

# Reconhecimento de Cenários baseado nas Localizações de Fornecedores do Governo Federal

---

-Autor- Rodrigo Peres Ferreira

-Orientador-Prof. Dr. Marcelo Ladeira

Data: 17 de dezembro de 2018

Universidade de Brasília

Mestrado Profissional em Computação Aplicada



1. Definição do Problema
  - 1.1 Hipóteses de Pesquisa
  - 1.2 Objetivos
  - 1.3 Contribuição Esperada
2. Revisão do Estado da Arte
3. Solução Proposta
  - 3.1 Metodologia
  - 3.2 Resultados dos Experimentos
4. Conclusões
5. Trabalhos Futuros

# Definição do Problema

---

## Ministério da Transparência e Controladoria-Geral da União (CGU)

O Ministério da Transparência e Controladoria-Geral da União (CGU) é o órgão central de controle interno do Poder Executivo Federal no Brasil.

- ⊙ Funções no Decreto N<sup>o</sup> 8910/16
  - Defesa do Patrimônio Público;
  - Controle Interno;
  - Auditoria Pública;
  - Correição;
  - Prevenção e Combate à Corrupção;
  - Ouvidoria;
  - Incremento da Transparência.

## Observatório da Despesa Pública (ODP)

O Observatório da Despesa Pública (ODP) é uma unidade de produção de informações estratégicas da CGU que realiza monitoramentos nas despesas do Governo Federal.

### ⦿ Trabalhos

- Cruzamento e Análise de Dados;
- Informações Gerenciais e de Auditoria.

**Dados de fontes não estruturadas (ex: imagens, textos) ainda são pouco utilizados para cruzamento de dados!**

## Conceito

Para nossos propósitos, as organizações ou fornecedores de fachada são tipos de corporações criadas e utilizadas para esconder identidades de pessoas envolvidas em casos de corrupção e lavagem de dinheiro.

## Polícia Federal identificou 84 empresas de fachada vinculadas à Lava-Jato

Valor movimentado por 55 empreendimentos movimentou R\$ 2,6 bilhões



Figura 1: Fonte: O Globo, reportagem de 30/08/2015.

- ⊙ Com base na **análise da imagem** do endereço de uma empresa é possível classificá-la entre **cenários comerciais e não comerciais (lojas/não lojas)**;
- ⊙ A identificação de **empresas em cenários comerciais e não comerciais (lojas/não lojas)** é um **indicador relevante** para determinar se ela é uma empresa de fachada ou de risco.

## Objetivo Geral

Avaliar, no âmbito da CGU, os métodos para identificação de fornecedores de fachada e fornecedores de risco do Governo Federal através da classificação e análise de imagens de endereços de fornecedores contratados pelo Governo Federal para o fornecimento de determinados produtos ou serviços.

## ⊙ Objetivos Específicos

- **Ajustar modelos de Redes Neurais Convolucionais (CNN)** existentes para classificação de cenários de forma a torná-los capazes de **identificar padrões** em cenários de fornecedores;
- **Verificar** se houve melhora na identificação de fornecedores de fachada ou fornecedores de risco através da inclusão da classificação automática de imagens quando comparada a abordagens anteriores que não utilizavam esta informação;

## Contribuição Esperada

Introduzir o uso de imagens como fonte de dados em outros projetos no âmbito da CGU.

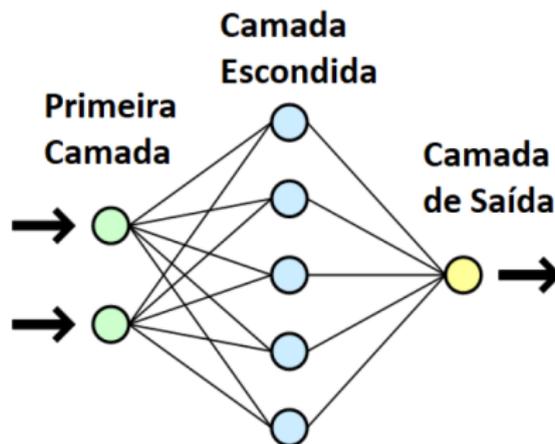
# Revisão do Estado da Arte

---

# Reconhecimento de Cenários

## Redes Neurais Artificiais (ANN)

Técnica de Aprendizagem de Máquina levemente inspirada pela neurociência. Define um mapeamento entre uma dada entrada  $x$  e uma saída  $y$  através de um conjunto de funções (“neurônios”)



## Redes Neurais Convolucionais (CNN)

Diferenciam-se das redes convencionais por selecionarem atributos através de operações de **convolução** e **pooling**.

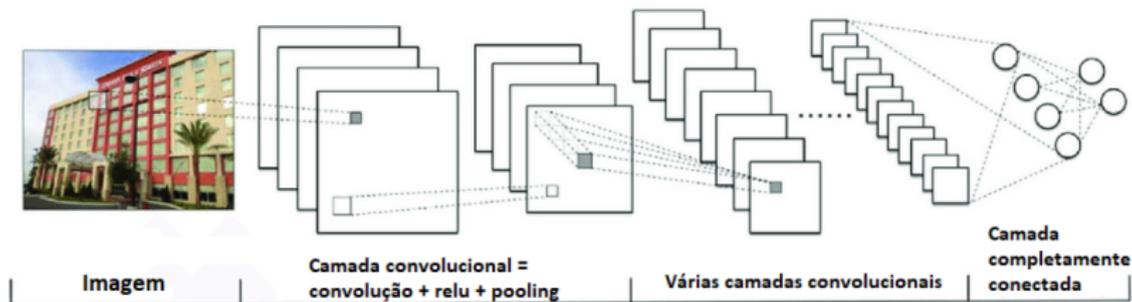


Figura 3: Fonte: Ma et al. (2018)

