

ARTIGO

AS PALAVRAS E OS TOKENS  
*projeção vetorial aplicada ao estudo  
da semântica dos tempos históricos*

RODRIGO BRAGIO BONALDO  
Universidade Federal de Santa Catarina  
Florianópolis | Santa Catarina | Brasil  
rodrigobonaldo@yahoo.com.br  
orcid.org/0000-0002-3938-5169

Este artigo explora a semântica dos tempos históricos usando Processamento de Linguagem Natural (PLN). Desenvolvemos a família de modelos Woke (*Word Embedding and Knowledge Model*), utilizando algoritmos de vetorização de palavras como o Word2Vec, treinados em um corpus de teses e dissertações da Universidade Federal de Santa Catarina (2003-2024). Os modelos Woke-HST e Woke-CFH foram treinados especificamente em História e Ciências Humanas. Já os modelos Woke-UFSC foram expostos a 96,25% dos dados nativo digitais disponíveis no repositório de nossa universidade. O desenvolvimento envolveu coleta, pré-processamento, treinamento e validação dos dados, usando aprendizados micro-diacrônico, temporal e incremental para capturar variações semânticas ao longo do tempo. Os resultados preliminares mostram mudanças na estabilidade dos significados de conceitos como “raça”, “gênero” e “classe”. Apresentamos também SKINNER, um componente de IA explicável (XAI) que rastreia contextos linguísticos específicos, contribuindo para a transparência dos resultados. Concluimos que a captura completa de “espaços de experiência” requer modelos mais complexos e um corpus de dados mais amplo. O próximo passo do projeto é escalar os dados e usar modelos baseados na arquitetura *Transformer* para uma representação mais precisa dos conceitos históricos. Este trabalho é parte de um projeto interdisciplinar que busca contribuir para uma história digital teoricamente orientada que integre abordagens quantitativas e qualitativas, aliando erudição e análise de big data.

*História conceitual—aprendizado de máquina—semântica vetorial*

ARTICLE

WORDS AND TOKENS  
*vector projection for the  
 semantics of historical times*

RODRIGO BRAGIO BONALDO  
 Universidade Federal de Santa Catarina  
 Florianópolis | Santa Catarina | Brazil  
 rodrigobonaldo@yahoo.com.br  
 orcid.org/0000-0002-3938-5169

This article explores the semantics of historical times using Natural Language Processing (NLP). We developed the Woke family of models (*Word Embedding and Knowledge Model*), utilizing word vectorization algorithms such as Word2Vec, trained on a corpus of theses and dissertations from the University of Santa Catarina (2003-2024). The Woke-HST and Woke-CFH models were specifically trained in History and Humanities. The Woke-UFSC models, in turn, were exposed to 96.25% of the native digital data available in our university's repository. The development process involved data collection, preprocessing, training, and validation, using micro-diachronic, temporal and incremental learning methods to capture semantic variations over time. Preliminary results show variations in the stability of meanings for concepts such as “race,” “gender,” and “class.” We also present SKINNER, an explainable AI (XAI) component that tracks specific linguistic contexts, contributing to the transparency of the results. We conclude that fully capturing “spaces of experience” requires more complex models and a broader data corpus. The next step in the project is to scale the data and use Transformer-based models for a more precise representation of historical concepts. This work is part of an interdisciplinary project aimed at contributing to a theoretically oriented digital history that integrates quantitative and qualitative approaches, combining scholarship and big data analysis.

*Conceptual history—machine learning—vector semantics*

*Em vez de tentar produzir um programa para simular a mente de um adulto, por que não tentar produzir um que simule a de uma criança?* (Turing 1950, 18)

## O EFEITO IA NA HISTÓRIA DIGITAL<sup>1</sup>

É possível parametrizar uma duração? A questão talvez soasse monstruosa para um autor como Henri Bergson. Um prodígio da matemática que decidiu não ser um matemático, mas sim um filósofo, ao notar que o caráter discreto e descontínuo dos números não permitia a captura das *qualidades* múltiplas – e até um tanto “confusas” – da experiência ordinária e fluída do tempo (Bergson 1988; Ansell-Pearson 2018). Mas o tempo passou, e como tudo que é sólido, meio século depois a oposição entre matemática e qualidade começava, ao menos aparentemente, a se desmanchar no ar: “matemática qualitativa”, “métodos computacionais”, escrutínio do “inconsciente histórico”. Mas não só no estudo das estruturas quase imóveis, não só no estudo econométrico da longa duração, residia a aposta de Fernand Braudel para o futuro digital das humanidades: os métodos das “novas matemáticas”, passados por uma longa revisão, “devem reencontrar o jogo múltiplo da vida, todos os seus movimentos, todas as suas direções, todas as suas rupturas, todas as suas variações” (Braudel 1990, 33). Mas esse primeiro “verão da IA” ainda passa despercebido quando relemos os clássicos da teoria da história – como se computadores fossem curiosidades do passado! Como passa despercebida, ainda, a longa revisão que os avanços computacionais da última década proporcionaram a esses modelos matemáticos.

Hoje podemos fazer com palavras aquilo que na geração de Fernand Braudel só era possível com números. Hoje representamos palavras como direções ou vetores, extraíndo informações semânticas da sintaxe. Com algoritmos de redes neurais artificiais (RNAs), ousamos medir, manipular e simular qualidades fenomenológicas, como a linguagem. Afinal, há algum tempo percebemos que “computadores poderiam manipular não apenas números, mas também símbolos” (Minsky 1982, 3). Será que não podemos, quem sabe, assim minerar dados úteis para o estudo da semântica dos tempos históricos? Este artigo apresenta os modelos Woke (*Word Embedding and Knowledge Model*),

---

<sup>1</sup> As revistas acadêmicas de história não costumam permitir que graduandos e pós-graduandos assinem artigos científicos. Mas esse é um projeto coletivo e, por isso, deixo aqui os nomes de todas as pessoas que contribuíram para o desenvolvimento de nossos modelos de IA: Franciele Dias da Silva, Igor Caetano de Souza, Éric Kundlatsch, Marcel Silva, Mateus Freitas Borsatti, Matheus Heck Melz, Alysson Risso, Thamiis Fátima dos Santos, Sarah Olivares, Carlos Eduardo Candido Vilches de Souza, Vinicius Tobias, Gustavo Henrique Shigunov, Maikon James Scheres, Ana Cristina Peron, Ícaro Meira de Oliveira, Davi Alves de Azevedo, Sara Pereira Silva Vinter Schmitt e Almir de Souza. Um agradecimento especial vai para Jader Garcia da Silveira, engenheiro de automação, e Giuliano Boava, professor do departamento de matemática da UFSC, por suas orientações a respeito dos cálculos envolvendo a similaridade dos cossenos. Este artigo foi apresentado, de forma embrionária, em diversas ocasiões entre 2023 e 2024. Agradeço também as contribuições, críticas e comentários de Alesson Rota, Allan Megill, Ana Carolina Schweitzer, Caio de Souza Tedesco, Eduardo Ferraz Felipe, Ewa Domańska, Helge Jordheim, Helio Cardoso, Henrique Espada Lima, Hugo Merlo, João Júlio Gomes dos Santos Júnior, Lucas Vargas de Fraga, María Inés Mudrovic, Murilo Gonçalves, Nauber Gavski da Silva, Rame Ferreira, Robbert-Jan Adriaansen, Rommel Curaming, Sandra Holtgreve, Stefan Tanaka, Tayna Marino, Thiago Lima Nicodemo, Valdeí Araujo, Walderez Ramalho, Walter Lippold, Wiktor Werner e Zoltan B. Simon. O texto a seguir, assim como todos os erros nele cometidos, são de minha inteira responsabilidade. Isso também vale para as traduções de línguas estrangeiras.

desenvolvidos no âmbito do projeto IA e História da UFSC. Esses modelos valem pelo *componente fundacional* de uma família de ferramentas de Processamento de Linguagem Natural (PLN). Eles são baseados em algoritmos de “aprendizado de máquina” como o Word2Vec (Mikolov et al., 2013), uma expressão – talvez por demais antropomórfica – para processamento de informação por reconhecimento de padrões com RNAs. Essas redes neurais, que possuem uma camada oculta entre a entrada e a saída, são treinadas em um banco de dados escalável, cujo primeiro lote foi exposto a 411 trabalhos defendidos no PPG em História da UFSC entre 2010 e 2023. Para o treinamento do segundo lote, coletamos a integralidade dos textos de 30.643 trabalhos, somando 96,25% dos dados nativos digitais do repositório institucional da UFSC para o período 2003-2024 – e 69,32% de todas as teses e dissertações já defendidas em nossa instituição. Neste artigo, apresento três séries de modelos: Woke-HST, Woke-CFH e Woke-UFSC, treinados, respectivamente, em teses e dissertações defendidas no PPG em História, nos PPGs do nosso Centro de Filosofia e Ciências Humanas, e em todas as coleções de nossa universidade. O funcionamento dos modelos Woke pode ser descrito da seguinte forma: eles operam com uma volumosa quantidade de dados acadêmicos pré-processados, manipulam tokens por meio de processos de análise e, por fim, convertem essas informações em vetores estruturados. Esses vetores são extremamente úteis, pois podem ser empregados no treinamento de outras RNAs, potencializando o desenvolvimento de aplicações de PLN.

O Grupo de Estudos em IA e História da UFSC foi fundado em março de 2023 pelo professor Rodrigo Bonaldo. Inicialmente, o objetivo era discutir textos que versavam sobre a história e a crítica da técnica, a sociologia dos algoritmos, a ética informacional e a filosofia da mente. Mas logo o grupo atraiu a atenção de estudantes de ciências exatas – tornando-se também um grupo interdisciplinar de desenvolvimento de sistemas de IA. Contando com dois bolsistas de Iniciação Científica, Franciele Dias da Silva (História) e Igor Caetano de Souza (Engenharia de Automação), além de pouco mais de uma dezena de voluntários, sua missão é mitigar a dependência acadêmica nos dados de treinamento e nos parâmetros de análise elaborados pelas *big techs*<sup>2</sup>. Ao mesmo tempo, o projeto desloca o foco das humanidades digitais da coleção, estruturação e gestão de dados, em direção à fase interpretativa da operação historiográfica (Ricoeur 2000), buscando contribuir para o desenvolvimento de uma “hermenêutica digital” (Klüver; Klüver 2011; Brasil 2022, 189; Gonçalves 2022; Marjanen 2023, 49). Em outras palavras, buscamos engajar a Ciência de Dados em função da Inteligência Artificial. Com um propósito *open source*, as ferramentas e as aplicações de IA que estamos criando têm ainda como inspiração resistir à apropriação indevida que os GAFAMI (*Google, Apple, Facebook, Amazon, Microsoft, IBM*) fazem de nossos dados comportamentais, de nosso trabalho físico e intelectual, da ciência e da arte, da agressiva e profunda *privatização da criatividade* que a indústria da álgebra linear – em nome da classe que se apossou dos vetores da informação – promove (Wark 2022).

---

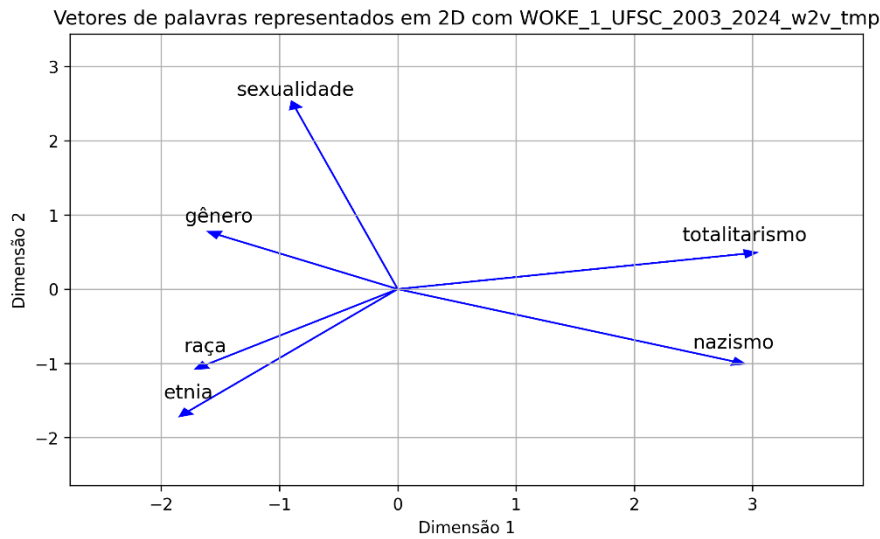
<sup>2</sup> Além disso, Éric Kundlatsch, bolsista de extensão (SeCArTE-UFSC), tem criado verbetes na Wikipédia para ajudar na compreensão do nosso trabalho. Para mais detalhes, veja: [https://pt.wikipedia.org/wiki/Word\\_embedding](https://pt.wikipedia.org/wiki/Word_embedding) Acesso em 10/05/2024. Nossa página no Instagram também é administrada pelo mesmo bolsista. Para acompanhar nossas atividades, visite: [https://www.instagram.com/iaehistoria\\_ufsc/](https://www.instagram.com/iaehistoria_ufsc/) Acesso em 19/07/2024.

Mas não devemos nos entusiasmar demais. A contribuição dos métodos que estamos desenvolvendo limita-se a traduzir princípios ético-epistemológicos da historiografia em linguagem de programação. Afinal, esse é o lugar de onde falo e a partir do qual acredito que possamos ser úteis como nunca (Lucchesi; Silveira; Nicodemo 2020). Mais particularmente, encontro na História dos Conceitos uma metodologia suficientemente clara e operacional para a captura da mudança conceitual em face da mudança social – princípio de uma teoria dos tempos históricos – e a ponho em diálogo com os recentes avanços no campo da semântica vetorial. Essa última abordagem parte da “hipótese distribucional”, segundo a qual o significado de uma palavra-alvo é determinado pela posição ocupada por classes e subclasses gramaticais que a cercam – e estatisticamente extrapolado com base em um grande volume de dados. *A estrutura distribucional* da linguagem, da qual a semântica é descrita como uma *função* da sintaxe, pode ser exemplificada por um dito popular. Diga-me com quem andas e te direi quem és: “palavras que têm um contexto linguístico semelhante tendem a ter significado similar ou aproximado” (Caseli; Nunes 2024, 190). É assim que funcionam tradutores *online* e *chatbots* avançados.

Por décadas, a linguística trabalhava com tabelas profundas em livros extensos, mapeando em matrizes a frequência e a correlação de palavras. Já faz algum tempo, é claro, que não é mais assim. Após a “revolução estatística” (Rocha 2016, 423) dos anos 90, a crescente capacidade de processamento gráfico (GPUs) demandada pela indústria dos jogos foi tornando o PLN mais viável em termos de recursos computacionais. A partir de 2010, essa viabilidade foi ainda mais fortalecida pela abundância de dados gerados na Internet e em redes sociais. Na última década também surgiram técnicas como *Skip-Gram Negative Sampling* (SGNS) e *Continuous Bag of Words* (CBOW), que nos permitem ir, respectivamente, das palavras ao contexto e do contexto às palavras. Os modelos Woke, por exemplo, fazem uso desses dois procedimentos para gerar vetores longos de alta-dimensionalidade. A seguir, calculamos os ângulos de cosseno entre os vetores, observamos a formação de *clusters* e, com técnicas como PCA, reduzimos os dados a espaços euclidianos de menor dimensão para facilitar a visualização (Mikolov *et al.* 2013). Para usar o vocabulário da História dos Conceitos, empregamos técnicas semasiológicas e onomasiológicas expondo os modelos a um grande conjunto de dados que permitem gerar campos semânticos vazados em gráficos. Trabalhando com modelos seriais, nosso objetivo passa a ser o de representar mudanças e permanências de significados diacronicamente, oferecendo visualizações que permitam não apenas testar hipóteses consagradas, como igualmente minerar “paisagens de dados disponíveis em busca de novas hipóteses” (Amaro 2022, 109).

Word Embedding Models (WEMs) representaram uma contribuição significativa em PLN (Le; Mikolov 2014). Esse tipo de modelo permite manipular os blocos fundamentais da linguagem e as unidades simbólicas da computação: as palavras e os tokens. Quando desenvolvemos um WEM, o primeiro passo consiste na tokenização do texto em palavras completas ou expressões/entidades nomeadas. No treinamento, cada token é então mapeado para um vetor numérico. Os tokens já foram as unidades *indivisíveis* de significado no processamento da linguagem natural (PLN), do mesmo modo que os átomos, na filosofia natural, foram um dia assim pensados. Mas não estamos mais diante de um modelo simbólico – um WEM não é programado com base em regras e na manipulação de símbolos. Trata-se de um modelo subsimbólico fundamentado em “representações distribuídas” (Kelleher 2019, 129), pois o significado de uma palavra não é por nós programado (*hardcoded*), mas

identificado pela ativação de redes neurais em uma camada mais baixa de processamento. Essa é a verdadeira revolução atômica da IA: a quebra dos átomos indivisíveis da computação.



Palavras vetorizadas em um espaço de embedding. O ângulo que se forma entre os vetores pode ser calculado para a identificação de relações semânticas. *Woke-UFSC: 30.643 teses e dissertações.*

Assim chegamos ao “*embedding*” de palavras. Nele, palavras com significados similares aparecem mais próximas umas das outras. Isso acontece porque modelos que aprendem a associar palavras a vetores tendem a codificar significados como direções dentro desses espaços vetoriais. Se pegarmos o *embedding* de “Biden” e o subtrairmos de um *embedding* de “Estados Unidos” para depois adicioná-lo a um *embedding* de “Brasil”, receberemos algo muito próximo de um *embedding* de “Lula”. É como se o modelo fosse capaz de aprender a vincular certas direções vetoriais com qualidades brasileiras e outras com líderes mundiais.

