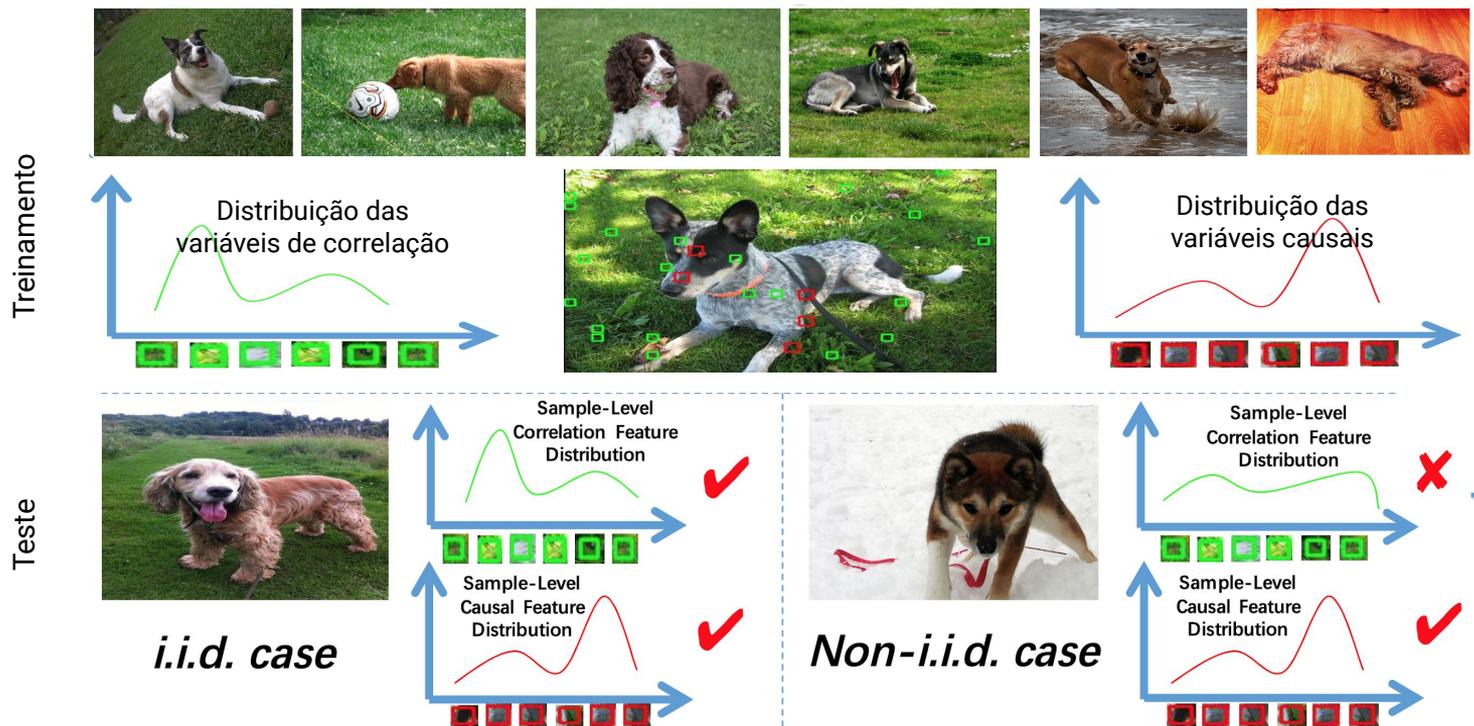
- Perguntas importantes para se fazer aos dados:
 - Existe uma conexão *real* entre as variáveis?
 - A correlação se manterá caso eu adicione novos dados?
 - A relação entre as variáveis analisadas é direta?
 - Existem fatores do problema possivelmente ocultos?