# Reconhecimento de Cenários

## Arquiteturas ResNet

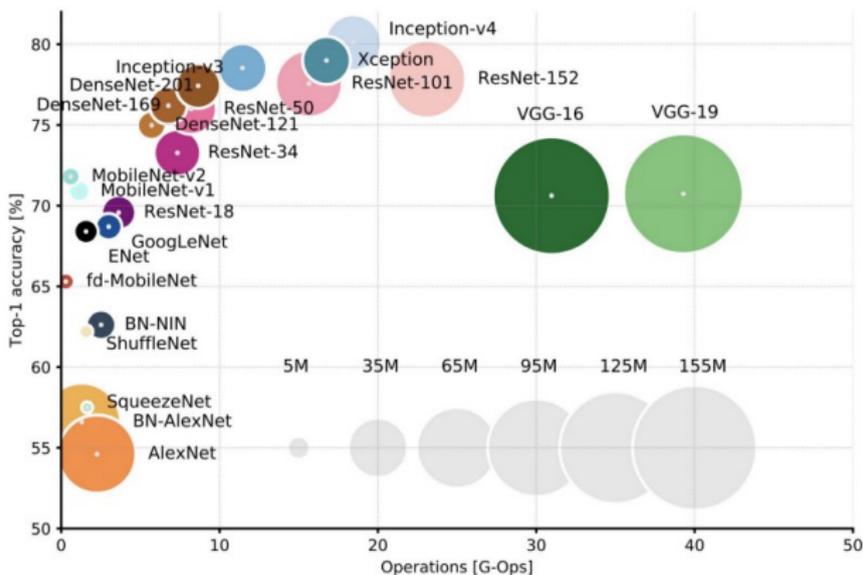


Figura 4: Comparação entre arquiteturas (Fonte: Culurciello, 2017)

<https://towardsdatascience.com/neural-network-architectures-156e5bad51ba>

# Reconhecimento de Cenários

## Arquiteturas ResNet

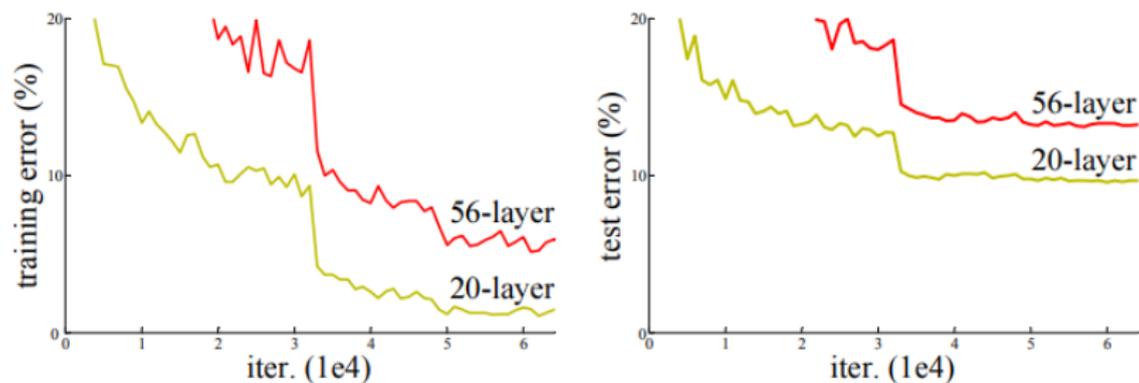


Figura 5: Degradação de desempenho (He et al., 2016)

# Reconhecimento de Cenários

## Arquiteturas ResNet

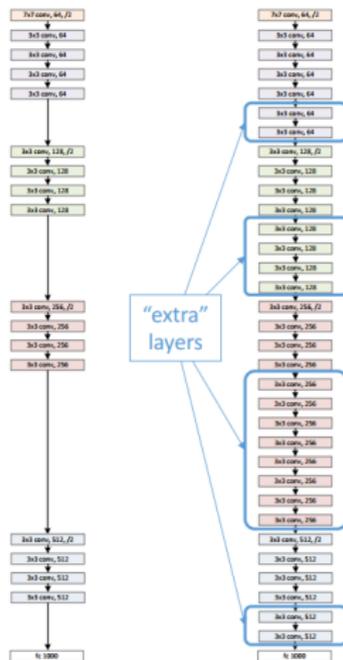


Figura 6: Solução por Construção (Fonte: <http://teleported.in/posts/decoding-resnet-architecture/>)

## Bloco Residual

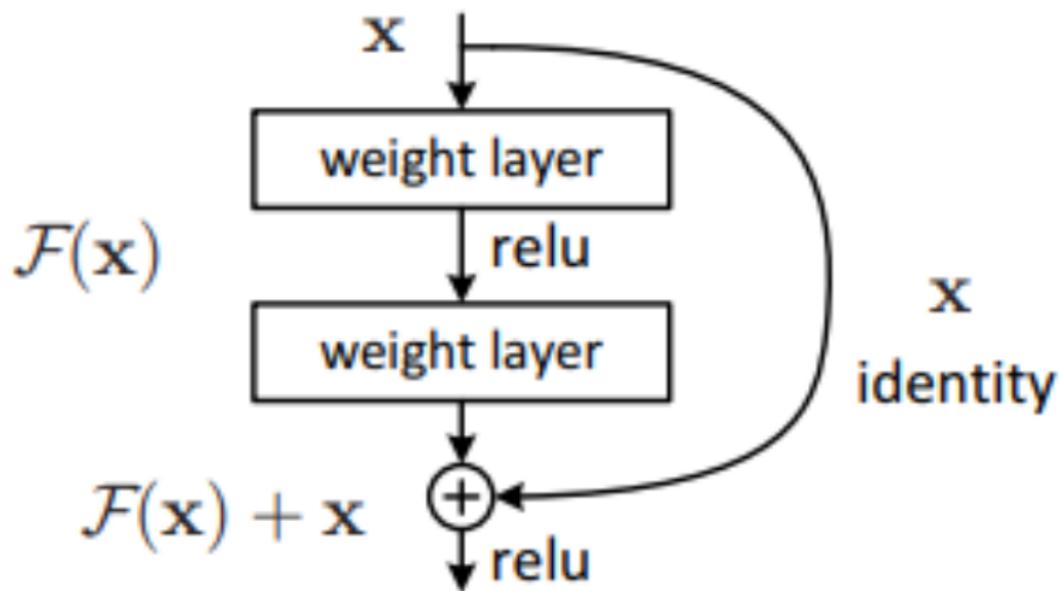
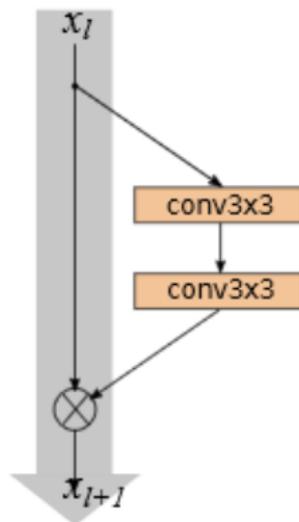


