



MINERAÇÃO DE TEXTO USANDO ARQUITETURA DA INFORMAÇÃO E ONTOLOGIA COMO MÉTODO PARA AUXÍLIO DE AUDITORIA EM NOTA FISCAL DE CONSUMIDOR ELETRÔNICA DO ESTADO DO AMAZONAS

Área de concentração: Gestão da Informação.

Linha de pesquisa: Arquitetura da Informação, Tecnologias e Organização da Informação e
do Conhecimento.

Discente: Diana Maria da Camara Gorayeb
Orientador: Prof. Dr. Claudio Gottschalg Duque



UnB

INTRODUÇÃO

- A **Era da Informação** traz impactos para a sociedade e altera os mecanismos e estruturas da aquisição e comunicação da informação e incorpora a capacidade de codificação, decodificação, armazenamento e recuperação das unidades de informacionais (dados) que geram conhecimento;
- O **desafio** é reconhecer os contornos de um contexto específico, entender seus processos informacionais e torná-los acessíveis e produtivos para atingir objetivos de usuários fazendo uso da revolução tecnológica.



INTRODUÇÃO

UnB

- A **Ciência da Informação (CI)**, contribui para alcançar soluções de problemas considerando **unidade informacional e conhecimento** no contexto social, institutional e individual. “Esta contribuição é proveniente de um ramo da pesquisa que, pode-se dizer, é parte do núcleo duro da Ciência da Informação: **os vocabulários controlados**” (ALMEIDA, 2020).
- A **CI** estuda a construção de instrumentos informacionais que hoje estão associados às **ciências técnicas computacionais** utilizando propriedades automáticas que incorporam o tratamento de grandes volumes de dados.



INTRODUÇÃO

UnB

- O papel da **Arquitetura da Informação** é afirmar a capacidade do “design” a ser desenvolvido para criar entendimento nas diversas formas de apresentação da informação: verbalmente, visualmente e numericamente, baseado na habilidade de organizar e habilidade de achar algo (WURMAN, 1997).



INTRODUÇÃO

UnB

- **Ontologia é um artefato tecnológico** acompanhada de abordagens conceitual, lógica, terminológica e filosófica que elimina as contradições na especificação do domínio, promove vocabulário de consenso, com mecanismo de inferência e que geram **conhecimento**.
- O modelo de **Ontologia** na **CI** colabora:
 - Representação do domínio;
 - Permite a compreensão da realidade e organização dos fatos;
 - Permite a descoberta, recuperação, análise e filtragem de informações como ferramenta de pesquisa ao usuário final visando o aprimoramento do trabalho especializado.



INTRODUÇÃO

- Esta pesquisa tem como **objeto de estudo** os **dados** de produtos descritos em campo livre nos documentos eletrônicos, **Notas Fiscais de Consumidor Eletrônicas (NFC-e)**, e armazenados em banco de dados da Secretaria da Fazenda do Estado do Amazonas;
- Está direcionada à construção de um modelo de **Ontologia** para reconhecer “[...] padrões de intercâmbio, controle de linguagem e modelos de representação do objeto por meio de metadados” (CAMPOS et al., 2006).



INTRODUÇÃO

UnB

- Na **Ciência da Informação** abrange os contextos de:
 - Organização e Representação da Informação;
 - Ontologia; e
 - Arquitetura da Informação.
- Utiliza técnicas aplicadas da **Ciência da Computação**:
 - Processamento da Linguagem Natural;
 - Aprendizado de Máquina;
 - Mineração de textos; e
 - Metadados.



PROBLEMA DE PESQUISA

UnB

- **Nota Fiscal de Consumidor Eletrônica (NFC-e)**, documento emitido e armazenado eletronicamente que registra:
 - Operações relativas aos produtos industrializados;
 - Circulação de mercadorias;
 - Transporte interestadual, intermunicipal e de comunicação.