O desenvolvimento de WEMs diacrônicos oferece a oportunidade de medir taxas de variação semântica e, com treinamentos temporais e incrementais (Hamilton *et al.*, 2018), gerar visualizações de significados historicamente saturados, não linearmente dispostos, mas estratificados ao longo de durações – procedimento que busco aproximar dos “estratos do tempo” de Koselleck (2014). Mas essa nunca poderá ser uma representação genuinamente contínua (Silveira 2023). Afinal, palavras transformadas em vetores, “enquanto servirem para formar [um] número” provisório e indivisível, passarão de um ao outro “*sempre* por safanões, por saltos bruscos” (Bergson 1988, 62 grifos meus). Mas seria um andar gentil alguma espécie de impossibilidade metafísica para as máquinas? Ou o “*sempre*”, no contexto da história da tecnologia, representa tão somente um desafio de engenharia? Neste artigo, exploro o argumento de que – fundamentados em vetores mais profundos e densos – os “saltos bruscos” dos quais falava Bergson tornam-se não mais do que pequenas passadas<sup>3</sup>. Depois do

<sup>3</sup> O processamento de dados contínuos é hoje uma operação ordinária em ciência de dados. Um exemplo simples são sistemas de recomendação em plataformas de *streaming*. Eles renderizam a experiência dos usuários em pontos de dados, aplicam técnicas de clusterização e PLN, vetorizam interesses comuns e, com um pouco de álgebra linear, calculam a similaridade

“efeito de real” e dos “efeitos de presença”, chegamos ao “efeito IA” (McCorduck 2004, 204; Bonaldo; Pereira 2023, 12). Os pontos de dados tornam-se linhas, a transição entre um e outro (0.87100001, 0.87100002, 0.87100003, etc) é imperceptível na escala de raciocínio humano, e “o conjunto apresenta todas as características da continuidade” (Bergson 1988, 62).

```
# Vetores com transição suave: simulação da experiência fluida do tempo
vector_1 = np.array([0.87100001, 0.87100002, 0.87129292, 0.87129301, 0.87129450,
0.87129678, 0.87129862, 0.87130002, 0.87130282, 0.87130562,
0.87130842, 0.87131052, 0.87131262, 0.87131542, 0.87131782,
0.87131972, 0.87132202, 0.87132412, 0.87132622, 0.87132842,
0.10030307, 0.36408262, 0.16134866])

vector_2 = np.array([0.86667312, 0.87795905, 0.88931251, 0.89012568, 0.89054345,
0.89094413, 0.89158910, 0.89229122, 0.89278145, 0.89332185,
0.89378329, 0.89412514, 0.89458345, 0.89512122, 0.89578128,
0.89654215, 0.89723212, 0.89812512, 0.89898145, 0.89978521,
0.11291665, 0.11964856, 0.12955948])

vector_3 = np.array([0.42537262, 0.43625256, 0.42636370, 0.42637390, 0.42638280,
0.42639170, 0.42639980, 0.42640790, 0.42641600, 0.42642310,
0.42643020, 0.42643850, 0.42644780, 0.42645510, 0.42646340,
0.42647070, 0.42647900, 0.42648730, 0.42649660, 0.42650590,
0.42532363, 0.43628392, 0.44172728])

vector_4 = np.array([0.12003262, 0.11999992, 0.11000010, 0.10999990, 0.10999880,
0.10999770, 0.10999660, 0.10999550, 0.10999440, 0.10999330,
0.10999220, 0.10999110, 0.10999000, 0.10998890, 0.10998780,
0.10998670, 0.10998560, 0.10998450, 0.10998340, 0.10998230,
0.10999999, 0.11999992, 0.11000010])
```

*Embeddings de vetores como conjuntos matemáticos. Em PLN, esses vetores podem ser usados para representar a distribuição de palavras em diferentes contextos linguísticos. Dados fictícios.*

Adicionalmente, defendo a hipótese de que o caráter polissêmico, disputado, ambíguo e impreciso dos conceitos seja melhor detectável por representações distribuídas. Dito de outra forma, sustento que conceitos, por serem mais do que palavras, não possuem uma natureza simbólica, mas subsimbólica – e que suas qualidades iterativas podem ser quantificadas ao longo do tempo por taxas de variação semântica. Com isso, busco contribuir para a identificação e a análise dos conceitos “que cada vez mais passam a ocupar um papel fundamental nos debates políticos e nas formas de orientação histórica” (Turin 2023, 715).

---

dos cossenos entre os interesses, devolvendo, por regressão linear, recomendações de filmes ou músicas.

```

▶ modelos_treinados[-1][1].wv.most_similar('antropoceno', topn=20)
↳ [('neguentropia', 0.43538254499435425),
   ('antropocentrismo', 0.41574859619140625),
   ('ecodesenvolvimento', 0.4072546362876892),
   ('biosfera', 0.402713805437088),
   ('planetária', 0.39021751284599304),
   ('planeta_terra', 0.3883117437362671),
   ('sobreexploração', 0.3861791491508484),
   ('planeta', 0.38238346576690674),
   ('pleistoceno', 0.37847429513931274),
   ('climático', 0.37352174520492554),
   ('apocalipse', 0.36408817768096924),

```

*Representação distribuída de “antropoceno”. Valores que se aproximam de “1” indicam posições mais próximas da palavra-alvo no espaço vetorial. Woke-CFH (2003-2024).*

Por outro lado, e em oposição aos decretos neopositivistas pela obsolescência da teoria, assumo que “a abstração seja um modo fundamental da experiência”, constitutiva dos objetos, pressuposto do conhecimento e da vivência no mundo, o que nos permite explorar um eventual distanciamento teórico como “espaço necessário para a realidade” (Fazi 2020a, 316). A abstração é constitutiva da experiência pois, em um paradigma subsimbólico, as escolhas de modelagem da IA substituem “o estudo do fenômeno concreto pelo estudo de um objeto constituído por sua definição” (Régner *apud* Certeau 2002, 84). Modelos são dispositivos epistemológicos que se situam entre o documento e a explicação. A situação se agrava no caso de algoritmos de aprendizado, dotados de crescentes níveis de autonomia, que constituem um objeto privilegiado da ética informacional (Bonaldo 2023, 12-14). Do ponto de vista da heurística das fontes, torna-se então necessário moderar o “distanciamento entre historiadores/as e a elaboração das ferramentas de pesquisa e os conjuntos de dados disponibilizados atualmente” (Brasil 2022, 213). Por isso, ao invés de propor que a matematização da história implique na transformação de nossa disciplina em “ciência positiva”, ofereço dados que introduzem – sob o signo da caixa-preta e do caráter indefinido a respeito das possibilidades da computação – elementos de incerteza e indeterminação que precisam ser reconhecidos e problematizados. É, portanto, a partir de uma agenda teórica ligada às humanidades digitais que busco defender a legitimidade do objetivismo histórico – dependente não apenas da questão norteadora de uma pesquisa, mas igualmente dos problemas levantados em seu percurso (Gadamer 1999, 450). No que segue, não apresento resultados como descrições imparciais da realidade – como pode sugerir a expressão *mineração de dados* – mas como evidências *produzidas* com o mero objetivo de explorá-la.

Este artigo está dividido em três partes, contando a introdução e a conclusão. Na primeira, ofereci informações a respeito do contexto, função objetiva e escopo de aplicações dos experimentos aqui apresentados. Na segunda, comento as escolhas de modelagem e detalho as etapas de desenvolvimento dos modelos Woke, da raspagem de dados ao pré-processamento, do treinamento não supervisionado à validação e ao ajuste fino, acompanhadas por uma amostra de visualizações de dados. Também aproveito para discutir aplicações e desafios de WEMs em questões clássicas de história conceitual. Ainda assim, nutro a esperança de que nossos modelos sejam úteis a quaisquer colegas que, trabalhando com documentos escritos, não se interessem pela linguagem apenas como evidência – “fui ao arquivo e coletei as provas!” –,




mas igualmente como um problema histórico. É a essa modalidade de investigação, enquadrada no amplo espectro da história intelectual e da análise do discurso orientadas ao estudo da linguagem política e das políticas da linguagem, para quem neste artigo também me dirijo. Linguagem, experiência e tempo: essa mobilização acessa o potencial de WEMs na captura não só da polissemia de conceitos básicos, mas também de padrões na cacofonia dos vieses ou preconceitos que – para um banco de dados, ou, mais precisamente, para os indivíduos que tiveram nele depositadas suas palavras – formam a “realidade histórica de seu ser” (Gadamer 1999, 416). É com uma reflexão crítica a respeito das limitações de nosso trabalho que encerro o artigo, na expectativa de contribuir para uma história digital teoricamente orientada.

## DESENVOLVIMENTO DO MODELO

Trabalhos recentes vêm discutindo o uso de métodos digitais no estudo da semântica histórica. Melvin Wevers e Marijn Koolen (2020) apresentam WEMs treinados em fontes históricas que utilizam tanto SGNS e CBOW como base para introduzir uma “história conceitual digital” (*Digital Begriffsgeschichte*). Em texto mais recente, Jani Marjanen oferece um balanço do uso de métodos computacionais na história dos conceitos – e parece menos entusiasmado com a aplicação de modelos de aprendizado de máquina como o Word2Vec. Marjanen, na esteira do trabalho de Antti Kanner (2022, 7), lembra que modelos mais complexos tendem a oferecer saídas opacas, de difícil interpretação e rastreabilidade de resultados. Ele não sugere abandonar o aprendizado de máquina, uma vez que seus resultados podem identificar padrões que dificilmente seriam identificados na pesquisa qualitativa. Mas aconselha corroborá-los com técnicas mais simples e seguras de frequência de palavras. Por isso, Marjanen prefere falar não de uma “história conceitual digital”, mas de uma “história conceitual quantitativa”:

Portanto, os métodos de aprendizado de máquina são melhor acompanhados por análises mensuráveis e reprodutíveis. Neste modelo, o aprendizado de máquina representa a *exploração*, enquanto os métodos baseados em contagem são um espaço para *rigor e precisão*. Após isso, vem a *interpretação*, que é a esfera da liberdade. Ela inclui especular, reunir diferentes tipos de evidências e chegar a um argumento. Embora também haja desafios em ser transparente sobre o processo de interpretação, é na esfera da apresentação de provas, seja qualitativa ou quantitativa, que a transparência é fundamental (Marjanen 2023, 66 grifos meus).

Exploração, precisão, interpretação: o método acima desenhado caracteriza-se por entender as limitações do emprego de modelos de aprendizado de máquina dentro da 1) ordem da explicabilidade das decisões da IA; 2) ausência de informações extralinguísticas nas saídas dos modelos. O primeiro problema remete à noção de “caixa-preta”, a qual descreve sistemas nos quais apenas as entradas (input) e as saídas (output) são visíveis ou conhecidas (Fazi 2020b, 59). WEMs, sozinhos, também não são capazes de indicar quais conjuntos de dados de treinamento e enunciações específicas contribuíram para a formação de um vetor. Sendo assim, Marjanen argumenta que modelos vetoriais devem ser combinados com técnicas “mais transparentes que permitam fornecer prova quantitativa” (2023, 48).



Google Ngram Viewer: “Identity” 1500-2019

Uma forma de entender as preocupações do historiador conceitual frente à opacidade da IA é confrontar as limitações dos métodos digitais com aquilo que Ian Iversen (2011) chamou de os três aspectos do significado dos conceitos básicos: o representacional, o referencial e o contextual. WEMs são capazes de *representar* campos semânticos de palavras alvo, mas as dimensões *referenciais* e *contextuais* (sociais) são mais desafiadores de serem capturadas por eles. Por outro lado, a solução apresentada por Marjanen – conciliar a semântica vetorial com análises de frequência – parece insuficiente, senão mesmo arriscada. Esse é o caso do uso de N-Gramas, como o *Google Ngram Viewer*, em estudos de história conceitual: eles não representam conceitos, mas apenas palavras, o que potencializa o risco do essencialismo semântico. Por exemplo, uma busca por “identity” entre 1500 e 2019 vai medir a frequência de sua ocorrência no corpus em inglês do *Google Books*. Mas essa técnica não diz nada sobre a mudança semântica da identidade, não diz nada sobre seu pico nos séculos XVII e XVIII, sobre sua acepção escolástica e metafísica como “*continuum* da semelhança”, nem sobre o significado do seu retorno no pós-guerra como “a simples e pura emergência da *diferença*” (Monteiro 2024, 264). Por fim, caso associemos “identity” com “difference” ou “continuity”, vamos apenas executar a manobra que, ao optarmos por desenvolver nossos próprios modelos, buscamos evitar a todo custo: induzir a “descoberta” daquilo que já sabemos.

Isso não é para dizer que as considerações de Marjanen (2023, 54) sobre a funcionalidade de análises de frequência para a medição da atualidade, expansão, polissemia e idiomatização de palavras não sejam contribuições valiosas. De fato, técnicas simples e computacionalmente pouco intensivas como N-gramas ou índices TF-IDF possuem um bom potencial heurístico, sobretudo quando trabalhamos com um corpus limitado. Mas o projeto IA e História da UFSC tem se dedicado a desenvolver e integrar códigos de *referenciação* dentro de nossos sistemas de PLN, contribuindo para a transparência dos modelos de aprendizado, como vou comentar mais adiante. Em outras palavras, medir e rastrear as saídas da IA não representam uma impossibilidade tecnológica, como podem sugerir as palavras de Marjanen, mas um desafio de engenharia para o qual buscamos desenvolver soluções. Resta-nos, ainda, o aspecto *contextual* ligado ao diálogo da história dos conceitos com a história social, o qual está tradicionalmente amarrado à abordagem qualitativa. Por ora, limito-me a lembrar que a interpretação erudita também guarda sinais de uma “caixa-preta”, marcada pelo “*fundo opaco* do viver, do agir e do sofrer para ser

dada por um autor a um leitor que a recebe e assim muda seu agir” (Ricoeur *apud* Mendes 2013, 64 grifos meus). É nessa encruzilhada mais do que humana, entre a *intencionalidade* natural e a *funcionalidade* artificial, que localizo a tarefa motora de uma hermenêutica digital: ousar abrir simultaneamente duas caixas-pretas. Investigar a “relação entre o que é *próprio da história* e o que é *próprio da computação*” é outra forma de enunciar esse problema (Silveira 2022, 222). Questão trabalhosa, a qual o projeto buscará dar respostas concretas no futuro, retornarei a ela em alguns momentos do artigo. Se a partir de agora comparo a coleta e o pré-processamento, o aprendizado de máquina e a visualização de dados com as três fases da operação historiográfica segundo Paul Ricoeur, esse é apenas um provisório e incompleto experimento de pensamento.

## RASPAGEM E PRÉ-PROCESSAMENTO DE DADOS

Assim chegamos à fase documental de nossa operação historiográfica artificial. Ela começa com a escolha do dataset, com o arquivo digital que queremos visitar, também com o recorte que nele buscamos fazer. Um duplo gesto se instaura, heurístico e epistemológico (Brasil 2022, 190). Começa, em nosso caso, com procedimentos de “curadoria digital” (Dallas 2016) que atuam no âmbito da: 1) escolha do dataset, 2) raspagem de dados (*web scraping*) e 3) validação, limpeza e estruturação da coleta. A escolha do dataset pode parecer inusitada para um projeto que se propõe a adaptar métodos da história conceitual para ferramentas digitais. De fato, teses e dissertações acadêmicas não são as únicas fontes trabalhadas nesse campo. Mas penso que esses documentos representam um primeiro passo para a constituição de um arquivo próprio ao estudo de uma “história conceitual do presente” (Turin 2023, 75). Creio que um empreendimento desse porte ganhe ao renegociar a ordem das fontes acessadas, uma vez que as taxas de estabilidade semântica das fontes e conceitos contemporâneos muito provavelmente diferem daquelas expressas pelas tipologias mais tradicionalmente acessadas pela história conceitual.

Mesmo que o registro lexicográfico possa ainda ser entendido enquanto “ferramenta metalinguística privilegiada de controle da estabilidade semântica” (Monteiro 2024, 13), esse não parece ser o caso para enciclopédias digitais como a Wikipédia: “wiki significa, em idioma havaiano, rápido ou veloz” (Varella; Bonaldo 2020, 149), e essa característica sugere menção tanto à velocidade do consumo quanto da colaboração. No outro extremo da duração conceitual, temos a efemeridade dos registros, personagens e significados presentes em panfletos políticos, pasquins, papelinhos ou “folhas volantes” – documentos preciosos para o estudo da captura dos horizontes de expectativa de futuros passados, como, por exemplo, aqueles expressos por personagens esquecidos do processo de independência (Neves 2020). O caso é que a instabilidade e inovação semântica dessas fontes, não seria desbaratado supor, empalideceria frente ao ritmo frenético da inovação conceitual expressa por memes da Internet no século XXI. Assim como os jornais de ontem ruborizariam face às postagens no Twitter, hoje X (Rota; Nicodemo 2023).

A meio caminho, como um corpus de média duração – possivelmente mais estável do que discursos parlamentares – temos a produção científica, humanista e artística que caracteriza o conteúdo dos repositórios institucionais de nossas universidades. Essa produção é pública, gratuita e de qualidade – gostamos de ressaltar. Assim como não é incomum identificarmos nela certo

balanço entre tradição e inovação. Por esses motivos, dados acadêmicos são uma boa entrada para iniciarmos um mapeamento das taxas de variação semântica em fontes contemporâneas, inevitavelmente massivas, como parte de um esforço propedêutico para uma história conceitual do tempo presente.