Figura 7: Bloco Residual (Fonte: He et al).

# Reconhecimento de Cenários

Wideresnet

**Resnet**



**Wideresnet**

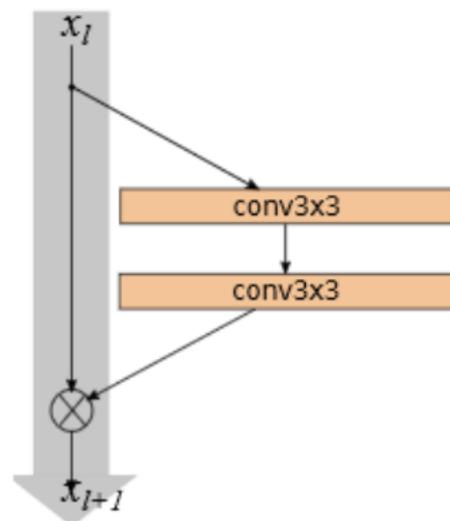


Figura 8: Wideresnet (Adaptado de Zagoruyko e Komodakis, 2017)

## Wideresnet

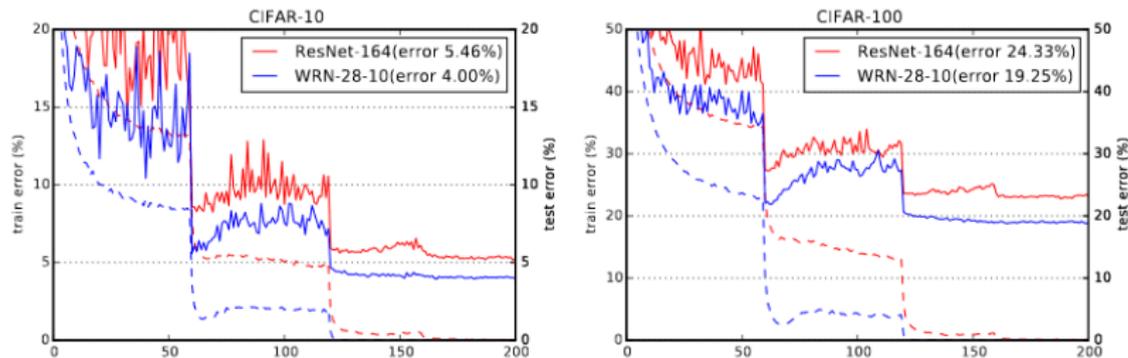


Figura 9: Curva de aprendizado de uma Wideresnet (Zagoruyko e Komodakis, 2017)

# Reconhecimento de Cenários

## Wideresnet 18 camadas



Figura 10: Fonte: Al Rabbani Alif, Ahmed e Hasan

# Reconhecimento de Cenários

O que esses exemplos têm em comum?



Figura 11: DeepBlue, Watson e Alpha Go (Fontes: <https://efemeridesdoefemello.com/2017/05/11/computador-deep-blue-vence-garry-kasparov>, <https://blog.ted.com/how-did-supercomputer-watson-beat-jeopardy-champion-ken-jennings-experts-discuss>, <https://www.technologyreview.com/s/604273/finding-solace-in-defeat-by-artificial-intelligence>)

## Muitos Dados

- ⊙ DeepBlue: 700 mil itens;
- ⊙ Watson: 8,6 milhões de itens;
- ⊙ Alpha Go: 30 milhões de itens.

“Não temos melhores algoritmos que ninguém, apenas temos mais dados,” Cientista-Chefe do Google, Peter Norvig (Google’s Zeitgeist 2011).

# Reconhecimento de Cenários

Acurácia de diversos modelos com o aumento de dados disponíveis para treino.

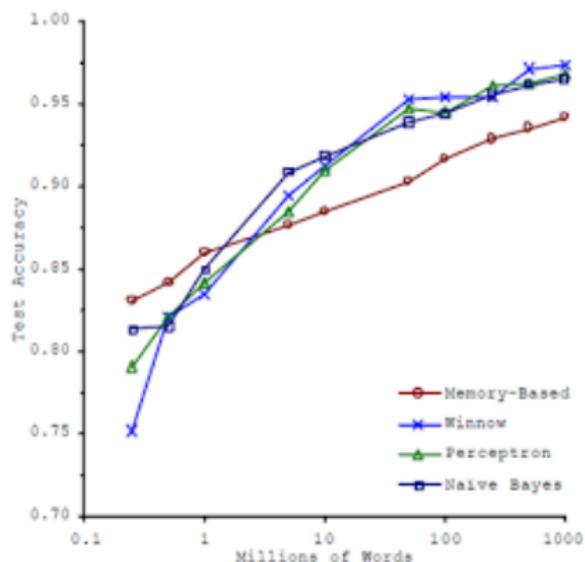


Figura 12: Fonte: Banko e Brill (2001)

Banco Places365 ([places2.csail.mit.edu](http://places2.csail.mit.edu))

- ⊙ 1.803.460 imagens de treinamento;
- ⊙ imagens por classe: de 3.068 a 5.000;
- ⊙ conjunto de validação: 50 imagens por classe;
- ⊙ conjunto de teste: 900 imagens por classe.