PROBLEMA DE PESQUISA

UnB

- Arquivos digitais no padrão *Extended Markup Language (XML)*;
- **Chave de acesso** com 44 dígitos para identificação (metadados lógicos computacionais);
- Campos de informação:
 - Denominação;
 - Número de ordem, série, subsérie e número da via;
 - Data de emissão;
 - Hora de emissão;
 - Nome, endereço, número de inscrição estadual e do CNPJ do emitente;
 - CPF ou CNPJ do consumidor (quando identificado);
 - Destaque dos tributos;
 - **Discriminação das mercadorias.**



PROBLEMA DE PESQUISA

UnB

- Metadados da identificação da mercadoria :
 - Nomenclatura Comum do Mercosul (NCM);
- Metadados da identificação da venda:
 - Número do item;
 - Código do item;
 - **Descrição do item;**
 - Quantidade do item;
 - Unidade;
 - Valor unitário do item;
 - Valor total da operação.



UnB

PROBLEMA DE PESQUISA

DANFE NFC-e Documento Auxiliar de
Nota Fiscal de Consumidor Eletronico

04/06/2024 10:56:25 Lj:2 Cx:003 Seq:095860
Oper.: Vend.:

Item Código Descrição Qtde Unid. Vl.unit (Vl.Tr) Valor total
001 7897395001001 CERVEJA ITA 100 MALT 1 un X 4,39 (1,60) 4,39
002 7897395040246 LONGNECK ITAIPAVA 25 1 un X 3,49 3,49

VALOR TOTAL: 7,88
Cartão de Crédito 7,88
Valor aprox. dos trib. (Lei Federal 12.741/2012) R\$ 1,60
Trib. aprox.: Federal R\$ 0,81 Estadual R\$ 0,79 Fonte: IBPT

OBRIGADO VOLTE SEMPRE !!!

CHAVE DE ACESSO

1324 0642 8056 3100 0128 6505 3000 0860 8010 3095 8603
CONSUMIDOR NÃO IDENTIFICADO
NFC-e 000086080 Serie 053 Emissao 04/06/2024 10:56:25
Protocolo: 113242815172208 Autorizacao 04/06/2024 10:57:19



Consulte Chave de Acesso www.sefaz.am.gov.br/nfce/consulta



UnB

PROBLEMA DE PESQUISA

DOCUMENTO AUXILIAR DA NOTA FISCAL DE CONSUMIDOR ELETRONICA					
ITEM	COD	DESC	QTDE	UN	VL. UNIT VL. TOTAL R\$
001	7891149010509	CERV BRAHMA 350ML	1,000	La x	2,69 2,69
002	78936683	CERV HEINEKEN 330ML	1,000	Un x	5,99 5,99
003	7896045506590	CERVEJ HEINEKEN 269M	1,000	Un x	3,29 3,29
QTD. TOTAL DE ITENS					3
VALOR TOTAL R\$					11,97
VALOR A PAGAR R\$					11,97
FORMA DE PAGAMENTO					VALOR PAGO
Cart Credito					11,97
Consulte pela Chave de Acesso em: www.sefaz.an.gov.br/nfce/consulta					
1324 0606 0572 2304 3571 6502 2000 0778 4312 2112 3920					
			CONSUMIDOR NAO IDENTIFICADO NFC-e n. 77843 Serie 22 04/06/2024 10:30:35 Protocolo de Autorizacao:113242815135158 Data de Autorizacao:04/06/2024 10:30:35		



PROBLEMA DE PESQUISA

UnB

- **Divergências** apresentadas entre a descrição do produto e os controles da SEFAZ/AM para tributar:
 - Nomenclatura Comum do Mercosul (NCM);
 - cEAN (GTIN);
- **Dificuldades para** acompanhar o trânsito do produto com divergências na descrição no início e final da cadeia de venda;
- **Inconsistência** e ausência de metadados na descrição dos produtos;
- **Polissemia** e **falta de padrões** da terminologia para categorização dos produtos;
- **O grande volume** de documentos eletrônicos e **de dados armazenados**.



UnB

Novo Chrome disponível ::

buscapreco.sefaz.am.gov.br/item/grupo/page/1

Secretaria de Estado da Fazenda do Amazonas

GOVERNO DO ESTADO DO AMAZONAS

Produto procurado: cerveja

Encontrados 675 itens nesta busca.

Consulta realizada em: 27/06/2024 16:49:33

BALAS (HORTELA/ MEL / MORANGO/CEREJA...) R\$ 0,25
Há 23 hora(s) 16 minuto(s) 48 segundo(s)
BRASIL.COM GRAFICA RAPIDA
NOEL NUTELS, NRO 1762, CIDADE NOVA, SALA 1002/1003, MANAUS-AM

FREEGELLS 27,9G CEREJA C CHOC R\$ 0,85
Há 1 dia(s) 4 hora(s) 43 minuto(s) 36 segundo(s)
SUPER NOVA DISTRIBUIDORA
NOSSA SENHORA DA CONCEICAO, NRO 1916, CIDADE DE DEUS, C. DE D...