Correlação vs Causalidade



Correlação vs Causalidade



Técnicas

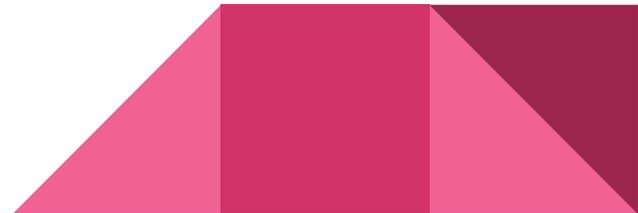
Regressão

- Suposição necessária
 - Observar **todas** as variáveis que poderiam afetar o resultado
- Alterar apenas a variável interveniente
- Mudança na variável de resultado implica causalidade
- Inadequado para estudos de ciências sociais

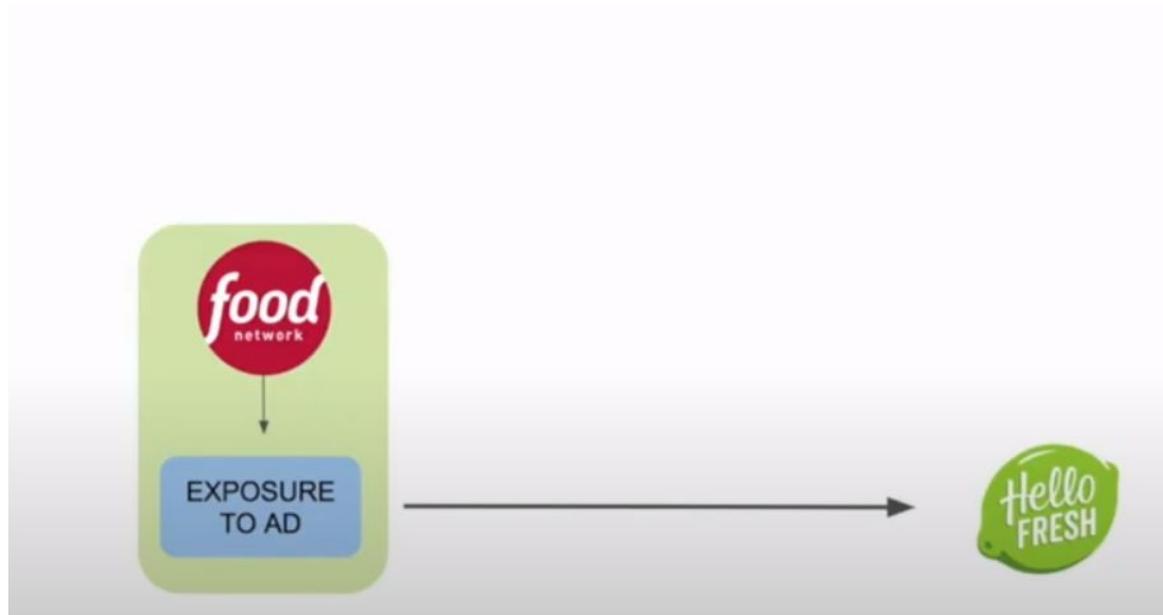


PSM - Propensity Score Matching (1983)

- Bom para lidar com *viés de seleção*
- Cálculo de um *Propensity Score*
- *Matching*
 - Grupos balanceados
- Comum nas ciências humanas e de comportamento
 - Saúde
 - Educação
 - Políticas públicas