# Solução Proposta



1. obter imagens dos fornecedores
2. realizar anotações nas imagens obtidas;
3. ajustar modelos baseados em redes convolucionais;
4. construir modelos de risco gerais com diversos atributos, utilizando a saída do modelo convolucional;
5. realizar a validação dos modelos de risco gerais, avaliando se houve melhoria pela inclusão da saída do modelo convolucional.

## Obter as imagens dos fornecedores: Coleta de endereços

1. CNPJ de licitantes vencedores da base do site ComprasNet (2016/2017);
2. Endereços da base de CNPJ da Receita Federal;
3. Endereços são colocados em um formato padronizado.  
Ex. "R. ALFREDO WAGNER, 858 - ALVORADA, Chapecó - SC, 89804-430";
4. Endereço utilizado como entrada para a API do Google Street View;

# Obter as imagens dos fornecedores: Download

## Requisições GET

### Metadados:

`https://maps.googleapis.com/maps/api/streetview/metadata?size=227x227&location=R. ALFREDO WAGNER, 858 - ALVORADA, CHAPECO-SC,89804-430&heading=90&key=CHAVE`



### Imagens:

`https://maps.googleapis.com/maps/api/streetview?size=227x227&location=R. ALFREDO WAGNER, 858 - ALVORADA, CHAPECO-SC,89804-430&heading=90&key=CHAVE`



## Respostas

```
{  
  "copyright" : "© Google, Inc.",  
  "date" : "2012-04",  
  "location" : {  
    "lat" : -27.07809942823494,  
    "lng" : -52.63945563168106  
  },  
  "pano_id" : "BfnAWN0g79DwgTS3lqBt0g",  
  "status" : "OK"  
}
```



Figura 13: Exemplo de requisição por dados e metadados. Fonte: Google Street View API

## Obter as imagens dos fornecedores: Download

1. Consulta metadados antes de consultar a imagem para verificar se existe imagem disponível;
2. Baixadas 4 imagens por fornecedor (com orientações Norte, Leste, Sul e Oeste);
3. Imagens de tamanho 227x227 (AlexNet), redimensionados para 224x224 (Wideresnet) e padrão RGB;
4. Implementação multi-threaded;
5. Após aplicação de filtros (exclusão de imagens de terceiros e de fornecedores sem atividade econômica principal informada), resultou em 120.752 imagens relativas a 30.188 fornecedores.

# Obter as imagens dos fornecedores: Decisões

Período 2016/2017

1. Delimitação de escopo
2. De preferência dados mais recentes (tempestividade)
3. Outros períodos podem ser adicionados após um trabalho inicial

Street View

1. Imagens têm mais detalhes que as do Google Maps
- 4 imagens por fornecedor (Norte, Leste, Sul, Oeste)
1. Uma imagem apenas pode não fornecer informação suficiente (Ex. Rua, Parede)
  2. A orientação da imagem não muda o desempenho da classificação de cenários (Wacker, Ferreira e Ladeira, 2018)

# Realizar anotações nas imagens obtidas

## EXEMPLOS POSITIVOS (ÁREA COMERCIAL)



## EXEMPLOS NEGATIVOS (ÁREA NÃO COMERCIAL)



Figura 14: Exemplo de imagens anotadas como áreas comerciais e não comerciais.  
Fonte: Wacker, Ferreira e Ladeira (2018).

# Ajustar modelos baseados em redes convolucionais



Figura 15: Exemplo de imagens classificadas pela rede convolucional AlexNet treinada no conjunto de dados Places205 (anterior à Places365), ilustrando a necessidade de ajuste desses modelos para adaptação à realidade nacional.

# Ajustar modelos baseados em redes convolucionais

Atributos transferíveis (*Transfer Learning*) por extração de features ou ajuste fino.



Figura 16: Exemplo de regiões que mais ativaram neurônios da penúltima camada da rede WideResNet18. Cada linha representa ativações de um tipo de neurônio.

Fonte: Wacker, Ferreira e Ladeira (2018).

## Tipologia

Atributo ou indicador levantado pela CGU resultante de cruzamento de bases governamentais. Pode ser um indicador gerencial ou de risco, indicando um indício de irregularidade ou mau uso de recursos públicos.

## Bases de Dados

- ⊙ Base de Compras Governamentais (ComprasNet/SIASG);
- ⊙ Base de sócios e pessoas jurídicas da Receita Federal do Brasil (RFB);
- ⊙ Base da Relação Anual de Informações Sociais (RAIS);
- ⊙ Base da Classificação Nacional de Atividades Econômicas (CNAE);
- ⊙ Cadastro de Empresas Inidôneas e Suspensas (CEIS).

# Construir modelos de riscos gerais com diversos atributos

- ⊙ tipologia 1 - Baixa quantidade de funcionários
- ⊙ tipologia 2 - Sócios com baixa qualificação ou remuneração
- ⊙ tipologia 3 - Microempresas ou empresas de pequeno porte com licitações de valores incompatíveis
- ⊙ tipologia 4 - Mais de um fornecedor no mesmo endereço
- ⊙ tipologia 5 - Grande quantidade de subclasses de atividade econômica secundária
- ⊙ tipologia 6 - Diferença entre data da abertura e compra inferior a 30 dias
- ⊙ tipologia 7 - Fornecedores com penalidades suspensivas no cadastro
- ⊙ tipologia 8 - Empresas no CEIS
- ⊙ tipologia 9 - Empresas com sócios com empresas no CEIS
- ⊙ tipologia 10 - Compatibilidade entre atividade econômica e produto/serviço fornecido

- ⊙ Modelos de Regressão Logística utilizando fornecedores punidos com penalidades graves (suspensivas) como variável dependente
  - modelo de regressão logística com base em variáveis binárias das tipologias levantadas pelo ODP;
  - modelo de regressão logística com base nas variáveis quantitativas das tipologias levantadas pelo ODP;
  - modelos de regressão logística separados por seção da Classificação Nacional de Atividades Econômicas (CNAE);

## Métricas

- ⊙ Precisão;
- ⊙ Recall (Abrangência);
- ⊙ F-Measure;
- ⊙ Área sobre a curva ROC (AUC).

