

DIÁLOGO

**RESULTADOS
DA 3ª EDIÇÃO
DO PROGRAMA
DE PESQUISA**

Classificação automatizada de produtos da Nota Fiscal Eletrônica de Compras Públicas

Augusto Fonseca (CEFET/RJ)

Bruno Melo (TCE-RJ)

Eduardo Bezerra (CEFET/RJ)

Leonardo Lima (UFPR)

Wellington Amaral (TCE-RJ)




Sumário

- Introdução
- Fundamentos
- Metodologia
- Conclusões



Introdução



Nota Fiscal Eletrônica (NFE)

- NFE
 - Implantada em 2006
 - Desde 2010 seu tornou obrigatória nas transações comerciais destinadas a órgãos públicos.
- Tal volume de dados gerado diariamente pode ser alvo para análises ou até mesmo servir de base para geração de modelos preditivos.
 - Exemplo: obter o preço médio de venda de um determinado produto (ou serviço), informação esta que pode ser utilizada para identificar discrepâncias nas aquisições.



EAN

- O identificador EAN (atualmente conhecido como GTIN) é um padrão criado e administrado pela GS1 Brasil.
- Em sua forma mais comum, possui 13 dígitos.
- Esse identificador estabelece a singularidade de um produto contido em algum item de uma NFE.



<https://blog.bling.com.br/gtin-tres-etapas/>



Problema

- Obstáculos
 - Não é raro encontrar descrições distintas em NFEs distintas que referenciam um mesmo produto comercial.
 - Posto que cada descrição é registrada como **texto livre**.
 - Também não é raro encontrar itens de NFEs em que não foi informado o EAN!
- Associar tais descrições ao produto (ou serviço) ao qual se referem não é uma tarefa trivial.



Problema

- Como determinar que os três itens abaixo fazem menção ao mesmo produto?

	unidade	quantidade	valor_unitario	descricao	ean
328519	UN	1.0	4.69	PARACETAMOL 750 TE.20C	7896112149705
330149	CX	6.0	2.33	PARACETAMOL TEUTO GEN 750MG C/20 CPR	7896112149705
331799	Cx	7.0	21.25	Tylenol 750mg - Cx c/ 20 comprimidos	N/I



Problema

- Como determinar que os três itens abaixo fazem menção ao mesmo produto?

	unidade	quantidade	valor_unitario		descricao	ean
328519	UN	1.0	4.69	PARACETAMOL	750 TE.20C	7896112149705
330149	CX	6.0	2.33	PARACETAMOL	TEUTO GEN 750MG C/20 CPR	7896112149705
331799	Cx	7.0	21.25	Tylenol	750mg - Cx c/ 20 comprimidos	N/I



Problema

- Como determinar que os três itens abaixo fazem menção ao mesmo produto?

	unidade	quantidade	valor_unitario	descricao	ean
328519	UN	1.0	4.69	PARACETAMOL 750 TE.20C	7896112149705
330149	CX	6.0	2.33	PARACETAMOL TEUTO GEN 750MG C/20 CPR	7896112149705
331799	Cx	7.0	21.25	Tylenol 750mg - Cx c/ 20 comprimidos	N/I



Problema

- Como determinar que os três itens abaixo fazem menção ao mesmo produto?

	unidade	quantidade	valor_unitario	descricao	ean
328519	UN	1.0	4.69	PARACETAMOL 750 TE 20C	7896112149705
330149	CX	6.0	2.33	PARACETAMOL TEUTO GEN 750MG C/20 CPR	7896112149705
331799	Cx	7.0	21.25	Tylenol 750mg - Cx c/ 20 comprimidos	N/I



Objetivo

- Este projeto de pesquisa buscou investigar a aplicação de métodos computacionais para associar, de forma automática, uma descrição de item de NFE ao produto comercial a qual se refere.



Fundamentos



Expressões Regulares

- A busca e manipulação em texto com ERs ocorre por meio de **padrões**.
- Quando um padrão é encontrado no texto, diz-se que ocorreu o *match*.
- Procedimento geral:
 - Entrada: um texto e um padrão
 - Saída: trechos que casam com o padrão e/ou as posições no texto de entrada em que o padrão foi encontrado.

```
VALID_EMAIL_REGEX = /\A[\w+\-\.]+\@[a-z\d\-\.\.][a-z]+\z/i
validates_email presence: true, length: { maximum: 255 },
                REGEX },
```

RegExp: `\A[\w+\-\.]+\@[a-z\d\-\.\.][a-z]+\z`

Sample: `example@jetbrains.com|`

Matches!