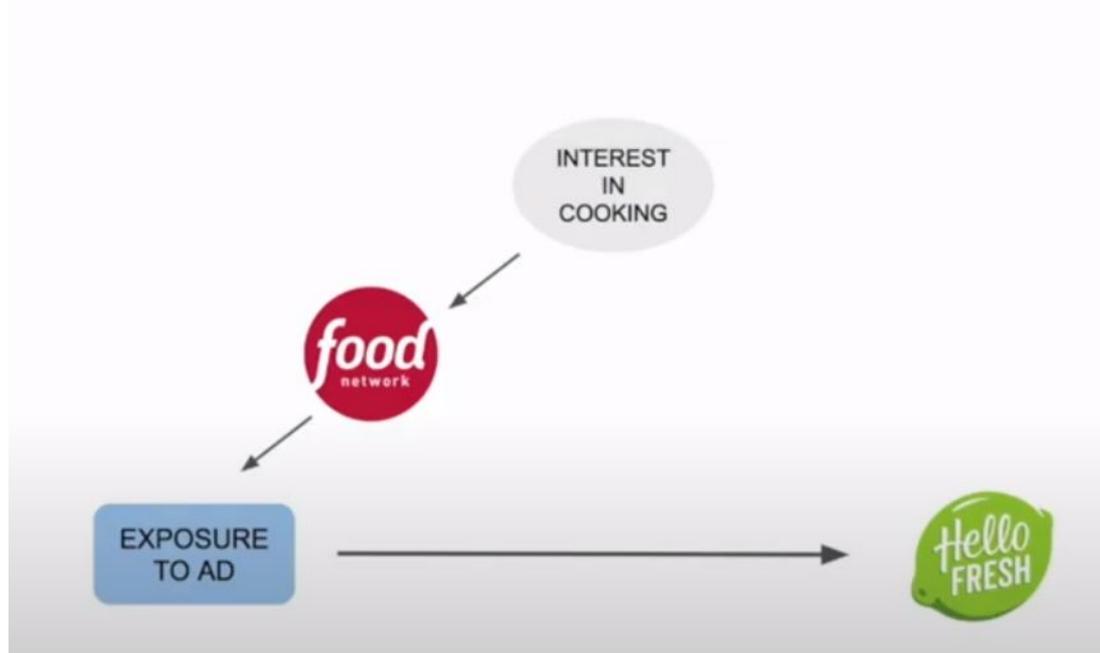


Exemplo



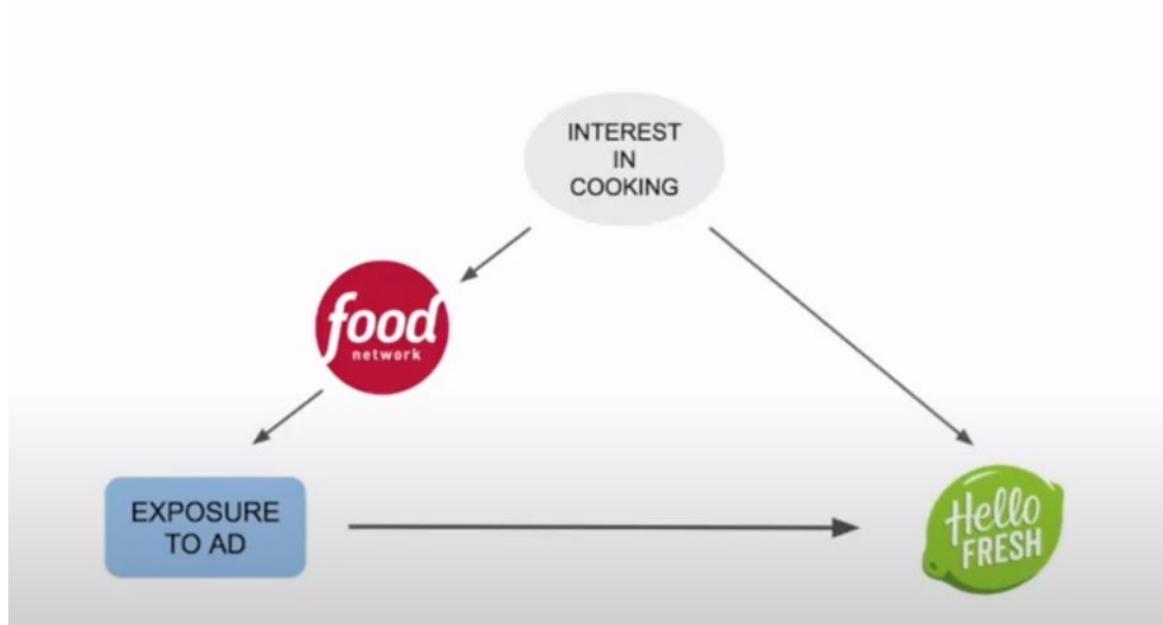
fonte:
<https://www.youtube.com/watch?v=gaUgW7NWai8>