# Experimentos realizados

## Matriz de confusão

		Classe Preditada	
		Positivo	Negativo
Classe Verdadeira	Positivo	<b>Verdadeiro</b> <b>Positivo (VP)</b>	<b>Falso</b> <b>Negativo (FN)</b>
	Negativo	<b>Falso</b> <b>Positivo (FP)</b>	<b>Verdadeiro</b> <b>Negativo (VN)</b>

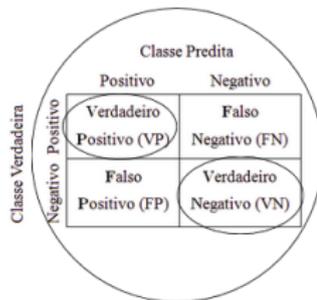
Figura 17: Matriz de Confusão. Fonte: Adaptado de

<https://www.researchgate.net/figure/>

Figura-4-Medidas-de-desempenho-calculadas-a-partir-da-matriz-de-confusao\_  
fig4\_321162277

## Acurácia

$$\text{Acurácia} = \frac{\text{Verdadeiros Positivos (TP)} + \text{Verdadeiros Negativos (VN)}}{\text{Total}}$$



## Precisão

$$\text{Precisão} = \frac{\text{Verdadeiros Positivos (TP)}}{\text{Verdadeiros Positivos (TP)} + \text{Falsos Positivos (FP)}}$$

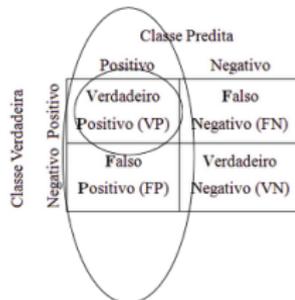


Figura 18: Acurácia e Precisão. Fonte: Adaptado de

[https://medium.com/as-m%C3%A1quinas-que-pensam/m%C3%](https://medium.com/as-m%C3%A1quinas-que-pensam/m%C3%A9tricas-comuns-em-machine-learning-como-analisar-a-qualidade-de-chat-bots)

[A9tricas-comuns-em-machine-learning-como-analisar-a-qualidade-de-chat-bots](https://medium.com/as-m%C3%A1quinas-que-pensam/m%C3%A9tricas-comuns-em-machine-learning-como-analisar-a-qualidade-de-chat-bots)

## Recall (abrangência)

$$\text{Recall} = \frac{\text{Verdadeiros Positivos (TP)}}{\text{Verdadeiros Positivos (TP)} + \text{Falsos Negativos (FN)}}$$

		Classe Predita	
		Positivo	Negativo
Classe Verdadeira	Positivo	Verdadeiro Positivo (VP)	Falso Negativo (FN)
	Negativo	Falso Positivo (FP)	Verdadeiro Negativo (VN)

## F-Measure (F1): Combina precisão e recall

$$F1 = \frac{2 * \text{precisão} * \text{recall}}{\text{precisão} + \text{recall}}$$

Figura 19: Recall e F-Measure. Fonte: Adaptado de <https://medium.com/as-m%C3%A1quinas-que-pensam/m%C3%A9tricas-comuns-em-machine-learning-como-analisar-a-qualidade-de-chat-bots>

# Experimentos realizados

Curva ROC (Receiving Operating Characteristics): É a curva de probabilidade que representa o grau de separação entre as classes de um modelo.

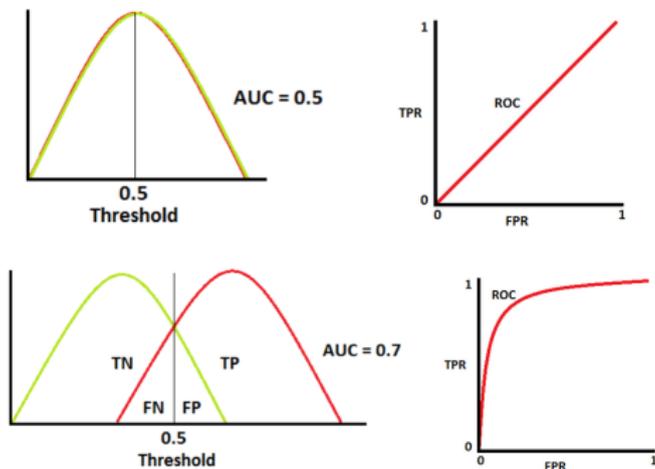


Figura 20: Exemplo de curvas ROC para graus de separação distintos. Fonte: <https://towardsdatascience.com/understanding-auc-roc-curve-68b2303cc9c5>

# Experimentos realizados

Tabela 1: Classificação de imagens individuais (Atributos das últimas camadas)

Atributos extraídos da Places	Média da AUC
Conv-12	$0.8877 \pm 0.0136$
Conv-13	$0.9208 \pm 0.0078$
Conv-14	$0.9387 \pm 0.0067$
Conv-15	$0.8527 \pm 0.0129$
Conv-16	$0.9545 \pm 0.0056$
Conv-17	$0.9483 \pm 0.0073$

Tabela 2: Área sobre a curva ROC (AUC) da abordagem de Fine-Tuning da Wide Resnet18.