PASTILHA MINTY DOCILE 17G CEREJA R\$ 0,89
Há 1 dia(s) 2 hora(s) 43 minuto(s) 39 segundo(s)
SUPERMERCADO BARATEIRO
OSCAR BOREL, NRO 30, COMPENSA, MANAUS-AM, CEP 69035-210

HALLS 28G CEREJA [S/M] R\$ 1,29
Há 6 hora(s) 10 minuto(s) 43 segundo(s)
S VIERA
RAYOL DOS SANTOS, NRO 47, CIDADE NOVA, ET 2 (NUCLEO 3), MANAU...

DROPS FREE PLAY CEREJA 27 9G R\$ 1,35
Há 7 hora(s) 19 minuto(s) 24 segundo(s)
HIPER DESCONTO
PE AGOSTINHO CABALLERO MARTIN, NRO 2462, SANTO ANTONIO, MA...

GELATINA SOL CEREJA R\$ 1,39
Há 4 hora(s) 58 minuto(s) 21 segundo(s)
ATACADAO S.A.
LEOPOLDO PERES, NRO 646, EDUCANDOS, MANAUS-AM, CEP 69070-250

PASTILHA MINTY CEREJA 17G - UN R\$ 1,40
Há 21 hora(s) 23 minuto(s) 17 segundo(s)
CN SUPERMERCADO
MARIA ANDRADE, NRO 739, SAO LAZARO, MANAUS-AM, CEP 69073-010

DROPS HALLS CEREJA 28G R\$ 1,49
Há 5 hora(s) 25 minuto(s) 46 segundo(s)
JORNALISTA HUMBERTO CALDERARO FILHO, NRO 1128, ADRIANOPOLI...

DROPS HALLS CEREJA 28GR - 1X28GR R\$ 1,49
Há 5 hora(s) 59 minuto(s) 5 segundo(s)
ATACK
MAX TEIXEIRA, NRO 1878, FLORES, MANAUS-AM, CEP 69058-415



OBJETIVOS

- Objetivo geral:
 - Auxiliar o processo de auditoria das Notas Fiscais da SEFAZ/AM, por meio da elaboração de um modelo de ontologia de descrição do produto.



OBJETIVOS

UnB

- **Objetivos Específicos (OE):**
 - **Descrever a relevância dos SOCs, especificamente, da Ontologia para os processos de organização e recuperação da informação (OE01);**
 - **Definir as principais informações extraídas quando aplicada a Mineração de Texto nas Notas Fiscais da SEFAZ/AM (OE02);**
 - **Identificar possíveis requisitos de uma Arquitetura da Informação em Notas Fiscais da SEFAZ/AM (OE03);**
 - **Apresentar um modelo de Ontologia para orientar um padrão de descrição do produto para a auditoria da Nota Fiscal da SEFAZ/AM (OE04).**



JUSTIFICATIVA

UnB

- Colaborar com **meios confiáveis de recuperação da informação** na SEFAZ/AM permitindo a percepção do produto e do seu significado em determinado contexto;
- Auxiliar o **processo de auditoria**:
 - Pesquisa de preço (PMPF) para substituição tributária;
 - Controle de Estoque (Fiscalização);
 - Tributação (MVA);
 - Desembaraço fiscal (Fiscalização);
 - Compras por licitação.
- Promover melhoria na **transparência da informação**.



METODOLOGIA

UnB

- MÉTODO DE PESQUISA:
 - **Estruturalismo**, (MARCONNI, LAKAKTOS, 2003), investiga um fenômeno concreto de “descrição do produto” e o transporta para o nível abstrato identificando termos e variáveis, estudando seus relacionamentos relevantes, compreendendo e indicando seu uso na construção de um modelo de ontologia que represente o objeto e dê significado, por fim a aplicação em uma realidade estruturada e considerando a experiência com o sujeito social.