Permitam-me deixar algo claro: não estamos trabalhando apenas com metadados, mas com a integralidade dos textos de teses e dissertações, uma vez que um WEM necessita de milhões de tokens para operar satisfatoriamente. Para alcançar os objetivos de nossa coleta, o primeiro passo exigiu a criação de um código de raspagem de dados, desenvolvido pelo bolsista Igor Caetano de Souza. Escrito em linguagem Python, no ambiente de programação do Google Colab, o código original rastreava todas as páginas de entrada do Repositório Institucional da UFSC, pronto para descarregar os arquivos PDF disponíveis, convertendo-os para formato TXT, leve e editável. Foram realizadas duas coletas: a primeira teve como alvo teses e dissertações defendidas no PPGH da UFSC entre 2010 e 2023. Portanto, a primeira coleta limitou-se a executar uma pequena parte do código, resultando na raspagem da totalidade do texto de 411 trabalhos, mais os metadados. Esses dados foram usados no treinamento de nossa primeira série de modelos de Word Embedding (Woke-HST CBOW) e os metadados foram organizados em tabelas CSV para posterior utilização em nossos sistemas de referência.

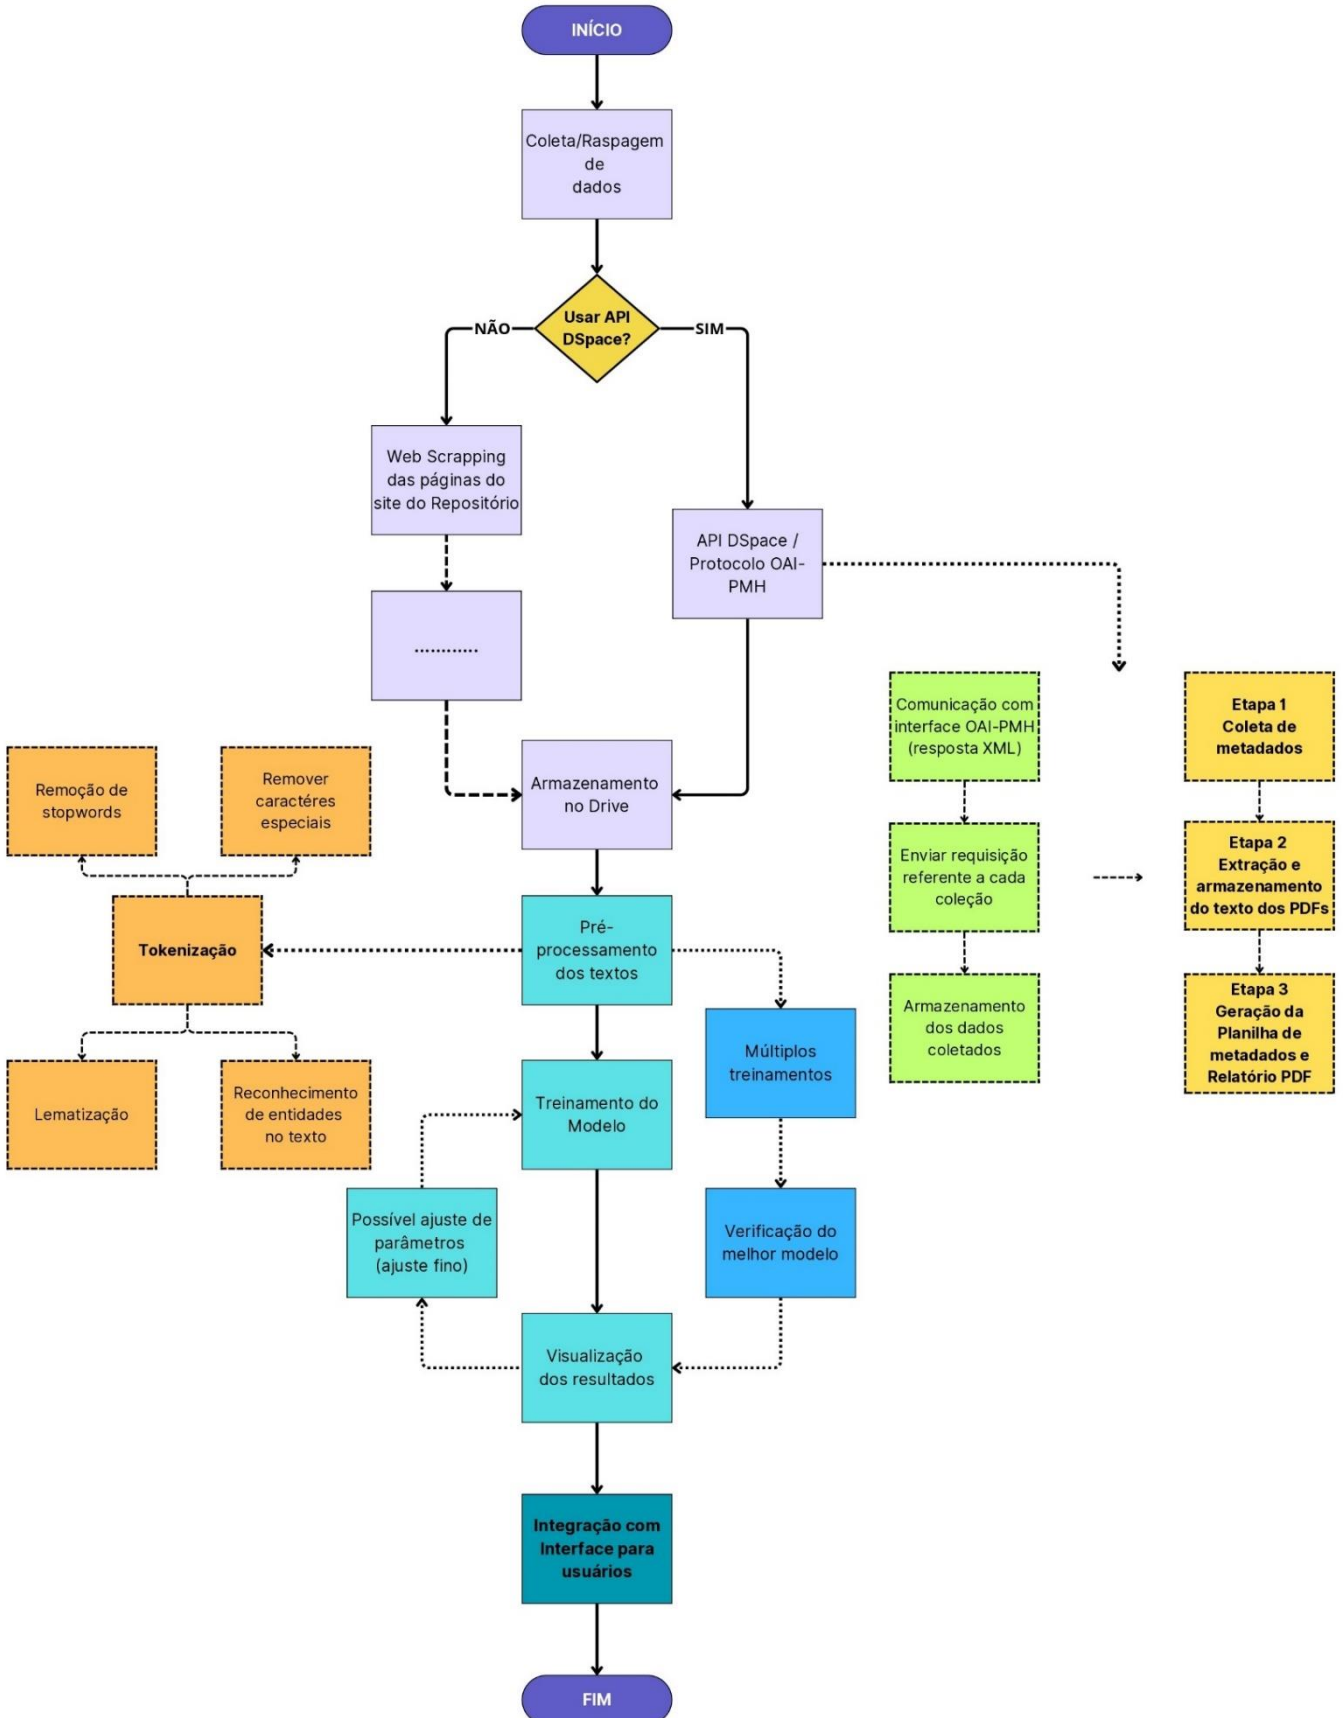
A segunda coleta teve como alvo todas as teses e dissertações defendidas na UFSC entre 2003 e 2024, compreendendo 112 coleções referentes a todas as áreas do conhecimento. O recorte justifica-se, pois, foi a partir de 2003 que a UFSC começou a solicitar o depósito de versões digitais dos trabalhos de pós-graduação. Para realizar a segunda coleta, no entanto, entramos em contato com a Superintendência de Governança Eletrônica e Tecnologia da Informação e Comunicação (SeTIC) da UFSC, uma vez que nossa estratégia de hackeamento poderia causar instabilidades no sistema. Com consentimento e apoio da SeTIC, acordamos que faríamos a coleta no mês de fevereiro, época de baixo tráfego nos servidores, e ao longo de algumas noites, de modo a não causar transtornos. Também foi solicitado que usássemos o protocolo OAI-PMH, uma API para conectar e comunicar sistemas de software, como parte do DSpace, a plataforma de gerenciamento de repositórios digitais adotada pela UFSC. O resultado desse *detour* foi positivo, uma vez que a API retornou metadados já estruturados, entre outras informações relevantes, como registros de extração, mais tarde organizados em um relatório detalhado contando 107 páginas.

Quantidade total de trabalhos analisados	31836
Quantidade total de trabalhos com texto extraído	30643
Quantidade total de trabalhos que não tiveram seus textos extraídos	1193
Taxa de aproveitamento dos textos dentro do nosso recorte	96,25%

*Relatório de Extração de Dados Woke-UFSC (Segunda coleta). Igor Caetano de Souza. Grupo de Estudos e Pesquisa em IA e História da UFSC. Março de 2024, 107 páginas.*

Os dados extraídos durante a segunda coleta compreendem a totalidade dos textos de 30.643 teses e dissertações. Após a extração, os dados passaram por uma série de procedimentos de pré-processamento. É sobre essa última etapa da fase documental de nossa operação que devemos agora discorrer.

# Fluxograma Projeto WOKE



Costuma-se dizer que a IA se alimenta de dados. Não é exatamente assim. Antes, os dados precisam ser pré-processados e estruturados em tabelas. Esse é um dos momentos nos quais a Ciência de Dados encontra o Processamento de Linguagem Natural. O primeiro procedimento que devemos realizar envolve a tokenização, ou a redução dos dados às unidades simbólicas da computação. Um token pode ser uma frequência sonora, um pixel, um caractere, uma palavra. No contexto do PLN, um token refere-se a uma cadeia de caracteres a qual é atribuída um significado ou um valor específico. Em nosso idioma, como ocorre com línguas ocidentais, essa cadeia geralmente é composta por caracteres separados por espaços em branco, e a tokenização – o processo de segmentar o texto em tokens – é adaptada para tratar adequadamente sinais de pontuação como limites entre entidades independentes. Esta peculiaridade nos leva a equiparar, frequentemente, o termo “token” com a noção de palavra escrita. Sob essa perspectiva, o número total de palavras e sinais de pontuação em uma sentença pode ser considerado como o número de tokens que ela contém (Caseli; Nunes 2024, p. 72).

Com o uso de bibliotecas disponíveis em linguagem *Python*, como a SpaCy e a NLTK, realizamos a tokenização, além de validar a extração removendo eventuais caracteres espúrios e limpando parte indesejada das unidades sintáticas dos dados de treinamento. Por isso, o segundo passo do pré-processamento foi a remoção das chamadas *stop-words*. Uma vez que a função objetiva do nosso modelo é a vetorização de palavras – e a quebra dos tokens em representações distribuídas – não estamos interessados no retorno de vetores compostos unicamente por conjunções, artigos e preposições, o que tornaria as saídas enigmáticas ou mesmo impenetráveis. Mantivemos, no entanto, advérbios de negação, importantes para a identificação de contraconceitos. Indo além, o terceiro passo envolveu a lematização de verbos, de modo a não poluir nossos vetores com variações de tempos verbais. Como as ferramentas de PLN disponíveis em português apresentaram validação insuficiente, abaixo dos 70%, Igor Caetano de Souza, com o auxílio de Franciele Dias da Silva e do esforço voluntário dos demais membros do projeto, desenvolveu o *PTBR-VL Toolkit*, um conjunto de ferramentas de PLN já disponíveis no *GitHub* e otimizadas para a língua portuguesa do Brasil<sup>4</sup>. Por fim, sobrou-nos aperfeiçoar os algoritmos de reconhecimento de entidades nomeadas, tokens compostos por mais de uma palavra que formam um único significado, como, por exemplo, “história dos conceitos”, “física quântica” ou “Universidade Federal da Paraíba”.

O pré-processamento da segunda coleta exigiu um esforço humano e computacional mais intenso. Igor Caetano de Souza criou 23 programas, dividindo entre eles as 112 coleções do repositório. Os programas foram rodados em 5 máquinas diferentes, ao longo de pouco mais de uma semana, contando também com o trabalho de Franciele Dias da Silva, Marcel Silva, Mateus Borsatti e daquele que vos escreve. Os códigos rodaram boa parte da caixa de ferramentas da SpaCy e NLTK, além do *PTBR-VL*. Os resultados foram a seguir validados qualitativamente por meio de um novo esforço coletivo fundado sobre amostragem estaticamente relevante.

---

<sup>4</sup> Nosso trabalho está sendo documentado nessa plataforma de hospedagem de código-fonte que facilita o controle de versão e a colaboração. Ver: <https://github.com/iaehistoriaUFSC/> acesso em 04/07/2024.

Não existe IA sem Ciência de Dados. Mas Ciência de Dados não é IA, do mesmo modo que a História depende da Arquivologia, mas não se confunde com ela. Assim chegamos às etapas intermediárias de nossa operação historiográfica artificial. Elas começam pelas funções das redes neurais que devem *explicar* e simular a *compreensão* da linguagem natural extraindo informações semânticas da sintaxe.

## TREINAMENTO DE MÁQUINA

Em texto que funda a discussão sobre modelos de linguagem na historiografia, Nicodemo e Cardoso sustentam seus experimentos com IA a partir da constatação de que bancos de dados se apresentam como impermeáveis à semiose narrativa (2019, 21). Velocidade, variedade e volume: os três vês associados à noção de *big data* nos lembram da dificuldade de acessar, ler e interpretar quantidades massivas de dados, como, por exemplo, dezenas de milhares de teses e dissertações. Esse é o primeiro dos motivos pelos quais sugiro o aprendizado de máquina como auxílio ao exame erudito da verdadeira biblioteca borgiana que acolhe as fontes necessárias ao sucesso do empreendimento de uma história conceitual do tempo presente. Um segundo motivo é a capacidade de WEMs representarem tokens em vetores, facilitando a visualização do caráter disputado e polissêmico dos conceitos. Por fim, a terceira vantagem do aprendizado de máquina é a possibilidade de capturar significados *êmicos* minimizando o risco de imputar noções *éticas* no ponto de partida da interpretação: como lembra Javier Fernández Sebastián, conceitos históricos idealmente não devem se confundir com categorias de análise – ao menos não durante a fase de estabelecimento do léxico de pesquisa, correndo o risco de falsear suas historicidades com “identidades anacrônicas”. Essa deveria ser, afinal, a missão da história dos conceitos: “ajudar o leitor e o historiador a distinguir com a maior clareza possível a linguagem analítica da ciência social (...) da linguagem das fontes” (Fernandez Sebastián 2018, 69).

Mas a IA é desprovida de intencionalidade. Isso significa que ela sequer pode inculcar noções éticas por si só e que qualquer viés nos resultados do aprendizado de máquina portanto não decorre da tecnologia em si, mas da natureza dos dados e das escolhas de modelagem feitas pelos humanos que a configuram. Assim, o sucesso da mineração de significados *êmicos* depende da adaptação do modelo escolhido aos dados disponíveis. Nesse contexto, o modelo é representado por equações parametrizadas com base nos dados de treinamento para executar funções determinadas. Fundamentando a fase interpretativa de nossa operação historiográfica artificial, as escolhas de modelagem nos permitem controlar as definições de “objetos, níveis e taxonomias de análise”, cuja “coerência” continua sendo “inicial” (Certeau, 2002, p. 85). Ou seja, a estrutura e os parâmetros da análise são configurados antecipadamente. Por isso, a escolha do modelo adequado é também uma tarefa de Ciência de Dados: a qualidade dos sinais de entrada deve determinar os parâmetros escolhidos em função das questões propostas pela pesquisa.