<https://www.jetbrains.com/help/ruby/regular-expressions.html>



Expressões Regulares

```
^[a-z0-9.]+@[a-z0-9]+\.[a-z]+\.[a-z]+)?$
```

augusto.jose@gmail.com	true
augusto.jose@gmail.com.br	true
augusto.jose@gmail.com.br.br	false
augusto.jose@gmail.	false
augusto.jose@gmailcom	false
augusto.josegmail.com	false
@gmail.com	false




Distância Levenshtein

- A Distância Levenshtein, também conhecida como distância de edição, é uma métrica de similaridade calculada sobre dois fragmentos de texto.
- O algoritmo utilizado para o cálculo desta distância foi desenvolvido pelo matemático Vladimir Levenshtein em 1965.
- Sua aplicação possibilita mensurar o quanto dois fragmentos de texto são **similares**.


A distância Levenshtein entre duas *strings* é o número mínimo de edições de um único caractere (inserções, exclusões ou substituições) necessárias para transformar uma string na outra.



Distância Levenshtein



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



■ Substitution ■ Insertion ■ Deletion

<https://devopedia.org/levenshtein-distance>



Metodologia

Bases de dados



- NFe_PUB
- ANV_MED



Recebemos de fração social do emissor os produtos e/ou serviços constantes da Nota Fiscal Eletrônica ao lado.		NFe-e											
DATA DE RECEBIMENTO	IDENTIFICAÇÃO E ASSINATURA DO RECEBEDOR		Nº 000.055.278 SERIE: 1										
Laboratórios Xavier S/A, Rua Pedro Castro, 777 Distrito Industrial JardSP 13.123-456 19-1234-1234		DANFE DOCUMENTO AUXILIAR DA NOTA FISCAL ELETRONICA 0 - ENTRADA 1 - SAIDA 1 Nº 000.055.278 SERIE 1 Página 1 de 1											
NATUREZA DA OPERAÇÃO Remessa de amostra grátis		CHAVE DE ACESSO XX PROTOKOLO DE AUTORIZAÇÃO DE USO XXXXXXXXXXXXXXXXXXXX - XXXXXXXX											
INSCRIÇÃO ESTADUAL 123.123.123.123	INSCR. ESTADUAL DO SUBST. TRIBUT.	CNPJ 12.123.123/0001-90											
DESTINATÁRIO / REMETENTE													
NOME / RAZÃO SOCIAL Clínica Sampaio Ltda.		CNPJ / CFF 12.123.123/0001-12	DATA DA EMISSÃO 15/06/20X1										
ENDEREÇO Avenida Pedro Albuquerque, n.º 500	BARRIO / DISTRITO Centro	CEP 11.111-111	DT SAÍDA/ENTRADA 15/06/20X1										
MUNICÍPIO Jau	FONE / FAX 19-3333-3333	UF SP	INSCRIÇÃO ESTADUAL 1.111.111.111.111										
FATURA / DUPLICADA													
OUTROS													
CALCULO DO IMPOSTO													
B. DE CÁLCULO DO ICMS	VALOR DO ICMS	BASE DE CÁLCULO ICMS ST	VALOR DO ICMS SUBSTITUIÇÃO										
			VALOR TOTAL DOS PRODUTOS 100,00										
VALOR DO FRETE	VALOR DO SEGURO	DESCONTO	OUTRAS DESPESAS ACESSÓRIAS										
			VALOR TOTAL DO IPI 100,00										
TRANSPORTADOR / VOLUMES TRANSPORTADOS													
NOME / RAZÃO SOCIAL		FRETE POR CONTA 3 - SEM FRETE	CÓDIGO										
ENDEREÇO		MUNICÍPIO	PLACA DO VEICULO										
		UF	CNPJ / CFF										
		UF	INSCRIÇÃO ESTADUAL										
QUANTIDADE	ESPÉCIE	MARCA	NÚMERO										
			PESO BRUTO										
			PESO LÍQUIDO										
DADOS DOS PRODUTOS / SERVIÇOS													
CÓD. PROD.	DESCRIÇÃO DOS PROD./SERVIÇOS	NCM/SH	CST	CFOP	UN	QUANT.	VL. UNITÁRIO	VALOR TOTAL	V. CÁLC. ICMS	VALOR ICMS	VALOR IPI	ALÍQUOTAS ICMS	ALÍQUOTAS IPI
	Amostra grátis de remédio para pressão alta		040	5311	UN	1	100,00	100,00	-	-	-	-	-
DADOS ADICIONAIS											RESERVADO AO FISCO		
INFORMAÇÕES COMPLEMENTARES													
Produtos que seguem para distribuição gratuita, a título de amostra grátis. Isento do ICMS, conf. art. 3º do Anexo I do RICMS/SP. Isento do IPI, conf. inciso II, alínea "c" do artigo 54 do RPI/2010.													