METODOLOGIA

UnB

- TIPO DA PESQUISA (TRIPODI et al., 1975)
 - ABORDAGEM:
 - **Quantitativa** ao analisar os elementos de descrição dos produtos e propor uma classificação relevante e com significado ao que está escrito baseado em técnicas de Mineração de Texto orientadas pela Arquitetura da Informação;
 - FINS:
 - **Descritiva**, pois pretende construir um modelo de Ontologia voltado para a representação do produto da NFC-e;



METODOLOGIA

UnB

- NATUREZA (APPOLINARIO, 2006):
 - **Aplicada** objetiva resolver um problema concreto e imediato do usuário, nesta pesquisa propõe o aprimoramento do processo de auditoria das Notas Fiscais de Consumidor Eletrônicas (NFC-e);
- PROCEDIMENTOS TÉCNICOS (GIL, 2002):
 - **Bibliográfico e Documental** de arquivos .csv tipo texto, no período de **01/02/2023 e 31/05/2023** disponibilizados pela SEFAZ/AM.
- ANÁLISE DOS DADOS:
 - **Corpus** por meio da sistematização das informações fornecidas pela SEFAZ/AM propondo categorias para as transações da NFC-E.



UnB

PERCURSO METODOLÓGICO

Descoberta e apresentação do problema à luz dos conhecimentos.

Identificar o problema

Levantar hipótese

Propor solução (Objetivos)

Identificar necessidade de informação

Identificação dos dados, teorias, instrumentos, técnicas e medidas relevantes.

Receber dados da NFC-e da SEFAZ/AM

Revisar bibliografia nos temas de interesse

- Pré-análise
- Organização
- Classificação

Desenho e obtenção da solução.

Corpus NFC-e

Proposta de Metadados

Ontologia NFC-e

Requisitos da Arquitetura da Informação

Construir modelo preliminar para mineração de texto

Investigação dos resultados e comprovação da solução aplicada à realidade concreta.

Validar Ontologia NFC-e: QC01, QC02 ... QCn

Repositório da NFC-e para auditoria



REFERENCIAL TEÓRICO DA PESQUISA

UnB

- **CIÊNCIA DA INFORMAÇÃO**

- **Base conceitual da informação e do conhecimento:** Borko (1968); Buckland (1991); Saracevic (1996); Pinheiro (2003); Capurro; Hjorland (2007); Lima-Marques (2011);
- **Interdisciplinaridade da CI:** Araújo (2003); Zins (2007);
- **Processo de comunicação:** Shannon; Weaver (1949); Belkin (1978); Brookes (1980); Wersig (1993).



REFERENCIAL TEÓRICO DA PESQUISA

UnB

- **ORGANIZAÇÃO E REPRESENTAÇÃO DA INFORMAÇÃO E CONHECIMENTO**
 - Conceitos da Organização da Informação: Hjørland (2012); Woledge (1983);
 - Sistemas de Organização do Conhecimento (SOC): Bräscher e Café (2008); Hodge, (2000); Duque (2005); Carlan (2010); Gorayeb; Gottschalg-Duque (2022).



REFERENCIAL TEÓRICO DA PESQUISA

UnB

- **ARQUITETURA DA INFORMAÇÃO**

- **Conceito, elementos e objetivos da Arquitetura da Informação:** Wurman (1997); Zachman (1997); Bailey (2002); Hinton (2009); Toms (2002); Downey e Banerjee (2010); Ding e Lin (2010); Siqueira (2012); Rosenfeld; Morville e Arango (2015); Cartaxo e Duque (2016); Cartaxo; Basílio e Duque (2017); Luz (2020); Kuroki Junior e Duque (2023);
- **Propostas de desenvolvimento de Arquitetura da Informação:** Lima-Marques e Macedo (2006); Orlandi (2019); Costa (2009); Ding e Lin (2010); Downey e Banerjee (2010).