Exemplo



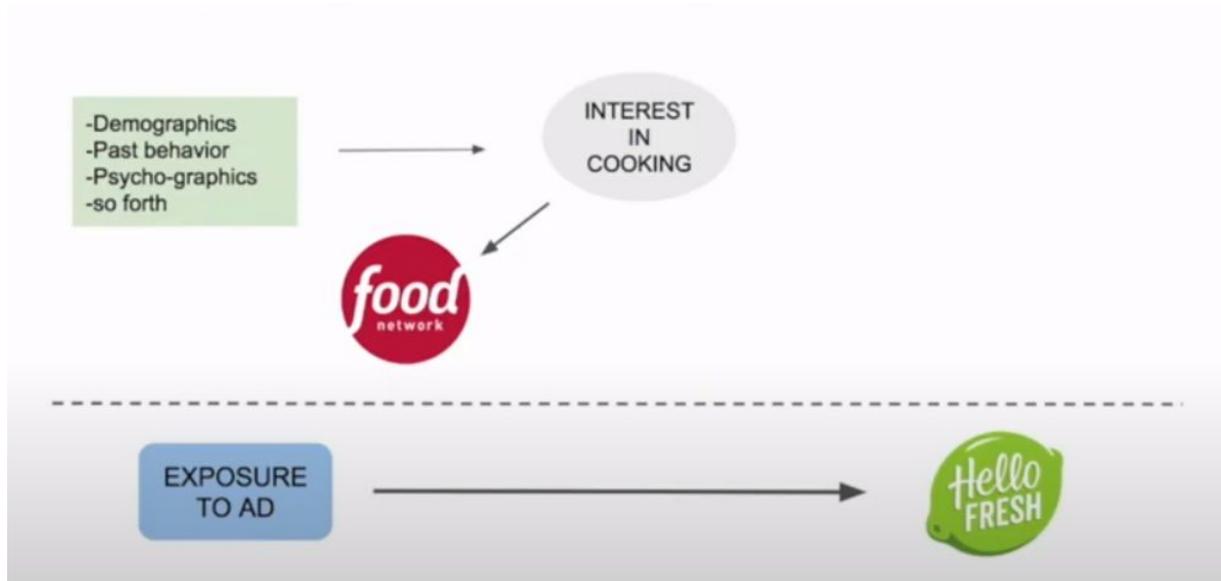
fonte:
<https://www.youtube.com/watch?v=gaUgW7NWai8>

Exemplo



fonte:
<https://www.youtube.com/watch?v=gaUgW7NWai8>

Exemplo



fonte:
<https://www.youtube.com/watch?v=gaUgW7NWai8>

Relações causais

- Descoberta causal se refere a descoberta de relações causais no dados.
- ex: a ponte 'causa' a presença do carro
 - Se removermos a ponte, a imagem não faz mais sentido com um carro flutuando sozinho



Relações causais em imagens

- Pesquisadores do Facebook e da Universidade de Berkeley foram capazes de achar **sinais de causalidade em imagens**