O resultado de cada uma das nossas coletas, portanto, levou ao desenvolvimento de diferentes modelos, ainda que tenhamos utilizado o mesmo algoritmo. O algoritmo padrão Word2Vec exige pelo menos 100 milhões de palavras por recorte temporal, além de um vocabulário idealmente composto por dois milhões de palavras diferentes (Hamilton *et al.* 2018; Wevers; Koolen

2020). Nossa primeira coleta compreendeu apenas 411 teses e dissertações da coleção de História do repositório da UFSC, resultando na extração de 20.472.456 palavras e abarcando um vocabulário de 65.446 palavras únicas. O problema de escala do dataset foi agravado uma vez que treinamos uma série micro-diacrônica de 5 modelos. Por esse motivo, adotamos os parâmetros do modelo Nonce2Vec, especificamente proposto para operar com um conjunto pequeno de dados, característica que também o torna mais sensível para a captura de palavras raras (Herbelot; Baroni 2017). Esse modelo foi mais tarde reajustado por humanistas digitais para o estudo da obra de Willard Van Orman Quine (1908-2000), envolvendo 228 artigos e focando nos livros *A System of Logistic* e *Word & Object* (Bloem *et al.* 2019, 134). Esses experimentos serviram de fundamento para nossa primeira série de 111 modelos, os quais passaram ainda por validação e ajuste fino de parâmetros de modo a adaptá-los ao dataset inicial. Os principais parâmetros dos modelos que desenvolvemos são os seguintes:

- *Modo CBOW: parte de um contexto e busca a palavra que o representa ou descreve (onomasiologia);*
- *Modo SGNS: Parte de uma palavra-alvo e busca associações ou significados que ela ganha em um contexto (semasiologia);*
- *Dimensionalidade: O número de dimensões nos embeddings adiciona camadas de representação semântica. Dimensões mais altas capturam maior polissemia;*
- *Negative: Número de “palavras negativas” na amostra de treinamento. Elas não são parte do contexto imediato da palavra-alvo e são usadas para ajudar o modelo a aprender a distinguir entre contextos relevantes e irrelevantes. Um rápido exemplo: “veículo” (hiperônimo), “carro” (hipônimo) e “futebol” (palavra fora de contexto).*
- *Semantic Window: O tamanho da janela semântica determina quantas palavras antes e depois são consideradas como contexto de uma palavra-alvo; esse também é o parâmetro revertido por nosso text crawler (ver 2.6).*
- *Epochs: Número de iterações sobre o corpus completo para o treinamento do modelo;*
- *Min Count: Frequência mínima de palavra no corpus para ser incluída no treinamento. Palavras com frequência menor são ignoradas. Os parâmetros Nonce2Vec, por exemplo, tem um min\_count menor.*

Todos os parâmetros são ajustáveis e se referem à etapa de aprendizado não supervisionado, ou seja, um tipo de aprendizado de máquina que não opera com uma variável alvo estabelecida. A segunda coleta realizada, envolvendo 30.643 teses e dissertações, resultou na extração de 1.220.839.374 palavras, o que nos garantiu um dataset suficientemente extenso para a elaboração de séries temporais e testes com diferentes configurações de parâmetros. A escala dos dados também permitiu a experimentação com treinamentos 1) micro-diacrônicos, 2) incrementais e 3) temporais.

O treinamento micro-diacrônico envolve o desenvolvimento de um modelo sincrônico para cada unidade temporal da série, criando modelos para cada período específico. O treinamento incremental, por sua vez, atualiza a rede gradualmente à medida que novos dados são adicionados, começando com um modelo inicial e incrementando-o sem recomeçar do zero. Já o treinamento temporal divide as redes em séries de modelos, onde cada novo modelo é treinado tanto com os novos dados quanto com os dados das séries temporais anteriores. As séries temporais e incrementais Woke-CFH foram construídas na ordem: 2003-2010, 2003-2013, 2003-2016, 2003-2019, 2003-2024. O primeiro recorte tem uma granularidade menor, pois busca garantir um número de tokens



suficientemente elevado para a definição dos parâmetros iniciais. Para os modelos Woke-UFSC, seguimos a ordem 2003-2006, 2003-2008, 2003-2010, 2003-2012, 2003-2014, 2003-2016, 2003-2018, 2003-2020, 2003-2022 e 2003-2024. Isso foi possível pois já possuíamos tokens suficientes no primeiro recorte, essencial para definir a coerência apriorística dos modelos temporais e incrementais. A vantagem das abordagens temporais e incrementais reside em ajustar os vetores gradualmente, camada a camada, sem perda de dados entre séries temporais – e tem a peculiaridade de guardar semelhança com o modelo koselleckiano dos estratos do tempo. Afinal, buscamos construir modelos que não apenas representem o caráter polissêmico dos termos – as disputas e transformações associadas – mas que também sejam, eles mesmos, historicamente saturados.

O treinamento temporal é o mais custoso em termos de recursos computacionais. A alternativa é o treinamento incremental, um tipo de aprendizado contínuo (*continual learning*), que, no entanto, carrega desafios ligados à garantia da consistência semântica ao longo das séries temporais. O fenômeno do “esquecimento catastrófico” foi diagnosticado ainda no final dos anos 1980 no contexto da técnica de retropropagação (*backpropagation*), segundo o qual “o aprendizado novo pode interferir catastróficamente com o aprendizado antigo quando redes são treinadas sequencialmente” (McCloskey; Cohen 1989, 110). A inicialização incremental significa que, ao treinar os *embeddings* para uma nova série temporal (t), começamos com os vetores previamente treinados (t – Δt). Portanto, o procedimento deve evitar que os novos significados sobreponham os anteriores, algo identificável pelo crescimento exagerado dos vetores mais recentes. Segundo a literatura especializada, WEMs treinados no modo *Skip-Gram with Negative Sampling* apresentam resultados superiores. Também existe a possibilidade de regularizar e normalizar os vetores, adicionando penalidades à função de perda para evitar que os vetores cresçam demais, levando ao esquecimento dos dados imediatamente anteriores a cada atualização (Hamilton et al. 2018, 3). Mas isso exige conhecimentos mais profundos de *PyTorch*.

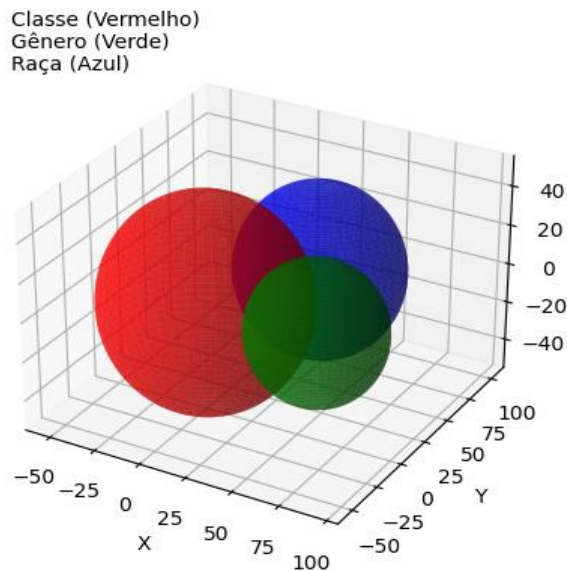
Por fim, para calcular a variação semântica de conceitos ao longo do tempo, desenvolvemos duas métricas. A primeira usa a similaridade dos cossenos entre os vetores de diferentes séries e subtrai as saídas mais recentes das mais antigas.

$$\cos(\theta) = \frac{\mathbf{A} \cdot \mathbf{B}}{\|\mathbf{A}\| \|\mathbf{B}\|} = \frac{\sum_{i=1}^n A_i B_i}{\sqrt{\sum_{i=1}^n A_i^2} \sqrt{\sum_{i=1}^n B_i^2}}$$

*Similaridade dos cossenos. A variação semântica em séries temporais pode ser medida por  $(t1, t2, t3) = | \text{similaridade}_{\cos}(\vec{V}_{t3}, \vec{V}_{t2}) - \text{similaridade}_{\cos}(\vec{V}_{t2}, \vec{V}_{t1}) |$*

A fórmula de variação semântica por meio da similaridade de cosseno é um método interessante, pois considera tanto a magnitude quanto a direção das mudanças vetoriais. Ademais, ela não depende da escolha arbitrária do número de vizinhos. Em nossas análises, utilizamos essa métrica para estudar mudanças ambíguas, vagas ou sutis, por conta de sua sensibilidade ao comparar vetores em

espaços contínuos, como demonstrarei mais abaixo. No entanto, é uma métrica muito formal e abstrata, sendo pouco intuitiva para quem não está familiarizado com geometria analítica. Por esses motivos, combinamos seus resultados com um método estatístico mais simples e fácil de aplicar. O índice de Jaccard pode ser utilizado para quantificar a similaridade e a diversidade entre conjuntos de palavras, avaliando tanto as intersecções quanto as uniões dos vizinhos semânticos em diferentes períodos. Ele lida com a teoria dos domínios ao analisar como diferentes contextos (ou domínios) compartilham ou divergem em termos de suas características semânticas.



*Intersecção entre classe, gênero e raça, utilizando o índice Jaccard. Woke-UFSC (2022-2024).*

O índice de Jaccard também é uma métrica útil para quantificar a mudança nos vizinhos semânticos de uma palavra ao longo do tempo. Este índice mede a similaridade entre dois conjuntos, calculando a proporção entre a intersecção e a união desses conjuntos. Em nossas análises, consideramos os conjuntos de 100 vizinhos mais próximos de uma palavra em diferentes períodos. Uma alta similaridade de Jaccard indica estabilidade nos vizinhos semânticos, enquanto uma baixa similaridade sugere uma mudança significativa. Isso nos permite detectar e quantificar a instabilidade semântica de conceitos ao longo do tempo. A fórmula do índice de Jaccard é dada por:

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|}$$

*A e B são os conjuntos de vizinhos semânticos da palavra-alvo em dois períodos diferentes. A intersecção  $|A \cap B|$  representa o número de vizinhos comuns aos dois conjuntos, enquanto a união  $|A \cup B|$  representa o número total de vizinhos distintos em ambos os conjuntos.*

Essas são as ferramentas que, por ora, desenvolvemos para quantificar as taxas de variação semântica específicas de cada conceito, e cada uma delas captura diferentes detalhes dessas transformações nos contextos linguísticos específicos das respectivas unidades da série temporal. A história dos conceitos nos ensina que, quando uma nova experiência emerge, costuma ser acompanhada por um novo conceito que a confere significado. Mas novas experiências não anulam experiências antigas. Consequentemente, significados mais antigos permanecem vivos na pragmática conceitual. Por isso, o ajuste de parâmetros especificamente configurados para os aprendizados temporais e contínuos se torna essencial para explorarmos representações da “simultaneidade do não simultâneo” (*die Gleichzeitigkeit des Ungleichzeitigen*).

Em nossa operação historiográfica artificial, os parâmetros – pesos em matrizes – devem fazer as vezes das hierarquias entre as durações de Braudel, ou, no contexto do diálogo do PLN com a história conceitual, entre os padrões de estabilidade e inovação na semântica dos tempos históricos de Koselleck. Os parâmetros não são mais do que construções que correlacionam a mudança semântica com a escala dos dados, em busca de uma descrição do ritmo temporal mais apropriado ao estudo dessa escala. Se formos bem-sucedidos, se essas construções forem “apropriadas à natureza do fenômeno estudado” – apropriadas à natureza de nossos dados – então elas serão “tudo menos arbitrárias, portanto, tudo menos fictícias”, potencialmente se tornando “reconstruções da condição histórica dos humanos, esse referente último da investigação histórica” (Ricoeur 2000, 741)? Nossa aposta é de que treinamentos temporais e incrementais permitirão *simular* melhor as características fluidas da experiência do tempo expressas pela linguagem, visando contribuir para a captura da natureza estratificada e não simultânea de sua semântica ao fazer uso de vetores densos entrelaçados em *clusters* historicamente saturados.

## VALIDAÇÃO E AJUSTE FINO


A qualidade e a eficácia dos *embeddings* de palavras devem ser validadas após a modelagem. Agora estamos no registro do aprendizado supervisionado, dentro do qual os modelos são testados em função de uma variável alvo estabelecida. Ou seja, fazemos perguntas para as quais conhecemos as respostas corretas e atribuímos uma pontuação a cada modelo. Essa é uma etapa importante para assegurar que os *embeddings* representem de maneira precisa e útil as relações semânticas e sintáticas das palavras no corpus de treinamento. Uma técnica de validação de WEMs relativamente simples e muito utilizada envolve a criação de conjuntos de analogias. Seu funcionamento se dá como “A está para B assim como C está para D”, onde o modelo deve identificar a palavra D baseado nas relações estabelecidas entre A, B e C. A analogia clássica é “homem está para rei assim como mulher está para X”, na qual o modelo deve calcular e prever “rainha” a partir da relação entre as outras três palavras. No quadro abaixo, a eficácia de 111 modelos treinados no primeiro lote é medida pela proporção de analogias que resolvem corretamente, oferecendo uma avaliação quantitativa das suas capacidades semânticas e sintáticas.



## VISUALIZAÇÃO E ANÁLISE DE DADOS

As visualizações de resultados formam a última etapa de nossa operação historiográfica artificial. Elas correspondem à fase literária, expositiva ou representacional da escrita da história. Em nosso caso, passamos da manipulação estatística, do cálculo e da álgebra linear para métricas de similaridade, como a similaridade de cossenos, que calcula distribuições de palavras representadas como vetores normalizados no espaço de *embedding*. A seguir, apresento algumas visualizações de dados como oportunidade de mobilizar uma discussão a respeito da aplicabilidade de métodos baseados em aprendizado de máquina para o estudo de conceitos históricos. Para que a amostragem se torne mais interessante, escolhi focá-las no trinômio clássico da interseccionalidade: classe, gênero e raça. A pergunta que agora passamos a perseguir é: qual desses conceitos é mais estável e qual é mais instável de acordo com nossos modelos? Nossa expectativa é de que “classe”, por ser o conceito mais antigo e estabelecido, seja também o mais estável.

Com WEMs, estamos muito além das análises de frequência que, como já argumentei, nos dizem muito pouco a respeito da polissemia e iteratividade dos significados conceituais.



Google N-gram views: “Race, Gender” 1900-2019

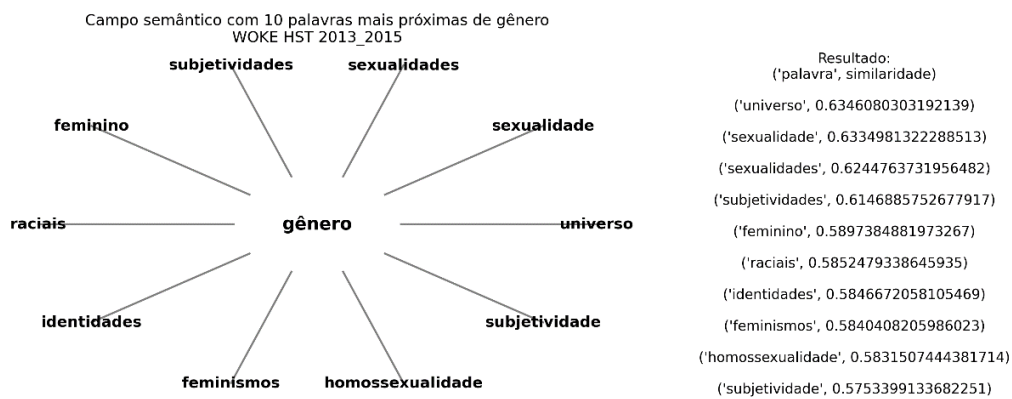
Para ilustrar e discutir as vantagens de WEMs frente a métricas mais simples de frequência, que não fazem mais do que contar palavras, vamos começar comparando os resultados acima com as saídas de modelos de *embedding* treinados em dados do Google e, logo abaixo, do Twitter:

```

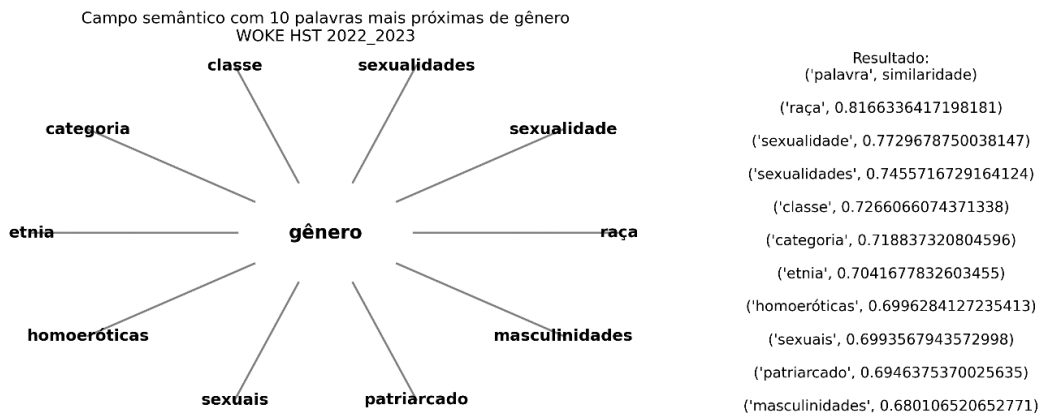
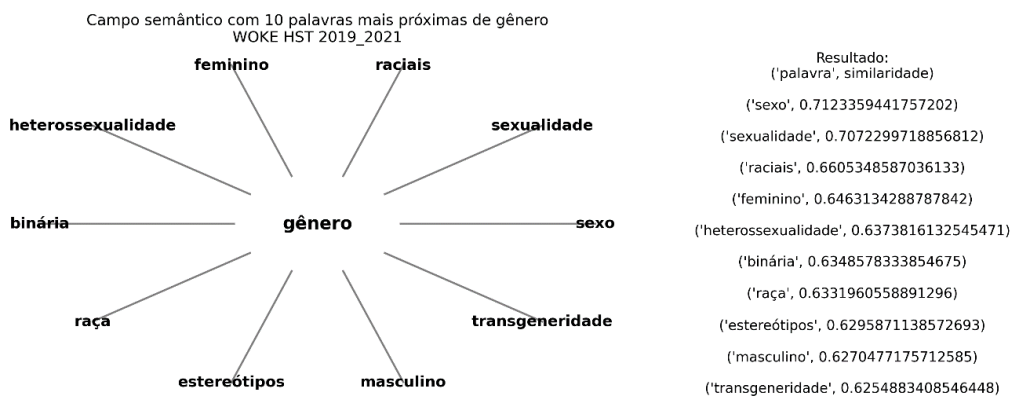
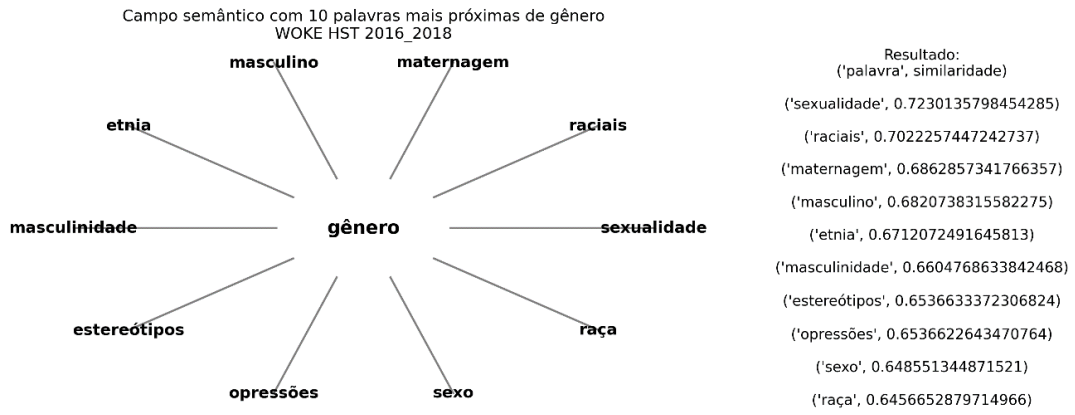
resposta = w2v_google_news_300.most_similar('gender',topn=300)
resposta
[('Gender', 0.7216669917106628),
 ('Col_Shafiq', 0.6607622564234314),
 ('genders', 0.6371080279350281),
 ('ethnicity', 0.6327993869781494),
 ('gendered', 0.6162462839543518),
 ('gender_ethnicity', 0.5960962772369385),
 ('sexes', 0.5851904153823853),
 ('Caster_Semenya_chuene', 0.5814965963363647),
 ('racial', 0.5681263208389282),
 ('gender_inequality', 0.5666836500167847),
 ('Rachel_Alexandra_romped', 0.5633226633071899),
 ('gender_bias', 0.5614519715309143),
 ('ethnicity_gender', 0.554655909538269),
 ('religion_caste_creed', 0.5504328012466431),
 ('gender_equality', 0.5487322807312012),
 ('races', 0.8232108950614929),
 ('Race', 0.6522380113601685),
 ('racing', 0.6222554445266724),
 ('sprint', 0.6156297922134399),
 ('Rain_postpones_Martinsville', 0.6032158732414246),
 ('Races', 0.5711029171943665),
 ('endurance_sportscar', 0.5543380975723267),
 ('Erion_Honda_Jake_Zemke', 0.5524527430534363),
 ('PK_Carsport', 0.5506871342658997),
 ('Deiny', 0.5442351698875427),
 ('Infineon_raceway', 0.5436782836914062),
 ('therace', 0.5411921143531799),
 ('prerace_favorites', 0.536238431930542),
 ('CherigaT', 0.5321540236473083),
 ('conteúdo', 0.8619630336761475),
 ('desporto', 0.8580375909805298),
 ('vocabulário', 0.8546937704086304),
 ('trocadilho', 0.8413988351821899),
 ('conteudo', 0.8397210777107239),
 ('roteiro', 0.8335832953453064),
 ('jornalismo', 0.8305172920227051),
 ('sobrevivência', 0.8285926580429077),
 ('conceito', 0.8271409869194031),
 ('posicionamento', 0.8217364549636841),
 ('tópico', 0.8212388157844543),
 ('xingamento', 0.8191283941268921),
 ('tradição', 0.9086280465126038),
 ('torcida', 0.9014577269554138),
 ('nação', 0.861863911151886),
 ('macumba', 0.8586179614067078),
 ('diretoria', 0.8541813492774963),
 ('gambazada', 0.8420472145800566),
 ('loucura', 0.840748250484666),
 ('paixão', 0.8394643664360046),
 ('galinhada', 0.8359181880950928),
 ('luta', 0.8316487073898315),
 ('sociedade', 0.830101490020752),
 ('miséria', 0.8292564153671265),
  