Base de dados NFe_PUB

- Uma base de dados utilizada, que batizamos de NFe_PUB, é oriunda de registros de aquisições por órgãos públicos brasileiros por meio de notas fiscais eletrônicas.
- Como restrição de escopo e para simplificar o problema, consideramos apenas entradas no conjunto de dados associadas a aquisições de medicamentos.





Base de dados NFe_PUB

	unidade	quantidade	valor_unitario		descricao	ean
328519	UN	1.0	4.69		PARACETAMOL 750 TE.20C	7896112149705
330149	CX	6.0	2.33	PARACETAMOL TEUTO GEN 750MG C/20 CPR		7896112149705
331799	Cx	7.0	21.25	Tylenol 750mg - Cx c/ 20 comprimidos		N/I


Total de 4.861.392 registros, apenas 24% com EAN registrado.



Conjunto de dados ANV_MED

- O outro conjunto de dados usado, batizado de ANV_MED, é fornecido pela ANVISA (24.816 registros, um para cada EAN).
- Possui informação do EAN!

produto	principio_ativo	apresentacao	ean
28412	PARACETAMOL	paracetamol 750 MG COM CT BL AL PLAS LAR X 20	7896112149705



Conjunto de dados ANV_MED

- O outro conjunto de dados usado, batizado de ANV_MED, é fornecido pela ANVISA (24.816 registros, um para cada EAN).
- Possui informação do EAN!


produto	principio_ativo	apresentacao	ean
28412	PARACETAMOL	750 MG COM CT BL AL PLAS LAR X 20	7896112149705

concentração ("750 MG"),
forma farmacêutica ("COM CT BL AL PLAS LAR"),
separador ("X")
quantidade ("20").



Conjunto de dados ANV_MED

produto	principio_ativo	apresentacao	ean
23858	TILENATI	PARACETAMOL 200 MG/ML SOL OR CT FR GOT PLAS OPC X 10 ML	7897848500341



	descricao	ean
0	TILENATI 200 MG/ML SOL OR CT FR GOT PLAS OPC X 10 ML	7897848500341
1	PARACETAMOL 200 MG/ML SOL OR CT FR GOT PLAS OPC X 10 ML	7897848500341




Abordagens

- Abordagem por similaridade
 - Emprego de expressões regulares e o algoritmo de Levenshtein para inferir o produto comercial baseado em um **valor de similaridade** entre a descrição deste na base NFe_PUB com a dos itens na base ANV_MED.
- Abordagem por Aprendizado de Máquina
 - Emprego de métodos de **aprendizado de máquina** para treinar um modelo de classificação capaz de inferir o produto comercial a qual determinada descrição de item de NFe pertence.



Abordagem por similaridade

- Dado um item de NFe sem EAN na base NFe_PUB, calcular a similaridade entre sua descrição e cada descrição contida na base ANV_MED.
 - Intuição: um valor de similaridade alto entre essas descrições seria um indicativo de que correspondem ao mesmo produto.



`distância_levenshtein(`  `,`  `)`

NFE ESTRUTURADO ANVISA



Abordagem por similaridade - passos

1. Pré-processamento do conjunto de dados NFe_PUB
 - transformação dos caracteres para maiúsculas, remoção de duplicatas, remoção de itens sem EAN registrado, etc.
2. Extração dos **termos principais** das descrições de itens das NFES
 - princípio ativo ou nome comercial do medicamento, concentração, forma farmacêutica e quantidade.
3. Normatização de nova descrição
4. Cálculo da similaridade (distância de Levestein)



Abordagem por similaridade - passos

1. Pré-processamento do conjunto de dados NFe_PUB
 - transformação dos caracteres para maiúsculas, remoção de duplicatas, remoção de itens sem EAN registrado, etc.
2. Extração dos **termos principais** das descrições de itens das NFes
 - princípio ativo ou nome comercial do medicamento, concentração, forma farmacêutica e quantidade.
3. Normatização de nova descrição Expressões regulares
4. Cálculo da similaridade (distância de Levestein)




Abordagem por similaridade – passo 3

DESCRIÇÃO	PRINCÍPIO ATV	CONC	FORMA	QTD
CIPROFLOXACINO 200MG CLORI- DRATO S.FECHA	CIPROFLOXACINO	200MG	None	None
CARBOLITIUM CR 450MG C/30 CPR	CARBOLITIUM CR	450MG	COM	30
MUPIROCINA 20MG/G 15G GENERICO PRATI,DONADUZZI	MUPIROCINA	20MG/G	None	15G





Abordagem por similaridade – passo 4

- Esse passo envolveu calcular o valor de similaridade entre descrições normatizadas e cada uma das descrições na base da ANV_MED.
- O produto associado à descrição ANVISA com maior valor de similaridade foi então considerado como o produto correspondente.
- Para avaliar a taxa de acerto desta abordagem, comparamos os EANs e calculamos o percentual de acerto.