Fine-Tuning (AUC)
0.9737

# Experimentos realizados

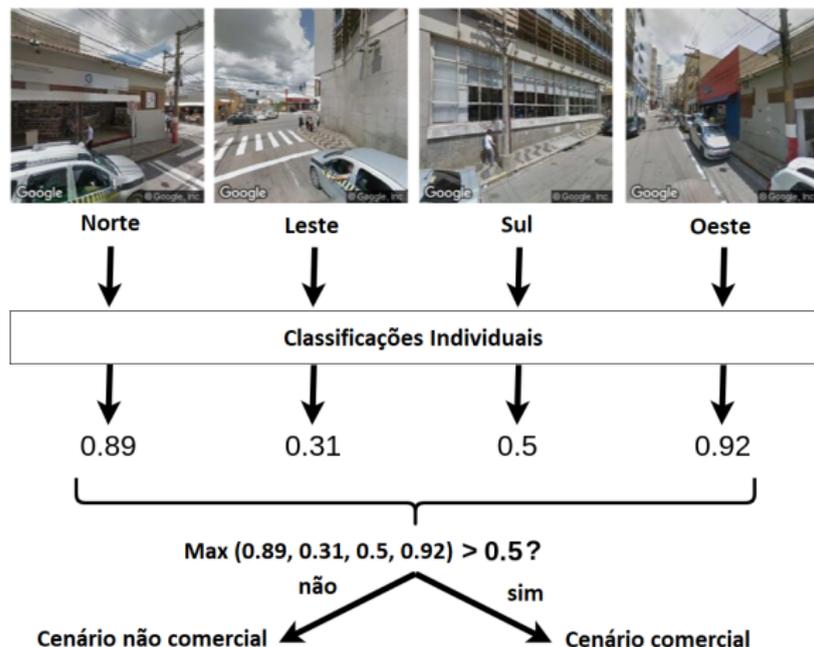


Figura 21: Fonte: Wacker, Ferreira e Ladeira (2018)

# Experimentos realizados

Tipologia	Efeito do relacionamento na frequência observada	P-valor do teste
Baixa quantidade de funcionários (1)	Maior que a esperada	0.007
Sócios com baixa qualificação ou remuneração (2)	-	0.47
EPP ou ME com valor homologado acima do limite (3)	Menor que a esperada	0.0015
Mais de um fornecedor com o mesmo endereço (4)	-	0.06
Grande quantidade de subclasses CNAE (5)	Menor que a esperada	7e-18
Fornecedor venceu licitações menos de 30 dias após abertura da empresa (6)	-	0.55
Fornecedor com punição suspensiva no cadastro (7)	Menor que a esperada	4e-14
Fornecedor cadastrado no CEIS (8)	-	0.0503
Fornecedor com sócios no CEIS (9)	Menor que a esperada	0.04
Compatibilidade entre atividade econômica e produto/serviço (10)	-	0.69

Figura 22: Teste Qui-Quadrado - Relacionamentos entre Cenário Comercial e outras Tipologias

# Experimentos realizados

Tabela 3: Variáveis do modelo base (Fornecedor Punido como variável dependente)

Variável	Coefficiente	P-valor do coeficiente
Intercept	-0.1164	0.073
Baixa quantidade (1)	-0.3258	0.000
IndSocioLaranja (2)	0.1575	0.000
EPP/ME acima do limite (3)	1.0811	0.000
Mais de um fornecedor (4)	0.0800	0.153
Mais de 10 subclasses (5)	0.7890	0.000
IndQtdDiasInferior30 (6)	1.0329	0.000
ind_socio_com_ceis (9)	1.2234	0.000
Matserv Incompatível (10)	-1.2854	0.000
NaoLoja (WideResNet)	-0.0231	0.730
Loja (WideResNet)	-0.1738	0.008

# Experimentos realizados

	Precisão	Recall	F-Measure	Suporte
Fornecedor não punido	0.78	0.76	0.77	7033
Fornecedor punido	0.46	0.48	0.47	2930
Média / Total	0.69	0.68	0.68	9963

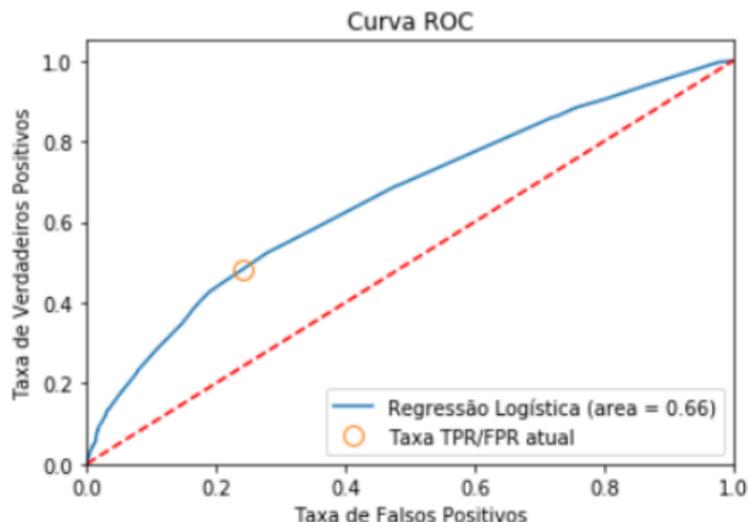


Figura 23: Métricas de desempenho do modelo base

# Experimentos realizados

Tabela 4: Variáveis do modelo quantitativo (Fornecedor Punido como variável dependente)

Variável	Coefficiente	P-valor do coeficiente
Intercept	-0.7689	0.000
qtd_media (1)	15.8415	0.000
Socio Laranja (2)	4.1915	0.000
Valor Total Homologado em 2017 (3)	17.8808	0.000
Micro Empresa (3)	0.3900	0.000
Não Informado (3)	-2.6930	0.000
Pequena Empresa (3)	0.5276	0.000
qtd_fornecedores (4)	1.2099	0.114
qtd_subclasses_cnae (5)	-1.7381	0.000
Qtd dias inferior a 30 (6)	15.1842	0.000
socio_com_ceis (9)	11.1347	0.000
VALIDO (10)	21.1931	0.000
prob_loja (WideResNet)	-0.1512	0.002

# Experimentos realizados

<b>Tipo de Modelo</b>	<b>Coefficiente da variável da CNN</b>	<b>P-valor da variável da CNN</b>
Modelo quantitativo original (com prob_loja)	-0.1512	0.002
Modelo + Loja	-0.1406	0.000
Modelo + NaoLoja	0.1289	0.000
Modelo + Indefinido	0.1141	0.105

Figura 24: Comparando o modelo com outras variáveis da rede convolucional (Fornecedor Punido como variável dependente).