```

Modelos de Word Embedding pré-treinados. Ambiente de programação do Google Colab, linguagem Python, biblioteca Gensim.

As funções executadas acima associam uma palavra de entrada (1) com outras palavras semanticamente similares, ligadas a um vetor (quanto mais próximo de “1”, maior a similaridade semântica). A entrada para “gender” no modelo do Google é acompanhada por vetores que correspondem razoavelmente a nossas expectativas a respeito da sua similaridade semântica com “sexuality”. Mas o mesmo já não ocorre com a entrada “race”. Pensávamos estar avaliando a categoria “raça” – e tal não é nossa surpresa ao descobrir que pesquisamos por automobilismo! A situação torna-se ainda mais risível no caso dos modelos pré-treinados em dados do Twitter em português: gênero são gêneros do discurso – e raça aparentemente tem relação com torcidas de futebol. Isso demonstra, novamente, como N-gramas podem ser enganosos, impondo expectativas éticas que deveriam ser orientadas de acordo com a natureza ética de um banco de dados. Mas deixemos os modelos pré-treinados de lado e passemos a discutir as saídas de nossos próprios modelos, alimentados por dados da UFSC e dispostos em séries temporais.







*Woke HST – campo semântico de “gênero”, 2013-2023 – 411 teses e dissertações do PPGH*

As visualizações acima permitem capturar a mudança dos vetores associados a uma palavra alvo (gênero) ao longo de uma década de produção historiográfica. Mas esse ainda é um método micro-diacrônico, ou seja, composto pelas saídas de quatro modelos treinados em dados sincrônicos, em intervalos de 2-3 anos, dispostos em sequência temporal. Para nossa segunda série de modelos escalados com os dados do Repositório Institucional da UFSC, implementamos treinamentos incrementais e temporais (Hamilton *et al.* 2018). Como assinalado, essas técnicas consistem em treinar modelos em camadas semântico-temporais sucessivas. Por exemplo, os modelos expostos às teses e dissertações defendidas entre 2003 e 2024 no Centro de Filosofia e Ciências Humanas de nossa universidade foram assim treinados:

Período	corpus_count (Quantidade de Frases)	corpus_total_words (Total de Tokens no Corpus)	index_to_key (Vocabulário)	Quantidade de Palavras Presentes no Treinamento
2003-2006	690244	10001161	11839	8837390
2006-2008	1092530	16260805	16877	23493727
2009-2011	1117895	16261017	19868	38082111
2012-2014	1304783	19224935	22683	55465668
2015-2017	1626106	23714768	26210	77026797
2018-2020	1483477	21931330	28361	96912667
2021-2024	1174139	17428066	29707	112614116

*Informações sobre os modelos Woke-CFH*

Adotando uma estratégia simples de mineração de dados, começamos analisando saídas holísticas, ou seja, saídas que englobam sincronicamente toda a série temporal para a palavra-alvo “classe”, com o objetivo de estabelecer um léxico:

```

modelos_treinados[-1][1].wv.most_similar('classe',topn=300)
[('classes', 0.4438398480415344),
 ('aristocracia', 0.4141194522380829),
 ('clase', 0.406383752822876),
 ('burguesia', 0.3941067755223206),
 ('elite', 0.3936455547809601),
 ('ideologia', 0.34314605593681335),
 ('sociedade', 0.3372933864593506),
 ('camada', 0.3310611844062805),
 ('preariado', 0.32195696234703064),
 ('proletariado', 0.31180673837661743),
 ('minoria', 0.30549976229667664),
 ('burgueses', 0.3052195906639099),
 ('desigualdade', 0.28929367661476135),
 ('casta', 0.2807401716709137),
 ('classista', 0.27558398246765137),
 ('nobreza', 0.2751740515232086),

```

*Woke-CFH, saída holística (112M de palavras)*



Essas são apenas as 16 primeiras entradas de uma análise dos 300 vetores mais próximos que disputam e compõe subsimolicamente o significado de “classe”, disperso em um corpus acadêmico de ciências humanas composto por 112.614.116 palavras. Interessante notar que “racialmente” (0.26318979263305664) surge em posição muito longa no espaço vetorial, ocupando a 19ª posição no ranking dos vizinhos mais próximos, “brancas” (0.20757244527339935) aparece ainda mais tarde na posição 81ª, negra (0.20586316287517548) na 87ª e patriarcal (0.19639630615711212) apenas na 111ª posição. Esses dados nos dizem que a frequência da coocorrência distribucional dessas palavras é rara e muito dispersa, sugerindo que trabalhos problematizando classes sociais tem outros indicadores e interesses de análise.


```

modelos_treinados[-1][1].wv.most_similar('raça',topn=300)  modelos_treinados[-1][1].wv.most_similar('gênero',topn=300)
[('etnia', 0.6045879125595093),                               [('gênero', 0.4795045256614685),
 ('raciais', 0.47190383076667786),                          ('raça', 0.4433887302875519),
 ('gênero', 0.4433887302875519),                             ('raciais', 0.434222549200058),
 ('nacionalidade', 0.43179383873939514),                   ('gêneros', 0.4020040332710266),
 ('racial', 0.4242917001247406),                             ('estudos_de_gênero', 0.39516884088516235),
 ('cor', 0.4105793833732605),                                ('étnico-raciais', 0.39374518394470215),
 ('racismo', 0.40790849924087524),                          ('sexo', 0.3870449662208557),
 ('étnico-racial', 0.4037182629108429),                     ('interseccionalidade', 0.37548962235450745),
 ('intersecções', 0.3720526099205017),                     ('racismo', 0.36165735125541687),
 ('racializados', 0.36829131841659546),                    ('heteronormatividade', 0.3604089617729187),
 ('sexualidade', 0.3676331639289856),                       ('interseccionais', 0.360007107257843),
 ('opressões', 0.3617524206638336),                         ('masculinidades', 0.35676729679107666),
 ('sexo', 0.3587409257888794),                              ('feminismo', 0.3554597795009613),
 ('marcadores', 0.3506223261356354),                       ('identitárias', 0.35205867886543274),
 ('interseccionais', 0.3503548502922058),

```


*Woke-CFH, saída holística (112M de palavras)*

O mesmo fenômeno não é visível entre os dois outros termos da tríade multiculturalista: “raça” é o segundo vetor mais próximo de “gênero” (0.4433887302875519) e “gênero” (0.4433887302875519) é o terceiro vetor associado à “raça”. Ou seja, a frequência da coocorrência dessas palavras em contextos linguísticos específicos é muito representativa, indicando que estudos étnico-raciais e estudos de gênero conversam muito mais entre si do que com trabalhos interessados em analisar a dinâmica de classes. Por exemplo, para a entrada “raça”, “estratificação” (0.30540773272514343) surge na 26ª posição, “casta” (0.2045816332101822) na 126ª e “classes” (0.17349305748939514) apenas na 247ª posição do espaço vetorial. Já para a entrada “gênero”, “classe” sequer é listada entre os 300 vetores mais similares, embora “classistas” (0.21444572508335114) apareça, ainda que bem tarde, na posição 202. Agora passamos para um mapa de calor indicando a representatividade de correlações semânticas ao longo do tempo. Abaixo temos a similaridade de “raça” com relação à “classe” e à “gênero”, com essa tríade disposta em uma série diacrônica pura, treinada camada a camada.



*Woke-CFH, cores mais quentes indicam maior relação semântica entre os vetores*


Agora que conhecemos as posições dimensionais dos vetores assinalados e temos uma boa ideia de suas correlações nos espaços de *embedding*, nos sentimos autorizados a imputar entradas selecionadas da lista de 300 posições mais próximas e continuar observando suas relações semânticas:



*Similaridade semântica entre "raça" e outros tokens pré-selecionados  
Woke-CFH (2003-2024)*

A relação sutil entre vetores longos e distantes, como “proletariado” em relação à “raça”, indicaria a possibilidade da captura de um “não dito”, de uma palavra relacionada, mas não explícita, que se encontra nas posições finais dos pontos de similaridade no espaço de *embedding*? Se esse for o caso, estaríamos próximos de dizer que não existem silêncios em *big data*, mas relações implícitas e imperceptíveis na escala dimensional de raciocínio humano. Por definição, o não dito se torna um fragmento discreto do discurso revelado por vetores dispersos que ocupam uma posição remota em relação àquilo que é explicitamente dito. Sendo assim, contrariando o que escreveu Jani Marjanen, o aprendizado de máquina se tornaria capaz de capturar a ambiguidade e a imprecisão da linguagem, aspectos “que mais frequentemente interessam a historiadores conceituais” (2023, 64)? Dito de outro modo, seríamos agora capazes de “apreender e de escutar os silêncios da história” (Cezar 2015, 446)?

Para aprofundar essa investigação, é necessário invocar outra função no código. A função de analogia, abaixo executada no modelo Woke-HST, serve para mapear relações semânticas entre pares de tokens e aplica uma métrica de similaridade funcional. Seguindo a lógica comum em processos de validação — “A está para B assim como C está para D” — essa abordagem agora se volta para a mineração de dados. A função de analogia definida foi: “branco está para racista assim como negro está para X”. O propósito desse pequeno experimento é duplo. Primeiro, examinar a capacidade de lidar com a vagueza e ambiguidade linguísticas; segundo, induzir uma relação semântica e testá-la em diferentes contextos para a identificação de potenciais vieses. Trata-se de associar vetores que podem estar dispersos demais no espaço de *embedding* caso uma associação análoga não seja estabelecida *a priori*. Essa conexão nos permite evidenciar *clusters* ou constelações de pontos de dados.




Woke N2V-HST, 411 teses e dissertações do PPGH, 400 dimensões reduzidas a duas. O cluster formado evidencia um viés (2013-2024)

Um experimento realizado em 2016 com WEMs pré-treinados em dados do *Google News* utilizou a função de mapeamento “homem está para programador assim como mulher está para X” – e o modelo retornou “dona de casa”. Esse estudo demonstrou não apenas o enviesamento de gênero no corpus do Google, como também a aplicabilidade de WEMs no estudo do alinhamento cultural de grandes bancos de dados (Bolukbase; Chang; Saligrama 2016). Em nosso exemplo, o modelo Woke treinado em teses e dissertações do PPG de História da UFSC no modo CBOw detectou um viés de raça. Este viés é

indicado em uma constelação na qual os dados são organizados em grupos ou padrões que compartilham características comuns dentro de um espaço maior: “branco está para racista assim como negro está para machista”.

Mas antes de acusar os estudantes de pós-graduação em história da UFSC de reproduzirem preconceitos raciais, devemos atentar para três questões: 1) sim, este é um viés, e foi identificado pelo mais bem avaliado modelo entre 111 modelos aprimorados a partir dos parâmetros Nonce2Vec (Herbelot; Baroni 2017), otimizados para trabalhar com poucos dados (“apenas” 411 teses e dissertações); 2) O vetor “machista” (0.9001689553260803) compete de muito perto com o vetor “heroico” (0.8901704549789429). A diferença entre os valores das similaridades por cossenos de “machista” e “heroico” é de 0,0099985003471374, representando uma variação de cerca de -1,11% na similaridade semântica. Não um “salto brusco” entre um e outro, mas uma pequena passada, indicando, ainda assim, uma grande ambiguidade no significado evidenciado pela analogia e provocando uma sutil imprecisão linguística dificilmente captável na pesquisa qualitativa; 3) Por fim, o modelo não faz distinção entre fontes primárias e secundárias. Essa é uma questão importante, pois uma análise manual dos documentos indicou que dissertações e teses estavam analisando (e, por vezes, denunciando) a relação entre pessoas negras com o machismo, um tropo discursivo muito recorrente na cultura popular e na mídia de massas. Outro de nossos modelos HST, treinado no modo SGNS, corrobora essas conclusões ao identificar um viés acompanhado de ambiguidade similar, com a vantagem de localizá-lo no tempo com maior granularidade.

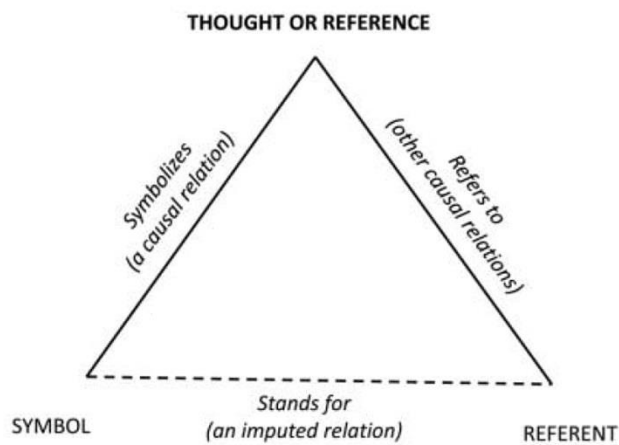


*Woke HST incremental 2 identifica o viés em teses e dissertações defendidas entre 2020 e 2024.*

A diferença entre os valores das similaridades por cossenos de “sexismo” (0.9723457098007202) e “discriminação” (0.9415830373764038) é de 0.03076267242, representando uma diferença de cerca de -3,16% na similaridade semântica. Um pouco maior do que no caso anterior, a diferença semântica agora não apenas expressa ambiguidade, mas é como se o segundo vetor denunciasse o primeiro: identificar pessoas negras com práticas sexistas é simples e pura discriminação. Estaríamos, literalmente – e não como figura de linguagem – diante de um “vetor de hierarquização [racial] que, juntamente com o gênero e a sexualidade, configuram as dinâmicas do sistema-mundo-moderno-patriarcal-capitalista” (Oliveira 2023, 445)?

