

Recursos da Linguateca para humanidades digitais em contexto multicultural

Oficina de Verão, Universidade Politécnica de Macau

Diana Santos

d.s.m.santos@ilos.uio.no

1-2 de julho de 2025



Audiência e objetivo

- alunos de mestrado e doutoramento, bem como aos docentes da Faculdade de Línguas e Tradução
- temas de investigação dos doutorandos: literatura portuguesa, estudos interculturais, ensino de português como língua estrangeira e estudos de tradução e interpretação entre chinês e português, etc.
- Objetivo: dar a conhecer a Linguateca e como usar os seus recursos
- Especial interesse em sessões práticas

Recursos de disseminação já existentes

Ao longo dos anos, fui dando vários cursos para várias audiências diferentes, alguns deles até foram gravados e encontram-se disponíveis, ver a minha página de publicações,

<https://www.linguateca.pt/Diana/public.html>

Dez 2024 Usando o AC/DC com o corpo DisPR (grav.)

Abr 2021 Grandes quantidades de informação: um olhar crítico (grav.)

Dez 2021 Humanidades Digitais e História: algumas observações

Nov 2021 Explorando o CorTrad para pesquisa e(m) tradução (grav.)

Dez 2020 Processamento de corpos e literatura: formação no âmbito do BILLIG

Jun 2019 Apresentando os recursos da Linguateca

Set 2013 Para que serve um corpo: O que é, o que significa a sua anotação, exemplos de uso

Também houve duas Escolas de Verão de Linguateca, ambas no Porto, em 2006 e 2009

◀ ◻ ▶ ◀ ☰ ▶ ◀ ☰ ▶ ☰ 🔍 ↻

História da Linguateca

- Os primórdios remontam ao interesse de Mariano Gago na língua, e às discussões públicas em algumas áreas da Ciência no final dos anos 90
- O pequeno projeto “processamento computacional do português” (1998-2000) preparou as bases para a discussão sobre a área, e projetou a Linguateca (na altura chamada CdRLP)
- A Linguateca foi financiada pelas autoridades portuguesas até 2011, mas teve sempre como objetivo o português em todo o mundo
- Depois disso passou a ser um projeto sem financiamento, mas com apoio institucional da FCCN/FCT, que abrigam os servidores onde estão os recursos

◀ ◻ ▶ ◀ ☰ ▶ ◀ ☰ ▶ ☰ 🔍 ↻

Principais recursos

Durante a história da Linguateca muitos recursos foram criados, e a maioria estão disponíveis ainda na internet, sobretudo os que provêm das variadas atividade de avaliação conjunta que nós organizámos.

- Santos, Diana & Cláudia Freitas. "Avaliação conjunta em português". In Helena M. Caselli & Maria das Graças Volpe Nunes (eds.), *Processamento de Linguagem Natural: Conceitos, Técnicas e Aplicações em Português*, 3ed. BPLN, 2024. Disponível em <https://brasileiraspln.com/livro-pln/3a-edicao>. Capítulo 15

Mas eu diria que, agora, os corpos, incluindo os corpos paralelos, e a sua anotação e exploração são o mais importante que a Linguateca (ainda) oferece. Por isso vou apresentar o AC/DC e o CorTrad.

Atividades presentes

- Anotação do domínio da comida e bebida em textos literários, no âmbito da leitura distante
- Criação do CulBras (subcorpo do CorTrad para culinária brasileira)

“Só na má literatura é que as personagens não comem”, afirmou Alberto Manguel (n. 1948) em Dezembro do ano passado, numa entrevista ao Ípsilon (Público). <https://www.paginaum.pt/2022/04/11/um-divertimento-literario-cheio-de-fantasia-culinaria>

com exemplos de Macau, China e macaense.

[lema="Japão|China|Indonésia|Índia|Macau"]

E apontando para a referência de 2022: "A sintaxe do AC/DC: apresentação do CWB e das opções tomadas"

<https://www.linguateca.pt/Diana/download/instrACDC.pdf>

Melhorias: Mais campos semânticos, donde:

- a procura [sema="cor"] passa a [sema=".*(cor|cor:.*)"]
- a procura [sema="medo"] passa a [sema=".*emo:medo.*"]
- e [lema="vermelho" & sema!="cor"] passa a [lema="vermelho" & sema!=".*(cor|cor:.*)"]