Abordagem por Aprendizado de Máquina






Abordagem por Aprendizado de Máquina







Abordagem por Aprendizado de Máquina






Abordagem por Aprendizado de Máquina



Desbalanceamento da base NFe_PUB



Técnicas para aumento de dados



- Web scrapping (coleta de descrições na Web).
 - Um algoritmo de coleta foi implementado para obter descrições adicionais de um dado medicamento.
 - Foi usado o mecanismo de busca do Google.

Google

Paracetamol 750mg 20 Comprimidos

All Images Shopping News Videos More Tools

About 93,200 results (0.49 seconds)

Ad · <https://www.drogaraia.com.br/> (11) 3003-7242

Paracetamol 750mg com 20 Comprimidos EMS | Droga Raia
Esquenta Black Friday. Descontos de Até 70% + Cupons. Confira! A Droga Raia tem os Melhores Preços em Produtos de Bem-Estar, Beleza e Saúde. Em até 3x c/ Frete Grátis.
Black Friday: Até 40% de desconto em Gama Italy - Validade 8 de nov. - 14 de nov.

Ad · <https://www.drogariaspacheco.com.br/> 4003-3393

Paracetamol 750mg Genérico EMS 20 Comprimidos
Mais Saúde e Proteção para sua família. Continue se Cuidando sem Sair de Casa!
Black Friday 2021 · Esquenta Black Friday · Preparação Black Friday · Antecipa Black Friday
Oferta: R\$ 15 de desconto em Em Todo Site · Código farma15

<https://www.drogaraia.com.br> para... · Translate this page

Paracetamol 750mg União Química com 20 comprimidos
Para que serve: Este medicamento é indicado em adultos para a redução da febre e para o alívio temporário de dores leves a moderadas, tais como: dores ...
Peso: 0.0350



Técnicas para aumento de dados

- Derivamos novas descrições por meio de transformações.
 - regras de expressão regular foram empregadas para substituição de termos, inclusão ou remoção de espaços, permutação de palavras, dentre outros.

ORIGINAL	DERIVADO
SELOKEN 1 MG/ML SOL INJ X 5 ML	SELOKEN 1 MG ML SOL INJ X 5ML
SELOKEN 1 MG/ML SOL INJ X 5 ML	SELOKEN 1MG ML SOL INJ X 5 ML
SELOKEN 1 MG/ML SOL INJ X 5 ML	SELOKEN 1G/1000ML SOL INJ X 5 ML



Técnicas para aumento de dados

- Após os procedimentos de Web scraping e de transformações, ainda aplicamos um procedimento de *oversampling*.
- Com isso, conseguimos aumentar em 1000X a quantidade de registros para treinamento do modelo!



Conclusões




Conclusões

- Classificação por similaridade
 - Apesar de parecer promissora a princípio, essa abordagem resultou em uma acurácia muito baixa.
 - Apenas 16% de acerto.
 - Baixa acurácia tem causa provável na ausência de informações mais detalhadas nas descrições de itens de NFE.
 - Nível de detalhamento das apresentações dos produtos ANV impactam a classificação por similaridade.



Conclusões

- Classificação por AM
 - Alcançou o objetivo do trabalho: resultados obtidos mostraram que o método é eficaz, gerando um modelo de classificação com 0,936 pela métrica F1 Score.
 - Com as devidas adequações, a classificação por AM pode ser aplicável em outros domínios.



DIÁLOGO

**RESULTADOS
DA 3ª EDIÇÃO
DO PROGRAMA
DE PESQUISA**

Classificação automatizada de produtos da Nota Fiscal Eletrônica de Compras Públicas

Augusto Fonseca (CEFET/RJ)

Bruno Melo (TCE/RJ)

Eduardo Bezerra (CEFET/RJ)

Leonardo Lima (UFPR)

Wellington Amaral (TCE/RJ)



Ferramentas utilizadas

- Linguagem de programação Python
- Bibliotecas:
 - python-Levenshtein
 - Imbalanced-learn
 - fastText



Estatísticas dos conjuntos de dados

- SEFAZ_ORIGINAL: 390.341 registros (somente produtos farmacêuticos)
- SEFAZ_PREPROCESSADO: 46.028 descrições distintas com EAN
- ANVISA: 24.816 registros (um para cada EAN)
- SEFAZ_JOIN_ANVISA: 52.226