Esse tipo de procedimento de análise nos permite continuar questionando a preferência dos historiadores conceituais por modelos simbólicos de representação. Jani Marjanen e Antti Kanner (2023) mobilizam esse problema no âmbito da discussão sobre o conceito de conceito. Eles identificam duas iterações meta-conceituais: Koselleck 1 e Koselleck 2. A primeira aparece no prefácio do *Geschichtliche Grundbegriffe*: “conceitos podem ser tratados como blocos de construção para um tipo de pesquisa que considera a linguagem social e política (...), tanto como fatores causais quanto como indicadores de mudança histórica” (Koselleck 2011, 8). Essa iteração, ligada à agência dos conceitos, se une possivelmente a uma terceira, a qual retornarei na conclusão. Ela é na verdade uma extensão da segunda, que aparece em *Futuro Passado*: “todo conceito se prende a uma palavra, mas nem toda palavra é um conceito”, de modo que um conceito “é mais do que uma palavra” (Koselleck 2006, 108-109).


Para entender o que é esse *mais do que uma palavra*, Marjanen e Kanner (2023) evocam o modelo de Ogden e Richards, autores que expandiram a abordagem sistêmica de Saussure para incluir o referente dos signos. Esse é o célebre triângulo semiótico. Nele, “um lado descreve a relação entre símbolo e pensamento (significante e significado na terminologia saussuriana), e o outro lado, a relação entre pensamento e referente” (Ifversen 2011, 68). Modelo similar também é empregado por “Benveniste e Jakobson, para quem a unidade de sentido no plano do discurso é a frase, onde alguém diz algo a alguém sobre algo segundo regras codificadas de interpretação” (Ricoeur 2000, 738-739).



*Triângulo semiótico de Ogden e Richard (apud Ifversen 2011, 69)*

O esquema piramidal tem o mérito de agregar referência e contexto. Mas ele me parece limitado para a captura da polissemia de conceitos históricos. Por isso, passemos ao modelo escalado em dados de todos os cursos de pós-graduação da UFSC, com o objetivo de comparar a imagem acima, simbólico-representacional, com representações distribuídas. Começemos pela palavra-alvo “raça”:

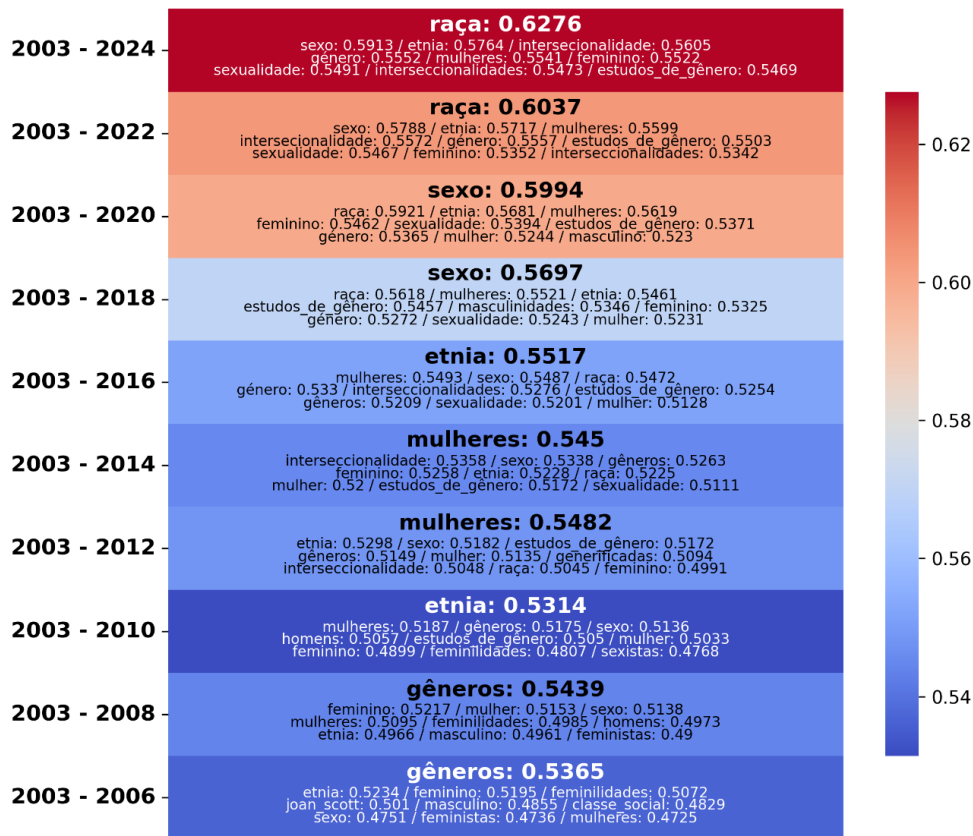
## Estratos do Tempo para "raça" usando WOKE\_1\_UFSC\_w2v\_tmp



Neste mapa de calor, cores mais quentes indicam maior similaridade semântica de “raça” com “etnia”, seu primeiro vetor ao longo de toda a série histórica. Abaixo, são apresentados os vetores seguintes da palavra-alvo para cada período.

Os modelos Woke incrementais e temporais – treinados camada a camada, sem perda de informações históricas – facilitam esse tipo de visualização, cujo design foi inspirado nos estratos do tempo de Koselleck. Vista com um olhar simbólico focado em unidades de significado, a história e a linguagem que a expressa repousam sobre uma clara estrutura de repetição: “etnia” é o primeiro vetor associado à “raça” ao longo de toda a série. “Vista como um todo”, compreendendo os demais vetores que disputam seu significado, dispostos logo abaixo em cada camada, observamos que “as estruturas de repetição (...) não se esgotam nas singularidades” (Koselleck 2014, 21, grifos meus). Os vetores de “raça” que ocupam dimensões mais distantes se modificam, além da própria similaridade entre a palavra-alvo e “etnia”, como indicam cores mais quentes e frias no mapa de calor. É assim que podemos observar a modificação das estruturas de repetição da linguagem e com isso identificar um padrão de aproximação. Uma mudança acentuada, sobretudo quando levamos os 100 primeiros vizinhos em consideração: a variação semântica de raça entre 2003 e 2024 é de 72.61% segundo o índice de Jaccard. Esse valor aumenta em séries recentes, o que nos permitiria lançar uma hipótese a respeito do impacto da implementação das ações afirmativas na produção universitária. Agora passemos para a palavra-alvo “gênero”:

## Estratos do Tempo para "gênero" usando WOKE\_1\_UFSC\_w2v\_tmp

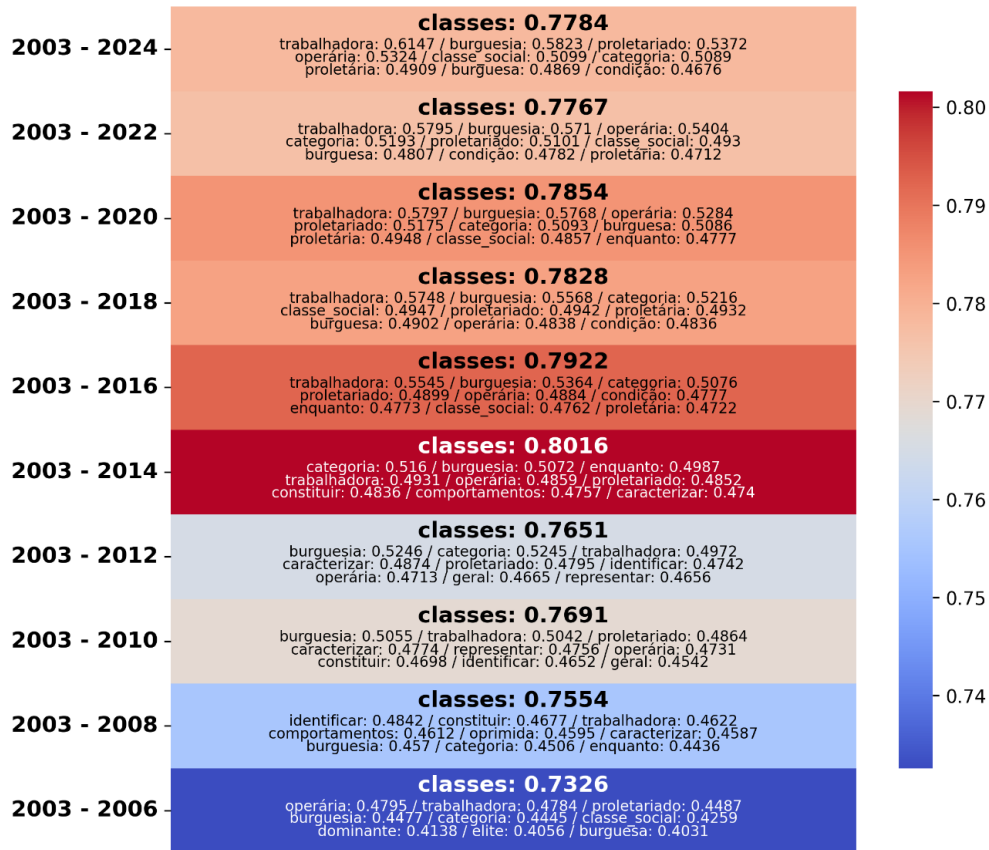


*Estratos do tempo do conceito de gênero. Cores mais quentes indicam maior similaridade semântica com seu primeiro vetor para cada recorte. Abaixo, são apresentados os vetores seguintes da palavra-alvo “gênero”.*

Novamente, os primeiros vetores mudam pouco, assim como a frequência de correlação com a palavra-alvo. Na verdade, embora as estruturas de repetição do conceito de gênero pareçam ainda mais sólidas, a situação muda quando mineramos posições mais afastadas. Através delas, podemos observar a emergência de um dos fenômenos que mais fascinou o fundador da história conceitual: “não só acontecimentos súbitos e singulares produzem mudanças; as estruturas de maior duração – que possibilitam mudanças – parecem estáticas, mas também mudam” (Koselleck 2014, 22). A mudança semântica de “gênero” de acordo com o índice de Jaccard é ainda maior, representando 78.79%. Passemos para “classe”:



## Estratos do Tempo para "classe" usando WOKE\_1\_UFSC\_w2v\_tmp

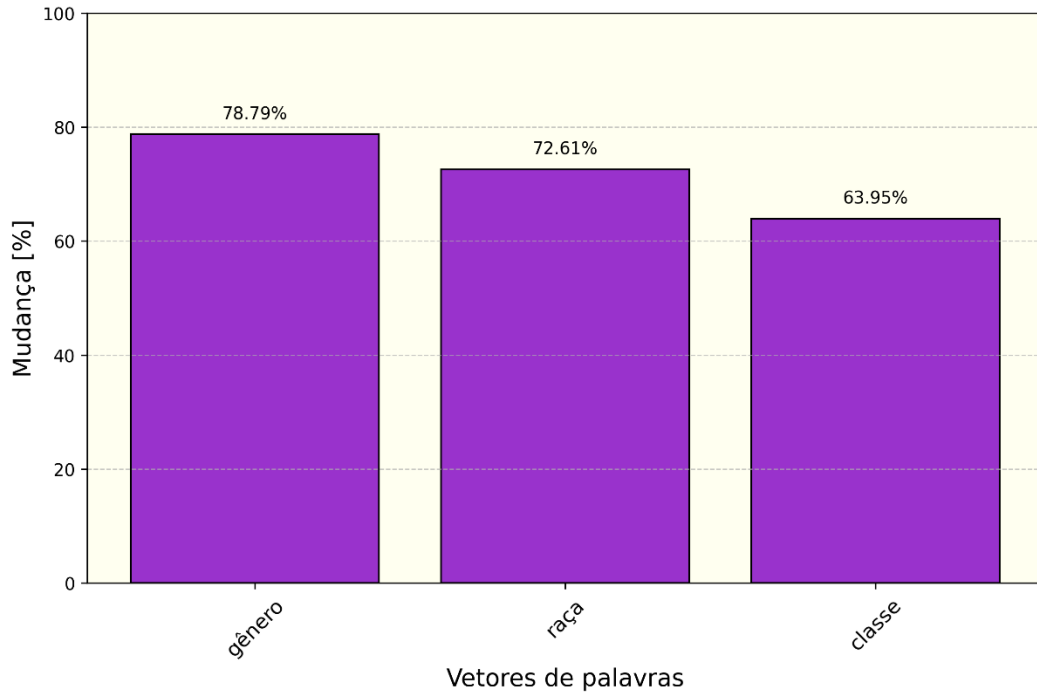


*Estratos do tempo do conceito de classe. Cores mais quentes indicam maior similaridade semântica com seu primeiro vetor para cada recorte. Abaixo, são apresentados os vetores seguintes da palavra-alvo “classe”. Woke-CFH.*

A situação muda bastante quando analisamos a palavra-alvo “classe”. A variação semântica de “classe” entre 2003-2006 e 2021-2024 é de 69.95% segundo o índice de Jaccard. O modelo UFSC temporal corrobora nossas expectativas iniciais. O conceito de classe é o membro mais estável da tríade analisada. Mas a execução de outra função (*Odd One Out*) revela uma informação adicional: classe é também o conceito cujo campo semântico menos se intersecta com raça e gênero ao longo de toda a série.



### Mudança dos vetores de palavras com índice de Jaccard usando modelo WOKE\_1\_UFSC\_w2v\_tmp de 2003 até 2024



O gráfico de barras compara a mudança semântica entre as palavras “raça”, “gênero” e “classe” entre os períodos de 2003-2006 e 2021-2024, utilizando índice de Jaccard.

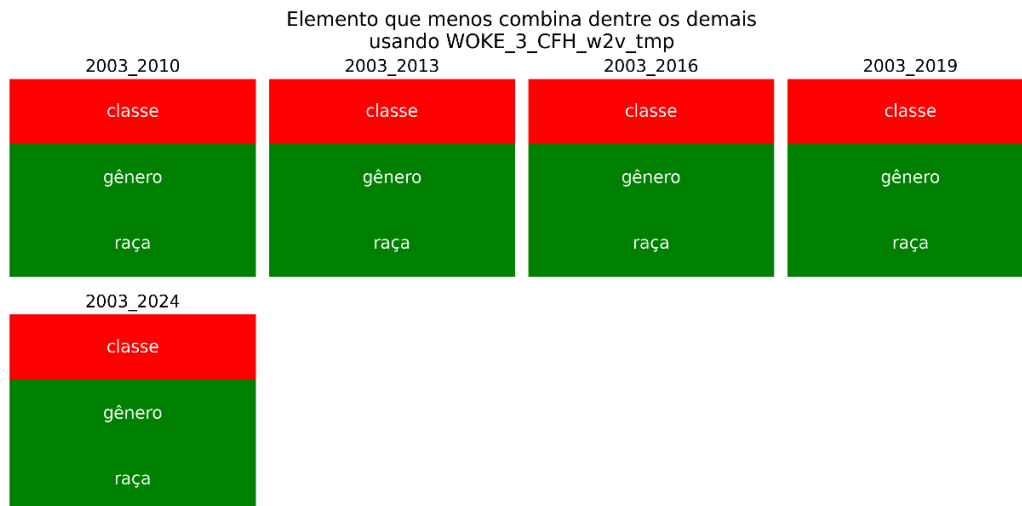
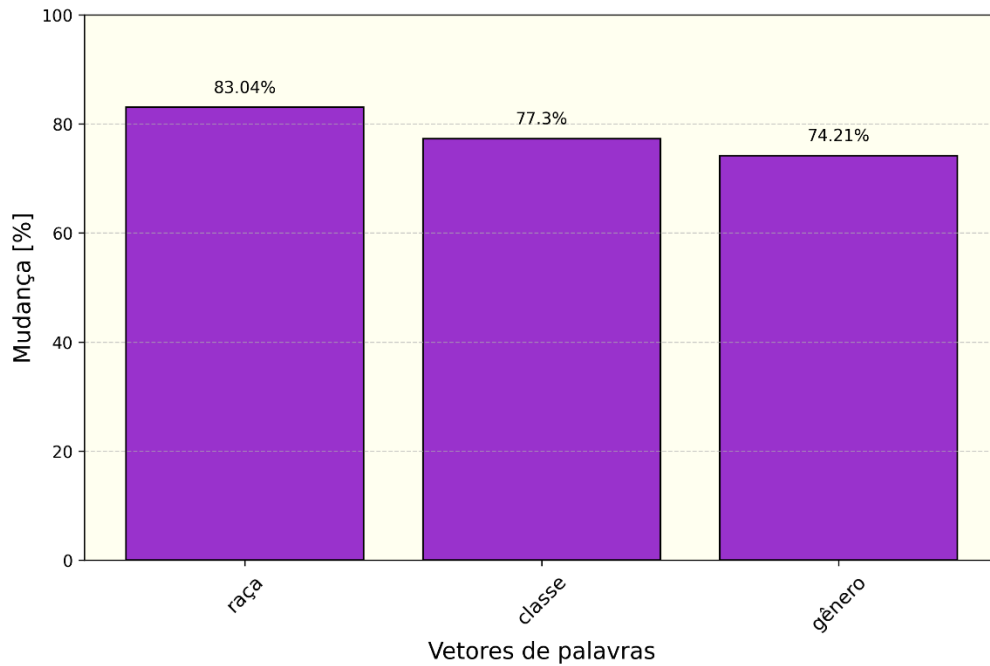
Elemento que menos combina dentre os demais usando WOKE\_1\_UFSC\_w2v\_tmp



A função “Odd One Out” ou, em português, “Intruso”, identifica o elemento que é semanticamente menos similar aos outros em um conjunto de palavras.

Mas o contexto novamente se altera quando comparamos as saídas dos modelos Woke-UFSC com as saídas dos modelos Woke-CFH. Raça passa a ser o conceito mais instável, e classe, contrariando nossas expectativas iniciais, se mostra mais disputado do que gênero. Uma pequena diferença, longe de um grande salto, mas ainda assim um passo significativo: a mudança acumulada dos vetores de raça é 8,83% maior do que a dos vetores de gênero – sendo este último, de qualquer forma, o conceito mais estável. Classe, por sua vez, continua sendo a “intrusa” na tríade conceitual.