REFERENCIAL TEÓRICO DA PESQUISA

UnB

- **ONTOLOGIAS**

- **Conceito:** Gruber (1993); Choukri (2014); Hamouda; Chourabi e Boughzala (2016); Chang *et al.* (2020); Miranda; Marcelino; Silva (2023);
- **Ciclo de vida:** Fox et al. (1993); Grüninguer; Fox (1995); Quine (1961 apud Kors, 1997); Vizcaino et al. (2004); Haridy et al. (2023);
- **Metodologia de desenvolvimento:** Fernández; Gómez Pérez; Juristo (1997); Noy; McGuinness (2001); Sure; Studer (2003); Almeida (2020); Suárez-Figueroa; Gómez-Pérez; Fernández-López (2015); Haridy *et al.*, (2023); Ghozi *et al.*, (2023);
- **Aplicação:** Standaert; Yaroslaski; Castro (2021); Schulze, *et al.* (2021). Warren (2024);



REFERENCIAL TEÓRICO DA PESQUISA

UnB

- **LINGUÍSTICA - BASE PARA CIÊNCIA DA COMPUTAÇÃO (LINGUÍSTICA COMPUTACIONAL):**
 - **Linguagem:** Chomsky (1996); Coseriu (1996); Mendonça (2000); Maculan; Lima (2017);
 - **Termo, Conceito e Significado:** Wittgenstein (1958); Gonzalez; Lima (2003); Novaes (2011); Maimone; Silveira; Tálamo (2011); Maculan; Lima (2017);
 - **Linguística computacional:** Duque (2005); Farias (1998); Othero (2006). Baptista (2015); Oliveira (2020).



REFERENCIAL TEÓRICO DA PESQUISA

UnB

- **PROCESSAMENTO DA LINGUAGEM NATURAL (PLN) e APRENDIZADO DE MÁQUINA (AM):**
 - **Técnicas de PLN e Algoritmos de AM Não Supervisionado:** Schuneider (2002); Gonzalez; Lima (2003); Duque (2005); Nadeau; Satoshi (2007); Cambria; White (2014); Sorato, *et al.* (2016); Faceli, *et al.* (2021); Mboli, *et al.* (2021); Chandra, *et al.* (2022); Albuquerque, *et al.* (2023); Haralambous (2024);
- **MINERAÇÃO DE TEXTO:**
 - **Descoberta de conhecimento em texto:** Fayyad; Piatetsky-Shapiro; Smyth (1996); Morais; Ambrósio (2007);
- **METADADOS**
 - **Informação e Documentação:** ISO 23081.



PROCESSOS E RESULTADOS DO MODELO

UnB

Processos	Resultados
Levantamento e compreensão das normas e documentos da gestão do fisco (Resolução n.º 0028/2023 SEFAZ/AM);	Escopo do projeto para fiscalização: <ul style="list-style-type: none">• Filtros para segmentos mais importantes para arrecadação;• Lista de produtos de substituição tributária com Preço Médio Ponderado ao Consumidor Final (PMPF);• Nome dos produtos que poderão enriquecer a ontologia.
Entrada dos filtros que serão aplicados na base NF-e e NFC-e;	Corpus a partir de: <ul style="list-style-type: none">• Número Comum do Mercosul (NCM);• Indicação de termo principal;• Períodos pré-determinados de arrecadação etc.
Definição dos metadados descrição dos produtos;	Sentença completa útil à auditoria.
Levantamento e definição de características sintáticas e semânticas dos termos, atributos e associações por meio de algoritmos de IA;	Ontologia: lista de candidatos às classes, subclasses, qualificadores (atributos) e relações existentes.
Definição, validação e enriquecimento dos termos.	Reuso de ontologias referenciadas e utilização de termos adicionais que estão nas Resoluções da SEFAZ/AM.
Incorporar propriedades de dados	Colocar os dados das NFC-e - Data Property Assertions de instâncias das classes para validação dos dados.
Incorporar requisitos da Arquitetura da Informação	Modelo de repositório para auxiliar a auditoria.



ABORDAGEM E CLASSIFICAÇÃO DO MODELO





CRONOGRAMA

2024											
ATIVIDADES											
JAN	FEV	MAR	ABR	MAIO	JUN	JUL	AGO	SET	OUT	NOV	DEZ
Qualificação do Projeto de Tese									X		
Ajustes na redação da Tese									X	X	
Tabulação de dados e desenvolvimento da Ontologia									X	X	



CRONOGRAMA

UnB

ATIVIDADES	2025											
	JAN	FEV	MAR	ABR	MAIO	JUN	JUL	AGO	SET	OUT	NOV	DEZ
Redação da Tese	X	X										
Validação e verificação da ontologia	X	X	X									
Elaboração do modelo de repositório para auditoria				X	X							
Ajustes na redação da Tese						X						
Defesa da Tese							X					