Roberto Carneiro

- Procurar [lema="Roberto=Carneiro"]
- Roberto Carneiro como objeto (linguístico): [pos="V.*"] [pos!="V.*"]* [lema="Roberto=Carneiro" & func="<ACC"] within s
- Roberto Carneiro como sujeito (linguístico): [lema="Roberto=Carneiro" & func="SUBJ>"] [pos="VAUX.*"]* @[pos="V.*"] [: pos!="V.*" :] within s [pos="V.*"] [pos!="V.*"]* [lema="Roberto=Carneiro" & func="<SUBJ"] within s

<https://www.publico.pt/2014/11/23/portugal/noticia/retrato-de-uma-familia-feliz-1676884>

<https://arquivos.rtp.pt/conteudos/roberto-carneiro-2/>

- Qual a região/continente mais falada na literatura? Em que contextos?
- Quais as palavras modificadas pelos adjetivos *européu* e *asiático*?
- Quem fala mais da família no Museu da Pessoa, os homens ou as mulheres?
- Veja a distribuição de comer, beber e fumar no CONDIVport, por tema e por variante.

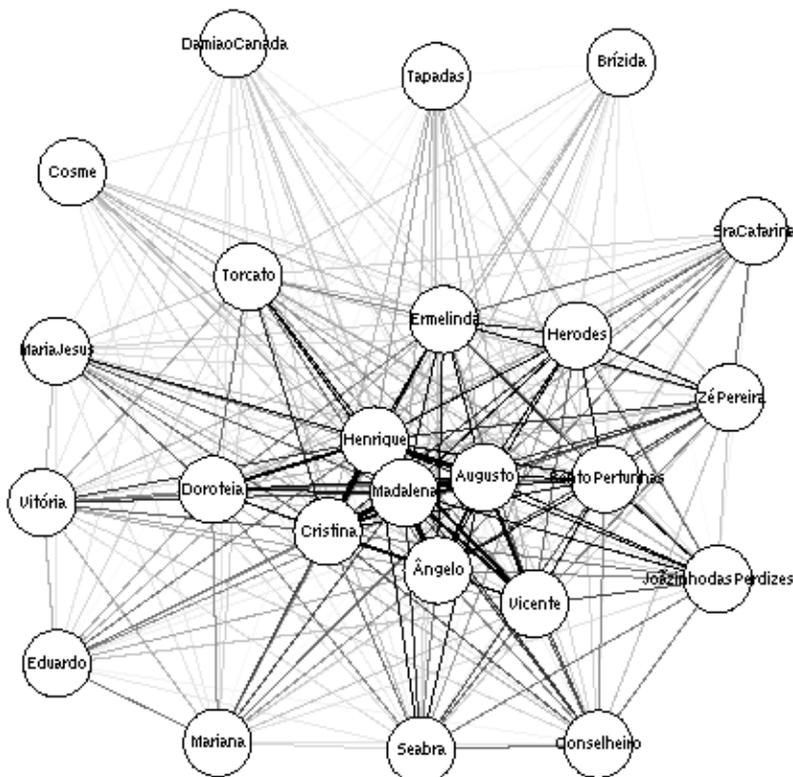
Apresentação da Literateca

- A ideia de leitura distante, de Moretti
- A ideia de humanidades digitais: usar métodos digitais para responder a perguntas de Letras
- A criação de corpos de obras literárias em português, para pesquisa na internet
- A necessidade de técnicas de visualização mais complexas, usando métodos estatísticos e R – ver as lições no *Programming Historian*

Embora exista grande conhecimento informático e matemático sobre grafos, as redes nas humanidades digitais são em geral usadas sobretudo para visualização

- Marcar nomes próprios como personagens no corpo
- Contar quantas vezes as personagens ocorrem, numa janela deslizante de 3000 unidades (com 500 de sobreposição)
- Contar quantas vezes co-ocorrem
- Usar R para desenhar a rede, usando o logaritmo do número de co-ocorrências para a grossura dos arcos