**Mudança dos vetores de palavras com índice de Jaccard usando modelo WOKE\_3\_CFH\_w2v\_tmp de 2003 até 2024**



*Para o Woke-CFH, “classe” continua sendo a “intrusa” na tríade multiculturalista.*

Os cálculos de variação semântica, associados às visualizações de dados, buscam tirar proveito da principal virtude da teoria dos estratos do tempo: “sua capacidade de *medir* diferentes velocidades, acelerações e atrasos, tornando *visíveis* os diferentes modos de mudança, que exibem grande complexidade temporal” (Koselleck 2014, 22 grifos meus). Nas visualizações acima, reconhecemos padrões, ritmos e variações na dança dos 400 vetores presentes nas saídas de cada unidade da série temporal. Entre nós humanistas, se gênero é como um suave blues, classe estaria mais próxima de um jazz – e raça, do rock n'roll. Mas o gosto musical varia conforme os dados de treinamento. Esse pequeno experimento demonstra como é complexa a tarefa de identificar padrões de mudança semântica. Ainda assim, trata-se de um passo incontornável para que possamos encontrar os parâmetros das durações conceituais, rumo à codificação de visualizações mais complexas, capazes de representar significados não simultâneos. A implosão das unidades de nossas séries temporais em durações parametrizadas pela *aceleração*, *atraso* e *velocidade* expressas pelas mudanças nas *estruturas de repetição da linguagem* é hoje nossa nova meta. Medir e tornar visível: esse é um desafio que tomamos ao pé da letra. Mas ele de pouco vale se não pudermos fazê-lo avançar em direção ao encontro com a realidade.

#### PADRÕES NA INDETERMINAÇÃO: REFERENCIALIDADE E EXPLICABILIDADE


Até agora, discutimos o escopo de aplicações dos modelos Woke2Vec em uma dimensão representacional. Mas à história dos conceitos, como a qualquer história, interessa fundamentalmente a dimensão referencial. É no estudo das referências que a *funcionalidade* da hermenêutica artificial encontra a *intencionalidade* da interpretação humana: a tarefa crítica de verificar, cruzar e estabelecer relações entre os contextos linguísticos que contribuem para a formação de um vetor, com o objetivo de estabelecer uma prova. Agora passamos, portanto, da *representação* à *representância*, expressão que Paul Ricoeur empregava “para dar conta da especificidade da referência ou do entrecruzamento entre a história e a realidade” (Mendes 2013, 178). Agora retornamos, também, à tarefa de inculcar valores ético-epistemológicos da historiografia nas máquinas, mediando a relação entre o que “é *próprio da computação*” e o que “é *próprio da história*” (Silveira 2022, 222).

Essa não é uma questão fácil. O PLN, quando unido ao aprendizado de máquina, nos devolve um problema que pode ser descrito no âmbito de uma *virada linguística 2.0*: a indeterminação. Temístocles Cezar nos lembra que Quentin Skinner – autor dificilmente associado a uma visão ingênua a respeito da linguagem – ainda em 1985 “prevenia-nos de ‘ameaças aos fundamentos das ciências humanas’, assombradas que estavam pelo ‘espectro do relativismo epistemológico’” (Skinner *apud* Cezar 2015, 441). É claro que ele não foi o único. Pois, quando lidamos com aspectos opacos da linguagem, emerge ainda aquela habitual “desconfiança do historiador médio em relação a tudo o que possa soar como pós-modernismo” (Fernandez Sebastián 2024, 2).


Nas análises anteriores, trabalhamos com nossos modelos mais bem validados. No entanto, diferentes redes, mesmo quando treinadas com os mesmos dados e recebendo altas pontuações de validação, podem apresentar resultados distintos. Após o desenvolvimento e validação de 2.444 modelos, a família Woke conta atualmente com 28. Além dos modelos micro-diacrônicos

Nonce2Vec, a série HST possui 4 modelos incrementais e 4 modelos temporais. A série CFH, 3 temporais e 3 incrementais. A série RI-UFSC, 4 temporais e 4 incrementais<sup>6</sup>. A pluralidade da relação entre realidade discursiva e realidade social – intensificada pela intrusão de *modelos* mais do que humanos no seio do processo interpretativo – enfatizaria a indeterminação? (Ferraz Felipe 2018). Os treinamentos que implementamos culminaram no desenvolvimento de modelos que apresentam saídas bastante similares para as mesmas entradas, como se pode observar nas visualizações abaixo:


Estratos do Tempo para "gênero" usando WOKE\_1\_UFSC\_w2v\_tmp



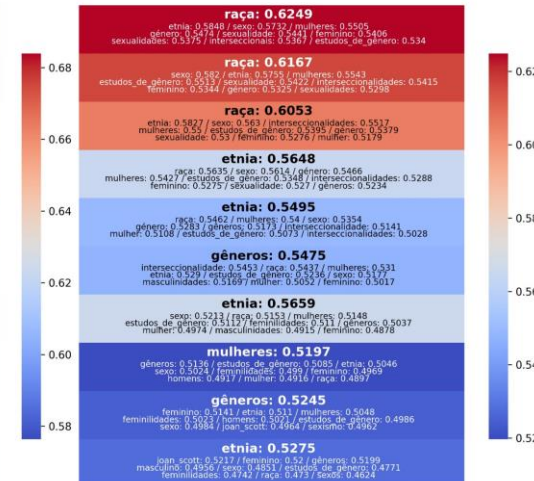
Estratos do Tempo para "gênero" usando WOKE\_2\_UFSC\_w2v\_tmp



Estratos do Tempo para "gênero" usando WOKE\_3\_UFSC\_w2v\_tmp



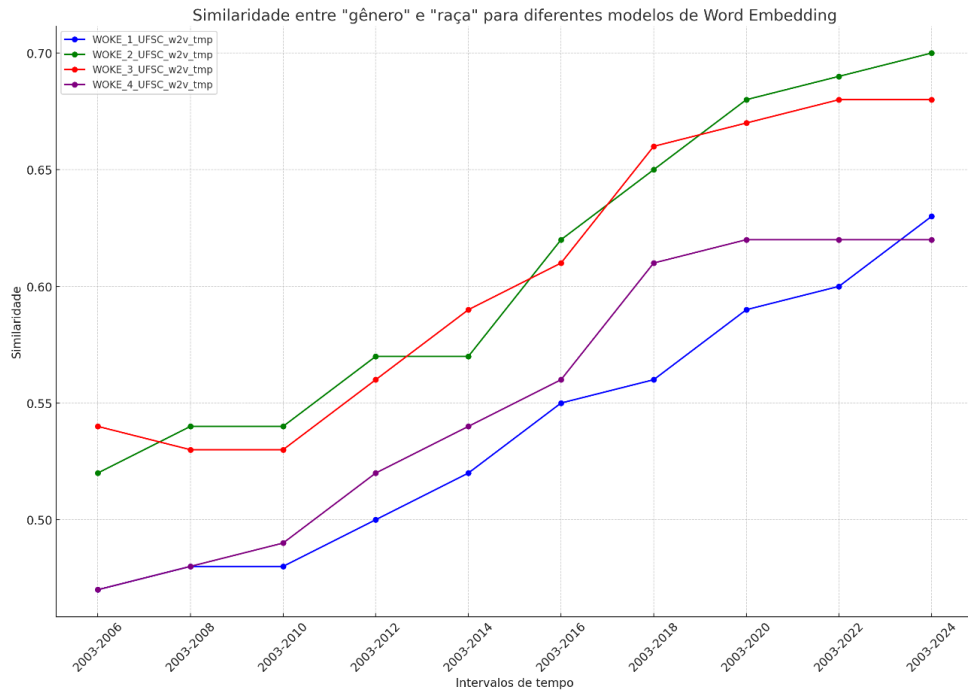
Estratos do Tempo para "gênero" usando WOKE\_4\_UFSC\_w2v\_tmp



Saídas para “gênero” na série de modelos temporais Woke-UFSC.

<sup>6</sup> Contamos também com a série “Saúde” com 3 modelos temporais e 3 modelos incrementais. Não a analiso neste artigo.

É verdade que os dados acima variam, ainda que pouco, conforme os modelos, tanto na proximidade da palavra-alvo com seus vetores subsequentes – representada por cores mais quentes no mapa de calor – quanto na posição ocupada por eles. Mesmo assim, é possível reconhecer um padrão geral de aproximação progressiva entre “gênero” e “raça”, que têm, como vimos, “etnia” como principal token de seu campo semântico em toda a série histórica. O gráfico a seguir ilustra essa tendência de aproximação para diferentes modelos Woke-UFSC:



O reconhecimento de padrões na indeterminação expressa pelas saídas de quatro modelos com parâmetros diferentes, mas alimentados com os mesmos dados, mede uma coerência cruzada que, todavia, é interna. Ainda não sabemos precisamente como se formam os vetores, nem quais enunciações provocam neles desvios, quedas e ascensões, ou diferentes ritmos de mudança. Esse é o problema da opacidade no aprendizado de máquina. A área da Inteligência Artificial que se ocupa com métodos e técnicas desenvolvidas para tornar os modelos de aprendizado mais transparentes e compreensíveis atende pelo nome de *Explainable AI* (XAI). Seu tropo fundamental é “abrir a caixa-preta” (Fazi, 2020b, 63). Para contribuir com esse campo de estudo, estamos desenvolvendo SKINNER (*Semantic Knowledge and Interpretation Navigator for Nurturing Exact References*), um *text crawler* projetado por Igor Caetano de Souza para identificar tokens e seus vizinhos dentro dos dados de treinamento do sistema Woke. Sua função objetiva é localizar *contextos linguísticos* específicos que participaram na formação de um vetor. O *text crawler* também deve cumprir essa tarefa executado a engenharia reversa do parâmetro “Semantic Window” (ver 2.3), retornando referências precisas, informações estatísticas e, possivelmente, visualizações de dados.

O código base de SKINNER é escrito em linguagem Python e baseado em regras e manipulação de símbolos. Por ser inflexível, a computação baseada em regras é muito mais confiável, tornando-se adequada para cumprir critérios referenciais. Afinal, nosso objetivo, nesse momento crítico, é implementar técnicas “mais transparentes que permitam fornecer prova” (Marjanen 2023, 48). Após rastrear o dataset, SKINNER retorna, em um arquivo PDF, uma lista de teses e dissertações, seus links para o repositório da UFSC, além de uma listagem do conteúdo de janelas semânticas na forma de enunciações envolvidas na construção de um vetor. O desenvolvimento desse componente de XAI visa demonstrar que é possível combinar potencialidades exploratórias e referenciais em sistemas de IA. Ele também cumprirá um papel essencial na validação dos modelos, possibilitando o estudo das decisões da IA por meio de engenharia reversa da auto-atualização (ajuste e refinamento) dos parâmetros iniciais, executada pela caixa-preta após a adição ou incrementação de camadas semântico-temporais aos dados de treinamento. Ao mesmo tempo, um subcomponente de aprendizado permitirá a identificação da representatividade de cada contexto linguístico, oferecendo uma métrica percentual. Isso ajudará na identificação de contingências que chamamos de outliers.

Verdadeiros pontos fora da curva de regressão, a Ciência de Dados habitualmente define outliers “pela distribuição geral dos pontos de dados subjacentes” (Aggarwal 2013, 79). Imagine uma lanterna que ilumina os padrões mais hegemônicos, quantitativamente representativos de uma mina de dados. Essa seria uma linha de regressão. Nela, os outliers ficariam no escuro. Contudo, ao desenvolvermos um modelo, temos o poder de controlar o que, em aprendizado de máquina, chamamos de *bias* e de *slope*: o “viés” desloca a linha de regressão para cima ou para baixo, ajustando sua interseção com o eixo y, enquanto a “inclinação” determina seu ângulo, representando a taxa de mudança da variável dependente em relação à variável independente. Temos o poder, em outras palavras, de ajustar as linhas de regressão e – para seguir com a metáfora – direcionar seus feixes de luz. Poderíamos então iluminar dados que, como certa vez comentou Edoardo Grendi, testemunham “indiretamente sobre um cotidiano normal e mal documentado” (Lima 2006, 331)?

SKINNER está sendo projetado para auxiliar na detecção de contingências análogas ao que a micro-história denominou “excepcional normal”: registros estatisticamente irrelevantes – raros ou dispersos dos padrões normativos – mas dotados de *qualidades* que indiciam o real de forma significativa. Esses seriam dados representativos, mas que aparecem com baixa frequência. Afinal, “casos anômalos” podem se revelar importantes pois as “anomalias (...) são mais ricas, do ponto de vista cognitivo, do que as normas, na medida em que as primeiras invariavelmente incluem as últimas – mas não o contrário” (Ginzburg 2021, 21).

Não é demais ressaltar que a experimentação com componentes desse tipo seria extremamente difícil caso estivéssemos trabalhando com modelos desenvolvidos por terceiros: nós conhecemos nosso dataset, pré-processamos todos os nossos textos e, por isso, podemos rastrear todos os tokens. Essa é a importância – destacada no debate entre Éric Brasil e Pedro Telles da Silveira (2022) – de desenvolvermos nossos próprios sistemas: em vez de objetos técnicos neutros e passivos – como a palavra “ferramenta” pode vir a sugerir – o aprendizado de máquina constrói *modelos* que se situam entre o documento e a explicação. Consequentemente, é apenas possuindo o controle dos *vetores da informação* que podemos realizar a engenharia reversa da caixa-preta, minerar contingências, ou executar a “função referencial” (Ifversen 2011, 77).

## CONCLUSÃO

Parametrizar durações: o paradigma econométrico da geração de Fernand Braudel e Emmanuel Le Roy Ladurie representou um primeiro passo, com os ritmos da longuíssima, da longa e da média temporalidades restando muito mais suscetíveis de captura por seus modelos. Afinal, falar de *temporalidade* tem “como inconveniente convocar o padrão de um tempo exterior (...) cujas diferentes durações se medem todas em relação a um tempo ‘exógeno’” (Hartog 2014, 12). Uma cronologia desprovida de experiência vivida, de memória, de linguagem e de emoção – vazia, portanto, de quaisquer qualia fenomenológicos que nos definem como seres humanos. Ir além significa recuar a uma escala muito menor, na qual sujeitos não são reduzidos à abstração de números intraduzíveis, dispersos em contestações *sintáticas*. Na linguagem, na casa do Ser, agora habitam experiências humanas renderizadas em pontos de dados, vetores e redes *semânticas*. Essa é uma escala doméstica, muito mais difícil de agarrar, medir e compreender: evasiva como a espuma das ondas, fugidia como a pragmática que se esconde por trás da linguagem política que orienta a ação social. Uma escala “micro-temporal” (Silveira 2023) e “micro-semântica” (Bonaldo 2023), na qual as variações de significado são medidas em decimais.

Identificar a *historicidade* dos conceitos básicos da vida política e social era o fundamento do monumental trabalho dirigido por Otto Brunner, Werner Conze e Reinhart Koselleck. Essa pesquisa empírica, que estabeleceu o léxico da modernidade clássica, redundou em um novo exame das durações. O teorema koselleckiano descreveu, ainda que de modo qualitativo, os hiper parâmetros que um dia dinamizaram os conceitos de movimento: democratização (*Demokratisierung*), politização (*Politisierung*), ideologização (*Ideologisierung*) e temporalização (*Verzeitlichung*). Processos que estão no centro da hipótese do *Sattelzeit* (1750-1850), um período delimitado em função de um conjunto coerente de ritmos de mudança temporal, uma *duração* durante a qual, “nos conceitos de Koselleck, espaços de experiência e horizonte de expectativa não foram modificados, sendo assim congruentes” (Rosa 2019, 147). A partir desses “quatro processos que moldaram nossos conceitos básicos”, o historiador acreditava ser possível descobrir os “valores-limite que caracterizaram a transformação epocal da experiência histórica até os nossos dias” (Koselleck 2011, 31).

Mas o que se passa “em nossos dias”, dias que não parecem ser mais os mesmos de Koselleck, mas, ainda assim, continuam marcados pela mudança nos conceitos que dão significado à experiência? Assistimos à ascensão da raça, do gênero e, agora, do meio ambiente, como conceitos inevitáveis no debate político: mesmo que extremistas neguem as mudanças climáticas, falem de ideologia de gênero ou reafirmem o mito da democracia racial, não fazem mais do que declarar uma disputa semântica. É precisamente essa situação que denuncia a ascensão de um conceito básico (Ifversen 2011, 75; Turin 2023, 708). Os conceitos básicos de hoje podem não ser mais os mesmos de ontem, porém, continuam inescapáveis, assinalados pela polissemia, ambiguidade e incerteza que caracterizam sua instrumentalização por diferentes projetos políticos, combinando, em nome de diferentes horizontes de expectativa, experiências igualmente diversas (Koselleck 1996, 64).

É na categoria experiência que atualmente reside a principal limitação de nossos modelos. O estudo de relações semânticas, ainda que referencial, esbarra em uma iteração do conceito de conceito que chamarei de Koselleck 3: “uma palavra se torna um conceito se a totalidade das circunstâncias político-sociais e empíricas, nas quais e para as quais essa palavra é usada, se agrega a ela” (Koselleck 2006, 109). É isso que Koselleck realmente chamava de “espaço de experiência”. Usamos algoritmos, medimos taxas de variação semântica, mas não estamos isentos de respaldar nossas análises no “uso real da linguagem” (Marjanen 2023, 48). Os métodos computacionais nos permitem observar como novos conceitos se revelam por meio de agitação e inovação linguísticas. Mas essa é apenas a sua dimensão interna. Outras se referem a elementos que estão fora da linguagem: é o “aspecto contextual do significado” (Ifversen 2011, 81), que responde pelo diálogo com a história social. Por um lado, a linguagem registra “o que acontece fora de si mesma” declarando aquilo “que se impõe (...) ao mundo”, o modo como “se apresenta pré e extralinguisticamente. Por outro lado, a linguagem transforma ativamente todos os objetos e fatos extralinguísticos” (Koselleck *apud* Ifversen 2011, 76). De todo o modo, Koselleck pensava ser “(...) teoricamente errônea toda postura que reduz a história a um fenômeno de linguagem, como se a língua viesse a se constituir na última instância da experiência histórica” (1992, 136). Para a historiografia que se debruça sobre documentos escritos, a língua na verdade é apenas a primeira instância. Por enquanto, o estudo da interação entre linguagem e mundo ainda é uma tarefa que relegamos à pesquisa analógica.