# Experimentos realizados

	Precisão	Recall	F-Measure	Suporte
Fornecedor não punido	0.84	0.81	0.83	7033
Fornecedor punido	0.58	0.63	0.61	2930
Média / Total	0.76	0.76	0.76	9963

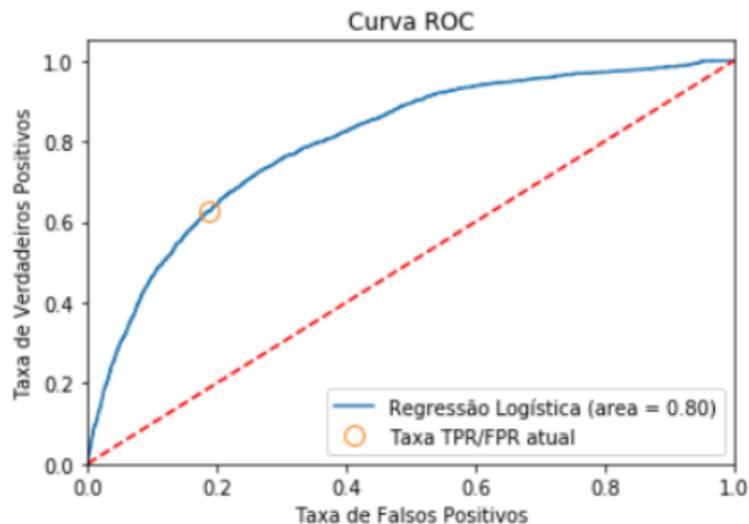


Figura 25: Métricas de desempenho do modelo quantitativo

# Experimentos realizados

	Precisão	Recall	F-Measure	Suporte
<b>Fornecedor não punido</b>	0.84	0.82	0.83	7033
<b>Fornecedor punido</b>	0.58	0.62	0.60	2930
<b>Média / Total</b>	0.76	0.76	0.76	9963

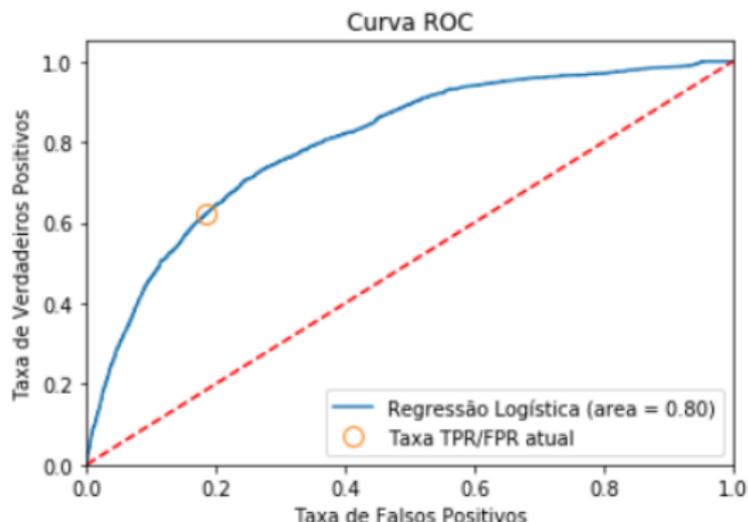


Figura 26: Métricas de desempenho do modelo quantitativo sem a variável “prob\_loja”

# Experimentos realizados

Seção de Atividade Econômica (CNAE)	Coefficiente de prob_loja	P-valor de prob_loja
A - AGRICULTURA, PECUÁRIA, PRODUÇÃO FLORESTAL, PESCA E AQUICULTURA	0.6881	0.161
B - INDÚSTRIAS EXTRATIVAS	0.9051	0.443
C - INDÚSTRIAS DE TRANSFORMAÇÃO	-0.0667	0.424
D - ELETRICIDADE E GÁS	0.6020	0.271
E - ÁGUA, ESGOTO, ATIVIDADES DE GESTÃO DE RESÍDUOS E DESCONTAMINAÇÃO	-0.6101	0.005
F - CONSTRUÇÃO	0.1086	0.206
G - COMÉRCIO; REPARAÇÃO DE VEÍCULOS AUTOMOTORES E MOTOCICLETAS	-0.2436	0.000
H - TRANSPORTE, ARMAZENAGEM E CORREIO	0.0914	0.560
I - ALOJAMENTO E ALIMENTAÇÃO	0.2111	0.306
J - INFORMAÇÃO E COMUNICAÇÃO	0.0109	0.933
K - ATIVIDADES FINANCEIRAS, DE SEGUROS E SERVIÇOS RELACIONADOS	0.3384	0.344
L - ATIVIDADES IMOBILIÁRIAS	-0.2434	0.298
M - ATIVIDADES PROFISSIONAIS, CIENTÍFICAS E TÉCNICAS	0.0802	0.452
N - ATIVIDADES ADMINISTRATIVAS E SERVIÇOS COMPLEMENTARES	-0.1305	0.162
O - ADMINISTRAÇÃO PÚBLICA, DEFESA E SEGURIDADE SOCIAL	-2.0433	0.000
P - EDUCAÇÃO	-0.3286	0.038
Q - SAÚDE HUMANA E SERVIÇOS SOCIAIS	-0.2723	0.000
R - ARTES, CULTURA, ESPORTE E RECREAÇÃO	0.8291	0.002
S - OUTRAS ATIVIDADES DE SERVIÇOS	-0.2856	0.033
U - ORGANISMOS INTERNACIONAIS E OUTRAS INSTITUIÇÕES EXTRATERRITORIAIS	-	-