arXiv:1605.08179v2 [stat.ML] 31 Oct 2017

Discovering Causal Signals in Images

David Lopez-Paz
Facebook AI Research
dlp@fb.com

Robert Nishihara
UC Berkeley
rkn@eecs.berkeley.edu

Soumith Chintala
Facebook AI Research
soumith@fb.com

Bernhard Schölkopf
MPI for Intelligent Systems
bs@tue.mpg.de

Léon Bottou
Facebook AI Research
leon@bottou.org

Abstract

This paper establishes the existence of observable footprints that reveal the “causal dispositions” of the object categories appearing in collections of images. We achieve this goal in two steps. First, we take a learning approach to observational causal discovery, and build a classifier that achieves state-of-the-art performance on finding the causal direction between pairs of random variables, given samples from their joint distribution. Second, we use our causal direction classifier to effectively distinguish between features of objects and features of their contexts in collections of static images. Our experiments demonstrate the existence of a relation between the direction of causality and the difference between objects and their contexts, and by the same token, the existence of observable signals that reveal the causal dispositions of objects.

1. Introduction

Imagine an image representing a bridge over a river. On top of the bridge, a car is speeding through the right lane.

Modern computer vision algorithms excel at answering questions about the observable properties of the scene, such as such as “Is there a car in this image?”. This is achieved by leveraging correlations between pixels and image features across large datasets of images. However, a more nuanced understanding of images arguably requires the ability to reason about how the scene depicted in the image would change in response to interventions. Since the list of possible

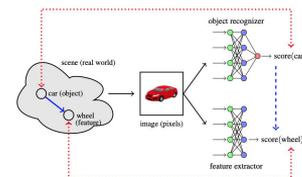
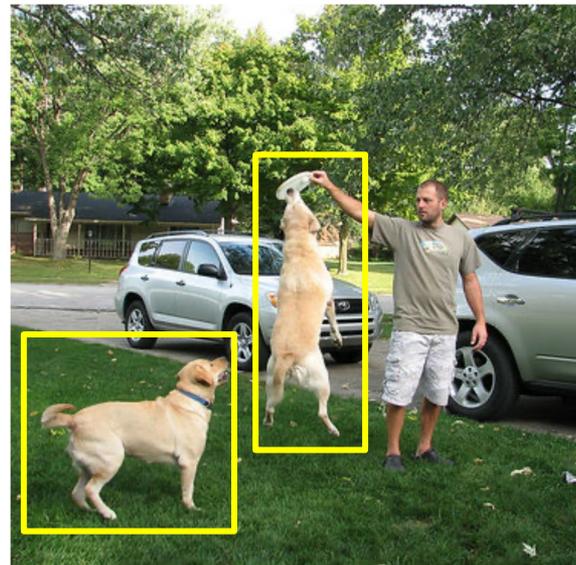


Figure 1: Our goal is to reveal causal relationships between pairs of real entities composing scenes in the world (e.g. “the presence of cars cause the presence of wheels”, solid blue arrow). To this end, we apply a novel observational causal discovery technique, NCC, to the joint distribution of a pair of related proxy variables that are computed by applying CNNs to the image pixels. Since these variables are expected to be highly correlated with the presence of the corresponding real entities, the appearance of causation between the proxy variables (dashed blue arrow) suggests that there is a causal link between the real world entities themselves (e.g. the appearance of causation between $score(car)$ and $score(wheel)$ suggests that the presence of cars causes the presence of wheels in the real world.)

that the rest of the scene depicted in the image (the river, the bridge) would remain invariant. On the other hand, the

Definições iniciais - Tipo de variáveis

- **Objeto/Contexto:**
 - **Variáveis de objeto:** mais ativadas dentro da caixinha que contém o objeto;
 - **Variáveis de contexto:** mais ativadas fora da caixinha que contém o objeto.
- **Causais/Anticausais:**
 - **Variáveis causais:** causam a presença do objeto na cena;
 - **Variáveis anticausais:** são aquelas causadas pela presença do objeto na cena.