A captura de espaços de experiência – compreendidos enquanto conjunto completo das situações políticas, sociais e práticas – só poderá ser automatizada com o desenvolvimento de modelos mais complexos, treinados em um banco de dados bem mais extenso e capazes de operar com milhões de parâmetros. Gesto que envolve completar um ciclo de retorno às pretensões de uma história total, rumo ao reencontro com “o jogo múltiplo da vida”, aproximando Braudel (1990, 33) de Koselleck ao unir temporalidade com historicidade (Marquese; Da Silva Júnior, 2018). Essas são as próximas fases do projeto IA e História da UFSC: escalar os dados com os repositórios de outras IEs brasileiras, em conjunto com uma amostra significativa de trabalhos de história social e fontes primárias de tipologias diversas, de modo a alimentar modelos de aprendizado *profundo* de máquina, como aqueles baseados na arquitetura *Transformer*.

Essa arquitetura, famosa pelos Modelos de Linguagem de Grande Escala (LLMs) como o GPT ou o Gemini, foi proposta por engenheiros do Google em 2017. Ela possui duas inovações fundamentais. A primeira é a “codificação posicional” (*positional encoding*) que ajuda o modelo a entender a sequência de palavras em uma frase. A segunda é a “auto atenção” (*self-attention*), pela qual o modelo processa tokens em paralelo, assim analisando todas as palavras em uma janela semântica de uma só vez (Vaswani *et al.* 2017). Esse é um novo salto na capacidade das máquinas em extrair informações semânticas da sintaxe: um *Transformer* opera por subtokenização e seus mecanismos de atenção são capazes de se concentrar em partes específicas dos dados de treinamento, o que é decisivo para o estudo de contextos sociais específicos.



Mas isso ainda seria fazer pouco caso da IA multimodal. Se “*Attention is all you need*” propôs o modelo *Transformer* em 2017, assistimos, poucos anos depois, à resposta da Microsoft: “*Language is not all you need*” (Huang *et al.* 2023). O artigo apresenta um modelo de linguagem grande multimodal (MLLM) desenvolvido para integrar capacidades de percepção, como visão e audição, com modelos tradicionais de linguagem. Uma nova corrida dentro da indústria da álgebra linear hoje busca identificar, analisar e simular qualidades fenomenológicas externas à linguagem – como o reconhecimento de padrões faciais, sonoros e emocionais – a partir da linguagem de programação. Uma espécie de *ultrapassagem por dentro* daquilo que chamei de *virada linguística 2.0*, rumo a uma espécie de “período pós-pós moderno” da IA (Cezar 2015, 446)? De todo o modo, uma oportunidade para “expandir as possibilidades da história conceitual desenvolvendo maneiras” – acrescento eu, digitais – “de levá-la além da linguagem” (Pernau; Rajamani 2016, 47).

É se engajando com essas novas tecnologias e problemas que o projeto de encontrar parâmetros na semântica dos tempos presentes, identificando períodos em função de durações, deve ganhar forma. É elaborando uma reflexão crítica da técnica – sincronizada pela experiência direta com o desenvolvimento tecnológico – que buscaremos contribuir para a “identificação e o mapeamento” de conceitos básicos de nossos tempos, “com suas diferentes redes semânticas, [posicionando-os] uns em relação aos outros, com suas diferentes disposições políticas, epistemológicas e mesmo ontológicas” (Turin 2023, 715). Estou convencido de que o volume massivo de documentação exigido por esse empreendimento ganhará com o emprego de métodos digitais. Entretanto, não estou convencido de que esta seja a tarefa de uma história conceitual meramente quantitativa, mas parte de um esforço coletivo por uma história digital que seja capaz de renegociar as fronteiras entre abordagens quantitativas e qualitativas (Cardoso Júnior 2023). A partir de agora, esse projeto transgeracional passa a depender de uma aliança entre duas formas de ver e interpretar o mundo: a erudição e a análise de *big data*.

## REFERENCIAS

- AGGARWAL, Charu C. *Outlier Analysis*. New York: Springer, 2013.
- AMARO, Ramon. *The black technical object: On machine learning and the aspiration of black being*. London: Sternberg Press, 2022.
- ANSELL-PEARSON, Keith. *Bergson thinking beyond the human condition*. Londres/Nova Iorque: Bloomsbury, 2018.
- BERGSON, Henri. Da multiplicidade dos estados de consciência: a ideia de duração. In: *Ensaio sobre os dados imediatos da consciência*. Lisboa: Edições 70, 1988.
- BLOEM, Jelke; FOKKENS, Antske; HERBELOT, Aurélie. Evaluating the Consistency of Word Embeddings from Small Data. In: *Proceedings of Recent Advances in Natural Language Processing*, 2019, Varna, pp. 132–141, 2019.
- BOLUKBASE, Tolga; CHANG, Kai-Wei; ZOU, James; SALIGRAMA, Venkatesh; KALAI, Adam. *Man is to Computer Programmer as Woman is to Homemaker? Debiasing Word Embeddings*. arXiv:1607.06520, 2016.
- BONALDO, Rodrigo. História mais do que humana: descrevendo o futuro como atualização repetidora da Inteligência Artificial. *História* (São Paulo), Vol. 42, n. 1, pp. 1-28, 2023.

- BONALDO, Rodrigo; PEREIRA, Ana Carolina Barbosa. Potential History: reading artificial intelligence from indigenous knowledges. *History and Theory*, n. 1, v. 62, pp 3-29, 2023.
- BRASIL, Eric. pyHDB - Ferramenta heurística para Hemeroteca Digital Brasileira: utilizando técnicas de web scrapping para a pesquisa em história. *História da Historiografia*, Ouro Preto, v. 15, n. 40, pp. 186-217, 2022.
- BRAUDEL, Fernand. A Longa Duração. In: *História e Ciência Sociais*. Lisboa: Presença, 1990.
- CARDOSO Jr., Hélio R. *Conceitos de Tempo na Teoria da História Recente (2000-2022): Banco de Dados com Recursos das Humanidades Digitais*, Projeto CNPq/AUXÍLIO À PESQUISA/GRUPOS CONSOLIDADOS, Processo: 404969/2023-2.
- CASELI, Helena de Madeiros; NUNES, Maria das Graças Volpe (org). *Processamento de Linguagem Natural: conceitos, técnicas e aplicações em português*. São Carlos: BPLN, 2024.
- CERTEAU, Michel de. *A escrita da história*. Rio de Janeiro: Forense Universitária, 2002.
- CEZAR, Temístocles. Hamlet Brasileiro: ensaio sobre giro linguístico e indeterminação historiográfica (1970-1980). *História da Historiografia*, Ouro Preto, v. 8, n. 17, pp. 440-461, 2015.
- DALLAS, Costis. Digital curation beyond the "wild frontier": a pragmatic approach. *Archival Science*. Vol. 16. No. 1, pp. 421-457, 2016.
- FAZI, Beatrice. O fim da Teoria da Mídia. *Intexto*, Vol. 1, No. 49, pp. 305-318, 2020a.
- FAZI, Beatrice. Beyond human: Deep learning, explainability and representation. In: *Theory, Culture & Society*, Vol. 38, No. 7-8, pp. 55-77, 2020b.
- FERNÁNDEZ SEBASTIÁN, Javier. Identidades Anacrónicas: el historiador ante el problema de las categorías y clasificaciones sociales. In: NEVES, Lucia Maria Bastos Pereira das; FERREIRA, Fátima Sá e Melo; NEVES, Guilherme Pereira das (org). *Linguagens da identidade e da diferença no mundo Ibero-Americano (1700-1890)*. Jundiá: Paco Editorial, 2018.
- FERNÁNDEZ SEBASTIÁN, Javier. *Key metaphors for history: mirrors of time*. New York: Routledge, 2024.
- FERRAZ FELIPPE, Eduardo. Correspondências historiográficas: Literatura e História além da forma tradicional. *Revista de Teoria da História*, v. 20, n. 2, pp. 6-27, 2018.
- GADAMER, Hans-Georg. *Verdade e Método: traços fundamentais de uma hermenêutica filosófica*. Petrópolis: Editora Vozes, 1999.
- GINZBURG, Carlo. Nossas palavras e as deles: o ofício do historiador na atualidade. *ArtCultura*, Uberlândia, v. 23, n. 42, pp. 7-26, 2021.
- GONÇALVES, Murilo. *A História (De)Codificada: Prolegômenos para uma Hermenêutica Digital*. 204 páginas. (Tese de Doutorado em História) – Universidade Federal de Goiás, Goiânia, 2022.
- HAMILTON, William L; LESKOVEC, Jure; JURAFSKY, Dan. *Diachronic Word Embeddings Reveal Statistical Laws of Semantic Change*. arXiv:1605.09096v6 [cs.CL] 25 Oct, Páginas 1-13, 2018.
- HARTOG, François. *Regimes de historicidade: presentismo e experiências do tempo*. Belo Horizonte: Autêntica, 2014.
- HERBELOT, Aurélie; BARONI, Marco. High-risk learning: acquiring new word vectors from tiny data. In: *Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing*, 2017, Copenhagen: Association for Computational Linguistics, pp. 304-309, 2017.
- HUANG, Shaohan et al. *Language is not all you need: aligning perception with language models*. arXiv:2302.14045v2 [cs.CL], 2023.
- IFVERSEN, Jan. About Key Concepts and How to Study Them. *Contributions to the History of Concepts*, v. 6, n. 1, p. 65-88, 2011.

- KANNER, Antti. *Meaning in Distributions: A Study on Computational Methods in Lexical Semantics*. Helsinki: University of Helsinki, 2022.
- KELLEHER, John. D. *Deep Learning*. Cambridge: The MIT Press, 2019.
- KLÜVER, Jürgen; KLÜVER, Christina. *Social Understanding: on hermeneutics, geometrical models and artificial intelligence*. London/New York: Springer, 2011.
- KOSELLECK, Reinhart. Uma história dos conceitos: problemas teóricos e práticos. *Estudos Históricos*, Rio de Janeiro, v. 5, n. 10, p. 134-146, 1992.
- KOSELLECK, Reinhart. Response to Comments. In: LEHMANN, Hartmut; RICHTER, Melvin (org). *The Meaning of Historical Terms and Concepts: New Studies on Begriffsgeschichte*. Washington: German Historical Institute, 1996.
- KOSELLECK, Reinhart. *Futuro Passado: Contribuição à semântica dos tempos históricos*. Rio de Janeiro: Contraponto, Editora Puc-RJ, 2006.
- KOSELLECK, Reinhart. Introduction and Prefaces to the Geschichtliche Grundbegriffe. *Contributions to the History of Concepts* Vol. 6, No. 1, p. 10-15, 2011.
- KOSELLECK, Reinhart. *Estratos do tempo: Estudos sobre História*. Rio de Janeiro: Contraponto, 2014.
- LE, Quoc; MIKOLOV, Tomas. *Distributed Representations of Sentences and Documents*. arXiv:1405.4053v2 22, pp. 1-9, 2014.
- LIMA, Henrique Espada. *A micro-história italiana: Escalas, Indícios e Singularidades*. Rio de Janeiro: Civilização Brasileira, 2006.
- LUCCHESI, Anita.; SILVEIRA, Pedro Telles.; NICODEMO, Thiago Lima. Nunca fomos tão úteis. In: *Esboços*, Florianópolis, Vol. 27, No. 45, pp. 161-169, 2020.
- MARQUESE, Rafael de Bivar; DA SILVA JÚNIOR, Waldomiro Lourenço. Tempos históricos plurais: Braudel, Koselleck e o problema da escravidão negra nas Américas. *História da Historiografia*, Ouro Preto, v. 11, n. 28, 2018.
- MARJANEN, Jani. Quantitative Conceptual History: on agency, reception and interpretation. *Contributions to the History of Concepts*. Vol. 18, No. 1, pp. 46-67, 2023.
- MARJANEN, Jani; KANNER, Antti. What are concepts in conceptual history? revisiting Koselleck through theories of semantic relations. In: *The 24th International Conference on the History of Concepts*, 2023, Varsóvia. Agency of Concepts in Interface Regions: Asymmetries, Asynchronities and Discontinuities. Varsóvia: University of Warsaw, 2023.
- MCCLOSKEY, Michael; COHEN, Neal J. Catastrophic Interference in Connectionist Networks: The Sequential Learning Problem. *Psychology of Learning and Motivation*, Vol. 24, No. 1, pp. 109-165, 1989.
- MCCORDUCK, Pamela. *Machines Who Think: A Personal Inquiry into the History and Prospects of Artificial Intelligence*. Natick, MA: A. K. Peters, 2004.
- MENDES, Breno. *A representância do passado histórico em Paul Ricoeur: linguagem, narrativa e verdade*. 223 páginas (Tese de Doutorado em História) – Universidade Federal de Minas Gerais, Belo Horizonte, 2013.
- MIKOLOV, Tomas; CORRADO, Greg; CHEN, Kai; DEAN, Jeffrey. *Efficient Estimation of Word Representations in Vector Space*. arXiv:1301.3781v3 [cs.CL] Sep 7, Páginas 1-12, 2013.
- MINSKY, Marvin. *Why People Think Computers Can't*. AI Magazine, v. 3, n. 4, p. 3-15, 1982.
- MONTEIRO, Renato de Araújo. *Identidade, história de um conceito e o conceito de história: uma arqueologia nos dicionários de língua portuguesa*. 306 Páginas. (Tese de Doutorado em História Global) – Universidade Federal de Santa Catarina, Florianópolis, 2024.
- NEVES, Lúcia M. Bastos P. Os esquecidos no processo de independência: uma história a se fazer. *Almanack*, Guarulhos, Vol. 1, No. 25, pp. 1-44, 2020.

- OLIVEIRA, Maria da G. de. Ficar com os espectros: políticas de temporalização da história em um presente fugidio. *Esboços*, Florianópolis, v. 30, n. 55, p. 442-455, 2023.
- PERNAU, Margrit; RAJAMANI, Imke. Emotional translations: conceptual history beyond language. *History and Theory*, v. 55, n. 1, p. 46-65, 2016.
- ROCHA, Marcos. Uma história da linguística computacional no âmbito das ciências cognitivas. *Circumscribere*, v. 18, p. 56-67, 2016.
- NICODEMO, Thiago Lima; CARDOSO, Oldimar. Metahistory for (Ro)bots: historical knowledge in the Artificial Intelligence Era. *História da Historiografia*, Vol. 12, No. 29, pp. 17-52, 2019.
- RICOEUR, Paul. L'écriture de l'histoire et la représentation du passé. In: *Annales: Histoire, Sciences Sociales*. Vol. 55, No. 4, pp. 731-747, 2000.
- ROSA, Hartmut. *Aceleração: A transformação das estruturas temporais na Modernidade*. São Paulo: Editora. Unesp, 2019.
- ROTA, Alesson Ramon; NICODEMO, Thiago Lima. Arquivos pessoais e redes sociais: o Twitter construído como documento histórico. In: *Estudos Históricos*, Vol. 36, No. 79, pp 268-291, 2023.
- SILVEIRA, Pedro Telles da. O que é uma ferramenta historiográfica? *História da Historiografia*, Ouro Preto, v. 15, n. 40, p. 219-231, 2022.
- SILVEIRA, Pedro Telles da. The counted time: Technical temporalities and their challenges to history. In: *History and Theory*, Vol. 62, No. 3, pp. 403-426, 2023.
- TURING, Alan. Computing Machinery and Intelligence. *Mind*, v. 58, n. 236, p. 433-460, 1950.
- TURIN, Rodrigo. Antropoceno e futuros presentes: entre regime climático e regimes de historicidade potenciais. *Topoi*, Rio de Janeiro, Vol. 24, No. 54, pp. 703-724, 2023.
- VARELLA, Flávia Florentino; BONALDO, Rodrigo Bragio. Negociando autoridades, construindo saberes: a historiografia digital e colaborativa no projeto Teoria da História na Wikipédia. In: *Revista Brasileira de História*, São Paulo, Vol. 40, No. 85, pp. 147-170, 2020.
- VASWANI, Ashish et al. *Attention is all you need*. arXiv:1706.03762v5 [cs.CL], 2017.
- WARK, Mckenzie. *O capital está morto*. São Paulo: Editora Funilaria e sobinfluência edições, 2022.
- WEVERS, Melvin; KOOLEN, Marijn. Digital Begriffsgeschichte: tracing semantic change using word embeddings. *Historical Methods: A Journal of Quantitative and Interdisciplinary History*, Vol. 53, No. 4, pp. 226-243, 2020.

AS PALAVRAS E OS TOKENS

*projeção vetorial aplicada ao estudo da semântica dos tempos históricos*

Artigo recebido em 30/04/24 • Aceito em 20/06/24

DOI | doi.org/10.5216/rth.v27i1.79370

Revista de Teoria da História | issn 2175-5892



Este é um artigo de acesso livre distribuído nos termos da licença *Creative Commons Attribution*, que permite uso irrestrito, distribuição e reprodução em qualquer meio, desde que o trabalho original seja citado de modo apropriado