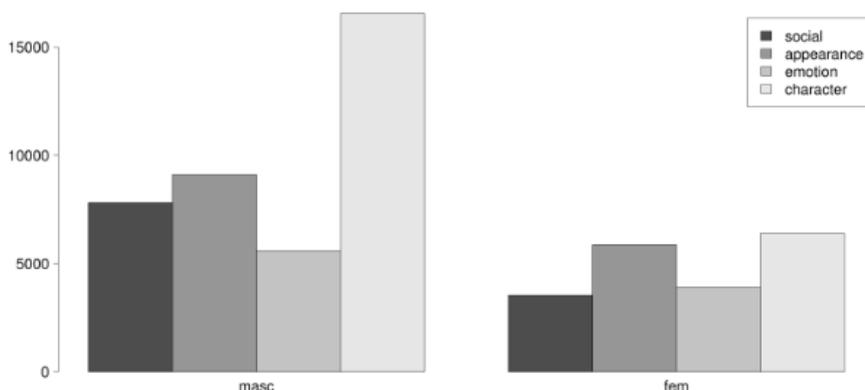
Redes de personagens: exemplo



- Com base na “redução” de centenas de obras a características linguísticas que se podem contar (estilo?), e depois reduzindo o número de dimensões a duas, visualizam-se regiões num espaço virtual. É possível identificar regiões correspondentes a escolas literárias?
- Com base na escolha das palavras (não gramaticais) mais frequentes num conjunto de obras românticas e realistas, é possível classificar novas obras automaticamente?

Caracterização de pessoas (na literatura)

- Com base na classificação dos adjetivos (e nomes) associados a palavras referentes a pessoas em quatro grandes áreas: social, aparência, emocional, carácter. Freitas & Santos (2023)

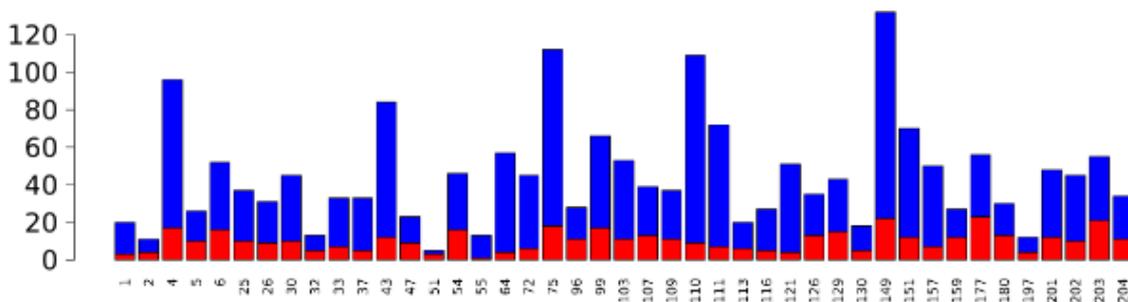


- E depois, o estudo das palavras preferidas por género...
 - *bonita, formosa, bela, linda, encantadora, feia...*
 - *velho, jovem, robusto, grande, baixo...*

Identificação de personagens, o DIP

Para um conjunto de obras literárias em português, identificar (Santos et al. 2023)

- as personagens (com os seus variados nomes)
- o seu género
- a sua profissão ou profissões
- as relações familiares com outras personagens



Navigation icons: back, forward, search, etc.

Comida e bebida na literatura (em apreciação)

Projeto contrastivo (literaturas portuguesa, brasileira, italiana e norueguesa) baseado em corpos

- léxico da comida e bebida nestas literaturas
- usos das expressões de comida
- questões pragmáticas associadas a comida e bebida
- descrição de atividades associadas a comida e bebida: refeições, preparações, etc.
- usos (literários) do emprego destas atividades nas obras literárias

Pressuposto/primeira fase: anotação e desambiguação de palavras de comida e bebida, e de (algumas) refeições.

Navigation icons: back, forward, search, etc.

Apresentação do CulBras

- Parte do CorTrad, um corpo paralelo português inglês criado em colaboração com Stella Tagnin e Elisa Teixeira, da USP. Ver Santos & Tagnin (2021)
- Culinária brasileira vs. culinária no Brasil: Este ano (2024-2025) aumentado com mais um subcorpo criado por Rozane Rebechi, sobre culinária brasileira traduzida para o inglês americano, a que chamamos CulBras.
- Corpo estruturado: título da receita, lista de ingredientes, modo de fazer, comentários, legendas de fotos
- Estudo da tradução: tradução cultural, e diferentes formas de resolver um “mesmo” desafio

<https://www.linguateca.pt/CorTrad/>

Apresentação do CulBras

Expressão de busca: <t> []* "arroz" %c []* </t>

Resultado escolhido: **concordância em contexto**

Corpus pesquisado: **originais** (versão 2.4)

30 ocorrências.



Voltar

Nova pesquisa

| Original | Tradução publicada |
|---------------------|---------------------|
| Arroz de cuxá | Cuxá rice |
| Arroz de hauçá | Hauçá rice |
| Arroz com guariroba | Rice with guariroba |
| Arroz com pequi | Rice with pequi |
| Arroz de carreteiro | Carreteiro rice |
| Bolinho de arroz | Rice cupcakes |
| Arroz de forno | Rice in the oven |