Expectativas para o experimento

- **Dependência** estatística entre variáveis de **objeto** e variáveis **anticausais**
 - A maior parte das variáveis causadas pela presença do objeto são, de fato, parte do objeto e estão dentro da caixinha que contém o objeto.
 - ex. presença de carro causa a presença de rodas
- Variáveis de **contexto** e variáveis **causais não** apresentam **dependência**
 - Variáveis de contexto podem ser causa dos objetos ou causadas por ele
 - ex. asfalto no chão é causa para carro e a sombra do carro é causada pelo carro



Procedimento

- Dois modelos:
 - **Classificador binário** que identifica relações **causais e anticausais**
 - Treinado com gráficos de dispersão num conjunto de dados sintéticos rotulados
 - **Rede neural que identifica objetos** e sua localização na figura
- Classificação das variáveis da rede neural em: causal/anticausal e de objeto/contexto

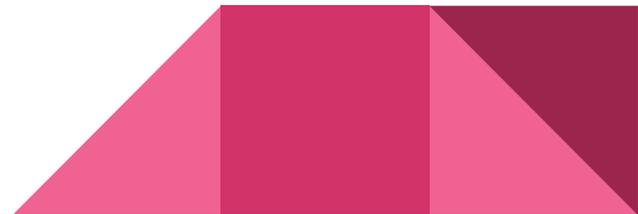
As variáveis anticausais tendem a ser as variáveis de objeto, conforme o esperado, o que indica que os modelos, de fato, conseguiram encontrar **sinais de causalidade nas imagens**



Regularização Causal

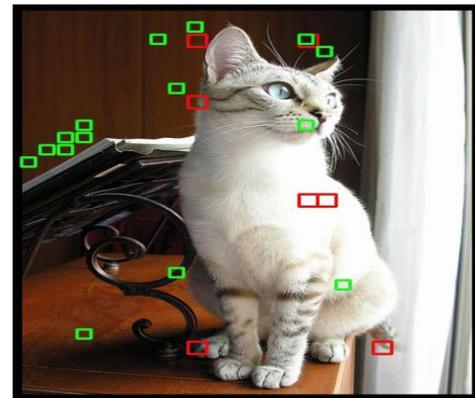
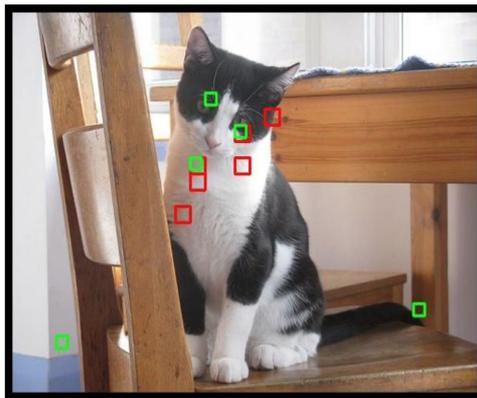
$$\hat{\mathbf{w}} = \underset{\mathbf{w}}{\operatorname{argmin}} \left\{ \frac{1}{n} \sum_{j=1}^n \mathcal{L}(\mathbf{x}_j, y_j | \mathbf{w}) + \lambda \sum_{i=1}^m c_i |w_i| \right\}$$

- \mathbf{L} é a função de perda para a predição de Y dado X_1, \dots, X_n ;
- c_i é a saída de um classificador que calcula a probabilidade $P[X_i \text{ não causar } Y]$;
- λ é um hiperparâmetro da regularização
 - quanto maior o valor, mais importância damos a selecionar variáveis causais



Regularização Causal

- Vantagens:
 - Modelo mais interpretável;
 - Modelo menos sujeito ao viés da amostra
- Desvantagens:
 - Treinar classificador que indica se a variável foi causal ou não



Revisão

- A correlação tem sido uma ferramenta poderosa em modelos de predição, mas não podemos nos limitar somente a isso, especialmente quando estamos explorando dados;
 - Grafos causais ajudam a formalizar o conhecimento causal no domínio de estudo;
 - Entre as técnicas para investigar causalidade nos dados, temos:
 - Regressão
 - Propensity Score Matching
 - Regularizadores Causais
 - Incorporar causalidade costuma gerar soluções mais **interpretáveis e acionáveis**
- 