Figura 27: Modelos de regressão com “prob\_loja” por seção da CNAE (Fornecedor Punido como variável dependente)

# Experimentos realizados

Seção de Atividade Econômica (CNAE)	Coefficiente de prob_loja	P-valor de prob_loja
E - ÁGUA, ESGOTO, ATIVIDADES DE GESTÃO DE RESÍDUOS E DESCONTAMINAÇÃO	-0.5128	0.079
G - COMÉRCIO; REPARAÇÃO DE VEÍCULOS AUTOMOTORES E MOTOCICLETAS	-0.1274	0.051
O - ADMINISTRAÇÃO PÚBLICA, DEFESA E SEGURIDADE SOCIAL	-2.7510	0.002
P - EDUCAÇÃO	-0.2653	0.204
Q - SAÚDE HUMANA E SERVIÇOS SOCIAIS	-0.4687	0.000
R - ARTES, CULTURA, ESPORTE E RECREAÇÃO	0.2002	0.578
S - OUTRAS ATIVIDADES DE SERVIÇOS	-0.6431	0.000

Figura 28: Modelos de regressão com 12 variáveis do modelo quantitativo por seção da CNAE

## Conclusões

---

## Hipótese de pesquisa I: É possível ajustar modelos para reconhecer cenários de lojas/não lojas

Com base nos resultados obtidos, provamos que é possível ajustar modelos de redes convolucionais para reconhecer cenários de lojas e não lojas entre fornecedores do Governo Federal. A tarefa de classificação obteve um bom desempenho (AUC 0.97) - Wacker, Ferreira e Ladeira (2018).

## Hipótese de pesquisa II: As informações de lojas/não lojas extraídas do modelo são relevantes frente a outros atributos

A classificação de um cenário como loja está relacionada à ligeira diminuição de risco do fornecedor (-0.15) com significância estatística ( $p$ -valor  $< 0.05$ ). Entretanto, a relação possui pouco valor preditivo (não houve piora no desempenho ao excluir esta variável da regressão).

## Conclusão I - Wacker, Ferreira e Ladeira (2018)

O trabalho concluiu também que o treinamento da rede convolucional pode ser feito independente dos ângulos de orientação das imagens baixadas. Os rótulos nas imagens do Google Street View com a logo do Google tiveram pouca influência na classificação dos cenários.

## Conclusão II - Modelo de Risco de Fornecedores da CGU (Sales, 2016)

Nosso modelo de regressão logística utilizando variáveis quantitativas apresenta desempenho (F-Measure de 0,76) inferior ao Modelo de Risco proposto por Sales para a CGU (F-Measure de 0,86). Entretanto, é importante observar que foram utilizadas apenas 12 variáveis preditoras contra 29 do modelo de Sales.

## Limitações

Dentre as limitações existentes neste trabalho estão: a falta de disponibilidade de imagens para todos os endereços de fornecedores, a desatualização de conjuntos de imagens baixadas e a imprecisão presente ao buscarmos localizações através de mera descrição textual dos endereços através da API.

## Contribuição

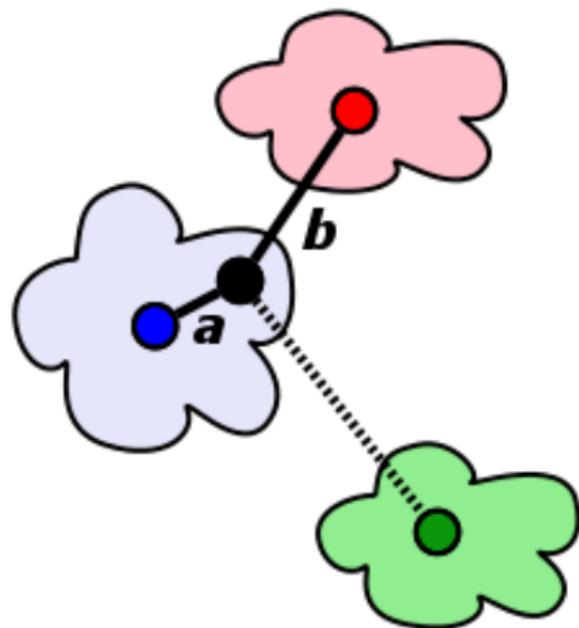
A pesquisa foi responsável por iniciar outras no âmbito da CGU envolvendo imagens como fontes de dados (ex. acompanhamento de obras de creches, detecção de rachaduras em estradas)

# Trabalhos Futuros

---

# Trabalhos Futuros

Buscar novos tipos de cenários (Clusterização) - em andamento



$$SSI_i = \frac{b_i - a_i}{\max(a_i, b_i)}$$

Buscar novos tipos de cenários (Clusterização) - em andamento

Silhueta: 0,43 - Max(a): 0,26



Silhueta: 0,40 - **Max(a): 0,51**



# Trabalhos Futuros

Acompanhamento de obras de creches do programa ProInfância (em andamento)



## Utilização de redes convolucionais para detecção de rachaduras em rodovias (2019)

### ROAD CRACK DETECTION USING DEEP CONVOLUTIONAL NEURAL NETWORK

*Lei Zhang, Fan Yang, Yimin Daniel Zhang, and Ying Julie Zhu*

Department of Electrical and Computer Engineering, Temple University, Philadelphia, PA 19122, USA

